




Universidade Estadual de Montes Claros

PRÓ-REITORIA DE PÓS-GRADUAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM

COMPUTACIONAL E SISTEMAS



Isabella Alkmim Barral

PROPOSTA DE HEURÍSTICA PARA A GERAÇÃO DE SOLUÇÕES VÁLIDAS PARA UM PROBLEMA DE PLANEJAMENTO DA PRODUÇÃO FLORESTAL

Montes Claros - MG

Agosto de 2022

Isabella Alkmim Barral

PROPOSTA DE HEURÍSTICA PARA A GERAÇÃO DE SOLUÇÕES VÁLIDAS PARA UM PROBLEMA DE PLANEJAMENTO DA PRODUÇÃO FLORESTAL

Dissertação apresentada ao Mestrado Profissional em Modelagem Computacional e Sistemas, da Universidade Estadual de Montes Claros, como exigência para obtenção do grau de Mestre em Modelagem Computacional e Sistemas.

Orientadora: Prof. Dr^a. Luciana Balieiro
Cosme

Coorientador: Prof. Dr. Allysson Steve Mota
Lacerda

Montes Claros - MG

Agosto de 2022



UNIVERSIDADE ESTADUAL DE MONTES CLAROS
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL E SISTEMAS

FOLHA DE APROVAÇÃO

PROPOSTA DE HEURÍSTICA PARA A GERAÇÃO DE SOLUÇÕES VÁLIDAS PARA UM PROBLEMA DE
PLANEJAMENTO DA PRODUÇÃO FLORESTAL

Isabella Alkmim Barral

Trabalho de conclusão defendido e aprovado pela banca examinadora constituída por:

PROF. Luciana Balieiro Cosme – Orientadora
IFNMG *Campus* Montes Claros

PROF. Allysson Steve Mota Lacerda – Coorientador
Departamento de Ciências da Computação – UNIMONTES

PROF. Carlos Alberto Araújo Júnior
Instituto de Ciências Agrárias – UFMG

PROF. João Batista Mendes
Departamento de Ciências da Computação – UNIMONTES

Montes Claros, 05 de Agosto de 2022

Resumo

O presente trabalho propõe o desenvolvimento de uma heurística para a geração de soluções válidas para um problema de planejamento da produção florestal. O desempenho da heurística proposta e das meta-heurísticas Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS) foram avaliados e comparados em 3 cenários, o original, apresentado pela literatura, e 2 cenários fictícios, mais restritivos. Além disso, foi realizada a comparação do desempenho do AG e CLONALG na resolução do primeiro cenário utilizando diferentes quantidades de soluções geradas pela heurística proposta (0, 1, 5, 10 e 15) no conjunto de soluções iniciais. Para o VNS foi testada a substituição da solução inicial aleatória pela gerada por meio da heurística e também realizada a comparação. Os resultados obtidos mostraram que para o cenário original (D_{min} igual a 140.000 m³ e D_{max} 160.000 m³) a heurística proposta foi capaz de gerar soluções válidas em todas as execuções utilizando, para isso, em média 82 cálculos de função objetivo. Em contrapartida, todas as meta-heurísticas estudadas tiveram pelo menos uma execução que retornou soluções inválidas. No segundo cenário (D_{min} igual a 140.000 m³ e D_{max} 150.000 m³) a heurística proposta obteve soluções válidas em 99,9% das execuções, demandando em média 1006 cálculos de função objetivo, enquanto as meta-heurísticas, no melhor dos casos (AG), encontram soluções válidas em 20% das execuções. Por fim, no terceiro cenário (D_{min} igual a 150.000 m³ e D_{max} 160.000 m³) a heurística proposta e as meta-heurísticas estudadas não obtiveram soluções válidas em nenhuma execução. Em relação a avaliação do impacto da inclusão de soluções válidas no conjunto de soluções iniciais das meta-heurísticas, os resultados apontam que a inserção de um único indivíduo válido não gerou uma diferença significativa no Valor Presente Líquido (VPL). Entretanto, ao avaliar a inserção de 5, 10 e 15 indivíduos foi identificada uma melhora significativa no resultado. Diante disso, conclui-se que a heurística desenvolvida pode ser uma alternativa viável para a tomada de decisão rápida no planejamento da produção florestal, assim como para melhorar o desempenho de meta-heurísticas como o AG e CLONALG.

Palavras-chave: planejamento florestal. heurística. solução válida. meta-heurísticas.

Abstract

This work proposes the development of a heuristic for the generation of feasible solutions to a forest production planning problem. The proposed heuristic, Genetic Algorithm (GA), Algorithm of Clonal Selection (CLONALG), and Variable Neighborhood Search (VNS) performance were evaluated and compared in 3 scenarios: the original, presented by the literature, and two more restrictive scenarios. In addition, AG and CLONALG were compared in the first scenario using different amounts of solutions generated by the proposed heuristic (0, 1, 5, 10, and 15) in the set of initial solutions. Also, replacing the VNS initial random solution with the one generated through the heuristic was tested. The results obtained showed that for the original scenario ($Dmin = 140,000 \text{ m}^3$ and $Dmax = 160,000 \text{ m}^3$), the proposed heuristic generated feasible solutions in all executions using, on average, 82 objective function calculations. In contrast, all metaheuristics studied had at least one execution that returned infeasible solutions. In the second scenario ($Dmin = 140,000 \text{ m}^3$ and $Dmax = 150,000 \text{ m}^3$), the proposed heuristic obtained valid solutions in 99.9% of the executions, demanding on average 1006 objective function calculations, while the AG found valid solutions in 20% of the executions. Finally, in the third scenario ($Dmin = 150,000 \text{ m}^3$ and $Dmax = 160,000 \text{ m}^3$), The proposed heuristic and the meta-heuristics studied did not obtain feasible solutions. Regarding evaluating the impact of including feasible solutions in the meta-heuristics initial solutions, the results indicate that the insertion of a single valid individual did not generate a significant difference in the VPL. However, the insertion of 5, 10, and 15 individuals identified a substantial improvement. Therefore, it is concluded that the developed heuristic can be a viable alternative for rapid decision-making in forest production planning and for improving the performance of meta-heuristics such as AG and CLONALG.

Keywords: forest management. heuristic. valid solutions. meta-heuristics.

Lista de ilustrações

Figura 1 – Representação de uma floresta dividida em 14 unidades de manejo ou talhões.	12
Figura 2 – Representação da base de dados. As colunas contém o número do talhão, a idade do povoamento florestal, a prescrição aplicada, a produção em cada ano do horizonte de planejamento e o VPL.	20
Figura 3 – Representação do cálculo da produção, em que (a) representa uma solução, (b) a base de dados, (c) o histórico de produção e (d) a produção total.	22
Figura 4 – Representação do histórico de produção e seleção dos talhões passíveis de modificação.	25
Figura 5 – Reorganização da base de dados. As prescrições armazenadas nas colunas 3 a 56, se atribuídas ao talhão da coluna 1, irão gerar colheita no ano da coluna 2.	26
Figura 6 – Mutação do tipo <i>swap</i> em que são trocadas as prescrições de dois talhões aleatórios. A primeira e a segunda imagem representam a solução antes e depois da mutação, respectivamente.	28
Figura 7 – A Figura (a) ilustra a produção nos 16 anos do horizonte de planejamento de uma solução gerada aleatoriamente. Já as Figuras (b), (c) e (d) foram geradas pela heurística proposta no primeiro, segundo e terceiros cenários, respectivamente. As linhas vermelhas representam a demanda máxima e mínima de cada cenário.	32
Figura 8 – Ilustração da convergência das meta-heurísticas estudadas utilizando diferentes quantidades de <i>qSoluções</i> . Para cada quantidade de <i>qSoluções</i> foi realizada uma execução.	35

Lista de tabelas

Tabela 1	– Avaliação da heurística proposta nos 3 cenários em relação à quantidade de cálculos de função objetivo e o número total de soluções válidas obtidas	31
Tabela 2	– Resultados das 3 meta-heurísticas em cada cenário estudado utilizando qSoluções igual a 0, contendo o método avaliado, o Valor Presente Líquido médio, mínimo e máximo, o desvio padrão e a verificação da existência de soluções válidas no final da execução das 30 execuções.	33
Tabela 3	– Valor Presente Líquido (VPL) médio e desvio padrão do Algoritmo Genético (AG), Busca em Vizinhança Variável (VNS) e Algoritmo de Seleção Clonal (CLONALG) no primeiro cenário estudado utilizando 0, 1, 5, 10 e 15 qSoluções no conjunto de soluções iniciais	34
Tabela 4	– Avaliação de parâmetros do Algoritmo Genético.	44
Tabela 5	– Avaliação de parâmetros do Algoritmo de Seleção Clonal. Em que TS é a taxa de seleção, TC a de clonagem, TH a de hipermutação e TM a de metadinâmica.	45
Tabela 6	– Avaliação de parâmetros do Busca em Vizinhança Variável. A estrutura de vizinhança 1 é 1, 2, 3 e 4% e a 2 é 1, 5, 10 e 15%	45
Tabela 7	– Resultados do teste de Shapiro-Wilk aplicado aos resultados das meta-heurísticas Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS) com diferentes quantidade de <i>qSoluções</i> .	46
Tabela 8	– Resultados do teste de Levene aplicado aos resultados das meta-heurísticas Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS).	47
Tabela 9	– Resultados do teste Kruskal-Wallis aplicado ao Algoritmo Genético (AG) e ANOVA ao Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS).	47
Tabela 10	– Resultados do teste Dunn aplicado ao Algoritmo Genético (AG) e Tukey ao Algoritmo de Seleção Clonal (CLONALG).	47

Lista de abreviaturas e siglas

AG	Algoritmo Genético
CLONALG	Algoritmo de Seleção Clonal (<i>Clonal Selection Algorithm</i>)
PL	Programação Linear
PLI	Programação Linear Inteira
PPGMCS	Programa de Pós-graduação em Modelagem Computacional e Sistemas
SA	Recozimento Simulado (<i>Simulated Annealing</i>)
VNS	Busca em Vizinhança Variável (<i>Variable Neighborhood Search</i>)
VPL	Valor Presente Líquido

Sumário

1	INTRODUÇÃO	10
1.1	Objetivos	11
1.2	Estrutura da dissertação	11
2	REVISÃO BIBLIOGRÁFICA	12
2.1	Planejamento da produção florestal	12
2.2	Heurísticas e meta-heurísticas	13
2.3	Trabalhos relacionados	16
3	MATERIAIS E MÉTODOS	19
3.1	Definição do problema	19
3.2	Abordagem proposta	22
3.2.1	Descrição da heurística proposta	22
3.2.2	Descrição das meta-heurísticas	27
3.3	Métodos de avaliação	29
4	RESULTADOS E DISCUSSÃO	31
4.1	Avaliação do desempenho da heurística e meta-heurísticas nos cenários estudados	31
4.2	Avaliação da viabilidade de aplicação da heurística proposta para a geração de soluções iniciais	34
5	CONCLUSÃO	36
	REFERÊNCIAS	37
	ANEXOS	42
	ANEXO A – AVALIAÇÃO DE PARÂMETROS	43
	ANEXO B – ANÁLISE ESTATÍSTICA DOS RESULTADOS DAS META-HEURÍSTICAS	46

1 Introdução

O setor florestal brasileiro, mais especificamente o de florestas plantadas, desempenha um papel fundamental no cenário socioeconômico do país, contribuindo com a geração de empregos, tributos, divisas e renda (JUNIOR et al., 2012). Em 2020, por exemplo, as empresas do segmento foram responsáveis pela criação de mais de 536 mil empregos diretos e 1,5 milhão de postos de trabalho indiretos, além disso, geraram R\$ 12,1 bilhões em tributos federais, o que equivale a 0,9% da arrecadação total do país (IBÁ, 2021).

Em razão de suas características edafoclimáticas (solo e clima) e do desenvolvimento tecnológico obtido na área da silvicultura, o Brasil apresenta grande competitividade no mercado de produtos florestais (JUVENAL; MATTOS, 2002). Entretanto, as pressões de mercado cada vez mais globalizados exigem que as empresas se tornem cada vez mais competitivas, devendo fornecer produtos de alta qualidade aos menores custos possíveis (SILVA, 2001b).

No setor florestal, uma das etapas consideradas mais dispendiosas é a colheita da madeira, representando em conjunto com o transporte mais de 40% dos custos de produção (MACHADO; LOPES, 2000; JASKIU, 2015; CHICHORRO et al., 2017). Devido ao grande impacto da colheita na viabilidade econômica dos empreendimentos florestais é imprescindível a realização de um planejamento eficiente dessa atividade, uma vez que, este permite a redução dos custos, elevação da produtividade, regulação do fluxo de madeira e a otimização do uso de máquinas e equipamentos (FIDELIS; REIS, 2019).

De modo geral, o planejamento da colheita consiste em determinar quais talhões devem ser colhidos em cada período de tempo com objetivo de atender a demanda de madeira, maximizando as receitas (e/ou minimizando os custos) e satisfazendo as demais restrições impostas (WERNEBURG, 2015). Contudo, este pode se tornar um problema complexo dependendo do número de talhões, devido ao aumento exponencial do número de variáveis (GOMIDE; ARCE; SILVA, 2009).

Na resolução deste tipo de problema, as abordagens tradicionais, como o uso de programação linear (PL) e programação linear inteira (PLI), têm oferecido bons resultados para o tratamento de problemas de pequena dimensão (NOBRE, 1999). Entretanto, para problemas de grande porte, o tempo computacional gasto muitas vezes torna a utilização desses métodos tecnicamente inviável (GOMIDE; ARCE; SILVA, 2009). Nessas situações, as heurísticas e meta-heurísticas tornam-se alternativas interessantes, possibilitando a obtenção de respostas satisfatórias com um tempo de processamento razoável.

As heurísticas e meta-heurísticas são técnicas de otimização que não oferecem nenhuma garantia acerca da qualidade da solução obtida, mas são capazes de encontrar

boas soluções com tempo adequado para as necessidades da aplicação (CHAVES, 2009). Na solução de problemas de planejamento florestal diversas meta-heurísticas vêm sendo empregadas, como o Algoritmo Genético, Algoritmo de Seleção Clonal e Busca em Vizinhança Variável (ARAÚJO et al., 2018a; ARAÚJO et al., 2018b; MATOS et al., 2019). Todavia, fatores como a configuração inadequada de parâmetros e o uso de soluções iniciais de baixa qualidade podem fazer com que as meta-heurísticas encerrem a execução antes de alcançarem soluções aceitáveis (MELO, 2009).

Nesse contexto, o desenvolvimento de uma heurística para a geração de soluções válidas pode contribuir com a tomada de decisão rápida no planejamento florestal, fornecendo resultados com menor dependência de ajuste de parâmetros. Além disso, os resultados obtidos pela heurística podem ser utilizados por outros métodos de otimização, visando melhorar o desempenho desses algoritmos.

1.1 Objetivos

O presente trabalho tem como objetivo geral o desenvolvimento de uma heurística para a geração de soluções válidas para um problema de planejamento da produção florestal.

Os objetivos específicos do trabalho foram:

- Avaliação do desempenho da heurística proposta em 3 cenários do problema de planejamento florestal.
- Implementação das meta-heurísticas Algoritmo Genético, Algoritmo de Seleção Clonal e Busca em Vizinhança Variável e avaliação do desempenho desses métodos na resolução dos 3 cenários do problema de planejamento florestal.
- Avaliação do impacto da inserção de diferentes quantidades de indivíduos gerados pela heurística proposta no conjunto de soluções iniciais do Algoritmo Genético, Algoritmo de Seleção Clonal e Busca em Vizinhança Variável.

1.2 Estrutura da dissertação


O trabalho está organizado da seguinte maneira: O Capítulo 2 apresenta uma breve revisão bibliográfica acerca do planejamento da produção florestal, heurísticas e meta-heurísticas e os trabalhos relacionados. O Capítulo 3 contém os materiais e métodos onde é realizada a definição do problema, a descrição da abordagem proposta e a apresentação dos métodos utilizados para a avaliação, respectivamente. No Capítulo 4 encontram-se os resultados e discussão e, por fim, a conclusão no Capítulo 5.

2 Revisão bibliográfica

2.1 Planejamento da produção florestal

A produção florestal, devido a origem biológica do produto e sua rotação de longa duração, envolve um grau significativo de incerteza (ARCE, 1997; NETO, 2016). Em decorrência disso, os empreendimentos florestais, de modo geral, exigem um planejamento eficiente e detalhado das operações a serem realizadas (FIORENTIN, 2016). Pois, o planejamento sistemático tende a reduzir a incerteza envolvida no processo decisório, consequentemente, provocando um aumento da probabilidade de que a empresa alcance os objetivos estabelecidos (OLIVEIRA, 2007).

Neste planejamento normalmente a floresta é dividida em unidades de manejo ou talhões (Figura 1) caracterizadas pela uniformidade em termos de produtividade e pela homogeneidade da idade e material genético (SANTOS, 2007). Os cursos alternativos de ação a serem realizados nessas unidades referem-se às alternativas de manejo ou prescrições, que consistem na sequência de decisões (como épocas de cortes, plantios e intensidades de desbaste) que ocorrem ao longo de um determinado período de tempo, denominado horizonte de planejamento (RODRIGUES, 2001).



Fonte: Adaptado de Junior et al. (2012)

Figura 1 – Representação de uma floresta dividida em 14 unidades de manejo ou talhões.

De acordo com Rodrigues (2001), o horizonte de planejamento é subdividido em períodos, geralmente anos, e as ações são realizadas nos inícios dos mesmos. Essas ações, quando combinadas, podem gerar uma infinidade de alternativas de manejo. Devendo a

escolha da melhor alternativa para cada talhão ser realizada de forma que sejam atendidos os objetivos de produção e as limitações operacionais do sistema florestal (NOBRE, 1999).

O planejamento geralmente é realizado de forma a obter o máximo retorno econômico dos povoamentos florestais (JASKIU, 2015). Nesse sentido, faz-se necessário a utilização de critérios econômicos para decidir qual a melhor alternativa a ser adotada (BERGER et al., 2011). Um dos métodos mais utilizados para a análise financeira de investimentos é o Valor Presente Líquido (VPL), estimado a partir dos custos e receitas futuras, descontados a uma taxa mínima de atratividade definida previamente (RODRIGUES, 2016). Nesse contexto, a escolha da melhor prescrição em cada unidade de manejo baseia-se na maximização do VPL total e no atendimento das condições e limitações de produção impostas ao projeto (NOBRE, 1999).

A colheita florestal é a etapa que mais requer atenção no planejamento, pois é nela que são refletidos todos os investimentos de manejo na forma de produto final (PEREIRA, 2016). Normalmente, as empresas devem atender a uma demanda pré-estabelecida de madeira e, para isso, possuem povoamentos com várias idades e tamanhos, localizados em locais com diferentes capacidades produtivas (SILVA, 2001b). Nesse sentido, é necessário elaborar um plano definindo quais talhões devem ser colhidos em cada período do horizonte de planejamento para atender a demanda, maximizar as receitas e/ou minimizar os custos, e satisfazer as demais restrições impostas (WERNEBURG, 2015). Entretanto, quando existem muitos talhões, alternativas de manejo e restrições associadas, a definição de um plano ótimo ou quase ótimo pode ser muito trabalhoso (VOLPI, 1997). Nessas situações, uma alternativa é a utilização de heurísticas e meta-heurísticas (GOMIDE; ARCE; SILVA, 2009).

2.2 Heurísticas e meta-heurísticas

De acordo com Hillier e Lieberman (2013), um método heurístico é um procedimento que provavelmente encontrará uma boa solução para um problema em questão, mas não necessariamente a solução ótima. Estes geralmente são baseados em ideias simples que são cuidadosamente adaptadas para atender a um problema específico. Já as meta-heurísticas podem ser vistas como estruturas algorítmicas gerais que podem ser utilizadas para a resolução de diferentes problemas de otimização, com um número relativamente pequeno de modificações que a adaptem para o tratamento de cada problema específico (ZAPELINI; LEJBMAN, 2009).

Diversas meta-heurísticas vêm sendo empregadas na resolução de problemas de planejamento florestal, entre elas encontram-se o Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e o Busca em Vizinhança Variável (VNS). O Algoritmo Genético, apresentado no Algoritmo 1, método idealizado por Holland (1975) e popularizado

por [Goldberg \(1989\)](#), baseia-se na teoria Darwiniana da evolução, na qual os indivíduos mais bem adaptados sobrevivem e tem uma maior probabilidade de perpetuar seus genes ([PACHECO et al., 1999](#)). Neste método as possíveis soluções de um determinado problema são tratadas como indivíduos de uma população, que irão se reproduzir e competir pela sobrevivência, gerando uma evolução da população a cada iteração ou geração ([POZO et al., 2005](#)). O Algoritmo 1 apresenta a estrutura de um Algoritmo Genético.

Algorithm 1 Estrutura de um Algoritmo Genético

1. $t \leftarrow 0$;
 2. Gerar a população inicial $P(t)$;
 3. Avaliar os indivíduos de $P(t)$;
 4. **while** o critério de parada não for satisfeito **do**
 5. Selecionar pais $P'(t)$ a partir de $P(t)$;
 6. Aplicar operadores genéticos a $P'(t)$ obtendo a nova população $P(t+1)$;
 7. Avaliar $P(t+1)$;
 8. Selecionar os sobreviventes $P(t)$ entre $P(t)$ e $P(t+1)$;
 9. $t = t + 1$;
 10. **end while**
-

Fonte: Adaptado de [Gaspar-Cunha, Takahashi e Antunes \(2012\)](#).

No AG o primeiro passo realizado é a geração de uma população inicial, seguido da atribuição de uma nota, denominada aptidão, para cada indivíduo. Os indivíduos gerados são selecionados para a reprodução, nesse processo os membros mais aptos geralmente possuem maior probabilidade de serem escolhidos ([LACERDA; CARVALHO, 1999](#)). Uma vez realizada a seleção dos indivíduos para formar os pais são aplicados os operadores genéticos, normalmente o cruzamento e a mutação. De acordo com [Gaspar-Cunha, Takahashi e Antunes \(2012\)](#) o operador de cruzamento realiza a troca de material genético entre pais conduzindo a geração de descendentes. Já a mutação atua sobre as soluções resultantes do cruzamento alterando ligeiramente algumas de suas características. A nova população, composta pelos descendentes, é avaliada e são selecionados os indivíduos para formar a população corrente. Essa seleção pode ser realizada de diversas formas, uma alternativa é a coexistência entre "pais" e "filhos", escolhendo os indivíduos sobreviventes (entre os pais e os filhos) com base na aptidão ([SILVA, 2001a](#)).

O Algoritmo de Seleção Clonal (do inglês *Clonal Selection Algorithm*) trata-se de uma meta-heurística proposta por [Castro e Zuben \(2000\)](#) que utiliza o princípio de seleção clonal e a maturação proporcional à afinidade como mecanismos para manipular uma população de soluções candidatas, denominadas anticorpos ([CASTRO, 2001](#)). De acordo com [Carraro et al. \(2012\)](#) o princípio de seleção clonal estabelece que as células capazes de reconhecer um determinado estímulo antigênico são selecionadas em detrimento de outras para a proliferação, visando produzir células em quantidade suficiente para combater a infecção. No processo de proliferação, mitose celular, as células filhas (clones) podem sofrer mutação genética (hipermutação) com taxas elevadas e inversamente proporcionais a suas

afinidades com o antígeno. Esse processo é responsável pela variação genética no repertório celular e combinado com a sobrevivência das células que melhor reconhecem o antígeno fazem com que o sistema imunológico seja capaz de se adaptar, preservando as células de alta afinidade enquanto fornece uma alta probabilidade de gerar células melhores.

O CLONALG possui duas versões, a primeira empregada para a resolução de problemas de aprendizagem de máquina e reconhecimento de padrões e a segunda para problemas de otimização (CASTRO, 2001). O Algoritmo 2 apresenta um CLONALG para o tratamento de problemas de otimização.

Algorithm 2 Algoritmo CLONALG para problemas de otimização

1. Gerar a população inicial de anticorpos (P);
 2. **while** o critério de parada não for satisfeito **do**
 3. Avaliar a afinidade dos anticorpos de P ;
 4. Selecionar os n melhores anticorpos (P') a partir de P ;
 5. Clonar os anticorpos P' gerando uma população C com N_c clones.
 6. Submeter a população de clones C a um processo de hipermutação obtendo C' ;
 7. Avaliar a afinidade de cada anticorpo pertencente a C' ;
 8. Re-selecionar os n melhores anticorpos ($C'n$) e os adicionar a população P descartando os anticorpos de pior qualidade;
 9. Substituir d anticorpos de baixa afinidade por novos anticorpos (Pd) (diversidade ou metadinâmica).
 10. **end while**
-

Fonte: Adaptado de Souza e Romero (2014 apud CASTRO; ZUBEN, 2000).

Assim como o AG, o CLONALG para a otimização inicia-se espalhando N pontos (anticorpos) sobre o espaço de busca do problema de otimização e realizando a avaliação desses anticorpos utilizando uma função objetivo (BATISTA, 2010). Esse anticorpos são classificados em ordem decrescente de afinidade e selecionados para o processo de clonagem, em que a quantidade de clones de cada anticorpo é diretamente proporcional a sua afinidade. Em seguida, a população de clones é submetida a um processo de hipermutação com taxa de mutação inversamente proporcional à afinidade, gerando uma população de anticorpos maduros/maturados. Os anticorpos maduros são avaliados e os melhores anticorpos são substituídos na população. Para manter a diversidade d anticorpos com baixa afinidade podem ser substituídos por novos anticorpos (SOUZA; ROMERO, 2014 apud CASTRO; ZUBEN, 2000).

A meta-heurística Busca em Vizinhança Variável ou *Variable neighborhood search* (VNS) foi proposta por Mladenovic (1995) e Mladenović e Hansen (1997) e baseia-se no princípio de explorar o espaço de soluções através de trocas sistemáticas de estruturas de vizinhança durante o processo de busca (FREITAS; RENATA; FLORENTINO, 2020). De acordo com Souza (2011) existem diversas propostas de algoritmos VNS que podem ser usados de forma independente ou integrados a estruturas de VNS mais complexas. A

estrutura de VNS básico para um problema de maximização está apresentada no Algoritmo 3.

Algorithm 3 Estrutura de um Algoritmo de Busca em Vizinhança Variável (VNS)

1. Definir o conjunto de estruturas de vizinhança N_k ($k = 1, \dots, k_{max}$);
 2. Gerar solução inicial x ;
 3. **repeat**
 4. $k \leftarrow 1$;
 5. **repeat**
 6. Escolher randomicamente $x' \in N_k(x)$
 7. Aplicar a busca local em x' obtendo x'' ;
 8. Avaliar x'' ;
 9. **if** $f(x'') > f(x)$ **then**
 10. $x \leftarrow x''$;
 11. $k \leftarrow 1$;
 12. **else**
 13. $k \leftarrow k + 1$;
 14. **end if**
 15. **until** $k = k_{max}$;
 16. **until** o critério de parada não for satisfeito
-

Fonte: Adaptado de [Silva \(2014\)](#).

No VNS básico o processo de otimização é iniciado definindo o conjunto de estruturas de vizinhança N_k ($k = 1, \dots, max$), e uma solução inicial qualquer. Na sequência é gerado aleatoriamente um vizinho dentro da vizinhança $k = 1$ ([SOUZA, 2011](#)). Esse vizinho é submetido a um procedimento de busca local e se a solução ótima local for melhor que a solução corrente, a busca continua recomeçando da primeira estrutura de vizinhança. Caso contrário, continua-se a busca a partir da próxima estrutura de vizinhança. Este procedimento é encerrado quando uma condição de parada for atingida ([SOUZA et al., 2002](#)).

2.3 Trabalhos relacionados

Diversos trabalhos vêm sendo desenvolvidos para a resolução de problemas de planejamento da produção florestal, avaliando algoritmos e buscando determinar a melhor combinação de parâmetros destes com o objetivo de obter melhores resultados com um menor custo computacional.

[Araújo et al. \(2018b\)](#) avaliaram a meta-heurística Algoritmo de Seleção Clonal, do inglês *Clonal Selection Algorithm* (CLONALG), variando as taxas de seleção, clonagem, hipermutação e substituição, além do tamanho da população inicial. Os autores destacaram a importância da escolha do melhor conjunto de parâmetros e concluíram que, quando

usado para resolver problemas de otimização combinatória em planejamento florestal, o CLONALG é eficiente se comparado a programação linear inteira.

Ferreira et al. (2018) realizaram a avaliação da performance da meta-heurística *Simulated Annealing* (SA) sob 27 combinações de parâmetros (três diferentes valores para os parâmetros temperatura inicial, taxa de decaimento da temperatura e número de vizinhos). Nos resultados apresentados foi possível observar que em todas as combinações avaliadas houveram execuções que retornaram valores negativos de VPL, sendo soluções inválidas. Porém, considerando a melhor execução, todas as combinações foram capazes de retornar soluções válidas, com diferenças significativas entre elas. Os autores concluíram que a definição da combinação ideal de parâmetros da meta-heurística SA é importante para obtenção de soluções próximas da otimalidade em um problema de planejamento da produção florestal.

Araújo et al. (2018a) testaram a Busca em Vizinhança Variável (VNS- *Variable Neighborhood Search*) com diferentes configurações para a estrutura de vizinhança, número de vizinhos e gerações. Os autores concluíram que o VNS é eficiente para resolver um problema de planejamento florestal em comparação com a programação linear inteira e pode gerar soluções mais próximas da encontrada por algoritmos exatos em um curto tempo de processamento. Entretanto, destacaram que a escolha dos parâmetros do algoritmo é crucial para a obtenção de boas soluções.

Matos et al. (2019) utilizando a meta-heurística Algoritmo Genético (AG) avaliaram a influência dos parâmetros elitismo, cruzamento (1 ponto de corte e uniforme), seleção dos pais para cruzamento (roleta e torneio) e mutação (escolha aleatória do gene e gene a gene). Além disso, foram avaliados o tamanho da população inicial (20, 50 e 80 indivíduos) e o critério de parada (100, 300 e 500 gerações). A melhor solução foi encontrada utilizando elitismo, cruzamento de 1 ponto, seleção do tipo torneio, mutação do tipo gene a gene, população inicial com 50 indivíduos e critério de parada com 500 gerações. Os autores concluíram que a qualidade das soluções geradas por essa meta-heurística depende da seleção de uma boa configuração de seus parâmetros. Rodrigues et al. (2004) também chegaram a mesma conclusão em relação a relevância da avaliação de parâmetros para o bom desempenho desta meta-heurística, destacando também que o AG pode ser uma abordagem bastante atrativa para solução de importantes problemas de gerenciamento florestal.

Embora a determinação dos parâmetros seja importante, existem outras alternativas que podem ser implementadas para aumentar a performance das meta-heurísticas. De acordo com Melo (2009), em vez de encontrar os melhores parâmetros para os algoritmos, muitos pesquisadores se concentram em outros procedimentos, como a geração da população inicial. No trabalho desenvolvido por Campos (2017) a respeito de otimização dos custos de energia elétrica, o autor conclui que ao adicionar à população inicial uma solução obtida

por outro método de otimização houve uma melhora na qualidade da solução e ainda ocorreu uma redução considerável no tempo de processamento. Esses resultados podem indicar a influência da solução inicial no processo de otimização do problema estudado.

Na solução de um problema de planejamento florestal, [Júnior et al. \(2021\)](#) avaliaram a inclusão, na população inicial, de uma solução obtida pelo arredondamento da solução ótima da programação linear para o problema relaxado como alternativa para aumentar a performance das meta-heurísticas CLONALG, AG, SA e VNS. De acordo com os autores, essa alternativa gerou uma melhora substancial na performance dos algoritmos CLONALG, AG e VNS, entretanto não foram observados efeitos positivos para a meta-heurística SA.

Diante do exposto, é possível identificar que várias meta-heurísticas vêm sendo empregadas para a solução de problemas de planejamento florestal, como o AG, CLONALG e VNS. Entretanto, a qualidade da solução obtida por esses métodos varia de acordo com os parâmetros utilizados, podendo ser obtidas soluções inválidas, dependendo dos parâmetros selecionados. Além disso, outro fator que pode impactar no desempenho de alguns desses métodos é a população inicial, podendo a inclusão de bons indivíduos nesta gerar uma melhora na qualidade da solução obtida.

3 Materiais e métodos

O presente trabalho foi desenvolvido em três etapas: 1) elaboração e avaliação da heurística proposta, 2) implementação do Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS) seguido da comparação do desempenho dessas meta-heurísticas com a heurística proposta e 3) análise do impacto de diferentes quantidades de indivíduos gerados pela heurística proposta (*qSoluções*) no conjunto de soluções iniciais do AG, CLONALG e VNS. Diante disso, inicialmente foi realizada a definição do problema, seguido pela descrição da heurística proposta e das meta-heurísticas implementadas e, por fim, a apresentação dos métodos utilizados para as avaliações.

3.1 Definição do problema

Neste trabalho foi utilizada a base de dados apresentada por [Júnior et al. \(2021\)](#) referente a uma floresta de eucalipto com idades variando entre 1 e 6 anos e área total igual a 4.210 hectares. De acordo com os autores, essa floresta foi dividida em 120 talhões (unidades de manejo) e foram geradas 81 diferentes prescrições (alternativas de manejo) para cada talhão, definindo a sequência de colheita e plantio a ser realizada durante um horizonte de planejamento de 16 anos. A definição das prescrições levou em consideração o corte das unidades de manejo com idades entre 5 e 7 anos e o plantio imediato após o corte.

A atribuição de determinada prescrição a um talhão define a idade do povoamento florestal em cada período do horizonte de planejamento, sendo cada período igual a um ano. O volume de madeira produzido e os custos silviculturais variam de acordo com a idade do talhão. Nesse sentido, a escolha da prescrição afeta não somente quando será realizada a colheita, mas também a quantidade de madeira colhida e o Valor Presente Líquido (VPL) obtido. Os valores de produção e VPL correspondentes a aplicação de cada alternativa de manejo em cada talhão estão contidos na base de dados, composta por 20 colunas e 9720 linhas. As colunas 1, 2 e 3 contém, respectivamente, o número do talhão, a idade atual e a prescrição aplicada. As colunas 4 até a 19, a produção volumétrica de madeira para cada ano do horizonte de planejamento e a coluna 20 o VPL (Figura 2).

	1	2	3	4	...	19	20
1	1	1	1	0	...	0	14703
2	1	1	2	0	...	0	14703
...	...	...	...	...	...	...	...
9719	120	6	80	8960	...	8960	442508
9720	120	6	81	8960	...	8960	442508

Fonte: os autores

Figura 2 – Representação da base de dados. As colunas contém o número do talhão, a idade do povoamento florestal, a prescrição aplicada, a produção em cada ano do horizonte de planejamento e o VPL.

O problema de planejamento da produção florestal estudado consiste em determinar qual das 81 prescrições deve ser atribuída a cada um dos 120 talhões para a maximização do VPL e atendimento da demanda mínima e máxima anual de madeira. Para isso, cada solução foi representada como um vetor com 120 posições, em que cada posição pode assumir um valor inteiro entre 1 e 81. Nessa representação as posições correspondem aos talhões e os valores atribuídos, as prescrições. O modelo matemático de otimização utilizado considerou a estrutura proposta por [Johnson e Scheurman \(1977\)](#), representada pela Equação 3.1.

$$\text{Max VPL} = \sum_{i=1}^M \sum_{j=1}^P VPL_{ij} \cdot X_{ij} \quad (3.1)$$

Sujeito a:

$$\sum_{j=1}^P X_{ij} = 1 \quad \forall i \in \{1, \dots, M\} \quad (3.2)$$

$$\sum_{i=1}^M \sum_{j=1}^P V_{ijk} \cdot X_{ij} \geq Dmin_k \quad \forall k \in \{1, 2, \dots, 16\} \quad (3.3)$$

$$\sum_{i=1}^M \sum_{j=1}^P V_{ijk} \cdot X_{ij} \leq Dmax_k \quad \forall k \in \{1, 2, \dots, 16\} \quad (3.4)$$

$$X_{ij} \in \{0, 1\} \quad (3.5)$$

Em que: VPL_{ij} é o VPL da unidade de manejo i segundo 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 ; V_{ijk} é o volume total de madeira (m^3) da unidade de manejo i segundo o regime de manejo j em um período k do horizonte de planejamento; $Dmin_k$ e $Dmax_k$ são, respectivamente, a demanda mínima e máxima de madeira (m^3) no período k do horizonte de planejamento.

A função objetivo (Eq. 3.1) busca maximizar o retorno financeiro e está sujeita à restrição binária (Eq. 3.5), de integridade (Eq. 3.2) e de produção (Eq. 3.3) e (Eq. 3.4). A restrição de integridade garante escolha de apenas uma prescrição para cada unidade de manejo e as restrições de produção asseguram o fornecimento do produto florestal nos níveis desejados em cada período do horizonte de planejamento (PEREIRA, 2004).


Neste trabalho, a função objetivo levou em consideração o método das penalidades, reduzindo o valor do cálculo da função (Eq. 3.1) em R\$ 500,00 (quinhentos reais) por volume de madeira produzido excedido ou faltante em relação ao $Dmin$ e $Dmax$. Este método também foi utilizado por Matos et al. (2019) e é representado pela Equação 3.6.

$$Max VPL = \sum_{i=1}^M \sum_{j=1}^P (VPL_{ij} \cdot X_{ij}) - P \sum_{k=1}^T dk \quad (3.6)$$

Em que: P representa a penalidade (R\$); dk é o valor absoluto do desvio volumétrico de madeira em m^3 em um período k do horizonte de planejamento.

O valor de dk é calculado por meio da diferença entre a produção total da solução e os limites $Dmin$ e $Dmax$. Para a obtenção da produção total é buscada na base de dados e armazenada no histórico de produção a quantidade de madeira colhida em cada ano do horizonte de planejamento em cada talhão sob as prescrições aplicadas, por fim, é realizado o somatório do histórico de produção para a determinação da produção total.

A Figura 3 ilustra o processo utilizado para o cálculo da produção total, em que (a) representa uma solução, (b) a base de dados, (c) o histórico de produção e (d) a produção total. A solução tem atribuída ao primeiro talhão a prescrição 66, portanto, é localizada na base de dados a linha que contenha na primeira coluna o número 1, referente ao talhão, e na terceira coluna o número 66 (prescrição). Da linha buscada são armazenados no histórico de produção (c) os valores contidos nas colunas 4 a 19 (produção em cada ano do horizonte de planejamento). Esse processo é realizado para todos os talhões e, posteriormente, é realizada a soma do histórico de produção para a obtenção da produção total (d). Com a produção total é possível identificar se determinado ano do horizonte de planejamento tem produção fora dos limites estabelecidos e calcular o valor absoluto do desvio volumétrico de madeira.



Fonte: os autores

Figura 3 – Representação do cálculo da produção, em que (a) representa uma solução, (b) a base de dados, (c) o histórico de produção e (d) a produção total.

Nota: Em (d) os anos em vermelho (1, 2, 14, 15 e 16) tem produção fora dos limites estabelecidos, então para cada metro cúbico de madeira em excesso ou falta nesses será aplicada a penalidade definida.

Considerando que existem 120^{81} soluções possíveis para este problema, adquirir soluções que atendam as demandas estabelecidas requer um grande esforço. Para isso, foi desenvolvida a heurística proposta.

3.2 Abordagem proposta

3.2.1 Descrição da heurística proposta

A heurística proposta tem o objetivo de encontrar soluções iniciais válidas para o problema de planejamento florestal estudado, sendo uma solução considerada válida quando todos os anos do horizonte de planejamento tem produção dentro dos limites mínimo (140.000 m^3) e máximo (160.000 m^3) estabelecidos por Júnior et al. (2021). Para isso, algoritmo desenvolvido partiu da ideia de definir, a cada iteração, os anos com maior e menor produção e buscar reduzir essa diferença através da alteração de prescrições em determinados talhões.

O Algoritmo 4 apresenta a heurística proposta, em que a variável $qSoluções$ é a quantidade de soluções válidas a serem geradas, BD é a base de dados e BDr é a base de dados reorganizada (detalhada na seção 3.2.1). As soluções geradas são armazenadas na variável $conjuntoSoluções$. O $CritParada$ é o limite máximo de cálculos de função objetivo por execução, o $CritPoda$ é o intervalo em que a função poda será executada. O $Dmin$ e $Dmax$ são os limites mínimo e máximo de produção anual definidos, o $NumPrescrições$ e $NumTalhões$ representam o número total de prescrições e talhões, respectivamente.

Algorithm 4 [conjuntoSoluções]= Heurística Inicial (qSoluções, BD, BDr)

```

1. Constantes: CritParada = 5000; CritPoda= 16; Dmin = 140.000; Dmax = 160.000;
   NumPrescrições = 81; NumTalhões = 120

2. for i = 1:qSoluções do
3.   contadorParada = 0;
4.   contadorPoda = 0;
5.   [solução] = Gera uma solução aleatória (NumTalhões, NumPrescrições);
6.   [histProd, prodTotal] = Calcula a produção (solução, BD, Dmin, Dmax, NumTa-
     lhões);
7.   contadorParada = contadorParada + 1;
8.   [qIrregulares] = Define a quantidade de anos com produção irregular (prodTotal,
     Dmin, Dmax);
9.   while qIrregulares > 0 do
10.    if contadorParada >= CritParada then
11.      Break;
12.    else
13.      [menorAno, maiorAno]= Selecciona os anos a serem trabalhados (prodTotal);
14.      [talhão] = Escolhe um talhão (histProd, menorAno, maiorAno);
15.      [prescrição] = Define a nova prescrição para o talhão selecionado (talhão,
        menorAno, maiorAno, BDr);
16.      [soluçãoaux] = Modifica a prescrição do talhão (solução, talhão, prescrição);
17.      [histProdaux, prodTotalaux] = Calcula a produção da nova solução (soluçãoaux,
        BD, Dmin, Dmax, NumTalhões);
18.      [qIrregularesaux] = Define a quantidade de anos com produção irregular
        (prodTotalaux, Dmin, Dmax);
19.      if qIrregularesaux <= qIrregulares then
20.        solução = soluçãoaux;
21.        histProd = histProdaux;
22.        prodTotal = prodTotalaux;
23.        qIrregulares = qIrregularesaux;
24.      end if
25.      contadorParada = contadorParada + 1;
26.      contadorPoda = contadorPoda + 1;
27.      if contadorPoda >= critPoda and qIrregulares > 0 then
28.        [solução] = Realiza a poda (solução, histProd, prodTotal, NumTalhões,
          NumPrescrições, Dmin, Dmax);
29.        [histProd, prodTotal] = Calcula a produção (solução, BD, Dmin, Dmax,
          NumTalhões);
30.        [qIrregulares] = Define a quantidade de anos com produção irregular (prod-
          Total, Dmin, Dmax);
31.        contadorParada = contadorParada + 1;
32.        contadorPoda = 0;
33.      end if
34.    end if
35.  end while
36.  conjuntoSoluções(i, :) = solução;
37. end for

```

Para a obtenção de uma solução válida, a heurística proposta gera uma solução aleatória e realiza o cálculo da produção, armazenando o histórico de produção e a produção total. Com a produção total, é possível determinar a quantidade de anos com produção irregular (menor do que 140.000 m³ ou maior do que 160.000 m³). Caso todos os anos tenham produção regular a solução é salva e a heurística é encerrada. Enquanto esse critério não for atendido ou até que seja excedido o número máximo de cálculos de função objetivo, o algoritmo ordena a produção de todos os anos e seleciona os que contiverem a maior e menor produção. O ano com maior produção é armazenado na variável *maiorAno* e o com menor produção, *menorAno*.

As variáveis e o histórico de produção são empregados para a seleção de um talhão para ter a prescrição modificada. Para isso, o critério utilizado é que, se possível, o talhão selecionado sob a prescrição atual tenha produção maior do que zero no *maiorAno* e igual a zero no *menorAno*. Esses requisitos foram definidos levando em consideração que a alteração da prescrição pode modificar os anos em que o talhão será colhido e, portanto, a produção total da solução. Nesse sentido, o primeiro requisito (produção no *maiorAno* > 0) foi adotado visando aumentar a probabilidade de que a modificação reduza a produção no *maiorAno* e o segundo requisito (produção no *menorAno* = 0) tem o intuito de evitar que essa modificação também diminua a produção no *menorAno*.

A Figura 4 ilustra a seleção dos talhões passíveis de modificação em uma solução que, conforme apresentado na produção total, tem como *maiorAno* (destacado em vermelho) e *menorAno* (destacado em azul) o primeiro e o décimo terceiro ano do horizonte de planejamento, respectivamente. Na primeira coluna do histórico de produção, que é constituída pela produção de todos os talhões no *maiorAno*, são selecionados os talhões 118, 119 e 120 por conterem produção maior do que zero. Posteriormente, avaliando na coluna 13, o talhão 120 é excluído das alternativas por possuir produção diferente de zero no *menorAno*. Logo, seriam alternativas de talhões para serem modificados o 118 e 119.

	1	2	3	4	5	...	12	13	14	15	16
1	0	0	0	0	0	...	0	0	5632	0	0
2	0	0	0	0	0	...	6468	0	0	0	0
...	...	...	...	...	...	...	...		...	...	...
118	8190	0	0	0	0	...	8190	0	0	0	0
119	4140	0	0	0	0	...	0	0	0	0	0
120	8190	0	0	0	0	...	0	8960	0	0	0

Produção Total	178542	131494	172975	129274	130838	...	153757	124962	165986	141769	130159
----------------	--------	--------	--------	--------	--------	-----	--------	--------	--------	--------	--------

Fonte: os autores

Figura 4 – Representação do histórico de produção e seleção dos talhões passíveis de modificação.

A escolha da nova prescrição é realizada visando aumentar a produção do *menor Ano*, mantendo a produção do *maior Ano*. Para isso, foi proposta uma reorganização da base de dados avaliando, para cada ano do horizonte de planejamento, quais prescrições poderiam ser atribuídas a cada um dos talhões para que ocorresse colheita naquele ano. Por exemplo, caso fosse selecionado para alteração o talhão 118 da solução apresentada na Figura 4, a base de dados reorganizada seria aplicada para definir quais prescrições poderiam ser atribuídas a este talhão para que houvesse colheita no décimo terceiro ano (*menor Ano*) e não no primeiro (*maior Ano*).

O método utilizado para a reorganização da base de dados foi filtrar, para cada talhão e ano do horizonte de planejamento, as prescrições com produção diferente de zero e copiá-las para um novo arquivo. A Figura 5 apresenta a base de dados reorganizada, em que a primeira coluna refere-se ao talhão e a segunda ao ano do horizonte de planejamento. As demais colunas contém as prescrições que, se atribuídas a determinado talhão, vão gerar produção no ano em questão, sendo o valor zero atribuído caso não existam prescrições que irão gerar colheita no ano avaliado.

	Talhão	Ano	Prescrições					
1	1	1	0	0	...	0	...	0
2	2	1	0	0	...	0	...	0
...	...	...	...	...	...	...	...	...
118	118	1	1	2	...	24	...	54
...	...	...	...	...	...	...	...	...
1558	118	13	7	8	...	66	...	0
...	...	...	...	...	...	...	...	...
1919	119	16	28	79	...	0	...	0
1920	120	16	28	79	...	0	...	0
	1	2	3	4		26		56

Fonte: os autores

Figura 5 – Reorganização da base de dados. As prescrições armazenadas nas colunas 3 a 56, se atribuídas ao talhão da coluna 1, irão gerar colheita no ano da coluna 2.

Nota: No exemplo mencionado as prescrições de 7, 8 e 66 poderiam ser atribuídas ao talhão 118 (linha 1558), para que este talhão tivesse produção no décimo terceiro ano. Contudo, a aplicação das prescrições entre 1 e 54 (linha 118) geram colheita no primeiro ano. Nessa situação, uma alternativa seria a prescrição 66, pois se aplicada geraria colheita no *menorAno* e não no *maiorAno*.

A escolha da prescrição a ser atribuída ao talhão definido é executada buscando na base de dados reorganizada as prescrições que têm colheita no *menorAno* e *maiorAno*. Das alternativas de prescrições que geram colheita no *menorAno* são excluídas as que também ocasionam colheita no *maiorAno*. Em seguida é selecionado aleatoriamente uma prescrição entre as alternativas restantes. Se não existirem prescrições que cumpram os requisitos ou todas as prescrições forem iguais a zero a seleção é feita aleatoriamente entre todas as prescrições.

Realizando a troca da prescrição no talhão escolhido, o cálculo da quantidade de anos com produção irregular é novamente realizado. Caso a solução modificada tenha uma quantidade igual ou menor de violações, esta passa a ser a solução corrente, caso contrário, é descartada. Esse processo é executado até que o algoritmo atinja o número máximo de cálculos de função objetivo ou a solução não tenha nenhum ano com produção irregular.

Na heurística proposta, a escolha do talhão e da prescrição foram desenvolvidas com o objetivo de realizar uma busca local, afim de melhorar a solução corrente. Entretanto, para evitar que o algoritmo ficasse preso em ótimos locais foi necessária a implementação da função de poda com o intuito de realizar mudanças na vizinhança. A função de poda é aplicada quando o algoritmo executa o procedimento descrito 16 vezes (*CritPoda*) e a solução permanece inválida. Essa função zera a produção e atribui prescrições aleatórias aos talhões que tenham colheita em anos com excesso de produção até que a produção

total destes anos se aproximem de $Dmin$. Se não existirem anos com excesso de produção, a função utiliza o ano com maior produção. O Algoritmo 5 apresenta a função de poda, em que a variável *solução* trata-se da solução corrente, *histProd* é o histórico de produção, *prodTotal* é a produção total.

Algorithm 5 [solução] = Poda (solução, histProd, prodTotal, NumTalhões, NumPrescrições, Dmin, Dmax)


```

1. histProdaux = histProd;
2. [qAltaProd, anosAltaProd] = Determina a quantidade de anos com produção alta e
   quais são (prodTotal, Dmax);
3. if qAltaProd = 0 then
4.   [anosAltaProd] = Ordena a produção de todos os anos e seleciona o com maior
   produção (prodTotal);
5.   qAltaProd = 1;
6. end if
7. for i = 1 to qAltaProd do
8.   for j = 1 to NumTalhões do
9.     if histProdaux (j, anosAltaProd (i)) > 0 then
10.      histProdaux (j, :) = 0;
11.      prodTotalaux = soma (histProdaux);
12.      if prodTotalaux (anosAltaProd(i)) > Dmin then
13.        solução (1, j) = Gera uma prescrição aleatória e atribui ao talhão que teve a
        produção zerada (NumPrescrições);
14.      else
15.        histProdaux (j, :) = histProd (j, :)
16.      end if
17.    end if
18.  end for
19. end for

```

3.2.2 Descrição das meta-heurísticas

O Algoritmo Genético (AG) proposto utiliza uma população inicial composta por 50 indivíduos, $qSoluções$ gerados pela heurística desenvolvida e os demais, aleatoriamente. O método de seleção por torneio foi empregado para a seleção dos pais para o cruzamento e o cruzamento dos indivíduos foi realizado com um ponto de ruptura a uma probabilidade de 80%. A mutação realizada consistiu na troca das prescrições de dois talhões selecionados de forma aleatória com uma probabilidade de 1%. Essa mutação foi denominada *swap* e está apresentada na Figura 6. O torneio também foi utilizado como método de substituição dos indivíduos na população, contudo foi adotado o elitismo para evitar a perda dos melhores indivíduos. No elitismo utilizado os 10 melhores indivíduos entre os pais e filhos gerados são selecionados para a próxima geração. Essa configuração de parâmetros foi obtida empiricamente, os testes realizados estão apresentados na Tabela 4 apresentada no Anexo A.



Fonte: os autores

Figura 6 – Mutação do tipo *swap* em que são trocadas as prescrições de dois talhões aleatórios. A primeira e a segunda imagem representam a solução antes e depois da mutação, respectivamente.

No Algoritmo de Seleção Clonal (CLONALG), assim como no AG, foi utilizado um conjunto de soluções iniciais composto por 50 indivíduos (anticorpos), $qSoluções$ gerados pela heurística desenvolvida e os demais, aleatoriamente. A taxa de seleção para clonagem adotada foi de 20% e o número de clones gerados para cada anticorpo foi determinado utilizando a Equação 3.7 (BATISTA, 2010).

$$N_c = \sum round(TC * N/i) \quad (3.7)$$

Em que: onde TC é a taxa de clonagem (25%), N é a quantidade total de anticorpos e round é o operador que arredonda o valor entre parênteses para o inteiro mais próximo.

Os clones gerados foram submetidos ao processo de hipermutação que consiste na atribuição de prescrições aleatórias a uma quantidade de talhões inversamente proporcional ao VPL (afinidade). A taxa de mutação foi obtida por meio das Equações 3.8, 3.9 (BATISTA, 2010; ARAÚJO et al., 2018b). Os piores anticorpos gerados foram substituídos pelos melhores clones de maneira elitista. Em seguida, o anticorpo com menor afinidade foi substituído por uma solução gerada de forma aleatória afim de manter a diversidade. A definição desta configuração de parâmetros foi realizada de forma empírica, os testes realizados estão apresentados na Tabela 5 do Anexo A.

$$\rho = 5(1 - TH) \quad (3.8)$$

$$\alpha = exp(-\rho.D^*) \quad (3.9)$$

Em que: TH é a taxa de hipermutação (10%), D^* é o VPL normalizado.

A meta-heurística Busca em Vizinhança Variável (VNS) utiliza somente uma solução corrente que neste trabalho foi gerada de forma aleatória ou por meio da heurística

proposta ($qSoluções = 1$). O conjunto de estruturas de vizinhança utilizadas consistiu na modificação de 1, 2, 3 e 4% das prescrições aleatoriamente (ARAÚJO et al., 2018a). O procedimento de Busca Local aplicado foi o *swap*, que troca a posição de duas prescrições aleatórias, utilizando 200 vizinhos. Os testes de parâmetros utilizados para a definição desta configuração estão apresentados na Tabela 6 do Anexo A.

3.3 Métodos de avaliação

Para a avaliação do desempenho da heurística proposta e das meta-heurísticas estudadas foram gerados dois cenários mais restritivos, além do cenário descrito na seção 3.1. O primeiro cenário gerado, intitulado cenário 2, tem a demanda mínima ($Dmin$) igual a 140.000 m² e a demanda máxima ($Dmax$) de 150.000 m². Já o segundo cenário gerado, cenário 3, tem a $Dmin$ igual 150.000 m³ e $Dmax$ 160.000 m³.

A heurística proposta foi testada em cada cenário, verificando a quantidade de cálculos da função objetivo necessários para a obtenção de soluções viáveis. Para isso, foram realizadas 1.000 execuções da heurística armazenando a quantidade de cálculos da função objetivo, a solução obtida e o tempo de execução. As meta-heurísticas foram implementadas conforme apresentado na seção 3.2.2, adotando como critério de parada 5.000 cálculos de função objetivo. Para cada cenário a heurística proposta e meta-heurísticas foram executadas 30 vezes, armazenando o VPL máximo e a quantidade de soluções válidas ao final de cada execução.

Posteriormente, foi avaliado o desempenho das meta-heurísticas AG e CLONALG utilizando 1, 5, 10 e 15 indivíduos gerados pela heurística proposta no conjunto de soluções iniciais na resolução do primeiro cenário estudado (original). Para o VNS, que utiliza somente uma solução corrente, foi avaliado a utilização de $qSoluções$ igual a 1. Nesses testes foi adotado o critério de parada de 5.000 cálculos de função objetivo, considerando os cálculos utilizados para a geração dos indivíduos iniciais, executando 30 vezes para cada valor de $qSoluções$ e armazenando o valor máximo de VPL obtido em cada execução. Os resultados obtidos pelas meta-heurísticas utilizando o conjunto de soluções gerado de forma aleatória e utilizando as soluções geradas pela heurística propostas foram submetidos a análise estatística a um nível de significância de 5%.

A implementação e os experimentos realizados foram executados utilizando o MATLAB R2020b, em um computador com processador Intel® Core™ i5-7400 de 3,0 GHz com 4 GB RAM. Para a análise estatística foi empregado o Excel 2019, realizando inicialmente a verificação dos pressupostos para a utilização da análise de variância de um fator (ANOVA *one – way*). Os pressupostos analisados foram a normalidade, por meio do teste de Shapiro-Wilk, e a homocedasticidade, aplicando o teste de Levene. Nos casos em que esses pressupostos foram atendidos procedeu-se a ANOVA, aplicando o teste

de comparação de média Tukey quando necessário. No caso em que os pressupostos não foram atendidos procedeu-se ao teste não paramétrico de Kruskal-Wallis, seguido pelo teste Dunn.

4 Resultados e discussão


4.1 Avaliação do desempenho da heurística e meta-heurísticas nos cenários estudados

Os resultados da avaliação da heurística proposta nos 3 cenários estudados estão apresentadas na Tabela 1. Para o primeiro cenário (D_{min} igual a 140.000 m² e D_{max} 160.000 m²) foram demandados em média, aproximadamente, 82 cálculos de função objetivo e 0,026 segundos para a obtenção de uma solução válida, sendo encontradas soluções com produção dentro dos limites estabelecidos em todas as execuções realizadas. No segundo cenário (D_{min} igual a 140.000 m² e D_{max} 150.000 m²) foram necessários em média 1.006 cálculos de função objetivo e 0,22 segundos, obtendo soluções válidas em 99,9% das execuções. Enquanto no cenário 3 (D_{min} igual a 150.000 m² e D_{max} 160.000 m²), não foram encontradas soluções válidas em nenhuma das 1.000 execuções e o tempo médio foi de 1,08 segundos.

Tabela 1 – Avaliação da heurística proposta nos 3 cenários em relação à quantidade de cálculos de função objetivo e o número total de soluções válidas obtidas

Cenário	Média	Mínimo	Máximo	Desvio padrão	Nº de soluções válidas geradas
1	81.86	15	371	48.82	1000
2	1005.81	51	5000	761.06	999
3	5000	5000	5000	0	0

A Figura 7 ilustra a produção em cada ano do horizonte de planejamento de 4 soluções, a primeira gerada aleatoriamente e as demais obtidas pela heurística proposta em cada um dos cenários. Na solução gerada de forma aleatória é possível observar uma grande variação no volume de madeira produzido, tendo o ano com menor produção 83.682 m³ e o com maior, 201.888 m³. As soluções geradas pela heurística proposta no primeiro e segundo cenários apresentam produções dentro dos limites estabelecidos. Já a solução gerada pela heurística no terceiro cenário é inválida, uma vez que, a produção de 6 dos 16 anos do horizonte de planejamento estão abaixo da demanda mínima estipulada. Entretanto, esta solução apresenta maior regularidade se comparada a gerada de forma aleatória. Os resultados apresentados apontam que a heurística desenvolvida é capaz de obter soluções válidas com um baixo custo computacional nos cenários 1 e 2. Contudo, o cenário 3 mostrou-se mais restritivo, havendo a possibilidade de não existirem soluções válidas para este problema nessas condições.



Fonte: os autores

Figura 7 – A Figura (a) ilustra a produção nos 16 anos do horizonte de planejamento de uma solução gerada aleatoriamente. Já as Figuras (b), (c) e (d) foram geradas pela heurística proposta no primeiro, segundo e terceiros cenários, respectivamente. As linhas vermelhas representam a demanda máxima e mínima de cada cenário.

Em seguida, foi avaliado o desempenho da heurística proposta e das meta-heurísticas Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS) na resolução dos 3 cenários do problema de planejamento florestal (Tabela 2). Verificando a quantidade de execuções com soluções válidas (ao final da execução) é possível observar que no primeiro cenário, ao contrário da heurística proposta, todas as meta-heurísticas estudadas tiveram pelo menos uma execução com soluções inválidas. Esses resultados demonstram que a obtenção de soluções com produção dentro dos limites estabelecidos não é uma tarefa trivial em nenhum dos cenários e indicam o potencial da heurística para a tomada de decisão rápida no planejamento da produção florestal. No segundo cenário, a heurística, o AG, o CLONALG e o VNS obtiveram soluções válidas

em 100%, 20%, 6,66% e 10% das execuções, respectivamente. Já no terceiro cenários não foram encontradas soluções válidas em nenhuma execução.

Tabela 2 – Resultados das 3 meta-heurísticas em cada cenário estudado utilizando qSoluções igual a 0, contendo o método avaliado, o Valor Presente Líquido médio, mínimo e máximo, o desvio padrão e a verificação da existência de soluções válidas no final da execução das 30 execuções.

Método	Média	Mínimo	Máximo	Desvio padrão	Execuções com soluções válidas
Cenário 1					
Heurística	29990716	29593240	30392521	187132	30
AG	30431317	30153012	30681827	149990	29
CLONALG	30384715	30118383	30629176	129446	28
VNS	30560674	30357679	30819973	142232	29
Cenário 2					
Heurística	30296563	30073647	30641133	131356	30
AG	28766777	24272351	30409291	1931754	6
CLONALG	28271868	24276469	30379693	1417596	2
VNS	28521090	21255287	30453983	1993373	3
Cenário 3					
Heurística	12558783	2173764	19499702	4539943	0
AG	15824019	8651377	21340680	3749860	0
CLONALG	17253809	11064146	22837152	2684917	0
VNS	15627888	6074459	21424824	3669773	0

Em relação ao Valor Presente Líquido (VPL), entre os métodos avaliados a heurística proposta foi o que apresentou o menor valor no primeiro cenário. Contudo, é relevante destacar que o método proposto interrompe a sua execução ao encontrar soluções válidas. Nesse sentido, para a obtenção deste resultado foram demandados, em média, 67 cálculos de função objetivo, enquanto as meta-heurísticas utilizaram 5.000. Em comparação com o VNS (a meta-heurística que teve o melhor desempenho entre as estudadas) a heurística proposta obteve um VPL corresponde a 98.13% utilizando, para isso, em média, 1,34% dos cálculos de função objetivo. Os resultados apresentados pelas meta-heurísticas estudadas e pela literatura (ARAÚJO et al., 2018a; ARAÚJO et al., 2018b; MATOS et al., 2019) indicam que a heurística proposta possui a capacidade de gerar soluções de boa qualidade com um baixo custo computacional. No trabalho realizado por Matos et al. (2019), por exemplo, a solução encontrada pela programação inteira (*branch and bound*), após 96 horas de processamento, apresentou um VPL igual a R\$ 31.964.100 e o AG¹, R\$ 30.336.526. Se

¹ Este resultado refere-se a melhor combinação de parâmetros encontrada utilizando 50 indivíduos e 100 gerações (VPL médio).

comparado com esses resultados, o VPL da heurística proposta corresponde a 93,83% e 98.86%.

Ainda em relação a Tabela 2, a heurística proposta apresentou resultados promissores para o segundo cenário. Além de obter soluções válidas em todas as execuções, este método apresentou um VPL médio maior do que os das meta-heurísticas avaliadas, R\$ 30.296.563,00, utilizando em média 906 cálculos de função objetivo. No terceiro cenário, a heurística proposta e as meta-heurísticas estudadas não encontraram soluções válidas demonstra a complexidade do problema nessas condições.


4.2 Avaliação da viabilidade de aplicação da heurística proposta para a geração de soluções iniciais

A Tabela 3 apresenta a comparação entre os resultados obtidos pelas meta-heurísticas na resolução do primeiro cenário (original) do problema de planejamento florestal utilizando diferentes quantidades de indivíduos gerados pela heurística proposta (*qSoluções*) no conjunto de soluções iniciais. Observando os resultados é possível identificar que o incremento de soluções válidas no conjunto de soluções iniciais gerou o aumento no VPL médio.

Tabela 3 – Valor Presente Líquido (VPL) médio e desvio padrão do Algoritmo Genético (AG), Busca em Vizinhança Variável (VNS) e Algoritmo de Seleção Clonal (CLONALG) no primeiro cenário estudado utilizando 0, 1, 5, 10 e 15 *qSoluções* no conjunto de soluções iniciais

Q Soluções	Média / Desvio Padrão		
	AG	CLONALG	VNS
0	30431317 (149990)	30384715 (129446)	30560674 (142232)
1	30500953 (147202)	30427883 (157953)	30615555 (160255)
5	30624375 (96735)	30575246 (112913)	-
10	30667067 (98946)	30582604 (96385)	-
15	30644007 (93582)	30585436 (103619)	-

A Figura 8 ilustra o VPL ao longo da execução das meta-heurísticas AG, CLONALG e VNS com diferentes quantidades de *qSoluções*. Nesta Figura é possível observar o consumo de cálculos de função objetivo pela heurística proposta, identificado pelo ponto de início do gráfico, e também o impacto desta na convergência das meta-heurísticas. Nas execuções realizadas a utilização de soluções válidas no conjunto de soluções iniciais gerou uma melhora na convergência das meta-heurísticas, especialmente ao utilizar mais do que 5 *qSoluções*.



Fonte: os autores

Figura 8 – Ilustração da convergência das meta-heurísticas estudadas utilizando diferentes quantidades de $qSoluções$. Para cada quantidade de $qSoluções$ foi realizada uma execução.

Para melhor compreensão dos resultados foi realizada a análise estatística dos dados apresentados na Tabela 3. Os resultados de todos os testes realizados encontram-se no Anexo B. Para o AG, considerando a heterogeneidade das variâncias verificada pelo teste de Levene ($2.02E-03$), a análise se deu por meio do teste não paramétrico de Kruskal-Wallis ($5.08E-10$), seguido pelo teste Dunn. O teste Dunn apontou que não existe diferença significativa entre a utilização de 0 e 1 indivíduo inicial. Entretanto, ao aumentar a quantidade de $qSoluções$ foi observado que $qSoluções$ igual a 0 e 5, 10 e 15 possuem diferenças estatisticamente significativas, indicando que a utilização da heurística pode impactar a convergência dessa meta-heurística quando utilizadas maiores quantidades de indivíduos iniciais. A comparação entre 1 indivíduo inicial e 5, 10 e 15, reforça esse resultado, mostrando que existe diferença significativa entre a utilização de 1 e uma quantidade maior de indivíduos. Por fim, não foram identificadas diferenças significativas entre o uso de 5, 10 ou 15 indivíduos iniciais.

Na avaliação do CLONALG a análise de variância de uma via apontou a presença de pelo menos uma diferença estatística entre os grupos ($1.47E-12$) e o teste Tukey realizado apresentou um resultado semelhante ao do AG. Já no VNS a análise de variância de uma via revelou que não existe diferenças estatísticas entre os grupos (0.1660). Ou seja, a utilização de somente uma solução válida não gerou diferença estatística no resultado.

5 Conclusão

Neste trabalho foi proposto o desenvolvimento de uma heurística para a obtenção de soluções válidas para um problema de planejamento florestal. O desempenho da heurística proposta foi avaliada em 3 cenários e comparado com as meta-heurísticas AG, CLONALG e VNS. Em seguida, diferentes quantidades de soluções geradas pela heurística proposta foram inseridas no conjunto de soluções iniciais das meta-heurísticas estudadas e avaliado o impacto no desempenho desses métodos. Os resultados obtidos apontam que a heurística desenvolvida pode ser uma alternativa viável para a tomada de decisão rápida no planejamento da produção florestal, uma vez que, obteve soluções válidas em 100% das execuções do primeiro cenário (original) e em 99,9% do segundo cenário, demandando para isso em média 82 e 1006 cálculos de função objetivo, respectivamente. Além disso, os resultados também indicam que as soluções geradas por essa heurística podem ser utilizadas na população inicial de meta-heurísticas como o Algoritmo Genético (AG) e o Algoritmo de Seleção Clonal (CLONALG), visando melhorar o desempenho destes.

Referências

ARAÚJO, C. A.; MENDES, J. B.; ASSIS, A. L. d.; CABACINHA, C. D.; STOCKS, J. J.; SILVA, L. F. d.; LEITE, H. G. Tuning of the metaheuristic variable neighborhood search for a forest planning problem. *Cerne*, SciELO Brasil, v. 24, p. 259–268, 2018. Citado 4 vezes nas páginas 11, 17, 29 e 33.

ARAÚJO, C. A.; MENDES, J. B.; CABACINHA, C. D.; ASSIS, A. L. d.; MATOS, L. M. A.; LEITE, H. G. Meta-heuristic clonal selection algorithm for optimization of forest planning. *Revista Árvore*, SciELO Brasil, v. 41, 2018. Citado 4 vezes nas páginas 11, 16, 28 e 33.

ARCE, J. E. *Um sistema de programação do transporte principal de multiprodutos florestais visando a minimização dos custos*. 98 p. Dissertação (Mestrado em Ciências Florestais) — Universidade Federal do Paraná, Curitiba, 1997. Citado na página 12.

BATISTA, L. de S. *Investigação de novas abordagens em sistemas imunes artificiais para otimização*. 190 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Minas Gerais, 2010. Citado 2 vezes nas páginas 15 e 28.

BERGER, R.; SANTOS, A. J. dos; JÚNIOR, R. T.; BITTENCOURT, A. M.; SOUZA, V. S. de; EISFELD, C. de L. O efeito do custo da terra na rentabilidade florestal: Um estudo de caso para santa catarina. *Floresta*, v. 41, n. 3, 2011. Citado na página 13.

CAMPOS, A. L. B. d. *Estudo de um modelo de otimização dos custos de energia elétrica do bombeamento em sistema de abastecimento de água*. 152 p. Dissertação (Mestrado em Tecnologia Ambiental e Recursos Hídricos) — Universidade de Brasília, Brasília, 2017. Citado na página 17.

CARRARO, L. A. et al. *Algoritmo de seleção clonal para a minimização de rearranjos em operações de pilhas de contêineres*. 75 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Presbiteriana Mackenzie, São Paulo, 2012. Citado na página 14.

CASTRO, L. N. D.; ZUBEN, F. J. V. The clonal selection algorithm with engineering applications. In: *Proceedings of GECCO*. [S.l.: s.n.], 2000. v. 2000, p. 36–39. Citado 2 vezes nas páginas 14 e 15.

CASTRO, L. N. de. *Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais*. Tese (Doutorado em Engenharia Elétrica) — Universidade Estadual de Campinas, Campinas, 2001. Citado 2 vezes nas páginas 14 e 15.

CHAVES, A. A. Uma meta-heurística híbrida com busca por agrupamentos aplicada a problemas de otimização combinatória. *Instituto Nacional de Pesquisas Espaciais*, 2009. Citado na página 11.

CHICHORRO, J. F.; SILVA, A. L. P. da; ANDRADE, W. S. de P.; HEGEDUS, C. E. N.; KUBOYAMA, F. Q. A. Custos e índices econômicos de povoamentos de eucalipto do programa produtor florestal no espírito santo. *Pesquisa Florestal Brasileira*, v. 37, n. 92, p. 447–456, 2017. Citado na página 10.

- FERREIRA, P. H. B.; MATOS, L. M. A.; ASSIS, A. L. de; CABACINHA, C. D.; JÚNIOR, C. A. A. Influência dos parâmetros da metaheurística simulated annealing em um problema de planejamento da produção florestal/influence of simulated annealing parameters in a forest production planning problem. *Caderno de Ciências Agrárias*, v. 10, n. 1, p. 59–67, 2018. Citado na página 17.
- FIDELIS, A. C.; REIS, R. P. Decisão no planejamento bianual da colheita florestal: o uso da programação inteira mista. *Revista de Economia e Sociologia Rural*, Editora Cubo, v. 39, n. 2, p. 9–26, 2019. Citado na página 10.
- FIORENTIN, L. D. *Estratégias de regulação de povoamentos de Pinus elliottii e Pinus taeda utilizando programação linear*. 90 p. Dissertação (Mestrado em Engenharia Floresta) — Universidade Federal do Paraná, Curitiba, 2016. Citado na página 12.
- FREITAS, J. C. de; RENATA, D. C.; FLORENTINO, H. de O. Busca em vizinhança variável para a escolha ótima de feixes no planejamento de radioterapia. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 7, n. 1, 2020. Citado na página 15.
- GASPAR-CUNHA, A.; TAKAHASHI, R.; ANTUNES, C. H. *Manual de computação evolutiva e metaheurística*. [S.l.]: Imprensa da Universidade de Coimbra/Coimbra University Press, 2012. Citado na página 14.
- GOLDBERG, D. E. Genetic algorithms in search, optimization, and machine learning. addison. *Reading*, 1989. Citado na página 14.
- GOMIDE, L. R.; ARCE, J. E.; SILVA, A. C. L. da. Uso do algoritmo genético no planejamento florestal considerando seus operadores de seleção. *Cerne*, Universidade Federal de Lavras, v. 15, n. 4, p. 460–467, 2009. Citado 2 vezes nas páginas 10 e 13.
- HILLIER, F. S.; LIEBERMAN, G. J. *Introdução à pesquisa operacional*. 9. ed. [S.l.]: McGraw Hill Brasil, 2013. Citado na página 13.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. [S.l.]: University of Michigan Press, Ann Arbor, 1975. Citado na página 13.
- IBÁ. *Relatório Anual 2020*. [S.l.], 2021. Disponível em: <<https://iba.org/publicacoes/relatorios>>. Acesso em: 31 de dez. 2021. Citado na página 10.
- JASKIU, E. *Planejamento florestal espacial atendendo exigências de áreas máximas e mínimas contínuas de colheita*. 63 p. Dissertação (Mestrado em Ciências Florestais) — Universidade Federal do Paraná, Curitiba, 2015. Citado 2 vezes nas páginas 10 e 13.
- JOHNSON, K. N.; SCHEURMAN, H. L. Techniques for prescribing optimal timber harvest and investment under different objectives—discussion and synthesis. *Forest Science*, Oxford University Press, v. 23, n. suppl_1, p. a0001–z0001, 1977. Citado na página 20.
- JUNIOR, A. A. de B.; SILVA, G. F. da; PEREIRA, G. W.; MELO, R. Aplicações de heurísticas para a solução de um problema de planejamento florestal. In: *Simpósio Brasileiro de Pesquisa Operacional*. Rio de Janeiro, Brazil: [s.n.], 2012. p. 2430–2241. Citado 2 vezes nas páginas 10 e 12.

- JÚNIOR, C. A. A.; CASTRO, R. V. O.; MENDES, J. B.; LEITE, H. G. Can linear programming assist metaheuristics in forest production planning problem? *FLORESTA*, v. 51, n. 3, p. 751–759, 2021. Citado 3 vezes nas páginas 18, 19 e 22.
- JUVENAL, T. L.; MATTOS, R. L. G. O setor florestal no brasil e a importância do reflorestamento. Banco Nacional de Desenvolvimento Econômico e Social, 2002. Citado na página 10.
- LACERDA, E. G. de; CARVALHO, A. D. Introdução aos algoritmos genéticos. *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*, v. 1, p. 99–148, 1999. Citado na página 14.
- MACHADO, C. C.; LOPES, E. da S. Análise da influência do comprimento de toras de eucalipto na produtividade e custo da colheita e transporte florestal. *Cerne*, Universidade Federal de Lavras, v. 6, n. 2, p. 124–129, 2000. Citado na página 10.
- MATOS, L. M. A.; JÚNIOR, C. A. A.; ASSIS, A. L. de; CABACINHA, C. D.; FERREIRA, P. H. B.; MAGALHÃES, E. C. Influência dos parâmetros da metaheurística algoritmo genético em um problema de planejamento florestal. *Advances in Forestry Science*, v. 6, n. 4, p. 767–774, 2019. Citado 4 vezes nas páginas 11, 17, 21 e 33.
- MELO, V. V. d. *Técnicas de Aumento de Eficiência para metaheurísticas aplicadas a otimização global contínua e discreta*. 164 p. Tese (Doutorado em Ciências da Computação e Matemática Computacional) — Universidade de São Paulo, 2009. Citado 2 vezes nas páginas 11 e 17.
- MLADENOVIC, N. A variable neighborhood algorithm-a new metaheuristic for combinatorial optimization. In: *papers presented at Optimization Days*. [S.l.: s.n.], 1995. v. 12. Citado na página 15.
- MLADENOVIC, N.; HANSEN, P. Variable neighborhood search. *Computers & operations research*, Elsevier, v. 24, n. 11, p. 1097–1100, 1997. Citado na página 15.
- NETO, R. R. d. O. *Sensibilidade do planejamento estratégico quanto a riscos e incertezas*. 40 p. Dissertação (Mestrado em Ciência Florestal) — Universidade Federal de Viçosa, Viçosa, 2016. Citado na página 12.
- NOBRE, S. R. *A heurística da razão-R aplicada a problemas de gestão florestal*. Tese (Doutorado) — Universidade Federal de Lavras, 1999. Citado 2 vezes nas páginas 10 e 13.
- OLIVEIRA, D. d. P. R. d. Planejamento estratégico: conceitos, metodologia e práticas. In: *Planejamento estratégico: conceitos, metodologia e práticas*. [S.l.: s.n.], 2007. p. 5. Citado na página 12.
- PACHECO, M. A. C. et al. Algoritmos genéticos: princípios e aplicações. *ICA: Laboratório de Inteligência Computacional Aplicada. Departamento de Engenharia Elétrica. Pontifícia Universidade Católica do Rio de Janeiro. Fonte desconhecida*, v. 28, 1999. Citado na página 14.
- PEREIRA, G. W. *Aplicação da técnica de recozimento simulado em problemas de planejamento florestal multiobjetivo*. 75 p. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de Minas Gerais, Belo Horizonte, 2004. Citado na página 21.

- PEREIRA, T. K. *Planejamento florestal otimizado de plantios de Eucalyptus spp. considerando blocos anuais de colheita*. 2016. Monografia (Bacharel em Engenharia Floresta), Universidade Federal de Paraná, Curitiba, Brazil. Citado na página 13.
- POZO, A.; CAVALHEIRO, A. d. F.; ISHIDA, C.; SPINOSA, E.; RODRIGUES, E. M. Computação evolutiva. *Universidade Federal do Paraná*, 61p. (Grupo de Pesquisas em Computação Evolutiva, Departamento de Informática-Universidade Federal do Paraná), 2005. Citado na página 14.
- RODRIGUES, F. L. *Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais*. Tese (Doutorado em Ciência Floresta) — Universidade Federal de Viçosa, Viçosa, 2001. Citado na página 12.
- RODRIGUES, F. L.; LEITE, H. G.; SANTOS, H. d. N.; SOUZA, A. L. d.; SILVA, G. F. d. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. *Revista Árvore*, SciELO Brasil, v. 28, p. 233–245, 2004. Citado na página 17.
- RODRIGUES, M. I. Categoria profissional 3º lugar: Análise financeira de investimentos em concessão florestal por meio de métodos determinísticos e estocásticos. IV Prêmio Serviço Florestal Brasileiro em Estudos de Economia e Mercado ..., 2016. Citado na página 13.
- SANTOS, B. B. *Procedimentos híbridos na exploração do espaço de soluções de problemas de natureza combinatória uma aplicação ao planejamento florestal*. 50 f. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de Viçosa, Viçosa, 2007. Citado na página 12.
- SILVA, E. E. d. *Otimização de estruturas de concreto armado utilizando algoritmos genéticos*. Tese (Mestrado em Engenharia) — Universidade de São Paulo, São Paulo, 2001. Citado na página 14.
- SILVA, G. F. d. *Problemas no uso de programação matemática e simulação em regulação florestal*. Tese (Doutorado em Ciência Florestal) — Universidade Federal de Viçosa, Viçosa, 2001. Citado 2 vezes nas páginas 10 e 13.
- SILVA, G. P. *Metaheurísticas Populacionais*. 2014. Disponível em: <<http://www.decom.ufop.br/gustavo/bcc342/AlgsPop.pdf>>. Acesso em: 19 de abril 2022. Citado na página 16.
- SOUZA, M. J. F.; MARTINS, A. X.; ARAÚJO, C.; COSTA, F. W. A. Métodos de pesquisa em vizinhança variável aplicados ao problema de alocação de salas. *XXII Encontro Nacional de Engenharia de Produção-ENEGEP, Curitiba, Brasil. Anais do XXII ENEGEP, CD-ROM*, 2002. Citado na página 16.
- SOUZA, R. F. F. *Planejamento da expansão de sistemas de distribuição usando a Metaheurística de busca em vizinhança variável*. 106 f. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual Paulista (UNESP), Ilha Solteira, 2011. Citado 2 vezes nas páginas 15 e 16.
- SOUZA, S. S.; ROMERO, R. Algoritmo imunológico artificial clonal e algoritmo genético aplicados ao problema do caixeiro viajante. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 2, n. 1, 2014. Citado na página 15.

VOLPI, N. M. P. *O impacto de perturbações estocásticas em um modelo de planejamento florestal*. 268 p. Tese (Doutorado em Ciências Florestais) — Universidade Federal do Paraná, Curitiba, 1997. Citado na página 13.

WERNEBURG, M. A. P. *Planejamento em grandes empresas florestais no Brasil*. 93 p. Dissertação (Mestrado em Ciência Florestal) — Universidade Estadual Paulista, Diamantina, 2015. Citado 2 vezes nas páginas 10 e 13.

ZAPELINI, C. Z.; LEJBMAN, A. G. vel. *Um Estudo Abrangente sobre Metaheurística, incluindo um Histórico*. 2009. Universidade de São Paulo. Disponível em: <<https://www.ime.usp.br/~gold/cursos/2009/mac5758/ChristianeHeuristics.pdf>>. Acesso em: 14 de abril 2022. Citado na página 13.

Anexos

ANEXO A – Avaliação de parâmetros

A avaliação dos parâmetros das meta-heurísticas foi realizada utilizando o critério de parada de 5.000 cálculos de função objetivo e o conjunto de soluções iniciais aleatórias. Nesse processo, para cada configuração de parâmetros foram realizadas 30 execuções e avaliada a média. Para o Algoritmo Genético (AG) foram avaliadas a seleção aleatória, roleta e torneio, o cruzamento com 1 e 2 pontos de corte e a mutação gene a gene e *swap*. Para a substituição dos indivíduos na população foram testados o Elitismo com 10 indivíduos, e a roleta e torneio elitista, com 1 indivíduo (Tabela 4). Em seguida, utilizando a melhor combinação foi testada a substituição com 5 e 10 indivíduos no elitismo. A melhor combinação encontrada foi utilizando a seleção torneio, com 1 ponto de cruzamento, mutação *swap*, e substituição torneio elitista com 10 indivíduos. Para todos os testes a probabilidade de cruzamento e mutação foram de 80% e 1%, respectivamente.

Para a meta-heurística Algoritmo de Seleção Clonal (CLONALG) foram testadas as taxas de seleção (TS) de 20 e 80 %, as de clonagem (TC) de 25 e 50%, as de hipermutação (TH) igual a 10 e 20% e a taxa de metadinâmica (TM) avaliada foi de 2 e 4% (Tabela 5). A melhor combinação encontrada consistiu a utilização de TS, TC, TH e TM igual a 20%, 25%, 10% e 2%, respectivamente. Já para a Busca em Vizinhança Variável (VNS), foram avaliadas a utilização de 2 conjuntos com 4 estrutura de vizinhança, o primeiro conjunto modifica aleatoriamente 1, 2, 3 e 4% das prescrições de talhões aleatórios e o segundo 1, 5, 10 e 15%. O número de vizinhos testados foram 10, 50, 100, 150, 200 e 250. A melhor combinação encontrada foi obtida utilizando o primeiro conjunto de estruturas de vizinhança e 200 vizinhos (Tabela 6).

Tabela 4 – Avaliação de parâmetros do Algoritmo Genético.

Seleção	Cruzamento	Mutação	Substituição	Média
Aleatória	1 ponto de cruzamento	Gene a gene	Elitismo (10)	30258089
Aleatória	1 ponto de cruzamento	Gene a gene	Roleta Elitista (1)	30122757
Aleatória	1 ponto de cruzamento	Gene a gene	Torneio Elitista (1)	30279833
Aleatória	1 ponto de cruzamento	Swap	Elitista (10)	30226495
Aleatória	1 ponto de cruzamento	Swap	Roleta Elitista (1)	30062608
Aleatória	1 ponto de cruzamento	Swap	Torneio Elitista (1)	30265323
Aleatória	2 pontos de cruzamento	Gene a gene	Elitista (10)	30256360
Aleatória	2 pontos de cruzamento	Gene a gene	Roleta Elitista (1)	30122459
Aleatória	2 pontos de cruzamento	Gene a gene	Torneio Elitista (1)	30255121
Aleatória	2 pontos de cruzamento	Swap	Elitista (10)	30253808
Aleatória	2 pontos de cruzamento	Swap	Roleta Elitista (1)	30049108
Aleatória	2 pontos de cruzamento	Swap	Torneio Elitista (1)	30243531
Roleta	1 ponto de cruzamento	Gene a gene	Elitista (10)	30281235
Roleta	1 ponto de cruzamento	Gene a gene	Roleta Elitista (1)	30193920
Roleta	1 ponto de cruzamento	Gene a gene	Torneio Elitista (1)	30299382
Roleta	1 ponto de cruzamento	Swap	Elitista (10)	30232974
Roleta	1 ponto de cruzamento	Swap	Roleta Elitista (1)	30170598
Roleta	1 ponto de cruzamento	Swap	Torneio Elitista (1)	30282712
Roleta	2 pontos de cruzamento	Swap	Elitista (10)	30211839
Roleta	2 pontos de cruzamento	Swap	Roleta Elitista (1)	30116693
Roleta	2 pontos de cruzamento	Gene a gene	Torneio Elitista (1)	30266200
Roleta	2 pontos de cruzamento	Gene a gene	Elitista (10)	30321315
Roleta	2 pontos de cruzamento	Gene a gene	Roleta Elitista (1)	30212999
Roleta	2 pontos de cruzamento	Swap	Torneio Elitista (1)	30256599
Torneio	1 ponto de cruzamento	Gene a gene	Elitista (10)	30297790
Torneio	1 ponto de cruzamento	Gene a gene	Roleta Elitista (1)	30277067
Torneio	1 ponto de cruzamento	Gene a gene	Torneio Elitista (1)	30263347
Torneio	1 ponto de cruzamento	Swap	Elitista (10)	30365480
Torneio	1 ponto de cruzamento	Swap	Roleta Elitista (1)	30236659
Torneio	1 ponto de cruzamento	Swap	Torneio Elitista (1)	30378035
Torneio	1 ponto de cruzamento	Swap	Torneio Elitista (5)	30364844
Torneio	1 ponto de cruzamento	Swap	Torneio Elitista (10)	30431317
Torneio	2 pontos de cruzamento	Gene a gene	Elitista (10)	30363114
Torneio	2 pontos de cruzamento	Gene a gene	Roleta Elitista (1)	30231031
Torneio	2 pontos de cruzamento	Gene a gene	Torneio Elitista (1)	30345061
Torneio	2 pontos de cruzamento	Swap	Elitista (10)	30336112
Torneio	2 pontos de cruzamento	Swap	Roleta Elitista (1)	30182128
Torneio	2 pontos de cruzamento	Swap	Torneio Elitista (1)	30352010

Tabela 5 – Avaliação de parâmetros do Algoritmo de Seleção Clonal. Em que TS é a taxa de seleção, TC a de clonagem, TH a de hipermutação e TM a de metadinâmica.

TS	TC	TH	TM	Média
0.2	0.25	0.1	0.02	30384715
0.2	0.25	0.1	0.04	30367127
0.2	0.25	0.2	0.02	30372501
0.2	0.25	0.2	0.04	30383147
0.2	0.5	0.1	0.02	30292088
0.2	0.5	0.1	0.04	30336000
0.2	0.5	0.2	0.02	30349281
0.2	0.5	0.2	0.04	30362312
0.8	0.25	0.1	0.02	30345239
0.8	0.25	0.1	0.04	30381162
0.8	0.25	0.2	0.02	30357988
0.8	0.25	0.2	0.04	30339533
0.8	0.5	0.1	0.02	30339157
0.8	0.5	0.1	0.04	30314983
0.8	0.5	0.2	0.02	30268897
0.8	0.5	0.2	0.04	30372638

Tabela 6 – Avaliação de parâmetros do Busca em Vizinhança Variável. A estrutura de vizinhança 1 é 1, 2, 3 e 4% e a 2 é 1, 5, 10 e 15% .

Estrutura de vizinhança	Número de Vizinhos	Média
1	10	30212952
1	50	30347325
1	100	30462167
1	150	30451690
1	200	30560674
1	250	30549188
2	10	30105798
2	50	30276589
2	100	30431278
2	150	30465268
2	200	30546415
2	250	30549515

ANEXO B – Análise estatística dos resultados das meta-heurísticas

Neste anexo são apresentados os dados que confirmaram os pressupostos necessários para a definição do tipo de teste estatístico empregado na avaliação da meta-heurística Algoritmo Genético, Algoritmo de Seleção Clonal e Busca em Vizinhança Variável, assim como os resultados dos testes aplicados. Todas as avaliações consideraram um nível de significância de 5%.

Inicialmente foi realizada a análise de normalidade utilizando o teste de Shapiro-Wilk. Este teste pressupõem a hipótese de normalidade dos dados (H_0). Portanto, um valor de $p - value < 0.05$ indica que a hipótese nula foi rejeitada, ou seja, os dados não possuem distribuição normal. Observando a Tabela 7 conclui-se que existem evidências de que os dados apresentam distribuição normal.

Tabela 7 – Resultados do teste de Shapiro-Wilk aplicado aos resultados das meta-heurísticas Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS) com diferentes quantidade de q Soluções.

Meta-heurística		0	1	5	10	15
AG	$W - stat$	0.9640	0.9418	0.9797	0.9825	0.9641
	$p - value$	0.3907	0.1017	0.8186	0.8867	0.3919
CLONALG	$W - stat$	0.9822	0.9642	0.9572	0.9596	0.9769
	$p - value$	0.8816	0.3948	0.2618	0.3030	0.7382
VNS	$W - stat$	0.9419	0.9410	-	-	-
	$p - value$	0.1025	0.0968	-	-	-

Em seguida foi realizada a análise de igualdade de variâncias (homocedasticidade) utilizando o teste de Levene. Neste teste se $p - valor$ for maior do que o nível de significância (0.05), aceita-se H_0 , ou seja, conclui-se que as variâncias são iguais em todos os grupos. Conforme apresentado na Tabela 8, o teste de Levene apontou as variâncias dos grupos da meta-heurística AG são heterogêneas e do VNS e CSA são homogêneas. Diante disso, foi aplicado o teste não paramétrico de Kruskal-Wallis para o AG e a análise de Variância (ANOVA) para as demais meta-heurísticas.

Tabela 8 – Resultados do teste de Levene aplicado aos resultados das meta-heurísticas Algoritmo Genético (AG), Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS).

Meta-heurística	$p - value$
AG	0.0020
CLONALG	0.1217
VNS	0.8147

O resultado dos testes estão apresentados na Tabela 9. A ANOVA aplicada aos dados da meta-heurística VNS apontou que com o nível de significância adotado não existem diferenças significativas entre os grupos. Já em relação ao AG e o CSA, o teste de Kruswall-Wallis e ANOVA indicaram que existe pelo menos uma diferença significativa entre os grupos. Nesse contexto, foi aplicado aos dados do AG o teste *post – hoc* Dunn e para o CSA o teste Tukey.

Tabela 9 – Resultados do teste Kruskal-Wallis aplicado ao Algoritmo Genético (AG) e ANOVA ao Algoritmo de Seleção Clonal (CLONALG) e Busca em Vizinhança Variável (VNS).

Meta-heurística	Teste	$p - value$
AG	Kruskal-Wallis	5.08E-10
CLONALG	ANOVA	1.47E-12
VNS	ANOVA	0.1660

Por fim, a Tabela 10 apresenta os resultados do teste Dunn e do teste Tukey para o AG e CLONALG, respectivamente. Ambos os testes apontaram diferença significativa entre a utilização de 0 e 5, 10 e 15 soluções válidas na população inicial. O mesmo foi observado para a utilização de 1 e 5, 10, e 15.

Tabela 10 – Resultados do teste Dunn aplicado ao Algoritmo Genético (AG) e Tukey ao Algoritmo de Seleção Clonal (CLONALG).

Grupo 1	Grupo 2	AG ($p - value$)	CLONALG ($p - value$)
0	1	0.14869	0.64788
0	5	1.14E-05	1.19E-07
0	10	7.62E-09	3.71E-08
0	15	4.88E-07	2.35E-08
1	5	3.23E-03	6.44E-05
1	10	1.47E-05	2.38E-05
1	15	3.35E-04	1.60E-05
5	10	0.16523	0.99933
5	15	0.52097	0.99761
10	15	0.45575	0.99999