



RESOLUÇÃO DE UM PROBLEMA DE PLANEJAMENTO FLORESTAL VIA CLUSTERING SEARCH UTILIZANDO A META-HEURÍSTICA GRASP COMO GERADORA DE SOLUÇÕES

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 propõe a utilização da meta-heurística *Greedy Randomized Adaptive Search Procedure* (GRASP) como geradora de soluções para a meta-heurística híbrida *Clustering Search* (CS) aplicada à resolução de um Problema de Planejamento Florestal (PPF). O PPF consiste na seleção de alternativas de manejo para plantio e colheita de madeira de forma a maximizar um valor associado ao plano de corte de unidades florestais dentro de um horizonte de planejamento. A CS foi utilizada em um trabalho anterior para a resolução do PPF, porém, considerando a meta-heurística *Iterated Local Search* (ILS) como geradora de soluções. Neste trabalho, é proposta a substituição da ILS pela GRASP na fase de geração de soluções da CS. O desempenho do método proposto é avaliado por meio de experimentos computacionais realizados e comparados com diferentes métodos apresentados em trabalhos anteriores encontrados na literatura.

PALAVRAS CHAVE. Planejamento Florestal, Clustering Search, GRASP.

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

ABSTRACT

This paper proposes to use the *Greedy Randomized Adaptive Search Procedure* (GRASP) to generate solutions inside the hybrid metaheuristic *Clustering Search* (CS) for solving a *Forest Planning Problem* (FPP). The FPP consists on selecting management alternatives for planting and harvesting of timber maximizing a value related to the forest cutting units plan within a planned horizon. The CS was used to solve the FPP in a previous work but using a *Iterated Local Search* (ILS) to generate solutions. In this paper, we propose replacing the ILS by GRASP to generate solutions for the CS. The performance of combining CS with GRASP is evaluated by computational experiments compared against another methods reported in the literature.

KEY WORDS. Forest Planning, Clustering Search, GRASP.

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

1. Introdução

O planejamento florestal deve ser elaborado por meio de metodologias científicas, baseando-se em dados coletados em situações reais e extrapolados para novas situações. Um fator decisivo na intensidade de exploração é o fluxo de madeira, que está diretamente ligado à demanda da empresa (MACHADO, 1994). A falta desse planejamento pode levar à formação de estruturas distorcidas e ao surgimento de processos inadequados de aproveitamento (ou mesmo de destruição) dos recursos florestais existentes.

Buongiorno e Gilles (1987) ressaltam que o planejamento florestal envolve variáveis biológicas, econômicas e sociais que podem estar ou não inter-relacionadas. Todas essas variáveis e as relações entre elas constituem um sistema complexo no qual decisões particulares não são facilmente tomadas. Assim, modelos matemáticos podem auxiliar os responsáveis pela tomada de decisões e/ou prever as consequências de suas ações.

O Problema de Planejamento Florestal (PPF), abordado neste trabalho, se baseia no manejo de áreas homogêneas denominadas unidades de produção (UP's). Uma UP consiste de uma área contínua com características semelhantes, tais como, material genético e idade das árvores, classe de produtividade, declive, altitude, dentre outros e, ainda, submetida a uma mesma alternativa de manejo (AM). Uma AM é uma sequência de decisões que ocorrem ao longo de um horizonte de planejamento.

A Figura 1 apresenta uma possível floresta dividida em 19 UP's. Cada UP contém características únicas, inclusive o conjunto de AM's. A quantidade de AM's para cada UP depende da idade das árvores, da definição das opções de manejo e do horizonte de planejamento do problema.

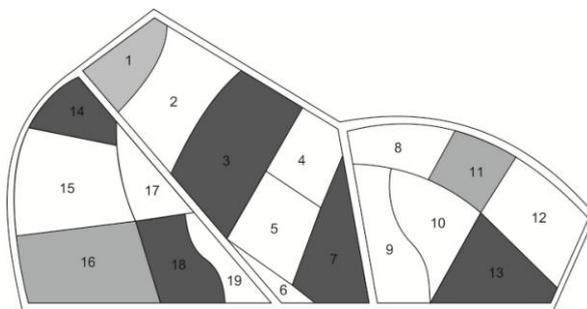


FIGURA 1 - Exemplo de área florestal dividida em 19 unidades de produção.

Cabe ao gerente florestal o desafio de decidir qual é o momento ideal para realizar cada intervenção nas unidades de produção de modo a atender a demanda do mercado e ao mesmo tempo obter o máximo retorno financeiro do empreendimento como um todo.

1.1. Modelo de Programação Inteira

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:

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

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

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

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

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 (m^3) 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

Uma solução S pode ser representada como um vetor que contém um determinado número de UP's, representadas na Figura 1 pelos números de 1 a 19. Para cada UP representada no vetor por i , existe um conjunto de possíveis AM's associadas, das quais apenas uma alternativa j deve ser escolhida. No exemplo ilustrado pela Figura 2, 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.

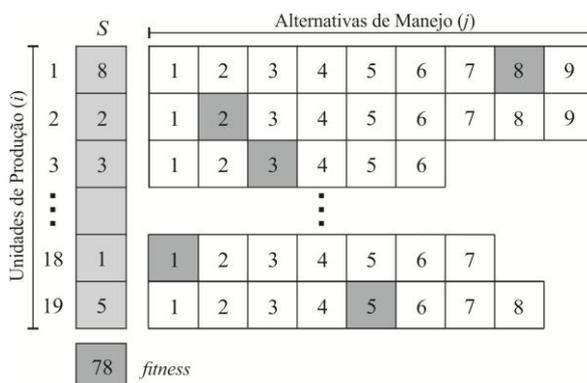


FIGURA 2 - Representação de uma solução S.

Todas as AM's possíveis para cada conjunto de UP'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 que compõe uma floresta.

Como descrito anteriormente, uma AM, para uma UP, é uma 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. A Figura 3 ilustra um exemplo no qual estão representadas as nove AM's da UP 1. Considerando um algoritmo guloso que escolhe sempre a AM com o maior VPL num dado momento, a AM número 8 seria a escolhida para a unidade de produção 1, 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, e isso implica em um VPL de R\$ 502.005,40 e um custo de R\$ 331.438,20. Ainda na Figura 3, a letra "x" representa o ano em que a UP foi plantada e o ano "0" (zero) representa o ano corrente.

		Horizonte de Planejamento																			
UP(i)	AM(j)	Regime	-8	-7	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6	7	8	VPL	Custo
1	1	5 5				x					r					r				296.514,10	400.583,40
1	2				x						c					c				395.611,80	301.485,60
1	3				x						c					r				349.846,70	347.250,70
1	4	5 6				x					r						r			354.817,80	418.761,30
1	5					x					c						c			455.284,50	318.294,60
1	6					x					c						r			408.150,40	365.428,60
1	7	5 7				x					r							r		400.740,40	432.703,20
1	8					x					c							c		502.005,40	331.438,20
1	9					x					c							r		502.000,00	432.703,20

FIGURA 3 - Representação de uma alternativa de manejo.

1.3. Objetivos

Este trabalho tem como objetivo a utilização da meta-heurística *Greedy Randomized Adaptive Search Procedure* (GRASP) como geradora de soluções para a meta-heurística híbrida *Clustering Search* (CS) aplicada à resolução do PPF descrito nesta seção. A CS foi utilizada por Melo et al. (2013) para a resolução do PPF, porém, considerando a meta-heurística *Iterated Local Search* (ILS) como geradora de soluções. Neste trabalho, é proposta a substituição da ILS pela GRASP na fase de geração de soluções da CS. O desempenho do método proposto (CS-GRASP) é comparado diretamente aos métodos GRASP, AG, ILS e CS-ILS, todos apresentados em outros trabalhos encontrados na literatura.

O restante do trabalho é organizado da seguinte forma: a Seção 2 apresenta uma breve revisão da literatura; na Seção 3 é apresentada em detalhes metodologia adotada para a utilização da CS com a GRASP; os resultados computacionais são apresentados na Seção 4, e as conclusões são descritas na Seção 5.

2. Revisão da Literatura

No Brasil, vários trabalhos vêm utilizando métodos de otimização para o planejamento dos recursos florestais. A seguir são apresentados alguns destes trabalhos encontrados na literatura.

Rodrigues (2001) apresenta diferentes heurísticas e as compara com o método de *branch and bound* para a resolução do PPF. Os experimentos realizados comprovaram a utilidade de se usar procedimentos heurísticos para resolver o problema. Já em Rodrigues et al. (2003) o PPF é abordado considerando uma restrição inteira, na qual decide-se abater ou não uma UP. Neste trabalho foi utilizada a meta-heurística Busca Tabu.

Rodrigues et al. (2004) fez uso da meta-heurística *Simulated Annealing* (SA) para resolver o PPF, com o objetivo de encontrar os melhores parâmetros para o SA.

Rodrigues et al. (2006) comparou em sua pesquisa dois modelos para o PPF, o Modelo I, citado neste trabalho, e o Modelo II (JOHNSON; SCHEURMAN, 1977). Os autores observaram que o Modelo II possui um número inferior de restrições quando comparado ao Modelo I, porém, o Modelo II se torna mais complexo por possuir restrições que devem ser definidas de forma não-linear.

Gomide (2009) utilizou as meta-heurísticas SA e Algoritmo Genético (AG) na resolução do PPF utilizando restrições de adjacência. Nestes experimentos, provou-se que a programação linear inteira não é capaz de resolver instâncias de grande porte e, portanto, a única opção para resolver essas instâncias é a utilização de métodos heurísticos.

Silva et al. (2009) utilizou a meta-heurística AG para resolver o PPF. No estudo, comprovou-se que a população inicial é o parâmetro no qual mais influencia a qualidade das soluções, tanto na questão de tempo quanto na aproximação da solução ótima.

Barros Junior et al. (2009) aplicou o método *Greedy Randomized Adaptive Search Procedure* (GRASP) com a técnica de intensificação *Path Relinking* (PR), e obteve resultados satisfatórios e constatando que a técnica PR consegue efetivamente intensificar os resultados.

Barros Junior e Pereira (2011), por sua vez, propuseram a utilização do AG juntamente com a técnica de intensificação PR. Estas meta-heurísticas conseguiram obter bons resultados, o que fez com que se tornassem base de comparação para outros métodos.

Já em Barros Junior et al. (2012) foi testado o uso do *Simulated Annealing* na resolução deste problema, porém, os resultados obtidos foram inferiores aos já conhecidos.

Recentemente, Melo et al. (2013) propuseram a aplicação da meta-heurística *Clustering Search* (CS) utilizando a meta-heurística *Iterated Local Search* (ILS) como geradora de soluções. Os resultados obtidos foram promissores em relação aos encontrados na literatura.

3. Clustering Search (CS) com GRASP

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* 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; LORENA, 2010).

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. A Figura 4 apresenta um fluxograma que ilustra o funcionamento da CS.

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.

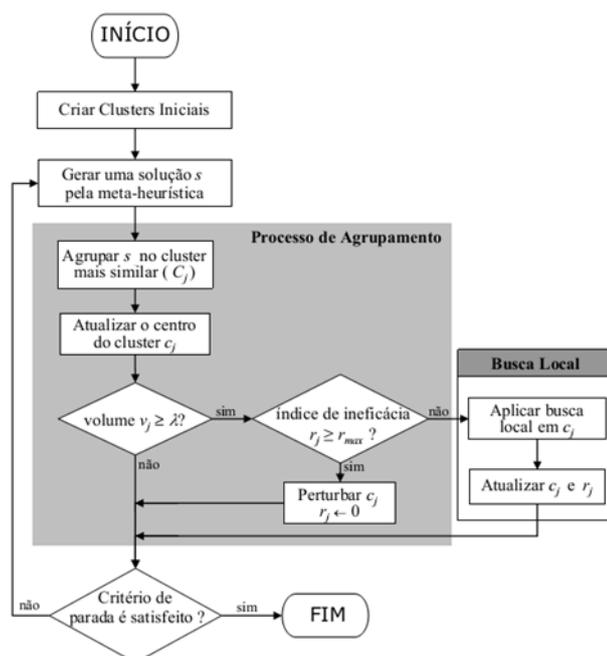


FIGURA 4 - Fluxograma da CS (CHAVES; LORENA, 2010).

3.1 Meta-heurística Geradora

Neste trabalho, foi utilizada como meta-heurística geradora de soluções a *Greedy Randomized Adaptive Search Procedure* (GRASP). Proposta por Feo e Resende (1995), a meta-heurística GRASP consiste em um procedimento iterativo de duas fases na qual a primeira consiste em construir uma solução inicial e na segunda é realizada uma busca local nesta solução com objetivo de encontrar melhores soluções.

De forma geral, a meta-heurística GRASP procura combinar da melhor forma possível as características dos algoritmos gulosos e dos procedimentos aleatórios para a construção das soluções iniciais e posteriormente refiná-las por meio de uma fase de busca local (RESENDE; RIBEIRO, 2002). A Figura 5 apresenta o pseudocódigo da meta-heurística GRASP implementada.

Procedimento GRASP (a) // a = numero de AM's a explorar

- 1 $f \leftarrow \infty$;
- 2 **Enquanto não** (critériodeparada) **faça**
- 3 $S \leftarrow$ construçãoParcialmenteGulosa (a);
- 4 $S' \leftarrow$ BuscaLocal (S);
- 5 **Se** ($f(S') > f(S^*)$) **então**
- 6 $S^* \leftarrow S$;
- 7 $f^* \leftarrow f(S')$
- 8 **Fim-se**
- 9 **Fim-enquanto**
- 10 $S \leftarrow S^*$;
- 11 **Retorne** S ;

Fim GRASP;

FIGURA 5 - Pseudocódigo da meta-heurística GRASP implementada.

A primeira fase da GRASP consiste em construir uma solução inicial (passo 3). Primeiramente, cria-se um conjunto CA de N soluções aleatórias e viáveis e, em seguida, essas soluções são ordenadas de acordo com o valor de sua função objetivo. A solução inicial S é

definida a partir da escolha aleatória de uma AM para cada UP nas a (parâmetro calibrado) primeiras soluções do conjunto CA (BARROS JUNIOR et al., 2009).

No passo 4 do procedimento, é realizada uma busca local na solução S na qual é gerada uma nova solução S' . Dado o bom desempenho, observado em testes, do procedimento de busca local na meta-heurística GRASP, o mesmo foi utilizado no CS, e mais detalhes sobre este procedimento são apresentados na Seção 3.3.

Após realizada a busca local, a solução S' é comparada com a melhor solução encontrada até o momento S^* . Caso S' seja melhor que S^* , S' se tornará a melhor solução (passos 5 a 7). No fim do procedimento, a melhor solução (S^*) é retornada.

3.2 Agrupamento de Soluções

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 , é utilizada a distância de *Hamming* (HAMMING, 1950). Assim, como cada solução é representada por meio de um vetor (Figura 2), 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).

3.3 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.

3.4 Perturbação

A perturbação utilizada neste trabalho é baseada em uma troca aleatória da AM selecionada para um conjunto de UP's definido pelo índice d (“taxa de destruição”).

A Figura 6 apresenta o pseudocódigo da CS implementada.

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 6 - Algoritmo CS (MELO et al. 2013).

4. Experimentos Computacionais

Os valores utilizados para os parâmetros da GRASP foram os mesmos valores calibrados por Barros Junior et al. (2009). 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 GRASP e CS.

Parâmetro	Significado	Valor
d	Índice de destruição	15%
α	Número de soluções para geração da solução inicial	15%
γ	Número máximo de <i>clusters</i>	7
λ	Volume máximo para aplicação da busca local	5
r_{max}	Limite para aplicação da perturbação	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 $(M \times \sqrt{m})/2$, 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.

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.

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

Tabela 3 - Volume total (m³) da demanda a ser atendida no período *k*.

Período (<i>k</i>)	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

Tabela 4 - Capacidade de reforma (ha) a ser atendida no período *k*.

Período (<i>k</i>)	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

Tabela 5 - Comparação das soluções obtidas com a literatura.

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

O CS-GRASP proposto superou os resultados obtidos pelo GRASP para todas as 10 instâncias testadas. Em relação à ILS utilizada de forma isolada, também conseguiu melhores resultados para todas as 10 instâncias. Porém, em relação ao AG, o método proposto conseguiu os melhores resultados para apenas 4 das 10 instâncias. Já em relação ao CS-ILS, o método proposto superou os resultados para apenas 3 das 10 instâncias testadas. Considerando a diferença entre as médias totais obtidas, a mesma situação foi observada.

É importante observar que, dentre todas as 10 instâncias testadas, o AG obteve uma melhor média geral, porém, a CS-ILS conseguiu ser mais eficiente em um número maior de instâncias, ficando a CS-GRASP, proposta neste trabalho, com os melhores resultados nas 3 primeiras

instâncias testadas.

Na Tabela 6 é apresentado o desvio padrão obtido pelos métodos testados. Como pode ser observado, a CS-GRASP apresentou uma melhor média para o desvio padrão, conseguindo atingir os melhores valores individuais para todas as instâncias testadas.

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

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

A Tabela 7 apresenta em porcentagem, o desempenho das meta-heurísticas implementadas recentemente, em relação aos resultados obtidos pela GRASP, proposta em Barros Junior et al. (2009).

Tabela 7 - Evolução (em %) das meta-heurísticas desenvolvidas em relação à meta-heurística GRASP.

Instância	GRASP	AG	ILS	CS-ILS	CS-GRASP
1	170.568.901,33	5,85%	-0,64%	5,85%	6,03%
2	168.005.501,97	6,15%	-0,22%	5,87%	6,21%
3	165.736.524,15	5,81%	-0,23%	5,95%	6,65%
4	520.454.711,87	7,82%	-0,41%	7,61%	7,09%
5	511.506.009,49	7,94%	-0,26%	7,99%	7,71%
6	238.477.829,62	9,20%	1,57%	8,61%	8,31%
7	237.317.743,93	8,01%	1,55%	8,12%	7,37%
8	236.504.492,97	8,24%	1,51%	8,30%	7,70%
9	362.530.132,21	8,89%	0,93%	9,04%	9,01%
10	359.728.766,18	9,36%	1,27%	9,59%	9,23%
Média	297.083.061,37	8,00%	0,46%	7,98%	7,72%

Nos resultados apresentados na Tabela 7, apesar da meta-heurística AG ter obtido um melhor desempenho médio quando comparado com a meta-heurística GRASP, pode-se observar de forma isolada, uma melhora significativa quando utilizado o método CS.

5. Conclusões

Este trabalho apresentou a aplicação da meta-heurística híbrida CS utilizando a meta-heurística GRASP como geradora de soluções para resolver um Problema de Planejamento Florestal (PPF).

A CS já foi utilizada em um trabalho anterior para a resolução do PPF, porém, considerando a meta-heurística *Iterated Local Search* (ILS) como geradora de soluções. Neste trabalho, foi proposta a substituição da ILS pela GRASP na fase de geração de soluções da CS.

A CS com GRASP proposta apresentou soluções com uma média melhor do que a apresentada pela GRASP e pela ILS utilizadas de forma isoladas. Porém, os resultados apresentados não superaram os obtidos pelo AG e pela CS com ILS. Entretanto, o método

proposto foi capaz de obter os melhores valores para o desvio padrão em todas as 10 instâncias consideradas.

Assim, a utilização da CS com GRASP demonstra ser uma nova alternativa para resolução do PPF, pois mesmo não superando alguns métodos encontrados na literatura em termos de qualidade das soluções, foi capaz de obter boas soluções e com pequenos valores de desvio padrão.

Agradecimentos

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

Referências

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. e Melo, R. S. (2012), Aplicação da metaheurística 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. *Forest management and economics. A primer in quantitative methods*. Macmillan Publishing Co. New York, 1987. 285 p.

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. *Timber Management: a quantitative approach*. New York, John Wiley & Sons. 333, 1983.

Feo T. A., Resende, M. G. C. Greedy Randomized Adaptive Search Procedures. *Journal of Global Optimization*, 6, 109-133, 1995.

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

Kidd, W. E., Thompson E. F., e Hoepner P.H. (1966). Forest Regulation by Linear Programming – A Case Study. *Journal of Forestry*, 64, 611-613.

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*.

Machado, C. C. *Planejamento e controle dos custos de exploração florestal*. Viçosa: UFRV, 1994. 138 p.

Resende, M. G. C., Ribeiro, C. C. *Greedy randomized adaptive search procedures*. In: *Fred Glover e Gary A. Kochenberger (eds.), Handbook of Metaheuristics*, 219-250. Kluwer Academic Publishers, Norwell, MA, 2002.

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., 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., Leite, H. G., Santos, H. N. Souza, A. L., Ribeiro, C. A. A. S. (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.

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 multiobjectivo, *Dissertação de Mestrado em Ciência da Computação*, Universidade Federal de Minas Gerais - UFMG, 2002.