

## APLICAÇÕES DE HEURISTICAS PARA A SOLUÇÃO DE UM PROBLEMA DE PLANEJAMENTO FLORESTAL

**Antonio Almeida de Barros Junior**

Universidade Federal do Espírito Santo  
Alto Universitário, s/nº - Cx Postal 16, Guararema – CEP: 29500-000 - Alegre-ES  
antonioabj@gmail.com

**Gilson Fernandes da Silva**

Universidade Federal do Espírito Santo  
Alto Universitário, s/nº - Cx Postal 16, Guararema – CEP: 29500-000 - Alegre-ES  
gilson.silva@pq.cnpq.br

**Gustavo Willam Pereira**

Faculdade de Filosofia Ciências e Letras Santa Marcelina  
Praça Annina Bisegna, 40 – Centro – CEP: 36880-000 - Muriaé – MG  
gustavowillam@gmail.com

**Robson Melo**

Universidade Federal do Espírito Santo  
Alto Universitário, s/nº - Cx Postal 16, Guararema – CEP: 29500-000 - Alegre-ES  
robson.info2@gmail.com

### RESUMO

Este trabalho é abordado um Problema de Planejamento Florestal (PF) que visa a escolha de um determinado plano de manejo para o plantio e colheita de madeira. O problema tem como objetivo a maximização do Valor Presente Líquido (VPL) de fluxos de caixa associados ao plano de corte de unidades florestais considerando um horizonte planejado e que atenda determinadas restrições. O objetivo deste trabalho é realizar uma revisão das principais heurísticas desenvolvidas para a solução de problemas de PF. Para isso foram testados os métodos: Algoritmos Genéticos (AG), *Greedy Randomized Adaptive Search Procedure* (GRASP), *Simulated Annealing* (SA) e *Iterated Local Search* (ILS). Foi utilizado um conjunto de 10 problemas. A heurística AG obteve o melhor desempenho quando comparada com as demais.

**PALAVRAS CHAVE. Otimização. Planejamento Florestal. Heurística.**

### ABSTRACT

In this paper we considered the Forest Planning Problem (FP) to ensure the choice of a management plan for planting and harvesting of timber. This problem aims to maximize the Net Present Value, of cash flows associated with the cutting plan of forest units planned considering a horizon that meets certain restrictions. This work intends to review the heuristics developed to solve FP Problems. For this, were tested the methods: Genetic Algorithm (AG), Greedy Randomized Adaptive Search Procedure (GRASP), Simulated Annealing (SA) and Iterated Local Search (ILS). We used 10 problems for test. The heuristic AG achieved the best performance when compared to the others.

**KEYWORDS. Optimization. Florest Management. Heuristics.**

## 1. Introdução

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. O Brasil é um país que apresenta condições físicas e naturais para o desenvolvimento deste setor.

Dados da Associação Brasileira dos Produtores de Florestas Plantadas (ABRAF) mostram a importância deste setor no crescimento do país. No ano de 2011, o total de área plantada no país foi de 6.516.000 hectares, o valor bruto da produção foi de 53,91 bilhões, o valor total de tributos recolhidos foi de 7,60 bilhões, o que representa 0,5% da arrecadação nacional, as exportações foram de 7,97 bilhões o que representa 3,1% do total das exportações do Brasil e os números de empregos gerados foram de 4.730.000 diretos e indiretos (ABRAF, 2012).

É indiscutível que a gestão do processo de produção florestal tem um papel importante para o país e para as empresas da área florestal. Portanto, deve ser possível manejar a floresta para produzir de forma racional de modo a conseguir resultado econômico sem, contudo, provocar problemas ambientais. Essas preocupações já ocorriam no passado, e diversos pesquisadores desenvolveram trabalhos buscando modelar problemas de planejamento florestal para tomar decisões melhores em situações muito complexas. Exemplos são encontrados na literatura como os trabalhos de Pereira (2004), Rodrigues (2001), Rodrigues et al. (2006), Castro (2007), Silva et al. (2009) e Gomide (2009).

Em função da complexidade dos problemas de planejamento florestal, a escolha da técnica de solução desses problemas é fundamental no sentido de que uma vez modelado o problema o mesmo possa ser implementado em nível prático. Para Silva (2001), as técnicas de Programação Linear (PL) e Programação Inteira (PI) constituem um instrumental analítico bastante utilizado no processo de tomada de decisão no Planejamento Florestal (PF), embora 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.

Na busca por métodos mais eficientes para soluções deste tipo de problemas, vários procedimentos heurísticos têm sido desenvolvidos em diversas áreas da ciência. De acordo com Ignízio e Cavalier (1994), as heurísticas são as mais promissoras abordagens para solução de problemas de programação inteira. Exemplos de trabalhos envolvendo estas técnicas têm sido experimentados como no trabalho de Teixeira (2002), Rodrigues et al. (2003), Pereira (2004), Rodrigues (2004), Barros Junior et al. (2009) e Barros Junior e Pereira (2011).

Neste contexto, o presente trabalho tem como objetivo principal realizar uma revisão nas principais heurísticas desenvolvidas para este problema sob um único objetivo. Especificamente testar e comparar os métodos: Algoritmos Genéticos (AG), *Greedy Randomized Adaptive Search Procedure* (GRASP), *Simulated Annealing* (SA) e *Iterated Local Search* (ILS).

## 2. Problema de Planejamento Florestal (PF)

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

Para melhor ilustrar o problema abordado, considere que na Figura 1 tem-se uma floresta e esta, por sua vez, está dividida em várias unidades de produção (UP's). Cada UP é uma área sem descontinuidade com características homogêneas tais como: mesma espécie, mesma idade, mesma altitude, etc. Dadas estas características, uma unidade de produção contém disponível um

conjunto de alternativas de manejo (AM's). Cabe então, ao manejador florestal a responsabilidade de escolher a melhor alternativa de manejo para cada unidade de produção.

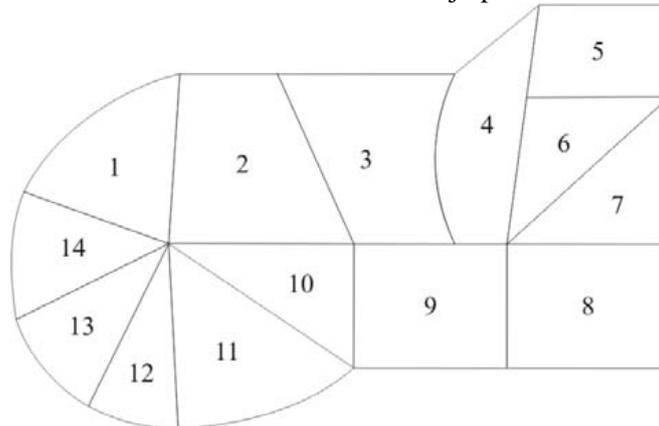


Figura 1. Floresta dividida em Unidades de Produção.

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

### 3. O Modelo para o Problema de Planejamento Florestal

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

$Z$  = lucro total (soma dos lucros de cada unidade de produção).

$M$  = número total de unidades de produção;

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

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

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

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

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

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

$t$  = taxa de desconto;

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

$k$  = período de tempo.

$A_{ijk}$  = 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.

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

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

$H$  = horizonte de planejamento.

O modelo completo é da seguinte maneira:

$$Max Z = \sum_{i=1}^M \sum_{j=1}^{N_i} VPL_{ij} X_{ij} \quad (2)$$

**Sujeito a:**

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

- $V_k \leq \sum_{i=1}^M \sum_{j=1}^{N_i} V_{ijk} X_{ij}, k = 0, 1, \dots, H-2 \quad (4)$

- $CR_k \geq \sum_{i=1}^M \sum_{j=1}^{N_i} A_{ijk} X_{ij}, k = 0, 1, \dots, H-2 \quad (5)$

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

onde, (1) representa a equação de cálculo do Valor Presente Líquido (Lucro), (2) representa a função objetivo, ou seja: a maximização do lucro (soma dos valores presentes líquidos das UP's sobre uma AM escolhida). A restrição (3) garante a escolha de uma única prescrição *j* (ou alternativa de manejo) para a unidade de produção *i*. A restrição (4) representa a imposição de cotas anuais de produção, onde a produção periódica de volume de madeira deve atender a uma demanda preestabelecida, 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, e por último a restrição (6) define as variáveis de decisão na forma binária, o que obriga a escolha de uma única variável de decisão (alternativa de manejo) em cada unidade de produção.

#### 4. Representação de uma solução

Para a representação das variáveis do problema, foram feitas as seguintes considerações: cada solução *S* contém um determinado número de unidades de produção (UP's), representadas na Figura 2 abaixo, pelas letras de "A" a "V". E para cada UP, existe um conjunto de possíveis prescrições ou alternativas de manejo (AM). O objetivo do problema é realizar a busca pela melhor combinação que maximize a função objetivo e satisfaça as restrições do problema.

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

Figura 2. Esquema representativo da solução. Na solução *S* são utilizadas as alternativas de manejo 05, 07, ..., 07 para as unidades de produção A, B, ..., V, respectivamente.

A Figura 3 ilustra com detalhes as alternativas de manejo das unidades de produção "A" e "B" onde, para as colunas, tem-se a linha do tempo, que vai do período de plantio, passando pelo estado atual até o último período do horizonte planejado. Cada célula da matriz pode assumir um dos seguintes estados:

- vazio quando houver apenas atividades de manutenção;

- “x” para a atividade de implantação da floresta (plantio);
- “r” para a atividade de exploração imediatamente seguida de reforma; e
- “c” para a atividade de exploração imediatamente seguida de condução da brotação.

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

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

Figura 3. Esquema representativo da alternativa de manejo.

### 5. Descrição das Heurísticas Testadas

A seguir serão apresentados os algoritmos desenvolvidos para o problema de planejamento florestal em questão. O algoritmo GRASP proposto por Barros Junior et al. (2009), o algoritmo AG proposto por Barros Junior e Pereira (2011) e os algoritmos SA e ILS desenvolvidos com a finalidade de serem utilizados neste trabalho. A base de desenvolvimento destes algoritmos foi o *framework* chamado *GENETICFRAME* proposto por Barros Junior et al. (2006) e o Gerador de Prescrições proposto por Teixeira (2002) e Teixeira et al. (2003).

#### 5.1 Algoritmo Greedy Randomized Adaptive Search Procedure (GRASP) para o Problema de Planejamento Florestal

A heurística GRASP (Figura 4) inicialmente proposta por Feo e Resende (1995), consiste em um procedimento iterativo de duas fases: A primeira fase, denominada de fase construtiva, consiste na geração de uma solução viável *S* utilizando um algoritmo guloso e randômico de acordo com um parâmetro  $\alpha$  (passo 3); a segunda fase realiza uma busca local onde a vizinhança da solução *S* é pesquisada até que se encontre uma solução ótima local *S'* (passo 4). A seguir, esta solução *S'* é comparada com a melhor solução encontrada até o momento (*S\**), caso ela seja melhor, *S'* passa a ser a melhor solução (passos 5 a 7). Ao encerrar as iterações, a melhor solução (*S\**) é retornada (passo 11).

```

procedimento GRASP ( $\alpha$ ) //  $\alpha$  = percentual de AM's a serem exploradas
1    $f^* \leftarrow \infty$ ;
2   para Iter = 1 até GRASPmax faça
3      $s \leftarrow$  ConstruçãoParcialmenteGulosa( $\alpha$ )
4      $s' \leftarrow$  BuscaLocal(s)
5     se ( $f(s') < f^*$ ) então
6        $s^* \leftarrow s'$ 
7        $f^* \leftarrow f(s')$ 
8     fim-se;
9   fim-para;
10   $s \leftarrow s^*$ ;
11  Retorne s
fim GRASP;

```

Figura 4. Pseudocódigo do algoritmo GRASP para um problema de PF.

O parâmetro percentual de alternativas de manejo a serem exploradas foi de  $\alpha = 0,15$ .

## 5.2 Algoritmo Genético (AG) para o Problema de Planejamento Florestal

A heurística Algoritmo Genéticos (AG) são algoritmos de otimização global, idealizados por John Holland em 1975 e baseados nos princípios da genética populacional (a variabilidade entre indivíduos em uma população de organismos que se reproduzem sexualmente é produzida pela mutação e pela recombinação genética).

Os passos básicos do algoritmo AG, para o caso de otimização de uma função objetivo (mono-objetivo), é apresentado na Figura 5.

<b>Procedimento AG (CritérioParada)</b>	
1	$S_1 \leftarrow$ Inicializa População Inicial Randomicamente;
2	$S^* \leftarrow S_1$ ; //melhor solução encontrada
3	<b>enquanto não</b> CritérioParada <b>faça</b>
4	$S_2 \leftarrow$ Seleção ( $S_1$ ); //seleciona 2 indivíduos de $S_1$
5	$S_2 \leftarrow$ Crossover ( $S_2$ );
6	$S_2 \leftarrow$ Mutação( $S_2$ );
7	$S_1 \leftarrow$ Survive( $S_1, S_2$ ); // seleciona melhores indivíduos
8	$S^* \leftarrow S_1$ ; //melhor solução encontrada
9	<b>fim-enquanto</b> ;
10	retorne $S^*$ ;
<b>fim GA</b> ;	

Figura 5. Pseudocódigo do algoritmo AG para um problema de PF.

Através do método de seleção pretendeu-se selecionar soluções da população  $S_1$ , para serem evoluídas; assim, pretendeu-se evoluir a partir de soluções da população inicial. Utilizou-se o método de seleção randômica, escolhendo-se aleatoriamente duas soluções do conjunto  $S_1$  para se realizar o *crossover* entre os dois indivíduos escolhidos que neste trabalho foi de 1 ponto. A partir do *crossover* realiza-se uma mutação nos novos indivíduos gerados, procurando-se evitar que o algoritmo estacione em ótimos locais. A nova população  $S_1$  será formada pelos melhores indivíduos entre  $S_1$  e  $S_2$  a partir do método *Survive*.

## 5.3 Algoritmo *Simulated Annealing* (SA) para o Problema de Planejamento Florestal

De acordo com Youssef et al. (2001), citado por Rodrigues (2001), o algoritmo SA foi criado com base no processo de recozimento de materiais 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, que inicia com 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).

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

Rodrigues (2001) citando Ignacio et al. (2000), afirma que a heurística SA é basicamente um algoritmo de busca local, sendo que a escolha de um novo elemento na vizinhança é realizada de forma semi-aleatória. Considerando que os algoritmos de busca local apresentam o inconveniente de estacionar num ótimo local, a heurística SA evita este problema, visto que utiliza 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.

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:

$$P(E) = \exp^{-(E2-E1)/kT}$$

em que:

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

$T$  = é o parâmetro de controle.

$k$  = é a constante de Boltzman.

$E1$  = é o valor da melhor solução da função objetivo encontrada até o momento.

$E2$  = 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  $T$  é a temperatura que se inicia com um valor alto e é gradativamente reduzida, no final do processo  $T$  é reduzida para um ponto onde somente as melhores soluções são aceitas. O algoritmo pára quando um valor para o parâmetro  $T$  seja satisfeito ou quando a função objetivo é atendida.

O algoritmo básico da metaheurística SA é apresentado a seguir (Figura 6), onde  $x$  é a solução qualquer inicial,  $x'$  é a solução vizinha de  $x$  e  $T$  é a temperatura inicial (Ignacio et al., 2000).

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.

Procedimento SA ( $x, x', T$ )	
1	<b>enquanto não</b> CritérioParada <b>faça</b>
2	$x' \leftarrow x$ ; //gerar $x'$ a partir de $x$
3	//avaliar a variação de energia; (diferença entre o valor
4	//da função objetivo encontrado e o melhor valor da
5	//solução encontrada até o momento);
6	$\Delta E = f(x') - f(x)$ ;
7	<b>Se</b> $\Delta E > 0$ <b>então</b> $x \leftarrow x'$ ; //caso contrário
8	Gerar $r \in Unif[0,1]$
9	<b>Se</b> $r < z = e^{-(f(x')-f(x))/kT}$ <b>então</b>
10	$x \leftarrow x'$
11	//reduzir a temperatura $T$
12	//testar critério de parada
13	<b>fim-enquanto</b> ;
	<b>fim AS</b> ;

Figura 6. Pseudocódigo do algoritmo SA para um problema de PF.

#### 5.4 Algoritmo *Iterated Local Search* (ILS) para o Problema de Planejamento Florestal

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

Na Figura 7, apresenta-se um pseudocódigo básico do algoritmo ILS mono objetivo, que possui 4 etapas principais: a primeira etapa é responsável pela obtenção de uma solução ótima local inicial  $S_1$  (passo 1); na segunda etapa é realizada uma perturbação da solução  $S_1$  obtendo uma nova solução  $S_2$  (passo 4), esta etapa consiste em trocar aleatoriamente as alternativas de manejo de  $d\%$  de unidades de produção, onde  $d$  é denominado *taxa de perturbação*; na etapa seguinte é realizada uma melhoria na solução  $S_2$  através de uma busca local (passo 5) e a etapa final é responsável pelo critério de aceitação da solução atual (passo 6). Com exceção da primeira etapa, todas as demais são executadas iterativamente enquanto o critério de parada não seja atendido. Após as iterações, o algoritmo retorna a melhor solução obtida durante toda sua a execução.

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

Figura 7. Pseudocódigo do algoritmo ILS para um problema de PF.

## 6. Resultados Computacionais

Neste artigo, testa-se o desempenho das heurísticas AG, GRASP, SA e ILS na resolução do problema de planejamento florestal mono-objetivo. Foi utilizado um conjunto de 10 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 e “B” com 100 unidades. Em cada classe, os horizontes de planejamento variaram entre 9 e 14 anos que, combinado com o número de unidades de produção, determina o número de prescrições (possíveis alternativas de manejo).

Os Problemas 1, 2 e 3 representam um cenário onde a empresa pretende planejar sua produção para os próximos 9 anos (horizonte de planejamento). A empresa objetiva, neste cenário, maximizar o lucro. Foram utilizadas para este cenário, 50 unidades de produção e, como formas de manejo, foram utilizadas as opções de reforma, uma e duas conduções de brotação. 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 serve como forma de exploração de cenários diferentes e influenciam diretamente no desempenho das técnicas utilizadas para se resolver os problemas. Para os Problemas 1, 2 e 3 foram consideradas, respectivamente, as demandas anuais mínimas previstas de 37.000 m<sup>3</sup>, 40.000 m<sup>3</sup> e 43.000 m<sup>3</sup> de madeira para o mercado, durante todo o horizonte de planejamento. Foi gerado para cada uma destas instâncias um total de 735 prescrições.

Tabela 1 – Problemas-teste utilizados para as demonstrações propostas.

Classe	Problema	Nº UP's	Horizonte	Nº Prescrições	Tempo
A	1	50	9 anos	735	11 min.
A	2	50	9 anos	735	11 min.
A	3	50	9 anos	735	11 min.
A	4	50	14 anos	2466	20 min.
A	5	50	14 anos	2466	20 min.
A	6	50	14 anos	2466	20 min.
B	7	100	9 anos	1533	30 min.
B	8	100	9 anos	1533	30 min.
B	9	100	14 anos	5094	60 min.
B	10	100	14 anos	5094	60 min.

Para os Problemas 4, 5 e 6 foi considerado um cenário onde a empresa pretende planejar sua produção para os próximos 14 anos. Como apresentada para os problemas anteriores (1, 2 e 3), a diferença entre os problemas 4, 5 e 6 também está relacionada com os valores utilizados para definir as restrições de demanda anual mínima. Aqui, esta diferenciação dos valores utilizados também serve como forma de obtenção de cenários diferentes. 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. Foi gerado para cada um destes problemas um total de 2466 prescrições.

Para os problemas 7, 8 e 9, 10 foi considerado um cenário onde a empresa pretende planejar sua produção para os próximos 9 e 14 anos respectivamente. Foram utilizadas, para este cenário, 100 unidades de produção e, como formas de manejo, também foram utilizadas as opções de reforma, uma e duas conduções de brotação. Como restrições ao problema foram consideradas demandas anuais mínimas previstas para o mercado de madeira e capacidade anual de reforma. Foram geradas, para este problema, um total de 1533 prescrições para os problemas 7 e 8, e 5094 prescrições para os problemas 9 e 10. Como nos problemas anteriores, a principal diferença está relacionada aos valores utilizados para se definir os níveis de demanda anual.

Ainda na Tabela 1, para determinar o tempo de execução dos algoritmos utilizado como critério de parada (coluna Tempo), foi utilizada a seguinte fórmula:  $(M \times m)/2$ , 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.

É importante ressaltar que os algoritmos foram codificados na linguagem pascal utilizando o ambiente de desenvolvimento Borland Delphi 2007 e os testes foram efetuados em um microcomputador Intel Core 2 Duo 2.20GHz com 3GB de memória RAM.

Cada algoritmo foi executado 10 vezes para cada problema, por se tratarem de algoritmos probabilísticos. Os resultados dos testes são apresentados na Tabela 2. Para cada problema determina-se o desvio padrão e a media da função objetivo obtidas durante as 10 execuções de cada algoritmo.

Dos 10 problemas testados, o AG obteve melhores médias em todos os problemas. As diferenças de valores obtidas pelo AG em relação ao GRASP, SA e ILS são apresentadas na Figura 8. Apesar de próximas graficamente, a distância é evidente quando considerado o valor da função objetivo.

Da Tabela 2 observa-se que o GRASP e o ILS obtiveram os melhores valores do desvio padrão (menor) quando comparado com o AG e o SA. Dos 10 problemas testados, o GRASP obteve o menor desvio padrão em 5 problemas e o ILS obteve o menor desvio padrão em 4 problemas. A Figura 9 representa estes resultados.

Tabela 2 – Resultados dos problemas-teste utilizados para as demonstrações propostas.

Problema	Desvio Padrão				Média			
	GRASP	AG	SA	ILS	GRASP	AG	SA	ILS
1	<b>869.836,59</b>	1.696.234,53	6.670.226,25	967.982,66	170.089.201,47	<b>180.550.495,45</b>	174.275.167,81	169.849.242,43
2	679.637,07	1.295.168,45	5.184.748,22	<b>562.034,65</b>	168.407.046,20	<b>178.330.908,66</b>	171.494.839,11	167.661.146,54
3	<b>788.103,47</b>	5.926.059,37	6.259.476,05	1.041.468,42	166.433.583,18	<b>175.373.017,91</b>	169.328.193,39	165.817.843,36
4	<b>1.535.160,68</b>	2.053.047,72	3.380.723,18	1.859.385,70	519.406.868,61	<b>561.178.394,53</b>	547.282.801,05	518.980.177,33
5	<b>2.157.116,01</b>	2.790.708,65	12.630.115,82	5.593.601,80	514.795.465,32	<b>552.133.334,04</b>	535.091.099,51	510.099.230,59
6	1.262.571,19	1.434.378,39	8.499.587,75	<b>1.170.508,36</b>	243.338.550,34	<b>260.424.178,69</b>	249.147.953,57	242.510.711,59
7	946.409,80	1.992.951,90	6.391.470,30	<b>900.592,77</b>	241.020.850,93	<b>255.980.694,39</b>	248.106.646,41	240.731.301,73
8	1.351.383,22	1.992.951,90	6.391.470,30	<b>1.219.038,27</b>	240.221.620,53	<b>255.980.694,39</b>	248.106.646,41	240.075.293,30
9	<b>1.079.250,47</b>	1.325.077,69	7.812.056,81	1.753.452,39	367.669.118,41	<b>394.743.106,75</b>	379.181.521,52	367.733.529,22
10	1.014.913,35	<b>915.950,77</b>	6.773.504,97	1.214.330,04	365.860.172,46	<b>393.383.603,29</b>	380.910.268,99	364.186.505,64
<b>Média</b>	1.168.438,19	2.142.252,94	6.999.337,96	<b>1.628.239,51</b>	299.724.247,74	<b>320.807.842,81</b>	310.292.513,78	298.764.498,17

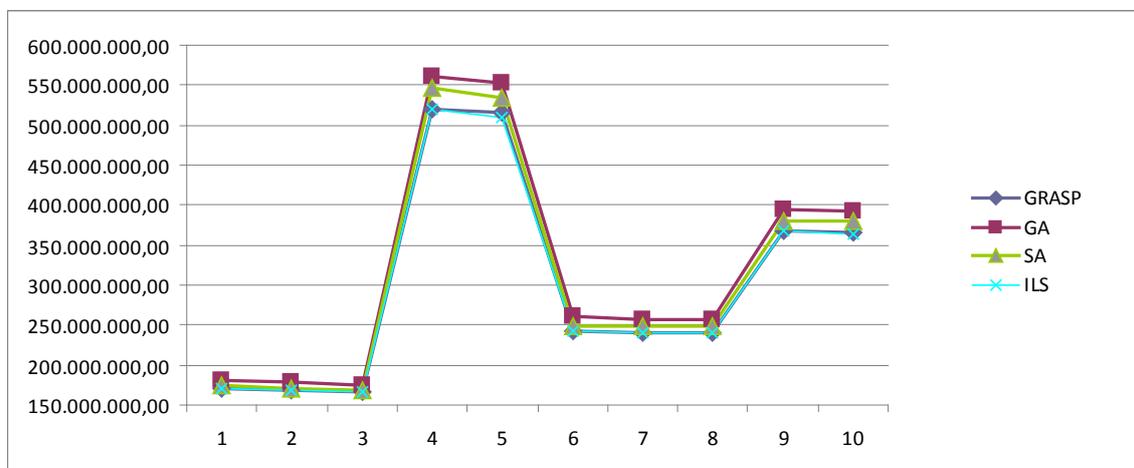


Figura 8. Diferença entre os valores obtidos pelo GRASP, AG, SA e ILS.

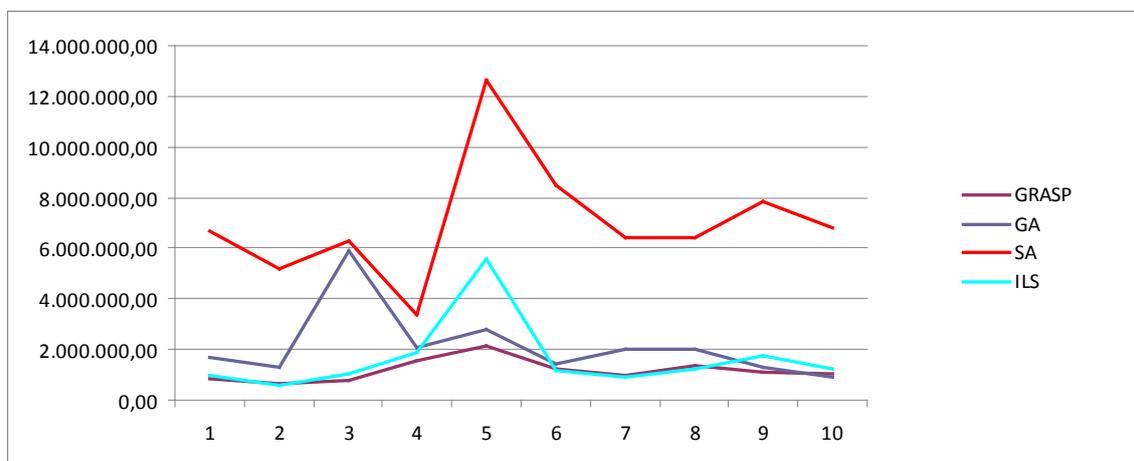


Figura 9. Desvio padrão obtido para os algoritmos AG, GRASP, SA e ILS.

## 7. Conclusões

Neste trabalho foi realizada uma revisão nos trabalhos propostos para a solução do problema de planejamento florestal. Foram realizados vários testes com as heurísticas Algoritmo Genético (AG), *Greedy Randomized Adaptive Search Procedure* (GRASP), *Simulated Annealing* (SA) e *Iterated Local Search* (ILS). Quanto aos resultados gerados, foram comparados os valores médios e o desvio padrão.

As diferenças médias entre o AG e os demais algoritmos foram de 7.04% quando comparado com o algoritmo GRASP, 3.40% quando comparado com o algoritmo SA e 7.38% quando comparado com o ILS. Essa diferença mostra a eficiência da técnica proposta pelo Algoritmo Genético que trabalha com o conceito de população tal como o SA. A diferença é maior quando foi comparado com os algoritmos que trabalham com uma única solução como é o caso do GRASP e ILS.

No que se refere ao desvio padrão, a média obtida a partir do grau de dispersão mostrou que o GRASP foi 83.35% superior ao AG, e 39.36% superior ao ILS. Isso mostra que a diversidade obtida na população inicial do Algoritmo Genético foi fundamental na obtenção dos melhores resultados.

Finalmente, é válido comentar que as metaheurísticas se comportaram de forma estável na obtenção da solução, isto é, não houve soluções muito discrepantes, o que seria indesejável. Assim, o baixo desvio padrão obtido torna as técnicas avaliadas confiáveis no sentido de obter soluções mais próximas de um valor ótimo sem oscilar muito.

## Referências

- Associação Brasileira dos Produtores de Florestas Plantadas – ABRAF.** (2012), Anuário Estatístico da ABRAF 2012 – Ano Base 2011. Disponível em: (<http://www.abraflor.org.br/estatisticas.asp>). Acessado em: 27 abr. 2012.
- Barros Junior, A. A., Teixeira, A.F., Freitas, P.M.** (2006) GENETICFRAME Framework para Algoritmos Genéticos. In: X Simpósio de Pesquisa Operacional e Logística da Marinha, 2006, Rio de Janeiro. A Pesquisa Operacional e a Logística na Operação Portuária.
- 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.
- Barros Junior, A. A., Pereira G.W.,** (2011), Aplicação da Metaheurística Algoritmo Genético com *Path Relinking* para a Solução de um Problema de Planejamento Florestal. In: XVIII Simpósio de Engenharia de Produção. Anais... Baurú.
- Baskent, E.Z.; Jordan, G.A.** (2002) *Forest landscape management modeling using simulated annealing*. In: *Forest Ecology and Management* 165, p. 29-45.
- Brito, J. A. M.; Montenegro, F. M. T.; Ochi, L. S.** Um algoritmo ILS para melhoria de eficiência da estratificação estatística. In: Simpósio Brasileiro de Pesquisa Operacional, 41., 2009, Porto Seguro. Anais... Porto Seguro, 2009. p. 2133-2144.
- Castro, R. R.** (2007) *Regulação de florestas equiâneas incluindo restrições de adjacência*. 2007. 74f. Dissertação (Mestrado em Ciência Florestal) – Programa de Pós-Graduação em Ciência Florestal, Universidade Federal de Viçosa. Viçosa.
- Cerny, V.** (1985) *Thermodynamical approach to the traveling salesman problem: an efficient simulation algorithm*. *Journal of Optimization Theory and Application*, v. 45 n. 1, p. 41-51.
- Feo T. A. e Resende, M. G. C.,** (1995), Greedy Randomized Adaptive Search Procedures. *Journal of Global Optimization*, 6, 109-133.
- Gomide, L. R.** (2009) *Planejamento florestal espacial*. 235f. Tese (Doutorado em Ciências Florestais) - Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná. Curitiba.

- Holland, J. H.** *Adaptation in natural and artificial systems*. The University of Michigan Press, Ann Arbor, MI, 1975.
- Ignacio, A.A.V.; Ferreira Filho, V.J.M.; Galvão, R.D.** (2000) *Métodos heurísticos num entorno paralelo*. In: Simpósio Brasileiro de Pesquisa Operacional, 32, 2000, Viçosa. Anais. Viçosa: Ufv, p. 769-788.
- Ignízió, J.P., Cavalier, T.M.** *Linear Programming*. Englewood Cliffs: Prentice Hall, 1994, 666p.
- Lourenço, H. R.; Martin, O.; Stützle, T.** *Iterated local search*. In: Glover, F.; Kochenberger, G. (Eds.). *Handbook of metaheuristics*, Norwell, MA: Kluwer Academic Publishers, 2002. p 321-353.
- Kirkpatrick Jr., S.; Gelatt, C.; Vecchi, M.** (1983) *Optimization by simulated annealing*. *Decision Science* 220(4598), p. 498-516.
- Metropolis, N. et al.** Equation of state calculations by fast computing machines. *J. Chem. Phys.* v. 21, p. 1087-1092, 1953.
- Pereira, G. W.; Santos, H. N.** (2004) *Aplicação da Técnica de Recozimento Simulado 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, Belo Horizonte, MG.
- Rodrigues, F.L.** (2001) *Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais*. 255p. Tese (Doutorado), Universidade Federal de Viçosa, Viçosa, MG.
- 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*, Viçosa-MG, v.27, n. 5, p. 701-713.
- Rodrigues, F.L.** (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.
- Rodrigues, F. L.; Silva, G. F.; Leite, H. G.; Xavier, A. C.; Pezzopane, J. E. M.** (2006) Um modelo de regulação florestal e suas implicações na formulação e solução de problemas com restrições de recobrimento. *Revista Árvore*, Viçosa, v.30, n.5, p.769-778.
- Silva, G. F.** *Problemas no uso de programação matemática e simulação em regulação florestal*. 2001. 89f. Tese (Doutorado em Ciência Florestal) – Programa de Pós-Graduação em Ciência Florestal, Universidade Federal de Viçosa. Viçosa, 2001.
- Silva, G. F.; Piassi, L. C.; Môra, R.; Martins, L. T.; Teixeira, A. F.; Barros Junior, A. A.** (2009) Metaheurística algoritmo genético na solução de modelos de planejamento florestal. *Agrária – Revista Brasileira de Ciências Agrárias*, Recife, v.4, n.2, p.160-166.
- 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.
- Youssef, H.; Sait, S.M.; Adiche, H.** (2001) Evolutionary algorithms, simulated annealing end tabu search: a comparative study. *Engineering Applications of Artificial Intelligence*, V. 14, p. 167-181.