

CLUSTERING SEARCH COM ITERATED LOCAL SEARCH PARA RESOLUÇÃO DO PROBLEMA DE PLANEJAMENTO FLORESTAL

Robson de Souza Melo

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

Antonio Almeida de Barros Junior

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

Geraldo Regis Mauri

Universidade Federal do Espírito Santo - UFES
Alto Universitário, s/nº - Cx Postal 16, Guararema – CEP: 29500-000 - Alegre-ES
mauri@cca.ufes.br

RESUMO

Este trabalho aborda um Problema de Planejamento Florestal (PPF) que visa a escolha de um determinado plano de manejo para o plantio e colheita de madeira. O PPF 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. O objetivo deste trabalho é aplicar a meta-heurística híbrida *Clustering Search* (CS) utilizando uma *Iterated Local Search* (ILS) para a resolução de um PPF. O desempenho do método proposto é avaliado por meio de um conjunto de 10 instâncias, e os resultados obtidos são comparados com aqueles obtidos pela *Iterated Local Search* (ILS) aplicada de forma isolada, que foi proposta em um trabalho anterior.

PALAVRAS CHAVE. *Clustering Search*, *Iterated Local Search*, Planejamento Florestal.

Área principal: AG&MA - PO na Agricultura e Meio Ambiente.

ABSTRACT

This work addresses a Forestry Planning Problem (FPP) which aims at choosing a specific management plan for the planting and harvesting of timber. The objective of the FPP consists of maximizing the Net Present Value (NPV) of cash flows associated with the plan to cut forestry units considering a planned horizon. Our objective is to apply the *Clustering Search* (CS) hybrid meta-heuristic using an *Iterated Local Search* (ILS) to solve a FPP. The performance of the proposed method is evaluated by using a set of 10 instances and our results area compared with results obtained by the *Iterated Local Search* (ILS) reported in a previous work.

KEYWORDS. *Clustering Search*, *Iterated Local Search*, Forest Planning.

Main area: AG&MA - OR in Agriculture and Environment.

1. Introdução

As florestas estão se tornando cada vez mais importantes à sobrevivência e para manter o equilíbrio do planeta. Além de ser fonte de recursos e riquezas para o ser humano, as florestas estão exercendo cada vez mais importância para o setor econômico do país. As florestas plantadas se tornaram as principais fontes de matéria prima e importante fator de competitividade para diversos segmentos industriais como: celulose e papel, siderurgia, painéis, móveis e em uma gama de produtos.

O Brasil, por se destacar no mercado florestal, está cada vez mais preocupado em utilizar os recursos florestais de forma ordenada. As florestas plantadas impulsionam a sociedade brasileira nos setores econômicos, sociais e ambientais, que podem ser mensurados pela avaliação de seus principais indicadores: a área de florestas plantadas, o valor bruto da produção, a geração de impostos, o valor das exportações e o número de empregos gerados e mantidos pelo setor em geral (BARROS JUNIOR, 2009).

Dados da Associação Brasileira de Produtores de Florestas Plantadas (ABRAF, 2012) referentes ao ano de 2011 mostram que 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 (0,5% da arrecadação nacional), as exportações foram de 7,97 bilhões (3,1% do total das exportações do Brasil) e o número de empregos gerados foi de 4.730.000, diretos e indiretos.

Os dados mostram que, tanto para o país quanto para as empresas da área florestal, uma boa gestão do processo de produção florestal voltada para maximizar os retornos econômicos, ambientais e sociais, e atender às exigências legais impostas pelo tipo de processo de produção, é de extrema relevância.

O planejamento florestal envolve, normalmente, um grande número de aspectos como: limitações de área, capital, mão de obra; além de atender várias outras restrições como: demanda anual de mercado, regulação da floresta, capacidade de reforma, entre outros. Muitos desses fatores são agravados pelas características próprias do setor florestal, que trabalha com ciclos longos e, além de tudo, a empresa tem que atender exigências legais, ambientais e sociais, o que torna a análise muito complexa.

Teixeira (2002), Weintraub et al. (2000) e Goycoolea et al. (2009) destacam as características inerentes aos problemas de planejamento do manejo florestal: natureza combinatória, problema típico de programação inteira, objetivos competitivos e conflitantes e que contém muitas variáveis aleatórias.

Procurando atender às exigências impostas pelo processo de produção florestal, pesquisadores desenvolveram trabalhos buscando modelar o Problema de Planejamento Florestal (PPF) para tomar decisões melhores em situações muito complexas. Neste trabalho, é utilizado o modelo proposto originalmente por Kidd et al. (1966, apud DYKSTRA, 1984), no qual cada variável de decisão representa uma alternativa de manejo, ou seja, uma sequência única de intervenções programadas para uma unidade de produção (CLUTTER et al., 1983). Vários exemplos de aplicação desse modelo no planejamento dos recursos florestais no Brasil são encontrados na literatura, como os trabalhos de Rodrigues (2001), Pereira (2004), Rodrigues (2006), Castro (2007), Silva et al. (2009) e Gomide (2009).

Além disso, diversos trabalhos envolvendo técnicas heurísticas foram desenvolvidos e, dentre eles, pode-se citar o trabalho de Weintraub et al. (2000), Teixeira (2002), Boston e Bettinger (2002), Caro et al. (2003), Rodrigues (2003), Pereira (2004), Rodrigues (2004), Sessions et al. (2007), Barros Junior et al. (2009), Barros Junior e Pereira (2011) e Barros Junior et al. (2012).

Este trabalho tem como objetivo a aplicação da meta-heurística híbrida *Clustering Search* (CS) com uma *Iterated Local Search* (ILS) para resolução de um Problema de Planejamento Florestal (PPF). Os resultados obtidos pelo método proposto são comparados com os resultados obtidos pela meta-heurística ILS aplicada de forma isolada, que foi proposta em um trabalho anterior. Assim, o potencial e a contribuição da CS em melhorar as soluções obtidas pela ILS também ficam evidentes.

O trabalho é organizado como segue: inicialmente, na Seção 2, é apresentada a modelagem matemática de programação linear inteira 0-1, proposta por Johnson e Scheurman (1977). Em sequência, na Seção 3, são apresentados os detalhes da metodologia utilizada para resolução do PPF. Na Seção 4 são apresentados os resultados computacionais obtidos, e as conclusões são descritas na Seção 5.

2. Descrição do Problema

Neste trabalho, o objetivo considerado para o Problema de Planejamento Florestal (PPF) é baseado na maximização do lucro obtido pelo corte de madeira de diversas Unidades de Produção (UP's). A escolha das UP's para corte é realizada conforme a Alternativa de Manejo selecionada. Ou seja, busca-se então definir a melhor AM para as diferentes UP's.

Uma UP, também conhecida na área florestal como talhão, consiste em uma divisão feita na floresta, na qual toda árvore que pertence a uma determinada UP possui as mesmas características tais como: mesma idade, mesma espécie, e mesmas intervenções. Já as AM's, ou prescrições, são as formas de se realizar o manejo de corte das UP's.

O modelo empregado neste trabalho é um modelo de Programação Inteira proposto por Johnson e Scheurman (1977), que é apresentado a seguir:

Maximizar

$$z = \sum_{i=1}^M \sum_{j=1}^{N_i} VPL_{ij} x_{ij} \quad (1)$$

Sujeito a:

$$\sum_{j=1}^{N_i} x_{ij} = 1 \quad i = 1, \dots, M \quad (2)$$

$$V_k \leq \sum_{i=1}^M \sum_{j=1}^{N_i} V_{ijk} x_{ij} \quad k = 0, 1, \dots, H - 2 \quad (3)$$

$$CR_k \geq \sum_{i=1}^M \sum_{j=1}^{N_i} A_{ijk} x_{ij} \quad k = 0, 1, \dots, H - 2 \quad (4)$$

$$x_{ij} \in \{0, 1\} \quad i = 1, \dots, M; j = 1, \dots, N_i \quad (5)$$

Em que:

- z = lucro total (soma dos lucros de cada unidade de produção);
- M = número total de unidades de produção;
- 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 alternativa de manejo j , e $x_{ij} = 0$ caso contrário;
- k = período de tempo;
- V_k = volume total (m³) da demanda a ser atendida no período k ;
- V_{ijk} = volume total produzido pela unidade de produção i sob a alternativa de manejo j , no k -ésimo período do horizonte de planejamento conforme a idade de corte naquele período;
- H = horizonte de planejamento;
- CR_k = capacidade de reforma da floresta;
- A_{ijk} = área da i -ésima unidade de produção sob a j -ésima alternativa de manejo, no início do período k e que esteja sob o regime de manejo de reforma;

- VPL_{ij} = valor presente líquido (VPL) da unidade de produção i sob a alternativa de manejo j . Esse valor é dado pela diferença dos valores de receitas e custos, descontados a uma taxa determinada, conforme Equação (6):

$$VPL_{ij} = \sum_{k=0}^n R_k (1+t)^{-k} - \sum_{k=0}^n C_k (1+t)^{-k} \quad (6)$$

- R_k = receita no final do período de tempo k ;
- C_k = custo no final do período de tempo k ;
- t = taxa de desconto;
- n = duração do projeto em número de períodos de tempo.

A função objetivo (1) representa a maximização do lucro, ou seja, a soma dos Valores Presentes Líquidos (VPL) das UP's sobre uma alternativa de manejo escolhida. A restrição (2) garante a escolha de uma única alternativa de manejo j para a unidade de produção i . A restrição (3) representa a imposição de cotas anuais de produção, ou seja, a produção periódica de madeira deve atender a uma demanda preestabelecida. A restrição (4) representa a capacidade máxima de reforma que a empresa florestal é capaz de realizar a cada período. Por fim, a restrição (5) garante que as variáveis de decisão sejam binárias, ou seja, indicam se a unidade de produção i será cortada sob a alternativa de manejo j .

3. Método de Solução

Nessa seção são apresentados detalhes da modelagem do problema e a descrição das meta-heurísticas utilizadas.

3.1 Representação de uma Solução

Cada solução S é construída em forma de uma matriz que contém um determinado número de UP's, representadas na Figura 1 pelas letras de "A" a "E", e para cada UP, existe um conjunto de possíveis AM's.

		Unidades de Produção					Fitness
		A	B	C	D	E	
Alternativas de Manejo	S	8	2	3	1	5	78
	1	1	1	1	1		
	2	2	2	2	2		
	3	3	3	3	3		
	4	4	4	4	4		
	5	5	5	5	5		
	6	6			6	6	
	7	7				7	
	8	8					

Figura 1 - Representação de uma solução S .

As AM's consideradas neste trabalho foram obtidas por meio de um protótipo proposto por Teixeira (2002), denominado Gerador de Prescrições. Esse gerador é um *software* que gera um conjunto de AM's para cada UP.

A Figura 2 ilustra uma situação na qual o usuário deseja obter a AM que contenha o maior Valor Presente Líquido (VPL). Neste caso, a AM número 8 seria a escolhida para a unidade de produção "A", uma vez que o maior VPL pertence a esta alternativa. No detalhe, a alternativa de manejo 8 está associada a uma condução no 7º período do planejamento, isso implica em um VPL de R\$ 502.005,40 e um custo de R\$ 331.438,20. Ainda na Figura 2, a letra "x" representa o ano em que a UP foi plantada e o ano "0" (zero) representa o ano corrente.

Horizonte de Planejamento																			VPL	Custo	
UP	AM	Regime	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6	7			8
A	1	5 5				x					r					r				296.514,10	400.583,40
A	2					x					c					c				395.611,80	301.485,60
A	3					x					c					r				349.846,70	347.250,70
A	4	5 6				x					r						r			354.817,80	418.761,30
A	5					x					c						c			455.284,50	318.294,60
A	6					x					c						r			408.150,40	365.428,60
A	7	5 7				x					r							r		400.740,40	432.703,20
A	8					x					c							c		502.005,40	331.438,20

Figura 2 - Representação de uma Alternativa de Manejo (AM).

3.2 Clustering Search (CS)

Segundo Chaves e Lorena (2010), a CS é um método iterativo que procura dividir o espaço de busca e localizar regiões promissoras por meio do enquadramento dessas em *clusters*.

Um *cluster* C_j é definido por um centro c_j , que é uma solução que representa o *cluster* j , ou seja, representa a “localização” do *cluster* j no espaço de soluções. Cada *cluster* possui um volume v_j , que indica a quantidade de soluções associadas a ele, e também um índice de ineficácia r_j , que é utilizado para identificar se a busca local está melhorando a sua solução. Assim, um *cluster* j pode ser representado como $C_j = \{c_j, v_j, r_j\}$, sendo c_j , v_j e r_j representações do centro, volume e ineficácia, respectivamente.

Em linhas gerais, a CS pode ser descrita basicamente por três partes: uma meta-heurística geradora de soluções; um algoritmo de agrupamento de soluções; e uma heurística de busca local. A Figura 3 apresenta um fluxograma que descreve o funcionamento da CS.

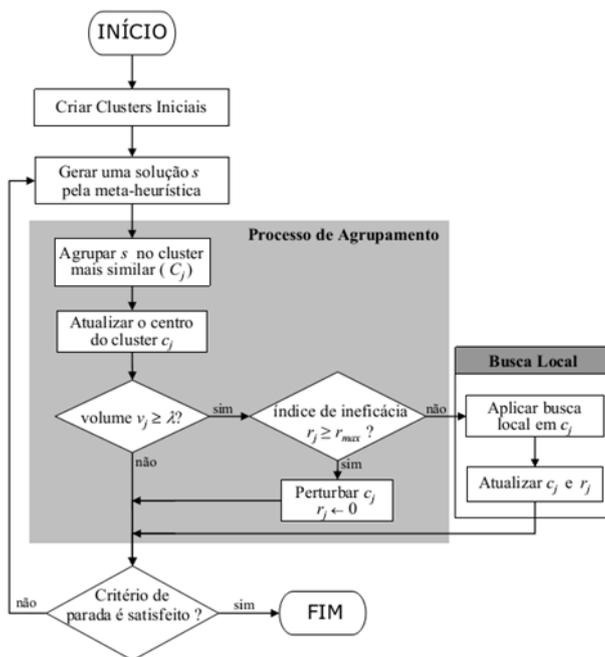


Figura 3 - Fluxograma da CS (CHAVES; LORENA, 2010).

O processo é iniciado pela criação de um conjunto de *clusters*, ou seja, um conjunto de soluções diferentes sendo que cada uma é associada a um *cluster*. A partir de então, uma meta-heurística é responsável por gerar uma solução S , que é enviada para o processo de agrupamento. A solução S é agrupada no *cluster* C_j que for mais similar a ela e, com isso, o centro c_j do *cluster* é alterado, fazendo com que este se desloque no espaço de soluções.

Em seguida, é analisado o volume v_j e, caso este tenha atingido um limitante λ , é sinal que esse *cluster* pode ser uma região promissora. Neste momento, é verificado o índice de

ineficácia r_j e, caso este tenha atingido o limitante r_{max} , uma perturbação no centro do *cluster* é aplicada. Caso contrário, uma busca local é realizada no centro do *cluster*.

Após a realização da busca local, o índice de ineficácia e o centro do *cluster* são atualizados e o processo retorna para a meta-heurística geradora de soluções, recomeçando assim o ciclo.

Neste trabalho, a criação dos *clusters* iniciais é realizada por meio das primeiras iterações da meta-heurística geradora. Um número máximo de *clusters* γ é definido e, assim, as primeiras γ soluções geradas são atribuídas como centro dos *clusters*. A partir de então, as três partes básicas da CS são utilizadas, conforme descrito a seguir.

3.2.1 Meta-Heurística Geradora de Soluções

Neste trabalho, foi utilizada uma *Iterated Local Search* (ILS) baseada na proposta de Barros Junior et al. (2012). A ILS é uma meta-heurística baseada na ideia de que um procedimento de busca local pode ser melhorado, gerando-se novas soluções de partida, as quais são obtidas por meio de perturbações em uma solução ótima local (LOURENÇO et al., 2002). Nesse método, 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). Dessa forma, a perturbação deve permitir que a busca local explore diferentes soluções, além de evitar um reinício aleatório.

A Figura 4 apresenta um pseudocódigo básico do algoritmo ILS, que possui 4 etapas principais: a primeira etapa (passo 1) é responsável pela obtenção de uma solução ótima local inicial S_1 ; na segunda etapa (passo 4) é realizada uma perturbação da solução S_1 obtendo uma nova solução S_2 . Essa perturbação é realizada em uma parte aleatória da solução, sendo essa parte escolhida de acordo com um índice d que é definido de acordo com o número de UP's. Neste trabalho, foi definido o índice de 20% do total de UP's. Esse índice foi definido empiricamente.

Na etapa seguinte (passo 5) é realizada uma melhoria na solução S_2 por meio de uma busca local, sendo essa responsável por vasculhar o espaço de soluções em busca da melhor solução; e a etapa final (passo 6) é responsável pelo critério de aceitação da solução atual, na qual será verificado se a solução atual é melhor que a solução que já estava armazenada. Se a solução corrente for melhor a melhor solução é atualizada, caso contrário, a solução corrente é descartada e a melhor solução continua sendo a antiga. Nesse momento, é testada a condição de parada, se for satisfeita a melhor solução atual é retornada, caso contrário volta-se a segunda etapa (passo 4).

Com exceção da primeira etapa, todas as demais são executadas iterativamente enquanto o critério de parada não é atendido. Após as iterações, o algoritmo retorna a melhor solução obtida durante toda sua execução.

```

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

```

Figura 4 - Pseudocódigo do ILS (LOURENÇO et al., 2002).

A solução inicial é obtida a partir da formação de um conjunto com n soluções viáveis para o problema, sendo essas geradas de forma parcialmente gulosa e aleatória, e agrupadas em um conjunto C . Esse conjunto fica ordenado de forma decrescente conforme o VPL de cada uma. Desse conjunto, somente as α primeiras soluções serão utilizadas para o processo de formação da

solução inicial S e, para cada UP da solução inicial, será escolhida uma AM de uma solução do conjunto C . Após a formação da solução, é verificado se ela é uma solução viável para o problema e, em caso positivo, ela é retornada como a solução inicial e, caso contrário, o processo é retomado e outra solução será gerada. Esse processo busca gerar uma solução inicial o mais heterogênea possível. O processo de busca local e a perturbação são os mesmos utilizados na CS, e são descritos a seguir.

3.2.2 Agrupamento de Soluções

Para que as soluções sejam agrupadas em *clusters* similares, deve-se encontrar uma forma para medir o “grau de similaridade” entre as soluções. Assim como nos principais trabalhos que utilizam a CS, neste trabalho é utilizada a distância de Hamming (HAMMING, 1950). Assim, como cada solução é representada por meio de uma matriz (Figura 1), a *distância* de Hamming é calculada com base no número de diferentes alternativas de manejo atribuídas a cada unidade de produção. Logo, quanto mais diferenças existirem entre duas soluções, maior será a “distância” entre elas.

3.2.3 Heurística de Busca Local

A heurística de busca local consiste em vasculhar a vizinhança de uma solução buscando uma que seja viável e melhor e, caso o processo encontre uma solução melhor, essa será retornada substituindo a anterior. Neste trabalho, a busca local utilizada consiste basicamente na troca das alternativas de manejo de cada uma das UP's da solução. A troca é realizada na primeira UP e se repete para todas as alternativas de manejo em cada uma das demais UP's. A perturbação utilizada é baseada na troca aleatória das AM's para um conjunto de UP's definido pelo índice d (“taxa de destruição”). Assim, as AM's relacionadas a cada UP nesse conjunto é são alteradas aleatoriamente.

Definidas então as três partes principais da CS, o algoritmo ILS é modificado, sendo inserido entre suas linhas 5 e 6 o código da CS, conforme a Figura 5.

```

Procedimento CS
1. dada (uma solução  $S$ );
2. encontrar (o cluster  $C_j$  mais similar a  $S$ );
3.  $v_j \leftarrow v_j + 1$ ;
4. atualizar (o centro do cluster  $C_j$ );
5. se  $v_j \geq \lambda$  então
6.    $v_j \leftarrow 1$ ;
7.   se  $r_j \geq r_{\max}$  então
8.     aplicar (perturbação em  $c_j$ )
9.      $r_j \leftarrow 0$ ;
10.  senão
11.    aplicar (busca local - gerar  $c_j'$ );
12.    se  $f(c_j') < f(c_j)$  então
13.       $r_j \leftarrow r_j + 1$ ;
14.    senão
15.       $c_j \leftarrow c_j'$ ;
16.       $r_j \leftarrow 0$ ;
17.    fim-se;
18.  fim-se;
19. fim-se;
fim CS;

```

Figura 5 - Algoritmo CS.

4. Resultados Computacionais

Inicialmente, com o intuito de calibrar a CS, foram definidos empiricamente, por meio de diversos experimentos computacionais, os valores dos parâmetros, sendo: número de *clusters* (γ) = 5, volume máximo (λ) = 10, e o índice de ineficácia (r_{\max}) = 5. Já o critério de parada foi baseado no tempo de execução, assim como o utilizado pela ILS proposta por Barros Junior et al. (2012), que é utilizada como comparação para a CS proposta.

Foi utilizado um conjunto de 10 instâncias (Tabela 1) baseadas em dados reais e em dados obtidos da literatura (TEIXEIRA, 2002). Cada instância é classificada quanto ao número de unidades de produção, sendo “A” com 50 unidades e “B” com 100 unidades. Em cada classe, os horizontes de planejamento variam entre 9 e 14 anos que, combinado com o número de unidades de produção, determina o número de possíveis alternativas de manejo. O tempo para resolução de cada instância é apresentado na última coluna dessa tabela. Assim como utilizado por Barros Junior et al. (2012), o tempo foi definido pela fórmula $(M \times \sqrt{m})/4$, sendo que M representa o número total de UP's e m representa o número total de AM's disponíveis para a instância. O resultado é dado em segundos e posteriormente convertido para minutos.

Tabela 1 - Descrição das instâncias utilizadas.

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

A principal diferença entre as instâncias que contém o mesmo número de AM's está relacionada com os valores utilizados na definição dos níveis de demanda anual (Tabela 2). Estes valores foram considerados na restrição (3) do problema.

Tabela 2 - Volume total (m³) da demanda a ser atendida no período k .

Período (k)	Instâncias									
	1	2	3	4	5	6	7	8	9	10
0	500.000	550.000	575.000	575.000	575.000	575.000	1.000.000	1.300.000	900.000	1.100.000
1	500.000	550.000	575.000	575.000	575.000	575.000	1.000.000	1.300.000	900.000	1.100.000
2	600.000	650.000	675.000	575.000	675.000	675.000	1.200.000	1.350.000	1.000.000	1.200.000
3	700.000	750.000	775.000	575.000	675.000	675.000	1.300.000	1.350.000	1.100.000	1.300.000
4	800.000	850.000	875.000	575.000	675.000	675.000	1.400.000	1.400.000	1.200.000	1.400.000
5	800.000	850.000	875.000	575.000	675.000	675.000	1.400.000	1.450.000	1.200.000	1.400.000
6	800.000	850.000	875.000	575.000	675.000	700.000	1.500.000	1.500.000	1.300.000	1.500.000
7	900.000	950.000	975.000	575.000	675.000	700.000	1.500.000	1.500.000	1.300.000	1.500.000
8	900.000	950.000	975.000	575.000	675.000	700.000	1.550.000	1.550.000	1.350.000	1.550.000
9	-	-	-	575.000	675.000	700.000	-	-	1.350.000	1.550.000
10	-	-	-	575.000	675.000	700.000	-	-	1.400.000	1.600.000
11	-	-	-	575.000	675.000	700.000	-	-	1.400.000	1.600.000
12	-	-	-	575.000	675.000	700.000	-	-	1.500.000	1.700.000
13	-	-	-	575.000	675.000	700.000	-	-	1.500.000	1.700.000

Outra diferença entre as instâncias que contém o mesmo número de AM's está relacionada à capacidade de reforma (Tabela 3), considerada na restrição (4) do problema.

Tabela 3 - Capacidade de reforma (ha) a ser atendida no período k .

Período (k)	Instâncias									
	1	2	3	4	5	6	7	8	9	10
0	6.000	7.000	8.000	8.000	8.000	8.000	7.500	8.500	7.500	7.500
1	6.500	7.500	8.500	8.000	8.000	8.000	7.500	8.500	7.500	7.500
2	7.000	8.000	9.000	9.000	9.000	8.000	7.500	8.500	7.500	7.500
3	7.500	8.500	9.500	10.000	10.000	8.000	7.500	8.500	7.500	7.500
4	8.000	9.000	10.000	11.000	11.000	8.000	7.500	8.500	7.500	7.500
5	8.500	9.500	10.500	11.000	11.000	8.000	7.500	8.500	7.500	7.500
6	9.000	10.000	11.000	11.000	11.000	8.000	7.500	8.500	7.500	7.500
7	9.500	10.500	11.500	12.000	12.000	8.000	7.500	8.500	7.500	7.500
8	10.000	11.000	12.000	12.000	12.000	8.000	7.500	8.500	7.500	7.500
9	-	-	-	12.000	12.000	8.000	-	-	7.500	7.500
10	-	-	-	12.000	12.000	8.000	-	-	7.500	7.500
11	-	-	-	12.000	12.000	8.000	-	-	7.500	7.500
12	-	-	-	12.000	12.000	8.000	-	-	7.500	7.500
13	-	-	-	12.000	12.000	8.000	-	-	7.500	7.500

Para cada instância, a CS foi executada 10 vezes, e os resultados obtidos são apresentados na Tabela 4. Nessa tabela, são apresentadas as médias (entre as 10 execuções) e o desvio padrão (diferença entre o maior valor encontrado e o valor médio) obtidos, para cada instância, tanto pela ILS proposta por Barros Junior et al. (2012) quanto pela CS proposta neste trabalho. Os melhores resultados estão destacados em negrito.

Tabela 4 - Resultados obtidos e comparação com a literatura.

Instância	Solução Média		Desvio Padrão	
	ILS	CS	ILS	CS
1	169.481.636,02	180.544.282,35	1.435.756,33	1.173.391,54
2	167.639.487,08	177.870.887,46	1.396.218,97	2.476.727,93
3	165.349.120,37	175.589.876,35	2.588.642,94	1.896.868,77
4	518.305.492,92	560.085.359,77	7.949.461,71	1.571.261,87
5	510.175.078,03	552.385.227,43	5.482.554,66	2.939.029,59
6	242.221.520,45	259.000.615,57	2.037.091,42	1.016.226,30
7	240.994.388,04	256.585.336,21	5.136.751,37	1.754.278,40
8	240.068.244,64	256.144.408,10	1.408.773,65	3.195.346,70
9	365.912.324,78	395.307.241,99	4.183.461,67	1.677.307,83
10	364.280.139,78	394.243.080,80	3.057.853,64	695.354,99
Média	298.442.743,21	320.775.631,60	3.467.656,64	1.839.579,39

Como pode ser observado na Tabela 4, a CS obteve as melhores soluções médias para as 10 instâncias, e o desvio padrão foi inferior em apenas duas. As diferenças entre os resultados comprovam a melhoria proporcionada pela aplicação da CS em relação a ILS executada de forma isolada para resolução do PPF. As melhores soluções obtidas tanto pela ILS quanto pela CS são apresentadas na Tabela 5. Mais uma vez, fica evidente o desempenho da CS proposta.

Tabela 5 - Melhores soluções obtidas para cada instância.

Instância	Melhor Solução	
	ILS	CS
1	170.917.392,35	181.717.673,89
2	169.035.706,05	180.347.615,39
3	167.937.763,31	177.486.745,12
4	526.254.954,63	561.656.621,64
5	515.657.632,69	555.324.257,02
6	244.258.611,87	260.016.841,87
7	246.131.139,41	258.339.614,61
8	241.477.018,29	259.339.754,80
9	370.095.786,45	396.984.549,82
10	367.337.993,41	394.938.435,78
Média	301.910.399,85	322.615.210,99

Toda a implementação foi desenvolvida na linguagem *Object Pascal*, e os experimentos foram executados em um microcomputador Intel Core 2 Duo 2.20GHz com 4GB de memória RAM.

5. Conclusões

Neste trabalho foi proposta uma aplicação da meta-heurística híbrida *Clustering search* utilizando a *Iterated Local Search* (ILS) para resolução do Problema de Planejamento Florestal (PPF). Os resultados obtidos foram comparados com aqueles apresentados pela ILS aplicada de forma isolada, reportados em um trabalho anterior encontrado na literatura.

A CS, que é uma técnica relativamente nova para a resolução de problemas combinatoriais, mostrou-se eficiente na resolução do PPF, uma vez que a mesma encontrou melhores soluções, e melhores médias, para as 10 instâncias consideradas.

Assim, com a aplicação da CS, foi possível encontrar uma melhora significativa nas melhores soluções conhecidas até então, isto é, com a aplicação da CS, pode-se obter uma maior lucratividade para as instâncias consideradas.

Logo, a CS demonstrou ser uma nova alternativa para resolução do PPF, apresentado um bom desempenho quando comparado a um método proposto em um trabalho recente sobre o problema.

Agradecimentos

Os autores agradecem ao CNPq (processos 300747/2010-1 e 477148/2011-5) e à FAPES (processo 59830042/2012) pelo apoio financeiro.

Referências

- ABRAF - Associação Brasileira dos Produtores de Florestas Plantadas.** *Anuário Estatístico da ABRAF 2012 – Ano Base 2011, 2012*, (<http://www.abraflor.org.br/estatisticas.asp>), 4, 2013.
- Barros Junior, A. A., Arroyo, J. E. C. e Santos, H. N.** (2009), GRASP com path relinking para um problema de planejamento florestal, *Anais do XLI SBPO - Simpósio Brasileiro de Pesquisa Operacional*.
- Barros Junior, A. A. e Pereira G. W.** (2011), Aplicação da metaheurística algoritmo genético com path relinking para a solução de um problema de planejamento florestal, *Anais do XVIII SIMPEP - Simpósio de Engenharia de Produção*.
- Barros Junior, A. A., Pereira G. W., Mauri, G. R. e Melo, R. S.** (2012), Aplicação da meta-heurística simulated annealing para a solução de um problema de planejamento florestal, *Anais do XIX SIMPEP - Simpósio de Engenharia de Produção*.
- Boston, K. e Bettinger, P.** (2002), Combining tabu search and genetic algorithms heuristic techniques to solve spatial harvest scheduling problems. *Forest Science*, 48, 35-46.

- Brito, J. A. M., Montenegro, F. M. T. e Ochi, L. S.** (2009), Um algoritmo ILS para melhoria de eficiência da estratificação estatística. *Anais do XLI SBPO - Simpósio Brasileiro de Pesquisa Operacional*.
- Caro, F., Constantino, M., Martins, I. e Weintraub, A.** (2003), A 2-Opt Tabu Search Procedure for the multi-period forest harvesting problem with adjacency, green-up, old growth and even flow constraints. *Forest Science*, 49, 738-751.
- Castro, R. R.** Regulação de florestas equiâneas incluindo restrições de adjacência, *Dissertação de Mestrado em Ciência Florestal*, Universidade Federal de Viçosa - UFV, 2007.
- Chaves, A. A. e Lorena, L. A. N.** (2010), Clustering search algorithm for the capacitated centered clustering problem, *Computers & Operations Research*, 37, 552-558.
- Clutter, J. L. et al.** *Timber Management: a quantitative approach*. New York, John Wiley & Sons. 333, 1983.
- Dykstra, D. P.** *Mathematical programming for natural resource management*. McGraw-Hill. 318, 1984.
- Goycoolea, M., Murray, A., Vielma, J. P. e Weintraub, A.** (2009), Evaluating approaches for solving the area restriction model in harvest scheduling, *Forest Science*, 55, 149-165.
- Gomide, L. R.** Planejamento florestal espacial, *Tese de Doutorado em Ciências Florestais*, Universidade Federal do Paraná - UFPR, 2009.
- Hamming, R. W.** (1950), Error detecting and error correcting codes, *Bell System Technical Journal*, 26, 147-160.
- Johnson, K. N. e Scheurman, H. L.** Techniques for prescribing optimal timber harvest and investment under different objectives, discussion and synthesis, *Forest Science Monograph*, USA, 1977.
- Lourenço, H. R., Martin, O., Stutzle, T.**, Iterated local search, em Glover, F. e Kochenberger, G. (Eds.), *Handbook of Metaheuristics*, Kluwer Academic Publishers, Norwell, MA, 321-353, 2002.
- Pereira, G. W. e Santos, H. N.** Aplicação da técnica de recozimento simulado na solução de problemas de planejamento florestal multiobjetivo. *Dissertação de Mestrado em Ciência da Computação*, Universidade Federal de Minas Gerais - UFMG, 2004.
- Rodrigues, F. L.** Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais, *Tese de Doutorado em Ciência Florestal*, Universidade Federal de Viçosa - UFV, 2001.
- Rodrigues, F. L., Leite, H. G., Santos, H. N. e Souza, A. L.** (2003), Solução de problemas de planejamento florestal com restrições de inteireza utilizando busca tabu, *Revista Árvore*, 27, 701-713.
- Rodrigues, F. L.** (2004), Metaheurística simulated annealing para solução de problemas de planejamento florestal com restrições de integridade, *Revista Árvore*, 28, 247-256.
- Rodrigues, F. L., Silva, G. F., Leite, H. G., Xavier, A. C. e 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*, 30, 769-778.
- Sessions, J., Bettinger, P. e Murphy, G.** Heuristics in Forest Planning, em Weintraub A., Romero C., Bjørndal, T., Epstein, R. e Miranda, J. (Eds.), *Handbook Of Operations Research In Natural Resources*, Springer, US, 431-448. 2007.
- Silva, G. F., Piassi, L. C., Môra, R., Martins, L. T., Teixeira, A. F. e Barros Junior, A. A.** (2009), Metaheurística algoritmo genético na solução de modelos de planejamento florestal, *Agrária – Revista Brasileira de Ciências Agrárias*, 4, 160-166.
- Teixeira, A. F.** Aplicação de algoritmos evolucionários na solução de problemas de planejamento florestal multiobjetivo, *Dissertação de Mestrado em Ciência da Computação*, Universidade Federal de Minas Gerais - UFMG, 2002.

Weintraub A., Church, R. L., Murray, A. e Guignard, M. (2000), Forest management models and combinatorial algorithms: analysis of state of the art, *Operations Research*, 96, 271–285.