

Gilson F. da Silva¹Ludmila de C. Piassi²Rômulo Mora²Leandro T. Martins²Alessandro de F. Teixeira³Antonio A. de B. Junior³

Metaheurística algoritmo genético na solução de modelos de planejamento florestal

RESUMO

Objetivou-se testar a metaheurística Algoritmo Genético (AG) e avaliar sua eficácia e eficiência na solução de problemas de planejamento florestal, comparado a resultados obtidos pelo *software* CPLEX. Para analisar o efeito dos diferentes parâmetros no desempenho do AG, foi empregado o delineamento inteiramente casualizado no arranjo fatorial, em que os fatores considerados foram: três tamanhos de população inicial (Pini), três taxas de *crossing-over* (Tcross) e dois métodos de *crossing-over* (Mcross). Nos casos em que as interações foram significativas pelo teste F em nível de 5% de probabilidade, foram realizados os desdobramentos dos fatores, testando-se as diferenças entre as médias pelo teste de Tukey, em nível de 5% de probabilidade. Como medida de eficácia e eficiência utilizou-se a distância percentual (distância entre a resposta do AG e a resposta exata) e o tempo de processamento, respectivamente. A população inicial é o fator que mais influencia o desempenho do AG em termos de distância e de tempo de processamento, de modo que para Pini maiores são encontrados maior proximidade da resposta do AG com a resposta exata e também maiores tempos de processamento.

Palavras-chave: manejo florestal, otimização, heurísticas

Genetic algorithm metaheuristic in the solution of forest management models

ABSTRACT

This work aimed to test the Genetic Algorithm (GA) metaheuristic evaluating its effectiveness and efficiency in the solution of this kind of problem, and comparing its results with those obtained by the *software* CPLEX. A completely randomized design, as the factorial arrangement, was used to analyze the effect of different parameters on GA performance. Sizes of initial population (Pini), *crossing-over* rates (Tcross) and *crossing-over* methods breaks (Mcross) were the analyzed factors. In the cases that the interactions were significant by F test ($P < 0.05$) the differences among the means were tested by Tukey test at 5% probability level. The percentage distance (distance between the answer of AG and the exact answer) and the time of processing were used as a measure of effectiveness and efficiency, respectively. The initial population is the factor that most influenced the AG performance considering percentage distance and processing time, so that for larger Pini are found greater proximity of GA response to the exact response and also greater processing times.

Key words: forest management, optimization, heuristics

¹ Engenheiro Florestal, Dr., Professor Adjunto IV do Departamento de Engenharia Florestal, CCA-UFES, Av. Carlos Lindenberg, S/N, CEP: 29.550-000, Jerônimo Monteiro, ES, gilson.silva@pq.cnpq.br

² Graduando do curso de Engenharia Florestal do CCA-UFES, Av. Carlos Lindenberg, S/N, CEP: 29.550-000, Jerônimo Monteiro, ES, ludpiassi@yahoo.com.br

³ Cientec – Softwares para o Agronegócio e Recursos Naturais, Av. P. H. Rolfs, 305 - Sala 20 - Viçosa - MG, Tel/Fax: (31) 3892-5008 - CEP: 36570-000, alessandro@cientec.net, antoniojr@cientec.net

INTRODUÇÃO

Atualmente, as pressões de mercados cada vez mais globalizados exigem que as empresas se tornem mais competitivas, devendo produzir produtos de alta qualidade com custos menores (Silva, 2001). De acordo com Leite (1994), o manejo florestal moderno requer integração entre floresta, indústria e mercado, para maximizar o retorno financeiro e, ao mesmo tempo, garantir uma base sustentável do estoque de crescimento da floresta. Em razão disso, estudos têm sido realizados com base nas principais etapas do processo de planejamento florestal, com o objetivo de tornar o produto florestal mais competitivo.

Por outro lado, o problema de planejamento florestal é significativamente complexo e, portanto, demanda grande esforço para se alcançarem soluções razoáveis. Entre os fatores que dificultam a tomada de decisão no ambiente das empresas florestais, citam-se o elevado número de variáveis ou alternativas de manejo (diferentes idades de corte, espaçamentos, épocas e intensidades de desbastes etc), os múltiplos objetivos a serem atingidos (minimizar custos, maximizar receitas, atender a legislação, entre outros), a necessidade de aumento da eficiência do processo e a escassez de técnicas de auxílio à tomada de decisão. Essas decisões podem ser de longo ou curto prazo e resultam em recomendações denominadas planos de manejo florestal.

Segundo Nobre (1999), o problema básico de manejo florestal é elaborar um plano sobre as diversas intervenções silviculturais que atenda às demandas e restrições definidas para certo período de tempo. Essas intervenções, incluindo colheitas e plantios, devem necessariamente atender às limitações operacionais e resultar em um fluxo adequado e sustentável de produção. O equacionamento do problema envolve a definição de um número muito grande de alternativas silviculturais para cada unidade de manejo na floresta. Dentre essas, e para cada unidade, o gestor deve escolher a que melhor atende aos seus objetivos e as restrições operacionais. O problema resultante pode se tornar de difícil solução, principalmente devido ao grande número de variáveis envolvidas e à natureza combinatória do problema quando impostas restrições espaciais e de integridade sobre as unidades de manejo.

No Brasil, foram desenvolvidos vários métodos exatos para resolver o problema de planejamento anteriormente descrito, especialmente a Programação Linear e Inteira (Taube Neto, 1984; Carnieri, 1989; Rodrigues et al., 1998; Silva et al., 2000; Silva et al., 2006 e Rodrigues et al., 2006). Nesse sentido, Silva (2001) discutiu as dificuldades em se empregar estes métodos convencionais e Rodrigues (2001), além disso, sugeriu as técnicas heurísticas como uma alternativa viável, pois, essas técnicas têm tido bastante sucesso na solução de problemas combinatoriais em diversas áreas, abrangendo desde heurísticas menos convencionais até as denominadas metaheurísticas.

Os Algoritmos Genéticos (AG) – uma metaheurística muito estudada atualmente – podem ser utilizados na solução de difíceis problemas de otimização combinatória (Ignacio et al., 2000; Baskent & Jordan, 2002). Alguns exemplos incluem pro-

blemas com restrições de singularidade, adjacência, roteamento de veículos no transporte florestal, corte na indústria de móveis e de papel, entre outros (Pereira, 2004).

Este trabalho foi conduzido com o principal objetivo de avaliar a metaheurística Algoritmos Genéticos para resolver problemas de planejamento florestal, preocupando-se com sua eficiência e eficácia computacional na solução desses problemas.

MATERIAL E MÉTODOS

A metodologia deste trabalho consistiu em resolver por meio da metaheurística de Algoritmos Genéticos (AG) um problema de planejamento florestal e comparar os resultados desta solução com uma solução exata obtida por *software* específico. Nesta comparação, considerou-se a proximidade da solução encontrada pelo algoritmo genético em relação à solução exata, bem como os tempos de processamento. Na seqüência, são apresentados: o problema de planejamento considerado e o modelo de otimização associado, o Algoritmo Genético avaliado na solução do problema e a metodologia de comparação entre os resultados obtidos pelo AG e a solução exata.

O problema de planejamento florestal considerado consistiu no estabelecimento de uma seqüência de cortes para uma floresta implantada subdividida em várias unidades de produção (UP), definindo-se idades mínimas e máximas de corte como alternativas de manejo, e tendo como principais restrições o atendimento de uma demanda anual por madeira e a capacidade da empresa em substituir povoamentos explorados por novos povoamentos ao longo de um horizonte de planejamento. A descrição detalhada deste tipo de problema pode ser encontrada em Ribeiro (1996), Nobre (1999), Silva (2001), Rodrigues (2001), Teixeira (2002) e Pereira (2004).

O modelo de otimização empregado para solucionar o problema anteriormente descrito, denominado modelo I, foi proposto originalmente por Kidd et al. (1966), citados por Dykstra (1984). A partir deste modelo, no contexto de um problema uniojetivo, trabalhou-se com o objetivo de se maximizar o lucro no final do horizonte de planejamento. A formulação matemática para este modelo, com os objetivos e restrições, é apresentada na seqüência:

$$\text{MaxVPL} = \sum_{i=1}^M \sum_{j=1}^N L_{ij} X_{ij}$$

Sujeito a:

$$\sum_{i=1}^M \sum_{j=1}^N x_{ij} = 1 \quad (\text{Restrição de singularidade})$$

$$\sum_{i=1}^M \sum_{j=1}^N v_{ijk} x_{ij} \geq V_k \quad (\text{Restrição de atendimento de demanda})$$

$$\{K = 0, 1, \dots, H - 1\}$$

$$\sum_{i=1}^M \sum_{j=1}^N a_{ijk} x_{ij} \geq CR_k \quad (\text{Restrição de capacidade de substituir povoamentos})$$

$$\{K = 0, 1, \dots, H - 1\}$$

em que VPL é valor presente líquido global ou lucro líquido atualizado; c_{ij} , VPL da unidade de produção i , manejada sob a alternativa de manejo j ; x_{ij} , variável binária, que ao assumir o valor 1 significa cortar a unidade de produção i seguindo a alternativa de manejo j , e 0 significa o contrário; M , número total de unidades de produção; N , número total de alternativas de manejo da i -ésima unidade de produção; EP , excesso de produção global da floresta; v_{ijk} , volume total produzido pela unidade de produção i , manejada sob a prescrição j , no k -ésimo período do horizonte de planejamento conforme a idade de corte naquele período; V_k , volume total da demanda a ser atendida no período k ; H , número de períodos do horizonte de planejamento; a_{ijk} , área da i -ésima unidade de produção, manejada sob a j -ésima prescrição, no início do período k e que esteja sob o regime de manejo de reforma; CR_k , capacidade de substituir povoamentos cortados preestabelecida para o período k .

No modelo proposto, para o objetivo de minimização do excesso de produção, foi considerado que todo o excedente da produção é vendido sem a imposição de nenhuma restrição ou depreciação do valor da madeira. A restrição de singularidade significou que cada unidade de produção só pode ser explorada integralmente, não se permitindo cortes parciais para a mesma, ou seja, na prática isto significou adotar uma única alternativa de manejo para cada unidade de produção (UP). A seguir são apresentadas as características principais do problema modelado segundo o modelo do Tipo I, dando uma idéia da dimensão do problema a ser resolvido tanto pelo algoritmo genético quanto pelo algoritmo exato:

- Número de Unidades de produção: 50;
- Horizonte de planejamento: 9 anos;
- Número de variáveis de decisão (x_{ij}): 735
- Limites de demanda: 400.000 (anos 0 e 1), 500.000 (ano 2), 600.000 (ano 3), 700.000 (anos 4, 5 e 6) e 800.000 m³ de madeira (anos 7 e 8); e
- Capacidade de Reforma: duas conduções de brotação.

A metodologia para a abordagem de Algoritmos Genéticos tem como referência os processos de evolução natural de uma população. Neste caso, a população deve ser entendida como um conjunto de possíveis soluções em que o objetivo foi encontrar o melhor indivíduo por meio de processos que se baseiam nas leis naturais de mutação, *crossing-over* e seleção natural. As pressões de seleção foram as restrições impostas ao processo de planejamento, como restrições de singularidade, atendimento à demanda por madeira e a capacidade da empresa em substituir povoamentos explorados.

O modelo de otimização utilizado baseou-se em uma abordagem de AG para solução de problemas de planejamento florestal, como descrito em Teixeira (2002). Para a implementação dos AG, foi empregado o Sistema de Planejamento Florestal (SPF), desenvolvido por Cientec (2008). Os testes com o AG foram efetuados em um microcomputador Intel(R) Core(TM)2 Duo CPU E6550 @ 2.33GHz, com memória RAM de 2GB e disco rígido de 300 GB.

Para a representação das variáveis do problema na forma de indivíduos de uma população, foram feitas as seguintes considerações: cada unidade de produção foi representada

por um gene e cada alternativa de manejo da Unidade de Produção (UP), por um alelo deste gene. O conjunto de todos os genes (UP) formou um cromossomo. O indivíduo foi representado pelo seu cromossomo, acrescido da informação de *fitness*. Uma população foi um conjunto de indivíduos.

Para cada alelo (alternativa de manejo) de um gene (UP) foram atribuídos os valores 0 ou 1. Como para cada UP somente pode ser escolhida uma alternativa de manejo a ser utilizada, em cada gene apenas um alelo pode ter valor 1, ficando os demais com valor 0. Um exemplo desta representação pode ser visto na Figura 1. Devido a esta consideração, para o operador de *crossing-over*, foi feita a ressalva de que o ponto de *crossing* deve ser entre genes e nunca entre alelos, pois o cruzamento entre alelos poderia causar o não cumprimento desta regra. A mesma regra foi aplicada para o operador de mutação, tomando-se o cuidado de não se atribuir a dois alelos o valor 1.




Figura 1. Esquema representativo do cromossomo

Figure 1. Representative scheme of the chromosome

A geração da população inicial foi feita de forma aleatória, ou seja, escolheu-se aleatoriamente para cada gene uma alternativa de manejo e atribuiu-se o valor 1 para a mesma.

Com vistas à avaliação comparativa da eficácia e eficiência da utilização do AG, utilizou-se a solução exata obtida por meio do software CPLEX (Ilog, 2008) como referência para se compararem as soluções obtidas neste trabalho por meio da referida metaheurística.

Como mencionado, a metodologia para a abordagem de AG tem como referência os processos de evolução natural de uma população, baseando-se nas leis naturais de mutação, *crossing-over* e seleção natural. Nesse sentido, parâmetros como o tamanho inicial da população, os métodos de seleção, a taxa de mutação, os métodos de *crossing-over* e as taxas de *crossing-over* passam a ter grande influência na busca da resposta ótima. Entretanto, são escassas as informações sobre os valores desses parâmetros para se chegar a soluções próximas do ótimo exato em tempos computacionais de processamento aceitáveis para problemas de planejamento florestal. Pelos motivos expostos, testar variações destes parâmetros buscando-se a melhor solução no menor tempo possível é um dos objetivos fundamentais deste trabalho.

Considerando o elevado número de possíveis combinações de parâmetros que poderiam ser avaliadas, selecionou-se um total de 18 combinações ou tratamentos com 10 repetições cada, representando uma linha de pesquisa inicial. A partir destas combinações ou tratamentos, foram avaliadas variações dos parâmetros: população inicial, método e taxa de *crossing-*

over (Tabela 1). A população inicial representou o número de indivíduos (cromossomos) com que o AG iniciou a simulação do processo de evolução natural em busca da resposta ótima, sendo testados os tamanhos de 250, 500 e 750 indivíduos. Os métodos 1 e 2 de *crossing-over* representaram em quantos lugares o cromossomo foi quebrado para se fazer o *crossing-over*. No método 1 se considerou a quebra em uma única posição, ao passo que no método 2 em duas posições. Finalmente, a taxa de *crossing-over* foi associada à porcentagem de indivíduos da população que sofreu o *crossing-over*, ou seja, 45, 60 e 75%.

Tabela 1. Descrição dos tratamentos que levam em conta combinações dos parâmetros população inicial (com níveis iguais a 250, 500 e 750), método de *crossing over* (com níveis iguais a 1 e 2) e taxa de *crossing over* (com níveis iguais a 45, 60 e 75%)

Table 1. Description of the treatments that consider combinations of the parameters initial population (with levels of 250, 500 and 750), method of crossing over (with levels equal to 1 and 2) and crossing over rate (with levels of 45, 60 and 75%)

Tratamento	População Inicial	Método de Crossing-over (Pontos)	Taxa de Crossing-over (%)
1	250	1	45
2	250	1	60
3	250	1	75
4	250	2	45
5	250	2	60
6	250	2	75
7	500	1	45
8	500	1	60
9	500	1	75
10	500	2	45
11	500	2	60
12	500	2	75
13	750	1	45
14	750	1	60
15	750	1	75
16	750	2	45
17	750	2	60
18	750	2	75

Para analisar o efeito dos diferentes parâmetros no desempenho do AG, foi empregado o delineamento inteiramente casualizado no arranjo fatorial, em que os fatores considerados foram: três tamanhos de população inicial (250, 500 e 750 indivíduos), três taxas de *crossing-over* (45, 60 e 75%) e dois métodos de *crossing-over* (quebra em um ponto e quebra em dois pontos). As análises de variância foram executadas por intermédio do teste F, em nível de 5% probabilidade, testando-se a hipótese de nulidade de que as combinações testadas não diferem em termos de eficiência e eficácia na busca pela resposta ótima. As variáveis analisadas foram o tempo total de processamento (medida de eficiência) e a distância percentual entre a resposta obtida pelo AG e a resposta exata obtida pelo algoritmo *Branch and Bound* implementado no software CPLEX (medida de eficácia). A distância percentual foi calculada dividindo-se o valor ótimo obtido pelo AG pelo valor ótimo obtido pelo CPLEX, multiplicando-se esta razão por cem. Nos casos em que as interações foram significativas pelo teste F, foram realizados os desdobramentos dos

fatores, testando-se as diferenças entre as médias pelo teste Tukey, em nível de 5% de probabilidade.

RESULTADOS E DISCUSSÃO

Na análise de variância para a variável distância percentual, não se encontrou interação significativa dos três fatores considerados. Verificou-se, entretanto, interação dos fatores Mcross e Tcross e Tcross e Pini, pelo teste F, em nível de 5% de probabilidade. Assim, foi realizado o desdobramento dessas interações no sentido de se compararem as médias pelo teste Tukey, em nível de 5% de probabilidade (Tabela 2).

Tabela 2. Comparação entre as médias de distância percentual para os fatores Mcross x Tcross e Tcross x Pini, em nível de 5% de probabilidade pelo teste de Tukey, sendo que as letras maiúsculas permitem comparar as médias nas colunas enquanto que as letras minúsculas entre parênteses permitem comparar as médias nas linhas. Médias seguidas pela mesma letra não diferem estatisticamente entre si

Table 2. Comparison among the averages of percentile distance for the factors Mcross x Tcross and Tcross x Pini, in level of 5% of probability for the test of Tukey, and the capital letters allow to compare the averages in the columns while the small letters between parentheses allow to compare the averages in the lines. Averages followed by the same letter don't differ statistically amongst themselves

TCross	MCross		Pini		
	1	2	750	500	250
45	97,45 A (a)	97,80 A (a)	98,04 A (a)	97,62 A (ab)	97,20 A (b)
60	97,16 A (b)	97,88 A (a)	98,00 A (a)	97,41 A (ab)	97,15 A (b)
75	97,45 A (a)	97,71 A (a)	97,95 A (a)	97,15 A (b)	96,95 A (b)

As médias para os níveis do fator Mcross só apresentaram diferença significativa para Tcross igual a 60, em nível de 5% de probabilidade pelo teste Tukey (Tabela 2). Nota-se não houve efeito do fator Mcross sobre o aumento da eficácia. Resultado semelhante foi encontrado por Rodrigues et al. (2004), que também não encontraram diferenças significativas entre os métodos de *crossing-over*.

Contudo, é importante cautela ao se compararem resultados de parametrizações diferentes, pois a interação dos fatores pode aumentar o desempenho do AG. Isto significa que, na pesquisa de Rodrigues et al. (2004) e neste trabalho, não se percebeu de forma clara a influência do fator Mcross no aumento da eficácia, mas, combinado com outros fatores ou com outros níveis, este efeito pode passar a ser importante. Infelizmente são poucos os trabalhos que apresentam resultados testando diferentes parametrizações de AG para solução de problemas de planejamento florestal, não sendo possível ainda delinear uma tendência clara na busca dos melhores métodos para a solução.

Na comparação das médias de distância percentual, para todos os níveis do fator Tcross fixados (Tabela 2), observa-se tendência de piora do desempenho em termos de eficácia com a redução de Pini. Para o maior nível de Tcross (Tcross = 75) essa tendência parece ficar mais clara, sugerindo que devem-se evitar populações iniciais menores para taxas mais

elevadas de *crossing-over* quando se busca a eficácia da solução. Da mesma forma, Rodrigues et al. (2004) reforçam a idéia de que o fator Pini foi o que exerceu a maior influência na aproximação da resposta obtida pelo AG da resposta exata. Esses autores encontraram maior eficácia para os maiores tamanhos de população inicial.

Por outro lado, quando se compararam as médias de distância percentual fixando-se o fator Pini na Tabela 2, não se obteve diferença entre as médias dos níveis de Tcross, em nível de 5% de probabilidade pelo teste Tukey, mesmo quando se aumentou o tamanho da população inicial (Pini). Novamente fica evidenciado que, diferentemente de Pini, o fator Tcross não exerceu influência significativa na busca da resposta exata pelo AG.

A menor e a maior média de distância encontrada foi de, respectivamente, 96,62 e 98,41% (Tabela 5). Isto significa que a resposta do AG, em seu pior desempenho, se afastou aproximadamente 3,5% da resposta ótima, o que indica o potencial dessa heurística para a solução de problemas de planejamento florestal. Rodrigues et al. (2004) encontraram distâncias de 90,01 a 98,48% para populações iniciais iguais a 75 e 100, ressaltando que estes tamanhos de população foram os maiores testados e também os que proporcionaram os melhores resultados em termos de eficácia, assim como ocorreu neste trabalho.

De acordo com Youssef et al. (2001), uma das dificuldades observadas durante a confecção de um AG é a definição do tamanho da população, pois uma população pequena pode causar convergência prematura do algoritmo, enquanto uma população muito grande pode demandar muito tempo de processamento para o algoritmo encontrar uma solução eficaz.

Na avaliação da variável tempo total de processamento, verificou-se interação tripla dos fatores taxa de *crossing-over* (Tcross), Método de *Crossing-over* (Mcross) e População Inicial (Pini), pelo teste F em nível de 5% de probabilidade. Assim, foi realizado um desdobramento dessa interação no sentido de estudar o tempo médio de processamento, considerando-se determinado fator quando os demais se mantinham fixos (Tabela 3). Esta tabela permite comparar os níveis do fator Tcross fixando-se os níveis dos fatores Mcross e Pini e

Tabela 3. Comparação entre as médias do tempo total de processamento em segundos, em nível de 5% de probabilidade pelo teste de Tukey*

Table 3. Comparison among the averages of the total time of processing in seconds, at 5% of probability by Tukey test*

Tcross	Mcross = 1		
	Pini = 250	Pini = 500	Pini = 750
45	24,60 A (c)	48,70 A (b)	76,00 A (a)
60	23,70 A (c)	49,90 A (b)	76,20 A (a)
75	23,60 A (c)	48,40 A (b)	76,00 A (a)
	Mcross = 2		
45	23,70 A (c)	48,70 A (b)	75,60 A (a)
60	23,80 A (c)	49,60 A (b)	75,40 A (a)
75	23,70 A (c)	51,10 A (b)	77,20 A (a)

* As letras minúsculas localizadas entre parênteses comparam os níveis do fator Pini (comparação das médias na linha) fixando-se os níveis dos fatores Mcross e Tcross e as letras maiúsculas localizadas à direita permitem comparar os níveis do fator Tcross fixando-se os níveis dos fatores Mcross e Pini (comparação das médias na coluna). Médias seguidas pela mesma letra não diferem estatisticamente entre si

comparar os níveis do fator Pini fixando-se os níveis dos fatores Tcross e Mcross.

As médias de Tcross, independentemente dos níveis de Mcross e Pini, foram sempre iguais pelo teste Tukey, em nível 5% de probabilidade (Tabela 3). Por outro lado, quando se avaliaram os níveis de Pini mantendo-se fixos os níveis de Mcross e Tcross, nota-se que, quanto maior a população inicial, maior o tempo de processamento. Estes resultados também corroboram aqueles encontrados por Rodrigues et al. (2004).

As médias de Mcross, independentemente dos níveis de Tcross e Pini, foram sempre semelhantes pelo teste Tukey ($P > 0,5$) (Tabela 4), exceto quando Tcross = 75 e Pini = 500, pois, neste caso, o Mcross igual a 1 apresentou menor tempo de processamento pelo teste Tukey, em nível de 5% de probabilidade. Este resultado era esperado uma vez que o Mcross igual a 2 implica em uma tarefa a mais na execução do AG, o que resultaria em acréscimo de tempo. Por outro lado, os resultados apresentados na Tabela 4 não indicam que este acréscimo de tempo seja significativo, uma vez que apenas no caso da exceção citada houve diferença entre os níveis de Mcross. Assim, não seria possível inferir que, para Mcross igual a 1, há nítida vantagem em termos de tempo de processamento, carecendo-se de mais estudos para se referendar tal conclusão.

Tabela 4. Comparação entre as médias do tempo total de processamento em segundos, em nível de 5% de probabilidade pelo teste Tukey. As letras maiúsculas comparam os níveis do fator Mcross (comparação das médias na coluna) fixando-se os níveis dos fatores Pini e Tcross

Table 4. Comparison among the averages of the total processing time in seconds, at 5% of probability by Tukey test. The capital letters compare the levels of Mcross factor (comparison of the averages in a column) fixing the levels of Pini and Tcross factors

Mcross	Pini = 250		
	Tcross = 45	Tcross = 60	Tcross = 75
1	24,60 A	23,70 A	23,60 A
2	23,70 A	23,80 A	23,70 A
	Pini = 500		
1	48,70 A	49,90 A	48,40 B
2	48,70 A	49,60 A	51,10 A
	Pini = 750		
1	76,00 A	76,20 A	76,00 A
2	75,60 A	75,40 A	77,20 A

Médias seguidas pela mesma letra não diferem estatisticamente entre si

A resposta exata obtida pelo CPLEX para o problema proposto foi encontrada em um tempo médio de 2,09 segundos. Consta-se que o tempo gasto pelo CPLEX foi bem inferior a todos os tempos encontrados pelo AG (Tabela 5). Este resultado já era esperado uma vez que o problema em questão apresenta apenas 735 variáveis, pois sabe-se que em problemas de pequeno porte o CPLEX tenderá a apresentar maior eficiência na busca da resposta ótima. No entanto, a expectativa é que em problemas de porte mais elevado esta tendência se inverta, ou seja, o tempo de processamento do CPLEX cresça exponencialmente, ao passo que o tempo para o AG cresça em progressão menos acentuada.

Tabela 5. Médias para o tempo total de processamento em segundos e para as distâncias percentuais entre as soluções geradas pelo AG e pelo CPLEX**Table 5.** Averages for the total time of processing in seconds and for the percentile distances among the solutions generated by AG and for CPLEX

Tratamento	Distância (%)	Tratamento	Tempo (s)
17	98,41 A	18	77,20 A
18	98,29 A	14	76,20 A
12	98,21 A	13	76,00 A
13	98,10 AB	15	76,00 A
10	98,01 AB	16	75,60 A
16	97,98 AB	17	75,40 A
11	97,78 AB	12	51,10 B
15	97,61 AB	8	49,90 B
14	97,59 AB	11	49,60 B
9	97,47 AB	7	48,70 B
5	97,45 AB	10	48,70 B
4	97,40 AB	9	48,40 B
3	97,28 AB	1	24,60 C
7	97,23 AB	5	23,80 C
8	97,05 AB	2	23,70 C
1	97,00 AB	4	23,70 C
2	96,85 AB	6	23,70 C
6	96,62 B	3	23,60 C

Médias seguidas pela mesma letra são estatisticamente iguais pelo teste Tukey em nível de 5% de probabilidade

Conforme resultados encontrados por Rodrigues et al. (2004), o tempo computacional gasto pelo algoritmo *Branch and Bound* cresceu mais rapidamente com o tamanho do problema (número de variáveis), comparado ao AG. Esses autores verificaram que o algoritmo *Branch and Bound* consumiu um tempo cinco vezes superior ao AG para os maiores problemas. Há que se considerar também que a eficiência do AG não foi avaliada rigorosamente neste trabalho, o que iria requerer análises de complexidade de algoritmos mais sofisticadas, como complexidade de tempo e de espaço.

Considerando-se que o AG utilizado foi apenas um protótipo de pesquisa, diferentemente do CPLEX, que já é um *software* consagrado no mercado, portanto, bem mais desenvolvido, há ainda razoáveis perspectivas de melhoria da eficiência do AG. Isto poderá ser obtido com uma estrutura de dados para otimizar operações como geração das populações e suas respectivas avaliações, cálculo da *fitness* e testes dos indivíduos, segundo as restrições do problema (avaliação de sua viabilidade). É consenso na literatura especializada que essas operações são críticas e consomem a maioria dos recursos de processamento do AG (Mitchell, 1996).

É importante mencionar que no planejamento florestal ainda é difícil construir problemas realísticos de grande porte pela raridade de ferramentas geradoras de alternativas de manejo. Outra dificuldade é associar as eventuais alternativas de manejo geradas para a floresta a dados consistentes e próximos da realidade, de modo que os testes realizados tenham valor. Estes dados incluem informações econômicas, como preços de produtos e insumos, taxa de juros, dados operacionais de produção, bem como dados envolvendo a produção física dos povoamentos florestais. Espera-se, contudo, que o desenvolvimento de novos processos de sistemas de informações permita brevemente superar estas dificuldades e que esta pesquisa possa ser útil no teste de problemas de porte mais elevado.

Analisando-se as combinações todas as combinações possíveis entre os níveis dos fatores Pini, Mcross e Tcross (Tabela 1) e os resultados encontrados na Tabela 5, nota-se claramente que o fator Pini teve grande influência no tempo de processamento, formando-se três grupos de médias distintos pelo teste Tukey em nível de 5% de probabilidade: grupo 1 – tratamentos de 1 a 6 associados a Pini igual a 250, menor tempo de processamento; grupo 2 – tratamentos de 7 a 12 associados a Pini igual a 500, tempo intermediário de processamento; e grupo 3 – tratamentos de 13 a 18 associados a Pini igual a 750, maior tempo de processamento. Este resultado deixa bem claro a maior influência do fator Pini sobre o tempo de processamento em relação aos demais fatores avaliados.

Quando se faz a mesma análise para a variável distância, não se encontra o mesmo resultado (Tabela 5). Neste caso, nota-se que Pini não teve tanta influência na diferença das médias, percebendo-se ligeira diminuição da distância com o aumento de Pini. Contudo, infere-se que o aumento de Pini de 250 para 750 não trouxe ganhos significativos de redução da distância da resposta do AG em relação à resposta exata. Assim, poder-se-ia recomendar os tratamentos de 1 a 5 como os mais interessantes, uma vez que apresentaram respostas próximas das melhores encontradas em termos de distância, com a vantagem de apresentar reduzido tempo de processamento.

CONCLUSÕES

Para populações iniciais menores (Pini igual a 100), devem-se evitar taxas de *crossing-over* mais elevadas.

A população inicial (Pini) é o fator que mais influencia o desempenho do AG em termos de distância, de modo que, quanto maior o Pini, menor a distância da resposta obtida pelo AG da resposta exata.

Os níveis de Tcross e Mcross não aumentam o desempenho do AG na busca da resposta ótima.

A população inicial (Pini) é o fator que mais influencia o desempenho do AG em termos de tempo, de modo que, quanto maior o Pini, maior o tempo de processamento.

Os tratamentos de 1 a 5 são os mais promissores em termos de tempo total de processamento e de distância percentual.

LITERATURA CITADA

- Baskent, E.Z.; Jordan, G.A. Forest landscape management modeling using simulated annealing. *Forest Ecology and Management*, v.165, n.1-3, p.29-45, 2002.
- Carnieri, C. Planejamento florestal otimizado via redes de manejo. Campinas: Universidade Estadual de Campinas, 1989. 144p. Tese Doutorado.
- Cientec – *Softwares* para o Agronegócio e Recursos Naturais. <http://www.cientec.net/cientec/index.asp>. 5 Mar. 2008.
- Dykstra, D.P. *athematical programming for natural resource manegement*. New York: McGraw-Hill, 1984. 318p.

- Ignacio, A.A.V.; Ferreira Filho, V.J.M.; Galvão, R.D. Métodos heurísticos num entorno paralelo. In: Simpósio Brasileiro de Pesquisa Operacional, 32, 2000, Viçosa. Anais... Rio de Janeiro: SOBRAPO, 2000. p.769-788.
- Ilog. CPLEX. Informações técnicas. <http://www.ilog.com/products/cplex>. 15 Dez. 2008.
- Leite, H.G. Conversão de troncos em multiprodutos da madeira, utilizando programação dinâmica. Viçosa: Universidade Federal de Viçosa, 1994. 230p. Tese Doutorado.
- Mitchell, M. An introduction to genetic algorithms. London: A. Bradford Book, 1996. 205p.
- Nobre, S.R. A heurística da Razão-R aplicada a problemas de gestão florestal. Lavras: Universidade Federal de Lavras, 1999. 98p. Dissertação Mestrado.
- Pereira, G.W. Aplicação da técnica de recozimento simulado em problemas de planejamento florestal multiobjetivo. Belo Horizonte: Universidade Federal de Minas Gerais, 2004. 74p. Dissertação Mestrado.
- Ribeiro, C.A.A.S. Pesquisa operacional aplicada ao manejo florestal. Viçosa: UFV, 1996. 107p.
- Rodrigues, F.L.; Leite, H.G.; Souza, A.L.; Ribeiro, C.A.A.S.; Silva, M.L. Regulação de florestas equiâneas utilizando programação linear: uma aplicação da teoria do modelo II. Revista *Árvore*, v.22, n.2, p.193-213, 1998.
- Rodrigues, F.L.; Leite, H.G.; Santos, H.N.; Souza, A.L.; Silva, G.F. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. Revista *Árvore*, v.28, n.2, p.233-245, 2004.
- Rodrigues, F.L. Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais. Viçosa: Universidade Federal de Viçosa, 2001. 239p. Tese Doutorado.
- Rodrigues, F.L.; Silva, G.F.; Leite, H.G.; Xavier, A.C.; Pezzopane, J.E.M. um modelo de regulação florestal e suas implicações na formulação e solução de problemas com restrições de recobrimento. Revista *Árvore*, v.30, n.5, p.769-778, 2006.
- Silva, G.F.; Rodrigues, F.L.; Santos, H.N. Um sistema de apoio a decisão para pequenas e médias empresas florestais. In: Simpósio Brasileiro de Pesquisa Operacional, 32, 2000, Viçosa. Anais... Rio de Janeiro: SOBRAPO, 2000. p.953-961.
- Silva, G.F. Problemas no uso de programação matemática e simulação em regulação florestal. Viçosa: Universidade Federal de Viçosa, 2001. 89p. Tese Doutorado.
- Silva, G.F.; Ghisolfi, E.M.; Teixeira, A.F.; Cabrini, A.M.; Barros Júnior, A.A. O método das restrições na solução de um problema de planejamento florestal multiobjetivo. Revista Brasileira de Ciências Agrárias, v.1, n.único, p.41-48, 2006.
- Taube Neto, M. Um modelo de programação linear para o planejamento de florestas de Eucalyptus. Revista Pesquisa Operacional, v.4, n.1, p.19-38, 1984.
- Teixeira, A.F. Aplicação de algoritmos evolucionários na solução de problemas de planejamento florestal multiobjetivo. Belo Horizonte: Universidade Federal de Minas Gerais, 2002. 70 p. Dissertação Mestrado.
- Youssef, H.; Sait, S.M.; Adiche, H. Evolutionary algorithms, simulated annealing end tabu search: a comparative study. *Engineering Applications of Artificial Intelligence*, v.14, n.2, 167-181, 2001.