

# BUSCA LOCAL ITERATIVA PARA UM PROBLEMA DE PLANEJAMENTO FLORESTAL MULTIOBJETIVO

#### Antonio Almeida de Barros Junior

Departamento de Informática - Universidade Federal de Viçosa Caixa Postal 216 – 36.570-000 – Viçosa – MG – Brasil antonioabj@gmail.com

## José Elias Claudio Arroyo

Departamento de Informática - Universidade Federal de Viçosa Caixa Postal 216 – 36.570-000 – Viçosa – MG – Brasil jarroyo@dpi.ufv.br

#### **RESUMO**

Neste artigo é abordado um Problema de Planejamento Florestal (PF) que visa a obtenção de um determinado plano de manejo para o plantio e colheita de madeira. O problema tem dois objetivos, a maximização do Valor Presente Líquido (VPL) e a minimização do Excesso de Produção. Para resolver o problema é proposta uma adaptação da heurística ILS (*Iterated Local Search*). O desempenho da heurística é testado em um conjunto de 30 problemas gerados com base a dados reais. Os resultados da heurística são comparados com soluções encontradas pelo Algoritmo Genético multiobjetivo SPEA da literatura. O bom desempenho da heurística ILS mostra o seu enorme potencial para resolver o problema de PF abordado neste trabalho.

PALAVRAS CHAVE. Planejamento Florestal. ILS. SPEA. MH – Metaheurísticas

#### **ABSTRACT**

This paper investigates a Forestry Planning problem (PF) and aims at obtaining a specific management plan for the planting and harvesting of timber. The problem has two objectives, the maximization of Net Present Value (NPV) and the minimization of Production Excess. To solve the problem we propose an adaptation of heuristic ILS (*Iterated Local Search*). The performance of the heuristic is tested on a set of 30 problems generate by having real data as its base. The results are compared with the heuristic solutions found by the multiobjective genetic algorithm, SPEA literature. The good performance achieved by the ILS heuristic shows its enormous potential to solve the FP problem approached in this work.

**KEYWORDS.** Florest Management. ILS. SPEA. MH - Metaheuristics.



#### 1. Introdução

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

Explorado por empresas florestais, esse setor também, contribui para o meio ambiente por manter o equilíbrio dos ecossistemas naturais; regular o clima global; conservar os recursos hídricos; proteger a biodiversidade e os ecossistemas florestais; fixação de carbono; reduzir o nível de desmatamento ilegal e o impacto sobre as florestas nativas através das florestas plantadas; regularizar os fluxos de água para evitar erosão. Além disso, é uma fonte de biodiversidade e de contribuição para sua manutenção (ABIMCI, 2007).

Dados recentes da Associação Brasileira dos Produtores de Florestas Plantadas (ABRAF, 2009) mostram que, as áreas de novos plantios aumentaram em 6,5% em 2008 (187,4 mil ha), quando comparado com 2007 (175,9 mil ha). As áreas de reforma, por sua vez, cresceram 7,6% em 2008 em relação ao ano anterior, passando de 185,8 mil ha para 199,9 mil ha. A condução de rebrota, nas empresas associadas da ABRAF, cresceu de 2,9 mil ha em 2007 para 19,0 mil ha em 2008. Estes dados mostram que cada vez mais, engenheiros florestais têm em suas mãos novas áreas para planejar e tomar decisões.

Em virtude da existência e interação de inúmeros e complexos fatores técnicos, econômicos e ambientais que interferem de forma dinâmica nas operações da colheita, há de se considerar que o planejamento é essencial para a identificação, previsão e controle dos aspectos adversos e com a antecedência devida. Fatores como: quando, onde e como realizar a colheita de madeira, satisfazendo as exigências dos consumidores são fatores relacionados às decisões táticas (Weintraub et al.,1994; Malinovski, 2007). A complexidade dos problemas envolvidos no planejamento florestal justificam a necessidade do uso de Sistemas de Suporte à Decisão (SSD).

Dentre as diversas ferramentas matemáticas aplicadas com o objetivo de otimizar o planejamento da produção florestal, as técnicas de Programação Linear e Inteira (PLI) constituem, sem dúvida, o instrumental analítico mais utilizado. Exemplos de uso desses modelos podem ser encontrados em Steuer e Schuler (1978), em Clutter et al. (1983), em Rodriguez et al. (1985), e em Laroze (1999), dentre outros. Por outro lado, de acordo com Fatureto e Santos (1999a; 1999b) e Silva et al. (2003) as técnicas de PLI quando aplicadas a este tipo de problema apresentam algumas deficiências, tais como as pressuposições de que o relacionamento entre as variáveis consideradas são lineares e as restrições devem ser estritamente respeitadas.

Neste contexto, é relevante a busca de novos métodos na tentativa de solucionar o problema do planejamento florestal. Atualmente, existem muitas técnicas heurísticas disponíveis para a solução de problemas combinatórios, incluindo desde heurísticas menos convencionais até as chamadas metaheurísticas. Exemplos destes métodos podem ser vistos em Teixeira (2003) que utilizou Algoritmos Evolucionários para problemas multiobjetivo, Rodrigues (2003) que utilizou a Busca Tabu, Pereira (2003) e Rodrigues (2004) fizeram uso do *Pareto Simulated Annealing* (PSA) e *Simulated Annealing* respectivamente. Mais recentemente, no trabalho de Barros Junior et al. (2009) foi proposto o uso da heurística *Greedy Randomized Adaptative Search Procedures* (GRASP).

O presente trabalho tem como objetivo principal, examinar a aplicabilidade e comparar a eficiência das heurísticas *Iterated Local Search* (ILS) e *Strength Pareto Evolutionary Algorithm* (SPEA) sob dois objetivos, como uma ferramenta de otimização no processo de tomada de decisão para o planejamento da produção florestal.

## 2. Definição e Modelagem do Problema

De acordo com Nobre (1999), o problema básico de manejo florestal consiste em elaborar um planejamento 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 dificil solução principalmente devido ao grande número de variáveis envolvidas, e a natureza combinatória do problema quando impostas restrições espaciais e de integridade sobre as unidades de manejo. 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 problema.

O modelo de planejamento empregado neste trabalho, foi proposto originalmente por Kidd et al. (1966), citado por Dykstra (1984), mas que recebeu essa denominação de Johnson & Scheurman (1977). Para Nobre (1999), citando Clutter et al. (1983), no modelo, cada variável de decisão representa uma seqüência única de intervenções programadas para uma unidade de produção. De acordo com este modelo, tem-se que:

- As variáveis de decisão correspondem à escolha 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.

Também foi utilizado neste trabalho, um sistema de otimização denominado de Gerador de Prescrições (Figura 1) e que teve como base o protótipo proposto no trabalho de Teixeira (2002). Considera-se como Prescrição, cada Alternativa de Manejo (AM) em uma Unidade de Produção (UP) ou talhão. As várias alternativas são obtidas combinando idades de corte, opções de reforma da floresta, desbastes ou condução de brotação e quaisquer outras características que se queira. É importante ressaltar que uma fazenda é dividida em diversas UP's onde podem existir centenas de AM's diferentes. Visto que as prescrições representam sequências preestabelecidas de ações que ocorrerão ao longo do período de planejamento, numa dada unidade de manejo. No exemplo da Figura 1, observa-se que foram geradas 10 prescrições para a UP 1. A primeira (segunda) prescrição representa uma alternativa de manejo onde a UP sofrerá duas reformas (conduções) representadas pela letra "r" (representadas pela letra "c"), ambas com 5 anos de idade. O ano 0 representa o ano corrente, o que mostra que a UP 1 foi plantada a 5 anos atrás, representado pela letra "x" no ano -5. Cabe ao método heurístico, encontrar a melhor prescrição para cada unidade de produção, considerando as limitações operacionais e condições de produção impostas ao modelo. O objetivo do problema é encontrar a melhor prescrição para cada UP.

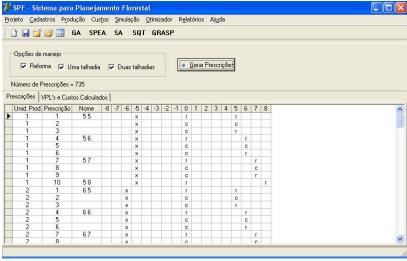


Figura 1. Protótipo Gerador de Prescrições.



## 2.1. Modelo de Programação Inteira para o Problema de Planejamento Florestal Multiobjetivo (PFM)

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

 $Z_1$  = lucro total (soma dos lucros de cada unidade de produção);

 $Z_2$  = excesso de produção;

M = número total de unidades de produção em uma fazenda;

 $N_i$  = número total de alternativas de manejo da *i*-ésima unidade de produção;

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

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

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

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

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

i = taxa de desconto;

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

k = período de tempo;

EP = excesso de produção global da floresta, é dado soma do volume total produzido pela unidade de produção i, manejada sob a alternativa de manejo j, no k-ésimo período do horizonte de planejamento conforme a idade de corte naquele período, menos o volume total (m³) da demanda a ser atendida no período k.

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

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

 $V_k$  = volume total (m<sup>3</sup>) da demanda a ser atendida no período k;

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

H = horizonte de planejamento.

 $CR_k$  = capacidade de reforma no período k.

O modelo completo é da seguinte maneira:

$$Max Z_1 = \sum_{i=1}^{M} \sum_{j=1}^{N_i} VPL_{ij} X_{ij}$$
 (1)

$$Min Z_2 = \sum_{k=1}^{H} \left( \sum_{i=1}^{M} \sum_{j=1}^{N_i} V_{ijk} X_{ij} - V_k \right)$$
 (2)

Sujeito a:

• 
$$\sum_{i=1}^{N_i} X_{ij} = 1$$
,  $\forall i = 1,...M$ , (3)

• 
$$V_k \le \sum_{i=1}^{M} \sum_{i=1}^{N_i} V_{ijk} X_{ij}$$
,  $k = 0, 1, ..., H-1$  (4)

• 
$$CR_k \ge \sum_{i=1}^{M} \sum_{j=1}^{N_i} A_{ijk} X_{ij}$$
,  $k = 0, 1, ..., H-1$  (5)

• 
$$X_{ij} \in \{0,1\}, \forall i=1,...M, j=1,...N$$
 (6)



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

## 3. Heurística ILS Multiobjetivo para um Problema de Planejamento Florestal

A heurística ILS é um algoritmo heurístico baseado na idéia de que um procedimento de busca local pode ser melhorado, gerando-se novas soluções de partida, as quais são obtidas por meio de perturbações numa solução ótima local (Lourenço et al., 2002). Neste algoritmo, o procedimento de busca local tem por finalidade melhorar a solução inicial e, também, aquelas produzidas após perturbações de soluções ótimas locais (Brito et al., 2009). Desta forma, a perturbação deve permitir que a busca local explore diferentes soluções, além de evitar um reinício aleatório. Os passos básicos do algoritmo ILS, para o caso de otimização de uma função objetivo (mono-objetivo), são mostrados na Figura 2.

```
Procedimento ILS (CritérioParada)

1   S_1 \leftarrow \text{Construção\_Solução\_Inicial};

2   S^* \leftarrow S_1; //melhor solução encontrada

3   enquanto não CritérioParada faça

4   S_2 \leftarrow \text{Perturbação}(S_1);

5   S_2 \leftarrow \text{Busca\_Local}(S_2);

6   S_1 \leftarrow \text{Criterio\_Aceitação}(S^*, S_1, S_2);

7   fim-enquanto;

8   retorne S^*;

fim ILS;
```

Figura 2. ILS Básico Mono-objetivo.

Por este trabalho abordar um Problema de Planejamento Florestal Multiobjetivo, o algoritmo ILS proposto (denominado *ILSMulti*) é baseado na proposta de Framinan e Leisten (2007) que desenvolveram um algoritmo denominado *Multi-Objective Iterated Greedy Search* (MOIGS). O algoritmo MOIGS é baseado no algoritmo mono-objetivo *Iterated Greedy Search* (IGS) proposto por Ruiz e Stützle (2007). Os algoritmos IGS e MOIGS foram originalmente aplicados para um problema de seqüenciamento de tarefas em um sistema *flow shop* e apresentaram excelentes resultados.

```
Procedimento ILSMulti(d, h, T) // Taxa de destruição das soluções

1 LD \leftarrow \emptyset; // Lista de dominantes

2 LD \leftarrow ConstrucaoAleatoria(T);

3 enquanto não CritérioParada faça

4 CS \leftarrow \emptyset;

5 S \leftarrow SelecionaSolucao(LD); //seleção aleatória

6 S \leftarrow Perturbação(S, d);

7 CS \leftarrow BuscaLocal(S, h);

8 LD \leftarrow LD \cup CS;

9 fim-enquanto;

10 retorne LD;

fim ILSMulti;
```

Figura 3. Pseudocódigo do Procedimento ILSMulti.



A Figura 3 apresenta o pseudocódigo do algoritmo ILSMulti proposto neste trabalho. O fluxo normal do algoritmo inicia com a geração de uma lista de soluções dominantes. Estas soluções são geradas de forma aleatória (Passo 2). A cada iteração do algoritmo, uma solução  $S_i$  é escolhida na lista LD (Passo 5) para que seja melhorada por uma busca local (Passo 7). Durante a busca local, o algoritmo encontra várias novas soluções, das quais as soluções dominantes são inseridas numa lista CS que, posteriormente, são inseridas na lista de soluções dominantes LD a ser retornado pelo algoritmo (Passo 8). O algoritmo possui quatro parâmetros, o CritérioParada, o número de soluções construídas na fase inicial (T), a taxa de perturbação d e uma probabilidade h usada na Busca Local.

Os detalhes dos procedimentos "ConstrucaoAleatoria", "SelecionaSolucao", "Perturbação" e "BuscaLocal" estão descritos nas próximas seções.

## 3.1. Construção Aleatória e Representação da Solução

A fase construtiva "ConstrucaoAleatoria" (Passo 2 do algoritmo ILSMulti) consiste, basicamente, em gerar uma lista de soluções dominantes LD. Para isto são gerados, de forma aleatória, T soluções viáveis e as soluções dominantes são armazenadas na lista LD. A estrutura de dados criada, para armazenar o conjunto de soluções, foi uma lista encadeada em que cada nó da lista representa uma solução dominante. Uma solução S será inserida na lista L se ela não for dominada por nenhuma solução da lista. As soluções dominadas por S são removidas da lista L.

Cada solução *S* do problema contém um determinado número de unidades de produção (N° UP's) e para cada UP, existe um conjunto de possíveis alternativas de manejo (AM) que a UP pode assumir, cada AM contém valores associados como custo, lucro, volume de madeira, regime e outros. Para cada UP deve-se escolher uma AM. A escolha de uma AM é feita de forma aleatória. Na Figura 4 é mostrada uma solução *S* com 20 UP's definas pelas letras de "A" a "U". É importante ressaltar que as alternativas de manejo (AM's) foram geradas através do protótipo Gerador de Prescrições (Teixeira, 2002).

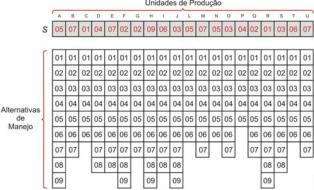


Figura 4. Esquema representativo da solução. Na solução *S* são utilizadas as alternativas de manejo 03, 07, ..., 07 para as unidades de produção A, B, ..., U, respectivamente.

Após gerar uma solução deve-se verificar sua viabilidade para o problema conforme as restrições impostas e calcular as funções objetivo. Caso a solução gerada seja viável, ela é inserida na lista LD, caso não seja dominada.

#### 3.2. Seleção da Solução

A cada iteração do algoritmo *ILSMulti*, uma solução *S* é selecionada da lista (*LD*) para que seja submetido ao processo de Busca Local. O procedimento denominado "*SelecionaSolucao*" realiza esta escolha de forma aleatória.

#### 3.3. Perturbação

O procedimento de perturbação, de uma solução S, utilizada no algoritmo ILSMulti consiste em trocar aleatoriamente as alternativas de manejo de d% de unidades de produção. Ou seja, são



escolhidas aleatoriamente d% das UP's, e para cada UP escolhe-se aleatoriamente uma nova AM de tal maneira que seja obtida uma solução viável. O parâmetro d é denominado taxa de perturbação.

#### 3.4. Busca Local

A fase da "BuscaLocal" (Passo 7 do algoritmo *ILSMulti*) consiste em determinar novas soluções vizinhas da solução *S* selecionada pelo procedimento "SelecionaSolucao". As soluções vizinhas dominantes são armazenadas em uma conjunto auxiliar *CS*.

O pseudocódigo do procedimento "BuscaLocal" é apresentado na Figura 5. Inicialmente, conjunto CS é vazio (Passo 1), para cada unidade de produção up (Passo 2) são realizadas as trocas das alternativas de manejo (passos 6 a 11). Essas trocas serão realizadas com uma probabilidade h% (passo 4). A cada troca realizada, uma nova solução é gerada, testada quanto sua viabilidade e inserida no conjunto CS. O retorno do procedimento é o conjunto CS de soluções dominantes.

O uso de uma probabilidade baixa para a escolha de uma unidade de produção (up) reduz consideravelmente o tempo gasto pela Busca Local. Nota-se que, para h=100%, todas as unidades de produção serão analisadas.

```
procedimento BuscaLocal(S, h)
1
       CS \leftarrow \emptyset;
2
       Para cada unidade de produção up faça
3
           r = número aleatório entre [0,100]
           Se r \le h\% então
             S^* := S;
             Para cada alternativa de manejo m_{up} \neq S[up] faça
                  S*[up] := m_{up};
                  Se S* é viável então
                     CS := soluções dominantes de CS \cup S^*;
10
                  Fim-se;
11
             Fim-para;
12
             S = escolha uma solução de CS;
13
          Fim-Se
14
       Fim-para;
15
       Retorne CS;
fim BuscaLocal
```

Figura 5. Procedimento de Busca Local.

## 4. Resultados Computacionais

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

Foi gerado um conjunto de 30 problemas testes baseados em dados reais e em dados obtidos da literatura (Teixeira, 2002). A Tabela 1 mostra a relação dos problemas-teste utilizados e os principais parâmetros de cada problema. Cada problema foi classificado quanto ao número de unidades de produção, sendo "A" com 50 unidades, "B" com 100 unidades e "C" com 150 unidades. Em cada classe, os horizontes de planejamento variaram entre 9 e 30 anos que,



combinado com o número de unidades de produção, determina o número de prescrições (possíveis alternativas de manejo).

Tabela 1 – Problemas-teste utilizados.

Classe	Problema	N°UP's	Horizonte	Nº Prescrições	Tempo
A	1	50	9 anos	735	5 min.
A	2	50	9 anos	735	5 min.
A	3	50	9 anos	735	5 min.
A	4	50	14 anos	2466	10 min.
A	5	50	14 anos	2466	10 min.
A	6	50	14 anos	2466	10 min.
A	7	50	20 anos	9108	20 min.
A	8	50	20 anos	9108	20 min.
A	9	50	20 anos	9108	20 min.
A	10	50	25 anos	27045	30 min.
В	11	100	9 anos	1533	15 min.
В	12	100	9 anos	1533	15 min.
В	13	100	9 anos	1533	15 min.
В	14	100	14 anos	5094	30 min.
В	15	100	14 anos	5094	30 min.
В	16	100	14 anos	7491	40 min.
В	17	100	20 anos	18924	60 min.
В	18	100	20 anos	18924	60 min.
В	19	100	20 anos	18924	60 min.
В	20	100	25 anos	56499	100 min.
С	21	150	9 anos	2189	30 min.
C	22	150	9 anos	2189	30 min.
C	23	150	9 anos	2189	30 min.
C	24	150	14 anos	7491	50 min.
C	25	150	14 anos	7491	50 min.
C	26	150	14 anos	7491	50 min.
C	27	150	20 anos	27807	105 min.
C	28	150	25 anos	82905	180 min.
C	29	150	28 anos	156042	240 min.
C	30	150	30 anos	220509	295 min.

Observa-se que alguns problemas contêm o mesmo número de unidades de produção, seguido do mesmo horizonte de planejamento, por exemplo, os problemas 1, 2 e 3. A diferença entre estes problemas está relacionada com os valores utilizados para 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 influenciarão, diretamente, no desempenho das técnicas utilizadas para se resolver os problemas.

Ainda na Tabela 1, são apresentados os tempos computacionais, em minutos, estabelecidos como *critério de parada* de cada algoritmo (*ILSMulti* e SPEA). Para determinar o tempo de execução dos algoritmos, foi utilizada a seguinte fórmula:  $(M \times \sqrt{m})/4$ , onde M representa o número total de UP's e m representa o número total de alternativas de manejo disponíveis no problema. O resultado é dado em segundos e posteriormente convertido para minutos.

#### 4.1. Avaliação das Soluções

Sejam LD e LD' os conjuntos de soluções dominantes obtidas pelos algoritmos ILSMulti e SPEA, respectivamente. A partir destes conjuntos é determinado o conjunto R é o conjunto de soluções dominantes referência: R = dominantes( $LD \cup LD$ '). Para comparar a qualidade das soluções geradas pelas metaheurísticas, foram utilizadas duas medidas:

- *Medida de cardinalidade*: número de soluções de referencia obtidas pela metaheurística.  $|D \cap R|$ ; onde D = LD ou LD'.
- Medida de distância (proposta por Czyzak e Jaszkiewicz, 1998): mede a proximidade de um conjunto D de soluções heurísticas em relação ao conjunto de referência R. Assume-



se que D é uma boa aproximação de R se as soluções de D estão bem próximas das soluções de R. Em outras palavras, para cada ponto  $z \square R$  existe  $z' \square D$  tal que a distância entre z' e z é mínima (D = LD ou LD').

A medidas de distância é definida como segue:

$$D_{med} = \frac{1}{\mid R \mid} \sum_{z \in R} \min_{z' \in D} d(z', z) \ \ \mathbf{e} \ \ D_{\max} = \max_{z \in R} \left\{ \min_{z' \in D} d(z', z) \right\}$$

onde *d* é definido por:

$$d(z',z) = \max_{j=1,\dots,r} \left\{ \frac{1}{\Delta_j} (z'_j - z_j) \right\}, z' = (z',\dots,z'_r) \in D, z = (z1,\dots,z_r) \in R,$$

$$\Delta_j = \max f_j - \min f_j, \ \max f_j = \max\{z_j = f_j(x); f(x) \in D \cup R\} \ \text{e}$$
 
$$\min\{z_j = f_j(x); f(x) \in D \cup R\}.$$

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

## 4.2. Parâmetros do Algoritmo ILSMulti

O algoritmo *ILSMulti* possui quatro parâmetros, o *CritérioParada*, *T* (o número de soluções construídas na fase inicial), *d* (taxa de perturbação) *h* (parâmetro usada da Busca Local).

O valor usado para T foi 100, ou seja, são geradas 100 soluções aleatórias das quais são selecionadas as dominantes no conjunto D. Para determinar a taxa de perturbação d, foram realizados testes computacionais considerando os valores de 5%, 7% e 10%. Os resultados obtidos apontaram o valor de 7% como a melhor taxa para perturbação.

Para calibrar o parâmetro h utilizado no procedimento de Busca Local, foram selecionados um subconjunto de problemas de diferentes tamanhos. Inicialmente foram gerados três valores para h: 5%, 10% e 15%. A heurística ILSMulti foi executada utilizando esses valores determinando, para cada problema, diferentes conjuntos de soluções dominantes LD. A partir desses conjuntos, determinou-se o conjunto referência R que é formado pelas soluções de referencia entre todas as soluções encontradas. Na Tabela 2 são apresentados os resultados obtidos. Nesta Tabela, são mostrados o número total de soluções de referencia |R|, a quantidade de soluções no conjunto LD e o número total de soluções de referencia  $|LD \cap R|$  obtidas pela heurística para cada valor de h.

Tabela  $2 - N^{o}$  de soluções encontradas pelo *ILSMulti* com diferentes valores para o parâmetro h.

Problema	R  —	LD			$ LD \cap R $		
		h=5%	h=10%	h=15%	h=5%	h=10%	h=15%
1	4491	3439	2638	3386	2155	2313	23
4	4379	2360	3811	4813	599	3780	0
7	1288	1287	859	866	970	302	16
10	578	673	326	368	268	309	1
11	5726	6621	4795	7221	994	4370	362
14	2442	3146	2447	1402	0	2442	0
17	2443	2316	2004	1602	1179	1264	0
20	749	574	727	396	0	698	51
21	8726	7314	8603	8047	6539	1557	630
24	3118	2840	2940	6645	1369	970	779
27	1173	927	827	971	76	553	544
28	720	707	370	442	320	256	144
30	916	370	647	509	355	370	191
Total	36749	32574	30994	36668	14824	19185	2741

Das 13 instâncias testadas, foram encontradas 36740 soluções de referência. Para cada valor de h (5%, 7% e 10%), foram obtidas respectivamente 14824, 19185 e 2741 soluções de referencia. Observa-se que usando h = 10% foi encontrado um número maior de soluções dominantes de referência em 10 dos 13 problemas testados. Também foi observado que, usando



*h*=10%, a Busca Local é rápida e o algoritmo *ILSMulti* executa um número maior de iterações, o qual é importante para o bom desempenho da heurística.

## 4.3. Comparação dos algoritmos ILSMulti e SPEA

Para comparar foi estabelecido um mesmo critério de parada baseado no tempo de execução, conforme mostra a Tabela 1. Os resultados (medida de cardinalidade) dos algoritmos *ILSMulti* e SPEA são mostradas na Tabela 3.

Tabela 3 – Número de soluções encontradas pelas metaheurísticas *ILSMulti* e SPEA.

Classe	Problema	R  —	ILS	Multi	SPEA	
			LD	$ LD \cap R $	<i>LD</i> '	LD'∩R
A	1	12540	7955	3845	9596	8695
A	2	9955	6045	3760	10130	6195
A	3	5509	1054	0	5509	5509
A	4	9020	9020	9020	8941	0
A	5	5991	5991	5991	9105	0
A	6	5379	5379	5379	7032	0
A	7	4372	4372	4372	10394	0
A	8	2165	2165	2165	5479	0
A	9	3043	3043	3043	6064	0
A	10	2903	1406	1406	10896	1497
В	11	7799	7799	7799	10058	0
В	12	10686	10686	10686	8218	0
В	13	6344	6344	6344	6302	0
В	14	5203	5203	5203	14674	0
В	15	3147	3147	3147	4151	0
В	16	3915	3915	3915	6785	0
В	17	1260	182	13	1497	1247
В	18	4670	4670	4670	4852	0
В	19	2156	2156	2156	11420	0
В	20	2892	2892	2892	5074	0
С	21	7636	7636	7636	14975	0
C	22	13442	13442	13442	12652	0
C	23	10205	10205	10205	12682	0
C	24	4832	4832	4832	11246	0
C	25	6727	6727	6727	5739	0
C	26	6142	6142	6142	8299	0
C	27	4015	4015	4015	11915	0
C	28	2627	2627	2627	6706	0
C	29	1951	1951	1951	6993	0
C	30	1452	1452	1452	222	0

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

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

Na Tabela 4 são mostrados os desempenhos das metaheurísticas ILSMulti e SPEA em relação à medida de distância. Observa-se que em grande parte das instâncias testadas, o algoritmo ILSMulti obteve como  $D_{\rm med}$  e  $D_{\rm max}$  o valor 0 (zero), um vez que o conjunto R foi o próprio conjunto gerado pela metaheurística.

LD: Conjunto de soluções dominantes obtidas pela metaheurística ILSMulti.

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

		Média de distância				
Classe	Problema	ILSMulti		SPEA		
		$D_{med}$	$D_{max}$	$D_{med}$	D <sub>max</sub>	
A	1	0.1440	0.3081	0.1598	2.6145	
Α	2	0.4906	1.8015	0.7914	11.5685	
A	3	4.1983	25.5844	0.0000	0.0000	
A	4	0.0000	0.0000	1.7567	17.3884	
Α	5	0.0000	0.0000	1.4001	9.8738	
A	6	0.0000	0.0000	1.4249	5.9054	
Α	7	0.0000	0.0000	1.0920	14.2160	
A	8	0.0000	0.0000	1.2804	17.2610	
Α	9	0.0000	0.0000	3.0694	24.3607	
Α	10	0.0942	0.3698	0.2068	9.4425	
В	11	0.0000	0.0000	0.3100	3.3708	
В	12	0.0000	0.0000	1.8349	16.8939	
В	13	0.0000	0.0000	0.8964	11.8181	
В	14	0.0000	0.0000	0.5946	7.0340	
В	15	0.0000	0.0000	1.5144	14.3101	
В	16	0.0000	0.0000	1.9100	16.2328	
В	17	0.4644	9.2691	0.0008	0.0966	
В	18	0.0000	0.0000	2.5090	22.1012	
В	19	0.0000	0.0000	2.1058	12.6023	
В	20	0.0000	0.0000	0.8660	5.8749	
С	21	0.0000	0.0000	1.7671	16.6535	
C	22	0.0000	0.0000	3.3334	22.9788	
C	23	0.0000	0.0000	1.6953	14.0978	
C	24	0.0000	0.0000	4.5157	24.5063	
C	25	0.0000	0.0000	2.9676	19.7141	
C	26	0.0000	0.0000	3.1721	16.0281	
C	27	0.0000	0.0000	1.4348	5.8912	
C	28	0.0000	0.0000	1.6712	8.4044	
C	29	0.0000	0.0000	1.3324	4.8761	
C	30	0.0000	0.0000	7.3241	19.9820	

Tabela 4 – Desempenho das metaheurísticas *ILSMulti* e SPEA (medida de distância).

#### 5. Conclusões

Neste trabalho foi proposta uma adaptação da metaheurística ILS (*Iterated Local Search*) para resolver o problema de planejamento florestal multiobjetivo. Os resultados gerados pela metaheurística ILS foram comparados com a metaheurística SPEA proposta por Teixeira (2002) para a solução do mesmo problema de planejamento florestal abordado.

Os parâmetros dos problemas utilizados foram definidos por meio de dados reais associados a uma empresa florestal. Os resultados obtidos mostram o bom desempenho da heurística ILS na determinação de soluções dominantes quando comparado com o algoritmo SPEA. Um ponto relevante é o fato da heurística ILS gera uma maior amplitude na fronteira de soluções dominantes, uma vez que o tomador de decisões pode optar por soluções mais extremas, tendendo a um dos objetivos. Assim, a aplicação da heurística ILS, é uma boa alternativa para a solução de problemas de planejamento florestal com múltiplos objetivos.

### Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo financiamento parcial do trabalho e à empresa CIENTEC – Consultoria e Desenvolvimento de Sistemas.

#### Referências

Associação Brasileira da Indústria de Madeira Processada Mecanicamente – ABIMCI, (2007), Estudo Setorial 2007: Indústria de Madeira Processada Mecanicamente. Disponível em: <a href="http://www.abimci.com.br/importancia">http://www.abimci.com.br/importancia</a> setor.html>. Acesso em: 10/03/2009.

**Associação Brasileira dos Produtores de Florestas Plantadas – ABRAF.** (2009), Segmento de Florestas Plantadas no Brasil – Indicadores – Ano Base 2008. Disponível em: <a href="http://www.abraflor.org.br/estatisticas.asp">http://www.abraflor.org.br/estatisticas.asp</a>>. Acesso em: 27 set. 2009.



- **Barros Junior. A. A., Arroyo, J.E.C., Santos, H.N.**, (2009), GRASP com Path Relinking para um Problema de Planejamento Florestal. In: XLI Simpósio Brasileiro de Pesquisa Operacional. Anais... Porto Seguro. p. 1953-1964.
- **Brito, J.A.M., Montenegro, F.M.T., Ochi, L.S.**, (2009), Um Algoritmo ILS para Melhoria de Eficiência da Estratificação Estatística. In: XLI Simpósio Brasileiro de Pesquisa Operacional. Anais... Porto Seguro. p. 2133-2144.
- Czyzak, P., e Jaszkiewicz, A., (1998), Pareto simulated annealing a metaheuristic technique for multiple objective combinatorial optimization. J. of Multi-Criteria Decision Analysis 7, 34-47.
- Clutter, J.L. et al., (1983), Timber Management: a quantitative approach. John Wiley & Sons. 333p.
- Dykstra, D.P. (1984) Mathematical programming for natural resource management.: McGraw-Hill. 318p.
- **Fatureto, C. R. C. e Santos, H. N.,** (1999a), Tomada de decisão sob critérios múltiplos: metodologias e oportunidades de aplicação no Agribusiness Parte I. Revista Brasileira de Agroinformática, Viçosa, v. 2, n. 1, p. 13-27.
- **Fatureto, C. R. C. e Santos, H. N.,** (1999b), Tomada de decisão sob critérios múltiplos: metodologias e oportunidades de aplicação no Agribusiness Parte II. Revista Brasileira de Agroinformática, Viçosa, v. 2, n. 2, p. 83-94.
- **Framinan, J.M., Leisten, R.**, (2007) A multi-objective iterated greedy search for flowshop scheduling with makespan and flowtime criteria. OR Spectrum.
- **Johnson, K. N. e Scheurman, H. L.,** (1977), Techniques for prescribling optimal timber harvest and investment under different objectives Discussion and Synthesis. Forest Science Monograph, USA, n 18
- **Kidd, W. E., Thompson E. F., e Hoepner P.H.** (1966). Forest Regulation by Linear Programming A Case Study. Journal of Forestry 64:611-613.
- **Laroze, A. J.,** (1999), A linear programming, tabu search method for solving forest-level bucking optimization problems. Forest Science, Washington, v. 45, n. 1, p. 108-116.
- **Lourenço, H.R.; Martin, O. e Stützle, T.** (2002), Iterated Local Search. In F. Glover and G. Kochenberger, editors, Handbook of Metaheuristics, pages 321–353. Kluwer Academic Publishers, Norwell, MA.
- **Malinovski, R. A.** (2007), Otimização da Distância de Extração de Madeira com Forwarder. Botucatu. 2007. 94 f. Tese (Doutorado em Agronomia / Energia na Agricultura). Faculdade de Ciências Agronômicas, Universidade Estadual Paulista.
- **Nobre, S. R.,** (1999), A heurística da Razão-R aplicada a problemas de gestão florestal. 1998. 98f. Dissertação (Mestrado), Universidade Federal de Lavras, Lavras, MG.
- **Pereira, G. W. e Santos, H. N.,** (2003), Aplicação do Simulated Annealing na solução de problemas de planejamento florestal multiobjetivo. Dissertação (Mestrado em Ciência da Computação) Curso de Pós-graduação em Ciência da Computação, Universidade Federal de Minas Gerais.
- **Rodrigues, F.L., Leite, H.G., Santos, H.N., Souza, A.L.,** (2003), Solução de problemas de planejamento florestal com restrições de inteireza utilizando Busca Tabu. Revista Árvore, v.27, n. 5, p. 701-713.
- **Rodrigues, et. al.,** (2004), Metaheurística Simulated Annealing para solução de problemas de planejamento florestal com restrições de integridade. Revista Árvore, Viçosa-MG, v.28, n. 2, p. 247-256.
- **Rodriguez, L. C. E. e Lima, A. B. N. P. M.** (1985), A utilização da programação linear na determinação de uma estratégia ótima de reforma de um talhão florestal. IPEF, Piracicaba-SP, n.31, p.47-53.
- **Ruiz R., Stützle T.** (2007), A simple and effective iterated greedy algorithm for the permutation flowshop scheduling problem. Eur J Oper Res 177:2033–2049.
- **Silva, G. F. et al.,** (2003) Problemas com o uso de programação linear com posterior arredondamento da solução ótima, em regulação florestal. Revista Árvore, Viçosa, v.27, n.5, p.677-688.
- **Steuer, R.E. e Schuler, A.T.** (1978), An interactive multiple-objective linear programming approach to a problem in forest management. Operations Research, v.26, n.2, p.254-269.
- **Teixeira, A. F.,** (2002), Aplicação de algoritmos evolucionários na solução de problemas de planejamento florestal multiobjetivo. 66p. Dissertação (Mestrado em Ciência da Computação) Curso de Pósgraduação em Ciência da Computação, Universidade Federal de Minas Gerais.
- **Teixeira, A. F., Santos, H.N., Silva, G.F., Freitas, P.M.,** (2003), Algoritmos evolucionários aplicados ao planejamento florestal com objetivos múltiplos. Anais do XXXV Simpósio Brasileiro de Pesquisa Operacional.
- Weintraub, A.; Jones, G.; Magendzo, A.; Meacham, M.; Kirby, M. (1994), A heuristic system to solve mixed interger Forest planning models. Operations Research, v. 42, n. 6, p. 1010 1024, vov./dec.