

USO DO ALGORITMO GENÉTICO NO PLANEJAMENTO FLORESTAL CONSIDERANDO SEUS OPERADORES DE SELEÇÃO

Lucas Rezende Gomide¹, Julio Eduardo Arce², Arinei Carlos Lindbeck da Silva³

(recebido: 7 de outubro de 2009; aceito: 30 de setembro de 2009)

RESUMO: Conduziu-se este estudo, com o objetivo de testar e analisar quatro tipos de operadores genéticos de seleção (Elitista, Torneio, Roleta e Bi-classista) e definir o melhor. O problema teste de planejamento florestal foi baseado no modelo tipo I de Johnson & Schermann (1977) e aplicado em uma floresta composta por 52 talhões de Eucalipto, sendo geradas 254 alternativas de manejo. O algoritmo genético (AG) foi desenvolvido utilizando a linguagem de programação *Microsoft® Visual Basic®* e seus parâmetros foram: população inicial (300), *crossover* (10%), mutação (10%) e *replacement* (60%). As variáveis mensuradas foram: valor mínimo, médio e máximo; coeficiente de variação para as variáveis *fitness* e tempo de processamento. Além disso, foi aplicado o teste não paramétrico de Kruskal-Wallis a 5% de probabilidade para analisar as diferenças entre os operadores de seleção, considerando 30 repetições. Os resultados mostraram que os operadores genéticos de seleção apresentaram diferenças ligadas a eficiência e eficácia, segundo o teste não paramétrico de Kruskal-Wallis a 5% de probabilidade. A sequência decrescente de eficiência foi: Bi-classista, Elitista, Torneio e Roleta, já, considerando a eficácia, sua ordem decrescente foi: Roleta, Torneio, Elitista e Bi-classista. Os menores desvios percentuais frente a solução ótima foram: 2,75% (Elitista), 2,15% (Torneio), 0,90% (Roleta) e 2,40% (Bi-classista). O melhor operador de seleção testado foi o programado via Roleta.

Palavras-chave: Metaheurística, análise combinatória, modelo tipo I.

USING GENETIC ALGORITHM IN FOREST PLANNING CONSIDERING ITS SELECTION OPERATORS

ABSTRACT: *This study tested and analyzed four selection operators (Elitist, Tournament, Roulette wheels and Bi-classist) and defined the best one. The forest planning problem test was based on the Johnson & Schermann (1977) type I model encompassing 52 eucalyptus stands, where 254 forest management prescriptions were created. The genetic algorithm (GA) was built in Visual Basic® Microsoft® and its sets of parameters were: initial population (300), crossover (10%), mutation (10%) and replacement (60%). The measuring variables were: minimum, median and maximum values; coefficient of variation for the fitness and the processing time. It was also applied the nonparametric Kruskal-Wallis test with 5% of the probability to check the differences among selection operators of 30 samples. The results showed that the selection operators presented different efficiency and effectiveness according to Kruskal-Wallis test for 5% of probability. The decreasing sequence of efficiency was: Roulette wheels, Tournament, Elitist and Bi-classist. The lower percentage deviations matched from the exact solution were: 2.75% (Elitist), 2.15% (Tournament), 0.90% (Roulette wheels) and 2.40% (Bi-classist). The best selection operator tested was the one that follows the Roulette wheels.*

Key words: Metaheuristic, combinatory analysis, model type I.

1 INTRODUÇÃO

O planejamento de qualquer empreendimento ou atividade florestal, nos dias atuais, pode ser considerado como uma arte, igualmente à ação de pintar um quadro ou compor uma música, pois a complexidade e magnitude de informações e as exigências dos agentes de produção desafiam a capacidade humana na resolução dos problemas. A criatividade necessária, para vencer esse desafio, definitivamente obriga o uso de técnicas computacionais para acelerar o processo e garantir, ao tomador de decisão, maior confiabilidade na gestão da informação.

A otimização desses sistemas de produção florestal compõe uma estrutura fundamental para o funcionamento equilibrado das atividades industriais e logísticas do segmento empresarial. Nesse aspecto, são analisadas diversas estratégias para a condução da floresta, incluindo questões ligadas à produção volumétrica, sortimento de produtos florestais, estoque de carbono, ou ainda outras alternativas.

Problemas que envolvem a seleção dos melhores regimes de manejo para a floresta são geralmente formulados como problemas de programação linear (PL) e programação linear inteira (PLI). Nesse último caso, uma forma tradicional

¹Engenheiro Florestal, Doutorando em Engenharia Florestal – Departamento de Ciências Florestais/DECIF – Universidade Federal do Paraná/UFPR – Rua Lothário Meissner, 900, Jardim Botânico – 80210-170 – Curitiba, PR – lrgomide@hotmail.com

²Engenheiro Florestal, Professor Dr. do Departamento de Ciências Florestais/DECIF – Universidade Federal do Paraná/UFPR – Rua Lothário Meissner, 900, Jardim Botânico – 80210-170 – Curitiba, PR – jarce@ufpr.br

³Licenciado em Matemática, Professor Dr. do Departamento de Matemática/DMAT – Universidade Federal do Paraná/UFPR – Cx.P. 019081 – 81531-990 – lindbeck@mat.ufpr.br

e exata de resolução pode ser via algoritmo *branch and bound*. Porém, muitas vezes o tempo computacional gasto torna o método tecnicamente inviável. Nesse tipo de problema, o grande entrave é o aumento do número de talhões, pois os mesmos promovem um aumento exponencial do número de variáveis, dificultando as buscas da solução ótima. Uma saída encontrada para aumentar a eficiência computacional é o uso de heurísticas e metaheurísticas.

As metaheurísticas são algoritmos matemáticos especialistas e inteligentes, compostos por regras de busca de soluções para um dado problema (BODINGTON & SHOBRY, 1995). Alguns exemplos de metaheurísticas amplamente encontradas na literatura são: *Simulated annealing*, Busca tabu, Colônia de formigas e Algoritmos Genéticos. Baskent (2001) afirma que as metaheurísticas geram soluções próximas do ótimo a um esforço computacional expressivamente menor, sendo o mesmo comentado por Reeves (1993). Mitsuo & Cheng (2000) complementam esse pressuposto, afirmando que este efeito pode ser positivo, principalmente quando o problema se enquadra em *NP-hard* (*Non-polynomial hard*).

Na área florestal existem diversos trabalhos que empregaram este algoritmo, a exemplo, cita-se o trabalho de Rodrigues et al. (2004) onde o Algoritmo Genético (AG) apresentou uma solução média com desvio de 5,72% em relação a solução ótima global, a um tempo computacional 5 vezes menor que o método exato. Ainda são observados outros estudos como em Bettinger et al. (2002), Falcão & Borges (2003) e Souza (2004).

Segundo Ashlock (2005), ao se pensar na utilização do AG para resolver problemas de qualquer natureza, surgem as seguintes perguntas: Que tipo de *fitness* utilizar? Qual o tipo de *crossover* e mutação escolher? Como selecionar os indivíduos da população para reproduzir, e como inseri-los na nova geração? Qual a melhor estratégia de parada? Qual codificação empregar? Por outro lado, Michalewicz (1996) diz que estudos sobre a definição do tipo de estratégia ainda está bem fragmentado e, em muitos casos, existe uma cultura empírica sobre a sua utilização. Em relação ao operador genético de seleção, Gen & Cheng (2000) comentam que o mesmo influencia no comportamento do AG ao realizar buscas no espaço de soluções.

Neste trabalho, objetivou-se, por meio da utilização do AG, testar e analisar o comportamento de quatro tipos de operadores genéticos de seleção (Elitista, Torneio, Roleta e Bi-classista) a taxas fixas de mutação, *crossover* e

replacement; e definir o melhor operador genético de seleção para o problema.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi desenvolvido em 5 fazendas pertencentes à empresa VCP - Votorantim Celulose e Papel, sendo todas localizadas no município de Caçapava-SP. O clima da região é denominado pela classificação de Köppen como Cwa, com verão chuvoso e quente, e inverno seco. A área total efetiva de plantio compreende aproximadamente 1490,7 ha, distribuídos em reflorestamentos com espécies de Eucalipto e alguns variações de clones da empresa (Figura 1).

A floresta submetida para as análises foi considerada madura, uma vez que 65,32% da sua área continham talhões em idade de corte (idade ≥ 5 anos) e possíveis de agendamento já no primeiro ano de atividade florestal. O desbalanceamento encontrado exigiu um maior intervalo entre os limites de produção volumétrica, durante a elaboração do cenário para o teste. O número de talhões estudados foi representado por 52 unidades de manejo ou compartimentos.

2.2 Descrição do problema teste

O problema teste de planejamento florestal foi caracterizado com a necessidade de maximizar o valor presente líquido (VPL), analogamente ao encontrado em uma série de trabalhos na literatura, e que tiveram o Modelo tipo I de Johnson & Scheurmann (1977) como referência. Além disso, restrições de fluxo constante na produção volumétrica de madeira foram introduzidas na formulação matemática, considerando a regulação da floresta do ponto de vista volumétrico.

A produção volumétrica deveria atender a uma meta anual estipulada de 84.500 m³, com variação constante e tolerável de $\pm 16\%$ em relação à mesma, como ainda respeitar a restrição de idade mínima (5 anos) e máxima (7 anos) de corte do talhão na seleção da colheita. A partir dessas informações foram simuladas 254 alternativas de manejo para a floresta em questão, considerando apenas o regime de alto fuste.

2.3 Formulação matemática do problema

O problema foi formulado nos moldes da programação linear inteira clássica, onde a função objetivo (1) contemplou a maximização do valor presente líquido

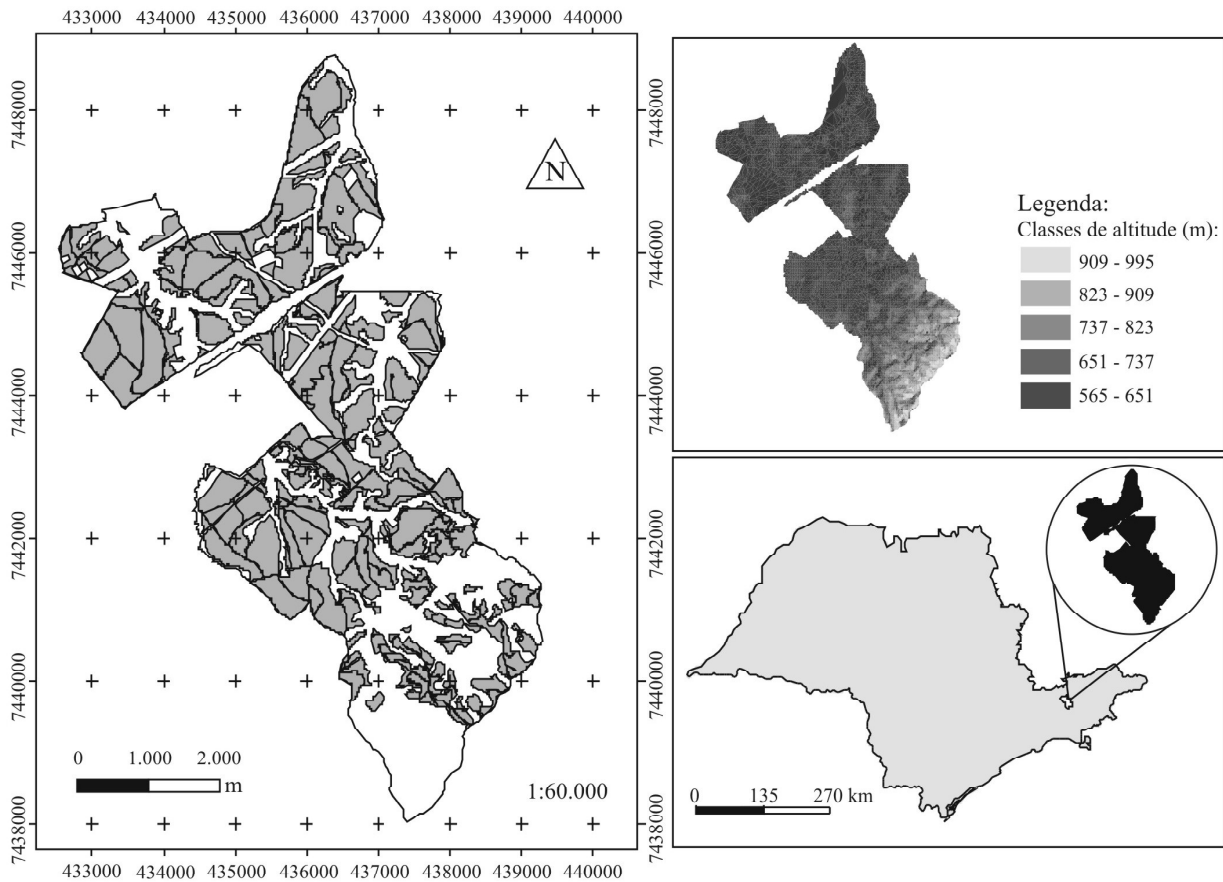


Figura 1 – Mapa da localização da floresta selecionada para a execução dos testes via operador de seleção no AG.

Figure 1 – Map of the selected forest location to be applied the tests by the selection operator in GA.

(VPL) a partir das restrições: (2) garantir a adoção de apenas um regime de manejo por unidade de talhão (singularidade); (3) e (4) promover um fluxo de produção volumétrico constante a partir de limite mínimo e máximo toleráveis já citados e (5) restrições de integridade e não negatividade das variáveis de decisão.

Função Objetivo:

$$\text{Maximizar} \quad \text{VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij} x_{ij} \quad (1)$$

$$\text{Sujeito a} \quad \sum_{j=1}^P x_{ij} = 1, \forall_j, \forall_{i=1,2,\dots,M} \quad (2)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \geq L_{\text{inferior}}, \forall_i, \forall_j, \forall_{T=1,2,\dots,7} \quad (3)$$

$$\sum_{i=1}^M \sum_{j=1}^P v_{ij} x_{ijT} \leq L_{\text{superior}}, \forall_i, \forall_j, \forall_{T=1,2,\dots,7} \quad (4)$$

$$0 \leq x_{ij} \leq 1 \text{ e } x_{ij} = \text{inteiro} \quad (5)$$

Onde:

- M - número total de talhões manejados;
- P - número total de opções de regimes de manejo;
- x_{ij} - variável binária (0/1) de decisão do modelo, referente ao talhão i da escolha de opção do regime de manejo j ;
- c_{ij} - valor presente líquido pertencente ao talhão i da opção de regime de manejo j ;
- T - período total de tempo de planejamento;
- v_{ij} - volume total produzido no talhão i pertencente a opção de regime de manejo j ;

2.4 Algoritmo Genético

O AG utilizado seguiu a idéia *steady state*, onde apenas uma parte da população é substituída a cada geração, considerando uma taxa de 60% de *replacement*. Desse modo pode-se evitar uma troca repentina da população, bem como permitir explorar mais as soluções vizinhas a cada geração, evitando a troca repentina da população. Uma mesma taxa de 60% foi usada nos trabalhos de Mitchell (1996) e Tsao & Chen (2004).

O tamanho da população testada foi de 300 indivíduos, onde seus indivíduos foram gerados de forma aleatória, considerando uma codificação binária {0,1}, sendo aceitas apenas sequências viáveis, ou seja, apenas um único regime de manejo viável para cada talhão. As trocas de genes entre cromossomos são conhecidas como *crossover*, e como resultado formam novos indivíduos. Dessa maneira, a estratégia utilizada foi a formação de dois novos indivíduos por cruzamento, aplicando um *crossover* de múltiplos pontos, com um limite fixo em 10% de trocas, o mesmo observado em Falcão & Borges (2003).

Outro operador é a mutação, que tem a finalidade de injetar novas bases genéticas em indivíduos selecionados da população, ajudando o algoritmo a realizar buscas em diferentes pontos do espaço. Assim, a taxa de mutação empregada foi de 10% com uma probabilidade fixa de 0,5 de ocorrência do evento.

A seleção dos indivíduos para a reprodução é definida pelos operadores genéticos de seleção. Esses influenciam na eficácia da resposta, velocidade de convergência e na eficiência do algoritmo. Assim, quatro operadores genéticos de seleção foram testados:

a) *Elitista* - tem como princípio selecionar apenas os melhores indivíduos via *fitness*, os quais são usados na formação de novas gerações (SAKAWA, 2002);

b) *Torneio* - a seleção é obtida por meio da competição entre 2 indivíduos, sendo escolhido sempre o melhor (maior *fitness*) para compor o grupo a reproduzir.

c) *Roleta* - a seleção dos indivíduos é feita de acordo com a probabilidade de serem selecionados, segundo os valores de *fitness*. Quanto maior o *fitness*, maior é a probabilidade de serem selecionados, a cada nova rodada da roleta (GOLDBERG, 1989);

d) *Bi-classista* - o método considera a seleção proporcional ao valor ordenado do *fitness* da população, sendo selecionada uma porção para os melhores *fitness* e outra para os piores, até completar a lista de seleção. No

estudo, a lista de seleção de indivíduos foi preenchida com 60% (melhores) e 40% (piores).

O critério de parada adotado durante os testes foi estabelecido em 1.000 iterações fixas. Entretanto, para que o algoritmo genético pudesse executar as buscas foi introduzida uma função de penalidade na Função Objetivo (1), conforme equação (6). O valor da penalidade é multiplicado pelo volume de madeira fora dos limites volumétricos estabelecidos, sendo então descontado do VPL.

$$\text{Maximizar } \text{VPL} = \sum_{i=1}^M \sum_{j=1}^P c_{ij}x_{ij} - \text{penalidade(R\$/m}^3) \quad (6)$$

Onde:

Penalidade - R\$500,00/m³ de madeira (excedente/deficitária);

VPL, M, P, x_{ij}, i, j e c_{ij} - apresentados anteriormente.

2.5 Implementação computacional e análise estatística

A implementação do AG foi desenvolvida, utilizando a linguagem de programação *Visual Basic*® da *Microsoft*®, criando-se então uma ferramenta para as análises. O processamento das opções testadas foi executado em um computador com processador *Intel*® *Celeron*® *core 2 duo* 2100 MHz e 2 Gb de RAM. A resposta exata foi obtida pelo solver LINGO versão 9.0 processada no mesmo CPU.

Na análise dos operadores genéticos de seleção foi mensurado o valor mínimo, médio e máximo do *fitness*, coeficiente de variação e aplicado o teste não paramétrico de Kruskal-Wallis (SHESKIN, 2000) como alternativa à ANOVA, tendo em vista a quebra das pressuposições básicas para sua utilização. O mesmo problema foi observado no estudo de Souza (2004).

O nível de significância adotado no teste de Kruskal-Wallis foi de 5%, indicando que significâncias (p-valor) iguais ou inferiores a 0,05 foram consideradas estatisticamente significativas. A mesma análise foi realizada para a variável tempo de processamento.

3 RESULTADOS E DISCUSSÃO

A estrutura do problema teste abordou um número de 67 restrições e 254 variáveis de decisão, que exigiram um esforço computacional de tempo igual a 2.763 segundos, totalizando 15.607.011 iterações e uma árvore no *Branch and Bound* com 3.020.286 ramificações. Exemplificando a complexidade, para cada variável binária que se acrescenta ao problema, o número de soluções a examinar duplica, e para 15 variáveis binárias tem-se 2¹⁵=32.768 possíveis

soluções. Assim, solução factível encontrada foi de R\$8.615.314,18 e o volume total de 609.222,05 m³ ao longo dos 7 anos de planejamento. O valor do VPL alcançado pelo AG nas estratégias testadas ficou muito próximo do valor exato, onde a diferença percentual foi de 2,75% (Elitista), 2,15% (Torneio), 2,40% (Bi-classista) e 0,90% (Roleta) nas melhores soluções obtidas pelos operadores.

As análises dos operadores genéticos de seleção testados mostraram que o método com o maior *fitness* médio foi a Roleta, seguido na sequência pelos métodos Torneio, Elitista e Bi-classista (Tabela 1). Esse resultado indica uma melhor capacidade do operador de seleção Roleta em suprir as demandas de madeira, já que o valor do *fitness* é calculado via penalidades na função de aptidão. Os métodos de seleção mais eficientes foram os métodos menos eficazes, ao considerar as médias como critério de comparação.

Analisando o coeficiente de variação (CV%) constatou-se que as variações dos valores de *fitness* não divergiram muito da média, para todos os operadores de seleção. Porém, o operador Elitista foi o que possuiu o maior valor (4,88%), este fato é facilmente explicado, pois este operador de seleção pode convergir mais rápido e de forma prematura, chegando a um baixo ótimo local. A idéia é reforçada quando foram comparados os mínimos obtidos entre os operadores testados.

O operador de seleção Roleta obteve uma maior diversidade de indivíduos ao longo das iterações e, por isso, explica-se o fato de se obter as melhores respostas em *fitness*. Dessa maneira, quanto maior a diversidade da população, maiores são as chances de se obter indivíduos

mais adaptados ao problema. Essa estratégia tenta evitar problemas de ótimo local. Por isso, a velocidade na convergência da resposta é geralmente mais lenta, quando se adota um critério de parada relacionado à estagnação das respostas a um número x de iterações. Na Figura 2, apresenta-se o comportamento do *fitness* médio/iteração e o melhor/iteração ao longo de 100 iterações, em uma dada repetição. Esse desenvolvimento nas buscas comprova as suposições citadas anteriormente, sobre a diversidade e tempo de convergência dos operadores testados.

O tempo computacional médio de processamento dos operadores testados mostrou que os métodos Bi-classista e Elitista foram os mais rápidos, consumindo respectivamente 177,80 segundos e 178,8 segundos. Esse resultado foi esperado, já que são operadores que não exigem sorteios na seleção de indivíduos, sendo necessário apenas ordenar o *fitness* da população. Porém, comparando com o tempo total gasto via PLI seus resultados ficaram próximos de 6,5% do consumido, em todos os operadores de seleção.

A melhor de todas as respostas foi encontrada utilizando o operador de seleção Roleta, obtendo um VPL de R\$ 8.537.569,78 e volume total de 608.206,33m³ para os 7 anos de planejamento, na repetição de número 25. Essa repetição conseguiu atingir todas as metas volumétricas propostas no problema, como ainda obteve um desvio de apenas 0,90% da solução ótima. Na Figura 3, mostram-se os desvios percentuais de todas as 30 repetições por operador genético de seleção testado.

Os operadores de seleção testados atingiram todas as metas em 30% (Elitista), 36,7% (Torneio), 23,3% (Roleta)

Tabela 1 – Análise dos valores de coeficiente de variação, mínimo, médio e máximo das variáveis *fitness* e tempo de processamento obtido por meio dos operadores de seleção testados.

Table 1 – Analysis of the coefficient of variation, minimum, median and maximum of the fitness and processing time variables obtained through the selection operators tested.

Variável	Operadores	Mínimo	Média	Máximo	CV (%)
<i>Fitness</i>	Elitista	6.964.700,0	8.022.386,2	8.377.826,0	4,88
	Torneio	7.703.258,5	8.128.949,8	8.429.231,9	2,23
	Roleta	7.864.645,5	8.290.668,5	8.537.569,7	2,03
	Bi-classista	7.312.945,3	7.994.110,5	8.408.027,5	3,36
Tempo (s)	Elitista	173,0	178,8	188,0	2,14
	Torneio	177,0	182,5	192,0	1,85
	Roleta	179,0	183,4	186,0	1,09
	Bi-classista	174,0	177,8	180,0	1,04




Figura 2 – Estrutura de evolução das buscas realizada pelo AG nos 4 operadores testados ao longo de 100 gerações considerando a média/iteração e a melhor solução/iteração.

Figure 2 – The evolution structure of the search conducted by GA through the 4 operators tested across 100 generations measuring median/iteration and best solution/iteration.




Figura 3 – Desvio percentual da solução ótima encontrada no problema teste entre PLI e AG considerando os 4 operadores de seleção testados e as 30 amostras.

Figure 3 – Percentage deviation of the optimal solution acquired in the trial problem through ILP and GA considering the 4 selection operators tested and the 30 samples.

e 46,7% (Bi-classista) das 30 repetições realizadas. Apesar de existir uma melhor capacidade no operador Bi-classista neste ponto, o mesmo não é eficaz quando comparado com o operador Roleta, já que o mesmo apresentou baixos estoques de madeira ao longo dos anos de HP. As falhas em atingir algumas metas, o que não é permitido na programação linear inteira, variaram de 6,71 m³ a 2.698,67 m³.

A partir dos resultados obtidos pelo teste de Kruskal-Wallis (Tabela 2), e considerando as comparações pela variável *fitness*, foi comprovado que não há diferenças significativas a 5% de probabilidade entre os operadores de seleção Elitista x Torneio (T5) e Elitista x Bi-classista (T6). Porém, o contrário foi observado entre Torneio x Bi-classista (T4), Roleta x Torneio (T2), e, por analogia, entre Roleta e os demais (T1), já que o teste não discrimina quais tratamentos são diferentes apenas indica a existência da significância. Assim, a sequência de melhor operador de seleção foi definida pela seguinte ordem crescente de

eficácia, considerando a média dos escores do teste: Roleta, Torneio, Elitista e Bi-classista.

Aplicando o mesmo teste não paramétrico na variável tempo, observou-se a seguinte ordem decrescente de eficiência, considerando a média dos escores/operador de seleção: Bi-classista, Elitista, Torneio e Roleta, porém não apresentando diferenças estatísticas entre os operadores Bi-classista x Elitista (T5) a 5% de probabilidade. E, por analogia, foram observadas diferenças estatísticas a 5% de probabilidade entre as médias dos escores: Roleta x Bi-classista e Elitista, Roleta x Torneio, como ainda Torneio x Bi-classista e Elitista.

4 CONCLUSÕES

Os operadores genéticos de seleção testados apresentaram diferenças ligadas a eficiência e eficácia, sendo discriminado pelo teste não paramétrico de Kruskal-Wallis a 5% de probabilidade. A sequência decrescente de eficiência foi: Bi-classista, Elitista, Torneio e Roleta, já

Tabela 2 – Resumo da análise estatística do teste não paramétrico Kruskal-Wallis aplicado nas variáveis *fitness* e tempo de processamento para o 4 operadores de seleção testados.

Table 2 – Statistical analysis summary of the nonparametric Kruskal-Wallis test applied in *fitness* and processing time variables for the 4 selection operators tested.

Variável	Operadores	Teste de Kruskal-Wallis (média dos escores)					
		T1	T2	T3	T4	T5	T6
<i>Fitness</i>	Elitista	55,67	-	48,17	-	30,03	33,63
	Torneio	57,90	22,97	50,43	34,97	30,97	-
	Roleta	85,67	38,03	-	-	-	-
	Bi-classista	42,77	-	37,90	26,03	-	27,37
	Nível de significancia (5%)	s	s	s	s	ns	ns
	valor-p	0,0000	0,0008	0,1408	0,0476	0,8360	0,1646
Tempo	Operadores	Teste de Kruskal-Wallis (média dos escores)					
		T1	T2	T3	T4	T5	T6
	Elitista	43,63	-	39,05	23,30	31,25	-
	Torneio	76,87	25,58	66,78	37,70	-	44,58
	Roleta	90,50	35,42	-	-	-	-
	Bi-classista	31,00	-	30,67	-	29,75	16,42
	Nível de significancia (5%)	s	s	s	s	ns	s
valor-p	0,0000	0,0264	0,0000	0,0013	0,7370	0,0000	

T - número do teste de Kruskal-Wallis aplicado para realizar as comparações necessárias; s - significância entre os escores médios; ns - não significância entre os escores médios; valor-p - nível de probabilidade obtido no teste.

T - number of the Kruskal-Wallis test applied to check the necessary comparisons; s - significance between scores medians; ns - non significance between scores medians; valor-p - probability level obtained through the test.

considerando a eficácia a sua ordem decrescente foi: Roleta, Torneio, Elitista e Bi-classista. Os métodos de seleção mais eficientes foram os métodos menos eficazes, ao considerar as médias dos *fitness* como critério de comparação.

Ao considerar a configuração do AG testado (população inicial: 300 indivíduos, taxa de *crossover*: 10%, taxa de mutação: 10% e taxa de *replacement*: 60%) o melhor operador genético de seleção foi o programado via Roleta.

5 AGRADECIMENTOS

Os autores agradecem pelo apoio financeiro e pela disponibilidade dos dados ao pessoal técnico da empresa Votorantim Celulose e Papel S/A, Engº Davi Rodrigues de Souza, o Engº Honório Kanegae Júnior, o Engº Márcio Barbosa da Conceição, e os funcionários José Carlos da Rosa e Reginaldo Soares de Freitas.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ASHLOCK, D. **Evolutionary computation for modeling and optimization**. London: Springer, 2005. 571 p.
- BASKENT, E. Z. Combinatorial optimization in forest ecosystem management modeling. **Turkish Journal of Agriculture and Forestry**, Amsterdam, v. 25, p. 187-194, 2001.
- BETTINGER, P.; GRAETZ, D.; BOSTON, K.; SESSIONS, J.; CHUNG, W. Eight heuristic planning techniques applied to three increasingly difficult wildlife planning problems. **Silva Fennica**, Helsinki, v. 36, n. 2, p. 561-584, 2002.
- BODINGTON, C. E.; SHOBRY, D. E. **Planning, scheduling and control integration in the process industries**. New York: McGraw-Hill, 1995. 414 p.
- FALCÃO, A. O.; BORGES, J. G. Heurísticas para a integração de níveis estratégico e operacional da gestão florestal em problemas de grande dimensão. **Scientia Forestalis**, Piracicaba, n. 63, p. 13-23, 2003.
- GEN, M.; CHENG, R. **Genetic algorithms and engineering optimization**. New York: Wiley, 2000. 495 p.
- GOLDBERG, D. E. **Genetic algorithms in search, optimization, and machine learning**. New York: Longman, 1989. 412 p.
- JOHNSON, K. N.; SCHEURMANN, H. L. Techniques for prescribing optimal timber harvest and investment under different objectives: discussion and synthesis. **Forest Science**, Amsterdam, v. 18, n. 1, p. 1-31, 1977.
- MICHALEWICZ, Z. **Genetic algorithms + data structures = evolution programs**. New York: Springer, 1996. 388 p.
- MITCHELL, M. **An introduction to genetic algorithms**. [S.l.]: MIT, 1996. 226 p.
- MITSUO, G.; CHENG, R. **Genetic algorithms and engineering optimization**. New York: J. Wiley, 2000. 495 p.
- REEVES, C. R. **Modern heuristic techniques for combinatorial problems**. New York: J. Wiley, 1993. 320 p.
- RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. N.; SOUZA, A. L.; SILVA, F. S. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. **Revista Árvore**, Viçosa, MG, v. 28, n. 2, p. 233-245, 2004.
- SAKAWA, M. **Genetic algorithms and fuzzy multiobjective optimization**. Netherlands: Springer, 2002. 306 p.
- SHESKIN, D. J. **Handbook of parametric and nonparametric statistical procedures**. New York: Chapman & Hall, 2000. 1016 p.
- SOUZA, D. O. **Algoritmos genéticos aplicados ao planejamento do transporte principal de madeira**. 2004. 169 p. Dissertação (Mestrado em Manejo Florestal) - Universidade Federal do Paraná, Curitiba, 2004.
- TSAO, C. Y.; CHEN, S. H. Statistical analysis of genetic algorithms in discovering technical trading strategies. In: BINNER, J. M.; KENDALL, G.; CHEN, S. H. **Applications of artificial intelligence in finance and economics advances in econometrics**. New York: Elsevier, 2004. p. 1-43.