

Gustavo Willam Pereira
Orientador: Heleno do Nascimento Santos
Co-Orientador: Henrique Pacca Loureiro Luna

Aplicação da Técnica de Recozimento Simulado em Problemas de Planejamento Florestal Multiobjetivo

Dissertação apresentada ao Curso de Pós-Graduação em Ciência da Computação do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais como requisito parcial para a obtenção do grau de Mestre em Ciência da Computação.

Belo Horizonte

26 de Março de 2004

DEDICATÓRIA

Aos meus pais José Carlos e Maria de Lourdes e ao meu tio Paulo.

AGRADECIMENTOS

A Deus, por tudo.

A minha Mãe Lourdes, fonte inesgotável de estímulo, força e coragem, pela sabedoria infinita, pelo amor e pelo carinho.

Ao meu Pai José Carlos, apesar de não participar mais ativamente em nossas vidas, esteve sempre torcendo pelo meu sucesso.

Ao meu tio Paulo, pela oportunidade oferecida desde a graduação, pelo constante incentivo, apoio, pela serenidade que me foi transmitido em muitas situações e pela sincera amizade. Meu eterno obrigado.

A minha avó Maria pelo carinho e orações.

Aos meus irmãos Mauro e Maurício, meus primos Marinho, Stela, Humberto, Paulo Jr., Cássio, as minhas tias Cida e Vilma, e a todos os demais familiares, que estiveram sempre torcendo pelo meu sucesso.

Ao meu avô Mário, tia Penha, tio Fiote e tio Tãozinho, que do céu compartilham comigo esta vitória.

A minha namorada Lilian pelo amor e alegria transmitida nos momentos mais difíceis.

À Universidade Federal de Minas Gerais, por intermédio do Departamento de Ciência da Computação, e à Universidade Federal de Viçosa, por intermédio do Departamento de Informática, pela oportunidade de realizar este curso.

Ao Prof. Heleno do Nascimento Santos, pela orientação, paciência, pelos esclarecimentos muitas vezes decisivos, compreensão demonstrados em todas as etapas deste trabalho.

À equipe da Cientec, especialmente Alessandro, Paulo Márcio, Anderson, pela amizade e fundamental ajuda no desenvolvimento e conclusão desse trabalho.

À equipe da Tripagel, especialmente Márcia, Valter, João José, Valtencir, Saulo pela amizade, apoio e nas caronas para Viçosa.

Aos amigos dos bons tempos da graduação André, Chiquinho, Marcelo Balbino, pelo companheirismo demonstrado a cada dia e pela oportunidade de compartilhar tantas experiências boas e más, com a certeza de que, embora nossas

vidas tenham seguido caminhos diferentes, estaremos sempre unidos por lembranças comuns.

Ao grande amigo André-Capitólio, pela eterna amizade e pelo auxílio nos testes realizados na Universidade Federal de Minas Gerais.

Aos meus amigos de curso pela agradável convivência e pela ajuda nos estudos.

Aos professores do Departamento de Informática da Universidade Federal de Viçosa pela total colaboração aos meus estudos e que muito contribuíram para minha formação acadêmica.

A todos aqueles que participaram da realização deste trabalho, direta ou indiretamente.

RESUMO

Este estudo tem como objetivo discutir a aplicabilidade do *Simulated Annealing* na solução de problemas de planejamento florestal multiobjetivo. Para tanto, é proposto um modelo de otimização sob critérios múltiplos e implementado um algoritmo para a solução do modelo, o PSA (*Pareto Simulated Annealing*), uma variação do *Simulated Annealing* uniobjetivo, para a solução heurística do modelo sob a visão multiobjetivo. Posteriormente, foram realizados vários testes com o algoritmo em problemas de diversos portes para medir a eficiência e a eficácia e os resultados foram comparados com o CPLEX, um software que utiliza um algoritmo exato *branch-and-bound* para a solução de problemas de Programação Inteira 0-1, e com o algoritmo SPEA implementado por Teixeira (2002), que utiliza a metaheurística *Algoritmos Genéticos* para a solução do mesmo problema. Em termos de eficácia entre o SPEA e o PSA pode-se afirmar que os dois foram equivalentes para problemas de pequeno porte; a eficiência do PSA, em relação ao SPEA, mostrou-se superior. Para problemas de médio a grande porte o SPEA não foi capaz de resolver provavelmente por falta de memória do sistema, enquanto que o PSA mostrou uma escalabilidade muito boa. Em um ambiente competitivo onde a tomada de decisão deve ser feita com agilidade, o PSA mostrou-se interessante, e apesar de não ser um algoritmo exato, conseguiu uma aproximação de 99,68%, em um tempo menor quando comparado com o CPLEX. Conclui-se pela aplicabilidade e pela eficiência da metaheurística *Simulated Annealing* na solução de problemas de planejamento florestal multiobjetivo e, portanto, pela aplicabilidade do PSA, em particular, como uma boa alternativa para o tratamento destes problemas. Seu desempenho mostrou-se satisfatório e bem superior aos algoritmos evolucionários, em particular o SPEA, sobre o conjunto de problemas-teste, onde vários parâmetros foram definidos por meio de dados reais associados à uma empresa da área florestal.

ABSTRACT

This study has as objective to discuss the *Simulated Annealing's* applicability in the solution of problems of planning forest under multiple objectives. Therefore, an optimization model is proposed under multiple objectives and implemented an algorithm for the solution of the model, PSA (*Pareto Simulated Annealing*), a variation of *Simulated Annealing* simple objective, for the solution heuristic of the model under the vision of multiple objectives. Later on, various tests were deed with the algorithm in problems of several loads to measure its efficiency and its efficacy and compared the results with the CPLEX, a software that uses an exact algorithm for the solution of problems of Programming Integer 0-1, and with the algorithm SPEA implemented by Teixeira (2002), that uses the metaheurística *Genetics Algorithms* for the solution of the same problem. In terms of efficacy between SPEA and PSA can be affirmed that the two were equivalent for problems of small load; the efficiency of PSA, in relation to SPEA, was superior. For problems of medium to great load SPEA was not able to solve probably for loss of memory of the system, while PSA showed a good performance. In a competitive environment where the taking of decision should be made with agility, PSA showed interesting in spite of not being an exact algorithm, it obtained an approximation of 99,68%, in a worthless time when compared with CPLEX. It is concluded by the applicability and for the efficiency of the metaheurística *Simulated Annealing* in the solution of problems of planning forest under multiple objectives and, therefore, for the applicability of PSA, in particular, as a good alternative for the treatment of these problems. Its performance showed satisfactory and very good in relation of the algorithms evolutionary, in particular SPEA, on the problem-test group, where several parameters were defined through of real data associated with a company of the forest area.

LISTA DE FIGURAS

Figura 1 - A probabilidade de aceitação em regras de aceitação multiobjetivo no caso de dois objetivos de maximizar.....	30
Figura 2 - A probabilidade de aceitação em regras de aceitação multiobjetivo no caso de dois objetivos de maximizar.....	32
Figura 3 - Ilustração gráfica da regra C em um caso de dois objetivos de maximizar.....	33
Figura 4 - Ilustração gráfica da regra SL em um caso de dois objetivos de maximizar.....	34
Figura 5 - O Papel dos pesos em regras de aceitação multiobjetivo.....	35
Figura 6 - Vetor contendo as prescrições adotadas para cada UP.....	37
Figura 7 - Diagrama de Classes referente as estruturas do PSA.....	38
Figura 8 - Diagrama de Classes referente as estruturas do Projeto.....	39
Figura 9 - Estratégia de movimento na geração de nova solução vizinha.....	41
Figura 10 : <i>Crossover</i> em de ponto.....	42
Figura 11 - Fronteira Pareto-Ótima construída pelo PSA, <i>B&B</i> e SPEA para o problema 1 com dois objetivos.....	50
Figura 12 - Fronteira Pareto-Ótima construída pelo PSA, <i>B&B</i> e SPEA para o problema 2 com dois objetivos.....	53
Figura 13 - Fronteira Pareto-Ótima construída pelo PSA, <i>B&B</i> e SPEA para o problema 3 com dois objetivos.....	54
Figura 14 - Fronteira Pareto-Ótima construída pelo PSA, <i>B&B</i> e SPEA para o problema 1, 2 e 3 com dois objetivos.....	55
Figura 15 - Tempo de Execução do PSA para os problemas 1, 2 e 3 com dois e três objetivos.....	59
Figura 16 - Tempo de Execução do CPLEX para os problemas 1, 2 e 3 com dois e três objetivos.....	59
Figura 17 - Fronteira Pareto-Ótima construída pelo PSA, <i>B&B</i> e SPEA para o problema 4 com dois objetivos.....	61
Figura 18 - Fronteira Pareto-Ótima construída pelo PSA, <i>B&B</i> e SPEA para o problema 4 e 5 com dois objetivos.....	63

LISTA DE QUADROS

Quadro 1 - Descrição dos povoamentos em termos de área e idade atual	21
Quadro 2 - Valores e volumes para a floresta, assumindo que todas as áreas possuem a mesma classe de produtividade.....	21
Quadro 3 - Prescrições viáveis de manejo para um horizonte de planejamento de 8 anos.....	22
Quadro 4 - Prescrições viáveis de manejo para um horizonte de planejamento de 8 anos geradas pelo protótipo	23
Quadro 5 – Volumes de produção para as diferentes idades da floresta.....	43
Quadro 6 – Custos médios das atividades principais.....	44
Quadro 7 – Demandas (D) anuais mínimas (m ³), e áreas de reforma (A) máxima (ha), previstas para os problemas	45
Quadro 8- Demandas anuais mínimas previstas para os problemas 7, 8 e 9.....	46
Quadro 9 – Objetivos considerados em cada um dos problemas propostos.....	46
Quadro 10 – Problemas-teste utilizados para as demonstrações propostas.....	47
Quadro 11 – Parâmetros de entrada utilizados pelo PSA e SPEA.....	47
Quadro 12 - Eficácia do PSA e SPEA em relação ao algoritmo exato <i>B&B</i> implementado no CPLEX para o problema 1	51
Quadro 13 - Eficiência do PSA em relação ao SPEA para o problema 1	51
Quadro 14 - Eficácia do PSA e SPEA em relação ao algoritmo exato <i>B&B</i> implementado no CPLEX para o problema 2	52
Quadro 15- Eficiência do PSA em relação ao SPEA para o problema 2	52
Quadro 16 - Eficácia do PSA e SPEA em relação ao algoritmo exato <i>B&B</i> implementado no CPLEX para o problema 3	52
Quadro 17- Eficiência do PSA em relação ao SPEA para o problema 3	52
Quadro 18 - Eficácia do PSA em relação ao CPLEX para o problema 1 com três objetivos.....	57
Quadro 19 - Tempo do PSA e CPLEX para o problema 1 com três objetivos	57
Quadro 20 - Eficácia do PSA em relação ao CPLEX para o problema 2 com três objetivos.....	58
Quadro 21 - Tempo do PSA e CPLEX para o problema 2 com três objetivos	58
Quadro 22 - Eficácia do PSA em relação ao CPLEX para o problema 3 com três objetivos.....	58
Quadro 23- Tempo do PSA e CPLEX para o problema 3 com três objetivos	58
Quadro 24- Eficácia do PSA e SPEA em relação ao CPLEX para o problema 4	60
Quadro 25- Eficiência do PSA em relação ao SPEA para o problema 4	60
Quadro 26- Eficácia do PSA em relação ao CPLEX para o problema 5	62
Quadro 27- Tempo do PSA em relação ao CPLEX para o problema 5	62
Quadro 28- Tempo do PSA em relação ao CPLEX para o problema 6 e 7	67
Quadro 29- Tempo do PSA em relação ao CPLEX para o problema 8 e 9	67
Quadro 30- Eficácia do PSA em relação ao CPLEX para o problema 6, 7, 8 e 9	67
Quadro 31 - Dados relativos às unidades de produção, com suas respectivas áreas e idade.....	73
Quadro 32- Exemplo de algumas prescrições geradas para os problema 1, 2 e 3.	75

SUMÁRIO

1.	INTRODUÇÃO	1
1.1.	O problema e sua importância	1
1.2.	Objetivos	3
1.3.	Organização do texto.....	4
2.	REVISÃO DE LITERATURA	5
2.1.	Otimização multiobjetivo	5
2.2.	<i>Simulated Annealing</i>	9
2.3.	Planejamento de áreas florestais.....	12
3.	MATERIAIS E MÉTODOS	20
3.1.	Unidades de produção	20
3.2.	O gerador de prescrições.....	20
3.3.	O modelo utilizado	24
3.4.	O algoritmo <i>Simulated Annealing</i> multiobjetivo.....	29
3.5.	<i>Pareto Simulated Annealing</i>	31
3.5.1.	Regras de aceitação com objetivos múltiplos.....	32
3.5.2.	Administrando a população de soluções geradas	34
3.5.3.	Atualização do conjunto de soluções potencialmente Pareto-ótimas 36	
3.5.4.	Implementação do algoritmo	36
3.5.5.	O procedimento híbrido	42
3.6.	Problemas-teste.....	43
3.7.	Medidas de desempenho do PSA	47
4.	RESULTADOS E DISCUSSÃO	49
4.1.	Resultados para os problemas 1, 2 e 3 com dois objetivos.....	49
4.2.	Resultados para os problemas 1, 2 e 3 com três objetivos.....	56
4.3.	Resultados para os problemas 4 e 5	60
4.4.	Resultados para os problemas 6, 7, 8 e 9	64
5.	CONCLUSÕES.....	66
6.	REFERÊNCIAS BIBLIOGRÁFICAS	68
	Anexos.....	73

1. INTRODUÇÃO

1.1. O problema e sua importância

Muitos problemas do mundo real envolvem múltiplas medidas de performance, ou objetivos, as quais deveriam ser otimizadas simultaneamente (Fonseca e Fleming, 1995; Zitzler e Thiele, 1998).

Para Zitzler (1999) tais problemas envolvem dois tipos de dificuldades: 1) objetivos múltiplos e conflitantes; 2) um espaço de busca altamente complexo.

De acordo com Coello (1999), a otimização multiobjetivo (também chamada otimização multicritério, multiperformance ou otimização de vetor) pode ser definida, segundo Osyczka (1985), 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”.

Segundo Van Veldhuizen e Lamont (2000), os problemas de otimização com um único objetivo podem ter uma única solução ótima. Problemas de otimização multiobjetivo (POM's) podem ter um conjunto incontável de soluções, que, quando avaliadas, produzem vetores cujos componentes representam soluções eficientes que dão origem aos *trade-offs* no espaço de solução. Um tomador de decisão (TD) então escolhe uma dessas soluções.

Para Zitzler e Thiele (1998), essas soluções são ótimas no sentido de que nenhuma outra solução no espaço de busca é superior a elas, quando todos os objetivos são considerados. Elas são conhecidas como soluções Pareto-ótimas.

Soluções Pareto-ótimas são também conhecidas como não-inferiores, admissíveis, ou soluções eficientes (Horn, 1997), e seus correspondentes vetores são chamados de não-dominados. Quando plotados no espaço objetivo, os vetores não-dominados são conhecidos como fronteira de Pareto e o conjunto Pareto-ótimo é um subconjunto de todas as possíveis soluções no espaço de solução. O TD está frequentemente, selecionando soluções através da escolha de objetivos aceitáveis, representados pela fronteira de Pareto. Ao se escolher uma solução do POM que otimize somente um objetivo pode-se estar ignorando soluções que, de um ponto de vista global, seriam melhores. O conjunto Pareto-ótimo contém essas melhores

soluções. Identificar o conjunto de soluções Pareto-ótimo é a chave para a escolha, pelo TD, de uma solução de compromisso satisfazendo os objetivos o melhor possível (Van Veldhuizen e Lamont, 2000).

Na ausência de preferências de informação, nenhum dos correspondentes *trade-offs* pode ser dito ser melhor que outro. Por outro lado, o espaço de busca pode ser muito grande e complexo para ser resolvido por métodos exatos. Assim, eficientes estratégias de otimização são requeridas, as quais são capazes de lidar com ambas as dificuldades (Zitzler, 1999).

Solução de problemas multiobjetivo na área científica e de engenharia são, 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.

Geralmente, os métodos para soluções de problemas de otimização multiobjetivo vão de agregação em uma única função objetivo linear até técnicas baseadas em Pareto (Van Veldhuizen e Lamont, 2000).

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.

Neste contexto, Silva (2001), destaca o uso da PL para a solução de problemas de manejo florestal com algumas limitações. Dentre essas, cabe citar a não-integralidade das soluções, levando a uma indesejada subdivisão das unidades de manejo, o que causa uma série de problemas de ordem operacional. A natureza aleatória de muitos elementos do modelo de PL, como variáveis econômicas e coeficientes tecnológicos, levam a um maior risco na tomada de decisão. Além disso os modelos de PL contemplam apenas uma única função objetivo, quando muitas vezes em uma empresa se tem vários objetivos.

Diante do exposto acima 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.

Existem muitas técnicas heurísticas disponíveis para solução de problemas combinatoriais, indo desde heurísticas menos convencionais até as chamadas

metaheurísticas. Uma metaheurística muito estudada atualmente tem sido *Simulated Annealing* (SA) que, junto com *Algoritmos Genéticos* (AG), podem constituir um método híbrido bastante poderoso no tratamento desse tipo de problema de otimização (Ignacio et al., 2000).

A SA pode ser utilizada na solução de uma variedade de difíceis problemas de otimização combinatória (Ignacio et al., 2000; Baskent e Jordan, 2002). Muitos problemas de otimização florestal são de natureza combinatória e, portanto, candidatos naturais à solução por esta técnica. Achar o plano de manejo ótimo dentre milhares de intervenções silviculturais, dentro de um horizonte de planejamento longo, em problemas de planejamento florestal, é um exemplo (Baskent e Jordan, 2002).

Alguns exemplos incluem problemas com restrições de singularidade, adjacência, roteamento de veículos no transporte florestal, corte na indústria de móveis e de papel, dentre outros. Existem, contudo, poucos trabalhos reportando a utilização dessa técnica na solução desses problemas (Rodrigues, 2001).

Diversos estudos têm sido desenvolvido aplicando a metaheurística SA na solução de problemas de planejamento florestal uniobjetivo. O presente trabalho pretende aplicar a metaheurística SA em Problemas de Otimização Multiobjetivo (POM) e, em particular, em problemas de planejamento florestal. Para isto será necessário a utilização de métodos heurísticos híbridos envolvendo SA e AG. As características relevantes dos AG's serão na formação das soluções não dominadas denominada Fronteira de Pareto.

1.2. Objetivos

Com base no exposto, este trabalho tem como objetivo geral analisar a metaheurística SA, que se apresenta como uma ferramenta capaz de contribuir na busca de solução para problemas de planejamento florestal com múltiplos objetivos.

Como objetivos específicos, citam-se:

- Apresentar e implementar uma metodologia de otimização sob múltiplos objetivos, como uma alternativa viável e interessante para solução de problemas de tomada de decisão na empresa florestal.

- Analisar a aplicação dessa metodologia, metaheurística SA, 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.
- Fazer uma análise comparativa com resultados obtidos por um algoritmo exato e por uma metaheurística alternativa.

1.3. Organização do texto

Esta dissertação está organizada da seguinte forma.

A Seção 1 mostra a importância do planejamento florestal e da utilização de procedimentos heurísticos na busca de solução para os problemas nessa área.

A Seção 2 descreve o conceito de otimização multiobjetivo, a metaheurística *Simulated Annealing* e o problema de planejamento do manejo florestal, de acordo com diversos conceitos apresentados na literatura.

A Seção 3 descreve o gerador de prescrições, o modelo a ser utilizado para o problema de planejamento florestal, o algoritmo *Simulated Annealing* multiobjetivo implementado, os problemas testes utilizados para mostrar a potencialidade de aplicação de *Simulated Annealing* na solução de problemas de planejamento florestal multiobjetivo e as medidas de desempenho utilizadas para medir a qualidade do algoritmo.

A Seção 4 faz uma análise comparativa das soluções obtidas pelo algoritmo proposto, pelo software comercial CPLEX 7.0 e o SPEA proposto por Zitzler (1999) e implementado por Teixeira (2002). Algumas considerações são feitas sobre estas análises.

Finalmente, a Seção 5 apresenta algumas conclusões sob o que foi realizado e sugestões para trabalhos futuros.

2. REVISÃO DE LITERATURA

2.1. Otimização multiobjetivo

Quase todos os problemas do mundo real envolvem otimização simultânea sobre objetivos múltiplos e conflitantes (Fonseca e Fleming, 1995; Zitzler e Thiele, 1998; Coello, 1999; Van Veldhuizen e Lamont, 2000; Coello, 2001; Zitzler, 2002).

Otimização multiobjetivo, é sem dúvida, um importante tópico de pesquisa para cientistas e engenheiros, não somente por causa da natureza multiobjetiva da maioria dos problemas do mundo real, mas, também, porque ainda existem muitas questões em aberto nesta área (Coello 1999; Zitzler, 1999).

De acordo com Bleuler et al. (2003), os problemas de otimização complexos podem ser achados em muitas áreas de aplicação. Um aspecto que contribui para a complexidade desses problemas compreende as características do espaço de busca; algoritmos exatos são, freqüentemente, não aplicáveis. Múltiplos objetivos formam outro tipo de dificuldades que métodos de otimização clássicos não foram projetados para tal. Assim, técnicas alternativas têm sido desenvolvidas ao longo do tempo como, por exemplo: *Algoritmos Evolucionários*, *Busca Tabu (BT)* e *Simulated Annealing*.

Segundo Coello (1999; 2001; 2002), a otimização multiobjetivo pode ser definida como otimização multicritério, multiperformance ou otimização de vetor, podendo ser definida como o problema de achar um vetor de variáveis de decisão cujos elementos representam as funções objetivos. Essas funções formam uma descrição matemática do critério de performance que estão em conflito umas com as outras. Aqui, o termo “otimizar” significa achar uma solução que daria os valores aceitáveis de todas as funções para o projetista. Formalmente podemos definir:

Achar o vetor $x^* = [x_1^*, x_2^*, \dots, x_n^*]^T$ que irá satisfazer as:

m inequações restrições: $g_i(x) \geq 0 \quad i = 1, 2, \dots, m;$

p equações restrições: $h_i(x) = 0 \quad i = 1, 2, \dots, p;$

e otimizar o vetor de funções: $f(x) = [f_1(x), f_2(x), \dots, f_k(x)]^T$

onde $x = [x_1, x_2, \dots, x_n]^T$ é o vetor de variáveis de decisão.

Enquanto que na otimização de objetivo único uma solução ótima é claramente identificada, para POM's isto não pode ser assegurado. Ao invés de uma

simples solução ótima, POM's apresentam um conjunto de alternativas, geralmente conhecidas como soluções Pareto-ótimas, que, para (Fonseca e Fleming, 1995), podem ser classificadas como soluções eficientes, ou conjunto admissível do problema; os correspondentes vetores objetivos, quando plotados no espaço dos objetivos, formam a fronteira de Pareto-ótimo ou conjunto não-dominado (Zitzler, 1999; Veldhuizen e Lamont, 2000; Coello, 2002); neste sentido, as soluções não podem ser identificadas como melhor que as outras, a menos que informações de preferência sejam incluídas.

Veldhuizen e Lamont (2000), citando Back (1996), afirma que achar o ótimo global de um POM é 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.

O conceito de Pareto-ótimo foi formulado por Vilfredo Pareto no século XIX e 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). 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 chamados de não-dominados (Coello, 1999; Coello, 2002; Van Veldhuizen e Lamont, 2000).

Coello (2002), diz que um vetor de variáveis de decisão $x^* \in F$ é Pareto-ótimo se não há nenhum outro vetor $x \in F$, tal que $f_i(x) \leq f_i(x^*)$ para todo $i = 1, 2, \dots, k$ e $f_j(x) < f_j(x^*)$ para ao menos um j .

Segundo Fonseca e Fleming (1995), a otimização simultânea de múltiplas e competitivas funções objetivas diverge da otimização de funções de um único objetivo, pelo fato de raramente admitir uma simples solução. Ao invés disto, POM's tendem a ser caracterizados por uma família de soluções alternativas que devem ser considerados equivalentes, na ausência de informação concernente à relevância de cada objetivo relativo ao outro.

À medida que aumenta o número de objetivos que competem entre si e, também, forem considerados objetivos menos “bem comportados”, o problema de buscar uma solução de compromisso satisfatória torna-se complexo de forma rápida e progressiva.

Em certos casos, as funções objetivos poderiam ser otimizadas separadamente uma da outra e um ganho de performance poderia ser percebido com relação ao ótimo que poderia ser alcançado para cada objetivo. Entretanto soluções satisfatórias para o problema global raramente poderiam ser achadas neste sentido. Desempenho ótimo em um objetivo, se tal ótimo existe, freqüentemente implica desempenho inaceitável em um ou mais dos outros objetivos, criando a necessidade de se alcançar um compromisso.

Técnicas de otimização convencional, como as baseadas no Gradiente e no Simplex, e mesmo as menos convencionais, como *Simulated Annealing*, são difíceis de serem estendidas para o caso multiobjetivo. Na prática, problemas multiobjetivos devem ser reformulados como problemas de um único objetivo antes da otimização, guiando para obter uma única solução por rodada do otimizador (Fonseca e Fleming, 1995).

Na solução de POM's, dois tipos de problemas conceitualmente distintos podem ser identificados (Horn, 1997): busca e tomada de decisão. O primeiro refere-se ao processo de otimização no qual o conjunto viável é representado por soluções Pareto-ótimas. Como acontece com a otimização de um único objetivo, espaços de busca grandes e complexos podem tornar a busca difícil, inviabilizando o uso de métodos exatos de otimização como o *Simplex* para Programação Linear (Steuer, 1986). O segundo aspecto enfoca o problema de selecionar uma solução de compromisso no conjunto Pareto-ótimo. Um tomador de decisão (TD) humano é necessário para fazer a escolha, às vezes difícil, entre objetivos conflitantes (Zitzler, 1999).

Dependendo de como a otimização e o processo de decisão são combinados, os métodos de otimização multiobjetivo podem ser amplamente classificados dentro de três categorias (Zitzler, 1999; Van Veldhuizen e Lamont, 2000; Fonseca, 1995).

- Tomada de decisão antes da busca: Os objetivos do POM são agregados dentro de um único objetivo, ao qual implicitamente incluem-se informações de preferência dadas pelo TD.
- Busca antes da tomada de decisão: A otimização é executada sem nenhuma informação de preferência dada. O resultado do processo de busca é um conjunto de soluções candidatas (idealmente Pareto-ótimo), sendo a escolha final feita pelo TD.
- Tomada de decisão durante a busca: O TD pode articular preferências durante o processo de otimização, de forma interativa. Antes de cada passo da otimização, um número de *trade-offs* é apresentado e o TD especifica informações de preferências adicionais, guiando assim a busca.

A agregação de objetivos múltiplos em um único critério de otimização tem as vantagens das estratégias de otimização clássicas com objetivo único, podendo ser aplicada sem modificações adicionais. Porém, requer um profundo conhecimento do domínio, o qual normalmente não está disponível. Executar a busca antes da tomada de decisão supera esta desvantagem, mas exclui articulações de preferências do TD que poderiam reduzir a complexidade do espaço de busca (Zitzler, 1999).

Para Fonseca (1995) a tomada de decisão antes da busca têm a vantagem de não requerer interação adicional com o TD. Por isso, esforços de computação podem ser concentrados na produção da solução final. Porém, se a solução achada não pode ser aceita como uma solução satisfatória, devido ao fato de a função usada excluir aspectos do problema que não foram conhecidos antes da otimização ou para uma colocação imprópria dos coeficientes da função combinada, novas execuções do otimizador podem ser necessárias e as funções de custo modificadas, até que uma solução satisfatória seja encontrada. Este método tem a desvantagem de requerer novas execuções do otimizador sempre que haja mudança nas preferências do TD (Fonseca e Fleming, 1995).

Busca antes da tomada de decisão tem a desvantagem de aumentar o tempo de computação. Sua vantagem é que nenhum conhecimento do domínio do problema seja assumido. Este método é especialmente bem apropriado a problemas que envolvem objetivos estáticos, mas onde as preferências do TD mudem com relativa frequência.

Em tais casos, mudanças de preferência não implica em nenhuma computação adicional.

De acordo com Esquivel et al. (1999), o conhecimento da fronteira de Pareto é de máxima importância quando a busca é aplicada antes da tomada de decisão. Essas informações dão ao TD conhecimento dos *trade-offs* para estabelecer interações entre os diferentes critérios, desde que simplifique o processo de decisão para escolher um conjunto aceitável de soluções para um problema multicritério.

Tomada de decisão durante a busca estabelece um compromisso entre estas duas classes de métodos, mas agora às custas de interação aumentada entre o TD e o otimizador. Especialmente no caso de um TD humano, a necessidade para intervenção humana constante pode ser de fato uma desvantagem.

2.2. *Simulated Annealing*

De acordo com Youssef et al. (2001), citado por Rodrigues (2001), SA foi derivada de processos de recozimento sólidos (Metropolis et al., 1953). A analogia com a otimização combinatória foi introduzida por Kirkpatrick et al. (1983) e aperfeiçoada por Cerny (1985). O termo *Annealing* refere-se a um processo térmico que começa pela liquefação de um cristal, a uma alta temperatura, seguido pela lenta e gradativa diminuição de sua temperatura, até que o ponto de solidificação seja atingido, quando o sistema atinge um estado de energia mínima (Ignacio et al., 2000).

SA procura encontrar uma solução ótima para problemas de otimização combinatória explorando novas áreas no espaço de soluções do problema, interativamente. De acordo com (Baskent e Jordan, 2002), a performance desta técnica é medida por sua habilidade de explorar essas áreas em um pequeno espaço de tempo e pouco esforço.

Rodrigues (2001) citando Ignacio et al. (2000), afirma que a metaheurística SA é basicamente um algoritmo de busca local, sendo que a escolha de um novo elemento na vizinhança é realizada de forma semi-aleatória. Os algoritmos de busca local apresentam o inconveniente de estacionar num ótimo local. A metaheurística SA evita este problema, utilizando uma probabilidade de aceitação de uma solução que

piora a solução corrente, o que implica na possibilidade de se escapar de um ótimo local. Esta probabilidade vai diminuindo, à medida que se aproxima da solução ótima.

Segundo Ignacio et al. (2000), citado por Rodrigues (2001), uma das vantagens da SA é o fato de que, em cada iteração, uma única solução é visitada, ao contrário de muitas técnicas heurísticas como os AG's e a BT, onde várias soluções são visitadas em cada iteração. Desta forma, processamentos como cálculo da função objetivo e outros processamentos necessários para avaliar as soluções pesquisadas não degradam muito a eficiência do algoritmo. Uma das desvantagens da SA é o fato de a heurística utilizar poucas informações do problema. De modo geral, a SA utiliza somente a variação do valor da função objetivo nas avaliações dos movimentos, o que a torna pouco “inteligente” (não se consideram outros aspectos característicos do problema na pesquisa do espaço de soluções).

À medida que novas soluções são encontradas, elas podem ser aceitas ou não. Soluções que melhoram o valor da função objetivo são sempre aceitas e soluções que pioram o valor da função objetivo são condicionalmente aceitas, dependendo do critério de Metropolis.

O critério de *Metropolis* (Metropolis et al., 1953), conforme exposto por Baskent e Jordan (2002), é baseado na seguinte função de probabilidade:

$$P(E) = \exp^{-(E_2 - E_1) / ck}$$

em que:

$P(E)$ = probabilidade (entre 0 e 1) de uma solução inferior ser aceita.

c = é o parâmetro de controle.

k = é a constante de Boltzman.

E_1 = é o valor da melhor solução da função objetivo encontrada até o momento.

E_2 = é o novo valor da função objetivo encontrado.

A probabilidade $P(E)$ é calculada e comparada com um número (r) aleatório e contínuo, uniformemente distribuído entre 0 e 1. A nova solução será aceita se $P(E) > r$, caso contrário, ignorada. O parâmetro de controle c é a temperatura que se inicia com um valor alto e é gradativamente reduzida, no final do processo c é reduzida para um ponto onde somente as melhores soluções são aceitas. O algoritmo pára quando um valor para o parâmetro c seja satisfeito ou quando a função objetivo é atendida.

O Algoritmo básico da metaheurística SA é apresentado a seguir, onde x é a solução inicial e T_0 é a temperatura inicial (Ignacio et al., 2000).

Algoritmo *Simulated Annealing* (x, x', T);

(x é uma solução qualquer);

(x' é a solução vizinha de x);

(T é a temperatura);

Início

Enquanto temperatura (T) elevada **faça**

Gera x' de x ;

Avaliar a variação de energia; (diferença entre o valor da função objetivo encontrado e o melhor valor da solução encontrado até o momento);

$$\Delta E = f(x') - f(x)$$

Se $\Delta E > 0$ então $x \leftarrow x'$

Caso contrário

Gerar $r \in \text{Unif}[0,1]$

Se $r < z = e^{-(f(x')-f(x)/kT)}$

Então $x \leftarrow x'$

Reduzir a temperatura T

Testar critério de parada

Fim

A temperatura T é considerada como um parâmetro de controle da mobilidade do sistema, ou seja, traduz a flexibilidade de aceitar novas soluções ou não. Cabe assinalar que, quanto menor a temperatura T , menor será a probabilidade de aceitar soluções que piorem a função objetivo, o que se traduz em rejeitar cada vez mais aquele tipo de soluções. Quando T é maior, a probabilidade fica próxima de um.

Não existem regras gerais para definir a redução da temperatura. Ao se considerar temperaturas altas como temperatura inicial, a qualidade da solução da SA não dependerá da solução inicial e permitirá o percurso de um espaço de soluções mais amplo. No entanto, é conveniente considerar uma temperatura inicial, dependente do problema. A velocidade de redução da temperatura irá implicar no número de soluções a serem visitadas. Se o processo de redução for lento implicará

em tempos de processamento muito grandes, caso contrário pode-se acelerar o processo de redução diminuindo-se assim o tempo de processamento, implicando em menos soluções a serem visitadas podendo não percorrer todo o espaço de soluções possíveis.

Apesar de já existirem alguns estudos utilizando a metaheurística SA para resolver alguns problemas de planejamento florestal, existem ainda algumas questões a serem elucidadas para melhoria e consolidação dessa técnica na solução de muitos problemas. Tais melhorias podem incluir, por exemplo, novas estratégias de movimentos para melhorar a performance do método em problemas maiores, estudos adicionais sobre o efeito dos diversos parâmetros na performance da heurística, critérios de parada mais informados, dentre outros. Existem poucos trabalhos desenvolvidos, especialmente no Brasil, o que justifica novos estudos, para disseminação desta técnica no meio florestal brasileiro (Rodrigues, 2001).

Rodrigues (2001), desenvolveu, testou e comparou a eficácia e eficiência desta técnica com duas outras metaheurísticas (*AG's* e *BT's*), na solução de problemas de planejamento florestal com restrições de inteireza. Outros trabalhos envolvendo a aplicação de SA em problemas de planejamento florestal são os de (Boston e Bettinger, 1999).

2.3. Planejamento de áreas florestais

Diversos setores da economia brasileira estão ligados diretamente ao setor florestal. Dentre os setores de expressão nacional que utilizam a madeira como matéria prima estão o siderúrgico, o de papel e celulose e o de chapas e moveleiro.

O planejamento rigoroso e bem estruturado é uma atividade de importância fundamental para a obtenção de bons resultados em empreendimentos econômicos. Através da elaboração consciente e bem formalizada do conjunto de metas que se pretende atingir, e das técnicas e recursos disponíveis para se chegar até elas, é possível prever com maior precisão os resultados de qualquer estratégia de ação, bem como detectar e corrigir possíveis falhas durante sua execução (Fatureto, 1997). Neste contexto, a gestão florestal preocupa-se com o processo de tomada de decisões relativas à organização, ao uso e à conservação de recursos florestais. Tais decisões

podem ser de longo prazo ou de curto prazo, e resultam em recomendações denominados planos de manejo florestal (Nobre, 1999).

Em manejo florestal, os cursos alternativos de ação referem-se às alternativas de manejo do problema. Uma alternativa de manejo 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 variedades a serem utilizadas. As diferentes combinações de ocorrência dessas decisões ao longo do horizonte e a interdependência das decisões criam uma infinidade de alternativas de manejo. O número 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. A elaboração de planos de manejo florestal requer a avaliação econômica de alternativas de manejo (Rodrigues, 2001).

Segundo 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 silviculturais para cada unidade de manejo na floresta. Dentre essas, e para cada unidade, o gestor deve escolher a 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 integridade sobre as unidades de manejo.

Rezende e Oliveira (1993), citado por Silva (2001), conceitua 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, 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. Por outro lado, para horizontes curtos, corre-se o risco de não se levarem em conta acontecimentos importantes que podem ocorrer após o período adotado para planejamento. O horizonte de planejamento infinito não quer dizer que os projetos devam durar para sempre, mas que as alternativas possam ser comparadas numa base justa de tempo.

Segundo Scolforo (1997), citado por Nobre (1999), 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. O gestor florestal gerencia uma grande gama de informações, necessárias para a análise e seleção do melhor plano de manejo possível, que por sua vez é selecionado dentre as alternativas de produção disponíveis.

Ainda segundo Nobre (1999), citando Paivinen (1996), a tarefa do gerente florestal é descrever o potencial de produção de uma floresta, determinando quando, onde e quais produtos e serviços serão produzidos para as diversas unidades florestais.

Rodriguez et al. (1996), conceitua gestão florestal como sendo o estudo, o desenvolvimento e a aplicação de técnicas que ajudam a justificar a escolha de um determinado plano de manejo. O plano de manejo, nesse contexto, define a condução da floresta e envolve conhecimentos silviculturais relativos à escolha de espécies, espaçamentos, manutenções, desbastes e podas (Scolforo, 1997), assim como o domínio de técnicas matemáticas e estatísticas de modelagem do crescimento da floresta e do problema de definição do momento ideal de corte (Nobre, 1999).

Nobre (1999) caracteriza as unidades de produção pela uniformidade em termos de produtividade e pela homogeneidade da idade e material genético de que são compostas. Um conjunto de unidades de produção constitui o projeto florestal para o qual se pretende definir uma programação de atividades que atenda ao objetivo global do projeto. O planejamento otimizado gerencial considera que existem planos (ou regimes) de manejo opcionais para cada unidade de produção florestal.

Existem centenas de regimes de manejo alternativos para cada uma das unidades de produção. Os regimes de manejo disponíveis em cada unidade de

produção são avaliados e a escolha do melhor regime em cada unidade de produção baseia-se nos objetivos e restrições impostas ao projeto.

Para Silva (2001), o grande número de variáveis relacionadas a um processo de planejamento, em especial o florestal, requer grande habilidade e experiência do gerente florestal.

Diversos fatores alheios ao controle do produtor podem interferir nas atividades agrícolas, operando como variáveis que dificultam a elaboração e implementação de qualquer plano de trabalho. Estes fatores incluem as incertezas associadas à instabilidade das políticas econômicas e agrícolas, as variações nos preços de mercado e as alterações climáticas, (Fatureto, 1997).

De acordo com Nobre (1999), os fatores nos quais as empresas florestais estão inseridas, influenciam a demanda de produtos com origem florestal e possuem a característica comum de não estarem conectados com a realidade de crescimento biológico das florestas sobre as quais o gestor florestal toma decisões. Em outras palavras, o gerente florestal está pressionado entre duas realidades muito diferentes: de um lado, um comportamento das florestas sujeito a fatores biológicos, climáticos, cujas intervenções têm conseqüências a longo prazo e, de outro lado, uma segunda realidade globalizada, rápida e dinâmica, que exige decisões de curto prazo.

Atualmente, as pressões de mercados cada vez mais globalizados exigem que as empresas se tornem mais e mais competitivas, devendo produzir produtos de alta qualidade a custos os menores possíveis (Silva, 2001).

A obtenção de informações com qualidade e rapidez é fundamental para o sucesso das tomadas de decisão em manejo florestal, sendo dependente do uso de métodos e técnicas da ciência gerencial, que permitem avaliar situações alternativas, analisar os resultados e reduzir riscos e incertezas na tomada de decisão. A utilização dessas técnicas propicia melhora na alocação de recursos produtivos, aumentando a rentabilidade econômica das empresas (Silva Jr, 1993).

Silva (2001), citando 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.

Muitos estudos têm sido feitos tratando de etapas importantes do planejamento, como o objetivo de tornar o produto florestal mais competitivo. Dentre estes, cabe citar esforços no desenvolvimento de modelos de crescimento e produção, avaliação econômica de projetos florestais e uso de técnicas de Pesquisa Operacional, principalmente Programação Linear, Programação Dinâmica e Simulação (Silva, 2001; Rodrigues, 2001). Esforços na área de modelagem do crescimento e da produção têm objetivado fornecer informações as mais detalhadas e precisas possíveis, de modo que o manejador possa fazer projeções seguras a respeito das possibilidades de retorno da floresta (Silva, 2001).

As técnicas de Programação Linear (PL) constituem um instrumental analítico bastante utilizado no processo de tomada de decisão no planejamento florestal. Entretanto, apesar da inegável contribuição das técnicas de PL para a solução desses problemas, deve-se reconhecer que essa metodologia apresenta algumas limitações: trabalha-se com apenas uma função-objetivo e assume-se que as restrições devem ser rigorosamente respeitadas. Na realidade, muitas vezes, os produtores estão interessados não apenas em otimizar um único objetivo, mas sim, em alcançar uma solução ótima que consiga satisfazer um grupo de objetivos, que podem apresentar natureza conflitante (Fatureto, 1997); Silva, 2001a).

Rodrigues (2001) afirma que os modelos de PL, até então tidos como adequados para solução dos problemas do setor, passaram a ser questionados em função de suas limitações no tratamento de problemas envolvendo múltiplos objetivos. Assim, modelos mais adequados para tratamentos desses problemas como a Programação com Múltiplos Objetivos (PMO), ganharam a atenção dos manejadores.

Oliveira (2003) afirma que problemas envolvendo múltiplos objetivos podem ser resolvidos usando programação linear, onde um dos objetivos, o mais importante, é otimizado e os outros são considerados como restrição. Estes procedimentos geram algumas desvantagens como:

- a) A representação dos objetivos através de restrições em PL geralmente resultam em problemas inviáveis. Em problemas de grande porte é difícil encontrar restrições que gerem soluções viáveis.
- b) A escolha de qual dos objetivos deve ser otimizado é muitas vezes, difícil ou subjetivo.

Neste contexto, Newman (1988) fez algumas ressalvas, enfocando que a PL tem encontrado muitas resistências como instrumento no auxílio ao planejamento florestal pelas seguintes razões:

- a) Problemas reais em geral não são bem definidos.
- b) Pode existir uma quantidade insuficiente de dados ou a qualidade destes é baixa.
- c) A PL é um método determinístico, quando a maioria dos problemas de planejamento florestal são estocásticos.
- d) A não inteireza das soluções, quando muitas situações em planejamento florestal a almeja.
- e) Existência de uma única função objetivo.

Essa última ressalva é a que mais tem sido criticada, dada a sua pouca correlação com muitos problemas reais. Em função dessa limitação imposta pelo modelo clássico de PL, diversas outras extensões de seus modelos foram introduzidas para contemplar a nova realidade. A Programação com Múltiplos Objetivos (PMO) é uma dessas extensões. Desenvolvida para o planejamento de uso múltiplo, foi primeiramente introduzida em uma variedade de problemas florestais. A PMO é útil na solução de problemas de planejamento, em que vários objetivos conflitantes devem ser otimizados de modo simultâneo.

Assim, por exemplo, uma empresa pode estar interessada em manter os lucros estáveis, aumentar sua fatia de mercado, diversificar produtos, melhorar a qualidade de vida dos trabalhadores e aumentar o prestígio da companhia. Por outro lado, um empreendedor florestal se depara com o desafio de aumentar sua produtividade, minimizar as perdas do solo e incrementar os benefícios sociais gerados para a comunidade local.

Nesses casos, nota-se uma necessidade de se satisfazer vários objetivos simultaneamente e, ainda que exista prioridade de alguns, não se poderá desprezar qualquer um deles. Os objetivos também são, na maioria das vezes, competitivos. Tomando-se, por exemplo, problemas que envolvem alocação de recursos, um objetivo tende a restringir o uso desses para outro objetivo.

De acordo com Oliveira (2003), a programação por múltiplos objetivos apresenta uma forma de resolver esses problemas, onde a solução ótima do problema

resolvido por PL é substituída por um conjunto de soluções, não necessariamente ótimas no caso de PL, mas soluções eficientes.

- a) A programação por múltiplos objetivos tem grande aplicabilidade em áreas de recursos naturais, devido às situações do uso múltiplo que implicam freqüentemente em objetivos múltiplos.
- b) As técnicas de programação por objetivos múltiplos são usadas quando há situações onde as decisões devem ser tomadas em um ambiente de objetivos conflitantes.
- c) Muitas das decisões tomadas em problemas florestais envolvem múltiplos objetivos (econômicos, sociais, ambientais, etc...).
- d) A globalização da economia e aumento da competição, principalmente no mercado externo, e a necessidade de obter certificação dos produtos florestais requerem que outros objetivos, além do econômico, sejam alcançados.

A Programação por Múltiplos Objetivos (PMO) está preocupada com o planejamento de problemas em que vários objetivos conflitantes devem ser otimizados simultaneamente (Rodrigues, 2001).

Rodrigues (2001) afirma que o uso da PMO tem sido bastante reduzido, em especial no Brasil, devido ao desconhecimento da técnica e de seus possíveis benefícios, por parte de alguns manejadores. Outra razão é a carência de interfaces computacionais para a formulação e solução de problemas envolvendo a utilização destes modelos. Os problemas reais, além de envolver muitos objetivos e restrições, só podem ser formulados e resolvidos com usos de sistemas automatizados. A utilização de PMO eliminou uma das limitações dos modelos de PL ao permitir o tratamento e otimização simultânea de objetivos conflitantes. 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).

A tomada de decisões sob critérios múltiplos significa efetuar decisões de preferência, como, por exemplo, avaliação, priorização e seleção sobre as alternativas

disponíveis, que são caracterizadas por objetivos múltiplos e geralmente conflitantes, sendo assim um processo dinâmico: uma complexa busca por informações, cheia de desvios, enriquecida pelo *feedback* da análise de todas as direções de busca possíveis (Fatureto 1997; Silva 2001a).

A existência de conflitos, aliada à impossibilidade de otimizar simultaneamente todos os objetivos considerados, conduz à idéia de soluções de compromisso, que buscam por um equilíbrio apropriado entre os múltiplos critérios conflitantes. O Tomador de Decisão procura então identificar e aceitar a possibilidade de não atingir uma determinada meta de forma ótima, desde que isto lhe possibilite um alcance maior de algum outro critério. Essa idéia é muitas vezes referida como um *trade-off*, ou seja, a proporção do nível de alcance de um critério que deve ser sacrificada para que se obtenha um aumento no nível de alcance de outro critério (Fatureto, 1997).

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.

Por outro lado, muitos problemas de planejamento florestal são de natureza combinatoria e podem envolver centenas a milhares de variáveis e não podem ser resolvidos eficientemente por tais métodos.

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).

Uma idéia interessante que tem despertado crescente atenção dos pesquisadores refere-se ao desenvolvimento de métodos heurísticos híbridos utilizando as metaheurísticas Busca Tabu, Simulated Annealing e Algoritmo Genético. O objetivo dos modelos híbridos é combinar as técnicas, preservando suas características individuais de ação inteligente, de tal forma que o procedimento resultante seja mais eficaz do que qualquer um dos seus componentes isoladamente (Souza e Moccellin, 2000). Estes autores citam diversos exemplos de aplicações dessas técnicas para problemas da classe planejamento e controle da produção.

3. MATERIAIS E MÉTODOS

3.1. Unidades de produção

As unidades de produção (UP's) ou unidades de manejo (UM's) foram consideradas como sendo os talhões florestais ou compartimentos.

Para cada UP são geradas um conjunto de alternativas de manejo, obtidas combinando-se as idades de cortes, opções de reformas dos povoamentos, desbastes ou condução de brotação e quaisquer outras características que se queira. Cada alternativa é chamada de prescrição. As prescrições representam seqüências preestabelecidas de ações que ocorrerão ao longo do horizonte de planejamento, numa dada unidade de produção.

3.2. O gerador de prescrições

Com vistas a alcançar o objetivo proposto, foi necessário o desenvolvimento de um protótipo de software para que as informações de entrada para o problema pudessem ser cadastradas e, a partir delas, fossem geradas as prescrições e construir os modelos de otimização a serem otimizados. O protótipo foi desenvolvido utilizando-se o ambiente de programação *Borland Delphi 6.0*, que tem como linguagem nativa o *Object Pascal*.

O usuário cadastra os projetos podendo trabalhar 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 de entrada de dados deve-se cadastrar as informações do 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, e
- as demandas anuais mínimas (expressa em m^3) 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.

Como exemplo, suponha uma floresta dividida em 8 talhões (UP's), tendo um horizonte de planejamento de 8 anos, podendo apresentar os seguintes dados:

Quadro 1 - Descrição dos povoamentos em termos de área e idade atual

	Idade Atual	Área (ha)	Custos				
			Implantação (\$/há)	Manut. Básica(\$/ha)	Exploração (\$/há)	Reforma (\$ha)	Cond. Brotação (\$/ha)
1	0	50,00	1.040,12	106,31	10,91	871,27	40,25
2	1	80,00	1.040,12	106,31	10,91	871,27	40,25
3	2	50,00	1.040,12	106,31	10,91	871,27	40,25
4	3	50,00	1.040,12	106,31	10,91	871,27	40,25
5	4	90,00	1.040,12	106,31	10,91	871,27	40,25
6	5	50,00	1.040,12	106,31	10,91	871,27	40,25
7	6	50,00	1.040,12	106,31	10,91	871,27	40,25
8	7	70,00	1.040,12	106,31	10,91	871,27	40,25

No Quadro 2 são apresentadas as informações de inventário florestal e valores comerciais da madeira, utilizados na formulação do problema.

Quadro 2 - Valores e volumes para a floresta, assumindo que todas as áreas possuem a mesma classe de produtividade

Idade (anos)	Produção (m^3 /há)	Valor ($\$/m^3$)
5	179,10	20
6	235,02	20
7	285,37	20
8	300,00	20

As prescrições geradas para este planejamento são apresentadas no Quadro 3.

Quadro 3 - Prescrições viáveis de manejo para um horizonte de planejamento de 8 anos

Presc. Manejo	Idade Atual	Rotações Em anos	Horizonte de Planejamento								Idade Final
			0	1	2	3	4	5	6	7	
X ₁₁	0	5						179,10			3
X ₁₂	0	6							235,02		2
X ₁₃	0	7								285,37	1
X ₂₁	1	5					179,10				4
X ₂₂	1	6						235,02			3
X ₂₃	1	7							285,37		2
X ₂₄	1	8								300,00	1
X ₃₁	2	5				179,10					5
X ₃₂	2	6					235,02				4
X ₃₃	2	7						285,37			3
X ₃₄	2	8							300,00		2
X ₄₁	3	5-5			179,10					179,10	1
X ₄₂	3	6				235,02					5
X ₄₃	3	7					285,37				4
X ₄₄	3	8						300,00			3
X ₅₁	4	5-5		179,10					179,10		2
X ₅₂	4	5-6		179,10						235,02	1
X ₅₃	4	6-5			235,02					179,10	1
X ₅₄	4	7				285,37					5
X ₅₅	4	8					300,00				4
X ₆₁	5	5-5	179,10					179,10			3
X ₆₂	5	5-6	179,10						235,02		2
X ₆₃	5	5-7	179,10							285,37	1
X ₆₄	5	6-5		235,02					179,10		2
X ₆₅	5	6-6		235,02						235,02	1
X ₆₆	5	7-5			285,37					179,10	1
X ₆₇	5	8				300,00					5
X ₇₁	6	6-5	235,02					179,10			3
X ₇₂	6	6-6	235,02						235,02		2
X ₇₃	6	6-7	235,02							285,37	1
X ₇₄	6	7-5		285,37					179,10		2
X ₇₅	6	7-6		285,37						235,02	1
X ₇₆	6	8-5			300,00					179,10	1
X ₈₁	7	7-5	285,37					179,10			3
X ₈₂	7	7-6	285,37						235,02		2
X ₈₃	7	7-7	285,37							285,37	1
X ₈₄	7	8-5		300,00					179,10		2
X ₈₅	7	8-6		300,00						235,02	1

 Corte
 Não Corte

Para a geração das prescrições acima, considerou-se como idades de corte, mínima e máxima, cinco e oito anos, respectivamente.

Vale lembrar que o exemplo aqui apresentado trata-se de uma situação hipotética, sem maiores preocupações com questões de modelagem e com a realidade dos coeficientes técnicos, uma vez que o foco do trabalho dirige-se para questões relativas à programação por múltiplos objetivos.

No segundo módulo foi implementado o algoritmo para a geração das prescrições para as unidades de produção. Este algoritmo lista todas as possíveis combinações de opções de manejos possíveis para as unidades de produção, levando-se em conta o horizonte de planejamento, as idades mínima e máxima de corte e as alternativas de condução dos povoamentos, (reforma, de uma ou duas condução de brotação).

As prescrições geradas pelo protótipo para o exemplo acima são apresentadas no Quadro 4.

Quadro 4 - Prescrições viáveis de manejo para um horizonte de planejamento de 8 anos geradas pelo protótipo

UP	Presc.		Horizonte de Planejamento															VPL	Custo	
			-9	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5			6
1	1	5									x					r			92332.4	202359.6
1	2	6									x						r		148436.8	219851.8
1	3	7									x							r	192627.2	233267.8
2	1	5									x					r			168185.4	357839.9
2	2	6									x						r		268331.7	389063.5
2	3	7									x							r	347211.6	413010.9
2	4	8									x							r	350522.1	410617.6
3	1	5									x					r			100281.5	224616.5
3	2	6									x						r		162136.6	243901.7
3	3	7									x						r		210856.5	258692.7
3	4	8									x							r	212901.2	257214.5
4	1	5 5									x					r			268599.5	339839.7
4	2	6									x						r		166645.7	259694.5
4	3	7									x						r		217801.6	275225.1
4	4	8									x							r	219948.5	273673
5	1	5 5									x					r			501177.1	648769.2
5	2	5 6									x							r	597356.1	678755.9
5	3	6 5									x							r	608907.4	678005.3
5	4	7									x								405169	526651.4
5	5	8									x							r	409226.8	523717.8
6	1	5 5									x							r	202128.9	267432.5
6	2	5 6									x								241402	279677.1

6	3	5 7					x									r					r	272335.3	289068.2
6	4	6 5					x									r					r	246118.8	279370.6
6	5	6 6					x									r					r	283521.7	291032
6	6	7 5					x										r				r	279756.8	287843.6
6	7	8					x											r				164582.5	216369.9
7	1	6 5					x									r					r	255906.3	295857.5
7	2	6 6					x									r					r	295179.4	308102.1
7	3	6 7					x									r					r	326112.7	317493.2
7	4	7 5					x									r					r	291226.2	304753.12
7	5	7 6					x									r					r	328629.14	316414.6
7	6	8 5					x										r				r	287124.4	299981.6
8	1	7 5					x									r					r	519889.9	552872.9
8	2	7 6					x									r					r	587215.2	573863.6
8	3	7 7					x									r					r	640243.6	589962.7
8	4	8 5					x									r					r	512506.6	544284.2
8	5	8 6					x									r					r	576626	564275.3

O gerador de prescrições utiliza uma estrutura matricial onde, para as colunas, tem-se a linha do tempo, (período de plantio da unidade de produção, passando pela época atual até o último período do horizonte de planejamento almejado), e para cada linha, uma prescrição. Cada célula pode assumir um dos seguintes estados de acordo com as atividades:

- vazio quando houver apenas atividade de manutenção;
- “x” implantação da floresta;
- “r” corte seguida de imediata regeneração via plantio;
- “c” corte seguida de imediata regeneração via condução de brotação;

As operações de corte ocorrem uma vez a cada ano, no início do ano.

3.3. O modelo utilizado

Segundo Nobre (1999), Johnson e Scheurman (1977) classificaram os modelos de programação matemática usados para a solução de problemas de planejamento florestal de longo prazo em Modelo I e Modelo II.

Ainda Nobre (1999), citando (Clutter et al., 1983), no Modelo I cada variável de decisão representa uma prescrição, ou seja, uma seqüência única de intervenções programadas para uma unidade de produção, enquanto que no Modelo II, cada variável de decisão corresponde a uma intervenção que ocorre em uma unidade de produção, geralmente, durante um subperíodo do horizonte de planejamento.

A maioria dos trabalhos aplicando técnicas de Programação Linear no planejamento florestal se baseiam-se nesses dois modelos e fazem adaptações e variações de acordo com as particularidades dos problemas tratados. A formulação do Modelo I permite um acompanhamento eficiente e simples das intervenções em cada unidade.

O modelo de planejamento proposto usa a formulação do Modelo I para representar o problema. Assim sendo:

- as variáveis de decisão correspondem à escolha de um único regime de manejo para cada unidade;
- 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.

A formulação matemática proposta por Silva (2001), de acordo com o Modelo I, apresenta objetivos e restrições conforme expostos a seguir:

a) Objetivos

▪ Maximizar o Valor Presente Líquido (VPL)

O Valor Presente Líquido (VPL) de uma prescrição j é calculado pela diferença dos valores de receitas e dos custos a ela associados, descontados a uma taxa determinada. Assim, este VPL pode ser calculado de acordo com a seguinte expressão:

$$VPL = \sum_{k=0}^n R_k (1+i)^{-k} - \sum_{k=0}^n C_k (1+i)^{-k}$$

em que:

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

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

i = taxa de desconto;

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

k = período de tempo.

De acordo com essa expressão, valores positivos de VPL indicam a viabilidade econômica da prescrição j , enquanto que valores negativos indicam o contrário.

Assim, o objetivo de maximizar o Valor Presente Líquido (VPL) global da floresta, é dado pela seguinte expressão:

$$\text{Max VPL} = \sum_{i=1}^M \sum_{j=1}^N L_{ij} X_{ij}$$

em que:

VPL = valor presente líquido (VPL) global;

L_{ij} = valor presente líquido (VPL) da unidade de produção i , manejada sob a prescrição j ;

X_{ij} = variável binária, que ao assumir o valor 1 significa cortar a unidade de produção i sob a prescrição j , e 0 significa o contrário;

M = número total de unidades de produção; e

N = número total de prescrições da i -ésima unidade de produção.

- **Minimização do custo global da floresta**

$$\text{Min Custo} = \sum_{i=1}^M \sum_{j=1}^N C_{ij} X_{ij}$$

em que:

$Custo$ = custo global de produção da floresta; e

C_{ij} = custo da unidade de produção i , manejada sob a prescrição j .

- **Minimização do excesso de produção global da floresta**

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

em que:

EP = excesso de produção global da floresta;

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 da demanda a ser atendida no período k ; e

H = número de períodos do horizonte de planejamento.

No modelo aqui proposto, para esta opção (minimização do excesso de produção), foi considerado que todo o excedente da produção é vendido, sem a imposição de nenhuma restrição ou depreciação do valor da madeira.

- **Maximização da mão-de-obra global empregada na exploração da floresta**

$$\text{Max } MO = \sum_{k=1}^H \left(\sum_{i=1}^M \sum_{j=1}^N T_{ijk} X_{ij} \right)$$

em que:

MO = mão-de-obra global empregada na exploração da floresta; e

T_{ijk} = mão-de-obra empregada na unidade de produção i , manejada sob a prescrição j , no k -ésimo período do horizonte de planejamento;

Também é necessário fazer uma ressalva com relação a esta última opção (maximização da mão-de-obra), no que diz respeito ao cálculo do total de mão-de-obra empregada. Foi considerada a utilização de uma unidade de mão-de-obra para cada hectare de floresta conduzida sob o regime de condução de brotação e duas unidades de mão-de-obra para cada hectare de floresta conduzida sob o regime de reforma.

b) Restrições

▪ Restrição de área

Esta é a restrição que determina que cada unidade de manejo florestal seja manejada por apenas uma prescrição, sendo:

$$\sum_{i=1}^M \sum_{j=1}^N X_{ij} = 1$$

em que:

$X_{ij} \in \{0,1\}$, onde:

0 = não-assinalamento da alternativa j na unidade de manejo i.

1 = caso contrário.

▪ **Imposição de cotas anuais de produção**

Esta é uma das restrições de maior importância, uma vez que a principal meta do empreendedor é a produção periódica de volume de madeira de modo a atender a uma demanda preestabelecida por uma fábrica ou atender a uma demanda contratual do mercado vigente.

Considerando-se V_K o volume total removido no período K, tem-se:

$$V_K \leq \sum_{i=1}^M \sum_{j=1}^N V_{ijk} X_{ij} \quad \{K = 0, 1, \dots, H-2\}$$

em que:

V_{ijk} = volume produzido pela i-ésima unidade de produção utilizando a j-ésima alternativa de manejo no início do período k;

V_K = volume total (m^3) removido no período k, representando a demanda a ser atendida no período k; e

▪ **Restrição de capacidade de reforma**

Essa restrição visa estabelecer uma capacidade máxima de reforma que a empresa florestal é capaz de realizar a cada período. Considerando-se CR_K a capacidade de reforma preestabelecida para o período k, então:

$$CR_k \geq \sum_{i=1}^M \sum_{j=1}^N A_{ijk} X_{ij} \quad \{k = 0, 1, \dots, H-2\},$$

em que:

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.

O protótipo disponibiliza a utilização das seguintes combinações de funções objetivo na solução de problemas multiobjetivos:

- maximização do VPL e minimização do excesso de produção.

- maximização do VPL, minimização do excesso de produção e maximização do uso da mão-de-obra.
- maximização do VPL e maximização do uso da mão-de-obra.
- minimização do custo total e minimização do excesso de produção.
- minimização do custo total e maximização do uso da mão-de-obra.
- minimização do excesso de produção e maximização do uso da mão-de-obra.

3.4. O algoritmo *Simulated Annealing* multiobjetivo

Segundo Jaszkievicz (2001), a primeira versão do SA multiobjetivo foi proposto por Serafini (1992). Este método utiliza o esquema padrão do SA com únicas soluções atuais. O resultado do algoritmo é o conjunto de soluções potencialmente Pareto-ótimas contendo todas as soluções não dominadas por outras soluções geradas pelo algoritmo. Serafini (1992) considerou um número de regras de aceitação, definindo probabilidade de aceitação de novas soluções vizinhas. SA com objetivo único aceita com probabilidade igual a um novas soluções melhores ou igual à solução corrente. Se uma nova solução é pior que a solução corrente ela é aceita com probabilidade menor que um. No caso multiobjetivo, três situações podem aparecer quando comparado a nova solução X' com a solução X corrente conforme Figura 1.

- X' pode dominar X ,
- X' pode ser dominada por X ,
- X' e X podem ser mutuamente não dominadas.

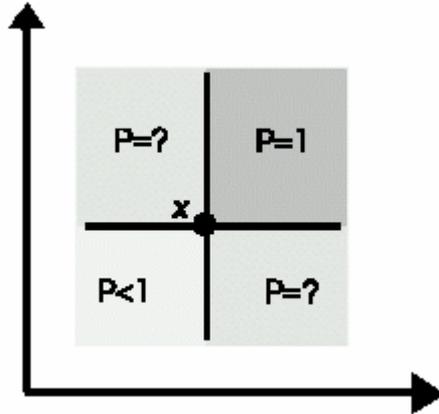


Figura 1 - A probabilidade de aceitação em regras de aceitação multiobjetivo no caso de dois objetivos de maximizar.

Na primeira situação é natural aceitar X' com probabilidade igual a um. No segundo caso a probabilidade de aceitação deve ser menor que um. A questão agora é: qual deveria ser a probabilidade de aceitação no terceiro caso. Serafini (1992) propôs um número de regras de aceitação multiobjetivo que, diferentemente, tratam a terceira situação. As regras correspondem em funções de agregação local que poderiam ser interpretadas como funções de escalarização ponderadas com pontos de referências na imagem da solução corrente x . Serafini (1992) analisou a convergência do algoritmo para o conjunto não dominado em um caminho similar usado no caso de um único objetivo. Ele foi capaz de mostrar que as regras de aceitação garantem que o algoritmo acha uma das soluções Pareto-ótimas se a temperatura é decrementada lentamente. Assim, as regras de aceitação asseguram a tendência de aproximar do conjunto não-dominado, mas não garante a dispersão sobre os pontos do conjunto não dominado. Para achar esta dispersão Serafini (1992) propôs modificar o vetor de pesos randomicamente interação por interação.

De acordo com Jaszkiwicz (2001), Ulungu et al. (1999) também desenvolveram um método utilizando *Simulated Annealing* Multiobjetivo chamado MOSA (Multi-objective *Simulated Annealing*). Este método também usa as regras de aceitação multiobjetivo. MOSA utiliza um número de vetores de pesos pré-definidos. Cada um dos vetores é associado com um processo de resfriamento independente. Cada processo inicia com uma solução randômica ou uma solução construída por uma heurística especializada. Assim, as soluções executam movimentos que são aceitos

com probabilidades definidas por uma regra de aceitação. O resultado do algoritmo é o conjunto de soluções potencialmente Pareto-ótimas contendo todas as soluções não dominadas.

3.5. *Pareto Simulated Annealing*

Pareto Simulated Annealing (PSA) foi proposto por Jazzkiewicz et al. (1994); Jazzkiewicz e Czyak, (1995) e desenvolvido futuramente em Jazzkiewicz e Czyak (1995a); Jazzkiewicz e Czyak (1996); Jazzkiewicz e Czyak (1997); Jazzkiewicz e Czyak (1997a) sendo, portanto, uma metaheurística multiobjetiva que usa os seguintes conceitos do método raiz – o *Simulated Annealing* com único objetivo (Laarhoven e Aarts, 1987):

- o conceito de vizinhança;
- probabilidade de aceitação de novas soluções vizinhas;
- dependência da probabilidade de aceitação de um parâmetro chamado temperatura; e
- o esquema de troca de temperatura.

As características do PSA são:

- o uso de uma função de escalarização baseada em probabilidades para aceitação de novas soluções vizinhas;
- o uso de uma população de soluções geradas cada uma explorando o espaço de busca de acordo com as regras SA. As soluções podem ser tratadas como agentes trabalhando quase que independentes, mas trocando informações sobre suas posições. A cada uma das soluções geradas é associado um vetor de pesos;
- uma regra para atualização do vetor de pesos das soluções geradas, objetivando assegurar a dispersão das soluções sobre todas as regiões do conjunto não dominado.

3.5.1. Regras de aceitação com objetivos múltiplos

Cada solução gerada x pode ser modificada pela aceitação de uma solução vizinha a x gerada randomicamente. A nova solução é aceita com alguma probabilidade. PSA utiliza o conceito de regras de aceitação multiobjetivo proposto por Serafini, (1994). No caso de objetivos múltiplos, uma das três seguintes situações podem ocorrer quando a nova solução y é comparada com a solução corrente x , (Figura 2).

- y domina ou é igual a x ,
- y é dominado por x ,
- y é não-dominado com relação à x .

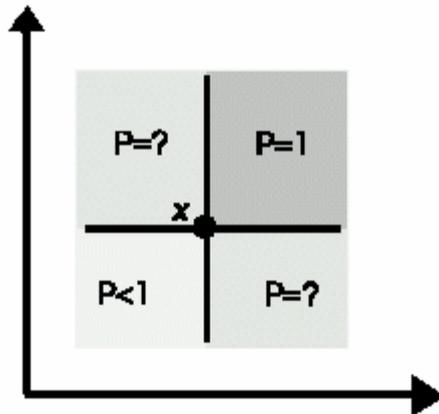


Figura 2 - A probabilidade de aceitação em regras de aceitação multiobjetivo no caso de dois objetivos de maximizar.

Na primeira situação a nova solução pode ser considerada como não pior que a solução corrente e aceita com probabilidade igual a um. Na segunda situação a nova solução pode ser considerada como pior que a solução corrente e aceita com probabilidade menor que um. Varias regras de aceitação tratam a terceira situação em vários caminhos, uma destas regras é a Regra C, interpretada como uma agregação local de todos os objetivos com a função de escalarização Tchebycheff com um ponto de referencia em $f(x)$. A probabilidade de aceitação da nova solução y é definida na seguinte expressão:

$$P(x, y, T, \Delta) = \min\{1, \exp(-\max_j \{I_j(f_j(x) - f_j(y))/T\})\},$$

em que:

T é a temperatura;

Δ é o vetor de pesos;

x é a solução corrente; e

y é a nova solução gerada a partir da solução x .

Uma ilustração gráfica da regra é mostrada na Figura 3.

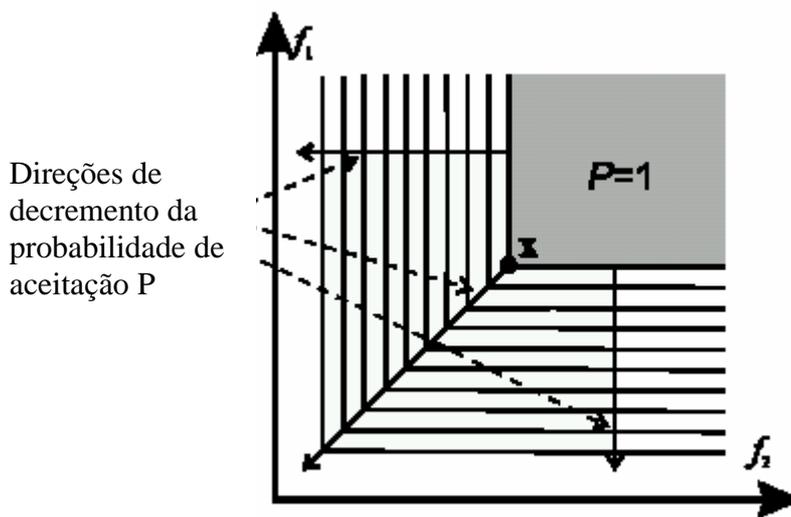


Figura 3 - Ilustração gráfica da regra C em um caso de dois objetivos de maximizar.

Outra regra de aceitação denominada regra SL pode ser interpretada como uma agregação local de todos os objetivos com uma função de escalarização Linear. Ela é definida pela seguinte expressão:

$$P(x, y, T, \Delta) = \min\{1, \exp(-\sum_{j=1}^J I_j(f_j(x) - f_j(y))/T)\}$$

Uma ilustração gráfica da regra SL é apresentada na Figura 4.

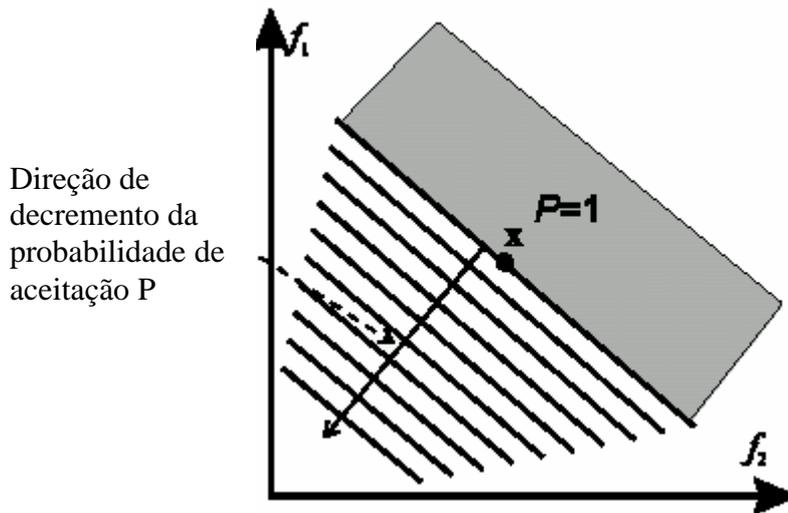


Figura 4 - Ilustração gráfica da regra SL em um caso de dois objetivos de maximizar.

3.5.2. Administrando a população de soluções geradas

Serafini (1992) tem provado que o uso de regras de aceitação multiobjetivo asseguram a tendência para a aproximação do conjunto não dominado, entretanto, isto pode ser insuficiente para assegurar a dispersão das soluções geradas sobre todas as regiões do conjunto. Os pesos usados nas regras de aceitação permitem influenciar a direção da busca no espaço objetivo para uma solução gerada em particular. Note que ao mais alto dos pesos associados com um dado objetivo, há mais alta influencia desse objetivo na probabilidade de aceitação de novas soluções e há mais alta pressão para melhorar esse objetivo. Assim, controlando o vetor de pesos, o método pode impulsionar as soluções geradas dentro de decisões desejadas no espaço de solução.

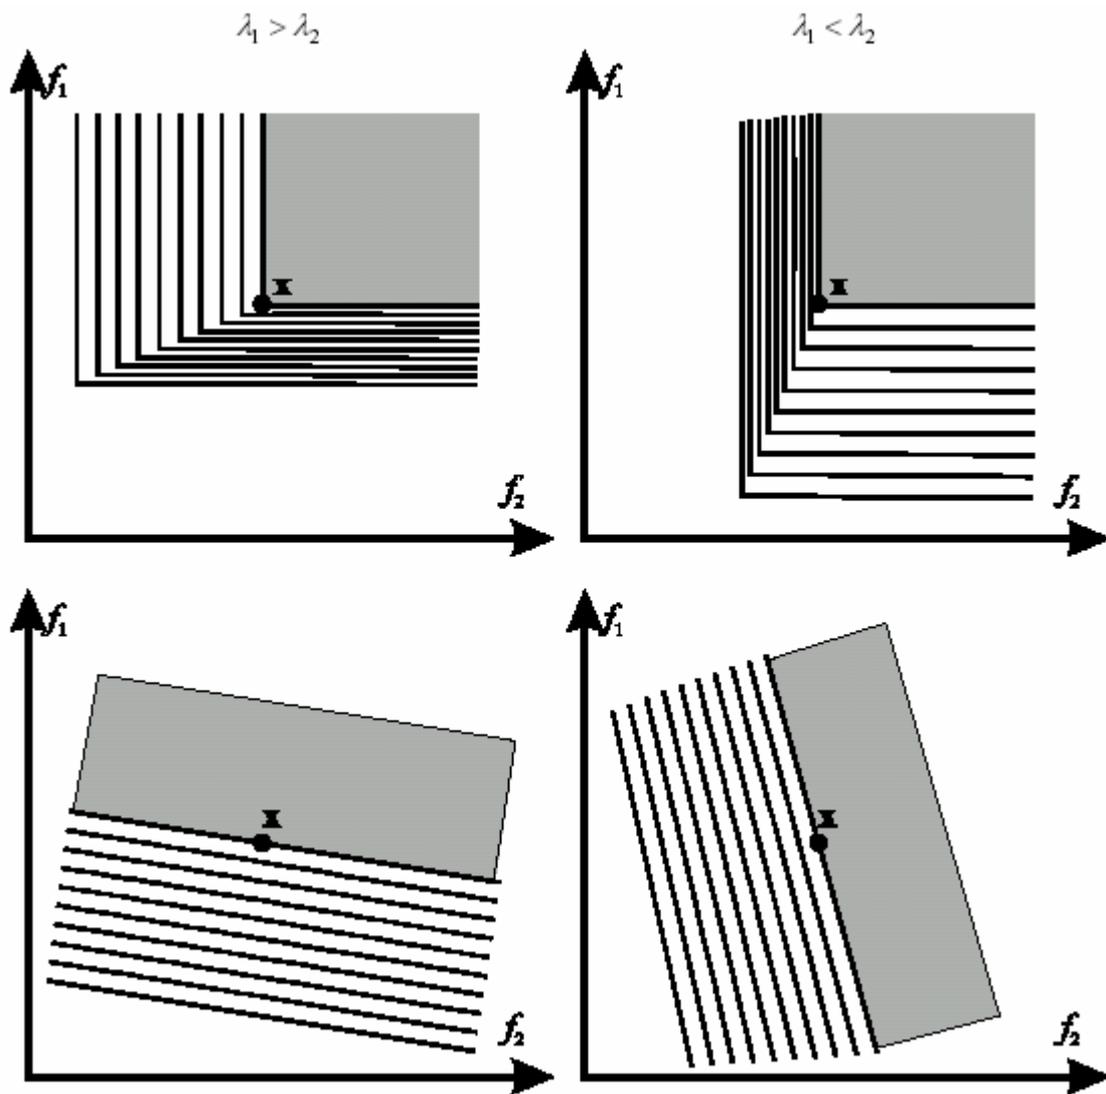


Figura 5 - O Papel dos pesos em regras de aceitação multiobjetivo.

PSA controla o vetor de pesos associados com cada solução gerada achando uma forma de repulsão entre as soluções. O vetor de pesos associado com uma dada solução gerada x é modificado na tentativa de aumentar a probabilidade de mover x na direção do vizinho mais próximo x' . Isto é obtido pelo incremento dos pesos dos objetivos no qual x é melhor que x' e decrementando os pesos onde x é pior que x' . A distância Euclidiana entre as soluções no espaço de objetivos normalizados é usada. Um requerimento adicional é que o vizinho mais próximo tem que ser não dominado em relação à x . Se não há nenhuma solução gerada que atenda a este requisito cada peso é incrementado ou decrementado com probabilidade igual a 0.5.

3.5.3. Atualização do conjunto de soluções potencialmente Pareto-ótimas

No início do algoritmo, o conjunto de soluções potencialmente Pareto-ótimas (PP) está vazio. Ele é atualizado quando uma nova solução é gerada. Atualizar o conjunto de soluções potencialmente Pareto-ótimas a solução x consiste em:

- Adicionar $f(x)$ para PP se nenhum ponto em PP domina $f(x)$,
- Remover de PP todos os pontos dominados por $f(x)$.

O processo de atualizar, o conjunto PP pode consumir muito tempo. Assim, as seguintes técnicas poderiam ser usado na tentativa de reduzir os requerimentos computacionais:

- Nova solução y obtida a partir de x deveria ser usada para atualizar PP somente se ela é não dominada por x .
- As soluções adicionadas ao PP nas iterações iniciais têm uma boa chance de serem removidas desses conjuntos em soluções futuras. Em outras palavras, o tempo gasto para atualizar PP nas soluções iniciais será perdido. Assim, é possível atrasar a atualização de PP a partir de um número de soluções iniciais.

3.5.4. Implementação do algoritmo

Para a implementação do algoritmo PSA utilizaram-se as técnicas de programação orientada a objetos (POO), no ambiente de programação *Borland Delphi 6*.

Para a representação das variáveis do problema na forma de soluções de uma população, utilizou-se uma estrutura vetorial instanciado dinamicamente fazendo-se as seguintes considerações:

- A unidade de produção é representada de acordo com o índice do vetor, ou seja, a UP_1 encontra-se na posição 1 do vetor, UP_2 encontra-se na posição 2 do vetor e, assim, sucessivamente.
- Cada prescrição da UP é representada por um número inteiro dentro do vetor, ou seja, se a UP_1 possui 10 prescrições, a primeira posição do vetor que representa a UP_1 conterà um numero inteiro entre 1 e 10, representando as

prescrições possíveis da UP₁. Para cada UP somente pode ser escolhida uma prescrição a ser utilizada.

Assim, o vetor representa as prescrições das UP's de uma determinada solução. Um exemplo desta representação pode ser visto na Figura 6.

5	8	1	4	3
---	---	---	---	---

Figura 6 - Vetor contendo as prescrições adotadas para cada UP.

A solução é representada por este vetor, acrescido da informação de *fitness*. Uma população é um conjunto de soluções. A Figura 7 representa a estrutura de dados utilizada para representar as classes que implementam estas definições.

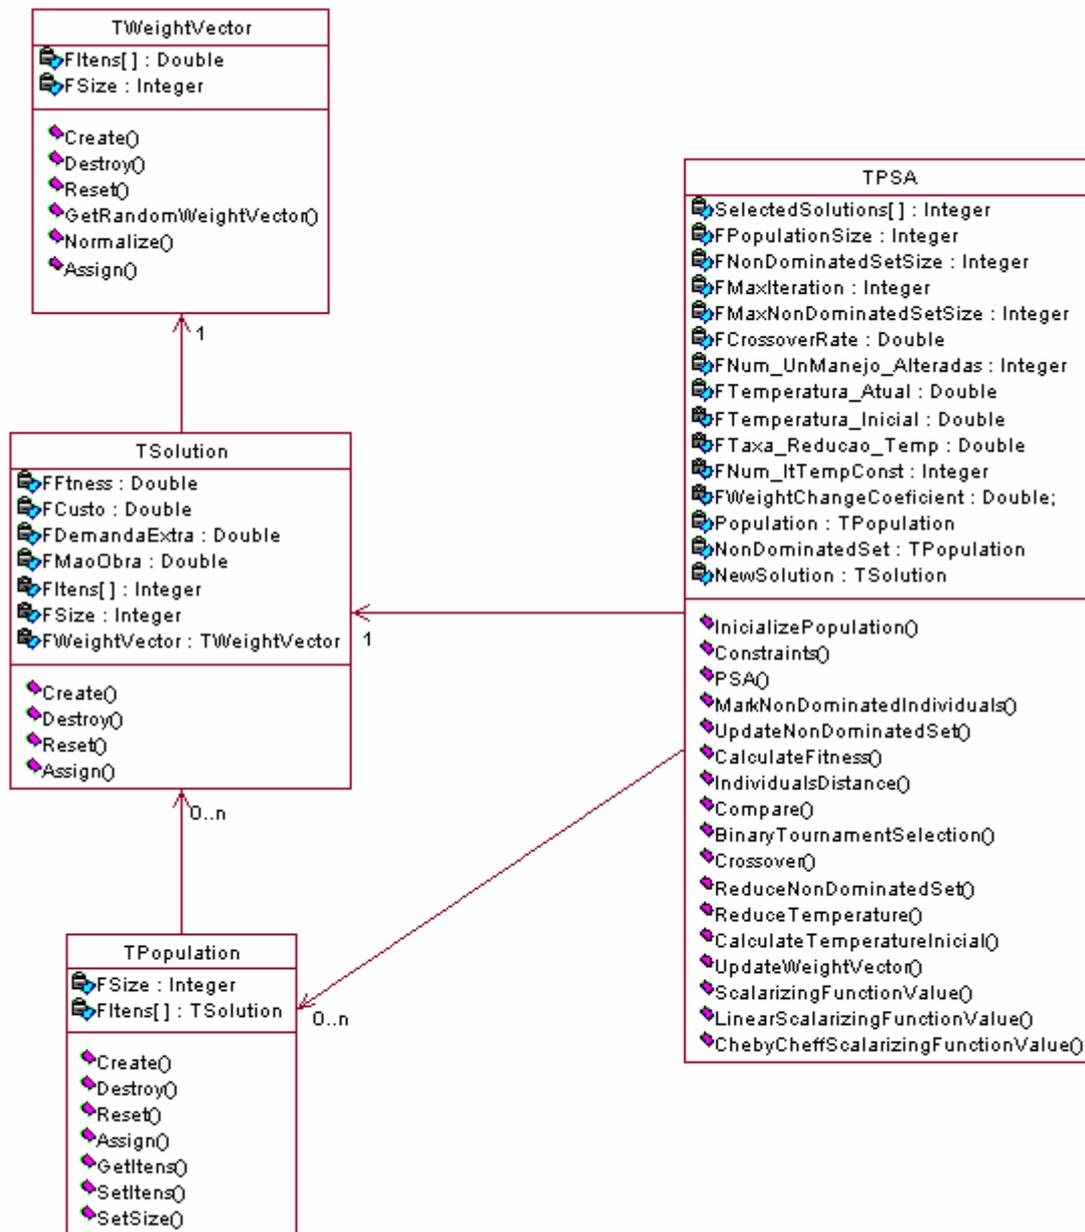


Figura 7 - Diagrama de Classes referente as estruturas do PSA

A geração da população inicial foi feita de forma aleatória, ou seja, escolheu-se aleatoriamente para cada posição do vetor uma prescrição e atribui-se o valor.

O diagrama de classes na Figura 8 abaixo representa as estruturas de dados utilizadas no protótipo para armazenar as informações relativas a um projeto.

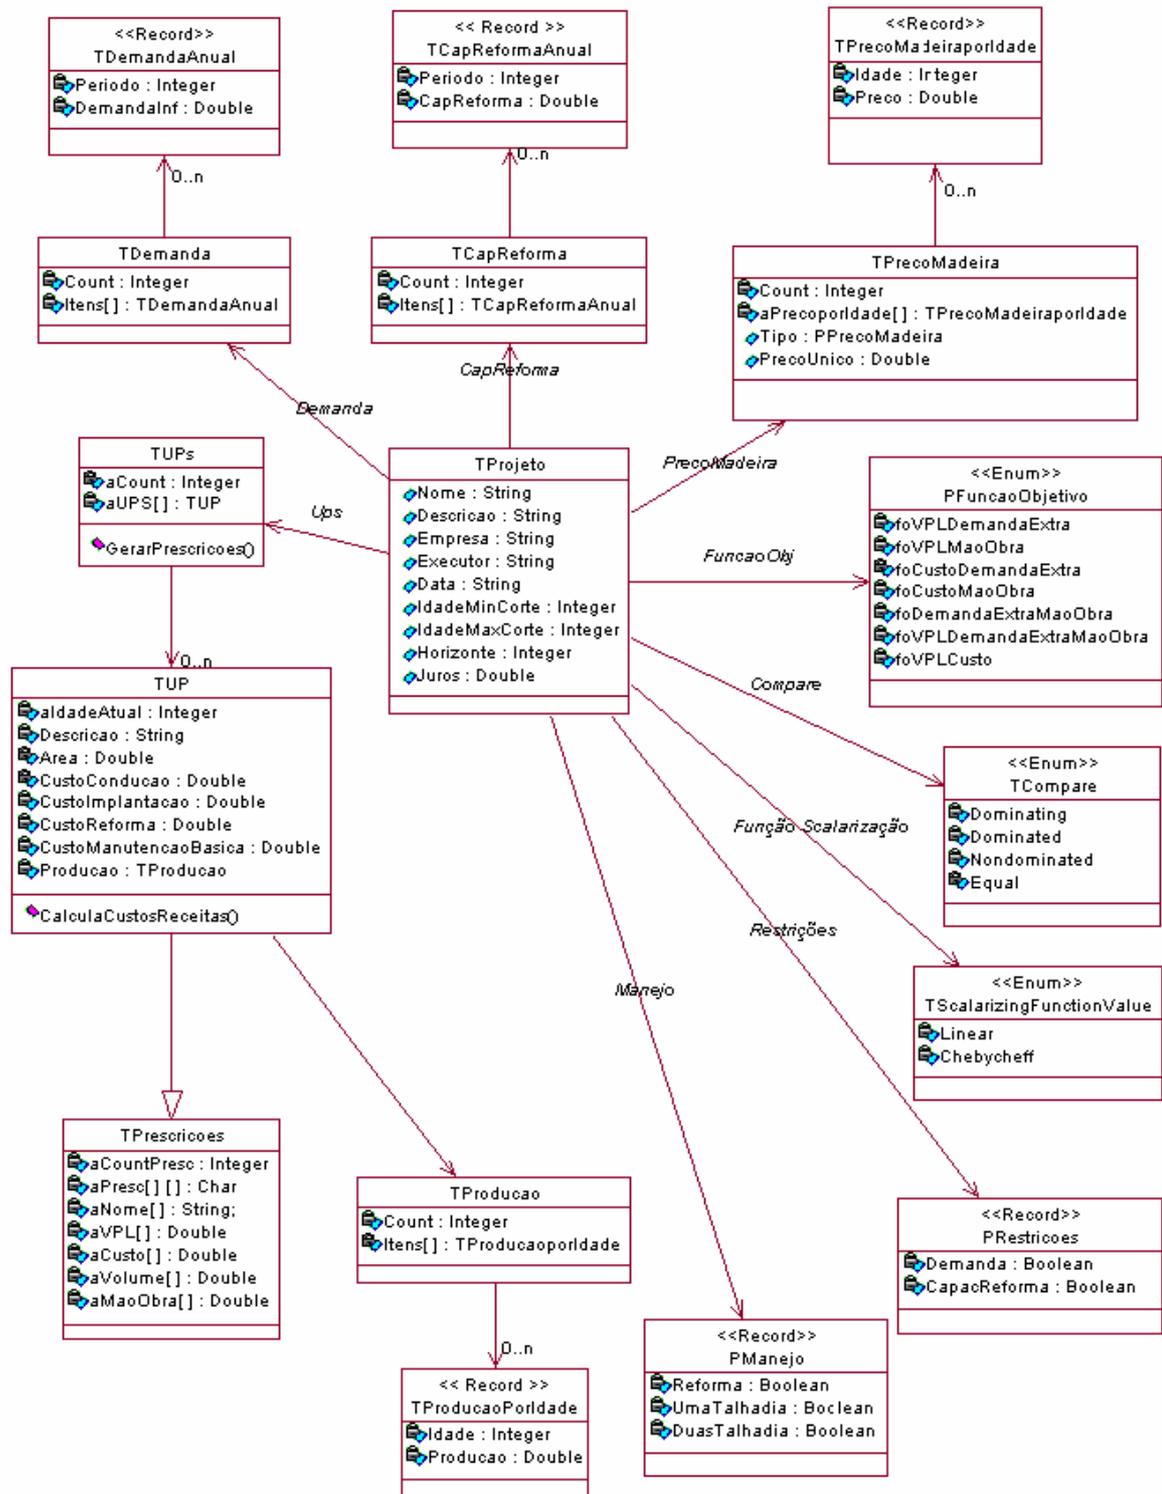


Figura 8 - Diagrama de Classes referente as estruturas do Projeto.

A versão básica do PSA pode ser visualizado abaixo.

Algoritmo PSA

Parâmetros: número de soluções geradas, Temperatura Inicial, coeficiente de repulsão $\alpha > 0$, regra de decremento de temperatura, critério de parada.

Randomicamente gera um conjunto de soluções $S \hat{I} D$, e associa um vetor de pesos randômicos com cada solução gerada.

Para cada $x \hat{I} S$ faça

Atualize o conjunto de soluções potencialmente Pareto-Ótimas (PP) com x

$T := T_0$

Repeat

Para cada $x \hat{I} S$ faça

Construa $y \hat{I} V(x)$

Se y é não-dominado por x faça

Atualize o conjunto PP com y

Selecione uma solução $x' \hat{I} S$ mais próxima de x e não-dominado em relação a x .

Se não há nenhuma solução x' faça

Para cada objetivo f_j

$I_j^* = I_j^* + \mathbf{a}$ ou $I_j^* = I_j^* - \mathbf{a}$ com probabilidade igual a 0.5

Se não

Para cada Objetivo f_j

$$I_j^* = \begin{cases} I_j^* + \mathbf{a}, & \text{se } f_j(x) \geq f_j(x') \\ I_j^* - \mathbf{a}, & \text{se } f_j(x) \leq f_j(x') \end{cases}$$

normalize os vetores de pesos tal que $\sum_j I_j^* = 1$

$x := y$ (aceita y) com probabilidade $P(x, y, T, \Lambda^x)$

Se a condição de troca de temperatura é satisfeita então

Decremente T

Até o critério de parada seja satisfeito

A construção de uma nova solução x' , vizinha a x foi feita de forma aleatória utilizando-se a seguinte estratégia: a partir de uma solução inicial (x_0) gerada aleatoriamente, a cada iteração, um determinado número de unidades de manejo é escolhido, aleatoriamente, para ter uma variável X_{ij} adicionada. A Figura 9 resume este procedimento, com um movimento x' gerado através da adição da variável X_{11} e da remoção da variável X_{15} na solução anterior (x), na unidade de manejo um. Neste caso, apenas uma unidade de manejo é escolhida para se fazer a troca.

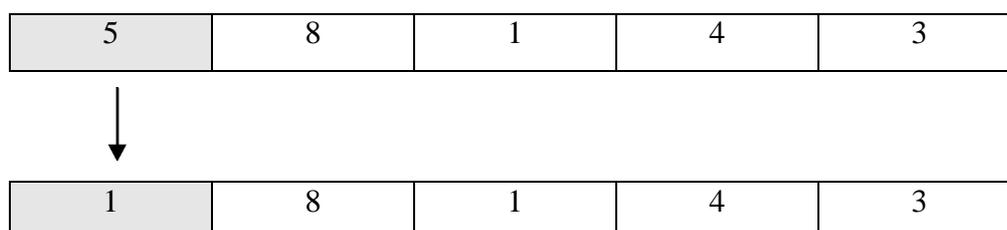


Figura 9 – Estratégia de movimento na geração de nova solução vizinha.

De acordo com Rodrigues (2001), a temperatura (T) é um dos principais parâmetros da SA. Ela inicia com um valor alto, permitindo que movimentos de pior qualidade (ou que pioram a função objetivo) tenham maiores chances de serem escolhidos, sendo gradativamente reduzida a temperatura até a convergência do algoritmo, o que equivale a diminuir as chances de escolha de um movimento de baixa qualidade, à medida que o algoritmo progride. Várias estratégias de redução da temperatura podem ser adotadas, e nenhum trabalho até o momento apresenta sugestões de qual o melhor esquema de redução dessa temperatura. Há um consenso na literatura especializada de que este parâmetro depende da natureza do problema, devendo ser definido por experimentação.

A temperatura inicial é calculada tomando-se duas soluções aleatórias do conjunto de soluções geradas. Os valores objetivos das duas soluções, denotados por $f(x_1)$ e $f(x_2)$, são introduzidos na fórmula abaixo de forma que a probabilidade inicial de se aceitar uma nova solução seja igual a um. Assim, a temperatura é reduzida gradativamente até que um estado de energia mínima seja atingido pelo sistema quando a temperatura está próxima de zero. Note que à medida em que a temperatura

vai diminuído, a probabilidade de se aceitar novas soluções vizinhas também diminui gradativamente, proporcional ao decréscimo da temperatura:

$$e^{(f(x_1)-f(x_2))/T_0} = 1$$

em que:

e = constante (2,718282);

T_0 = Temperatura inicial a ser calculada;

$f(x_1)$ = valor da função objetivo da primeira solução escolhida aleatoriamente;

$f(x_2)$ = valor da função objetivo da segunda solução escolhida aleatoriamente;

3.5.5. O procedimento híbrido

Como mencionado anteriormente, foram utilizados alguns procedimentos da metaheurística AG, como os métodos de Seleção e *Crossover*. A utilização desses métodos objetiva alcançar, de forma mais rápida, uma fronteira eficiente mais homogênea. Através do método de seleção pretendeu-se inserir soluções não-dominadas, da fronteira de Pareto, no conjunto de soluções a serem evoluídas; assim, pretendeu-se evoluir a partir de soluções não dominadas e soluções da população, simultaneamente. Utilizou-se o método de seleção por torneio binário.

Com o uso do *Crossover* procurou-se alcançar a fronteira de forma mais eficiente, garantindo assim a convergência em busca de novas soluções. Utilizou-se o *Crossover* de um ponto. O *Crossover* de um ponto é realizado aos pares de soluções, e corta as “*Strings*” do cromossomo em alguma posição escolhida randomicamente, produzindo assim duas novas “cabeças” e duas novas “caldas”, como mostrado na Figura 10:

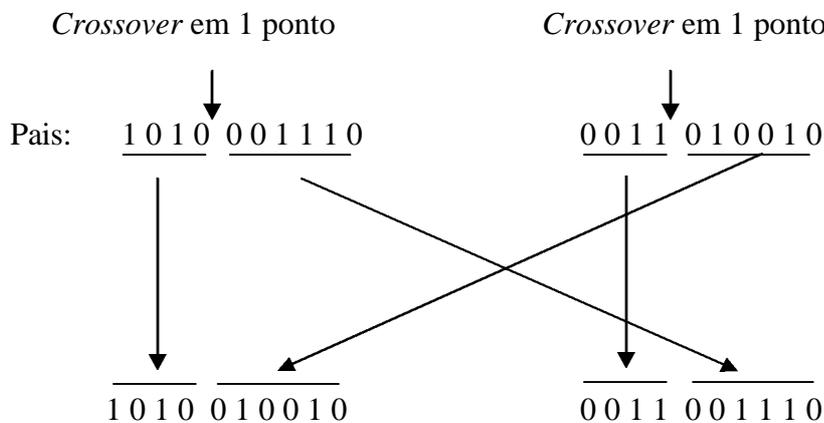


Figura 10 : *Crossover* em de ponto

3.6. Problemas-teste

Com vistas a alcançar o objetivo proposto e de mostrar a potencialidade de aplicação de *Simulated Annealing* na solução de problemas de planejamento florestal multiobjetivos, foram realizados alguns estudos de casos baseados em dados hipotéticos e reais, estes adquiridos em empresas florestais.

Na geração dos problemas foram consideradas as seguintes premissas em todos os problemas, onde o objetivo da empresa florestal é planejar a sua produção de madeira através de um plano de manejo florestal.

- 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;
- 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 no Quadro 5. 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 no Quadro 6.

Quadro 5 – 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

Quadro 6 – 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

No Quadro 31, (Anexos) encontram-se as informações relativas às unidades de produção consideradas em todos os problemas propostos. Em alguns problemas, apenas um subconjunto destas unidades de produção foi considerado. O quadro completo, com as unidades de produção utilizadas, bem como as prescrições geradas encontram-se nos Anexos.

Os valores de demandas mínimas anuais e áreas máximas de reforma utilizadas em cada um dos problemas são apresentados no Quadro 7 e 8. Os objetivos considerados em cada um dos problemas são apresentados no Quadro 9.

Nos problemas 1, 2 e 3 foram utilizados os dois primeiros objetivos e, posteriormente, incluiu-se o terceiro objetivo para se medir o impacto da inclusão de mais um objetivo na performance do algoritmo.

A diferença entre os problemas 1, 2 e 3 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 servirá como forma de exploração de cenários diferentes e influenciará diretamente no desempenho das técnicas utilizadas para se resolver os problemas, como será discutido na seção 4.

Este cenário pode ocorrer quando a empresa florestal está projetando o seu crescimento ou o aumento da demanda de madeira no mercado ao longo do tempo e pretende aumentar a mão de obra a ser utilizada pela empresa florestal, gerando assim mais empregos.

O número de unidades de produção, o tamanho do horizonte de planejamento e as prescrições geradas para cada um dos problemas, considerando as premissas deste estudo de caso, são apresentadas no Quadro 10.

Quadro 7 – Demandas (D) anuais mínimas (m3), e áreas de reforma (A) máxima (ha), previstas para os problemas

Período	Problemas											
	1		2		3		4		5		6	
	D(m3)) x1000	A(ha) x100 0										
0	500	6	550	7	575	8	900	7.5	1.100	*	1.600	*
1	500	6.5	550	7.5	575	8	900	7.5	1.100		1.600	
2	600	7	650	8	675	9	1.000	7.5	1.200		1.700	
3	700	7.5	750	8.5	775	10	1.100	7.5	1.300		1.800	
4	800	8	850	9	875	11	1.200	7.5	1.400		1.900	
5	800	8.5	850	9.5	875	11	1.200	7.5	1.400		1.900	
6	800	9	850	10	875	11	1.300	7.5	1.500		2.000	
7	900	9.5	950	10.5	975	12	1.300	7.5	1.500		2.000	
8	900	10	950	11	975	12	1.350	7.5	1.550		2.050	
9							1.350	7.5	1.550		2.050	
10							1.400	7.5	1.600		2.100	
11							1.400	7.5	1.600		2.100	
12							1.500	7.5	1.700		2.200	
13							1.500	7.5	1.700		2.200	

* Restrição não considerada

Para os problemas 7, 8 e 9 foram utilizados os horizontes de planejamento de 20, 25 e 28 anos respectivamente, com restrições de demanda apresentadas no Quadro 8.

Quadro 8- Demandas anuais mínimas previstas para os problemas 7, 8 e 9.

Período	Demanda (m³)*1000
0	1.500
1	1.500
2	1.600
3	1.700
4	1.800
5	1.800
6	1.900
7	1.900
8	1.950
9	1.950
10	2.000
11	2.000
12	2.100
13	2.100
14	2.150
15	2.150
16	2.200
17	2.200
18	2.250
19	2.250
20	2.250
21	2.250
22	2.250
23	2.250
24	2.250
25	2.250
26	2.250
27	2.250

Quadro 9 – Objetivos considerados em cada um dos problemas propostos.

Problemas	Objetivos		
	I	II	III
1	X	X	X
2	X	X	X
3	X	X	X
4	X	X	
5	X	X	
6	X	X	
7	X	X	
8	X	X	
9	X	X	

em que:

- I. - Maximizar o retorno econômico (VPL).
- II. - Minimizar o excesso de produção em relação às demandas anuais.
- III. - Maximizar o uso da mão-de-obra a ser empregada.

Quadro 10 – Problemas-teste utilizados para as demonstrações propostas.

Problema	Número de UP's **	Horizonte de Planejamento	Número de Prescrições
1	50	9 anos	735
2	50	9 anos	735
3	50	9 anos	735
4	100	14 anos	5094
5	100	14 anos	5094
6	150	14 anos	7491
7	150	20 anos	27807
8	150	25 anos	82905
9	150	28 anos	156042

** Foram utilizadas as “n” primeiras unidades de produção descritas no Quadro 31 que se encontra nos anexos.

Para estes problemas foram utilizados os parâmetros de entrada informados no Quadro 11 abaixo.

Quadro 11 – Parâmetros de entrada utilizados pelo PSA e SPEA

Algoritmo	PSA	SPEA
Taxa de crossover	0,85	0,85
Taxa de mutação		0,05
Número de iterações com temperatura cte.	1	
Taxa de redução de temperatura	0,90	
Unidades de manejo trocadas	1	
Weight change coeficiente	0,10	
Função de escalarização	Linear	

3.7. Medidas de desempenho do PSA

O desempenho do algoritmo PSA foi comparado com o algoritmo exato *Branch-and-Bound (B&B)*, implementado no software comercial CPLEX, versão 7.0.

Nos problemas 1, 2, 3 e 4 além da comparação com o algoritmo exato (*B&B*), também foram feitas comparações com o algoritmo SPEA proposto por Zitzler (1999) e implementado por Teixeira (2002).

Os testes envolvendo os algoritmos PSA e SPEA foram realizados em um Microcomputador *Desktop* com as seguintes configurações: Sistema Operacional *Windows 2000*, processador *Pentium 3*, 700 MHz com 512 MB. de memória RAM.

Os testes com o software CPLEX foram realizados em um Microcomputador com as seguintes configurações: Sistema Operacional: *Solaris 5.8*; processador *SUN Blade 100 ULTRASPARC-IIe* 500 MHz com 1024 GB de memória RAM.

Como a natureza dos problemas é multiobjetiva, utilizou-se o Método das Restrições no software CPLEX, deixando como função-objetivo somente um dos objetivos e os demais foram parametrizados e colocados como restrições, de forma a se obter soluções ao longo da fronteira de Pareto-ótima.

Como medida de eficiência utilizaram-se apenas medidas de tempo de processamento do algoritmo PSA e do algoritmo SPEA implementado por (Teixeira 2002), para os problemas 1, 2, 3 e 4, uma vez que os mesmos foram executados em uma mesma máquina, com as mesmas configurações. Não serão feitas aqui comparações de tempo entre os métodos de solução do PSA e CPLEX, uma vez que os testes foram realizados utilizando recursos computacionais distintos. Serão mencionados apenas os tempos gastos por cada método. Os testes do PSA e SPEA foram realizados no Departamento de Informática da Universidade Federal de Viçosa, e os testes do CPLEX foram realizados no Departamento de Ciência da Computação da Universidade Federal de Belo Horizonte, pois o DPI-UFV possui apenas uma versão reduzida do software, com limite de trezentas restrições, inadequada para a solução dos problemas propostos.

A performance do PSA foi avaliada de acordo com (Rodrigues, 2001), através da sua eficácia, calculada pela razão entre um valor da função objetivo do PSA e o valor obtido pelo algoritmo exato *Branch-and-Bound* implementado no software CPLEX. Dividiu-se a fronteira de Pareto-ótimo em três regiões denominadas: Região Inferior, Região Intermediária e Região Superior da fronteira, sendo calculada e eficácia expressa em porcentagem para cada região do gráfico. Assim:

$$Ef = \frac{f_{PSA}}{f_o} \times 100$$

em que:

f_{SA} = eficácia (%).

f_{SA} = valor da melhor solução obtida em uma corrida da PSA.

f_o = valor da solução ótima obtida pelo CPLEX.

4. RESULTADOS E DISCUSSÃO

4.1. Resultados para os problemas 1, 2 e 3 com dois objetivos

Para melhor compreensão dos resultados, primeiro é feita uma comparação dos resultados para os problemas 1, 2, 3 e 4 com 2 objetivos (maximizar lucro, minimizar excesso de produção) entre o algoritmo PSA, SPEA e o algoritmo exato *B&B* implementado no software CPLEX. Não serão feitos testes com o algoritmo SPEA para os demais problemas, devido ao elevado tempo computacional gasto.

O gráfico apresentando a fronteira Pareto-ótima para o problema 1 é apresentado na Figura 11. Pode-se observar claramente as fronteiras geradas pelos algoritmos *B&B* (implementado no software CPLEX), PSA e SPEA. Observa-se, também, uma aproximação considerável destas fronteiras entre as soluções geradas pelos algoritmos PSA e SPEA. Percebe-se uma menor aproximação nas soluções que se encontram nos extremos. Tal constatação é feita não só para o problema 1, mas para os demais problemas aqui mencionados, devido ao fato das restrições se tornarem mais fortes nos extremos da fronteira Pareto-ótima. Essa complexidade também é observada no software CPLEX, demandando mais tempo para encontrar as soluções nos extremos.

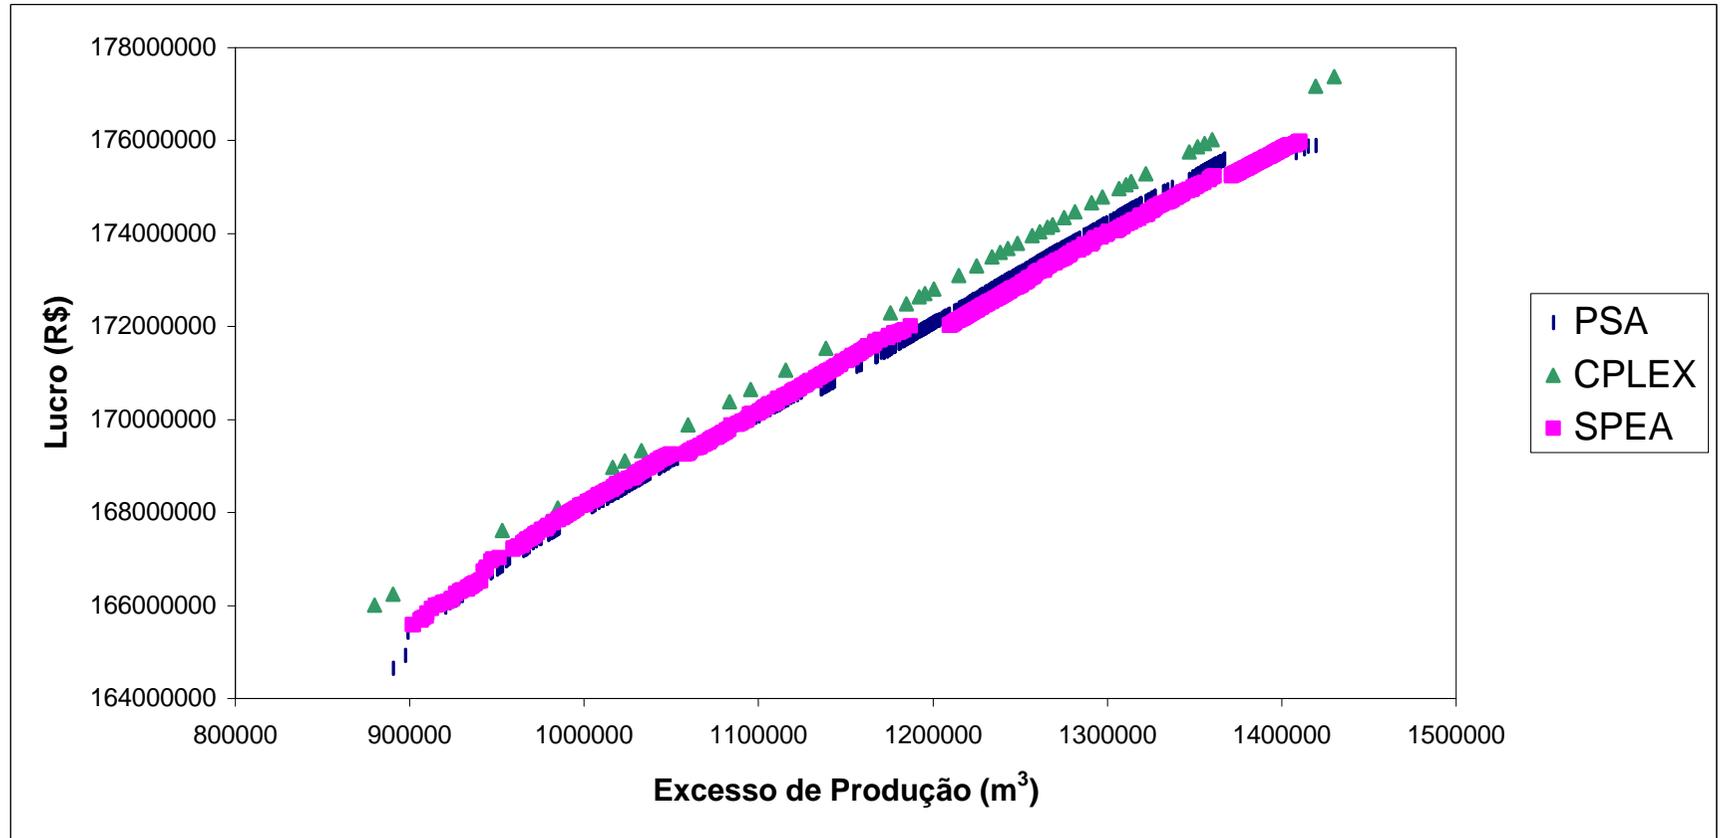


Figura 11 – Fronteira Pareto-Ótima construída pelo PSA, *B&B* e SPEA para o problema 1 com dois objetivos

Para a comparação da eficácia proposta por Rodrigues (2001), foi escolhida uma solução próxima ao extremo inferior, outra numa posição intermediária e outra próxima ao extremo superior do gráfico. O Quadro 12, apresenta a eficácia do PSA e SPEA em relação ao CPLEX; percebe-se uma aproximação muito boa entre os dois algoritmos e o método exato.

Quadro 12 - Eficácia do PSA e SPEA em relação ao algoritmo exato *B&B* implementado no CPLEX para o problema 1

Região/Eficácia(%)	PSA	SPEA
Inferior	99,66	99,73
Intermediário	99,59	99,55
Superior	99,68	99,55

A eficiência do PSA e do SPEA é apresentada no Quadro 13. Nota-se uma grande diferença entre os tempos de convergência dos dois algoritmos.

Essa diferença entre os tempos de execução dos dois algoritmos pode ser atribuída à heurística utilizada e às estruturas de dados escolhidas na implementação de cada algoritmo. Como mencionado anteriormente, não foram comparados os tempos dos algoritmos PSA e SPEA em relação ao software CPLEX, devido às diferenças de recursos computacionais utilizados, sendo apenas apresentado o tempo gasto pelo CPLEX. Para os problemas 1, 2 e 3 o número de soluções parametrizadas no CPLEX foram 40, enquanto que o número de soluções encontradas pelo PSA e SPEA foi de 800, embora se reconheça a falta de utilidade prática deste número tão elevado.

Quadro 13 - Eficiência do PSA em relação ao SPEA para o problema 1

	PSA	SPEA	CPLEX
Tempo total	5m 38s	40m 39s	2h 39m 14s
Tempo gasto para gerar as soluções iniciais	1m 21s	14m 32s	
Tempo gasto pelas iterações	4m 17s	26m 07s	
Número de soluções na população	2000	2000	
Número de soluções no conjunto não-dominado	800	800	40
Número de iterações	150	150	

Para o problema 2, os resultados de eficiência e eficácia são apresentados nos

Quadro 14 e 15, e na Figura 12. No problema 3 estes resultados aparecem na Figura 13 e nos Quadro 16 e 17.

Quadro 14 - Eficácia do PSA e SPEA em relação ao algoritmo exato *B&B* implementado no CPLEX para o problema 2

Região/Eficácia(%)	PSA	SPEA
Inferior	98,37	99,13
Intermediário	99,40	99,39
Superior	99,44	99,46

Quadro 15- Eficiência do PSA em relação ao SPEA para o problema 2

	PSA	SPEA	CPLEX
Tempo total	20m 44s	3h 21m 57s	11h 51m 30s
Tempo gasto para gerar as soluções iniciais	16m 02s	2h 48m 10s	
Tempo gasto pelas iterações	4m 42s	33m 47s	
Número de soluções na população	2000	2000	
Número de soluções no conjunto não-dominado	800	800	40
Número de iterações	150	150	

Quadro 16 - Eficácia do PSA e SPEA em relação ao algoritmo exato *B&B* implementado no CPLEX para o problema 3

Região/Eficácia(%)	PSA	SPEA
Inferior	99,04	99,10
Intermediário	99,34	99,34
Superior	99,35	99,42

Quadro 17- Eficiência do PSA em relação ao SPEA para o problema 3

	PSA	SPEA	CPLEX
Tempo total	1h 16m 35s	17h 24m 57s	17h 45m 11s
Tempo gasto para gerar as soluções iniciais	1h 12m 37s	16h 56m 10s	
Tempo gasto pelas iterações	3m 58s	28m 47s	
Número de soluções na população	2000	2000	
Número de soluções no conjunto não-dominado	800	800	40
Número de iterações	150	150	

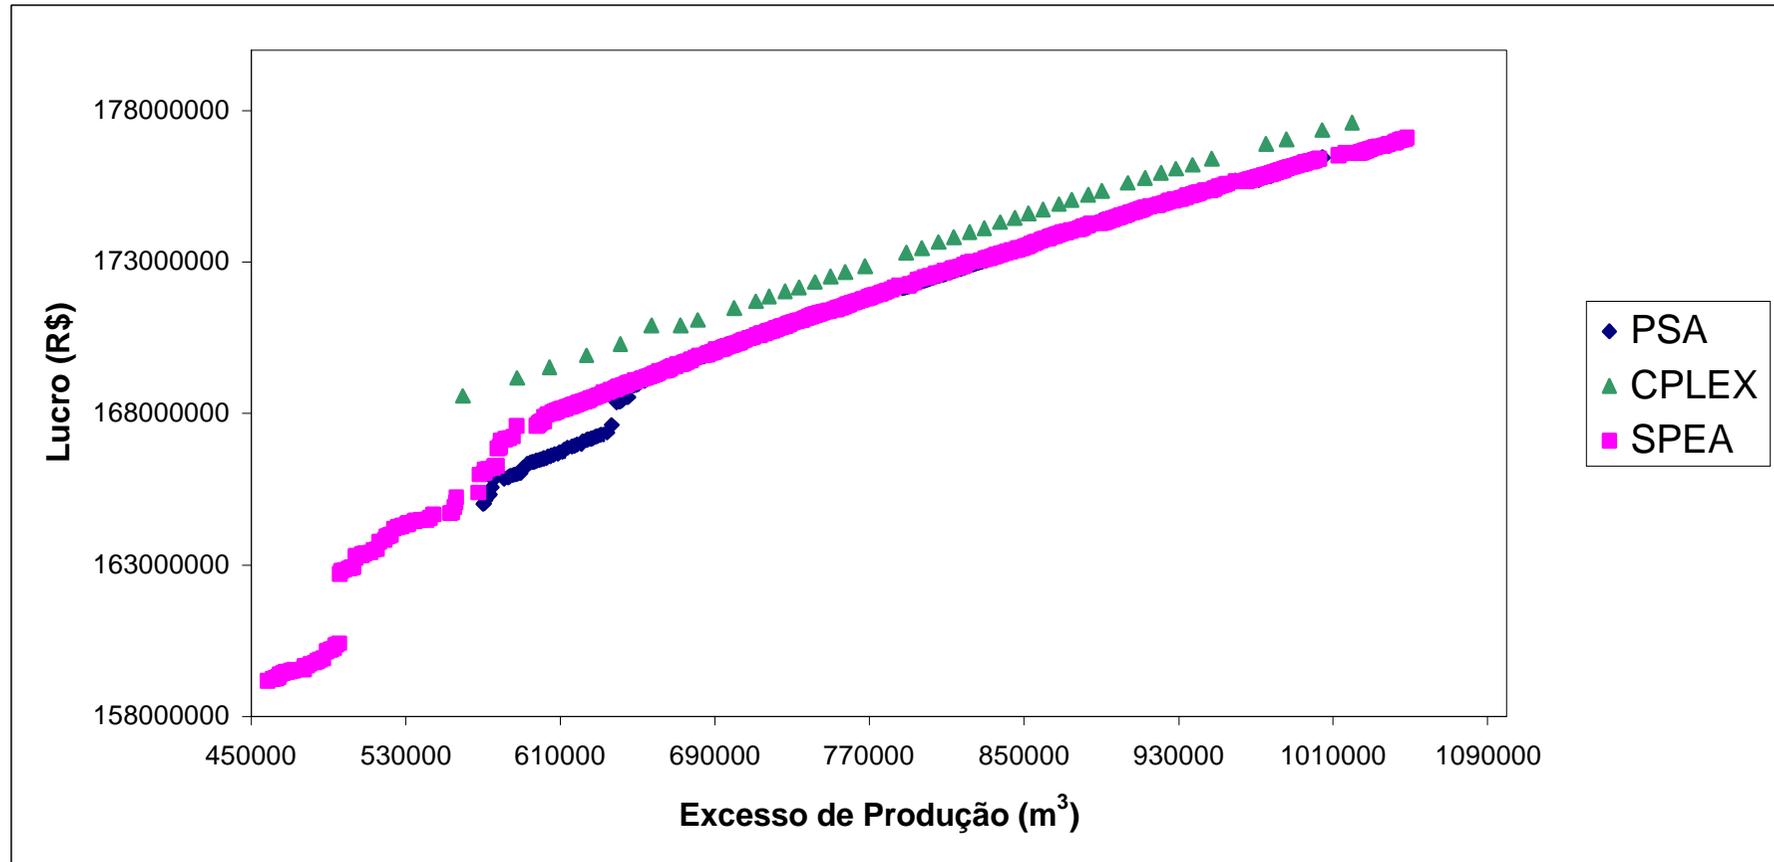


Figura 12 - Fronteira Pareto-Ótima construída pelo PSA, *B&B* e SPEA para o problema 2 com dois objetivos

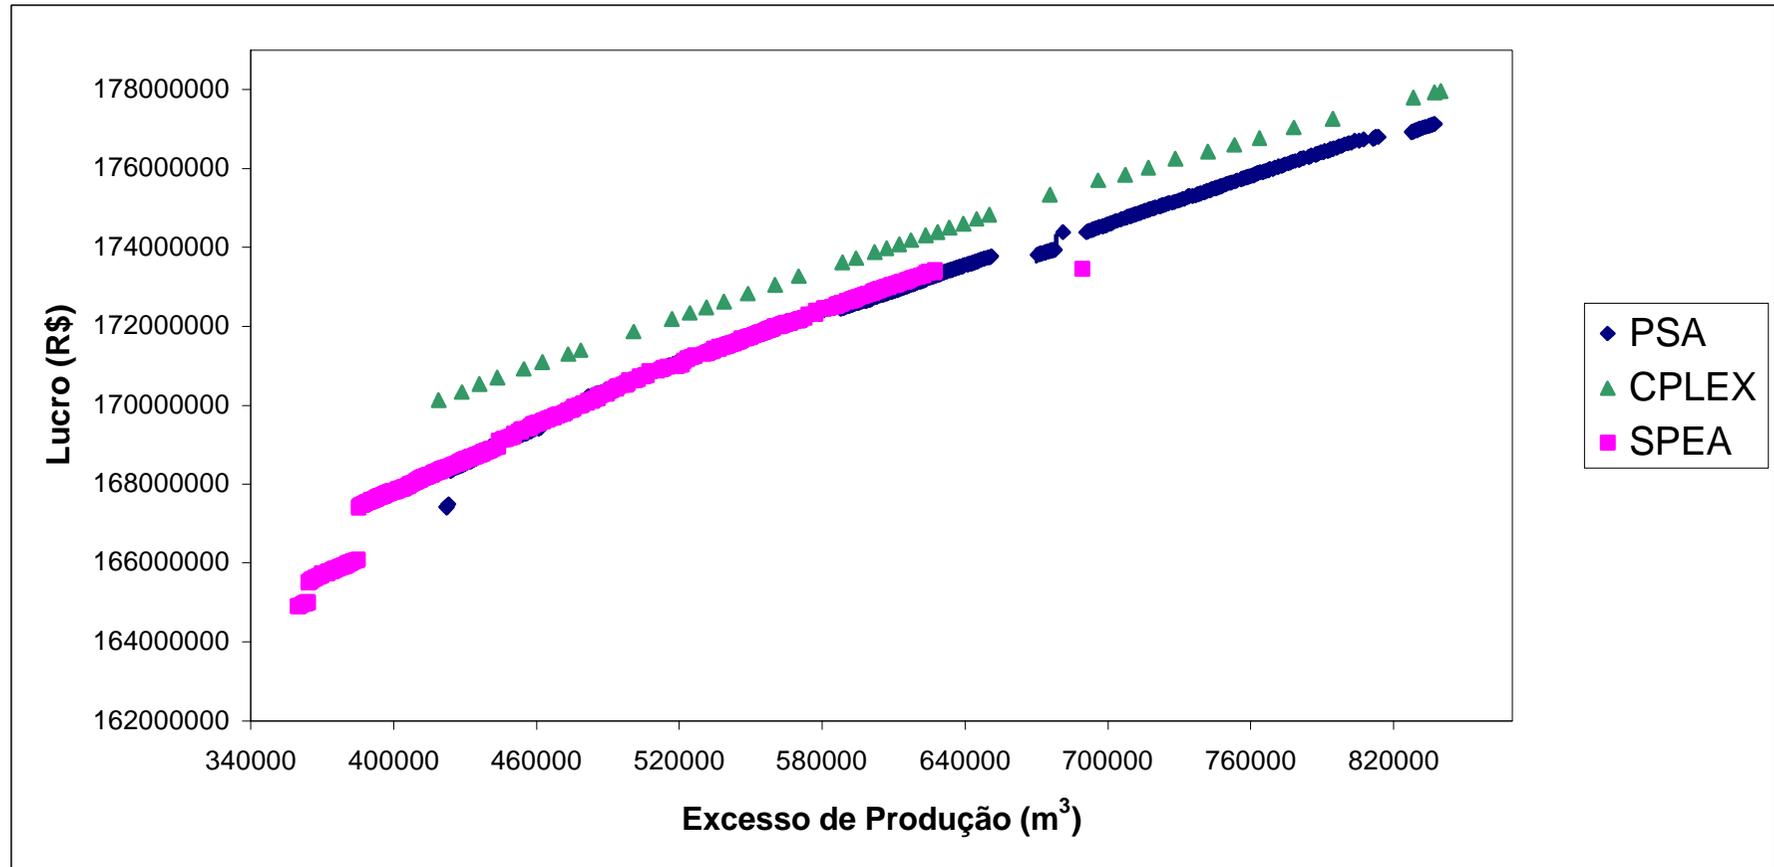


Figura 13 - Fronteira Pareto-Ótima construída pelo PSA, *B&B* e SPEA para o problema 3 com dois objetivos

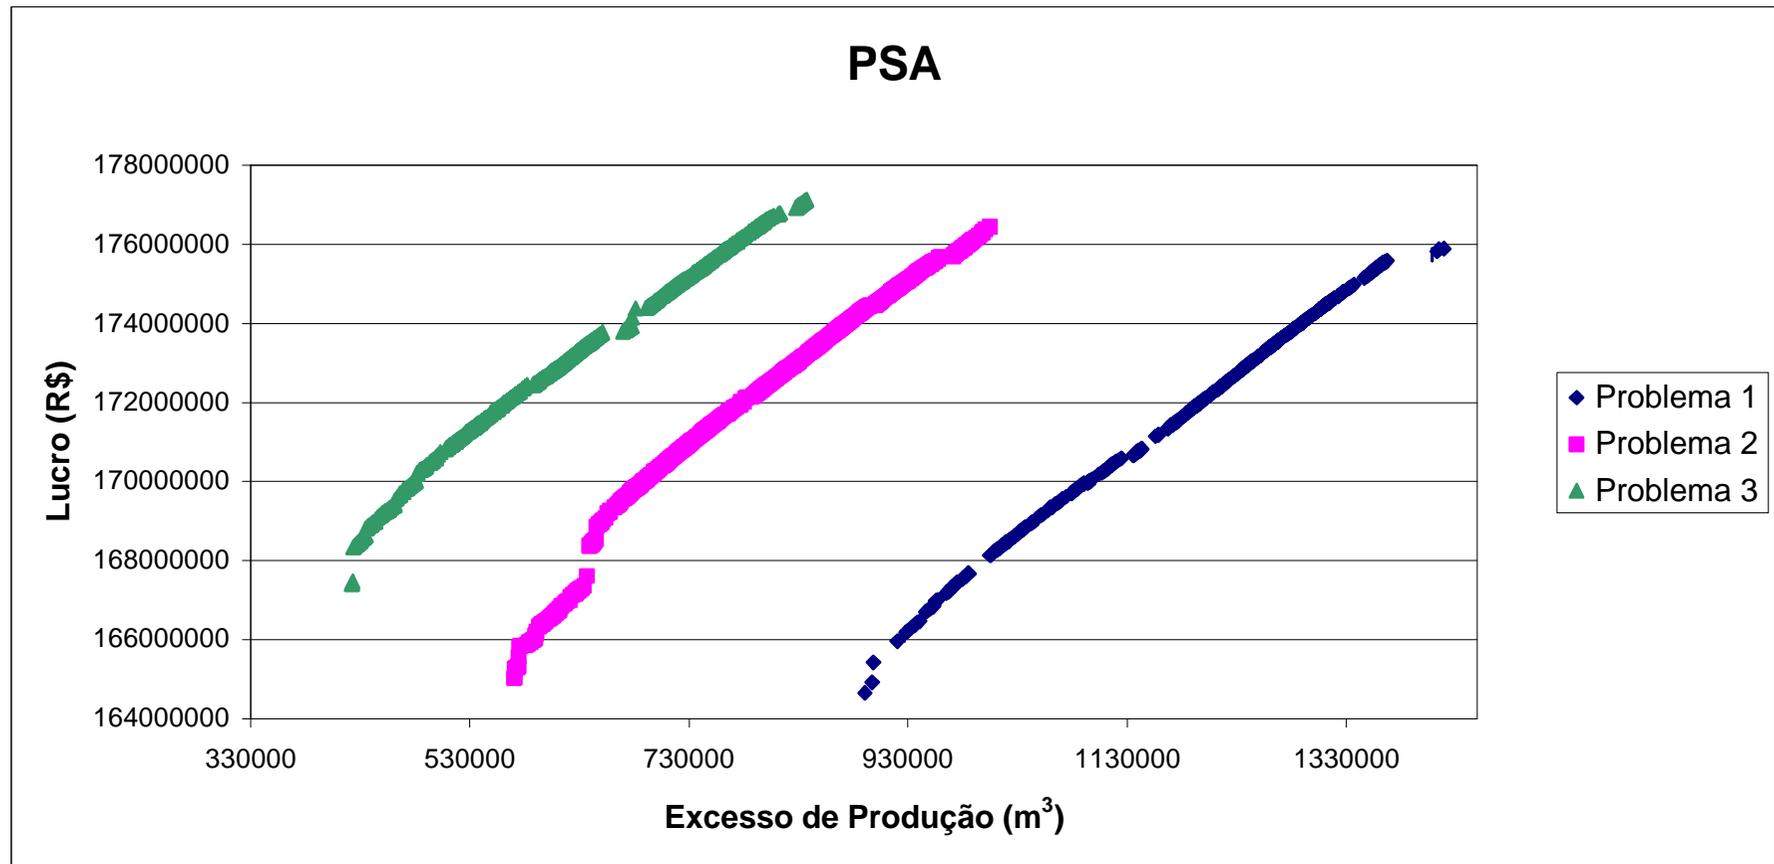


Figura 14 - Fronteira Pareto-Ótima construída pelo PSA, B&B e SPEA para o problema 1, 2 e 3 com dois objetivos

A Figura 14 ilustra o gráfico comparativo entre os problemas 1, 2 e 3 nos quais as fronteiras Pareto-ótimas são apresentadas. Pode-se observar que, para um mesmo excesso de produção, os maiores lucros foram alcançados no problema 3, seguido pelos problemas 2 e 1. Isto pode se explicado pelo fato do problema 3 apresentar uma demanda mínima anual superior às demandas dos problemas 2 e 1, resultando em um menor excedente na produção. De outra maneira, para um mesmo lucro, maiores excedentes de produção estão associados a demandas menores.

Uma vez que o CPLEX encontra uma solução para cada execução do algoritmo, percebe-se que há uma grande diferença entre os tempos do CPLEX e os do PSA e do SPEA, sendo que os mesmos fazem uma busca paralela por soluções. Também um grande tempo é despendido para a parametrização do problema para a entrada no CPLEX.

Apesar de obtidas eficácias semelhantes, o PSA mostrou-se extremamente eficiente em relação ao SPEA, principalmente para problemas onde as restrições são mais fortes.

4.2. Resultados para os problemas 1, 2 e 3 com três objetivos

Para os problemas 1, 2 e 3 com 3 objetivos (maximizar VPL, minimizar excesso de produção e maximizar mão-de-obra) foram feitas comparações apenas entre os algoritmos PSA e CPLEX, uma vez que o SPEA implementado por Teixeira (2002), não apresenta tal funcionalidade.

Utilizando-se da eficácia proposta por Rodrigues (2001), como mencionado na sessão 3.7, obtiveram-se os resultados apresentados no Quadro 18. Pode-se observar, através destes resultados, que o algoritmo PSA apresentou uma eficácia muito boa, ao se considerar a inclusão de mais um objetivo (maximizar a mão-de-obra).

Quadro 18 - Eficácia do PSA em relação ao CPLEX para o problema 1 com três objetivos

Região/Eficácia(%)	PSA
Inferior	97,64
Intermediário	97,83
Superior	97,04

A eficiência (tempo gasto) dos algoritmos PSA e *B&B* são apresentadas no Quadro 19. O número de soluções parametrizadas no CPLEX foi de 40, enquanto que o número de soluções encontradas pelo PSA foi de 800.

Quadro 19 - Tempo do PSA e CPLEX para o problema 1 com três objetivos

	PSA	CPLEX
Tempo total	18m 15s	65h 26m 24s
Tempo gasto para gerar as soluções iniciais	1m 28s	
Tempo gasto pelas iterações	16m 47s	
Número de soluções na população	2000	
Número de soluções no conjunto não-dominado	800	40
Número de iterações	150	

De acordo com o quadro acima, percebe-se que ao se incluir, no PSA, mais um objetivo em relação ao problema 1 com dois objetivos, não houve grande aumento do tempo de resolução, ao contrário do ocorrido no *B&B*. Para o problema 1, com dois objetivos, o PSA gastou-se 5 min e 38 seg enquanto que, para o mesmo problema com três objetivos, gastou um tempo de 18 min e 15 seg, representando um aumento de 223,97%. Já o CPLEX para o problema 1, com dois objetivos, consumiu 2h 39 min e 14 seg e para o problema 1, com três objetivos, gastaria 65h 26min.e 24seg. para serem achadas 40 soluções, correspondendo a um aumento de 2.465,81% ou seja um tempo 11 vezes superior ao PSA para resolver o mesmo problema, embora se reconheça que tais projeções de tempos estão associadas a soluções exatas.

Para o problema 2, com três objetivos, os resultados são apresentados nos Quadro 20 e 21, enquanto que, para o problema 3, com três objetivos, os resultados aparecem nos Quadro 22 e 23.

Quadro 20 - Eficácia do PSA em relação ao CPLEX para o problema 2 com três objetivos

Região/Eficácia(%)	PSA
Inferior	96,77
Intermediário	97,02
Superior	96,64

Quadro 21 - Tempo do PSA e CPLEX para o problema 2 com três objetivos

	PSA	CPLEX
Tempo total	33m 28s	72h 44m 35s
Tempo gasto para gerar as soluções iniciais	16m 22s	
Tempo gasto pelas iterações	17m 06s	
Número de soluções na população	2000	
Número de soluções no conjunto não-dominado	800	40
Número de iterações	150	

Quadro 22 - Eficácia do PSA em relação ao CPLEX para o problema 3 com três objetivos

Região/Eficácia(%)	PSA
Inferior	97,83
Intermediário	98,11
Superior	98,15

Quadro 23- Tempo do PSA e CPLEX para o problema 3 com três objetivos

	PSA	CPLEX
Tempo total	1h 31m 53s	67h 08m 51s
Tempo gasto para gerar as soluções iniciais	1h 15m 05s	
Tempo gasto pelas iterações	16m 48s	
Número de soluções na população	2000	
Número de soluções no conjunto não-dominado	800	10
Número de iterações	150	

Comparando-se a eficácia dos problemas 1, 2 e 3 com dois objetivos e dos problemas 1, 2 e 3, com três objetivos, percebe-se que há uma queda na qualidade das soluções do PSA, para estes últimos, em torno de 2%, fato este atribuído dificuldade de se encontrar soluções não-dominadas com três objetivos.

Nas Figura 15 e 16 é possível visualizar o impacto decorrente da inclusão de mais um objetivo, quando se usam os algoritmos PSA e CPLEX., respectivamente.

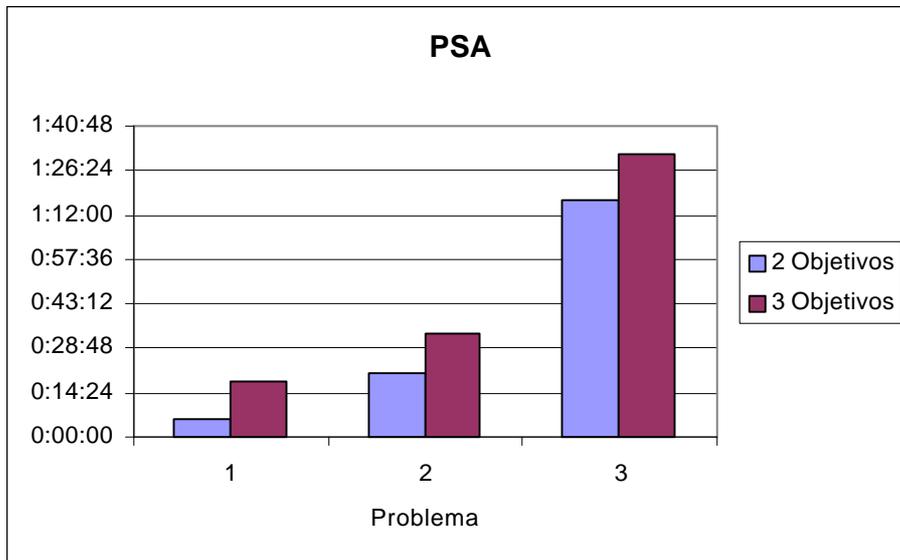


Figura 15 - Tempo de Execução do PSA para os problemas 1, 2 e 3 com dois e três objetivos

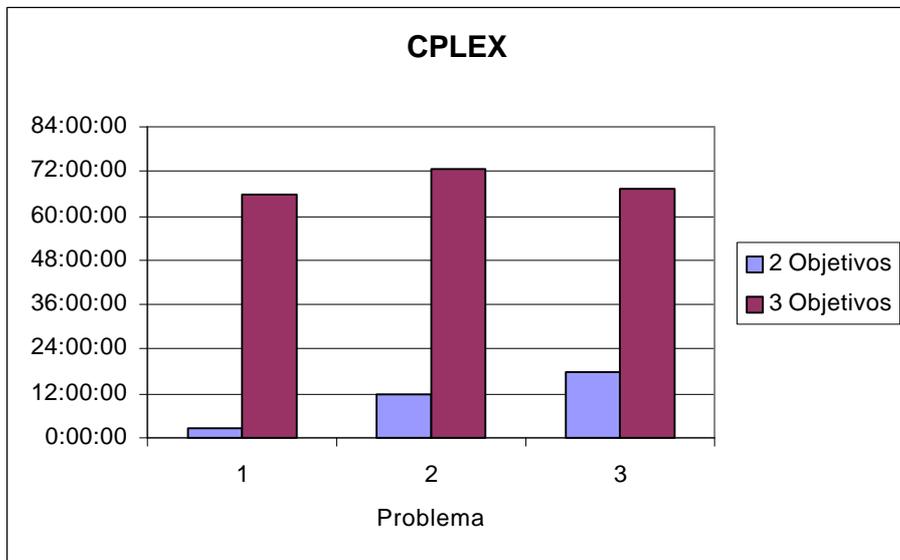


Figura 16 - Tempo de Execução do CPLEX para os problemas 1, 2 e 3 com dois e três objetivos

4.3. Resultados para os problemas 4 e 5

Os problemas 4 e 5 apresentam diferenças nas restrições. Enquanto que o problema 4 possui restrições de demanda mínima e capacidade máxima anual de reforma apresentadas no Quadro 7, o problema 5 só possui as restrições de demanda mínima. Com isso, é possível observar o impacto na eficiência e na eficácia do algoritmo com a inclusão de mais uma restrição.

Quadro 24- Eficácia do PSA e SPEA em relação ao CPLEX para o problema 4

Região/Eficácia(%)	PSA	SPEA
Inferior	99,60	98,54
Intermediário	99,68	98,66
Superior	99,70	98,17

Quadro 25- Eficiência do PSA em relação ao SPEA para o problema 4

	PSA	SPEA	CPLEX
Tempo total	54m 52s	20h 04m 35s	11h 54m 30s
Tempo gasto para gerar as soluções iniciais	35m 14s	11h 19m 35s	
Tempo gasto pelas iterações	19m 38s	08h 45m 00s	
Número de soluções na população	4000	4000	
Número de soluções no conjunto não-dominado	1600	1600	
Número de iterações	150	250	

Na Figura 17 é possível visualizar as fronteiras Pareto-ótimas construídas pelos três algoritmos. Para o algoritmo SPEA foram construídas duas fronteiras: a fronteira inferior foi construída pelo SPEA com um total de 150 gerações e, a outra, com 243 gerações. O SPEA não conseguiu completar a segunda execução, abordando a operação, possivelmente por falta de memória do sistema, chegando somente a 243 gerações, enquanto que o parâmetro de entrada era de 250 gerações. O SPEA só conseguiu encontrar 166 soluções Pareto-ótimas com 150 gerações e 261 com 243 gerações, enquanto que o PSA encontrou 1600 com 150 iterações.

Quando submetidos, os dois algoritmos PSA e SPEA, a um mesmo número de execuções, percebe-se que o PSA atinge a fronteira de forma mais eficiente e eficaz, observação esta constatada também para os problemas anteriores.

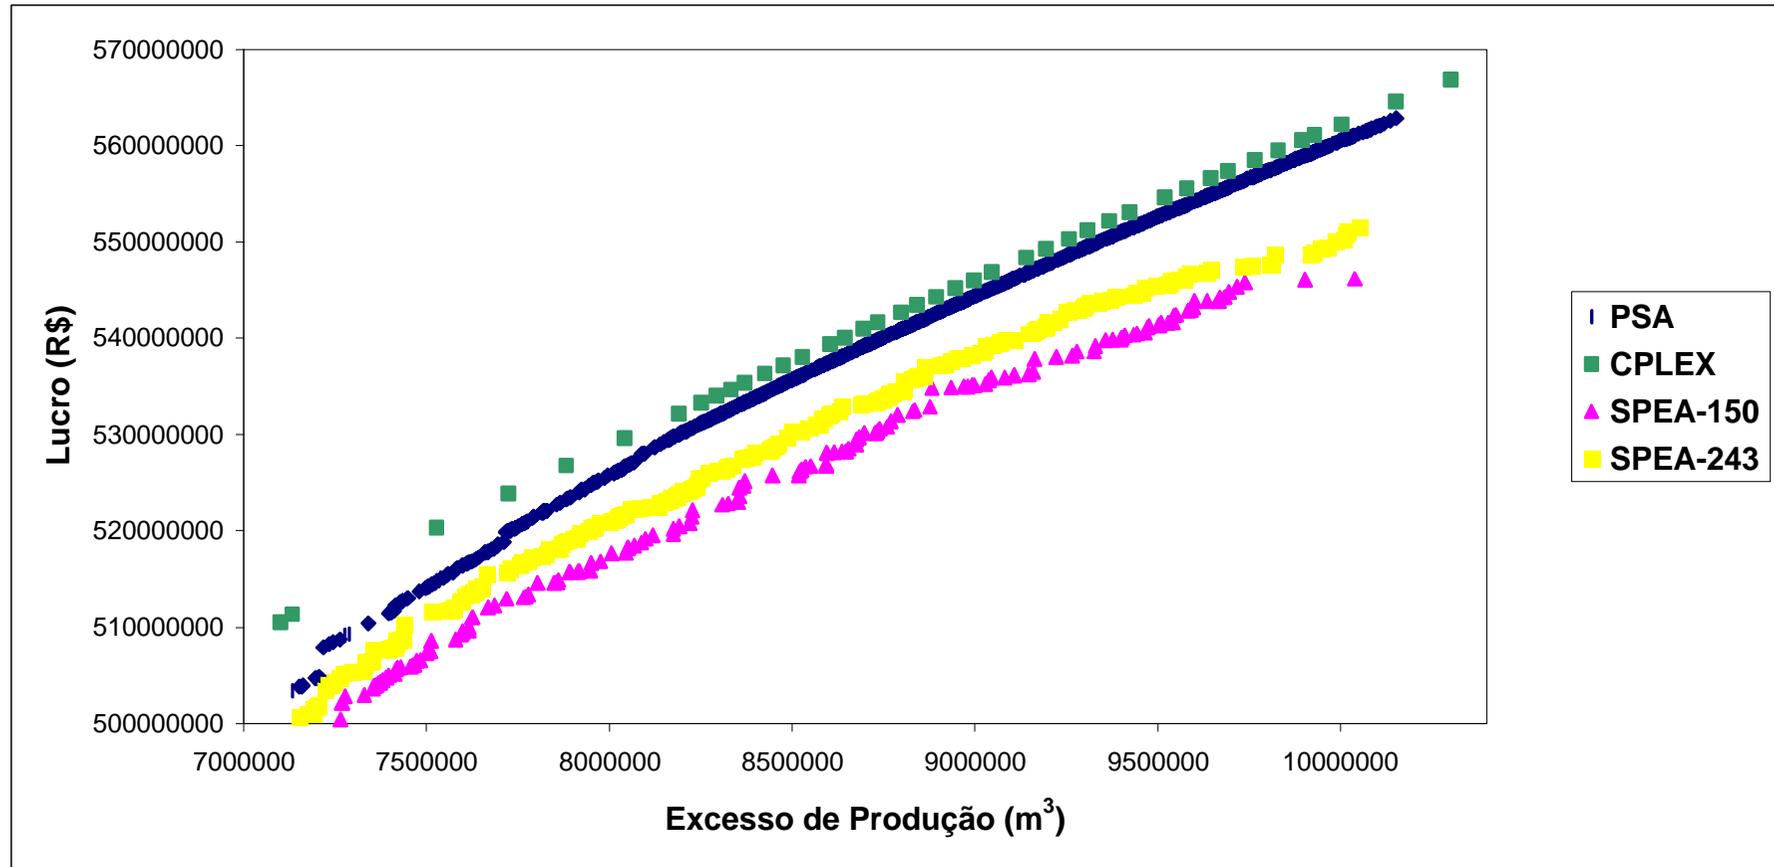


Figura 17 - Fronteira Pareto-Ótima construída pelo PSA, *B&B* e SPEA para o problema 4 com dois objetivos

Para o problema 5, os Quadros 26 e 27 apresentam sua eficácia e sua eficiência, respectivamente.

Quadro 26- Eficácia do PSA em relação ao CPLEX para o problema 5

Região/Eficácia(%)	PSA
Inferior	99,05
Intermediário	99,48
Superior	99,52

Quadro 27- Tempo do PSA em relação ao CPLEX para o problema 5

	PSA	CPLEX
Tempo total	23m 06s	46h 09m 59s
Tempo gasto para gerar as soluções iniciais	07m 07s	
Tempo gasto pelas iterações	15m 59s	
Número de soluções na população	4000	
Número de soluções no conjunto não-dominado	1600	
Número de iterações	150	

Apesar do problema 5 não incluir a restrição de capacidade de reforma imposta no problema 4, , nota-se que o tempo computacional para resolvê-lo foi bem superior ao problema 4, provavelmente devido à maior rigidez da restrição de demanda imposta no problema 5.

As eficácias, alcançadas pelos algoritmos nestes dois problemas, não diferiram significativamente, o que indica que a inclusão de restrições influencia mais diretamente a eficiência do algoritmo.

Como a restrição de demanda é mais forte no problema 5, para um mesmo lucro, obtêm-se menos excesso de produção, ou seja, maiores excedentes de produção estão associados a demandas menores (Figura 18).

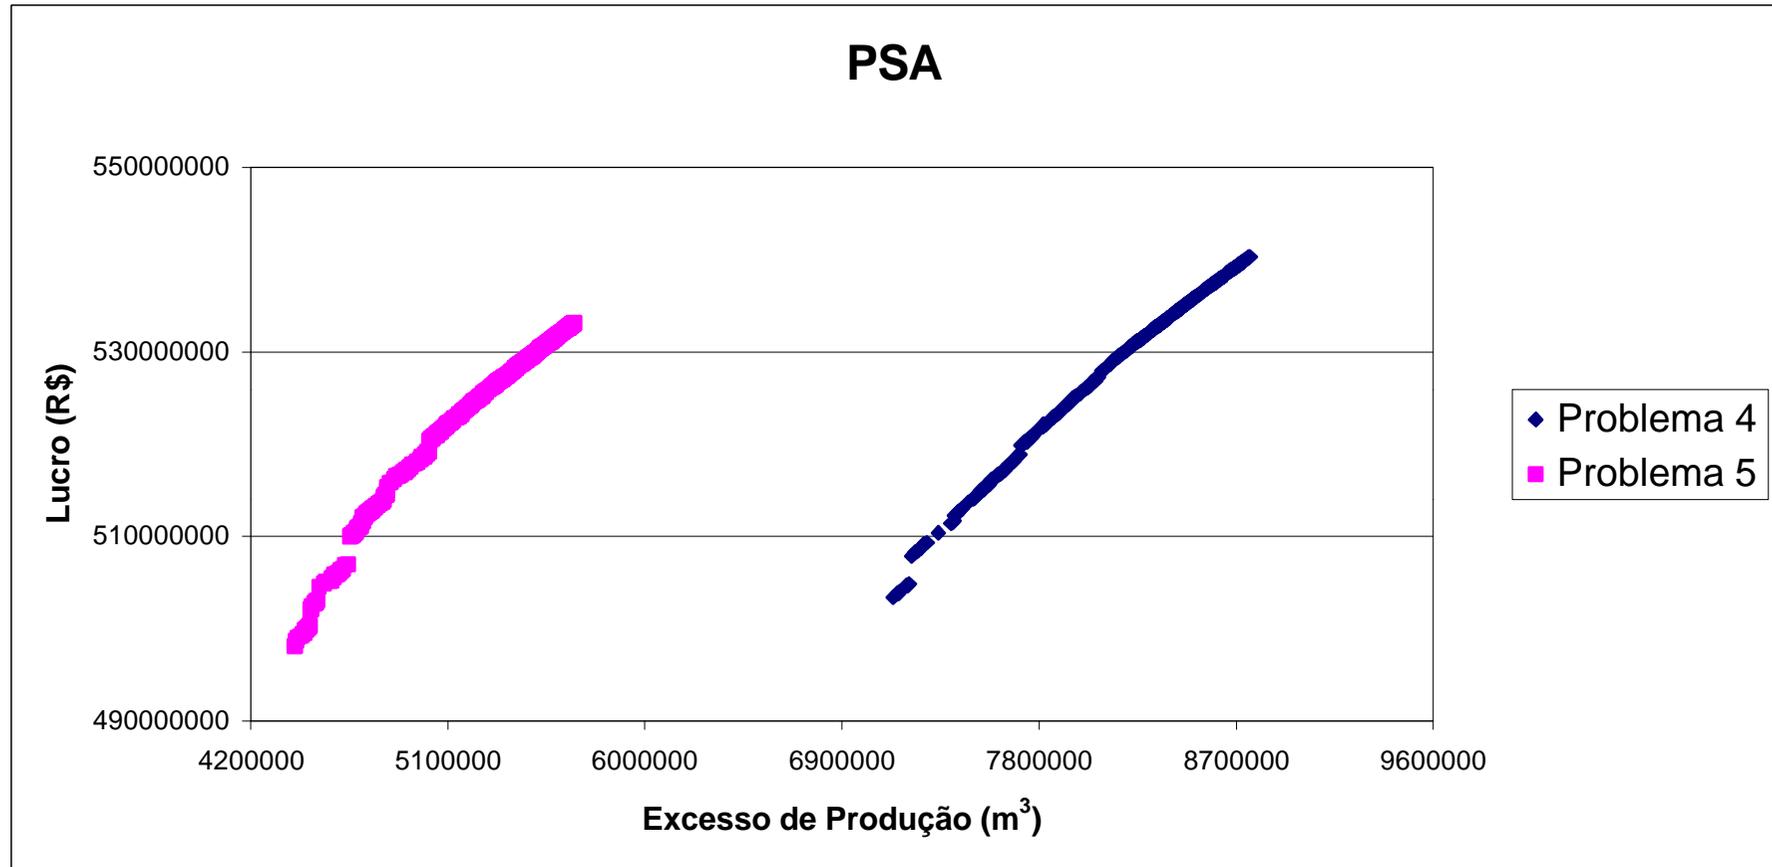


Figura 18 - Fronteira Pareto-Ótima construída pelo PSA, B&B e SPEA para o problema 4 e 5 com dois objetivos

4.4. Resultados para os problemas 6, 7, 8 e 9

Para os problemas 6, 7, 8 e 9 são usadas todas as unidades de produção vistas no Quadro 31, nos anexos, variando-se apenas o horizonte de planejamento e as demandas mínimas anuais, visando, com isso, aumentar o número de variáveis do problema, começando com 7.491 no problema 6 e chegando a 156.042 no problema 9.

Estes testes foram realizados para avaliar a performance e a eficácia do PSA com relação ao CPLEX possibilitando, assim, fazer uma análise da escalabilidade do PSA voltada para problemas de grande porte, comuns no meio florestal.

Para os problemas 6 foram parametrizadas 40 soluções no CPLEX, sendo que o tempo gasto para encontrar tais soluções foi de 22 horas e 40 minutos. Em nenhum problema excedeu-se o tempo limite de 5 horas, utilizado como parâmetro de entrada no CPLEX.

Todavia, na busca de solução exata para os problemas 7 e 8 excedeu-se o tempo de 5 horas, imposto como limite ao CPLEX, não sendo encontrada a solução ótima neste período. No problema 9, o tempo limite foi de 7 horas, que também foi excedido.

No problema 7 foram utilizadas 40 parametrizações, consumindo um tempo de 200 horas para encontrar todas as soluções, enquanto que nos problemas 8 e 9 utilizaram-se 20 parametrizações, gastando-se 100 horas para o problema 8 e 140 horas para o problema 9 para se obter suas soluções exatas.

Os resultados para os problemas 6, 7, 8 e 9 são visualizados nos Quadros 28, 29 e 30.

Quadro 28- Tempo do PSA em relação ao CPLEX para o problema 6 e 7

	Problema 6		Problema 7	
	PSA	CPLEX	PSA	CPLEX
Tempo total	1h 03m 43s	22h 24m	7h 42m 28s	200 h.*
Tempo gasto para gerar as soluções iniciais	06m 49s		13m 45s	
Tempo gasto pelas iterações	56m 54s		7h 28m 43s	
Número de soluções na população	8000		9000	
Número de soluções no conjunto não-dominado	2000		2500	
Número de iterações	150		700	
Número de soluções encontradas	1729	40	2500	

Quadro 29- Tempo do PSA em relação ao CPLEX para o problema 8 e 9

	Problema 8		Problema 9	
	PSA	CPLEX	PSA	CPLEX
Tempo total	9h 15m 45s	100 h.*	20h 02m 08s	140 h.*
Tempo gasto para gerar as soluções iniciais	42m 39s		2h 43m 07s	
Tempo gasto pelas iterações	8h 33m 06s		17h 19m 01s	
Número de soluções na população	10000		12000	
Número de soluções no conjunto não-dominado	3000		4000	
Número de iterações	700		250	
Número de soluções encontradas	3000		3251	

Quadro 30- Eficácia do PSA em relação ao CPLEX para o problema 6, 7, 8 e 9

Região/Eficácia(%)	Problema 6	Problema 7	Problema 8	Problema 9
Inferior	99,38%	98,99%	99,68%	99,27%
Intermediário	99,52%	98,63%	99,08%	98,84%
Superior	99,46%	97,64%	98,34%	97,89%

5. CONCLUSÕES

A metaheurística *Simulated Annealing* mostrou-se adequada para explorar o complexo espaço de soluções viáveis do modelo proposto para um problema de planejamento florestal multiobjetivo. Esta afirmação está fundamentada no uso de nove problemas testes, contendo entre 735 e 156.042 variáveis de decisão binárias (0-1), onde os objetivos foram: maximizar o valor presente líquido, minimizar o excesso de produção e maximizar o uso da mão-de-obra a ser empregada na floresta, sujeito a restrições de capacidade anual de reforma e de demanda anual mínima.

O algoritmo implementado, o PSA, teve o seu desempenho avaliado pela medida de eficácia expressa pela relação entre o valor da função objetivo encontrada pelo PSA e o ótimo obtido pelo algoritmo exato *Branch-and-Bound* contido no CPLEX.

Com base nos resultados obtidos, pode-se concluir que:

- Para os problemas com dois objetivos, até 25.000 variáveis binárias (0-1), a eficácia do PSA mostrou-se satisfatória com eficácia de 99,68% de aproximação. Quando se incorporou um terceiro objetivo a esses problemas, a melhor eficácia foi de 98,15%. Apesar desse declínio na eficácia, os resultados podem ser considerados satisfatórios, sendo que a diferença de tempo computacional para encontrar as soluções dos problemas com três objetivos, pelo PSA, foi pequena se comparada aos tempos gastos pelo algoritmo exato *Branch-and-Bound* implementado no CPLEX.
- Para os problemas com variáveis binárias (0-1) acima de 25.000, o CPLEX esgotou todos os tempos limites impostos em sua execução. Se fosse calculado todo o tempo gasto para encontrar o mesmo número de soluções obtidas pelo PSA, seria encontrado um tempo extremamente grande, algo inaceitável pelo TD que se encontra em um ambiente competitivo, onde a tomada de decisão deve ser feita com agilidade. A eficácia do PSA também foi menor para esses problemas, sendo justificada pelo tempo gasto na obtenção dessas soluções.
- A grande diferença observada, entre o tempo do PSA e do CPLEX, pode ser explicada pelo fato do PSA realizar busca múltipla de soluções, ao passo que o

CPLEX busca uma única solução de cada vez e esta deve ser exata. Outro inconveniente da busca de soluções pelo CPLEX é o trabalho manual despendido para a parametrização do problema. Além disso, o algoritmo *B&B* é um método exato enumerativo, ao passo que o PSA explora apenas um subconjunto de soluções do problema.

- O tempo de processamento do algoritmo PSA foi muito inferior ao do SPEA (cerca de quatorze vezes menor neste trabalho) e praticamente incomparável com o tempo gasto pelo método exato.
- Os problemas mais relaxados, ou seja, aqueles com apenas uma restrição ou demandas menores, apresentam uma maior eficiência na busca; contudo, esta relaxação de restrições pode levar a soluções que não atendam às reais necessidades do tomador de decisão (TD) como, por exemplo, atendimento da demanda anual.
- Um dos problemas encontrados pelo SPEA, que é a geração da população inicial, causadora de um baixo desempenho do algoritmo, foi contornado pelo PSA, devido às estruturas de dados utilizadas pelo mesmo. As estruturas de dados utilizadas no PSA foram decisivas para seu ótimo desempenho em relação ao SPEA. Procurou-se utilizar estruturas dinâmicas, criadas em tempo de execução, possibilitando um melhor gerenciamento e otimizando o uso de memória do sistema operacional.
- Finalmente, pode-se concluir que os objetivos do trabalho foram alcançados. Dada a natureza combinatória e o porte dos problemas reais, percebe-se a necessidade de tratamentos heurísticos na busca de soluções eficientes pertencentes à fronteira Pareto-ótima.
- Como futuras pesquisas, é sugerida uma maior interação com o TD, tanto na definição dos parâmetros para a geração da população inicial, quanto no processo de evolução das iterações, onde o mesmo terá a oportunidade de expressar seus gostos e preferências, gerando assim uma fronteira Pareto-Ótima mais direcionada, com menos soluções alternativas e, provavelmente, com um menor custo computacional.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- [Back, 1996] Back, T. *Evolutionary Algorithms in theory and practice*. Oxford University Press, New York.
- [Baskent e Jordan, 2002] Baskent, E.Z.; Jordan, G.A. Forest landscape management modeling using simulated annealing. In: *Forest Ecology and Management* 165, p. 29-45, 2002.
- [Bleuler et al., 2003] Bleuler, S.; Laumanns, M.; Thiele, L.; Zitzler, E. PISA-A platform and programming language independent interface for search algorithms, In: Carlos M. Fonseca, Peter J. Fleming, Eckart Zitzler, Kalyanmoy Deb and Lothar Thiele (editors), *Evolutionary Multi-Criterion Optimization. Second International Conference, EMO 2003*, Springer. *Lecture Notes in Computer Science*, Faro, Portugal, v. 2632, p. 494-508, 2003.
- [Boston e Bettinger, 1999] Boston, K.; Bettinger, P. An analysis of Monte Carlo integer programming, Simulated Annealing, and Tabu Search heuristics for solving spatial harvest scheduling problems. *Forest Science*, Washington, v. 45 n. 2, p. 292-301, 1999.
- [Cerny, 1985] Cerny, V. Thermodynamical approach to the traveling salesman problem: an efficient simulation algorithm. *Journal of Optimization Theory and Application*, v. 45 n. 1, p. 41-51, 1985.
- [Clutter et al., 1983] Clutter, J.L. et al. *Timber Management: A quantitative approach*. New York, John Wiley & Sons, 1983. 333p.
- [Coello, 1999] Coello, C. A. C. An updated survey of GA-Based multiobjective optimization techniques: state of the art and future trends. In *Congress on Evolutionary Computation (CEC99)*, IEEE, v. 1, p. 3-13, 1999.
- [Coello, 2001] Coello, C. A. C. A short tutorial on evolutionary multiobjective optimization. In: Eckart Zitzler, Kalyanmoy Deb, Lothar Thiele, Carlos A. Coello Coello, and David Corne, editors, *First International Conference on Evolutionary Multi-Criterion Optimization*, Springer-Verlag, *Lecture Notes in Computer Science* No. 1993, p. 21-40. 2001.
- [Coello, 2002] Coello, C. A. C.; Cortés, N. C. An approach to solve multiobjective optimization problems based on an artificial immune system. In: Jonathan Timmis and Peter J. Bentley (editors), *First International Conference on Artificial Immune Systems (ICARIS'2002)*, University of Kent at Canterbury, Inglaterra, p. 212-221, 2002.

- [Esquivel et al., 1999] Esquivel S.; Leiva H.; Gallard R. Multiplicity in genetic algorithms to face multicriteria optimization, Proceedings of the 1999 Congress on Evolutionary Computation (IEEE). Washington DC, p 85-90. 1999.
- [Fatureto, 1997] Fatureto, C.R.C. *Otimização sob critérios múltiplos: metodologias e uma aplicação para o planejamento agrícola*. 1997. 145f. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, MG, 1997.
- [Fonseca e Fleming, 1993] Fonseca, C. M.; Fleming, P. J. Genetic Algorithms for multiobjective optimization: Formulation, Discussion and Generalization. In: Forrest, S. (editor), Proceedings of the Fifth International Conference on Genetic Algorithms, University of Illinois at Urbana-champaign, Morgan Kauffman Publishers. San Mateo, California, p. 416-423, 1993.
- [Fonseca, 1995] Fonseca, C. M. Multiobjective Genetic Algorithms with application to control engineering problems. Ph.D. thesis, Department of Automatic Control and Systems Engineering, University of Sheffield, 1995.
- [Fonseca e Fleming, 1995] Fonseca, C. M.; Fleming, P. J. An overview of evolutionary algorithms in multiobjective optimization. *Evolutionary Computation*, v.3 n. 1, p. 1-16, 1995.
- [Horn, 1997] Horn, J. Multicriteria Decision Making. In: Bäck, T.; Fogel, D. B.; Michalewicz, Z. (editores), *Handbook of Evolutionary Computation.*, Oxford University Press, Oxford, England, v. 1, p: F1.9:1 – F1.9:15, 1997.
- [Ignacio et al, 2000] Ignacio, A.A.V.; Ferreira Filho, V.J.M.; Galvão, R.D. Métodos heurísticos num entorno paralelo. In: Simpósio Brasileiro de Pesquisa Operacional, 32, 2000, Viçosa. Anais. Viçosa: Ufv, p. 769-788, 2000.
- [Jaszkiewicz et al., 1994] Jaszkiewicz, A.; Czyak, P.; Hapke M. Application of the Pareto-Simulated Annealing to the multiple criteria shortest path problem, Technical Report, Institute of Computing Science, Poznan University of Technology, 94/03 1994.
- [Jaszkiewicz e Czyak, 1995] Jaszkiewicz, A.; Czyak, P. A metaheuristic procedure for multiple objective combinatorial optimization problems, (in Polish), In: R. Kulikowski, L. Bogdan (eds.), Decision support. Expert systems, Instytut Bada Systemowych PAN, Warszawa, p. 85-94, 1995.
- [Jaszkiewicz e Czyak, 1995a] Jaszkiewicz, A.; Czyak, P. Pareto Simulated Annealing. Computational experiment, (in Polish), Technical Report, Institute of Computing Science, Poznan University of Technology, 003/95, 1995.

- [Jaszkiewicz e Czyak, 1996] Jaszkiewicz, A.; Czyak, P. A multiobjective metaheuristic approach to the localization of a chain of petrol stations by the capital budgeting model, *Control and Cybernetics*, v. 25, n. 1, p. 177-87, 1996.
- [Jaszkiewicz e Czyak, 1997] Jaszkiewicz, A.; Czyak, P. Pareto Simulated Annealing, In: G. Fandel, T. Gal (eds.), *Multiple Criteria Decision Making. Proceedings of the XIIth International Conference*, Hagen (Germany), Springer, Berlin, p. 297-307, 1997.
- [Jaszkiewicz e Czyak, 1997a] Jaszkiewicz, A.; Czyak, P. The Multiobjective metaheuristic approach for optimization of complex manufacturing systems, In: G. Fandel, T. Gal (eds.), *Multiple Criteria Decision Making. Proceedings of the XIIth International Conference*, Hagen (Germany), Springer, Berlin, p. 591-592, 1997.
- [Jaszkiewicz, 2001] Jaszkiewicz, A. Multiple objective metaheuristic algorithms for combinatorial optimization. 2001. 360f. Habilitation thesis, Poznan University of Technology, Poznam, 2001.
- [Johnson e Scheurman, 1977] Johnson, K.N.; Scheurman, H.L. Techniques for prescribing optimal timber harvest and investment under different objectives - Discussion and Synthesis. *Forest Science Monograph*, USA, n.18, 1977.
- [Kirkpatrick et al., 1983] Kirkpatrick Jr., S.; Gelatt, C.; Vecchi, M. Optimization by simulated annealing. *Decision Science* 220(4598), p. 498-516, 1983.
- [Laarhoven e Aarts , 1987] Laarhoven P.J.M. Aarts E.H.L. *Simulated Annealing: theory and applications*, Reidel, Dordrecht, 1987.
- [Leite, 1994] Leite, H.G. *Conversão de troncos em multiprodutos da madeira, utilizando programação dinâmica*. 1994. 230f. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, MG, 1994.
- [Leuschner, 1984] Leuschner, W. A. *Introduction to forest resource management*. New York: John Willey & Sons, 298p, 1984.
- [Metropolis et al, 1953] Metropolis, N. et al. Equation of state calculations by fast computing machines. *J. Chem. Phys.* v. 21, p. 1087-1092, 1953.
- [Newman, 1988] Newman, D.H. The optimal forest rotation: a discussion and annotated bibliography. *General Technical Report*, Washington, v.90, n.48, p.1-47, 1988.
- [Nobre, 1999] Nobre, S.R. *A heurística da Razão-R aplicada a problemas de gestão florestal*. 1998. 98f. Dissertação (Mestrado), Universidade Federal de Lavras, Lavras, MG, 1999.

- [Oliveira, 2003] Oliveira, F.; Volpi, N. M. P.; Sanquetta, C. R. Goal programming in a planning problem”, *Applied Mathematics and Computation*, v. 140, Issue 1, p.165-178,2003.
- [Osyczka, 1985] Osyczka, A., Multicriteria optimization for engineering design. In: Gero, J. S. (editor), *Design optimization*, Academic Press, p. 193-227, 1985.
- [Paivinen, 1996] Paivinen, R. Large-scale forestry scenario models – where are we? In: *International Seminar Large-Scale Forestry Scenario Models: Experiences And Requirements*, Joensuu-Finlândia. Proceedings... Joensuu-Finlândia: European Forest Institute, n. 5, p.5-14, 1996.
- [Rezende e Oliveira, 1993] Rezende, J.P.L.; Oliveira, A.D. Avaliação de projetos florestais. Viçosa, Minas Gerais: Imprensa Universitária, UFV 1993. 49p. Universidade Federal de Viçosa, 237.
- [Rodrigues, 2001] Rodrigues, F.L., *Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais*. 2001. 255p. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, MG, 2001.
- [Rodriguez et al., 1996] Rodriguez, L.C.E., Batista, J.L.F., Couto, H.T.Z. Técnicas e modelos quantitativos de suporte à decisão florestal – Programa de reciclagem em métodos quantitativos. ESALQ-USP-IPEF, Piracicaba, 21p., 1996.
- [Scolforo, 1997] Scolforo, J.R.S. Manejo florestal. Lavras, UFLA-FAEPE, 438p., 1997.
- [Serafini, 1992] Serafini P., Simulated annealing for multiple objective optimization problems, in: *Proceedings of the Tenth International Conference on Multiple Criteria Decision Making*, Taipei 19-24.07, vol. 1, p. 87-96, 1992.
- [Serafini, 1994] Serafini P. Simulated annealing for multiple objective optimization problems, In: G.H. Tzeng, H.F. Wang, V.P. Wen, P.L. Yu (eds.), *Multiple Criteria Decision Making. Expand and Enrich the Domains of Thinking and Application*, Springer, Berlin, p. 283-292, 1994.
- [Silva, 2001] Silva, G.F., *Problemas no uso de programação matemática e simulação em regulação florestal*. 2001. 89f. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, MG, 2001.
- [Silva, 2001a] Silva, J.T.M., *Tomada de decisão sob critérios múltiplos: Uma aplicação ao projeto de irrigação do Jaíba*. 2001. 198f. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, MG, 2001.

- [Silva Jr, 1993] Silva Jr, A.G., *Sistema de suporte a decisão integrado a sistemas especialistas: uma aplicação para gerenciamento de fazendas produtoras de leite*. 1993. 94p. Dissertação (Mestrado), Universidade Federal de Viçosa, Viçosa, MG, 1993.
- [Souza e Moccellini, 2000] Souza, A.B.D.; Moccellini, J.V. Metaheurística híbrida algoritmo genético-busca tabu para programação de operações flow shop. In: Simpósio Brasileiro de Pesquisa Operacional, 32, 2000, Viçosa. Anais. Viçosa: UFV, 2000. p314-324.
- [Steuer, 1986] Steuer, R. E. *Multiple Criteria Optimization: Theory, Computation, and Applications*. New York: Wiley, 1986.
- [Teixeira, 2002] Teixeira, A.F., *Aplicação de algoritmos evolucionários na solução de problemas de planejamento florestal multiobjetivo*. 2002. 72f. Dissertação (Mestrado), Universidade Federal de Belo Horizonte, Belo Horizonte, MG, 2002.
- [Ulungu et al., 1999] Ulungu E.L. et al. *MOSA method: a tool for solving multiobjective combinatorial optimization problems*, Journal of Multi-Criteria Decision Analysis, v. 8, p. 221-236, 1999.
- [Van Veldhuizen e Lamont, 2000] Van Veldhuizen, D. A., Lamont, G. B., Multiobjective evolutionary algorithms: analyzing the state-of-the-art. *Evolutionary Computation*, v. 8 n. 2, p.125-147, 2000.
- [Youssef et al., 2001] Youssef, H.; Sait, S.M.; Adiche, H. Evolutionary algorithms, simulated annealing and tabu search: a comparative study. *Engineering Applications of Artificial Intelligence*, V. 14, p. 167-181, 2001.
- [Zitzler e Thiele, 1998] Zitzler, E.; Thiele, L. *An Evolutionary algorithms for multiobjective optimization: The strength pareto approach*. Computer Engineering and Communication Networks Lab N° 43, Swiss Federal Institute of Technology, 1998.
- [Zitzler, 1999] Zitzler, E. *Evolutionary algorithms for multiobjective optimization: methods and applications*. Ph.D. thesis, Swiss Federal Institute of Technology Zurich, 1999.
- [Zitzler, 2002] Zitzler, E. Evolutionary algorithms for multiobjective optimization. Evolutionary methods for design, optimisation, and control, CIMNE, Barcelona, Spain, p. 19-26, 2002.

Anexos

Quadro 31 - Dados relativos às unidades de produção, com suas respectivas áreas e idade.

Unidades de Produção	Idade Atual (anos)	Área (há)	Unidades de Produção	Idade Atual (anos)	Área (ha)
1	5	51.96	76	1	115.7
2	6	341.9	77	2	1267.9
3	3	33.51	78	3	568.1
4	2	402.19	79	4	33.7
5	1	323.52	80	5	174.8
6	0	985.26	81	0	229.5
7	6	369.1	82	1	868.4
8	7	612	83	2	1059.5
9	5	333.9	84	3	22.5
10	4	1474.8	85	4	1611.9
11	3	940.5	86	5	284.1
12	2	1598.2	87	0	959.1
13	1	470.4	88	1	214.6
14	0	314.8	89	2	553.9
15	8	622.3	90	3	158.6
16	0	462.6	91	4	196.9
17	4	466.2	92	5	217.8
18	2	234.8	93	1	654.4
19	6	648.4	94	6	450.1
20	8	363.6	95	5	750.3
21	6	1566.1	96	3	1250.4
22	1	1301	97	1	400.3
23	2	1251.6	98	4	550.5
24	3	703.2	99	3	315
25	4	211.2	100	7	450
26	0	107.2	101	7	899.5
27	1	439	102	1	775.4
28	2	542.5	103	3	456.4
29	3	143.3	104	0	265.4
30	5	1124.2	105	2	340.4
31	0	288.7	106	2	702.5
32	1	400.8	107	1	226.3
33	2	51.7	108	2	575.9
34	2	8.9	109	4	432
35	3	1151	110	0	98.4
36	4	703.6	111	1	205.1
37	5	131.4	112	3	113.7
38	6	225.7	113	2	217.3
39	0	153.9	114	1	655.1
40	1	40.8	115	3	76.1
41	1	334.7	116	4	8.6
42	2	77.4	117	5	405.3
43	3	99.8	118	0	574.3
44	4	128.9	119	2	416.4
45	5	426.4	120	4	78.2

46	0	8.3	121	2	255.2
47	1	852.2	122	1	1075.2
48	2	481.1	123	3	1003.2
49	3	3.6	124	4	434.1
50	3	76.1	125	0	1155.2
51	4	8.6	126	2	984.9
52	4	638.9	127	4	485.8
53	5	105.2	128	0	420.5
54	6	699.4	129	2	900.9
55	0	99.2	130	4	100.8
56	1	1049.4	131	0	269.5
57	2	408.1	132	2	1022
58	3	432.5	133	4	1284
59	4	65.3	134	0	429.2
60	4	152.2	135	2	359
61	5	147.1	136	2	30
62	0	426.2	137	3	542.1
63	1	1125.3	138	2	231.5
64	2	1000.7	139	2	202.3
65	3	16.9	140	2	376.5
66	3	2077.3	141	0	499.3
67	4	434.1	142	5	468.9
68	5	1585.4	143	6	355.3
69	0	1563.5	144	5	439.1
70	1	896.8	145	2	754.8
71	2	1484.9	146	2	849.4
72	3	464	147	2	1408.1
73	4	403.8	148	2	472.9
74	5	556.1	149	4	214.8
75	0	720.5	150	6	352.2

Quadro 32- Exemplo de algumas prescrições geradas para os problema 1, 2 e 3.

UP	Presc.	Cortes	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6	7	8	VPL (R\$)	Custos (R\$)	Mão-de-obra (ho)
1	1	5 5			x					r						r				296514,10	400583,40	207.8
1	2				x					c						c				395611,80	301485,60	103.9
1	3				x					c						r				349846,70	347250,70	155.9
1	4	5 6			x					r							r			354817,80	418761,30	207.8
1	5				x					c							c			455284,50	318294,60	103.9
1	6				x					c							r			408150,40	365428,60	155.9
1	7	5 7			x					r								r		400740,40	432703,20	207.8
1	8				x					c								c		502005,40	331438,20	103.9
1	9				x					c								r		454073,10	379370,50	155.9
1	10	5 8			x					r								r		402667,70	431309,80	207.8
1	11				x					c								c		502492,20	331485,30	103.9
1	12				x					c								r		456000,40	377977,10	155.9
1	13	6 5			x							r					r			361820,20	418306,30	207.8
1	14				x							c						c		459218,10	320908,40	103.9
1	15				x							c						r		415632,30	364494,20	155.9
1	16	6 6			x							r						r		417347,50	435618,60	207.8
1	17				x							c						c		516049,20	336916,90	103.9
1	18				x							c						r		471159,60	381806,50	155.9
1	19	6 7			x							r						r		461083,40	448896,50	207.8
1	20				x							c						c		560545,20	349434,70	103.9
1	21				x							c						r		514895,50	395084,50	155.9
1	22	7 5			x								r					r		411758,20	430883,60	207.8
1	23				x									c				c		507107,00	335534,80	103.9
1	24				x									c				r		465596,70	377045,10	155.9
1	25	7 6			x								r					r		464641,40	447371,50	207.8
1	26				x									c				c		561231,90	350781,00	103.9
1	27				x									c				r		518479,90	393533,00	155.9
1	28	8 5			x										r			r		405958,80	424137,30	207.8
1	29				x										c			c		497483,50	332612,50	103.9
1	30				x										c			r		457950,00	372146,10	155.9
2	1	6 5			x							r						r		2476409,10	2913535,20	1367.6
2	2				x							c						c		3149337,40	2240606,90	683.8
2	3				x							c						r		2848200,30	2541744,00	1025.7
2	4	6 6			x							r						r		2860051,00	3033146,90	1367.6
2	5				x							c						c		3541987,20	2351210,70	683.8
2	6				x							c						r		3231842,20	2661355,70	1025.7