

UNIVERSIDADE FEDERAL DO PARANÁ

LUCAS REZENDE GOMIDE

PLANEJAMENTO FLORESTAL ESPACIAL

CURITIBA

2009

LUCAS REZENDE GOMIDE

PLANEJAMENTO FLORESTAL ESPACIAL

**Tese apresentada como requisito parcial à
obtenção do grau de Doutor, pelo
Programa de Pós-Graduação em
Engenharia Florestal - Área Manejo
Florestal, do Setor de Ciências Agrárias da
Universidade Federal do Paraná.**

Orientador:

Prof. Dr. Julio Eduardo Arce

Coorientador:

Prof. Dr. Arinei Carlos Lindbeck da Silva

CURITIBA

2009

“Quando aprenderes uma lição, tens de repeti-la até que a mente física consiga capturá-la; de outro modo, a lição não se torna parte da consciência”.

Sri Aurobindo

Aos meus familiares e companheiros de caminho

DEDICO

AGRADECIMENTOS

O autor expressa os seus sinceros agradecimentos à fonte criadora e inspiradora dos universos locais e distantes, Deus. Às hierarquias e outras formas divinas que nos ajudam no plano físico. Aos meus pais (Márcio e Lenilce) e irmãs (Andrea e Fernanda) que souberam irradiar um amor incondicional a minha pessoa.

Ao Professor Dr. Julio Arce, pela orientação tranqüila, contínua, eficaz e eficiente durante todo o período desta obra, bem como os proveitosos ensinamentos científicos, didáticos e culturais compartilhados, além de possuir um excelente senso de humor.

À Universidade Federal do Paraná por proporcionar a expansão do meu saber, e manter sempre suas portas abertas ao desenvolvimento científico qualificado. Ao órgão financiador CNPq pela concessão da bolsa de estudo durante este vínculo com a UFPR.

Aos Professores Dr. Arinei Carlos Lindbeck da Silva pelos incentivos e desafios lançados na programação computacional, tendo um papel importante no desenvolvimento das ferramentas de análise da tese; Dr. Celso Carnieri pelo rico arcabouço de conhecimento em otimização e PL, compartilhados durante suas aulas; Dra. Maria Teresinha Arns Steiner pelos brilhantes ensinamentos ligados a PLI; Dr. José Roberto S. Scolforo pelas importantes conversas iniciais. Aos professores do Departamento de Ciências Florestais em especial aos Professores Dr. Sebastião do Amaral Machado e Dr. Afonso Figueiredo Filho pelos conhecimentos divididos e amizade formada. Aos membros da banca pela ajuda na melhoria da Tese.

Ao pessoal técnico da empresa Votorantim Celulose e Papel S/A, Eng^o Davi Rodrigues de Souza, o Eng^o Honório Kanegae Júnior, o Eng^o Márcio Barbosa da Conceição, e os funcionários José Carlos da Rosa e Reginaldo Soares de Freitas, pela disponibilização da área de estudo e apoio financeiro.

Aos funcionários do Departamento de Ciências Florestais, Reinaldo e Davi, e à secretária do CESEC-UFPR, Maristela, bem como aos bibliotecários da UFPR e demais servidores.

As minhas eternas vizinhas Silviana, Fernanda e Érika, por fazerem parte de minha família em Curitiba. Além é claro do amigo Antônio Américo. Aos colegas Marco Aurélio e Tiago Vettori que dividiram o mesmo teto comigo, durante um período.

Aos excelentes amigos do curso de pós-graduação representados por: Éder, Saulo, Mauro, Rode, Mário, Chico, Lorena, Dani, Andrea, Helena, Dirceu, Djason, Denise e tantos outros. E principalmente aos colegas de futebol, pelos momentos de descontração vividos, representados pelos “craques”: Reinaldo (atacante), Romano (lateral) e Márcio (goleiro).

SUMÁRIO

LISTA DE TABELAS	vi
LISTA DE FIGURAS	viii
LISTA DE GRÁFICOS	viii
LISTA DE ANEXOS	xv
RESUMO GERAL	1
GENERAL SUMMARY	2
I. INTRODUÇÃO GERAL	3
II. OBJETIVO GERAL	5
III. ESTRUTURA DO TRABALHO	6
CAPÍTULO 1: O ESTADO DA ARTE	7
1. REVISÃO DE LITERATURA	8
1.1 PLANEJAMENTO FLORESTAL	8
1.1.1 Ferramentas de planejamento florestal	10
1.1.2 Visualizadores 3D no planejamento florestal	12
1.1.3 Planejamento florestal espacial	14
1.1.4 Agendamento da colheita florestal	16
1.2 Paisagem	16
1.2.1 Impacto visual sobre a paisagem	17
1.2.2. Modelando a paisagem florestal	18
1.2.2.1 Adjacência	19
1.2.2.1.1 <i>Unit restriction model</i> (URM)	21
1.2.2.1.2 <i>Area restriction model</i> (ARM)	23
1.3 PROGRAMAÇÃO LINEAR	25
1.3.1 Programação Linear Inteira/Mista (PLI/PLIM)	27
1.4 HEURÍSTICAS E METAHEURÍSTICAS	30
1.4.1 Busca de soluções	33
1.4.2 Algoritmo genético (AG)	37
1.4.2.1 Histórico de desenvolvimento	37
1.4.2.2 Idéias biológicas e evolutivas introduzidas no algoritmo	39
1.4.2.3 Princípio de funcionamento	41
1.4.2.4 Processo de codificação	43
1.4.2.5 Função de avaliação (<i>fitness</i>)	43

1.4.2.6 População	44
1.4.2.7 Operadores.....	45
1.4.2.7.1 Operadores evolutivos de seleção.....	45
1.4.2.7.2 Operadores genéticos de reprodução (<i>Crossover</i>).....	47
1.4.2.7.3 Operadores genéticos de mutação	48
1.4.2.8 <i>Replacement</i>	49
1.4.2.9 Critério de parada	50
1.4.2.10 Vantagens e desvantagens	51
1.4.3 <i>Simulated annealing</i> (SA)	52
1.4.3.1 Histórico de desenvolvimento	52
1.4.3.2 Solução inicial	55
1.4.3.3 Critério de Metropolis	56
1.4.3.4 Processos térmicos.....	56
1.4.3.5 Critério de Parada	58
1.4.3.6 Vantagens e desvantagens	58
1.4.4 Aplicações das metaheurísticas na otimização de recursos florestais	59
2. REFERÊNCIA BIBLIOGRÁFICA.....	61
CAPÍTULO 2: ESTUDO E MODELAGEM DOS PARÂMETROS PRESENTES NA METAHEURÍSTICA ALGORITMO GENÉTICO	81
RESUMO	82
ABSTRACT	83
1. INTRODUÇÃO.....	84
2. OBJETIVO	86
3. MATERIAL E MÉTODOS.....	87
3.1 ÁREA DE ESTUDO	87
3.2 DESCRIÇÃO DO PROBLEMA COMO BASE EXPERIMENTAL.....	87
3.3 ALGORITMO GENÉTICO	89
3.3.1 Codificação	90
3.3.2 Função de avaliação.....	92
3.3.3 População inicial	93
3.3.4 Operadores de seleção	93
3.3.4.1 Aleatório salvacionista	93
3.3.4.2 Roleta.....	94

3.3.4.3 Amostragem estocástica universal	96
3.3.4.4 Sigma <i>truncation scaling</i>	97
3.3.5 Operador genético.....	98
3.3.5.1 <i>Crossover</i>	98
3.3.5.2 Mutação	99
3.3.6 <i>Replacement</i>	100
3.3.7 Critério de parada	102
3.4 IMPLEMENTAÇÃO COMPUTACIONAL E PROCESSAMENTO	102
3.5 ANÁLISE DOS DADOS	103
4. RESULTADOS E DISCUSSÃO	103
5. CONCLUSÃO.....	116
6. REFERÊNCIA BIBLIOGRÁFICA.....	118
CAPÍTULO 3: ESTUDO E MODELAGEM DOS PARÂMETROS PRESENTES NA METAHEURÍSTICA <i>SIMULATED ANNEALING</i>	122
RESUMO	123
ABSTRACT	124
1. INTRODUÇÃO.....	125
2. OBJETIVO	127
3. MATERIAL E MÉTODOS.....	128
3.1 ÁREA DE ESTUDO	128
3.2 DESCRIÇÃO DO PROBLEMA COMO BASE EXPERIMENTAL	128
3.3 <i>SIMULATED ANNEALING</i>	130
3.3.1 Codificação da <i>string</i>	131
3.3.2 Função de avaliação.....	132
3.3.3 Solução inicial	133
3.3.4 Parâmetros testados	133
3.3.4.1 Função de resfriamento	133
3.3.4.2 Distância de busca local	135
3.3.5 Processos testados	135
3.3.5.1 <i>Simulated annealing</i> tradicional	135
3.3.5.2 Aquecimento.....	136
3.3.5.3 Explorar a vizinhança de busca	138
3.3.5.4 Combinação	139

3.3.6 Critério de Parada	140
3.4 IMPLEMENTAÇÃO COMPUTACIONAL E PROCESSAMENTO	140
3.5 ANÁLISE E RESUMO DOS TESTES	141
4. RESULTADOS E DISCUSSÃO	141
5. CONCLUSÃO	151
6. REFERÊNCIA BIBLIOGRÁFICA	153
CAPÍTULO 4: AGENDAMENTO DA COLHEITA FLORESTAL UTILIZANDO O	
CONCEITO DE PLANEJAMENTO FLORESTAL ESPACIAL	156
RESUMO	157
ABSTRACT	158
1. INTRODUÇÃO	159
2. OBJETIVO	162
3. MATERIAL E MÉTODOS	163
3.1 ÁREA DE ESTUDO	163
3.2 AGENDAMENTO DA COLHEITA FLORESTAL	163
3.2.1 O problema	163
3.2.2 A vizinhança	166
3.2.3 Simulação de cenários florestais	168
3.3 MÉTODOS DE RESOLUÇÃO	169
3.3.1 Programação linear inteira	169
3.3.2 Metaheurísticas	170
3.3.2.1 Algoritmo genético	170
3.3.2.2 <i>Simulated annealing</i>	171
3.4 FORMULAÇÃO MATEMÁTICA	171
3.4.1 Caso 1	171
3.4.2 Caso 2	174
3.4.3 Casos 3 e 4	178
3.5 IMPLEMENTAÇÃO COMPUTACIONAL E PROCESSAMENTO	184
4. RESULTADOS E DISCUSSÃO	185
4.1 A FLORESTA	185
4.2 PLANEJAMENTO FLORESTAL	186
4.3 EXEMPLO APLICADO	203
5. CONCLUSÃO	207

6. REFERÊNCIA BIBLIOGRÁFICA.....	209
ANEXOS	212

LISTA DE TABELAS

TABELA 1	ESTRUTURA RESUMIDA DOS CAPÍTULOS PRESENTES NA TESE.	6
TABELA 2	SUBTIPOS DE RESTRIÇÕES DE ADJACÊNCIA EMPREGADOS NO MODELO DE PLANEJAMENTO FLORESTAL.	21
TABELA 3	CLASSIFICAÇÃO DAS METAHEURÍSTICAS SEGUNDO A ESTRATÉGIA DE FUNCIONAMENTO (ADAPTADO DE STÜTZLE, 1998).	32
TABELA 4	TERMOS E RELAÇÕES ENTRE OS PROCESSOS FÍSICOS E A OTIMIZAÇÃO VIA METAHEURÍSTICA <i>SIMULATED ANNEALING</i>	54
TABELA 5	RELAÇÃO ENTRE A CODIFICAÇÃO EMPREGADA NO ALGORITMO GENÉTICO E AS ALTERNATIVAS DE MANEJO ESTABELECIDAS PARA UMA FLORESTA HIPOTÉTICA.	91
TABELA 6	MELHORES CONFIGURAÇÕES ENCONTRADAS PARA O AG FIXANDO OS QUATRO OPERADORES DE SELEÇÃO.	105
TABELA 7	PIORES CONFIGURAÇÕES ENCONTRADAS PARA O AG FIXANDO OS QUATRO OPERADORES DE SELEÇÃO.	106
TABELA 8	RESUMO DAS MELHORES SOLUÇÕES MÉDIAS OBTIDAS POR CADA ESTRATÉGIAS DA METAHEURÍSTICA SA APLICADA.	142
TABELA 9	TIPO DE FUNÇÃO DE RESFRIAMENTO E SUAS MELHORES MÉDIAS DE ENERGIA OBTIDA.	146
TABELA 10	DESCRIÇÃO DOS CASOS DE PLANEJAMENTO FLORESTAL RETRATADOS PARA A ANÁLISE.	165
TABELA 11	ESTRUTURA DOS 32 CENÁRIOS FLORESTAIS APLICADOS NO ESTUDO.	169
TABELA 12	ESTRUTURA ETÁRIA DA FLORESTAL ESTUDADA.	185
TABELA 13	CLASSIFICAÇÃO DA PRODUTIVIDADE VOLUMÉTRICA E SUA OCUPAÇÃO NOS TALHÕES.	185

TABELA 14	NÚMERO DE RESTRIÇÕES PRESENTES NO MODELO ABRANGENDO O PLANEJAMENTO FLORESTAL TRADICIONAL E O ESPACIAL NOS CASOS ESTUDADOS.	187
TABELA 15	NÚMERO DE VARIÁVEIS DE DECISÃO PRESENTES NO MODELO DE PLI CONSIDERANDO O PLANEJAMENTO FLORESTAL TRADICIONAL E O ESPACIAL.	189
TABELA 16	NÚMERO DE RAMIFICAÇÕES GERADAS PELO ALGORITMO <i>BRANCH-AND-BOUND</i> ATÉ 4 HORAS DE PROCESSAMENTO NO SOFTWARE LINGO.	190
TABELA 17	EFICÁCIA DO ALGORITMO GENÉTICO EM ATENDER AS METAS NO PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL.	195
TABELA 18	COMPORTAMENTO MÉDIO DO NÚMERO DE ITERAÇÕES E DO TEMPO DE PROCESSAMENTO AO LONGO DOS CENÁRIOS PROCESSADOS PELO ALGORITMO GENÉTICO.	196
TABELA 19	EFICÁCIA DA METAHEURÍSTICA <i>SIMULATED ANNEALING</i> EM ATENDER AS METAS NO PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL.	197
TABELA 20	TEMPO MÉDIO EM SEGUNDOS REQUERIDO PARA A OBTENÇÃO DE SOLUÇÕES VIA METAHEURÍSTICA <i>SIMULATED ANNEALING</i>	198
TABELA 21	LISTA DE TALHÕES OCIOSOS EM CADA MÉTODO DE PROCESSAMENTO.	201
TABELA 22	DESVIO PERCENTUAL TOTAL DA PRODUÇÃO VOLUMÉTRICA DOS CASOS 2, 3 E 4 FRENTE AO CASO 1 NOS TRÊS MÉTODOS DE RESOLUÇÃO.	203
TABELA 23	INFORMAÇÕES COMPARATIVAS DE VOLUME PRODUZIDO ENTRE O PLANEJAMENTO FLORESTAL ESPACIAL E O PLANEJAMENTO FLORESTAL TRADICIONAL NO SEGUNDO ANO.	204
TABELA 24	LISTA DE TALHÕES DESTINADOS À COLHEITA FLORESTAL ENVOLVENDO OS 4 CENÁRIOS PROPOSTOS E O SEGUNDO ANO DO HORIZONTE DE PLANEJAMENTO.	205

LISTA DE FIGURAS

FIGURA 1	FLUXOGRAMA DA ESTRUTURA HIERÁRQUICA DE FUNCIONAMENTO DO PLANEJAMENTO FLORESTAL (ADAPTADO DE MITCHELL, 2004).....	10
FIGURA 2	VISUALIZADOR DE PAISAGENS FLORESTAIS E SUAS SAÍDAS GRÁFICAS EM DIFERENTES CENÁRIOS (FONTE: FALCÃO, 2004).	13
FIGURA 3	VISUALIZAÇÃO DE DIFERENTES CENÁRIOS FLORESTAIS (FONTE: MEITNER <i>et al.</i> , 2005).	13
FIGURA 4	EXEMPLO ILUSTRATIVO DO AGENDAMENTO DA COLHEITA FLORESTAL CONSIDERANDO DUAS SITUAÇÕES DE RESPOSTA (FACTÍVEL/INFACTÍVEL) FRENTE À RESTRIÇÃO ARM.....	23
FIGURA 5	DIFERENÇA ENTRE A PROGRAMAÇÃO LINEAR E A PROGRAMAÇÃO LINEAR INTEIRA (ADAPTADO DE HILLIER e LIEBERMAN, 2001).	28
FIGURA 6	ILUSTRAÇÃO DO PROCESSO DE BUSCA DE SOLUÇÃO INTEIRA (VARIÁVEL X_1) PELO ALGORITMO <i>BRANCH-AND-BOUND</i> (ADAPTADO DE HILLIER E LIEBERMAN, 2001).....	29
FIGURA 7	DISTRIBUIÇÃO DAS ÁREAS LIGADAS A COMPUTAÇÃO NATURAL (VICTORINO, 2005).	31
FIGURA 8	REPRESENTAÇÃO DO ESPAÇO DE SOLUÇÕES E SUA DIVERSIDADE DE RESPOSTAS (ADAPTADO DE ASHLOCK, 2005).	34
FIGURA 9	REPRESENTAÇÃO GENÉRICA DE UM PROCESSO HEURÍSTICO QUE REALIZA BUSCAS ATRAVÉS DE UMA ÚNICA SOLUÇÃO POR ITERAÇÃO (ADAPTADO DE MURRAY, 1999).	35
FIGURA 10	ESTRUTURA DE FUNCIONAMENTO DE UMA HEURÍSTICA EVOLUTIVA GENÉRICA COM BASE NO MÉTODO DE BUSCA POR POPULAÇÃO (ADAPTADO DE ASHLOCK, 2005).	36

FIGURA 11	ESTRUTURA DE FUNCIONAMENTO DE UM ALGORITMO GENÉTICO SIMPLES.	38
FIGURA 12	EXEMPLO DA NOMENCLATURA E CODIFICAÇÃO EMPREGADA NO ALGORITMO GENÉTICO.	40
FIGURA 13	EXEMPLO DE FUNCIONAMENTO DE DOIS TIPOS DE OPERADORES GENÉTICOS DE REPRODUÇÃO.	48
FIGURA 14	EXEMPLO DE FUNCIONAMENTO DO OPERADOR GENÉTICO DE MUTAÇÃO.	48
FIGURA 15	ESTRUTURA GERAL DA METAHEURÍSTICA <i>SIMULATED ANNEALING</i> (ADAPTADO DE BUCKHAM E LAMBERT, 1999).	55
FIGURA 16	MAPA DA LOCALIZAÇÃO DA ÁREA DE ESTUDO NO ESTADO DE SÃO PAULO.	87
FIGURA 17	EXEMPLIFICAÇÃO DA CODIFICAÇÃO BINÁRIA UTILIZADA NO ALGORITMO GENÉTICO PARA O PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL	90
FIGURA 18	SELEÇÃO DO INDIVÍDUO 1 (a) E 5 (b) DA POPULAÇÃO A PARTIR DE DUAS RODADAS DA AGULHA DA ROLETA.	95
FIGURA 19	SELEÇÃO DOS INDIVÍDUOS {1, 1, 3 e 5} DA POPULAÇÃO CONSIDERANDO MÚLTIPLAS AGULHAS.	96
FIGURA 20	ESTRATÉGIA DE <i>CROSSOVER</i> ADOTADA NA RECOMBINAÇÃO DE GENES ENTRE CROMOSSOMOS.	99
FIGURA 21	EXEMPLO DE APLICAÇÃO DE UMA MUTAÇÃO SIMPLES NA FORMAÇÃO DE UM NOVO INDIVÍDUO PARA A POPULAÇÃO.	100
FIGURA 22	<i>LAYOUT</i> DO <i>PCFLORESTAL</i> NA OPÇÃO DE PROCESSAMENTO UTILIZANDO O ALGORITMO GENÉTICO.	103
FIGURA 23	MAPA DA LOCALIZAÇÃO DA ÁREA DE ESTUDO NO ESTADO DE SÃO PAULO.	128
FIGURA 24	EXEMPLIFICAÇÃO DA CODIFICAÇÃO BINÁRIA UTILIZADA NA <i>STRING</i> PERTENCENTE À METAHEURÍSTICA SA.	131
FIGURA 25	ESTRUTURA DE FUNCIONAMENTO DE BUSCA DA METAHEURÍSTICA <i>SIMULATED ANNEALING</i>	136

FIGURA 26	ESTRUTURA DE FUNCIONAMENTO DE BUSCA DA METAHEURÍSTICA <i>SIMULATED ANNEALING</i> APLICANDO A ESTRATÉGIA DE AQUECIMENTO.	137
FIGURA 27	ESTRUTURA DE FUNCIONAMENTO DA METAHEURÍSTICA <i>SIMULATED ANNEALING</i> APLICANDO A ESTRATÉGIA DE EXPLORAR MAIS A VIZINHANÇA DE BUSCA DAS MELHORES SOLUÇÕES.....	139
FIGURA 28	LAYOUT DO PROGRAMA PCFLORESTAL DESENVOLVIDO PARA A REALIZAÇÃO DOS TESTES DIRECIONADOS À METAHEURÍSTICA <i>SIMULATED ANNEALING</i>	140
FIGURA 29	MAPA DA LOCALIZAÇÃO DA ÁREA DE ESTUDO NO ESTADO DE SÃO PAULO.	163
FIGURA 30	MAPA DA VIZINHANÇA ENTRE UNIDADES DE MANEJO FLORESTAL PRESENTE EM UMA PORÇÃO DA ÁREA DE ESTUDO E SUAS INFORMAÇÕES DE ÁREA.	165
FIGURA 31	EXEMPLO DOS TIPOS DE VIZINHANÇA ENTRE TALHÕES RECORRENTE NA ÁREA DE ESTUDO.	167

LISTA DE GRÁFICOS

GRÁFICO 1	NÚMERO DE ARTIGOS PUBLICADOS E RELACIONADOS A ASPECTOS ESPACIAIS/NÃO ESPACIAIS PUBLICADOS PELAS REVISTAS AMERICANAS DO GÊNERO FLORESTAL (ADAPTADO DE BETTINGER E CHUNG, 2004).....	14
GRÁFICO 2	INFLUÊNCIA DOS OPERADORES DE SELEÇÃO NA QUALIDADE DA RESPOSTA GERADA PELO AG, CONSIDERANDO UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS, <i>STEADY STATE</i> 3 E TAXA DE ALTERAÇÃO GÊNICA NA MUTAÇÃO (1) 10% E (2) 20%.....	104
GRÁFICO 3	COMPORTAMENTO DAS TAXAS DE ALTERAÇÃO GÊNICA NA MUTAÇÃO A PARTIR DE UMA POPULAÇÃO INICIAL DE 100 INDIVÍDUOS E <i>STEADY STATE</i> 1.....	106
GRÁFICO 4	COMPORTAMENTO DAS TAXAS DE ALTERAÇÃO GÊNICA NA MUTAÇÃO A PARTIR DE UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS E <i>STEADY STATE</i> 1.....	107
GRÁFICO 5	INFLUÊNCIA DA TAXA DE <i>REPLACEMENT</i> NA QUALIDADE DA RESPOSTA CONSIDERANDO UMA POPULAÇÃO INICIAL DE 100 INDIVÍDUOS E ALTERAÇÕES GÊNICAS DE 20% NA MUTAÇÃO.....	108
GRÁFICO 6	EFEITO DA POPULAÇÃO INICIAL NAS OPÇÕES DE <i>REPLACEMENT</i> CONSIDERANDO UMA TAXA DE ALTERAÇÃO DE 10 % NA MUTAÇÃO E USO DA AMOSTRAGEM ESTOCÁSTICA UNIVERSAL COMO OPERADOR DE SELEÇÃO.....	108
GRÁFICO 7	EFEITO DA TAXA DE ALTERAÇÃO GÊNICA NA MUTAÇÃO EM OPÇÕES DE <i>REPLACEMENT</i> CONSIDERANDO UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS E USO DO OPERADOR DE SELEÇÃO ALEATÓRIO SALVACIONISTA.....	109
GRÁFICO 8	EFEITO DA POPULAÇÃO INICIAL AO <i>FITNESS</i> CONSIDERANDO UMA TAXA DE ALTERAÇÃO GÊNICA DE 10% NA MUTAÇÃO E OPÇÃO <i>STEADY STATE</i> 1.....	110

GRÁFICO 9	EFEITO DAS TAXAS DE TROCAS GÊNICAS PELO <i>CROSSOVER</i> NA QUALIDADE DO <i>FITNESS</i> CONSIDERANDO UMA TAXA DE ALTERAÇÃO GÊNICA DE 20% NA MUTAÇÃO, OPÇÃO <i>STEADY STATE 3</i> , POPULAÇÃO INICIAL DE 200 INDIVÍDUOS E USO DA AMOSTRAGEM ESTOCÁSTICA UNIVERSAL COMO OPERADOR DE SELEÇÃO.....	111
GRÁFICO 10	INFLUÊNCIA DA POPULAÇÃO INICIAL NO TEMPO DE PROCESSAMENTO CONSIDERANDO A CONFIGURAÇÃO: <i>STEADY STATE 2</i> , AMOSTRAGEM ESTOCÁSTICA UNIVERSAL COMO OPERADOR DE SELEÇÃO E TAXA DE ALTERAÇÃO GÊNICA DE 20% NA MUTAÇÃO.....	112
GRÁFICO 11	COMPORTAMENTO DO TEMPO DE EXECUÇÃO POR OPERADOR SEGUINDO A CONFIGURAÇÃO: <i>STEADY STATE 2</i> , POPULAÇÃO INICIAL DE 100 E TAXA DE ALTERAÇÃO GÊNICA DE 20% NA MUTAÇÃO.....	112
GRÁFICO 12	COMPORTAMENTO DO TEMPO DE EXECUÇÃO EM RELAÇÃO A TAXA DE ALTERAÇÃO GÊNICA NA MUTAÇÃO SEGUINDO A CONFIGURAÇÃO: <i>STEADY STATE 2</i> , AMOSTRAGEM ESTOCÁSTICA UNIVERSAL E POPULAÇÃO INICIAL DE 200 INDIVÍDUOS.....	113
GRÁFICO 13	INFLUÊNCIA DAS OPÇÕES DE <i>REPLACEMENT</i> NO TEMPO DE PROCESSAMENTO FIXANDO A SEGUINTE CONFIGURAÇÃO: OPERADOR DE SELEÇÃO ROLETA, TAXA DE ALTERAÇÃO GÊNICA DE 20% E POPULAÇÃO INICIAL DE 100 INDIVÍDUOS....	113
GRÁFICO 14	INFLUÊNCIA DA POPULAÇÃO INICIAL NA VARIAÇÃO DO <i>FITNESS</i> CONSIDERANDO A OPÇÃO <i>STEADY STATE 3</i> , TAXA DE ALTERAÇÃO DE 10% NA MUTAÇÃO E O USO DO OPERADOR AMOSTRAGEM ESTOCÁSTICA UNIVERSAL.....	114
GRÁFICO 15	INFLUÊNCIA DA TAXA DE <i>REPLACEMENT</i> NA VARIAÇÃO DO <i>FITNESS</i> CONSIDERANDO UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS, TAXA DE ALTERAÇÃO GÊNICA DE 10% NA MUTAÇÃO E USO DO OPERADOR AMOSTRAGEM ESTOCÁSTICA UNIVERSAL.....	115

GRÁFICO 16	RESFRIAMENTO DA TEMPERATURA ATRAVÉS DAS TRÊS FUNÇÕES TESTADAS AO LONGO DAS ITERAÇÕES.	135
GRÁFICO 17	INFLUÊNCIA DO AQUECIMENTO NA QUALIDADE DA ENERGIA MÉDIA DO SISTEMA (AQ1 - AQUECIMENTO1; AQ2 - AQUECIMENTO2 E TRAD - TRADICIONAL).....	142
GRÁFICO 18	COMPARAÇÃO ENTRE AS ESTRATÉGIAS DE EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).	143
GRÁFICO 19	COMPARAÇÃO ENTRE AS COMBINAÇÕES ESTRATÉTICAS AQUECIMENTO1 + EXPLORAR MELHOR A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (AQ1- AQUECIMENTO1; B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).	144
GRÁFICO 20	COMPARAÇÃO ENTRE AS COMBINAÇÕES ESTRATÉTICAS AQUECIMENTO2 + EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (AQ1- AQUECIMENTO1; B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).	145
GRÁFICO 21	COMPARAÇÃO ENTRE AS MELHORES OPÇÕES SELECIONADAS DA COMBINAÇÃO ENTRE AQUECIMENTO + EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (AQ1- AQUECIMENTO1; AQ2- AQUECIMENTO2; B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).....	146
GRÁFICO 22	INFLUÊNCIA DAS FUNÇÕES DE RESFRIAMENTO NA QUALIDADE DAS SOLUÇÕES GERADAS PELA METAHEURÍSTICA SA.....	147

GRÁFICO 23	INFLUÊNCIA DA VIZINHANÇA DE BUSCA NO VALOR DA ENERGIA MÉDIA PRODUZIDA PELA METAHEURÍSTICA SA.....	147
GRÁFICO 24	INFLUÊNCIA DAS TAXAS DE VIZINHANÇA DE BUSCA NA REDUÇÃO PERCENTUAL DA ENERGIA MÉDIA OBTIDA PELA METAHEURÍSTICA SA.....	148
GRÁFICO 25	EFEITO DA VARIAÇÃO NA TAXA DE VIZINHANÇA DE BUSCA EM RELAÇÃO AO TEMPO DE PROCESSAMENTO NA METAHEURÍSTICA SA.....	148
GRÁFICO 26	EFEITO DA VIZINHANÇA DE BUSCA NA VARIAÇÃO MÉDIA DAS SOLUÇÕES OBTIDAS PELA METAHEURÍSTICA SA.....	149
GRÁFICO 27	COMPORTAMENTO VOLUMÉTRICO DA PRODUÇÃO E CRESCIMENTO DA FLORESTA A PARTIR DA IDADE DE 5 ANOS.....	186
GRÁFICO 28	NÚMERO DE ALTERNATIVAS DE MANEJO DISPONÍVEIS NO PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL COM O AUMENTO DO HORIZONTE DE PLANEJAMENTO.	186
GRÁFICO 29	EXEMPLO DE AMPLIAÇÃO DA FLORESTA CONSIDERANDO SEUS IMPACTOS NO NÚMERO DE RESTRIÇÕES DO MODELO DE PLI.	189
GRÁFICO 30	TEMPO DE PROCESSAMENTO DOS CASOS ESTUDADOS CONSIDERANDO UM LIMITE DE 4 HORAS DE EXECUÇÃO.	191
GRÁFICO 31	DESVIO PERCENTUAL DO VPL ENTRE O PLANEJAMENTO FLORESTAL TRADICIONAL (CASO 1) E O PLANEJAMENTO FLORESTAL ESPACIAL (CASOS 2, 3 E 4).....	193
GRÁFICO 32	DESVIO PERCENTUAL DO VPL ENTRE OS MÉTODOS DE APROXIMAÇÃO E O EXATO AO LONGO DO HP.	199
GRÁFICO 33	TEMPO DE PROCESSAMENTO REQUERIDO PELOS 3 MÉTODOS PARA OS CENÁRIOS DO CASO 1.	203

LISTA DE ANEXOS

ANEXO 1	FLUXOGRAMA DAS COMBINAÇÕES DE PARÂMETROS TESTADOS NO ALGORITMO GENÉTICO.....	213
ANEXO 2	FLUXOGRAMA DAS COMBINAÇÕES DE PARÂMETROS TESTADOS NA METAHEURÍSTICA SIMULATED ANNEALING....	214
ANEXO 3	LISTA DE TALHÕES PRESENTES NA FLORESTA ABRANGENDO AINDA SUA RESPECTIVA ÁREA E SEUS VIZINHOS.....	215
ANEXO 4	MAPA DE IDENTIFICAÇÃO DA VIZINHANÇA ENTRE TALHÕES PRESENTE NA ÁREA DE ESTUDO E SUAS RESPECTIVAS ÁREAS.....	216
ANEXO 5	EXEMPLO DE UMA ÁRVORE DE ALTERNATIVAS DE MANEJO PARA UM HORIZONTE DE PLANEJAMENTO DE 14 ANOS.....	217
ANEXO 6	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 7 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.....	218
ANEXO 7	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 8 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.....	219
ANEXO 8	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 9 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.....	220
ANEXO 9	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 10 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.....	221
ANEXO 10	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 11 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.....	222
ANEXO 11	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 12 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.....	223

ANEXO 12	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 13 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.	224
ANEXO 13	STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 14 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.	225
ANEXO 14	VALORES ABSOLUTOS E DESVIOS (%) DE VPL PARA OS 32 CENÁRIOS FORMULADOS VIA PLI.	226
ANEXO 15	VALORES ABSOLUTOS DE VPL CALCULADOS PARA OS 32 CENÁRIOS FORMULADOS VIA ALGORITMO GENÉTICO.	226
ANEXO 16	VALORES ABSOLUTOS DE VPL CALCULADOS PARA OS 32 CENÁRIOS FORMULADOS VIA METAHEURÍSTICA <i>SIMULATED ANNEALING</i>	227
ANEXO 17	GRÁFICO DO COMPORTAMENTO DE BUSCAS DO ALGORITMO GENÉTICO PARA O CASO 3 CONSIDERANDO UM HP DE 7 ANOS.	228
ANEXO 18	GRÁFICO DO COMPORTAMENTO DE BUSCAS DO <i>SIMULATED ANNEALING</i> PARA O CASO 3 CONSIDERANDO UM HP DE 7 ANOS.	228
ANEXO 19	COMPORTAMENTO VOLUMÉTRICO PARA OS 4 CASOS CONSIDERANDO OS 3 MÉTODOS DE RESOLUÇÃO E UM HP DE 7 ANOS.	229
ANEXO 20	COMPORTAMENTO VOLUMÉTRICO PARA OS 4 CASOS CONSIDERANDO OS 3 MÉTODOS DE RESOLUÇÃO E UM HP DE 14 ANOS.	230
ANEXO 21	MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 1 VIA PLI.	231
ANEXO 22	MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 2 VIA PLI.	232

ANEXO 23	MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 3 VIA PLI.....	233
ANEXO 24	MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 4 VIA PLI.....	234
ANEXO 25	FOTOS DA ÁREA FLORESTAL DESTINADA AO ESTUDO	235

RESUMO GERAL

O planejamento florestal espacial é uma opção ainda nova no Brasil, porém antiga nos países desenvolvidos. A sua importância está relacionada à melhor compreensão e análise do talhão dentro da floresta, entendendo ainda suas relações espaciais com outros talhões e áreas vizinhas. A restrição de adjacência é um exemplo de controle espacial na colheita florestal e contribui para a redução de danos ao ambiente e à paisagem. Existem dois tipos de restrições de adjacência: 1) URM (*Unit Restriction Model*) - que impede a colheita de talhões adjacentes no mesmo período de tempo; e 2) ARM (*Area Restriction Model*) - que permite a colheita deste tipo de situação, desde que não ultrapasse um limite de área máxima estabelecida. Assim, o estudo teve como objetivo geral aplicar o planejamento florestal espacial, levando em consideração o problema de agendamento da colheita florestal. Além disso, analisar o grau de impacto econômico no VPL e na produção volumétrica de madeira, entre as opções de planejamento florestal tradicional e espacial e ainda testar a utilização do algoritmo genético (AG) e *simulated annealing* (SA) na resolução de cenários florestais, comparando com o método exato via programação linear inteira (PLI). Foram gerados 4 tipos de casos de planejamento distribuídos em 32 cenários florestais, tendo como referência o modelo tipo I de Johnson e Scheurmann (1977) e as restrições URM, ARM50 e ARM70. Os dados foram obtidos de um reflorestamento de eucalipto com 1.490 ha, contendo 52 talhões, pertencente à empresa VCP (Votorantim Celulose e Papel) na região de Caçapava-SP. Os métodos de resolução foram o AG, SA e PLI, porém houve a necessidade de modelar os parâmetros das metaheurísticas, através de testes para diferentes configurações. Os resultados mostraram que as metaheurísticas foram influenciadas pela configuração testada, onde a melhor configuração para o AG foi: população inicial (300 indivíduos), operador de seleção (amostragem estocástica universal), taxa de trocas gênicas pelo *crossover* (50%), taxa de alteração gênica na mutação (20%) e *replacement* (*steady state* 3 ou 50% de substituição); e para a metaheurística SA: o uso da opção *busca3*, função3 de resfriamento e porcentagem de 10% na taxa de vizinhança de busca. A utilização de restrições de adjacência aumenta o número de restrições dos modelos, principalmente quando são empregadas as restrições do tipo ARM 50 e 70. O uso do planejamento florestal espacial promoveu uma redução do VPL na faixa de 2,10% (caso 4) a 3,74% (caso 2), proporcionado pelas perdas volumétricas de madeira colhida. As metaheurísticas foram eficientes e eficazes na resolução dos cenários, onde os desvios percentuais de VPL em relação à PLI foram: AG 0,76% e SA 2,45% (caso 1), AG 13,60% e SA 6,02% (caso 2), AG 4,18% e SA 7,66% (caso 3) e AG 2,91% e SA 3,31% (caso 4) para os cenários com HP de 7 anos. No caso de problemas onde a PLI apresenta problemas em tempo de processamento, as metaheurísticas podem ser aplicadas como uma opção viável. Os casos de planejamento florestal espacial demonstram ser perfeitamente aptos e viáveis. As restrições de adjacência URM, ARM50 e ARM70 controlam as relações espaciais entre talhões e podem ser empregadas como uma opção no planejamento florestal.

Palavras-chave: Programação Linear Inteira, Metaheurísticas, Colheita Florestal.

GENERAL SUMMARY

Spatial forest planning is still a new option in Brazil, but old in the developed countries. Its importance is related to the better understanding and analysis of the stand within the forest, understanding, still, their space relationships with other stands and neighboring areas. The adjacency constraints are an example of space control in the forest harvest, and it contributes to environmental and landscape damage reduction. Two types of adjacency constraints exist: 1) URM (*Unit Restriction Model*) - it avoids the harvest of adjacent stands at the same period of time; 2) ARM (*Area Restriction Model*) - that it allows the harvest of this type of situation, as long as it does not cross an established limit of maximum area. As such, this study had, as general objective to apply the spatial forest planning, taking into account the forest harvest scheduling problem. An objective was also to analyze the degree of economic impact on the NPV and on the volumetric production of wood, between the traditional and spatial forest planning options. Another objective was to test the use of the genetic algorithm (GA) and simulated annealing (SA) on the resolution of forest scenarios, comparing with the exact method via complete linear programming (ILP). For this, 4 types of planning cases were generated, distributed in 32 forest scenarios, having as a reference, the type I model of Jonhson and Scheurmann (1977) and the URM, ARM50 and ARM70 constraints. The data were obtained from a reforestation with 1,490 ha of eucalyptus, containing 52 stands and belonging to the VCP (Votorantim Celulose e Papel) company in the area of Caçapava-SP. The resolution methods were GA, SA and ILP, however there was the need to model the metaheuristic parameters, through tests for different configurations. The results showed that the metaheuristics were influenced by the configuration tested, where the best configuration for GA was: initial population (300 individuals), selection operator (stochastic universal sampling), gene exchange rates by crossover (50%), rate of gene alteration in the mutation (20%) and replacement (steady state 3 or 50% of substitution); and the metaheuristic SA: the use of the option *busca3*, cooling função3 and percentage of 10% in the search neighborhood rate. The use of adjacency constraints increased the number of restrictions for the models, mainly when employing the constraints of the ARM 50 and 70 type. The use of spatial forest planning promoted a reduction of NPV in a range from 2.10% (case 4) to 3.74% (case 2), proportionate to the volumetric loss of harvested wood. The metaheuristics were efficient and effective in the resolution of the scenarios, where the percentile deviations of NPV in relation to ILP were: GA 0.76% and SA 2.45% (case 1), GA 13.60% and SA 6.02% (case 2), GA 4,18% and SA 7.66% (case 3) and GA 2.91% and SA 3.31% (case 4) for the 7 year HP scenario. In the case of large problems, where ILP is not applied, the metaheuristics can be applied as a viable option. The cases of spatial forest planning demonstrate to be perfectly capable and viable. The URM, ARM50 and ARM70 adjacency constraints control the space relationships among stands, and can be used as an option in forest planning.

Keywords: Spatial forest planning, ILP, Metaheuristics, Forest Harvest.

I. INTRODUÇÃO GERAL

Teorias e idéias matemáticas sempre fizeram parte do cotidiano no manejo florestal, influenciando os manejadores florestais na construção de modelos que expressam aspectos como o crescimento florestal, teor de carbono, biomassa, qualidade de sítio, ou até mesmo equações simples para a estimativa da altura de uma árvore. As respostas provenientes destes modelos sempre foram essenciais na mensuração de um dado recurso florestal, como por exemplo, o volume de madeira presente e futuro de uma floresta. No passado, essas técnicas de biometria florestal eram consideradas como o ponto final do processo, deixando uma lacuna de ligação entre o planejamento florestal e o consumidor final. Talvez o momento não permitisse esta união, devido à dificuldade ou inexistência de ferramentas computacionais, ou até mesmo à falta de conhecimento técnico sobre o assunto.

Além disso, os manejadores florestais tinham como idéia fixa encontrar o ótimo de cada talhão, ou seja, a melhor alternativa de manejo para um único e exclusivo talhão a cada análise. O resultado para este tipo de visão proporcionava problemas na estrutura da floresta, dificultando o estabelecimento de um plano de suprimento de madeira.

A formação de uma base sólida de planejamento florestal só foi possível através do desenvolvimento de um procedimento matricial de cálculo, criado por Dantzig na década de 40, e relacionado à programação linear. O criador do algoritmo simplex causou uma revolução, ao desenvolver um procedimento capaz de resolver problemas de grande escala e mais complexos. A partir deste marco, inúmeros trabalhos foram executados, destacando os trabalhos de Johnson e Scheurmann (1977) na área florestal. Esses autores reuniram os principais modelos matemáticos de planejamento florestal desenvolvidos, classificando-os em 2 tipos, sendo estes até hoje utilizados para regular as florestas em todo o mundo.

Os modelos de planejamento florestal desenvolvidos encontravam as melhores combinações de opções de manejo para o conjunto de talhões de uma floresta, regulando a produção da floresta. O talhão passou, então, a ser analisado como parte de um amplo sistema, e desde então não fazia mais sentido o ótimo para um único talhão.

O conceito de floresta regulada passou a ser amplamente utilizado na Europa e América do Norte, onde os processos florestais eram mais desenvolvidos. Esta nova fase da Engenharia Florestal proporcionou um maior cuidado dos bens florestais, definindo as melhores opções de se manejar o recurso. Neste momento, os manejadores florestais passaram a exigir técnicas mais refinadas, devido ao surgimento de problemas envolvendo variáveis

inteiras. Assim, paralelamente surgiu uma série de algoritmos exatos que cobririam esta deficiência, como o algoritmo *branch-and-bound*, o algoritmo de corte de Gomory, *branch and Cut* e relaxação lagrangeana.

Nas décadas de 60' e 70' o controle do planejamento florestal estratégico já estava considerado como resolvido, sendo consolidado pela existência de ferramentas computacionais no mercado, como: *Timber RAM*, *MaxMillion*, *MUSYC*, *FORPLAN* e outros. Entretanto, aspectos ambientais e sociais passaram a ganhar importância entre os países consumidores de produtos florestais, exigindo mudanças na conduta dos processos produtivos.

Logicamente, esta mudança afetou a maneira de se formular os problemas florestais tradicionais, pois agora outras idéias eram forçadamente absorvidas. Desta maneira, o controle das relações espaciais na floresta passou a ser um dos exemplos mais pesquisados, abrangendo restrições de manutenção de corredores ecológicos (FISCHER e CHURCH, 2003), restrições de índices de paisagem (HEINONEN *et al.*, 2007), restrições de blocos que trabalham a formação de grupos de talhões para facilitar a colheita (NELSON, 2001), outras restrições para problemas de *green-up* (BOSTON e BETTINGER, 2001a), restrições de adjacência (MURRAY, 1999), dentre outras opções. Assim, o planejamento florestal ganhou uma nova versão, sendo denominado de planejamento florestal espacial.

A nova versão de planejamento exige uma maior velocidade na geração de informações e o uso de algoritmos mais eficientes e eficazes se torna uma necessidade. Em virtude dos novos problemas foram introduzidos algoritmos inteligentes de aproximação no cenário florestal, para suprir certas deficiências de técnicas tradicionais. O pioneirismo florestal mais uma vez foi observado, ao incorporar o uso de recursos matemáticos avançados.

Os algoritmos de aproximação destinados à substituir os processos clássicos de otimização, quando estes não podem ser aplicados, passaram a sofrer evoluções constantes, principalmente na abordagem do número de variáveis retratadas e na eficiência. Hoje em dia, pode-se dizer que eles atingiram uma maturidade na resolução de problemas. Entretanto, muitos aspectos ainda devem ser estudados para permitir uma melhor adaptação ao problema e garantir respostas mais aproximadas do ótimo. O ponto chave desta adaptação está relacionado ao desenvolvimento e testes dos parâmetros dos algoritmos, nos quais uma simples combinação menos eficiente destes parâmetros pode levar a respostas divergentes, ou seja, atingir ótimos locais piores que o esperado.

II. OBJETIVO GERAL

O objetivo geral deste estudo foi abordar o funcionamento do planejamento florestal espacial na sua essência, tendo como ponto de comparação o planejamento florestal tradicional, muito difundido nas empresas ligadas à gestão de ativos florestais. O foco do planejamento florestal espacial retratado foi a questão da adjacência entre talhões ou unidades de manejo, utilizando as restrições do tipo URM e ARM. Neste sentido, um objetivo técnico e econômico foi formulado para analisar qual o impacto do planejamento florestal espacial no VPL e na produção volumétrica anual de madeira.

Além disso, foram equacionados outros objetivos específicos como:

- Modelar os parâmetros presentes no algoritmo genético (AG), como: tamanho da população inicial, tipo de operador de seleção, porcentagem de mutação, taxa de *crossover* e taxa de *replacement*, considerando um cenário de agendamento da colheita florestal como problema teste (*forest harvest scheduling problem*);
- Modelar os parâmetros presentes na metaheurística *simulated annealing* (SA), sendo: tipos de função de resfriamento e porcentagem da vizinhança de busca, como ainda estratégias de programação do algoritmo envolvendo aquecimento, explorar mais a vizinhança de busca das melhores soluções e a combinação de ambas as estratégias, considerando um cenário de agendamento da colheita florestal como problema teste (*forest harvest scheduling problem*);
- Analisar a capacidade do AG e SA na resolução de 32 cenários florestais envolvendo os dois tipos de planejamento florestal (tradicional e espacial), comparando suas soluções com as fornecidas pela programação linear inteira (PLI).

III. ESTRUTURA DO TRABALHO

O trabalho se divide em quatro capítulos, dispostos conforme a Tabela 1. O primeiro retrata o estado da arte, sendo uma revisão de literatura abordando os temas mais relevantes ao desenvolvimento e suporte da tese. Os capítulos 2 e 3 referem-se à modelagem dos parâmetros das metaheurísticas AG e SA em problemas de agendamento da colheita florestal. O quarto capítulo, considerado a parte mais aplicada da tese, consiste na resolução de 32 cenários florestais dimensionados para a questão de agendamento da colheita florestal. O foco desta última etapa foi aplicar formulações ligadas ao planejamento florestal espacial que incluíssem o controle da colheita através de restrições de adjacência. Neste aspecto foram testadas as restrições de adjacência do tipo URM e ARM, sendo as mesmas confrontadas com os resultados do planejamento florestal tradicional. As bases matemáticas dos casos foram restritos ao modelo tipo I de Johnson e Scheurmann (1977), apresentando uma função de maximização do VPL e restrições de fluxo de produção. Os métodos de processamento empregados foram AG, SA e PLI, sendo realizadas comparações entre os mesmos.

TABELA 1 - ESTRUTURA RESUMIDA DOS CAPÍTULOS PRESENTES NA TESE.

Capítulo	Objetivo	Metodologia	Restrições
1	Revisão de literatura	-	-
2	Modelar os parâmetros do AG	Foram testados diferentes tamanhos de população inicial, operadores de seleção, taxas de <i>crossover</i> , <i>replacement</i> e mutação no AG.	Controle do fluxo volumétrico anual de madeira.
3	Modelar os parâmetros da metaheurística SA e suas estratégias de programação.	Foram testadas funções de resfriamento, vizinhança de busca, e estratégias de programação do algoritmo envolvendo aquecimento, explorar mais a vizinhança das melhores soluções e a combinação destas 2 estratégias na metaheurística SA.	Controle do fluxo volumétrico anual de madeira.
4	Aplicar e comparar o planejamento florestal espacial e o planejamento florestal tradicional.	Foram criados 4 casos contendo 32 cenários florestais de agendamento da colheita florestal, aplicando o AG, SA e a PLI.	Controle do fluxo volumétrico anual de madeira e Adjacência (URM, ARM50 e ARM70).

CAPÍTULO 1

O ESTADO DA ARTE

1. REVISÃO DE LITERATURA

1.1 PLANEJAMENTO FLORESTAL

Analisando a estrutura de organização das empresas ao longo das décadas, percebe-se que o foco de suas atividades está permanentemente voltado para a sustentabilidade do empreendimento e dos recursos como um todo (ROCHA, 2002). Essa afirmativa inicial se encaixa perfeitamente no planejamento de qualquer empresa florestal, onde uma série de atividades é programada com a finalidade de gerar recursos financeiros/produtos no prazo estipulado de planejamento.

Segundo Rodriguez *et al.* (1997), a gestão do recurso florestal baseia-se nas intervenções florestais em cada unidade de manejo, promovendo mudanças na estrutura da floresta e na geração de recursos financeiros. Ilustrando a idéia citam-se operações de manejo florestal como desbastes, podas e corte raso; necessidades do mercado como qualidade, comprimento e padrão de toras; operações de transporte e roteamento de veículos, sendo todas estas atividades definidas previamente pelo planejador florestal.

Um conceito sobre planejamento florestal, em um estágio mais geral, afirma que o planejamento trabalha normalmente junto na definição de metas de produção, para períodos de tempo definidos, considerando previsões do mercado (preço e demanda), estoque e recursos disponíveis (BIREWAR, 1989). O planejamento florestal pode ser definido como uma identificação de atividades integradas, ao longo do tempo, e necessárias para atingir os objetivos dentro do manejo florestal (SESSIONS e BETTINGER, 2001).

A expressão conhecida como “planejamento florestal estratégico” foi definida na segunda metade do século passado por Ware e Clutter (1971) como “planejamento florestal”, e seu conceito está atualmente implícito em uma série de trabalhos relacionados ao tema, nos quais, na sua maioria, a sustentabilidade e a viabilidade do empreendimento sempre são analisadas. Buongiorno e Gilless (1987) afirmam que a viabilidade temporal de uma empresa florestal depende dos processos de planejamento, motivados por metas volumétricas de produção e receita, metas sociais ou ambientais e continuidade dos recursos físicos e financeiros durante um determinado período de tempo.

De acordo com Hosokawa (1982), o planejamento da produção florestal carece da definição de metas financeiras e de produção total, a partir de todas as alternativas de manejo aplicáveis no povoamento. Alguns autores consideram que o planejamento florestal pode ser

desmembrado em cinco esferas de atuação, sendo elas na produção florestal, escala empresarial, escala regional, integrado com outros setores da economia e no setor florestal propriamente dito (HOSOKAWA e MENDES, 1984).

Nas florestas tropicais de grande porte como as localizadas na floresta amazônica, o planejamento florestal absorve uma lógica mais organizacional, direcionando principalmente seu foco nas práticas de uma exploração florestal menos impactante. Assim, seguindo esta linha, observa-se o uso de terminologias como o manejo florestal de precisão, que adota o uso de geotecnologias e banco de dados confiáveis para confeccionar um modelo digital de exploração florestal, no qual apresenta diversas vantagens ambientais e de produção, conforme comentam Figueiredo e Lima (2008).

O planejamento florestal pode ser identificado como a organização de uma série de atividades distribuídas no tempo com o propósito de atender os objetivos de manejo florestal (BASKENT e KELES, 2005). Weintraub e Cholaky (1991) relatam que o planejamento florestal estratégico é caracterizado por considerar um grande número de opções de manejo nas unidades do povoamento, requisitando um longo horizonte de planejamento para garantir a sustentabilidade da floresta. Devido a esta complexidade, a estrutura original do planejamento é classificada em subproblemas que são modelados de forma hierárquica.

Assim, resumidamente pode-se afirmar que o planejamento florestal é uma estrutura hierárquica composta por objetivos pré-definidos em cada nível, no qual apresenta uma escala de tempo para o cumprimento das atividades florestais. Este sistema ainda é dominado por um ambiente de riscos e incertezas, como existente em todo empreendimento.

Os modelos hierárquicos de planejamento consistem em um grande conjunto de subsistemas conectados que compõem uma estrutura de camadas composta por objetivos, metas e uma gama de variáveis (MARCIN, 1993). A classificação hierárquica de planejamento florestal foi primeiramente introduzida por Paredes no final da década de 80, porém, somente com Weintraub e Cholaky no início da década de 90 é que os modelos hierárquicos foram aplicados (ANDERSSON, 2005).

Segundo Andersson (2005), a hierarquia do planejamento florestal encontra-se dividida tradicionalmente em três classes: planejamento estratégico, planejamento tático e planejamento operacional. O fluxograma da Figura 1 ilustra esta hierarquia.

A análise hierárquica consiste na organização das informações para a tomada de decisão nos diferentes níveis e a qualidade da decisão depende da correta ligação entre os níveis hierárquicos (CONNELLY, 1996). Segundo Mitchell (2004), a definição de cada nível

de planejamento é dada a seguir:

- a) Planejamento Estratégico: representa uma estratégia a longo prazo, sendo a escala mais distante do ano zero em termos de tempo, comparado com os outros estágios de planejamento. Geralmente, o horizonte é definido em torno de 2 a 4 rotações silviculturais; menor grau de detalhamento das informações; relaciona ainda temas ligados principalmente a aspectos sociais, técnicos, industrial, econômico, demográfico, ecológico e de legislação local;
- b) Planejamento Tático: apresenta uma escala em torno de 2 a 5 anos do horizonte de planejamento, a depender da espécie manejada, e utiliza alguns resultados do Planejamento Estratégico. Neste estágio são incluídas restrições de custo de estradas; definição do tipo de alternativas de manejo adotadas; análise de oferta e demanda do mercado e tipos de produtos desejados pelos consumidores. As metas de produção volumétrica são importantes e devem ser alcançadas nesta fase, a partir do agendamento da colheita;
- c) Planejamento Operacional: retrata as operações que ocorrem semanalmente ou diariamente, e tem referência nas informações providas do planejamento Estratégico e Tático da empresa, como decisões de colheita das unidades selecionadas e o tipo de produto a gerar.

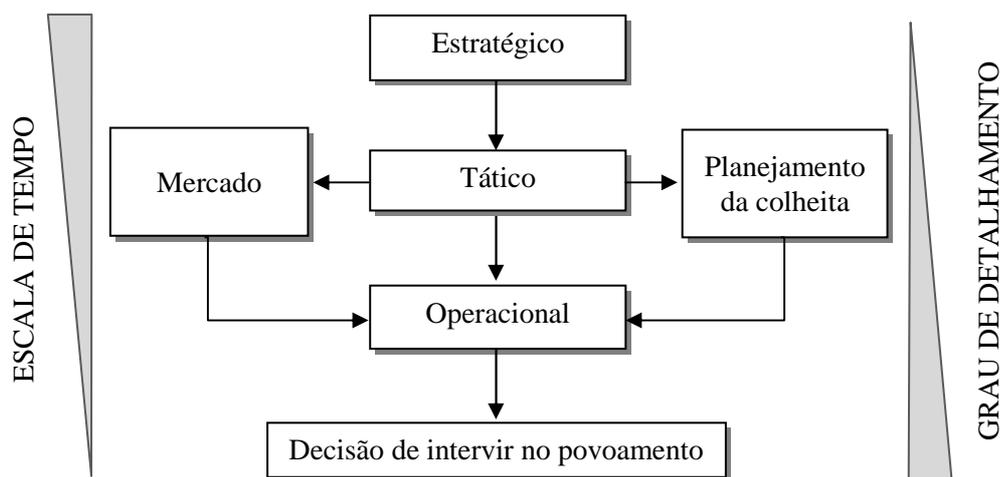


FIGURA 1- FLUXOGRAMA DA ESTRUTURA HIERÁRQUICA DE FUNCIONAMENTO DO PLANEJAMENTO FLORESTAL (ADAPTADO DE MITCHELL, 2004).

1.1.1 Ferramentas de planejamento florestal

A dedicação por processos de modelagem de dados tem transformado o cenário

florestal ao longo das décadas. Esta atitude se inspirou na necessidade de informações mais apuradas sobre a gestão do negócio florestal, onde muitas ferramentas foram desenvolvidas com a finalidade de acelerar os processos de tomada de decisão. O ponto inicial desta trajetória foi marcado a partir do desenvolvimento do algoritmo Simplex, por Dantzig no final da década de 40, o qual abriu caminho para o surgimento de métodos mais sofisticados de programação e amplamente difundidos no meio florestal.

Segundo Van Deusen (1999), as ferramentas de planejamento florestal permitem identificar as melhores opções de manejo a partir de vários objetivos, tornando o processo de decisão mais flexível e dinâmico. Apesar do contínuo uso destas ferramentas na década de 60 e comprovado auxílio no planejamento florestal, as primeiras aplicações no Brasil ocorreram na década de 80 pelo sistema denominado *Planflor*, e posteriormente por um software cooperativo coordenado pelo IPEF (REMADE, 2003).

Historicamente, o serviço florestal americano (USDA) teve uma participação especial no desenvolvimento de ferramentas voltadas para o planejamento florestal. Um dos primeiros software foi o *Timber RAM (Resources Allocation Method)*, seguido por *MaxMillion*, ambos criados no início da década de 70 e que contavam com a programação linear na regulação da floresta a curto prazo (KENT *et al.*, 1991). Nesta década, um pacote computacional composto pelos softwares *FOREST*, *REGEN* e *FINAL* realizava a simulação do crescimento de plantações de Douglas-fir (*Pseudotsuga menziesii*), bem como a otimização de opções de manejo via programação linear (BUONGIORNO e TEEGUARDEN, 1978).

Seguindo a escala de tempo, o software *MUSYC (Multiple Use Sustained Yield Calculation)* apareceu no mercado em 1979, sendo desenvolvido por Johnson e Jones. Na Nova Zelândia, Shieley desenvolveu o CPLAN com o apoio do serviço florestal do país (*New Zealand Forest Service*), durante a mesma década (MANLEY, 1995). Seguindo a mesma lógica e contando com algumas inovações, o software *FORPLAN (Forest Planning Language and Simulator)* foi desenvolvido para o planejamento de áreas naturais a longo prazo, sendo formado por um sistema de modelos de programação linear (POTTER *et al.* 1979). No início dos anos 90, muitas críticas foram feitas ao *FORPLAN* e desta maneira surgiu o *SPECTRUM*, com o propósito de aumentar as opções de modelos (programação inteira, programação multiobjetivo, programação inteira mista e programação estocástica) e incorporar saídas gráficas (USDA, 2002).

Influenciado pelo surgimento de softwares de planejamento florestal, García (1984) desenvolveu o *FOLPI (Forestry Oriented Linear Programming Interpreter)* na Nova

Zelândia. Nesta fase, diversas áreas do globo passaram a construir seus próprios otimizadores de alternativas de manejo. Na região Nórdica encontram-se os softwares de planejamento MELA e GAYA-JPL, ambos desenvolvidos no final dos anos 80 e início dos anos 90 (NUUTINEN e KELLOMÄKI, 2001). No Brasil, cita-se o sistema *PLANFOR*[®] que apresenta um módulo de programação linear de grande porte, o qual foi desenvolvido entre 1984 e 1988 pelos pesquisadores brasileiros Taube Netto e Lopes (UNISOMA, 2008). O *OpTimber-LP*[®] é outro software de planejamento estratégico capaz de realizar o planejamento a longo prazo e simular opções de manejo e, assim como os outros, utiliza a programação linear como método de resolução (OPTIMBER, 2008).

A empresa canadense Remsoft vem desenvolvendo desde 1990 ferramentas de planejamento florestal, sendo eles o *Woodstok*[®] (Planejamento Estratégico) e o *Stanley*[®] (Planejamento Tático). Segundo Walters (1993), o *Woodstok*[®] utiliza como opção de resolução os métodos via programação linear, busca binária ou simulação de Monte Carlo.

O *Habplan*[®] é um software escrito em Java e desenvolvido para o planejamento da colheita florestal. Ele possui a capacidade de planejar espacialmente a criação de habitat para a fauna, o controle da produção volumétrica e a definição de opções de manejo para as unidades florestais. O método de resolução apresenta 2 opções, a primeira considera soluções aproximadas pelo algoritmo Metropolis e a segunda ocorre através de soluções exatas via Programação linear (NCASI, 2006).

1.1.2 Visualizadores 3D no planejamento florestal

A nova geração de softwares apresenta inovações futuristas no suporte ao planejamento e gestão florestal. Uma nova visão gráfica em terceira dimensão permite ao planejador acompanhar o resultado das intervenções florestais na floresta e analisar seus impactos visuais na paisagem local facilitando na gestão do recurso. O processo para a modelagem destes sistemas é mais complexa, pois exige um maior detalhamento da área em estudo, como por exemplo o conhecimento da topografia do terreno.

MacGaughey (2001) comenta que a visualização de cenários durante o planejamento tático/operacional é comumente esperada, pois este procedimento ilustra as estratégias de manejo, como ainda auxilia na decisão de se construir estradas durante a colheita florestal. Segundo o autor, para uma precisa geração precisa da visualização é necessário um número elevado de informações, sendo estas classificadas em 4 grupos: 1 - informações gerais sobre o

terreno; 2 - dados de elevação/topografia do terreno; 3-aspectos antrópicos como estradas, construções e 4 - dados de vegetação.

Falcão (2004) descreve o funcionamento de um visualizador de paisagens florestais (Figura 2) conectado a um sistema de apoio à decisão de recursos naturais. O autor ainda relata a existência de 5 componentes principais nesta arquitetura: a) sistema de gestão de bases de dados; b) simulador e gerador de alternativas de gestão; c) modelos de decisão ligados a programação linear e várias heurísticas; d) pré-processador e e) visualizador.

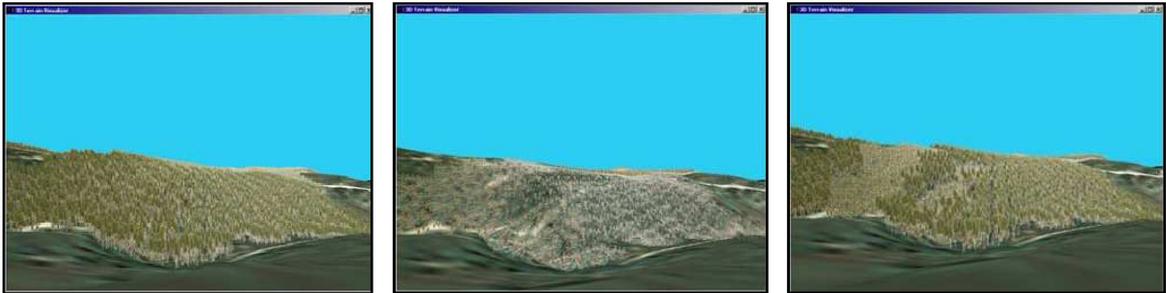


FIGURA 2 - VISUALIZADOR DE PAISAGENS FLORESTAIS E SUAS SAÍDAS GRÁFICAS EM DIFERENTES CENÁRIOS (FONTE: FALCÃO, 2004).

O software *Smartforest II*[®] é um software que permite a visualização do caminhamento do observador ao longo da área manejada, em tempo real de 3D. Segundo Thorn *et al.* (1997), o esquema de representação da paisagem é composto pela densidade de árvores, tipos e tamanhos dispersos na topografia, para em seguida sobrepôr as saídas do planejamento florestal. Um sistema de planejamento similar é composto pelos softwares: *FORECAST*, *ATLAS* e *SIMFOR* que permite simular e visualizar os cenários paisagísticos (NELSON e HARRISON, 2001). A Figura 3 apresenta uma saída gráfica do programa.

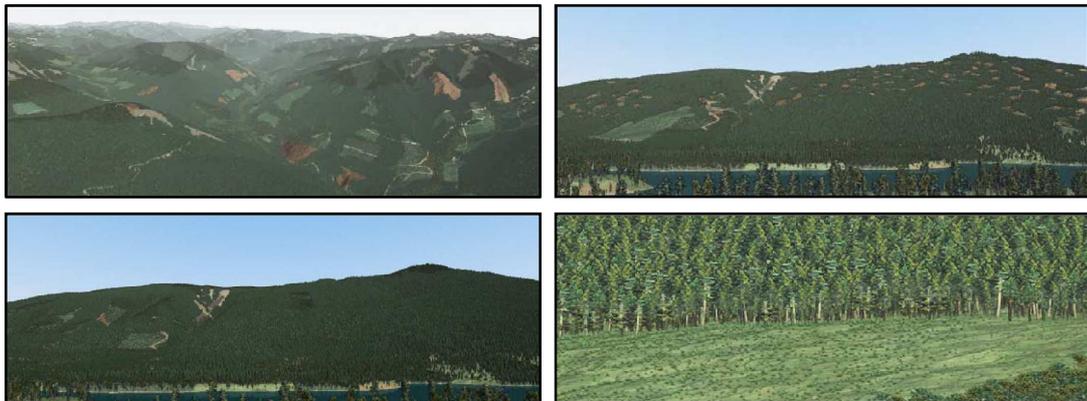


FIGURA 3 - VISUALIZAÇÃO DE DIFERENTES CENÁRIOS FLORESTAIS (FONTE: MEITNER *et al.*, 2005).

O serviço florestal americano desenvolveu uma ferramenta de visualização em 3D projetada para representar as diferentes opções de manejo florestal. O programa é conhecido

como *Envision*[®] e simula as opções de planejamento florestal na paisagem (USDA, 2004).

1.1.3 Planejamento florestal espacial

A idéia do planejamento florestal levando em consideração o espaço se mistura com a história inicial do Sistema de Informação Geográfica (SIG). Este fato é muitas vezes observado, durante as décadas, pelo grande número de pesquisadores que passaram a utilizar o SIG em seus trabalhos (BASKENT e JORDAN, 1991). Os pesquisadores daquela época tentaram incorporar o SIG ao planejamento florestal, em problemas relacionados ao agendamento da colheita a partir de restrições espaciais. Esta preocupação com a disposição espacial trouxe a idéia da preservação de habitats e conservação da vida selvagem. Segundo Bettinger e Chung (2004), o crescimento desta linha de estudo é percebido pelo número de artigos científicos publicados nas principais revistas americanas do gênero florestal como: *The Forest Chronicle*, *Southern Journal of Applied Forestry*, *Journal of Forestry*, *Forest Science* e *Canadian Journal of Forest Research*, retratado no Gráfico 1.

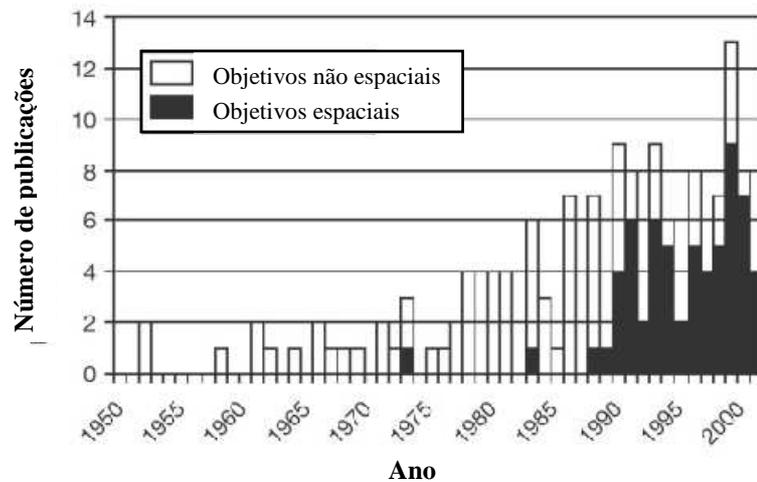


GRÁFICO 1 - NÚMERO DE ARTIGOS PUBLICADOS E RELACIONADOS A ASPECTOS ESPACIAIS/NÃO ESPACIAIS PUBLICADOS PELAS REVISTAS AMERICANAS DO GÊNERO FLORESTAL (ADAPTADO DE BETTINGER E CHUNG, 2004).

O planejamento espacial identifica e expõe os componentes da paisagem, auxiliando a uma tomada de decisão mais consciente sobre os aspectos ecológicos do ecossistema. Neste ponto, algumas restrições são introduzidas no modelo matemático para permitir esta ação. Assim, como exemplo de restrições tem-se: áreas de conexão entre fragmentos, distância entre blocos explorados, distribuição de estradas e outros itens importantes na redução de impactos.

Segundo Baskent e Keles (2005), a diferença entre o planejamento florestal tradicional e o espacial é o fato de como analisar o talhão dentro da floresta. No primeiro caso, o talhão é apenas uma unidade de produção desconectada dos demais talhões; já no segundo, o talhão passa a ser observado segundo o seu tamanho, forma e distribuição dentro da floresta. Neste caso, o controle de seus efeitos sobre o ecossistema é determinado espacialmente através de restrições formuladas exclusivamente para o planejamento florestal espacial.

Um grupo de pesquisadores trabalhou a questão de modelagem da paisagem e não apenas a distribuição espacial na sua pura análise. Entretanto, a maior dificuldade encontrada ao trabalhar o espaço foi a possibilidade de surgirem problemas não lineares, tornando impraticável o uso da programação linear (ÖHMAN, 2001). Assim, iniciaram a procura por novos algoritmos que se adaptassem às condições e restrições espaciais (WALTERS, 1993).

Seppelt e Voinov (2004) comentam que a complexidade dos modelos de otimização no planejamento florestal espacial depende de dois fatores: o número de variáveis e a complexidade espacial (tamanho da área de estudo e número de processos espaciais que se interagem). A complexidade do problema aumenta na medida em que se aumentam as relações espaciais entre as variáveis e, desta maneira, as chances de sucesso na otimização ficam reduzidas.

Stewart *et al.* (2004) utilizaram restrições espaciais para alocar diferentes atividades de uso do solo na Holanda, utilizando algoritmo genético e *goal programming* em problemas classificados como multi-objetivo. Falcão e Borges (2002) utilizaram 3 heurísticas para a resolução de um problema de planejamento florestal, no qual controlavam o fluxo de produção de madeira e questões espaciais ligadas à paisagem em Portugal.

Rempel e Kaufmann (2003) realizaram um estudo sobre os efeitos de restrições espaciais (tamanho de bloco, distância entre blocos, adjacência entre unidades de manejo) frente a objetivos ligados à produção volumétrica e manutenção de habitats para a fauna. O estudo visava reduzir os impactos gerados pela colheita florestal e impedir a fragmentação acentuada da área natural estudada. Vários trabalhos similares podem ser encontrados em Baskent e Jordan (1996), Tang e Gustafson (1997), Brumelle *et al.* (1998), Gustafson *et al.* (2001), Boston e Bettinger (2001a), Kurttila (2001), Bettinger *et al.* (2002), Jumppanen *et al.* (2003), Bettinger *et al.* (2005), Bettinger *et al.* (2007), Heinonen (2007).

O planejamento florestal será chamado brevemente de planejamento florestal espacial, tendo como foco as atividades do manejo florestal e políticas ambientais, conforme discutido no trabalho de Bettinger e Sessions (2003).

1.1.4 Agendamento da colheita florestal

O planejamento de suprimento de madeira é normalmente parte integrante do manejo florestal, tendo como objetivos definir a agenda de corte das unidades e auxiliar na regulação da floresta (HOTVEDT, 1983). O agendamento da colheita florestal apresenta algumas características específicas na formulação dos modelos de programação linear, conforme encontrado em Mitchell (2004). Segundo o autor, o horizonte de planejamento desta atividade geralmente é decorrente de um curto período de tempo, sendo necessário responder os seguintes interrogantes: quando as unidades de manejo serão colhidas?; quem será responsável pela colheita?; que tipo de produto florestal será produzido?; qual o consumidor que será abastecido pela produção e qual a seqüência de unidades selecionadas para a colheita?

A estratégia de seqüência ótima de corte dos talhões se insere no planejamento tático de uma empresa florestal, conforme formulado por Boston e Bettinger (2001b) em seus estudos. Existem outros trabalhos encontrados na literatura que retratam o tema como em: Bettinger *et al.* (1999), Meilby *et al.* (2001) e Mitchell (2004).

Nos dias atuais, o agendamento da colheita florestal passou a considerar os cuidados com o ambiente, tornado um fator preponderante na sustentabilidade do mercado no setor florestal. Van Deusen (1999) comenta que atualmente existe uma expansão de objetivos e restrições visando à produção volumétrica de madeira e aspectos ambientais. Alguns exemplos podem ser vistos, como em Hof e Bevers (2000). Nesse estudo, os autores utilizaram o problema de agendamento da colheita florestal formulado via programação linear, e restrições de controle da erosão laminar em uma bacia hidrográfica hipotética. O mesmo pôde ser encontrado em Amaral (2002). Carlsson (1999) utilizou um problema parecido, porém integrando a biodiversidade em seu modelo.

A questão relacionada à adjacência também é um tema bastante discutido no planejamento florestal espacial, sendo observado nos trabalhos de Weintraub *et al.* (1994), Brumelle *et al.* (1998), Borges e Hoganson (1999), Weintraub *et al.* (2000), Boston e Bettinger (2001a), Murray *et al.* (2004), Goycooela *et al.* (2005), Zhu *et al.* (2007), dentre outros. No Brasil podemos citar trabalhos de Alonso (2003) e Castro (2007).

1.2 Paisagem

Segundo Bell (2001) os profissionais responsáveis pelo planejamento e manejo

florestal devem pensar em incorporar variáveis ligadas ao manejo visual da paisagem em seus trabalhos. Uma das afirmativas do autor é que existe disponível, no meio científico, uma série de técnicas e ferramentas que auxiliam na redução do impacto de operações florestais sobre a paisagem. Magro (1996) relata que a colheita florestal nem sempre é bem aceita pelo público em geral, principalmente quando abrange grandes áreas. O autor ainda demonstra uma série de medidas e propostas para mitigar estes danos visuais na paisagem.

O termo paisagem é usado para descrever a aparência de uma área ou uma porção de terra, situada em qualquer localidade (LONGMAN, 2003). Lucas (1991) menciona que a paisagem é composta por elementos naturais, atributos humanos, e ainda qualidades estéticas, existindo ainda uma variação de formas e designs retratando exclusivamente cada local.

A expressão *landchap* originária do holandês designava algum lugar comum como: um conjunto de fazendas ou campos, cercados às vezes por uma pequena propriedade ou uma unidade administrativa. Quando o termo foi levado para a Inglaterra (século XVI) transformou-se em *landscape* passando a significar arte ou panorama visto de um lugar (TUAN, 1983). A palavra *landscape* é correlata à palavra paisagem em português.

A paisagem comumente refere-se à aparência da terra, incluindo a forma, textura e cor. Isso também reflete os vários componentes combinados, criando padrões específicos que são característicos de cada localidade particular, não sendo apenas um fenômeno puramente visual, mas também um conjunto de aspectos ligados a geologia, topografia, ecologia, arquitetura, história, uso do solo, dentre outros (INSTITUTE OF ENVIRONMENT ASSESSMENT, 1995).

De acordo com Forman e Godron (1986) a paisagem é uma unidade heterogênea, cuja estrutura pode ser definida pela área, forma e disposição espacial de suas unidades, sendo ainda formada por um complexo de unidades interativas como ecossistemas, unidades de vegetação, e uso do solo. Ainda comenta-se que, partindo de uma visão simplificada, a paisagem é percebida como um conjunto de fragmentos de habitat dispersos na matriz.

1.2.1 Impacto visual sobre a paisagem

A visão é um dos principais sistemas sensoriais que os seres humanos apresentam, sendo responsável por distinguir uma grande variação de cores, texturas e profundidade espacial e um dos importantes guias nas escolhas humanas, bem como em grande parte dos animais.

Existem muitos casos onde a percepção humana é aguçada primeiramente pelas questões visuais, discriminando e julgando ambientes que mais lhe agradam ou não, e na seqüência tornam-se padrões e tendências de escolhas. Um exemplo é observado em locais cujo relevo é montanhoso ou em áreas litorâneas, para onde uma grande parcela da humanidade é atraída. A preferência pela escolha da paisagem é definida geralmente por questões culturais, genéticas e de certos valores de cada indivíduo (KARJALAINEN, 2006).

Os impactos sobre a paisagem geram, num primeiro momento, uma degradação visual, percebida e capturada rapidamente pelo olhar humano. Este talvez seja o impacto mais rápido de ser quantificado, devido à capacidade humana de observar e registrar imagens.

Segundo o Institute of Environment Assessment (1995), o impacto visual pode ser causado por uma série de fatores, como alterações no solo, expansão da área urbana, mineração, agricultura, reflorestamentos, desmatamento, redes de transmissão, áreas industriais, dentre outros. Seixas e Magro (1998) comentam que inúmeros são os impactos sobre a paisagem durante a operação de colheita florestal, sendo um deles a agressão cênica ao público, que estava anteriormente acostumado à imagem de milhares de árvores ocupando o seu espaço visual.

A significância do impacto visual sobre a paisagem é uma função da sensibilidade do observador em perceber as mudanças e alterações. Sendo assim, a sensibilidade incorpora questões ligadas à tolerância e valoração da paisagem para cada observador.

1.2.2. Modelando a paisagem florestal

Ao se pensar em modelar uma paisagem, a primeira idéia que surge é a realização de mudanças na forma dos elementos paisagísticos. Algumas alterações refletem um caráter estético e puramente artístico, como mudança na forma dos talhões, retirada de formas lineares de plantios, construção de estradas menos retilíneas e adequação de áreas próximas a rodovias, para torná-las mais naturais. Por outro lado, matematicamente é possível produzir efeitos na estrutura dos elementos da paisagem através de restrições presentes no modelo. A estratégia neste momento é a definição de talhões a serem colhidos durante as operações de colheita florestais. Assim, a combinação dos talhões selecionados produz uma mudança na dinâmica da paisagem.

Na literatura são observados diversos tipos de modelos e restrições designadas a modelar espacialmente a paisagem florestal. Os modelos construídos são muitas vezes

testados em diferentes ambientes conforme observado em: Baskent e Jordan (1996), Kurttila (2001), Shifley *et al.* (2006), Radloff *et al.* (2006), Zollner *et al.* (2008), dentre outros. O agendamento da colheita florestal é sempre retratado nestes estudos, sendo uma atividade que reflete diretamente o design e a estrutura da paisagem.

Tang e Gustafson (1997) concluem em seu estudo que alguns atributos das unidades de manejo influenciam a paisagem, como características ligadas ao tamanho, à forma e ao tamanho da borda. Logo, o processo de modelar uma paisagem passa necessariamente por estes atributos, principalmente quando se trabalha em áreas reflorestadas, já que apresentam um grau de artificialidade.

Uma tendência neste tipo de modelagem é o uso de restrições de adjacência, inseridas nos modelos de programação linear (BOSTON e BETTINGER, 2001b). Problemas desta natureza são gerados pela necessidade de controlar o tamanho da área, distância e arranjo entre talhões a serem explorados, constituindo assim um conjunto de restrições e condições à exploração.

1.2.2.1 Adjacência

Aspectos espaciais do planejamento florestal estão ganhando atenção ao longo dos anos, principalmente em se tratando das interações entre a vizinhança das unidades de manejo. Um dos tantos exemplos é encontrado pela *American Forest and Paper Association* que incentiva processos de sustentabilidade de florestas nos Estados Unidos, ao restringir o corte de áreas contíguas com mais de 120 acres ou 48,55 ha (GOYCOOLEA *et al.*, 2005).

Os debates em prol do controle da colheita em extensas áreas de floresta contribuíram para o surgimento do conceito de proteção de habitats, conhecido como *green up*. Segundo McNaughton *et al.* (2001) o efeito aplicado desta medida promove um processo de dispersão da colheita florestal na área, durante o planejamento da colheita. Esta dispersão é explicada quando um talhão é selecionado para o corte e, pela regra, seus vizinhos ficam impedidos de ser colhidos durante um determinado período de tempo (*green up delay*). O exemplo encontra-se na Nova Zelândia, que restringe o corte de talhões vizinhos durante os próximos 5-10 anos subsequentes. Este tempo de espera é aguardado para permitir que as árvores alcancem uma altura média de 2-4 metros, liberando assim as áreas vizinhas para o corte (NELSON, 2000). McNaughton *et al.* (2001) afirmam que o seu surgimento foi basicamente em virtude da necessidade de redução do impacto da erosão do solo após a colheita florestal.

Nelson (2000) comenta que as regras de adjacência surgiram no início da década de 70, sendo aplicadas com o propósito de dispersar a colheita em florestas que recobriam os mananciais hídricos e abrigavam a fauna. Segundo Mcdill e Braze (2000) o pioneiro no desenvolvimento de restrições de adjacência foi Thompson em 1973, e seu estudo continha propostas multiobjetivas de produção de madeira e proteção à fauna.

A maioria dos problemas de adjacência pesquisados apresenta, na formulação matemática, uma função de lucro/receita a ser maximizada, juntamente com as próprias restrições de adjacência (HOGANSON e BORGES, 1998). Em muitos casos é utilizado o modelo de planejamento tipo I (JOHNSON e SCHEURMANN, 1977) combinado com as restrições de adjacência e de fluxos de produção volumétrica.

Nelson (2000) considera que o trabalho do planejador florestal é conhecer o impacto econômico destas restrições na atividade florestal, sendo uma proposta desafiadora e importante. Boston e Bettinger (2001a) realizaram um estudo para retratar este impacto e concluíram que, a curtas rotações o seu efeito é pouco perceptível pela análise econômica. O estudo foi desenvolvido considerando um efeito de adjacência de 2 e 3 anos apenas e o uso de uma heurística híbrida para a resolução. Um trabalho interessante pode ser observado em Borges e Hoganson (1999), no qual os autores fizeram o uso da programação dinâmica para a resolução do problema adjacência. Neste estudo ficou claro que impactos na produção de madeira foram observados, porém os autores exaltam o potencial de aplicação em áreas ambientais sensíveis.

A modelagem da paisagem auxilia na construção de áreas mais resistentes a impactos naturais e/ou antrópicos, promovendo uma proteção ao local. Um estudo realizado por Thompson *et al.* (1998) comprovou que as restrições de adjacência auxiliam na construção de paisagens mais resistentes à propagação do fogo, quando simulados os riscos de desastres por incêndio.

Öhman (2001) relata a existência de três linhas distintas de restrições espaciais: a primeira delas considera a conectividade entre talhões/áreas; a segunda executa um processo contrário, o de dispersão da colheita ao longo da floresta; e a terceira é uma mistura de características da primeira com a segunda. A restrição de adjacência se enquadra na segunda linha definida por Öhman (2001). Problemas desta natureza podem ainda ser subdivididos em 2 classes distintas. Segundo Murray (1999), os modelos de adjacência apresentam variações ligadas a restrições por unidade e por área, sendo então formulados com concepções matemáticas diferentes. O autor propõe, de forma bem objetiva, uma classificação de uso

destas terminologias, sendo as restrições do modelo tipo URM (*Unit Restriction Model*) e ARM (*Area Restriction Model*).

Os modelos que apresentam restrições por unidade (URM) desenvolvem uma incompatibilidade de colheita florestal de dois ou mais talhões vizinhos (STEIGUER *et al.*, 2003). A outra opção de restrição (ARM) permite a colheita de talhões vizinhos, desde que não ultrapassem um limite máximo de área contígua pré estabelecida (STEIGUER *et al.*, 2003). A diferença entre os modelos ARM e URM é o fato de haver a possibilidade de colher talhões vizinhos (respeitando um limite máximo de área) no primeiro caso, e para o segundo caso, não. Além disso, o grau de dificuldade de se formular um modelo ARM é muito maior que no modelo URM (ZHU e BETTINGER, 2007).

1.2.2.1.1 *Unit restriction model* (URM)

A primeira tentativa de se modelar problemas de adjacência utilizava restrições do tipo pares (*Pairwise*), cuja formulação matemática é considerada mais fácil de aplicar, e talvez por isso mais difundida entre os planejadores florestais. A desvantagem deste tipo de restrição está associada ao elevado número de inequações desenvolvidas para retratar todo o problema (SILVA, 2004). Uma revisão detalhada sobre este tipo de restrição pode ser encontrada em Mcdill e Braze (2000), na qual conseguiram listar um total de 14 subtipos de restrições alternativas de adjacência, ou possibilidades de representar matematicamente o problema, conforme mostra a Tabela 2.

TABELA 2 - SUBTIPOS DE RESTRIÇÕES DE ADJACÊNCIA EMPREGADOS NO MODELO DE PLANEJAMENTO FLORESTAL.

Restrição	Nome das restrições alternativas de adjacência	Ano
1	Type I MKJ (Meneghim, Kirby e Jones)	1988
2	Type II	1988
3	T-B	1990
4	Type I <i>unspecified</i>	1991
5	OAM (<i>Ordinary Adjacency Matrix</i>)	1994
6	TAM (<i>Triangulated Adjacency Matrix</i>)	1994
7	RTAM (<i>Reduced Triangulated Adjacency Matrix</i>)	1994
8	RAM (<i>Reduced Adjacency Matrix</i>)	1994
9	NOAM (<i>New Ordinary Adjacency Matrix</i>)	1995
10	NTAM (<i>New Triangulated Adjacency Matrix</i>)	1995
11	Y&B MIN (<i>Minimized OAM</i>)	1995
12	Type I ND (<i>Nondominated</i>)	1996
13	Type I MIN (<i>Minimized</i>)	1996
14	M&C MIN (<i>Minimized NOAM</i>)	1996

O aparecimento deste conjunto de restrições alternativas mostra a importância de modelar o problema. Além disso, foi observada pelos pesquisadores a necessidade de minimizar o número de inequações produzidas durante as formulações (MURRAY e CHURCH, 1995). A formulação utilizada até então era denominada *Pairwise* ou em pares, e produzia um grande número de restrições.

Segundo Mcdill e Braze (2000), estes tipos alternativos de restrições de adjacência podem ser reunidos em 5 grupos distintos, conforme o raciocínio de dedução das formulações:

1) *Modified Adjacency Matrix Group* ou Grupo de Matriz de Adjacência Modificada - tem como referência a variação da matriz de adjacência. Uma Matriz $M \times M$, onde M é o número de talhões cujo elemento a_{ij} assume o valor 1 se i e j são adjacentes; e 0 caso contrário (os elementos na diagonal $a_{ii} = 0$). Os subtipos de restrições que fazem parte são: OAM (*Ordinary Adjacency Matrix*), TAM (*Triangulated Adjacency Matrix*), RTAM (*Reduced Triangulated Adjacency Matrix*) e RAM (*Reduced Adjacency Matrix*);

2) *Type I* ou Tipo I - baseiam no conjunto de talhões mutuamente adjacentes. Os grupos de talhões apresentam membros que são adjacentes a outros talhões, e estes por sua vez pertencem a outros grupos. Pode-se considerar um estado onde a soma das variáveis binárias deve ser menor ou igual a 1. Os subtipos de restrições que fazem parte são: Type I *unspecified*, Type I MIN (*Minimized*), Type I ND (*Nondominated*) e Type I MKJ (Meneghim, Kirby e Jones);

3) *Aggregated Constraint Group* ou Grupo de Restrições Agregadas - é um tipo de formulação que considera a combinação entre restrições de adjacência, com o propósito de reduzir o número de restrições no modelo. As restrições que fazem parte são: *Type II* e T-B;

4) *Tightened Coefficient Group* ou Grupo de Coeficientes Compactados - representa um grupo de restrições formadas pela redução de alguns coeficientes das restrições de adjacência. Quando possível, reduz os coeficientes da restrição e o resultado é uma restrição mais compacta. A formulação resulta em um problema de programação linear relaxado, que é próximo de uma programação linear inteira mista. Os subtipos de restrições que fazem parte são: NOAM (*New Ordinary Adjacency Matrix*) e NTAM (*New Triangulated Adjacency Matrix*);

5) *Minimized Constraint Group* ou Grupo de Restrições Minimizado - são obtidas pela resolução de um conjunto de problemas, que identifica o menor conjunto de restrições de adjacência entre todas as restrições. As restrições que fazem parte são: Type I MIN

(*Minimized*), M&C MIN (*Minimized NOAM*) e Y&B MIN (*Minimized OAM*) e Type I MIN (*Minimized*) presente também no grupo 3 (Tipo I) .

No trabalho de Alonso (2003), um dos objetivos foi utilizar as restrições de adjacência (URM) e trabalhar a formulação matemática na tentativa de reduzir as restrições do modelo, tendo o *Type II* como método. Nas formulações, o autor conseguiu êxito na operação e percebeu que existe uma redução do VPL (valor presente líquido) quando aplicadas estas restrições. Castro (2007) utilizou uma floresta contendo 105 talhões como base de seus estudos de planejamento florestal, aplicando a mesma formulação do trabalho anterior. O autor encontrou uma perda de 6,57% do VPL, ao se comparar com o modelo sem estas restrições. Entretanto, houve uma redução na degradação da paisagem, em virtude da ausência de grandes áreas cortadas.

1.2.2.1.2 Area restriction model (ARM)

O modelo ARM tem como idéia permitir a colheita de talhões vizinhos, desde que o somatório total de suas áreas não ultrapasse a área máxima permitida (Figura 4). Este tipo de restrição espacial é empregado quando não se deseja que o somatório das áreas de talhões vizinhos seja superior ao limite máximo de área permitida na colheita florestal. Esta flexibilidade não é observada no modelo URM.

Segundo Murray (1999), o desafio é encontrar uma maneira de formular linearmente este tipo de restrição, pois devido a características não lineares a sua formulação torna-se impossível via programação linear inteira. A alternativa para os métodos exatos é o uso de procedimentos de aproximação (metaheurísticas) que, apesar do grau de dificuldade na implementação, permitem encontrar soluções viáveis a partir de funções de penalidade.



$$T_1(10\text{ha}) + T_2(10\text{ha}) < A_{\text{limite}}(25\text{ha})$$

$$T_1(10\text{ha}) + T_2(10\text{ha}) + T_5(10\text{ha}) > A_{\text{limite}}(25\text{ha})$$

FIGURA 4 - EXEMPLO ILUSTRATIVO DO AGENDAMENTO DA COLHEITA FLORESTAL CONSIDERANDO DUAS SITUAÇÕES DE RESPOSTA (FACTÍVEL/INFACÍVEL) FRENTE À RESTRIÇÃO ARM.

Uma função recursiva foi proposta por Murray (1999) para entender e exemplificar o grau de dificuldade na formulação matemática linear tradicional:

$$f_{it}(x) \leq A \quad \forall_{i,t} \quad (1)$$

Onde:

A - área máxima contígua permitida;

$f_{it}(x)$ - função recursiva que soma a área de todas as unidades de um grupo de talhões adjacentes, sempre associados a X_{it} (se $X_{it} = 1$);

t - determinado período de tempo dentro do horizonte de planejamento.

Zhu *et al.* (2007) consideram o uso de restrições ARM como muito difíceis de serem formuladas via programação linear inteira, reforçando o postulado de Murray. Segundo Murray (1999), é praticamente impossível formular estas restrições *a priori*, pois existem muitas combinações possíveis entre talhões vizinhos, tornando o processo bastante exaustivo e passível de erro.

A partir deste desafio lançado, alguns pesquisadores trabalharam o tema, e assim propuseram uma metodologia capaz de formular linearmente este tipo de restrição. A proposta se consolidou com o desenvolvimento de um algoritmo que construía as restrições de adjacência, batizado de *Path Algorithm* (McDill *et al.*, 2002). Os autores foram ainda mais longe e desenvolveram outro procedimento de formulação, denominada de GMU (*Generalized Management Unit*). Um ano mais tarde, outro método de formulação foi desenvolvido por Crowe *et al.* (2003). Nestes exemplos, os autores utilizam a formulação matemática dos modelos, escrita por seus algoritmos, e aplicaram o método de resolução exato via *branch-and-bound*.

De acordo com Goycoolea *et al.* (2005) a resolução de problemas com restrições ARM, em modelos de programação linear inteira mista, assume dois caminhos ou estratégias diferentes de formulação; a primeira utiliza as idéias de McDill *et al.* (2002) e a segunda via postulado por Crowe *et al.* (2003). Contudo, ainda é possível utilizar uma terceira variação, considerando o uso de Heurísticas e Metaheurísticas, como métodos não exatos. Porém esta alternativa está sendo pouco explorada no meio florestal (MURRAY,1999).

Gunn e Richards (2005) seguiram as idéias do trabalho efetuado por McDill *et al.* (2002), e assim desenvolveram uma outra opção de formulação alternativa (ou complementar) conhecida por *stand-centered*.

Novas categorias de adjacência podem surgir em virtude da criação de leis ambientais e tendências do mercado. E neste sentido as formulações matemáticas devem acompanhar

estas necessidades. A exemplo tem-se o trabalho de Murray *et al.* (2004), no qual apresentaram uma formulação contendo as restrições ARM, porém considerando agora a média por área entre talhões (média-ARM).

1.3 PROGRAMAÇÃO LINEAR

A história da programação linear (PL) se mistura aos primeiros estudos sobre Pesquisa Operacional, no período da segunda guerra mundial. Durante a guerra, pesquisadores americanos e britânicos foram convocados a trabalhar na resolução de problemas ligados a táticas militares e direcionamento de recursos, devido à necessidade de reduzir os esforços humanos e suprir a carência de produtos. Devido ao grande sucesso, esta tecnologia passou a ser empregada em diversas áreas do conhecimento, como: na industrial, logística, construção, negócios, economia, órgãos governamentais dentre outros (HILLIER e LIEBERMAN, 2001).

A PL basicamente surgiu no período dos anos 50, durante uma época em que não existiam computadores disponíveis. O termo PL não se refere diretamente à questão de programação computacional, como se pode sugerir, porém, a um conjunto de inequações (restrições) que definem um plano, sendo este medido por uma função linear (MATOUŠEK e GÄRTNER, 2007).

A maior aplicação da PL se desenvolveu graças ao surgimento do algoritmo *SIMPLEX*, sendo este capaz de resolver problemas grandes e complexos. Segundo Matoušek e Gärtner (2007), o algoritmo *SIMPLEX*, desenvolvido por George Dantzig entre 1947 e 1949, é considerado um dos 10 algoritmos mais influentes do século 20, por promover o desenvolvimento da ciência. A primeira aplicação de modelos de PL em problemas ligados a Engenharia Florestal foi no início da década de 60, e desde então foi cada vez mais utilizado (BUONGIORNO e GILLESS, 1987).

Segundo Leuschner (1990), um modelo usando PL é formulado para maximizar ou minimizar uma função objetivo, atendendo a um conjunto de restrições (inequações ou equações). No modelo, Z é o valor da função objetivo; c é um vetor de coeficientes que indicam a contribuição das variáveis de decisão x ; A é uma matriz de coeficientes das restrições e r é um vetor das restrições. Uma maneira geral de representar a formulação é dada a seguir, conforme o autor:

$$\text{Max (Min) } Z = cx \quad (2)$$

$$\text{Sujeito a: } Ax \begin{matrix} \geq \\ \leq \end{matrix} r \quad (3)$$

$$x \geq 0 \quad (4)$$

Os modelos de otimização via PL têm como meta encontrar as melhores combinações do *pool* de alternativas de manejo de uma floresta, auxiliando na tomada de decisão (BOYLAND *et al.*, 2005). Segundo os autores, a existência de objetivos conflitantes como o de produzir madeira e preservar áreas florestais pode ser balanceada e melhor explorada pelo uso da PL.

Rodriguez (2001) afirma que, durante a década de 80, os processos de gestão florestal passaram por grandes reformulações; uma delas foi adotar técnicas de PL em conjunto com modelos de otimização. Estes modelos encontram o ótimo global para o conjunto de talhões de uma floresta. A partir desta data, o talhão passou a ser analisado como parte de um amplo sistema e desde então não fazia mais sentido o ótimo para um único talhão.

Em problemas envolvendo o agendamento da colheita florestal é muito comum o uso da PL, principalmente quando se deseja conhecer a melhor combinação de corte, que maximize a receita e gere fluxos contínuos de produção. Johnson e Scheurmann (1977) comentam que a PL é um dos métodos mais empregados para resolver problemas de planejamento florestal.

De acordo com Rustagi (1978), o planejamento da colheita florestal demanda uma série de informações como projeção da produção florestal, preços e custos de produção por talhão. Geralmente, o resultado deste conjunto de informações confere aos modelos uma estrutura complexa e com elevado número de restrições e variáveis. Alguns critérios econômicos podem ser introduzidos na função objetivo e auxiliar na análise de projetos florestais (RUSTAGI, 1978).

Estudos desta natureza podem ser encontrados em Murray e Church (1996), Borges e Hoganson (1999), McDill e Braze (2000 e 2001), Meilby *et al.* (2001), Falcão e Borges (2001), Öhman e Eriksson (2002), McDill *et al.* (2002), Silva *et al.* (2003a), Falcão e Borges (2002), Mello *et al.* (2005), dentre outros.

A maioria destes trabalhos utilizou os modelos de formulação classificados por Johnson e Scheurmann (1977), e conhecidos como modelo tipo I e II. Segundo Rodrigues *et al.* (2006), uma diferença entre os modelos é a menor quantidade de variáveis e restrições que o modelo II geralmente apresenta, em comparação ao modelo I. Esta característica já foi de grande importância na época em que Johnson e Scheurmann publicaram seu trabalho (1977). Atualmente, com a evolução dos equipamentos e programas para resolução de problemas de PL de grande tamanho, a escolha de qual modelo adotar não passa apenas pela expectativa de redução do número de variáveis com o modelo tipo II.

Rodrigues *et al.* (2006) aplicaram os modelos I e II na tentativa de regular a floresta, adotando a programação linear inteira como método de resolução. Um dos propósitos dos autores foi conhecer melhor as respostas dos modelos, quanto ao uso de restrições de recobrimento. Conforme esperado, o modelo I não violou as restrições e respeitou a integralidade das unidades de manejo; já o mesmo não foi observado pelo modelo II. O modelo II permitiu que algumas unidades de manejo fossem fracionadas e não assegurou a integralidade destas unidades.

Independente do tipo de modelo abordado, a PL apresenta uma eficiência computacional comprovada, e uma versatilidade em formular as restrições ligadas ao manejo das operações florestais (ÖHMAN e ERIKSSON, 2002). Estes modelos podem governar a maioria das questões quantitativas, retratando-as por meio de expressões lineares. Entretanto, alguns artifícios devem ser introduzidos no modelo quando o problema engloba variáveis não contínuas. Neste caso, o uso da programação linear com variáveis inteiras e/ou mistas se faz necessário.

1.3.1 Programação Linear Inteira/Mista (PLI/PLIM)

No passado, a maioria dos modelos constituía-se exclusivamente de variáveis contínuas, em suas formulações, cujo principal objetivo estava associado a valores percentuais de volume, área ou região a ser manejada. Uma nova tendência de restrições exigiu o uso de variáveis inteiras, no qual conseguia retratar os objetivos vinculados ao planejamento florestal. Esta alteração em declarar as variáveis de decisão foi necessária para atender questões espaciais da floresta (MURRAY e SNYDER, 2000). O novo conceito de planejamento florestal espacial impulsionou e difundiu a aplicação de modelos baseados em programação linear inteira/mista.

A definição do uso de determinado tipo de programação é orientada exclusivamente pela natureza das variáveis presentes no modelo. Assim, se o modelo não apresentar variáveis inteiras, emprega-se a PL normalmente. Caso haja apenas variáveis inteiras, diz-se que é programação linear inteira pura. O terceiro caso é quando existe uma mistura de variáveis inteiras e contínuas, denominando o uso da programação linear inteira mista (Pardalos *et al.*, 2006).

Silva *et al.* (2003b) afirmam que os resultados operacionais provenientes de processos de arredondamentos de soluções obtida via PL não devem ser adotadas. A explicação foi

mostrada em seu estudo, indicando que certas restrições e objetivos não puderam ser atendidos após o arredondamento, sendo ainda produzida uma solução inviável para o problema. Segundo os autores, o problema de arredondamento ocorre independente do comportamento da função objetivo (maximizar ou minimizar).

A inclusão de variáveis inteiras muda consideravelmente a natureza da região factível e assim não há nenhuma garantia de que a solução ótima esteja no ponto extremo do plano, conforme observado na PL (MITCHELL, 2001). A Figura 5 ilustra a idéia da diferença entre soluções inteiras e contínuas.

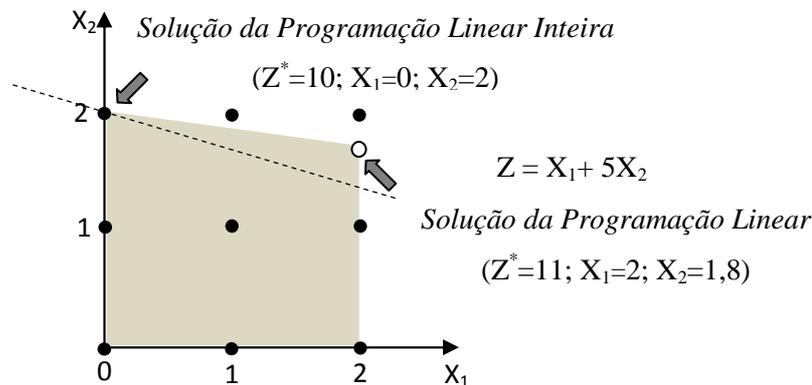


FIGURA 5 - DIFERENÇA ENTRE A PROGRAMAÇÃO LINEAR E A PROGRAMAÇÃO LINEAR INTEIRA (ADAPTADO DE HILLIER e LIEBERMAN, 2001).

Segundo Williams (2006), as alternativas de resolução de problemas envolvendo a programação linear inteira/mista englobam métodos enumerativos, algoritmos construtivos e algoritmos de corte. Desta maneira, o primeiro método de resolução desenvolvido foi o algoritmo de corte de Gomory. Entretanto outros métodos foram propostos como: *branch-and-bound*, *branch-and-cut*, relaxação lagrangeana, *constraint satisfaction*, heurísticas e o método de projeções (eliminação de Fourier-Motzkin). Contudo, o método de resolução mais popular é o mecanismo de busca do algoritmo *branch-and-bound* (ROSSI *et al.*, 2006).

A idéia básica do algoritmo *branch-and-bound* é dividir e delimitar, ou seja, este processo, chamado divisão (*branch*) no primeiro momento, tem o efeito de contrair a região factível com o propósito de eliminar a solução corrente não inteira, porém preservando ainda todas as possíveis soluções inteiras do problema original. A delimitação é realizada na medida em que se encontram boas soluções no conjunto das divisões. A Figura 6 mostra a idéia do algoritmo de dividir e delimitar a solução.

1.4 HEURÍSTICAS E METAHEURÍSTICAS

Os processos de otimização passaram por reformulações e mudanças conceituais durante as últimas décadas, devido à crescente demanda por métodos de resolução mais eficientes. Assim, durante a década de 70, problemas considerados de difícil resolução ganharam a atenção da ciência, pois os métodos tradicionais não eram viáveis. Neste período, não existiam algoritmos capazes de obter soluções factíveis ótimas, com requerimento de tempo computacional polinomial compatível (JONES *et al.*, 2002b). Desta maneira, uma revolução de idéias e tendências matemáticas foi surgindo a partir da necessidade gerada e objetivos complexos.

Um algoritmo não determinístico é dividido em duas partes, a primeira corresponde à escolha da solução candidata inicial (podendo fazer uso de escolhas não determinísticas); já a outra parte consiste em verificar de forma determinística se a provável solução é de fato uma solução para o problema (NASCIMENTO, 2002).

Os problemas classificados como *NP-hard* estão associados normalmente à otimização de processos combinatórios. Segundo Heinonen (2007), a otimização combinatória é definida como um processo de busca de uma ou mais soluções, a partir de um conjunto de soluções possíveis ao problema. Na área florestal, a maioria dos problemas de otimização assumem a natureza combinatória e como exemplo tem-se: problemas de adjacência, roteamento de veículo para o transporte florestal, corte na indústria de móveis e papel, dentre outros (PEREIRA, 2004). Hertz e Widmer (2003) afirmam que a otimização combinatória é um processo complicado na tomada de decisão, principalmente quando decisões ótimas dependem de vários fatores não triviais.

Nas décadas de 80' e 90', inúmeros algoritmos de busca foram desenvolvidos como foi o caso de *hillclimbing*, busca tabu, *simulated annealing* e outros (HERRMAN, 2006). Havia ainda a presença de algoritmos que apresentavam estratégias de busca baseadas em processos ou fenômenos naturais (ADELI e SARMA, 2006). Assim, muitos problemas florestais considerados complexos e com características não lineares passaram a ser resolvidos, graças à introdução de algoritmos mais flexíveis e inteligentes (BETTINGER *et al.*, 2002). Esta classe de métodos inteligentes de busca só foi desenvolvida após constatar a ineficiência dos métodos tradicionais (BASKENT, 2001).

Nas últimas décadas, uma nova ciência computacional denominada de computação natural foi introduzida no meio científico, sendo inspirada na natureza (VICTORINO, 2005).

Esta ciência baseia-se em processos e fenômenos naturais, inspirando o desenvolvimento de metodologias e algoritmos para a resolução de problemas matemáticos. A diferença entre os diversos algoritmos está nos critérios de seleção e mapeamento da solução, durante os processos de busca (BASKENT, 2001). A Figura 7 apresenta a relação dos processos pertencentes à computação natural.

Stützle (1998) comenta a existência de uma classe de algoritmos de aproximação conhecida como heurísticas, que buscam soluções próximas do ótimo em tempo polinomial compatível. Oliveira (2004) afirma que o conceito de heurística foi revisto, devido ao aperfeiçoamento de seu desempenho, resultando na nova classe chamada metaheurísticas.

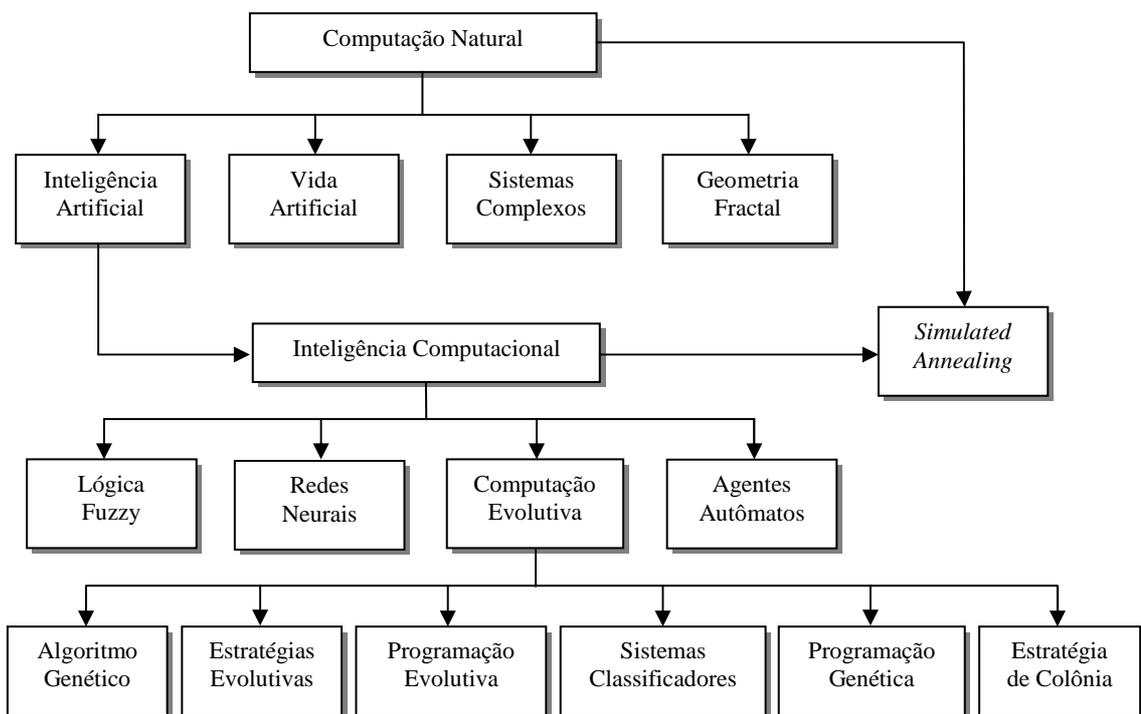


FIGURA 7- DISTRIBUIÇÃO DAS ÁREAS LIGADAS À COMPUTAÇÃO NATURAL (VICTORINO, 2005).

O pioneiro no uso da expressão metaheurística foi Glover (1986), que abordou em seu estudo as novas perspectivas sobre a pesquisa operacional e inteligência artificial na resolução de problemas de análise combinatória. Segundo Ponsich *et al.* (2008), o desenvolvimento e aprimoramento das metaheurísticas durante as últimas décadas é considerado um avanço importante na área de otimização.

As metaheurísticas são geralmente técnicas de otimização combinatória, que não se dedicam exclusivamente a um único tipo de problema abordado, mas são desenvolvidas para ter uma maior flexibilidade e resolver diferentes tipos de problemas de otimização (HERTZ e WIDMER, 2003). Segundo Glover e Kochenberger (2003) as metaheurísticas são métodos de

resolução que orquestram uma interação entre procedimentos de melhoria local e apuradas estratégias, com a finalidade de escapar de ótimos locais a partir de buscas robustas no espaço de soluções.

De acordo com Ponsich *et al.* (2008) as metaheurísticas são métodos formados por um conjunto fundamental de idéias, onde se expressa uma seqüência de regras heurísticas, idealizadas para a resolução de problemas de otimização.

Um conceito mais completo sobre metaheurísticas pode ser observado em Osman e Laporte (1996). Os autores as definem como sendo um processo de geração iterativo e inteligente, que guia uma heurística subordinada a explorar espaços de buscas. Nesta etapa, utilizam inspirações nas ciências naturais para encontrar soluções não tão distantes do ótimo, porém não garantem a otimalidade. A classificação das metaheurísticas engloba questões ligadas à estratégia de funcionamento, conforme observado na Tabela 3.

TABELA 3 - CLASSIFICAÇÃO DAS METAHEURÍSTICAS SEGUNDO A ESTRATÉGIA DE FUNCIONAMENTO (ADAPTADO DE STÜTZLE, 1998).

Estratégia	Tipo de funcionamento	
	A	B
1	trajetória	descontínuos
2	utiliza memória	não utilizam memória
3	várias soluções candidatas (população)	uma única solução candidata
4	única vizinhança	várias vizinhanças
5	função objetivo estática	função objetivo dinâmica
6	inspirados na natureza	não inspirados na natureza

As metaheurísticas não são capazes de certificar que a solução apresentada por elas possa ser considerada como ótimo global (ÖHMAN e ERIKSSON, 2002). O conhecimento desta afirmativa é possível, pois muitas vezes as metaheurísticas são confrontadas com procedimentos exatos para mensurar a distância entre o ótimo global e o melhor encontrado após as buscas (GLOVER e KOCHENBERGER, 2003). Segundo Youseff *et al.* (2001) outros problemas podem ser recorrentes nas metaheurísticas, como o caso de serem míopes e não reconhecerem quando a solução ótima for encontrada; aceitam soluções piores durante o ciclo de processamento e necessitam de critérios de parada.

Baskent e Jordan (2002) listam uma série de deficiências encontradas nas metaheurísticas, conforme apresentado anteriormente, e acrescentam ainda a necessidade de estudar o comportamento de seus parâmetros. Segundo os autores, a modelagem dos parâmetros nas metaheurísticas requer um conhecimento prévio dos usuários, pois o mesmo se torna um problema específico.

Jones *et al.* (2002b) afirmam que os procedimentos heurísticos são técnicas que procuram boas soluções em problemas de difícil solução, e por isso são recomendados para problemas de otimização combinatória.

1.4.1 Busca de soluções

Uma busca exaustiva por soluções exatas não é uma prática inteligente, principalmente quando o problema apresenta restrições complexas. A pesquisa do espaço de soluções pode ser muitas vezes exageradamente grande, ou existir muita inconveniência em enumerar todo o espaço de busca. Tipicamente, o espaço de busca é formado por restrições matemáticas do problema, que definem um polígono composto por soluções factíveis em seu interior (BURKE *et al.*, 2003). Segundo Groner *et al.* (1983) as heurísticas foram desenvolvidas para reduzir o tempo de busca das soluções, através de um conjunto de regras definidas.

A metaheurística apresenta uma função semelhante à função objetivo, presente na programação linear, porém têm como finalidade avaliar a qualidade das respostas. Este mecanismo é vital para um bom desenvolvimento do algoritmo, pois o guia para os melhores *nichos* de respostas.

O procedimento de busca adotado pela metaheurística é um ponto chave para a qualidade da solução. Em geral, um ponto importante é a relação entre intensificação (concentrar a busca de solução em parte do espaço) e diversificação (elaborar vários caminhos de busca no espaço) durante os processos de busca dos algoritmos. Esta mistura de estratégia é sempre apropriada, pois promove uma exploração detalhada nas vizinhanças visitadas, e ao mesmo tempo, uma ampla busca de rotas dentro do espaço de soluções (GREISTORFER e VOB, 2005).

As buscas sucessivas de soluções são proporcionadas em virtude da habilidade e estratégia dos algoritmos, ao realizar um elevado número de buscas durante as iterações. Esta busca é representada por funções de vizinhança, que trabalham os arranjos da solução atual, via trocas e/ou movimentos, definindo assim um espaço de vizinhança local pesquisado (MICHIELS *et al.*, 2007).

A qualidade da solução final depende de sua localização no espaço, pois o mesmo é dividido em duas regiões distintas. Segundo Ashlock (2005) a primeira região refere-se a um ponto conhecido como ótimo global, e que representa a solução exata para o problema. Em outras palavras é um ponto no espaço onde nenhum outro ponto excede seu valor

(maximização), ou o ponto mais inferior ao conjunto de pontos do espaço (minimização). A segunda região diz respeito ao ótimo local que representa um ponto estacionário formado por uma solução não ótima, onde o algoritmo não consegue melhorar sua solução. Entretanto, existem estratégias para sair destes ótimos locais, mas muitas vezes são deslocados para outro ótimo local. Desta forma, faz-se necessário processar uma metaheurística n vezes para evitar um péssimo ótimo local (ÖHMAN e ERIKSSON, 2002).

A Figura 8 apresenta um espaço de soluções factíveis definidas para um problema de maximização, sendo representados dois pontos (soluções) o ótimo global e o local. Este último pode ser encontrado em várias regiões do espaço a diferentes distâncias do ótimo global.

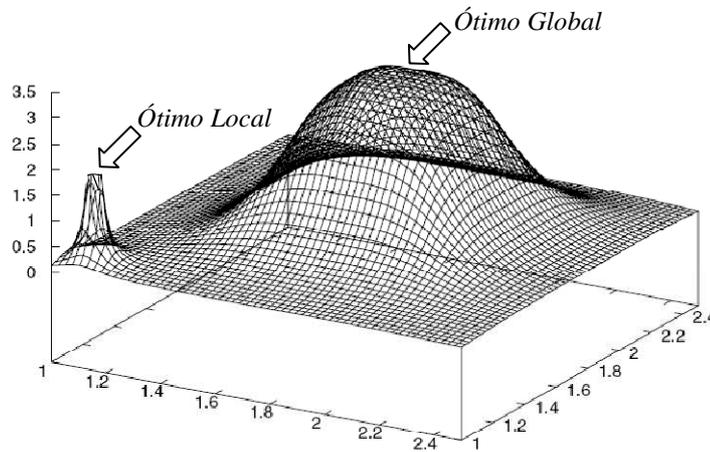


FIGURA 8 - REPRESENTAÇÃO DO ESPAÇO DE SOLUÇÕES E SUA DIVERSIDADE DE RESPOSTAS (ADAPTADO DE ASHLOCK, 2005).

Segundo Mitsuo e Cheng (2000) o tamanho da vizinhança afeta a qualidade do ótimo local, e em certos casos, a probabilidade de se encontrar boas soluções é altamente correlacionada com o número de soluções vizinhas formadas. A busca por soluções em processos ligados à programação evolutiva é feita de forma múltipla, ou seja, através de iterações via população; já em outros casos, a cada iteração é pesquisado apenas um único vizinho local, ou solução candidata. Estes fatos demonstram que a qualidade dos processos de busca vem sendo pesquisada exaustivamente durante as últimas décadas, conforme comentam Hertz e Widmer (2003).

Michiels *et al.* (2007) consideram que os algoritmos de aproximação podem ser classificadas em duas categorias: algoritmos construtivos - a solução é encontrada a partir de um número de etapas onde, a cada etapa, uma parte da solução é obtida até a conclusão do processo e a formação da solução na última fase, e algoritmos de refinamento - uma solução inicial é produzida e, a partir de n -iteraões, novas soluções vizinhas são geradas objetivando

uma melhoria da solução nas iterações subseqüentes.

Os algoritmos de refinamento apresentam ainda duas subdivisões, de acordo com o tipo de funcionamento das buscas. O primeiro tipo representa um grupo de algoritmo que utiliza apenas uma busca por iteração; já o segundo grupo considera a busca a partir de várias soluções iniciais, também chamada de população inicial. Neste caso, as buscas são realizadas de forma múltipla por iteração (MICHIELS *et al.*, 2007). A Figura 9 apresenta uma estrutura genérica de funcionamento de um algoritmo que realiza apenas uma busca por iteração.

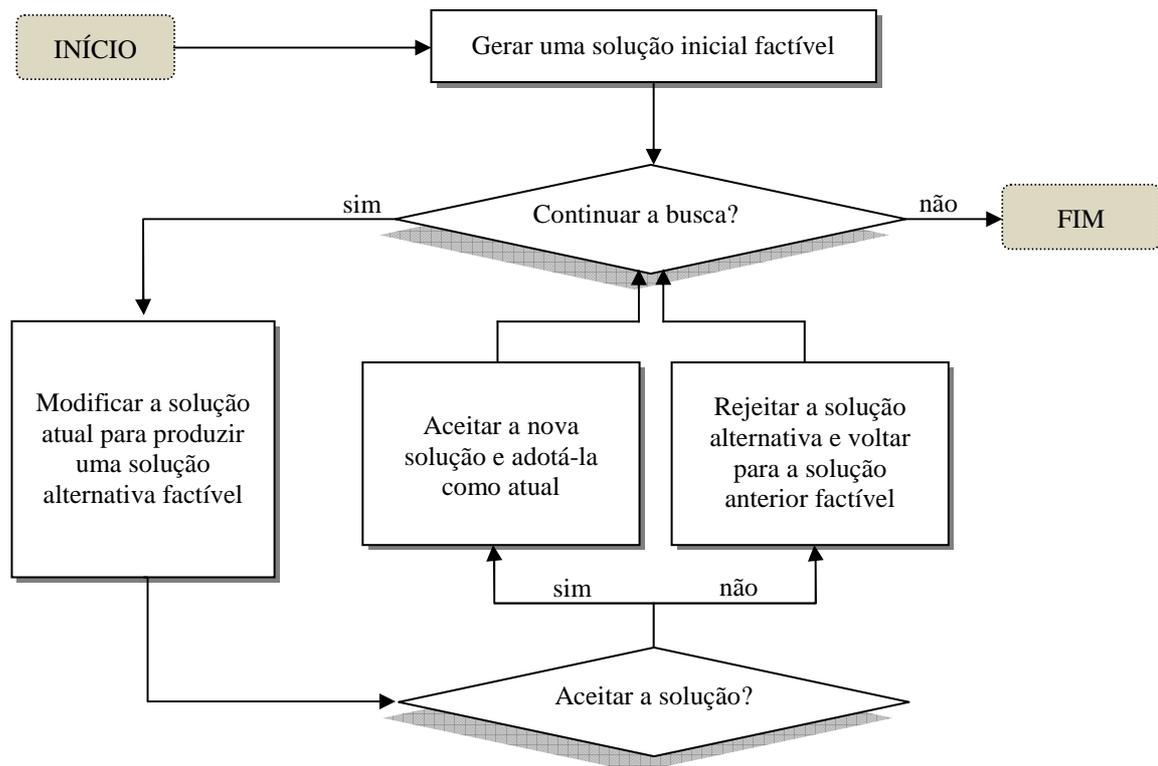


FIGURA 9 - REPRESENTAÇÃO GENÉRICA DE UM PROCESSO HEURÍSTICO QUE REALIZA BUSCAS ATRAVÉS DE UMA ÚNICA SOLUÇÃO POR ITERAÇÃO (ADAPTADO DE MURRAY, 1999).

Hertz e Widmer (2003) apresentam um guia de uso de metaheurísticas em problemas de otimização combinatória. No artigo, os autores listam os cuidados e critérios ao construir processos de busca de soluções:

A) Busca através de uma única solução por iteração:

- A formação da solução deve ser um processo simples;
- As soluções visitadas devem ser viáveis para facilitar a procura da solução ótima;
- A vizinhança de uma solução N deve ser razoavelmente fácil de obtenção, através de pequenas modificações na solução atual;

- A função de custo não deve ter uma topografia muito plana, pois este comportamento dificulta a fuga de ótimos locais.

B) Busca via população

- Informações importantes devem ser transmitidas durante a fase de reprodução;
- A combinação de dois pais (soluções) deveria produzir filhos diferentes de seus pais;
- A diversidade deve ser preservada na população.

A Figura 10 apresenta um fluxograma genérico de funcionamento do processo de busca de uma heurística, que considera o uso de múltiplas soluções ou população.

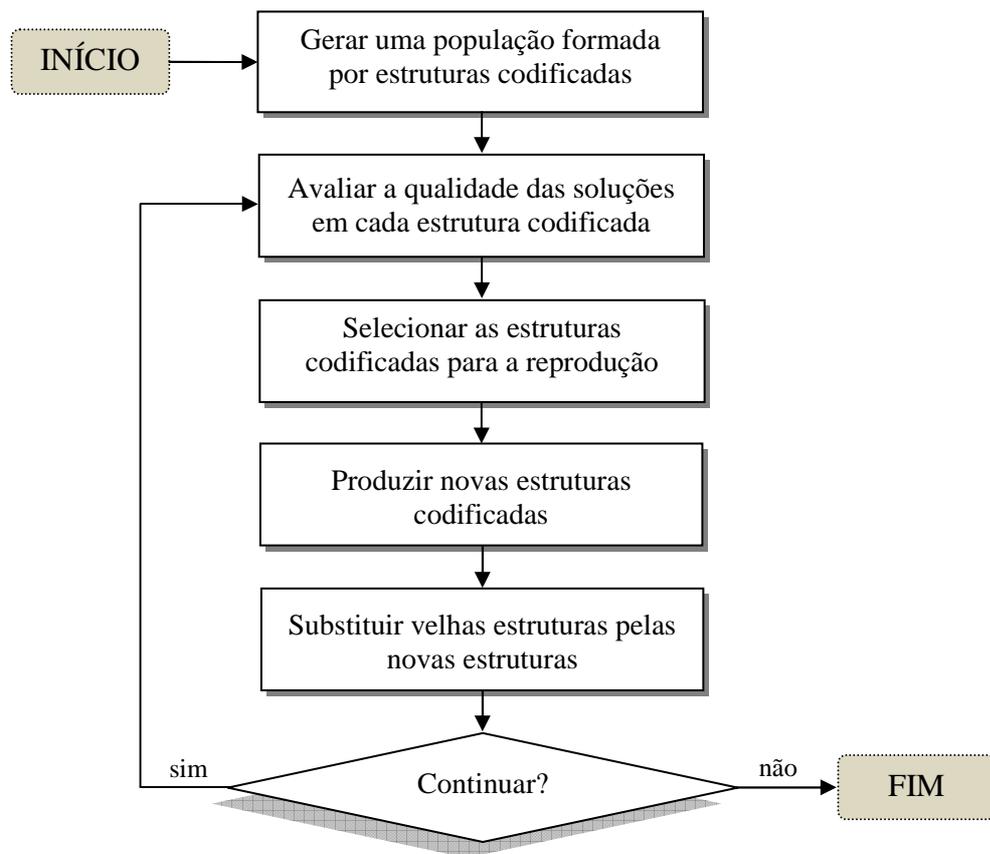


FIGURA 10 - ESTRUTURA DE FUNCIONAMENTO DE UMA HEURÍSTICA EVOLUTIVA GENÉRICA COM BASE NO MÉTODO DE BUSCA POR POPULAÇÃO (ADAPTADO DE ASHLOCK, 2005).

Os dois métodos de busca de solução funcionam basicamente da mesma maneira, devendo inicialmente gerar um conjunto de soluções potenciais, ou uma única solução potencial, e em seguida realizar avaliações conforme o critério proposto em cada algoritmo (VICTORINO, 2005). Segundo Stützle (1998), uma metaheurística terá sucesso na resolução de problemas de otimização se explorar e mapear o espaço em regiões compostas de boas soluções. Além disso, é de fundamental importância acumular esta experiência durante o mapeamento.

1.4.2 Algoritmo genético (AG)

1.4.2.1 Histórico de desenvolvimento

Historicamente, o primeiro material publicado sobre algoritmo genético foi *Adaptation in Nature and Artificial Systems* escrito por John Holland em 1975, onde o autor apresenta suas idéias e teorias a respeito do assunto (REEVES, 2003). Entretanto, na década de 60', alguns cientistas como Ingo Rechenberg e Hans-Paul Schewefel (Alemanha) e Bremermann e Fogel (EUA) já esboçavam a criação de algoritmos que inspiraram o algoritmo genético (REEVES, 2003).

Mitchell (1996) comenta que Rechenberg introduziu o conceito de estratégias evolutivas na década de 60, onde suas idéias foram melhoradas por Schewefel na década seguinte. As descobertas encontradas pelos pesquisadores Fogel, Owens e Walsh ajudaram ainda mais o desenvolvimento do AG, pois estes autores apresentaram um conceito rudimentar de programação evolutiva, ao demonstrar uma idéia de mutação randômica no estado da solução candidata (MITCHELL, 1996). Assim, o passo seguinte na construção do AG foi unir os conhecimentos já desenvolvidos e introduzir o conceito de população definido por Holland. O ponto chave do AG foi a introdução da população no algoritmo, pois até o momento não existia.

Desta forma, a influência de Holland no seu desenvolvimento foi considerada o marco inicial na história do AG e que indiscutivelmente contribuiu para a ciência como um todo. Segundo Mitchell (1996), apesar do pioneirismo e vanguarda, o algoritmo tinha poucas aplicações e se restringia a um pequeno número de problemas específicos. Assim, o autor da obra não imaginava o grande impacto de seu método em aplicações futuras.

Goldberg (1989) define o AG como um procedimento de busca baseado no mecanismo genético e de seleção natural. Este algoritmo é um exemplo de como a humanidade imita os processos e mecanismos existentes na natureza, na tentativa de resolver seus próprios problemas (LOBO, 2005). Os processos de criação das metaheurísticas passaram, na maioria dos casos, pela observação de fenômenos ambientais e biológicos, sendo na seqüência estruturados matematicamente. Segundo Victorino (2005), os objetivos da pesquisa de Holland envolvendo o AG foram: resumir e explicar rigorosamente os processos adaptativos dos sistemas naturais; e, projetar e desenvolver sistemas artificiais que imitam estes mecanismos.

Ashlock (2007) afirma que o AG é o algoritmo evolutivo mais conhecido atualmente, atuando nas estruturas a partir das operações de seleção, mutação e reprodução. A Figura 11 apresenta um fluxograma de funcionamento de um AG simples.

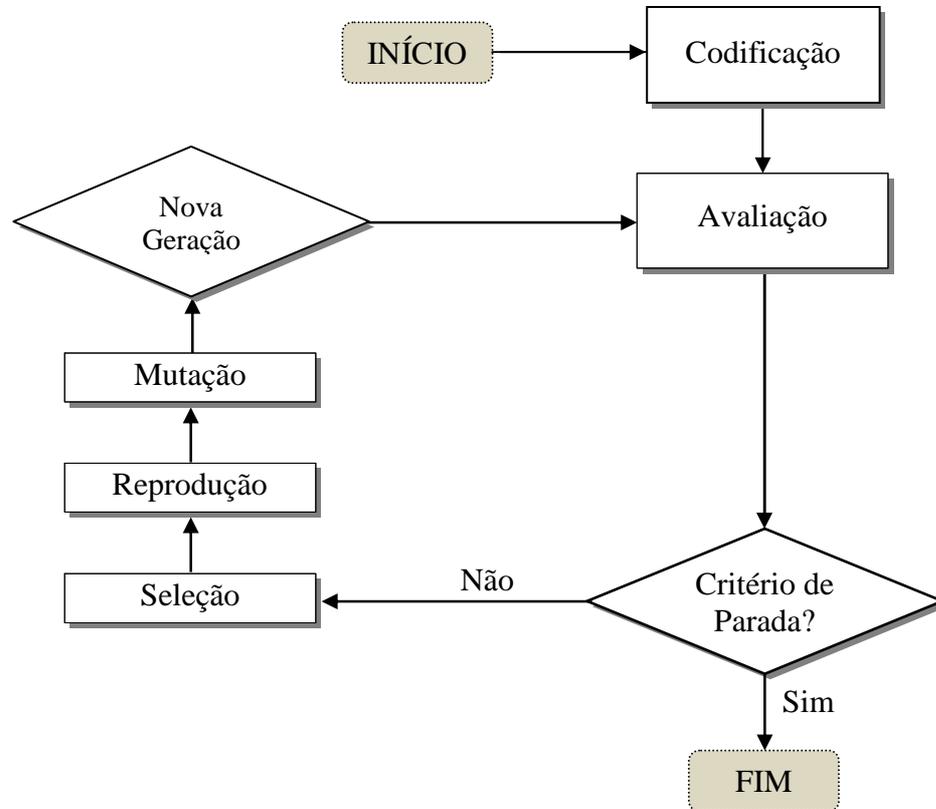


FIGURA 11 - ESTRUTURA DE FUNCIONAMENTO DE UM ALGORITMO GENÉTICO SIMPLES.

Através das décadas seguintes, inúmeras aplicações foram atribuídas ao AG e nas diversas áreas do conhecimento. Coley (1999) lista uma série de atividades científicas e técnicas que estão utilizando o AG, sendo elas: processamento de imagem, predição de estrutura de proteínas em 3D, tecnologia a laser, VLSI (*very large scale integration*) em camadas eletrônicas para chips, medicina, trajetória de viagem espacial, análise de séries temporais, processos termodinâmicos, aeronáutica, robótica, regras de autômatos celulares, aspectos arquitetônicos de construção de casas, avaliação automática de softwares, reconhecimento de face e padrão, otimização, dentre outros. Tsao e Chen (2004) relatam o sucesso do uso deste algoritmo na resolução de problemas reais, principalmente aqueles onde o espaço de busca da solução é bastante complexo.

A introdução do AG na otimização foi realizada através do trabalho de Ken DeJong, um orientado de John Holland (REEVES, 2003). Neste trabalho de Tese, DeJong descreve o quanto o algoritmo é robusto ao estimar uma série de parâmetros desconhecidos de um modelo (COLEY, 1999). Todavia, o AG se difundiu apenas na década de 80, após um

importante trabalho na área industrial desenvolvido por Goldberg, outro aluno de John Holland (MITCHELL, 1996).

1.4.2.2 Idéias biológicas e evolutivas introduzidas no algoritmo

O funcionamento do AG é baseado na analogia de conceitos de adaptação, seleção natural e idéias genéticas, onde boas soluções são pesquisadas a partir de uma série de regras ligadas aos indivíduos e ao problema considerado (PONSICH *et al.*, 2008). Exemplificando, o algoritmo inicia com um conjunto de soluções candidatas ao problema (população), onde são avaliadas por uma função de qualidade, denominada de *fitness*. Assim, os indivíduos mais fracos desaparecem do sistema enquanto os melhores sobrevivem e reproduzem entre si. Pelo conceito de herança genética, as qualidades genéticas de cada indivíduo considerado bom são preservadas na população e repassadas para as gerações seguintes.

De acordo com Koza (1992), a população parte de indivíduos heterogêneos em um primeiro instante; contudo, ao longo do tempo os mais adaptados sobrevivem e se reproduzem a taxas aceleradas e suas características são transmitidas a gerações futuras. Desta forma afirma-se que a nova população evolui e suas diferenças são visualmente mensuráveis. A elaboração destas regras é baseada nas teorias evolutivas desenvolvidas por Charles Darwin, nas idéias de hereditariedade discutidas por Gregor Mendel e em outros conceitos ligados à genética moderna.

Segundo Rothlauf (2006) as idéias de Darwin podem ser resumidas nos seguintes princípios básicos: existem na população alguns indivíduos com propriedades e habilidades diferentes; a natureza cria novos indivíduos com propriedades parecidas à população já existente; indivíduos mais aptos são selecionados mais facilmente para a reprodução nos processos naturais. Darwin pensou ainda que a população pode apresentar um crescimento exponencial se todos os indivíduos de uma mesma espécie reproduzissem; e o processo de seleção natural fornece para as espécies (indivíduos) a condição de estarem cada vez mais adaptadas (VICTORINO, 2005).

A idéia de hereditariedade e conceitos provindos da genética moderna também participa das regras de funcionamento do AG. Assim, o termo cromossomo refere-se à solução candidata do problema, sendo codificada por uma seqüência de códigos, que muitas vezes é binária (0,1). Os genes são constituições presentes dentro de cada cromossomo e podem ser um simples *bit* ou um pequeno grupo seqüencial de *bits* adjacentes. Assim, cada

elemento do gene é responsável por expressar uma qualidade dentro do problema e contribui por carregar uma porção da informação. O valor binário (0,1) que estes genes assumem em cada unidade é denominado de alelo, e estes assumem a tarefa de ativar ou desativar partes da função de avaliação (*fitness*). A posição que os alelos ocupam dentro do cromossomo é informada pelo *locus*. A Figura 12 apresenta um esquema resumido da nomenclatura utilizada para o AG.

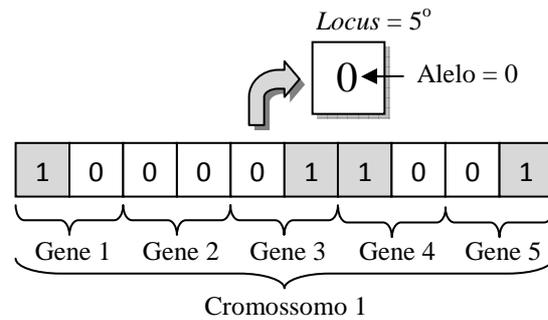


FIGURA 12 - EXEMPLO DA NOMENCLATURA E CODIFICAÇÃO EMPREGADA NO ALGORITMO GENÉTICO.

Segundo Mitchell (1996), os termos fenótipo e genótipo foram introduzidos recentemente, sendo também uma analogia aos conceitos do processo biológico. Rothlauf (2006) explica que o fenótipo descreve a aparência externa de um indivíduo; já o genótipo é responsável pela estrutura de códigos dos cromossomos. A ligação entre eles é observada pela capacidade do genótipo em modelar e criar um novo fenótipo, sendo o fenótipo uma expressão gênica do genótipo.

Durante o processo de reprodução, os filhos não herdam as informações diretamente do fenótipo de seus pais, mas somente as informações contidas nos genótipos. Assim, os filhos herdam as informações genéticas dos pais, e pela combinação de genes é formado o fenótipo do filho. Entretanto, no processo de seleção a escolha dos cromossomos para a reprodução é feita exclusivamente via fenótipo (ROTHLAUF, 2006).

A qualidade e evolução da população é medida por uma função de adaptação calculada para cada indivíduo. As decisões de seleção e reprodução muitas vezes são feitas pela comparação destas funções, também chamadas de *fitness*. Adeli e Sarma (2006) conceituam *fitness* como um indicador do potencial de sobrevivência e reprodução dos indivíduos, através das gerações. O *fitness* apresenta a mesma característica que a função objetivo encontrada na programação linear em problemas de otimização. A função de *fitness* é definida por Ashlock (2007) como sendo uma maneira da metaheurística estimar a qualidade dos membros pertencentes à população.

1.4.2.3 Princípio de funcionamento

Segundo Reeves (2003), existe uma ampla discussão a respeito do tema, principalmente de como e porque o AG funciona. Esta questão ainda é debatida por várias escolas; entretanto nenhuma conclusão exata de seu funcionamento ainda foi formulada. Queiroz (2005) comenta que não existe qualquer demonstração matemática comprovando o funcionamento do AG, em direção à convergência de um ótimo local, para um dado problema teste.

A teoria tradicional de funcionamento do AG foi desenvolvida por Holland, sendo conhecida como teoria *schemata* ou esquema. A idéia base de Holland consistia em mostrar que o esquema é um subconjunto do espaço A' , onde os cromossomos dividem um conjunto de valores, ou seja, dividem porções de informações semelhantes entre si. Exemplificando, imagine um cromossomo formado por quatro genes onde seus alelos assumem valores binários $\{0,1\}$. Supondo agora que o primeiro e último locus assumam valores iguais a 1 $\{1 _ _ 1\}$, e o restante dos loci pode variar entre os valores binários $\{0,1\}$. As estruturas variantes deste cromossomo são representadas da seguinte maneira: $\{1 \ 0 \ 0 \ 1; 1 \ 1 \ 1 \ 1; 1 \ 1 \ 0 \ 1; 1 \ 0 \ 1 \ 1\}$. Considerando esta estrutura binária, o cromossomo pode assumir 2^n diferentes tipos de estruturas ou esquemas, onde n é o número de loci do cromossomo.

No teorema existem duas propriedades para a construção dos esquemas: a extensão ($d(S)$) que se refere à distância entre o primeiro e o último locus com valor conhecido, e a ordem ($o(S)$) que caracteriza o número de loci onde se conhece o valor da posição $\{0, 1\}$.

Coley (1999) apresenta uma formulação (5) na qual é possível estimar a melhoria da população para a próxima geração. A formulação indica que os esquemas com bons valores de *fitness*, ou adaptação acima da média, têm a possibilidade de crescer exponencialmente nas gerações futuras a partir de uma dada estimativa. Entretanto, o resultado desta fórmula é apenas uma expectativa e deve ser utilizado apenas para uma geração posterior à atual (REEVES, 2003). Assim, qualquer intenção de extrapolar seus resultados para mais de uma geração leva a erros. Desta maneira, a média das soluções encontradas é melhorada ao longo das gerações.

$$\bar{\theta}(S, g + 1) = \frac{u(S, g)}{f_{ave}(g)} \theta(S, g) \left[1 - P_c \frac{d(S)}{L-1} - o(S) P_m \right] \quad (5)$$

Onde:

S - esquema;

o - ordem;

d - extensão;

P_c - probabilidade de cruzamento;

P_m - probabilidade de mutação;

L - número de locos do cromossomo;

g - geração;

$\bar{\theta}(S, g + 1)$ - *fitness* médio estimado para a próxima geração, a partir de $\theta(S, g)$;

$\theta(S, g)$ - o número de instâncias do esquema, ou o número de combinações possíveis que um dado cromossomo pode gerar, quando são fixados alguns genes com valores binários;

$f^{ave}(g)$ - valor do *fitness* médio da população na geração g ;

$u(S, g)$ - é a média dos *fitness* de S .

Gen e Cheng (2000) comentam a existência das hipóteses *building-blocks* e *Convergence-controlled variation* que explicam a capacidade do AG em explorar boas soluções e repassá-las às novas gerações, sendo então descritas:

- *Building blocks* (blocos construtivos): foi proposta por Holland e refinada mais tarde por Goldberg. Esta hipótese descreve que o *crossover* recombina dois pais, e estes produzem seus descendentes. Assim, neste ponto pode existir a combinação de dois genótipos de alta qualidade e gerar um indivíduo melhor.

- *Convergence-controlled variation* (variação da convergência controlada): foi desenvolvida por Eshelman, Mathias e Schaffer. A hipótese sugere o uso da convergência de uma população para restringir sua busca. Assim, novos indivíduos são amostrados em função de uma distribuição da população, a qualquer tempo. Em outras palavras, uma randomização de amostras do espaço é selecionada em virtude da distribuição da população na geração atual.

Estas duas hipóteses trabalham juntas durante o processamento do algoritmo e tentam demonstrar o funcionamento do algoritmo genético. Outras teorias foram propostas na tentativa de se conhecer o exato funcionamento do algoritmo, podendo citar a teoria da cadeia de Markov¹, teorias estatísticas e teorias ligadas à busca de vizinhança (REEVES, 2003).

¹ Cadeia de Markov: é um processo randômico que utiliza variáveis aleatórias e estados estocásticos de transição, sendo aplicado em diversas áreas do conhecimento.

1.4.2.4 Processo de codificação

Nos últimos anos, vários métodos de codificação do AG têm sido propostos devido ao surgimento de problemas que dificultavam a sua implementação (GEN e CHENG, 2000). Segundo Ponsich *et al.* (2008), a estratégia utilizada na codificação pode afetar fortemente o desenvolvimento e a eficiência do algoritmo. Uma das diferenças básicas entre os processos de codificação se restringe ao tipo de variável a ser utilizada, podendo ser discreta ou contínua a depender do problema abordado. Gen e Cheng (2000) comentam que o desafio de se implementar o AG está na forma de como traduzir o problema para a codificação das variáveis dentro do cromossomo.

Mitchell (1996) afirma que o código binário {0,1} é a codificação mais empregada no AG. O autor afirma que esta tendência é histórica e está ligada ao processo de desenvolvimento do AG por John Holland. A classificação do tipo de codificação existente pode ser observada a seguir, conforme Victorino (2005), sendo: codificação binária, codificação com números reais e codificação *Gray*. Na literatura ainda é possível encontrar outro mecanismo de codificação, o qual utiliza o alfabeto para preencher todos os lócus do cromossomo em processos de criptografia e quebra de códigos, como observado em (MORELLI e WALDE, 2003).

O tipo de codificação a ser utilizado não é determinado por regras claras, e sim pela forma como o usuário entende o problema e o traduz para o universo do AG. A princípio, a maneira mais sensata de conhecer a modelagem da codificação é a partir de testes e experimentação (MITCHELL, 1996).

1.4.2.5 Função de avaliação (*fitness*)

A sobrevivência dos indivíduos no ambiente provém da adaptação dos mesmos ao ambiente, conforme idealizado por Darwin. O princípio de adaptação ou *fitness* foi introduzido no AG por Holland, para direcionar os processos de seleção na reprodução. Segundo a teoria de seleção natural de Darwin, os melhores indivíduos ou os mais adaptados ao meio reproduzem com mais frequência.

No AG o *fitness* é apenas um link entre o algoritmo e o problema a ser resolvido (SAKAWA, 2002). Desta forma, o *fitness* é uma função que avalia a qualidade dos indivíduos da população, sendo referência nos processos de seleção dos indivíduos para a reprodução

(ASHLOCK, 2005). Além disso, apresenta uma característica de mapear a qualidade dos genes na população. Resumidamente, pode-se dizer que o *fitness* é a expressão fenotípica de um indivíduo, calculado a partir da combinação dos genes presentes no cromossomo, e que tem como objetivo medir a qualidade do indivíduo. A idéia de maximizar ou minimizar uma função é preservada e aplicada sobre a função *fitness*, em problemas envolvendo otimização (ASHLOCK, 2005).

Segundo Victorino (2005), a função de avaliação presente no AG deve ser elaborada, na maioria das vezes, para cada tipo de problema a ser resolvido. Em outras palavras, existe um conjunto de regras para a implementação da função de aptidão, mas é sempre necessária a definição da estrutura do *fitness* a cada novo problema.

1.4.2.6 População

A população é a característica que mais identifica o AG do conjunto de metaheurísticas desenvolvidas, por ser o pioneiro no uso desta estratégia. Adeli e Sarma (2006) comentam que o AG difere dos algoritmos de busca tradicional, como o *Hill-climbing*, exatamente por apresentar um conjunto de soluções candidatas a cada iteração. Esta estratégia possui uma maior probabilidade de sair de ótimos locais, graças a este conjunto de soluções.

O método utilizando população não é um conceito exclusivo do AG, sendo muito utilizado na programação evolutiva, a exemplo cita-se a metaheurística *Scatter search*. Segundo Hertz e Widmer (2003), os métodos que trabalham a população estão associados a técnicas que modelam os indivíduos a partir de regras de seleção, reprodução e mutação. Segundo Glover (2003), o tamanho da população é um dos primeiros parâmetros que devem ser analisados para o processamento do AG.

Oliveira (2004) afirma que o tamanho da população é um parâmetro importante para a performance do algoritmo durante as buscas. Segundo o autor, se o tamanho da população for muito pequeno, a convergência do algoritmo pode ser prematura e atrapalhar a qualidade da solução final. Na biologia esta afirmativa é plausível, pois em pequenas populações a diversidade genética dos indivíduos é muito baixa, o que provoca problemas em adaptação ao meio, caso ocorram grandes mudanças (ASHLOCK, 2005). O efeito de uma população reduzida causa uma limitação na pesquisa do espaço de soluções, e o contrário promove uma perda de sua eficiência (GLOVER, 2003).

1.4.2.7 Operadores

Um dos pontos chave no planejamento do AG está relacionado à escolha do tipo de operador empregado. Embora o tipo de estratégia adotada pelo AG possa variar na literatura, é sabido que três operações básicas ainda são preservadas e utilizadas, sendo elas: seleção, reprodução e mutação (ADELI e SARMA, 2006). A idéia destes operadores está diretamente relacionada às teorias evolutivas e genéticas introduzidas no algoritmo por Holland. Reeves (2003) comenta a existência de uma opção alternativa, que utiliza apenas a reprodução ou mutação na formação de novos indivíduos. Ashlock (2005) denomina que a reprodução e a mutação são operadores de variação, exatamente por realizar mudanças nas bases genéticas dos indivíduos.

Gen e Cheng (1996) apontam a existência de apenas dois tipos de operadores presentes no AG, sendo eles os operadores genéticos de recombinação e os operadores evolutivos de seleção. Os autores descrevem ainda que o operador genético de recombinação sintetiza os processos genéticos de herdabilidade dos genes, para criar novos indivíduos. Os operadores evolutivos de seleção, por sua vez, copiam a idéia de seleção natural de Darwin para modelar as gerações ao longo do tempo.

Rothlauf (2006) comenta que os novos indivíduos criados não são gerados aleatoriamente, e sim seguindo a lógica de funcionamento dos operadores. A importância destes operadores é refletida na capacidade do algoritmo em buscar melhores soluções a cada geração. Neste caso, indivíduos inferiores são removidos da população após um pequeno número de iterações e assim não têm chance de gerar filhos com suas características. Como resultado, a média do *fitness* da população aumenta através das gerações. A idéia descrita mostra a existência de uma dependência direta entre os operadores e a resposta do *fitness* para cada indivíduo da população.

1.4.2.7.1 Operadores evolutivos de seleção

O processo de seleção utiliza a teoria de evolução natural de Darwin, conforme comentado, e consiste basicamente na seleção dos indivíduos que irão reproduzir e gerar descendentes para a próxima geração (RODRIGUES, 2004a). Segundo Mitchell (1996), após definir o tipo de codificação, o próximo passo é estabelecer um critério de seleção dos indivíduos da população. Ainda segundo o autor, o processo de seleção deve ser balanceado com a mutação e reprodução, para se ter uma melhora do *fitness* médio a cada geração.

Gen e Cheng (2000) afirmam que a seleção influencia no comportamento do AG em realizar buscas no espaço de soluções. Para os autores, a estratégia de seleção ideal consiste inicialmente em reduzir a pressão de seleção, o que proporciona uma maior pesquisa do espaço de soluções. Posteriormente a esta fase, a pressão de seleção é aumentada para explorar melhor a vizinhança das melhores soluções.

Chambers (1999) diz que o AG deve produzir novas soluções a cada geração e esta quantidade depende exclusivamente da pressão de seleção testada do usuário, o que irá destinar indivíduos para a reprodução. De acordo com as teorias produzidas na era pós Darwin, o processo de pressão de seleção é classificado em três categorias: *seleção estabilizada* - é um processo onde se eliminam os cromossomos nas posições extremas da população ordenada; *seleção direcional* - direciona ao aumento ou diminuição da média da população e *seleção desagregada* - tem como princípio eliminar os cromossomos com valores medianos da função de adaptação (GEN e CHENG, 1996).

O mecanismo de seleção adotado é essencial no desenvolvimento do AG, pois define a estratégia de amostragem do espaço e os caminhos a percorrê-lo (COLEY, 1999). Na literatura são encontrados diferentes métodos de seleção, que diferem entre si de acordo com o procedimento matemático adotado como: determinísticos, estocásticos e uma mistura dos dois (GEN e CHENG, 1996). Os mais conhecidos atualmente são: Elitista, Proporção, Roleta (*Roulette wheel*), *Stochastic Universal Sampling*, *Windowing*, Truncamento, Torneio (*Tournament*), duplo torneio (*Double Tournament*), Boltzmann, *Sigma Scaling*, *Sigma Scaling* truncada, Normalizada, *Ranking* (linear, linear dinâmica, logarítmica e exponencial), *Sharing*, relacionado a Diversidade, Bi-classista, Aleatória salvacionista e Aleatória não salvacionista. Nos problemas de otimização onde é necessário minimizar uma função, uma opção é utilizar o método de seleção via função de Mayerle, conforme abordado por Barboza (2005). O método de seleção mais difundido na literatura é seleção via roleta (*Roulette wheel*), porém a idéia inicial surgiu com o método de proporção desenvolvido por Holland (MITCHELL, 1999).

Nos trabalhos de Holland, o termo seleção foi mencionado apenas para descrever uma etapa anterior à reprodução e à mutação. Neste ponto, os indivíduos eram selecionados para realizar a reprodução e, terminada a operação, seus descendentes substituíam a população de seus pais para gerar a nova população. Após os trabalhos de Grefenstette e Baker é que o processo de seleção também passou a ser incorporado na sobrevivência dos indivíduos, uma etapa posterior à mutação (GEN e CHENG, 1996).

1.4.2.7.2 Operadores genéticos de reprodução (*Crossover*)

Os operadores genéticos de reprodução imitam o processo natural de reprodução sexual e são aplicados no conjunto de indivíduos da população. Na maioria dos casos, a cada cruzamento são produzidos dois novos indivíduos, compostos pela troca gênica entre seus pais conforme comentam DeJong *et al.* (1993) e Rothlauf (2006).

A qualidade de cada indivíduo medida pelo *fitness* depende obviamente de uma boa combinação entre os genes, e neste sentido não é uma tarefa simples, pois depende de complexos procedimentos combinatórios para gerar tal expressão. Além disso, o operador deve ter a capacidade e sensibilidade de propagar a parcela do cromossomo, onde apresenta uma boa combinação para a solução do problema (GEN e CHENG, 2000). Seguindo esta idéia, surge o termo Epistasia (*Epistasis*), que se refere à forte interação entre dois genes na codificação a qual como resultado impede a boa expressão gênica. Victorino (2005) diz que em problemas com alta Epistasia é mais complicado encontrar boas soluções.

O mecanismo de reprodução é geralmente implementado a partir de escolhas compostas por regras aleatórias e, neste caso, o operador executa um pseudocódigo que realiza uma recombinação de genes entre cromossomos (REEVES, 2003). Esta operação não consegue garantir a formação de indivíduos melhores que seus pais, exatamente por ser baseada em regras aleatórias (GEN e CHENG, 2000). Alguns autores consideram a busca como *blend* ou busca cega no espaço.

Na literatura são encontrados diversas maneiras e procedimentos de aplicar este operador, sendo comum o uso dos seguintes tipos: uniforme, segmentado, único ponto, dois ou múltiplos pontos. Segundo Rothlauf (2006), os operadores mais comuns são o de único ponto e múltiplos pontos. A Figura 13 ilustra um exemplo de operação realizada pelos operadores genéticos de reprodução.

De acordo com Barboza (2005), para cada tipo de codificação adotado (binária, inteira, real e outras) no AG, existe um conjunto de estratégias diferentes aplicado por um dado operador genético de reprodução. Existem ainda outros tipos de operadores que foram testados por Starkweather *et al.* (1991) como: *order crossover #1*, *order crossover #2*, *partially mapped crossover*, *cycle crossover* e *position based crossover*. Além disso, a taxa de trocas e recombinações entre genes é um aspecto delicado na funcionalidade do AG, influenciando na sua eficiência (MITCHELL, 1999). Alguns autores comentam que diferentes tipos de operadores também influenciam nesta eficiência (ADELI e SARMA, 2006).

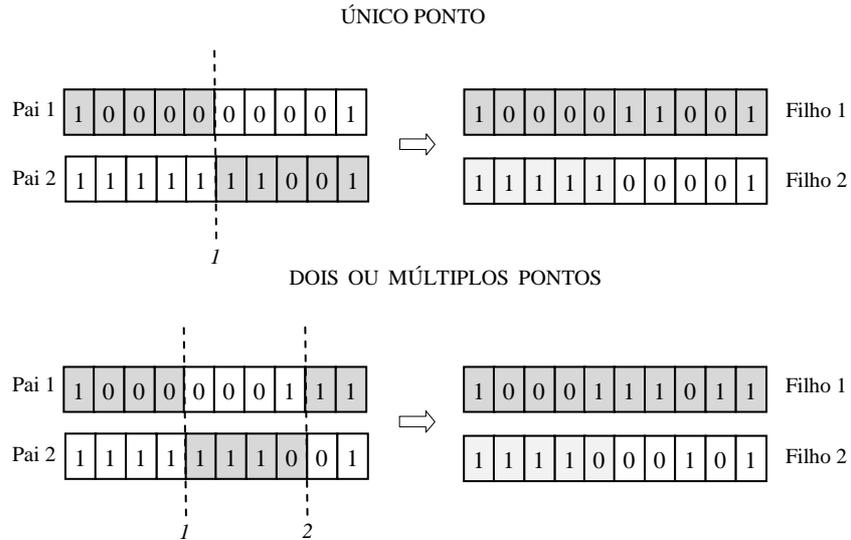


FIGURA 13 - EXEMPLO DE FUNCIONAMENTO DE DOIS TIPOS DE OPERADORES GENÉTICOS DE REPRODUÇÃO.

1.4.2.7.3 Operadores genéticos de mutação

A mutação é um processo aleatório que ocorre na natureza, onde um alelo do gene é trocado por outro, a ponto de gerar uma nova estrutura genética (CHAMBERS,1999). No AG este tipo de operador ocorre à probabilidade baixa e assume a mesma aleatoriedade. A formação de um bom indivíduo também é incerta, como ocorre na reprodução, e a garantia de sua permanência depende exclusivamente dos operadores de seleção e reprodução, bem como o seu valor de *fitness*. Este operador é responsável pela introdução e manutenção da diversidade genética da população, evitando a estagnação das buscas em apenas um ponto do espaço a pesquisar (VICTORINO, 2005).

A diferença entre mutação e reprodução consiste no fato da mutação trabalhar aleatoriamente e assim tentar a melhoria de algumas soluções individuais. Já a reprodução tem como característica marcante realizar uma busca exploratória direcionada e randômica no espaço de soluções (GEN e CHENG, 2000). Ashlock (2005) descreve que a diferença está na forma como atuam na formação de novos indivíduos, onde a mutação envolve apenas um indivíduo por vez, já a reprodução necessita de no mínimo dois indivíduos. A Figura 14 ilustra o mecanismo de alteração gênica provocado pela mutação.

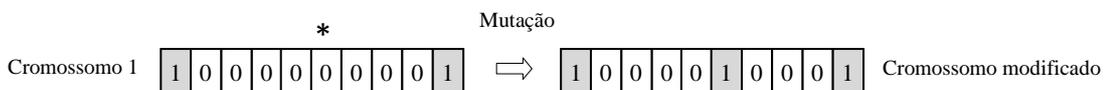


FIGURA 14 - EXEMPLO DE FUNCIONAMENTO DO OPERADOR GENÉTICO DE MUTAÇÃO.

No AG convencional, a reprodução é considerada como principal operador genético, porém a mutação apresenta o mecanismo mais simples de implementação. Além disso, a mutação permite explorar melhor a vizinhança de um dado cromossomo, já que realiza pequenas alterações na base (MITSUO e CHENG, 2000).

Gen e Cheng (2000) relatam a existência de trabalhos que compararam os operadores de reprodução e mutação e, de acordo com os autores, a mutação em alguns casos mostrou ser mais importante que a reprodução. Entretanto, os mesmos autores fizeram comparações parecidas entre os operadores e não encontraram diferenças significativas. Estes resultados mostram que existe certa discordância entre qual operador é mais importante. Porém uma coisa é certa, ambos são importantes para a boa performance do AG.

Chambers (1999) comenta a existência de variações no tipo de mutação, citando as seguintes estratégias: uniforme, gaussiana, direcionada, aleatória, troca de alelo simples e vizinhança, onde a taxa de mutação pode ser não uniforme ou uniforme. A taxa uniforme considera, como o próprio nome diz, uma taxa constante de mutação ao longo das gerações. Já a opção não uniforme aplica uma taxa inicial alta de mutação que decresce após gerações. Esta taxa mencionada é o valor da probabilidade de ocorrência do evento. Existem ainda mutações baseadas em permutações de genes ou alelos, e neste caso citam-se as mutações de translocação, inversão, *shift* e *swap*.

A hipermutação é uma opção de mutação que seleciona uma porcentagem de indivíduos da população que sofrerão alterações, onde os melhores modificados serão introduzidos na população (BARBOZA, 2005).

1.4.2.8 *Replacement*

Após os processos de seleção, reprodução e mutação, o número de indivíduos da população é maior que a determinada inicialmente, já que foram criados novos indivíduos. Neste momento é importante lembrar que o AG tem por regra trabalhar com um número definido de indivíduos, no final de cada geração. Desta maneira, surgem dois tipos de estratégias (geracional e estado fixo) em que o algoritmo elimina o “excedente” de indivíduos. Assim, a diferença entre eles está na forma como os novos indivíduos criados são introduzidos na população.

Reeves (2003) comenta que a idéia original de Holland assumia o tipo geracional (*Generational*) e seus preceitos determinavam que os indivíduos produzidos substituíssem

toda a população de seus pais. A idéia não se encaixava em problemas de otimização, exatamente pela necessidade de preservar a melhor solução. Neste caminho, boas soluções eram perdidas pela simples operação de substituição, a cada geração proposta. Segundo Michalewicz (1996), uma estratégia conhecida como elitista e desenvolvida por DeJong foi elaborada com o propósito de preservar a melhor solução do processo, ao longo das substituições. Seguindo a idéia de melhora do método, alguns experimentos foram feitos para evitar a sobreposição de populações através das gerações. Assim, finalmente foi proposto um novo tipo, conhecido como *steady state* ou *incremental* (estado fixo), onde um número definido (menor que o tamanho da população) de indivíduos é criado por geração e estes substituem uma parcela da população.

O princípio do *steady state* (estado estacionário) considera que apenas uma parcela da população necessita ser mensurada pela função do *fitness* a cada geração, esta parcela usualmente é formada pelos novos indivíduos criados. Uma característica própria desta estratégia se refere às ligações ancestrais entre cromossomos. Ashlock (2007) apresenta um exemplo onde um indivíduo com baixo *fitness*, criado na geração 60, pode ter sido ancestral de um indivíduo com alto *fitness* na geração 120, e pertencerem à mesma população. O mesmo não ocorre no processo geracional, devido à necessidade de “reciclar” toda a população atual pela nova. Mitchell (1999) afirma que a maioria dos trabalhos na literatura considera o tipo geracional como o mais predominante.

1.4.2.9 Critério de parada

A existência de um critério de parada de um algoritmo é importante para o processo de finalização de suas atividades. A sua escolha deve ser realizada de forma a maximizar a performance do algoritmo. Espera-se sempre que a escolha de um critério de parada consiga refletir um ponto onde o algoritmo tenha atingido o seu máximo operacional de buscas.

A partir das diversas aplicações dos algoritmos, em problemas reais, inúmeras opções de parada foram desenvolvidas. Segundo Lobo (2005), os critérios de parada adotados podem ser descritos nas seguintes categorias:

- após um dado número de gerações (avaliações), ou seja, um total de iterações do AG;
- quando o *fitness* não melhorar após n iterações;
- quando o fitness dos indivíduos de uma população se tornar parecidos;
- quando existir uma perda de diversidade da população.

Victorino (2005) apresenta outro critério de parada complementar à lista anterior, onde considera o fato do AG encontrar uma solução aceitável, e assim não fazer mais sentido continuar o processamento.

1.4.2.10 Vantagens e desvantagens

A maioria das heurísticas e metaheurísticas desenvolvidas apresentam pontos positivos na resolução de problemas complexos, estas vantagens os qualificam para o uso rotineiro em problemas de otimização. Entretanto, ainda se faz notar algumas desvantagens nestes algoritmos.

Segundo Ponsich *et al.* (2008), a maior dificuldade no AG é definir o ajuste dos parâmetros, o que influencia a eficiência do algoritmo durante o processamento. Existe uma grande discussão a respeito do melhor conjunto de parâmetros, e a maioria dos usuários geralmente realiza testes preliminares, antes de realmente aplicar o algoritmo (MITCHELL, 1996).

Algumas características do AG são bem recebidas em processos de otimização, quando o espaço de busca é grande (ADELI e SARMA, 2006). A primeira delas reflete a capacidade do algoritmo na convergência de boas soluções em tempo computacional curto; a segunda descreve a necessidade de funções de avaliação simples, e a terceira permite o processamento em paralelo já que o cromossomo da população é independente. Victorino (2005) lista uma série de vantagens e desvantagens do AG frente a outras técnicas, sendo elas:

a) Vantagem

- Trabalha com o conceito de população, e por isso encontram segurança na qualidade da solução;
- Apresenta uma população de pontos bem adaptados, reduzindo a possibilidade de alcançar um falso ótimo (falsos ótimos);
- Aplica uma simplicidade na formação da função de avaliação, e não precisam de métodos baseados em procedimentos complicados de resolução;
- Funciona tanto com parâmetros contínuos como discretos ou através de uma combinação deles;
- Realiza buscas simultâneas em várias regiões do espaço de busca;
- Utiliza informações de perdas ou ganhos e não derivadas ou outro conhecimento auxiliar;

- Trabalha com restrições arbitrárias de forma flexível, e otimização com múltiplas funções composta por objetivos conflitantes;
- Permite uma facilidade de implementação em computadores e boa adaptabilidade a computadores paralelos;
- Fornece uma lista de soluções aproximadas e não apenas uma simples solução;
- Apresenta facilidades em produzir híbridos com outras técnicas heurísticas;
- Trabalha uma grande variedade de problemas por ser robusto;
- Apresenta um bom desempenho para uma grande escala de problemas.

B) Desvantagem

- Apresenta dificuldade para achar o ótimo global exato, caracterizando como uma metaheurística aproximativa;
- Requer um grande número de avaliações das funções de aptidão e suas restrições a cada geração;
- Permite grandes possibilidades de configurações e codificações, podendo complicar a resolução.

1.4.3 *Simulated annealing* (SA)

1.4.3.1 Histórico de desenvolvimento

A metaheurística SA é um perfeito exemplo de como introduzir idéias completamente diferentes e inicialmente não correlacionadas, na formação de um procedimento eficiente na otimização combinatória. A lógica na técnica de SA é inspirada na têmpera (*annealing*) a qual é um processo de aquecimento e posterior resfriamento de um metal, a partir de reduções gradativas de temperatura, com o propósito de evitar a formação de defeitos no metal. Nesta proposta, a necessidade é minimizar a energia do sistema durante o processo de redução de temperatura (LAARHOVEN e AARTS, 1987).

Segundo Mahmoud (2007) a idéia fundamental na técnica de SA é realizar movimentos através das iterações, rearranjando as moléculas do metal no estado líquido até o resfriamento. Assim, a energia gerada pelas moléculas corresponde à função de custo que deve ser otimizada ao longo das iterações. Este processo natural foi o ponto de inspiração na criação desta metaheurística, e desenvolvido pelo grupo de pesquisadores liderados por Kirkpatrick. De acordo com Laarhoven e Aarts (1987), Černý também teve seus méritos sobre

esta descoberta, pois trabalhou e contribuiu de forma independente na possibilidade de aplicação do procedimento na década de 80'.

Um dos fundamentos da metaheurística SA inicia-se antes da década de 80, mais precisamente no ano de 1953, quando Metropolis e outros pesquisadores propuseram um algoritmo eficiente para simular o desenvolvimento de equilíbrio térmico dos sólidos. Aproximadamente trinta anos mais tarde, Kirkpatrick, Gelatt e Vecchi perceberam que existia uma profunda analogia entre minimizar uma função de custo em problemas de otimização combinatória e o resfriamento de sólidos até baixas energias. Assim, o critério de Metropolis poderia ser utilizado para ajudar a simular este efeito (LAARHOVEN e AARTS, 1987).

Segundo Kirkpatrick *et al.* (1983), o processo de *annealing* é guiado pelo critério de Metropolis, e por isso difere dos processos tradicionais de busca. O critério de Metropolis promove um controle na escolha das soluções, sendo assim, permite que o algoritmo não fique concentrado apenas em uma região do espaço de soluções, como ocorre nos algoritmos baseados em refinamento da solução. Então, a simulação de possíveis soluções é observada a cada iteração do algoritmo. A simulação é um mecanismo desenvolvido para criar e experimentar modelos que descrevem um sistema ou um problema, contando com a ajuda de procedimentos computacionais de base matemática (CHUNG, 2004).

A metaheurística SA pode ser modelada matematicamente usando a teoria da cadeia de Markov e, sob esta condição, a solução encontrada é definida unicamente a partir das probabilidades de seleção. Neste ponto, o processo de resfriamento da temperatura especifica um número finito de transições de soluções aceitas, a partir de regras probabilísticas baseada na função de Boltzmann (AARTS *et al.*, 2003). O elevado aquecimento inicial é para impedir a estagnação em ótimos locais, por outro lado, o resfriamento controla a direção da busca através da vizinhança da solução candidata. Em síntese, quanto maior a temperatura do sistema, maiores são as probabilidades de aceitar soluções piores. Devido a estes fatos, esta metaheurística fez muito sucesso na década de 80 e desde aquele período tem sido usada para resolver diversos tipos de problemas (AVELO *et al.*, 2004).

Rao (1996) descreve esta metaheurística como uma técnica de otimização combinatória, ligada a procedimentos randômicos de avaliação de uma função de custo, onde a transição de seleção entre boas soluções e piores é possível. O autor ainda comenta que o método exige um elevado número de avaliações da função de custo, para assim definir a solução. Henderson *et al.* (2003) dizem que a SA é um algoritmo típico de busca local, que realiza movimentos de busca baseado no algoritmo primário de busca. Na verdade, segundo

Goldstein e Waterman (1988), a SA é o algoritmo de busca *greedy* (guloso) modificado pela introdução de critérios probabilísticos. O seu ponto chave é a capacidade de sair de ótimos locais, bem como a facilidade de implementação. Na Tabela 4 são mostradas as relações de terminologia entre os processos físicos e o algoritmo de otimização, conforme apresentado por Yamamoto (2004).

TABELA 4 - TERMOS E RELAÇÕES ENTRE OS PROCESSOS FÍSICOS E A OTIMIZAÇÃO VIA METAHEURÍSTICA *SIMULATED ANNEALING*.

Física	<i>Simulated Annealing</i>
estado	solução atual do processo, ponto no espaço
energia	função de custo ou Função objetivo
estado de transição	soluções vizinhas
temperatura	parâmetros de controle
ponto de congelamento	solução final da metaheurística

A função objetivo ou função de custo presente na metaheurística SA corresponde à energia da molécula no processo de têmpera, e esta energia depende dos valores das variáveis do projeto (BUSTAMANTE, 2002). A Figura 15 apresenta um fluxograma de funcionamento desta técnica.

Suman e Kumar (2006) comentam que a SA é uma técnica compacta e robusta e que apresenta excelentes soluções para problemas de otimização, em reduzido tempo computacional. Este método pode ser considerada como um AG configurado com um único indivíduo, adotando o critério de seleção de Boltzmann e aplicando apenas o operador genético de mutação. Segundo Hartmann e Rieger (2004), os fenômenos físicos ainda são inspirações para o desenvolvimento de outros algoritmos para a otimização, como o *External optimization method* ou *hysteric optimization*.

Na literatura brasileira é comum existir uma variação de nomes para a SA, devido aos processos de tradução. Assim, são encontrados os seguintes nomes: têmpera simulada, recozimento simulado e esfriamento estatístico.

Atualmente existe uma série de aplicações para a SA incluindo, além da otimização combinatória, usos como: reconfiguração de rede de distribuição elétrica, reconhecimento de padrão de imagem, análise exploratória de dados, problemas de rotas, problemas multiobjetivos, traçamento de trajetórias para robôs via funções *spline*, dentre outras.

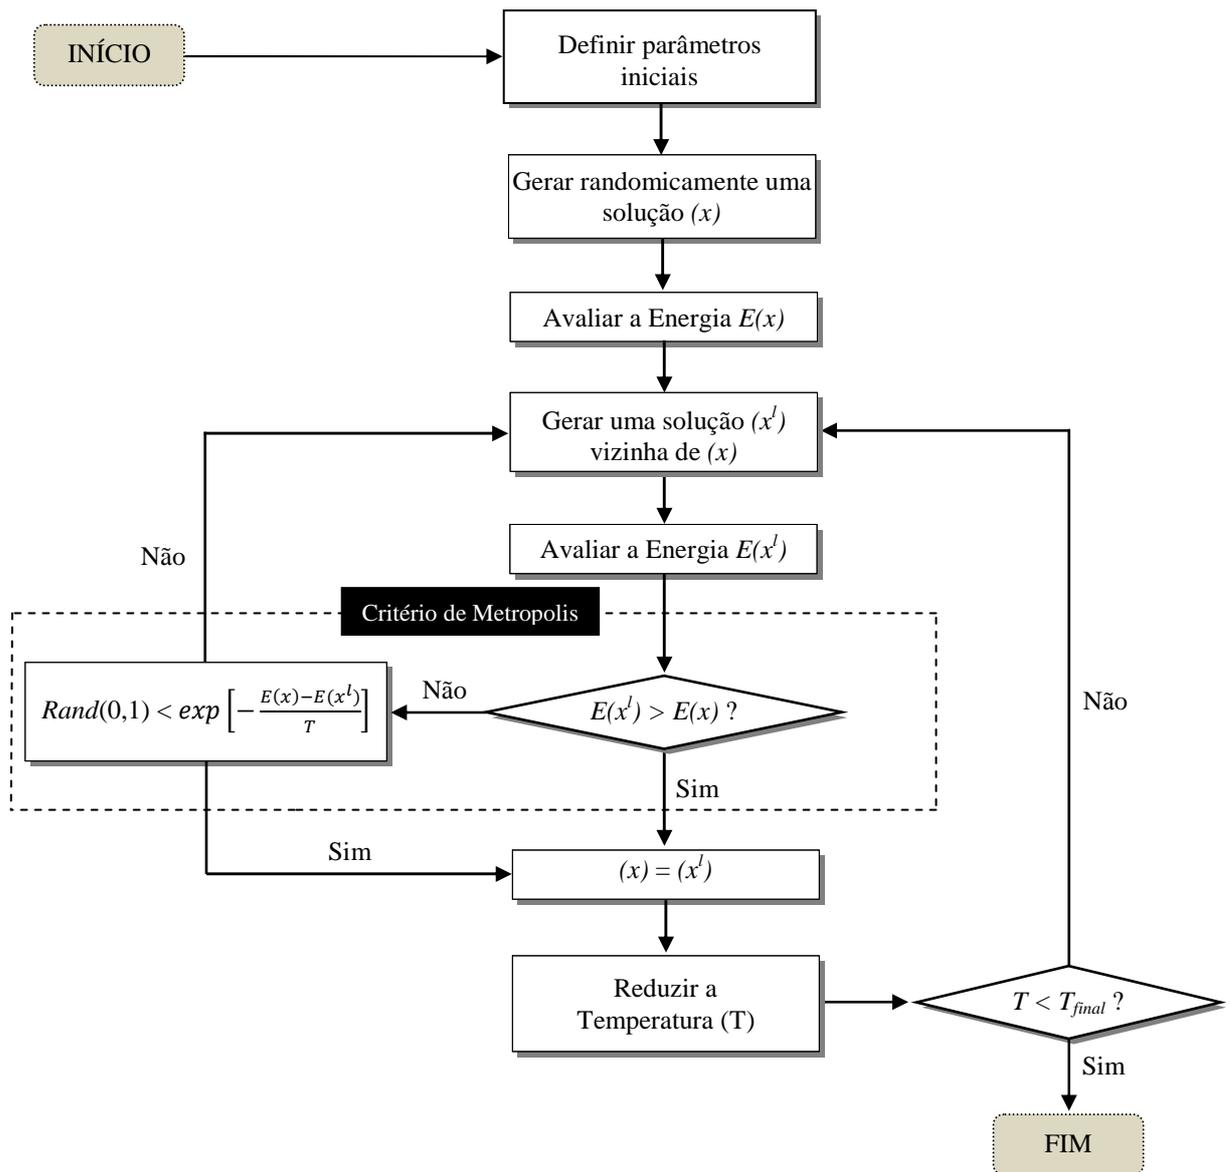


FIGURA 15 - ESTRUTURA GERAL DA METAHEURÍSTICA *SIMULATED ANNEALING* (ADAPTADO DE BUCKHAM E LAMBERT, 1999).

1.4.3.2 Solução inicial

As metaheurísticas relacionadas a processos de refinamento necessitam de uma solução inicial como ponto de partida, para se realizar as buscas no espaço de soluções. Segundo Rao (1996), a qualidade da solução inicial não influencia o desenvolvimento do algoritmo, tendo em vista a necessidade de se pesquisar várias partes do espaço de soluções. A busca é realizada a partir de uma única solução a cada iteração, que varia as buscas em várias partes do espaço.

1.4.3.3 Critério de Metropolis

O critério de Metropolis participa na decisão de escolher uma solução, influenciando na direção das buscas de forma probabilística. Este critério foi desenvolvido baseado na constante de Boltzmann e inserido na estrutura do algoritmo Metropolis. Assim, o algoritmo simula a probabilidade de movimento do átomo a uma dada temperatura, a partir da variação de energia do sistema (KIRKPATRICK *et al.* 1983). Em cada passo do algoritmo, um valor do átomo é mudado de forma randômica, medindo assim a energia do sistema. A função de probabilidade de Boltzmann é usada para simular a movimentação dos átomos, considerando os estados energéticos do sistema.

O algoritmo de Metropolis pertence a uma das ramificações dos métodos estatísticos de simulação de Monte Carlo. E, neste caso, os autores da SA empregaram este algoritmo para simular a probabilidade de transição da temperatura, durante a realização das buscas. De acordo com Kirkpatrick *et al.* (1983), o algoritmo de Metropolis simula o processo de equilíbrio termal a uma temperatura fixa, apresentando a seguinte regra para aceitar ou rejeitar a nova solução:

$$\left\{ \begin{array}{ll} \text{Rand}(0,1) < \exp\left[-\frac{E(x)-E(x^l)}{T}\right] & \text{aceita a nova solução } (x^l); \\ \text{Caso contrário} & \text{não aceita a nova solução } (x^l); \end{array} \right.$$

Onde:

E - energia do sistema;

$\text{Rand}(0,1)$ - número aleatório entre 0 e 1;

T - temperatura atual do sistema;

x - solução atual;

x^l - solução vizinha;

exp - exponencial.

1.4.3.4 Processos térmicos

Os processos térmicos da metaheurística SA são responsáveis pela eficiência do método na busca de boas soluções, sendo modelados por um conjunto de parâmetros, incluindo: temperatura inicial, temperatura final, função de resfriamento e aquecimento.

Segundo Henderson *et al.* (2003), o valor da temperatura exerce influência na

probabilidade de seleção da solução. O autor exemplifica o fato ao descrever a regra de aceitar ou rejeitar uma solução dada pelo algoritmo, onde a melhor solução sempre é aceita pelo sistema. Por outro lado, soluções de pior qualidade são rejeitadas ou aceitas a partir do cálculo da função de probabilidade de Boltzmann. Nesta função, o valor da temperatura é geralmente inversamente proporcional à probabilidade calculada. Assim, altos valores de probabilidade (0,1) calculada pela função, indicam uma maior probabilidade de aceitar soluções piores.

O valor da temperatura inicial contribui para o número de soluções visitadas durante o processo de busca no espaço, sendo assim, altos valores iniciais de temperatura proporcionam um aumento das iterações (SUMAR e KUMAR, 2006). Martins e Tsuzuki (2006) comentam que a alta temperatura inicial promove buscas redundantes de soluções ou o mesmo que perdas de tempo de processamento. Desta maneira, uma das explicações para a performance da SA está no valor do desvio entre a temperatura inicial e final, que definem o número de iterações.

O processo térmico inicia-se com uma temperatura inicial superior à temperatura final, e durante as iterações esta temperatura vai reduzindo o seu valor (KIRKPATRICK *et al.*, 1983). Na literatura existe uma série de funções utilizadas para a redução da temperatura, como encontrado nos trabalhos de Rodrigues (2004b), Öhman e Låmas (2005), Martins e Tsuzuki (2006), dentre outros. Considerando o processo de redução da temperatura, este pode ser homogêneo ou heterogêneo. De acordo com Nunes (2003), a SA homogênea descreve uma redução seqüencial da temperatura, onde a temperatura é reduzida a taxas contínuas por meio de uma função. O processo heterogêneo considera a redução da temperatura não como uma constante, apesar de seguir também uma função, mas agora sofrendo interrupções nas taxas de redução.

A forma tradicional de funcionamento da metaheurística SA elaborada por Kirkpatrick utiliza uma função matemática para simular o resfriamento homogêneo do sistema. Contudo, ainda existe outro processo térmico controlador da dinâmica da temperatura e que atua no aquecimento do sistema em algumas situações. Segundo Anagnostopoulos *et al.* (2006), a idéia do reaquecimento permite o escape de ótimos locais, habilitado o sistema a buscar novas regiões do espaço, já que a temperatura afeta diretamente os cálculos da função de Boltzmann.

Ingber (1993) comenta que alguns aspectos podem ser melhorados nesta metaheurística e um deles está ligado ao estágio próximo à temperatura final do processo.

Segundo o autor, se algumas informações importantes forem conhecidas sobre o problema, as chances de melhora da solução encontrada são grandes. Esta afirmativa é explicada, pois a baixas temperaturas ocorre uma procura mais detalhada da vizinhança da solução atual, que muitas vezes pode estar próxima do ótimo global.

1.4.3.5 Critério de Parada

A parada no processamento de cálculo dos algoritmos de busca é geralmente muito parecida, variando alguns detalhes específicos em cada metaheurística e, conforme observado no AG existe uma lista de critérios bem definidos e bastante discutida na literatura. Assim, segundo Sumar e Kumar (2006), as principais regras são:

- Atingir um determinado número de iterações;
- Quando o valor da temperatura final for maior que a temperatura atual do sistema;
- Analisar se a solução encontrada apresenta um valor próximo do valor desejável;
- Apresentar uma temperatura igual a zero e, assim, assumir que a temperatura atingiu o ponto de congelamento.

Bustamante (2002) descreve outro tipo de critério de parada que complementa a lista anterior. Segundo o autor, o algoritmo também pode finalizar suas atividades de cálculo se não for constatada nenhuma melhoria na solução, após um determinado número de iterações.

1.4.3.6 Vantagens e desvantagens

De acordo com Aarts *et al.* (2003) a metaheurística SA pertence a uma classe de algoritmos de busca local e apresenta duas vantagens em sua estratégia: flexibilidade de aplicação em diversos problemas combinatórios e um componente estocástico no seu funcionamento, o que facilita o escape de ótimos locais.

Rao (1996) descreve algumas vantagens desta técnica como: capacidade de resolver problemas envolvendo variáveis inteiras, mista, contínua e discreta; flexibilidade ao adaptar a problemas envolvendo restrições; possibilidade das variáveis assumirem valores negativos; independência da qualidade da solução final com a solução inicial. Algumas desvantagens podem ser observadas, a citar: a convergência pode ser lenta se o cálculo da função de custo for complexo, já que há a necessidade de calcular a função a cada iteração; em problemas onde o espaço de soluções é muito suave, ou existe poucos pontos de ótimo local, a qualidade

da solução gerada pela metaheurística SA deixa a desejar; em alguns casos onde existe uma heurística específica para o problema, a SA pode apresentar um desempenho pior que o algoritmo específico; não há garantias de que a solução encontrada é exata, já que o método é aproximação.

1.4.4 Aplicações das metaheurísticas na otimização de recursos florestais

O constante desafio de superar objetivos, cada vez mais complexos, promove a revisão dos conceitos e usos das técnicas tradicionais de otimização. A análise detalhada da eficiência dos algoritmos de aproximação tem demonstrado uma série de vantagens em processos de otimização florestal. Geralmente, problemas desta natureza apresentam um grau de dificuldade elevado (*NP-Hard*) em virtude de pertencerem a uma classe de problemas relacionados à otimização combinatória. Pode-se dizer que estas técnicas atingiram um grau de maturidade satisfatório, e são perfeitamente aplicáveis na otimização.

Falcão e Borges (2001) utilizaram o AG para a resolução de problemas de agendamento da colheita florestal, baseado no modelo tipo I de Jonhson e Scheurmann (1977). Neste estudo, os autores utilizaram uma floresta com 8.700 ha, pertencente à Floresta Nacional de Leiria em Portugal. O experimento montado pelos pesquisadores demonstrou que a melhor solução encontrada esteve distante apenas 0,2% do ótimo global e 1% considerando a média. O tempo para a convergência do AG ficou em menos de 25 minutos em média, sendo considerado pelos autores uma resposta eficiente.

Um estudo semelhante foi desenvolvido por Rodrigues *et al.* (2004a) no Brasil, onde o objetivo, assim como no caso anterior, foi de maximizar o valor presente líquido (VPL). O AG foi implementado testando os operadores de seleção: proporcional, escalonamento, Boltzmann, rank e torneio, além de diferentes tamanhos da população inicial (25, 50, 75 e 100) e 3 tipos de *crossover*. Os pesquisadores concluíram que os melhores parâmetros para o AG foram: uma população inicial de 75 e 100 indivíduos; operadores de seleção Boltzmann e Escalonamento e não havendo influência no tipo de *crossover* testado.

Rodrigues *et al.* (2004b) testaram o uso da metaheurística SA no mesmo tipo de problema abordado anteriormente. Neste trabalho, os autores testaram algumas estratégias randômicas de busca de solução vizinha, diferentes valores de temperatura inicial e alterações nas taxas de resfriamento. Segundo os autores, os resultados demonstraram que as temperaturas iniciais não afetaram as respostas, e a melhor taxa de resfriamento para a função

adotada ficou a 5%, se comparada com as demais. A melhor resposta encontrou-se distante do modelo exato, apenas 5%, mostrando a habilidade da técnica SA na resolução de problemas de combinatórios.

Um estudo de gestão florestal foi desenvolvido por Falcão e Borges (2003) e envolvia o planejamento operacional e estratégico de problemas considerados de grande dimensão. Neste trabalho, os autores testaram 3 metaheurísticas (AG, SA e busca tabu) em duas florestas vegetadas empiricamente por *Eucalyptus globulus* e *Pinus pinaster*. A conclusão que tiveram foi a possibilidade de utilizar as metaheurísticas em problemas desta natureza, indicando ainda que a SA apresentou o melhor desempenho.

Crowe e Nelson (2005) avaliaram a SA na resolução de problemas envolvendo restrições de adjacência (ARM). Segundo os autores, depois de 30 minutos de processamento, as respostas estavam entre 1% a 13% do ótimo global. Um trabalho considerando a questão espacial e o planejamento da colheita pode ser visto em Bettinger *et al.* (2002). Neste estudo, os autores criaram uma floresta vegetada artificialmente para testar 8 metaheurísticas e assim, perceberam que a SA e o AG apresentaram boas soluções, dando uma superioridade a SA.

Na otimização florestal ainda são encontrados inúmeros trabalhos na literatura, os quais fazem o uso destas metaheurísticas, a citar: Moore *et al.* (2000), Baskent (2001), Falcão e Borges (2001), Falcão e Borges (2002), Falcão e Borges (2005), dentre outros. Desta maneira, fica comprovado o quanto estes algoritmos são robustos e eficientes na otimização de recursos florestais.

2. REFERÊNCIA BIBLIOGRÁFICA

AARTS, E. H. L.; KORST, J. H. M.; LAARHOVEN, P. J. M. Simulated annealing. p. 91-120. In: AARTS, E. H. L., LENSTRA, J. K. (Eds.) **Local Search in Combinatorial Optimization**. Princeton. p.536. 2003.

ADELI, H.; SARMA, K. C. **Cost optimization of structures: fuzzy logic, genetic algorithms, and parallel computing**. Wiley. p.203. 2006.

ALONSO, L. R. L. **O problema da consideração de restrições de adjacência em um planejamento florestal**. Curitiba. 2003. 114 f. Dissertação de Mestrado. Universidade Federal do Paraná.

AMARAL, T. M. **Inclusão do controle de deflúvio em modelos de gestão ambiental: um estudo no vale do Paraíba-SP**. Piracicaba. 2002. 64 f. Dissertação de mestrado. Universidade Estadual de São Paulo.

ANAGNOSTOPOULOS, A.; MICHEL, L.; HENTENRYCK, P. V.; VERGADOS, Y. A Simulated Annealing Approach to the Traveling Tournament Problem. **Journal of Scheduling**, Netherlands, v. 9, n.2, p. 177-193, 2006.

ANDERSSON, D. **Approaches to integrated strategic/tactical forest planning**. Umeå. 29f. Swedish University of Agricultural Sciences. 2005.

ASHLOCK, D. **Evolutionary Computation for Modeling and Optimization**. Springer. p.571. 2005.

AVELLO, E.A.; BAESLER, F. F.; MORAGA, R. J. A meta-heuristic based on simulated annealing for solving multiple-objective problems in simulation optimization. In: Proceedings of the 2004 Winter Simulation Conference. **Proceedings...** 2004. p.508-513

BARBOZA, A. O. **Simulação e técnicas da computação evolucionária aplicadas a problemas de programação linear inteira mista**. Curitiba. 2005. 217f. Tese de Doutorado.

Universidade Tecnológica Federal do Paraná.

BASKENT, E.Z. Combinatorial optimization in forest ecosystem management modeling. **Turkish Journal of Agriculture and Forestry**. Turkey, v.25, p.187-194. 2001.

BASKENT, E. Z., KELES S. Spatial forest planning: A review. **Ecological Modeling**, Netherlands, v.188, p. 29, 2005.

BASKENT, E.Z., JORDAN, G.A., Spatial wood supply simulation modeling. **The Forestry Chronicle**, Canada, v.67, n.6, p. 610-621. 1991.

BASKENT, E.Z.; JORDAN, G.A. Designing forest management to control spatial structure of Landscapes. **Landscape and Urban Planning**, Netherlands, v.34, n.1. p.55-74. 1996.

BASKENT, E.Z.; JORDAN, G.A. Forest landscape management modeling using simulated annealing. **Forest Ecology and Management**, Netherlands, v.165, n.1, p.29-45. 2002.

BELL, S. Landscape pattern, perception and visualization in the visual management of forest. **Landscape and Urban Planning**, Netherlands, v.54. n.2, p.201-211. 2001.

BETTINGER, P.; BOSTON, K.; KIM, Y.H.; ZHU, J. Landscape-level optimization using tabu search and stand density-related forest management prescriptions. **European Journal of Operational Research**, Netherlands, v.176, n.2, p.1265-1282, 2007.

BETTINGER, P.; CHUNG, W. The key literature of, and trends in, forest-level management planning in North America, 1950-2001. **International Forestry Review**, United Kingdom, v.6, n.1, p.40-50, 2004.

BETTINGER, P., SESSIONS, J. Spatial forest planning: to adopt, or not to adopt? **Journal Forestry**, USA, v.101, n.2, p.24-29. 2003.

BETTINGER, P.; BOSTON, K.; SESSIONS, J. Intensifying a heuristic forest harvest scheduling search procedure with 2-opt decision choices. **Canadian Journal of Forest**

Research, Canada, v.29, n.11, p.1784-1792, 1999.

BETTINGER, P.; GRAETZ, D.; BOSTON, K.; SESSIONS, J.; CHUNG, W. Eight heuristic planning techniques applied to three increasingly difficult wildlife planning problems. **Silva Fennica**, Finland, v.36, n.2, p. 561-584, 2002.

BETTINGER, P.; LENNETTE, M.; JOHNSON, K. N.; SPIES, T.A. A hierarchical spatial framework for forest landscape planning. **Ecological Modelling**, Netherlands, v.182, p.25-48, 2005.

BIREWAR, D. B. **Design, planning and scheduling of multiproduct batch plants**. Pittsburg. 1989. 194f. Thesis. University of Carnegie Mellow.

BORGES, J. G.; HOGANSON, H. M. Assessing the impact of management unit design and adjacency constraints on forestwide spatial conditions and timber revenues. **Canadian Journal of Forest Research**, Canada, v. 29, n.11, p.1764-1774, 1999.

BOSTON, K.; BETTINGER, P. The economic impact of green-up constraints in the southeastern United States. **Forest Ecology and Management**, Netherlands, v.145, n.3, p.191-202, 2001a.

BOSTON, K.; BETTINGER, P. Development of spatially feasible forest plans: a comparison of two modeling approaches. **Silva Fennica**, Finland, v.35, n.4, p.425-435, 2001b.

BOYLAND, M.; NELSON, J.; BUNNELL, F.L. A test for robustness in harvest scheduling models. **Forest Ecology and Management**, Netherlands, v.207, n.1, p.121-132, 2005.

BRUMELLE, S.; GRANOT, D.; HALME, M.; VERTINSKY, I. A tabu search algorithm for finding good forest harvest schedules satisfying green-up constraints. **European Journal of Operational Research**, Netherlands, v.106, n.2, p.408-424. 1998.

BUCKHAM, B. J.; LAMBERT, C. **Simulated Annealing Applications**. 16p. 1999. Disponível em: <http://www.me.uvic.ca/~zdong/courses/mech620/SA_App.PDF>. Acesso

em: 07/04/2009.

BUONGIORNO, J. e GILLESS, J. K. **Forest management and economics: a primer in quantitative methods**. New York, Collin Macmillan, 1987. p.284.

BUONGIORNO, J.; TEEGUARDEN, D. E. Operations Research Techniques in the Management of Large-Scale Reforestation Programs. IN: NAVON, D (Eds.) **Operational Forest management planning methods: proceeding, meetings of steering Systems project groups**, IUFRO, Romenia, p. 36-44. 1978.

BURKE, E.; KENDALL, G.; NEWALL, J.; HART, E.; ROSS, P.; SCHULENBURG, S. Hyper-heuristics: an Emerging Direction in Modern Search Technology p.457-574. In: GLOVER, F.; KOCHENBERGER, G. A. **Handbook of metaheuristics**. Kluwer. 2003. p.557.

BUSTAMANTE, R. C. R. **Otimização de painéis sanduíche utilizando o método de recozimento simulado**. São José dos Campos. 2002. 101f. Dissertação de Mestrado. Instituto Nacional de Pesquisas Espaciais.

CARLSSON, M. A method for integrated planning of timber production and biodiversity: a case study. **Canadian Journal of Forest Research**, Canada, v.29, n.8, p.1183-1191, 1999.

CASTRO, R. R. **Regulação de florestas eqüiâneas incluindo restrições de adjacência**. Viçosa. 2007. 64f. Dissertação de Mestrado. Universidade Federal de Viçosa.

CHAMBERS, L. **Practical handbook of genetic algorithm: complex coding systems**. CRC. 1999. p. 572.

CHUNG, C. A. **Simulation modeling handbook: A Practical Approach**. CRC. 2004. p. 574.

COLEY, D.A. **An introduction to genetic algorithms for scientists and engineers**. World Scientific. 1999. p.185.

CONNELLY, W. A definition for hierarchical analysis for forest planning. In: Proceedings of Hierarchical Approaches to Forest Management in Public and Private Organizations. **Proceedings...**1996. p.1.

CROWE, K.; NELSON, J.; BOYLAND, M. Solving the area-restricted harvest-scheduling model using the branch-and-bound algorithm. **Canadian Journal of Forest Research**, Canada, v.33, p.1804-1814, 2003.

CROWE, K. A.; NELSON, J. D. An evaluation of the simulated annealing algorithm for solving the area-restricted harvest-scheduling model against optimal benchmarks. **Canadian Journal of Forest Research**, Canada, v.35, n.10, p.2500-2509, 2005.

DEJONG, K. A; SPEARS, W. M.; GORDON, D. F. Using genetic algorithms for concept learning. p. 5-32. In: GREFENSTETTE, J. J. (Ed.) **Genetic algorithms for machine learning**. Kluwer. 1993. p.176.

FALCÃO, A. O. Integração de um Visualizador Interactivo de Paisagens Florestais num Sistema de Apoio à Decisão em Gestão de Recursos Naturais - Aplicação à Serra da Lousã. **Silva Lusitana**, v.12, p.89-102, 2004.

FALCÃO, A. O.; BORGES, J. G. Designing an evolution program for solving integer forest management scheduling models: an application in Portugal. **Forest Science**, USA, v.74, n.2, p.158-168, 2001.

FALCÃO, A. O.; BORGES, J. G. Combining random and systematic search heuristic procedures for solving spatially constrained forest management scheduling models. **Forest Science**, USA, v.48, n.3, p.608-621. 2002.

FALCÃO, A. O.; BORGES, J. G. Heurísticas para a integração de níveis estratégico e operacional da gestão florestal em problemas de grande dimensão. **Scientia Forestalis**, Piracicaba, n.63, p.13-23. 2003.

FALCÃO, A. O.; BORGES, J. G. Designing decision support tools for Mediterranean forest ecosystems management: a case study in Portugal. **Annals of Forest Science**, France, v.62, n.7, p.751-760, 2005.

FIGUEIREDO, E. O.; LIMA, Q. S. Coeficientes Técnicos para o Inventário e Manejo Florestal com Emprego do Modelo Digital de Exploração Florestal (Modelflora). **Comunicado técnico 169**. EMBRAPA. Acre. p.19. 2008.

FISCHER, D. T.; CHURCH, R. L. Clustering and compactness in reserve site selection: an extension of the biodiversity management area selection model. **Forest Science**. USA, v.49, n.4. 2003.

FORMAN, R.T.T, GODRON M. **Landscape ecology**. New York. Wiley. 1986. 619p.

GARCÍA, O. FOLPI, a Forestry-oriented Linear Programming Interpreter. In: Proceedings IUFRO Symposium on Forest Management Planning and Managerial Economics, University of Tokyo. **Proceedings...**1984. p 293-305.

GEN, M.; CHENG, R. **Genetic Algorithms and Engineering Design**. Wiley. p.432. 1996.

GEN, M.; CHENG, R. **Genetic Algorithms and Engineering optimization**. Wiley. 2000. p.495.

GLOVER, F. Future paths for integer programming and links to artificial intelligence. **Computer and Operational Research**, Netherlands, v.13, n.5, p.533-549, 1986.

GLOVER, F.; KOCHENBERGER, G. A. **Handbook of metaheuristics**. Kluwer. 2003. p.557.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Longman, 1989. 412 p.

GOLDSTEIN, L.; WATERMAN, M. Neighborhood size in the simulated annealing

algorithm. **American journal of mathematical and management sciences**, USA, v.8, n.4, p.409-423, 1988.

GOYCOOLEA, M.; MURRAY, A.T.; BARAHONA, F.; EPSTEIN, R.; WIENRAUB, A. Harvest scheduling subject to maximum area restrictions: Exploring the exact approaches. **Operational Research**, v.53, n.3, p.490-500, 2005.

GREISTORFER, P.; VOB, S. Controlled pool maintenance for metaheuristics. p. 387-424. In: REGO, C.; ALIDAEI, B. (Eds.) **Metaheuristic Optimization via Memory and Evolution: Tabu Search and Scatter Search**. Kluwer. 2005. p.466.

GRONER, M.; GRONER, R.; BRISCHOF, W.F. Approaches to heuristics: A Historical review. p.1-18. In: GRONER, R.; GRONER, M.; BRISCHOF, W.F. (Eds.) **Methods of Heuristics**. Lawrence. 1983. p.420.

GUNN, E. A.; RICHARDS, E. W. Solving the adjacency problem with stand-centred constraints. **Canadian Journal of Forest Research**, Canada, v.35, n.4, p.832-842, 2005.

GUSTAFSON, E. J.; MURPHY, N. L.; CROW, T. R. Using a GIS model to assess terrestrial salamander response to alternative forest management plans. **Journal of Environmental Management**, Netherlands, n.63. p. 281-292. 2001.

HARTMANN, A. K.; RIEGER, H. **New Optimization Algorithms in Physics**. Wiley. 2004. p.300.

HEINONEN, T., KURTTILA, M.; PUKKALA, T. Possibilities to aggregate raster cells through spatial optimization in forest planning. **Silva Fennica**. Finland, v.41, n.1, p.89-103. 2007.

HEINONEN, T. **Developing spatial optimization in forest planning**. Joensuu. 2007. 48f. Dissertation. University of Joensuu.

HENDERSON, D.; JACOBSON, S. H.; JOHNSON, A. W. The Theory and Practice of

Simulated Annealing. p.287-319. In: GLOVER, F.; KOCHENBERGER, G. A. (Eds.) **Handbook of metaheuristics**. Kluwer. 2003. p.557.

HERRMAN, J.W. A history of production scheduling. p.1-22. In: HERRMAN, J.W. (Ed.) **Handbook of production scheduling**. Springer. 2006. p.318.

HERTZ, A.; WIDMER, M. Guidelines for the use of meta-heuristics in combinatorial optimization. **European Journal of Operational Research**, Netherlands, v.151, n.2, p.247-252, 2003.

HILLIER, F. S.; LIEBERMAN, G. J. **Introduction to operations research**. McGraw-Hill. 2001. p.1214.

HOF, J., BEVERS, M. Optimal timber harvest scheduling with spatially defined sediment objectives. **Canadian Journal of Forest Research**, Canada, v.30, n.9, p.1494-1500, 2000.

HOGANSON, H. M.; BORGES, J. G. Using dynamic programming and overlapping subproblems to address adjacency in large harvest scheduling problem. **Forest Science**, USA, v.44, n.4, p.526-538, 1998.

HOOKER, J. N. **A principled approach to mixed integer/linear problem formulation**. p. 21. 2008. Disponível em: <<http://ba.gsia.cmu.edu/jnh/milpmodeling.pdf>>. Acesso em: 06/07/2008.

HOSOKAWA, R. T. Funções de forma e o planejamento da produção florestal. In: Seminário sobre atualidades e perspectivas florestais. **Anais...**Curitiba, EMBRAPA/CNPQ. 1982. p.7-14.

HOSOKAWA, R. T.; MENDES, J. B. Planejamento florestal. **Revista Floresta**, Curitiba, v.15, n.1, p.4-7, 1984.

HOTVEDT, J. E. Application of linear goal programming to forest harvest scheduling. **Southern Journal of Agricultural Economics**, USA, v.15, p.103-108, 1983.

INGBER, A. L. Simulated annealing: Practice versus theory. **Mathematical and Computer Modeling**, Netherlands, v.18, n.11, p.967-973, 1993.

INSTITUTE OF ENVIRONMENT ASSESSMENT. **Guidelines for landscape and visual impact assessment**. London: Spon. 1995. 126p.

JOHNSON, K. N.; SCHEURMANN, H. L. Techniques for prescribing optimal timber harvest and investment under different objectives - discussion and synthesis. **Forest Science**, USA, v.18, n.1, p.1-31, 1977.

JONES, D. F.; MIRRAZAVI, S.K.; TAMIZ, M. Multi-objective meta-heuristics: An overview of the current state-of-art. **European Journal of Operational Research**, Netherlands, v.137, p.1-9, 2002.

JUMPPANEN, J.; KURTTILA, M.; PUKKALA, T.; UUTTERA, J. Spatial harvest scheduling approach for areas involving multiple Ownership. **Forest Policy and Economics**, Netherlands, v.5, n.1, p.27-38, 2003.

KARJALAINEN, E. **The visual preferences for forest regeneration and field afforestation – four case studies in Finland**. Helsinki. 2006. 111f. Dissertation. University of Helsinki.

KENT, B.; BARE, B. B.; FIELD, R.; BRADLEY, G. Natural Resource Land Management Planning using Large-Scale Linear Programs: The USDA Forest Service Experience with FORPLAN. **Operations Research Society of America**, USA, v.39, n.1, p.13-27, 1991.

KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by Simulated Annealing. **Science**, USA, v. 220, n.4598, p.671-680, 1983.

KOZA, J.R. **Genetic programming: on the programming of computers by means of natural selection**. Cambridge. MIT. 1992. 840p.

KURTTILA, M. The spatial structure of forests in the optimization calculations of forest planning - a landscape ecological perspective. **Forest Ecology and Management**,

Netherlands, v.142, n.2, p.129-142. 2001.

LAARHOVEN, P. J. V.; AARTS, E. H. **Simulated Annealing: Theory and Applications**. Springer. 1987. p. 204.

LEUSCHNER, W. **Forest Regulation, Harvest Scheduling, and Planning Techniques**. New York: Wiley. 1990. 281p.

LOBO, E. L. M. **Uma solução do problema de horário escolar via algoritmo genético paralelo**. Belo Horizonte. 2005. 86f. Dissertação de Mestrado. Centro Federal de Educação Técnica de Minas Gerais.

LONGMAN, **dictionary of contemporary English**. Longman. 2003. p.1950.

LUCAS, O. W. R. **The design of Forest landscape**. Oxford. 1991. p. 381.

MACGAUGHEY, R.J. Using data-driven visual simulations to support Forest operations planning. 2001. p.173-179. In: Proceedings of the first international precision forestry cooperative symposium. **Proceedings...**Washington. 2001. p.201.

MAGRO, T. C. Manejo de paisagens em áreas florestadas. **Série Técnica IPEF**, v.10, n.29, p.59-72, 1996.

MAHMOUD, T. M. A Genetic and Simulated Annealing Based Algorithms for Solving the Flow Assignment Problem in Computer Networks. **International Journal of Electronics, Circuits and Systems**, , v.1, n. 2, p.128-134, 2007.

MANLEY, B. New information tools for the forest manager. **Bulletin Forest Research Institute**, New Zealand, p.35-44, 1995.

MARCIN, T. C. A hierarchical model for technological assessment of the economic feasibility of new forest products and processes. In: Proceedings of the Symposium Villa del Rio Conference Center. **Proceedings...** Chile. 1993. p.207-214.

MARTINS, T. C.; TSUZUKI, M. S. G. Applying the Simulated Annealing to the Problem of Positioning Rotational Non Convex Polygons. In: Symposium Series in Mecatronics. **Proceedings...**2006. p.707-714.

MATOUŠEK, J.; GÄRTNER, B. **Understanding and Using Linear Programming**. Springer. 2007. p.222.

MCDILL, M. E.; BRAZE, J. Comparing adjacency constraint formulation for randomly generated forest planning problems with four age-class distributions. **Forest Science**, USA, v.46, n.3, p.423-436, 2000.

MCDILL, M. E.; BRAZE, J. Using the branch-and-bound algorithm to solve Forest planning problems with adjacency constraint. **Forest Science**, USA, v.47, n.3, p.403-418, 2001.

MCDILL, M. E.; REBAIN, S. A.; BRAZE, J. Harvest scheduling with area-based adjacency constraint. **Forest Science**, USA, v.48, n.4, p.631-642, 2002.

MCNAUGHTON, A. J.; PAGE, G. D.; RYAN, D.M.. 2001. Adjacency Constraints in Forest Harvesting. In: Proceedings of the ORSNZ. **Proceedings...** New Zealand. 2001. p 9-15.

MEILBY, H.; STRANGE, N.; THORSEN, B. J. Optimal spatial harvest planning under risk of windthrow. **Forest Ecology and Management**, Netherlands, v.149, n.1, p.15-31, 2001.

MEITNER, M. J.; SHEPPARD, S. R. J.; CAVENS, D.; GANDY, R.; PICARD, P.; HARSHAW, H.; HARRISON, D. The multiple roles of environmental data visualization in evaluating alternative forest management strategies. **Computers and Electronics in Agriculture**, Netherlands, v.49, n.1, p.192-205, 2005.

MELLO, A. A.; CARNIERI, C.; ARCE, J. E.; SANQUETTA, C. R. Planejamento florestal visando à maximização dos lucros e a manutenção do estoque de carbono. **Cerne**, Lavras, v. 11, n. 3, p. 205-217, 2005.

MICHALEWICZ, Z. **Genetic algorithms + data structures = evolutions programs**. Springer. The Netherlands. 1996. p.387.

MICHIELS, W.; ARTS, E. A.; KORST, J. **Theoretical Aspects of Local Search**. Springer. 2007. p.235.

MITCHELL, M. **An introduction to Genetic Algorithms**. Bradford. 1996. p.158.

MITCHELL, S. A. **Operational Forest Harvest Scheduling Optimisation - A mathematical model and solution strategy**. Auckland. 2004. 252f. Thesis. University of Auckland.

MITSUO, G.; CHENG, R. **Genetic algorithms and engineering optimization**. Wiley. 2000. p.495.

MORELLI, R.; WALDE, R. **A Word-Based Genetic Algorithm for Cryptanalysis of Short Cryptograms**. Disponível em: <<http://www.aaai.org/Papers/FLAIRS/2003/Flairs03-045.pdf>>. Acesso: 28/08/2009.

MOORE, C. T.; CONROY, M. J.; BOSTON, K. Forest management decisions for wildlife objectives: system resolution and optimality. **Computers and Electronics in Agriculture**, Netherlands, v.27, n.1, p.25-39, 2000.

MURRAY, A. T.; CHURCH, R. L. Analyzing cliques for imposing adjacency restrictions in Forest models. **Forest Science**, USA, v.42, n.2, p.166-175, 1996.

MURRAY, A. T. Spatial restriction in harvest scheduling. **Forest Science**, USA, v.45, n.1, p.45-52, 1999.

MURRAY, A. T.; CHURCH, R. L. Measuring the efficacy of adjacency constraint structure in Forest planning models. **Canadian Journal of Forest Research**, Canada, v.25, p.1416-1424, 1995.

MURRAY, A. T.; GOYCOOLEA, M.; WEINTRAUB, A. Incorporating average and

maximum area restrictions in harvest scheduling models. **Canadian Journal of Forest Research**, Canada, v.34, p.456-464, 2004.

MURRAY, T.; SNYDER, S. Introduction to spatial modeling in Forest management and natural resource planning, **Forest Science**, USA, v.46, n.2, p.153-154, 2000.

NASCIMENTO, J. M. **Ferramentas computacionais híbridas para a otimização da produção de petróleo em águas profundas**. Campinas. 2002. 134f. Dissertação de Mestrado. Universidade Estadual de Campinas.

NCASI. **Habplan User Manual - Version 3**. p.72 2006. Disponível em: <<http://ncasi.uml.edu>>. Acesso em: 14/03/2007.

NELSON, J. Assessment of forest harvest blocks generated from operational polygons and forest-cover polygons in tactical as strategic planning. **Canadian Journal of Forest Research**, Canada, v.31, p. 682-693. 2001.

NELSON, J.; HARRISON, D. Global demands drive advantages in data management and hierarchical decision support system in northern British Columbia. In: Proceedings of the first international precision forestry cooperative symposium. **Proceedings...**Washington. 2001. p.157-163.

NELSON, J. D. **The Mechanics of Adjacency**. ATLAS/SIMFOR Project Extension Report. p.8. 2000. Disponível em: <<http://www.forestry.ubc.ca/atlas-simfor/extension/reports.html>>. Acesso em: 07/07/2008.

NUNES, L. M. A. F. F. **Monitoring networks optimization with simulated annealing**. Lisboa. 2003. 205f. Tese de Doutorado. Universidade técnica de Lisboa.

NUUTINEN, T.; KELLOMÄKI, S. A comparison of three modelling approaches for largescale forest scenario analysis in Finland. **Silva Fennica**, Finland, v.35, n.3, p.299-308, 2001.

ÖHMAN, K. **Forest Planning with Consideration to Spatial Relationships**. Ultuna. 2001. 32f. Thesis. Swedish University of Agricultural Science.

ÖHMAN, K.; ERIKSSON, L.O. Allowing for spatial consideration in long-term forest planning by linking linear programming with simulated annealing. **Forest Ecology and Management**, Netherlands, v.161, n.1, p.221-230, 2002.

ÖHMAN, K.; LÄMAS, T. Reducing forest fragmentation in long-term forest planning by using the shape index. **Forest Ecology and Management**, Netherlands, v.212, n.1, p.346-357. 2005.

OLIVEIRA, S. A. **Metaheurísticas Aplicadas ao Planejamento da Expansão da Transmissão de Energia Elétrica em Ambiente de Processamento Distribuído**. Campinas. 2004. 315f. Tese de Doutorado. Universidade Estadual de Campinas.

OPTIMBER, disponível em: <<http://www.optimber.com.br/software.html>>. Acesso em: 18/06/2008.

OSMAN, I. H.; LAPORTE, G. Metaheuristic: a bibliography. **Annals of Operational Research**, France, v.63, p.513-623, 1996.

PARDALOS, P.M.; PROKOPYEV, O.A.; BUSYGIN, S. Continuous approaches for solving discrete optimization problems. p. 39-60. 2006. In: APPA, G.; PITSOULIS, L.; WILLIAMS, H.P. (Eds.) **Handbook on modeling for discrete optimization**. Springer. 2006. p.429.

PEREIRA, G. W. **Aplicação da Técnica de Recozimento Simulado em Problemas de Planejamento Florestal Multiobjetivo**. Belo Horizonte. 2004. f. 75. Dissertação de Mestrado. Universidade Federal de Minas Gerais.

PONSICH, A., C. AZZARO-PANTEL, S. DOMENECH, L. PIBOULEAU. Some Guidelines for Genetic Algorithm Implementation in MINLP Batch Plant Design Problems. p.293-316. IN: SIARRY, P.; MICHALEWICZ, Z. (Eds.) **Advances in Metaheuristics for Hard Optimization**. Springer. 2008. p.474.

POTTER, M.W.; KESSELL, S.R.; CATTELINO, P.J. FORPLAN: A Forest Planning Language and Simulator. **Environmental Management**, USA, v.3, n.1, p.59-72, 1979.

QUEIROZ, L. M. O. **Algoritmos genéticos híbridos para redução de perdas técnicas em redes primárias de distribuição considerando variações de demandas**. Campinas. 2005. 81f. Dissertação de Mestrado. Universidade Estadual de Campinas.

RADELOFF, V. C.; MLADENOFF, D. J.; GUSTAFSON, E. J.; SCHELLER, R. M.; ZOLLNER, P. A.; HE, H. S.; AKÇAKAYA, H. R. Modeling forest harvesting effects on landscape pattern in the Northwest Wisconsin Pine Barrens. **Forest Ecology and Management**, Netherlands, v.236, n.1, p.113-126, 2006.

RAO, S. S. **Engineering optimization: Theory and practice**. Wiley. 1996. p.922.

REEVES, C. R. Genetic Algorithms. p.55-82. In: GLOVER, F.; KOCHENBERGER, G. A. (Eds.) **Handbook of metaheuristics**. Kluwer. 2003. p.557.

REMADE, disponível em: <http://www.remade.com.br/pt/revista_materia.php?edicao=73&id=369>. Acesso em: 18/06/2008.

REMPEL, R.S.; KAUFMANN, C.K. Spatial modelling of harvest constraints on wood supply versus wildlife habitat objectives. **Environmental management**, USA, v.32, n.5, p.646-659, 2003.

ROCHA, D. X. **Otimização do planejamento da manutenção preventiva em sistemas complexos, com foco na cadeia de suprimento**. Florianópolis. 2002. 84f. Dissertação de Mestrado. Universidade Federal de Santa Catarina.

RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L.; SILVA, G. F. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, Viçosa, v.28, n.2, p.233-245, 2004a.

RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L.; RIBEIRO, C. A. A. S.

Metaheurística *simulated annealing* para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, Viçosa, v.28, n.2, p.247-256, 2004b.

RODRIGUES, F. L.; SILVA, G. F.; LEITE, H. G.; XAVIER, A. C.; PEZZOPANE, J. E. M. Um modelo de regulação florestal e suas implicações na formulação e solução de problemas com restrições de recobrimento. **Revista Árvore**, Viçosa, v.30, n.5, p.769-778, 2006.

RODRIGUEZ, L. C. E. Ordenamento sustentável das florestas de eucaliptos plantados para a produção de celulose no Brasil. 2001.150-158. In: I Simpósio Ibero-Americano de Gestão e Economia Florestal. **Anais...Porto Seguro**. 2001. p.158.

RODRIGUEZ, L. C. E; BUENO, A. R. S.; RODRIGUES, F. Rotações de eucaliptos mais longas: análise volumétrica e econômica. **Scientia Forestalis**, Piracicaba, n.51, p.15-28, 1997.

ROSSI, F.; BEEK, P.; WALSH, T. **Handbook of Constraint Programming**. Elsevier. 2006. p.955.

ROTHLAUF, F. **Representations for genetic and evolutionary algorithms**. Springer. 2006. p.325.

RUSTAGI, K. P. Forest Management Planning for Timber Production: A Sequential Approach. In: Operational forest management planning methods: proceedings, meeting of steering systems project group, International Union of Forestry Research Organizations. **Proceedings...** Bucharest. 1978. p.68-75.

SAKAWA, M. Genetic algorithm and fuzzy multiobjective optimization. USA. Kluwer. 2002. p.288.

SEIXAS, F.; MAGRO, T. C. Indicadores ambientais e paisagísticos relacionados às operações florestais. **Série técnica IPEF**, v.12, n.31, p.65-78, 1998.

SEPPELT, R.; VOINOV, A. Landscape Optimization: Applications of a Spatial Ecosystem Model. p. 301-326. In: COSTANZA, R.; VOINOV, A. (Eds.) **Landscape Simulation**

Modeling A Spatially Explicit, Dynamic Approach. Springer. 2004. 330p.

SESSIONS, J., BETTINGER, P. Hierarchical planning: Pathway to the future? In: Proceedings of the first international precision forestry cooperative symposium. **Proceedings...** Washington. 2001. p.185-190.

SHIFLEY, S. R.; THOMPSON, F.R.; DIJAK, W.D.; LARSON, M.A.; MILLSPAUGH, J.J. Simulated effects of forest management alternatives on landscape structure and habitat suitability in the Midwestern United States. **Forest Ecology and Management**, Netherlands, v.229, n.3, p. 361-377, 2006.

SILVA, G. F.; LEITE, H. G.; SOARES, C. P. B.; SILVA, M. L. Influência de estimativas de produção de madeira em processos de regulação florestal utilizando programação linear. **Ciência Florestal**. Santa Maria, v.13, n.1, p. 57-72, 2003a.

SILVA, G. F.; LEITE, H. G.; SILVA, M. L.; RODRIGUES, F. L.; SANTOS, H. N. Problemas com o uso de programação linear com posterior arredondamento da solução ótima, em regulação florestal. **Revista Árvore**, Viçosa, v.27, n.5, p.677-688, 2003b.

SILVA, R. T. **Planeamento florestal, modelos de programação inteira, multiobjectivo e aplicações.** Coimbra. 2004. 120f. Dissertação de Mestrado, Universidade de Coimbra.

SOUZA, D. O. **Algoritmos genéticos aplicados ao planejamento do transporte principal de madeira.** Curitiba. 2004. 169 f. Dissertação de Mestrado. Universidade Federal do Paraná.

STARKWEATHER, T.; MCDANIEL, S.; MATHIAS, K.; WHITLEY, D.; WHITLEY, C. A comparison of genetic sequencing operators. In: International conference on genetic algorithms. **Proceedings...** Los Altos. 1991. p.69-76.

STEIGUER, J. E.; LIBERTI, L.; SCHULER, A.; HANSEN, B. Multicriteria decision models for forestry and natural resources management: an annotated bibliography. **General Technical Report. NE-307. Newtown Square, PA: U.S. Department of Agriculture, Forest Service, Northeastern Research Station.** p.32. 2003.

STEWART, T. J.; JANSSEN, R.; VAN HERWIJNEN, M. A genetic algorithm approach to multiobjective landuse Planning. **Computers and Operations Research**, Netherlands, v.31, n.14, p.2293-2313, 2004.

STÜTZLE, T.G. **Local Search Algorithms for Combinatorial Problems**. Darmstadt. 1998. 204f. Thesis. University Technical of Darmstadt.

SUMAN, B; KUMAR, P. A survey of simulated annealing as a tool for single and multiobjective optimization. **Journal of the Operational Research Society**, United Kingdom, v.57, n.10, p.1143-1160, 2006.

TANG, S. M.; GUSTFSON, E. I. Perception of scale in forest management planning: Challenges and implications. **Landscape and Urban Planning**, Netherlands, v.39, p.1-9, 1997.

THOMPSON, W. A.; VERTINSKY, I.; SCHEIER, H.; BLACKWELL, B. A. Using Forest Fire Hazard Modelling in Multiple Use Forest Management Planning. **Bulletin of Sustainable Forest Management Network**, n.11, p.1-22, 1998.

THORN, A. J.; DANIEL, T. C., ORLAND, B. Data Visualization for New Zealand Forestry. In: Second annual conference of GeoComputation. **Proceedings...**New Zealand. 1997. p.15-27.

TSAO, C. Y.; CHEN, S. H. Statistical analysis of genetic algorithms in discovering technical trading strategies. p.1-44. In: BINNER, J. M.; KENDALL, G.; CHEN, S. H. (Eds.) **Applications of artificial intelligence in finance and economics**. Elsevier. 2004. p.275.

TUAN, Y. F. **Espaço e lugar: a perspectiva da experiência**. São Paulo: Difel, 1983.

UNISOMA, disponível em: <http://www.unisoma.com.br/br/index.php?pagina=industria&industria=papel_e_celulose>. Acesso em: 18/06/2008.

USDA. **SPECTRUM Overview**. USDA Forest Service Inventory and Monitoring Institute. 2002. p.27. Disponível em: http://www.fs.fed.us/institute/planning_center/files/Spectrum26

_Overview.pdf Acesso em:07/07/2008.

USDA. Fuels Planning: Science Synthesis and Integration. **Bulletin: Forest Structure and Fire Hazard Fact**. p.2. 2004.

VAN DEUSEN, P.C. Multiple solution harvest scheduling. **Silva Fennica**, Finland, v.33, n.3, p.207-216, 1999.

VICTORINO, I. R. S. **Otimização de um reator industrial de produção de álcool cíclico utilizando algoritmos genéticos**. Campinas. 2005. 527f. Tese de Doutorado. Universidade Estadual de Campinas.

WALTERS, K.R. Design and development of a generalized forest management modeling system: WOODSTOCK. In: Proceedings of the International Symposium on Systems Analysis and Management Decisions in Forestry. **Proceedings...Chile**. 1993. p.190-196.

WARE, G. O.; CLUTTER, J. L. A mathematical programming system for the management of industrial forest. **Forest Science**, USA, v.17, n.4, p.425-445, 1971.

WEINTRAUB, A.; CHOLAKY, A., A hierarchical approach to forest planning. **Forest Science**, USA, v.37, n.2, p.439-460, 1991.

WEINTRAUB, A.; BARAHONA, F.; EPSTEIN,R. A column generation algorithm for solving general forest planning problem with adjacency constraints. **Forest Science**, USA, v.40, n.1, p.142-161, 1994.

WEINTRAUB, A.; CHURCH, R. L.; MURRAY, A. T.; GUIGNARD, M. Forest management models and combinatorial algorithms: analysis of state of the art. In: Annals of Operations Research. **Proceedings...San Antonio**. p.271-285. 2000.

WILLIAMS, H.P. The Formulation and Solution of Discrete Optimisation Models. p.3-38. In: APPA, G.; PITSOULIS, L.; WILLIAMS, H. P. (Eds.) **Handbook on modeling for discrete optimization**. Springer. 2006. p.429.

YAMAMOTO, L. **Uso de *simulated annealing* e algoritmo genético no problema da reconfiguração de uma rede de distribuição de energia elétrica.** Curitiba. 2004. 92f. Dissertação de Mestrado. Universidade Federal do Paraná.

YOUSSEF, H.; SAIT, S. M.; ADICHE, H. Evolutionary algorithms, simulated annealing and tabu search: a comparative study. **Engineering Applications of Artificial Intelligence**, Netherlands, v.14, n.2, p.167-181, 2001.

ZHU, J.; BETTINGER, P.; LI, R. Additional insight into the performance of a new heuristic for solving spatially constrained forest planning problems. **Silva Fennica**, Finland, v.41, n.4, p.687-698, 2007.

ZIONTS, S. **Linear and integer programming.** New Jersey: Prentice-Hall, 1974. 514p.

ZOLLNER, P. A.; ROBERTS, L. J.; GUSTAFSON, E. J.; HE, H. S.; RADELOFF, V. Influence of forest planning alternatives on landscape pattern and ecosystem processes in northern Wisconsin, USA. **Forest Ecology and Management**, Netherlands, v.254, p.429-444, 2008.

CAPÍTULO 2

**ESTUDO E MODELAGEM DOS PARÂMETROS PRESENTES NA METAHEURÍSTICA
ALGORITMO GENÉTICO**

RESUMO

ESTUDO E MODELAGEM DOS PARÂMETROS PRESENTES NA METAHEURÍSTICA ALGORITMO GENÉTICO

O AG apresenta uma boa performance na resolução de problemas complexos (*NP-Hard*), sendo comprovada a partir de diversas pesquisas. Entretanto, esta qualidade deixa de existir quando não é utilizada uma configuração apropriada. Assim, este capítulo teve como objetivo modelar a configuração da metaheurística AG, através de testes realizados em diferentes configurações propostas, considerando o problema de agendamento da colheita florestal como suporte para os cálculos. Os parâmetros avaliados foram: tamanho da população (100, 200 e 300), tipo de operador de seleção (aleatório salvacionista, amostragem estocástica universal, roleta e sigma *truncation scaling*), taxa de alteração gênica na mutação (10% e 20%), taxa de alteração gênica no *crossover* (10%, 30%, 50%, 70% e 90%) e taxa de *replacement* dos piores indivíduos (*steady state 1* - substituição de 2 indivíduos, *steady state 2* - 10% da população inicial e *steady state 3* - 50% da população inicial). Desta forma, foram testadas 360 configurações de AG, sendo realizadas 8 repetições/configuração e considerando um critério de parada de 1.000 iterações. Os dados foram obtidos de um reflorestamento de eucalipto pertencente à empresa VCP - Votorantim Celulose e Papel na região de Caçapava-SP. Os resultados mostraram que as configurações dos parâmetros presentes no AG contribuíram diretamente na qualidade final do *fitness*, onde a diferença entre a melhor e pior configuração foi de 74,62% no valor do *fitness* médio. O tamanho da população inicial demonstrou ser um dos parâmetros mais importantes na modelagem da metaheurística, dando destaque à população com 300 indivíduos. O tipo de operador de seleção não apresentou uma tendência de superioridade entre métodos, porém, comparando as melhores respostas, observou-se que a amostragem estocástica universal foi o método superior, seguido pela roleta, sigma *truncation scaling* e aleatória salvacionista. O melhor *fitness* médio foi obtido utilizando uma taxa de alteração de 20% na mutação, considerando uma população inicial de 300 indivíduos. A melhor taxa de *replacement* foi ao aplicar 50% de substituição dos piores indivíduos/geração, conforme a orientação da opção *steady state 3*. A taxa de alteração gênica ideal no *crossover* foi de 30% e 50%, apresentando uma boa modelagem das relações *exploration* e *exploitation* nas buscas. A melhor configuração do AG e que obteve o melhor *fitness* médio foi: população inicial (300 indivíduos), operador de seleção (amostragem estocástica universal), *replacement* (*steady state 3* - 50% de substituição), taxa de alteração gênica na mutação 20% e 50% no *crossover*. As configurações que mais demandaram tempo de processamento foram aquelas utilizando uma população inicial de 300 indivíduos e a opção *steady state 3*, apresentando ainda os menores coeficientes de variação.

Palavras-chave: Algoritmo Genético, Configuração, Planejamento Florestal, Otimização.

ABSTRACT

STUDY AND MODELING OF THE PARAMETERS IN THE METAHEURÍSTICA GENETIC ALGORITHM

GA presents a good performance in the resolution of complex problems (*NP-Hard*), being proven in various research works. However, this quality stops existing when an appropriate configuration is not used. Therefore, this chapter had as objective to model the configurations the metaheuristic GA, through tests carried out in different proposed configurations, considering a scheduling problem of the forest harvest as support for the calculations. The appraised parameters were: population size (100, 200 and 300), type of selection operator (random salvationist, stochastic universal sampling, roulette and sigma truncation scaling), rate of gene alteration in the mutation (10% and 20%), rate of gene alteration in the crossover (10%, 30%, 50%, 70% and 90%) and replacement rate of the worst individuals (*steady state 1* - substitution of 2 individuals, *steady state 2* - 10% of the initial population *and steady state 3* - 50% of the initial population). In this way, 360 GA configurations were tested, 8 repetitions/configuration being done and considering a stop criterion of 1,000 iterations. The data were obtained from a eucalyptus reforestation belonging to the company VCP - Votorantim Celulose and Pulp in the area of Caçapava-SP. The results showed that the configurations of the present parameters in GA directly contributed to the final quality of the fitness, where the difference between the best and worst configuration was 74.62% in the value of the average fitness. The size of the initial population demonstrated to be one of the most important parameters in the modelling of the metaheuristic, giving prominence to the population with 300 individuals. The type of selection operator did not present a tendency towards superiority among methods, however comparing the best responses it was observed that the stochastic universal sampling was the superior method, followed by the roulette, sigma truncation scaling and random salvationist. The best average fitness was obtained using an alteration rate of 20% in the mutation, considering an initial population of 300 individuals. The best replacement rate was when applying 50% substitution of the worst individuals/generation, according to the orientation of the steady state 3 option. The ideal gene alteration rate in the crossover was 30% and 50%, presenting a good modelling of the exploration and exploitation relationships in the searches. The best GA configuration and that which obtained the best average fitness was: initial population (300 individuals), selection operator (stochastic universal sampling), replacement (steady state 3 - 50% of substitution), gene alteration rate in the mutation 20% and 50% in the crossover. The configurations that demanded more processing time were those using an initial population of 300 individuals and the steady state 3 option, still presenting the lowest variation coefficients.

Keywords: Genetic Algorithm, Configuration, Forest Planning, Optimization.

1. INTRODUÇÃO

A evolução da raça humana sempre esteve relacionada ao domínio dos processos naturais, principalmente em momentos em que as adversidades do ambiente proporcionavam cenários adversos. Assim, a história da humanidade mostra diversas passagens e relatos do cotidiano da sociedade, onde a observação da natureza estimulava a capacidade de pensar do homem, auxiliando na criação de diversas teorias, técnicas e ferramentas essenciais aos dias atuais. Historicamente, o AG também faz parte desta estatística, pois seus criadores buscaram inspirações em processos naturais e teorias evolutivas ao desenvolverem seu mecanismo de busca por soluções. Goldberg (1989) define o AG como um procedimento de busca baseado no mecanismo genético e de seleção natural.

No ano de 1975, uma equipe dirigida por Holland apresentou a idéia inicial do AG e suas teorias foram materializadas no livro: *Adaptation in Nature and Artificial Systems*. Naquela época, os autores atribuíram ao algoritmo um uso restrito de aplicações, apesar de seu pioneirismo e vanguarda (MITCHELL, 1996). Entretanto, o passar do tempo foi essencial no surgimento de variações positivas a sua estrutura inicial, promovendo paralelamente a difusão e utilização do algoritmo em diversas áreas da ciência, destacando: processamento de imagem, predição de estrutura de proteínas em 3D, tecnologia a laser, medicina, trajetória de viagem espacial, análise de séries temporais, processos termodinâmicos, aeronáutica, robótica, regras de autômatos celulares, avaliação automática de softwares, reconhecimento de face e padrão, otimização, dentre outros. A introdução na otimização foi realizada na mesma década de sua criação, através do trabalho de Ken DeJong, já sua difusão na área industrial ficou a cargo dos estudos de David Goldberg, ambos alunos de Holland.

Segundo Ashlock (2005), ao se pensar na utilização do AG para resolver problemas de qualquer natureza, surgem as seguintes perguntas: Que tipo de *fitness* utilizar? Qual o tipo de *crossover* e mutação escolher? Como selecionar os indivíduos da população para reproduzir, e como inseri-los na nova geração? Qual a melhor estratégia de parada? Qual codificação empregar?

A relevância destas perguntas faz sentido, pois a maior dificuldade na utilização do AG concentra-se na escolha destas respostas. Conseqüentemente, a combinação escolhida irá influenciar na qualidade dos resultados (PONSICH *et al.*, 2008). Segundo Wall (1996), a configuração dos parâmetros pode ser considerada uma arte e está além da pura ciência. Mitchell (1996) comenta que a os parâmetros mutação, população, *crossover* e seleção podem

interagir entre si de forma não linear, o que dificulta a modelagem da melhor combinação. Segundo o autor, apesar da existência de inúmeros trabalhos na literatura, nenhuma conclusão plausível foi ainda emitida, sendo ainda um ponto de discussão entre os pesquisadores. Michalewicz (1996) diz que estudos sobre a definição do tipo de estratégia ainda está bem fragmentado e, em muitos casos existe uma cultura empírica sobre a sua utilização.

A maioria dos estudos encontrados na literatura sugere configurações a partir de experiências do usuário, conforme encontrado em: Moore *et al.* (2000), Bettinger *et al.* (2002), Swiech (2004), Vename *et al.* (2005) e outros, ou através de estudos baseados na experimentação e testes, conforme encontrado em: Souza (2004) e Rodrigues (2006), Meyrs e Hancock (2001), dentre outros. Assim, segundo Rodrigues (2006), a maioria dos problemas de planejamento florestal, em especial os problemas de grande porte, baseiam-se na definição dos parâmetros via experimentação.

A análise da experimentação contribui significativamente neste tipo problema, ajudando a encontrar o melhor conjunto de combinações dentro do universo pesquisado. Entretanto, devido ao grande número de opções a serem testadas e possíveis relações existentes entre os parâmetros, torna-se uma operação difícil e complicada de implementar (HAUPT e HAUPT, 2004). Imagine testar 5 tipos de operadores de seleção, 3 taxas de mutação diferentes, 4 estratégias de *crossover*, 5 opções de tamanho de população inicial e 4 maneiras de introduzir os indivíduos na nova geração. Este pequeno exemplo, mas totalmente recorrente, produz um total de 1.200 combinações ou configurações. Agora, considere repetir cada tratamento 100 vezes para cada combinação formada, o que gera um total de 120.000 processamentos.

Assim, para garantir boas respostas do AG é essencial estruturar experimentos contemplando diversas combinações. Principalmente quando o objetivo final é maximizar um recurso florestal valorizado, como o caso de madeira destinada para a celulose.

2. OBJETIVO

O objetivo central deste capítulo foi modelar a configuração da metaheurística AG, através de combinações estratégicas entre seus parâmetros, tendo um problema de agendamento da colheita florestal como suporte para os cálculos. Para compreender melhor a importância e eficiência de cada parâmetro no AG foram estabelecidos os seguintes objetivos específicos, por parâmetro:

- a) **População:** conhecer a influência da população inicial na qualidade do *fitness* e seus impactos na velocidade de processamento do algoritmo, analisando ainda neste contexto uma população inicial de 100, 200 e 300 indivíduos;
- b) **Operador de seleção:** testar o comportamento de diferentes tipos de operadores de seleção (aleatório salvacionista, amostragem estocástica universal, sigma *truncation scaling* e roleta) na qualidade final da resposta e no tempo de processamento do algoritmo;
- c) **Mutação:** conhecer seu grau de influência na resposta final e tempo de processamento, quando o cromossomo for submetido a taxas de 10% e 20% de alterações gênicas, considerando, para isso, uma probabilidade fixa (0,5) de ocorrência em 10% da população;
- d) **Replacement:** estabelecer um limite aceitável de substituição dos piores indivíduos/geração na formação da nova geração, bem como a sua influência no tempo de processamento. Neste sentido, foi considerando o princípio *steady state* a uma taxa de substituição de 10% e 50% da população inicial, como ainda uma opção mais lenta igual a 2 indivíduos/geração;
- e) **Crossover:** definir qual o melhor número de trocas de genes (10%, 30%, 50%, 70% e 90%) entre os pais selecionados para o *crossover*, considerando uma estratégia de múltiplos pontos. Conhecer ainda a influência das buscas pela vizinhança, no tempo de execução do processo.

3. MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

O estudo foi desenvolvido em 5 fazendas pertencentes à empresa VCP - Votorantim Celulose e Papel, sendo todas localizadas no município de Caçapava-SP. O clima da região é denominado pela classificação de Köppen como Cwa, com verão chuvoso e quente, e inverno seco. A área total efetiva de plantio compreende 1.490,7 ha, distribuídos em reflorestamentos com espécies de eucalipto e algumas variações de clones da empresa. A Figura 16 apresenta a localização da área de estudo.

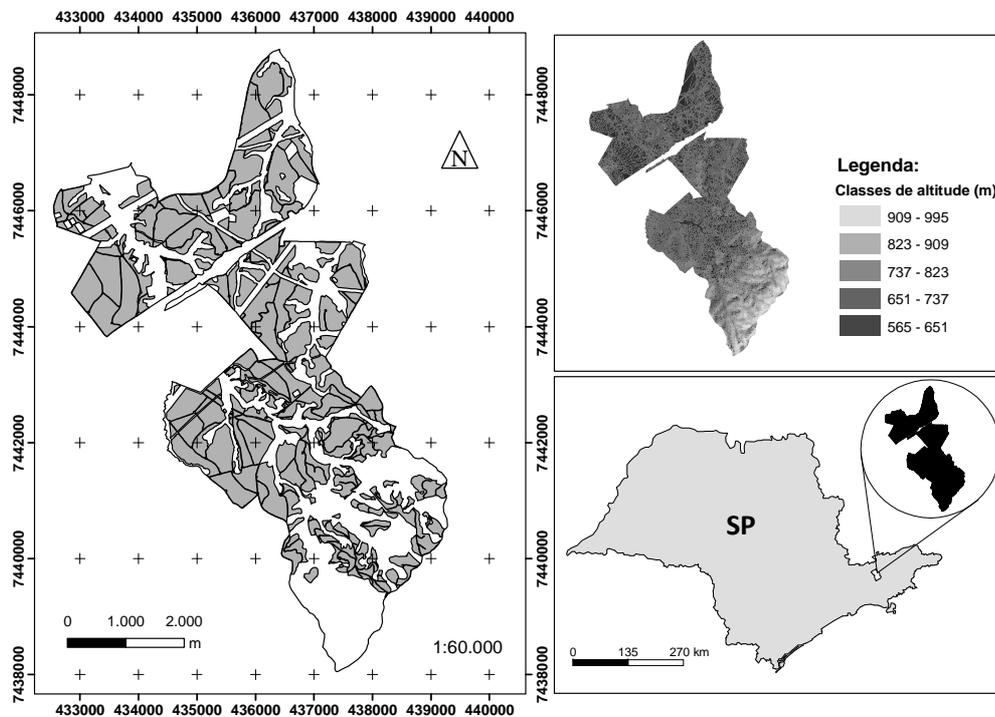


FIGURA 16 - MAPA DA LOCALIZAÇÃO DA ÁREA DE ESTUDO NO ESTADO DE SÃO PAULO.

A floresta designada para este estudo contabilizou uma malha de 52 talhões, contendo uma variação de idades. As projeções de crescimento volumétrico de madeira na floresta foram seguidas segundo dados da própria empresa.

3.2 DESCRIÇÃO DO PROBLEMA COMO BASE EXPERIMENTAL

O problema florestal foi caracterizado com a necessidade de maximizar o valor presente líquido (VPL) da floresta, analogamente ao encontrado em uma série de trabalhos na

literatura, e que tiveram o modelo tipo I de Johnson e Scheurmann (1977) como referência. Segundo Rezende e Oliveira (2001), o VPL de um projeto de investimento pode ser definido como a soma algébrica dos valores descontados do fluxo de caixa a ele associado, sendo definido pela formulação (1):

$$VPL = \sum_{j=0}^n R_j(1+i)^{-j} - \sum_{j=0}^n C_j(1+i)^{-j} \quad (1)$$

Onde:

j - período de tempo considerado;

C_j - custo final do ano j ou do período de tempo considerado;

C_0 - custo inicial do investimento;

R_j - receita no final do ano j ou do período de tempo considerado;

i - taxa de desconto;

n - duração do projeto ou número de tempo considerado.

O uso do indicador econômico VPL foi aplicado apenas para atualizar as receitas líquidas geradas por cada alternativa de manejo, não sendo aplicado como método de comparação entre alternativas de manejo na sua forma pura de análise.

A idéia do problema seguiu os moldes da programação linear clássica, onde a função objetivo (2) foi dimensionada para maximizar o valor presente líquido (VPL), contando ainda com a inclusão de restrições direcionadas à adoção de apenas uma alternativa de manejo por unidade de talhão (3), outras ligadas ao controle do fluxo de produção volumétrica a partir de um limite mínimo (4) e máximo (5) toleráveis, além das restrições de integridade e não negatividade das variáveis de decisão (6).

$$\text{Função Objetivo: Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} \quad (2)$$

Sujeito a

$$\sum_{j=1}^P x_{ij} = 1, \quad \forall_j, \forall_{i=1,2,\dots,M} \quad (3)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \geq L_{\text{inferior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,7} \quad (4)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \leq L_{\text{superior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,7} \quad (5)$$

$$x_{ij} \in \{0,1\} \quad \forall_i, \forall_j \quad (6)$$

Onde:

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pertencente à opção de manejo j ;

Desta maneira, o objetivo numérico do problema foi definir uma produção volumétrica anual estipulada em 84.500 m^3 , com variação constante e tolerável de $\pm 16\%$. Este valor volumétrico anual foi definido considerando os aspectos da produção da floresta, ligados as alternativas de manejo florestal.

A idade mínima e máxima dos talhões liberados para a colheita florestal foi de 5 e 7 anos, respectivamente, onde o talhão selecionado não poderia ser cortado a uma idade inferior a 5 anos ou superior ao máximo estabelecido. O regime de manejo considerado foi o *pulp wood* destinado a produção de madeira para celulose. Por outro lado, o sistema silvicultural foi o alto fuste, onde ao cortar um talhão na sua totalidade, o mesmo material genético seria plantado na seqüência, a ciclos contínuos. A taxa de juros adotada foi de 10% e o preço de venda da madeira estipulado em $\text{R}\$70,00/\text{m}^3$. Os demais custos para o cálculo do valor presente líquido (VPL) foram fornecidos pela empresa.

3.3 ALGORITMO GENÉTICO

A programação do AG envolve uma série de variáveis controladoras, conhecidas como parâmetros, onde sua diversidade é representada por diferentes estratégias e alternativas de buscas. Na literatura são encontradas diversas opções, que podem influir diretamente na qualidade das soluções. Além disso, a velocidade do processamento sofre diretamente com a escolha destes parâmetros. Assim, foram testadas diferentes opções de parâmetros existentes para o AG, com o propósito de extrair o melhor conjunto de parâmetros testado.

3.3.1 Codificação

De acordo com Haupt e Haupt (2004) todo mecanismo de implementação do AG inicia-se com a definição do tipo de codificação empregada. A cada opção de código, um determinado tipo de problema poderá ser abordado ou não, a depender principalmente do tipo de variável retratada (contínua ou discreta).

A natureza do problema testado envolveu apenas o uso de variáveis de decisão inteira. Assim, neste tipo de problema, uma maneira popular de se codificar o algoritmo é a partir de um código binário. Mitchell (1996) afirma que os códigos binários {0,1} são as codificações mais empregadas no AG. Autores como: Falcão e Borges (2001), Bettinger *et al.* (2002), Rodrigues (2006), dentre outros, utilizaram este tipo de código em seus estudos.

O código binário é um código de simples implementação, pois podem assumir apenas os valores 0 ou 1, de forma restrita. Desta maneira, a codificação dos cromossomos presentes no algoritmo seguiu o esquema apresentado pela Figura 17.

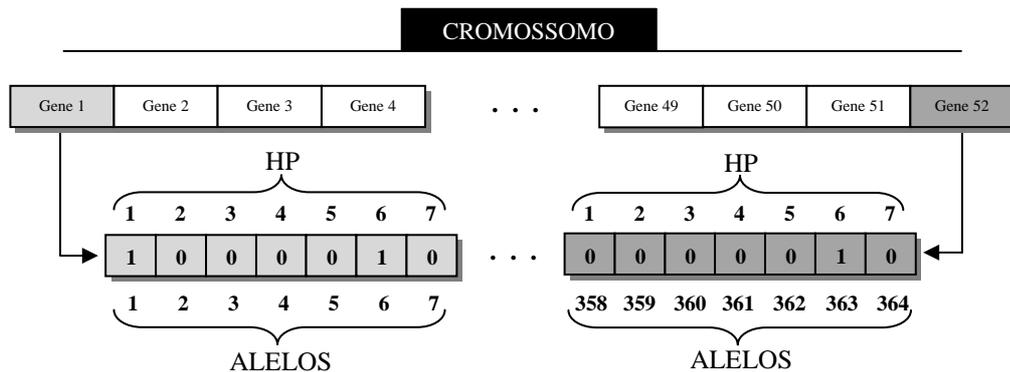


FIGURA 17 - EXEMPLIFICAÇÃO DA CODIFICAÇÃO BINÁRIA UTILIZADA NO ALGORITMO GENÉTICO PARA O PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL

A regra para a codificação do algoritmo contou com a seguinte correlação ao problema florestal: o número de genes foi igual ao número de unidades de manejo da área de estudo (52); o horizonte de planejamento foi definido em 7 anos e, por isso, o número de *loci* foi igual a 364 (7x52); a codificação do gene representou uma dada alternativa de manejo de um talhão.

A estratégia foi popular todos os *loci* com as variáveis binárias {0,1}, escolhidas de forma randômica. A randomização é um processo bastante comum na formação de soluções iniciais para o AG, conforme comentam: Mitchell (1996), Michalewicz (1996), Chambers (1999), Mitsuo e Cheng (2000) e outros.

A Figura 17 apresenta a codificação do 1º e 52º gene presentes no cromossomo, sendo ainda simulados os valores de cada alelo {0,1} presente em cada *locus*. A combinação destes códigos binários retrata a capacidade de cada gene em ativar uma alternativa de manejo, estabelecido para cada unidade de manejo. Em outras palavras, o valor 1 ativa o corte de uma unidade de manejo em um dado período de tempo (t) dentro do horizonte de planejamento definido. Caso contrário o valor é zero.

Assim, por analogia, pode-se dizer que cada unidade de manejo da floresta é representada por um dado gene presente no cromossomo. Este gene sempre estará ligado ao talhão de forma obrigatória, até o final do processamento. Desta maneira, a cada alteração alélica gerada no gene, repercutirá na alternativa de manejo adotado para o talhão, sendo para isso decodificado ao problema de agendamento de corte. Logo, a alternativa de manejo gera uma prescrição de manejo para uma dada unidade, e estas atividades representam um conjunto de operações como poda, desbaste, corte raso e outras, que influencia no crescimento da floresta. A característica da alternativa empregada foi definida pela utilidade ou destino final do produto. Neste caso, foi considerado o agendamento da colheita florestal envolvendo apenas como questão técnica a definição do período de corte raso da unidade selecionada.

A Tabela 5 apresenta um conjunto de alternativas de manejo para cada talhão e estabelece uma correlação com os genes (1º e 52º) da Figura 17. No exemplo, a configuração genética do 1º gene, quando decodificado, representa a alternativa de manejo 1 do sistema; já para o 52º gene, expressa a alternativa de manejo hipotética número 202.

TABELA 5 - RELAÇÃO ENTRE A CODIFICAÇÃO EMPREGADA NO ALGORITMO GENÉTICO E AS ALTERNATIVAS DE MANEJO ESTABELECIDAS PARA UMA FLORESTA HIPOTÉTICA.

Talhão/Gene	Idade	Alternativa de Manejo	Escolha	Horizonte de Planejamento						
				1	2	3	4	5	6	7
1	5	1	x	1	0	0	0	0	1	0
		2		1	0	0	0	0	0	1
		3		0	1	0	0	0	0	1
		4		0	1	0	0	0	0	0
		5		0	0	1	0	0	0	0
⋮	⋮	⋮								
52	2	200		0	0	0	1	0	0	0
		201		0	0	0	0	1	0	0
		202	x	0	0	0	0	0	1	0

Contudo, apesar da simplicidade (corte/não corte), existe um número elevado de

opções de manejo factíveis para cada unidade de manejo, que depende exclusivamente de suas características como crescimento e idade. Esta última variável foi empregada para definir a restrição de idade mínima (5 anos) e máxima (7 anos) para a colheita florestal, auxiliando na formação de alternativas viáveis. De posse das idades atuais de cada talhão, foi desenvolvido um algoritmo para guiar o processo randômico de preenchimento dos alelos, em cada posição no *locus*.

3.3.2 Função de avaliação

A função de avaliação (*fitness*) é uma função que avalia a qualidade dos indivíduos da população e seu valor provém da tentativa de maximizar o VPL da floresta. A utilização desta função no AG levou em consideração a introdução de penalidades no modelo.

O método de penalidades foi empregado para guiar o algoritmo nas buscas de soluções e contribuir para uma boa convergência da resposta. Segundo Pezeshk e Camp (2002), o resultado da função objetivo penalizada representa de forma quantitativa a extensão da violação da restrição e promove uma medida relativa da qualidade de cada solução mensurada. Apesar da existência de outras estratégias de mensurar o *fitness*, a baseada em penalidades é a mais comum entre problemas envolvendo a otimização de recursos florestais via AG.

A determinação do valor da penalidade foi obtida a partir de testes preliminares, onde o valor de R\$500,00/m³ foi o melhor encontrado, devido aos altos valores financeiros produzidos pela floresta em estudo. A penalidade é aplicada apenas quando o volume obtido não respeita os limites mínimos e máximos estabelecidos. Desta forma, para cada m³ de madeira fora da meta, este valor é multiplicado pela penalidade. Assim, de posse deste resultado, o *fitness* é calculado apenas subtraindo do VPL esta quantia calculada (7).

$$\text{Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} - \text{penalidade (R\$/m}^3) \sum_{k=1}^T D_k \quad (7)$$

Onde:

Penalidade - R\$/m³ de madeira;

D - Valor absoluto do desvio volumétrico de madeira (m³);

k - período anual dentro do horizonte de planejamento;

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pela alternativa de manejo j ;

3.3.3 População inicial

O tamanho da população inicial é um dos parâmetros mais importantes presentes no AG, participando diretamente na qualidade da resposta e no tempo de convergência do algoritmo (MICHALEWICZ, 1996). Segundo Queiroz (2005), normalmente o AG possui de 20 a 200 indivíduos na população, porém, quando o cálculo do *fitness* é considerado complicado, recomendam-se populações reduzidas. A definição do tamanho deste parâmetro é fundamental, e por isso, foram testadas as seguintes populações iniciais: 100, 200 e 300 indivíduos. O propósito da variação da população inicial foi para compreender a sua influência na qualidade da resposta final, bem como no tempo de processamento.

3.3.4 Operadores de seleção

O operador de seleção é responsável pela definição de quais indivíduos serão deslocados para a reprodução, exercendo um papel fundamental no direcionamento da diversidade da população e, conseqüentemente, na solução final do problema. Segundo Gen e Cheng (2000), o operador de seleção influencia no comportamento do AG ao realizar buscas no espaço de soluções. No trabalho foram testados os seguintes operadores de seleção: aleatório salvacionista, amostragem estocástica universal (*stochastic universal sampling*), roleta (*roulette wheels*) e sigma *truncation scaling*.

3.3.4.1 Aleatório salvacionista

Os processos aleatórios se caracterizam pela indefinição de seus resultados, ou seja, como uma loteria, na qual tanto os melhores indivíduos podem ser selecionados, como também os piores. A característica marcante nestes processos é que todos os indivíduos

apresentam as mesmas chances de serem selecionados. Alguns pontos negativos podem ser encontrados neste tipo de estratégia como, por exemplo, produzir uma grande variância populacional do *fitness* e dificuldades de explorar as melhores soluções. Por outro lado, existe uma variação mais inteligente deste método, que obriga a seleção do melhor indivíduo.

Segundo Victorino (2005), a seleção aleatória salvacionista seleciona aleatoriamente N indivíduos da população, porém, obrigatoriamente, o melhor indivíduo é escolhido. Assim, o procedimento adotado neste estudo seguiu esta lógica. Entretanto, os sorteios foram sem reposição para aumentar a diversidade na reprodução, sendo a única alteração realizada.

3.3.4.2 Roleta

Um dos operadores mais comuns de seleção é o método da roleta (*Rolette Wheel*) ou proporcional ao *fitness* (COLEY, 1999). Segundo Mitchell (1996) o método foi proposto originalmente por Holland, no qual a probabilidade de seleção de um dado indivíduo depende diretamente do seu valor de *fitness*. Logo, o método considera uma seleção proporcional ao *fitness* de cada indivíduo. A forma de quantificar a expectativa de seleção dos indivíduos presentes na população é dada de acordo com a expressão (8).

$$E_i = \frac{f_i}{\sum_{i=1}^N f_i} \quad (8)$$

Onde:

i - indivíduo;

N - número de indivíduos da população;

E_i - expectativa de seleção do indivíduo i ;

f_i - *fitness* do indivíduo i .

De acordo com Chambers (1998), este operador de seleção é considerado como um método padrão, sendo encontrado na maioria dos trabalhos envolvendo o AG. Coley (1999) comenta que a sua grande aplicação possa estar relacionada à facilidade de implementação.

Assim, a seleção do indivíduo é feita a cada rodada da agulha presente na roleta, e o ponto onde ela pára indica o indivíduo a ser selecionado. Portanto, quanto maior a área na roleta, atribuída a cada indivíduo, maiores serão suas chances de seleção. A característica mais recorrente da roleta é parar em regiões compostas pelos melhores indivíduos (REEVES, 2003).

Considere como exemplo uma população composta por 5 indivíduos, onde o *fitness* e a

probabilidade de seleção de cada indivíduo são dados por $\{32, 9, 17, 17, 25\}$ e $\{0,32; 0,09; 0,17; 0,17; 0,25\}$, respectivamente. No método da roleta, a probabilidade de seleção do indivíduo é correspondente à área de cada setor dentro da roleta, conforme mostra a Figura 18. Desta maneira, ao rodar de forma aleatória a agulha da roleta, o seu ponto de parada indicará o indivíduo selecionado.

No exemplo é mostrada a seleção de dois indivíduos $\{1, 5\}$, após rodar aleatoriamente a agulha da roleta duas vezes e obter as seguintes probabilidades 0,27 e 0,82. A roleta deve ser rodada N vezes, até atingir o número desejável de indivíduos para completar a operação.

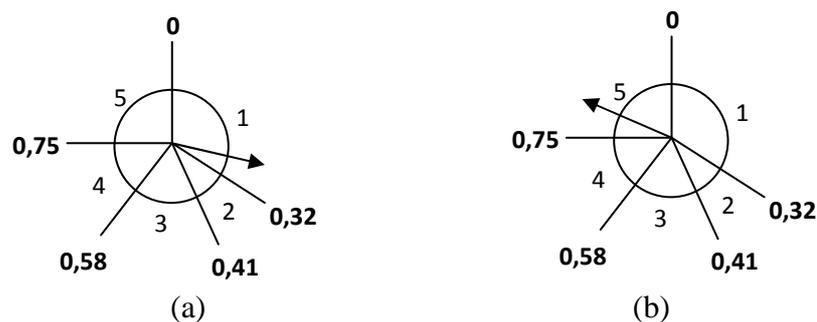


FIGURA 18 - SELEÇÃO DO INDIVÍDUO 1 (a) E 5 (b) DA POPULAÇÃO A PARTIR DE DUAS RODADAS DA AGULHA DA ROLETA.

O aspecto negativo do método consiste em não oferecer garantias de seleção do melhor indivíduo, já que a seleção é realizada aleatoriamente a cada nova rodada (HANCOCK,1999). Além disso, por ser um operador dependente do *fitness* populacional, a seleção pode estagnar em gerações mais avançadas, quando deparado com a baixa diversidade. O método apresenta ainda uma alta variabilidade estocástica, que em outras palavras, significa uma variação no número de vezes que um dado indivíduo é selecionado a cada geração.

Usualmente, os melhores indivíduos são selecionados mais de uma vez, o que provoca uma redução da diversidade e uma possível convergência prematura. A possível repetição de indivíduos selecionados, a cada nova rodada, é devido ao efeito de introduzir o indivíduo novamente na roleta. Desta forma, a amostragem sem reposição pode ser utilizada nestes casos, para garantir uma seleção equilibrada da diversidade (REEVES, 2003).

A roleta foi utilizada como um dos operadores de seleção testados, porém algumas alterações foram realizadas para tentar mitigar as suas falhas. A primeira mudança estabelecida foi a seleção do melhor indivíduo de forma independente do processo probabilístico da roleta. Esta estratégia foi empregada para que o melhor indivíduo pudesse sempre repassar seus genes a gerações futuras. Em outras palavras, permitir uma melhor *exploitation* da melhor solução encontrada a cada geração. A última mudança foi elaborada

para aumentar a diversidade de indivíduos a reproduzir, impedindo a seleção repetida de um mesmo indivíduo, caracterizando um processo de sorteio sem reposição.

3.3.4.3 Amostragem estocástica universal

A amostragem estocástica universal (*stochastic universal sampling*) foi proposta por Baker na década de 80 e sua estratégia de seleção baseia-se no operador roleta, onde sofreu uma mudança estrutural de funcionamento (MITCHELL, 1996). A alteração foi desenvolvida exatamente para corrigir problemas específicos de amostragem, enfrentados pelo operador descrito anteriormente.

A alteração feita no operador roleta permite realizar todas as seleções de uma única vez, pois agora a roleta apresenta múltiplas agulhas (MITCHELL, 1996). Estas múltiplas agulhas ficam separadas a partir de distâncias igualmente definidas, sendo necessário apenas informar a probabilidade inicial. Do ponto de vista de amostragem, este procedimento corresponde à amostragem sistemática (REEVES, 2004).

Considere como exemplo uma população composta por 5 indivíduos, onde o *fitness* e a probabilidade de seleção de cada indivíduo são, respectivamente $\{32, 9, 17, 17, 25\}$ e $\{0,32; 0,09; 0,17; 0,17; 0,25\}$. No método, a probabilidade de seleção do indivíduo é correspondente à área de cada setor dentro da roleta, conforme mostra a Figura 19. Desta maneira, ao rodar de forma aleatória a agulha da roleta, o seu ponto de parada indicará o indivíduo selecionado. No exemplo, o interesse foi eleger 4 indivíduos, que foram selecionados pelas múltiplas agulhas de uma única vez. A partir da seleção exemplificada foi adotada uma estratégia elitista, na qual o melhor indivíduo sempre seria selecionado, garantindo a ele no mínimo uma única seleção.

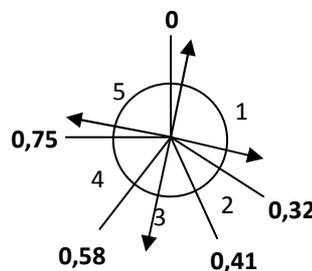


FIGURA 19 - SELEÇÃO DOS INDIVÍDUOS {1, 1, 3 e 5} DA POPULAÇÃO CONSIDERANDO MÚLTIPLAS AGULHAS.

3.3.4.4 Sigma *truncation scaling*

O operador sigma *truncation scaling* é um método que reordena a escala do *fitness* e modela o comportamento de sua curva de probabilidade. A transformação é aplicação para evitar distorções significativas entre os *fitness* presentes na população. Segundo Michalewicz (1996), o método foi desenvolvido para melhorar outro procedimento conhecido como *Linear scaling*.

PEZESHK e CAMP (2002) comentam que durante algumas gerações, ou pequeno espaço de tempo, é possível formar um reduzido e extraordinário grupo de indivíduos. Esta parcela de indivíduos apresenta uma participação significativa no *fitness* total da população, interferindo diretamente no processo de seleção, devido às maiores chances de serem selecionados. O resultado final exercido por esta situação é uma baixa diversidade e convergência prematura. A transformação da escala do *fitness* é estabelecida pela seguinte condição (9), segundo Kuilekov *et al.* (2003):

$$f'_i = \begin{cases} f_i - (\bar{f} - c\sigma), & \text{se } f_i \geq 0 \\ 0, & \text{caso contrário} \end{cases} \quad (9)$$

Onde:

i - indivíduo pertencente à população;

f'_i - *fitness* recalculado para o indivíduo i ;

f_i - *fitness* do indivíduo i ;

\bar{f} - *fitness* médio da população;

c - constante;

σ - desvio padrão populacional da variável *fitness*.

O método não oferece chances de selecionar indivíduos com valores negativos, conforme suas condições de transformação. Entretanto, nas primeiras gerações pode surgir um elevado número de indivíduos com *fitness* negativo, devido à randomização na formação inicial dos indivíduos. Assim, para controlar este problema foi somado o valor mais negativo encontrado (quando ocorrido), a cada geração e em módulo, a todos os *fitness* da população. Esta média transforma todos os *fitness* em valores positivos e não altera a esperança de seleção de cada indivíduo.

Apesar da transformação na escala do *fitness*, faz-se necessária a aplicação de um procedimento de seleção para realizar as seleções desejadas. Segundo Rodrigues (2001), o operador necessita de uma operação adicional para viabilizar a seleção dos indivíduos

destinados ao cruzamento.

Segundo Murphy (2003), a constante do modelo pode variar entre $1 \leq c \leq 3$; já outro autor como Michalewicz (1996) considera o seguinte intervalo $1 \leq c \leq 5$. O valor da constante c influencia diretamente na seleção dos indivíduos pois, a baixos valores, os melhores indivíduos são privilegiados para a seleção (aumento de sua área na roleta), já altos valores tendem a igualar as esperanças de seleção entre os indivíduos. Desta maneira, o valor assumido no trabalho foi de $c = 2$, após testes prévios. O mesmo operador foi utilizado no trabalho de Kuilekov *et al.* (2003).

Assim, a partir da reconstrução de uma nova escala de *fitness* e posterior cálculo da expectativa de seleção, um mecanismo probabilístico foi empregado para a escolha dos indivíduos. O mecanismo empregado foi a amostragem estocástica universal, seguindo os moldes descritos anteriormente no item 3.3.4.3.

3.3.5 Operador genético

3.3.5.1 *Crossover*

O *crossover* é responsável pela troca de genes entre os cromossomos selecionados para a reprodução, proporcionando a recombinação de genes para a formação de novos indivíduos. O mecanismo é geralmente implementado a partir de escolhas compostas por regras aleatórias e, neste caso, executa um pseudocódigo que realiza uma recombinação de genes entre cromossomos (REEVES, 2003). Na maioria dos casos vistos na literatura, este tipo de operador é considerado como “cego”, pois não se conhece o resultado final de sua operação. Neste sentido, o *crossover* pode produzir filhos com características fenotípicas pioradas ou não.

Assim, a estratégia empregada foi considerar a operação às cegas, a partir de um processo randômico ou aleatório de seleção dos genes para a troca. A modalidade direcionada de *crossover* pode comprometer a velocidade do processamento e por isso não foi escolhida.

A ação do operador produz um número definido de novos cromossomos, sendo o mais comum na literatura a formação de dois novos cromossomos, e este foi o mesmo critério adotado. Além desta informação é necessário definir a taxa de troca de genes entre cromossomos e por isso foram testadas as seguintes opções: 10%, 30%, 50%, 70% e 90%, levando em consideração o operador de múltiplos pontos. A Figura 20 apresenta um esquema

do tipo de operador empregado na análise, os quais foram modelados para o problema florestal.

A variação das taxas de trocas gênicas entre cromossomos foi aplicada para compreender qual o grau de pressão de alterações gênicas é admissível, já que a curtas trocas o algoritmo passa a pesquisar soluções vizinhas mais próximas; por outro lado, trocas elevadas exploram mais o espaço de buscas. A última opção pode tornar o algoritmo muito aleatório e prejudicar a sua eficiência, porém faz-se necessário seu estudo.

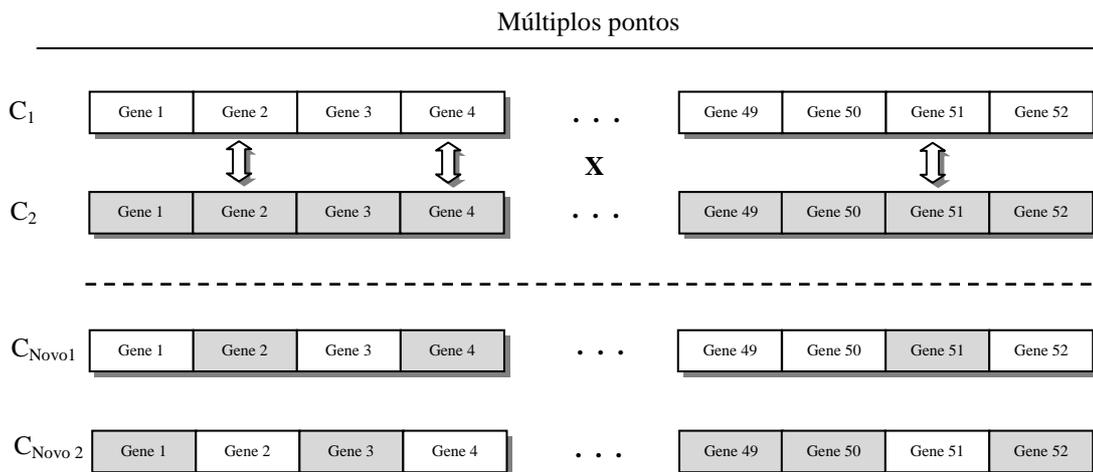


FIGURA 20 - ESTRATÉGIA DE *CROSSOVER* ADOTADA NA RECOMBINAÇÃO DE GENES ENTRE CROMOSSOMOS.

3.3.5.2 Mutação

A mutação é um processo natural recorrente na natureza, mas que ocorre de forma bem reduzida na parcela da população. Os seus efeitos podem levar o indivíduo a ganhos fenotípicos ou não, devido a sua característica aleatória de ocorrência. Usualmente, a mutação estabelece uma substituição simples nos valores presentes no alelo, em um específico gene, podendo ainda assumir diferentes estratégias e taxas de ocorrência. A principal importância deste operador é introduzir novos indivíduos na população, além de contribuir para a manutenção da diversidade genética da população, evitando a estagnação das buscas em apenas um ponto do espaço a pesquisar (VICTORINO, 2005).

O critério utilizado foi considerar uma mutação uniforme, ou seja, aplicar uma taxa constante de mutação ao longo do tempo, e em todas as gerações. Além disso, para que o operador possa ser aplicado, é necessário estabelecer uma probabilidade do evento, já que o mesmo é aleatório. Desta maneira, o efeito só foi introduzido a partir de uma probabilidade

fixa de 0,5 de ocorrência do evento, em apenas uma parcela da população, o que caracteriza evidentemente os processos de mutação. Assim, o número de indivíduos selecionados aleatoriamente da população e que sofreram mutação foi fixado em 10% da população inicial. Além disso, após a seleção dos indivíduos para a mutação, faz-se necessário a definição do número de genes que sofrerão as alterações. Nos testes do AG foram empregadas as pressões de alteração gênica de 10% e 20% dos genes para cada cromossomo selecionado.

A Figura 21 apresenta uma mutação aplicada em um gene do cromossomo, onde apenas uma simples troca no valor do alelo ($0 \rightarrow 1$) produziu uma nova alternativa de manejo para o talhão. Vale ainda ressaltar a obrigatoriedade de se produzir indivíduo viável (alternativa de manejo viável para o talhão), após esta operação. O exemplo de mutação apresentado irá afetar as produções volumétricas de madeira e conseqüentemente o valor do VPL.

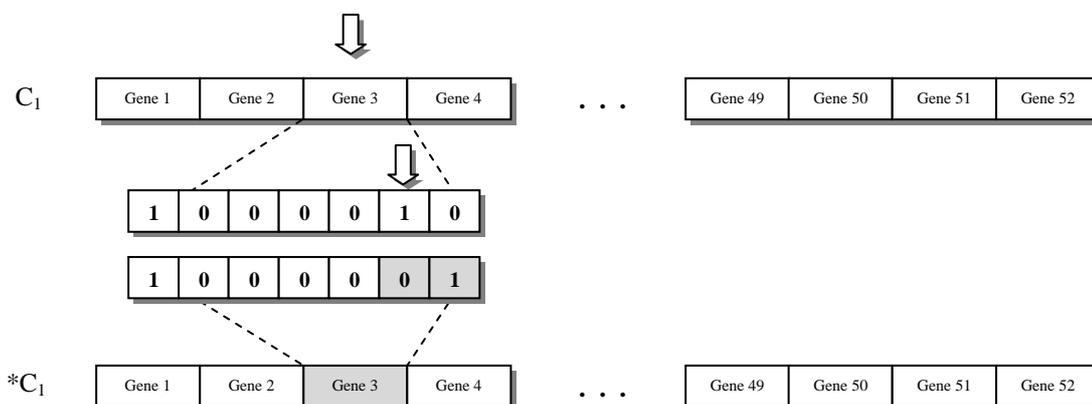


FIGURA 21 - EXEMPLO DE APLICAÇÃO DE UMA MUTAÇÃO SIMPLES NA FORMAÇÃO DE UM NOVO INDIVÍDUO PARA A POPULAÇÃO.

O objetivo da variação foi verificar se existem diferenças na taxa de alteração de genes dentro do cromossomo e na qualidade da solução final encontrada, bem como no tempo de processamento.

3.3.6 Replacement

A idéia original do AG, proposto por Holland, foi aplicar os operadores de seleção, reprodução e mutação na geração (G) e produzir novos indivíduos, que na geração ($G+1$) substituíam completamente seus pais. O método conhecido como *Generational* ou Geracional tinha como um dos pontos falhos a perda das relações entre pais e filhos e principalmente o descarte do melhor indivíduo encontrado na geração (G). Mais tarde, o conceito de elitismo foi introduzido para garantir a permanência do melhor indivíduo encontrado a cada nova

geração. Posteriormente, novas maneiras de substituição dos indivíduos na geração (G+1) foram sugeridas, e assim foi criado o conceito *steady state* ou *incremental strategies*, ou estado fixo, que consistia em substituir apenas uma parcela da população (RAWLINS, 1991). Alguns autores consideram que o *steady state* restringe a introdução de apenas 1 indivíduo por geração, eliminando geralmente o pior indivíduo da população (GARCÍA-MARTÍNEZ e LOZANO, 2008).

A substituição é um mecanismo necessário ao AG, pois a lógica é sempre trabalhar com um número fixo de indivíduos presente na população. Além disso, a cada processo de reprodução, novos indivíduos são gerados, o que aumenta o número inicial de indivíduos da população. Na literatura observam-se duas maneiras de substituição: a primeira, que aplica um mecanismo para selecionar quais indivíduos sobreviverão, a qual une pais e filhos e então realiza o processo; e a segunda opção, que realiza a troca dos pais pelos filhos criados, a uma taxa fixa de substituição (GEN e CHENG, 1996). Considerando a segunda opção, os esquemas de substituição mais comumente encontrados são: os piores, os melhores, os pais, aleatório e apenas os idênticos (TSENOV, 2005).

A variação no número de substituições, na população, exerce pressões diferentes na dinâmica populacional, ou seja, altas taxas de substituição promovem um maior número de busca no espaço de soluções, e baixas taxas causam o efeito contrário. Entretanto, uma alta pressão de seleção, que está ligada ao *replacement*, pode diminuir a diversidade da população e promover uma convergência prematura. Por outro lado, o contrário promove uma busca ineficiente (MICHALEWICZ, 1998). Assim, o equilíbrio desta pressão de seleção e substituição é essencial ao bom funcionamento do AG. A parcela da população a ser substituída, a cada geração, varia muito na literatura, passando de apenas um indivíduo a toda a população.

Segundo Coley (1996), a fração de indivíduos criados e que substituem uma parcela da população é conhecida como *generation gap*. Esta foi uma das opções utilizadas no trabalho para formar a nova geração, sendo então eliminados os piores pais em detrimento dos filhos. Uma aplicação semelhante foi encontrada no trabalho de Wilson *et al.* (2004), onde os autores eliminaram o conjunto dos piores indivíduos. Os operadores de substituição da população devem assegurar que os cromossomos menos aptos ou mais fracos sejam substituídos por outros com maiores valores de *fitness* (CASTRO, 2001).

Desta forma, o critério adotado foi considerar o conceito do método *steady state*, porém variando o número de indivíduos (os piores) a serem substituídos por geração, sendo

eles: substituir apenas 2 indivíduos por geração (*steady state 1*), 10% dos indivíduos da população inicial (*steady state 2*) e 50% dos indivíduos da população inicial (*steady state 3*). Neste sentido, a porcentagem de novos indivíduos substitui a mesma fração da população, composta pelos pais. A formulação (10) descreve a substituição da população, pelo método *steady state* a cada nova geração.

$$\text{População (G+1)} = \text{População (G)} - \text{População (G)} \times P_{\text{substituição}} + N_{\text{indivíduos}} \quad (10)$$

Onde:

População (G+1) - População formada para a próxima geração;

População (G) - População da geração atual;

$P_{\text{substituição}}$ - Porcentagem ou parcela da população que será substituída;

$N_{\text{indivíduo}}$ - Número de indivíduos gerados;

3.3.7 Critério de parada

O critério de parada no AG assume diversas opções, variando desde tempo de processamento até o valor da solução encontrado. A maioria dos trabalhos pesquisados cita como critério de parada a não alteração do melhor valor de *fitness* a partir de n iterações. Entretanto, este tipo de critério pode promover distorções no resultado final da análise, quando se quer testar e comparar diferentes configurações. O problema encontra-se na variação do número de iterações gastas/utilizadas por cada configuração do AG. Neste caso, podem aumentar as chances de uma dada configuração melhorar a solução, em virtude de disponibilizar algumas iterações extras. Assim, a partir de testes prévios foi definido um limite de 1.000 iterações para cada processamento. Este número de iterações foi empregado por Mota Filho (2005).

3.4 IMPLEMENTAÇÃO COMPUTACIONAL E PROCESSAMENTO

A implementação da metaheurística foi desenvolvida utilizando a linguagem de programação *Visual Basic*[®] versão 6.0 *Enterprise* da *Microsoft*[®], licenciada para o PPGEF (Programa de Pós Graduação em Engenharia Florestal) da UFPR.

O *PCFLORESTAL* é uma ferramenta desenvolvida no presente trabalho para otimizar o agendamento da colheita florestal via metaheurísticas (AG e SA), apresentando uma série de saídas gráficas e mapas para a colheita florestal. Além disso, possui diversas opções de AG

e SA, conforme mostra a Figura 22.

Desta maneira, o processamento de todas as configurações foi efetuado através da plataforma do *PCFLORESTAL*, sendo executado em um computador com processador *Celeron® core 2 duo 2100 MHz* e 2 Gb de RAM.

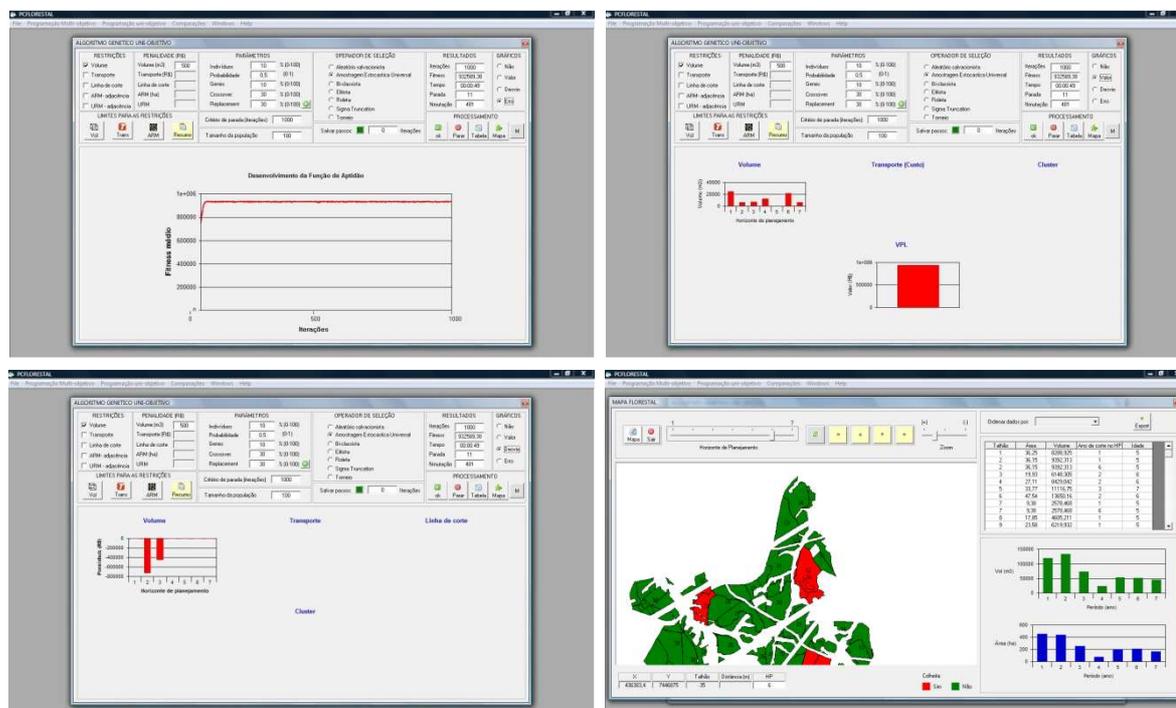


FIGURA 22 - LAYOUT DO *PCFLORESTAL* NA OPÇÃO DE PROCESSAMENTO UTILIZANDO O ALGORITMO GENÉTICO.

3.5 ANÁLISE DOS DADOS

Os dados de *fitness* e tempo de processamento foram analisados a partir da média aritmética de cada configuração testada, proveniente de 8 repetições, sendo comparadas ao todo 360 opções de AG. O ANEXO 1 apresenta um resumo das opções testadas e analisadas, bem como suas combinações.

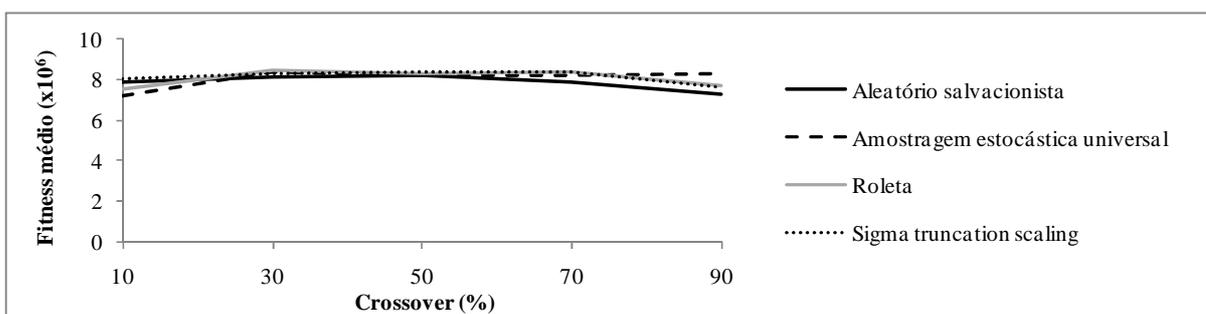
4. RESULTADOS E DISCUSSÃO

O tempo total de execução dos 2.880 processos, referente às 360 configurações testadas foi de 310.087 segundos (83,13 horas), sendo que, ao longo deste período, observou-se que o AG é realmente dependente de sua configuração inicial. Os parâmetros testados como operador de seleção, taxas de trocas gênicas (*crossover*), taxas de alteração de genes na mutação, população inicial e intensidades de *replacement* apresentaram interações positivas

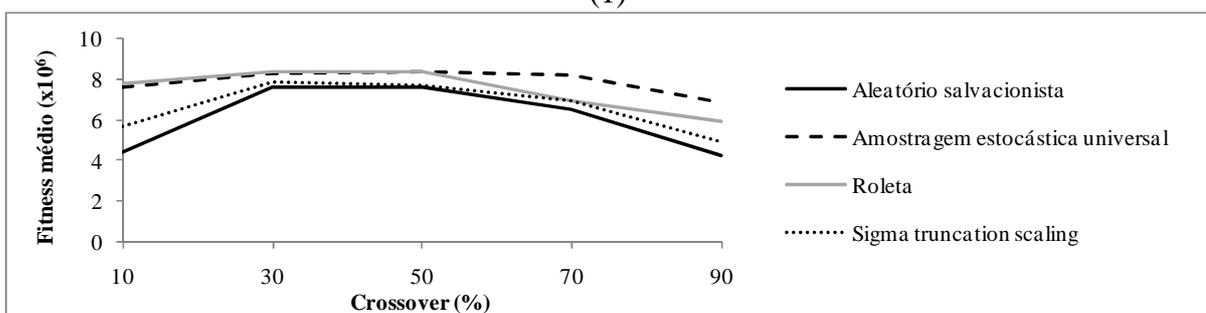
no AG durante as buscas, na maioria dos casos, demonstrando haver relações importantes entre os parâmetros.

A diferença percentual entre a melhor e a pior solução encontrada, provindos dos testes e independente da configuração formada, foi na ordem de 74,62%, o que sugere a necessidade de estudos desta natureza. Além desta situação extrema de diferença, outros desvios foram encontrados ao se comparar todas as configurações testadas.

As estratégias de seleção dos indivíduos, para a reprodução, demonstraram não ser o ponto chave do AG, e sim a combinação dos mesmos com os outros parâmetros presentes no AG. Entretanto, foram observadas diferenças de respostas entre os operadores testados (Gráfico 2). Estas diferenças podem ser consideradas importantes, já que representam ganhos na função maximizada do VPL. Na configuração representada pelo Gráfico 2 é apresentada uma situação com baixa influência destes operadores (1) e uma outra tendência contrária (2) na determinação da solução final.



(1)



(2)

GRÁFICO 2 - INFLUÊNCIA DOS OPERADORES DE SELEÇÃO NA QUALIDADE DA RESPOSTA GERADA PELO AG, CONSIDERANDO UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS, *STEADY STATE 3* E TAXA DE ALTERAÇÃO GÊNICA NA MUTAÇÃO (1) 10% E (2) 20%.

Em todos os 360 casos analisados, existiu sempre uma alternância da indicação do melhor operador de seleção para o AG. Como exemplo, a cada configuração formada um tipo de operador se destacava. Porém, observou-se uma ligeira superioridade de boas respostas quando utilizava a amostragem estocástica universal, seguido pelos operadores roleta, sigma

truncation scaling e aleatória salvacionista. As diferenças percentuais entre os valores médios do *fitness* ficaram em: 0,16%, 0,34% e 0,84% em relação ao melhor operador de seleção, e na mesma seqüência de superioridade. De acordo com Reeves (2003), o operador de seleção via amostragem estocástica universal é superior ao operador via roleta, confirmando os resultados obtidos.

A Tabela 6 mostra a melhor configuração encontrada para cada tipo de operador de seleção. Assim, observou-se a princípio que a configuração dos parâmetros *replacement* e população foram constantes para todos os casos. Neste sentido, fica claro que o tamanho da população e a pressão de substituição (*replacement*) foram os parâmetros mais importantes ao AG.

TABELA 6 - MELHORES CONFIGURAÇÕES ENCONTRADAS PARA O AG FIXANDO OS QUATRO OPERADORES DE SELEÇÃO.

Operadores de Seleção	<i>Replacement</i>	População	Operação gênica		<i>Fitness</i>
			Mutação (%)	<i>Crossover</i> (%)	
Amostragem estocástica universal	<i>steady state</i> 3	300	20	50	8.513.046,62
Roleta	<i>steady state</i> 3	300	20	50	8.499.003,56
Sigma <i>truncation scaling</i>	<i>steady state</i> 3	300	20	50	8.484.407,11
Aleatório salvacionista	<i>steady state</i> 3	300	10	30	8.441.957,71

As taxas de trocas gênicas (*crossover*) e alteração gênica (mutação) assumiram características semelhantes, para três dos quatro operadores, alterando apenas suas configurações no operador aleatório salvacionista. Uma possível explicação sobre este efeito é devido à característica de funcionamento do operador aleatório salvacionista. Este método considera um processo totalmente aleatório de seleção dos indivíduos, para a reprodução (exceção para o melhor indivíduo) a cada geração. Assim, durante as etapas de reprodução e mutação, o aumento nas taxas de trocas de genes no *crossover* e alterações na mutação provocam um aumento da aleatoriedade no AG. Desta forma, o aumento da aleatoriedade retratado significa a realização de buscas em diferentes regiões do espaço de soluções, não permitindo um refinamento das respostas encontradas. Por outro lado, quando o processo se torna mais lento nas buscas, ou pouco aleatório, o algoritmo encontra dificuldades de percorrer regiões mais distantes do local analisado, acarretando na baixa qualidade das soluções. A exemplo tem-se os resultados de uma configuração não desejável para o AG, disposto na Tabela 7.

TABELA 7 - PIORES CONFIGURAÇÕES ENCONTRADAS PARA O AG FIXANDO OS QUATRO OPERADORES DE SELEÇÃO.

Operadores de Seleção	Replacement	População	Mutação (%)	Crossover (%)	Fitness
Amostragem estocástica universal	<i>steady state 1</i>	100	20	90	3.146.777,09
Roleta	<i>steady state 1</i>	100	20	90	2.949.458,00
<i>Sigma truncation scaling</i>	<i>steady state 2</i>	100	20	10	2.945.715,44
Aleatório salvacionista	<i>steady state 1</i>	200	20	90	2.160.431,94

A taxa de alteração gênica na mutação influenciou mais a qualidade da solução final, quando comparado o tipo de operador de seleção. Neste aspecto, o Gráfico 3 ilustra a importância desta taxa na qualidade das respostas, para cada tipo de operador de seleção. Graficamente observa-se que ao aplicar uma taxa de alteração gênica de 10%, na mutação, a qualidade da resposta final é sempre superior para a configuração adotada (100 indivíduos e *steady state 1*), e independente da taxa de *crossover* utilizada.

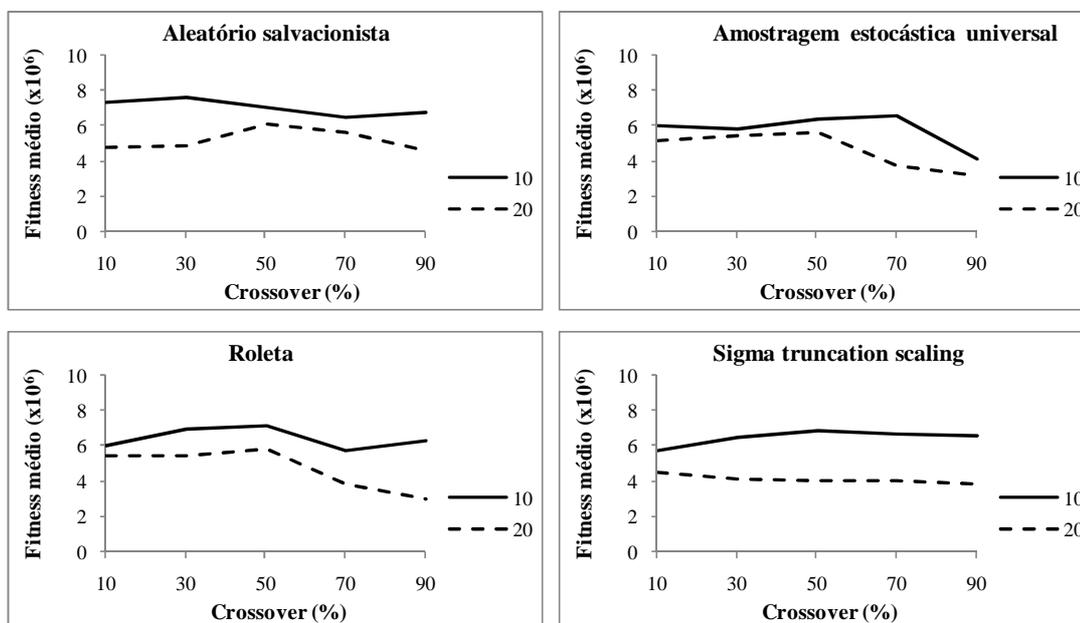


GRÁFICO 3 - COMPORTAMENTO DAS TAXAS DE ALTERAÇÃO GÊNICA NA MUTAÇÃO A PARTIR DE UMA POPULAÇÃO INICIAL DE 100 INDIVÍDUOS E *STEADY STATE 1*.

A mesma tendência foi observada para as configurações *steady state 2* e *steady state 3*, considerando uma população inicial de 100 indivíduos. Entretanto, ao aumentar o tamanho da população inicial para 300 indivíduos, o efeito desta taxa passou a diminuir e, em alguns casos, a alteração de 20% foi superior (Gráfico 4).

Os efeitos da alteração gênica na mutação a 10% e 20% tornaram-se muito parecidos, notando ainda que o melhor *fitness* médio foi obtido quando se empregou uma taxa de 20%. A melhor configuração formada considerando a alteração gênica foi em 20% na mutação, sendo superior a opção de 10% em apenas 0,17% em relação ao *fitness*. Segundo Alves (2002), a

mutação é um operador que avalia áreas do espaço de busca ainda não avaliadas (*exploration*), e por isso pode provocar melhoras na solução. A razão deste efeito pode estar relacionada à teoria da mutação, sendo um processo raro e que ocorre de forma aleatória. O mecanismo de randomização é também aplicado nos genes que sofrerão mutação, tornando assim o evento totalmente aleatório e sem controle. Desta maneira, o refinamento das soluções tende a ser dificultado em populações reduzidas, quando a taxa de alteração gênica na mutação for elevada. O mesmo problema pode ocorrer se o número de indivíduos selecionados para mutação for alto, o que não foi contemplado neste estudo.

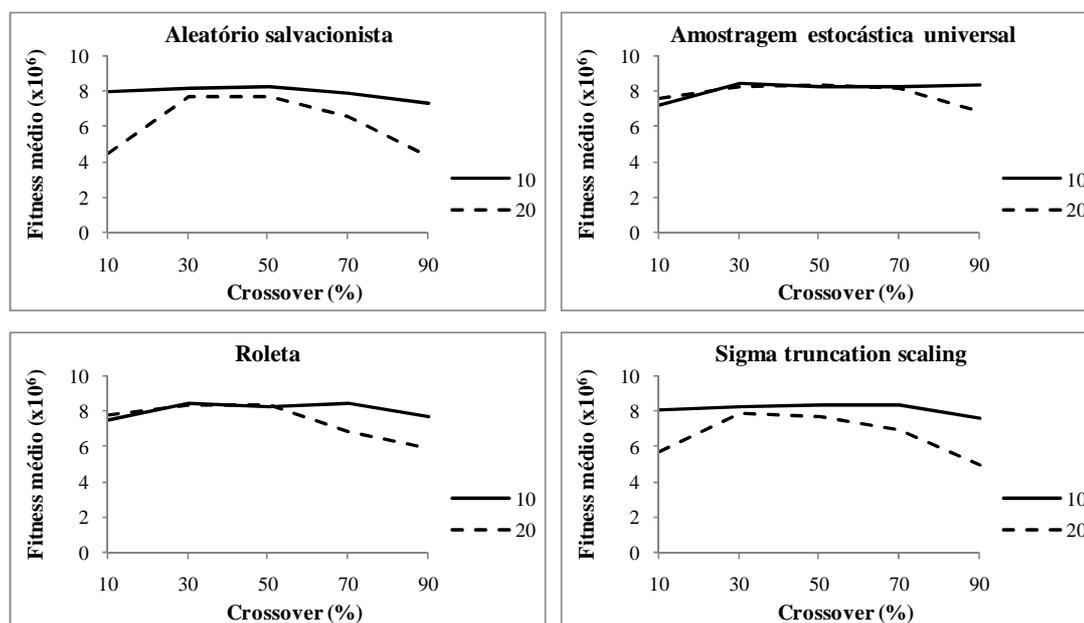


GRÁFICO 4 - COMPORTAMENTO DAS TAXAS DE ALTERAÇÃO GÊNICA NA MUTAÇÃO A PARTIR DE UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS E *STEADY STATE* 1.

O acelerado processo de substituição da população dos pais pelos novos indivíduos formados resultou em boas respostas ao AG, considerando um critério de parada de 1.000 iterações (Gráfico 5). A estratégia adotada sempre substituiu os piores indivíduos, consolidando assim um método elitista, que neste caso surtiu efeito positivo na evolução das buscas. A possível causa de sucesso pode ser analisada seguindo os seguintes raciocínios: 1 - os cruzamentos realizados através das gerações poderiam produzir filhos com maior vigor genético; 2- a diversidade não foi reduzida drasticamente, conforme sugerido pela literatura, pois não havia controle da qualidade dos cruzamentos, ou seja, havia a possibilidade de formação de diversos tipos de indivíduos (piores e melhores) na reprodução; 3 - havia a possibilidade de inserir indivíduos piores na nova geração, aumentando a diversidade; 4 - quanto maiores as taxas de substituição, maiores foram as taxas de reprodução e buscas por

novas soluções; 5 - uma convergência mais rápida a 1.000 iterações, já que este foi o critério de parada. Desta forma, a opção *steady state 3* foi a responsável pela obtenção do melhor *fitness* médio.

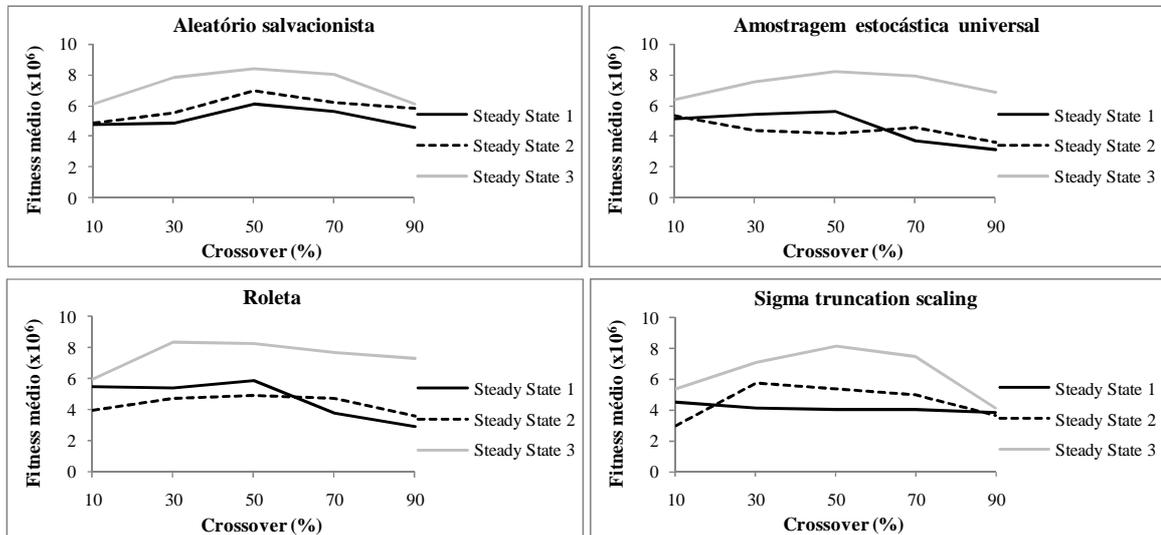


GRÁFICO 5 - INFLUÊNCIA DA TAXA DE *REPLACEMENT* NA QUALIDADE DA RESPOSTA CONSIDERANDO UMA POPULAÇÃO INICIAL DE 100 INDIVÍDUOS E ALTERAÇÕES GÊNICAS DE 20% NA MUTAÇÃO.

Entretanto, com o aumento da população, o efeito da taxa de substituição passou a influenciar menos na diferença entre respostas, em virtude da maior diversidade de soluções existentes em cada geração, conforme apresentado no Gráfico 6.

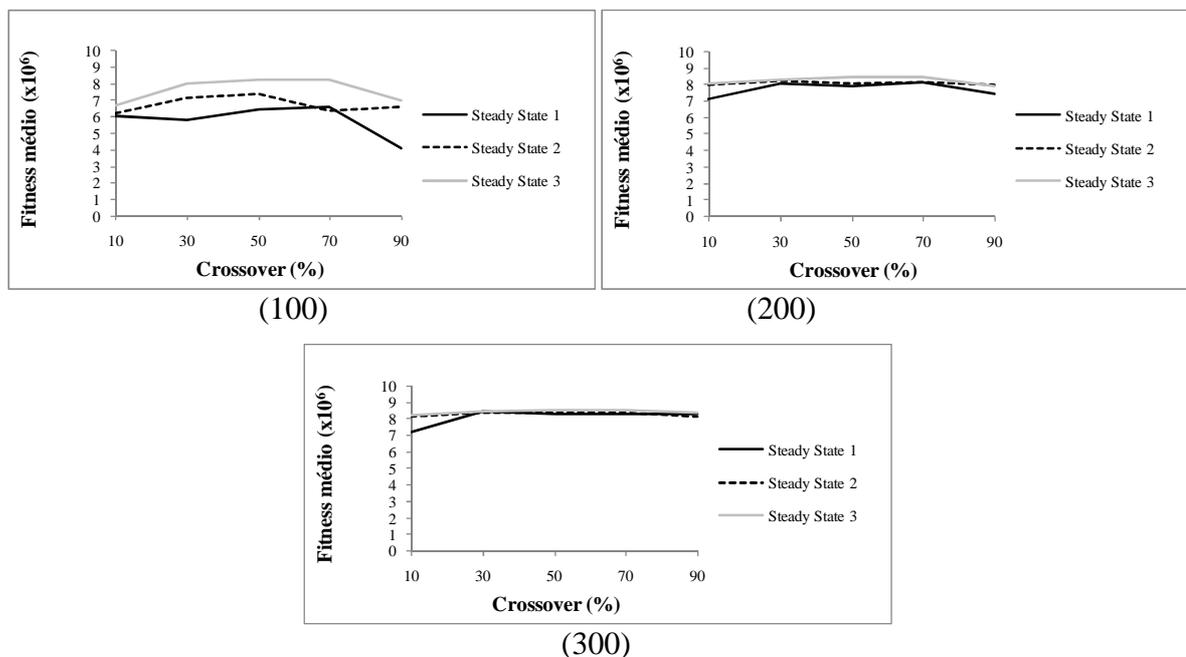


GRÁFICO 6 - EFEITO DA POPULAÇÃO INICIAL NAS OPÇÕES DE *REPLACEMENT* CONSIDERANDO UMA TAXA DE ALTERAÇÃO DE 10% NA MUTAÇÃO E USO DA AMOSTRAGEM ESTOCÁSTICA UNIVERSAL COMO OPERADOR DE SELEÇÃO.

Chipperfield (1997) comparou técnicas determinísticas de substituição de indivíduos e mostrou que não há diferença significativa nas características de convergência do AG. O critério de parada adotado pelo autor foi diferente do determinado para o presente estudo, e por isso pode ter promovido um resultado diferente. Contudo, esta divergência mostra que o AG necessita de um número maior de iterações para convergir em boas soluções, quando utilizado configurações do tipo *steady state* 1. Além disso, Michalewicz (1996) comenta que existem duas características importantes no processo evolutivo do AG: a população e a diversidade. Estes fatores estão fortemente relacionados à pressão de seleção, o que pode reduzir ou aumentar a diversidade da população.

A taxa de alteração na mutação também influenciou a qualidade da resposta, nas três opções de *replacement* testada, de acordo com o Gráfico 7. Os cruzamentos das curvas (*steady state* 1 e 2) ao longo das taxas de *crossover* indicam uma semelhança de comportamento entre estas opções. Estas duas opções apresentam uma taxa de *replacement* muito similar, a depender do tamanho da população, e assim é explicada esta ligeira igualdade. O mesmo não ocorre com a opção *steady state* 3, por estabelecer substituições mais elevadas na população.

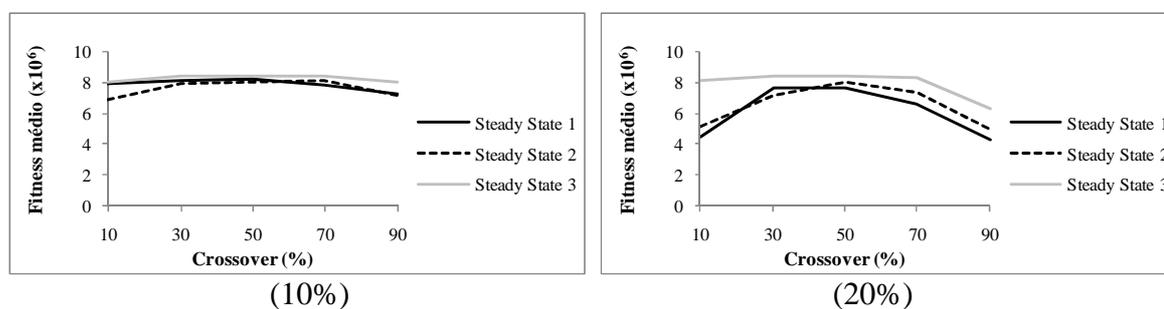


GRÁFICO 7 - EFEITO DA TAXA DE ALTERAÇÃO GÊNICA NA MUTAÇÃO EM OPÇÕES DE *REPLACEMENT* CONSIDERANDO UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS E USO DO OPERADOR DE SELEÇÃO ALEATÓRIO SALVACIONISTA.

O tamanho da população inicial foi um dos principais fatores na qualidade das buscas realizada pelo AG, juntamente com a estratégia de *replacement*. A população influi diretamente no número de soluções visitadas durante as gerações, bem como na taxa de diversidade. O último caso reflete diretamente os efeitos já comentados anteriormente, quando retratado o comportamento das taxas de *replacement*. Assim, ficou clara a percepção de que populações maiores possuem maiores chances de convergir em melhores soluções, conforme mostra o Gráfico 8.

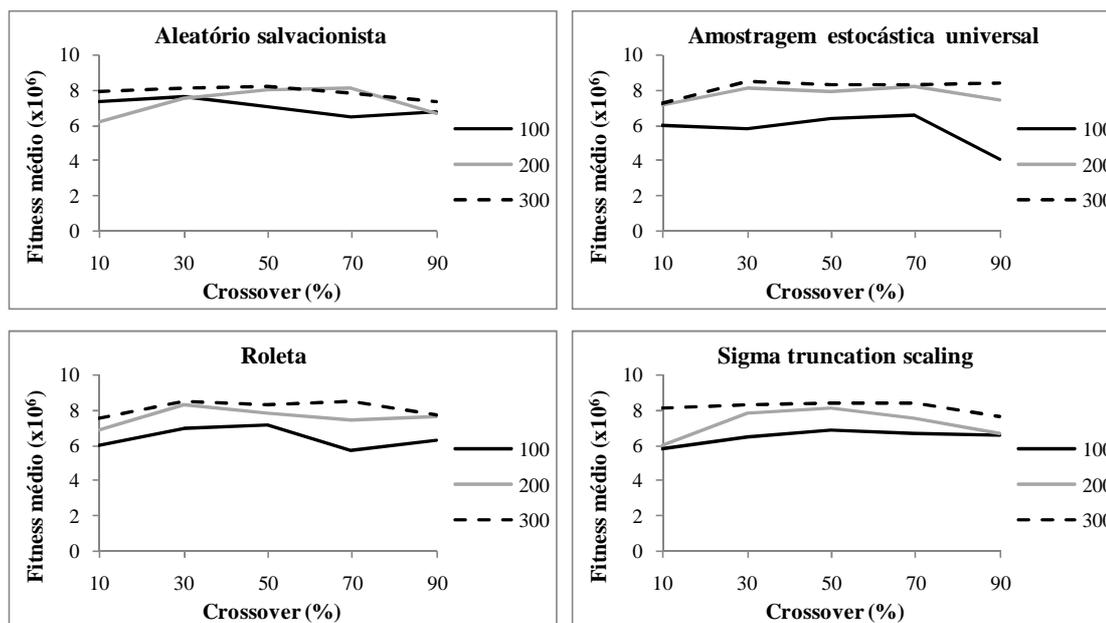


GRÁFICO 8 - EFEITO DA POPULAÇÃO INICIAL AO *FITNESS* CONSIDERANDO UMA TAXA DE ALTERAÇÃO GÊNICA DE 10% NA MUTAÇÃO E OPÇÃO *STEADY STATE 1*.

No presente estudo, as melhores configurações foram observadas em populações maiores. Entretanto, dependendo da configuração utilizada no AG, o parâmetro população inicial pode não corresponder às expectativas de obtenção de boas soluções. No estudo de otimização de um reator industrial para a produção de álcool cíclico, a melhor configuração do AG foi composta por uma população de 40 indivíduos, sendo testadas as seguintes opções: 20, 30, 40 e 50 indivíduos (VICTORINO, 2005).

Mendel (2006) mostrou em seu estudo que o aumento da população inicial promove uma melhora da solução até um dado limite. Rodrigues (2001) realizou testes para conhecer a melhor configuração para o AG testando as seguintes populações: 25, 50, 75 e 100, e as melhores respostas foram obtidas a 75 e 100 indivíduos.

De forma geral, as melhores soluções obtidas foram ao adotar uma população inicial igual de 300 indivíduos. Assim, foi identificado que as 29 melhores configurações apresentavam apenas as opções de 200 e 300 indivíduos, expressando uma maior frequência para a última opção. Complementando ainda estas informações, o melhor *fitness* médio foi obtido pela configuração de uma população de 300 indivíduos. Esta solução foi superior a 0,31% e 0,93% em relação aos melhores *fitness* médio obtidos pelas populações de 200 e 100 indivíduos, respectivamente.

Um importante efeito presente no AG refere-se ao controle das buscas por soluções vizinhas, sendo atribuídas à taxa trocas gênicas pelo *crossover*. A troca de genes entre

cromossomos promove o surgimento de novos indivíduos, bem como o refinamento de soluções. Neste caso, em taxas mais reduzidas o AG passou a explorar melhor a questão do refinamento, e o oposto trabalhou a amostragem de outros pontos não pesquisados do espaço. O balanceamento destas duas características torna o AG mais robusto na busca de boas soluções. A boa modelagem dos parâmetros visa o encontro do ponto equilibrado entre *exploration* e *exploitation*, ou seja, o termo *exploration* refere-se a explorar o espaço de soluções, investigando áreas novas e desconhecidas de forma intensa, já *exploitation* trabalha o contrário do termo anterior, no refinamento, onde as buscas são recorrentes nas soluções próximas as já visitadas.

Nos testes, observou-se que as duas estratégias (*exploration* e *exploitation*) levadas ao extremo não foram bem sucedidas, ou seja, taxas de trocas gênicas pelo *crossover* igual 10% e 90% (Gráfico 9). Os melhores *fitness* médios obtidos estiveram em uma faixa variando de 30%, 50% e 70% de trocas gênicas entre cromossomos, reportando ainda que a melhor opção foi encontrada ao nível de 50%. Este resultado confirma a idéia de sempre utilizar um ponto de equilíbrio nas buscas, possibilitando então o refinamento (*exploitation*) e a amostragem de outros pontos (*exploration*).

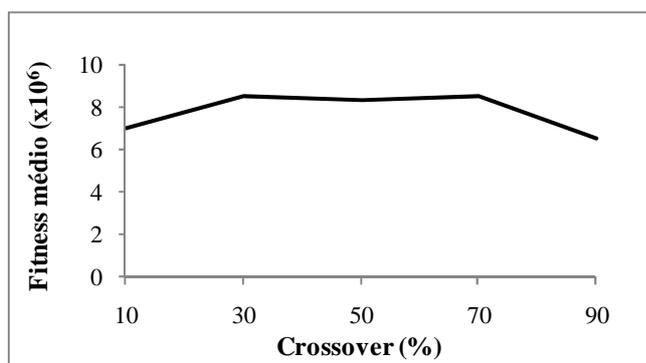


GRÁFICO 9 - EFEITO DAS TAXAS DE TROCAS GÊNICAS PELO *CROSSOVER* NA QUALIDADE DO *FITNESS* CONSIDERANDO UMA TAXA DE ALTERAÇÃO GÊNICA DE 20% NA MUTAÇÃO, OPÇÃO *STEADY STATE* 3, POPULAÇÃO INICIAL DE 200 INDIVÍDUOS E USO DA AMOSTRAGEM ESTOCÁSTICA UNIVERSAL COMO OPERADOR DE SELEÇÃO.

As duas melhores configurações encontradas para o AG compartilham praticamente da mesma configuração: o uso de uma taxa de *replacement* igual a 50% (*steady state* 3), uma população inicial igual a 300 indivíduos, a amostragem estocástica universal como o operador de seleção e uma taxa de alteração na mutação igual a 20%, diferenciando apenas na taxa de trocas gênicas pelo *crossover* (30% e 50%). A taxa de 50% apresentou uma melhora de apenas 0,16% de *fitness* médio quando comparado à de 30%, e por isso foi considerada como

a melhor resposta geral. Victorino (2005) estabeleceu uma variação ótima para estas taxas, determinando em seu estudo um intervalo viável de 0,4 a 0,8 para a otimização de um reator industrial de produção de álcool cíclico.

O tempo de processamento também é uma variável importante e contribui para a definição do tipo de configuração indicada. No estudo, as configurações que mais demandaram tempo de processamento foram aquelas que utilizaram uma população inicial de 300 indivíduos e taxas elevadas de trocas gênicas pelo *crossover* (90%), conforme Gráfico 10. O valor de 90% não apresentou boas soluções, conforme discutido anteriormente, o mesmo não se pode dizer para uma população de 300 indivíduos. Neste último caso, o maior tempo de processamento foi positivo, devido aos ganhos observados nas respostas. Entretanto, segundo Goldberg (1989), o tamanho da população não deve ser exagerado, dando preferência a populações relativamente pequenas para ganhar eficiência no processo.

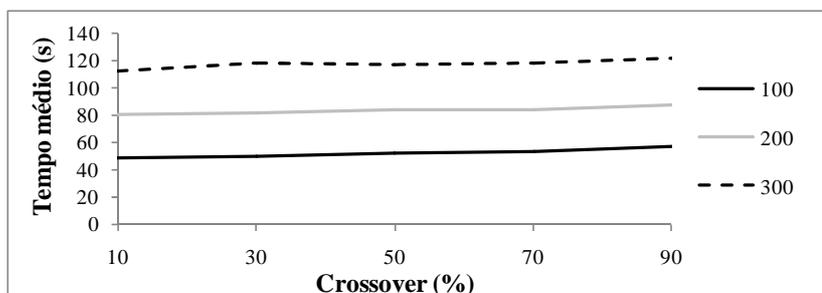


GRÁFICO 10 - INFLUÊNCIA DA POPULAÇÃO INICIAL NO TEMPO DE PROCESSAMENTO CONSIDERANDO A CONFIGURAÇÃO: *STEADY STATE 2*, AMOSTRAGEM ESTOCÁSTICA UNIVERSAL COMO OPERADOR DE SELEÇÃO E TAXA DE ALTERAÇÃO GÊNICA DE 20% NA MUTAÇÃO.

O número de cálculos realizados por cada operador, durante suas estratégias de seleção, contribuiu diretamente no tempo de execução final do processo (Gráfico 11).

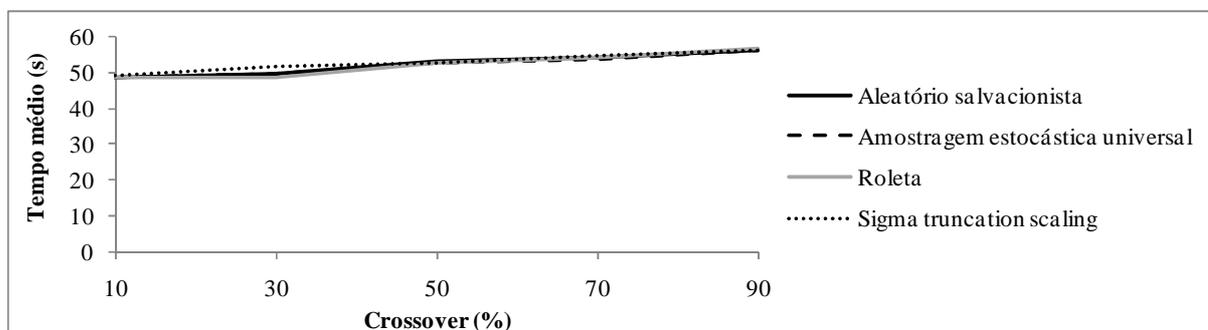


GRÁFICO 11 - COMPORTAMENTO DO TEMPO DE EXECUÇÃO POR OPERADOR SEGUINDO A CONFIGURAÇÃO: *STEADY STATE 2*, POPULAÇÃO INICIAL DE 100 E TAXA DE ALTERAÇÃO GÊNICA DE 20% NA MUTAÇÃO.

O operador *sigma truncation scaling* apresentou em média os maiores tempos demandados, já que necessita de transformações na escala dos *fitness* a cada geração. Os outros operadores apresentaram um comportamento semelhante de uma maneira geral, onde o ponto chave está ligado à forma de programação do processo de randomização nos operadores.

Uma ligeira diferença em tempo de execução pode ser observada ao aplicar taxas diferentes de alteração gênica, pela mutação. A diferença se deu devido ao maior volume de alterações por mutação realizada, sendo um resultado já esperado inicialmente. O Gráfico 12 apresenta a relação do tempo médio de processamento e a alteração nestas taxas, ao variar as taxas de trocas gênicas pelo *crossover*.

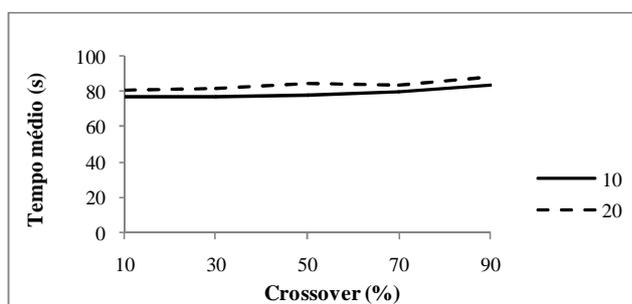


GRÁFICO 12 - COMPORTAMENTO DO TEMPO DE EXECUÇÃO EM RELAÇÃO À TAXA DE ALTERAÇÃO GÊNICA NA MUTAÇÃO SEGUINDO A CONFIGURAÇÃO: *STEADY STATE 2*, AMOSTRAGEM ESTOCÁSTICA UNIVERSAL E POPULAÇÃO INICIAL DE 200 INDIVÍDUOS.

O número de indivíduos a serem substituídos pelo processo de *replacement*, a cada geração, também influenciou o tempo de execução (Gráfico 13). Este resultado já era esperado, pois a taxa de *replacement* influi diretamente no número de indivíduos selecionados para a reprodução, e conseqüentemente em todos os cálculos realizados para se obter o valor do *fitness* individual. Além disso, o número de operações de trocas entre genes também é influenciado pela variação desta taxa, porém de maneira indireta.

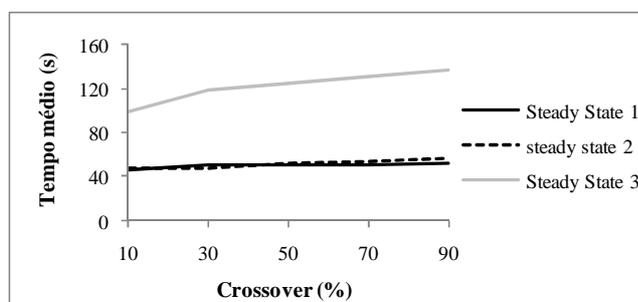


GRÁFICO 13 - INFLUÊNCIA DAS OPÇÕES DE *REPLACEMENT* NO TEMPO DE PROCESSAMENTO FIXANDO A SEGUINTE CONFIGURAÇÃO: OPERADOR DE SELEÇÃO ROLETA, TAXA DE ALTERAÇÃO GÊNICA DE 20% E POPULAÇÃO INICIAL DE 100 INDIVÍDUOS.

As opções *steady state* 1 e 2 apresentaram tendências similares de gasto de tempo para o processamento, já que as diferenças no número de substituições por geração foram bem próximas. Entretanto, a opção *steady state* 3 consumiu em média um tempo superior aos observados nas outras opções, porém seus resultados foram considerados superiores em muitos casos.

Segundo Reeves (2003), o AG deve ser processado várias vezes, pois existem diferentes agentes durante o processo que podem influenciar na convergência de uma boa resposta. Estas repetições promovem uma maior exploração nas buscas, resultando em diferentes opções de resposta. Assim, foi observado que configurações utilizando uma baixa população apresentaram em média uma maior variação nos *fitness* obtidos (Gráfico 14).

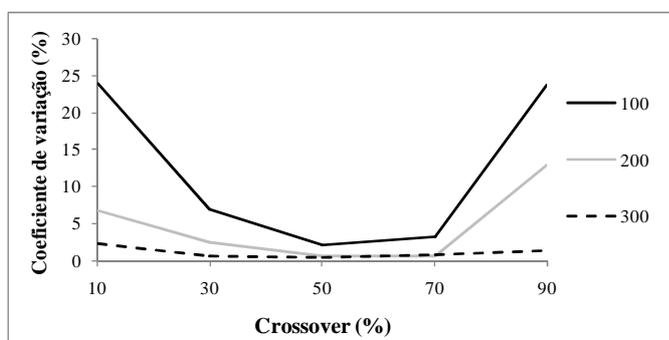


GRÁFICO 14 - INFLUÊNCIA DA POPULAÇÃO INICIAL NA VARIAÇÃO DO *FITNESS* CONSIDERANDO A OPÇÃO *STEADY STATE* 3, TAXA DE ALTERAÇÃO DE 10% NA MUTAÇÃO E O USO DO OPERADOR AMOSTRAGEM ESTOCÁSTICA UNIVERSAL.

A maior variação do *fitness* em populações menores pode indicar que o AG necessita de mais gerações para convergir em melhores respostas, e por isso se deve estruturar corretamente o critério de parada. A lógica mostra que populações maiores apresentam uma diversidade teórica maior e, por isso, quando processados com o mesmo número de iterações em relação a populações menores, apresentam um coeficiente de variação mais estabilizado e reduzido. Este comportamento foi observado na maioria das configurações testadas.

As taxas de trocas gênicas no *crossover* mostram que as maiores variações nos *fitness* foram observadas em pontos mais extremos de busca, ou seja, em locais inseridos na região de 10% e próximo de 90% de trocas. A partir destas taxas ficou demonstrado um baixo equilíbrio da relação *exploration* e *exploitation*.

O controle na taxa de *replacement* também afetou a variação dos dados de *fitness*, obtidos através das repetições (Gráfico 15). Os resultados mostram que no intervalo de 1.000 iterações, o número de trocas realizadas pela opção *steady state* 3 promoveu um maior controle na variação dos dados. Este aspecto confirma uma maior velocidade de convergência

e estabilização da resposta, graças ao elevado número de buscas realizadas.

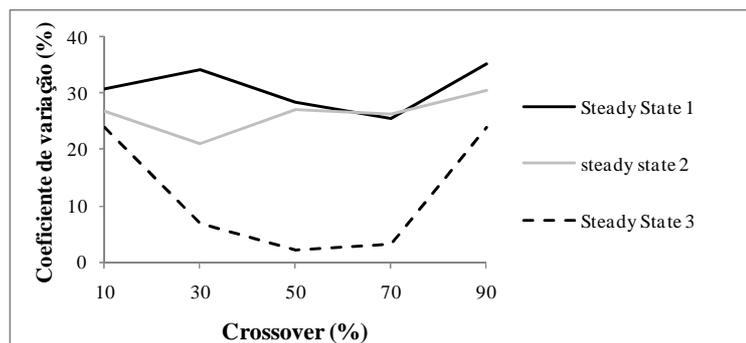


GRÁFICO 15 - INFLUÊNCIA DA TAXA DE *REPLACEMENT* NA VARIAÇÃO DO *FITNESS* CONSIDERANDO UMA POPULAÇÃO INICIAL DE 300 INDIVÍDUOS, TAXA DE ALTERAÇÃO GÊNICA DE 10% NA MUTAÇÃO E USO DO OPERADOR AMOSTRAGEM ESTOCÁSTICA UNIVERSAL.

Os últimos resultados apresentados mostram que, além da qualidade da solução obtida, a confiabilidade de sua recorrência também deve ser levada em consideração. Neste momento observou-se que as configurações consideradas melhores apresentaram uma baixa taxa de variação de suas respostas. O coeficiente de variação ficou abaixo de 1% para as 29 melhores configurações testadas, por outro lado, as piores opções de AG apresentaram uma variação acima de 30%.

5. CONCLUSÃO

- A configuração dos parâmetros presentes no AG contribui diretamente na qualidade da solução obtida. No estudo realizado a melhor configuração (superior em 74,62% no valor do *fitness* médio frente a pior) demonstra a real importância de um estudo prévio;
- O tamanho da população inicial demonstra que seu aumento contribui para obtenção de melhores respostas. Contudo, o incremento de indivíduos na população favorece ao aumento no tempo de processamento;
- Existem diferenças no tipo de operador de seleção empregado, quando analisados os valores médios de *fitness*, porém dependendo da configuração dos outros parâmetros presentes no AG, sua contribuição nas buscas é pouco influente. Assim, de uma maneira geral a melhor seqüência é: amostragem estocástica universal, roleta, sigma *truncation scaling* e aleatória salvacionista. O operador sigma *truncation scaling* mostra-se o mais exigente na demanda de tempo computacional;
- A taxa de alteração gênica de 10% na mutação exerce uma maior influência positiva na qualidade do *fitness*, principalmente em populações menores e a taxas reduzidas de *replacement*. Porém, em populações maiores, o efeito da diferença entre as taxas de 10% e 20% tende a desaparecer, sendo o mesmo observado nas maiores taxas de *replacement*. O tempo computacional de processamento aumenta na medida em que aumenta esta taxa;
- O aumento na pressão de substituição dos indivíduos (*replacement*) por geração promove uma melhora crescente na solução final, dando destaque à opção *steady state* 3. Entretanto, este efeito aumenta o tempo de processamento da metaheurística;
- A taxa ideal de trocas gênicas pelo *crossover* encontra-se entre 30% e 70%, onde se observa uma boa modelagem das relações *exploration* e *exploitation* nas buscas, sendo o uso de taxas de 30% e 50% as mais indicadas. Os valores localizados no extremo (10% e 90%) não apresentam o mesmo equilíbrio desta relação. O tempo de processamento é afetado pelo aumento no valor das taxas de trocas gênicas no *crossover*;
- A melhor configuração do AG e que obtém o melhor *fitness* médio é: população

inicial (300 indivíduos), operador de seleção (amostragem estocástica universal), taxa de trocas gênicas pelo *crossover* (50%), taxa de alteração gênica na mutação (20%) e *replacement (steady state 3* - 50% de substituição);

- As melhores configurações apresentam um coeficiente de variação abaixo de 1%, demonstrando uma melhor capacidade de convergência em melhores soluções.

6. REFERÊNCIA BIBLIOGRÁFICA

ALVES, A. C. **Algoritmos genéticos aplicados ao planejamento da distribuição de energia elétrica em Curitiba e região metropolitana.** Curitiba. 2002. 80f. Universidade Federal do Paraná.

ASHLOCK, D. **Evolutionary Computation for Modeling and Optimization.** Springer. p.571. 2005.

BETTINGER, P.; GRAETZ, D.; BOSTON, K.; SESSIONS, J.; CHUNG, W. Eight heuristic planning techniques applied to three increasingly difficult wildlife planning problems. **Silva Fennica**, Finland, v.36, n.2, p. 561-584, 2002.

CASTRO, H. P. **Utilização de algoritmos genéticos para solução de problema de programação de produção de uma refinaria de petróleo.** Florianópolis. f.59. 2001. Dissertação de Mestrado. Universidade Federal de Santa Catarina.

CHAMBERS, L. **Practical handbook of genetic algorithm: complex coding systems.** CRC. 1999. p. 572.

CHIPPERFIELD, A. Introduction to genetic algorithms. p.1-45. In: ZALZALA, A. M.S.; FLEMING, P. J. **Genetic algorithms in engineering systems.** EIT. p. 263. 1997.

COLEY, D.A. **An introduction to genetic algorithms for scientists and engineers.** World Scientific. 1999. p.185.

FALCÃO, A. O.; BORGES, J. G. Designing an evolution program for solving integer forest management scheduling models: an application in Portugal. **Forest Science**, USA, v.74, n.2, p.158-168, 2001.

GARCÍA-MARTÍNEZ, C.; LOZANO, M. Local Search Based on Genetic Algorithms. p. IN: Siarry, P.; Michalewicz, Z. **Advances in Metaheuristics for Hard Optimization.** Springer. p.474. 2008.

GEN, M.; CHENG, R. **Genetic Algorithms and Engineering Design**. Wiley. 1996. p.432.

GEN, M.; CHENG, R. **Genetic Algorithms and Engineering optimization**. Wiley. 2000. p.495.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Longman, 1989. 412 p.

HANCOCK, P. J. B. Selection methods for evolutionary algorithms. p.61- 86. In: CHAMBERS, L. **Practical handbook of genetic algorithm: complex coding systems**. CRC. 1999. p. 572.

HAUPT, R.; HAUPT, S. H. **Practical genetic algorithm**. USA. Wiley. 2004. 253p.

KUILEKOV, M.; ZIOLKOWSKI, M.; BRAUER, H. Application of Genetic Algorithms to an Inverse Field Problem in Magnetic Fluid Dynamics. **Serbian Journal of Electrical Engineering**, Serbian, v.1, n.1, p.1-13, 2003.

MENDEL, C. A. **Utilização de Algoritmos Genéticos em recomposição de sistemas de potência**. São Leopoldo. 2006. 151f. Dissertação de Mestrado. Universidade do Vale do rio dos Sinos.

MICHALEWICZ, Z. **Genetic algorithms + Data structures = evolution programs**. USA. Springer. 1996. 388p.

MITCHELL, M. **An introduction to Genetic Algorithms**. Bradford. 1996. 158p.

MITSUO, G.; CHENG, R. **Genetic algorithms and engineering optimization**. Wiley. 2000. p.495.

MOORE, C. T.; CONROY, M. J.; BOSTON, K. Forest management decisions for wildlife objectives: system resolution and optimality. **Computers and Electronics in Agriculture**, Netherlands, v.27, n.1, p.25-39, 2000.

MOTA FILHO, F. O. M. **Aplicação de modelos de estimação de fitness em algoritmos genéticos**. Campinas. 2005. 184f. Dissertação de Mestrado. Universidade Estadual de Campinas.

MURPHY, R. **A Generic Parallel Genetic Algorithm**. Dublin. 2003. 68f. Thesis. University of Dublin.

MYERS, R.; HANCOCK, E. R. Empirical modelling of genetic algorithms. **Evolutionary Computation**, United kingdom, v.9, p.461-493, 2001.

PEZESHK, S.; CAMP, C. V. State of the on the use of genetic algorithm in design of steel structures. p.200-250. In: BURNS, S. A. (Ed.) **Recent advances in optimal structural optimization**. ASCE. Reston. 2002. p.312.

PONSICH, A., C. AZZARO-PANTEL, S. DOMENECH, L. PIBOULEAU. Some Guidelines for Genetic Algorithm Implementation in MINLP Batch Plant Design Problems. p.293-316. IN: SIARRY, P.; MICHALEWICZ, Z. (Eds.) **Advances in Metaheuristics for Hard Optimization**. Springer. 2008. p.474.

QUEIROZ, L. M. O. **Algoritmos genéticos híbridos para redução de perdas técnicas em redes primárias de distribuição considerando variações de demandas**. Campinas. 2005. 81f. Dissertação de Mestrado. Universidade Estadual de Campinas.

RAWLINS, G. J. E. **Foundations of genetic algorithm: v1**. Morgan Kaufmann. USA. p.314. 1991.

REZENDE, J. L. P.; OLIVEIRA, A. D. **Análise econômica e social de projetos florestais**. UFV. Viçosa. 2001. 389p.

REEVES, C. R. Genetic Algorithms. p.55-82. In: GLOVER, F.; KOCHENBERGER, G. A. (Eds.) **Handbook of metaheuristics**. Kluwer. 2003. p.557.

RODRIGUES, F. L.; SILVA, G. F.; LEITE, H. G.; XAVIER, A. C.; PEZZOPANE, J. E. M.

Um modelo de regulação florestal e suas implicações na formulação e solução de problemas com restrições de recobrimento. **Revista Árvore**, Viçosa, v.30, n.5, p.769-778, 2006.

RODRIGUES, F. L. **Metaheurísticas e Sistema de Suporte à Decisão para o Planejamento Florestal**. Viçosa. 2001. 225f. Tese de doutorado. Universidade Federal de Viçosa.

SOUZA, D. O. **Algoritmos genéticos aplicados ao planejamento do transporte principal de madeira**. Curitiba. 2004. 169 f. Dissertação de Mestrado. Universidade Federal do Paraná.

SWIECH, M. C. S. **Algoritmos genéticos para sintonia simultânea de múltiplos controladores em processos de refino**. Curitiba. 2004. 127f. Dissertação de Mestrado. Universidade Técnica Federal do Paraná.

TSENOV, A. Simulated Annealing and Genetic Algorithm in Telecommunications Network Planning. **International Journal of Computational Intelligence**. p. 240-245. v. 2, n.4. 2005.

VICTORINO, I. R. S. **Otimização de um reator industrial de produção de álcool cíclico utilizando algoritmos genéticos**. Campinas. 2005. 527f. Tese de Doutorado. Universidade Estadual de Campinas.

VENEMA, H. D.; CALAMAI, P. H.; FIEGUTH, P. Forest structure optimization using evolutionary programming and landscape ecology metrics. **European Journal of Operational Research**, Netherlands, v.164, p.423-439, 2005.

WALL, M. 1996. **GAlib: A C++ Library of Genetic Algorithm Components**. Disponível em: <<http://lancet.mit.edu/ga/dist/galibdoc.pdf>>. Acesso em: 29/8/08.

WILSON, I. D.; JONES, A. J.; JENKINS, D. H.; WARE, J.A. Predicting housing value: genetic algorithm attribute selection and dependence of modeling utilizing the gamma test. p. 243-275. In: BINNER, J.M.; KENDALL, G.; CHEN, S.H. **Applications of artificial intelligence in finance and economics**. p.275. 2004.

CAPÍTULO 3

ESTUDO E MODELAGEM DOS PARÂMETROS PRESENTES NA METAHEURÍSTICA

SIMULATED ANNEALING

RESUMO

ESTUDO E MODELAGEM DOS PARÂMETROS PRESENTES NA METAHEURÍSTICA *SIMULATED ANNEALING*

O uso de metaheurísticas como o caso da *simulated annealing* (SA) contribui para a resolução de problemas complexos. Entretanto, uma configuração inapropriada de seus parâmetros pode prejudicar o processo de busca. Assim, este capítulo teve como objetivo modelar os parâmetros e estratégias de programação da metaheurística SA, através de testes realizados em diferentes configurações propostas, considerando um problema de agendamento da colheita florestal como suporte para os cálculos. Além disso, propôs-se conhecer o potencial de dois procedimentos alternativos (aquecimento e exploração da vizinhança da melhor solução), bem como a combinação entre si na melhoria da solução. Estudar ainda a influência da função de resfriamento e a vizinhança de busca, nos processos de busca executado pela técnica de SA. Desta forma, o problema foi formulado seguindo os preceitos de uma programação linear inteira (PLI), apresentando uma função objetivo (energia) na qual se pretendia maximizar o VPL (valor presente líquido). Os dados econômicos e de crescimento de cada unidade florestal foram obtidos pela VCP - Votorantim Celulose e Papel, sendo uma floresta composta por 52 unidades de manejo e distribuídas entre diferentes clones de eucalipto, na região de Caçapava-SP. Foram testadas duas opções de ativação do aquecimento (Aquecimento1 - 200 iterações e Aquecimento2 - 600 iterações) com um aumento de 0,01% da temperatura inicial do sistema, três configurações de exploração da vizinhança da melhor solução (Busca1 - 20, Busca2 - 30 e Busca3 - 60 iterações), seis combinações possíveis entre estas duas últimas possibilidades, a forma tradicional de programação, além de testar três funções de resfriamento e variações na taxa de vizinhança de busca (10%, 30%, 50%, 70% e 90%). Como resultado, foi observado que o uso das estratégias de aquecimento apresentaram uma alta variação na qualidade das soluções, entretanto, ao considerar apenas as melhores soluções médias, estas foram melhores que o método Tradicional de programação. O Aquecimento 2 foi superior ao Aquecimento 1, considerando este mesmo critério, e indicando que o aquecimento deve ocorrer de forma mais controlada no sistema. As estratégias de aumentar as buscas pela vizinhança das melhores soluções também se mostraram viáveis, dando destaque à opção Busca 3. A maioria das combinações entre as estratégias de aquecimento e exploração da vizinhança da melhor solução apresentaram resultados superiores ao método Tradicional, considerando como referência as melhores soluções médias. O tipo de função de resfriamento interagiu com cada configuração testada, mascarando a existência de tendências de seu comportamento, porém pode-se afirmar que a função 3 foi responsável pela obtenção da melhor média de soluções. A vizinhança de busca pode ser considerada como um dos principais parâmetros a ser modelado na metaheurística SA, onde as melhores soluções foram obtidas a taxas reduzidas de alterações na *string*. Por outro lado, valores elevados desta taxa tornaram as buscas mais aleatórias, prejudicando a convergência da metaheurística SA. A melhor opção foi empregar o uso de 10% de alteração na vizinhança de busca, e a pior a 90%. A melhor configuração encontrada foi o uso da opção Busca 3, função de resfriamento 3 e porcentagem de 10% na taxa de vizinhança de busca, para este tipo de problema abordado. Os processos de otimização que empregam o uso de metaheurísticas, como método de resolução precisam ser estudados detalhadamente antes de sua aplicação nos problemas reais de otimização, para evitar baixas convergências da solução.

Palavras-chave: *Simulated Annealing*, Configuração, Planejamento Florestal, Otimização.

ABSTRACT

STUDY AND MODELING OF THE PARAMETERS IN THE METAHEURISTIC SIMULATED ANNEALING

The use of metaheuristics, as in the case of simulated annealing contributes to the resolution of complex problems. However, an inappropriate configuration of their parameters can harm the search process. Therefore, this chapter had as objective to model the parameters and the programming strategies of the metaheuristic SA, through tests carried out in different proposed configurations, considering the scheduling problem of the forest harvest as support for the calculations. Furthermore it was intended to know the potential of two alternative procedures (heating and neighborhood search best solution), as well as the combination among them in the improvement of the solution. Another objective was also to study the influence of the cooling function and the search neighborhood, in the search processes executed by SA technique. Thus, the problem was formulated following the precepts of an integer linear programming (ILP), presenting an objective function (energy) which intended to maximize NPV (net present value). The economic and growth data of each forest stand were obtained from VCP - Votorantim Celulose and Pulp, a forest being composed of 52 management units distributed among different eucalyptus clones, in the region of Caçapava-SP. Two heating activation options were tested (aquecimento1 - 200 iterations and aquecimento2 - 600 iterations) with an increase of 0.01% of the initial system temperature, three configurations of the neighborhood search best solution (busca1 - 20, busca2 - 30 and busca3 - 60 iterations), six possible combinations between these last two possibilities, traditional SA form, besides testing three cooling functions and variations in the search neighborhood rate (10%, 30%, 50%, 70% and 90%). As a result, it was observed that the use of the heating strategies presented a high variation in the quality of the solutions, however, when just considering the best average solutions, these were better than Traditional SA method. The aquecimento2 was superior to aquecimento1, considering this same criterion, and indicating that the heating should happen in a more controlled way in the system. The strategies of increasing the searches for the neighborhood best solution were also shown viable, giving prominence to the option busca3. Most of the combinations between the heating strategies and neighborhood search best solution presented results superior to the Traditional method, considering as reference, the best average solutions. The type of cooling function interacted with each tested configuration, masking the existence of their behavioral tendencies, however it can be affirmed that the função3 was responsible for the obtaining of the best average of solutions. The search neighborhood can be considered as one of the main parameters to be modeled in SA, where the best solutions were obtained at reduced string alteration rates. On the other hand, high values of this rate made the searches more random, harming the convergence of the metaheuristic SA. The best option was to employ the use of 10% of alteration in the search neighborhood, and the worst at 90%. The best configuration found was the use of the option Search3, cooling function 3 and 10% in the search neighborhood rate, for this type of approached problem. The optimization processes that employ the use of metaheuristics, as a resolution method, need to be studied in detail before their application in the real problems of optimization, to avoid low convergences of the solution.

Keyword: Metaheuristic, Simulated Annealing, Modeling, Optimization.

1. INTRODUÇÃO

O constante desafio de superar objetivos mais complexos promove a revisão de conceitos e técnicas tradicionais de otimização, como por exemplo, a programação linear. Em virtude deste aspecto, comprovado pelas pesquisas, os algoritmos de aproximação tem demonstrado uma série de vantagens em processos de otimização florestal. Geralmente, problemas desta natureza apresentam um grau de dificuldade elevado (*NP-Hard*), em virtude de pertencerem a uma classe de problemas relacionados à otimização combinatória. A análise combinatória foi considerada primordial em muitos ramos da ciência, auxiliando na evolução do conhecimento humano, como no caso da Pesquisa Operacional. Na otimização, suas influências foram notadas, promovendo um melhor manejo econômico e produtivo de diversas variáveis. Neste ponto, contribuiu positivamente aos processos de tomada de decisão, principalmente em problemas considerados de difícil resolução.

A técnica *simulated annealing* (SA), por sua vez, é comumente aplicada na resolução de problemas de otimização florestal, como encontrados nos trabalhos de Bettinger *et al.* (2002), Falcão e Borges (2003), Rodrigues *et al.* (2004), Crowe e Nelson (2005) dentre outros. Esta metaheurística foi desenvolvida no início da década de 80, por um grupo de pesquisadores liderados por Kirkpatrick. Segundo Goldstein e Waterman (1988) e Henderson *et al.* (2003), SA é um algoritmo típico de busca local, que realiza movimentos de busca baseado no algoritmo primário (*greedy*). Além disso, um de seus fundamentos básicos originou-se do algoritmo proposto por Metropolis no ano de 1953, que simula o comportamento de equilíbrio térmico dos sólidos.

O resultado desta brilhante jogada proporcionou a projeção e difusão da metaheurística SA no meio produtivo e científico, a ponto de se tornar uma das técnicas mais utilizadas na década de 80, conforme citado no trabalho de AVELO *et al.* (2004).

Segundo Mahmoud (2007), a idéia fundamental da técnica SA é realizar movimentos através das iterações, rearranjando as moléculas do metal no estado líquido até o resfriamento. Assim, a energia gerada pelas moléculas corresponde à função de custo que deve ser otimizada ao longo das iterações.

Rao (1996) descreve este método como uma técnica de otimização combinatória, ligada a procedimentos randômicos de avaliação de uma função de custo, onde a transição de seleção entre boas soluções e piores é possível. O autor ainda comenta que o método exige um elevado número de avaliações da função de custo, para assim definir a solução. O seu ponto

chave é a capacidade de sair de ótimos locais, bem como a facilidade de implementação.

Goldstein e Waterman (1988) afirmam que a aplicação de um algoritmo para a resolução de um dado problema requer uma série de tomadas de decisão. As estratégias e caminhos adotados pelo usuário podem promover o seu sucesso ou fracasso, a depender prioritariamente destas escolhas feitas. Os componentes existentes na técnica SA envolvem basicamente uma função de resfriamento, temperatura (inicial e final) e a distância de busca na vizinhança da solução. Na literatura são observados diversos trabalhos que os estudam, como em: Rodrigues *et al.* (2004), Öhman e Låmas (2005), Martins e Tsuzuki (2006), dentre outros.

De acordo com MIDDLETON (2004), é importante conhecer como as configurações presentes na metaheurística SA influem no comportamento da energia, ao longo das iterações, considerando ainda suas possíveis relações entre parâmetros. Alguns autores como Zolfaghari e Liang (2002) discutem que reduções lentas de temperatura podem comprometer a eficiência da metaheurística, devido a desperdícios de iterações em pontos mais randômicos dos processos. Desta maneira, o algoritmo deixa de efetuar um refinamento mais detalhado e, como resultado, pode encontrar uma solução pior. A dinâmica destas informações contribuem para a identificação de possíveis falhas do método e/ou dificuldade de adaptação do algoritmo ao problema abordado, mas por outro lado, pode possibilitar o surgimento de melhorias e até mesmo a formação de híbridos.

Segundo Ingber (1993), alguns aspectos podem ser melhorados na metaheurística SA e um deles está ligado ao estágio próximo à temperatura final do processo. O autor considera que se algumas informações importantes forem conhecidas sobre o problema, as chances de melhora da solução encontrada são grandes. Entretanto, a existência de ótimos locais ainda é um ponto chave na eficiência deste algoritmo. Esta região é representada basicamente por um ponto capaz de impedir o surgimento de soluções melhores, prejudicando os processos de refinamento da solução. Desta forma, percebe-se a necessidade de conhecimento da metaheurística SA na aplicação de problemas envolvendo a otimização de recursos florestais, para que suas soluções possam estar próximas do exato.

2. OBJETIVO

O objetivo geral deste capítulo foi modelar os parâmetros e estratégias da metaheurística SA. Neste sentido, o problema teste foi o agendamento da colheita florestal, onde as unidades de manejo devem ser ordenadas seqüencialmente ao longo do horizonte de planejamento para a colheita e assim garantir uma produção volumétrica de madeira à indústria. Além disso, o problema visa maximizar o VPL (Valor Presente líquido) da floresta. Sendo assim, foram inseridos e testados dois procedimentos alternativos e suas combinações na estrutura de programação da técnica SA:

- a) **Aquecimento:** avaliar se o emprego do aquecimento no sistema é capaz de melhorar a solução final, ao permitir a saída de ótimos locais. Neste caso, foram testadas duas opções de ativação do aquecimento: a 200 iterações e a 600 iterações. A temperatura foi elevada ao patamar de 0,01% da temperatura inicial, quando não transcorriam alterações na solução atual;
- b) **Exploração da vizinhança da melhor solução:** verificar se uma busca mais detalhada nas soluções implica em melhores respostas, sendo então testadas três estratégias de exploração desta vizinhança, considerando um intervalo de ação de 20, 30 e 60 iterações;
- c) **Combinação dos dois procedimentos anteriores:** avaliar se a união destes dois procedimentos traz benefícios para a melhora nas buscas, e conseqüentemente o surgimento de soluções diferenciadas;

Paralelamente, e aproveitando a capacidade de simular diferentes tipos de combinações entre os parâmetros do método de SA, foram estabelecidos outros objetivos específicos referentes à função de resfriamento e à vizinhança de busca:

- a) **Função de resfriamento:** conhecer e avaliar o comportamento de três funções de resfriamento, responsáveis pela redução da temperatura do sistema.
- b) **Vizinhança de buscas:** avaliar a vizinhança de busca da solução e estabelecer um limite que melhor maximize a resolução do problema, considerando para isso a simulação de perturbações a 10%, 30%, 50%, 70% e 90% na seqüência da *string*.

3. MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

O estudo foi desenvolvido em 5 fazendas pertencentes à empresa VCP - Votorantim Celulose e Papel, sendo todas localizadas no município de Caçapava-SP. O clima da região é denominado pela classificação de Köppen como Cwa, com verão chuvoso e quente, e inverno seco. A área total efetiva de plantio compreende 1490,7 ha, distribuídos em reflorestamentos com espécies de Eucalipto e algumas variações de clones da empresa. A Figura 23 apresenta a localização da área de estudo.

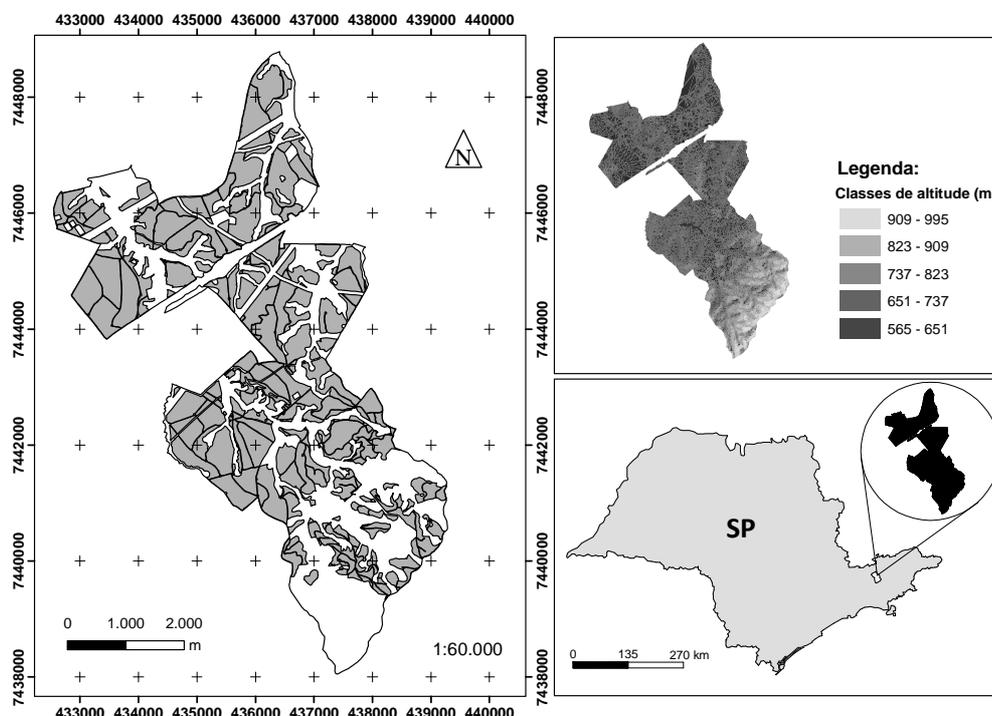


FIGURA 23 - MAPA DA LOCALIZAÇÃO DA ÁREA DE ESTUDO NO ESTADO DE SÃO PAULO.

A floresta designada para o estudo contabilizou uma malha de 52 talhões, contendo uma variação de idades. As projeções de crescimento volumétrico de madeira na floresta foram seguidas segundo dados da própria empresa.

3.2 DESCRIÇÃO DO PROBLEMA COMO BASE EXPERIMENTAL

O problema florestal foi caracterizado com a necessidade de maximizar o valor presente líquido (VPL) da floresta, analogamente ao encontrado em uma série de trabalhos na

literatura, e que tiveram o Modelo tipo I de Johnson e Scheurmann (1977) como referência. Segundo Rezende e Oliveira (2001), o VPL de um projeto de investimento pode ser definido como a soma algébrica dos valores descontados do fluxo de caixa a ele associado, sendo definido pela formulação (1):

$$VPL = \sum_{j=0}^n R_j(1+i)^{-j} - \sum_{j=0}^n C_j(1+i)^{-j} \quad (1)$$

Onde:

j - período de tempo considerado;

C_j - custo final do ano j ou do período de tempo considerado;

C_0 - custo inicial do investimento;

R_j - receita no final do ano j ou do período de tempo considerado;

i - taxa de desconto;

n - duração do projeto ou número de tempo considerado.

O uso do indicador econômico VPL foi aplicado apenas para atualizar as receitas líquidas geradas por cada alternativa de manejo, não sendo aplicado como método de comparação entre alternativas de manejo na sua forma pura de análise.

A idéia do problema seguiu os moldes da programação linear clássica, onde a função objetivo (2) foi dimensionada para maximizar o valor presente líquido (VPL), contando ainda com a inclusão de restrições direcionadas à adoção de apenas uma alternativa de manejo por unidade de talhão (3), outras ligadas ao controle do fluxo de produção volumétrica a partir de um limite mínimo (4) e máximo (5) toleráveis, além das restrições de integridade e não negatividade das variáveis de decisão (6).

$$\text{Função Objetivo: Maximizar } VPL = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} \quad (2)$$

Sujeito a

$$\sum_{j=1}^P x_{ij} = 1, \quad \forall_j, \forall_{i=1,2,\dots,M} \quad (3)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \geq L_{\text{inferior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,7} \quad (4)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \leq L_{\text{superior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,7} \quad (5)$$

$$x_{ij} \in \{0,1\} \quad \forall_i, \forall_j \quad (6)$$

Onde:

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pela alternativa de manejo j ;

Desta maneira, o objetivo numérico do problema foi definir uma produção volumétrica anual estipulada em 84.500 m^3 , com variação constante e tolerável de $\pm 16\%$. Este valor volumétrico anual foi definido considerando os aspectos da produção da floresta, ligados as opções de manejo florestal.

A idade mínima e máxima dos talhões liberados para a colheita florestal foi de 5 e 7 anos, respectivamente, onde o talhão selecionado não poderia ser cortado a uma idade inferior a 5 anos ou superior ao máximo estabelecido. O regime de manejo considerado foi o *pulp wood* destinado a produção de madeira para celulose. Por outro lado, o sistema silvicultural foi o alto fuste, onde ao cortar um talhão na sua totalidade, o mesmo material genético seria plantado na seqüência, a ciclos contínuos. A taxa de juros adotada foi de 10% e o preço de venda da madeira estipulado em R\$70,00/m³. Os demais custos para o cálculo do valor presente líquido (VPL) foram fornecidos pela empresa.

3.3 SIMULATED ANNEALING

A programação da metaheurística SA na sua forma tradicional, conforme proposta por Kirkpatrick *et al.* (1983), envolve basicamente um conjunto reduzido de parâmetros. Resumidamente, existe uma função de resfriamento, definição da vizinhança de busca e da temperatura inicial e final do sistema. Entretanto, existe uma série de outros procedimentos e estratégias empregadas para melhorar este algoritmo, como o aquecimento do sistema (ANAGNOSTOPOULOS *et al.*,2006). Assim, foram testadas diferentes configurações de parâmetros e procedimentos estratégicos.

3.3.1 Codificação da *string*

A *string*, citada no trabalho, é uma seqüência numérica composta por códigos e responsável por carregar as informações do problema no seu estado matemático puro, ou seja, necessita de uma tradução específica (decodificação) para expressar o seu valor no mundo real. Neste caso, adotou-se uma codificação binária {0,1} para popular esta *string*. Este código binário é um código de simples implementação, pois seus valores podem assumir apenas o valor 0 ou 1, de forma restrita. A razão de sua escolha foi em virtude da natureza do problema base, sendo caracterizado por apresentar variáveis de decisão inteira. Desta maneira, a codificação da *string* presente na SA seguiu o esquema apresentado pela Figura 24. O termo *U* representa cada unidade de manejo pertencente à floresta avaliada, onde o mesmo foi subdividido conforme o número de anos de avaliação do projeto (horizonte de planejamento).

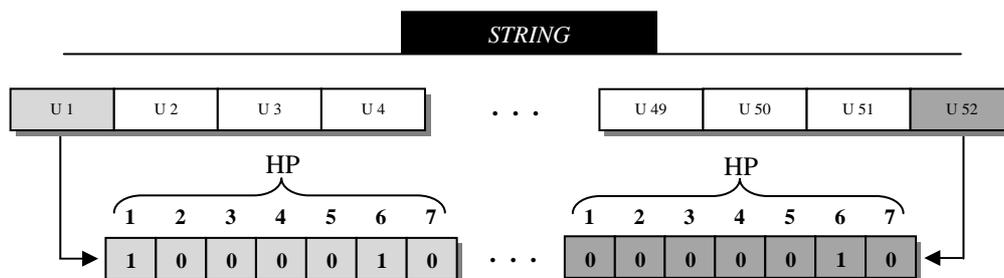


FIGURA 24 - EXEMPLIFICAÇÃO DA CODIFICAÇÃO BINÁRIA UTILIZADA NA *STRING* PERTENCENTE À METAHEURÍSTICA SA.

Assim, a regra para a codificação da *string* contou com a seguinte correlação ao problema florestal: o número de *Us* foi igual ao número de unidades de manejo da área de estudo (52); o horizonte de planejamento foi definido em 7 anos e, por isso, o número de códigos binários foi igual a 364 (7anos x 52unidades). A codificação do código no nível *U* representou uma dada opção de manejo viável, para uma respectiva unidade de manejo.

A estratégia foi popular todos os 364 códigos com variáveis binárias {0,1}, escolhidas de forma randômica, porém com a necessidade de gerar alternativas de manejo viáveis por unidade de manejo. A combinação destes códigos binários retrata a capacidade de cada *U* em ativar uma alternativa de manejo, estabelecido para cada unidade de manejo. Em outras palavras, o valor 1 ativa o corte de uma unidade de manejo a um dado período de tempo (*t*), dentro do horizonte de planejamento definido, e 0 é o contrário, ou o não corte da unidade. Desta maneira, a cada alteração no código proporciona uma alteração na opção de manejo adotado para a unidade, sendo então decodificado para o problema de agendamento de corte. Logo, a alternativa de manejo gera uma prescrição de manejo para uma dada unidade, e estas

atividades representam um conjunto de operações como poda, desbaste, corte raso e outras, que influencia no crescimento da floresta. A característica da alternativa empregada foi definida pela utilidade ou destino final do produto. Neste caso, foi considerado o agendamento da colheita florestal envolvendo apenas como questão técnica a definição do período de corte raso da unidade selecionada.

Entretanto, apesar da simplicidade (corte/não corte), existe um número elevado de alternativas de manejo factíveis para cada unidade de manejo, que depende exclusivamente de suas características como crescimento e idade. Esta última variável foi empregada para definir a restrição de idade mínima (5 anos) e máxima (7 anos) para a colheita florestal, auxiliando na formação de opções viáveis.

3.3.2 Função de avaliação

A função de avaliação (energia) utilizada na metaheurística levou em consideração a introdução de penalidades no modelo. O método de penalidades foi empregado para guiar a SA nas buscas de soluções e contribuir para uma boa convergência da resposta. Segundo Pezeshk e Camp (2002), o resultado da função objetivo penalizada representa de forma quantitativa a extensão da violação da restrição e promove uma medida relativa da qualidade de cada solução mensurada.

A determinação do valor da penalidade foi obtida a partir de testes preliminares, onde o valor de R\$500,00/m³ foi o melhor encontrado, devido aos altos valores financeiros produzidos pela floresta em estudo. A penalidade é aplicada apenas quando o volume obtido não respeita os limites mínimos e máximos estabelecidos. Desta forma, para cada m³ de madeira fora da meta, este valor é multiplicado pela penalidade. Assim, de posse deste resultado, a energia é calculada apenas subtraindo do VPL esta quantia calculada (7).

$$\text{Energia (Maximizar VPL)} = \sum_{i=1}^M \sum_{j=1}^P c_{ij}x_{ij} - \text{penalidade (R\$/m}^3) \sum_{k=1}^T D_k \quad (7)$$

Onde:

Penalidade - R\$/m³ de madeira;

D - Valor absoluto do desvio volumétrico de madeira (m³);

k - período anual dentro do horizonte de planejamento;

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pela alternativa de manejo j ;

Ao contrário do ocorrido no capítulo 2, onde a função de avaliação (*fitness*) não precisou de uma redução na escala, na SA o processo foi necessário para evitar um *overflow* nos cálculos, ou uma inabilidade na realização dos cálculos, em virtude do dimensionamento da capacidade da variável em armazenar dados. A exemplo tem-se uma solução hipotética onde a seqüência da colheita florestal gerou um VPL para a floresta igual a R\$ 8.350.000,00 no horizonte de planejamento de 7 anos. Além disso, a produção volumétrica anual esteve dentro dos limites de produção (mínimo e máximo) exigidos na formulação, e por isso não foi aplicada nenhuma penalidade. Assim, no processo de redução da escala a energia foi dividida por 10.000 (valor fixo nos testes), passando a assumir um valor de 83,5.

3.3.3 Solução inicial

Os procedimentos metaheurísticos pertencentes à classe de algoritmos de refinamento necessitam de uma solução inicial como ponto de partida para se realizarem as buscas no espaço de soluções. Desta forma, foi gerada uma solução inicial randômica e sem se preocupar com a qualidade da solução, observando apenas a viabilidade das alternativas de manejo para cada unidade.

3.3.4 Parâmetros testados

Os parâmetros presentes na técnica de SA apresentam um número reduzido de opções, quando comparados a outros procedimentos. Porém, apesar desta vantagem na sua estruturação, algumas configurações devem ser testadas, como as funções de resfriamento e distância de busca.

3.3.4.1 Função de resfriamento

Na literatura existe uma série de funções utilizadas no direcionamento da redução da temperatura e que apresentam diferentes comportamentos em sua orientação ao longo das iterações. Esta variação influi diretamente na probabilidade de escolha de soluções piores, pelo critério de Metropolis, contribuindo principalmente na saída de ótimos locais. Neste sentido, foram testados três tipos de funções:

$$T_i = T_{i-1} \alpha \quad (\text{Função 1})$$

$$T_i = \frac{T_{i-1}}{(1+\theta)} \quad (\text{Função 2})$$

$$T_i = \frac{(i-1)T_{i-1} + T_0}{i(1+\log(i))} \quad (\text{Função 3})$$

Onde:

- T_i - Temperatura do sistema na iteração i ;
- T_{i-1} - Temperatura do sistema na iteração $i-1$;
- α - Valor da constante (0,999);
- θ - Valor da constante (0,008);
- T_0 - Temperatura inicial do sistema;
- \log - Logaritmo neperiano na base 10;
- i - Iteração atual do processo.

A primeira função testada é conhecida como resfriamento geométrico, sendo talvez a opção mais empregada nos estudos envolvendo SA. O valor de alfa presente nesta função assume valores inferiores a 1, podendo geralmente variar entre 0,90 a 0,99. Entretanto, apesar da literatura sugerir este intervalo, neste presente estudo foi adotado um valor de alfa igual a 0,999. A estratégia adotada foi aplicada para permitir uma redução mais lenta, a qual apresentou melhores resultados em testes preliminares.

A função 2 foi utilizada por Pedamallu e Özdamar (2008) a um teta igual a 0,005, entretanto no estudo adotou-se um valor igual a 0,008 para acelerar o resfriamento a curtas iterações. A Função 3 foi originalmente proposta por Zolfaghari e Liang (2002) e permite um resfriamento acelerado do sistema, no primeiro momento, para depois proporcionar uma redução mais lenta. O Gráfico 16 apresenta o comportamento das três funções de resfriamento testadas.

A definição da temperatura inicial do sistema (T_0) não apresenta uma regra clara na literatura, pois seu valor se restringe a cada problema formulado, em virtude da escala do problema retratado. Assim, no presente estudo seu valor foi fixado em 4.091, de acordo com testes prévios. Já a temperatura final (T_N) foi estabelecida em um ponto próximo de zero, no

qual a redução da temperatura foi relacionada a cada função de resfriamento estudada.

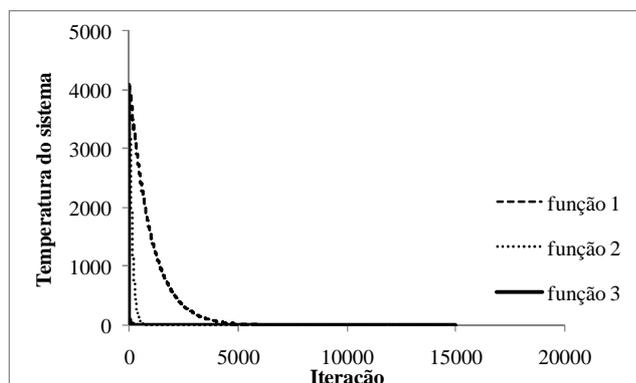


GRÁFICO 16 - RESFRIAMENTO DA TEMPERATURA ATRAVÉS DAS TRÊS FUNÇÕES TESTADAS AO LONGO DAS ITERAÇÕES.

3.3.4.2 Distância de busca local

A distância de busca local, mencionada no trabalho, refere-se ao grau de perturbação na solução pesquisada. Esta perturbação indica quantos *Us* da *string* serão alterados a cada geração, para produzir uma nova solução vizinha. A alteração foi medida em porcentagem do total de *Us*, ou unidades de manejo, sendo testadas as seguintes opções: 10%, 30%, 50%, 70% e 90%, indicando que quanto maior o seu valor, maior o grau de perturbação na solução atual. A definição de quais *Us* seriam alterados foi realizada de forma aleatória, bem como a sua nova codificação binária, devendo apenas gerar opções viáveis.

3.3.5 Processos testados

Os processos testados referem-se às estratégias adotadas no método de SA durante o desenvolvimento de busca da solução, sendo alterações na forma tradicional de programação da mesma. Desta maneira foi testada a forma tradicional desenvolvida por Kirkpatrick; o uso de aquecimentos na temperatura do sistema; explorar a vizinhança de busca e a combinação das duas últimas opções.

3.3.5.1 *Simulated annealing* tradicional

A metaheurística foi programada conforme encontrado no trabalho de Kirkpatrick *et al.* (1983), iniciando com a definição de uma solução gerada randomicamente. Neste

momento, é realizada uma perturbação nesta solução e sua energia é avaliada. O passo seguinte é aceitar ou não esta nova solução, dependendo diretamente do seu valor (energia). Paralelamente, um processo térmico se inicia com uma temperatura inicial superior à temperatura final e, durante as iterações sua temperatura vai reduzindo até atingir um critério de parada. A Figura 25 apresenta um esquema detalhado de seu funcionamento.

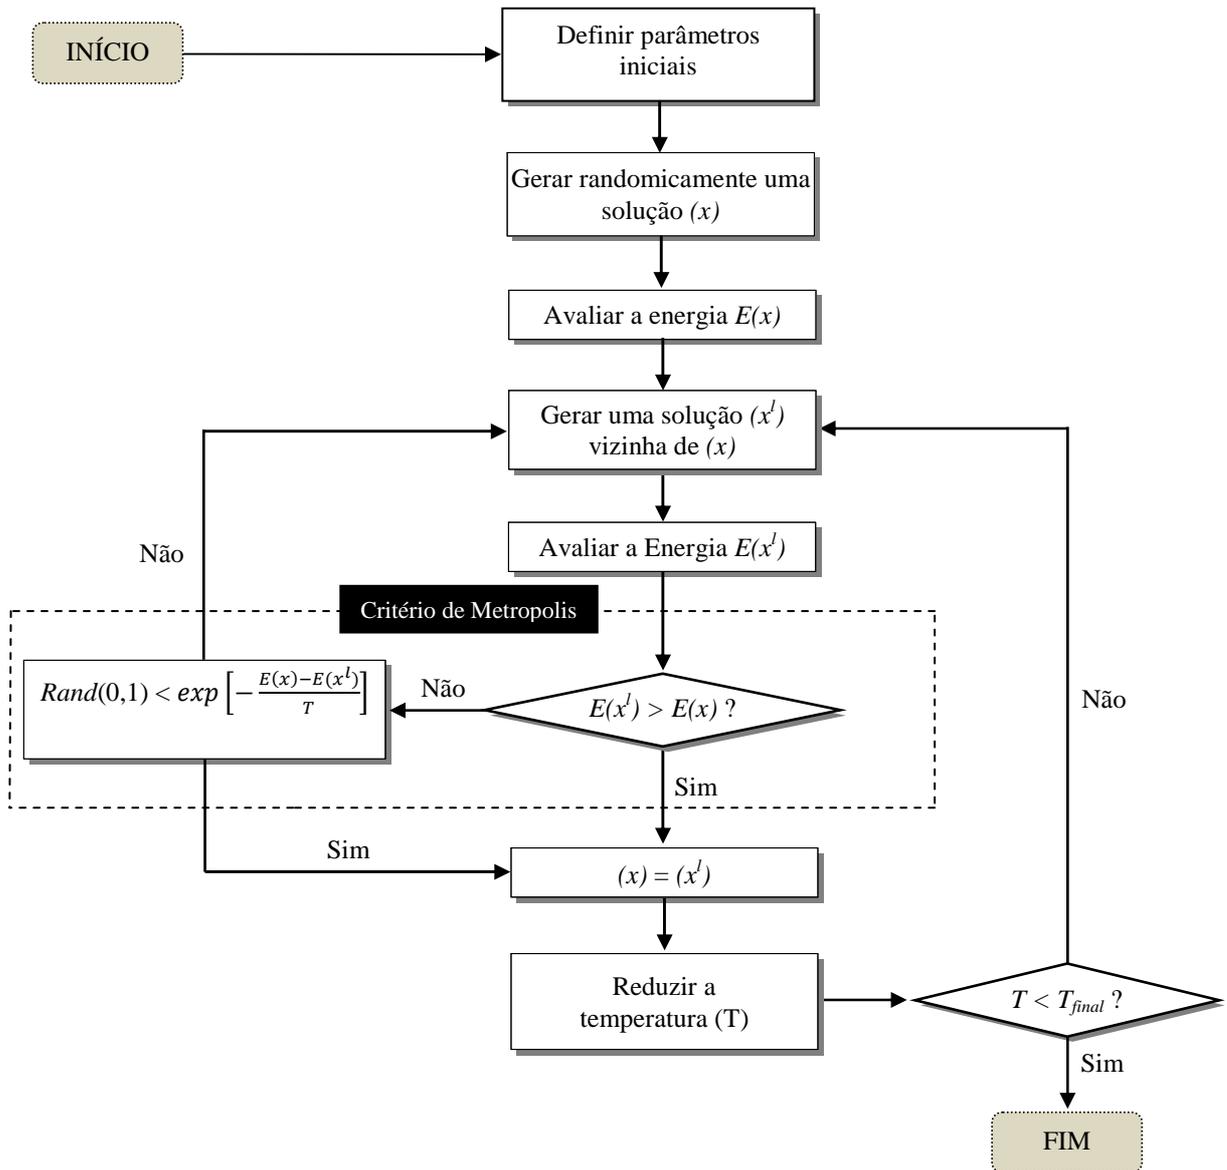


FIGURA 25 - ESTRUTURA DE FUNCIONAMENTO DE BUSCA DA METAHEURÍSTICA *SIMULATED ANNEALING*.

3.3.5.2 Aquecimento

A forma tradicional de programação da SA e elaborada por Kirkpatrick utiliza uma função para simular o resfriamento homogêneo do sistema. Contudo, ainda existe outro

processo térmico controlador da dinâmica da temperatura e que atua no aquecimento do sistema em algumas situações. Segundo Anagnostopoulos *et al.* (2006), a idéia do aquecimento permite o escape de ótimos locais, habilitando o sistema a buscar novas regiões do espaço, já que a temperatura afeta diretamente os cálculos da função de Boltzmann. O seu funcionamento é similar ao descrito no item 3.3.5.1, onde a única diferença é a introdução de um mecanismo de aquecimento do sistema, conforme mostra a Figura 26.

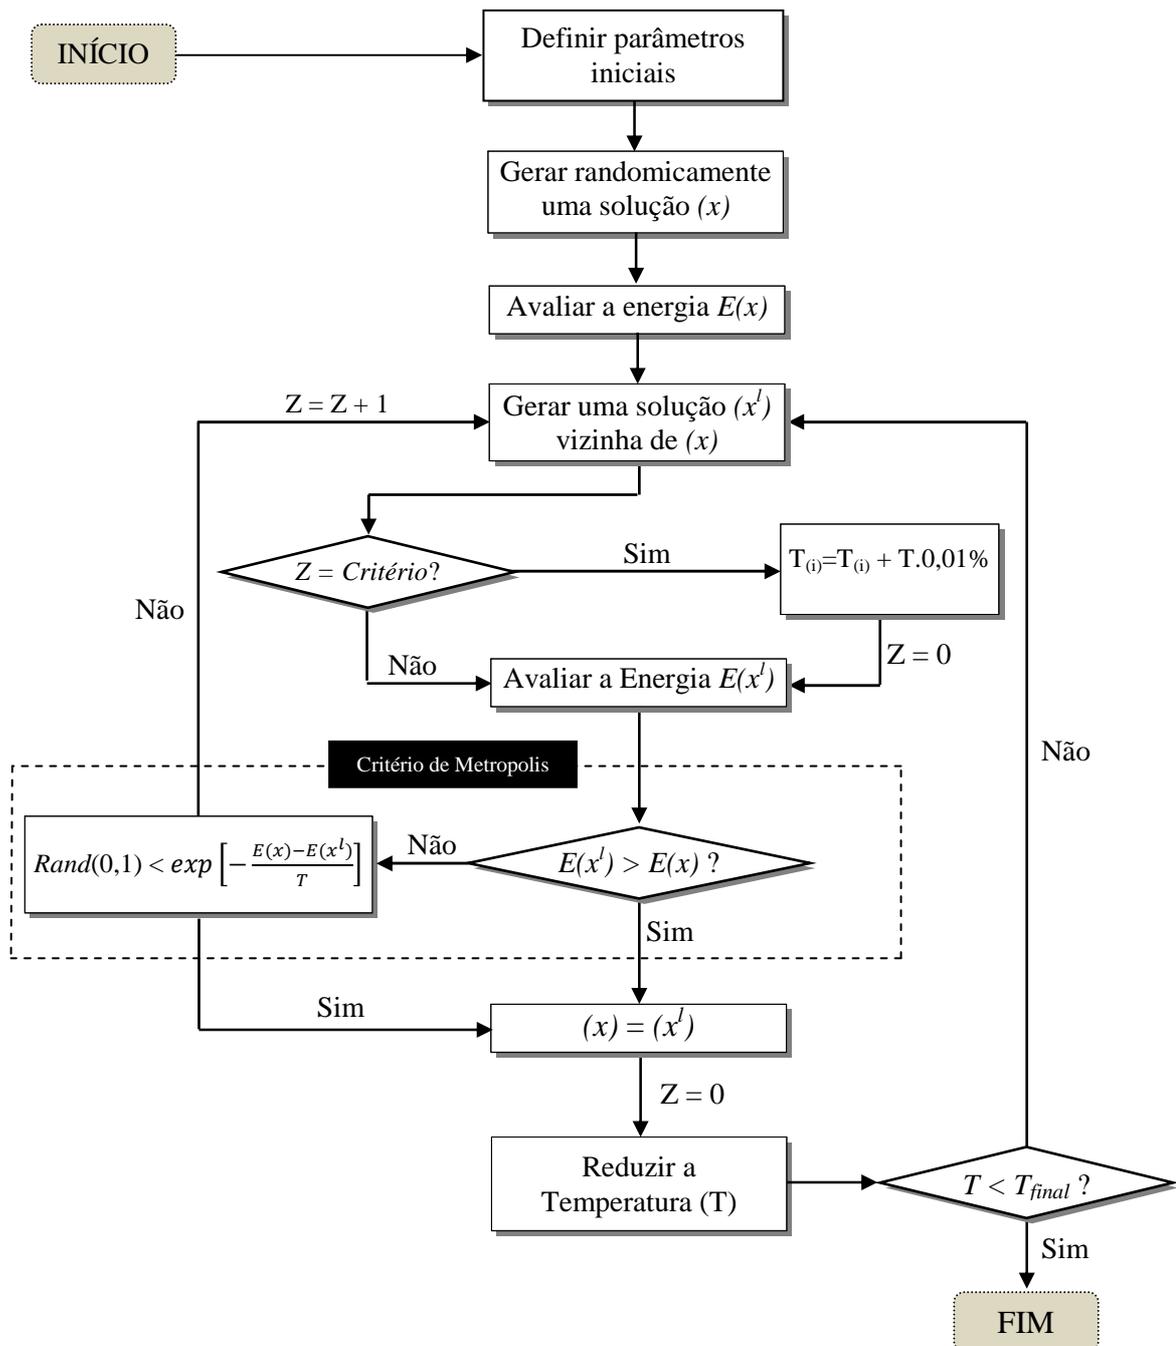


FIGURA 26 - ESTRUTURA DE FUNCIONAMENTO DE BUSCA DA METAHEURÍSTICA *SIMULATED ANNEALING* APLICANDO A ESTRATÉGIA DE AQUECIMENTO.

O aquecimento então foi ativado quando nenhuma solução vizinha foi aceita pela metaheurística SA, tentando assim reduzir a estagnação nas buscas e procuras desnecessárias em novas iterações. Desta forma, o processo de estagnação foi caracterizado pela presença de um ótimo local, que impede o surgimento de soluções aceitas pelo sistema. A estratégia adotada foi considerar a estagnação de duas formas, a 200 iterações (aquecimento 1) e a 600 iterações (aquecimento 2), para então realizar o aquecimento a uma taxa de fixa em 0,01% da temperatura inicial.

3.3.5.3 Explorar a vizinhança de busca

A programação tradicional da metaheurística SA permite que boas soluções sejam substituídas por soluções de qualidade inferior, seguindo o critério do algoritmo de Metropolis, e conseqüentemente seus cálculos de probabilidade. Assim, o método proposto apresenta uma pequena variação frente ao método tradicional descrito no item 3.3.5.1, conforme Figura 27.

Ao aceitar soluções piores, a SA visa a saída de pontos ligados ao ótimo local, o que proporciona um avanço da metaheurística frente a outros algoritmos de busca. Entretanto, este mecanismo pode descartar boas soluções de forma acelerada e, desta maneira, deixar de explorar melhor a sua vizinhança.

A alteração proposta no método tradicional de SA visa explorar mais a vizinhança da solução considerada melhor, encontrada até a iteração i . Este processo exploratório de busca desativa o critério de Metropolis a um número limitado de iterações, impedindo a entrada de soluções inferiores no sistema.

O mecanismo proposto é ativado ($A=1$) sempre que a condição $E(x^l) > E(x)$ for atendida. Após a ativação, a metaheurística passa a um estado *greedy* de buscas limitada por um número de iterações (N). A estratégia adotada foi 20 iterações (busca1), 30 iterações (busca2) e 60 iterações (busca3). Além disso, a redução na temperatura não é desabilitada durante este período de busca, sofrendo reduções de acordo com sua função de resfriamento.

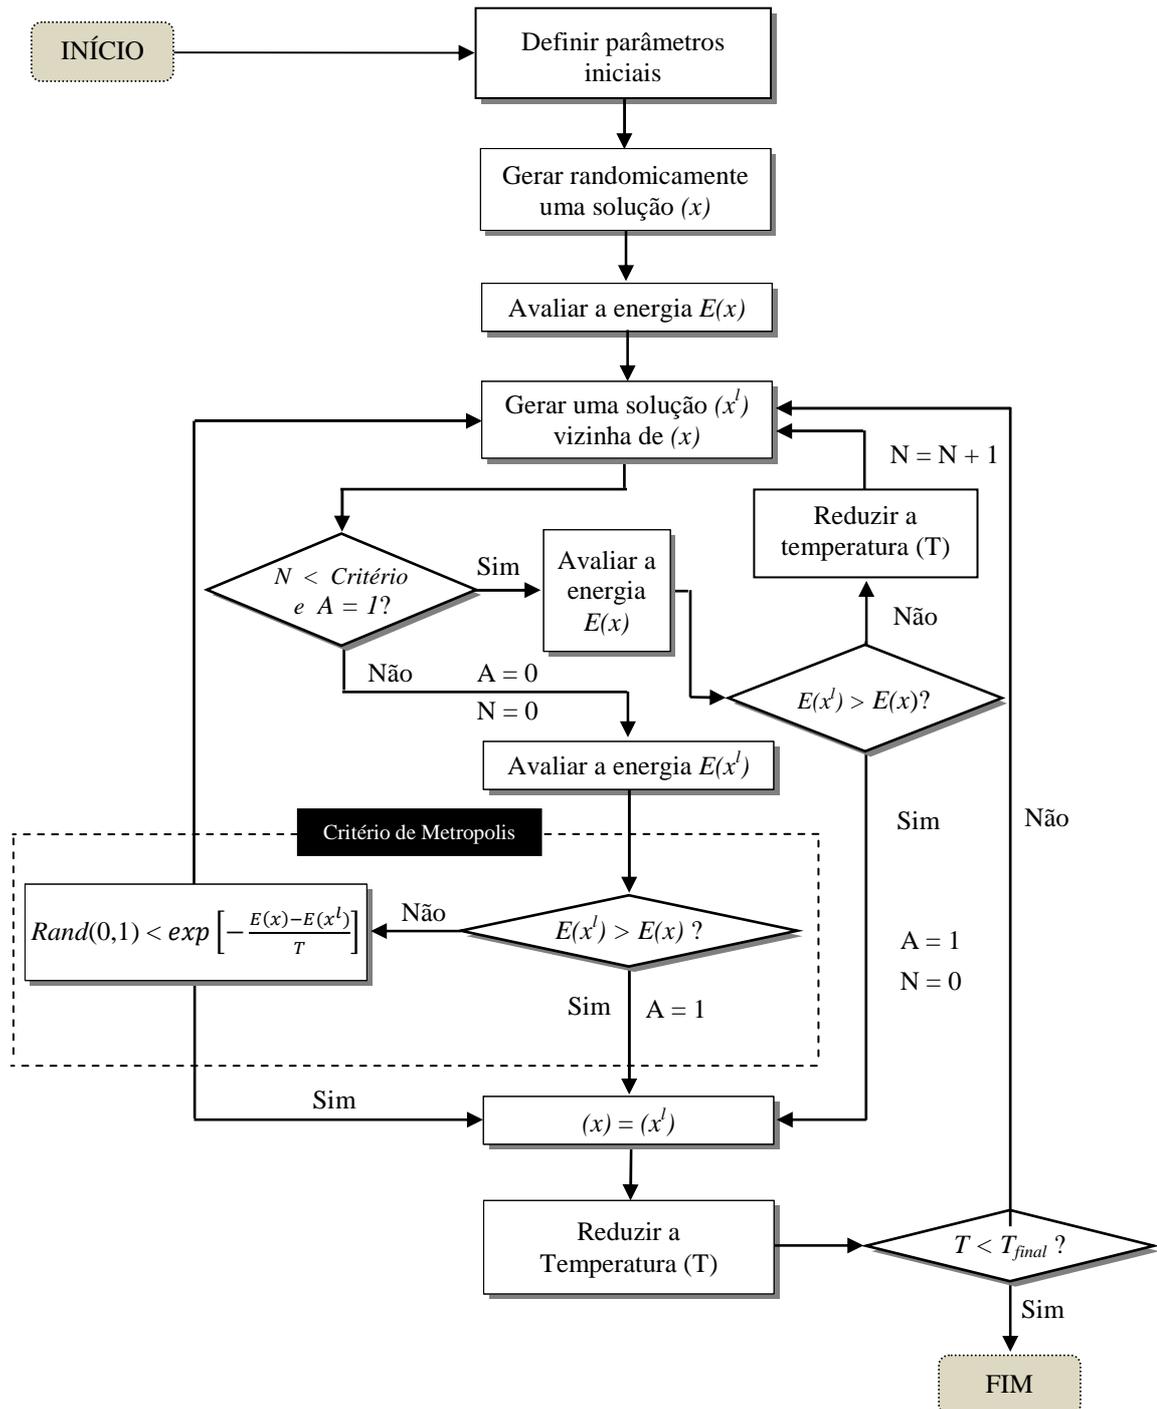


FIGURA 27 - ESTRUTURA DE FUNCIONAMENTO DA METAHEURÍSTICA *SIMULATED ANNEALING* APLICANDO A ESTRATÉGIA DE EXPLORAR MAIS A VIZINHANÇA DE BUSCA DAS MELHORES SOLUÇÕES.

3.3.5.4 Combinação

A combinação entre todos os processos alternativos (aquecimento e explorar a vizinhança de busca) foi determinada para se compreender se existia alguma melhoria nas buscas. Neste ponto foram geradas as seguintes combinações: aquecimento 1 + busca 1, aquecimento 1 + busca 2, aquecimento 1 + busca 3, aquecimento 2 + busca 1, aquecimento 2

+ busca 2 e aquecimento 2 + busca 3. O funcionamento destas combinações seguiu a lógica descrita nos itens 3.3.5.1, 3.3.5.2 e 3.3.5.3.

3.3.6 Critério de Parada

O número de iterações foi o critério adotado para o término do processamento, cujo valor estabelecido foi de 15.000 iterações. Assim, a temperatura final do sistema não ultrapassou o valor abaixo de zero.

3.4 IMPLEMENTAÇÃO COMPUTACIONAL E PROCESSAMENTO

A implementação da metaheurística SA foi desenvolvida utilizando a linguagem de programação *Visual Basic*[®] versão 6.0 *Enterprise* da *Microsoft*[®], licenciada para o PPGEF (Programa de Pós Graduação em Engenharia Florestal) da UFPR.

O *PCFLORESTAL* é uma ferramenta desenvolvida no presente trabalho para otimizar o agendamento da colheita florestal via metaheurísticas (AG e SA), apresentando uma série de saídas gráficas e mapas para a colheita florestal. Além disso, possui diversas opções de AG e SA, conforme mostra a Figura 28.

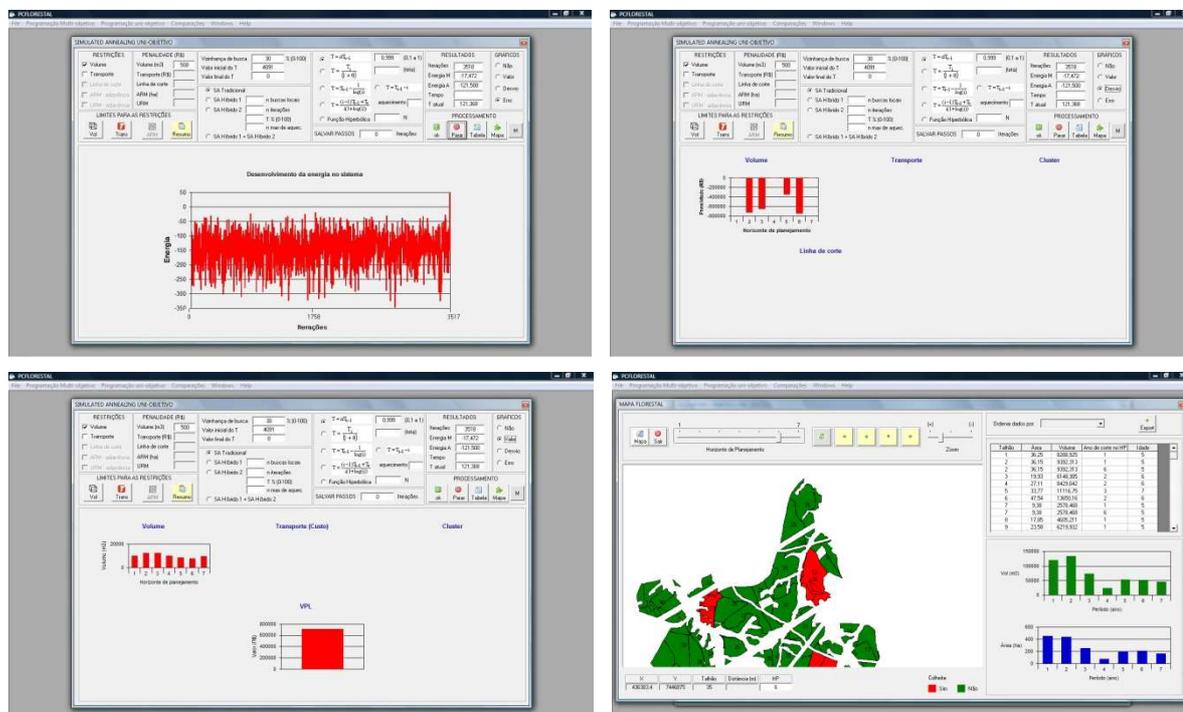


FIGURA 28 - LAYOUT DO PROGRAMA PCFLORESTAL DESENVOLVIDO PARA A REALIZAÇÃO DOS TESTES DIRECIONADOS À METAHEURÍSTICA *SIMULATED ANNEALING*.

Desta maneira, o processamento de todas as opções da metaheurística SA geradas foi através da plataforma do *PCFLORESTAL*, sendo executado em um computador com processador *Celeron*[®] *core 2 duo* 2100 MHz e 2 Gb de RAM.

3.5 ANÁLISE E RESUMO DOS TESTES

Os dados da função de avaliação (energia) e tempo de processamento foram analisados a partir da média aritmética de cada configuração testada, proveniente de 14 repetições, sendo comparadas ao todo 180 configurações da metaheurística SA. O ANEXO 2 apresenta um resumo das opções testadas e analisadas, bem como suas combinações.

4. RESULTADOS E DISCUSSÃO

A modelagem dos parâmetros e as estratégias testadas mostraram uma grande variação de soluções, graças à heterogeneidade de configurações, que muitas vezes exprimiam comportamentos diferentes de buscas. A exemplo tem-se uma diferença de 54,61% entre a melhor e a pior energia média/configuração encontrada, ou em termos absolutos de 84,41 e 38,31, respectivamente.

Estes valores absolutos indicam que quanto maior o seu valor, maior é a qualidade da resposta ao problema abordado, pois o problema envolvia a maximização do VPL. Os resultados demonstram ainda a necessidade de realização dos testes para promover a melhor utilização da metaheurística, tendo em vista que os processos de otimização sempre visam obter a melhor resposta.

A Tabela 8 apresenta as melhores soluções médias (energia) para cada tipo de estratégia adotada na metaheurística SA, onde os dados informam que o método tradicional não foi considerado a melhor estratégia. As melhores, no entanto, foram as que utilizaram algumas estratégias alternativas para fugir dos ótimos locais, destacando busca 3 e aquecimento 2 + busca 1. Entretanto, nem todas estas estratégias foram superiores ao método tradicional, como em: busca2, busca1, aquecimento 2 + busca 3 e aquecimento 2 + busca 2.

TABELA 8 - RESUMO DAS MELHORES SOLUÇÕES MÉDIAS OBTIDAS POR CADA ESTRATÉGIAS DA METAHEURÍSTICA SA APLICADA.

Estratégia	Função de Resfriamento	Vizinhança de busca (%)	Energia		Número de Aquecimento
			Média	CV(%)	
Busca3	3	10	84,41	0,89	-
Aquecimento2 + Busca1	2	10	84,36	0,68	14
Aquecimento2	1	10	84,23	0,96	4
Aquecimento1 + Busca3	3	10	84,08	2,13	59
Aquecimento1	2	10	83,99	2,10	46
Aquecimento1 + Busca2	3	10	83,95	1,08	63
Aquecimento1 + Busca1	2	10	83,87	4,18	37
Tradicional	3	10	83,83	1,84	-
Busca2	1	10	83,67	2,14	-
Busca1	3	10	83,50	2,53	-
Aquecimento2 + Busca3	2	50	82,28	1,80	16
Aquecimento2 + Busca2	1	10	81,69	9,54	3

As estratégias de aquecimento da temperatura do sistema apresentaram resultados variados em relação à melhor solução média obtida. Os resultados mostraram que a opção intitulada de aquecimento2 foi superior ao aquecimento1 em 0,28%, considerando a melhor média de cada opção, indicando que o número de aquecimentos durante o processo exerce real pressão na qualidade das buscas realizadas pela metaheurística. A ação deste efeito aumentou a probabilidade de aceitar piores soluções via o algoritmo de Metropolis, sendo recorrente de acordo com o número de aquecimentos realizados. Desta maneira, o número de aquecimentos executados para estas duas situações foi 4 vezes (aquecimento2) e 46 vezes (aquecimento1). Entretanto, ao variar a vizinhança de busca e o tipo de função de resfriamento, não houve uma tendência de superioridade de uma única opção, apresentando alterações entre as mesmas (Gráfico 17). Contudo, estas estratégias de aquecimento foram superiores à forma tradicional, na grande maioria dos casos.

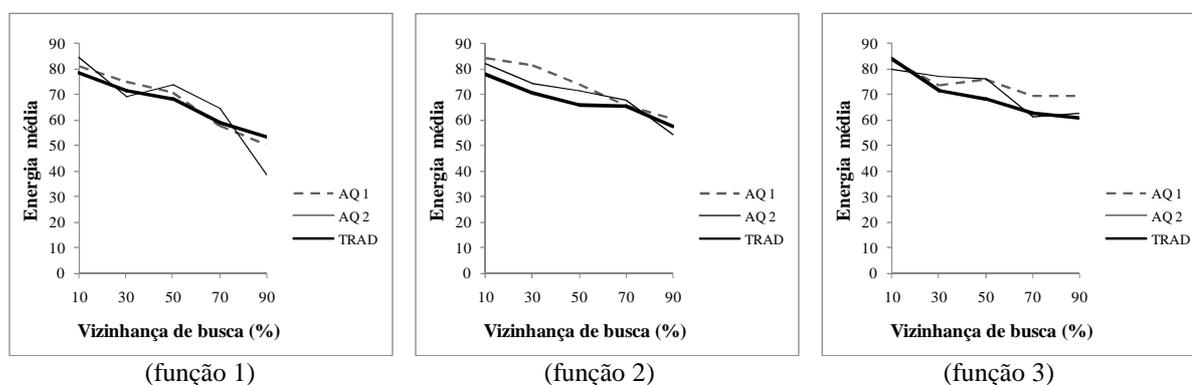


GRÁFICO 17 - INFLUÊNCIA DO AQUECIMENTO NA QUALIDADE DA ENERGIA MÉDIA DO SISTEMA (AQ1 - AQUECIMENTO1; AQ2 - AQUECIMENTO2 E TRAD - TRADICIONAL).

Assim, ao considerar apenas as melhores soluções médias, a diferença foi 0,47%

(aquecimento2) e 0,19% (aquecimento1) para o método tradicional em relação à energia. A função1 de resfriamento, conhecida como função de redução geométrica de temperatura, foi utilizada por Abramson *et al.* (1999) a um alfa de 0,9, sendo empregadas ainda 6 diferentes estratégias de SA e 4 opções de aquecimento. Os testes utilizaram o problema de horário escolar (*timetabling problem*), cujo objetivo é adequar o horário dos professores e estudantes a partir de determinadas restrições. Os seus resultados mostraram que o uso do aquecimento foi superior em todas as opções testadas. O mesmo resultado foi observado no presente estudo, ao analisar apenas a função1 e as duas estratégias de aquecimento testadas.

A estratégia de explorar mais a vizinhança das melhores soluções, ao longo do processamento da metaheurística, também apresentou resultados positivos ao se comparar com o método tradicional (Gráfico 18). Na maioria dos casos analisados, esta estratégia apresentou uma superioridade na solução média, frente ao método tradicional, e independente do tipo de função de resfriamento ou taxa percentual de alterações na vizinhança de busca. O método atua basicamente no início do processo, permitindo explorar mais a vizinhança das melhores soluções obtidas, já que a baixas temperaturas o seu funcionamento se aproxima do método tradicional, o que passa a realizar esta ação de refinamento da solução. Pode-se dizer que o método atuou apenas em temperaturas elevadas, onde a probabilidade de trocas das soluções é considerada alta.

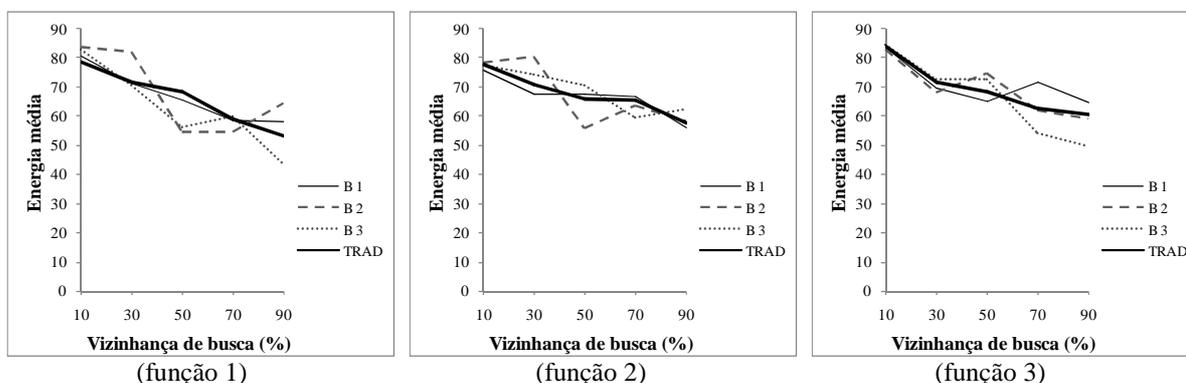


GRÁFICO 18 - COMPARAÇÃO ENTRE AS ESTRATÉGIAS DE EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).

O número de soluções vizinhas exploradas, ativado sempre a cada melhora da solução ao longo das iterações, apresentou um comportamento crescente de melhora da resposta final. Assim, ao aumentar este número de 20 iterações (busca1) para 60 iterações (busca3), a melhora foi de 1,08% considerando apenas a média das melhores respostas. Porém, se analisarmos o conjunto de opções empregando estas estratégias, não há uma tendência de uma

única melhor opção, devido às interações existentes entre as variáveis do sistema. Se observarmos que o método tradicional apresenta trocas rápidas de soluções, no início do processo, e não explora bem a vizinhança destas soluções candidatas, este deixa de ter uma melhora de 0,68% em média frente a opção busca3, considerando as melhores soluções médias obtidas. Por outro lado, as melhores soluções médias obtidas pelas opções busca1 e busca2 não foram superiores a melhor média do método tradicional de programação da metaheurística SA.

A combinação entre as estratégias de aquecimento1 e explorar mais a vizinhança das melhores soluções demonstraram que bons resultados podem ser encontrados quando comparados com o método tradicional (Gráfico 19). A melhora percentual na média das melhores soluções foi de 0,05% (aquecimento1+busca1), 0,14% (aquecimento1+busca2) e 0,30% (aquecimento1+busca3), sendo mais evidente no emprego da função2 de resfriamento.

Assim, não foi possível observar uma tendência superior de uma única opção devido às constantes alterações na curva de energia média do sistema. Porém, a combinação aquecimento1+busca2 foi a opção que mais dominou o conjunto das respostas, considerando os três tipos de função de resfriamento e as alterações percentuais na vizinhança de busca. Entretanto, a melhor resposta considerando as combinações foi obtida entre aquecimento1+busca3, confirmando a vantagem da busca3 frente às outras opções de sua classe.

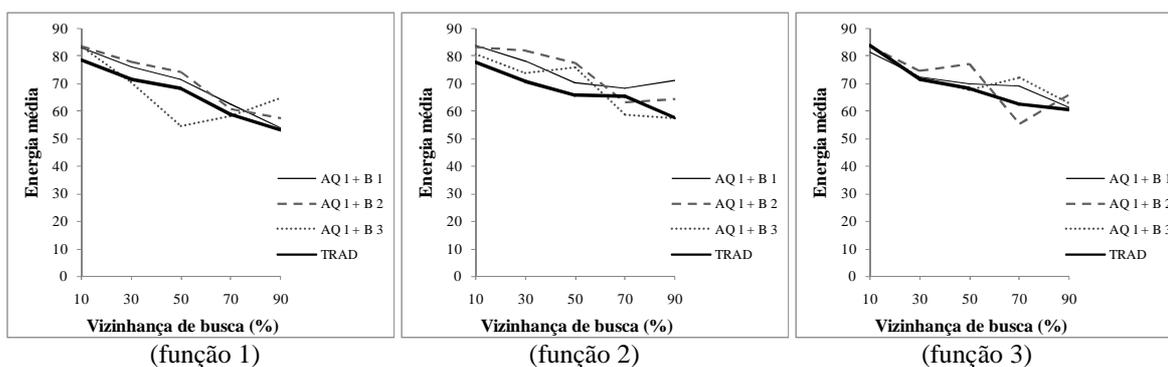


GRÁFICO 19 - COMPARAÇÃO ENTRE AS COMBINAÇÕES ESTRATÉGICAS AQUECIMENTO1 + EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METEHEURÍSTICA SA (AQ1-AQUECIMENTO1; B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).

As combinações aquecimento1+busca1 e aquecimento1+busca2 apresentaram uma melhora em suas soluções médias de 0,44% e 0,33% respectivamente, quando utilizadas apenas a estratégia busca1 e busca2 na sua forma pura, considerando como referência a

melhor solução média obtida. Porém, a introdução destas 2 opções prejudicou a estratégia de aquecimento1 em 0,04% (busca2) e 0,14% (busca1). Entretanto, a combinação entre aquecimento1+busca3 promoveu uma melhora de 0,11% na melhor solução média, quando aplicado apenas o aquecimento1. A estratégia busca3, por sua vez, apresentou uma queda de 0,39% na sua melhor solução média, quando combinada com a estratégia aquecimento1.

O uso da combinação entre aquecimento2 e explorar mais a vizinhança das melhores soluções mostrou que resultados superiores ao método tradicional podem ser obtidos. Todavia, ao considerar a melhor solução média obtida por cada opção, percebeu-se que o método tradicional foi superior ao aquecimento2+busca2 e aquecimento2+busca3, em 2,55% e 1,85% respectivamente, perdendo apenas para aquecimento2+busca1 em 0,63%. O aquecimento2+busca1 foi a opção com a melhor média, considerando as opções de combinação. O Gráfico 20 apresenta o comportamento da combinação entre as estratégias citadas.

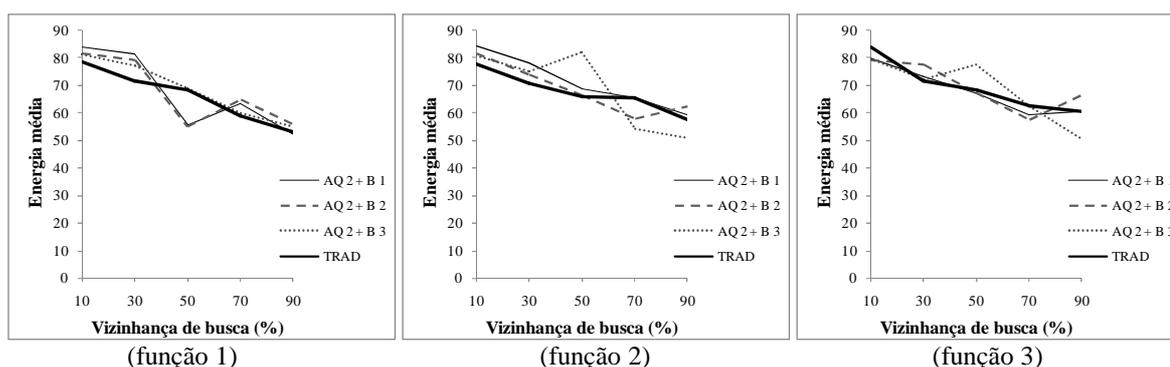


GRÁFICO 20 - COMPARAÇÃO ENTRE AS COMBINAÇÕES ESTRATÉGICAS AQUECIMENTO2 + EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (AQ1-AQUECIMENTO1; B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).

Analisando a variação na taxa de aquecimento entre as combinações, observa-se que a melhor opção adotada para cada estratégia de aquecimento foi aquecimento1+busca3 e aquecimento2+busca1 (Gráfico 21). Neste ponto, nota-se que, ao aumentar a possibilidade de aquecimentos (aquecimento1), a melhor combinação foi também aumentar a vizinhança de busca da melhor solução (busca3), o que desempenhou uma melhor estratégia de escape de ótimos locais para as combinações. Contudo, ao reduzir a possibilidade de aquecimento (aquecimento2), a melhor opção foi reduzir vizinhança de busca da melhor solução (busca1). O antagonismo de reações mostra que existe uma grande interação entre as opções, repercutindo diretamente na combinação das mesmas.

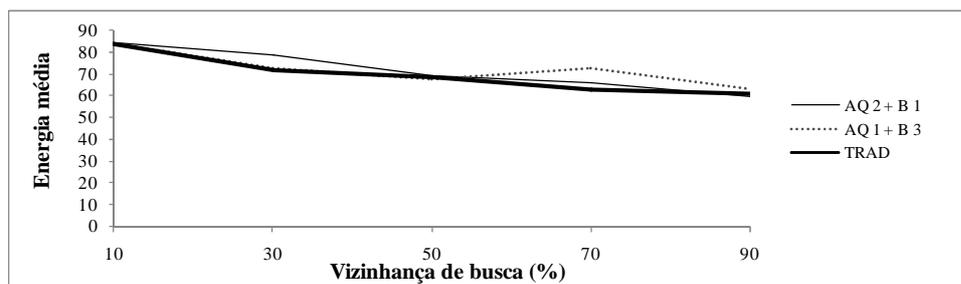


GRÁFICO 21 - COMPARAÇÃO ENTRE AS MELHORES OPÇÕES SELECIONADAS DA COMBINAÇÃO ENTRE AQUECIMENTO + EXPLORAR MAIS A VIZINHANÇA DAS MELHORES SOLUÇÕES FRENTE AO MÉTODO TRADICIONAL DE PROGRAMAÇÃO DA METAHEURÍSTICA SA (AQ1- AQUECIMENTO1; AQ2- AQUECIMENTO2; B1 - BUSCA1; B2 - BUSCA2; B3 - BUSCA3 E TRAD - TRADICIONAL).

As funções de resfriamento passaram a interagir com as diferentes estratégias da metaheurística SA, e apresentaram um comportamento muito parecido, devido aos diferentes mecanismos de escape de ótimos locais. A partir deste ponto, notou-se que para cada tipo de estratégia uma dada função se modelava melhor. Neste sentido, a função de resfriamento não foi o principal parâmetro a ser modelado. A Tabela 9 comprova o exposto, além de mostrar uma reduzida diferença entre as melhores energias médias do processo, por função de resfriamento.

TABELA 9 - TIPO DE FUNÇÃO DE RESFRIAMENTO E SUAS MELHORES MÉDIAS DE ENERGIA OBTIDA.

Estratégia	Função de Resfriamento	Vizinhança de busca (%)	Energia		Número de Aquecimento
			Média	CV(%)	
Busca 3	3	10	84,41	0,89	-
Aquecimento 2 + Busca 1	2	10	84,36	0,68	14
Aquecimento 2	1	10	84,23	0,96	4

Assim, a função 3 foi definida como a melhor estratégia de redução de temperatura, seguida das funções 2 e 1, onde o desvio percentual de energia entre elas foi de 0,06% (função 2) e 0,21% (função 1) em relação à melhor solução média. Uma possível explicação a este fato deve-se ao seu comportamento expresso na curva de redução de temperatura, o qual promove uma redução acelerada no início e lentas reduções na parte final das iterações. Esta hipótese é comprovada, pois o grau acentuado de redução de temperatura é também observado na função 2, porém em menor escala. Uma alternativa para a melhoria das funções 1 e 2 seria redefinir os valores de α e θ ou mesmo aumentar o número de iterações para as buscas. Neste sentido, utilizando a função 3, a SA apresentou uma melhor convergência, a depender ainda do tipo de estratégia empregada na metaheurística SA. O Gráfico 22 ilustra um exemplo das diferenças entre as funções de resfriamento utilizadas neste estudo.

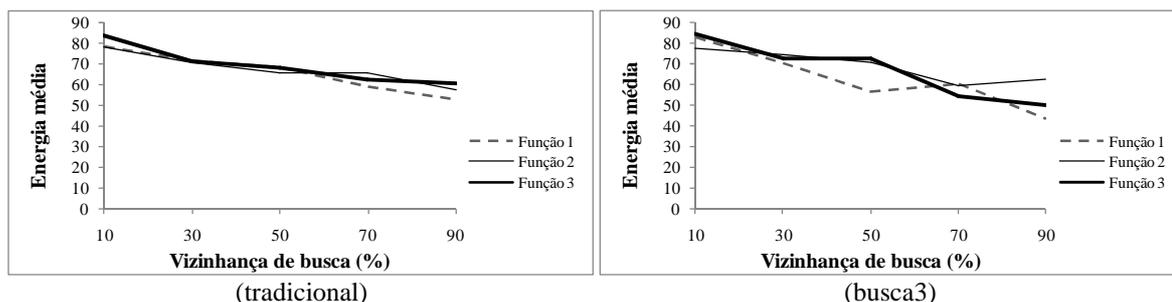


GRÁFICO 22 - INFLUÊNCIA DAS FUNÇÕES DE RESFRIAMENTO NA QUALIDADE DAS SOLUÇÕES GERADAS PELA METAHEURÍSTICA SA.

Rodrigues (2001) realizou um estudo para modelar os parâmetros da metaheurística SA em um problema florestal, onde suas estratégias de redução de temperatura consideravam apenas os valores 0,5%, 1% e 5% de redução por iteração. Assim, o autor percebeu que reduções mais aceleradas de temperatura contribuíam para a melhor eficácia da metaheurística, além de não encontrar diferenças significativas entre as opções 0,5% e 1%.

O parâmetro definido como vizinhança de busca pode ser considerado como um dos principais agentes responsáveis pela qualidade da solução final, pois define a distância a ser explorada nas vizinhanças da solução. Um fato que comprova esta afirmativa foi a variação de soluções encontradas, onde a simples mudança percentual nesta taxa promoveu impactos na forma de busca da metaheurística SA (Gráfico 23). Assim, uma configuração de 90% na vizinhança de busca resultou em soluções inferiores, devido ao maior uso de processos aleatórios nas buscas. Por outro lado, taxas mais conservadoras deste parâmetro culminaram em melhores respostas, devido ao fato de trabalharem a busca em locais mais próximos da solução. Neste sentido, o tipo de função e estratégia adotada na metaheurística SA não foi capaz de alterar esta tendência, de uma forma geral.

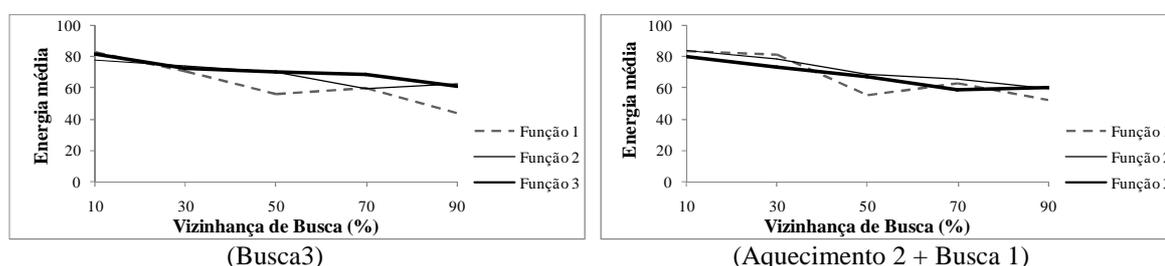


GRÁFICO 23 - INFLUÊNCIA DA VIZINHANÇA DE BUSCA NO VALOR DA ENERGIA MÉDIA PRODUZIDA PELA METAHEURÍSTICA SA.

Segundo Goldstein e Waterman (1988), se a escolha da vizinhança de busca for muito pequena, o algoritmo não será capaz de mover-se de forma eficiente no espaço S de soluções, e o contrário promove processos mais aleatórios que afetam da mesma maneira a qualidade da solução final. Os autores comprovaram esta regra a partir do problema do caixeiro viajante

(*Travelling Salesman Problem*), atribuindo diferentes opções de valores para a vizinhança de busca. A mesma importância da vizinhança de busca foi relatada no trabalho de Ribas (2003), no qual o autor também concluiu que valores mais reduzidos na vizinhança de busca promove a formação de melhores soluções.

A exemplo tem-se a configuração formada pela busca3 e função3 de resfriamento que, ao assumir uma taxa de vizinhança de busca igual a 10%, a sua energia média chegou à máxima expressão encontrada no estudo (84,41), e que após o seu aumento para 30%, 50%, 70% e 90% seu valor sofreu reduções percentuais de: 13,85%, 13,88%, 35,75% e 41,01%, respectivamente na energia média. O Gráfico 24 ilustra outros exemplos ocorridos deste efeito e que mostram esta tendência.

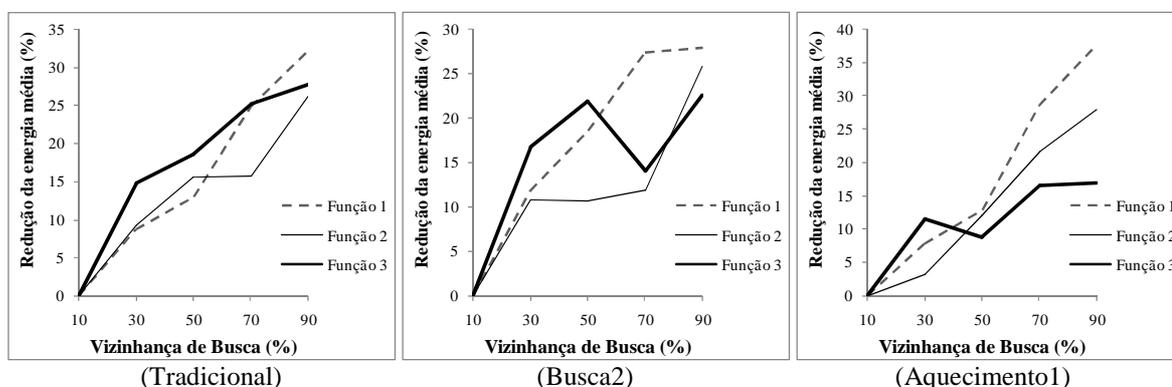


GRÁFICO 24 - INFLUÊNCIA DAS TAXAS DE VIZINHANÇA DE BUSCA NA REDUÇÃO PERCENTUAL DA ENERGIA MÉDIA OBTIDA PELA METAHEURÍSTICA SA.

O tempo de processamento, ao contrário do ocorrido anteriormente, mostrou que, ao aumentar a taxa de vizinhança de busca este efeito promoveu um aumento no tempo de processamento da metaheurística SA (Gráfico 25).

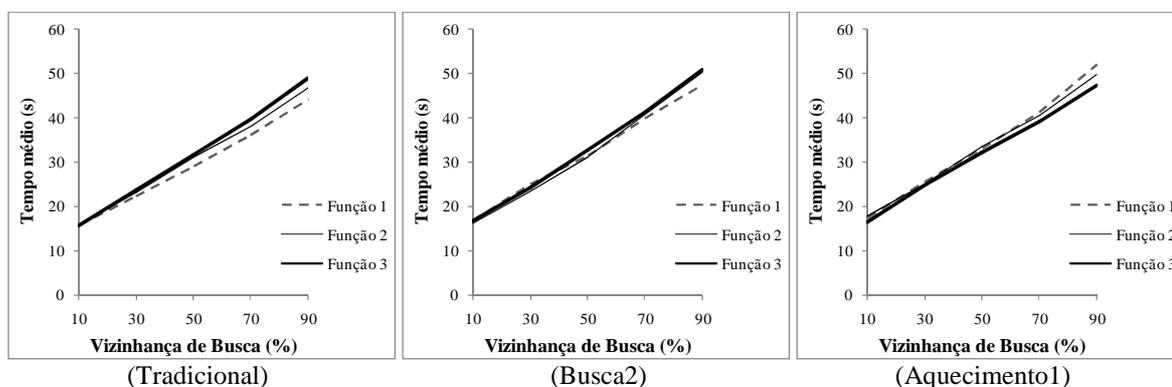


GRÁFICO 25 - EFEITO DA VARIAÇÃO NA TAXA DE VIZINHANÇA DE BUSCA EM RELAÇÃO AO TEMPO DE PROCESSAMENTO NA METAHEURÍSTICA SA.

O resultado confirmou algo já esperado pois, ao aumentar o valor percentual da taxa de vizinhança de busca, o número de alterações realizadas na *string* aumenta, e assim promove um consumo maior de tempo computacional. A alteração na *string* significa a criação de novas alternativas de manejo para substituir as opções atuais nos pontos (*U*) escolhidos randomicamente e, caso aumente o número de alterações, o seu efeito no tempo de processamento aumenta.

As estratégias adotadas como o aquecimento e exploração da vizinhança das melhores soluções não afetaram o tempo de processamento da metaheurística SA, e as diferenças existentes estão relacionadas aos processos de aleatorização implementados na rotina do algoritmo. O mesmo pode-se dizer para o uso de diferentes funções de resfriamento, que graficamente apresentaram a mesma tendência. O único ponto que foi impactante no tempo de processamento foi a variação na taxa de vizinhança de busca, conforme comentado.

A taxa de vizinhança de busca foi a maior responsável pela variação média das soluções, conforme disposto no Gráfico 26. O comportamento desta variação apresentou uma tendência crescente, afetando o coeficiente de variação médio com o aumento dos valores percentuais desta taxa.

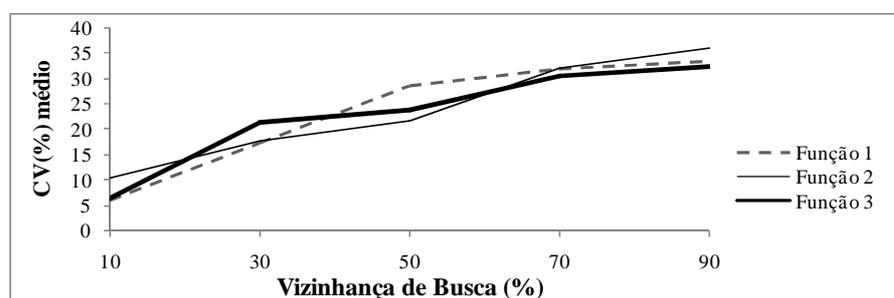


GRÁFICO 26 - EFEITO DA VIZINHANÇA DE BUSCA NA VARIAÇÃO MÉDIA DAS SOLUÇÕES OBTIDAS PELAS METAHEURÍSTICA SA.

A metaheurística SA tem como princípio um processo randomizado de busca e por isso pode impedir o bom refinamento das soluções encontradas, mesmo considerando o critério de Metropolis como regulador da seleção de soluções. Assim, durante os processos de busca o método pode ser atraída por ótimos locais de baixa qualidade, a depender basicamente da complexidade do problema retratado, como foi o caso. Desta forma, pode surgir ainda uma maior variação de soluções, em virtude destes pontos distribuídos no espaço de busca. Contudo, ao considerar taxas reduzidas de vizinhança de busca, seu efeito foi o oposto, promovendo uma melhor busca pela vizinhança das soluções e, conseqüentemente, uma melhor convergência das mesmas. Assim, a capacidade da metaheurística SA em produzir soluções com baixa variação dependeu diretamente destes aspectos. O critério de parada pode

ter influenciado também na convergência da solução, principalmente em estratégias consideradas mais aleatórias de busca, já que apresentaram um alto coeficiente de variação. Segundo McEachin (1994), a variação no critério de parada influencia diretamente o processo de otimização das metaheurísticas e heurísticas.

O tipo de estratégia empregada na metaheurística SA também apresentou impactos na variação das soluções, porém não foi observada uma tendência clara como ocorrido na taxa de vizinhança de busca. O mesmo pode-se dizer para os tipos de função de resfriamento empregada. A melhor solução média encontrada apresentou um coeficiente de variação de apenas 0,89%, demonstrando que a configuração busca3, além de produzir boas soluções, também conseguiu estabilizar a convergência das soluções em valores mais próximos.

5. CONCLUSÃO

- Os processos de otimização que utilizam a metaheurística SA como método de resolução precisam ser estudados detalhadamente, antes de sua aplicação. A advertência neste ponto consiste em virtude da variação de resultados encontrados, já que foram influenciados pelas estratégias e parâmetros empregados. Por outro lado, estruturas híbridas ou modificações no funcionamento do método devem ser vistas sempre com bons olhos, já que boas soluções foram alcançadas;
- A estratégia de aquecimento da temperatura do sistema a 0,01% da temperatura inicial provoca uma maior variação no valor das soluções. Entretanto, suas soluções médias são superiores ao método tradicional, em alguns casos;
- A ativação do aquecimento deve ser realizada de forma mais controlada, já que as melhores médias são obtidas ao ativar o aquecimento a 600 iterações de estagnação de solução (aquecimento 2), sendo superior a 200 iterações (aquecimento 1);
- A estratégia de aumentar as buscas pela vizinhança das melhores soluções também apresenta variações na qualidade das soluções. O emprego de uma busca mais ampla nesta vizinhança igual a 60 iterações (busca3) é conveniente. As opções busca1 (20 iterações) e busca2 (30 iterações) são inferiores ao método tradicional, ao considerar apenas as melhores soluções médias;
- A maioria das combinações entre as estratégias de aquecimento e exploração da vizinhança da melhor solução apresentam resultados superiores ao método tradicional, considerando como referência as melhores soluções médias. As melhores combinações são: aquecimento2+busca1 (aquecimento a 600 iterações de estagnação e ampliar as buscas em 20 iterações ao encontrar melhores soluções), aquecimento1+busca3 (aquecimento a 200 iterações de estagnação e ampliar as buscas em 60 iterações ao encontrar melhores soluções), aquecimento1+busca2 (aquecimento a 200 iterações de estagnação e ampliar as buscas em 30 iterações ao encontrar melhores soluções) e aquecimento1+busca1 (aquecimento a 200 iterações de estagnação e ampliar as buscas em 20 iterações ao encontrar melhores soluções). No lado oposto, as piores combinações foram aquecimento2+busca3 e aquecimento2+busca2, que apresentaram valores

inferiores ao método tradicional, pelo critério de comparação via as melhores soluções médias;

- O tipo de função de resfriamento interage com cada configuração testada (aquecimento1, aquecimento2, busca1, busca3, busca3, tradicional, aquecimento1+busca1, aquecimento1+busca2, aquecimento1+busca3, aquecimento2+busca1, aquecimento2+busca2 e aquecimento2+busca3) mascarando a existência de tendências de seu comportamento e assim apresentam valores muito próximos em várias situações. Entretanto, pode-se afirmar que a função3 foi responsável pela obtenção da melhor média de soluções;
- A vizinhança de busca pode ser considerada como um dos principais parâmetros a ser modelado na metaheurística SA, onde as melhores soluções são obtidas a taxas reduzidas de alterações na *string*. Por outro lado, valores elevados desta taxa acentuam a randomização nos processos de busca, prejudicando a convergência da SA. A melhor opção é empregar o uso de 10% na vizinhança de busca;
- A melhor configuração encontrada é o uso da opção busca3, ou seja, ampliar as buscas sobre a vizinhança das melhores soluções encontradas em 60 iterações, função3 de resfriamento e porcentagem de 10% na taxa de vizinhança de busca, para este tipo de problema abordado.

6. REFERÊNCIA BIBLIOGRÁFICA

ABRAMSON, D.; KRISHNAMOORTHY, M.; DANG, H. Simulated Annealing Cooling Schedules for the School Timetabling Problem. p.1-17. Asia, **Pacific Journal of Operational Research**. v.16, n.1, p.1-17, 1999.

ANAGNOSTOPOULOS, A.; MICHEL, L.; HENTENRYCK, P. V.; VERGADOS, Y. A Simulated Annealing Approach to the Traveling Tournament Problem. **Journal of Scheduling**, Netherlands, v. 9, n.2, p. 177-193, 2006.

AVELLO, E.A.; BAESLER, F. F.; MORAGA, R. J. A meta-heuristic based on simulated annealing for solving multiple-objective problems in simulation optimization.. **In: Proceedings of the 2004 Winter Simulation Conference**. 2004. p.508-513.

BETTINGER, P.; GRAETZ, D.; BOSTON, K.; SESSIONS, J.; CHUNG, W. Eight heuristic planning techniques applied to three increasingly difficult wildlife planning problems. **Silva Fennica**, Finland, v.36, n.2, p. 561-584, 2002.

CROWE, K. A.; NELSON, J. D. An evaluation of the simulated annealing algorithm for solving the area-restricted harvest-scheduling model against optimal benchmarks. **Canadian Journal of Forest Research**, Canada, v.35, n.10, p.2500-2509, 2005.

FALCÃO, A. O.; BORGES, J. G. Heurísticas para a integração de níveis estratégico e operacional da gestão florestal em problemas de grande dimensão. **Scientia Forestalis**, Piracicaba, n.63, p.13-23. 2003.

INGBER, A. L. Simulated annealing: Practice versus theory. **Mathematical and Computer Modeling**, Netherlands, v.18, n.11, p.967-973, 1993.

GOLDSTEIN, L.; WATERMAN, M. Neighborhood size in the simulated annealing algorithm. **American journal of mathematical and management sciences**, USA, v.8, n.4, p.409-423, 1988.

HENDERSON, D.; JACOBSON, S. H.; JOHNSON, A. W. The Theory and Practice of

Simulated Annealing. p.287-319. **In: GLOVER, F.; KOCHENBERGER, G. A. Handbook of metaheuristics.** Kluwer. 2003. p.557.

KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by Simulated Annealing. **Science**, USA, v. 220, n.4598, p.671-680, 1983.

LAARHOVEN, P. J. V.; AARTS, E. H. **Simulated Annealing: Theory and Applications.** Springer. 1987. p. 204.

MAHMOUD, T. M. A Genetic and Simulated Annealing Based Algorithms for Solving the Flow Assignment Problem in Computer Networks. **International Journal of Electronics, Circuits and Systems**, , v.1, n. 2, p.128-134, 2007.

MARTINS, T. C.; TSUZUKI, M. S. G. Applying the Simulated Annealing to the Problem of Positioning Rotational Non Convex Polygons. **In: Symposium Series in Mecatronics. Proceedings...**2006. p.707-714.

MCEACHIN, R. C. **An investigation of simulated annealing applied to structural optimization problems.** Ohio. 1994. 107f. Thesis. Air Force Institute of Technology.

MIDDLETON, A. A. Counting States and Counting Operations. p. 71-100. In: HARTMANN, A. K.; RIEGER, H. **New Optimization Algorithms in Physics.** Wiley. p.300. 2004.

ÖHMAN, K.; LÄMAS, T. Reducing forest fragmentation in long-term forest planning by using the shape index. **Forest Ecology and Management**, Netherlands, v.212, n.1, p.346-357. 2005.

PEDAMALLU, C.S.; ÖZDAMAR, L. Comparison of Simulated Annealing, Interval Partitioning and Hybrid Algorithms in Constrained Global Optimization. p.1-22 In: SIARRY, P.; MICHALEWICZ, Z. **Advances in metaheuristic hard optimization.** Spring. The Netherlands. 2008. 479p.

PEZESHK, S.; CAMP, C. V. State of the on the use of genetic algorithm in design of steel

structures. p.200-250. In: BURNS, S. A. (Ed.) **Recent advances in optimal structural optimization**. ASCE. Reston. 2002. p.312.

RAO, S. S. **Engineering optimization: Theory and practice**. Wiley. 1996. p.922.

REZENDE, J. L. P.; OLIVEIRA, A. D. **Análise econômica e social de projetos florestais**. UFV. Viçosa. 2001. 389p.

RIBAS, P. C. **Análise do uso da têmpera simulada na otimização do planejamento mestre de produção**. Curitiba. 2003. 131f. Dissertação de Mestrado. Pontifícia Universidade Católica do Paraná.

RODRIGUES, F. L. **Metaheurísticas e Sistema de Suporte à Decisão para o Planejamento Florestal**. Viçosa. 2001. 225f. Tese de doutorado. Universidade Federal de Viçosa.

RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L.; RIBEIRO, C. A. A. S. Metaheurística *simulated annealing* para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, Viçosa, v.28, n.2, p.247-256, 2004.

ZOLFAGHARI, S.; LIANG, M. Comparative study of simulated annealing, genetic algorithm and tabu search of solving binary and comprehensive machine-grouping problemas. **International Journal of production research**, v.40, n.9, p. 2141-2158, 2002.

CAPÍTULO 4

AGENDAMENTO DA COLHEITA FLORESTAL UTILIZANDO O CONCEITO DE PLANEJAMENTO FLORESTAL ESPACIAL

RESUMO

AGENDAMENTO DA COLHEITA FLORESTAL UTILIZANDO O CONCEITO DE PLANEJAMENTO FLORESTAL ESPACIAL

A visão bidimensional de problemas envolvendo o planejamento florestal é uma prática comum no setor, onde o conhecimento das relações espaciais entre talhões é desprezado. Desta forma, uma seqüência de talhões selecionados para a colheita pode causar impactos negativos ao ambiente, em um dado período de tempo. A alternativa seria o uso do planejamento florestal espacial que contempla estas relações espaciais. Assim, este estudo teve como objetivo testar a viabilidade do planejamento florestal espacial; analisar o grau de impacto econômico no índice VPL e na produção volumétrica de madeira, quando aplicadas as restrições de adjacência; aplicar o AG, SA e a PLI como métodos de resolução comparando-os; analisar o desempenho dos métodos de resolução com o aumento da complexidade dos problemas, definidos pelos 32 cenários criados; testar e analisar as diferenças entre as restrições de adjacência do tipo ARM (*Area Restriction Model*) e URM (*Unit Restriction Model*) na produção volumétrica de madeira e no índice econômico VPL; comparar os efeitos de dois limites de área (50 ha e 70 ha) na restrição do tipo ARM, considerando a produção volumétrica de madeira e o índice econômico VPL como parâmetros de análise. Sendo assim, foram criados 32 cenários florestais envolvendo o uso do modelo tipo I e a maximização do VPL da floresta, distribuído em 4 casos de acordo com as restrições empregadas: caso 1 - restrições de produção anual de madeira, caso 2 - idem ao caso 1 e acrescido da restrição URM, caso 3 - idem ao caso 1 e acrescido da restrição ARM50 e caso 4 - idem ao caso 1 e acrescido da restrição ARM70. Os métodos de resolução aplicados foram a AG, SA e PLI. A floresta utilizada para o estudo foi composta de 52 talhões de eucalipto, distribuída em diferentes classes de idade e de produção. Os resultados demonstraram que as restrições de adjacência aumentam o número de restrições no modelo, principalmente quando empregado às restrições do tipo ARM. A redução no VPL gerada pelo uso do planejamento florestal espacial foi de 3,74% (caso 2), 2,24% (caso 3) e 2,10% (caso 4), quando comparado ao planejamento florestal tradicional, considerando um horizonte de planejamento de 7 anos. O limite de tempo estabelecido de 4 horas para a PLI não foi suficiente na maioria dos cenários, devido à complexidade do problema combinatório. O AG foi capaz de gerar soluções factíveis para todos os 32 cenários propostos, entretanto, em 2 situações foram encontradas falhas, e os cenários ficaram sem solução. O caso 2 foi considerado o mais difícil para o AG em se aproximar da PLI, apresentando os maiores desvios percentuais de VPL; por outro lado, os cenários contendo os casos 1 e 4 possuíram os menores desvios deste índice. A SA foi superior ao AG nos cenários envolvendo o caso 2. Além disso, o método foi capaz de encontrar o maior número de soluções factíveis para os 32 cenários. Contudo, a maioria de suas soluções foram inferiores às encontradas pelo AG. O tempo de processamento das metaheurísticas foram inferiores ao executado pela PLI, na maioria dos casos, chegando a economia de 97,92% (AG) e 99,78% (SA) nos casos mais extremos. As metaheurísticas foram mais eficientes na resolução de problemas abordando o planejamento florestal tradicional (caso 1). No caso de problemas onde a PLI apresenta limitações no tempo processamento, as metaheurísticas podem ser aplicadas como uma opção viável e de rápido processamento.

Palavras-chave: Metaheurísticas, Programação Linear Inteira, Adjacência.

ABSTRACT

FOREST HARVEST SCHEDULING UTILIZING SPATIAL FOREST PLANNING CONCEPT

The two dimensional vision of problems involving forest planning is a common practice in the sector, where the knowledge of the spatial relationships among stands is ignored. As such, a sequence of stands selected for harvest can cause negative impacts to the environment, in a given period of time. The alternative would be the use of the spatial forest planning, which considers these spatial relationships. Therefore, this study had as objective, to test the viability of the spatial forest planning; to analyze the degree of economic impact on the NPV index and in the volumetric production of wood, when introducing the adjacency constraints; to use GA, SA and ILP as resolution methods, comparing them; to analyze the performance of the resolution methods with the increasing complexity of the problems, defined for the 32 scenarios created; to test and to analyze the differences among the ARM (Area Restriction Model) and URM (Unit Restriction Model) adjacency constraints in the volumetric production of wood and in the LPV economic index; to compare the effects of two area limits (50 ha and 70 ha) in the ARM constraint, considering the volumetric production of wood and the NPV economic index as analysis parameters. As a result, 32 forest scenarios were created involving the use of the model type I and the maximization of NPV of the forest, distributed in 4 cases according to the employed constraints: case 1 - annual wood production constraints, case 2 - same as case1 plus the URM constraint, case 3 - same as case1 plus the ARM50 constraint and case 4 - same as case1 plus ARM70 constraint. The resolution methods applied were GA, SA and ILP. The forest used for the study was composed of 52 eucalyptus stands, distributed in different age and production classes. The results demonstrated that the adjacency constraint increase the number of restrictions in the model, mainly when employing the ARM constraints. The reduction in NPV generated by the use of the spatial forest planning was 3.74% (case 2), 2.24% (case 3) and 2.10% (case 4), when compared to the traditional forest planning, considering a 7 year horizon planning. The 4 hour established time limit for ILP was not enough in most of the scenarios, due to the complexity of the problem combination. GA was capable of generating feasible solutions for all the 32 proposed scenarios, while in 2 situations flaws were found, and the scenarios were without solution. The case 2 was considered the most difficult for GA in approximating ILP, presenting the highest percentile deviations of NPV; on the other hand, the scenarios containing the cases 1 and 4 possessed the lowest deviations of this index. SA was superior to GA in the scenarios involving the case 2. Furthermore, the method was capable of finding the highest number of feasible solutions for the 32 scenarios. However, most of its solutions were inferior to those found by GA. The processing time of the metaheuristics was inferior to that executed by ILP, in most of the cases, reaching an economy of 97.92% (GA) and 99.78% (SA) in the most extreme cases. The metaheuristics were more efficient in the resolution of problems approaching the traditional forest planning (case1). In the case of very large problems, where ILP is not applied, the metaheuristics can be applied as a viable option of fast processing.

Keywords: Metaheuristics, Integer Linear Programming, Adjacency.

1. INTRODUÇÃO

A atividade de planejamento florestal é caracterizada por muitos avanços ao longo das últimas décadas, representando um histórico rico de idéias inovadoras, bem como o desenvolvimento de ferramentas de tomada de decisão. Particularmente no campo da matemática surgiram instrumentos capazes de facilitar o cotidiano operacional das empresas florestais. Neste ponto, nasceram modelos de otimização importantes para melhorar a gerência dos recursos florestais madeireiros, garantindo uma base sólida na análise do produto manejado.

A partir desta fase, a determinação das áreas florestais a serem colhidas passou a depender, além da habilidade e experiência dos gestores de informação, do uso destas ferramentas de otimização. A grande vantagem observada nestas ferramentas foi a facilidade na resolução de problemas complexos, que caracterizam cada vez mais a realidade da tomada de decisões em florestas de produção e que envolvem um acentuado número de variáveis. No planejamento florestal é comum a presença de um grande número de alternativas de manejo destinadas a cada unidade do povoamento.

O agendamento da colheita florestal é um típico problema de planejamento, onde usualmente são envolvidas diversas opções de manejo representadas pelas variáveis de decisão do modelo matemático. Neste caso, o problema é estabelecer uma agenda de colheita para um período de tempo pré-definido, através da seleção de talhões presentes nas áreas florestais. Geralmente estes problemas têm como objetivo a maximização de uma função de lucro ou receita, vinculada a restrições de produção volumétrica. Esta visão bidimensional do problema considerando apenas a produção volumétrica de madeira e receita pode repercutir em impactos ao ambiente, pois são desprezadas as relações espaciais entre os talhões na floresta, bem como a idéia de conjunto que estes formam após a colheita.

Assim, os aspectos ambientais passaram a definir restrições ao sistema de produção vigente, com o propósito de controlar ou mitigar os possíveis distúrbios gerados no agendamento da colheita, sendo o caso das restrições de adjacência. Segundo Mcdill e Braze (2000), o pioneiro no desenvolvimento destas restrições foi Thompson em 1973, a partir de um estudo com propostas multiobjetivas de produção de madeira e proteção à fauna. Murray (1999) comenta que os modelos envolvendo as restrições de adjacência possuem duas variações e por isso suas formulações matemáticas apresentam diferenças entre si. O autor ainda propõe uma classificação destas variações a partir das terminologias: URM (*unit*

restriction model) sendo restrições de adjacência que impede a colheita de unidades ou talhões vizinhos no mesmo período de tempo e ARM (*area restriction model*) definido como restrições de adjacência que permite a colheita de unidades ou talhões vizinhos, desde que respeite um limite máximo de área formado pelos mesmos. Além disso, o grau de dificuldade de se formular um modelo contendo a restrição ARM é muito maior que no modelo URM (ZHU e BETTINGER, 2007).

Historicamente, a resolução de problemas florestais envolvendo as restrições do tipo ARM, por método exato, só surgiu a partir de McDill *et al.* (2002), estimulando assim a abertura para novas descobertas e o desenvolvimento de mecanismos de resolução. Por outro lado, o surgimento e resolução de modelos relacionados às restrições do tipo URM são mais antigos, sendo originário na década de 70. A diferença temporal existente entre o pleno conhecimento destas restrições demonstra o grau de complexidade e evolução dos problemas florestais. Além das restrições de adjacência, pode-se encontrar ainda restrições designadas para a manutenção de corredores ecológicos (FISCHER e CHURCH, 2003), algumas ligadas a índices de paisagem (HEINONEN *et al.*, 2007), restrições de blocos para facilitar a colheita (NELSON, 2001) restrições para problemas de *green-up* (BOSTON e BETTINGER, 2001), dentre outras. O ponto chave destas opções de restrições está no fato de trabalharem a espacialidade entre talhões na floresta.

Durante o processo de construção dos modelos envolvendo espacialidade, o uso do sistema de informação geográfica é empregado, porém apenas como suporte na criação das restrições, não participando do processo de seleção das áreas a serem colhidas. Segundo Baskent e Keles (2005), a diferença entre o planejamento florestal convencional e o planejamento florestal espacial consiste na forma de enxergar cada talhão dentro da floresta. No primeiro caso, o talhão é apenas uma unidade de produção desconectada dos demais talhões, já na segunda versão do planejamento, o talhão passa a ser observado segundo o seu tamanho, forma e distribuição dentro da floresta. Neste último caso, seus efeitos sobre o ecossistema são determinados espacialmente, contando para isso com regras matemáticas formuladas exclusivamente para o planejamento florestal espacial. Bettinger e Sessions (2003) acreditam que brevemente o planejamento florestal será chamado de planejamento florestal espacial, tendo como foco as atividades do manejo florestal e políticas ambientais.

O planejamento florestal espacial convive com o uso obrigatório de variáveis binárias, que dificultam a resolução e elevam os tempos de processamento para a obtenção da solução. A utilização de métodos de aproximação muitas vezes se faz necessária, como o caso das

metaheurísticas.

Assim, estes novos desafios matemáticos e ambientais devem sempre ser analisados pelos agentes ligados ao planejamento de uma empresa florestal, pois a exigência do mercado mundial pode regulamentar o uso de práticas desta natureza. Um dos tantos exemplos é encontrado pela *American Forest and Paper Association* que incentiva processos de sustentabilidade de florestas nos Estados Unidos, ao restringir o corte de áreas contíguas com mais de 120 acres ou 48,55 ha (GOYCOOLEA *et al.*, 2005).

A partir do exposto surgem questionamentos como: Qual o custo deste tipo de restrição espacial para a indústria de base florestal? Existem alternativas mais vantajosas economicamente e que se enquadram na linha ambiental como o retalhamento? Qual a redução volumétrica em projetos desta natureza? Qual o limite de tolerância aceitável de adjacência no manejo de extensas florestas e em quais anos aplicar? Qual o tipo de restrição espacial empregar no planejamento florestal? Existem ferramentas para modelar estes problemas e quais métodos de resolução? Além de outras questões ligadas diretamente à parte operacional e estratégica do empreendimento florestal.

2. OBJETIVO

O objetivo geral do capítulo foi comparar a versão de planejamento florestal tradicional e espacial, considerando a introdução de restrições de adjacência no modelo matemático tipo I desenvolvido por Johnson e Scheurmann (1977). Neste modelo foram testados dois tipos de restrições de adjacência (URM e ARM), contando ainda com restrições de controle de produção volumétrica de madeira e uma função objetivo representada pelo VPL da floresta, onde deveria ser maximizada. Desta forma, os objetivos específicos foram:

- a) testar a viabilidade do planejamento florestal espacial;
- b) analisar o grau de impacto econômico no índice VPL e na produção volumétrica de madeira, quando introduzido às restrições de adjacência;
- c) utilizar o AG, SA e a PLI como métodos de resolução, comparando-os;
- d) analisar o desempenho dos métodos de resolução com o aumento da complexidade dos problemas, definidos pelos 32 cenários criados;
- e) testar e analisar as diferenças entre as restrições de adjacência do tipo ARM (*area restriction model*) e URM (*unit restriction model*) na produção volumétrica de madeira e no índice econômico VPL;
- f) comparar os efeitos de dois limites de área (50 ha e 70 ha) na restrição do tipo ARM, considerando a produção volumétrica de madeira e o índice econômico VPL como parâmetros de análise.

3. MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

O estudo foi desenvolvido em 5 fazendas pertencentes à empresa VCP - Votorantim Celulose e Papel, sendo todas localizadas no município de Caçapava-SP. O clima da região é denominado pela classificação de Köppen como Cwa, com verão chuvoso e quente, e inverno seco. A área total efetiva de plantio compreende 1.490,7 ha, distribuídos em reflorestamentos com espécies de eucalipto e algumas variações de clones da empresa. A Figura 29 apresenta a localização da área de estudo.

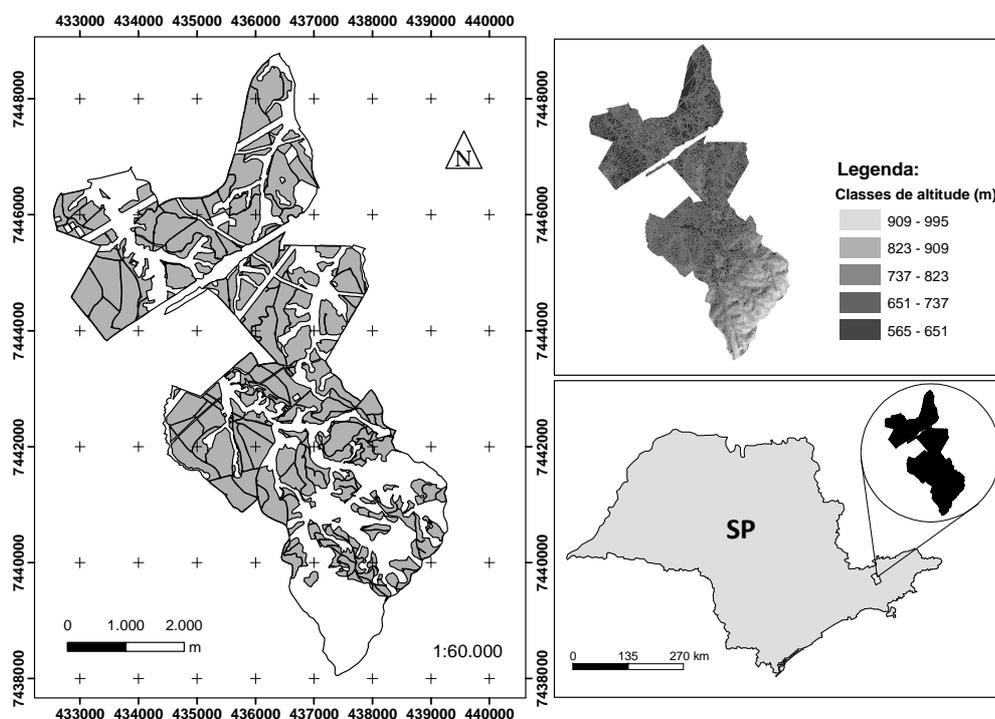


FIGURA 29 - MAPA DA LOCALIZAÇÃO DA ÁREA DE ESTUDO NO ESTADO DE SÃO PAULO.

A floresta designada para o estudo contabilizou uma malha de 52 talhões, contendo uma variação de idades. As projeções de crescimento volumétrico de madeira na floresta foram seguidas segundo dados da própria empresa.

3.2 AGENDAMENTO DA COLHEITA FLORESTAL

3.2.1 O problema

O planejamento de suprimento de madeira é normalmente parte integrante do manejo florestal, tendo como objetivos definir a agenda de corte das unidades e auxiliar na regulação da floresta (HOTVEDT, 1983). O seu agendamento representa um ponto estratégico para a empresa florestal, onde se dimensiona uma série de atividades de logística e procedimentos técnicos na colheita, em virtude da seqüência de talhões agendados para a colheita. Nos dias atuais, o agendamento da colheita florestal vai além da simples preocupação com a produção de madeira e a capitalização de recursos financeiros. O cuidado com o ambiente tem se tornado um fator preponderante na sustentabilidade do mercado no setor florestal. Existe atualmente um aumento de objetivos e restrições que não atendam basicamente a produção volumétrica de madeira, mas também contemplem aspectos ambientais (VAN DEUSEN, 1999). A questão relacionada à adjacência também é um tema discutido no planejamento florestal, sendo observado nos trabalhos de Weintraub *et al.* (1994), Brumelle *et al.* (1998), Borges e Hoganson (1999), Weintraub *et al.* (2000), Boston e Benttinger (2001a), Murray *et al.* (2004), Goycooela *et al.* (2005), Zhu *et al.* (2007), dentre outros. No Brasil podemos citar trabalhos de Alonso (2003) e Castro (2007).

Assim, o problema florestal foi caracterizado com a necessidade de maximizar o valor presente líquido (VPL), analogamente ao encontrado em uma série de trabalhos na literatura, e que tiveram o modelo tipo I de Johnson e Scheurmann (1977) como referência, sendo ainda introduzidas restrições de adjacência para um controle ambiental da colheita. Desta forma, foram introduzidas restrições ligadas à estabilização da produção volumétrica de madeira, o que promove um fornecimento contínuo e constante de madeira dentro de um intervalo pré-definido de tempo. Além disso, foram empregados dois tipos de restrições espaciais ligadas à adjacência entre talhões, quais sejam as restrições ARM (*area restriction model*) e URM (*unit restriction model*), aplicadas separadamente.

O problema de agendamento da colheita florestal foi dividido em 4 tipos de problemas ou casos, conforme apresentado na Tabela 10. Estes problemas descrevem 4 situações distintas, porém apresentando uma função de maximização semelhante. O caso 1, planejamento florestal tradicional, considera o uso de apenas restrições de controle volumétrico, sendo uma situação onde os cuidados ambientais e a visão de interação entre talhões foram descartados. Os casos 2, 3 e 4, contidos no planejamento florestal espacial, empregaram o uso de restrições de adjacência, juntamente com restrição de controle volumétrico. As restrições de integralidade também foram usadas para garantir a seleção de apenas uma opção de manejo, estando presente em todos os casos.

TABELA 10 - DESCRIÇÃO DOS CASOS DE PLANEJAMENTO FLORESTAL RETRATADOS PARA A ANÁLISE.

Caso	Planejamento Florestal	Restrições				
		Volume	Integridade	URM	ARM 50	ARM 70
1	Tradicional	x	x	-	-	-
2	Espacial	x	x	x	-	-
3	Espacial	x	x	-	x	-
4	Espacial	x	x	-	-	x

As restrições de adjacência do tipo URM impedem o corte de talhões adjacentes na floresta no mesmo período de tempo. Este tipo de restrição é considerado muito rígido, por não considerar a área dos talhões envolvidos para o corte. A Figura 30 apresenta uma fração do mapa da área de estudo, no qual um exemplo de funcionamento desta restrição é apresentado para elucidar seu entendimento, sendo utilizados apenas 13 talhões dos 52 empregados no estudo.

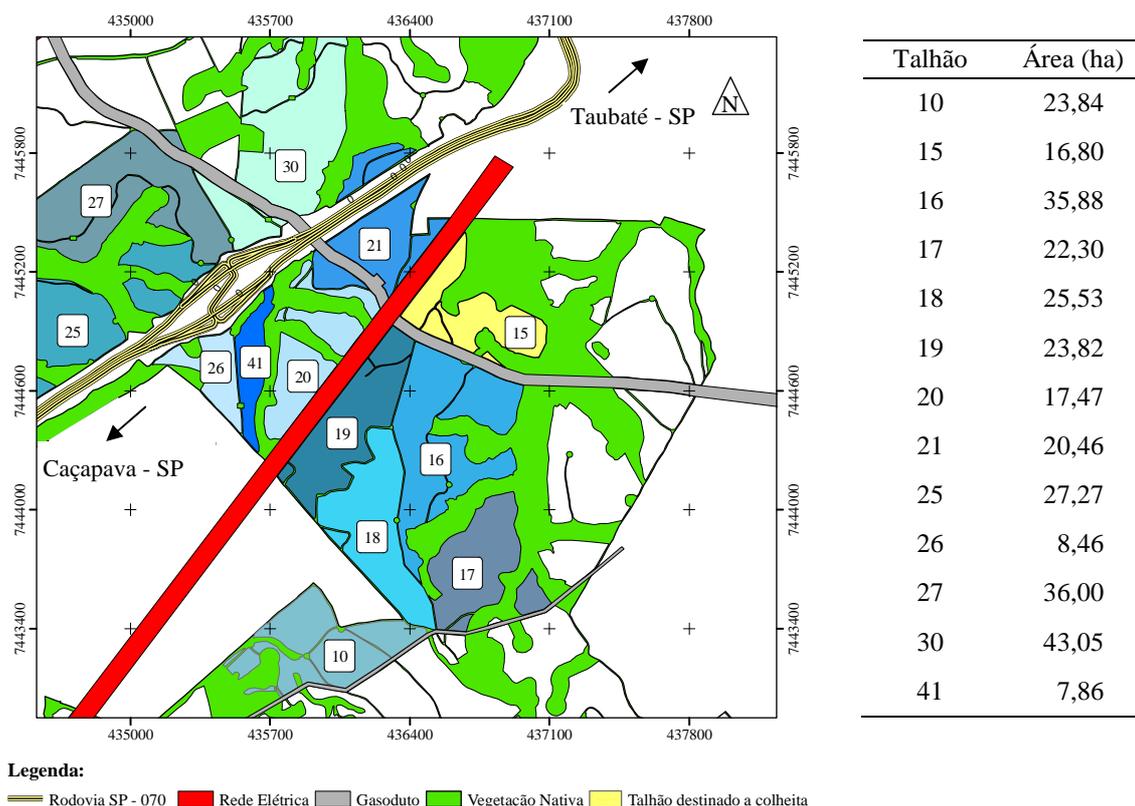


FIGURA 30 - MAPA DA VIZINHANÇA ENTRE UNIDADES DE MANEJO FLORESTAL PRESENTE EM UMA PORÇÃO DA ÁREA DE ESTUDO E SUAS INFORMAÇÕES DE ÁREA.

No mapa são apresentados 13 talhões disponíveis para a colheita florestal no período t de tempo. Assim, no exemplo de agendamento da colheita florestal, foi selecionado, de forma

arbitrária, o talhão 15 para o período t de tempo. Desta maneira, os talhões 16, 19, 20 e 21 que pertencem à vizinhança do talhão 15 são impedidos de serem colhidos neste mesmo período de tempo, mesmo existindo viabilidade técnica para tal ação florestal. O impedimento apresentado foi decorrente da restrição de adjacência do tipo URM, que impede a colheita de talhões adjacentes. Este tipo de restrição considera apenas as unidades e sua vizinhança, desprezando o tamanho em área formado por cada unidade.

As restrições de adjacência do tipo ARM, ao contrário do apresentado anteriormente, permitem o corte de talhões vizinhos, desde que não ultrapassem o limite máximo de área permitido. As restrições desta natureza são mais flexíveis na questão da adjacência, uma vez que não basta serem apenas vizinhos para não serem cortados simultaneamente; eles devem ser analisados como um conjunto formado por áreas contíguas. A união de talhões adjacentes foi denominada de grupo e significa um conjunto fechado de elementos mutuamente adjacentes e analogamente ligados à questão de área máxima permitida para corte.

Na literatura é encontrada uma variedade de limites de área para as restrições ARM. A diversidade destes valores está atribuída a questões regionais, políticas ou ligadas a processos de certificação, ou até mesmo a questões operacionais vinculadas ao equipamento utilizado na colheita florestal. Sessions e Bettinger (2001) citam alguns exemplos como: 49 ha (Oregon - EUA), 17 ha (Califórnia - EUA), 20 ha (Suécia) e 120 acres ou 48,55 ha (*American Forest and Paper Association*). Nos casos 3 e 4, a restrição ARM foi dividida em duas possibilidades, a primeira considerando um limite máximo de 50 ha, ou um grupo de talhões adjacentes apresentando uma área total conjunta limitada a 50 ha, o que segue um limite próximo ao definido pela *American Forest and Paper Association*. A segunda opção testou um limite igual a 70 ha, representando uma maior folga ao modelo.

As influências destas restrições podem ser vistas ao considerar o mesmo exemplo abordado anteriormente, via restrição URM. Neste ponto, ao se empregar a restrição ARM 50, surgem novas opções para a colheita florestal. O mesmo talhão 15, selecionado para a colheita no exemplo anterior, permite a colheita de talhões adjacentes, como nas combinações: 15+19 (40,62 ha) ou 15+21 (37,26 ha). No caso do uso da restrição ARM 70, este limite foi ampliado, gerando as seguintes opções de corte: 15+16 (52,68 ha), 15+18+19 (66,15 ha), 15+19+20 (58,09 ha) ou 15+19+21 (61,08 ha).

3.2.2 A vizinhança

A definição da adjacência entre talhões vizinhos seguiu um processo criterioso, pois a área de estudo é composta por estradas, rodovias, linhas de transmissão de energia elétrica e gasoduto. Segundo Lockwood e Moore (1993), a floresta é representada como um grafo² não direcionado, onde os talhões são representados como um conjunto de vértices conectados. O ANEXO 3 apresenta a lista de vizinhança e a área de cada talhão, já a Figura 31 ilustra os tipos recorrentes de adjacência identificados na área de estudo, onde a distribuição dos talhões na área é observado no mapa do ANEXO 4.

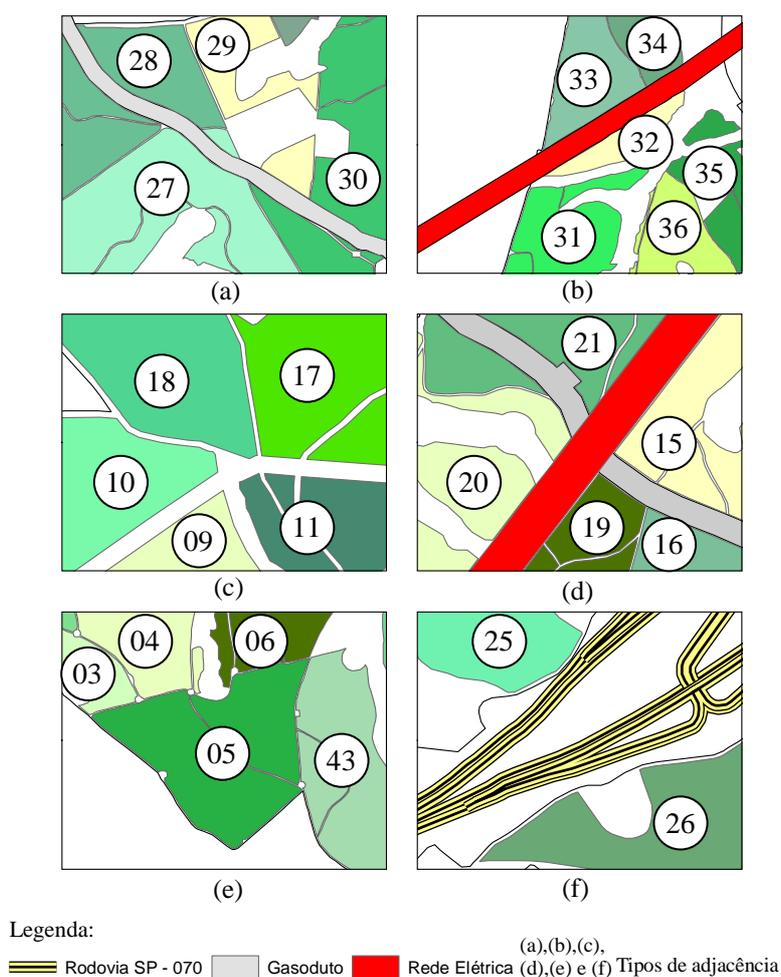


FIGURA 31 - EXEMPLO DOS TIPOS DE VIZINHANÇA ENTRE TALHÕES RECORRENTE NA ÁREA DE ESTUDO.

A partir das informações supracitadas foram definidos e adotados os seguintes critérios para a definição da adjacência entre talhões:

² Grafos: é uma rede composta por um conjunto de vértices (nós) e ligações (arcos), onde estas ligações podem apresentar um sentido de deslocamento (grafos direcionados) ou não (grafos não direcionados), sendo muito aplicado em problemas de otimização de transportes, linhas de transmissão, comunicação e em outras áreas do conhecimento (HILLIER e LIEBERMAN, 2001).

- a) Adjacência tradicional: talhões que se tocam lateralmente e dividem uma linha em comum (Figura 3, letra *e*), como os talhões: 3+4, 3+5, 4+5, 5+6 e 5+43; excluindo aqueles que são adjacentes somente na encruzilhada de estradas, ou que têm apenas um ponto de contato (Figura 3, letra *c*), como os pares de talhões: 9+17, 9+18, 10+11, 10+17 e 11+18. McDill e Braze (2000) adotaram esta mesma regra para a definição da adjacência entre talhões;
- b) Presença de gasoduto: não considerado como uma barreira à adjacência (Figura 3, letras *a* e *d*), seguindo o critério anterior, sendo os pares de talhões adjacentes: 15+16, 15+19, 20+21, 27+28 e 27+30;
- c) Presença de redes de transmissão de energia elétrica: não considerado como uma barreira à adjacência (Figura 3, letras *b* e *d*), seguindo a idéia do primeiro critério, onde os pares de talhões adjacentes que servem de exemplo são: 15+21, 19+20, 19+21, 32+33 e 32+34;
- d) Presença de estradas: não considerado como uma barreira à adjacência (Figura 3, letra *c*), seguindo a idéia do primeiro critério, onde pelo exemplo os talhões adjacentes são: 9+10, 9+11, 10+18, 11+17 e 17+18. Lockwood e Moore (1993) aplicaram a mesma lógica em seus estudos;
- e) Presença de rodovias: não considerado como uma barreira à adjacência (Figura 3, letra *f*), seguindo a idéia do primeiro critério, apesar da distância entre os talhões (25+26). Lockwood e Moore (1993) comentam sobre o uso de uma distância crítica aceitável. Neste aspecto, a distância não foi considerada uma barreira, exatamente para reduzir o impacto visual da colheita na paisagem, devido ao tráfego de veículos.

3.2.3 Simulação de cenários florestais

O agendamento da colheita florestal apresenta algumas características específicas na formulação dos modelos de programação linear inteira, conforme encontrado em Mitchell (2004). Segundo o autor, o horizonte de planejamento desta atividade geralmente é decorrente de um curto período de tempo, retratando o planejamento operacional. Entretanto, para exemplificar o grau de complexidade deste tipo de problema, foram simulados alguns cenários para elucidar melhor seus efeitos na resolução, uma vez que suas variáveis de decisão são binárias. Desta forma, o problema de agendamento da colheita florestal foi

ampliado para 32 cenários, definidos de acordo com a Tabela 11.

Os cenários tiveram uma demanda constante anual de madeira de 69.000 m³, com variação de $\pm 42\%$ de sua meta. A definição dos limites de produção volumétrica foi proposta em virtude de testes preliminares, nos quais uma porcentagem mais conservadora de desvio da meta volumétrica gerou sempre uma infactibilidade na programação linear inteira. O horizonte de planejamento (HP) estudado foi de 7 a 14 anos e assim, a cada alteração anual do mesmo, um número de 4 cenários se formava, compreendendo um total de 32 cenários ao fim. Os 32 cenários incluíram o processamento dos casos 1, 2, 3 e 4, nos quais a taxa de juros foi fixada em 10% ao ano em todos os cenários simulados. As projeções de crescimento volumétrico da floresta foram seguidas segundo dados da própria empresa.

TABELA 11 - ESTRUTURA DOS 32 CENÁRIOS FLORESTAIS APLICADOS NO ESTUDO.

Casos	Restrição	Limites	Horizonte de Planejamento								
			7	8	9	10	11	12	13	14	
1	Volume	Inferior	42%	42%	42%	42%	42%	42%	42%	42%	42%
		Meta (m ³)	69.000	69.000	69.000	69.000	69.000	69.000	69.000	69.000	69.000
		Superior	42%	42%	42%	42%	42%	42%	42%	42%	42%
2	URM	-	-	-	-	-	-	-	-	-	
3	ARM 50	Máximo (ha)	50	50	50	50	50	50	50	50	
4	ARM 70	Máximo (ha)	70	70	70	70	70	70	70	70	

Onde: (-) As restrições de adjacência do tipo URM não necessitam de meta.

Os custos de manutenção da floresta, de colheita e transporte foram informados pela empresa, como ainda o preço de venda da madeira em R\$76,00 m⁻³. A idade máxima permitida de corte foi estabelecida em 7 anos e a mínima em 5 anos, para a construção das alternativas de manejo, conforme o exemplo apresentado na ANEXO 5. Ainda foi permitido deixar o talhão ocioso, ou seja, sem definir nenhuma opção de manejo para o mesmo. O sistema silvicultural considerado foi o alto fuste, onde ao cortar um talhão na sua totalidade, o mesmo material genético seria plantado na seqüência, a ciclos contínuos.

3.3 MÉTODOS DE RESOLUÇÃO

3.3.1 Programação linear inteira

O problema de agendamento da colheita florestal requer o uso de variáveis binárias devido à necessidade de colher totalmente um talhão ou não. Portanto, foi utilizada a PLI por meio do algoritmo *branch-and-bound* para a obtenção das soluções. Este procedimento foi

adotado como testemunha, uma vez que a PLI garante a otimalidade das respostas.

3.3.2 Metaheurísticas

3.3.2.1 Algoritmo genético

O AG foi programado nos moldes apresentados no Capítulo 2, onde foi empregado um código binário {0,1} para criar os indivíduos e uma função de avaliação composta por penalidades, para expressar o *fitness* individual. O conjunto de parâmetros do AG, que sobressaíram nos testes realizados no Capítulo 2 foram utilizados, sendo recomendados em problemas similares ao caso 1. Assim, resgatando esta configuração como informação, adotou-se a seguinte estrutura:

- a) Tamanho da população inicial: 300 indivíduos;
- b) Operador de seleção: amostragem estocástica universal (*stochastic universal sampling*);
- c) *Crossover*: operador de múltiplos pontos com trocas gênicas de 50%;
- d) Mutação: aplicado a 10% da população e uniforme a 20% dos genes no cromossomo, com probabilidade de 0,5 de ocorrência;
- e) *Steady state*: substituição de 50% dos piores indivíduos a cada geração;
- f) Critério de parada: valor de *fitness* constante após 500 iterações. O valor foi alterado de 1000 (capítulo 2) para 500 em virtude da maior complexidade dos problemas abordados neste capítulo, e exigência de tempos de processamentos mais elevados.

Os casos 1, 3 e 4 seguiram o uso desta configuração, porém o caso 2 não apresentou resultados preliminares satisfatórios. A natureza do problema envolvendo a adjacência do tipo URM (caso 2) necessita de trocas mais lentas e buscas mais conservadoras no espaço de soluções. Esta característica ficou bastante clara a partir dos testes realizados e assim duas alterações foram definidas para melhorar as buscas. A primeira em relação à taxa de trocas gênicas, passando a assumir um valor de 10%, e a segunda, ao assumir um valor de 10% de substituição dos piores indivíduos a cada geração, no item *steady state*. Nos casos 3 (ARM 50) e 4 (ARM 70) por serem mais flexíveis que o anterior, não foram necessárias alterações na configuração.

3.3.2.2 Simulated annealing

Assim como ocorrido com o AG, a metaheurística SA foi empregada utilizando as informações dos testes realizados no Capítulo 3. A estrutura da solução foi baseada em códigos binários {0,1} que constituíam uma *string*, e uma função de avaliação da solução (energia) foi criada considerando penalidades para os desvios das metas. Desta maneira, a configuração empregada para a resolução dos casos 1, 2, 3 e 4 foi a seguinte:

a) Temperatura inicial: 4091;

b) Função de resfriamento:

$$T_i = \frac{(i-1)T_{i-1} + T_0}{i(1 + \log(i))} \quad (\text{Função 3})$$

Onde:

T_i - Temperatura do sistema na iteração i ;

T_{i-1} - Temperatura do sistema na iteração $i-1$;

T_0 - Temperatura inicial do sistema;

\log - Logaritmo neperiano na base 10;

i - Iteração atual do processo.

c) Critério de parada: o valor foi ampliado de 15.000 iterações para 30.000 iterações devido a maior complexidade do problema abordado, exigindo, neste caso, mais iterações para uma melhor qualidade nas buscas;

d) Distância de busca local: mudança de 10% nas Us presentes na *string* a cada iteração;

e) Estratégia de programação da metaheurística SA: explorar mais a vizinhança de busca das melhores soluções considerando 60 iterações (Busca 3), conforme apresentado no item 3.3.5.3 do Capítulo 3.

3.4 FORMULAÇÃO MATEMÁTICA

3.4.1 Caso 1

A idéia do problema seguiu os moldes da programação linear clássica modelo tipo I (JOHNSON e SCHEURMANN, 1977). Neste caso, a abordagem foi tratada como planejamento florestal tradicional e sua formulação matemática seguiu a seguinte estrutura:

(1) função objetivo dimensionada para maximizar o valor presente líquido (VPL) da floresta;

(2) restrição de integridade das unidades de manejo; (3) e (4) restrições de controle do fluxo de produção volumétrico de madeira e (5) restrições binárias das variáveis de decisão do modelo. Na seqüência é apresentada a formulação aplicada no caso 1.

$$\text{Função Objetivo: Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} X_{ij} \quad (1)$$

Sujeito a:

$$\sum_{j=1}^P X_{ij} \leq 1, \quad \forall_j, \forall_{i=1,2,\dots,M} \quad (2)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} X_{ijT} \geq L_{\text{inferior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,HP} \quad (3)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} X_{ijT} \leq L_{\text{superior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,HP} \quad (4)$$

$$X_{ij} \in \{0,1\} \quad \forall_i, \forall_j \quad (5)$$

Onde:

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pela alternativa de manejo j ;

O uso do indicador econômico VPL foi aplicado apenas para atualizar as receitas líquidas geradas por cada alternativa de manejo, não sendo aplicado como método de comparação entre alternativas de manejo na sua forma pura de análise. A mesma idéia foi aplicada nos casos 2, 3 e 4, descrito nos próximos itens.

Um exemplo resumido da formulação matemática é apresentado a seguir, considerando um horizonte de planejamento de 7 anos e a estrutura do caso 1, descrito anteriormente.

Função objetivo:

$$\begin{aligned} \text{Max VPL} = & 299.106X_{IJ_1_1} + 346.765X_{IJ_1_2} + 157.814X_{IJ_1_3} + 348.226X_{IJ_1_4} + \\ & + 194.312X_{IJ_1_5} + 213.558X_{IJ_1_6} + 371.623X_{IJ_2_1} + 418.287X_{IJ_2_2} + 202.626X_{IJ_2_3} + \\ & + 416.661X_{IJ_2_4} + 237.629X_{IJ_2_5} + 254.355X_{IJ_2_6} + \dots + 40.067X_{IJ_52_1} + 56.010X_{IJ_52_2} + \\ & + 77.477X_{IJ_52_3} \end{aligned}$$

Restrições de integridade entre alternativas de manejo:

$$\begin{aligned} \textcircled{1} & X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_1_6} \leq 1 \\ \textcircled{2} & X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} + X_{IJ_2_4} + X_{IJ_2_5} + X_{IJ_2_6} \leq 1 \\ & \vdots \\ \textcircled{52} & X_{IJ_52_1} + X_{IJ_52_2} + X_{IJ_52_3} \leq 1 \end{aligned}$$

Restrições de limites de produção volumétrica de madeira:

A) Limite inferior

$$\begin{aligned} \textcircled{1} & 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + \\ & + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + \\ & + 2.539,76X_{IJ_41_3} \geq 40.020 \\ \textcircled{2} & 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + \\ & + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \geq 40.020 \\ & \vdots \\ \textcircled{7} & 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + \\ & + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \geq 40.020 \end{aligned}$$

B) Limite superior

$$\begin{aligned} \textcircled{1} & 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + \\ & + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + \\ & + 2.539,76X_{IJ_41_3} \leq 97.980 \\ \textcircled{2} & 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + \\ & + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \leq 97.980 \\ & \vdots \\ \textcircled{7} & 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + \\ & + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \leq 97.980 \end{aligned}$$

Variáveis binárias:

$$X_{IJ} \in \{0,1\}, \forall_i, \forall_j$$

A formulação empregada nas metaheurísticas AG e SA seguiu a mesma lógica descrita anteriormente, porém foi introduzida na função objetivo (1) uma penalidade, transformando-a na função objetivo (6). O método de penalidades foi empregado para guiar nas buscas de

soluções e contribuir para uma boa convergência da resposta. Assim como discutido nos capítulos 2 e 3, o valor da penalidade foi de R\$500,00 para cada m³ de madeira desviado da meta volumétrica. Desta maneira, a nova função objetivo assumiu a seguinte formulação:

$$\text{Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} - \text{penalidade (R\$/m}^3) \sum_{k=1}^T D_k \quad (6)$$

Onde:

Penalidade - R\$/m³ de madeira;

D - Valor absoluto do desvio volumétrico de madeira (m³);

k - período anual de tempo dentro do horizonte de planejamento;

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão *i* e alternativa de manejo *j*;

c_{ij} - valor presente líquido pertencente ao talhão *i* segundo a alternativa de manejo *j*;

T - período total de tempo de planejamento;

v_{ij}- volume total produzido no talhão *i* pela alternativa de manejo *j*;

A nova função objetivo passa a ser chamada de *fitness* (AG) ou energia (SA), a depender do tipo de metaheurística empregada como método de resolução.

3.4.2 Caso 2

Esta estratégia representa uma estrutura de planejamento que impede o corte de talhões adjacentes, sendo classificada como planejamento florestal espacial. Neste caso, foi adicionada a restrição do tipo URM no modelo de programação. Sendo assim, conforme observado no caso 1, a sua formulação foi composta por: (7) função objetivo dimensionada para maximizar o valor presente líquido (VPL) da floresta; (8) restrição de integridade das unidades de manejo; (9) e (10) restrições de controle do fluxo de produção volumétrico de madeira; (11) restrição de adjacência do tipo URM e (12) restrições binárias das variáveis de decisão do modelo. A representação matemática é descrita a seguir:

$$\text{Função Objetivo: Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} X_{ij} \quad (7)$$

Sujeito a

$$\sum_{j=1}^P X_{ij} \leq 1, \quad \forall_j, \forall_{i=1,2,\dots,M} \quad (8)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} X_{ijT} \geq L_{\text{inferior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,HP} \quad (9)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} X_{ijT} \leq L_{\text{superior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,HP} \quad (10)$$

$$\sum_{\substack{i=1 \\ i \neq k}}^M a_{ik} X_{ijT} + \left[\sum_{i=1}^M a_{ik} \right] \cdot X_{ijT} \leq \sum_{i=1}^M a_{ik}, \quad \forall_i, \forall_k, \forall_j, \forall_{T=1,2,\dots,HP} \quad (11)$$

$$X_{ij} \in \{0,1\} \quad \forall_i, \forall_j \quad (12)$$

Onde:

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pela alternativa de manejo j ;

k - talhão número;

a_{ik} - matriz binária $\{0,1\}$ de adjacência entre talhões, onde $i=k$.

A restrição de adjacência do tipo URM foi formulada seguindo a mesma lógica encontrada nos trabalhos de Alonso (2003) e Castro (2007). Assim, um exemplo resumido da formulação do caso 2 é descrita a seguir, considerando um horizonte de planejamento de 7 anos.

Função objetivo:

$$\text{Max VPL} = 299.106X_{IJ_1_1} + 346.765X_{IJ_1_2} + 157.814X_{IJ_1_3} + 348.226X_{IJ_1_4} + \\ + 194.312X_{IJ_1_5} + 213.558X_{IJ_1_6} + 371.623X_{IJ_2_1} + 418.287X_{IJ_2_2} + 202.626X_{IJ_2_3} +$$

$$+416.661X_{IJ_2_4} + 237.629X_{IJ_2_5} + 254.355X_{IJ_2_6} + \dots + 40.067X_{IJ_52_1} + 56.010X_{IJ_52_2} + 77.477X_{IJ_52_3}$$

Restrições de integridade entre alternativas de manejo:

$$\textcircled{1} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_1_6} \leq 1$$

$$\textcircled{2} X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} + X_{IJ_2_4} + X_{IJ_2_5} + X_{IJ_2_6} \leq 1$$

⋮

$$\textcircled{52} X_{IJ_52_1} + X_{IJ_52_2} + X_{IJ_52_3} \leq 1$$

Restrições de limites de produção volumétrica de madeira:

A) Limite inferior

$$\textcircled{1} 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + 2.539,76X_{IJ_41_3} \geq 40.020$$

$$\textcircled{2} 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \geq 40.020$$

⋮

$$\textcircled{7} 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \geq 40.020$$

B) Limite superior

$$\textcircled{1} 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + 2.539,76X_{IJ_41_3} \leq 97.980$$

$$\textcircled{2} 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \leq 97.980$$

⋮

$$\textcircled{7} 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \leq 97.980$$

Restrições de adjacência do tipo URM:

a) Ano 1

$$\textcircled{1} X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} + X_{IJ_3_1} + X_{IJ_3_2} + X_{IJ_3_3} + 3X_{IJ_1_1} + 3X_{IJ_1_2} + 3X_{IJ_1_3} \leq 3$$

$$\textcircled{2} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_3_1} + X_{IJ_3_2} + X_{IJ_3_3} + X_{IJ_4_1} + X_{IJ_4_2} + X_{IJ_4_3} + 4X_{IJ_2_1} + 4X_{IJ_2_2} + 4X_{IJ_2_3} \leq 4$$

⋮

$$\textcircled{31} X_{IJ_25_1} + X_{IJ_25_2} + X_{IJ_25_3} + X_{IJ_26_1} + X_{IJ_26_2} + X_{IJ_26_3} + X_{IJ_27_1} + X_{IJ_27_2} + X_{IJ_27_3} + X_{IJ_30_1} + X_{IJ_30_2} + X_{IJ_30_3} + 5X_{IJ_41_1} + 5X_{IJ_41_2} + 5X_{IJ_41_3} \leq 5$$

b) Ano 2

$$\begin{aligned} \textcircled{1} & X_{IJ_2_4} + X_{IJ_2_5} + X_{IJ_3_4} + X_{IJ_3_5} + 3X_{IJ_1_4} + 3X_{IJ_1_5} \leq 3 \\ \textcircled{2} & X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_3_4} + X_{IJ_3_5} + X_{IJ_4_4} + X_{IJ_4_5} + 4X_{IJ_2_4} + 4X_{IJ_2_5} \leq 4 \\ & \vdots \\ \textcircled{32} & X_{IJ_5_4} + X_{IJ_5_5} + 2X_{IJ_43_1} + 2X_{IJ_43_2} \leq 2 \\ & \vdots \\ \text{c) Ano 7} \end{aligned}$$

$$\begin{aligned} \textcircled{1} & X_{IJ_2_2} + X_{IJ_2_4} + X_{IJ_3_2} + X_{IJ_3_4} + 3X_{IJ_1_2} + 3X_{IJ_1_4} \leq 3 \\ \textcircled{2} & X_{IJ_1_2} + X_{IJ_1_4} + X_{IJ_3_2} + X_{IJ_3_4} + X_{IJ_4_2} + X_{IJ_4_4} + 4X_{IJ_2_2} + 4X_{IJ_2_4} \leq 4 \\ & \vdots \\ \textcircled{41} & X_{IJ_45_3} + 2X_{IJ_51_3} \leq 2 \end{aligned}$$

Variáveis binárias:

$$X_{IJ} \in \{0,1\}, \forall_i, \forall_j$$

A formulação empregada nas metaheurísticas AG e SA seguiu a mesma lógica descrita anteriormente, porém foram introduzidas na função objetivo (7) duas penalidades, e assim transformado-a em uma nova função objetivo (13). A primeira penalidade está ligada à produção volumétrica, considerando para isso o valor de R\$500,00 para cada m³ de madeira desviada da meta volumétrica. A segunda penalidade foi introduzida na função objetivo para controlar a adjacência. Neste sentido, o valor desta penalidade foi estabelecido em R\$1.000.000,00 por corte de talhões adjacentes, no mesmo período de tempo. Desta maneira, a nova função objetivo assumiu a seguinte formulação:

$$\text{Maximizar } VPL = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} - \text{penalidade (VOL)} \sum_{k=1}^T D_k - \text{penalidade (URM)} \sum_{k=1}^T A_k \quad (13)$$

Onde:

Penalidade (VOL) - R\$500,00/m³ de madeira;

Penalidade (URM) - R\$1.000.000,00 por cortes de talhões adjacentes;

D - valor absoluto do desvio volumétrico de madeira (m³);

A - número de talhões vizinhos cortados no mesmo período de tempo;

k - período anual de tempo dentro do horizonte de planejamento;

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de

manejo j ;

T - período total de tempo de planejamento;

3.4.3 Casos 3 e 4

A formulação dos casos 3 e 4 seguiu os moldes descritos no caso 1, porém foram introduzidas as restrições de adjacência ARM. A grande dificuldade na construção das restrições de adjacência do tipo ARM se resume basicamente em estabelecer os grupos de talhões adjacente e relacionáveis para a colheita no mesmo período de tempo. Uma função recursiva (14) foi proposta por Murray (1999) para exemplificar a formulação matemática linear tradicional:

$$f_{it}(x) \leq A \quad \forall_{i,t} \quad (14)$$

Onde:

A - área máxima contígua permitida;

$f_{it}(x)$ - função recursiva que soma a área de todas as unidades de um grupo de talhões adjacentes, sempre associados a X_{it} (se $X_{it} = 1$);

t - determinado período de tempo dentro do horizonte de planejamento.

Entretanto, a equação matemática (15) apresentada por McDill et al. (2002) é que realmente pode ser utilizada para a construção das restrições de adjacência do tipo ARM, sendo a mesma equação empregada no presente estudo.

$$\sum_{U \in P_i} x_{Ut} \leq n_{P_i} - 1 \quad \forall_{P_i} \text{ e } t=1, 2, 3, \dots, T \quad (15)$$

Onde:

U - unidade de manejo ou talhão;

T - período de tempo;

x - variável binária {0,1} do modelo;

P_i - conjunto de talhões adjacentes, ou grupo;

n_{P_i} - número de talhões adjacentes presentes no conjunto, ou grupo;

Apesar da simplicidade da equação (15), esta operação se torna complicada devido ao elevado número de restrições que são construídas. Assim, o uso de um procedimento computacional se faz necessário para identificar todos os grupos de talhões adjacentes. Desta maneira, foi utilizada a lógica do *Path algorithm* desenvolvido por McDill et al. (2002), para

identificar e escrever estas restrições. A estrutura a seguir descreve este algoritmo:

- ① Inicie com um par de talhões adjacentes qualquer. Se o somatório em área exceder o máximo permitido, então escreva a restrição para este conjunto, e selecione outro par qualquer. Caso contrário, continue os passos;
- ② Selecione qualquer talhão adjacente ao grupo formado anteriormente, adicionando-o. Então, calcule a área acumulada;
- ③ Defina uma rede, baseada neste grupo, no qual um nó corresponde a cada talhão e um arco é gerado para conectá-los. Identifique cada possibilidade de gerar uma nova ligação, ao grupo já formado. A cada excedente de área acumulada formada, uma nova restrição é gerada. Verificando sempre o não fechamento do ciclo, ou seja, se um novo talhão adicionado não se encontra presente no grupo formado. A presença de múltiplas ramificações é comum, e deve ser seguida. Além disso, devem-se eliminar as restrições repetidas;
- ④ Se todos os grupos forem identificados e convertidos em restrições ARM, pare. Caso contrário, volte ao passo 2.

Sendo assim, conforme observado no caso 1, a sua formulação foi composta por: (16) função objetivo dimensionada para maximizar o valor presente líquido (VPL) da floresta; (17) restrição de integridade das unidades de manejo; (18) e (19) restrições de controle do fluxo de produção volumétrico de madeira; (20) restrição de adjacência do tipo ARM e (21) restrições binárias das variáveis de decisão do modelo. A representação matemática é descrita a seguir:

$$\text{Função Objetivo: Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} \quad (16)$$

Sujeito a

$$\sum_{j=1}^P x_{ij} \leq 1, \quad \forall_j, \forall_{i=1,2,\dots,M} \quad (17)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \geq L_{\text{inferior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,HP} \quad (18)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \leq L_{\text{superior}}, \quad \forall_i, \forall_j, \forall_{T=1,2,\dots,HP} \quad (19)$$

$$\sum_{i \in P_i} x_{ijT} \leq n_{P_i} - 1 \quad \forall_i, \forall_j, \forall_{P_i}, \forall_{T=1,2,\dots,HP} \quad (20)$$

$$x_{ij} \in \{0,1\} \quad \forall_i, \forall_j \quad (21)$$

Onde:

M - número total de talhões manejados;

P - número total de alternativas de manejo;

x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;

c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;

T - período total de tempo de planejamento;

v_{ij} - volume total produzido no talhão i pela alternativa de manejo j ;

k - talhão número;

P_i - conjunto de talhões adjacentes, ou grupo;

n_{pi} - número de talhões adjacentes presentes no conjunto, ou grupo;

Um exemplo resumido da formulação presente nos casos 3 e 4 é descrito a seguir, considerando um horizonte de planejamento de 7 anos:

A) Caso 3 (ARM 50)

Função objetivo:

$$\begin{aligned} \text{Max VPL} = & 299.106X_{IJ_1_1} + 346.765X_{IJ_1_2} + 157.814X_{IJ_1_3} + 348.226X_{IJ_1_4} + \\ & + 194.312X_{IJ_1_5} + 213.558X_{IJ_1_6} + 371.623X_{IJ_2_1} + 418.287X_{IJ_2_2} + 202.626X_{IJ_2_3} + \\ & + 416.661X_{IJ_2_4} + 237.629X_{IJ_2_5} + 254.355X_{IJ_2_6} + \dots + 40.067X_{IJ_52_1} + 56.010X_{IJ_52_2} + \\ & + 77.477X_{IJ_52_3} \end{aligned}$$

Restrições de integridade entre alternativas de manejo:

$$\textcircled{1} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_1_6} \leq 1$$

$$\textcircled{2} X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} + X_{IJ_2_4} + X_{IJ_2_5} + X_{IJ_2_6} \leq 1$$

⋮

$$\textcircled{52} X_{IJ_52_1} + X_{IJ_52_2} + X_{IJ_52_3} \leq 1$$

Restrições de limites de produção volumétrica de madeira:

A) Limite inferior

$$\textcircled{1} 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + \\ + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + \\ + 2.539,76X_{IJ_41_3} \geq 40.020$$

$$\textcircled{2} 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots +$$

$$+ 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \geq 40.020$$

$$\vdots$$

$$\textcircled{7} 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + \\ + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \geq 40.020$$

B) Limite superior

$$\textcircled{1} 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + \\ + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + \\ + 2.539,76X_{IJ_41_3} \leq 97.980$$

$$\textcircled{2} 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + \\ + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \leq 97.980$$

$$\vdots$$

$$\textcircled{7} 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + \\ + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \leq 97.980$$

Restrições de adjacência do tipo ARM 50:

a) Ano 1

$$\textcircled{1} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} \leq 1$$

$$\textcircled{2} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_3_1} + X_{IJ_3_2} + X_{IJ_3_3} \leq 1$$

$$\vdots$$

$$\textcircled{70} X_{IJ_27_1} + X_{IJ_27_2} + X_{IJ_27_3} + X_{IJ_28_1} + X_{IJ_28_2} + X_{IJ_28_3} + X_{IJ_41_1} + X_{IJ_41_2} + \\ + X_{IJ_41_3} \leq 2$$

b) Ano 2

$$\textcircled{1} X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_2_4} + X_{IJ_2_5} \leq 1$$

$$\textcircled{2} X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_3_4} + X_{IJ_3_5} \leq 1$$

$$\vdots$$

$$\textcircled{71} X_{IJ_27_4} + X_{IJ_27_5} + X_{IJ_28_4} + X_{IJ_28_5} + X_{IJ_41_4} + X_{IJ_41_5} \leq 2$$

$$\vdots$$

c) Ano 7

$$\textcircled{1} X_{IJ_1_2} + X_{IJ_1_4} + X_{IJ_2_2} + X_{IJ_2_4} \leq 1$$

$$\textcircled{2} X_{IJ_1_2} + X_{IJ_1_4} + X_{IJ_3_2} + X_{IJ_3_4} \leq 1$$

$$\vdots$$

$$\textcircled{77} X_{IJ_45_3} + X_{IJ_51_3} \leq 1$$

Variáveis binárias:

$$X_{IJ} \in \{0,1\}, \forall_i, \forall_j$$

B) Caso 4 (ARM 70)

Função objetivo:

$$\begin{aligned} \text{Max VPL} = & 299.106X_{IJ_1_1} + 346.765X_{IJ_1_2} + 157.814X_{IJ_1_3} + 348.226X_{IJ_1_4} + \\ & + 194.312X_{IJ_1_5} + 213.558X_{IJ_1_6} + 371.623X_{IJ_2_1} + 418.287X_{IJ_2_2} + 202.626X_{IJ_2_3} + \\ & + 416.661X_{IJ_2_4} + 237.629X_{IJ_2_5} + 254.355X_{IJ_2_6} + \dots + 40.067X_{IJ_52_1} + 56.010X_{IJ_52_2} + \\ & + 77.477X_{IJ_52_3} \end{aligned}$$

Restrições de integridade entre alternativas de manejo:

$$\textcircled{1} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_1_6} \leq 1$$

$$\textcircled{2} X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} + X_{IJ_2_4} + X_{IJ_2_5} + X_{IJ_2_6} \leq 1$$

⋮

$$\textcircled{52} X_{IJ_52_1} + X_{IJ_52_2} + X_{IJ_52_3} \leq 1$$

Restrições de limites de produção volumétrica de madeira:

A) Limite inferior

$$\textcircled{1} 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + \\ + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + \\ + 2.539,76X_{IJ_41_3} \geq 40.020$$

$$\textcircled{2} 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + \\ + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \geq 40.020$$

⋮

$$\textcircled{7} 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + \\ + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \geq 40.020$$

B) Limite superior

$$\textcircled{1} 8.288,93X_{IJ_1_1} + 8.288,93X_{IJ_1_2} + 8.288,93X_{IJ_1_3} + 9.392,31X_{IJ_2_1} + \\ + 9.392,31X_{IJ_2_2} + 9.392,31X_{IJ_2_3} + \dots + 2.539,76X_{IJ_41_1} + 2.539,76X_{IJ_41_2} + \\ + 2.539,76X_{IJ_41_3} \leq 97.980$$

$$\textcircled{2} 9.833,9X_{IJ_1_4} + 9.833,9X_{IJ_1_5} + 11.007,49X_{IJ_2_4} + 11.007,49X_{IJ_2_5} + \dots + \\ + 10.405,83X_{IJ_43_1} + 10.405,83X_{IJ_43_2} \leq 97.980$$

⋮

$$\textcircled{7} 9.833,9X_{IJ_1_2} + 8.288,93X_{IJ_1_4} + 11.007,49X_{IJ_2_2} + 9.392,31X_{IJ_2_4} + \dots + \\ + 8.805X_{IJ_51_3} + 7.596,34X_{IJ_52_3} \leq 97.980$$

Restrições de adjacência do tipo ARM 70:

a) Ano 1

$$\textcircled{1} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} \leq 1$$

$$\textcircled{2} X_{IJ_1_1} + X_{IJ_1_2} + X_{IJ_1_3} + X_{IJ_2_1} + X_{IJ_2_2} + X_{IJ_2_3} + X_{IJ_3_1} + X_{IJ_3_2} + \\ + X_{IJ_3_3} \leq 2$$

⋮

$$\textcircled{103} X_{IJ_28_1} + X_{IJ_28_2} + X_{IJ_28_3} + X_{IJ_29_1} + X_{IJ_29_2} + X_{IJ_29_3} + X_{IJ_30_1} + X_{IJ_30_2} +$$

$$+ X_{IJ_30_3} + X_{IJ_41_1} + X_{IJ_41_2} + X_{IJ_41_3} \leq 3$$

b) Ano 2

$$\textcircled{1} X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_2_4} + X_{IJ_2_5} \leq 1$$

$$\textcircled{2} X_{IJ_1_4} + X_{IJ_1_5} + X_{IJ_2_4} + X_{IJ_2_5} + X_{IJ_3_4} + X_{IJ_3_5} \leq 2$$

⋮

$$\textcircled{107} X_{IJ_28_4} + X_{IJ_28_5} + X_{IJ_29_4} + X_{IJ_29_5} + X_{IJ_30_4} + X_{IJ_30_5} + X_{IJ_41_4} + X_{IJ_41_5} \leq 3$$

⋮

c) Ano 7

$$\textcircled{1} X_{IJ_1_2} + X_{IJ_1_4} + X_{IJ_2_2} + X_{IJ_2_4} \leq 1$$

$$\textcircled{2} X_{IJ_1_2} + X_{IJ_1_4} + X_{IJ_2_2} + X_{IJ_2_4} + X_{IJ_3_2} + X_{IJ_3_4} \leq 2$$

⋮

$$\textcircled{111} X_{IJ_29_2} + X_{IJ_29_4} + X_{IJ_30_2} + X_{IJ_30_4} + X_{IJ_31_3} + X_{IJ_41_2} + X_{IJ_41_4} \leq 3$$

Variáveis binárias:

$$X_{IJ} \in \{0,1\}, \forall_i, \forall_j$$

A formulação empregada nas metaheurísticas AG e SA seguiu a mesma lógica descrita anteriormente, porém foram introduzidas duas penalidades na função objetivo (16) convertendo-a em uma nova função objetivo (22). A primeira referente à produção volumétrica, considerando o valor da penalidade de R\$500,00 para cada m³ de madeira desviada da meta volumétrica. A segunda penalidade foi introduzida na função objetivo para controlar a questão de adjacência do tipo ARM. Neste sentido, o valor desta penalidade foi estabelecido em R\$1.000.000,00/ha excedente do limite imposto pela adjacência, colhidos no mesmo período de tempo. Desta maneira, a nova função objetivo assumiu a seguinte formulação:

$$\text{Maximizar VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} - \text{penalidade (VOL)} \sum_{k=1}^T D_k - \text{penalidade (ARM)} \sum_{k=1}^T A_k \quad (22)$$

Onde:

Penalidade (VOL) - R\$500,00/m³ de desvio de madeira;

Penalidade (ARM) - R\$1.000.000,00/ha em área excedente ao limite 50 ha (caso 3) ou 70 ha (caso 4) aos grupos de talhões adjacentes formados;

D - valor absoluto do desvio volumétrico de madeira (m³);

A - número de talhões vizinhos cortados no mesmo período de tempo;

k - período anual de tempo dentro do horizonte de planejamento;

M - número total de talhões manejados;

- P - número total de alternativas de manejo;
- x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i e alternativa de manejo j ;
- c_{ij} - valor presente líquido pertencente ao talhão i segundo a alternativa de manejo j ;
- T - período total de tempo de planejamento;

3.5 IMPLEMENTAÇÃO COMPUTACIONAL E PROCESSAMENTO

A implementação da metaheurística foi desenvolvida utilizando a linguagem de programação *Visual Basic*[®] versão 6.0 *Enterprise* da *Microsoft*[®], licenciada para o PPGEF (Programa de Pós Graduação em Engenharia Florestal) da UFPR, criando-se então uma ferramenta para as análises denominada de *PCFLORESTAL*. O *PCFLORESTAL* é uma ferramenta desenvolvida no presente trabalho para otimizar o agendamento da colheita florestal via metaheurísticas (AG e SA), apresentando uma série de saídas gráficas e mapas para a colheita florestal. Além disso, possui diversas opções de AG e SA, responsáveis pelo processamento dos casos 1, 2, 3 e 4, abrangendo 32 cenários.

Os modelos matemáticos de PLI também foram escritos por esta ferramenta, porém o seu processamento foi realizado através do software LINGO 9.0 (*Language for Interactive General Optimizer*). Um critério de parada envolvendo tempo de processamento foi empregado para evitar processamentos muito longos. Segundo Carter *et al.* (1996) apud Mcdill e Braze (2001), modelos envolvendo restrições de adjacência podem consumir até dias de processamento, a depender de seu tamanho. Desta forma, um limite de 4 horas foi usado como critério de parada, sendo o mesmo valor empregado por Mcdill e Braze (2000) em problemas envolvendo as restrições de adjacência do tipo URM.

O processamento foi executado em um computador com processador *Celeron*[®] *core 2 duo* 2100 MHz e 2 Gb de RAM, abordando os 32 cenários e os 3 métodos de resolução. As metaheurísticas foram executadas em um total de 3 repetições por cenário, para garantir uma confiabilidade nas soluções.

4. RESULTADOS E DISCUSSÃO

4.1 A FLORESTA

As florestas submetidas para as análises foram consideradas maduras, uma vez que 65,32% da sua área continham talhões em idade de corte (idade ≥ 5 anos) e possíveis de agendamento já no primeiro ano de atividade florestal. Além disso, não foram observados talhões com idade de 2 anos, indicando um desbalanceamento da relação idade/área na floresta. O desbalanceamento encontrado exigiu um maior intervalo entre os limites de produção volumétrica durante a elaboração dos cenários. Na Tabela 12 observa-se a distribuição etária da floresta na área de estudo.

TABELA 12 - ESTRUTURA ETÁRIA DA FLORESTAL ESTUDADA.

Idade (anos)	Talhões		Área	
	Número	(%)	(ha)	(%)
1	9	17,30	233,65	15,68
2	0	0,00	0,00	0,00
3	6	11,54	242,58	16,27
4	1	1,92	40,78	2,73
5	25	48,08	629,40	42,22
6	11	21,16	344,29	23,10
Total	52	100,00	1490,70	100,00

No planejamento florestal é importante considerar o crescimento da floresta, durante os períodos de intervenção e administração da área. Assim, a partir do crescimento individual de cada talhão, foi definida a classificação da produtividade volumétrica em 3 classes, considerando uma idade de 6 anos como de referência e uma amplitude entre classes de 2 desvios padrão (Tabela 13).

TABELA 13 - CLASSIFICAÇÃO DA PRODUTIVIDADE VOLUMÉTRICA E SUA OCUPAÇÃO NOS TALHÕES.

Classe de Produção	LI	LS	Frequência	Ocupação (ha)	Ocupação (%)
1	323,78	373,89	5	85,8	5,76
2	273,68	323,78	39	1172,16	78,64
3	223,57	273,68	8	232,52	15,60

Onde: LI - limite inferior da classe e LS - limite superior da classe.

A ordenação decrescente dos talhões mais produtivos foi: 48, 12, 14, 24 e 41, já os menos produtivos ordenados em: 16, 26, 25, 39, 1, 22, 23 e 46. Estes 13 talhões apresentaram

um total de 318,32 ha ou apenas 21,36% de ocupação da floresta, reforçando a idéia de uma taxa de crescimento média semelhante na área. O Gráfico 27 apresenta o comportamento médio do crescimento da floresta, ao longo de seu período produtivo, notando ainda as curvas de IMA (incremento médio anual) e ICA (incremento corrente anual) para a floresta em geral, sem considerar as classes de produtividade volumétrica.

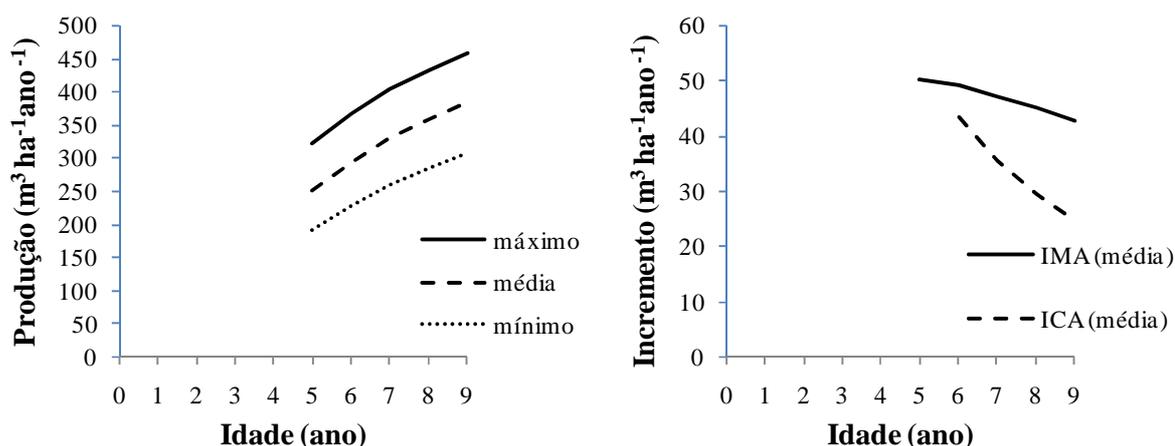


GRÁFICO 27 - COMPORTAMENTO VOLUMÉTRICO DA PRODUÇÃO E CRESCIMENTO DA FLORESTA A PARTIR DA IDADE DE 5 ANOS.

4.2 PLANEJAMENTO FLORESTAL

A simulação dos 32 cenários florestais mostrou que um problema considerado simples, a primeira vista, pode assumir um grau elevado de complexidade, na medida em que se aumenta o horizonte de planejamento de intervenção na floresta (Gráfico 28).

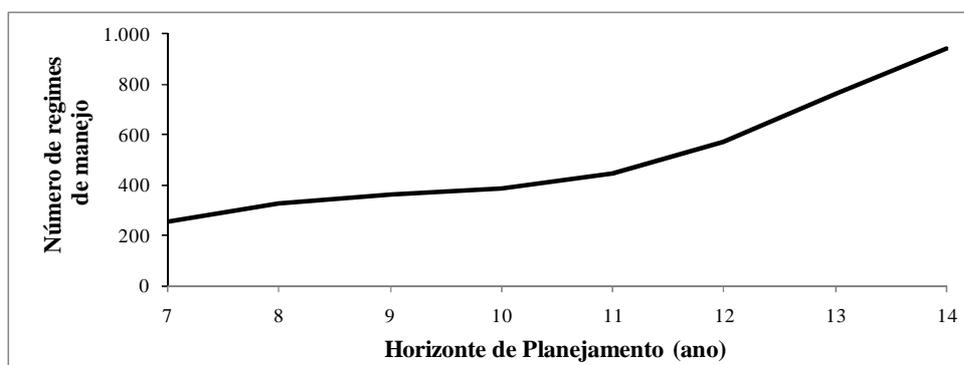


GRÁFICO 28 - NÚMERO DE ALTERNATIVAS DE MANEJO DISPONÍVEIS NO PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL COM O AUMENTO DO HORIZONTE DE PLANEJAMENTO.

A exemplo deste incremento observa-se um talhão com idade de 5 anos e um

horizonte de planejamento reduzido de 7 anos (cenário simples), este pode apresentar 6 alternativas de manejo segundo as restrições de colheita. Entretanto, ao considerar cenários mais avançados de tempo (HP=14 anos), o mesmo talhão pode assumir 23 opções de manejo, o que representa um incremento de 3,83 vezes o número inicial.

O aumento no número de alternativas de manejo dentro dos cenários com maiores horizontes de planejamentos também influenciou e impulsionou o número de restrições nos casos de PLI. Entretanto, esta marca é mais visível nos cenários envolvendo os casos 2, 3 e 4 (planejamento florestal espacial), frente aos observados para o caso 1 (planejamento florestal tradicional). A diferença no número de restrições entre estes dois tipos de abordagem de planejamento foi considerada alta, baseado nas observações realizadas entre os casos. A Tabela 14 mostra melhor esta relação, porém desprezando as restrições de integralidade, já que são constantes (52 restrições) em todos os cenários.

TABELA 14 - NÚMERO DE RESTRIÇÕES PRESENTES NO MODELO ABRANGENDO O PLANEJAMENTO FLORESTAL TRADICIONAL E O ESPACIAL NOS CASOS ESTUDADOS.

Horizonte de Planejamento	Ano	Casos													
		1		2		3		4							
		Vol	Vol	URM	Vol	ARM 50	Vol	ARM 70							
14	13	12	11	10	9	8	7	1	2	2	31	2	70	2	104
								2	2	2	32	2	71	2	107
								3	2	2	27	2	53	2	77
								4	2	2	5	2	3	2	3
								5	2	2	10	2	6	2	4
								6	2	2	39	2	76	2	108
								7	2	2	40	2	77	2	111
								8	2	2	37	2	82	2	126
								9	2	2	37	2	82	2	126
								10	2	2	35	2	58	2	80
								11	2	2	45	2	88	2	130
								12	2	2	45	2	88	2	130
								13	2	2	45	2	88	2	130
								14	2	2	45	2	88	2	130

Onde: Vol - restrições ligadas aos limites de produção volumétrica; URM- restrições de adjacência do tipo URM; ARM50 e ARM70- restrições de adjacência do tipo ARM;

No caso 1 (planejamento florestal tradicional) foram empregadas 66 restrições para um cenário com HP de 7 anos. Por outro lado, este mesmo cenário apresentou 250, 422 e 580 restrições quando utilizados os casos 2, 3 e 4, respectivamente. Assim, ao ampliar esta comparação para um cenário mais complexo, ou seja, um HP de 14 anos, os mesmos casos apresentaram os seguintes números de restrições: 80 (caso 1), 553 (caso 2), 1.010 (caso 3) e 1.446 (caso 4), comprovando o incremento no número de restrições.

Os casos de PLI que apresentaram restrições de adjacência pelo conceito ARM (casos 3 e 4) foram considerados os mais complexos entre os cenários, tanto na sua formulação, quanto no número de restrições. O aumento em seu limite de área, de 50 ha para 70 ha, também influenciou na expansão de combinações entre talhões adjacentes, acarretando no incremento dos grupos formados. O incremento foi de 30,15% em relação ao número de restrições, para o cenário com HP de 14 anos. Assim, ao aumentar o limite de área nas restrições ARM, produz-se um maior número de grupos de talhões adjacentes, impactando negativamente no número de restrições do modelo de programação. Além disso, o mesmo efeito pode ser observado caso os talhões apresentem uma área reduzida em relação ao limite máximo de área. No estudo desenvolvido por McDill *et al.* (2002) as restrições de adjacência do tipo ARM também apresentaram um maior número frente às restrições do tipo URM.

A identificação e enumeração das restrições de adjacência não foi um entrave para as metaheurísticas, pois não havia a necessidade destas etapas nos métodos, uma vez que para cada solução, uma nova combinação de alternativa de manejo é sugerida e analisada para o agendamento da colheita florestal.

A complexidade dos modelos de PLI ligados às restrições espaciais (casos 2, 3 e 4) podem inviabilizar o uso desta técnica, pois o problema pode se tornar de grande magnitude em número de restrições. Além disso, os problemas de agendamento da colheita florestal envolvendo restrições de adjacência são classificados como *NP-Hard*. Este tipo de abordagem considera a não existência de um método capaz de gerar uma solução ótima global em um tempo viável de espera. Zhu *et al.* (2007) comentam que o planejamento florestal envolvendo problemas de otimização combinatória, usualmente ganham complexidade com o aumento do tamanho do problema, uma vez que geralmente este efeito ocorre de forma não linear, conforme observado no presente estudo.

O grau de complexidade pode ser observado no exemplo a seguir, quando retratada a questão do número de restrições do modelo de PLI. Considere o agendamento da colheita florestal para três florestas similares à estudada, tanto em número de talhões (52) como em crescimento e distribuição da vizinhança, sendo ainda as mesmas desconectadas entre si. Desta maneira, a nova área hipotética a ser planejada apresenta 156 talhões distribuídos em aproximadamente 4.471 ha. Assim, na construção do modelo de PLI para os 4 casos analisados percebe-se que no caso 1 (planejamento florestal tradicional) o número de restrições aumenta em escalas reduzidas e de forma linear, sendo o aumento definido pelo surgimento de 2 novas restrições ligadas ao fluxo de produção volumétrica (limite máximo e

mínimo) a cada alteração do HP. Contudo, nos casos 2, 3 e 4 (planejamento florestal espacial) há um aumento não linear e acelerado no número de restrições.

O Gráfico 29 apresenta a ampliação da floresta partindo do seu estado original chegando a um tamanho de 6 vezes a sua estrutura.

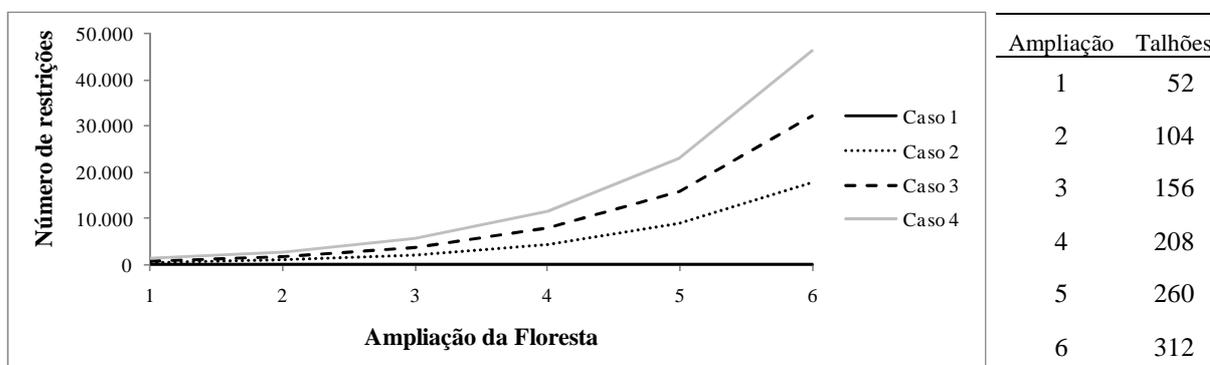


GRÁFICO 29 - EXEMPLO DE AMPLIAÇÃO DA FLORESTA CONSIDERANDO SEUS IMPACTOS NO NÚMERO DE RESTRIÇÕES DO MODELO DE PLI.

De acordo com McDill *et al.* (2002), o tamanho e a complexidade dos modelos envolvendo o uso de restrições de adjacência ARM aumentam a medida em que são disponibilizados novos talhões para a colheita, no mesmo período de tempo.

O número de variáveis de decisão do modelo para os 4 casos também aumentou com a ampliação dos horizontes de planejamento nos cenários. Contudo, o tipo abordagem de planejamento (tradicional x espacial) adotado não representou mudanças em suas estruturas, conforme esperado (Tabela 15). As variáveis de decisão estão ligadas diretamente as opções de manejo prescritas para a área, sendo estas desconectadas dos processos de adjacência entre talhões vizinhos (restrições URM) ou formação de grupos de talhões adjacentes (restrições ARM).

TABELA 15 - NÚMERO DE VARIÁVEIS DE DECISÃO PRESENTES NO MODELO DE PLI CONSIDERANDO O PLANEJAMENTO FLORESTAL TRADICIONAL E O ESPACIAL.

Caso	Horizonte de Planejamento (ano)							
	7	8	9	10	11	12	13	14
1	254	323	362	384	444	571	758	939
2	254	323	362	384	444	571	758	939
3	254	323	362	384	444	571	758	939
4	254	323	362	384	444	571	758	939

Na situação do caso 1 percebeu-se que o limite de tempo imposto (4 horas) foi insuficiente na grande maioria de seus cenários, para se chegar a soluções ótimas globais.

Sendo assim, as comparações entre o planejamento florestal espacial (casos 2, 3 e 4) e o tradicional (caso 1) se restringiram aos cenários com um HP de 7 anos. No total de 32 cenários estudados, apenas 15 obtiveram sucesso da análise antes do prazo proposto, destacando o caso 3. McDill e Braze (2000) encontraram os mesmos problemas envolvendo tempo de processamento, quando comparavam três maneiras de se formular as restrições do tipo URM em vários cenários. Os mesmos autores comentam que problemas desta natureza podem ser de fácil resolução ou o contrário, não sendo possível a explicação deste efeito, pois a solução pode estar já na primeira ramificação ou na última.

Na Tabela 16 são apresentadas informações sobre o *status* do algoritmo *branch-and-bound*, onde valores iguais a zero indicam que o ótimo foi alcançado antes do limite de tempo estabelecido (4 horas). Além disso, os demais valores indicam o número de *branches* abertos, ou ramificações de busca por soluções inteiras. Nos ANEXOS de 6 a 13 são apresentadas as janelas de *status* de processamento do LINGO, que completam estas informações.

TABELA 16 - NÚMERO DE RAMIFICAÇÕES GERADAS PELO ALGORITMO *BRANCH-AND-BOUND* ATÉ 4 HORAS DE PROCESSAMENTO NO SOFTWARE LINGO.

Caso	Horizonte de planejamento							
	7	8	9	10	11	12	13	14
1	0	49.000	46.926	46.652	49.756	49.496	49.298	49.947
2	0	0	0	0	46.951	30.069	49.741	48.383
3	0	0	0	0	0	47.185	0	48.610
4	0	0	0	49.173	0	48.773	49.480	46.329

A maior disposição de talhões destinados à colheita florestal já nos primeiros anos de planejamento indica uma floresta madura do ponto de vista da idade e produção. Este mesmo tipo cenário foi estudado por McDill e Braze (2000) e considerou o uso das restrições de adjacência URM. Os autores constataram uma forte correlação entre a presença de floresta madura e a dificuldade de resolução pelo algoritmo *branch-and-bound*.

O tempo de processamento dos 32 cenários, a partir da PLI, pode ser observado melhor através do Gráfico 30. Neste ponto fica claro que o número de restrições pode não afetar o tempo de processamento via PLI, em algumas situações. Entretanto, segundo McDill *et al.* (2002) o tamanho dos modelos geralmente influencia neste aspecto. E ainda segundo os autores, os modelos envolvendo as restrições do tipo ARM são mais dispendiosos de tempo que os do tipo URM. Esta tendência foi observada nos cenários compostos por horizontes de planejamento de 7, 8 e 10 anos. O caso 1 considerado o mais simples foi o mais exigente em tempo de processamento e, uma possível resposta para o fato está no maior número de

soluções inteiras factíveis e próximas, uma vez que reduzidas melhoras proporcionam um aumento na busca do algoritmo *branch-and-bound*.

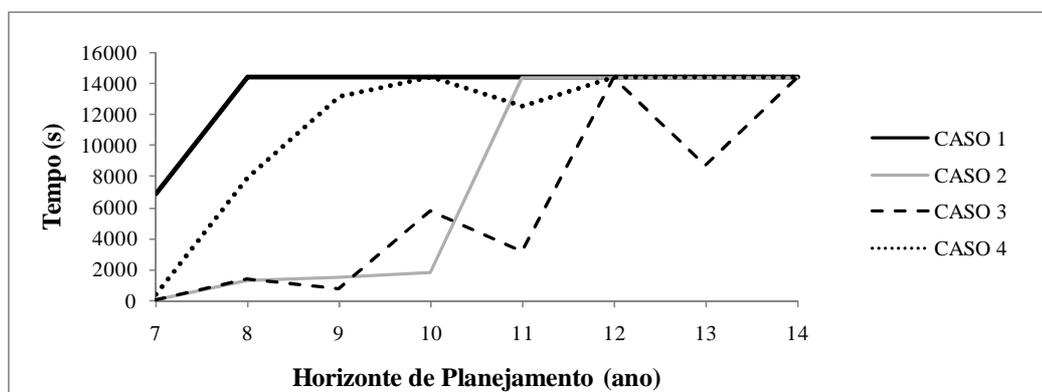


GRÁFICO 30 - TEMPO DE PROCESSAMENTO DOS CASOS ESTUDADOS CONSIDERANDO UM LIMITE DE 4 HORAS DE EXECUÇÃO.

A curva de tempo nos cenários do caso 4 foi a que mais se aproximou do caso 1, exatamente por ser mais flexível na questão da adjacência. Os casos 2 e 3, por outro lado, tiveram respostas de tempo semelhantes entre si, talvez por possuírem maior rigidez nas suas restrições espaciais. Nos cenários com HP de 7, 8 e 9 anos (mais simples) retratados via planejamento florestal espacial (casos 2, 3 e 4), a questão tempo não foi considerada um problema pois seus ótimos foram obtidos antes do critério de parada de 4 horas. Entretanto, esta demanda aumentou de forma rápida e não linear à medida que o problema ganhou complexidade. Exemplificando esta tendência através do caso 4, percebeu-se que o tempo de processamento passou de 376 segundos para 13.117 segundos, ao variar o HP de 7 a 9 anos. Este fato comprova o esforço computacional exigido ao se realizar pequenas alterações no cenário.

Alonso (2003) aplicou as restrições URM em 5 cenários florestais simulados de Pinus, com o propósito de maximizar a receita e suprir a demanda dos produtos gerados e, assim, os tempos de processamento via PLI foram de 23 segundos (15 talhões e HP de 10 anos), 7 segundos (25 talhões e HP 15), 4 segundos (32 talhões e HP de 15 anos) e 6 segundos (50 talhões e HP de 30 anos). A velocidade na resolução foi devido à simplicidade dos problemas formulados.

O valor do VPL foi influenciado pelo tipo de abordagem de planejamento executado, no qual reduções de seus valores podem ser percebidas à medida que o modelo se torna mais restritivo à questão da adjacência, tendo como referência apenas as soluções ótimas geradas na PLI. Uma comparação mais completa desta análise só foi possível considerando um cenário mais reduzido (HP de 7 anos), pois a natureza do problema demonstra a exigência de

um tempo computacional de processamento maior que 4 horas, por ser classificado como *NP-Hard*.

Assim, o desvio percentual de perda do VPL ao utilizar o modelo de planejamento florestal espacial (casos 2, 3 e 4) ficou abaixo de 4%, ou de forma mais detalhada: 3,74% (caso 2), 2,24% (caso 3) e 2,10% (caso 4). Entretanto, vale lembrar que esta tendência encontrada não é uma regra geral, pois seus resultados são dependentes do tipo de relações espaciais de adjacência existente em cada área.

Zhu *et al.* (2007) testaram o uso das metaheurísticas busca tabu, *threshold accepting* e *raindrop method* na resolução de uma série de problemas envolvendo a restrição ARM, cujo limite máximo de área foi 97 ha. O melhor método encontrado por eles foi *raindrop method*, e o custo real destas restrições variou de 0,5 a 3,0% definido pelo ótimo global. No presente estudo, estes valores foram 2,24% (ARM50) e 2,10% (ARM70) ficando dentro dos limites mencionados anteriormente.

Hoganson e Borges (1999) constataram uma redução na produção volumétrica e no VPL contendo as restrições de adjacência (URM) para o agendamento da colheita florestal, considerando o uso de PLI. Nos 4 cenários estudados pelos autores, a perda final no VPL chegou a 1,3%, 1,4%, 1,5% e 1,7%, referente à introdução destas restrições em cada década do HP. Os menores valores de perda encontrados estão vinculados à presença de períodos dentro do HP, no qual foi permitida a colheita de talhões adjacentes, fato não ocorrido no presente estudo. McDill *et al.* (2002) comentam que os modelos formulados com restrições do tipo ARM geram os maiores valores nas funções de lucro, quando comparado com restrições do tipo URM. O mesmo resultado foi encontrado no presente estudo.

Carter *et al.* (1997), estudando os efeitos das restrições de adjacência (URM) nos modelos de planejamento florestal, constataram reduções de seus valores de VPL quando aplicados em uma área natural de Pinus, localizada na Flórida (EUA) e composta por 937 talhões. As reduções apresentadas foram na ordem de 18,1% a 36,6%, a depender do cenário estabelecido, afetando também a produção volumétrica de madeira. Segundo os autores, a explicação para uma redução desta magnitude foi relacionada à maior conexão entre talhões na vizinhança, ou seja, uma elevada interação espacial entre os talhões adjacentes. A confirmação desta afirmativa está no número de violações da adjacência (723 ocorrências) pelo modelo sem o uso desta restrição.

Alonso (2003) encontrou um custo de se aplicar a restrição URM na casa dos 2% em uma floresta hipotética de Pinus composta de 15 talhões, já em uma floresta de Eucalipto

dividida em 105 talhões o desvio foi de 6,57% no trabalho de Castro (2006).

A redução dos impactos ocasionados pelas restrições de adjacência (URM) pode ser mitigada da seguinte maneira: estipular uma regra na formulação dos modelos de planejamento, no qual os talhões com maior área tenham preferência na seleção; permitir um limite mínimo de violação desta restrição; e alterar a estrutura de vizinhança entre os talhões (NELSON, 2000). Entretanto, uma medida possível de se aplicar condiz com o uso de formulações matemáticas similares aos casos 3 e 4, testados no presente estudo.

O Gráfico 31 apresenta o comportamento dos desvios de VPL entre os casos 2, 3 e 4 frente ao caso 1. Estas diferenças encontradas flutuam através dos horizontes de planejamento, entre os cenários propostos. Porém, deve-se ressaltar que soluções ótimas só foram obtidas para o cenário com um HP de 7 anos no caso1 (testemunha). Contudo, apesar de não haver atingido o ótimo nos outros cenários pelo critério de parada utilizado (4 horas), estes resultados servem de indicativos de comparação. No ANEXO 14 encontram-se todos os valores absolutos de VPL calculados pela PLI para os 32 cenários.

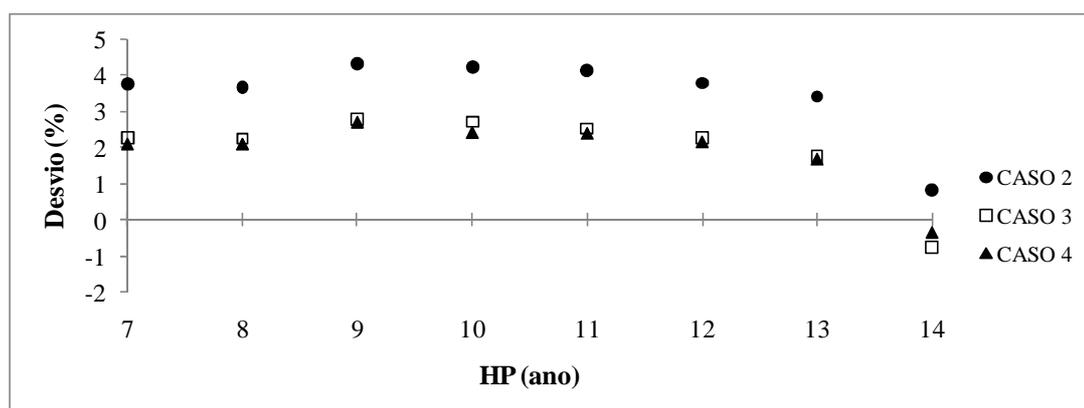


GRÁFICO 31 - DESVIO PERCENTUAL DO VPL ENTRE O PLANEJAMENTO FLORESTAL TRADICIONAL (CASO 1) E O PLANEJAMENTO FLORESTAL ESPACIAL (CASOS 2, 3 E 4).

Assim, o caso 1 obteve a maior expressão do VPL ao se comparar com os demais, por não possuir restrições espaciais de adjacência. A única exceção foi observada no cenário com um HP de 14 anos; porém, pelo limite de tempo de processamento (4 horas), seus resultados não podem ser considerados estáticos e definitivos. Além disso, analisando melhor as informações deste processamento, a ramificação de busca do algoritmo *branch-and-bound* examinou soluções inteiras com valores superiores aos demais casos, criando uma expectativa positiva de sua melhora (ANEXO 13-a).

As perdas volumétricas totais observadas nos cenários com um HP de 7 ficaram abaixo de 3%, envolvendo a comparação entre planejamento florestal espacial e o tradicional.

Os valores absolutos da produção volumétrica foram: 614.919,46m³ (caso 1), 596.964,4 m³ (caso 2), 603.937,3m³ (caso 3) e 604.279,2m³ (caso 4), ou em termos percentuais de 2,92% (caso 2), 1,79% (caso 3) e 1,73% (caso 4) de desvio volumétrico frente ao caso 1.

MARIANOV *et. al* (2004) estudaram uma floresta hipotética composta por 144 grids, adotando a programação multi-objetivo com o propósito de maximizar a produção volumétrica e a preservação de espécies. Nesse estudo, a redução volumétrica de madeira chegou a 38% quando introduzidas restrições de adjacência, em virtude da forte interação entre vizinhanças.

O problema de tempo de processamento foi menor para as metaheurísticas AG e SA, quando comparado com a PLI. A utilização destes métodos aproximativos de processamento demonstrou ser capaz de obter respostas factíveis na maioria dos 32 cenários, em tempos razoáveis de espera.

Bettinger *et al.* (1999) formularam um modelo composto por restrições de adjacência URM e de controle do fluxo de produção de madeira/período, com o propósito de maximizar a produção volumétrica de madeira, a partir da PL relaxada, PLI e busca tabu. A área de estudo dos autores abrangiam duas florestas de Douglas-fir (*Pseudotsuga menziesii*) com 40 e 700 talhões nos EUA. No estudo dos autores, a floresta composta por 40 talhões obteve um ótimo global via PL relaxada em 9 segundos e uma média de 6,5 minutos para a metaheurística. Entretanto, utilizando a PLI não foi possível obter o ótimo global até o limite de 5 horas, e sim uma solução factível. No caso da floresta com 700 talhões, outro cenário desenvolvido pelos autores, não foi possível encontrar uma solução factível via PLI, porém pela metaheurística esta operação obteve sucesso em 215 minutos, indicando uma solução factível.

O tempo de processamento é uma importante variável para qualificar o uso de um determinado método de resolução em problemas de planejamento florestal. Entretanto, há ainda a necessidade de se conhecer a eficácia do método em suprir as metas estabelecidas para o problema. A Tabela 17 apresenta a eficácia do AG em suprir as metas dos 32 cenários, considerando as 3 repetições executadas.

O AG foi eficiente na geração de soluções factíveis, principalmente para os cenários englobando o caso 3, o qual apresentou 23 soluções factíveis, contra 1 sem atender a meta volumétrica. Uma situação semelhante foi observada no cenário envolvendo o caso 1, no qual 20 soluções factíveis foram encontradas, contra 4 soluções sem atender a meta volumétrica. Porém, para os casos 2 e 4 sua habilidade em encontrar soluções factíveis ficou abaixo dos

demais, a ponto de ocorrer 2 cenários sem respostas (caso 2: HP=11 e caso 4: HP=12).

TABELA 17 - EFICÁCIA DO ALGORITMO GENÉTICO EM ATENDER AS METAS NO PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL.

Caso	Repetição	Horizonte de Planejamento							
		7	8	9	10	11	12	13	14
1	1	v	v	v	v	v	v	n	v
	2	v	v	v	v	v	v	v	n
	3	v	v	v	n	v	v	n	v
2	1	v + a	v + a	v + a	v	a	v + a	v + a	v
	2	v + a	v + a	v + a	v	v	v + a	v + a	v + a
	3	v	v	v + a	v + a	v	v + a	a	v
3	1	v + a	v + a	v + a	v + a	v + a	v + a	a	v + a
	2	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
	3	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
4	1	v	v + a	v	v + a	v + a	v	v	v + a
	2	a	v	v	v	v + a	v	v + a	v
	3	v + a	v + a	v + a	v + a	v	v	v + a	v + a

Onde: v- meta volumétrica alcançada; a- meta da adjacência respeitada, n- nenhuma delas.

A presença de cenários com metas não atendidas indica a necessidade de aumento no número de repetições e/ou alterações na configuração do AG, e não incapacidade do método. Assim, como exemplo tem-se o caso 2 no cenário com HP de 11 anos, onde não foi encontrada uma solução factível que respeitasse as metas volumétricas e de adjacência (URM) simultaneamente. Entretanto, em cenários mais complexos e com um horizonte de planejamento superior (12, 13 e 14) foram encontradas soluções factíveis em pelo menos uma repetição para o caso 2. O mesmo foi observado no caso 4 envolvendo os cenários com HP de 13 e 14 anos.

Os resultados mostram que a meta de adjacência foi a mais difícil de ser cumprida pelo AG em relação à meta de produção volumétrica. Além disso, as imposições ligadas à adjacência URM apresentaram um grau mais elevado de dificuldade, quando comparadas com as restrições ARM, principalmente ao analisar os resultados do caso 3 (ARM 50). Porém, o contrário ocorreu entre o caso 4 (ARM70) e caso 2 (URM). Assim, o número de iterações realizadas pelo AG nos cenários estudados reforça a idéia de graus diferentes de complexidade das metas, uma vez que o caso 2 foi o que exigiu um número médio maior de iterações em todos os cenários (Tabela 18). Entretanto, uma explicação para este comportamento está na configuração do AG para o caso 2, onde as estratégias *steady state* e *crossover* foram configuradas para a realização de buscas mais conservadoras no espaço de soluções, resultando em acréscimos de iterações no final do processo. Uma explicação complementar sobre a variação dos resultados está na qualidade das soluções iniciais geradas

pelo algoritmo e, programadas para serem geradas randomicamente sem analisar o seu valor. A qualidade desta solução inicial contribui ainda para a velocidade de convergência do algoritmo. Os cálculos médios da Tabela 18 foram baseados nas três repetições de processamento, dos quais não foram excluídas as soluções inactíveis via PLI.

TABELA 18 - COMPORTAMENTO MÉDIO DO NÚMERO DE ITERAÇÕES E DO TEMPO DE PROCESSAMENTO AO LONGO DOS CENÁRIOS PROCESSADOS PELO ALGORITMO GENÉTICO.

Caso	Variável	Horizonte de Planeamento							
		7	8	9	10	11	12	13	14
1	Iteração	1.105	1.604	1.994	967	1.208	1.669	1.062	2.603
	Tempo (s)	188,0	367,3	503,0	269,0	299,7	535,3	369,0	976,7
2	Iteração	1.976	1.881	2.183	2.194	2.526*	2.413	3.508	2.807
	Tempo (s)	190,0	205,3	261,0	319,3	364,7*	362,0	585,3	363,7
3	Iteração	1.078	1.549	1.867	1.948	1.160	1.530	1.299	2.488
	Tempo (s)	241,0	389,0	513,7	584,0	468,7	622,3	572,0	1154,3
4	Iteração	987	1.417	2.020	1.080	1.273	1.561*	1.629	2.216
	Tempo (s)	221,7	356,0	561,0	342,3	481,7	639,3*	723,7	1053,7

Onde: (*) - cenários sem soluções factíveis do ponto de vista da PLI.

O consumo do tempo de processamento não está correlacionado diretamente com o número de iterações, uma vez que o caso 2 necessitou do menor consumo desta variável, quando comparado com os casos 3 e 4. Estes casos exigiram maior tempo de processamento, uma vez que a dificuldade na formulação das restrições ARM via PLI foi transferida para a identificação dos grupos de talhões adjacentes a cada mudança da solução pelo AG. As operações desta natureza podem ser consideradas complexas, exigindo rotinas computacionais mais elaboradas do que aquelas presentes nas restrições URM.

O tempo de processamento do AG foi inferior ao exigido na PLI, para a maioria dos casos, ocorrendo apenas 2 exceções nos cenários ligados aos casos 2 e 3, e um horizonte de planeamento de 7 anos. O tempo reduzido na PLI para o caso 2 foi compatível com o trabalho de Alonso (2003), sendo um exemplo considerado simples segundo o autor.

Quando todas as metas são cumpridas na solução encontrada, a penalidade (volume e/ou adjacência) existente na função deixa de exercer pressão negativa. Desta forma, o valor de *fitness* se iguala ao encontrado no VPL e então surge uma solução factível para o problema. Porém, quando este efeito não ocorre, surgem soluções inactíveis segundo a lógica da PLI (ANEXO 15). Os maiores valores de *fitness* foram preservados, indicando que estes representam as soluções para os respectivos cenários de agendamento da colheita florestal.

Analisando o comportamento da metaheurística SA na resolução dos cenários, notou-se que sua habilidade em encontrar soluções factíveis foi elevada, atingindo um nível de

93,75% que inclui todas as 96 repetições realizadas (Tabela 19). Segundo Murray e Church (1995), o sucesso e a qualidade da solução final produzida pelas metaheurísticas dependem principalmente das pesquisas em soluções factíveis durante o processamento.

TABELA 19 - EFICÁCIA DA METAHEURÍSTICA *SIMULATED ANNEALING* EM ATENDER AS METAS NO PROBLEMA DE AGENDAMENTO DA COLHEITA FLORESTAL.

Caso	Repetição	Horizonte de Planejamento							
		7	8	9	10	11	12	13	14
1	1	v	v	n	v	v	v	v	v
	2	v	v	v	v	v	v	v	n
	3	v	v	v	v	v	v	v	v
2	1	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
	2	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
	3	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
3	1	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
	2	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
	3	v + a	v + a	v + a	v + a	v + a	v + a	v + a	v + a
4	1	v + a	v + a	v + a	v + a	v + a	v + a	v	v + a
	2	v + a	v + a	v + a	v	v + a	v + a	v + a	v + a
	3	v + a	v	v + a	v + a	v + a	v + a	v + a	v

Onde: v- meta volumétrica alcançada; a- meta da adjacência respeitada, n- nenhuma delas.

Nos EUA, Lockwood e Moore (1993) utilizaram restrições espaciais no agendamento da colheita florestal em uma área natural de black spruce (*Picea mariana*) com 240.000 ha. Os autores simularam 18 cenários florestais e concluíram que a metaheurística SA foi capaz de gerar soluções factíveis em praticamente todos os cenários, a exceção de um único caso. No presente estudo, a SA foi superior em relação ao AG em 42,71% e, seus pontos falhos se encontraram apenas nas metas presentes nos casos 1 e 4, distribuídos ao longo dos horizontes de planejamento. As metas presentes nos casos 2 e 3 foram consideradas as que atingiram os maiores valores percentuais de sucesso, para a SA. Os problemas de adjacência do tipo URM não foram definidos como complicados, assim como ocorrido no AG, pois foram respeitados em 100% dos cenários. Uma das hipóteses é pelo fato do método SA trabalhar de forma mais intensa a vizinhança de soluções candidatas ao problema. A mesma idéia sobre a SA pode ser encontrada em Baskent e Jordan (2002).

A adjacência envolvendo a restrição ARM 70 (caso 4) foi a situação mais difícil de ser respeitada pelas metaheurísticas, devido ao limite de área imposto. Analisando melhor o caso, percebeu-se que existe uma “armadilha” combinatória para o problema ou um ponto de estagnação nas buscas. Esta região compreende um conjunto de talhões (38 e 39), onde o

valor de área soma 70,05 ha e que excedem o limite de 70 ha, porém bem próximo do limite estabelecido. E quando os algoritmos passam por este local, dificilmente conseguem escapar deste baixo ótimo local. Além disso, suas contribuições para a produção volumétrica são importantes, pois pertencem à classe de produção 1 (talhão 39) e 2 (talhão 38), aliado ao tamanho de suas áreas.

A modificação no valor da penalidade para a restrição ARM 70 (caso 4) em valores superiores a R\$1.000.000/área excedente, a partir de testes paralelos ao estudo, mostrou uma melhora no suprimento desta meta. Contudo, a questão de produção volumétrica do cenário foi prejudicada, devido a maior presença de talhões ociosos. Estes talhões são formados para evitar uma maior redução na função objetivo, já que a penalidade relacionada à adjacência passou a pesar mais na função. Desta maneira, alterações nas penalidades devem ser analisadas de forma criteriosa.

Na Tabela 20 são observados os tempos médio de processamento da metaheurística SA proveniente das 3 repetições realizadas. Estes dados mostram que as restrições do tipo ARM foram definidas como as mais complexas de execução, exigindo um maior tempo de processamento. Um ponto importante para o incremento dos cálculos está na variação do horizonte de planejamento, uma vez que aumentos nesta variável refletiram em maiores VPL (ANEXO 16) e tempos de processamento. Nos ANEXOS 17 e 18 encontra-se um exemplo gráfico de funcionamento das buscas realizadas pelo AG e SA.

TABELA 20 - TEMPO MÉDIO EM SEGUNDOS REQUERIDO PARA A OBTENÇÃO DE SOLUÇÕES VIA METAHEURÍSTICA *SIMULATED ANNEALING*.

Caso	Horizonte de Planejamento							
	7	8	9	10	11	12	13	14
1	29,7	30,3	34,0	38,0	40,0	44,0	47,7	49,3
2	34,0	37,0	40,3	43,3	46,7	51,3	55,3	58,0
3	37,7	41,7	46,7	50,3	57,0	60,7	66,3	70,7
4	37,3	41,7	46,7	51,7	54,3	63,0	68,0	70,7

As soluções encontradas pelas metaheurísticas, além de atingir as metas impostas, devem garantir resultados de VPL próximos dos valores exatos (PLI) no problema estudado. Os desvios entre estes valores exatos e os provindos de aproximação, caso existam, devem enquadrar-se em limites aceitáveis aos problemas de otimização florestal. Além disso, comparando as soluções factíveis obtidas pelo AG e SA com a PLI (testemunha) observou-se que os maiores desvios de VPL representam os casos mais difíceis de serem resolvidos pelas metaheurísticas. O Gráfico 32 dispõe os desvios percentuais de VPL nos 32 cenários, considerando as soluções ótimas (*) e factíveis até 4 horas de processamento via PLI.

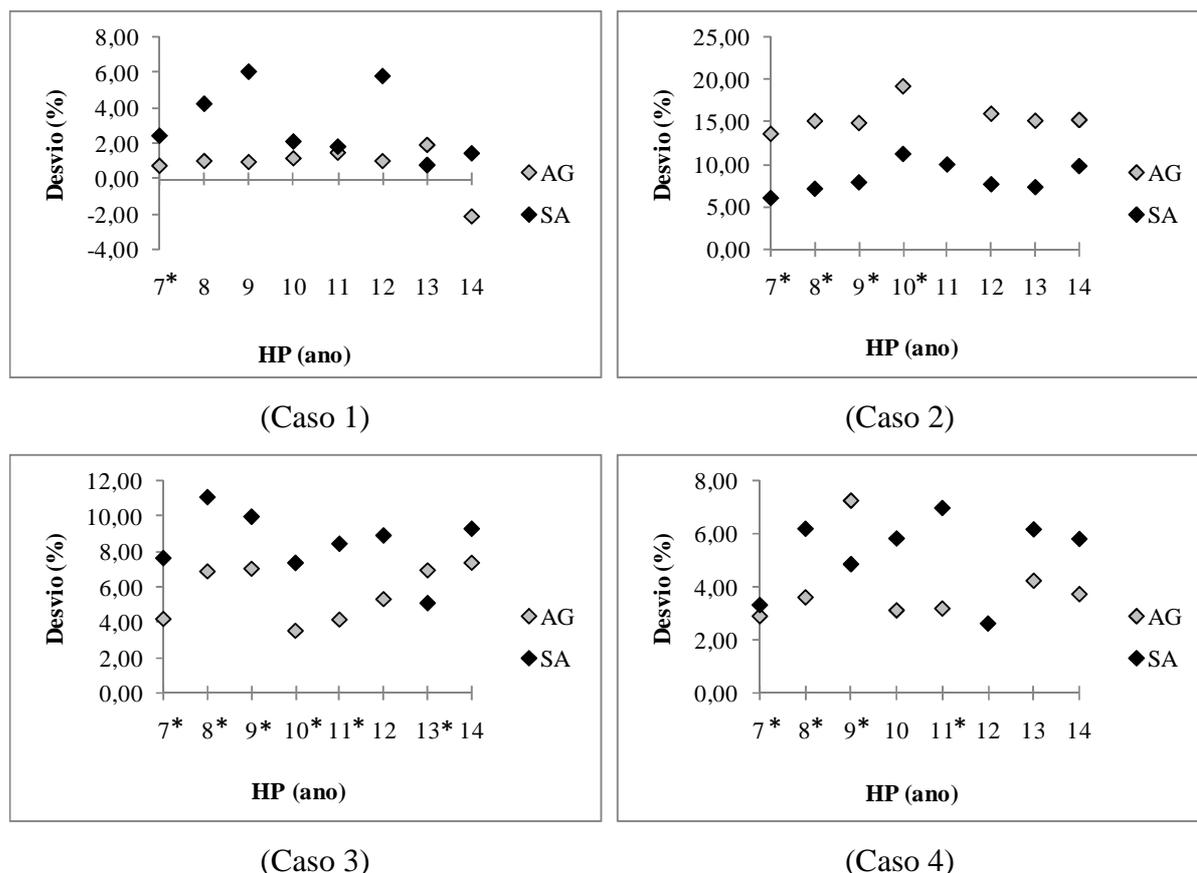


GRÁFICO 32 - DESVIO PERCENTUAL DO VPL ENTRE OS MÉTODOS DE APROXIMAÇÃO E O EXATO AO LONGO DO HP.

As melhores soluções obtidas em cada repetição (AG e SA) foram empregadas como critério de comparação, sendo descartadas as respostas via AG para o caso 2 (cenário com HP de 11 anos) e caso 4 (cenário com HP de 12 anos), por deixarem de atender as metas impostas antes do critério de parada, que foi de 500 iterações sem alteração do *fitness* (ANEXOS 15 e 16). Analisando os resultados notou-se que o AG foi superior a SA de um modo geral, exatamente por apresentar os menores desvios percentuais frente à PLI. A única exceção desta tendência foi encontrada no caso 2, que envolvia a restrição de adjacência do tipo URM. Estes dados demonstram que apesar da metaheurística SA ser mais eficiente que o AG na produção de soluções factíveis para o estudo, suas soluções apresentaram uma qualidade inferior ou baixa eficácia. Neste aspecto, suas soluções foram superiores em apenas 37,50% dos cenários, em relação às encontradas pelo AG.

O AG foi superior a PLI apenas no caso 1 envolvendo um cenário com HP de 14 anos. O mesmo problema foi observado por Bettinger *et al.* (1999) na resolução de modelos envolvendo restrições de adjacência, no qual a solução gerada pela metaheurística busca tabu superou a PLI, em um dos cenários formulados. Este fenômeno explica-se devido a PLI não

ter atingido o ótimo global, em ambos os casos.

Boston e Bettinger (2001) avaliaram o impacto econômico do uso de restrições de adjacência, a partir das metaheurísticas busca tabu e um híbrido composto de 5 componentes incluindo o algoritmo de Monte-Carlo, busca tabu *1-opt*, busca tabu *2-opt*, diversificação das soluções e AG (*crossover*). O resultado apresentado mostrou uma superioridade deste último método, no qual trabalhou melhor a diversidade e aprofundou mais as buscas no espaço de soluções. A superioridade dos resultados foi devido à introdução do AG, que trabalha de forma especial a combinação de soluções ótimas locais.

Os menores desvios de VPL entre PLI e as metaheurísticas foram observados nos cenários pertencentes aos casos 1 e 4 (GRÁFICO 32), indicando uma maior facilidade em atingir estas metas. A facilidade é devido a maior ou total flexibilidade em administrar as metas volumétricas nestes casos, já que as restrições volumétricas foram as mais simples de serem atendidas. O segundo ponto está relacionado ao limite de área da restrição ARM70 (caso 4), no qual é mais tolerante a adjacência entre talhões quando comparado com as restrições URM e ARM50. Assim, o número de combinações factíveis é maior para o caso 4 frente aos casos 2 e 3 e, aumentando o limite de área na restrição aumenta o número de grupos de talhões adjacentes, desta maneira aumentando as chances de sair de baixos ótimos locais.

Os maiores desvios percentuais de VPL foram observados nos cenários do caso 2 (URM), quando confrontadas as metaheurísticas e a PLI. Uma possível explicação está no número reduzido de soluções factíveis disponíveis, ao se comparar com os outros casos. Este tipo de restrição é mais rigoroso na questão de adjacência, mesmo apresentando um número menor de restrições de adjacência que os casos 3 e 4. Assim, o uso da restrição URM (caso 2) foi considerado o mais difícil de obter soluções aproximadas, pelo AG e em alguns cenários da SA. O caso 3 (ARM50) foi considerado um intermediário entre os casos 2 e 4, quando analisados seus desvios de VPL. Este resultado foi esperado, pois seu limite de área é menor que o adotado no caso 4, e por sua vez não é uma restrição rigorosa como URM.

Segundo Crowe e Nelson (2005) na medida em que aumenta a complexidade dos problemas relacionados às restrições ARM, a metaheurística SA deixa de apresentar boas soluções. Os autores testaram para isso diferentes limites de área na restrição ARM (20 ha, 30 ha, 40 ha e 50 ha) e tamanhos de floresta, onde soluções aproximadas ficaram variando entre 1% a 13% ao ótimo. No presente estudo, o desvio do VPL concentrou-se nesta faixa e foi de 3,31% (ARM70) e 7,66% (ARM50) ao ótimo, considerando os cenários com HP de 7 anos. A diferença encontrada entre o trabalho de Crowe e Nelson (2005) e o

presente estudo é um fato normal e característico de cada local de estudo, pois a vizinhança entre talhões depende da floresta e isso influencia o problema.

O que elevou o desvio do VPL entre as metaheurísticas e a PLI nos casos 2, 3 e 4 foi uma presença maior de talhões ociosos. Um talhão é ocioso quando nenhuma alternativa de manejo foi definida para ele, pelos métodos de resolução. Este termo equivale dizer que o talhão foi abandonado da análise final, pela PLI, AG ou SA, por não permitir a formação de soluções factíveis. No caso das metaheurísticas, a eliminação destes talhões proporcionou a melhora significativa de suas soluções, no primeiro momento, porém levando-os a um baixo ótimo local em certos cenários. No caso 2, esta afirmativa se torna real e justificada pelos valores dos desvios encontrados. A Tabela 21 mostra com mais detalhes o número de talhões ociosos presentes em cada cenário.

TABELA 21 - LISTA DE TALHÕES OCIOSOS EM CADA MÉTODO DE PROCESSAMENTO.

Caso	Método	Horizonte de Planejamento							
		7	8	9	10	11	12	13	14
1	PLI	-	-	-	-	-	-	-	-
	AG	-	-	-	-	-	-	-	-
	SA	22	38	20, 39	-	-	27	-	38
2	PLI	15, 38	15, 38	15, 38	15, 38	15, 38	15, 38	15, 38	15, 38
	AG	4, 15, 23, 29, 38, 1	3, 19, 21, 23, 39, 41	6, 11, 15, 38, 41	2, 5, 9, 15, 21, 27, 38	-	11, 15, 19, 27, 39	3, 15, 16, 18, 23, 38, 41	3, 19, 20, 28, 39, 41
	SA	19, 39	15, 24, 37	21, 27, 38	15, 27, 30, 38	1, 4, 20, 38	16, 21, 38	16, 21, 38	19, 28, 38
3	PLI	38	38	38	38	38	38	38	38
	AG	39	19, 38	30, 39	39	39	3, 38	5, 39	28, 38
	SA	1, 39	2, 29, 39	5, 30, 39	16, 37	27, 37	27, 37	37	3, 28, 38
4	PLI	38	38	38	38	38	38	38	38
	AG	38	38	27, 39	38	39	-	37	37
	SA	38	37	37	17, 39	1, 39	38	11, 38	5, 39

Quando este tipo de evento ocorre em florestas naturais, promovido pelo uso de restrições de adjacência, muitas vezes os talhões são abandonadas para virar reserva (MARIANOV *et. al*, 2004). Entretanto, devido ao grande investimento realizado em florestas plantadas e às expectativas de retorno do capital, o abandono de talhões torna-se um assunto delicado. Além disso, de modo geral no Brasil as florestas de Eucalipto possuem altos incrementos volumétricos, e o abandono de um talhão significa a não intervenção na competição entre árvores, resultando no processo de morte natural e redução do crescimento

no povoamento.

Uma medida para evitar a formação destes talhões é o processo de retalhamento, o que proporciona a formação de novas configurações espaciais na floresta. Assim, os maiores talhões são subdivididos em menores para formar outros novos. A outra opção é aumentar o limite de área na restrição ARM, contudo esta medida não faz sentido, pois com este aumento o agendamento da colheita passa a incluir mais talhões adjacentes, a ponto da restrição ARM ser inoperante no modelo.

Segundo Carter *et al.* (1997) o modelo matemático de PLI contendo restrições de adjacência pode produzir soluções infactíveis em virtude da rigidez de suas restrições, ou por problemas de crescimento na floresta. Os autores discutem ainda a possibilidade de criar opções de manejo no qual não são produzidos volume, sendo o mesmo que abandoná-los. Esta estratégia permite a formação de soluções factíveis, como ainda a presença de talhões ociosos.

Apesar dos cenários conterem a presença de talhões ociosos como mais um fator complicador para as metaheurísticas resolverem, em muitos casos estes métodos foram eficientes, ou seja, conseguiram eliminar exatamente os mesmos talhões definidos pela PLI, ou outros adjacentes aos eliminados. Assim, uma das diferenças de valores encontrados de VPL foi relacionada diretamente à seleção das alternativas de manejo florestal para os talhões não ociosos. Estas alterações provocaram mudanças nos fluxos de produção volumétrica ao longo do HP nos diferentes cenários.

Nos ANEXOS 19 e 20 encontram-se exemplos gráficos deste efeito, onde as curvas de produção de madeira foram mais similares entre os métodos, principalmente para os casos 1 e 4. As quedas no fluxo de produção volumétrica para os períodos próximo de 4 e 10 anos são reflexos do desequilíbrio da floresta (ANEXO 20). A floresta não apresenta áreas com idade de 2 anos, além de possuir 65,32% de sua área já em estado maduro e prontas para a colheita.

O complemento desta análise pode ser compreendido através da Tabela 22, onde se encontram os desvios percentuais da produção volumétrica, tendo como referência o caso 1 de cada método de resolução.

A maioria das respostas apresentou uma ordem decrescente de valores volumétricos, como segue: caso 1 > caso 2 > caso 3 > caso 4, sendo algo já esperado, conforme discutido ao longo do texto.

TABELA 22 - DESVIO PERCENTUAL TOTAL DA PRODUÇÃO VOLUMÉTRICA DOS CASOS 2, 3 E 4 FRENTE AO CASO 1 NOS TRÊS MÉTODOS DE RESOLUÇÃO.

Método	Caso	Horizonte de Planejamento							
		7	8	9	10	11	12	13	14
PLI	1	-	-	-	-	-	-	-	-
PLI	2	2,92	2,86	3,78	3,79	3,37	2,96	2,98	-0,27
PLI	3	1,79	1,84	2,51	2,55	2,17	1,78	1,63	-1,73
PLI	4	1,73	1,77	2,49	2,11	1,94	1,84	1,61	-1,22
AG	1	-	-	-	-	-	-	-	-
AG	2	11,66	13,21	13,19	14,66	*	12,44	10,60	12,40
AG	3	3,85	6,72	6,18	3,72	3,43	4,29	3,52	5,78
AG	4	2,89	3,64	6,38	3,34	2,71	*	1,36	3,77
SA	1	-	-	-	-	-	-	-	-
SA	2	5,53	4,46	2,96	8,27	7,85	4,04	6,86	6,83
SA	3	6,10	8,01	3,59	5,45	5,57	3,35	4,54	4,57
SA	4	1,82	3,63	-0,20	3,76	4,83	-0,77	4,74	2,59

Onde: (*) cenários sem soluções factíveis até o critério de parada.

A análise do tempo de processamento comprova a economia em requerimento computacional produzida pelas metaheurísticas, dando destaque a SA por ser o método mais rápido. A economia de tempo em relação a PLI chegou a 97,92% (AG) e 99,78% (SA) nos cenários mais extremos, podendo ser ainda maior em virtude do critério de parada (4 horas) adotado na PLI. O Gráfico 33 apresenta uma comparação entre os tempos de processamento para os 3 métodos, sendo considerados apenas os cenários do caso 1.

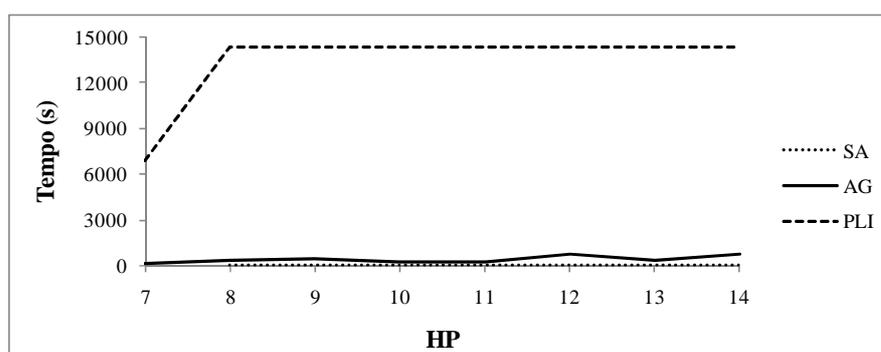


GRÁFICO 33 - TEMPO DE PROCESSAMENTO REQUERIDO PELOS 3 MÉTODOS PARA OS CENÁRIOS DO CASO 1.

4.3 EXEMPLO APLICADO

Na seqüência é apresentado um exemplo extraído das análises e que envolveu o uso do planejamento florestal tradicional (caso 1) e o espacial (casos 2, 3 e 4). A idéia do exemplo foi mostrar como a falta de restrições de adjacência no modelo de planejamento florestal

contribuiu para uma possível degradação visual e ambiental das paisagens, contendo florestas plantadas. Além disso, outro objetivo foi mostrar os impactos destas restrições na produção volumétrica e no VPL da floresta.

O exemplo representa um cenário cujo horizonte de planejamento foi de 7 anos e pertencente aos 4 casos de planejamento florestal. A seqüência de corte dos talhões foi definida através da PLI por ter atingido o ótimo global nos 4 cenários. Este agendamento consistiu na indicação de quais talhões deveriam ser colhidos apenas para o segundo ano do projeto. De posse destas informações preliminares, foi comparada a produção volumétrica e o número de talhões agendados para a colheita, bem como o somatório de áreas adjacentes indicadas para a colheita e suas receitas geradas. Resumidamente, o exemplo teve como propósito realçar as diferenças entre o planejamento florestal tradicional e o planejamento florestal espacial.

A produção volumétrica total gerada para os 4 cenários foi de 614.919 m³ (caso 1); 596.961 m³ (caso 2); 603.937 m³ (caso 3) e 604.279 m³ (caso 4), já para o segundo ano do projeto estes valores são apresentados na Tabela 23.

TABELA 23 - INFORMAÇÕES COMPARATIVAS DE VOLUME PRODUZIDO ENTRE O PLANEJAMENTO FLORESTAL ESPACIAL E O PLANEJAMENTO FLORESTAL TRADICIONAL NO SEGUNDO ANO.

Caso	Volume (m ³)	Área total (ha)	Número de talhões selecionados
1	97.961,91	325,81	12
2	97.809,37	323,98	12
3	97.970,01	324,38	11
4	97.685,59	328,32	12

A partir dos dados percebeu-se que as produções volumétricas de madeira apresentaram valores muito próximos, bem como a área total designada à colheita florestal. O número de talhões selecionados para o corte foi praticamente o mesmo, exceto para o cenário 3, diferenciando-se no conjunto de unidades de manejo selecionados para o agendamento, conforme Tabela 24. As áreas marcadas na Tabela 24 indicam a igualdade de talhões selecionados nos cenários 2, 3 e 4 frente ao cenário 1. Assim, estes resultados mostram uma similaridade entre os casos, do ponto de vista técnico-operacional para a atividade da colheita florestal. Contudo, ao executar a colheita destes talhões para o ano analisado, e nos diferentes casos abordados, notou-se que seus efeitos foram diferentes na matriz paisagística, conforme os mapas dispostos nos ANEXOS 21, 22, 23 e 24.

TABELA 24 - LISTA DE TALHÕES DESTINADOS À COLHEITA FLORESTAL ENVOLVENDO OS 4 CENÁRIOS PROPOSTOS E O SEGUNDO ANO DO HORIZONTE DE PLANEJAMENTO.

Cenários		Talhões selecionados para a colheita florestal no segundo ano											
1	2	4	5	6	7	9	18	21	23	29	38	39	
2	3	7	9	12	13	17	19	22	25	28	30	39	
3	2	6	8	9	15	17	18	22	28	30	39	-	
4	2	3	6	9	18	20	21	22	26	27	36	39	

O planejamento florestal tradicional (caso 1) definiu uma seqüência de colheita que incluiu talhões adjacentes, proporcionando a formação de 2 grupos de talhões adjacentes com áreas de 153,95 ha e 70,05 ha. Por sua vez, os casos contemplando o planejamento florestal espacial (caso 2, 3 e 4) não apresentaram grupos de talhões adjacentes superiores ao mínimo encontrado no caso anterior, não chegando a constituir a formação destes grupos no caso 2, conforme esperado. Nos casos 3 e 4, a presença de grupos de talhões adjacentes foi um fato natural, porém devidamente controlada pelo limite de área. Sendo assim, o caso 3 permitiu o aparecimento de 2 grupos de talhões adjacentes com áreas de 47,83 ha e 41,43 ha. O caso 4, analogamente, gerou o mesmo número de grupos, porém com áreas de 37,93 ha e 56,08 ha.

Nelson (2000) afirma que o uso de restrições de adjacência promove uma maior dispersão da atividade de colheita na área, resultando no aumento dos gastos na construção de estradas ao longo do horizonte de planejamento. Esta mesma dispersão foi observada no exemplo abordado, porém infelizmente não foram analisados os custos ligados à colheita destas opções de planejamento.

O tamanho das áreas formadas em cada grupo de talhões adjacentes esboça o sucesso no controle espacial, pelos modelos destinados a esta causa. Neste sentido, percebeu-se visualmente através dos mapas (ANEXOS 21, 22, 23 e 24) que a matriz paisagística sofreu menos impactos. No ANEXO 25 encontram-se fotos da área de estudo, evidenciando o que pode ocorrer a áreas similares quando não são respeitadas as restrições de adjacência entre talhões. No exemplo retratado pelos 4 casos, a redução do VPL foi de 3,74% (caso 2), 2,24% (caso 3) e 2,20% (caso 4) em relação ao caso 1 sem controle da adjacência entre talhões. Estes resultados demonstram que a utilização de restrições de adjacência é consistente e de direta aplicação, devendo ser analisada como uma opção pelos tomadores de decisão nas empresas florestais.

No trabalho de Boston e Bettinger (2001), encontram-se referências sobre a decisão de considerar o uso das restrições de adjacência nos modelos de planejamento florestal, a ponto de seguir o seu agendamento na colheita florestal. Os autores concluíram que uma produção

volumétrica de madeira elevada e/ou preços dos produtos florestais atraentes faz com que o uso de restrições de adjacência não seja adotado, porém, quando estes efeitos ocorrem em direção oposta, os incentivos econômicos para a adoção da adjacência tornam-se recomendados.

Segundo Constantino *et al.* (2008), a complexidade computacional exigida pela restrição ARM fica pouco evidente, quando os resultados de suas ações são implementados na prática. Entretanto, de acordo com os autores, a formulação computacional destas restrições tem sido um obstáculo para o seu uso efetivo, principalmente em se tratando de métodos exatos como o *branch-and-bound*.

5. CONCLUSÃO

- O modelo de planejamento florestal espacial é apto e viável ao uso e as restrições de adjacência URM, ARM 50 e ARM 70, formuladas e implementadas na presente pesquisa, e contribuem para o controle das relações espaciais entre talhões adjacentes;
- A influência do planejamento florestal espacial (casos 2, 3 e 4) sobre o VPL é negativa, pois reduz seu valor. Nos cenários com horizonte de planejamento de 7 anos, as reduções são de 3,74% (caso 2), 2,24% (caso 3) e 2,20% (caso 4) com relação ao caso 1 de PLI, que apresenta um ótimo global. A produção volumétrica de madeira sofre reduções na maioria dos cenários, demonstrando que o controle da adjacência no modelo penaliza o volume de madeira colhida;
- O aumento da complexidade dos cenários comprova que a PLI não é capaz de retratar problemas de grande proporção. Entretanto, as metaheurísticas são capazes de fornecer soluções factíveis em tempos viáveis;
- O AG é capaz de gerar soluções factíveis para os cenários propostos, entretanto, em algumas situações ocorreram falhas, e os cenários ficaram sem solução. Como alternativa, o aumento no número de repetições por cenário é uma saída plausível. O caso 2, com restrições URM, é considerado o mais difícil para o AG aproximar-se da PLI, apresentando os maiores desvios percentuais; o oposto é encontrado nos casos 1 e 4;
- A metaheurística SA é superior ao AG para o caso 2 (URM), encontrando ainda um maior número de soluções factíveis para os 32 cenários. Porém, apesar de sua eficiência, o AG é mais eficaz para a maioria dos cenários;
- O tempo de processamento das metaheurísticas é inferior ao empregado pela PLI, na maioria dos casos, chegando à economia de 97,92% (AG) e 99,78% (SA). As metaheurísticas são mais eficientes e eficazes na resolução de problemas abordando o planejamento florestal tradicional (caso 1). No caso de problemas grandes, onde a PLI não pode ser aplicada, a metaheurística é a única opção viável e de rápido processamento;
- O aumento no limite de área na restrição de adjacência ARM se traduz em um aumento na produção volumétrica total, bem como melhora no valor do VPL. O uso de restrições URM causa maiores reduções no VPL e produção volumétrica

de madeira, quando comparado às restrições ARM 50 e 70. O número de restrições formuladas na PLI utilizando as restrições ARM50 é menor que a opção ARM70, porém superior à restrição de adjacência URM.

6. REFERÊNCIA BIBLIOGRÁFICA

ALONSO, L. R. L. **O problema da consideração de restrições de adjacência em um planejamento florestal.** Curitiba. 2003. 114 f. Dissertação de Mestrado. Universidade Federal do Paraná.

BASKENT, E. Z.; JORDAN, G. A. Forest landscape management modeling using simulated annealing. **Forest Ecology and Management**, USA, n.165, p.29-45. 2001.

BETTINGER, P.; BOSTON, K.; SESSIONS, J. Intensifying a heuristic forest harvest scheduling search procedure with 2-opt decision choices. **Canadian Journal of Forest Research**, Canada, n.29, p.1784-1792. 1999.

BOSTON, K.; BETTINGER, P. The impact of gree-up constraints in the southern United States. **Forest Ecology and Management**, USA, n.145, p.191-202. 2001.

CARTER, D. R.; VOGIATZIS, M.; MOSS, C. B.; ARVANITIS, L. G. Ecosystem management os infeasible guidelines? Implications of adjacency restrictions for wildlife habitat and timber production. **Canadian Journal of Forest Research**, Canada, n.27, p. 1302-1310. 1997.

CASTRO, R. R. **Regulação de florestas equiâneas incluindo restrições de adjacência.** Viçosa. 2007. 64f. Dissertação de Mestrado. Universidade Federal de Viçosa.

CONSTANTINO, M.; MARTINS, I.; BORGES, J. G. A New Mixed-Integer Programming Model for Harvest Scheduling Subject to Maximum Area Restrictions. **Operations Research**. v. 56, n.3, p. 542-551, 2008.

FISCHER, D. T.; CHURCH, R. L. Clustering and compactness in reserve site selection: an extension of the biodiversity management area selection model. **Forest Science**. USA, v.49, n.4. 2003.

HILLIER, F. S.; LIEBERMAN, G. J. **Introduction to operations research.** McGraw-Hill.

2001. p.1214.

HEINONEN, T., KURTTILA, M.; PUKKALA, T. Possibilities to aggregate raster cells through spatial optimization in forest planning. **Silva Fennica**. Finland, v.41, n.1, p.89-103. 2007.

HOGANSON, H. M.; BORGES, J. G. Impacts of the time horizon for adjacency constraints in harvest scheduling. **Forest Science**, USA, n.46, v.2, p.177-187. 2000.

JOHNSON, K. N.; SCHEURMANN, H. L. Techniques for prescribing optimal timber harvest and investment under different objectives - discussion and synthesis. **Forest Science Monograph**, USA, v.18, n.1, p.1-31, 1977.

LOCKWOOD, C.; MOORE, T. Harvest scheduling with spatial constraints: a simulated annealing approach. **Canadian Journal of Forest Research**, Canada, v. 23, p.469-478. 1993.

MARIANOV, V.; SNYDER, S.; REVELLE, C. Trading off species protection and timber production in forests managed for multiple objectives. England. **Environment and Planning B**. England, v.31, p. 847 - 862. 2004.

MCDILL, M. E.; BRAZE, J. Comparing adjacency constraint formulation for randomly generated forest planning problems with four age-class distributions. **Forest Science**, USA, v.46, n.3, p.423-436, 2000.

MCDILL, M. E.; REBAIN, S. A.; BRAZE, J. Harvest scheduling with area-based adjacency constraint. **Forest Science**, USA, v.48, n.4, p.631-642, 2002.

MURRAY, A.; CHURCH, R. Heuristic solution approaches to operational Forest planning problems. **Operational Research Spektrum**, USA, v.17, p. 193-203. 1995.

MURRAY, A. T. Spatial restriction in harvest scheduling. **Forest Science**, USA, v.45, n.1, p.45-52, 1999.

NELSON, J. Assessment of forest harvest blocks generated from operational polygons and forest-cover polygons in tactical as strategic planning. **Canadian Journal of Forest Research**, Canada, v.31, p. 682-693. 2001.

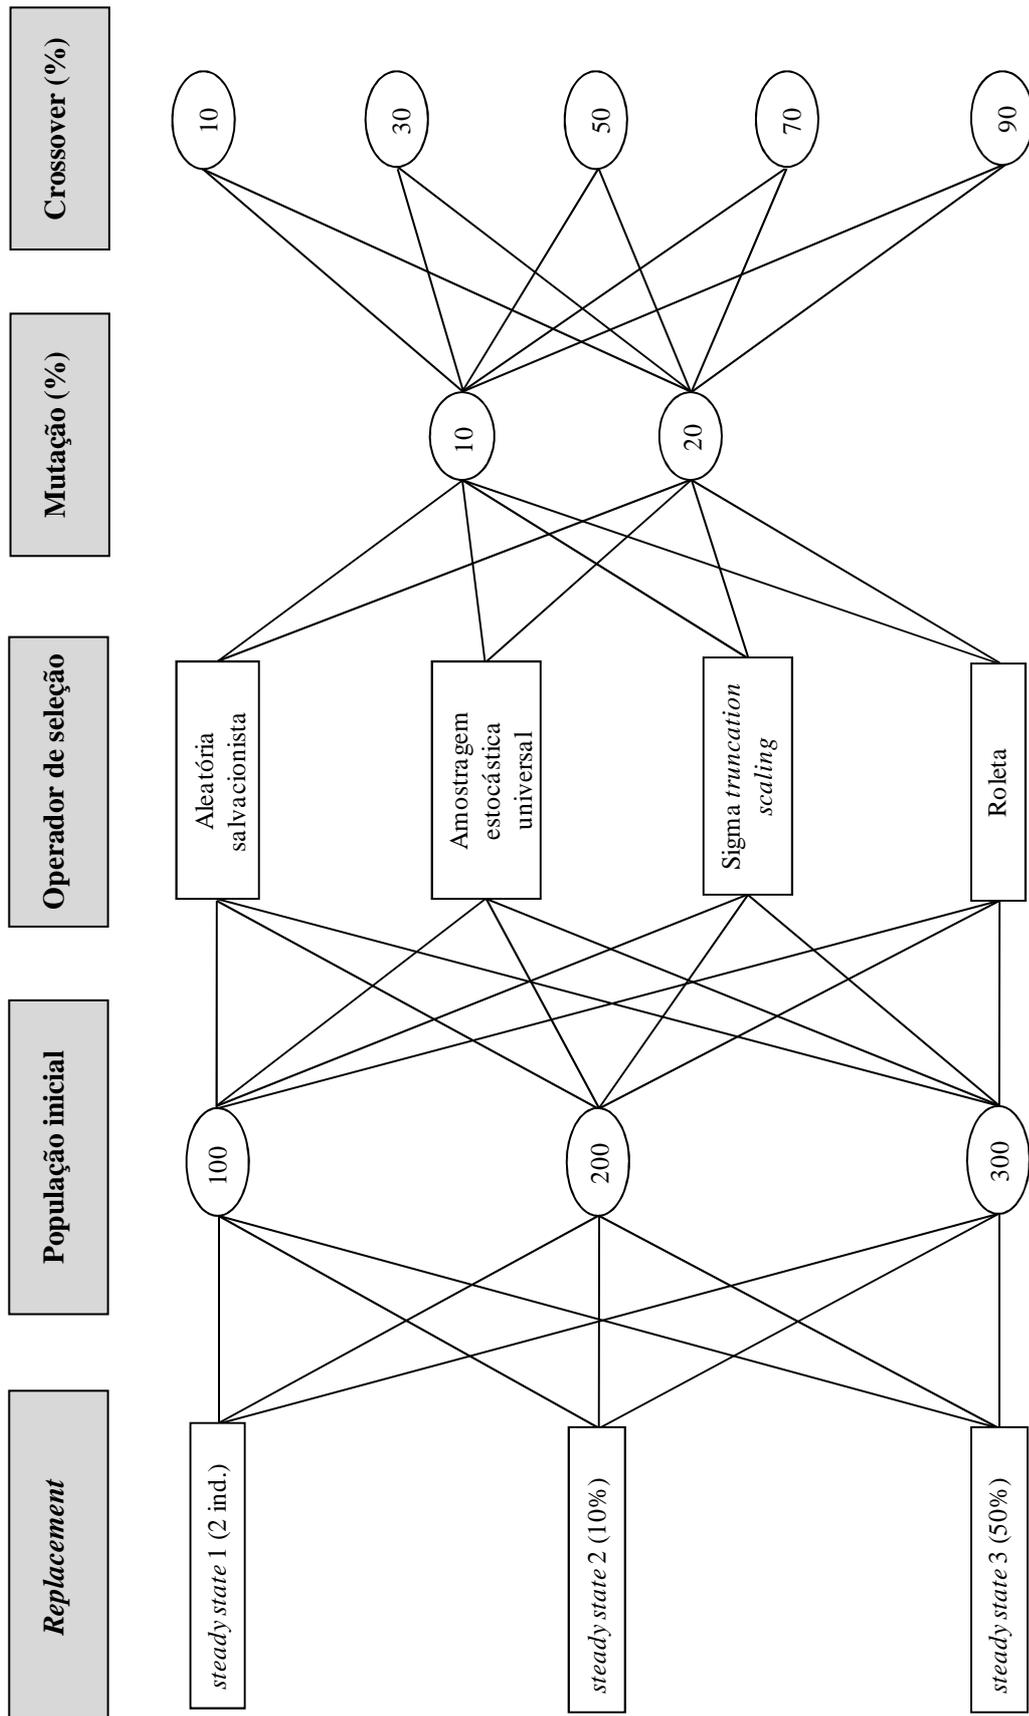
NELSON, J. **Mechanics of adjacency**. Faculty of Forestry. Vancouver. p.8. 2000. Disponível em: <http://www.forestry.ubc.ca/atlas-simfor/WebDocs/extension/mechanics_of_adjacency.pdf>. Acesso em: 14/02/2009.

SESSIONS, J.; BETTINGER, P. Hierarchical planning: a pathway to the future? p.186-190. In: BRIGGS, D. **Proceedings of the first international precision forestry cooperative symposium**, Washington, 2001.

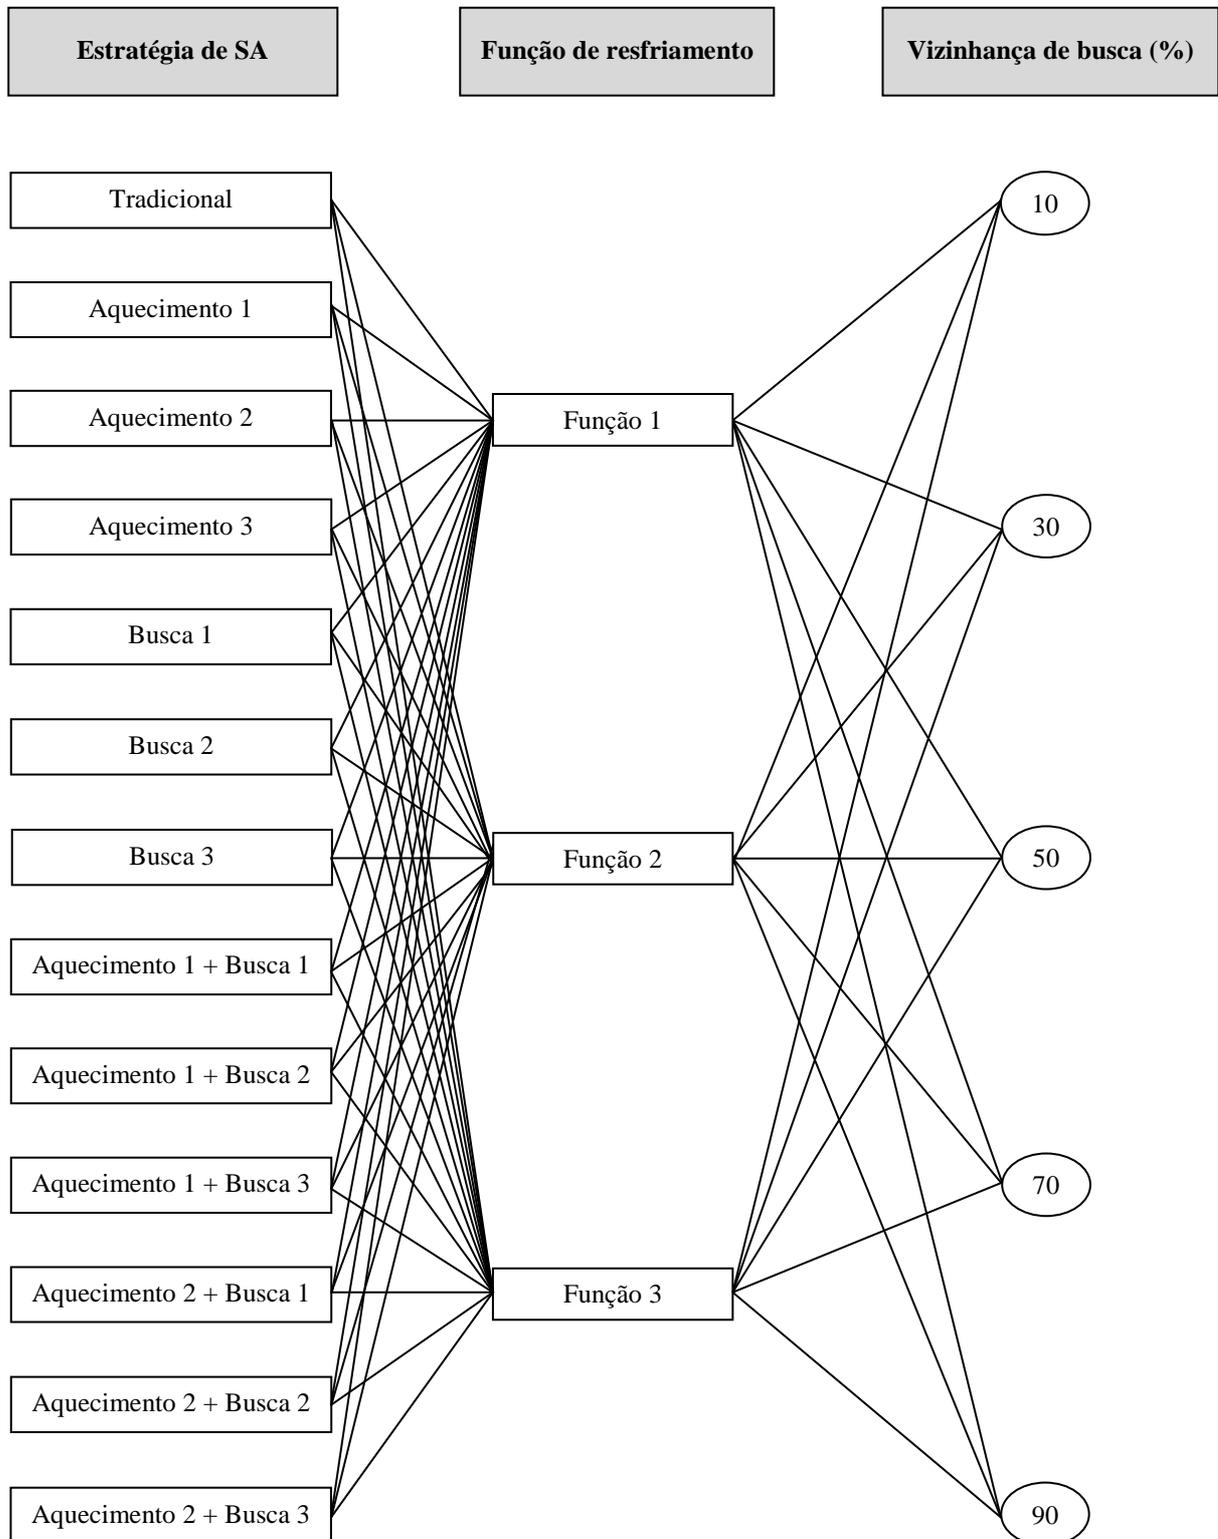
ZHU, J.; BETTINGER, P.; LI, R. Additional insight into the performance of a new heuristic for solving spatially constrained forest planning problems. **Silva Fennica**, Finland, n.41, v.4. p.687-698. 2007.

ANEXOS

ANEXO 1 - FLUXOGRAMA DAS COMBINAÇÕES DE PARÂMETROS TESTADOS NO ALGORITMO GENÉTICO.



ANEXO 2 - FLUXOGRAMA DAS COMBINAÇÕES DE PARÂMETROS TESTADOS NA METAHEURÍSTICA SIMULATED ANNEALING.

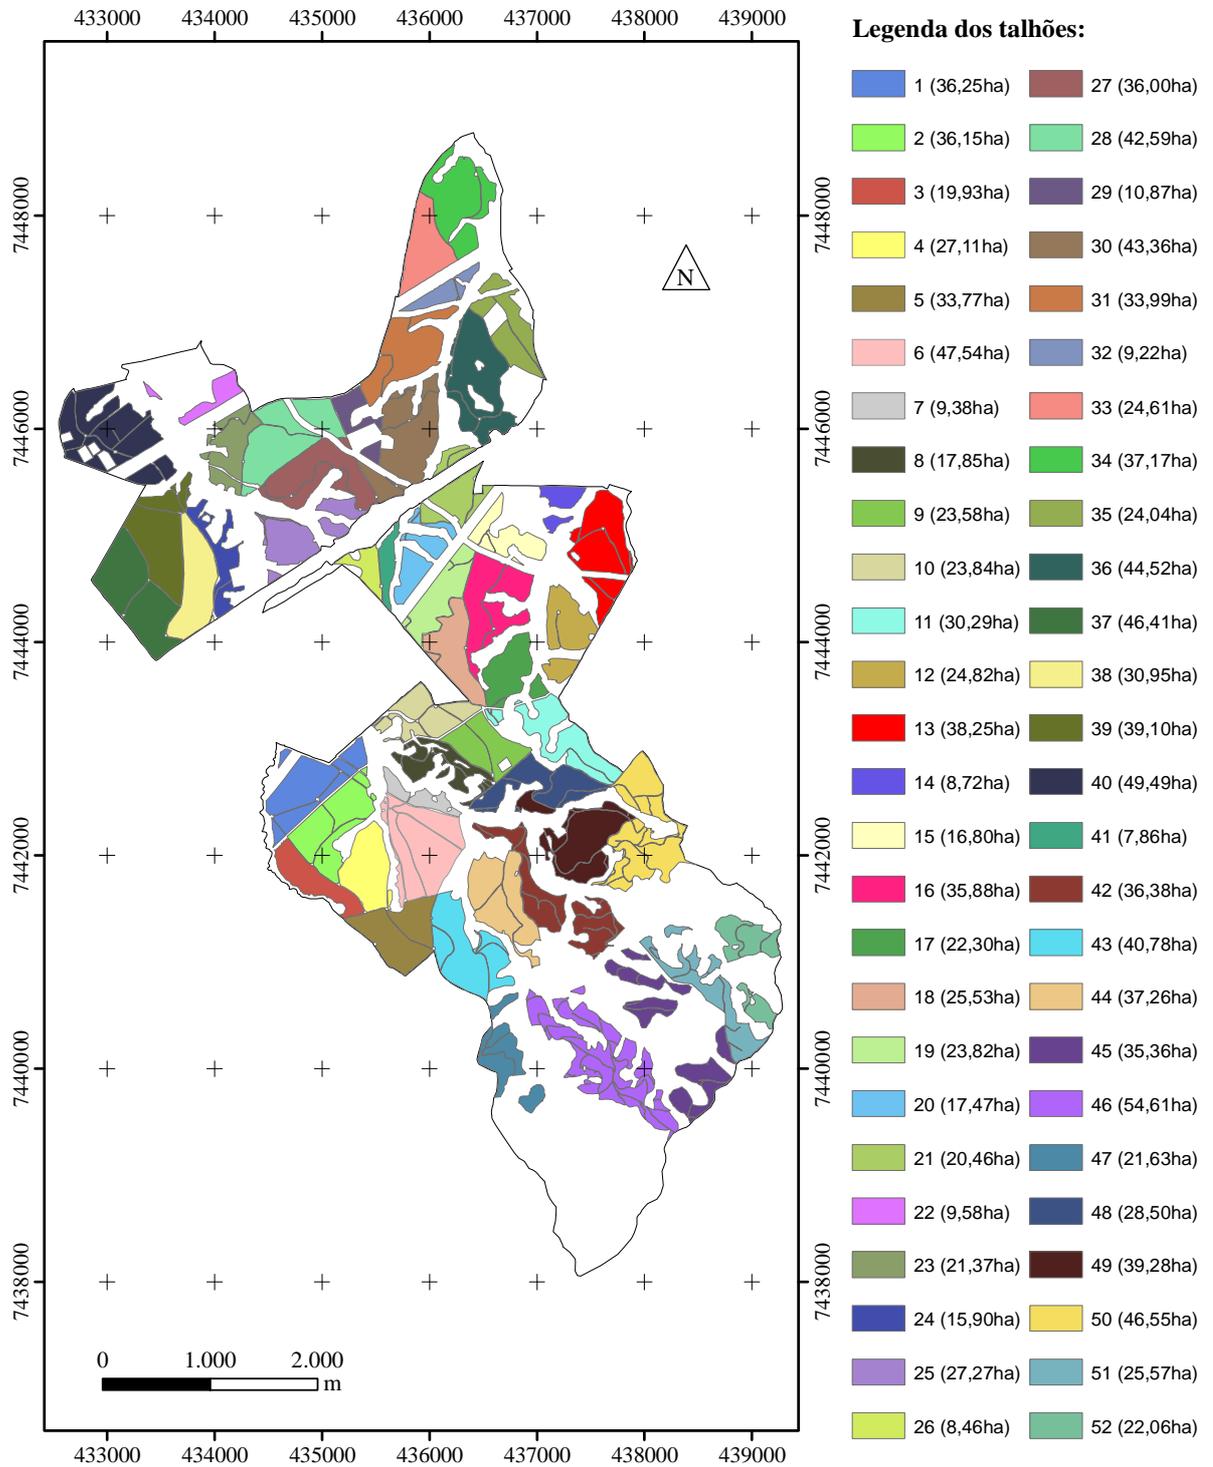


ANEXO 3 - LISTA DE TALHÕES PRESENTES NA FLORESTA ABRANGENDO AINDA SUA RESPECTIVA ÁREA E SEUS VIZINHOS.

Talhão	Área (ha)	Talhões adjacentes	Talhão	Área (ha)	Talhões adjacentes
1	36,25	2 e 3	27	36,00	25, 28, 30 e 41
2	36,15	1, 3 e 4	28	42,90	23, 27 e 29
3	19,93	1, 2, 4 e 5	29	10,87	28, 30 e 31
4	27,11	2, 3 e 5	30	43,05	20, 21, 27, 29, 41
5	33,77	3, 4, 6 e 43	31	33,99	29
6	47,54	5 e 7	32	9,22	33 e 34
7	9,38	6	33	24,61	32 e 34
8	17,85	9, 10 e 48	34	37,17	32 e 33
9	23,58	8, 10, 11 e 48	35	24,04	36
10	23,84	8, 9 e 18	36	44,52	35
11	30,29	9, 17, 48 e 50	37	46,41	38 e 39
12	24,82	-	38	30,95	24, 37 e 39
13	38,25	-	39	39,10	24, 37 e 38
14	8,72	-	40	49,49	-
15	16,80	16, 19, 20 e 21	41	7,86	25, 26, 27 e 30
16	35,88	15, 18 e 19	42	36,38	44
17	22,30	11 e 18	43	40,78	5
18	25,53	10, 16, 17 e 19	44	37,26	42
19	23,82	15, 16, 18, 20 e 21	45	35,36	51
20	17,47	15, 19, 21 e 30	46	54,61	-
21	20,46	15, 19, 20 e 30	47	21,63	-
22	9,58	23	48	28,50	8, 9, 11 e 49
23	21,37	22 e 28	49	39,28	48 e 50
24	15,90	38 e 39	50	46,55	11 e 49
25	27,27	26, 27 e 41	51	25,57	45
26	8,46	25 e 41	52	22,06	-

Onde: (-) indica que o talhão encontra-se isolado dos outros talhões na matriz paisagística, e por isso não apresentam vizinhança alguma.

ANEXO 4 - MAPA DE IDENTIFICAÇÃO DA VIZINHANÇA ENTRE TALHÕES PRESENTE NA ÁREA DE ESTUDO E SUAS RESPECTIVAS ÁREAS.

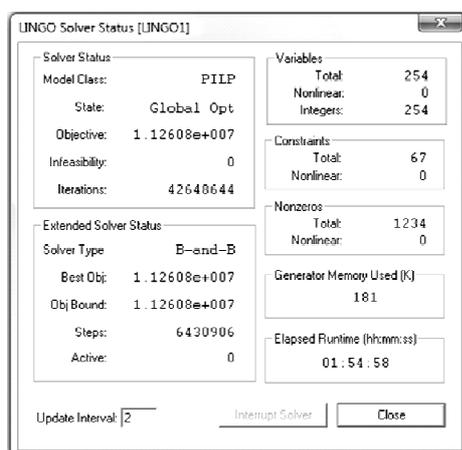


ANEXO 5 - EXEMPLO DE UMA ÁRVORE DE ALTERNATIVAS DE MANEJO PARA UM HORIZONTE DE PLANEJAMENTO DE 14 ANOS.

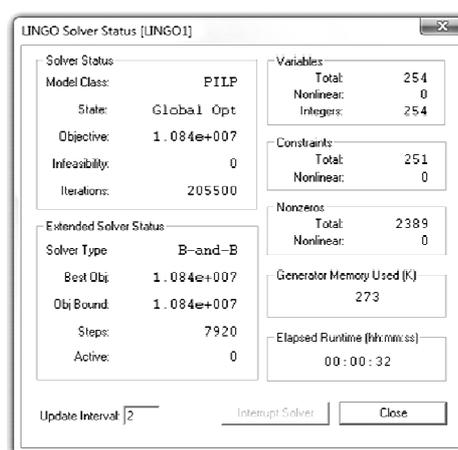
Alternativa de manejo*	Volume total (m ³)	VPL (R\$)	Período ao longo do HP													
			1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	24.866,79	347.353	x					x				x				
2	26.411,76	361.796	x					x					x			
3	27.691,64	371.089	x					x						x		
4	26.411,76	362.701	x						x				x			
5	27.956,73	377.365	x						x					x		
6	29.236,61	396.940	x						x						x	
7	27.691,64	369.541	x							x				x		
8	29.236,61	393.998	x							x					x	
9	19.402,71	297.036	x							x						
10	26.411,76	364.162		x					x				x			
11	27.956,73	378.826		x					x					x		
12	29.236,61	398.401		x					x						x	
13	27.956,73	379.652		x						x				x		
14	29.501,70	404.109		x						x					x	
15	19.667,80	307.147		x						x						
16	29.236,61	396.996		x							x				x	
17	20.947,68	318.013		x							x					
18	27.691,64	367.047			x					x				x		
19	29.236,61	391.504			x					x					x	
20	19.402,71	294.542			x					x						
21	29.236,61	392.254			x						x				x	
22	20.947,68	313.271			x						x					
23	22.227,56	323.146			x							x				

Onde: (*) - o talhão utilizado no exemplo foi o talhão número 1, que apresentou uma idade de 5 anos e área de 36,25 ha. A taxa de juros empregada foi de 10% ao ano para o cálculo do VPL.

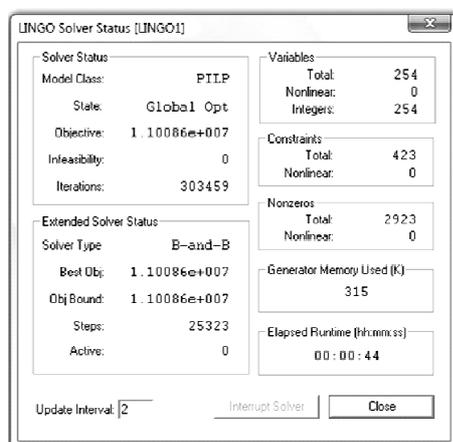
ANEXO 6 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 7 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.



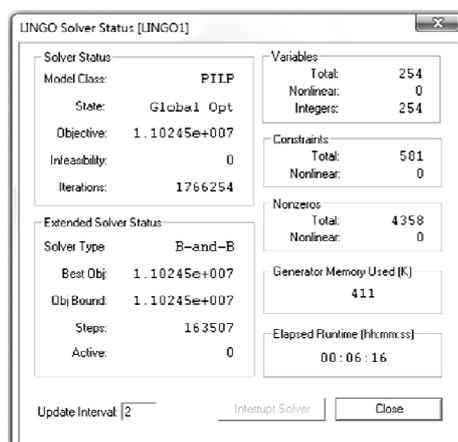
(a)



(b)

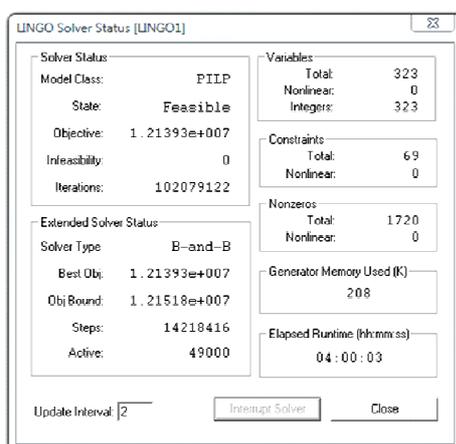


(c)

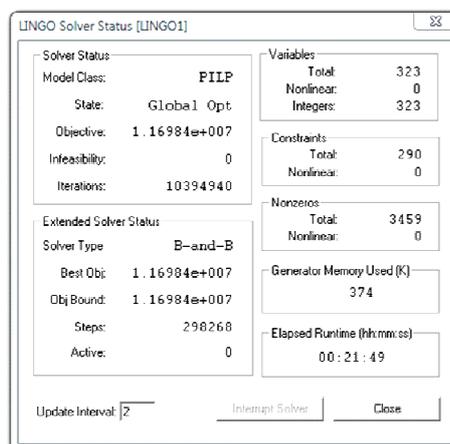


(d)

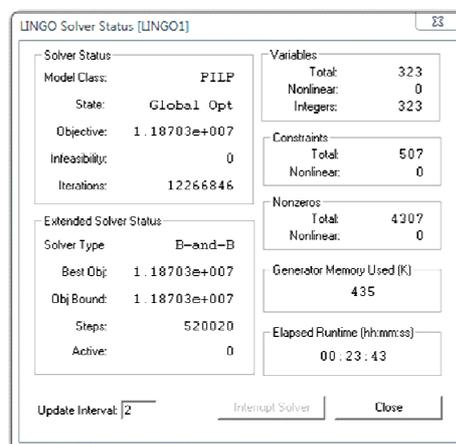
ANEXO 7 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 8 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.



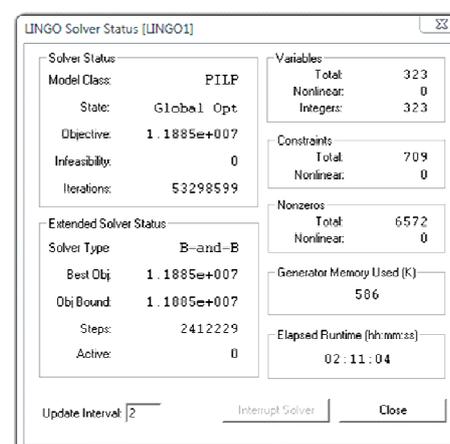
(a)



(b)

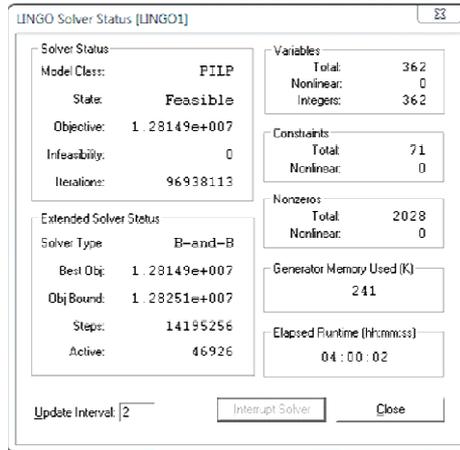


(c)

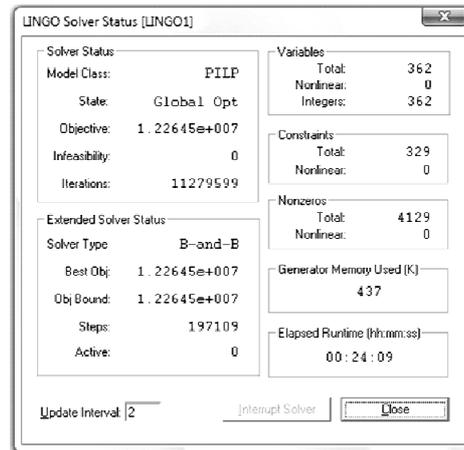


(d)

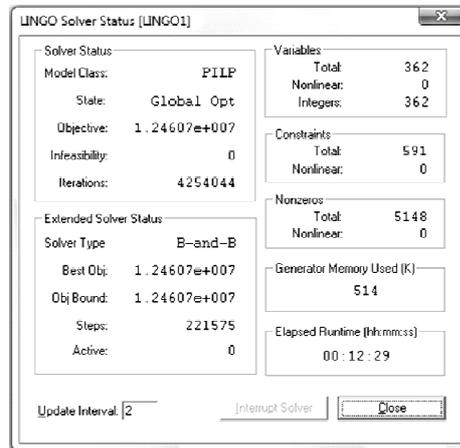
ANEXO 8 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 9 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.



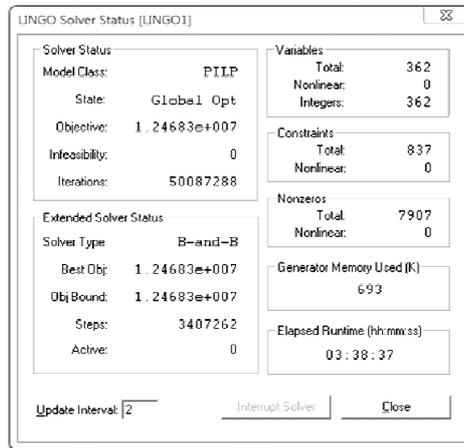
(a)



(b)



(c)

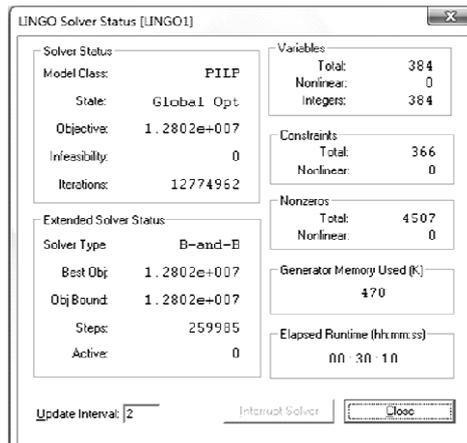


(d)

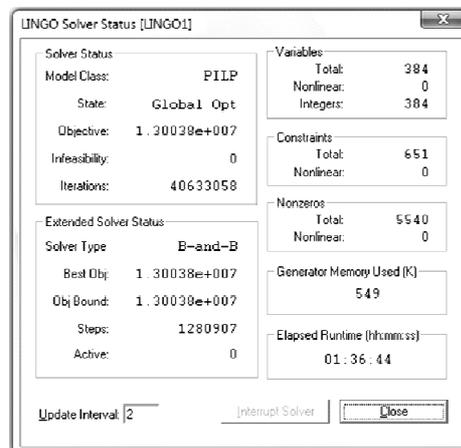
ANEXO 9 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 10 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.



(a)



(b)

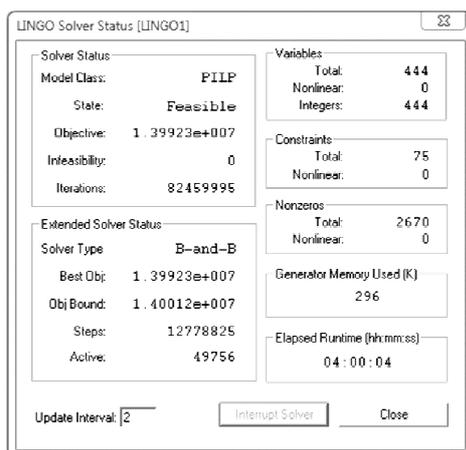


(c)

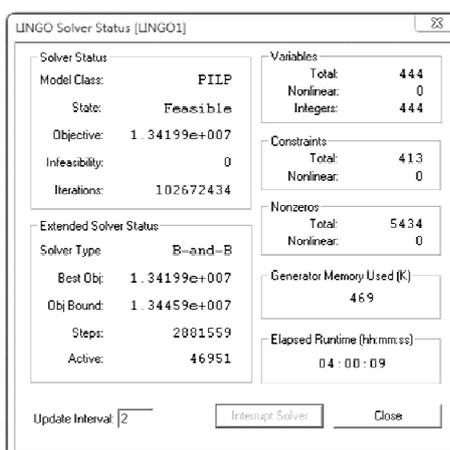


(d)

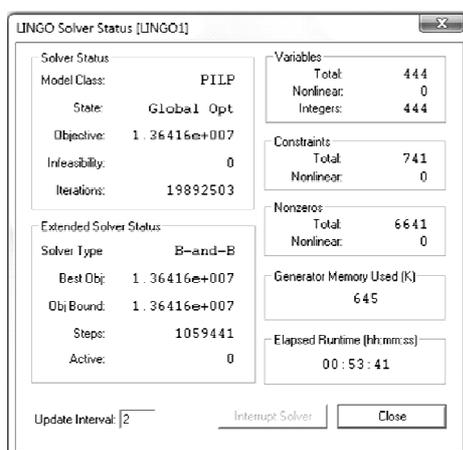
ANEXO 10 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 11 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.



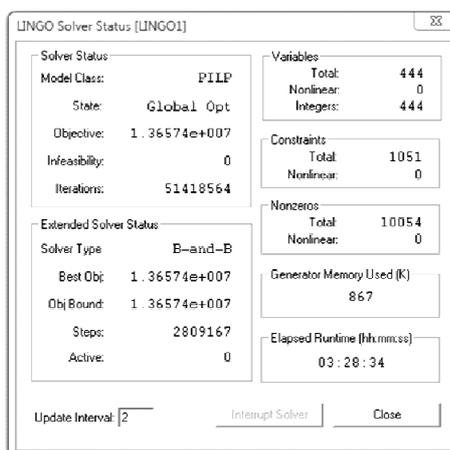
(a)



(b)



(c)



(d)

ANEXO 11 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 12 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.

LINGO Solver Status [LINGO1]	
Solver Status	
Model Class:	PILP
State:	Feasible
Objective:	1.4474e+007
Infeasibility:	0
Iterations:	88151912
Variables	
Total	571
Nonlinear:	0
Integers:	571
Constraints	
Total	77
Nonlinear:	0
Nonzeros	
Total	3680
Nonlinear:	0
Extended Solver Status	
Solver Type	B-and-B
Best Obj:	1.4474e+007
Obj Bound:	1.45196e+007
Steps:	15721416
Active:	49496
Generator Memory Used (K)	
	400
Elapsed Runtime (hh:mm:ss)	
	04:00:03
Update Interval:	2
Interrupt Solver Close	

(a)

LINGO Solver Status [LINGO1]	
Solver Status	
Model Class:	PILP
State:	Feasible
Objective:	1.39302e+007
Infeasibility:	0
Iterations:	103215327
Variables	
Total	571
Nonlinear:	0
Integers:	571
Constraints	
Total	460
Nonlinear:	0
Nonzeros	
Total	7675
Nonlinear:	0
Extended Solver Status	
Solver Type	B-and-B
Best Obj:	1.39302e+007
Obj Bound:	1.39404e+007
Steps:	2108932
Active:	30069
Generator Memory Used (K)	
	643
Elapsed Runtime (hh:mm:ss)	
	04:00:03
Update Interval:	2
Interrupt Solver Close	

(b)

LINGO Solver Status [LINGO1]	
Solver Status	
Model Class:	PILP
State:	Feasible
Objective:	1.41487e+007
Infeasibility:	0
Iterations:	129370078
Variables	
Total	571
Nonlinear:	0
Integers:	571
Constraints	
Total	931
Nonlinear:	0
Nonzeros	
Total	9465
Nonlinear:	0
Extended Solver Status	
Solver Type	B-and-B
Best Obj:	1.41487e+007
Obj Bound:	1.41614e+007
Steps:	1002646
Active:	47185
Generator Memory Used (K)	
	742
Elapsed Runtime (hh:mm:ss)	
	04:00:04
Update Interval:	2
Interrupt Solver Close	

(c)

LINGO Solver Status [LINGO1]	
Solver Status	
Model Class:	PILP
State:	Feasible
Objective:	1.41619e+007
Infeasibility:	0
Iterations:	51608333
Variables	
Total	571
Nonlinear:	0
Integers:	571
Constraints	
Total	1183
Nonlinear:	0
Nonzeros	
Total	14425
Nonlinear:	0
Extended Solver Status	
Solver Type	B-and-B
Best Obj:	1.41619e+007
Obj Bound:	1.41716e+007
Steps:	3085905
Active:	48773
Generator Memory Used (K)	
	1003
Elapsed Runtime (hh:mm:ss)	
	04:00:03
Update Interval:	2
Interrupt Solver Close	

(d)

ANEXO 12 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 13 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.

LINGO Solver Status [LINGO1]	
Solver Status: Model Class: PIIP State: Feasible Objective: 1.48567e+007 Infeasibility: 0 Iterations: 92531573	
Variables: Total: 758 Nonlinear: 0 Integers: 758	
Constraints: Total: 79 Nonlinear: 0	
Nonzeros: Total: 5248 Nonlinear: 0	
Extended Solver Status: Solver Type: B-and-B Best Obj: 1.48567e+007 Obj Bound: 1.49714e+007 Steps: 13110350 Active: 49298	
Generator Memory Used (K): 564 Elapsed Runtime (hh:mm:ss): 04:00:04	
Update Interval: 2	Interrupt Solver Close

(a)

LINGO Solver Status [LINGO1]	
Solver Status: Model Class: PIIP State: Feasible Objective: 1.43556e+007 Infeasibility: 0 Iterations: 94386829	
Variables: Total: 758 Nonlinear: 0 Integers: 758	
Constraints: Total: 507 Nonlinear: 0	
Nonzeros: Total: 11255 Nonlinear: 0	
Extended Solver Status: Solver Type: B-and-B Best Obj: 1.43556e+007 Obj Bound: 1.44041e+007 Steps: 1343459 Active: 49741	
Generator Memory Used (K): 915 Elapsed Runtime (hh:mm:ss): 04:00:05	
Update Interval: 2	Interrupt Solver Close

(b)

LINGO Solver Status [LINGO1]	
Solver Status: Model Class: PIIP State: Global Opt. Objective: 1.45993e+007 Infeasibility: 0 Iterations: 64795099	
Variables: Total: 758 Nonlinear: 0 Integers: 758	
Constraints: Total: 921 Nonlinear: 0	
Nonzeros: Total: 14103 Nonlinear: 0	
Extended Solver Status: Solver Type: B-and-B Best Obj: 1.45993e+007 Obj Bound: 1.45993e+007 Steps: 1794932 Active: 0	
Generator Memory Used (K): 1265 Elapsed Runtime (hh:mm:ss): 02:24:56	
Update Interval: 2	Interrupt Solver Close

(c)

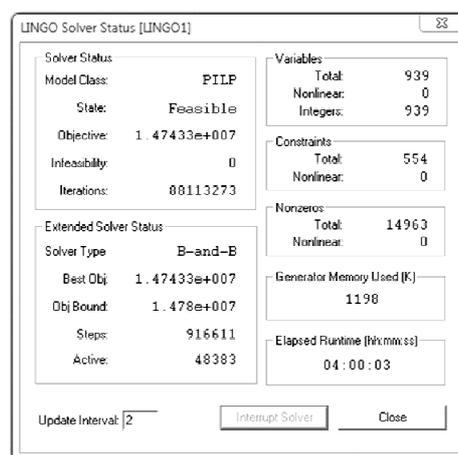
LINGO Solver Status [LINGO1]	
Solver Status: Model Class: PIIP State: Feasible Objective: 1.46075e+007 Infeasibility: 0 Iterations: 75156549	
Variables: Total: 758 Nonlinear: 0 Integers: 758	
Constraints: Total: 1315 Nonlinear: 0	
Nonzeros: Total: 21818 Nonlinear: 0	
Extended Solver Status: Solver Type: B-and-B Best Obj: 1.46075e+007 Obj Bound: 1.46182e+007 Steps: 2362167 Active: 49480	
Generator Memory Used (K): 1457 Elapsed Runtime (hh:mm:ss): 04:00:04	
Update Interval: 2	Interrupt Solver Close

(d)

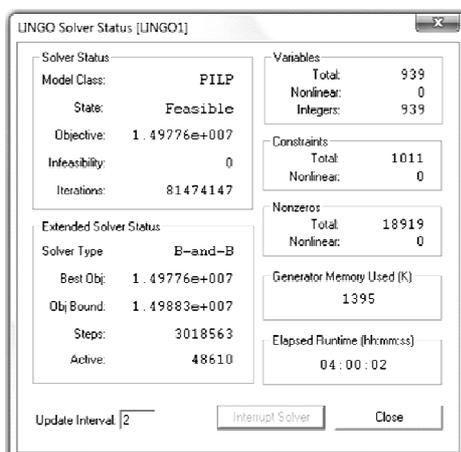
ANEXO 13 - STATUS DE PROCESSAMENTO POR MEIO DO SOFTWARE LINGO PARA O UM HP DE 14 ANOS ONDE (A) CASO 1; (B) CASO 2; (C) CASO 3 E (D) CASO 4.



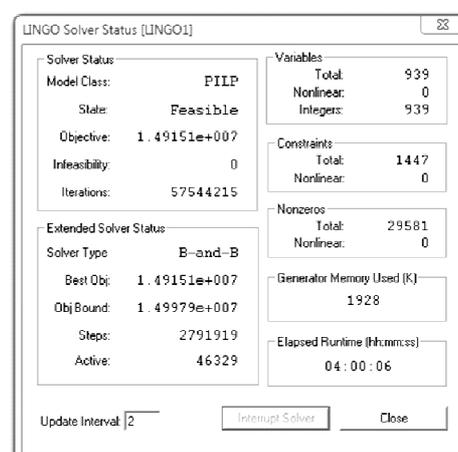
(a)



(b)



(c)



(d)

ANEXO 14 - VALORES ABSOLUTOS E DESVIOS (%) DE VPL PARA OS 32 CENÁRIOS FORMULADOS VIA PLI.

Valor	Caso	HORIZONTE DE PLANEJAMENTO							
		7	8	9	10	11	12	13	14
Absoluto (R\$)	1	11.260.780	12.139.280	12.814.860	13.363.440	13.992.340	14.474.040	14.856.740	14.860.720
	2	10.840.050	11.698.380	12.264.520	12.801.960	13.419.920	13.930.160	14.355.569	14.743.270
	3	11.008.560	11.870.290	12.460.720	13.003.810	13.641.570	14.148.680	14.599.330	14.977.630
	4	11.024.550	11.885.020	12.468.300	13.040.700	13.657.380	14.161.940	14.607.530	14.915.070
Desvio* (%)	1	-	-	-	-	-	-	-	-
	2	3,74	3,63	4,29	4,20	4,09	3,76	3,37	0,79
	3	2,24	2,22	2,76	2,69	2,51	2,25	1,73	-0,79
	4	2,10	2,09	2,70	2,42	2,39	2,16	1,68	-0,37

Onde: - soluções ótimas; * - desvio (%) dos casos 2, 3 e 4 (planejamento florestal espacial) em relação ao caso 1 (planejamento florestal tradicional).

ANEXO 15 - VALORES ABSOLUTOS DE VPL CALCULADOS PARA OS 32 CENÁRIOS FORMULADOS VIA ALGORITMO GENÉTICO.

C	R	Horizonte de planejamento (ano)							
		7	8	9	10	11	12	13	14
1	1	11.145.452	12.013.591	12.689.460	13.203.985	13.738.991	14.233.227	d	15.154.113
	2	11.174.835	11.955.406	12.618.698	13.184.961	13.780.215	14.324.480	14.566.394	d
	3	11.133.979	12.012.628	12.633.053	d	13.641.680	14.245.046	d	15.173.636
2	1	9.365.779	9.932.165	9.527.997	d	d	10.265.803	12.147.468	d
	2	9.229.448	9.029.870	10.441.658	d	d	11.708.155	12.183.583	12.498.432
	3	d	d	9.993.628	10.350.799	d	11.547.316	d	d
3	1	10.547.897	11.048.867	11.236.125	12.184.125	12.559.532	13.395.110	d	12.496.596
	2	10.510.887	10.983.418	11.472.214	11.914.062	12.502.830	11.928.132	13.580.386	13.105.727
	3	9.765.818	10.947.914	11.579.604	12.547.790	13.075.013	13.366.750	13.344.075	13.867.803
4	1	d	11.456.270	d	12.633.612	13.221.800	d	d	14.358.350
	2	d	d	d	d	12.810.405	d	13.509.987	d
	3	10.704.261	11.412.952	11.565.422	12.461.547	d	d	13.988.722	14.293.549

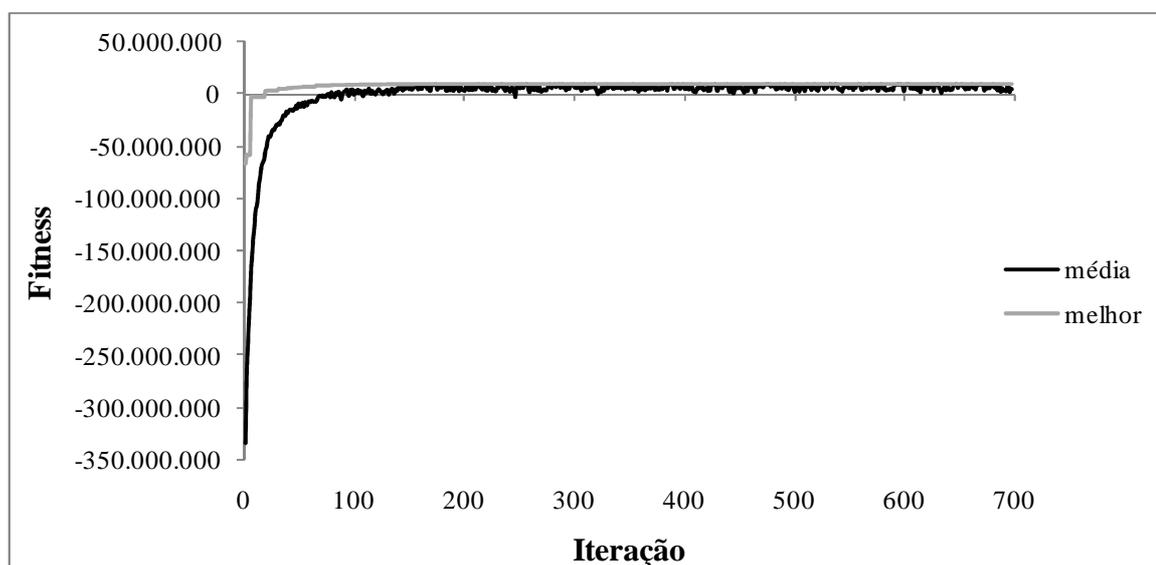
Onde: C - caso; R - repetição; d - valores descartados por não atingirem as metas estabelecidas e - melhores valores observados.

ANEXO 16 - VALORES ABSOLUTOS DE VPL CALCULADOS PARA OS 32 CENÁRIOS FORMULADOS VIA METAHEURÍSTICA *SIMULATED ANNEALING*.

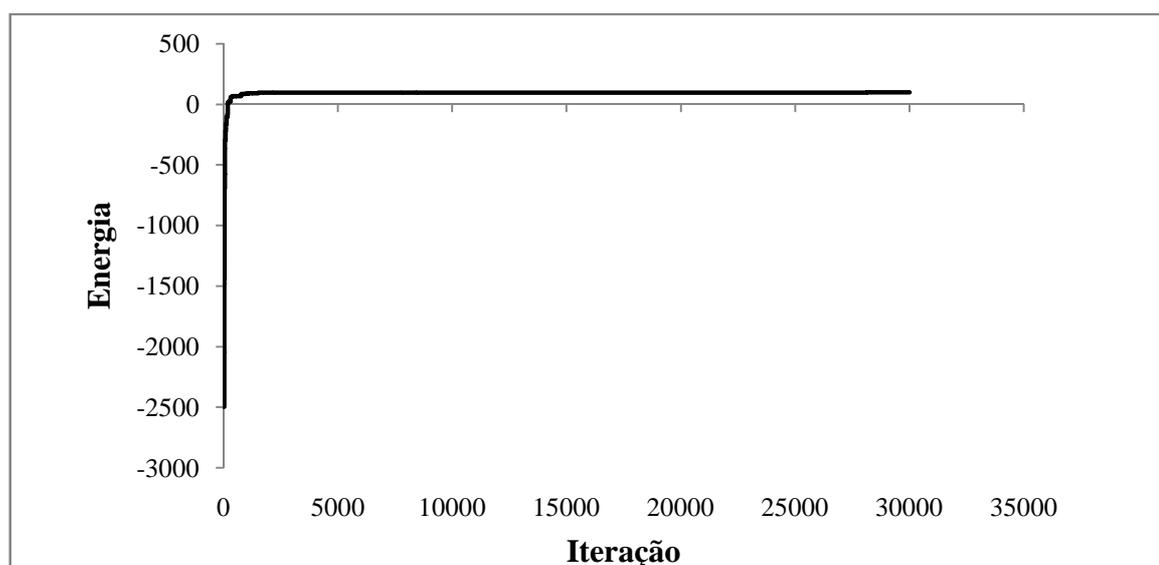
C	R	Horizonte de planejamento (ano)							
		7	8	9	10	11	12	13	14
1	1	10.984.389	11.401.668	d	12.597.732	12.735.079	13.587.480	13.721.636	14.553.640
1	2	10.537.452	11.478.636	12.041.187	13.078.717	13.314.671	13.635.021	13.392.083	d
	3	10.516.055	11.624.005	11.384.117	12.607.996	13.734.372	13.393.282	14.736.530	14.643.065
1	1	9.443.489	10.865.635	10.640.487	11.235.546	11.955.994	12.321.562	13.305.499	12.463.270
2	2	10.187.149	10.819.724	10.952.359	10.257.906	12.077.804	12.269.642	12.785.484	12.921.457
	3	9.505.861	9.704.967	11.298.610	11.363.317	11.940.018	12.864.519	11.830.923	13.297.386
1	1	10.165.756	10.475.735	10.552.480	11.702.482	12.464.716	12.886.031	12.805.986	13.128.598
3	2	9.947.504	10.529.959	11.167.292	11.211.999	12.244.942	12.886.268	13.851.007	13.584.758
	3	9.995.461	10.555.502	11.217.711	12.043.607	12.487.834	13.135.096	13.393.535	12.673.278
1	1	10.165.872	11.148.885	11.389.481	12.105.157	12.606.776	13.791.307	d	14.049.066
4	2	10.427.632	10.448.037	11.435.358	d	12.704.509	13.126.840	13.342.830	13.811.290
	3	10.659.285	d	11.863.150	12.280.933	12.528.089	12.967.791	13.706.762	d

Onde: C - caso; R - repetição; d - valores descartados por não atingirem as metas estabelecidas e - melhores valores observados.

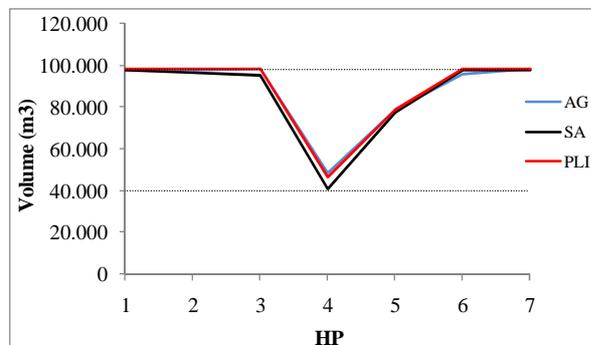
ANEXO 17 - GRÁFICO DO COMPORTAMENTO DE BUSCAS DO ALGORITMO GENÉTICO PARA O CASO 3 CONSIDERANDO UM HP DE 7 ANOS.



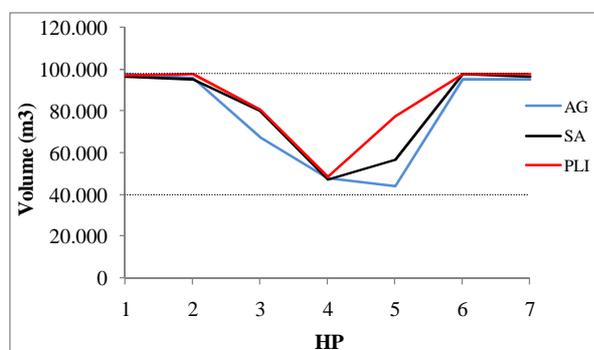
ANEXO 18 - GRÁFICO DO COMPORTAMENTO DE BUSCAS DO *SIMULATED ANNEALING* PARA O CASO 3 CONSIDERANDO UM HP DE 7 ANOS.



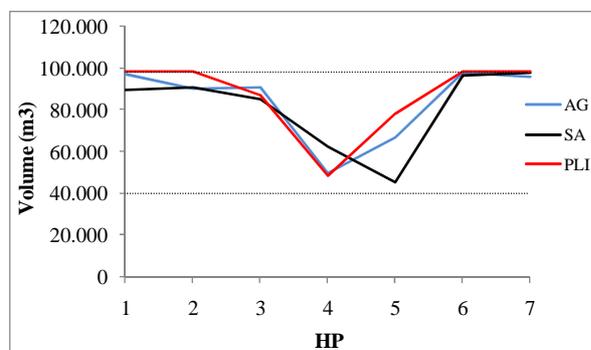
ANEXO 19 - COMPORTAMENTO VOLUMÉTRICO PARA OS 4 CASOS CONSIDERANDO OS 3 MÉTODOS DE RESOLUÇÃO E UM HP DE 7 ANOS.



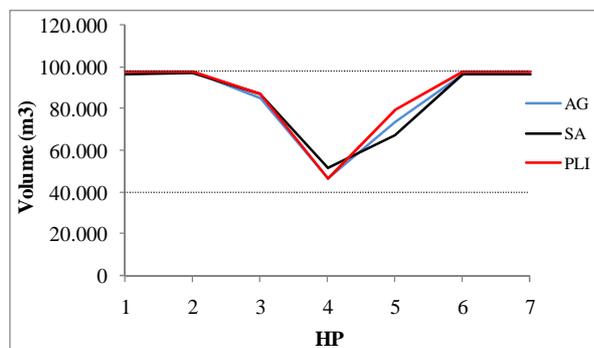
(Caso 1)



(Caso 2)

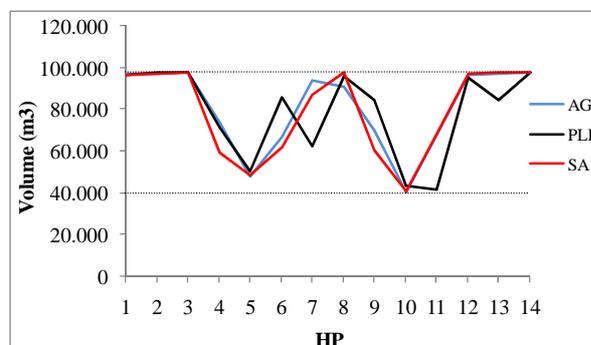


(Caso 3)

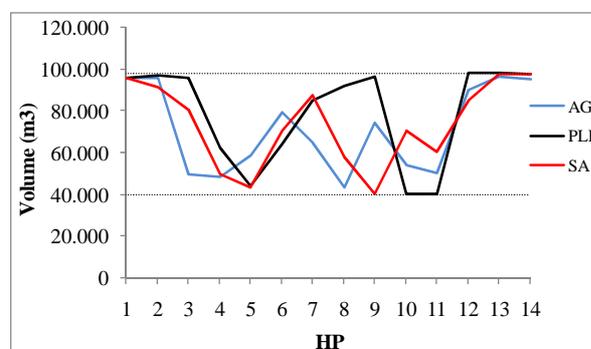


(Caso 4)

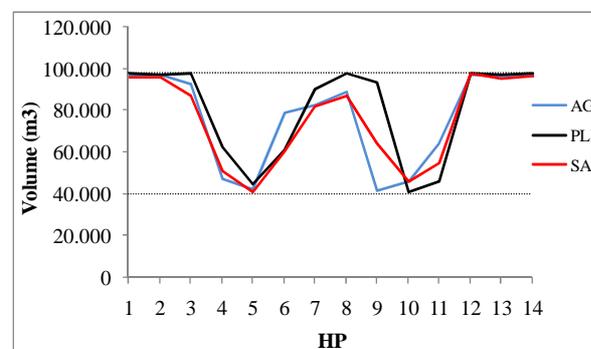
ANEXO 20 - COMPORTAMENTO VOLUMÉTRICO PARA OS 4 CASOS CONSIDERANDO OS 3 MÉTODOS DE RESOLUÇÃO E UM HP DE 14 ANOS.



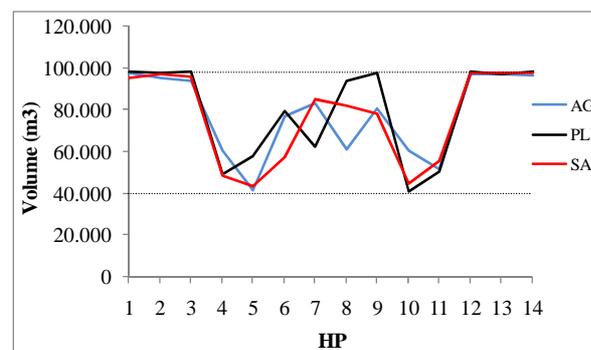
(Caso 1)



(Caso 2)

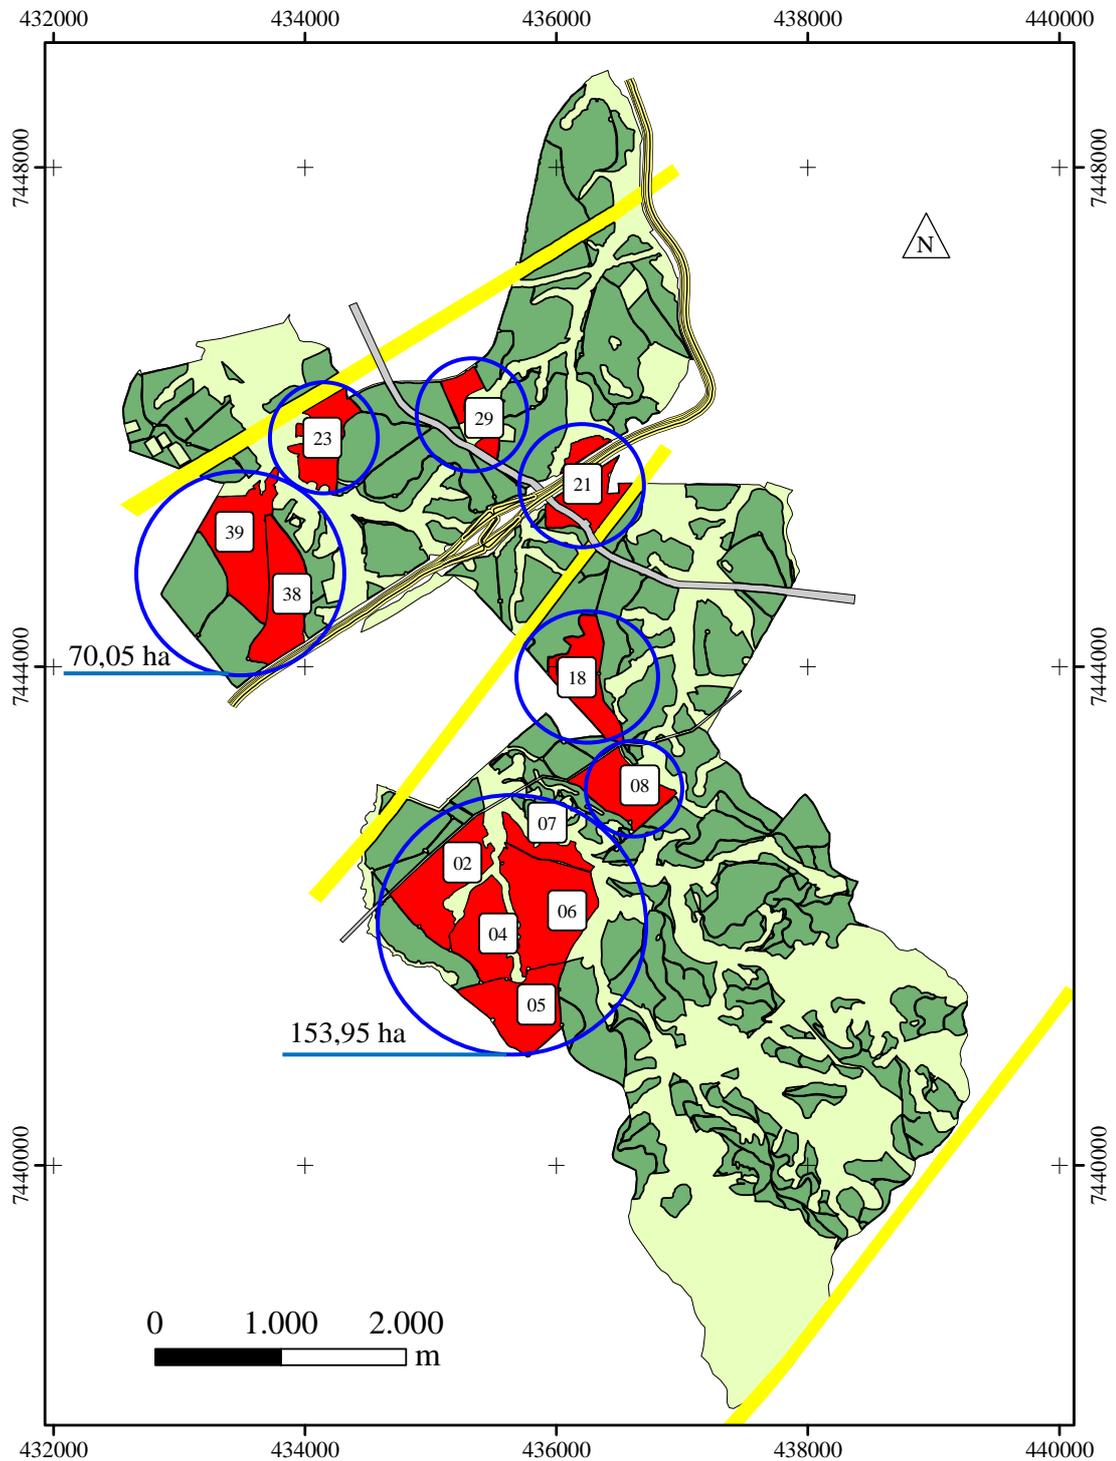


(Caso 3)



(Caso 4)

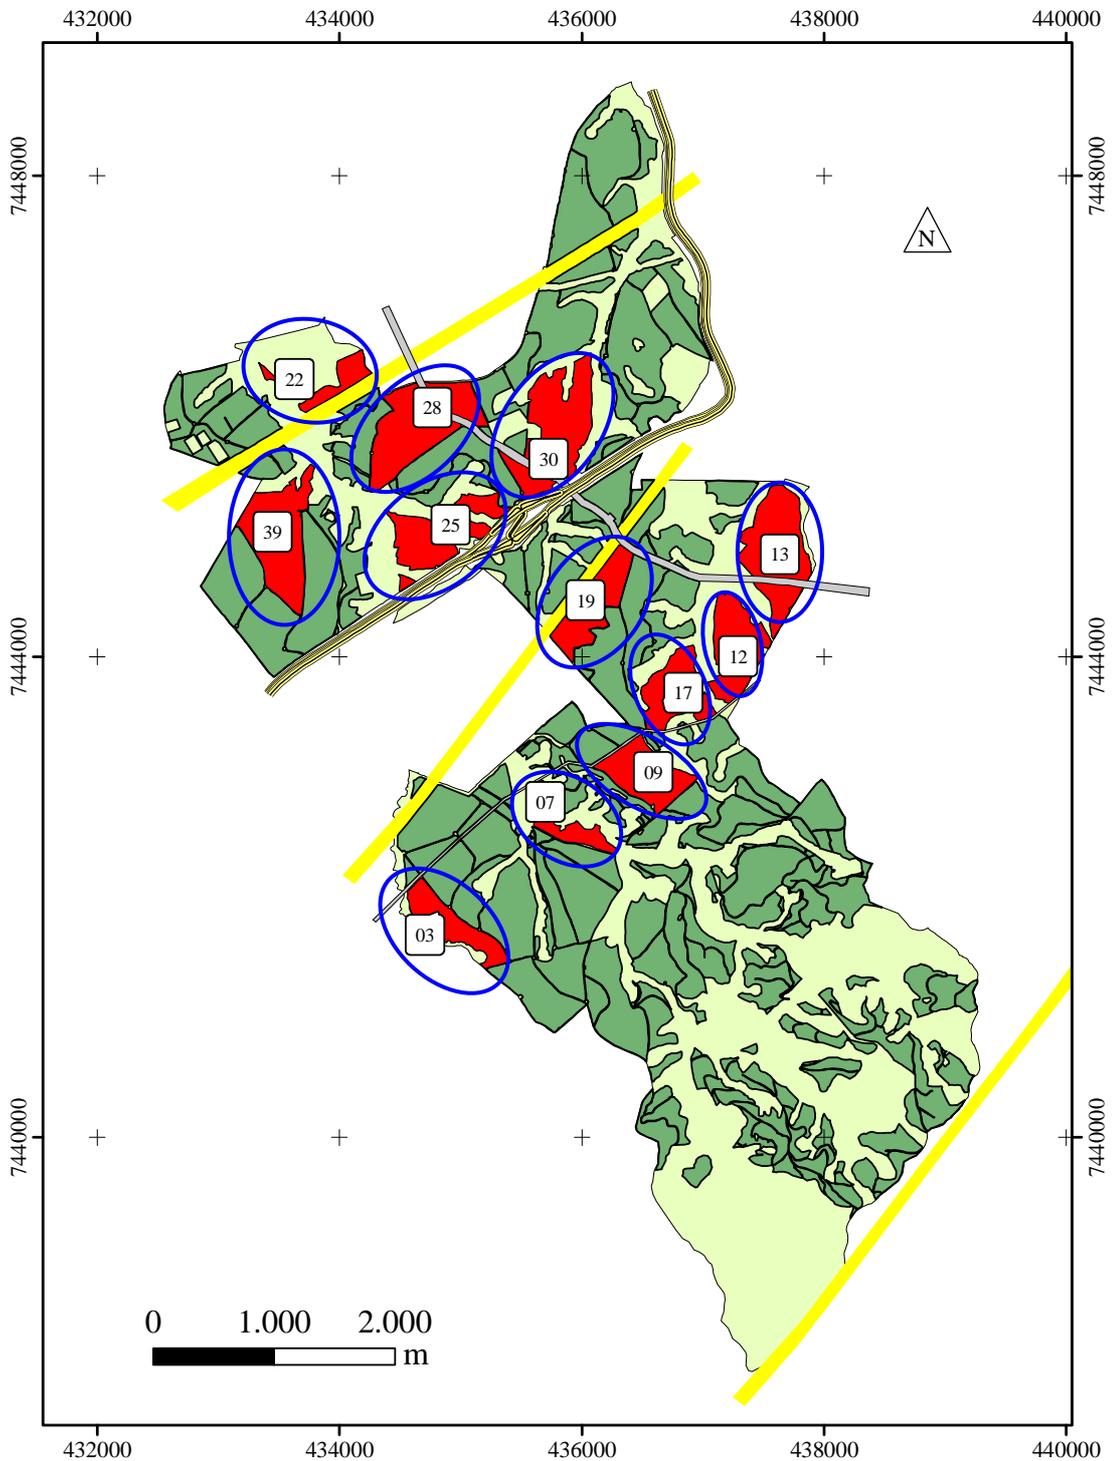
ANEXO 21 - MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 1 VIA PLI.



Legenda:

Estradas
 Modelo1
 Talhão
 Gasoduto
 Rede Elétrica
 Vegetação Nativa

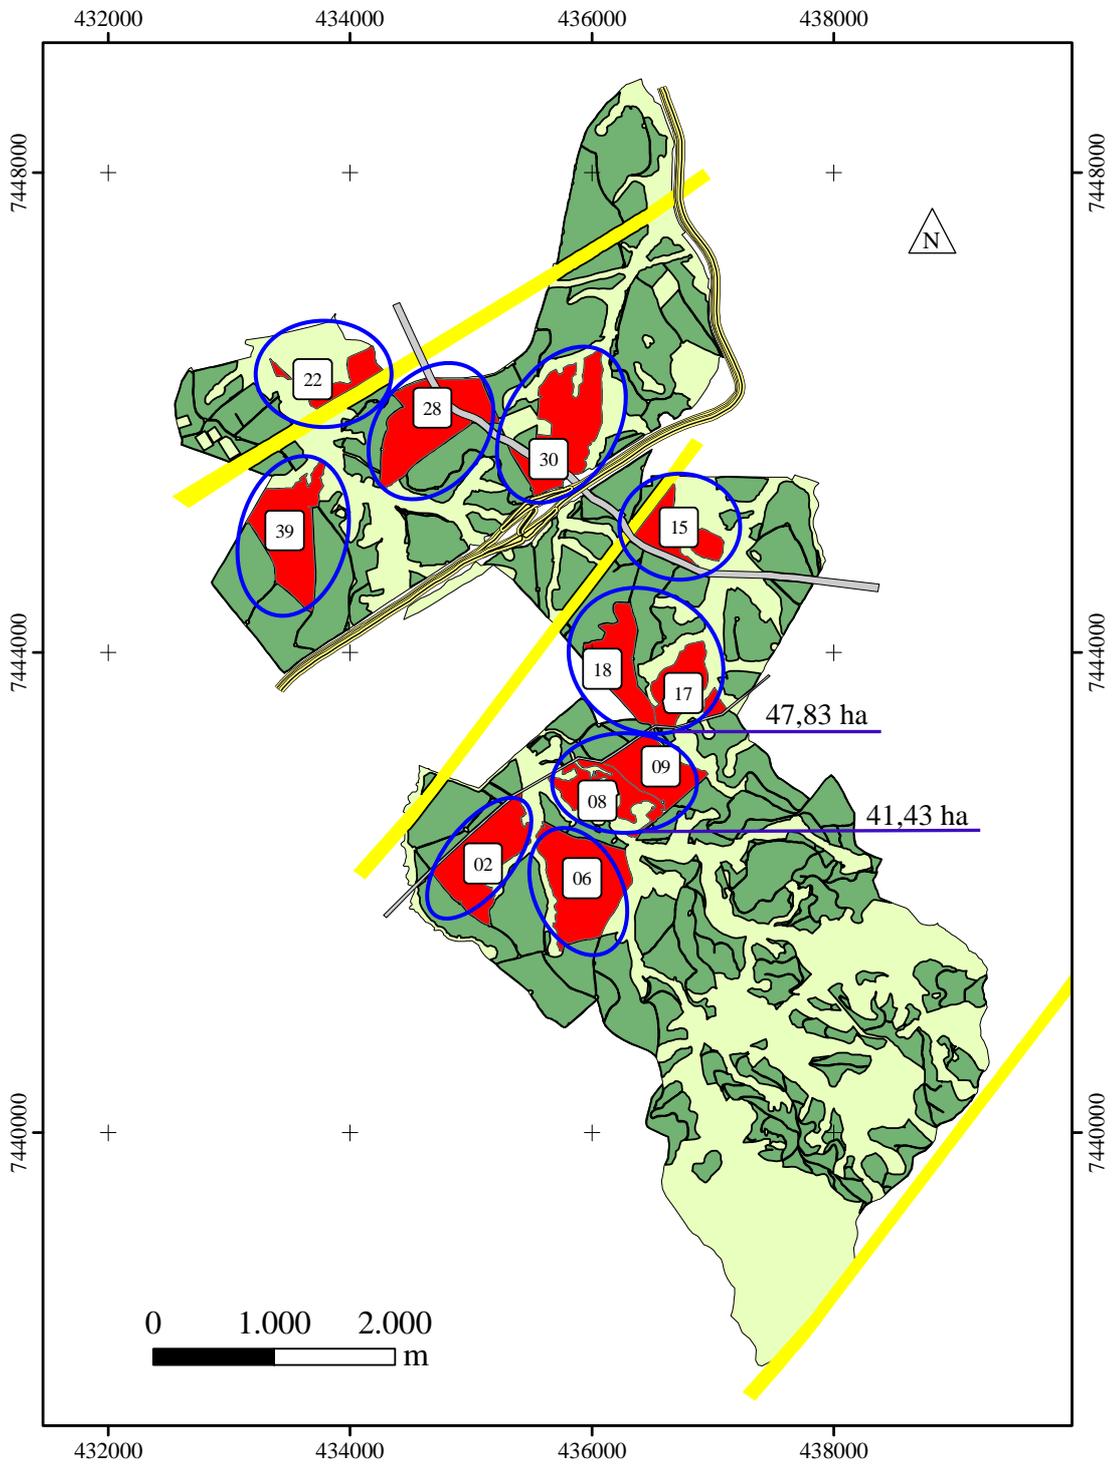
ANEXO 22 - MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 2 VIA PLI.



Legenda:

Estradas
 Modelo2
 Talhão
 Gasoduto
 Rede Elétrica
 Vegetação Nativa

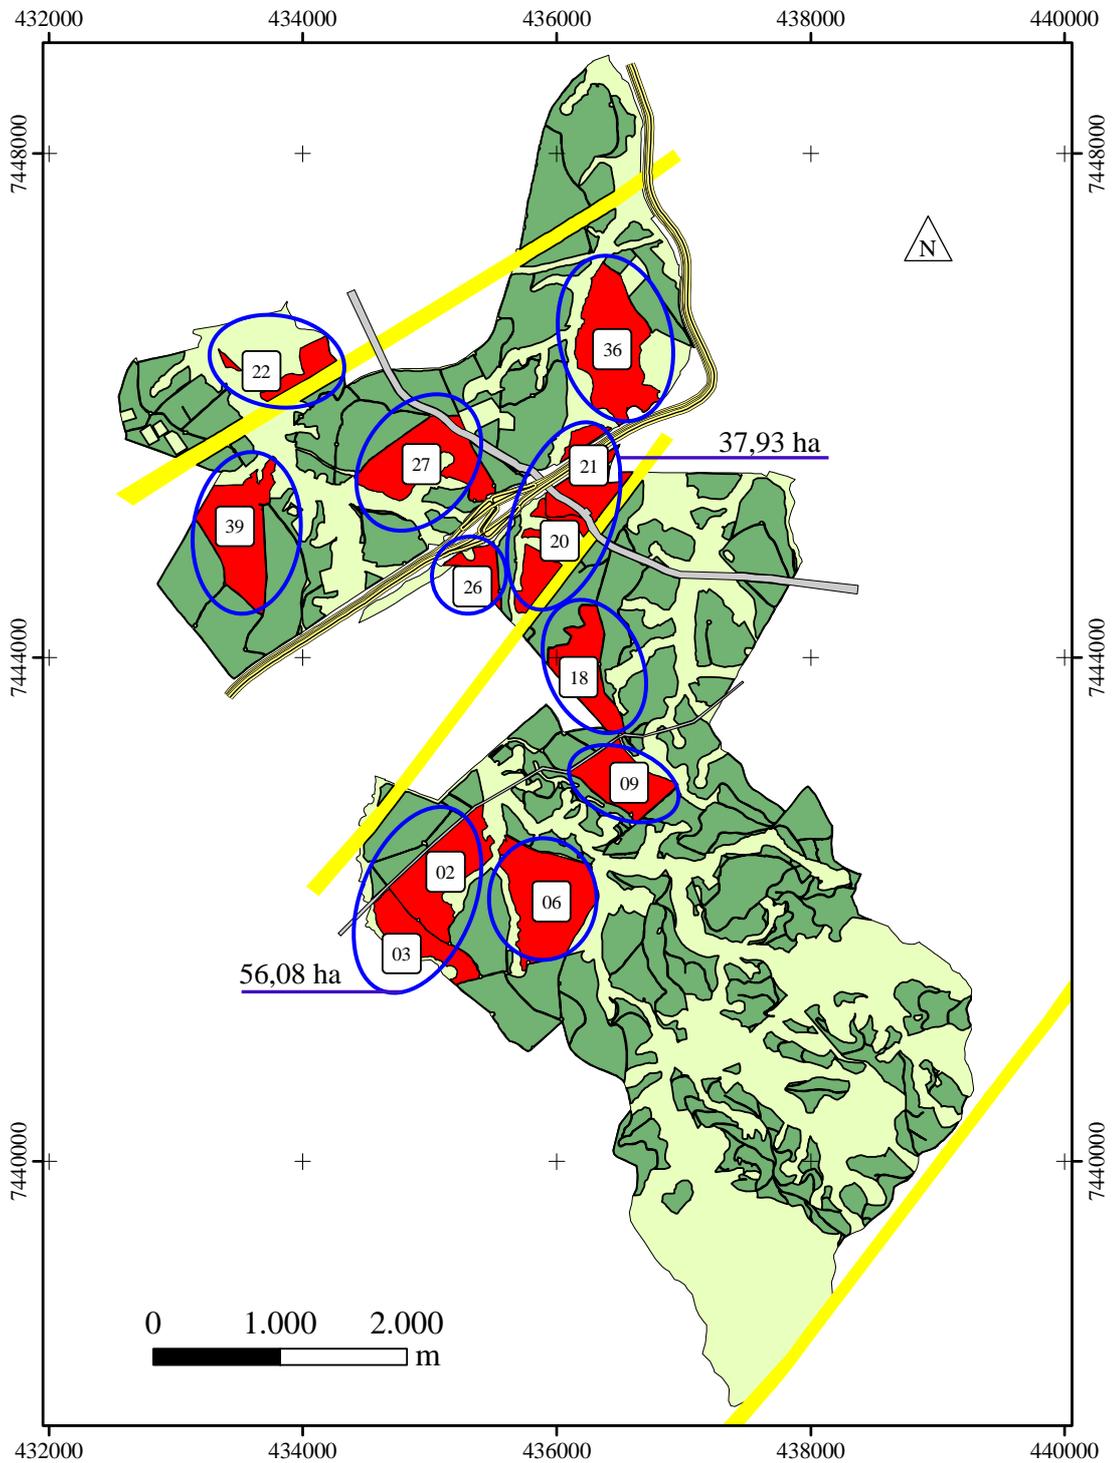
ANEXO 23 - MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 3 VIA PLI.



Legenda:

- Estradas
- Modelo3
- Talhão
- Gasoduto
- Rede Elétrica
- Vegetação Nativa

ANEXO 24 - MAPA DO AGENDAMENTO DA COLHEITA FLORESTAL PARA O SEGUNDO ANO (HP=7) DEFINIDO PELO CASO 4 VIA PLI.



Legenda:

Estradas
 Modelo4
 Talhão
 Gasoduto
 Rede Elétrica
 Vegetação Nativa

ANEXO 25 - FOTOS DA ÁREA FLORESTAL DESTINADA AO ESTUDO.



Foto a - Região próxima aos talhões de número 27 e 28, tendo como fundo os talhões 20, 21 e 26, mostrando que a operação de colheita já havia sido realizada.

Foto b - A mesma região descrita anteriormente, porém tendo como fundo os talhões de número 24, 38 e 39 e um bairro da cidade de Caçapava-SP. A foto mostra uma área onde a operação de colheita já havia sido realizada.



Foto c - Vista observada na região limítrofe entre os talhões de número 20 e 21, tendo como fundo os talhões de número 27 e 30, que já haviam passado pela operação de colheita.

Foto d - Vista da região próxima ao talhão de número 47, que apresenta idade de 2 anos, onde ao fundo se observa os talhões de número: 3, 4, 5 e 6, após a realização da colheita.

