

Influência dos parâmetros da metaheurística *simulated annealing* em um problema de planejamento da produção florestal

Paulo Henrique Batista Ferreira¹, Lisandra Maria Alves Matos², Adriana Leandra de Assis¹, Christian Dias Cabacinha¹, Carlos Alberto Araújo Júnior^{1*}

Resumo

A quantidade excessiva de variáveis envolvidas no processo de produção florestal requer a utilização de ferramentas que forneçam respostas com elevado grau de precisão e no menor tempo possível. O presente trabalho visou a avaliação da performance da metaheurística *simulated annealing* sob diversas combinações de valores para seus parâmetros. O estudo considerou um problema de otimização do planejamento da produção florestal com um horizonte de planejamento de 16 anos, 120 talhões, idades de colheita entre 5 e 7 anos e demanda volumétrica entre 140.000 m³ e 160.000 m³. Foram avaliados três diferentes valores para os parâmetros temperatura inicial, taxa de decaimento da temperatura e número de vizinhos, gerando um total de 27 combinações. Para cada um considerou-se 30 repetições com critério de parada considerando 1000 iterações. O processamento foi realizado utilizando-se o software MeP e para a avaliação estatística aplicou-se o teste não-paramétrico de Kruskal-Wallis. A solução que apresentou maior valor presente líquido (R\$ 31.054.933) foi encontrada ao utilizar uma temperatura inicial igual a 10⁶, taxa de decaimento de 0,01 e 30 vizinhos. Porém, todas as soluções encontradas apresentam uma eficácia satisfatória, variando entre 94,97% e 94,16%. Os resultados encontrados permitem concluir que há diferença estatisticamente significativa entre as melhores e as piores combinações de parâmetros. Apesar disso, para que o algoritmo encontre soluções viáveis, tais combinações não são determinantes.

Palavras-chave: Pesquisa operacional; Regulação florestal; Inteligência artificial.

Influence of simulated annealing parameters in a forest production planning problem

Abstract

The excessive quantity of variables in the forest production process requires the use of tools that provide answers with a high degree of accuracy in a shortest possible time. Thus, this work aimed to evaluate simulated annealing metaheuristic performance under different combinations of values for its parameters. The study considered a forest production planning optimization problem with horizon plan of 16 years, 120 stands, harvest age between 5 e 7 years and volumetric demand between 140.000 m³ and 160.000 m³. Three different values were evaluated for the initial temperature, temperature decay rate and amount of neighbors, totaling 27 combinations. For each one, it was considered 30 repetitions with stopping criterion equals to 1000 iterations. The process was performed using MeP software and for the statistic evaluation, it was applied the Kruskal-Wallis test. The solution that showed the highest net present value (R\$ 31.054.933) was found using an initial temperature equal to 10⁶, the decay rate of 0,01 and 30 neighbors. All the solutions obtained had a satisfactory efficacy and it ranged from 94,97% to 94,16%. The results found showed a statistically significant difference between the best and the worst combination of parameters. It is possible to conclude that the set of parameters is important to find good solutions but it is not determinant to find viable solutions.

Keywords: Operational research; Forest regulation; Artificial intelligence.

¹Instituto de Ciência Agrárias, Universidade Federal de Minas Gerais, Montes Claros, Minas Gerais, Brasil, paulohenriqueferreira30@hotmail.com, adrianaleandra@gmail.com, christian.cabacinha@gmail.com, carlosaraujo@ufmg.br

²Departamento de Engenharia Florestal, Universidade Federal do Paraná, Curitiba, Paraná, Brasil, lisandraamatos@gmail.com

*Autor para correspondência: carlosaraujo@ufmg.br

Introdução

O planejamento florestal pode ser dividido em planejamento estratégico (longo prazo), tático (médio prazo) e operacional (curto prazo) (Werneburg, 2015), sendo cada um deles responsável pela elaboração de planos de alocação de recursos, principalmente associados às atividades de colheita e plantio, ao longo de um horizonte de planejamento definido.

Neste caso, a elaboração de tais planos, diante do cenário ambiental e econômico atual, exige cada vez mais que os gestores florestais foquem na consistência e efetiva utilização das florestas, fornecendo matéria-prima de forma homogênea ao longo dos períodos de planejamento (Augustynzil, 2014) e garantindo a sustentabilidade do empreendimento.

Entretanto, elaborar um plano de atividades para períodos relativamente longos não é tarefa trivial, sendo necessário utilizar robustos modelos de programação matemática para solucionar um problema de planejamento florestal (Araújo Júnior, 2012). Isso ocorre principalmente pelo fato de que a atividade florestal possui uma quantidade elevada de variáveis (Binoti, 2010) que devem ser consideradas em tais modelos. Dessa maneira, é indicado que os gestores florestais tenham conhecimento de ferramentas de pesquisa operacional que possam contribuir para resolução de tais problemas (Costa et al., 2013).

Utilizando-se de tais ferramentas, é possível realizar a otimização das atividades e regulação das florestas, aumentando as possibilidades de detecção de desvios e fornecendo possibilidades de melhorias no escalonamento das atividades (Castro, 2007). Entretanto, para o caso da definição da sequência de colheita e plantio de áreas florestais, ferramentas da pesquisa operacional clássica, tal como a programação linear inteira, apresentam algumas desvantagens, principalmente relacionadas com a natureza combinatorial do problema de planejamento da produção florestal (Araújo Júnior et al., 2017).

Nesse sentido, as metaheurísticas surgem como uma importante ferramenta para obtenção de respostas viáveis para tal problema, sendo próximas das soluções ótimas e obtidas em um intervalo de tempo consideravelmente menor (Souza, 2004). As mesmas têm sido largamente utilizadas em planejamento florestal com destaque para a *Simulated Annealing* (SA), cujo algoritmo tem como inspiração o processo de resfriamento de sólidos (Gomide et al., 2013).

Apesar disso, o avanço da computação tem proporcionado melhorias nos algoritmos e indicado a necessidade de novas avaliações de suas performances para o mesmo problema. Assim, objetivou-se avaliar como a definição dos parâmetros da metaheurística simulated annealing afetam sua performance na busca por uma solução para o problema de planejamento da produção florestal.

Material e Métodos

O problema de planejamento da produção florestal consistiu em obter um plano de colheita e plantio para uma floresta com área total igual a 4.210 hectares, distribuída em 120 talhões e com idades variando entre 1 e 6 anos. A distribuição de área por classe de idades é irregular, sendo 339, 768, 1031, 601, 958 e 513 hectares para as idades de 1, 2, 3, 4, 5 e 6 anos, respectivamente.

Os custos silviculturais foram obtidos de Araújo Júnior (2012), sendo: R\$ 4.059,05 ha⁻¹ para o primeiro ano; R\$ 1.627,81 ha⁻¹ no segundo ano; R\$ 757,95 ha⁻¹ no terceiro ano; e R\$ 88,20 ha⁻¹ para as idades subsequentes do quarto ano do estabelecimento da floresta. Os valores referentes às receitas advindas da comercialização da madeira foram: R\$ 20,00 m⁻³ para florestas com idade inferior a 3 anos; R\$ 30,00 m⁻³ para florestas com 4 anos de idade; R\$ 40,00 m⁻³ para florestas com 5 anos de idade; e, para idades igual ou superior a 6 anos, R\$ 80,00 m⁻³. Considerou-se ainda, duas restrições: A idade de corte (entre 5 e 7 anos) e a demanda mínima e máxima anual de madeira (140.000 m³ e 160.000 m³, respectivamente).

A problemática proposta visa à obtenção de um cenário de planejamento da produção florestal considerando a maximização do Valor Presente Líquido (VPL). Para tal, o modelo matemático de otimização considerou a estrutura proposta por Johnson e Scheurman (1977):

$$\text{Max VPL} = \sum_{i=1}^M \sum_{j=1}^P \text{VPL}_{ij} \cdot X_{ij} \quad (\text{Eq. 1})$$

Sujeito a

$$\sum_{i=1}^M \sum_{j=1}^P X_{ij} = 1 \quad (\text{Eq. 2})$$

$$\sum_{i=1}^M \sum_{j=1}^P V_{ij} X_{ij} \geq D_{\text{min}_k} \quad (\text{Eq. 3})$$

$$\sum_{i=1}^M \sum_{j=1}^P V_{ij} X_{ij} \leq D_{\text{max}_k} \quad (\text{Eq. 4})$$

$$X_{ij} \in \{0, 1\} \quad (\text{Eq. 5})$$

onde: VPL_{ij} é o VPL da correspondente a unidade de manejo i seguindo o regime de manejo j; X_{ij} é a variável de decisão do tipo binária, recebendo valor 1 quando a alternativa de manejo j é assinalada à unidade de manejo i ou 0, caso contrário; M é o número total de unidades de manejo; P é o número total de alternativas de manejo para a unidade de manejo i; k é o período do horizonte de planejamento; D_{min_k} e D_{max_k} são, respectivamente, a demanda mínima e máxima de madeira (m³) no período k do horizonte de planejamento.

A função de aptidão do SA utilizado levou em consideração o método de penalidades, conforme Gomide *et al.* (2009), Rodrigues *et al.* (2004) e Binoti *et al.* (2014). O valor adotado nesse trabalho foi de R\$ 500,00/m³ por volume excedido ou faltante em relação ao intervalo pré-estabelecido pelas restrições impostas ao modelo. Assim, a equação que representa a função objetivo é dada por:

$$\text{Max VPL} = \sum_{i=1}^M \sum_{j=1}^P \text{VPL}_{ij} \cdot X_{ij} - P \cdot \sum_{k=1}^T d_k \quad (\text{Eq. 6})$$

em que: P é a penalidade em R\$/m³ de madeira; T é o tempo total do planejamento; e d_k é o valor absoluto do desvio volumétrico de madeira em m³ em um período k do horizonte de planejamento.

Durante os testes, foram avaliados diferentes valores para três parâmetros da metaheurística: temperatura inicial (Ti), considerando os valores iguais a 10⁸, 10⁶ e 10⁴; taxa de redução da temperatura (α), sendo 0,01, 0,05 e 0,10; e número de vizinhos avaliados em cada iteração (V), sendo avaliadas quantidades iguais a 1, 10 e 30. O número de gerações foi igual a 1000 para todas as combinações possíveis entre os parâmetros, sendo esse o critério de parada para o algoritmo. Dessa maneira, foram avaliados um total de 27 combinações de parâmetros da metaheurística *Simulated Annealing*, sendo consideradas 30 repetições para cada uma delas.

Para a realização do processamento das configurações propostas, utilizou-se o aplicativo *Metaheuristics for Forest Planning* (MeP), desenvolvido pelo Laboratório de Pesquisa Operacional e Modelagem Florestal (LPM), na Universidade Federal de Minas Gerais.

Após o processamento no aplicativo, com a obtenção dos dados de *fitness* e tempo de processamento para cada combinação, analisou-se os mesmos através dos valores máximo, médio e mínimo de cada repetição. A análise estatística aplicada considerou o teste não paramétrico proposto por Kruskal e Wallis (1952).

Para comparação da eficiência dos resultados gerados pela metaheurística SA foi realizada a comparação com valores obtidos através da programação inteira. Para esse caso, considerou-se o algoritmo de *branch-and-bound* (B&B) executado no *software* Lingo. A eficiência relativa foi calculada segundo a fórmula:

$$Ef = \frac{f_{AG}}{f_0} \cdot 100 \quad (\text{Eq. 7})$$

onde f_{AG} é o valor máximo de cada solução obtida pelo *simulated annealing* (R\$) e f_0 é o valor máximo para cada solução gerada pelo algoritmo de *branch and bound* (R\$).

Resultados e Discussão

A solução do problema considerando o algoritmo de B&B apresentou um valor igual a R\$ 31.964.100 para a função objetivo. Tal valor foi encontrado considerando 1 hora de processamento, sem que o algoritmo convergisse para o ótimo global do problema. A eficácia das combinações testadas variou entre 94,97 % e 97,16 % (Tabela 1), que são os valores referentes à pior e à melhor combinação, respectivamente. Os valores obtidos foram relativamente próximos, não havendo grande diferença entre as piores e melhores soluções encontradas.

De acordo com Rodrigues *et al.* (2004), a metaheurística SA é uma das ferramentas que menos são afetadas pelas alterações nos seus parâmetros, em contraponto a outras metaheurísticas, tais como o Algoritmo Genético (AG). Para este caso, quando submetida a diferentes configurações de parâmetros, o AG pode levar a uma variação muito grande nas soluções obtidas, reduzindo assim a eficácia de cada solução (Gomide *et al.*, 2009), o que também foi comprovado por Matos (2017).

Analisando os resultados obtidos, é possível observar que a alteração nos parâmetros testados (temperatura inicial, alfa e número de vizinhos) não afetam fortemente a eficácia da solução, o que poderia indicar uma interação fraca entre os parâmetros utilizados para configurar o algoritmo. Entretanto, ao aplicar o teste estatístico de Kruskal Wallis, observou-se que os valores das soluções encontradas pelas distintas combinações apresentaram diferenças estatisticamente significativas ao nível de significância igual a 5% (Tabela 2). As combinações 12, 03, 06, 15, 09, 24, 27, 18 e 21 são, portanto, estatisticamente melhores que as demais combinações testadas.

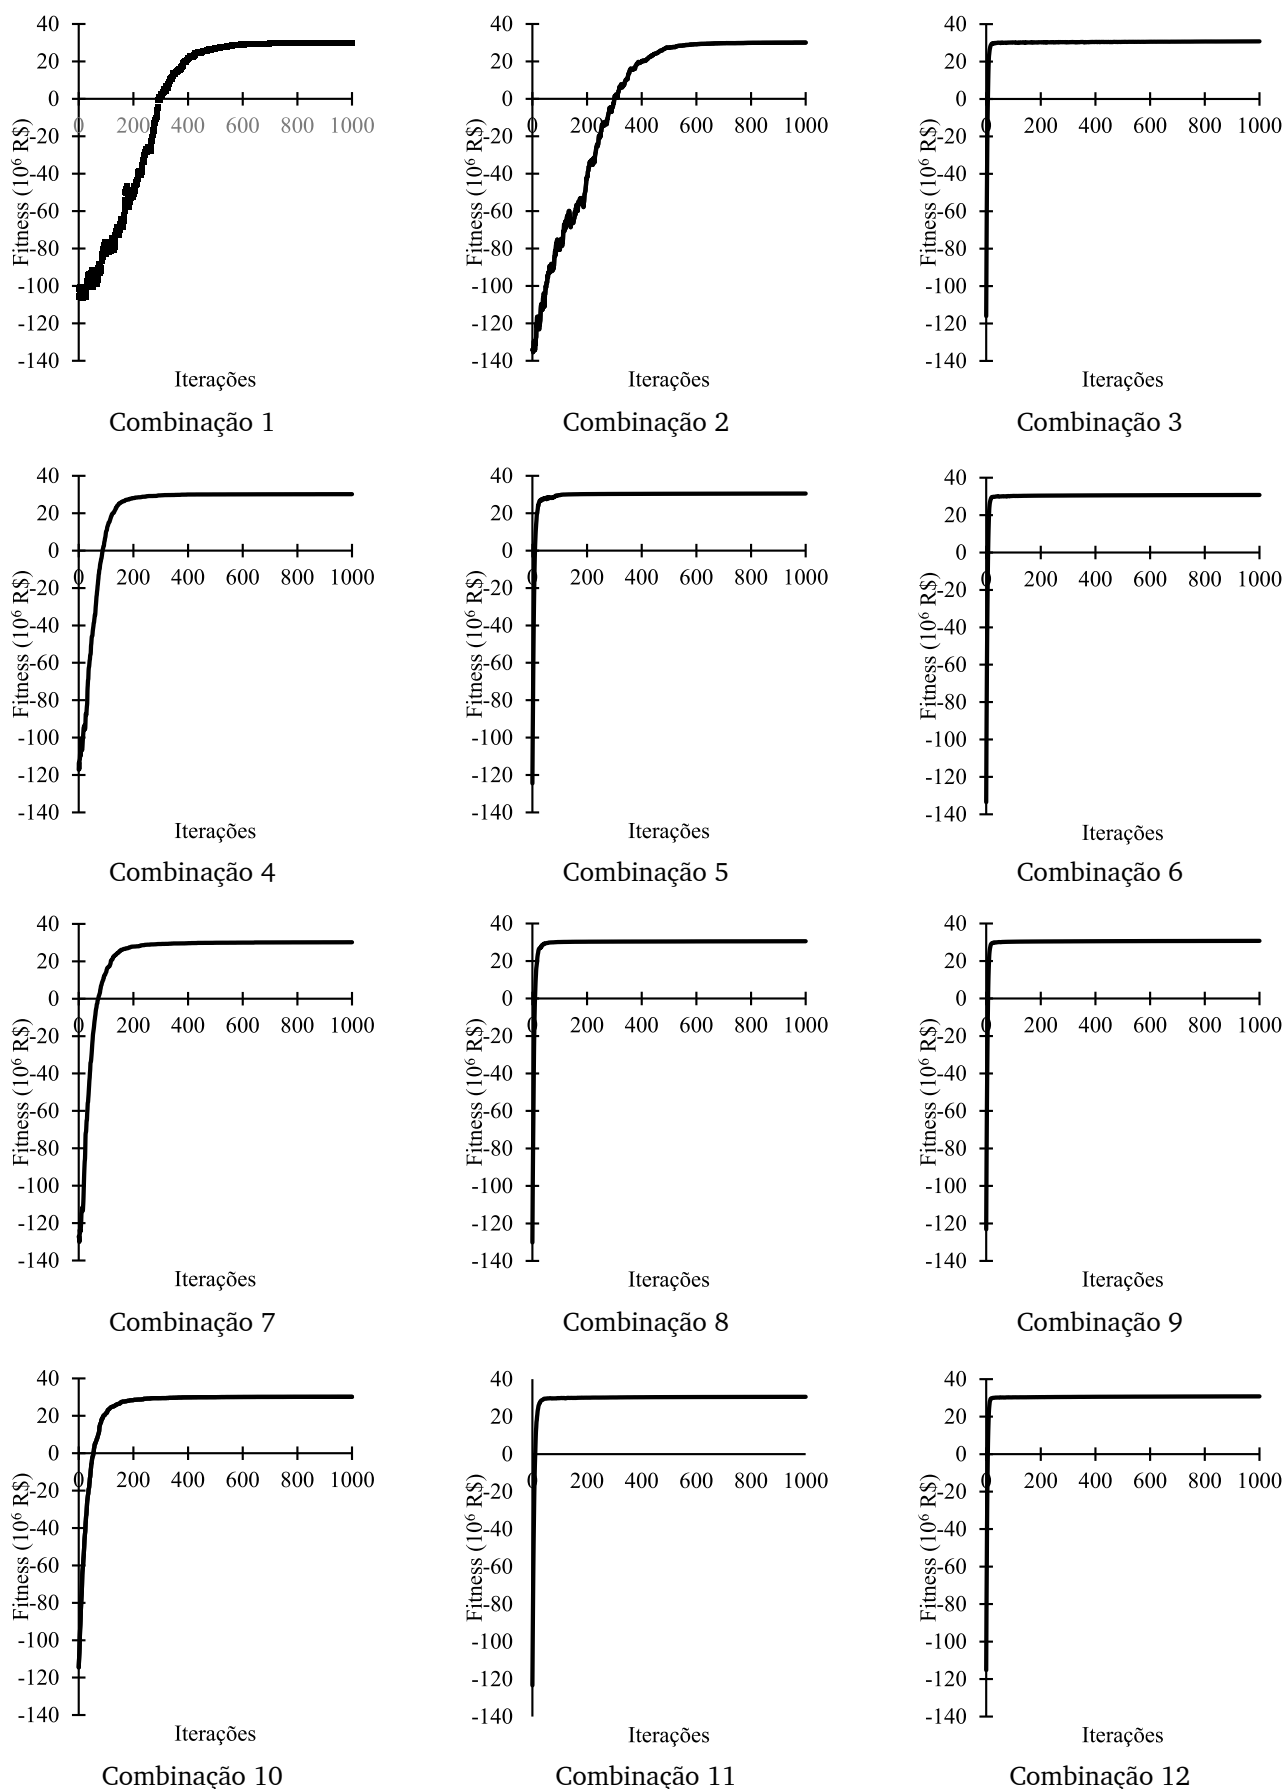
Assim, é possível afirmar que a performance do algoritmo está atrelada ao problema em questão, sendo necessário realizar testes prévios para identificar a configuração ideal para a metaheurística *simulated annealing*. De fato, ao analisar os gráficos de evolução média do *fitness* a cada iteração para cada uma das combinações (Figura 1), é possível perceber que há uma distinção entre os comportamentos. Uma maior quantidade de soluções vizinhas avaliadas permite uma melhor exploração do espaço de soluções e conseqüentemente uma convergência mais rápida para uma região mais promissora (Combinações 12 e 03, por exemplo). Já a utilização de menores taxas de decaimento da temperatura favorece a possibilidade de se adotar uma solução inferior durante uma maior quantidade de iterações, o que pode fazer com que o algoritmo explore regiões menos promissoras do espaço de busca (Combinações 1 e 2, por exemplo).


Tabela 1 – Valores máximo, médio, mínimo, desvio padrão e eficácia considerando as soluções obtidas para cada combinação dos parâmetros da metaheurística *simulated annealing*

Combinação	Ti	Alfa	V	Máximo (R\$)	Médio (R\$)	Mínimo (R\$)	Desvio (R\$)	Eficácia (%)
01	10 ⁸	0,01	01	30.357.792	-516.738	-240.578.479	204.214	94,97
02	10 ⁸	0,01	10	30.419.090	-207.413	-311.394.809	140.816	95,17
03	10 ⁸	0,01	30	30.968.572	29.824.148	-257.488.299	100.103	96,89
04	10 ⁸	0,05	01	30.510.939	21.241.216	-228.327.621	156.025	95,45
05	10 ⁸	0,05	10	30.858.629	29.194.999	-211.583.248	112.264	96,54
06	10 ⁸	0,05	30	30.963.372	29.778.606	-211.646.319	130.172	96,87
07	10 ⁸	0,10	01	30.461.889	22.229.476	-254.866.216	134.140	95,30
08	10 ⁸	0,10	10	30.720.313	29.297.947	-243.469.068	125.923	96,11
09	10 ⁸	0,10	30	30.986.644	29.812.001	-238.281.796	119.936	96,94
10	10 ⁶	0,01	01	30.497.972	24.825.762	-221.499.899	140.356	95,41
11	10 ⁶	0,01	10	30.857.137	29.268.776	-191.309.836	125.055	96,54
12	10 ⁶	0,01	30	31.054.933	29.969.871	-219.372.563	133.753	97,16
13	10 ⁶	0,05	01	30.608.481	24.774.565	-217.773.041	229.736	95,76
14	10 ⁶	0,05	10	30.727.503	29.387.716	-289.931.311	115.002	96,13
15	10 ⁶	0,05	30	30.973.894	29.845.790	-244.874.024	133.454	96,90
16	10 ⁶	0,10	01	30.462.257	24.424.590	-273.569.523	168.963	95,30
17	10 ⁶	0,10	10	30.745.267	29.335.056	-268.056.831	129.808	96,19
18	10 ⁶	0,10	30	30.881.065	29.935.543	-231.865.279	113.955	96,61
19	10 ⁴	0,01	01	30.423.316	24.429.942	-268.996.434	122.237	95,18
20	10 ⁴	0,01	10	30.707.033	29.270.964	-232.290.048	122.192	96,07
21	10 ⁴	0,01	30	30.998.189	29.830.974	-264.938.125	139.487	96,98
22	10 ⁴	0,05	01	30.604.896	25.137.861	-188.180.226	168.664	95,75
23	10 ⁴	0,05	10	30.814.701	29.345.938	-205.033.487	144.325	96,40
24	10 ⁴	0,05	30	30.946.159	29.859.432	-190.757.148	122.959	96,82
25	10 ⁴	0,10	01	30.448.619	25.156.450	-215.115.302	134.802	95,26
26	10 ⁴	0,10	10	30.828.926	29.438.710	-207.451.105	115.046	96,45
27	10 ⁴	0,10	30	30.946.986	29.887.703	-223.308.393	104.298	96,82


Tabela 2 – Análise estatística não paramétrica pelo teste de *Kruskal Wallis* aplicado nas variáveis *fitness* para as 27 combinações dos parâmetros

Combinação	Ti	Alfa	V	Fitness médio (R\$)	
12	10 ⁶	0,01	30	30.824.537	a
03	10 ⁸	0,01	30	30.792.467	a
06	10 ⁶	0,05	30	30.776.546	a
15	10 ⁸	0,05	30	30.783.289	a
09	10 ⁸	0,1	30	30.738.570	a
24	10 ⁴	0,05	30	30.690.900	a
27	10 ⁴	0,1	30	30.707.841	a
18	10 ⁶	0,1	30	30.729.919	a
21	10 ⁴	0,01	30	30.695.171	a
11	10 ⁶	0,01	10	30.558.387	b
08	10 ⁸	0,1	10	30.570.767	b
26	10 ⁴	0,1	10	30.529.513	b
05	10 ⁸	0,05	10	30.503.104	b
20	10 ⁴	0,01	10	30.533.609	b
23	10 ⁴	0,05	10	30.486.879	b
17	10 ⁶	0,1	10	30.485.708	b
16	10 ⁶	0,1	1	30.227.501	c
22	10 ⁴	0,05	1	30.169.552	c
04	10 ⁸	0,05	1	30.150.216	c
07	10 ⁸	0,1	1	30.191.117	c
13	10 ⁶	0,05	1	30.159.634	cd
19	10 ⁴	0,01	1	30.173.907	cd
10	10 ⁶	0,01	1	30.144.277	cd
25	10 ⁴	0,1	1	30.150.622	cd
02	10 ⁸	0,01	10	30.072.661	cd
01	10 ⁸	0,01	1	30.044.153	d


Figura 1 – Estrutura da evolução das buscas pelos valores médios de *fitness* obtidos pelo SA nas 27 combinações testadas ao longo de 1000 gerações




Combinação 13




Combinação 14




Combinação 15




Combinação 16




Combinação 17



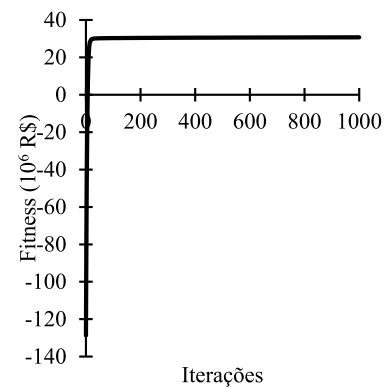
Combinação 18




Combinação 19




Combinação 20




Combinação 21



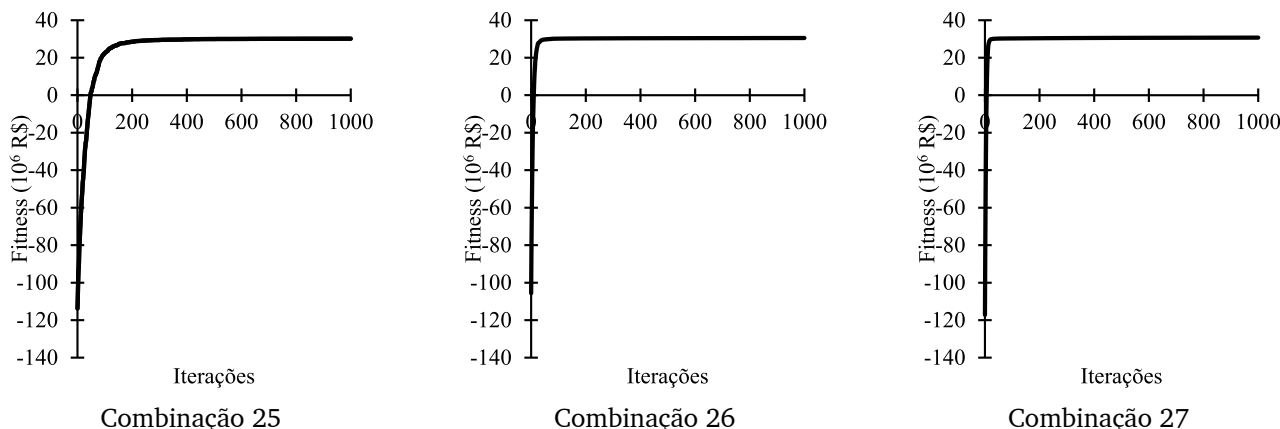
Combinação 22



Combinação 23




Combinação 24



Apesar das diferenças estatisticamente significativas apresentadas, tanto a pior combinação quanto a melhor combinação apresentam soluções viáveis para

o problema analisado (Figura 2). Para todos os casos a restrição de demanda volumétrica anual foi atendida.

Figura 2 – Volumes obtidos para uma repetição da combinação 12 (a) e uma repetição da combinação 1 (b) distribuídos ao longo dos 16 anos do horizonte de planejamento



Conclusão

A definição da combinação ideal de parâmetros da metaheurística *simulated annealing* é importante para obtenção de soluções próximas da *otimalidade* em um problema de planejamento da produção florestal.

A obtenção de soluções viáveis para o problema analisado não foi dependente da combinação de parâmetros da metaheurística considerada.

Agradecimentos

Os autores agradecem à Universidade Federal de Minas Gerais pelo apoio técnico.

Referências

Araújo Júnior, C. A. Simulação multiagentes aplicada ao planejamento da produção florestal sustentável. 2012. 75 f. Dissertação (Mestrado em Ciências Florestais). Universidade Federal de Viçosa, Viçosa – MG. Disponível em: <https://goo.gl/nAW7HF>.

Augustynzik, A. L. D. Planejamento florestal otimizado considerando áreas mínimas e máximas operacionais de colheita. 2014. 185 f., Dissertação (Mestrado em ciências florestais). Universidade Federal do Paraná, Curitiba, 2014. Disponível em: <https://goo.gl/v8PDhG>.

Araújo Júnior, C. A.; Leite, H. G.; Soares, C. P. B.; Binoti, D. H. B.; Souza, A. P.; Santana, A. F.; Torres, C. M. M. E. 2017. A multi-agent system for forest transport activity planning. *Cerne* 23: 329-337. Doi: <http://dx.doi.org/10.1590/01047760201723032335>.

Binoti, D. H. B., Binoti, M. L. M., Leite, H. G., Gleriani, J. M., Ribeiro, C. A. A. S., 2014. Inclusão e influência de características espaciais em modelos de regulação florestal. *Cerne* 20:1 57-164. Doi: <http://dx.doi.org/10.1590/S0104-77602014000100019>.

- Binoti, D. H. B. Estratégias de regulação de florestas equiâneas com vistas ao manejo da paisagem. 2010. 145 f. Dissertação (Mestrado em Ciências Florestais). Universidade Federal de Viçosa, Viçosa – MG. Disponível em: <https://goo.gl/WesmJ6>.
- Castro, R. R. Regulação de florestas equiâneas incluindo restrições de adjacência. 2007. 64 f. Dissertação (Mestrado em Ciências Florestais). Universidade Federal de Viçosa, Viçosa – MG. Disponível em: <https://goo.gl/PUE2jQ>.
- Gomide, L. R, Arce, J. E, Silva, A. C. L, 2009. Uso do algoritmo genético no planejamento florestal considerando seus operadores de seleção. *Cerne* 15: 460-467
- Gomide, L. R, Arce, J. E, Silva, A. C. L, 2013. Comparação entre a meta-heurística simulated annealing e a programação linear inteira no agendamento da colheita florestal com restrições de adjacência. *Ciência Florestal* 23: 449-460. Doi: <http://dx.doi.org/10.5902/198050989289>.
- Johnson, K. N.; Scheurman, H. L. 1977. Techniques for prescribing optimal timber harvest and investment under different objectives: discussion and synthesis. *Forest Science* 23. <https://doi.org/10.1093/forestscience/23.s1.a0001>
- Kruskal, W. H, Wallis, W. A, 1950. Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association* 47: 583-621. Disponível em: <https://goo.gl/D1xx2G>.
- Matos, L. M. A. Utilização da metaheurística algoritmo genético em um modelo de regulação da produção florestal. 2017. 47 f. Trabalho de conclusão de curso (Graduação em Engenharia Florestal). Universidade Federal de Minas Gerais. Montes Claros, MG. 2017.
- Rodrigues, F. L, Leite, H. G, Santos, H. N, Souza, A. L, Silva, G. F, 2004. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. *Revista Árvore* 28: 233-245. Doi: <http://dx.doi.org/10.1590/S0100-67622004000200010>.
- Souza, D. O. Algoritmos genéticos aplicados ao planejamento do transporte principal de madeira. 2004. 184 f. Dissertação (Mestrado em ciências florestais). Universidade Federal do Paraná. Curitiba. 2004. Disponível em: <https://goo.gl/6ho2i1>.
- Werneburg, M. A. P. Planejamento em grandes empresas florestais no Brasil. 2015. 95 f. Dissertação (Mestrado em ciências florestais). Universidade Federal do Vale do Jequitinhonha e Mucuri, Diamantina, 2015. Disponível em: <https://goo.gl/D2GjAt>.