São José dos Campos - SP
LV SBPO
LV Simpósio Brasileiro de Pesquisa Operacional
São José dos Campos, SP - 6 a 9 de novembro de 2023

Heurísticas para Otimização de um Problema de Transporte interconectado a um Problema Agendamento de Tarefas: Estudo de Caso da Colheita Florestal

Ana Paula Martins Guimarães Mutz, Leandro Colombi Resendo
Instituto Federal do Espírito Santo - Serra
ES-010 Km-6,5 - Manguinhos, Serra - ES, 29173-087
anapdiasguimaraes@gmail.com, leandro@ifes.edu.br

Filipe Wall Mutz
Universidade Federal do Espirito Santo
Caixa Postal 01-9011, CEP: 29060-970, Vitoria - ES - Brasil
filipemtz@gmail.com

RESUMO

A logística de transporte representa mais de 50% dos custos na colheita florestal. Portanto, otimizar essa atividade é essencial para as empresas do setor. Neste estudo, modelamos o problema da colheita florestal como um desafio de transporte interligado a agendamento de tarefas. Propusemos a implementação de três heurísticas: Algoritmos Genéticos, Algoritmo do Vagalume e um método híbrido combinando ambos. Avaliamos trinta instâncias, divididas em seis grupos, com diferentes características. Os resultados numéricos indicam que os algoritmos se adaptaram bem a diversos cenários, com tempo computacional viável para instâncias reais. Apesar de ser o método mais antigo, o algoritmo genético obteve os melhores resultados em termos de qualidade da solução e tempo de execução.

PALAVRAS CHAVE. Algoritmo Genético, Algoritmo do Vagalume, Colheita Florestal.

Tópicos:MH – Metaheurísticas; OC – Otimização Combinatória

ABSTRACT

The transportation logistics account for over 50% of the costs associated with forest harvesting. Therefore, optimizing this activity is crucial for companies in the market. In this study, we model the forest harvesting problem as a transportation problem linked to a task scheduling problem. To achieve optimization, we proposed the implementation of three heuristics: Genetic Algorithms, Firefly Algorithm, and a hybrid method combining characteristics of both. We analyzed thirty instances divided into six groups, each with distinct characteristics. The numerical results demonstrate that the analyzed algorithms were capable of adapting to different scenarios within a viable computational time frame for real-sized instances. However, despite being the oldest method, the genetic algorithm yielded the best results in terms of solution quality and computational time.

KEYWORDS. Genetic Algorithm, Firefly Algorithm, Forest Harvest.

Topics:MH – Metaheuristics; OC – Combinatorial Optimization;

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

1. Introdução

A amplitude florestal do território brasileiro, combinada às condições edafoclimáticas para a silvicultura, proporciona ao Brasil vantagens para a atividade florestal. O setor florestal contribui para a relevância social, econômica e ambiental, sendo importante para o desenvolvimento do País [Carvalho et al., 2005]. Segundo o relatório de Produção da Extração Vegetal e da Silvicultura (PEVS 2019), publicado em [IBGE, 2020], 4.867 municípios tiveram produção florestal no país em 2019. Desse total, 3.523 municípios brasileiros registraram 10 milhões de hectares de áreas de florestas plantadas, sendo 7,6 milhões de hectares de eucaliptos, o equivalente a 76,3% do total; 2 milhões de hectares de pinus (19,8%); e 387 mil hectares de outras espécies (3,9%). Esse setor gerou uma receita anual de R$ 20 bilhões.

A colheita florestal é parte importante da cadeia produtiva da celulose e na produção sustentável de madeira. No setor florestal, o transporte da madeira colhida é uma operação de alto custo [de Sousa et al., 2018]. A distância é um dos fatores que mais afetam o custo de transporte [LEITE, 1992]. Em grandes indústrias produtoras de celulose, as áreas de produção costumam ficar a centenas de quilômetros de distância da fábrica responsável pelo manuseio da madeira. O transporte florestal é realizado por caminhões, que costumam percorrer essas grandes distâncias, impactando consideravelmente os custos de produção. O planejamento da colheita florestal consiste em otimizar os processos logísticos visando minimizar os custos de produção.

No processo de colheita florestal, tem-se basicamente, a fábrica, caminhões, máquinas empilhadeiras, talhões e lotes. Um talhão florestal é resultado da subdivisão em pequenas áreas de uma floresta plantada e voltada para o suprimento industrial, com localização e dimensões bem definidas. Os talhões funcionam como depósitos ao ar livre, onde os troncos colhidos são acumulados. O lote consiste em um agrupamento de madeira de menor volume derivado de cada talhão, com a quantidade de madeira que um veículo possa carregar. No processo, os caminhões saem da fábrica em direção aos talhões, obedecendo uma rota e uma ordem de atendimento previamente programada. As máquinas empilhadeiras são responsáveis por organizar os lotes e acomodar a madeira no caminhão. Por fim, os caminhões voltam para a fábrica, podendo repetir esse processo diversas vezes, no mesmo talhão ou em talhões diferentes, conforme a programação.

Com relação aos métodos de otimização, a principal estratégia encontrada na literatura é a programação linear e inteira (PLI). Utilizando esta estratégia pode-se citar o trabalho de de Melo et al. [2012], que apresenta uma revisão de literatura sobre a utilização da técnica de programação linear como suporte para a tomada de decisão por empresas do setor florestal; Lachini et al. [2018], que apresenta um estudo com objetivo minimizar os custos de transporte de madeira de uma empresa florestal por meio da utilização de PLI; e Vieira [2018] que propõem a otimização da roteirização do transporte de máquinas florestais utilizando a PLI.

Ainda que o problema da colheita florestal possua relevância para este setor da economia, encontramos poucos trabalhos tratando da otimização da logística da colheita florestal. Silva [2015] formulou modelos de colheita por blocos e talhões, com o intuito de minimizar os custos das atividades de colheita e manutenção da rede de estradas florestais envolvida. Porém, o principal objetivo do trabalho tratou do problema de inspeção de rodovias, onde a geração de caminhos de escoamento da produção estaria sujeita a demandas de manutenção das estradas. Rudez [2015] propôs um estudo de otimização considerando restrições específicas para regiões montanhosas.

Destacamos que este trabalho é uma evolução do trabalho apresentado por Mutz et al. [2019], onde foi proposto um algoritmo genético para o problema de coleta de madeira em talhões, considerando apenas os caminhões. Diferente dos trabalhos encontrados na literatura, inclusive Mutz et al. [2019], o cenário que abordamos não trata apenas do problema de transporte da madeira

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

dos talhões à fábrica. Além disso, também trataremos do sequenciamento de tarefas das empilhadeiras. Como o número de empilhadeiras é menor do que o número de talhões é necessário interconectar o problema de transporte dos veículos com o problema do sequenciamento de tarefas das empilhadeiras. Assim, a principal contribuição desse trabalho é a proposição de heurísticas para otimização de um cenário de logística com um problema de transporte interconectado a um problema de sequenciamento de tarefas.

Considerando que o problema de transporte é um subproblema para uma colheita florestal, temos que a logística desse tipo de colheira é classificada como um problema ND-Hard. Consequentemente, modelos de PLI são incapazes de encontrar boas soluções para cenários maiores, como instâncias baseadas em situações reais. Nesse trabalho, propomos a investigação de duas meta-heurísticas para a solução do problema da colheita florestal, o Algoritmo Genético (*Genetic Algorithm* - GA) e o Algoritmo do Vagalume (*Firefly Algorithm* - FA). Adicionalmente, também foi proposto um método híbrido tentando utilizar as qualidades desses dois processos. Nos resultados numéricos, os experimentos foram divididos em 3 partes: calibração dos parâmetros dos métodos, validação da convergência dos métodos em diferentes situações e análise de escalabilidade.

O restante desse artigo está dividido da seguinte forma: a Seção 2 está apresentando a descrição do problema; na Seção 3 estão descritas as heurísticas propostas; na Seção 4 temos a descrição dos experimentos e análise dos resultados; e as conclusões estão na Seção 5.

2. DESCRIÇÃO DO PROBLEMA

Os métodos propostos neste trabalho buscam otimizar a ordem em que caminhões e empilhadeiras atendem as demandas de madeira da indústria, buscando minimizar o tempo de atendimento. Esta tarefa é parte do processo de planejamento logístico florestal, o que por sua vez é parte do problema de planejamento florestal, [Bettinger e et. al., 2016].

O planejamento florestal consiste na definição e execução de atividades que devem ser realizadas com objetivo de atender os interesses da indústria. Manejar a plantação sem um planejamento adequado pode levar à redução dos lucros e outras consequências indesejáveis, [Bettinger e et. al., 2016]. Por ter como uma das tarefas o Problema do Roteamento de Veículos (PRV), que é um problema NP-Completo ([Kumar e Panneerselvam, 2012]), o problema da colheira florestal é considerado um problema complexo. De acordo com [Silva e et. al., 2009], características como o elevado número de variáveis ou alternativas de manejo torna esse problema extremamente complexo. A necessidade de aumento da eficiência e a escassez de técnicas específicas para o auxílio à tomada de decisão dificultam elaborar um planejamento eficiente.

A colheita é uma das atividades florestais mais importantes para o planejamento florestal devido ao seu impacto nos custos de operação da empresa, [Augustynczik, 2014]. O planejamento da colheita envolve vários fatores. Um subconjunto destes fatores é o planejamento logístico que se preocupa com as distâncias entre talhões e a fábrica, número de veículos utilizados, atividade das empilhadeiras e tempo de espera. Um bom planejamento logístico é fundamental para a otimização dos custos, garantindo o rendimento esperado.

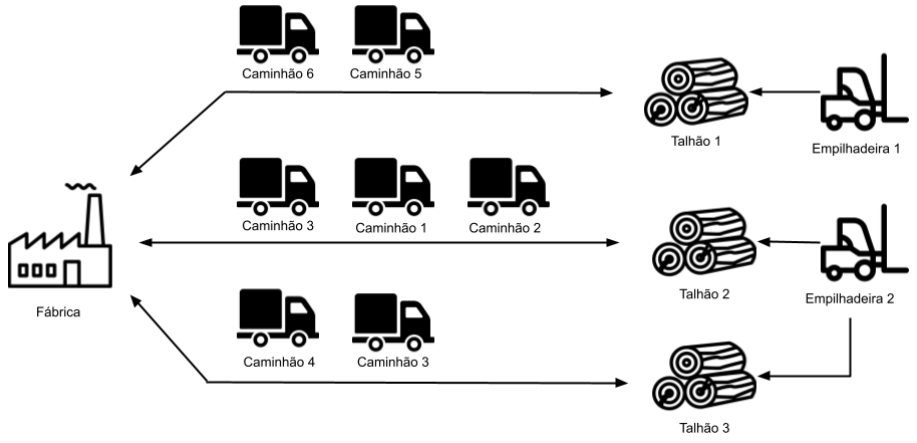
O escopo desse trabalho considera o problema de transporte que contém as operações de deslocamento dos caminhões entre a fábrica e os talhões, a atividade das empilhadeiras para o carregamento dos veículos nos talhões e o deslocamento das empilhadeiras entre os talhões. Como informação para as decisões de logística tem-se: a distância da fábrica e os talhões; número de lotes em cada talhão; e distância entre os talhões. Nesse cenário, do ponto de vista do caminhão, deve ser decidido qual veículo atenderá cada lote e a sequência de coleta dos lotes. Com isso tem-se o problema de roteamento de veículos e o sequenciamento do atendimento dos lotes. Adicionalmente, deve ser garantido que as empilhadeiras estarão nos talhões para o carregamento. Como,

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

em geral, temos menos empilhadeiras do que talhões, também é necessário elaborar a sequência de atendimento dos talhões pelas empilhadeiras. Assim, temos um problema de transporte interligado a um problema de sequenciamento de tarefas. A função objetivo adotada busca minimizar o maior tempo de atendimento dos talhões. Essa estratégia, além de otimizar o tempo de atendimento geral, também busca uma distribuição uniforme do trabalho, fazendo com que a finalização do atendimento dos talhões ocorra mais ou menos juntas.

A Figura 1 ilustra um exemplo com 3 talhões, sendo dois deles com 2 lotes e um com 3 lotes, 6 caminhões e 2 empilhadeiras. Na ilustração dessa solução o talhão 1 será atendido pelos caminhões 5 e 6, o talhão 2 será atendido pelos caminhões 2, 1 e 3, nessa ordem, e o talhão 3 será atendido pelos caminhões 3 e 4. A empilhadeira 1 atenderá o talhão 1 e a empilhadeira 2 atenderá os talhões 2 e 3, nessa ordem. Pode ser observado que a sequência de atendimento apresentada no exemplo é ruim. Pois, o caminhão 3 será um último a ser atendido pela empilhadeira 2 no talhão 2 e o primeiro do talhão 3, pela mesma empilhadeira. Assim, o caminhão 4 ficará aguardando todo atendimento do talhão 2, o deslocamento da empilhadeira e o atendimento do caminhão 3 no talhão 3. Uma opção para melhorar essa solução, bastaria que o talhão 3 seja atendido pela empilhadeira 1 e o caminhão 3 seja o primeiro da sequência de atendimento do talhão 2.

Figura 1: Representação do modelo heurístico proposto.



Não encontramos na literatura nenhum trabalho que tenha tratado a logística da colheira florestal com os seus dois sub-problemas simultaneamente, o sequenciamento dos caminhões e empilhadeiras, e a interdependência entre eles. Assim, diferente das estratégias encontradas na literatura, este trabalho propõe investigar a otimização do transporte de madeira em uma colheita florestal de forma integrada. Dada a complexidade do problema, os modelos exatos de otimização não serão capazes de encontrar soluções para instâncias de tamanho real. Considerando isso, nesse trabalho é proposto duas meta-heurísticas, o GA e o FA, além um método híbrida utilizando as duas estratégias. Como função objetivo, buscamos otimizar o tempo de atendimento do último lote, contribuindo para um planejamento de colheita com um tempo de distribuição de tarefas mais uniforme e, adicionalmente, com um custo de transporte menor.

3. Heurísticas Propostas

A seguir descreveremos as 3 estratégias propostas nesse trabalho: GA, FA e um método híbrido utilizando o GA e o FA.

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

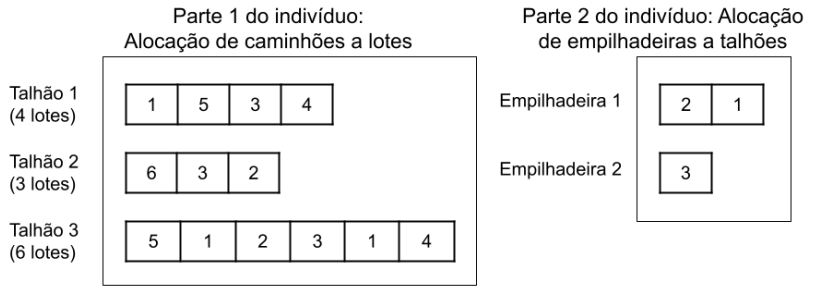
3.1. Algoritmo Genético - GA

Desenvolvido por [Holland, 1975], os Algoritmos Genéticos (AG) simulam processos encontrados na natureza como seleção, reprodução e mutação. O algoritmo é iniciado criando uma população de indivíduos, aleatoriamente. A aptidão (*fitness*) de cada indivíduo é calculada conforme a função objetivo proposta. Em seguida, os pais são escolhidos de acordo com algum método de seleção, para gerar os descendentes, podendo em alguns destes ocorrer a mutação. Após a formação dos filhos, uma nova população é criada. Ao final o algoritmo retorna o melhor indivíduo.

No Algoritmo Genético (AG), um indivíduo (correspondente a um cromossomo) representa uma solução para o problema proposto. Neste trabalho, cada indivíduo corresponde ao sequenciamento do conjunto de caminhões e empilhadeiras que atenderá cada talhão. A Figura 2 apresenta um exemplo de indivíduo. A estrutura à esquerda contém a alocação dos veículos para cada lote, enquanto a estrutura à direita contém a alocação das empilhadeiras para cada talhão. O tamanho de cada vetor na primeira parte é definido pela quantidade de lotes colhidos nos talhões, ou seja, a sua demanda. Cada posição do vetor representa um lote e cada número representa o veículo que atenderá aquele lote. No exemplo, o Talhão 1 é composto por quatro lotes atendidos por quatro caminhões diferentes, o Talhão 2 é composto por três lotes atendidos por 3 caminhões diferentes, e o Talhão 3 é composto por 6 lotes atendidos por 5 caminhões diferentes.

Na segunda parte, o tamanho de cada vetor é determinado pela quantidade de talhões atendidos pela empilhadeira correspondente, e cada número nos vetores representa um talhão. No exemplo, o Talhão 1 será atendido pela empilhadeira 1, o Talhão 2 será atendido pela empilhadeira 1, e o Talhão 3 será atendido pela empilhadeira 2. A seleção dos pais ocorre pelo método de seleção por Torneio, que envolve a escolha aleatória de dois indivíduos da população e a seleção do melhor ou pior indivíduo, dependendo de uma probabilidade k previamente definida, [Mitchell, 1996].

Figura 2: Representação de um indivíduo (solução)



Após escolher os pais, o cruzamento gera dois descendentes e cria uma nova população. Nesse processo, cada vetor da parte 1 do indivíduo gera dois novos vetores, intercalando parte dos vetores escolhidos. Porém, o cruzamento da parte de empilhadeiras é diferente. Como cada talhão requer apenas uma empilhadeira, não há repetições no sequenciamento. Após selecionar os pais, os vetores de empilhadeiras de cada pai são combinados em um vetor único. O ponto de corte é definido, e cada filho é preenchido com genes dos pais. O primeiro filho recebe a primeira parte do pai 1 até o ponto de corte, enquanto o segundo filho preenche o restante do pai 2 a partir do ponto de corte. Então, o primeiro filho recebe os genes restantes do pai 2, evitando duplicação. O segundo filho preenche os genes do pai 1, também evitando repetição. Após esse processo, cada vetor único é dividido novamente em vetores separados, correspondendo às demandas dos talhões.

A mutação ocorre com base na probabilidade definida. Pode ser a troca de posições entre veículos ou alteração na sequência de lotes de um caminhão. Para empilhadeiras, é mais simples:

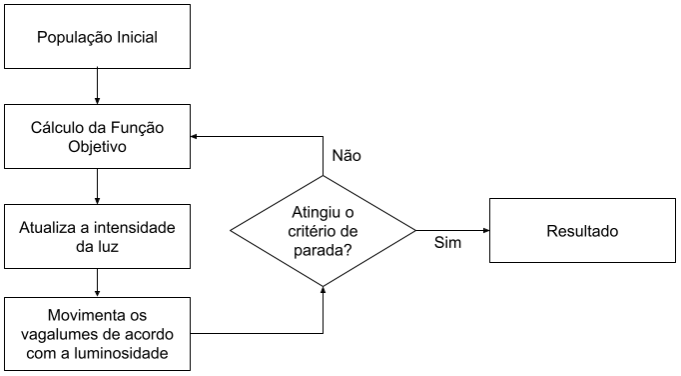
DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

se selecionado, ocorre a troca de duas empilhadeiras nos talhões. O algoritmo executa essas etapas até atingir o critério de parada, ou seja, um número predefinido de gerações.

3.2. Algoritmo do Vagalume - FA

O Algoritmo *Firefly* (Vagalume), proposto por [Yang, 2010], é baseado no comportamento dos vagalumes na natureza, em particular, a atração pela emissão luminosa. A Figura 3 apresenta a estrutura geral do algoritmo. A ideia do algoritmo é calcular o valor da função objetivo em diversos pontos do domínio, considerando que em cada um destes pontos exista um vagalume, e fazer com que o valor da função nestes pontos esteja relacionado com a intensidade da luz gerada pelos vagalumes. Na natureza, os vagalumes são atraídos por pontos com alta intensidade de luz e se movem em direção à estes pontos. Semelhantemente, no algoritmo, as soluções são ajustadas para se aproximarem dos pontos com melhor valor da função objetivo. Inicialmente, as posições dos vagalumes no espaço de busca é escolhido de forma aleatória. Em seguida, são feitas iterações, com o objetivo de fazer com que as soluções (os vagalumes) convirjam para o ponto que gera o maior brilho (melhor valor até o momento).

Figura 3: Estrutura de um Algoritmo Firefly.



Nesse processo, um vagalume de menor brilho sempre irá se mover em direção ao de maior brilho. Contudo, a atratividade é inversamente proporcional à distância, isto é, ela diminui de acordo com a distância entre os vagalumes. A intensidade da luz produzida por um vagalume e percebida por outro pode ser escrita pela Equação 1.

$$I(r) = I_0 e^{-\gamma . r^2} \tag{1}$$

Na Equação 1 temos que, r é a distância entre os vagalumes, γ é o coeficiente de absorção de luz que define quanto a intensidade diminui com a distância e I_0 é a intensidade da luz emitida.

A atratividade de um vagalume em relação a outro da população é definida com base na intensidade de luz. Este parâmetro é apresentado pela Equação 2.

$$\beta(r) = \beta_0 e^{-\gamma . r^2}; \text{onde } \beta_0 \text{ é a atratividade em } r = 0. \tag{2}$$

Como geralmente é mais rápido calcular $\dfrac{1}{1+r^2}$ do que a função exponencial, a Equação 2 pode ser aproximada como a Equação 3.

$$\beta(r) = \frac{\beta_0}{1+\gamma . r^2} \tag{3}$$

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

Os vagalumes se movem em direção àqueles que produzem maior atração. O movimento de um vagalume i em direção a um vagalume j é dado pela Equação 4.

$$x_i = x_{i0} + \beta_0 e^{-\gamma r_{ij}^2} (x_j - x_{i0}) + \alpha \left(rand - \frac{1}{2} \right) \quad (4)$$

Na Equação 4 temos que x_{i0} é a posição inicial do vagalume i, o termo $(x_j - x_{i0})$ é o vetor que conecta as posições, o termo $\beta_0 e^{-\gamma r_{ij}^2}$ define a proporção do caminho que será percorrido pelo vagalume e depende da atratividade, o termo $(rand - 1/2)$ é um fator aleatório natural do movimento dos animais e $rand$ é valor aleatório escolhido entre 0 e 1. O parâmetro α representa um passo máximo para a permutação, que consiste em n elementos. Para isso, é necessário que α faça parte do conjunto $\{1, ..., n\}$. Portanto, se α = 1 significa que nenhuma troca foi feita e se α = n significa trocar todos os elementos da permutação.

Para este trabalho foram realizadas modificações em relação à versão tradicional do algoritmo Firefly. Cada indivíduo corresponde ao sequenciamento do conjunto de caminhões e empilhadeiras que atenderá cada talhão, como na Figura 2. Após calcular o brilho de cada indivíduo da população, utilizando a função objetivo, é feita a comparação do brilho de cada indivíduo. No algoritmo tradicional um vagalume é comparado com todos da população, mas para reduzir o custo computacional (tempo) um vagalume foi comparado com outros 10 aleatórios. O cálculo da atratividade é feito utilizando a distância de Hamming, que é o número de elementos não correspondentes na sequência. Isso significa que para uma permutação se aproximar da outra permutação, a quantidade de seus elementos comuns devem aumentar, [Mohsen e Al-Sorori, 2017].

Para a parte dos veículos, pode acontecer a troca dos caminhões que irão atender os lotes. Para as empilhadeiras o processo de mover consiste em verificar se o elemento a ser movido já existe na matriz de resultado (novo vagalume) ou não. Se não existir, o elemento é inserido, se existir, a posição do elemento repetido é armazenada em uma lista auxiliar. Após esse processo, é realizada a busca por possíveis elementos que não foram adicionados no novo vagalume e esses elementos são adicionados em outra lista auxiliar. Os elementos da lista de não adicionados são reordenados para aumentar a variedade e são inseridos na matriz de resultado ocupando a posição que os elementos repetidos ocupavam. Dessa forma, o vagalume é movido sem repetição.

3.3. Modelagem Híbrida

Os algoritmos híbridos têm conquistado um espaço significativo na literatura devido ao seu potencial para obter resultados relevantes. Esses algoritmos consistem na combinação de dois ou mais algoritmos de otimização, ou seja, eles integram as características de cada meta-heurística em um único algoritmo. Para este estudo, foi desenvolvida uma heurística híbrida que utiliza o Algoritmo Genético e o Algoritmo Firefly. Esse algoritmo combina soluções provenientes dos dois algoritmos com o objetivo de proporcionar soluções mais eficazes para o problema em questão. A abordagem começa executando todas as etapas do Algoritmo Firefly. Após a obtenção do resultado, todas as fases do Algoritmo Genético são aplicadas à solução gerada anteriormente.

4. Resultados Numéricos

Os experimentos realizados neste estudo estão divididos em três etapas, cada uma com objetivos específicos. O primeiro conjunto de experimentos teve como propósito ajustar os parâmetros das heurísticas avaliadas (Algoritmo Genético e Algoritmo Firefly), além de verificar se as configurações dos parâmetros permitem a convergência dos resultados. Em seguida, foram empregados cinco conjuntos de instâncias com diferentes características para avaliar a capacidade das heurísticas implementadas em lidar com uma variedade de cenários. Por fim, utilizando mais um conjunto de

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

instâncias, foi avaliada a escalabilidade das heurísticas, ou seja, o tempo de resposta para obter soluções em cenários de aplicação real. É importante ressaltar que não foi possível realizar uma comparação direta dos resultados com os trabalhos da literatura, uma vez que não foram encontrados estudos que abordassem as mesmas restrições consideradas no nosso problema.

As experiências foram conduzidas em um sistema com um processador Intel Core i3 de 2.0GHz, equipado com quatro núcleos e 12GB de memória RAM, sob o sistema operacional Ubuntu 18.04 LTS. A heurística foi implementada utilizando a linguagem Python 3.9.6.

4.1. Planejamento dos Experimentos

As Tabelas 1 e 2 apresentam os cenários investigados, com as instâncias divididas em cinco grupos denominados G1 a G5. Cada um dos cinco grupos contém quatro talhões. A Tabela 1 exibe informações sobre as demandas de lotes em cada talhão, enquanto as colunas "Empilhadeiras"e "Caminhões"indicam as quantidades correspondentes de cada tipo de equipamento. Adicionalmente, nos grupos G1 a G4, foi considerado um tempo de viagem entre a fábrica e os talhões com pequenas variações. Enquanto o deslocamento das empilhadeiras tem tempo fixo.

Nos grupos G1, G2 e G3, as demandas de cada lote e o número de empilhadeiras disponíveis foram fixados em 2, 3 e 4, respectivamente. Nesses grupos, as instâncias simularam variações no número de veículos (caminhões). Por exemplo, no grupo G1, existem 5 instâncias, nomeadas de 1 a 5, com 4, 6, 8, 10 e 12 caminhões, respectivamente. Dessa forma, cada grupo explora a variação no número de caminhões, enquanto a variação no número de empilhadeiras é analisada entre os diferentes grupos. O grupo G4 tem como objetivo analisar as soluções em três cenários, abrangendo as instâncias de 16 a 18, variando a distribuição das demandas entre os lotes.

Grupos	Instâncias	Demandas	Empilhadeiras	Caminhões
G1	1 - 5	[7, 4, 5, 6]	2	**4 / 6 / 8 / 10 / 12**
G2	6 - 10	[7, 4, 5, 6]	3	**4 / 6 / 8 / 10 / 12**
G3	11 - 15	[7, 4, 5, 6]	4	**4 / 6 / 8 / 10 / 12**
G4	16 - 18	**[7, 7, 7, 7]** **[10, 10, 5, 5]** **[12, 12, 3, 3]**	3	8

Tabela 1: Instâncias dos grupos G1 - G4

No grupo G5, a investigação aborda a variação nas demandas e distâncias entre os lotes. Para esse grupo específico, foram consideradas 3 empilhadeiras, 9 caminhões e uma demanda de lotes de $[7, 4, 5, 6]$ nos respectivos talhões. O tempo de viagem ao percorrer o trajeto da fábrica até os talhões é denominado T_{go}. Nos experimentos desse grupo, foram analisadas duas configurações para o T_{go}. A primeira configuração envolve um T_{go} homogêneo, que simula uma distribuição uniforme entre os talhões. A segunda configuração apresenta um T_{go} com uma grande variação, que simula um cenário em que um ou dois talhões estão mais afastados. De maneira similar, foram considerados tempos de viagem realizados pelas empilhadeiras entre cada par de talhões (De).

A Tabela 3 apresenta as instâncias investigadas do grupo G6. Neste grupo, 9 instâncias foram utilizadas para investigar a escalabilidade das heurísticas e seu comportamento para a variação de lotes, veículos e empilhadeiras.

4.2. Calibração do GA e FA

A calibração de uma heurística envolve encontrar a combinação ideal de parâmetros que resulta em melhores resultados. Para realizar esses testes, a instância 22 foi selecionada para ambas as heurísticas (GA e FA), uma vez que se assemelha a cenários reais. Durante os experimentos, cada combinação de parâmetros foi executada cinco vezes, com o melhor resultado sendo escolhido.

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

Grupos	Instâncias	Tempo dos caminhões	Tempo das empilhadeiras
G5	19	T_{go} = [4, 4, 4, 4]	$De[a][b] = 8; \forall a, b \in W : a \neq b$
	20	T_{go} = [10, 10, 2, 2]	$De = \begin{bmatrix} 0 & 1 & 7 & 10 \\ 1 & 0 & 6 & 9 \\ 7 & 6 & 0 & 3 \\ 10 & 9 & 3 & 0 \end{bmatrix}$
	21	T_{go} = [1, 12, 2, 2]	$De = \begin{bmatrix} 0 & 15 & 1 & 2 \\ 15 & 0 & 14 & 13 \\ 1 & 14 & 0 & 1 \\ 2 & 13 & 1 & 0 \end{bmatrix}$

Tabela 2: Instâncias do grupo G5

G6			
Instância	Lotes	Caminhões	Empilhadeiras
22	10	20	10
23	10	40	5
24	20	20	10
25	20	40	40
26	30	20	10
27	30	40	20
28	50	20	20
29	50	30	20
30	50	40	40

Tabela 3: Instâncias do grupo G6

No caso do Algoritmo Genético (GA), três parâmetros foram calibrados: tamanho da população, número de gerações e probabilidade de mutação. Para ajustar o tamanho da população, foram testadas populações com 25, 50, 75, 100, 125, 150, 175 e 200 indivíduos. Foram consideradas 1000 gerações e uma taxa de mutação de 10%. A melhor configuração foi alcançada com 100 indivíduos, resultando em um valor de aptidão (fitness) de 144. Entretanto, é válido destacar que o tamanho da população teve um impacto limitado nos resultados, já que a média dos resultados foi de 149. Após ajustar esse parâmetro, o número de gerações foi calibrado considerando uma população de 100 indivíduos e taxa de mutação de 10%. Foram testadas execuções com 250, 500, 750, 1000, 1250, 1500, 1750 e 2000 gerações, sendo que a melhor configuração foi obtida com 500 gerações, resultando em um valor de aptidão de 149. Com a população fixada em 100 indivíduos e 500 gerações, a probabilidade de mutação foi testada com valores de 0%, 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90% e 100%. O melhor resultado foi obtido com 70%.

Experimentos análogos foram realizados para ajustar os cinco parâmetros do Algoritmo *Firefly* (FA): tamanho da população, número de gerações, γ, β e α. As variações analisadas para o tamanho da população e o número de gerações no FA foram as mesmas utilizadas no GA. As variações dos parâmetros γ, β e α no FA foram as mesmas empregadas para a mutação no GA. Dessa forma, após a calibração dos parâmetros, a configuração final para o FA ficou definida como: Tamanho da população = 125; Número de gerações = 1000; γ = 0.1; β = 0,8; e α = 0,5.

4.3. Resultados Numéricos

As Tabelas 4 e 5 apresentam os resultados obtidos por meio dos três métodos heurísticos em todas as instâncias investigadas. Nos grupos G4, G5 e G6, o número de caminhões é mantido constante, enquanto nos grupos G1, G2 e G3 a variação desse número é analisada. Dessa forma, as tabelas também incluem a informação sobre o número de caminhões em cada instância.

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

A partir da Tabela 4, podemos observar que no grupo G1, o aumento no número de caminhões resultou em uma diminuição praticamente linear do valor da função objetivo para os três métodos implementados. Essa tendência também se mantém nas instâncias dos grupos G2 e G3. No entanto, dado que as instâncias desses grupos possuem 4 talhões, enquanto nos grupos G1, G2 e G3 são consideradas 2, 3 e 4 empilhadeiras, respectivamente, esperava-se uma redução significativa na função objetivo para o grupo G3. Isso ocorre porque, nesse cenário, não haveria necessidade de deslocamento das empilhadeiras entre os talhões. Esse resultado demonstra que os algoritmos conseguiram gerenciar eficazmente a distribuição de tarefas entre os caminhões, de modo que o resultado não foi afetado pelo deslocamento das empilhadeiras.

Grupo	Instância	Caminhões	GA		FA		Híbrido	
			F.O.	Tempo	F.O.	Tempo	F.O.	Tempo
1	1	4	44,0	21,41	42,0	43,21	45,0	51,33
	2	6	27,0	9,60	30,0	44,30	30,0	50,33
	3	8	21,5	19,11	22,5	63,58	22,5	65,44
	4	10	17,0	19,09	20,0	56,21	19,0	60,65
	5	12	13,5	11,03	16,5	57,62	17,0	80,45
2	6	4	43,5	19,15	42,5	76,00	44,5	54,57
	7	6	27,5	11,68	27,0	47,32	29,0	75,15
	8	8	21,5	12,74	23,5	47,71	23,0	85,32
	9	10	16,5	18,89	17,0	52,44	18,5	56,09
	10	12	15,0	14,22	15,5	87,12	16,0	54,66
3	11	4	43,5	9,58	41,5	57,72	44,0	53,88
	12	6	28,0	9,02	26,0	55,34	28,5	57,70
	13	8	20,0	13,97	22,5	61,94	22,0	80,08
	14	10	15,5	18,45	16,5	56,45	17,0	69,43
	15	12	14,5	18,76	15,0	91,94	15,0	104,33

Tabela 4: Resultados das Heurísticas para os Grupos 1, 2 e 3

A Tabela 5 fornece os resultados obtidos pelos algoritmos nos grupos G4, G5 e G6. No grupo G4, as instâncias mantêm o número de caminhões e empilhadeiras constantes, variando apenas a quantidade de lotes nos talhões. Isso é feito com distribuição homogênea (instância 16) e heterogênea (instâncias 17 e 18). Os resultados mostram que os três métodos conseguiram resultados semelhantes entre as instâncias, indicando que eles foram capazes de tratar a variação nas demandas. No grupo G5, a variação na distribuição dos talhões é avaliada. Os resultados revelam que um talhão mais distante influencia significativamente os resultados, independentemente do método aplicado. O grupo G6 tem como objetivo avaliar a aplicabilidade dos métodos em cenários reais, onde o tempo de processamento (em segundos) é analisado. Nesse experimento, o Algoritmo Genético tradicional obteve soluções melhores e consideravelmente mais rápido do que o Algoritmo Firefly (FA) e o Híbrido. Esperava-se que o Híbrido obtivesse um tempo de processamento maior, porém, em contrapartida, os resultados deveriam ter sido melhores do que os do AG.

Ao comparar os métodos heurísticos implementados, pode-se observar que, em geral, o Algoritmo Genético obteve os melhores resultados. Embora se esperasse que o Algoritmo Firefly alcançasse resultados superiores, dada sua natureza mais moderna, o FA não somente obteve os resultados mais baixos, mas também não permitiu que as soluções fossem aprimoradas de forma significativa pelo Algoritmo Genético na abordagem híbrida.

5. Conclusão

Este trabalho investigou um problema de otimização resultante da integração entre o problema de roteamento de veículos e o problema de agendamento de tarefas. A aplicação prática que

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

Grupo	Instância	GA		FA		Híbrido	
		F.O.	Tempo	F.O.	Tempo	F.O.	Tempo
4	16	28,0	21,77	30,0	83,55	31,0	100,47
	17	28,0	22,72	32,5	89,30	31,0	108,46
	18	26,0	22,91	32,0	51,33	29,0	57,15
5	19	25,0	11,74	25,0	59,61	21,5	55,75
	20	32,5	18,30	33,0	60,53	32,5	104,45
	21	42,5	21,53	43,0	45,82	43,0	52,67
6	22	137,5	45,28	139	165,53	153,5	183,89
	23	73,0	45,08	113,5	147,02	85,5	171,07
	24	245,0	68,14	409,0	270,99	242,5	339,12
	25	98,5	65,78	187,0	325,48	117,0	355,03
	26	493,0	109,3	985,0	430,75	630,0	478,90
	27	194,0	100,15	312,5	485,40	167,0	510,88
	28	683,0	167,05	1473,5	871,01	778,5	1037,44
	29	551,0	155,61	1130,0	858,67	569,0	865,94
	30	522,5	165,58	912,5	1121,26	417,0	1691,85

Tabela 5: Resultados das Heurísticas para os Grupos 4, 5 e 6

motivou essa investigação está relacionada com a otimização logística de uma colheita florestal. Nesse contexto, o desafio é agendar caminhões e empilhadeiras que transportam troncos de madeira durante o processo de colheita florestal. A resolução eficiente desse problema é de grande interesse para a indústria madeireira, já que a otimização do uso dos recursos e a melhoria nos tempos de atendimento das demandas podem levar à redução de custos e ao aumento dos lucros. Para abordar essa problemática da colheita florestal, exploramos a aplicação de três heurísticas distintas: Algoritmo Genético, Algoritmo do Vagalume e um método híbrido que combina características dessas duas heurísticas. Para avaliar o desempenho das heurísticas, utilizamos um conjunto de 30 instâncias divididas em 6 grupos.

A primeira etapa dos experimentos foi dedicada à calibração dos parâmetros tanto para o Algoritmo Genético quanto para o Algoritmo do Vagalume. Após essa calibração, os três métodos foram submetidos à avaliação. Os primeiros três grupos de instâncias (G1, G2 e G3) exploraram a variação do número de caminhões e empilhadeiras disponíveis, visando quantificar o impacto do aumento desses equipamentos na capacidade de atender às demandas. O grupo G4 investigou variações na distribuição das demandas entre os talhões, enquanto o grupo G5 analisou as variações nas distâncias percorridas por caminhões e empilhadeiras. Além disso, todos os três métodos demonstraram adaptabilidade a essas variações nos grupos G4 e G5. Finalmente, o grupo G6 testou a escalabilidade das heurísticas, avaliando a capacidade de lidar com cenários de aplicação real. Embora o método híbrido tenha requerido mais tempo de processamento, todos os três métodos conseguiram atender aos cenários. No entanto, o Algoritmo Genético, apesar de ser a técnica mais tradicional, se destacou ao obter os melhores resultados e o menor tempo computacional.

Dado que não encontramos na literatura uma base de dados para a comparação de resultados, um ponto de melhoria para trabalhos futuros consiste em desenvolver um modelo de Programação Linear Inteira (PLI) para gerar *benchmarks*, a fim de proporcionar uma base sólida para a avaliação das heurísticas propostas.

6. Agradecimentos

Agradecemos a FAPES (Fundação de Amparo à Pesquisa e Inovação do Espírito Santo) e a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo apoio financeiro dado por meio do PDPG (Parcerias Estratégicas nos Estados da CAPES).

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981

Referências

Augustynczik, A. L. D. (2014). *Planejamento florestal otimizado considerando áreas mínimas e máximas operacionais de colheita*. PhD thesis, Master thesis, Universidade Federal do Paraná.

Bettinger, P. e et. al. (2016). *Forest management and planning*. Academic press.

Carvalho, R. M. M. A., Soares, T. S., e Valverde, S. R. (2005). Caracterização do setor florestal: uma abordagem comparativa com outros setores da economia. *Ciência Florestal*, 15(1):105–118.

de Melo, R. A. T., de Souza, M. D., Junior, R. T., Ribeiro, E. S., Dorval, A., et al. (2012). Utilização de programação linear na análise do transporte principal de madeira. *Multitemas*.

de Sousa, P. R., Lopes, D. P. T., Andrade, S. C., e de Resende, P. T. V. (2018). Terceirização das atividades florestais na indústria de celulose e papel. *Revista de Admin. IMED*, 8:260–280.

Holland, J. (1975). Adaptation in natural and artificial systems, univ. of mich. press. *Ann Arbor*.

IBGE (2020). Produção da extração vegetal e da silvicultura 2019. *ISSN 0103-8435*.

Kumar, S. e Panneerselvam, R. (2012). A survey on the vehicle routing problem and its variants. *Intelligent Information Management*, 4(3):66–74.

Lachini, E., FIEDLER, N. C., da SILVA, E. F., VIEIRA, G. C., de SOUZA, L. A., e do CARMO, F. C. d. A. (2018). Pesquisa operacional na minimização de custos de transporte florestal. *Revista Brasileira de Biometria*, 36(2):473–488.

LEITE, A. (1992). *Análise dos fatores que afetam o desempenho de veículo e o custo de transporte de madeira no distrito florestal do Vale do Rio Doce/MG. 1992. 105p*. PhD thesis, Universidade Federal de Viçosa.

Mitchell, M. (1996). An introduction to genetic algorithms. cambridge.

Mohsen, A. M. e Al-Sorori, W. (2017). A new hybrid discrete firefly algorithm for solving the traveling salesman problem. In *Applied Comp. and Inform. Techn.*, p. 169–180. Springer.

Mutz, A., Resendo, L., e Rosa, R. (2019). Otimização do problema da colheita floresta utilizando um algoritmo genético. In *33º Congresso de Pesquisa e Ensino em Transporte ANPET*, p. 2634–2643, Camboriú - SC. ANPET.

Rudez, A. (2015). *Planejamento de Colheita de Madeira em Região Montanhosa com Uso de Modelagem Espacial e Programação Linear Inteira*. PhD thesis, Dissertação apresentada à Universidade Estadual do Centro-Oeste.

Silva, G. F. e et. al. (2009). Metaheurística algoritmo genético na solução de modelos de planejamento florestal. *Revista Brasileira de Ciências Agrárias*, 4(2):160–166.

Silva, P. (2015). *Planejamento otimizado da colheita florestal por blocos e talhões integrado à rede de estradas*. PhD thesis, Universidade Federal do Paraná. Curitiba, Parana, Brasil.

Vieira, G. (2018). Modelagem matemática do transporte de máquinas em florestas de produção.

Yang, X.-S. (2010). *Nature-inspired metaheuristic algorithms*. Luniver press.

DOI: 10.59254/sbpo-2023-174981
http://live-proceedings.pantheonsite.io/p/174981