

CLUSTERING SEARCH COM PATH RELINKING PARA RESOLUÇÃO DE UM 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
geraldo.mauri@ufes.br

RESUMO

Este trabalho propõe a utilização da meta-heurística *Clustering Search* (CS) com a técnica de intensificação *Path Relinking* (PR) aplicada à resolução de um Problema de Planejamento Florestal (PPF). O PPF se baseia na escolha da melhor alternativa de manejo (AM) para cada unidade de produção (UP) da floresta. O objetivo do PPF é obter um maior valor presente líquido (VPL) com a atividade de extração de madeira. Neste trabalho, é utilizada a meta-heurística *Clustering Search* (CS) e a técnica de intensificação *Path Relinking* (PR) com o objetivo de conseguir alcançar melhores resultados para o PPF. Os resultados obtidos pelo método proposto serão comparados com outros métodos encontrados na literatura.

PALAVRAS CHAVE. Planejamento Florestal, *Clustering Search*, *Path Relinking*.

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

ABSTRACT

This work proposes the use of Clustering Search (CS) meta-heuristic with the Path Relinking (PR) intensification technique applied to solve a Forest Planning Problem (PPF). The PPF is based on choosing the best management alternative (AM) for each production unit (PU) of the forest. The PPF seeks for a higher net present value (VPL) with the logging activity. This work used the Clustering Search (CS) meta-heuristic and the Path Relinking (PR) intensification technique to achieve better results for PPF. The results obtained by the proposed method are compared with other methods found in the literature.

KEY WORDS. Forest Planning, *Clustering Search*, *Path Relinking*.

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

1. Introdução

As árvores plantadas são uma matéria-prima renovável, reciclável e amigável ao meio ambiente, à biodiversidade e à vida humana. O Brasil possui 7,6 milhões de hectares plantados de eucalipto, pinus e demais espécies, as quais são utilizadas como matéria-prima na produção de painéis de madeira, pisos laminados, celulose, papel, florestas energéticas e biomassa (IBA, 2015).

A gestão otimizada destes recursos é um grande desafio para as empresas do setor. Dentre os diversos problemas que envolvem o planejamento estratégico de florestas plantadas, o Problema de Planejamento Florestal (PPF) é um importante objeto de estudo.

Buongiorno e Gilles (1987) ressaltam que o PPF envolve diversos tipos de variáveis que nem sempre podem ser inter-relacionadas, isso faz com que o sistema se torne muito complexo e dificulta a tomada de decisão.

Para melhor entendimento do PPF, considere uma floresta subdividida em diversas áreas heterogêneas denominadas Unidades de Produção (UP's). Cada UP contém características próprias como material genético, idade, classe de produtividade e um conjunto de Alternativas de Manejo (AM's). Uma AM refere-se à sequência 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.

De forma objetiva, o PPF consiste em definir quais unidades de produção (UP's) serão desbastadas de forma a atender a indústria em um determinado período de tempo.

Nos últimos anos, diversos trabalhos foram publicados com objetivo de encontrar melhores alternativas para o PPF, dentre eles pode-se citar: Busca Tabu, *Simulated Annealing* (SA), Algoritmo Genético (AG) (Rodrigues, 2001); SA e AG (Gomide, 2009); AG (Silva et al., 2009); *Greedy Randomized Adaptive Search Procedure* (GRASP) com a técnica de intensificação *Path Relinking* (PR) (Barros Junior et al., 2009); AG juntamente com a técnica de intensificação PR (Barros Junior e Pereira, 2011); SA (Barros Junior et al., 2012); CS com ILS (Melo et al., 2013); e CS com GRASP (Melo et al., 2014).

1.1. Modelo de Programação Inteira para o PPF

O modelo utilizado neste trabalho é um modelo de Programação Inteira proposto por Johnson e Scheurman (1977), o qual apresenta a seguinte especificação:

Maximizar

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

Sujeito a:

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

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

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

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

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):

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

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 .

1.2. Representação de uma Solução

No caso do PPF, pode-se representar uma solução S na forma de um vetor, no qual cada posição representa uma UP diferente. Assim, o vetor terá o número de posições igual ao número de UP's da instância do problema, de acordo com a representação apresentada na Figura 1. Para cada UP no vetor, existe um conjunto de possíveis alternativas de manejo (AM) associadas, mas, para cada UP, apenas uma alternativa j deve ser escolhida. No exemplo ilustrado pela Figura 1, para a solução S , foram escolhidas as alternativas de manejo 8, 2, 3, ..., 1 e 5 para as UP's 1, 2, 3, ..., 18 e 19 respectivamente.

S		Alternativas de Manejo (j)									
		1	2	3	4	5	6	7	8	9	
Unidades de Produção (i)	1	8									
	2	2									
	3	3									
	⋮										
	18	1									
	19	5									
	78		<i>fitness</i>								

FIGURA 1 - Representação de uma solução S (MELO et al., 2014).

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

Uma prescrição é cada alternativa de manejo (AM) em uma unidade de produção (UP). Para cada UP, podem existir centenas de AM's diferentes, que são obtidas pela combinação das idades de corte, opções de reforma da floresta, desbastes ou condução de brotação e quaisquer outras características que se queira. No exemplo da Figura 2, foram geradas 8 prescrições para a UP 1. O objetivo dos métodos propostos é escolher a melhor AM para cada UP, levando em conta todas as restrições impostas pelo problema, e buscando obter o maior Valor Presente Líquido (VPL). A alternativa selecionada na Figura 2 representa que a UP sofrerá duas intervenções, sendo uma condução por brotação no ano "0", que representa o ano atual, e outra condução no ano 7. O ano no qual a floresta foi plantada é representado pela letra "x".

UP	AM	Regime	Horizonte de Planejamento																VPL	Custo	
			-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6	7			8
A	1	55				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	56				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	57				x				r							r			400.740,40	432.703,20
A	8					x				c							c			502.005,40	331.438,20

FIGURA 2 - Gerador de prescrições (MELO et al, 2013).

1.3. Objetivos

Este trabalho tem como objetivo a utilização da meta-heurística *Clustering Search* (CS) utilizando o *Path Relinking* (PR) para intensificar as melhores soluções obtidas para resolução do PPF descrito nesta seção. A CS já foi utilizada por Melo et al. (2013) e Melo et al. (2014) na resolução do PPF, porém, considerando as meta-heurísticas *Iterated Local Search* (ILS) e GRASP, respectivamente, como geradoras de soluções. Neste trabalho, é proposta a substituição destas meta-heurísticas pela *Simulated Annealing* (SA) na fase de geração de soluções da CS, bem como intensificar as melhores soluções obtidas através da técnica *Path Relinking* (PR). O desempenho do método proposto (CS-SA-PR) é comparado diretamente aos métodos GRASP, AG, ILS, CS-ILS e CS-GRASP encontrados na literatura.

O restante do trabalho é organizado da seguinte forma: a Seção 2 apresenta detalhes da metodologia adotada para a utilização da CS com o SA e a PR; os resultados computacionais são apresentados na Seção 3, e as conclusões são descritas na Seção 4.

2. Metodologia

A opção de utilizar o SA como meta-heurística geradora de soluções para a CS foi um processo natural visto que o mesmo já fora testado para esse tipo de problema e a CS também testada com outras meta-heurísticas geradoras. Outro aspecto que motivou o uso desses métodos foi o fato de os mesmos terem encontrados bons resultados em outros trabalhos como: Chaves et al. (2008) no problema de balanceamento e designação de trabalhadores em linha de produção, Almeida e Senne (2010) com o problema de localização de *hubs* com restrições de capacidade; Araújo e Mauri (2013) na resolução de um problema de rotação de culturas com restrições de adjacências e Rabello et al. (2013) para resolver o problema de rotulação cartográfica de pontos.

Como mencionado anteriormente, a CS já foi utilizada na resolução do PPF nos trabalhos de Melo et al. (2013) e Melo et al. (2014), porém utilizando o *Iterated Local Search* (ILS) e a GRASP, respectivamente, como geradoras de solução para a CS.

2.1 Clustering Search (CS)

A *Clustering Search* (CS) parte do pressuposto que um processo de busca pode ser otimizado por meio do agrupamento de soluções em *clusters* diferentes e realizando uma busca local somente em *clusters* promissores. A Figura 3 representa o pseudocódigo da CS.

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 3 - PseudoCódigo da CS (MELO et al., 2013).

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

O centro do *cluster* (c_j) é uma solução que representará o *cluster* C_j no espaço de soluções. O volume (v_j) do *cluster* C_j , indica o número de soluções que estão alocadas no *cluster* e, quando v_j alcançar um limitante (λ) deve-se utilizar uma busca local neste *cluster*, pois este representa uma região promissora no espaço de soluções. Outro componente importante é o índice de ineficácia (r_j), que indica se o procedimento de busca local está melhorando a solução do centro *cluster* (c_j). Caso r_j alcance o limitante r_{\max} , a busca local não está melhorando a solução, portanto é necessário aplicar uma perturbação no centro do *cluster*.

Em linhas gerais, a CS pode ser descrita basicamente por três partes: (1) uma meta-heurística geradora de soluções; (2) um algoritmo de agrupamento de soluções; e (3) uma heurística de busca local.

Neste trabalho, a criação dos *clusters* iniciais foi 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.

2.1.1 Meta-heurística Geradora

O algoritmo *Simulated Annealing* (SA), introduzido por Kirkpatrick et al. (1983), foi criado com base no processo de recozimento de materiais sólidos. Na analogia, o metal inicia com uma alta temperatura, a qual vai diminuindo gradativamente, até atingir o ponto de solidificação, que é caracterizado como o estado de energia mínima.

A SA procura explorar novas áreas no espaço de soluções do problema em um curto

período de tempo e com pouco esforço. O algoritmo implementado (Figura 4) utiliza como entrada uma solução gerada aleatoriamente (S). Logo em seguida, é gerada S' a partir de uma mutação em S , e essa mutação consiste em escolher 30% das UP's de S e trocar aleatoriamente as suas AM's. Após gerar S' , verifica-se a variação de energia. Neste trabalho, a variação de energia é calculada por meio da diferença entre as funções objetivo de S' e S e, caso a variação de energia seja positiva, a solução S recebe S' e, caso contrário, é escolhido um número aleatório r no conjunto $[0,1]$ e o valor de w é calculado. Neste caso, w representa a probabilidade de aceitar soluções piores que a solução atual.

A fórmula para o cálculo de w é dada pelo exponencial do valor da função objetivo da solução S menos o valor da função objetivo de S' dividido pela temperatura. Se o resultado de w for maior que o r , escolhido anteriormente, S recebe S' , senão S' é eliminada e retorna ao passo 2. No final, o algoritmo retorna S .

Procedimento SA (S, S', T)

- 1 **Enquanto não** CritérioParada **faça**
- 2 $S' \leftarrow S$; //gerar S' a partir de S
- 3 $\Delta E = f(S') - f(S)$ //Variação de energia
- 4 **Se** $\Delta E > 0$ **então**
- 5 $S \leftarrow S'$;
- 6 **Senão**
- 7 Gerar $r \in \text{Unif}[0,1]$;
- 8 **Se** $r < w = e^{-\frac{f(S') - f(S)}{kT}}$ **então**
- 9 $S \leftarrow S'$;
- 10 $T \leftarrow a * T$; // a = índice de redução
- 11 **Fim-se**;
- 12 **Fim-senão**;
- 13 **Fim-Enquanto**;

Fim SA;

FIGURA 4 - Pseudocódigo do algoritmo SA (Barros Junior et al., 2012).

2.1.2 Algoritmo de agrupamento

As soluções geradas pela meta-heurística geradora são posteriormente enviadas para a CS, na qual são agrupadas nos *clusters* mais similares. Para descobrir qual o *cluster* mais similar a uma solução S , foi utilizada a distância de *Hamming* (HAMMING, 1950). Assim, como cada solução é representada por meio de um vetor (Figura 1), a distância de *Hamming* é obtida por meio do cálculo das diferentes alternativas de manejo atribuídas a cada unidade de produção. Logo, quanto mais diferenças existirem entre duas soluções, maior será a “distância” entre elas. Assim, a solução S será agrupada ao *cluster* com a menor distância em relação ao seu centro (c_j). A Figura 5 apresenta como é definida a distância de *Hamming* neste trabalho.

Distância de Hamming = 4

5	3	7	2	8	9	4
↓	↓	↓	↓			
5	4	7	1	8	3	2

FIGURA 5 - Representação da distância de *Hamming*.

2.1.3 Heurística de Busca Local

O procedimento de busca local utilizado neste trabalho consiste em rotinas de trocas das alternativas de manejo de uma solução. Assim, para cada UP da solução S , são testadas todas as AM's. Após cada troca, uma nova solução é gerada e sua viabilidade é verificada. Caso a solução

gerada seja viável e melhor que a solução S (parâmetro do procedimento), ela é armazenada para ser comparada com a próxima solução. Ao final do procedimento, a melhor solução gerada é retornada pelo procedimento.

2.1.4 Perturbação

A perturbação é realizada de forma aleatória em parte de uma 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 15% do total de UP's. Esse índice foi definido empiricamente. Logo após selecionar essas UP's da solução, as AM's escolhidas para elas são substituídas aleatoriamente. O objetivo dessa perturbação é fazer com que os centros dos *clusters* consigam migrar de região dentro do espaço de soluções, fazendo com que o algoritmo escape de ótimos locais. Um exemplo do processo de Perturbação descrito é exibido na Figura 6.

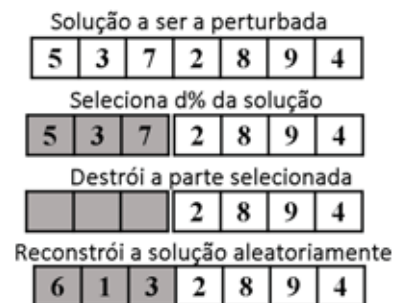


FIGURA 6 - Representação da perturbação utilizada no trabalho.

2.1.5 Path Relinking (PR)

O algoritmo *Path Relinking* (PR), proposto por Glover (1999), é uma técnica de intensificação que procura melhores soluções explorando trajetórias existentes entre duas soluções.

O PR recebe como entrada duas soluções, uma solução de origem (S_o) e uma solução guia (S_g). O objetivo é transformar a solução S_o em S_g e gerar, nesse caminho, novas soluções. Ao final o método deve retornar a melhor solução dentre todas as soluções geradas.

A cada iteração do algoritmo a alternativa de manejo de uma UP da S_o é trocada pela alternativa de manejo da mesma UP de S_g (caso elas sejam diferentes) e a cada iteração a melhor solução é guardada. As iterações do algoritmo terminam quando a solução S_o for igual a S_g . Um exemplo do processo é exibido na Figura 7.




FIGURA 7 - Processo da técnica de intensificação *Path Relinking*.

3. Experimentos Computacionais

Os valores utilizados para os parâmetros do *Simulated Annealing* (SA) foram os mesmos utilizados no trabalho de Barros Junior et al (2012), que podem ser encontrados na Tabela 1. Já para a CS, os parâmetros foram definidos empiricamente, por meio de diversos experimentos computacionais. O resultado da calibração obtida para a CS é apresentado na Tabela 1. O critério

de parada para ambos os métodos foi baseado no tempo de execução de acordo com a Tabela 2, assim como nos demais trabalhos utilizados como comparação.

Tabela 1- Parâmetros da CS e SA.

CS-SA		
SA	Temperatura Inicial	1000000
	<i>Decrease</i>	3%
	Congelamento	50
CS	<i>Clusters</i>	5
	Volume	5
	Ineficácia	3

Para a realização dos experimentos computacionais, foram utilizadas 10 instâncias (Tabela 2) baseadas em dados reais e em dados obtidos na literatura (Teixeira, 2002). Mais detalhes sobre as classes, UP's, horizonte e número de AM's descritas na Tabela 2 são apresentados em Barros Junior et al. (2009).

O tempo para resolução de cada instância é definido pela fórmula $(M \times \sqrt{m})/4$, na qual, 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 e está apresentado na última coluna da Tabela 2. Essa fórmula segue o modelo encontrado em Barros Junior et al. (2012).

Tabela 2 - Descrição das instâncias utilizadas.

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

 Tabela 3 - 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

A principal diferença entre as instâncias que contêm o mesmo número de AM's está

relacionada com os valores utilizados na definição dos níveis de demanda anual (Tabela 3). Esses valores foram considerados na restrição (3) do problema.

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

Tabela 4 - 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

Na Tabela 5 são apresentados os resultados médios obtidos pela meta-heurística CS-SA-PR proposta neste trabalho. Também são apresentados os resultados médios obtidos pelas meta-heurísticas GRASP, proposta por Barros Junior et al. (2009), Algoritmo Genético (AG) proposto por Barros Junior e Pereira (2011), *Iterated local Search* (ILS) e CS-ILS propostas por Melo et al. (2013) e o CS-GRASP proposto em Melo et al. (2014). Todos os testes foram realizados da mesma maneira, ou seja, cada meta-heurística foi executada 10 vezes para cada uma das instâncias, ao final foi encontrado o valor médio.

Tabela 5 - Comparação das soluções obtidas com a literatura.

Instância	GRASP	AG	ILS	CS-ILS	CS-GRASP	CS-SA-PR
1	170.568.901,33	180.550.495,45	169.481.636,02	180.544.282,35	180.849.191,58	181.397.954,38
2	168.005.501,97	178.330.908,66	167.639.487,08	177.870.887,46	178.445.048,02	178.721.972,86
3	165.736.524,15	175.373.017,91	165.349.120,37	175.589.876,35	176.764.552,98	176.512.225,00
4	520.454.711,87	561.178.394,53	518.305.492,92	560.085.359,77	557.337.475,57	566.004.265,24
5	511.506.009,49	552.133.334,04	510.175.078,03	552.385.227,43	550.948.367,05	556.094.019,05
6	238.477.829,62	260.424.178,69	242.221.520,45	259.000.615,57	258.296.804,37	261.450.720,91
7	237.317.743,93	256.316.557,36	240.994.388,04	256.585.336,21	254.814.613,12	257.847.050,39
8	236.504.492,97	255.980.694,39	240.068.244,64	256.144.408,10	254.704.255,17	255.367.349,90
9	362.530.132,21	394.743.106,75	365.912.324,78	395.307.241,99	395.186.928,49	397.920.295,99
10	359.728.766,18	393.383.603,29	364.280.139,78	394.243.080,80	392.928.546,40	396.085.782,44
Média	297.083.061,37	320.841.429,11	298.442.743,21	320.775.631,60	320.027.578,27	322.740.163,62

Nota-se pela Tabela 5 que a CS conseguiu os melhores resultados para todas as instâncias testadas, sendo que a CS-SA-PR proposta superou os resultados dos demais métodos encontrados na literatura em 8 das 10 instâncias. A CS-ILS e a CS-GRASP foram melhores em uma instância cada uma. A CS-SA-PR também obteve uma melhor média final entre todos os métodos testados.

Na Tabela 6 pode-se perceber que a CS conseguiu também os melhores resultados para o desvio padrão em relação aos demais métodos encontrados na literatura, ficando a CS-GRASP com uma melhor média para o desvio padrão, conseguindo atingir os melhores valores individuais para 8 das 10 instâncias testadas, sendo que a CS-SA-PR foi melhor nas 2 instâncias

maiores.

Tabela 6 - Comparação do desvio padrão obtido com a literatura.

Instância	GRASP	AG	ILS	CS-ILS	CS-GRASP	CS-SA-PR
1	1.458.827,85	2.006.727,10	1.435.756,33	1.173.391,54	951.789,27	1.080.110,05
2	1.304.077,70	1.947.806,58	1.396.218,97	2.476.727,93	1.433.223,74	1.720.824,00
3	1.251.111,04	3.280.134,56	2.588.642,94	1.896.868,77	1.712.399,75	1.761.947,50
4	2.222.536,24	2.595.466,75	7.949.461,71	1.571.261,87	1.339.323,47	2.775.527,46
5	3.550.079,57	3.628.064,57	5.482.554,66	2.939.029,59	2.048.027,36	3.484.922,34
6	2.087.428,34	1.577.986,04	2.037.091,42	1.016.226,30	1.007.315,42	1.229.870,93
7	1.823.102,93	2.870.805,05	5.136.751,37	1.754.278,40	1.299.029,03	1.312.584,41
8	2.840.508,35	2.886.400,50	1.408.773,65	3.195.346,70	1.410.949,05	1.718.435,85
9	2.242.312,56	1.586.728,04	4.183.461,67	1.677.307,83	541.477,75	458.366,21
10	1.413.780,56	1.435.932,69	3.057.853,64	695.354,99	661.029,39	552.711,23
Média	2.019.376,51	2.381.605,19	3.467.656,64	1.839.579,39	1.240.456,42	1.609.530,00

4. Conclusões

Este trabalho apresentou a aplicação da meta-heurística híbrida *Clustering Search* (CS) utilizando a meta-heurística *Simulated annealing* (SA) como geradora de soluções e aplicando a técnica de intensificação *Path Relinking* (PR) (CS-SA-PR) para resolver um Problema de Planejamento Florestal (PPF).

A CS já foi utilizada em trabalhos anteriores para a resolução do PPF, porém, considerando a meta-heurística *Iterated Local Search* (ILS) e a meta-heurística GRASP como geradora de soluções. Neste trabalho, além de substituir a meta-heurística geradora, os resultados obtidos foram intensificados pela técnica PR.

Assim, a utilização da CS com SA e o PR se mostra como uma nova alternativa para resolução do PPF, apesar de não conseguir ser melhor que a CS-GRASP no desvio padrão, conseguiu superar o resultado de 8 das 10 instâncias testadas, além de conseguir a melhor média geral, o que comprova a eficácia, eficiência e confiabilidade da técnica proposta.

Agradecimentos

Os autores agradecem ao CNPq (processo 303052/2013-9 e 454569/2014-9) pelo apoio financeiro.

Referências

- Almeida, G. W. e Senne, E. L. F. (2010), Metaheurística híbrida com busca por agrupamento Aplicado ao problema de localização de hubs com Restrições de capacidade, *Anais do XLII SBPO - Simpósio Brasileiro de Pesquisa Operacional*.
- Araújo, D. L. e Mauri, G. R. (2013) *Clustering search* para resolução de um problema de rotação de culturas com restrições de adjacências, *Anais do XLV SBPO - Simpósio Brasileiro de Pesquisa Operacional*.
- Barros Junior, A. A.; Arroyo, J. E. C.; 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.; 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*.

Buongiorno, J. e Gilles, J. K. (1987), *Forest management and economics. A primer in quantitative methods*. Macmillan Publishing Co. New York, 285 p.

Chaves, A. A.; Miralles, C.; Lorena, L. A. N. (2008) Uma metaheurística híbrida aplicada ao problema de balanceamento e designação de trabalhadores em linha de produção, *Anais do XL SBPO - Simpósio Brasileiro de Pesquisa Operacional*.

Chaves, A. A. e Lorena, L. A. N. (2010), Clustering search algorithm for the capacitated centered clustering problem, *Computers & Operations Research*, 37, 552-558.

Glover, F. (1999), Scatter search and path relinking. *New ideas in optimization*, 297-316.

Gomide, L. R. (2009), Planejamento florestal espacial. *Tese de Doutorado em Ciências Florestais*, Universidade Federal do Paraná - UFPR.

Hamming, R. W. (1950), Error detecting and error correcting codes. *Bell System Technical Journal*, 26, 147-160.

Indústria Brasileira De Árvores (IBA) (2015), ano base 2014, (http://www.iba.org/shared/destaque/cenarios_marco_imprensa2015.pdf).

Johnson, K. N.; Scheurman, H. L. (1977), Techniques for prescribing optimal timber harvest and investment under different objectives, discussion and synthesis. *Forest Science Monograph*, USA.

Kirkpatrick, Jr. S.; Gelatt, C.; Vecchi, M. (1983), Optimization by simulated annealing. *Decision Science* 220(4598), p. 498-516.

Melo, R. S.; Barros Junior, A. A.; Mauri, G. R. (2013), Clustering search com iterated local search para resolução do problema de planejamento florestal, *Anais do XLV SBPO - Simpósio Brasileiro de Pesquisa Operacional, SBPO*.

Melo, R. S.; Barros Junior, A. A.; Mauri, G. R. (2014), Resolução de um problema de planejamento florestal via clustering search utilizando a meta-heurística GRASP como geradora de soluções, *Anais do XLVI SBPO - Simpósio Brasileiro de Pesquisa Operacional*.

Rabello, R. L.; Mauri, G. R.; Ribeiro, G. M.; Lorena, L. A. N. (2013), Meta-heurística Clustering search aplicada ao problema de Rotulação cartográfica de pontos, *Anais do XLV SBPO - Simpósio Brasileiro de Pesquisa Operacional*.

Rodrigues, F. L. (2001), Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais, *Tese de Doutorado em Ciência Florestal*, Universidade Federal de Viçosa - UFV.

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*, 4, 160-166.

Teixeira, A. F. (2002), Aplicação de algoritmos evolucionários na solução de problemas de planejamento florestal multiobjectivo, *Dissertação de Mestrado em Ciência da Computação*, Universidade Federal de Minas Gerais - UFMG.