

ANTONIO ALMEIDA DE BARROS JUNIOR

**APLICAÇÕES DE HEURÍSTICAS EM PROBLEMAS DE
PLANEJAMENTO FLORESTAL MULTIOBJETIVO**

Dissertação apresentada à
Universidade Federal de Viçosa, como
parte das exigências do Programa de
Pós-Graduação em Ciência da
Computação, para obtenção do título de
Magister Scientiae.

VIÇOSA
MINAS GERAIS - BRASIL
2010

Livros Grátis

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

Milhares de livros grátis para download.

ANTONIO ALMEIDA DE BARROS JUNIOR

**APLICAÇÕES DE HEURÍSTICAS EM PROBLEMAS DE
PLANEJAMENTO FLORESTAL MULTIOBJETIVO**

Dissertação apresentada à
Universidade Federal de Viçosa, como
parte das exigências do Programa de
Pós-Graduação em Ciência da
Computação, para obtenção do título de
Magister Scientiae

APROVADA: 26 de fevereiro de 2010

Prof. Heleno do Nascimento Santos
(Co-Orientador)

Prof. Alcione de Paiva Oliveira
(Co-Orientador)

Prof. Gilson Fernandes da Silva

Prof. André Gustavo dos Santos

Prof. José Elias Claudio Arroyo
(Orientador)

*Dedico essa dissertação aos meus pais
Antonio e Annazilda*

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus que por intercessão de N.S. Aparecida me deu força e coragem para realizar este trabalho. Agradeço por sempre colocar pessoas certas em meu caminho, que sempre me auxiliaram, não só neste trabalho, como em toda a vida.

Gostaria de agradecer à minha família, meus pais Antonio e Annazilda e aos meus irmãos Marco Antônio, Maria José e Marconi pela força e incentivo. Às minhas sobrinhas Nathália, Anna Laura e Esther e ao sobrinho Arthur por trazerem alegrias para minha vida, tornando os momentos difíceis mais suaves. À minha linda noiva Michelha, pelo amor e compreensão.

Às minhas tias Laura, Rosália, Dolores e Milinha pelo carinho e prontidão nos momentos de necessidade.

Aos meus amigos Lecinho (Vulgo Welison), Bruno Laviola, Edmar e Lissandra pelo incentivo e apoio dado na minha estadia em Viçosa. A busca desta conquista foi incentivada por vocês. Obrigado!

Aos amigos da Cientec, em especial Alessandro e Paulo Márcio pela contribuição neste trabalho, sem o apoio de vocês esta pesquisa não seria realizada.

À Faculdade Santa Marcelina, aos colegas de trabalho Paulo, Gustavo, Tarcísio, Carlos, Érica e Emília. E aos meus alunos que me ensinam tanto quanto aprendem.

Ao Departamento de Informática da Universidade Federal de Viçosa nos nomes de José Luiz e Altino. Em especial meus orientadores, José Elias, Heleno e Alcione pela atenção dada e comprometimento na orientação.

Aos professores convidados André e Gilson, pela prontidão em avaliar e contribuir com este trabalho.

BIOGRAFIA

ANTONIO ALMEIDA DE BARROS JUNIOR, filho de Antonio Almeida de Barros e Annazilda Pedrosa de Barros, brasileiro nascido em 17 de março de 1978 na cidade de Carangola, no estado de Minas Gerais.

No ano de 1997, após concluir o ensino médio na Escola Estadual Santo Agostinho na cidade de São Francisco do Glória, ingressou no curso Técnico em Processamento de Dados na Escola Agrotécnica Federal de Barbacena, concluindo em 1999. No ano de 2000 ingressou no curso de graduação em Sistemas de Informação na Universidade Iguazu onde concluiu no ano de 2004.

Em 2007, foi aprovado na seleção do programa de pós-graduação do Departamento de Informática – DPI, onde, em março de 2007, iniciou o mestrado em Ciência da Computação na Universidade Federal de Viçosa – UFV, defendendo sua dissertação em fevereiro de 2010.

Atualmente, trabalha como Analista de Sistemas na empresa Cientec, desde março de 2005 e é docente na Faculdade de Filosofia Ciências e Letras Santa Marcelina - FAFISM, desde março de 2006.

SUMÁRIO

LISTA DE FIGURAS	vii
LISTA DE TABELAS	ix
LISTA DE ABREVIATURAS E SIGLAS	x
RESUMO	xi
ABSTRACT	xii
1 INTRODUÇÃO	1
1.1 Motivação	4
1.2 Objetivos.....	9
1.3 Organização desse documento	9
2 REFERENCIAL TEÓRICO	11
2.1 O Problema de Planejamento Florestal.....	11
2.2 Otimização Multiobjetivo	14
2.3 Sistemas de Apoio a Decisão (SAD).....	17
2.4 Trabalhos Correlatos	19
3 METODOLOGIA	20
3.1 O Gerador de Prescrições	20
3.2 O Modelo.....	23
3.3 Heurística ILS Multiobjetivo para um Problema de Planejamento Florestal...26	
3.3.1 Construção Aleatória e Representação da Solução	29
3.3.2 Seleção da Solução.....	30
3.3.3 Perturbação	32
3.3.4 Busca Local	32
3.4 Heurística <i>SPEA</i> para um Problema de Planejamento Florestal	34
3.5 Problemas Testes.....	35
3.6 Avaliação das Soluções	38
4 RESULTADOS.....	40
4.1 Análise dos Parâmetros do Algoritmo <i>ILSMulti</i>	40

4.1.1	Análise dos Parâmetros	40
4.1.2	Análise do Método de Seleção.....	42
4.2	Comparação do <i>ILSMulti</i> com o SPEA	44
4.3	Comparação do <i>ILSMulti</i> com Resultados Obtidos no CPLEX.....	53
4.4	Comparação do <i>ILSMulti</i> com Outra Heurística da Literatura.....	56
5	CONCLUSÕES E PERSPECTIVAS FUTURAS.....	61
6	REFERÊNCIAS BIBLIOGRÁFICAS	63

LISTA DE FIGURAS

Figura 1.1 Distribuição das florestas plantadas com eucalipto e pinus no Brasil por estado em 2008.	5
Figura 1.2: Evolução do plantio anual com florestas plantadas de eucalipto e pinus das empresas associadas da ABRAF por espécie (2000-2008).	7
Figura 2.1 Floresta dividida em unidades de produção.	12
Figura 2.2 Floresta dividida em unidades de produção.	13
Figura 2.3 Diferentes idades de uma floresta.	14
Figura 2.4 Conjunto de soluções Pareto-ótimas.	16
Figura 2.5 Exemplo de dominância.	16
Figura 3.1 Módulo Dados do protótipo.	21
Figura 3.2 Módulo Gerador de Prescrições do Protótipo.	22
Figura 3.3 ILS Básico Mono-objetivo.	26
Figura 3.4 Pseudocódigo do Procedimento IGS.	27
Figura 3.5 Pseudocódigo do Procedimento MOIGS.	28
Figura 3.6 Pseudocódigo do Procedimento <i>ILSMulti</i>	28
Figura 3.7 Lista encadeada de soluções dominantes.	29
Figura 3.8 Esquema representativo da solução. Na solução <i>S</i> são utilizadas as alternativas de manejo 03, 07, ..., 07 para as unidades de produção <i>A</i> , <i>B</i> , ..., <i>U</i> , respectivamente.	30
Figura 3.9 Esquema representativo da alternativa de manejo.	30
Figura 3.10 Esquema representativo da seleção seqüencial.	31
Figura 3.11 Procedimento de Perturbação.	32
Figura 3.12 Procedimento de Busca Local.	33
Figura 3.13 Procedimento de Busca Local.	34
Figura 3.14 Pseudocódigo do Procedimento SPEA.	35
Figura 3.15 Idades de Corte entre o 5º e o 8º período do horizonte.	36

Figura 4.1 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e SPEA para o problema 1	47
Figura 4.2 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e SPEA para o problema 7	48
Figura 4.3 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e SPEA para o problema 13	49
Figura 4.4 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e SPEA para o problema 19	50
Figura 4.5 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e SPEA para o problema 25	51
Figura 4.6 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e SPEA para o problema 30	52
Figura 4.7 Distribuição dos pontos no eixo Excesso de Produção.....	54
Figura 4.8 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e PSA para o Problema 1	58
Figura 4.9 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e PSA para o problema 14	59
Figura 4.10 Fronteira Pareto-Ótima construída pelos algoritmos <i>ILSMulti</i> e PSA para o problema 27	60

LISTA DE TABELAS

Tabela 3.1 Volumes de produção para as diferentes idades da floresta.	36
Tabela 3.2 Custos médios das atividades principais.	36
Tabela 3.3 Problemas-teste utilizados para as demonstrações propostas.	37
Tabela 4.1 Problemas utilizados para calibrar o parâmetro d	41
Tabela 4.2 Número de soluções encontradas pelo metaheurística <i>ILSMulti</i> com diferentes valores para o parâmetro h	42
Tabela 4.3 Número de soluções encontradas pela metaheurística <i>ILSMulti</i> com diferentes métodos de seleção da próxima solução.	43
Tabela 4.4 Número de soluções encontradas pelas metaheurísticas <i>ILSMulti</i> e SPEA.	44
Tabela 4.5 Desempenho das metaheurísticas <i>ILSMulti</i> e SPEA (medida de distância)	45
Tabela 4.6 Tempo gasto pelo <i>software</i> CPLEX, versão 11.	55
Tabela 4.7 Desempenho dos métodos <i>ILSMulti</i> e CPLEX (medida de distância)	55
Tabela 4.8 Número de soluções encontradas pelas metaheurísticas <i>ILSMulti</i> e PSA.	56

LISTA DE ABREVIATURAS E SIGLAS

- AM - Alternativa de Manejo
- CPLEX - Software matemático de otimização
- EIS - *Executive Information Systems*
- GRASP - *Greedy Randomized Adaptive Search Procedure*
- IGS - *Iterated Greedy Search*
- ILS - *Iterated Local Search*
- ILSMulti - *Multi-Objective Iterated Local Search*
- ILSS - Método de seleção seqüencial
- ILSR - Método de seleção randômico
- LD - Lista de Soluções
- LDR - Soluções dominantes que fazem parte do conjunto referência
- LUP - Lista de Unidades de Produção
- MOIGS - *Multi-Objective Iterated Greedy Search*
- PI - Programação Inteira
- PL - Programação Linear
- PMO - Programação com Múltiplos Objetivos
- PSA - *Pareto Simulated Annealing*
- SI - Sistemas de Informação
- SAD - Sistemas de Apoio a Decisão
- SGBD - Sistemas de Gerenciamento de Banco de Dados
- SLS - *Stochastic Local Search*
- SPEA - *Strength Pareto Evolutionary Algorithm*
- UP - Unidade de Produção
- VBPF - Valor Bruto da Produção Florestal
- VPL - Valor Presente Líquido

RESUMO

BARROS JUNIOR, Antonio Almeida de, M.Sc., Universidade Federal de Viçosa, fevereiro de 2010. **Aplicações de heurísticas em problemas de planejamento florestal multiobjetivo.** Orientador: José Elias Claudio Arroyo. Co-Orientadores: Heleno do Nascimento Santos e Alcione de Paiva Oliveira.

O presente trabalho tem como objetivo discutir a aplicabilidade do Algoritmo *ILSMulti* na solução de Problemas de Planejamento Florestal Multiobjetivo. Para tanto, foi proposto um modelo de otimização sob dois critérios e implementado os algoritmos *ILSMulti* (*Iterated Local Search*) e SPEA (*Strength Pareto Evolutionary Algorithm*). O algoritmo *ILSMulti* é uma variação do algoritmo MOIGS (*Multi-Objective Iterated Greedy Search*), enquanto que o SPEA fora proposto por TEIXEIRA (2002). Foram realizados diversos testes para a resolução de problemas de otimização, utilizando-se os algoritmos implementados, tendo o *ILSMulti* mostrado boa performance. Como forma de comparação, para cada instância, foi definido um conjunto referência com os resultados gerados pelos algoritmos, obtendo-se as medidas de cardinalidade e de distância das soluções. Também foram realizadas comparações de algumas instâncias com o *software* CPLEX, que utiliza o algoritmo exato *branch-and-bound*, utilizado na solução de problemas de Programação Inteira 0-1. Os resultados mostraram que, das 30 instâncias testadas, o *ILSMulti* obteve um número superior de soluções dominantes em 26 instâncias quando comparado com o SPEA que obteve apenas 4 instâncias. Em relação à medida de distância, o *ILSMulti* também se mostrou mais eficiente. Conclui-se que a metaheurística *ILSMulti* torna-se uma boa alternativa para o tratamento de Problemas de Planejamento Florestal Multiobjetivo. Seu desempenho mostrou-se satisfatório e bem superior aos algoritmos evolucionários, em particular o SPEA, tendo em vista o conjunto de problemas-teste.

ABSTRACT

BARROS JUNIOR, Antonio Almeida de, M.Sc., Universidade Federal de Viçosa, February, 2010. **Applications of heuristics in problems of forestry planning multiobjetivo.** Adviser: José Elias Claudio Arroyo. Co- Advisers: Heleno do Nascimento Santos and Alcione de Paiva Oliveira.

The purpose of the present work is to discuss the applicability of the algorithm *ILSMulti* in solving problems of multi-objective Forest Planning. Therefore, a model was proposed under two optimization criteria and algorithms implemented *ILSMulti* (*Iterated Local Search*) and SPEA (*Strength Pareto Evolutionary Algorithm*). The *ILSMulti* algorithm is a variation of the algorithm MOIGS (*Multi-Objective Iterated Greedy Search*), while the SPEA was proposed by TEIXEIRA (2002). Were performed several tests to solve optimization problems, using the algorithms implemented, the *ILSMulti* shown good performance. As comparison way, for each instance, a group reference was defined with the results generated by the algorithms, which provided measurements of distance and cardinality of solutions. Also comparisons were accomplished of some instances with the software CPLEX, which uses the exact algorithm *branch-and-bound*, used in solving problems of 0-1 integer programming. The results showed that of the 30 instances tested, the *ILSMulti* obtained a higher number of dominant solutions in 26 instances when compared with the SPEA that received only 4 instances. Regarding the measure of distance, the *ILSMulti* was also more efficient. It is concluded that the metaheuristic *ILSMulti* becomes a good alternative for the treatment of problems multi-objective Forest Planning. Its performance was satisfactory and well above the evolutionary algorithms, in matter the SPEA, on the set of test problems.

1 INTRODUÇÃO

A Pesquisa Operacional (PO) pode ser descrita como uma abordagem científica para o processo de tomada de decisão que envolva operações de um sistema organizacional. A PO envolve pesquisa em operações e a base para a sua aplicação é sempre o problema, onde a busca da otimalidade desempenha um papel central. Uma característica importante e que facilita o processo de análise e de decisão é a utilização de modelos (RIBEIRO, 2007).

Os problemas de otimização, na sua forma geral, têm como objetivo maximizar ou minimizar uma função definida sobre um certo domínio. A teoria clássica de otimização trata do caso em que o domínio é infinito. Já no caso dos chamados problemas de otimização combinatória, o domínio é tipicamente finito; portanto, no geral, é possível listar os elementos e também testar se um dado elemento pertence a esse domínio. Ainda assim, a idéia ingênua de testar todos os elementos deste domínio na busca pelo melhor mostra-se inviável na prática, mesmo para instâncias de tamanho moderado (MIYAZAWA, 2007).

Considerada uma disciplina de tomada de decisões no caso de problemas discretos, a Otimização Combinatória pode ser encontrada em diversas áreas, tais como, problemas de planejamento e programação (scheduling) da produção, problemas de corte e empacotamento, roteamento de veículos, problemas de localização, problemas de planejamento florestal, dentre outras. É comum nestes problemas surgirem vários critérios de desempenho (funções objetivos), em geral, conflitantes entre si. Estes objetivos conflitantes são mais a regra do que a exceção em diversos problemas reais e a otimização multiobjetivo é utilizada para tratar essas situações (ARROYO, 2002).

Para COELHO (1999) citando OSYCZKA (1985), a otimização multiobjetivo (também chamada otimização multicritério, multiperformance ou otimização de vetor) pode ser definida como o problema de “buscar um vetor de variáveis de decisão que satisfaça as restrições e otimize um vetor de funções cujos elementos representam as funções-objetivo. Estas funções formam uma

descrição matemática do critério de desempenho e, normalmente, estão em conflito umas com as outras”.

De acordo VAN VELDHUIZEN e LAMONT (2000), os problemas de otimização com um único objetivo podem produzir uma única solução ótima. Enquanto que os problemas de otimização multiobjetivos (POM's) podem apresentar um conjunto incontável de soluções, que, quando avaliadas, produzem vetores cujos componentes representam os *trade-offs* no espaço de solução. Um tomador de decisão (TD) então escolhe, implicitamente, uma solução aceitável (ou solução Pareto-ótima) através da seleção de um ou mais desses vetores. Tais soluções são denominadas soluções ótimas, uma vez que são superiores às demais soluções viáveis no espaço de busca onde devem ser considerados todos os objetivos.

Portanto, a solução de problemas multiobjetivo na área científica e de engenharia é, em geral, uma meta muito difícil. E nesses problemas de otimização em particular, os objetivos freqüentemente competem através de um espaço de alta dimensão e podem requerer extensivos recursos computacionais (PEREIRA, 2004). Em decorrência desse fato, torna-se relevante a busca por alternativas para solucionar tais problemas, visto que muitos problemas do mundo real envolvem dois tipos de dificuldades: objetivos múltiplos e conflitantes e um espaço de busca altamente complexo (ZITZLER, 1999. FONSECA e FLEMING, 1995). Em se tratando de processo de planejamento da produção florestal (manejo florestal) não é diferente, uma vez que existe um grande número de variáveis envolvidas.

TEIXEIRA (2002) destaca características inerentes aos problemas de planejamento do manejo florestal que demonstram o que fora exposto anteriormente: natureza combinatorial, problema típico de programação inteira, objetivos competitivos e conflitantes e por se tratar de um problema de natureza estocástica por conter muitas variáveis aleatórias.

LEUSCHENER (1984) define o manejo florestal da seguinte maneira:

O gerenciamento florestal se refere ao estudo e aplicação de técnicas analíticas de busca das alternativas de gerenciamento que mais contribuem para os objetivos organizacionais.

As alternativas de gerenciamento florestal mencionadas na definição podem ser vistas como as diferentes formas de ação à disposição do gerente

florestal para atingir seus objetivos. Dentre as alternativas, pode-se citar: *cortar ou não cortar* uma determinada área, *tipo de corte*, *práticas de reflorestamento* e outras. Enfim, as alternativas dependem das diferentes possibilidades físicas de produção da floresta sob intervenção que, por sua vez, são afetadas pela intervenção do homem. É fundamental, portanto, conhecer às conseqüências de tais intervenções. Técnicas analíticas (instrumentos de auxílio ao processo de tomada de decisão) são, então, utilizadas para se avaliar quão próximo dos objetivos se encontra o planejador florestal (por exemplo, valor presente líquido e outras técnicas de descapitalização).

Neste contexto, observa-se que para alcançar múltiplos objetivos, os manejadores florestais necessitam, além de grande habilidade e experiência, ferramentas adequadas para apoiá-los na tarefa de tomada de decisão. A quantidade de áreas manejadas pelas empresas florestais e o crescente desenvolvimento tecnológico da silvicultura fazem com que seja impossível gerir a atividade florestal sem apoio da tecnologia de informação (TI). A TI apoia os gestores florestais a cumprir o seu compromisso de abastecer a indústrias com regularidade e sustentabilidade, nos três níveis de planejamento da produção florestal: estratégico, tático e operacional (NOBRE et al., 2004).

Dentre as diversas ferramentas matemáticas atualmente aplicadas com o objetivo de otimizar o planejamento da produção florestal, as técnicas de Programação Linear (PL) constituem, sem dúvida, o instrumental analítico mais utilizado. Exemplos de uso desses modelos para este fim podem ser encontrados em STEUER & SCHULER (1978), em CLUTTER et al. (1983), em RODRIGUEZ et al. (1985), e em LAROZE (1999), dentre outros. Por outro lado, de acordo com FATURETO & SANTOS (1999a; 1999b) e SILVA et al. (2003) apesar da inegável importância das técnicas de PL para solução de problemas de planejamento florestal, deve-se reconhecer que esta metodologia apresenta algumas deficiências, tais como as pressuposições de que o relacionamento entre as variáveis consideradas é linear, as restrições também lineares, devem ser estritamente respeitadas e as escolhas são feitas a partir de um único critério e um único objetivo.

Segundo RODRIGUES et al. (2000), apesar do grande avanço da Pesquisa Operacional (PO) na área florestal, com a evolução dos modelos de Programação Linear (PL) para modelos de Programação Inteira (PI) e Programação com

Múltiplos Objetivos (PMO), com relatos de uma infinidade de trabalhos enfocando a utilização desses modelos no suporte à tomada de decisão no planejamento florestal, a solução de problemas de grande porte tem sido ainda bastante limitada, principalmente no Brasil.

1.1 Motivação

As florestas, entre elas as florestas plantadas, são fonte de recursos e riquezas para a humanidade e esses benefícios vão além do simples retorno econômico através de produtos madeireiros e não-madeireiros. O setor de florestas plantadas no Brasil desempenha um papel fundamental no cenário sócio-econômico do país, ao contribuir com a produção de bens e serviços, agregação de valor aos produtos florestais e para a geração de empregos, divisas, tributos e renda.

Explorado por empresas florestais, esse setor também contribui para o meio ambiente por manter o equilíbrio dos ecossistemas naturais; regular o clima global; conservar os recursos hídricos; proteger a biodiversidade e os ecossistemas florestais (conservação da fauna e flora); fixação de carbono; reduzir o nível de desmatamento ilegal e o impacto sobre as florestas nativas através das florestas plantadas; regularizar os fluxos de água para evitar erosão. Além disso, é uma fonte de biodiversidade e de contribuição para sua manutenção (ABIMCI, 2008).

Como o setor florestal brasileiro tem grande potencial a ser explorado e como o país apresenta condições físicas e naturais para o desenvolvimento do mesmo, como elevada extensão de terras apropriadas, mão-de-obra abundante, clima e solo favoráveis, tecnologia silvicultural avançada e rápido crescimento das plantações florestais, o investimento na atividade florestal pode contribuir ainda mais para o desenvolvimento sócio-econômico do país (SOARES, 2006).

ROCHA (2002), analisando a estrutura de organização das empresas florestais ao longo das décadas, percebeu que o foco de suas atividades está permanentemente voltado para a sustentabilidade do empreendimento e dos recursos como um todo.

De acordo com a Associação Brasileira de Produtores de Florestas Plantadas (ABRAF, 2009), o segmento de florestas plantadas no Brasil mantém atualmente cerca de 6,1 milhões de hectares cultivados com eucalipto e pinus, tendo sido responsável por 3% do total das exportações em 2008, o que

representou um valor de aproximadamente US\$ 6,8 bilhões, recolhendo R\$ 8,82 bilhões em tributos, representando 0,83% de participação deste setor no total do Brasil e gerando 636,2 mil empregos diretos. Apesar do ano de 2008 ter sido afetado pela crise econômica mundial no 4º trimestre, a estimativa do VBPF (Valor Bruto da Produção Florestal) do setor de florestas plantadas alcançou R\$ 52,8 bilhões, em 2008, contra R\$ 49,8 bilhões em 2007.

Grande parte da produção da indústria florestal brasileira é baseada em plantações florestais de rápido crescimento, principalmente de eucaliptos. Através da Figura 1.1, observa-se o percentual da distribuição das florestas plantadas, entre eucalipto e pinus, nos principais estados brasileiros.

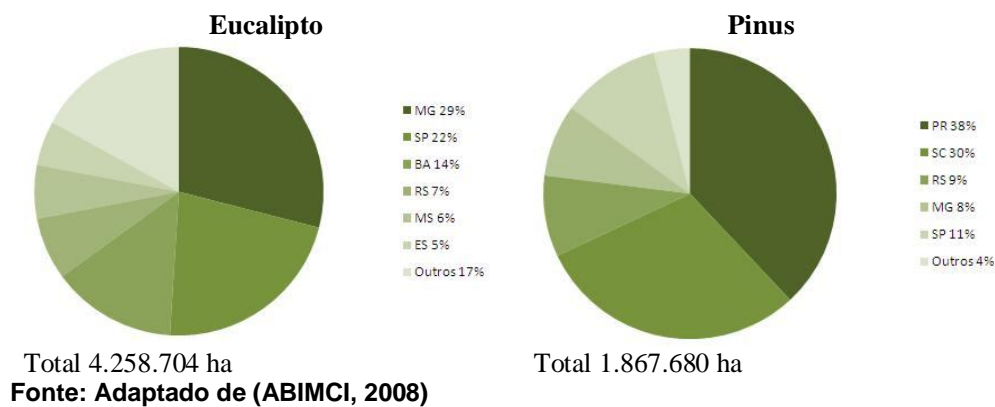


Figura 1.1 Distribuição das florestas plantadas com eucalipto e pinus no Brasil por estado em 2008.

As florestas plantadas se concentraram nos últimos 40 anos, principalmente, nas regiões Sul e Sudeste do país e mais recentemente têm se expandido para outras regiões, como o Nordeste, Norte e o Centro-Oeste. Os plantios florestais, via de regra, são impulsionados por empresas consumidoras da madeira. Nesse sentido, e em busca de novas fronteiras, algumas empresas, com o apoio dos governos estaduais, estão investindo em estados até então considerados não tradicionais na cultura florestal. Dentre eles, destacam-se o Piauí e o Maranhão, regiões não tradicionais da Bahia, os estados do Mato Grosso do Sul e Mato Grosso, na região Centro Oeste, e ainda as expansões de florestas plantadas, em menor escala, no estado do Pará (Norte).

O Programa Florestal destes estados prevê a geração de condições que possam conduzir à implementação de um modelo sustentado de desenvolvimento setorial, tendo como base todo o potencial a partir de florestas plantadas, além da capacidade de transformação desse potencial em bens e serviços. O resultado

esperado é o de alavancar o crescimento sob os princípios da sustentabilidade, atendendo critérios sócio-ambientais.

De acordo com a ABRAF (2009), em 2008, uma das maiores empresas produtoras de celulose e papel do país anunciou a instalação de duas novas fábricas, sendo uma no estado do Piauí e a outra no Maranhão. A empresa prevê aplicar aproximadamente US\$ 1,8 bilhão em cada projeto até 2015. A base florestal da empresa no Piauí deverá ser 70% constituída a partir de plantios próprios e 30% a partir de produtores locais.


Outro estado que está expandindo rapidamente o cultivo de florestas plantadas é o Mato Grosso do Sul que, entre 2004 a 2008, aumentou sua área plantada de 126.717 ha para 284.051 ha (eucalipto e pinus). Segundo estimativas, os investimentos no estado até 2010 podem atingir R\$ 4 bilhões, em reforma e expansão florestais, associados também a novas plantas industriais.

Em Minas Gerais, o Governo do Estado, em parceria com outras instituições, vem atuando na promoção de estudos e programas voltados para o setor florestal, tendo recentemente criado o Centro de Inteligência de Florestas - CIF (www.ciflorestas.com.br), no âmbito do Pólo de Excelência em Florestas patrocinado pelo Estado, com a finalidade de fomentar estudos e pesquisas na área florestal.

Conforme se observa na Figura 1.2, as áreas de novos plantios aumentaram em 6,5% em 2008 (187,4 mil ha), quando comparado com 2007 (175,9 mil ha). As áreas de reforma, por sua vez, cresceram 7,6% em 2008 em relação ao ano anterior, passando de 185,8 mil ha para 199,9 mil ha. A condução de rebrota, nas associadas da ABRAF, cresceu de 2,9 mil ha em 2007 para 19,0 mil ha em 2008.

Os dados mostram que cada vez mais, engenheiros florestais têm em suas mãos novas áreas para planejar e tomar decisões. Dentre os fatores técnicos que influenciam o planejamento das operações e colheita estão: a floresta, o terreno, a finalidade da madeira, o rendimento operacional das máquinas, a demanda e as estradas. Já dentre os fatores econômicos na tomada de decisão estão: os recursos financeiros, os custos operacionais das máquinas, a manutenção mecânica, o grau de mecanização e o regime de manejo. Por outro lado, nos fatores ambientais estão a capacidade de suporte do solo, as condições climáticas, o sistema de

colheita e os valores estéticos e paisagísticos da floresta (MACHADO e LOPES, 2002).



Fonte: Associadas da ABRAF (2009), adaptado por STCP.
¹ Inclui expansão e reforma florestal.

Fonte: Adaptado de (ABRAF, 2009)

Figura 1.2: Evolução do plantio anual com florestas plantadas de eucalipto e pinus das empresas associadas da ABRAF por espécie (2000-2008).

Em virtude da existência e interação de inúmeros e complexos fatores técnicos, econômicos e ambientais que interferem de forma dinâmica nas operações da colheita, há de se considerar que o planejamento é essencial para a identificação, previsão e controle dos aspectos adversos e com a antecedência devida. Fatores como: quando, onde e como realizar a colheita de madeira, satisfazendo as exigências do consumidor são fatores relacionados às decisões táticas (WEINTRAUB et al.,1994; MALINOVSKI, 2007).

Neste contexto, nota-se a complexidade dos problemas envolvidos no planejamento florestal, o excessivo número de variáveis, a necessidade de respostas às diversas questões em um curto espaço de tempo, a necessidade do uso de diferentes modelos e o elevado volume de dados para alimentar tais modelos são alguns fatores que justificam a necessidade do uso de Sistemas de Suporte à Decisão (SSD).

Para PEREIRA (2004), os principais trabalhos envolvendo a utilização de algoritmos exatos como o algoritmo *branch-and-bound* para solução de problemas combinatoriais mostraram que estes são eficientes apenas em problemas de pequeno porte. SILVA (2001), citando LEUSCHNER (1984),

afirma que a Programação Linear (PL) tem sido aplicada em uma variedade de problemas florestais, como na solução de problemas nas indústrias florestais, na regulação e ordenação de florestas, no planejamento econômico florestal e na proteção florestal. Porém, muitos problemas de planejamento florestal são de natureza combinatória e podem envolver centenas a milhares de variáveis e não podem ser resolvidos eficientemente por tais métodos.

A utilização de Programação Multiobjetivo (PMO) eliminou uma das limitações dos modelos de PL ao permitir o tratamento e otimização simultânea de objetivos conflitantes. Ao mesmo tempo, VELDHUIZEN e LAMONT (2000), citando BACK (1996), afirma que achar o ótimo global de um problema de otimização multiobjetivo (POM) pode ser um problema NP-Completo. Soluções perfeitas em POM's, onde todas as variáveis de decisão satisfazem as restrições associadas e a função objetivo atinge um mínimo global, podem nunca existir.

Diante do exposto anteriormente, existe um grande interesse em buscar metodologias alternativas para solucionar o problema do planejamento florestal, que vão além dos modelos tradicionais de PL com objetivo único. As técnicas heurísticas têm tido bastante sucesso na solução de problemas combinatoriais em diversas áreas, e alguns estudos já foram desenvolvidos na área florestal com sucesso (RODRIGUES, 2001).

Atualmente, existem muitas técnicas heurísticas disponíveis para solução de problemas combinatoriais, incluindo desde heurísticas menos convencionais até as chamadas metaheurísticas. A heurística *Iterated Local Search* (ILS) pode ser utilizada em diversos problemas de otimização combinatorial, proposta por LOURENÇO et al. (2002). Ela consiste em um algoritmo heurístico baseado na idéia de que um procedimento de busca local pode ser melhorado, gerando-se novas soluções de partida, as quais são obtidas por meio de perturbações numa solução ótima local. A melhor solução é definida como resultado.

Na tentativa de fazer uso dos benefícios particulares dos vários métodos de busca local, e em função da diversidade de problemas aplicáveis, ultimamente também tem sido propostas metaheurísticas híbridas. Como exemplo, pode-se citar o trabalho de VIANNA (2006) que propõe o uso da heurística *Greedy Randomized Adaptive Search Procedures* (GRASP) híbrida para um problema de otimização combinatória multiobjetivo.

1.2 Objetivos

O presente trabalho tem como objetivo geral, examinar a aplicabilidade da heurística *Iterated Local Search* (ILS) considerando dois objetivos, como uma ferramenta auxiliar no processo de tomada de decisão ao planejamento da produção florestal.

O trabalho teve os seguintes objetivos específicos:

- Propor uma adaptação da heurística ILS para problemas de otimização multiobjetivo (POM) denominada *ILSMulti* e apresentá-la como uma alternativa para a solução de problemas de tomada de decisão.
- Analisar a aplicação das heurísticas em problemas de planejamento florestal multiobjetivo de pequeno porte, através do desenvolvimento de um código computacional com esta finalidade.
- Expandir a sua aplicação para problemas maiores e mais complexos, incorporando procedimentos híbridos.
- Comparar a eficiência da heurística *ILSMulti* com técnicas anteriormente testadas: *Strength Pareto Evolutionary Algorithm* (SPEA) e *Pareto Simulated Annealing* (PSA).

1.3 Organização desse documento

Esta dissertação está organizada da seguinte forma.

A Sessão 1 mostra a contribuição do setor florestal no cenário sócio-econômico do país e a importância da realização do planejamento florestal e da utilização de procedimentos heurísticos na busca de solução para os problemas nessa área.

A Sessão 2 apresenta conceitos sobre o Problema de Planejamento Florestal, Otimização Multiobjetivo, Sistemas de Apoio a Decisão e trabalhos correlatos, de acordo com conceitos extraídos da literatura.

A Sessão 3 apresenta a metodologia utilizada no desenvolvimento desta pesquisa. Neste contexto está o protótipo Gerador de Prescrições e seu papel, o modelo a ser utilizado para o problema de planejamento florestal, a adaptação da heurística ILS denominada *ILSMulti* com seus métodos e o algoritmo SPEA.

Na Sessão 4 são apresentados os problemas testes, a configuração do algoritmo, os resultados de simulações realizadas com o objetivo de mostrar a

viabilidade e a aplicabilidade do algoritmo quando comparado com técnicas anteriormente testadas.

Finalmente, a Sessão 5 apresenta algumas conclusões obtidas e as principais contribuições disponibilizadas por esse trabalho. Também são apresentadas sugestões para trabalhos futuros.

2 REFERENCIAL TEÓRICO

2.1 O Problema de Planejamento Florestal

Atualmente, as pressões de mercados cada vez mais globalizados exigem que as empresas florestais se tornem mais e mais competitivas, devendo produzir produtos de alta qualidade a custos os menores possíveis (SILVA, 2001). LEITE (1994) afirma que o manejo florestal moderno requer integração entre floresta, indústria e mercado, para maximizar o retorno financeiro e, ao mesmo tempo, garantir uma base sustentável do estoque de crescimento da floresta. Para Nobre (1999), citando SCOLFORO (1997), o manejo florestal envolve o conceito da utilização, de forma sensata e sustentada, dos recursos florestais, e a função básica do manejo florestal é conduzir o recurso florestal para atender aos objetivos de uma organização.

Ainda de acordo com NOBRE (1999), o problema básico de manejo florestal é elaborar um plano especificando as diversas intervenções silviculturais que atendem às demandas e restrições definidas para um certo período de tempo. Essas intervenções, incluindo colheitas e plantios, devem necessariamente atender às limitações operacionais e resultar em um fluxo adequado e sustentável de produção. O equacionamento do problema envolve a definição de um número muito grande de alternativas de manejo (AM) para cada unidade de produção (UP) na floresta.

Assim, o planejamento florestal é um tema complexo, que abrange desde aspectos relacionados com o crescimento das árvores até aspectos ambientais amplos dos ecossistemas, passando pela melhoria das espécies, pelo plano de exploração, pela qualidade da paisagem, pela preservação do ambiente, pela matemática dos modelos de crescimento e modelos de otimização, etc. Tantos assuntos não poderiam ser abordados em apenas um único trabalho, portanto, este trabalho dedica-se apenas à aplicação de um modelo de otimização no planejamento dos cortes e exploração de uma floresta.

Para melhor ilustrar o problema abordado, considere que na Figura 2.1 tem-se uma floresta e esta, por sua vez, está dividida em várias unidades de produção. Cada unidade de produção é uma área sem descontinuidade com características homogêneas tais como: mesma espécie, mesma idade, mesma altitude, etc. Dadas estas características, uma unidade de produção contém disponível um conjunto de alternativas de manejo. Cabe então, ao manejador florestal a responsabilidade de escolher a melhor alternativa de manejo para cada unidade de produção. Esta divisão da floresta pode ser vista na realidade através da Figura 2.2.




Figura 2.1 Floresta dividida em unidades de produção.

Uma alternativa de manejo, para uma unidade de produção, é uma seqüência de decisões que ocorrem ao longo de um horizonte de planejamento. Tais decisões podem representar, por exemplo, épocas de cortes, plantios, intensidades de desbastes, tecnologias e materiais genéticos a serem utilizados. As diferentes combinações de ocorrência dessas decisões ao longo do horizonte e a interdependência das decisões criam uma infinidade de alternativas de manejo. Portanto, o número global de alternativas de manejo geradas para um dado problema depende de fatores como: número de unidades de produção, estrutura dos povoamentos (composição de idades, espécies, regime de manejo), usos da madeira e outras decisões consideradas pelo manejador (aquisição de terras, desbaste, corte raso, variações nas idades de colheita e outras), podendo chegar a centenas ou milhares de alternativas.



Fonte: ABRAF (2009)

Figura 2.2 Floresta dividida em unidades de produção.

REZENDE e OLIVEIRA (1993), citados por SILVA (2001), conceituam horizonte de planejamento como o período de tempo estimado durante o qual o empreendimento em análise será operado, podendo ser finito ou infinito. De acordo com estes mesmos autores, não existe uma regra para determinação do horizonte de planejamento; no entanto, deve-se considerar que, para horizontes maiores, são as incertezas de concretização de planos feitos para o futuro, devido a fatores como mudanças nas condições econômicas, aparecimento de produtos concorrentes, alteração de custos, preferência dos consumidores e mudanças tecnológicas.

Pode-se citar, como exemplo de decisão a ser tomada, a idade de corte. A atividade florestal exige rotações mais longas que as demais atividades agropecuárias, principalmente para que se obtenha um produto final para serraria. Para determinada atividade, o corte do eucalipto pode ocorrer aos 7 anos de idade, num regime que permite até 3 rotações sucessivas e econômicas, com ciclo final de até 21 anos. A figura 2.3 ilustra as diferentes idades de corte do eucalipto, sendo que a partir do 5º ano (período), a árvore já pode ser cortada dependendo da finalidade da produção.




Figura 2.3 Diferentes idades de uma floresta.

Observa-se que para obter o melhor uso dessas áreas, os manejadores florestais defrontam-se com diversos tipos de problemas, envolvendo, por exemplo, quantificação de madeira para diferentes finalidades, atendimento de demandas periódicas para diferentes usos da madeira e clientes, quantificação de receitas e custos de empreendimento (análise de fluxos de caixa), planejamento da produção de forma sustentável, atendimento dos múltiplos objetivos conflitantes da floresta, geração e avaliação de alternativas de manejo, posicionamento estratégico na venda ou na aquisição de terras, simulação e avaliação de diferentes regimes de desbastes e outros. Além de identificar e descrever tais problemas, suas soluções envolvem a definição do horizonte de planejamento e coleta, processamento e armazenamento de dados e informações.

Dentre essas, e para cada unidade de produção, o gestor deve escolher a alternativa que melhor atende aos seus objetivos e restrições operacionais. O problema resultante pode se tornar de difícil solução, principalmente devido ao grande número de variáveis envolvidas e à natureza combinatória do problema quando impostas restrições espaciais e de inteireza sobre as unidades de manejo.

2.2 Otimização Multiobjetivo

Os problemas de otimização complexos podem ser encontrados em muitas áreas de aplicação. Um aspecto que contribui para a complexidade desses problemas compreende as características do espaço de busca; algoritmos exatos são, frequentemente, não aplicáveis. Múltiplos objetivos formam outro tipo de dificuldades que métodos de otimização clássicos não foram projetados para tal (BLEULER, 2003). Portanto, técnicas alternativas têm sido desenvolvidas ao longo do tempo como, por exemplo: Algoritmos Evolucionários, Busca Tabu (BT), *Simulated Annealing*, *Greedy Randomized Adaptive Search Procedure* (GRASP) e ILS.

Para ARROYO (2002), um problema de otimização multiobjetivo, geralmente, consiste em minimizar (ou maximizar) simultaneamente um conjunto de critérios (objetivos) satisfazendo um conjunto de restrições. Diferentes de problemas de otimização comuns, que podem ter uma única solução ótima, os problemas de otimização multiobjetivo apresentam um conjunto de soluções eficientes, no qual nenhuma solução é melhor que outra solução para todos os objetivos, denominado de conjunto Pareto-ótimo. Cabe a um tomador de decisões (*decisor*) escolher uma solução (ou soluções) aceitável (eis), selecionando um ou mais destes vetores.

Formulado por Vilfredo Pareto no século XIX, o conceito de Pareto-ótimo constitui em si, a origem da busca na otimização multiobjetivo. A definição diz que um vetor x é Pareto-ótimo se não existe um outro vetor viável x' que possa diminuir (em problema de minimização de dois ou mais atributos) algum atributo, sem causar um simultâneo aumento em pelo menos um outro atributo, ou seja, o critério de Pareto simplesmente afirma que uma solução é melhor do que a outra se ela é tão boa em todos os atributos, e melhor em pelo menos um deles (ESQUIVEL et al., 1999).

Neste contexto, uma solução x_1 domina uma solução x_2 se as seguintes condições se verificam:

- Condição 1: $\forall i: f_i(x_1) \leq f_i(x_2)$
- Condição 2: $\exists i: f_i(x_1) < f_i(x_2)$

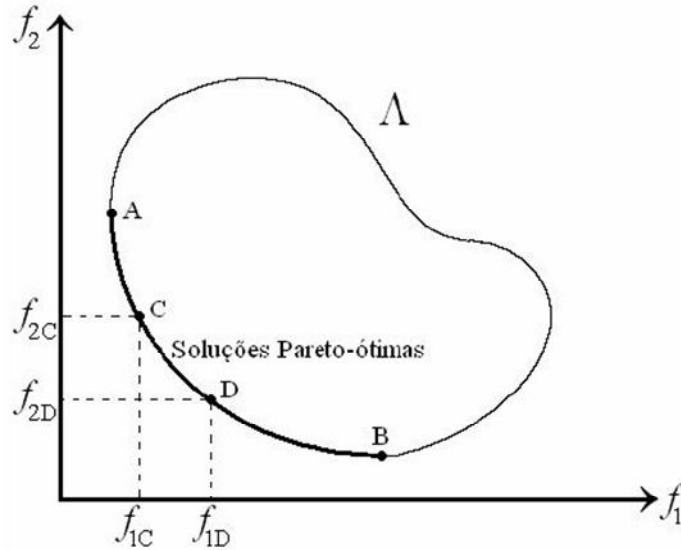
A partir desse conceito, pode-se dizer que existem três possibilidades de dominância entre duas soluções x_1 e x_2 :

- $x_1 \prec x_2$ x_1 domina x_2
- $x_1 \succ x_2$ x_2 domina x_1
- $x_1 \sim x_2$ x_1 e x_2 são indiferentes.

Seja uma série de soluções P , o conjunto de soluções não-dominadas P' , é composto por todas as soluções que não são dominadas por nenhum elemento de P . Quando a série P é representada por toda a região factível, o conjunto não-dominado resultante P' , é chamado de conjunto Pareto-ótimo (DEB, 2001).

O Pareto-ótimo quase sempre fornece não uma solução simples, mas um conjunto de soluções chamadas soluções não-inferiores, admissíveis, eficientes ou não-dominadas e seus vetores correspondentes são também chamados de não-dominados (COELHO, 1999; COELHO, 2002; VAN VELDHUIZEN e

LAMONT, 2000). A figura 2.4 ilustra um exemplo bidimensional, onde ambas as funções tem como objetivo minimizar. Observa-se que o conjunto de soluções Pareto-ótimas está representado entre os pontos A e B, e os pontos C e D são soluções Pareto-ótimas. Uma melhora no objetivo f_1 resulta em degradação do objetivo f_2 , isto é, $f_{1C} < f_{1D}$ e $f_{2C} > f_{2D}$.



Fonte: BERBERT (2008)

Figura 2.4 Conjunto de soluções Pareto-ótimas.

Grande parte das técnicas multiobjetivo para delimitação da região Pareto-ótima utilizam o conceito de *dominância*, onde todas as soluções são comparadas duas a duas, sendo verificada a dominância ou não de uma sobre a outra. A Figura 2.5 ilustra este conceito em um problema com dois objetivos.

x	$f_1(x)$	$f_2(x)$
1	10	5
2	8	10
3	7	12
4	7	11
5	13	6

Diagrama de dominância: setas curvas vermelhas apontam da solução 1 para a 2 e da 2 para a 4, indicando que a solução 1 não é dominada por 2 e 4, e que a solução 2 não é dominada por 4.

Figura 2.5 Exemplo de dominância.

Observa-se que as soluções 1, 2 e 4 são soluções não dominadas, visto que se compararmos a solução 1 com a solução 2 tem-se o objetivo f_1 inferior, porém o objetivo f_2 é superior. O mesmo acontece comparando f_1 com f_4 e f_2 com f_4 . Por

outro lado, ao se comparar a solução 1 com a solução 5, observa-se que a solução 5 é dominada pela solução 1, uma vez que ambos os objetivos da solução 5 são superiores aos objetivos da solução 1. O mesmo acontece com a solução 3 ao ser comparada com a solução 4.

HORN (1997) classifica três categorias básicas possíveis para os métodos de otimização multiobjetivos, dependendo de como a otimização (busca) e o processo de decisão são combinados:

- A priori: a tomada de decisão é feita antes da busca, onde os objetivos do POM são agregados em um único objetivo com informações de preferência, dadas pelo tomador de decisão, incluídas implicitamente.
- A posteriori: busca antes da tomada de decisão, onde a otimização é realizada sem a entrada de qualquer informação de preferência. O resultado do processo de busca é o conjunto de soluções candidatas (idealmente o conjunto Pareto-ótimo), do qual a escolha final é feita pelo tomador de decisão.
- Progressiva: a decisão é tomada durante a busca, ou seja, o tomador de decisão pode articular preferências durante o processo de otimização interativo. Antes de cada passo da otimização, um número de *trade-offs* alternativos são apresentados, na qual o tomador de decisão especifica alguma informação de preferência, guiando assim a busca.

Neste contexto, o termo "otimizar" significa encontrar soluções com todos os valores dos objetivos que não podem ser melhorados simultaneamente. A categoria adotada neste trabalho é a posteriori.

2.3 Sistemas de Apoio a Decisão (SAD)

Com base no que fora exposto, o planejamento florestal tem muitas características de situações complexas dos problemas comuns de tomada de decisão. Os vários decisores com múltiplos objetivos contraditórios, o vasto número de alternativas possíveis, as decisões atuais com grande influência nas futuras ações e a incerteza nos resultados são características típicas do planejamento florestal (KURTTILA, 2001).

Para RODRIGUES (2002), independente da técnica utilizada na tomada de decisão, desenvolver e utilizar Sistemas de Apoio à Decisão (SAD) em planejamento florestal tem se tornado cada vez mais imprescindível.

Os primeiros Sistemas de Apoio à Decisão surgiram nos anos 60 e 70, para dar suporte aos gerentes na solução de problemas gerenciais não estruturados (PEARSON & SHIM, 1995). Durante a década de 80, com o surgimento dos Sistemas de Gerenciamento de Banco de Dados (SGBD), tornou-se possível um melhor acesso aos dados disponíveis, à sua formatação e à construção de consultas e relatórios de forma mais prática.

Porém, mesmo com os avanços alcançados nesta década, era difícil elaborar um relatório que contivesse uma análise, cruzando informações de sistemas diferentes, o que era constantemente necessário aos gerentes. Portanto, a partir destas necessidades começaram a surgir os primeiros sistemas especialmente desenvolvidos para os gerentes, os chamados Sistemas de Informação para Executivos (*Executive Information Systems - EIS*).

A partir da década de 90, com o surgimento da OOP – Programação Orientada a Objetos, foram desenvolvidos diversos sistemas para dar suporte à solução dos problemas das empresas. Entre as novas ferramentas de Tecnologia da Informação, está a nova geração de Sistemas de Apoio à Decisão.

Os SAD têm como objetivo apoiar processos de decisão que apresentam problemas de estruturação. Possuem características tecnológicas, estruturais e de utilização específicas, que os distinguem de outros tipos de Sistemas de Informação (SI); e o seu conhecimento por parte dos seus desenvolvedores e usuários levam a uma melhor e, conseqüentemente, maior satisfação da utilização dos SI.

Os Sistemas de Apoio à Decisão são sistemas computacionais que visam sistematizar e apoiar os processos decisórios empresariais, sendo comumente compostos pelos mesmos componentes básicos como: interface com o usuário, banco de dados e banco de modelos, visando fornecer apoio em decisões semi-estruturadas e desestruturadas, estando sob controle do tomador de decisões e disponibilizando um conjunto de ferramentas para estruturar e aumentar a efetividade das decisões (JUNIOR et al., 2006).

Para TAVARES (2008) citando BUOSI (2004), os SADs fornecem aos executivos diversas ferramentas de modelagem e análise com o objetivo de capacitar os usuários a solucionar problemas de forma integral, fornecendo informações obtidas de diversas fontes de dados da empresa.

Principais características dos SAD:

- Foco nas decisões;
- Ênfase na flexibilidade, adaptabilidade e capacidade de fornecer respostas rápidas;
- Iniciado e controlado pelo usuário;
- Suporte para estilos pessoais de tomada de decisão;
- Voltados para problemas menos estruturados.

Em geral, os SADs são sistemas computadorizados, interativos e amigáveis que auxiliam o tomador de decisão em todas as fases do processo decisório, utilizando-se de dados, modelos e conhecimento de especialista na solução de problemas mal estruturados (TURBAN, 1998).

2.4 Trabalhos Correlatos

O gerenciamento de recursos florestais tem sido auxiliado por uma variedade de ferramentas de suporte à decisão. E em diversas partes do mundo, os Sistemas de Apoio à Decisão (SAD) têm sido utilizados desde a década de 1970, a exemplo do Timber RAM que possibilita o planejamento em longo prazo de áreas florestais (NAVON, 1971), a ferramenta de otimização Forplan que utiliza recursos de programação linear, programação inteira mista e técnicas de programação por metas (IVERSON e ALSTON, 1986), o Planflor que se baseia num modelo de Programação Misto-Inteira (TAUBE NETTO, 1984), e outras como Musyc (JOHNSON et al., 1979) e Sisflor (RODRIGUES et al., 2000).

Alguns trabalhos relacionados ao gerenciamento de recursos florestais fazem uso de procedimentos heurísticos. Dentre eles pode-se citar o trabalho de TEIXEIRA (2002) que utilizou Algoritmos Evolucionários para problemas multiobjetivo, a aplicação do *Pareto Simulated Annealing* (PSA) proposta por PEREIRA (2004), o uso da heurística *Greedy Randomized Adaptive Search Procedures* (GRASP) no trabalho de BARROS JR et al. (2009), entre outros.

3 METODOLOGIA

Nesse capítulo é apresentada a metodologia adotada no trabalho. A princípio utilizou-se o protótipo proposto no trabalho de TEIXEIRA (2002) com objetivo de gerar todas as possíveis alternativas de manejo para o problema (seção 3.1). Estas alternativas servem de base para o funcionamento dos algoritmos. Na seção 3.2 é apresentado o modelo utilizado com dois objetivos: maximizar o Valor Presente Líquido (VPL) e minimizar o Excesso de Produção. Na seção 3.3 e 3.4 são apresentados os algoritmos ILS e SPEA como uma alternativa para a solução do problema de planejamento florestal multiobjetivo. A seção 3.5 apresenta a descrição básica do conjunto de problemas que foram utilizados para testes. Na última seção (3.6), é apresentado o método adotado para avaliar os conjuntos de soluções gerados pelos algoritmos.

3.1 O Gerador de Prescrições

O sistema de otimização utilizado neste trabalho teve como base o protótipo proposto no trabalho de TEIXEIRA (2002) que simula o real conjunto de soluções viáveis. O protótipo foi desenvolvido utilizando-se o ambiente de programação *Borland Delphi*[®] 7.0, que tem como linguagem nativa o *Object Pascal*.

O *software* possui três módulos básicos: Dados, Gerador de Prescrições e Otimizador. Nele, o usuário trabalha com os projetos de forma independente, inserindo-se assim os dados e salvando-os em um arquivo, podendo carregá-lo a qualquer momento. É permitido trabalhar com apenas um projeto por vez.

No módulo Dados (Figura 3.1) deve-se cadastrar as informações relativas ao projeto, tais como:

- a idade mínima e máxima de corte, horizonte de planejamento, taxa de desconto anual para a atualização presente dos valores das receitas e dos custos;

- cadastro das unidades de produção: para cada unidade de produção deve-se cadastrar a idade, a área, os valores de custos das atividades realizadas na unidade, aqui resumidos em implantação, manutenção anual média, exploração, reforma e condução de brotação, e os valores de produção de madeira esperados em diferentes idades;
- o valor da madeira a ser utilizado para o cálculo do retorno econômico da produção, podendo este ser expresso como valor único ou por idade da madeira;
- as demandas anuais mínimas (expressa em m³) a serem atendidas e
- as capacidades máximas de reformas anuais (expressa em ha) da empresa florestal. Informações estas utilizadas para geração das restrições dos problemas.

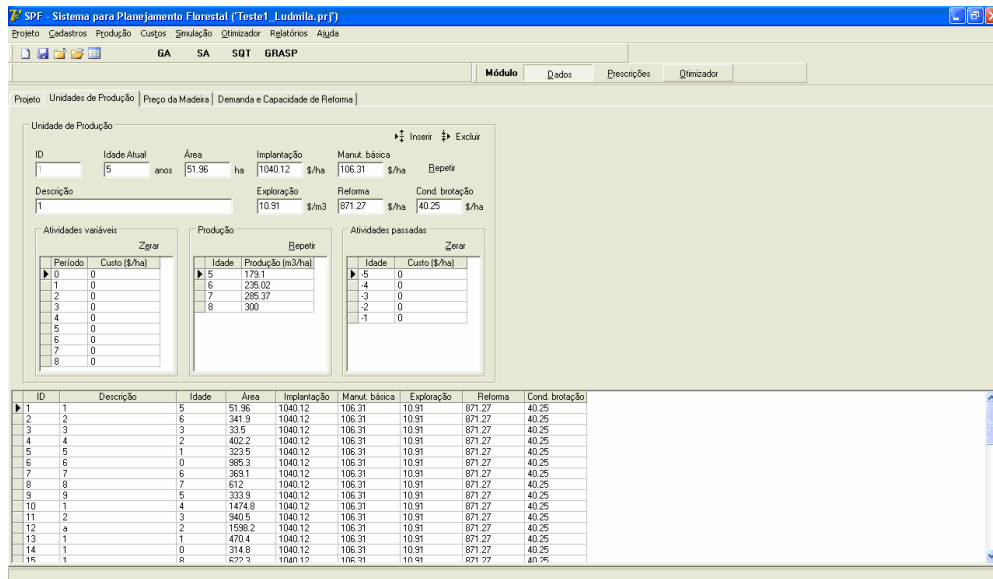


Figura 3.1 Módulo Dados do protótipo.

O módulo Gerador de Prescrições (Figura 3.2) é o responsável por gerar alternativas de manejo para cada uma das unidades de produção (UP) cadastradas. Através de uma estrutura matricial onde, para as colunas, tem-se a linha do tempo, que vai do período de plantio da UP, passando pelo estado atual até o último período do horizonte planejado. Além do horizonte de planejamento, o algoritmo leva em consideração as idades máxima e mínima de cortes e as formas de condução da floresta, onde foram consideradas apenas as opções de reforma, de uma e de duas conduções de brotação.

Cada célula da matriz pode assumir um dos seguintes estados:

- vazio quando houver apenas atividades de manutenção;
- “x” para a atividade de implantação da floresta;
- “r” para a atividade de exploração imediatamente seguida de reforma; e
- “c” para a atividade de exploração imediatamente seguida de condução da brotação.

No exemplo da Figura 3.2, observa-se que foram geradas 17 alternativas de manejo (prescrições) para a unidade de produção 1. A primeira (segunda) prescrição representa uma alternativa de manejo onde a UP sofrerá duas reformas (conduções) representadas pela letra “r” (representadas pela letra “c”), ambas com 5 anos de idade. O ano 0 representa o ano corrente, o que mostra que a UP 1 foi plantada há 5 anos atrás, representado pela letra “x” no ano -5. A prescrição número 7 (assinalada) representa que o regime adotado é o 5 7, onde a unidade de produção 1 vai sofrer uma reforma no 5º período e posteriormente uma nova reforma no 7º período.

Unid. Prod.	Prescrição	Nome	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6	7	8
1	1	55				x					r								r
1	2					x					c					c			
1	3					x					c					r			
1	4	56				x					r								r
1	5					x					c								c
1	6					x					c								r
1	7	57				x					r								r
1	8					x					c								c
1	9					x					c								r
1	10	58				x					r								r
1	11					x					c								c
1	12					x					c								r
1	13	65				x						r							r
1	14					x					c								c
1	15					x					c								r
1	16	66				x					r								r
1	17					x					c								c
2	1	65				x					r								r
2	2					x					c								c
2	3					x					c								r
2	4	66				x					r								r
2	5					x					c								c
2	6					x					c								r

Figura 3.2 Módulo Gerador de Prescrições do Protótipo.

O objetivo do problema é encontrar a melhor alternativa de manejo para cada unidade de produção considerando as limitações operacionais e condições de produção impostas ao projeto. O módulo Otimizador é o responsável por esta tarefa. Ele contém as heurísticas propostas neste trabalho.

3.2 O Modelo

Cada tipo de SAD tem suas características específicas; porém, é possível identificar componentes básicos. Segundo SPRAGUE & WATSON (1989), citado por GIBOSHI (2005), uma forma de enxergar os componentes de um SAD e a relação entre estes é por meio do paradigma “Diálogo, Dados e Modelos”, pelo qual há um diálogo entre o usuário e o sistema, modelos para prover a capacidade de análise e dados suportando-os.

O diálogo entre o usuário e o sistema é feito pela interface que, sob a perspectiva do usuário, representa “o sistema”. Por esta razão, é necessário dedicar a esse componente grande parte do projeto e desenvolvimento do sistema.

Os dados utilizados em um SAD são de diferentes tipos: internos, externos e estimativas subjetivas do tomador de decisões. Estes dados podem ser acessados diretamente pelo usuário ou inseridos junto aos modelos para serem processados.

Os modelos fornecem capacidade de análise para um SAD. Usando uma representação matemática do problema, algoritmos são utilizados para gerar informações para dar suporte à tomada de decisão.

Desta forma, o modelo de planejamento, empregado neste trabalho, foi proposto originalmente por KIDD et al. (1966), citado por DYKSTRA (1984) e, posteriormente, revisado por JOHNSON e SCHEURMAN (1977). Para NOBRE (1999), citando CLUTTER et al. (1983), no modelo, cada variável de decisão representa uma seqüência única de intervenções programadas para uma unidade de produção. De acordo com este modelo, tem-se que:

- As variáveis de decisão correspondem à escolha, ou não, de um único regime de manejo j para cada unidade i ;
- As restrições de área garantem a escolha de apenas um manejo para cada unidade; e
- As restrições de produção garantem o fornecimento do produto florestal nos níveis desejados em cada período do horizonte de planejamento.

Para o problema de PF abordado neste trabalho foram consideradas as seguintes notações:

$Z1$ = lucro total (soma dos lucros de cada unidade de produção);

$Z2$ = excesso de produção;

M = número total de unidades de produção;

N_i = número total de prescrições da i -ésima unidade de produção;

$X_{ij} = 1$ significa cortar a unidade de produção i sob a prescrição j , e $X_{ij} = 0$, caso contrário;

VPL_{ij} = valor presente líquido (VPL) da unidade de produção i , manejada sob a prescrição j , é dado pela diferença dos valores de receitas e custos, descontados a uma taxa determinada:

$$VPL_{ij} = \sum_{k=0}^n R_k (1+t)^{-k} - \sum_{k=0}^n C_k (1+t)^{-k}$$

R_k = receita no final do período de tempo (k) considerado;

C_k = custo no final do período de tempo (k) considerado;

i = unidade de produção;

n = duração do projeto em número de períodos de tempo;

k = período de tempo;

EP = excesso de produção global da floresta, é dado pela soma do volume total produzido pela unidade de produção i , manejada sob a prescrição j , no k -ésimo período do horizonte de planejamento conforme a idade de corte naquele período, menos o volume total (m^3) da demanda a ser atendida no período k :

$$EP = \sum_{k=1}^H \left(\sum_{i=1}^M \sum_{j=1}^N V_{ijk} X_{ij} - V_k \right)$$

V_{ijk} = volume total produzido pela unidade de produção i , manejada sob a prescrição j , no k -ésimo período do horizonte de planejamento conforme a idade de corte naquele período;

V_k = volume total (m^3) da demanda a ser atendida no período k ;

A_{ijk} = área da i -ésima unidade de produção, manejada sob a j -ésima prescrição, no início do período k e que esteja sob o regime de manejo de reforma;

H = horizonte de planejamento;

CR_k = capacidade de reforma no período k .

O modelo completo pode ser expresso tal como se segue:

$$Max Z1 = \sum_{i=1}^M \sum_{j=1}^{N_i} VPL_{ij} X_{ij} \quad (1)$$

$$Min Z2 = \sum_{k=1}^H \left(\sum_{i=1}^M \sum_{j=1}^{N_i} V_{ijk} X_{ij} - V_k \right) \quad (2)$$

Sujeito a:

$$\bullet \sum_{j=1}^{N_i} X_{ij} = 1, \quad \forall i = 1, \dots, M, \quad (3)$$

$$\bullet V_k \leq \sum_{i=1}^M \sum_{j=1}^{N_i} V_{ijk} X_{ij}, \quad k = 0, 1, \dots, H-1 \quad (4)$$

$$\bullet CR_k \geq \sum_{i=1}^M \sum_{j=1}^{N_i} A_{ijk} X_{ij}, \quad k = 0, 1, \dots, H-1 \quad (5)$$

$$\bullet X_{ij} \in \{0, 1\}, \quad \forall i = 1, \dots, M, j = 1, \dots, N \quad (6)$$

onde, (1) representa a maximização do lucro (soma dos valores presentes líquidos das UP's sobre uma prescrição escolhida) e (2) representa a minimização do excesso de produção global da floresta. A restrição (3) garante a escolha de uma única prescrição j (ou alternativa de manejo) para a unidade de produção i . A restrição (4) representa a imposição de cotas anuais de produção, onde a produção periódica de volume de madeira deve atender a uma demanda preestabelecida, e por último a restrição de capacidade de reforma (5) visa estabelecer uma capacidade máxima de reforma que a empresa florestal é capaz de realizar a cada período.

O modelo utilizado tem os objetivos: maximizar o Valor Presente Líquido (VPL) e minimizar o Excesso de Produção. O primeiro objetivo está presente em grande parte dos trabalhos de otimização, uma vez que representa a busca pelo maior lucro. Por outro lado, o segundo objetivo é relevante no que se refere à minimização das sobras de madeiras, visto que se trata de um Problema de Programação Inteiro, em que a unidade de produção sofre corte raso. O excesso de produção pode acarretar em dificuldades na estocagem e na venda. Outro ponto importante a ser considerado é o fato da empresa florestal poder manter um maior estoque de carbono, podendo assim, contribuir com o meio ambiente.

3.3 Heurística ILS Multiobjetivo para um Problema de Planejamento Florestal

A heurística ILS é um algoritmo heurístico baseado na idéia de que um procedimento de busca local pode ser melhorado, gerando-se novas soluções de partida, as quais são obtidas por meio de perturbações numa solução ótima local (LOURENÇO *et al.*, 2002). Neste algoritmo, o procedimento de busca local tem por finalidade melhorar a solução inicial e, também, aquelas produzidas após perturbações de soluções ótimas locais (BRITO *et al.*, 2009). Desta forma, a perturbação deve permitir que a busca local explore diferentes soluções, além de evitar um reinício aleatório.

Na Figura 3.3, apresenta-se um pseudocódigo básico do algoritmo ILS mono objetivo, que possui 4 etapas principais: a primeira etapa é responsável pela obtenção de uma solução ótima local inicial S_1 (passo 1); na segunda etapa é realizada uma perturbação da solução S_1 obtendo uma nova solução S_2 (passo 4); na etapa seguinte é realizada uma melhoria na solução S_2 através de uma busca local (passo 5) e a etapa final é responsável pelo critério de aceitação da solução atual (passo 6). Com exceção da primeira etapa, todas as demais são executadas iterativamente enquanto o critério de parada não seja atendido. Após as iterações, o algoritmo retorna a melhor solução obtida durante toda sua execução.

```
Procedimento ILS (CritérioParada)  
1    $S_1 \leftarrow$  Construção_Solução_Inicial;  
2    $S \leftarrow S_1$ ; //Melhor solução encontrada  
3   enquanto não CritérioParada faça  
4        $S_2 \leftarrow$  Perturbação( $S_1, d$ );  
5        $S_2 \leftarrow$  Busca_Local( $S_2$ );  
6       Critério_Aceitação( $S^*, S_1, S_2$ );  
7   fim-enquanto;  
8   retorne  $S$ ;  
fim ILS;
```

Fonte: LOURENÇO *et al.* (2002)

Figura 3.3 ILS Básico Mono-objetivo.

O parâmetro a ser definido no algoritmo ILS mono-objetivo é o critério de parada que, geralmente, é o número de iterações do algoritmo.

Por este trabalho abordar um Problema de Planejamento Florestal Multiobjetivo, o algoritmo ILS proposto (denominado *ILSMulti*), é baseado na

proposta de FRAMINAN e LEISTEN (2007) que desenvolveram um algoritmo denominado *Multi-Objective Iterated Greedy Search* (MOIGS). O algoritmo MOIGS é baseado no algoritmo mono-objetivo *Iterated Greedy Search* (IGS) proposto por RUIZ e STÜTZLE (2007), sendo que este algoritmo está estreitamente relacionado a outros métodos *Stochastic Local Search* (SLS), em especial ao *Iterated Local Search* (ILS) (LOURENÇO *et al.*, 2002). Os algoritmos IGS e MOIGS foram originalmente aplicados para um problema de seqüenciamento de tarefas em um sistema de *flow shop* e apresentaram excelentes resultados.

O pseudocódigo dos algoritmos IGS e MOIGS, podem ser vistos nas figuras 3.4 e 3.5 respectivamente.

Procedimento IGS()	
1	$S_0 \leftarrow$ Construção_Solução_Inicial;
2	$S \leftarrow$ Busca_Local(S_0); // % opcional
3	enquanto não CritérioParada faça
4	$S_p \leftarrow$ Destruição(S);
5	$S' \leftarrow$ Construção(S_p);
6	$S' \leftarrow$ Busca_Local(S');
7	Critério_Aceitação(S, S');
8	fim-enquanto;
9	retorne S ;
	fim IGS;

Fonte: RUIZ e STÜTZLE (2008)

Figura 3.4 Pseudocódigo do Procedimento IGS.

O algoritmo IGS inicia gerando uma solução inicial S_0 (passo 1); no próximo passo um parâmetro (percentual) determina se será, ou não, realizada uma busca local (passo 2) na solução inicial. As demais etapas são executadas iterativamente, enquanto o critério de parada não seja atendido; entre elas, as etapas de destruição (passo 4) e construção (passo 5) promovem uma perturbação na solução S gerando assim a solução S' . Posteriormente, é realizada uma melhoria na solução S' através da busca local (passo 6). Ao final, o critério de aceitação (passo 7) determina qual solução, S ou S' , melhor atende o objetivo. Após as iterações, o algoritmo retorna a melhor solução obtida durante toda sua a execução.

```

Procedimento MOIGS()
1    $S_0 \leftarrow$  Construção_Solução_Inicial;
2    $S_1 \leftarrow$  Construção_Solução_Inicial;
3   Set  $LD := \{ S_0, S_1 \}$ ;
4   enquanto não CritérioParada faça
5     para  $S_i$  de  $LD$  faça
6        $S(S_i) \leftarrow$  generateGreedySet( $S_i$ );
7        $CS \leftarrow CS \cup S(S_i)$ ;
8     fim-para;
9      $LD := LD \cup CS$ ;
10  fim-enquanto;
11  retorne  $LD$ ;
fim MOIGS;

```

Fonte: FRAMINAN e LEISTEN (2007)

Figura 3.5 Pseudocódigo do Procedimento MOIGS.

A Figura 3.6 apresenta o pseudocódigo do algoritmo *ILSMulti* proposto neste trabalho. O fluxo normal do algoritmo inicia com a geração de uma lista de soluções dominantes. Estas soluções são geradas de forma aleatória (passo 2) e o parâmetro T representa o tamanho inicial desta lista. A cada iteração do algoritmo, uma solução S é selecionada na lista de soluções dominantes LD (passo 5) para que seja realizada a perturbação (passo 6) e a busca local (passo 7). Os detalhes dos métodos “ConstrucaoAleatoria”, “SelecionaSolucao”, “Perturbação” e “BuscaLocal” estão descritos nas próximas seções.

```

Procedimento ILSMulti( $d, h, T$ )
1    $LD \leftarrow \emptyset$ ; // Lista de soluções dominantes
2    $LD \leftarrow$  ConstrucaoAleatoria( $T$ );
3   enquanto não CritérioParada faça
4      $CS \leftarrow \emptyset$ ;
5      $S \leftarrow$  SelecionaSolucao( $LD$ );
6      $S \leftarrow$  Perturbação( $S, d$ );
7      $CS \leftarrow$  BuscaLocal( $S, h$ );
8      $LD \leftarrow LD \cup CS$ ;
9   fim-enquanto;
10  retorne  $LD$ ;
Fim ILSMulti;

```

Figura 3.6 Pseudocódigo do Procedimento *ILSMulti*.

3.3.1 Construção Aleatória e Representação da Solução

A fase construtiva “ConstrucaoAleatoria” (Passo 2 do algoritmo *ILSMulti*), recebe o parâmetro T , que representa o número de soluções que serão geradas de forma aleatória. Para cada solução gerada, testa-se a sua viabilidade quanto às restrições impostas pelo modelo. Caso a solução seja viável, ela é inserida no conjunto de soluções dominantes LD . A estrutura de dados criada, para armazenar o conjunto de soluções, foi uma lista encadeada em que cada nó da lista (figura 3.7) representa uma solução dominante. Uma solução S será inserida na lista LD caso ela não seja dominada por nenhuma outra solução da lista. As soluções dominadas por S são removidas da lista LD . E a ordem das soluções na lista é dada de forma crescente ao 1º objetivo do problema.




Figura 3.7 Lista encadeada de soluções dominantes.

Cada solução S da lista contém um determinado número de unidades de produção (N^o UP's), representadas na Figura 3.8 pelas letras de “A” a “U”. Para cada UP, existe um conjunto de possíveis alternativas de manejo (AM) que a UP pode assumir, cada AM contém valores associados como custo, lucro, volume de madeira, regime e outros.

		Unidades de Produção																			
		A	B	C	D	E	F	G	H	I	J	L	M	N	O	P	Q	R	S	T	U
S		05	07	01	04	07	02	02	09	06	03	05	07	05	03	04	02	01	03	06	07
Alternativas de Manejo	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01	01
	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02	02
	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03	03
	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04	04
	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05	05
	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06	06
	07	07			07	07	07	07	07	07	07		07		07		07		07	07	07
	08				08	08	08			08	08	08							08	08	
	09						09			09		09								09	

Figura 3.8 Esquema representativo da solução. Na solução S são utilizadas as alternativas de manejo 03, 07, ..., 07 para as unidades de produção A, B, ..., U, respectivamente.

A Figura 3.9, ilustra uma situação onde o usuário deseja obter a alternativa de manejo que contenha o maior lucro. Neste caso, a AM número 3 seria a escolhida para a unidade de produção “A”, uma vez que o maior lucro pertence a esta alternativa. No detalhe, a alternativa de manejo 3 está associada a uma reforma no 7º período do planejamento, isso implica em um lucro (VPL) de R\$ 192.627,20 e um custo de R\$ 233.267,80.

		Horizonte de Planejamento																	VPL	Custo	
UP	AM	Regime	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6			7
A	1	5										x					r			92332.40	202359.60
A	2	6										x						r		148436.80	219851.80
A	3	7										x						r		192627.20	233267.80
B	1	5									x						r			168185.40	357839.90

Figura 3.9 Esquema representativo da alternativa de manejo.

3.3.2 Seleção da Solução

A cada iteração do algoritmo *ILSMulti*, uma solução S é selecionada da lista de soluções dominantes (LD) para que seja realizado os procedimentos de Perturbação e Busca Local. Este procedimento denominado “SelecionaSolucao” realiza a escolha de duas maneiras. A primeira contém um índice i que é incrementado a cada iteração. Este índice representa a posição da solução na lista

e, ao atingir o número de soluções que compõe a lista, ele é reiniciado e retorna ao início.

O uso do índice não garante que a Busca Local será realizada em todas as soluções da lista LD , visto que a lista de dominantes é atualizada a cada iteração. A Figura 3.10 ilustra o procedimento; observa-se, neste exemplo, que foram realizadas ao todo 6 iterações e, a cada iteração, uma solução foi escolhida de forma seqüencial: na 1ª a solução escolhida foi S_5 , na 2ª a solução S_{20} e, assim, sucessivamente. Observa-se, também, que algumas soluções não foram escolhidas; são exemplos as soluções S_2 e S_{14} . O reinício ocorreu na 6ª iteração, onde o número de soluções da lista foi alcançado.

Na segunda forma de seleção, o índice i é escolhido de forma aleatória. Estes dois métodos foram denominados Método de Seleção Seqüencial (ILSS) e Método de Seleção Randômico (ILSR).

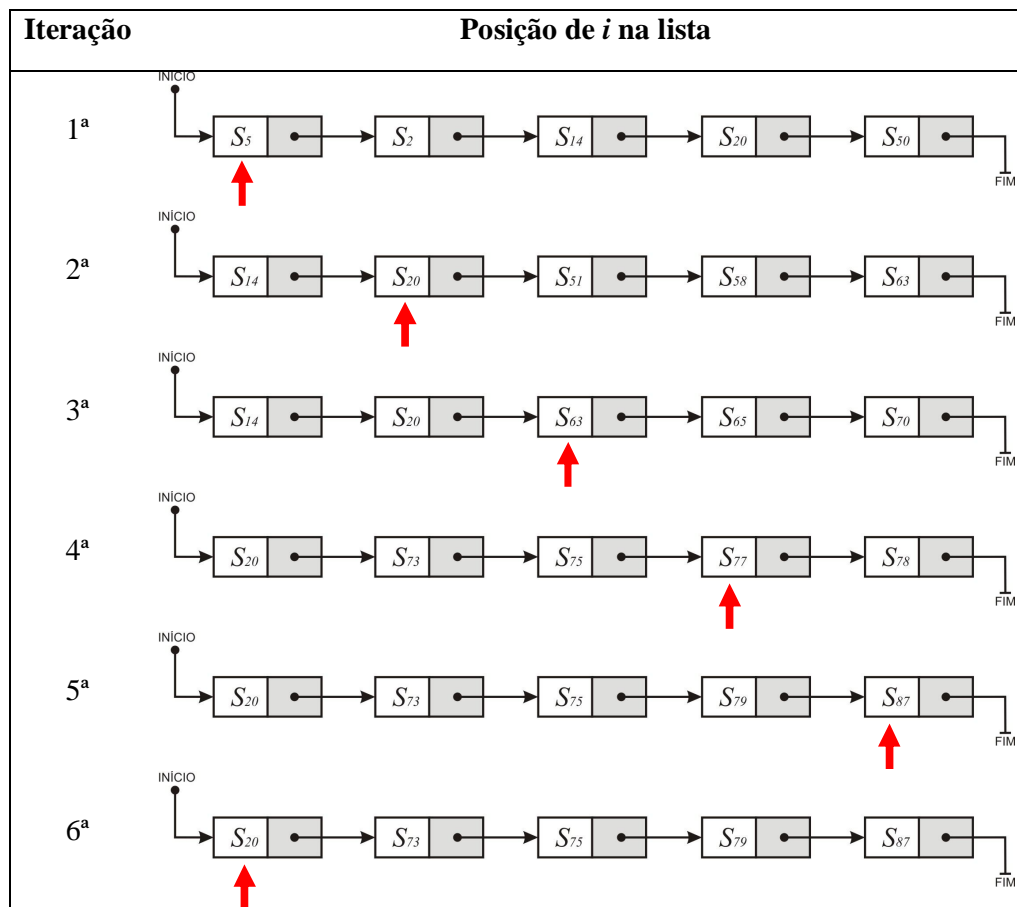


Figura 3.10 Esquema representativo da seleção seqüencial.

3.3.3 Perturbação

A Figura 3.11 apresenta o procedimento de “Perturbação” proposta no algoritmo *ILSMulti* como uma forma de suprir os movimentos de “destruição” e “construção” que foram propostos no algoritmo IGS (Figura 3.4). A perturbação é realizada na solução S , e o número de alternativas de manejo que sofrem a perturbação é dado pelo parâmetro d (taxa de destruição).

No passo 1, é definida uma lista de unidades de produção (LUP) que, posteriormente será preenchida com d índices de unidades de produção escolhidos aleatoriamente, de S (passos 2 à 5). Os passos de 7 a 12 fazem o papel de construção, em que para cada unidade de produção adicionada na lista LUP é realizada uma troca de alternativa de manejo de forma aleatória. Observe que a alternativa de manejo m , escolhida aleatoriamente no passo 9, será inserida em S . Ao final S é retornada pelo método.

```
Procedimento Perturbação( $S, d$ )
1    $LUP \leftarrow \emptyset$  // Lista de Unidades de Produção
2   enquanto (  $|LUP| < d$  ) faça
3      $up \leftarrow$  Escolhe aleatoriamente uma  $up$  de  $S$ ;
4      $LUP \leftarrow LUP \cup \{up\}$ ; //Insere a unidade de produção selecionada em  $S$ 
5   fim-enquanto;
6    $i \leftarrow 0$ ;
7   enquanto (  $|LUP| > 0$  ) faça
8      $up \leftarrow LUP[i]$ ;
9      $m \leftarrow$  Escolhe aleatoriamente uma  $AM$  de  $S[up]$ ;
10     $S[up] \leftarrow m$ ; //Insere a alternativa de manejo na  $up$  de  $S$ 
11     $i \leftarrow i + 1$ ;
12  fim-enquanto;
13  retorne  $S$ ;
fim Perturbação;
```

Figura 3.11 Procedimento de Perturbação.

3.3.4 Busca Local

A próxima fase “BuscaLocal” (passo 7 do algoritmo *ILSMulti*) consiste em determinar novas soluções vizinhas da solução S selecionada pelo procedimento “SelecionaSolucao”. As soluções vizinhas dominantes são armazenadas em um

conjunto auxiliar CS . O pseudocódigo do procedimento “BuscaLocal” é apresentado na Figura 3.12.

```

procedimento BuscaLocal( $S, h$ )
1    $CS \leftarrow \emptyset$ ;
2    $i \leftarrow 0$ ;
3   enquanto  $i < h$  faça
4      $up \leftarrow$  Escolhe aleatoriamente uma  $up$  de  $S$ ;
5      $S^* \leftarrow S$ ;
6     para cada alternativa de manejo  $m_{up} \neq S[up]$  faça
7        $S^*[up] \leftarrow m_{up}$ ;
8       se  $S^*$  é viável então
9          $CS \leftarrow$  soluções não-dominadas de  $CS \cup S^*$ ;
10      fim-se;
11     fim-para;
12      $S \leftarrow$  escolha uma solução de  $CS$ ;
13  fim-enquanto;
14  retorne  $CS$ ;
Fim BuscaLocal

```

Figura 3.12 Procedimento de Busca Local.

O procedimento inicia com o conjunto CS vazio (passo1). E por esta fase representar a etapa mais dispendiosa em termos de tempo computacional, o algoritmo analisa apenas $h\%$ das unidades de produção (passo3) que são escolhidas aleatoriamente (passo 4). Para cada unidade de produção selecionada, são realizadas as trocas das alternativas de manejo (Passos 6 a 9). A cada troca realizada, uma nova solução é gerada, testada quanto sua viabilidade e inserida no conjunto CS . O retorno do procedimento é o conjunto CS de soluções dominantes.

O comportamento das trocas das alternativas de manejo (passos 6 à 10) é representado na Figura 3.13. Neste exemplo, S^* é a solução recebida via parâmetro S ; assim, a rotina inicia a troca das alternativas de manejo de cada uma das UP's selecionadas. A 1ª troca é realizada na primeira UP, representada pela letra “A”. Observa-se que a alternativa 04 é substituída pela alternativa 01. Feito isso, a rotina calcula o valor da função objetivo na nova solução gerada (S_1) e, em seguida, compara S_1 com S^* ; caso S_1 seja melhor que S^* , S_1 passa a ser a nova S^* (melhor solução encontrada). Na 2ª Troca, uma nova solução é gerada (S_2) através da troca das alternativas: 01 com 02. Novamente, S^* é colocado à prova, sendo comparada com S_2 . Caso S_2 seja superior, ele passa a ser S^* . Este procedimento se repete para todas as alternativas de manejo e para cada UP selecionada.

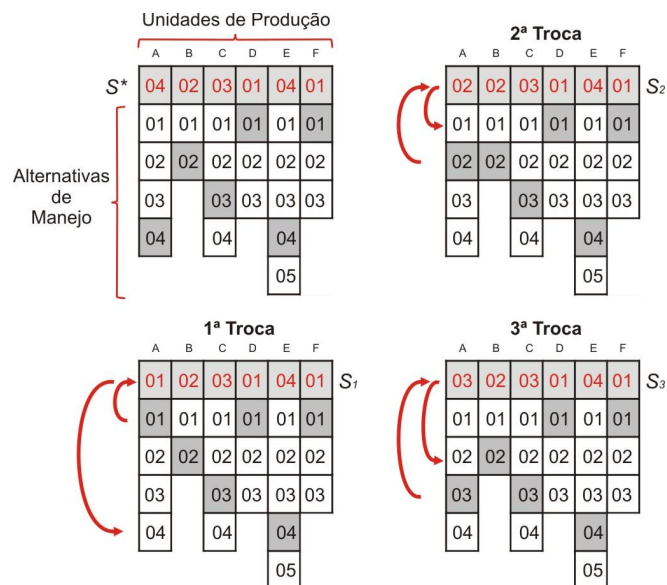


Figura 3.13 Procedimento de Busca Local.

Observa-se que a busca local é exaustiva, tornando esta etapa a mais dispendiosa em termos de tempo computacional exigida pelo *ILSMulti*. Foram analisadas, de forma iterativa, todas as soluções (alternativas de manejo) que constituem a vizinhança, substituindo a solução corrente por uma melhor, pertencente à vizinhança.

3.4 Heurística *SPEA* para um Problema de Planejamento Florestal

Proposto por ZITZLER (1999), o *Strength Pareto Evolutionary Algorithm* (*SPEA*) foi inicialmente utilizado por TEIXEIRA (2002) em Problemas de Planejamento Florestal, e novamente implementado neste trabalho. Esta abordagem se encaixa nas técnicas baseadas em Pareto, ou seja, o algoritmo atribui o *fitness* levando em consideração a dominância dos indivíduos dentro da população.

O pseudocódigo do algoritmo *SPEA* é mostrado na Figura 3.14, os parâmetros N , \bar{N} , T , p_c e pm representam o tamanho da população, o tamanho máximo do conjunto externo, o número máximo de gerações, a probabilidade de *crossover* e a taxa de mutação, respectivamente.

Procedimento <i>SPEA</i>(N, \bar{N}, T, p_c, pm)	
1	$P \leftarrow \emptyset$; // Definição da População Inicial
2	enquanto não CritérioParada faça


```

3       $\bar{P} \leftarrow \text{AtualizaConjuntoExterno}(\bar{N});$ 
4       $\bar{P} \leftarrow \text{CalcularFitness}();$ 
5       $P \leftarrow \text{CalcularFitness}();$ 
6       $P' \leftarrow P \cup \bar{P};$ 
7       $P'' \leftarrow \text{Recombinação}(P', p_c);$ 
8       $P''' \leftarrow \text{Mutaç\~{a}o}(P'', pm);$ 
9       $A \leftarrow A \cup P''';$ 
10     fim-enquanto;
11     retorne  $A$ ; // Conjunto não-dominado
fim SPEA;

```

Fonte: ZITZLER (1999)

Figura 3.14 Pseudocódigo do Procedimento SPEA.

No início de cada iteração (Passo 3), o conjunto externo \bar{P} é atualizado e reduzido se seu tamanho máximo \bar{N} for ultrapassado. Então, os indivíduos em \bar{P} e P são avaliados e a eles atribuídos os valores de *fitness* (Passos 4 e 5). O próximo passo representa a fase de seleção, onde os indivíduos de $\bar{P} + P$ (a união de população e conjunto externo) são selecionados para formar o *mating pool*. O método de seleção, recomendado por ZITZLER (1999), é o torneio binário com reposição. Finalmente, os operadores de *crossover* e mutação são aplicados na forma usual. Ao final do algoritmo, o conjunto não-dominado é retornado.

3.5 Problemas Testes

Neste trabalho, testa-se o desempenho das metaheurísticas *ILSMulti* (proposta neste trabalho). Os resultados desta metaheurística são comparados com os resultados do Algoritmo Genético (SPEA) proposto por TEIXEIRA (2002 e 2003), na resolução do problema de planejamento florestal multiobjetivo. Os algoritmos *ILSMulti* e *SPEA* foram desenvolvidos utilizando-se o ambiente de programação *Borland Delphi 7.0*. E todos os testes foram efetuados em um microcomputador Intel Xeon 2.86GHz com 4GB de memória RAM.

Foi gerado um conjunto de 30 problemas testes baseados em dados reais e em dados obtidos na literatura (TEIXEIRA, 2002). Na geração destas instâncias, foram consideradas as seguintes metodologias, considerando que o objetivo da empresa florestal é planejar a sua produção de madeira através de um plano de manejo florestal. Assim:

- As possíveis opções de manejo incluem: reforma, uma ou duas conduções da brotação;
- As idades mínima e máxima de corte são de 5 e 8 anos, respectivamente como mostra a Figura 3.15;
- As operações de corte são realizadas uma vez a cada período, sempre no início do período;
- Os sítios são homogêneos;
- Para simplificar o problema, foi considerada, para todas as unidades de produção, a mesma classe de produção, apresentada na Tabela 3.1. As produções nos regimes de primeira e segunda condução de brotação foram reduzidas em 10% e 15% respectivamente, em relação à produção do regime de alto fuste;
- Foi considerada uma taxa de desconto de 5% a.a;
- O preço da madeira utilizado foi de R\$ 42,00/m³;
- Os valores de custo das principais atividades da floresta são apresentados na Tabela 3.2.




Figura 3.15 Idades de Corte entre o 5º e o 8º período do horizonte.

Tabela 3.1 Volumes de produção para as diferentes idades da floresta.

Idade (anos)	Produção (m ³ /ha)		
	Alto Fuste	1ª Brotação	2ª Brotação
5	179,10	161,19	152,24
6	235,02	211,52	199,77
7	285,37	256,83	242,56
8	300,00	270,00	255,00

Tabela 3.2 Custos médios das atividades principais.

Atividade	Custo (R\$/ha)
Implantação	1040,12
Manutenção básica anual média	106,31
Reforma	871,27

Condução da brotação	40,25
Exploração (R\$/m ³)	10,91

A Tabela 3.3 mostra os problemas-teste com relação aos principais parâmetros usados na definição de cada um. Cada problema foi classificado quanto ao número de unidades de produção, sendo “A” com 50 unidades, “B” com 100 unidades e “C” com 150 unidades. Em cada classe, os horizontes de planejamento variaram entre 9 e 25 anos para as classes “A” e “B”, e entre 9 e 30 anos para a classe “C” que, combinado com o número de unidades de produção, determina o número de prescrições (possíveis alternativas de manejo).

Observa-se que alguns problemas contêm o mesmo número de unidades de produção, seguido do mesmo horizonte de planejamento, como exemplo os problemas 1, 2 e 3. A diferença entre estes problemas está relacionada com os valores utilizados para se definir os níveis de demanda anual a serem considerados para cada um dos problemas. Esta diferenciação dos valores utilizados serviu como forma de exploração de cenários diferentes e influenciaram, diretamente, no desempenho das técnicas utilizadas para se resolver os problemas.

Em todos os casos apresentados, foi considerada uma mesma empresa florestal hipotética, com algumas características básicas, simulando-se cenários diferentes, de forma a possibilitar a criação de problemas-teste necessários às demonstrações propostas.

Tabela 3.3 Problemas-teste utilizados para as demonstrações propostas.

Classe	Problema	Nº UP's	Horizonte	Nº AM's	Tempo
A	1	50	9 anos	735	5 min.
A	2	50	9 anos	735	5 min.
A	3	50	9 anos	735	5 min.
A	4	50	14 anos	2466	10 min.
A	5	50	14 anos	2466	10 min.
A	6	50	14 anos	2466	10 min.
A	7	50	20 anos	9108	20 min.
A	8	50	20 anos	9108	20 min.
A	9	50	20 anos	9108	20 min.
A	10	50	25 anos	27045	30 min.
B	11	100	9 anos	1533	15 min.
B	12	100	9 anos	1533	15 min.
B	13	100	9 anos	1533	15 min.
B	14	100	14 anos	5094	30 min.

B	15	100	14 anos	5094	30 min.
B	16	100	14 anos	7491	40 min.
B	17	100	20 anos	18924	60 min.
B	18	100	20 anos	18924	60 min.
B	19	100	20 anos	18924	60 min.
B	20	100	25 anos	56499	100 min.
C	21	150	9 anos	2189	30 min.
C	22	150	9 anos	2189	30 min.
C	23	150	9 anos	2189	30 min.
C	24	150	14 anos	7491	50 min.
C	25	150	14 anos	7491	50 min.
C	26	150	14 anos	7491	50 min.
C	27	150	20 anos	27807	105 min.
C	28	150	25 anos	82905	180 min.
C	29	150	28 anos	156042	240 min.
C	30	150	30 anos	220509	295 min.

Ainda na Tabela 3.3 são apresentados os tempos computacionais, em minutos, estabelecidos como critério de parada de cada algoritmo (*ILSMulti* e *SPEA*). Para determinar o tempo de execução dos algoritmos, foi utilizada a seguinte fórmula: $(M \times \sqrt{m})/4$, onde M representa o número total de UP's e m representa o número total de alternativas de manejo disponíveis no problema. O resultado é dado em segundos e posteriormente convertido para minutos.

3.6 Avaliação das Soluções

Para comparar dois conjuntos heurísticos LD e LD' (gerados pelos métodos *ILSMulti*, *SPEA* ou *PSA*), primeiramente determina-se o conjunto de referência R a partir das soluções dominantes de $LD \cup LD'$. Desta forma, $R = \text{dominantes}(LD \cup LD')$. E para comparar a qualidade das soluções geradas pelas metaheurísticas, foram utilizadas duas medidas:

- Medida de cardinalidade: número de soluções de referência obtidas pela metaheurística $|LD \cap R|$;
- Medida de distância (proposta por CZYZAK e JASZKIEWICZ, 1998): mede a proximidade de um conjunto LD de soluções heurísticas não-dominadas em relação ao conjunto de referência R . Assume-se que LD é uma boa aproximação de R se as soluções de LD estão bem próximas das

soluções de R . Em outras palavras, para cada ponto $z \in R$ existe $z' \in LD$ tal que a distância entre z' e z é mínima.

As medidas de distância são definidas como segue:

$$D_{med} = \frac{1}{|R|} \sum_{z \in R} \min_{z' \in LD} d(z', z) \text{ e } D_{max} = \max_{z \in R} \{ \min_{z' \in LD} d(z', z) \}$$

onde $|R|$ é a cardinalidade do conjunto R e d é definido por:

$$d(z', z) = \max_{j=1, \dots, r} \left\{ \frac{1}{\Delta_j} (z'_j - z_j) \right\}, z' = (z'_1, \dots, z'_r) \in LD, z = (z_1, \dots, z_r) \in R$$

onde $\Delta_j = \max f_j - \min f_j$ com $\max f_j = \max \{z_j = f_j(x); f(x) \in LD \cup R\}$ e $\min \{z_j = f_j(x); f(x) \in LD \cup R\}$.

D_{med} é a média das distancias de um ponto $z \in R$ ao ponto mais próximo em LD , enquanto D_{max} fornece o máximo das distancias mínimas de um ponto $z \in R$ a algum ponto em LD .

4 RESULTADOS

Nesse capítulo são apresentados os resultados da aplicação das metaheurísticas propostas ao conjunto de problemas para testes. Além disso, são detalhados também os parâmetros e justificativas para utilização dos mesmos. A seção 4.1 apresenta os parâmetros utilizados no algoritmo *ILSMulti*, além da justificativa para escolha do procedimento de seleção. A seção 4.2 apresenta os resultados e as comparações de desempenho entre os métodos *ILSMulti* e SPEA. A seção 4.3 apresenta os resultados obtidos pelo método CPLEX. Por fim, a seção 5.4 apresenta os resultados e as comparações de desempenho entre os métodos heurísticos *ILSMulti* e PSA.

4.1 Análise dos Parâmetros do Algoritmo *ILSMulti*

4.1.1 Análise dos Parâmetros

O algoritmo *ILSMulti* possui quatro parâmetros, o *CritérioParada*, T (o número de soluções construídas na fase inicial), d (taxa de perturbação) e h (parâmetro usado na Busca Local). O valor usado para T foi 100, ou seja, inicialmente são geradas 100 soluções aleatórias das quais são selecionadas as dominantes no conjunto LD .

Por ser um algoritmo de busca local, o ILS permite a exploração de pequenos espaços de vizinhança, sem a necessidade de se explorar todo o espectro de soluções existentes para o problema. Desta forma, cabe ao mecanismo de perturbação ser forte o suficiente para permitir escapar do ótimo local corrente e permitir também a exploração de diferentes regiões do espaço de soluções. Ao mesmo tempo, o mecanismo de perturbação precisa ser fraco o suficiente para guardar características do ótimo local corrente, evitando o reinício aleatório.

Considerando estas características do algoritmo ILS e do procedimento de perturbação, foram realizados testes computacionais para determinar a taxa de perturbação d . Para estes testes, foram considerados os valores de $d=5%$, $d=7%$ e $d=10%$. Os resultados obtidos apontaram o valor de $d=7%$ como a melhor

alternativa para taxa de perturbação, uma vez que 5% não permite a fuga do ótimo local e o valor de 10% não mantém as características do ótimo local.

Para calibrar o parâmetro h utilizado no procedimento de Busca Local, foram selecionados um subconjunto de problemas de diferentes tamanhos. A Tabela 4.1 apresenta estes problemas.

Tabela 4.1 Problemas utilizados para calibrar o parâmetro d .

Classe	Problema	Nº UP's	Horizonte	Nº Prescrições	Tempo
A	1	50	9 anos	735	5 min.
A	4	50	14 anos	2466	10 min.
A	7	50	20 anos	9108	20 min.
A	10	50	25 anos	27045	30 min.
B	11	100	9 anos	1533	15 min.
B	14	100	14 anos	5094	30 min.
B	17	100	20 anos	18924	60 min.
B	20	100	25 anos	56499	100 min.
C	21	150	9 anos	2189	30 min.
C	24	150	14 anos	7491	50 min.
C	27	150	20 anos	27807	105 min.
C	28	150	25 anos	82905	180 min.
C	30	150	30 anos	220509	295 min.

Inicialmente foram gerados três valores para o parâmetro h : 5%, 10% e 15%. A heurística *ILSMulti* foi executada utilizando esses valores determinando, para cada problema, diferentes conjuntos de soluções dominantes LD . A partir destes conjuntos, determinou-se o conjunto referência R que é formado pelas soluções de referência entre todas as soluções encontradas. Na Tabela 4.2 são apresentados os resultados obtidos, que contém o número total de soluções de referência $|R|$, a quantidade de soluções no conjunto LD e o número total de soluções de referência $|LD \cap R|$ obtidas pela heurística para cada valor de h .

Das 13 instâncias testadas, foram encontradas 36.740 soluções de referência. Para cada valor de h (5%, 7% e 10%), foram obtidas respectivamente 14.824, 19.185 e 2.741 soluções de referência. Observa-se que o parâmetro $h = 10\%$ obteve maior número de soluções dominantes de referência em 10 dos 13 problemas testados. Também foi observado que, usando $h=10\%$, a Busca Local é rápida e o algoritmo *ILSMulti* executa um número maior de iterações, o qual é importante para o bom desempenho da heurística.

Tabela 4.2 Número de soluções encontradas pelo metaheurística *ILSMulti* com diferentes valores para o parâmetro *h*.

Problema	<i>R</i>	<i>LD</i>			<i>LD</i> ∩ <i>R</i>		
		<i>h</i> =5%	<i>h</i> =10%	<i>h</i> =15%	<i>h</i> =5%	<i>h</i> =10%	<i>h</i> =15%
1	4491	3439	2638	3386	2155	2313	23
4	4379	2360	3811	4813	599	3780	0
7	1288	1287	859	866	970	302	16
10	578	673	326	368	268	309	1
11	5726	6621	4795	7221	994	4370	362
14	2442	3146	2447	1402	0	2442	0
17	2443	2316	2004	1602	1179	1264	0
20	749	574	727	396	0	698	51
21	8726	7314	8603	8047	6539	1558	630
24	3118	2840	2940	6645	1369	970	779
27	1173	927	827	971	76	553	544
28	720	707	370	442	320	256	144
30	916	370	647	509	355	370	191
Total	36749	32574	30994	36668	14824	19185	2741

4.1.2 Análise do Método de Seleção

Conforme mencionado na seção 3.3.2, o algoritmo *ILSMulti* pode ser utilizado com dois diferentes procedimentos de seleção da solução: Randômico e Sequencial. Para comparar estes dois métodos, foram utilizados todos os problemas apresentados na Tabela 4.1, e os resultados são apresentados na Tabela 4.3.

A partir dos conjuntos de soluções obtidas pela metaheurística *ILSMulti*, utilizando os diferentes procedimentos de seleção da solução, determina-se o conjunto de referência *R* que é formado pelas soluções dominantes entre todas as soluções encontradas. Na Tabela 4.3, para cada problema, mostra-se o número de soluções de referência *R*, e para cada método de seleção (ILSR e ILSS) mostra-se número de soluções dominantes (*LD*) encontradas pela heurística e o número de soluções dominantes que fazem parte do conjunto referência *R* (*LD*∩*R*).

Nas três classes de problemas testados, classe “A”, classe “B” e classe “C”, o método de seleção da solução randômico ILSR obteve um número superior de soluções de referência em relação ao método de seleção da solução sequencial ILSS. Foram 24 das 30 instâncias testadas. Portanto, para realizar os demais testes

foi utilizado no algoritmo *ILSMulti* com o método de seleção da solução randômico (ILSR).

Tabela 4.3 Número de soluções encontradas pela metaheurística *ISLMulti* com diferentes métodos de seleção da próxima solução.

Classe	Problema	R	ILSR		ILSS	
			LD	LD∩R	LD'	LD'∩R
A	1	6798	7955	2300	4957	4498
A	2	6811	6045	3548	6653	3263
A	3	2579	1054	431	2151	2148
A	4	9020	9035	9020	6153	0
A	5	6355	6006	5991	3762	364
A	6	5982	5388	5379	4986	603
A	7	4372	4376	4372	2738	0
A	8	2716	2169	2164	1924	552
A	9	3098	3046	3042	2342	56
A	10	1464	1429	1406	3491	58
B	11	8689	7814	7618	9678	1071
B	12	10809	10708	10686	10012	123
B	13	6280	6355	6174	8517	106
B	14	5204	5208	5203	10045	1
B	15	3126	3150	3029	3425	97
B	16	3915	3916	3915	4908	0
B	17	485	183	0	485	485
B	18	4676	4683	4484	2568	192
B	19	2505	2158	1715	1336	790
B	20	3221	2935	1357	2501	1864
C	21	8052	7641	7062	8549	990
C	22	13442	13464	13442	13985	0
C	23	10205	10221	10205	9156	0
C	24	4954	4835	4832	6818	122
C	25	6502	6729	6425	4313	77
C	26	6019	6149	6005	7252	14
C	27	4241	4029	3543	3381	698
C	28	1851	2649	528	2531	1323
C	29	2011	1964	1951	917	60
C	30	1291	1469	358	939	933

R: Conjunto de soluções de dominantes de $(LD \cap LD')$

LD: Conjunto de soluções dominantes obtidas com o método randômico ILSR.

LD': Conjunto de soluções dominantes obtidas com o método sequencial ILSS.

4.2 Comparação do *ILSMulti* com o SPEA

Para comparar as metaheurísticas *ILSMulti* e SPEA, novos resultados foram gerados a partir do algoritmo SPEA. O critério de parada estabelecido para ambos os algoritmos foi o tempo, conforme mostra a Tabela 3.3. Os resultados são apresentados na Tabela 4.4, onde, para cada problema, mostra-se o número de soluções de referência R , e para cada algoritmo (*ILSMulti* e SPEA) mostra-se o número de soluções dominantes ($|LD|$) encontradas pela heurística e o número de soluções dominantes que fazem parte do conjunto referência R ($|LD \cap R|$).

Tabela 4.4 Número de soluções encontradas pelas metaheurísticas *ILSMulti* e SPEA.

Classe	Problema	$ R $	<i>ILSMulti</i>		SPEA	
			$ LD $	$ LD \cap R $	$ LD' $	$ LD' \cap R $
A	1	12540	7955	3845	9596	8695
A	2	9955	6045	3760	10130	6195
A	3	5509	1054	0	5509	5509
A	4	9020	9020	9020	8941	0
A	5	5991	5991	5991	9105	0
A	6	5379	5379	5379	7032	0
A	7	4372	4372	4372	10394	0
A	8	2165	2165	2165	5479	0
A	9	3043	3043	3043	6064	0
A	10	2903	1406	1406	10896	1497
B	11	7799	7799	7799	10058	0
B	12	10686	10686	10686	8218	0
B	13	6344	6344	6344	6302	0
B	14	5203	5203	5203	14674	0
B	15	3147	3147	3147	4151	0
B	16	3915	3915	3915	6785	0
B	17	1260	182	13	1497	1247
B	18	4670	4670	4670	4852	0
B	19	2156	2156	2156	11420	0
B	20	2892	2892	2892	5074	0
C	21	7636	7636	7636	14975	0
C	22	13442	13442	13442	12652	0
C	23	10205	10205	10205	12682	0
C	24	4832	4832	4832	11246	0
C	25	6727	6727	6727	5739	0
C	26	6142	6142	6142	8299	0
C	27	4015	4015	4015	11915	0
C	28	2627	2627	2627	6706	0
C	29	1951	1951	1951	6993	0

Observa-se que em 25 instâncias testadas, o conjunto referência R foi determinado exatamente pelo algoritmo *ILSMulti*. E um único problema (3), o SPEA determinou exatamente o conjunto R . Em 4 problemas testados, o conjunto R foi determinado por ambos os algoritmos, sendo que nestes casos, sempre o SPEA obteve um maior número de soluções de referência.

Na Tabela 4.5 são mostrados os desempenhos das metaheurísticas *ILSMulti* e SPEA em relação à medida de distância.

Tabela 4.5 Desempenho das metaheurísticas *ILSMulti* e SPEA (medida de distância)

Classe	Problema	Média de distância			
		<i>ILSMulti</i>		SPEA	
		D_{med}	D_{max}	D_{med}	D_{max}
A	1	0.1440	0.3081	0.1598	2.6145
A	2	0.4906	1.8015	0.7914	11.5685
A	3	4.1983	25.5844	0.0000	0.0000
A	4	0.0000	0.0000	1.7567	17.3884
A	5	0.0000	0.0000	1.4001	9.8738
A	6	0.0000	0.0000	1.4249	5.9054
A	7	0.0000	0.0000	1.0920	14.2160
A	8	0.0000	0.0000	1.2804	17.2610
A	9	0.0000	0.0000	3.0694	24.3607
A	10	0.0942	0.3698	0.2068	9.4425
B	11	0.0000	0.0000	0.3100	3.3708
B	12	0.0000	0.0000	1.8349	16.8939
B	13	0.0000	0.0000	0.8964	11.8181
B	14	0.0000	0.0000	0.5946	7.0340
B	15	0.0000	0.0000	1.5144	14.3101
B	16	0.0000	0.0000	1.9100	16.2328
B	17	0.4644	9.2691	0.0008	0.0966
B	18	0.0000	0.0000	2.5090	22.1012
B	19	0.0000	0.0000	2.1058	12.6023
B	20	0.0000	0.0000	0.8660	5.8749
C	21	0.0000	0.0000	1.7671	16.6535
C	22	0.0000	0.0000	3.3334	22.9788
C	23	0.0000	0.0000	1.6953	14.0978
C	24	0.0000	0.0000	4.5157	24.5063
C	25	0.0000	0.0000	2.9676	19.7141
C	26	0.0000	0.0000	3.1721	16.0281
C	27	0.0000	0.0000	1.4348	5.8912
C	28	0.0000	0.0000	1.6712	8.4044
C	29	0.0000	0.0000	1.3324	4.8761

C	30	0.0000	0.0000	7.3241	19.9820
---	----	--------	--------	--------	---------

Observa-se que em grande parte das instâncias testadas, o algoritmo *ILSMulti* obteve como D_{med} e D_{max} o valor 0 (zero), um vez que o conjunto R foi o próprio conjunto gerado pela metaheurística.

Com o propósito de ilustrar os Conjuntos-Dominantes, foram selecionados 6 das 30 instâncias testadas. As Figuras 4.1, 4.2, 4.3, 4.4, 4.5 e 4.6 representam os conjuntos das instâncias 1, 7, 13, 19, 25 e 30, respectivamente. Na Figura 4.1, apesar do algoritmo SPEA obter um maior número de soluções dominantes, observa-se que o *ILSMulti* obteve uma fronteira de maior amplitude, o que ocorreu em todas as instâncias testadas. Nas demais situações representadas pelas Figuras 4.2, 4.3, 4.4, 4.5 e 4.6, as soluções geradas pelo algoritmo *ILSMulti* correspondem à 100% do conjunto referência (fronteira dominante).




Figura 4.1 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *SPEA* para o problema 1




Figura 4.2 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *SPEA* para o problema 7




Figura 4.3 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *SPEA* para o problema 13

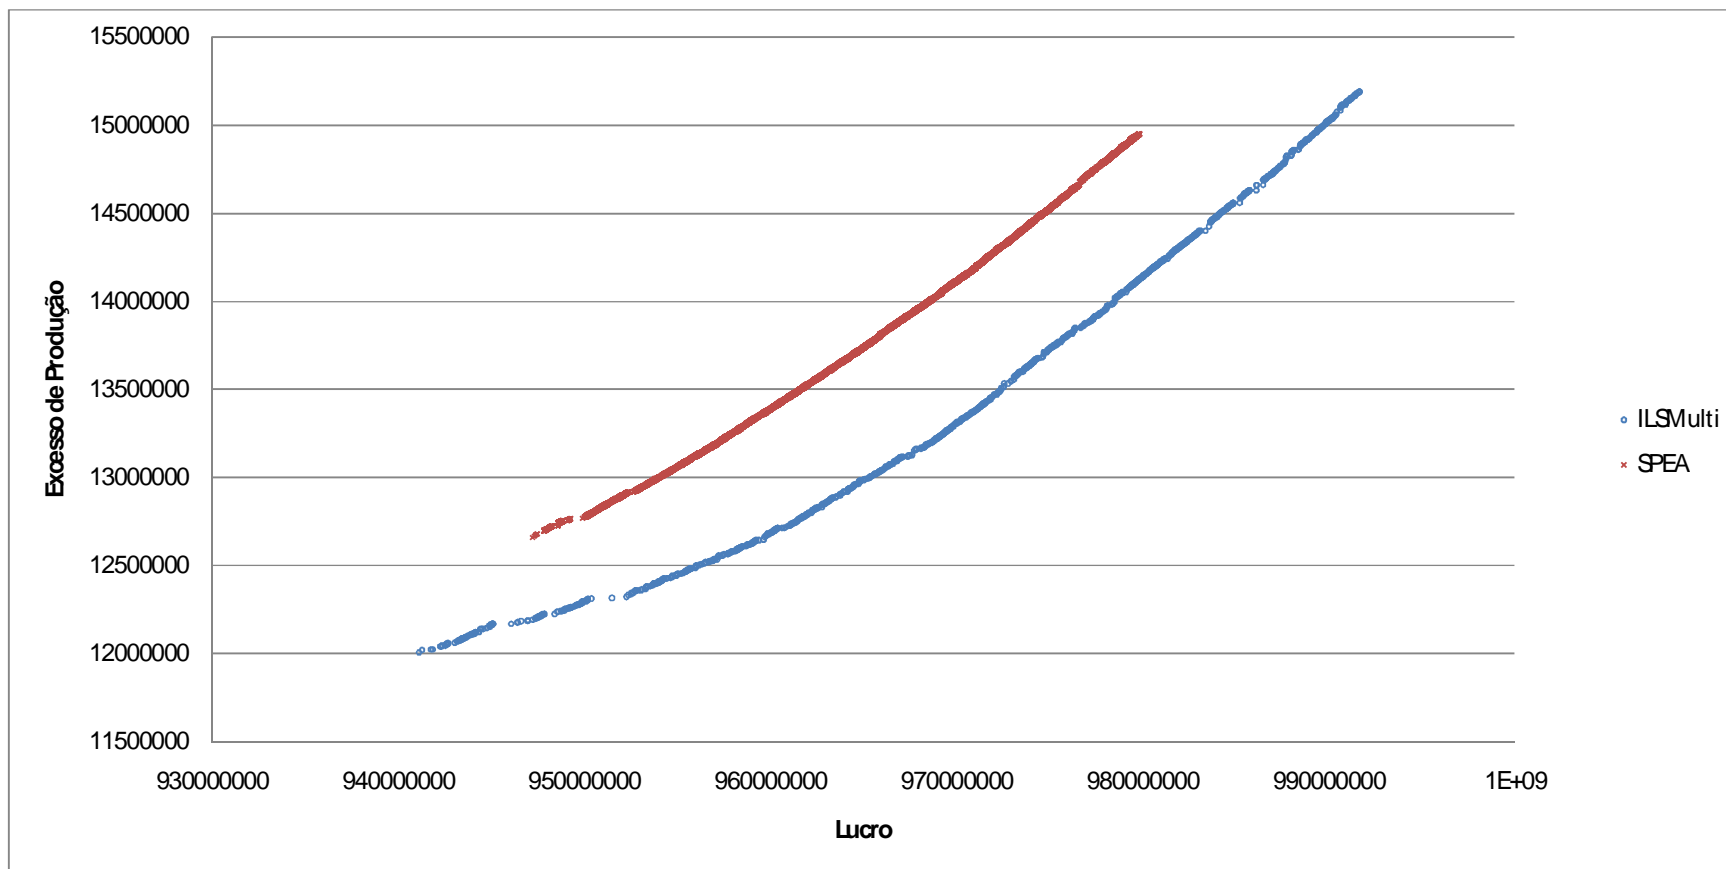


Figura 4.4 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *SPEA* para o problema 19




Figura 4.5 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *SPEA* para o problema 25




Figura 4.6 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *SPEA* para o problema 30

4.3 Comparação do *ILSMulti* com Resultados Obtidos no CPLEX

Para analisar a eficiência da metaheurística *ILSMulti*, os resultados gerados foram comparados com resultados obtidos pelo *software* comercial CPLEX, versão 11, que utiliza um algoritmo exato para resolução de problemas de Programação Inteira. Nesta comparação, apenas as instâncias 1, 2 e 3 (Classe “A”), as instâncias 14, 15 e 16 (Classe “B”) e as instâncias 27, 28 e 29 (Classe “C”) foram utilizadas (Tabela 4.1).

Como os problemas propostos são de natureza multiobjetivo e o *software* CPLEX apresenta um solver apenas para problemas de objetivo único, utilizou-se o artifício de se transformar uma das funções-objetivo do problema em restrição, e parametrizar valores para esta restrição, de forma a se obter soluções ao longo da fronteira Pareto-ótima (Método da Restrição), metodologia semelhante à empregada por Teixeira (2002).

Desta forma, a função objetivo *Z2* (excesso de produção global da floresta) do modelo apresentado na seção 3.2 foi transformada em uma nova restrição para o problema. O modelo utilizado pode ser expresso tal como se segue:

$$\text{Max } Z1 = \sum_{i=1}^M \sum_{j=1}^{N_i} VPL_{ij} X_{ij} \quad (1)$$

Sujeito a:

$$\bullet \sum_{j=1}^{N_i} X_{ij} = 1, \quad \forall i = 1, \dots, M, \quad (3)$$

$$\bullet V_k \leq \sum_{i=1}^M \sum_{j=1}^{N_i} V_{ijk} X_{ij}, \quad k = 0, 1, \dots, H-1 \quad (4)$$

$$\bullet CR_k \geq \sum_{i=1}^M \sum_{j=1}^{N_i} A_{ijk} X_{ij}, \quad k = 0, 1, \dots, H-1 \quad (5)$$

$$\bullet \sum_{k=1}^H \left(\sum_{i=1}^M \sum_{j=1}^{N_i} V_{ijk} X_{ij} - V_k \right) + F = P \quad (2)$$

$$\bullet X_{ij} \in \{0, 1\}, \quad \forall i = 1, \dots, M, j = 1, \dots, N \quad (6)$$

Observa-se que a restrição (2) contém uma variável de folga *F*, uma vez que o valor do parâmetro *P* é fixo. Para determinar os valores atribuídos ao parâmetro *P*, foram selecionados de forma uniforme 50 pontos no eixo Excesso de

Produção, como mostra o exemplo da figura 4.7. Neste exemplo, observa-se que o algoritmo *ILSMulti* gerou pontos entre 1000 e 1140 no eixo Excesso de Produção. Para selecionar cada ponto, primeiramente foi necessário encontrar a diferença entre o maior (1140) e menor valor (1000). Em seguida faz-se a divisão da diferença (140) por 50 (número de pontos desejados), o resultado desta operação é a distância entre um ponto e outro. Para este exemplo, a diferença entre os pontos seria igual à 2.8, e os valores atribuídos à P seriam a seqüência: 1000, 1002.8, 1005.6, 1008.4, 1011.2, ..., 1140.

Uma vez definido os pontos, são gerados 50 modelos para cada problema. E para execução de cada modelo, foi utilizado um arquivo de extensão BAT que realiza a chamada ao software CPLEX passando como parâmetro o arquivo do modelo e um arquivo para o armazenamento dos resultados. Após executado os 50 modelos propostos para cada problema, faz-se a coleta do tempo, do valor encontrado para o objetivo ($Z1$) e da variável de folga F .

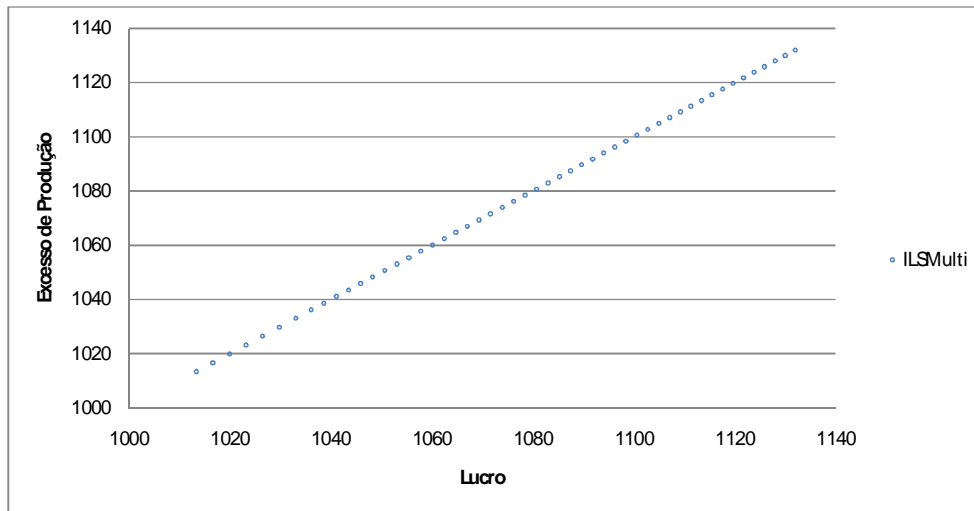


Figura 4.7 Distribuição dos pontos no eixo Excesso de Produção

É importante ressaltar que foi estabelecido um tempo limite para as heurísticas. Enquanto que para o *software* CPLEX, o tempo a ser considerado é o somatório dos tempos gastos para a solução de cada problema parametrizado, um total de 50 problemas. A Tabela 4.6 apresenta o tempo gasto pelo *software* CPLEX para formar uma fronteira de 50 soluções. Observa-se que para os problemas de classe “C” o CPLEX não encontrou soluções, e o tempo de busca permitido foi superior ao tempo destinado às heurísticas.

Tabela 4.6 Tempo gasto pelo software CPLEX, versão 11.

Classe	Problema	Tempo		I
		Heurísticas	CPLEX	
A	1	5	5 min.	50
A	2	5	169 min.	50
A	3	5	50 min.	50
B	14	30	22 min.	50
B	15	30	73 min.	50
B	16	40	10 min.	50
C	27	105	150 min.	-
C	28	180	1500 min.	-
C	29	240	2900 min.	-

I: número total de soluções encontradas.

Na Tabela 4.7 são mostrados os desempenhos dos métodos *ILSMulti* e CPLEX em relação à medida de distância. Observa-se que para os problemas de classe A e B onde o CPLEX encontrou soluções, ele foi superior em 100% dos testes.

Tabela 4.7 Desempenho dos métodos *ILSMulti* e CPLEX (medida de distância)

Classe	Problema	Média de distância			
		<i>ILSMulti</i>		CPLEX	
		D_{med}	D_{max}	D_{med}	D_{max}
A	1	0.50136	0.71124	0.0000	0.0000
A	2	0.87690	1.50201	0.0000	0.0000
A	3	2.13484	2.62591	0.0000	0.0000
B	14	0.0132	0.57861	0.0212	0.0620
B	15	0.68435	1.24666	0.0000	0.0000
B	16	0.64344	0.89771	0.0000	0.0000

4.4 Comparação do *ILSMulti* com Outra Heurística da Literatura

Os resultados gerados pela metaheurística *ILSMulti*, também foram comparados com resultados obtidos pela metaheurística *Pareto Simulated Annealing* (PEREIRA, 2004), neste trabalho representados por PSA. Pelo fato dos dados do PSA serem obtidos a partir da literatura, apenas as instâncias 1, 2 e 3 (Classe “A”), as instâncias 14, 15 e 16 (Classe “B”) e as instâncias 27, 28 e 29 (Classe “C”) foram utilizadas nesta comparação (Tabela 4.1), visto que foram as instâncias utilizadas nos trabalhos citados.

A Tabela 4.8 apresenta os resultados encontradas pelas metaheurísticas *ILSMulti* e PSA. Para cada problema, mostra-se o número de soluções de referência $|R|$, e para cada algoritmo (*ILSMulti* e PSA) mostra-se o número de soluções referência ($|LD|$) encontradas pela heurística e o número de soluções dominantes que fazem parte do conjunto referência R ($|LD \cap R|$). Observa-se que o *ILSMulti* foi superior em 6 das 9 instâncias testadas.

Tabela 4.8 Número de soluções encontradas pelas metaheurísticas *ILSMulti* e PSA

Classe	Problema	$ R $	<i>ILSMulti</i>		PSA	
			$ LD $	$ LD \cap R $	$ LD' $	$ LD' \cap R $
A	1	4449	7955	3805	800	644
A	2	4840	6045	4537	800	303
A	3	801	1054	2	800	799
B	14	5203	5203	5203	1600	0
B	15	1894	3147	721	1356	1173
B	16	2572	3915	899	1729	1673
C	27	4300	4015	3081	2500	1219
C	28	2656	2627	2627	517	29
C	29	1951	1951	1951	541	0

R : Conjunto de soluções de dominantes de $(LD \cap LD')$

LD : Conjunto de soluções dominantes obtidas pela metaheurística *ILSMulti*.

LD' : Conjunto de soluções dominantes obtidas pela metaheurística PSA.

Para ilustrar os Conjuntos-Dominantes, foram selecionados 3 das 9 instâncias testadas, sendo cada um representando uma classe. As Figuras 4.8, 4.9 e 4.10 representam os conjuntos das instâncias 1, 14 e 27 respectivamente.

Na Figura 4.8, observa-se dois pontos relevantes para o algoritmo *ILSMulti*: primeiramente ele alcançou pontos mais próximos da fronteira gerada

pelo CPLEX e por conseguinte, ele obteve soluções mais extremas, o que torna sua fronteira mais ampla que a fronteira do PSA. Na Figura 4.9, novamente o *ILSMulti* obteve os melhores resultados, visto que sua fronteira ficou mais próxima da fronteira gerada pelo *software* CPLEX. E na Figura 4.10 observa-se que o *ILSMulti* obteve um maior número de soluções dominantes quando comparado com o algoritmo PSA.




Figura 4.8 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *PSA* para o Problema 1




Figura 4.9 Fronteira Pareto-Ótima construída pelos algoritmos *ILSMulti* e *PSA* para o problema 14




Figura 4.10 Fronteira Pareto-Ótima construída pelos algoritmos ILSMulti e PSA para o problema 27

5 CONCLUSÕES E PERSPECTIVAS FUTURAS

Neste trabalho foi proposta uma adaptação da metaheurística ILS (*Iterated Local Search*) para resolver problema de planejamento florestal multiobjetivo. A metaheurística mostrou-se adequada para explorar o complexo espaço de soluções viáveis do modelo proposto para um problema de planejamento florestal multiobjetivo. Atualmente, para se manter no mercado, e melhor gerenciar sua produção, as empresas florestais necessitam de tomar decisões sob múltiplos objetivos. Isso torna a utilização do *ILSMulti* uma boa opção, visto que as características destes problemas são favoráveis à sua utilização.

Os resultados apresentados mostram uma melhora significativa na aplicação do *ILSMulti* quando comparado com o algoritmo SPEA proposto por TEIXEIRA (2002). Esta melhoria é evidenciada nos problemas maiores onde foi necessário um tempo de processamento maior.

Dentre as vantagens apresentada pelo algoritmo perante os demais estão:

- Menor número de parâmetros a serem calibrados;
- Menor tempo para encontrar soluções quando comparado com o CPLEX, o que pode ser explicado pelo fato do *ILSMulti* realizar busca múltipla de soluções, ao passo que o CPLEX busca uma única solução de cada vez;
- Outro inconveniente da busca de soluções pelo CPLEX é o trabalho manual despendido para a parametrização do problema, por se tratar de um algoritmo exato;
- Maior amplitude na fronteira pareto-ótima, uma vez que o tomador de decisões pode optar por soluções mais extremas, tendendo a algum dos objetivos;

Como perspectivas futuras e de continuação dos estudos na área, alguns pontos devem ser levados em consideração:

- Com o objetivo de facilitar o processo de tomada de decisão atribuído ao manejador florestal, é relevante a inclusão de rotinas que faça a redução no número de soluções da fronteira, facilitando assim a escolha das soluções;

- A técnica de intensificação *Path Relinking* tem-se mostrado importante na obtenção de bons resultados em problemas com apenas um objetivo. Esta técnica pode ser inserida após o procedimento de busca local para intensificar a busca por novas soluções;
- Comparar a eficiência da busca local, visto que ela pode ser testada no algoritmo SPEA, tornando-o um algoritmo híbrido.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ARROYO, J. E. C. **Heurísticas e metaheurísticas para otimização combinatória multiobjetivo**. 2002. 225 f. Tese (Doutorado em Engenharia Elétrica) – Curso de Pós-Graduação em Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, SP, 2002.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE – ABIMCI. 2007. **Estudo setorial 2007**: indústria de madeira processada mecanicamente. Disponível em: <http://www.abimci.com.br/importancia_setor.html>. Acesso em: 10 mar. 2008.
- ASSOCIAÇÃO BRASILEIRA DOS PRODUTORES DE FLORESTAS PLANTADAS – ABRAF. **Segmento de florestas plantadas no Brasil – Indicadores (2009) – Ano-base 2008**. Disponível em: <<http://www.abraflor.org.br/estatisticas.asp>>. Acesso em: 27 set. 2009.
- BACK, T. **Evolutionary algorithms in theory and practice**. New York: Oxford University Press, 1996.
- BARROS JUNIOR, A. A.; ARROYO, J. E. C.; SANTOS, H. N. GRASP com Path Relinking para um problema de planejamento florestal. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 41. 2009, Porto Seguro. **Anais...** Porto Seguro, 2009.
- BERBET, P. C. **Sistema imunológico artificial para otimização multiobjetivo**. 2008. 119 f. Dissertação (Mestrado em Engenharia Elétrica) – Curso de Pós-Graduação em Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, SP, 2008.
- BLEULER, S.; LAUMANN, M.; THIELE, L.; ZITZLER, E. PISA-A platform and programming language independent interface for search algorithms. In: FONSECA, Carlos M.; FLEMING, Peter J.; KALYANMOY Deb Eckart Zitzler; THIELE, Lothar (Eds.). **Evolutionary multi-criterion optimization**.

Second international conference, EMO 2003, Springer. Portugal: Lecture Notes in Computer Science Faro, 2003. v. 2632, p. 494-508.

BRITO, J. A. M.; MONTENEGRO, F. M. T.; OCHI, L. S. Um algoritmo ILS para melhoria de eficiência da estratificação estatística. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 41., 2009, Porto Seguro. **Anais...** Porto Seguro, 2009. p. 2133-2144.

BUOSI, T. **Sistemas computacionais de suporte à medição de desempenho:** proposição de critérios para análise, comparação e aquisição de sistemas. 2004. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2004.

CLUTTER, J. C.; FORTSON, J. C.; PIENNAR, L.V.; BRISTER, G. H.; BAILEY, R. L. **Timber management:** a quantitative approach. 3. ed. New York: John Willey, 1983. 333 p.

COELHO, C. A. C. An updated survey of GA-Based multiobjective optimization techniques: state of the art and future trends. In: CONGRESSO EVOLUTIONARY COMPUTATION (9CEC99), 1999. **Anais...** [S.l.]: IEEE, 1999. v. 1, p. 3-13.

COELHO, C. A. C.; CORTÉS, N. C. An approach to solve multiobjective optimization problems based on an artificial immune system. In: TIMMIS, Jonathan; BENTLEY, Peter J. (Eds.). INTERNATIONAL CONFERENCE ON ARTIFICIAL IMMUNE SYSTEMS (ICARIS'2002), 1., 2002, Canterbury. **Abstracts...** Canterbury, England: University of Kent at Canterbury, 2002. p. 212-221.

CZYZAK, P.; JASZKIEWICZ, A. "Pareto simulated annealing - a metaheuristic technique for multiple objective combinatorial optimization". **Journal of Multi-Criteria Decision Analysis**, v. 7, p. 34-47, 1998.

DEB, K. **Multi-objective optimization using evolutionary algorithms.** Chichester, England: John Willey & Sons, 2001. 498 p.

DYDSTRA, D. P. **Mathematical programming for natural resource management.** New York: McGraw-Hill, 1984. 318 p.

- ESQUIVEL, S.; LEIVA, H.; GALLARD, R. Multiplicity in genetic algorithms to face multicriteria optimization. In: CONGRESS ON EVOLUTIONARY COMPUTATION (IEEE), 33., 1999, Washington. **Proceedings...** Washington DC., 1999. p 85-90.
- FATURETO, C. R. C.; SANTOS, H. N. Tomada de decisão sob critérios múltiplos: metodologias e oportunidades de aplicação no Agribusiness – Parte I. **Revista Brasileira de Agroinformática**, Viçosa, v. 2, n. 1, p. 13-27, 1999a.
- FATURETO, C. R. C.; SANTOS, H. N. Tomada de decisão sob critérios múltiplos: metodologias e oportunidades de aplicação no Agribusiness – Parte II. **Revista Brasileira de Agroinformática**, Viçosa, v. 2, n. 2, p. 83-94, 1999b.
- FONSECA, C. M.; FLEMING, P. J. “An overview of evolutionary algorithms in multiobjective optimization”. **Evolutionary Computation**, v. 3, n. 1, p. 1-16, 1995.
- FRAMINAN, J. M.; LEISTEN, R. “An efficient constructive heuristic for flowtimeminimisation in permutation flowshops”. **OMEGA**, n. 31, p. 311-317, 2003.
- FRAMINAN, J. M.; LEISTEN, R. **A multi-objective iterated greedy search for flowshop scheduling with makespan and flowtime criteria**. [S.l.]: OR Spectrum, 2007.
- GIBOSHI, M. L. **Sistema de apoio ao processo de decisão para a gestão do uso agrícola da terra**. 2005. Tese (Doutorado) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, SP, 2005.
- HORN, J. Multicriteria decision making. In: BÄCK, T.; FOGEL, D. B.; MICHALEWICZ, Z. (Eds.). **Handbook of Evolutionary Computation**. v. 1, p. F1.9:1-F1.9:15. Oxford, England: Oxford University Press, 1997.
- IVERSON, D. C.; ALSTON, R. M. **The genesis of FORPLAN a historical and analytical review of Forest Service planning models**. Washington: USDA Forest Service, 1986. 25 p. (General Technical Report, INT-214).

JOHNSON, K. N.; SCHEURMAN, H. L. **Techniques for prescribing optimal timber harvest and investment under different objectives** – Discussion and synthesis. USA, 1977. (Forest Science Monograph, 18).

JOHNSON, K. N.; JONES, D.; DANIEL, B. **A user's guide to multiple use sustained yield scheduling calculation (MUSYC)**. Fort Collins: Department of Agriculture, Forest Service, Timber Management, 1979. 242 p.

JUNIOR, R. F. T.; FERNANDES, F. C. F.; PEREIRA, N. A. Sistemas de apoio à decisão para programação da produção em fundições de mercado. **Gestão & Produção**, v. 13, n. 2, 2006.

KIDD, W. E.; THOMPSON, E. F.; HOEPNER, P. H. Forest regulation by linear programming – A case study. **Journal of Forestry**, v. 64, p. 611-613, 1966.

KURTTLA, M. **Methods for integrating ecological objectives into landscape-level planning of non-industrial private forestry**. Joensuu: Faculty of Forestry; University of Joensuu, 2001. 35 p.

LAROZE, A. J. A linear programming, tabu search method for solving forest-level bucking optimization problems. **Forest Science**, Washington, v. 45, n. 1, p. 108-116, 1999.

LEITE, H. G. **Conversão de troncos em multiprodutos da madeira, utilizando programação dinâmica**. 1994. 230 f. Tese (Doutorado) – Universidade Federal de Viçosa, Viçosa, MG, 1994.

LEUSCHENER, W. A. **Introduction to forest resource management**. New York: John Willey & Sons, 1984. 298 p.

LOURENÇO, H. R.; MARTIN, O.; STÜTZLE, T. Iterated local search. In: GLOVER, F.; KOCHENBERGER, G. (Eds.). **Handbook of metaheuristics**, Norwell, MA: Kluwer Academic Publishers, 2002. p 321-353.

MACHADO, C. C.; LOPES, E. S. Planejamento. In: MACHADO, C. C. (Org.). **Colheita florestal**. Viçosa, MG: Editora UFV, 2002. 468 p.

MALINOVSKI, R. A. **Otimização da distância de extração de madeira com forwarder**. 2007. 94 f. Tese (Doutorado em Agronomia/Energia na

Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, SP, 2007.

MIYAZAWA, F. K. **Otimização combinatória**. Disponível em: <<http://www.ic.unicamp.br/~fkm/problemas.html>>. Acesso em: 23 maio 2007.

NAVON, D. I. RAM, Timber. **A long-range planning method for commercial timber lands under multiple-use management**. Berkeley: Department of Agriculture, Forest Service, Pacific Southwest Forest and Range Experiment Station, 1971. 22 p. (USDA. Forest Service, Res. paper PNW - 70).

NAWAZ, M.; ENSCORE, E. E., HAM, I. “A heuristic algorithm for the n-machine, n-job flowshop sequencing problem”. **OMEGA**, n. 11, p. 91-98, 1983.

NOBRE, S. R. **A heurística da Razão-R aplicada a problemas de gestão florestal**. 1998. 98 f. Dissertação (Mestrado) - Universidade Federal de Lavras, Lavras, MG, 1999.

NOBRE, S. R.; ROGRIGUEZ, L. C. E.; SILVEIRA, L. E. S.; SIMÕES, G. Componentes básicos de um modelo relacional de dados para a gestão florestal. **SiLva LusitAna**, Lisboa, v. 12, p.103-117, 2004. Número especial.

PEARSON, J. M.; SHIM, J. P. An empirical investigation into DSS structures and environments. **Decision Support Systems**, n. 13, p. 141-158, 1995.

PEREIRA, G. W. **Aplicação da técnica de recozimento simulado em problemas de planejamento florestal multiobjetivo**. 2004. 67 f. Dissertação (Mestrado em Ciência da Computação) – Curso de Pós-Graduação em Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, 2004.

OSYCHKA, A. Multicriteria optimization for engineering design. In: GERO, J.S. (Ed.). **Design optimization**. [S.l.]: Academic Press, 1985. p. 193-227.

REZENDE, J. P. L.; OLIVEIRA, A. D. **Avaliação de projetos florestais**. Viçosa, MG: Imprensa Universitária, UFV, 1993. 237 p.

RIBEIRO, C. A. A. S. **Otimização florestal**. Viçosa, MG: UFV, Departamento de Engenharia Florestal, 2007. 80 p.

- ROCHA, D. X. **Otimização do planejamento da manutenção preventiva em sistemas complexos, com foco na cadeia de suprimentos**. 2002. 84 f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Florianópolis, Florianópolis, 2002.
- RODRIGUES, F. L.; LEITE, H. G.; ALVES, J. M. Sysflor - Um sistema de suporte à decisão em planejamento florestal. In SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 32., 2000. Viçosa. **Anais...** Viçosa, MG: UFV, 2000. p. 974-995.
- RODRIGUES, F. L. **Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais**. 2001. 25 f. Tese (Doutorado) - Universidade Federal de Viçosa, Viçosa, MG, 2001.
- RODRIGUEZ, L. C. E.; LIMA, A. B. N. P. M. A utilização da programação linear na determinação de uma estratégia ótima de reforma de um talhão florestal. **IPEF**, Piracicaba-SP, n. 31, p. 47-53, 1985.
- RUIZ, R.; STÜTZLE, T. A simple and effective iterated greedy algorithm for the permutation flowshop scheduling problem. **Eur. J. Oper. Res.**, v. 177, p. 2033-2049, 2007.
- RUIZ, R.; STÜTZLE, T. An Iterated Greedy heuristic for the sequence dependent setup times flowshop problem with makespan and weighted tardiness objectives. **Eur. J. Oper. Res.**, v. 187, p.1143-1159, 2008.
- SCOLFORO, J. R. S. **Manejo florestal**. Lavras, MG: UFLA-FAEPE, 1997. 438 p.
- SILVA, G. F. **Problemas no uso de programação matemática e simulação em regulação florestal**. 2001. 89 f. Tese (Doutorado) - Universidade Federal de Viçosa, Viçosa, MG, 2001.
- SILVA, G. F.; LEITE, H. G.; SILVA, M. L. da; 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, 2003.

- SOARES, N. S. **Potencial de implantação de um contrato futuro da madeira de reflorestamento.** 2006. 121 f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2006.
- SPRAGUE, R. H.; WATSON, H. J. **Decision Support systems: putting theory into practice.** 2. ed. Englewood Cliffs: Prentice Hall, 1989. 419 p.
- STEUER, R. E.; SCHULER, A. T. An interactive multiple-objective linear programming approach to a problem in forest management. **Operations Research**, v. 26, n. 2, p. 254-269, 1978.
- TAUBE NETTO, M. Um modelo de programação linear para planejamento de florestas de eucalipto. **Pesquisa Operacional**, v. 4, n. 1, p. 19-39, 1984.
- TAVARES, R. **Proposta de um sistema de apoio à decisão para controle e gerenciamento agrícola em usinas de açúcar e álcool.** 2008. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2008.
- TEIXEIRA, A. F. **Aplicação de algoritmos evolucionários na solução de problemas de planejamento florestal multiobjetivo.** 2002. 66 f. Dissertação (Mestrado em Ciência da Computação) – Curso de Pós-Graduação em Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, MG, 2002.
- TURBAN, E.; ARONSON, J. E. **Decision support systems and intelligent systems.** New Jersey: Prentice-Hall, 1998. 890 p.
- VAN VELDHUIZEN, D. A.; LAMONT, G. B. Multiobjective evolutionary algorithms: analysing the state-of-the-art. **Evolutionary Computation**, v. 8, n. 2, p. 125-147, 2000.
- VIANNA, D. S.; VIANNA, M. F. D. Uma Heurística GRASP híbrida para um problema de otimização combinatória multiobjetivo. In Encontro Nacional de Engenharia de Produção, 26., 2006, Fortaleza. **Anais...** Fortaleza, CE: ABREPO, 2006. p. 1-9.

WEINTRAUB, A.; JONES, G.; MAGENDZO, A.; MEACHAM, M.; KIRBY, M.
A heuristic system to solve mixed interger Forest planning models.
Operations Research, v. 42, n. 6, p. 1010-1024, nov./dec. 1994.

ZITZLER, E. **Evolutionary algorithms for multiobjective optimization:
methods and applications**. 1999. Ph. D. Thesis - Swiss Federal Institute of
Technology Zurich, 1999.

Livros Grátis

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

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)