

Comparação da estimativa de Biomassa Florestal em Ecossistemas Tropicais Utilizando OLS, Modelos Multinível e Algoritmos Genéticos: Uma Abordagem Integrada ao AHP Gaussiano

Gilmara de Oliveira Machado (UNICENTRO) gmachado@unicentro.br

Eric Bacconi Gonçalves(PUC) ebgoncalves@pucsp.br

Yasmin Nunes Alves (UFF) ynalves@id.uff.br

Agnieszka Pawlicka (USP) agnieska@iqsc.usp.br

Marcos dos Santos (UFF/IME) marcosdossantos@ime.ub.br

Resumo

A quantificação precisa da biomassa aérea em ecossistemas tropicais é essencial para o monitoramento do carbono e o manejo sustentável das florestas. Métodos tradicionais, como a regressão linear simples, apresentam limitações, exigindo abordagens mais avançadas, existindo uma multiplicidade de modelos estatísticos e de aprendizado de máquina disponíveis, o que emerge o problema de pesquisa de identificar o modelo mais adequado para estimar a biomassa acima do solo. Este estudo teve como objetivo aplicar o método multicritério AHP Gaussiano para avaliar e ranquear modelos de regressão linear simples (OLS), regressão multinível (MN) e algoritmo genético (AG), com base em diferentes critérios de qualidade de ajuste. A metodologia consistiu na calibração dos modelos com dados de 4004 árvores provenientes de 27 países tropicais, seguida da avaliação por métricas estatísticas (MSE, RMSE, MAE, MAPE e R^2). Essas métricas foram ponderadas por meio do AHP Gaussiano, permitindo integrar precisão, consistência e capacidade explicativa em uma única estrutura decisória. Os resultados indicaram maior peso para MSE e MAPE, refletindo sua relevância na minimização de erros absolutos e relativos. O modelo multinível apresentou a melhor performance global no ranqueamento multicritério, seguido pelo algoritmo genético e pelo OLS. Conclui-se que o AHP Gaussiano constitui uma ferramenta robusta para apoiar decisões metodológicas em modelagem florestal, promovendo maior rigor e transparência na seleção de modelos para estimativas de biomassa.

Palavras-Chave: *AHP Gaussiano, Biomassa florestal, Modelos multinível.*

Abstract

Accurate quantification of aboveground biomass in tropical ecosystems is essential for carbon monitoring and sustainable forest management. Traditional methods, such as simple linear regression, present limitations, requiring more advanced approaches. There is a wide variety of statistical and machine learning models available, which raises the research problem of identifying the most suitable model for estimating aboveground biomass. This study aimed to apply the Gaussian AHP multicriteria method to evaluate and rank simple linear regression models (OLS), multilevel regression (MN), and genetic algorithms (GA), based on different goodness-of-fit criteria. The methodology consisted of calibrating the models using data from 4,004 trees from 27 tropical countries, followed by evaluation through statistical metrics (MSE, RMSE, MAE, MAPE, and R^2). These metrics were weighted using the Gaussian AHP method,



allowing the integration of accuracy, consistency, and explanatory power into a single decision-making framework. The results indicated greater weight for MSE and MAPE, reflecting their relevance in minimizing absolute and relative errors. The multilevel model showed the best overall performance in the multicriteria ranking, followed by the genetic algorithm and OLS. It is concluded that Gaussian AHP constitutes a robust tool to support methodological decisions in forest modeling, promoting greater rigor and transparency in the selection of models for biomass estimation

Keywords: *Forest biomass, Gaussian AHP, Multilevel models.*

1. Introdução

A estimativa da biomassa acima do solo, do inglês, *aboveground biomass* (AGB), em ecossistemas tropicais desempenha papel central no monitoramento do carbono, na modelagem climática e na formulação de políticas de mitigação das mudanças climáticas (Nunes *et al.*, 2020). Tradicionalmente, a AGB é estimada por meio de modelos alométricos baseados em variáveis dendrométricas individuais, em outras palavras, por equações matemáticas que estimam características biológicas das árvores, como diâmetro à altura do peito, altura total e densidade básica da madeira (Chave *et al.*, 2014).

A elevada heterogeneidade estrutural das florestas tropicais, influenciada por fatores climáticos, atributos do solo e biogeográficos, impõe desafios adicionais à modelagem da biomassa, conforme ressaltado por Ehbrecht *et al* (2021). Modelos estatísticos tradicionais, como os Mínimos Quadrados Ordinários, embora amplamente utilizados, assumem relações lineares simplificadas e independência das observações, o que pode limitar sua capacidade de capturar estruturas hierárquicas presentes nos dados florestais. Nesse contexto, modelos multinível têm se mostrado mais adequados para representar variações intra e entre grupos, especialmente quando há dependência geográfica ou ecológica (Abreu *et al.*, 2020; Feng *et al.*, 2021; Cysneiros *et al.*, 2024). Paralelamente, técnicas de aprendizado de máquina têm sido exploradas para modelar relações não lineares complexas, ampliando o potencial preditivo das estimativas de biomassa (Li *et al.*, 2020; Luo *et al.*, 2024).

Isto posto, este trabalho tem como objetivo identificar o modelo estatístico mais adequado para estimar a biomassa acima do solo visto que a escolha baseada em um único indicador estatístico pode conduzir a decisões parciais, uma vez que cada métrica captura dimensões distintas da qualidade do ajuste. Nesse cenário, a Análise Multicritério de Apoio à Decisão surge como uma estrutura metodológica capaz de integrar múltiplos critérios, ponderando sua relevância relativa e promovendo maior rigor na seleção de alternativas (Santos *et al.*, 2021).

Entre os métodos multicritério, o *Analytic Hierarchy Process* (AHP) destaca-se por sua capacidade de estruturar problemas complexos em níveis hierárquicos e atribuir pesos relativos aos critérios de decisão. A versão Gaussiana do AHP (AHP-G) aprimora essa abordagem ao incorporar fatores de normalização baseados em distribuição gaussiana, reduzindo inconsistências e permitindo maior robustez na agregação dos critérios (Santos *et al.*, 2021).

Diante desse contexto, este estudo propõe um arcabouço metodológico orientado pela análise multicritério, no qual os modelos OLS, multinível e algoritmo genético são avaliados não apenas sob a ótica preditiva, mas também por meio de uma estrutura decisória integrada baseada no AHP-G ordenando as abordagens quando utilizadas para análise estimativa de biomassa florestal. Para isso, este artigo é composto por essa introdução, seguido pelo referencial teórico aplicável, assim como a metodologia, estudo de caso e considerações finais.

2. Referencial Teórico

2.1 Biomassa Florestal

O aumento da concentração de dióxido de carbono (CO_2) na atmosfera constitui um dos principais vetores das mudanças climáticas globais, intensificando o efeito estufa e elevando a temperatura média do planeta (Solomon *et al.*, 2009). Nesse contexto, as florestas desempenham papel estratégico, pois atuam como importantes sumidouros de carbono por meio do processo de fotossíntese, no qual o carbono atmosférico é fixado e incorporado à estrutura vegetal, fenômeno conhecido como sequestro de carbono.

A vegetação terrestre, especialmente as florestas tropicais, representa o principal reservatório natural de carbono em ambientes terrestres (Ehbrecht *et al.*, 2021). Entretanto, perturbações como desmatamento e queimadas liberam novamente o carbono estocado, contribuindo para desequilíbrios climáticos significativos (Nunes *et al.*, 2020). Assim, a quantificação precisa da biomassa florestal torna-se fundamental para compreender o papel das florestas no equilíbrio climático global.

Biomassa florestal é definida como a quantidade total de matéria orgânica acumulada pelos componentes vegetais de um ecossistema florestal, geralmente expressa em massa seca por unidade de área (Mg/ha). Entre seus compartimentos, destaca-se a biomassa acima do solo, que inclui tronco, galhos, folhas e casca, representando aproximadamente metade do estoque global de carbono terrestre (Becattini *et al.*, 2022), considerado o principal indicador para estimativas de carbono florestal, e sendo amplamente utilizada em inventários nacionais, modelagens climáticas e políticas ambientais.

Tradicionalmente, a estimativa da biomassa pode ser realizada pelo método direto, conhecido como gravimétrico, que consiste na colheita da árvore, separação de seus compartimentos e pesagem direta da biomassa. Trata-se do método mais preciso, porém destrutivo, oneroso e operacionalmente inviável em larga escala (Chave *et al.*, 2014). Por esse

motivo, sua aplicação é geralmente restrita à calibração de modelos indiretos, baseados em variáveis individuais, como diâmetro à altura do peito, altura total e densidade básica da madeira (Chave *et al.*, 2014) e conhecidos como modelos alométricos. Esses modelos estabelecem relações matemáticas entre atributos estruturais da árvore e sua biomassa, permitindo estimativas indiretas sem necessidade de métodos destrutivos.

Entretanto, a aplicação indiscriminada de equações alométricas em diferentes contextos ecológicos pode gerar vieses significativos, especialmente em florestas tropicais, caracterizadas por alta heterogeneidade estrutural e diversidade de espécies (Sileshi, 2014; Temesgen *et al.*, 2015). Estudos como os realizados por Ehbrecht *et al.*, (2021) e Ma *et al.*, (2024) ressaltam que fatores climáticos, estruturais e edáficos influenciam diretamente a variação espacial da biomassa, reforçando a necessidade de modelos mais flexíveis e adaptativos

Modelos de regressão linear simples (OLS) são amplamente utilizados na modelagem alométrica devido à sua simplicidade e fácil interpretação. Contudo, assumem independência entre observações e relações lineares fixas, o que pode limitar sua capacidade explicativa em dados com estrutura hierárquica (Fu *et al.*, 2012).

Já em ecossistemas tropicais, as árvores estão organizadas em níveis hierárquicos naturais, configurando dependência intra-grupo e heterogeneidade entre unidades amostrais. Nesse contexto, modelos multinível ou de efeitos mistos têm sido largamente empregados para capturar variações intra e entre grupos, incorporando efeitos aleatórios e melhorando a precisão das estimativas (Cysneiros *et al.*, 2024). Esses modelos permitem representar diferenças regionais e ecológicas, aumentando a capacidade preditiva e reduzindo erros sistemáticos quando comparados aos modelos lineares tradicionais.

O avanço das técnicas de aprendizado de máquina ampliou as possibilidades de modelagem da biomassa florestal. Métodos como Random Forest, redes neurais artificiais e XGBoost têm sido aplicados para capturar relações não lineares complexas entre variáveis dendrométricas e biomassa (Li *et al.*, 2020; Luo *et al.*, 2024).

Entre essas técnicas, algoritmos genéticos destacam-se como métodos de otimização inspirados na evolução biológica, capazes de explorar grandes espaços de busca e encontrar soluções próximas do ótimo global (Moghimi *et al.*, 2024). No contexto florestal, têm sido utilizados para ajuste de parâmetros e seleção de variáveis, contribuindo para aprimorar o desempenho de modelos estatísticos tradicionais.


Apesar do potencial preditivo dessas abordagens, a multiplicidade de métricas de desempenho (MSE, RMSE, MAE, MAPE e R^2) pode conduzir a resultados conflitantes quanto à escolha do modelo mais adequado. Assim, torna-se necessária uma estrutura sistemática para apoiar a decisão metodológica, para isso, os métodos multicritérios surgem com uma alternativa para suportar a decisão de qual abordagem utilizar.

2.2 AHP Gaussiano

A versão Gaussiana do AHP foi desenvolvida por Santos *et al.* (2021) ao incorporar um fator de normalização baseado em distribuição gaussiana, reduzindo distorções decorrentes de escalas heterogêneas e aumentando a robustez da agregação dos critérios ao método AHP proposto por Saaty (1987). A característica inserida ao método o tornou particularmente relevante na avaliação de modelos estatísticos, cujas métricas possuem magnitudes distintas e comportamentos variáveis.

O artigo seminal, originalmente aplicou o método para seleção de navios de guerra, no entanto, como pode ser observado na Figura 1, desde sua publicação, o método vem sendo amplamente utilizado, seja em aplicações civis ou militares.

Figura 1 – Mapa Visual AHP Gaussiano



Fonte: Litmaps (2026)

No contexto da modelagem de biomassa florestal, a aplicação do AHP Gaussiano permite integrar múltiplas métricas de qualidade de ajuste em uma estrutura decisória única, promovendo maior transparência e rigor científico na seleção do modelo mais adequado.

Para isso, os autores do método destacam que o mesmo deve ser utilizado em problemas com entradas quantitativas, e orientam a execução de 6 etapas, conforme descrito em Santos *et al.*, (2024):

1. Definição da matriz de decisão;
2. Normalização;
3. Cálculo da média e desvio padrão das alternativas;
4. Cálculo do Fator Gaussiano;
5. Agregação das Importância;
6. Ordenação das alternativas.

Sendo assim, devem ser definidos os critérios e alternativas, construindo a matriz de decisão onde o método AHP-G será aplicado. Como já dito anteriormente, diferente do método AHP original, o método Gaussiano trabalha apenas com matrizes quantitativas.

A Normalização da Matriz é feita por meio da Equação 1.

$$x_{ij} = \frac{a_{ij}}{\sum_{i=1}^n a_{ij}} \quad (1)$$

Um ponto de atenção se dá aos critérios monotônicos de custo, que devem ser convertidos antes da normalização. Para isso, o valor convertido será $\frac{1}{a_{ij}}$. Apenas após a conversão, exclusivamente dos critérios monotônicos de custo, que os mesmos poderão ser normalizados.

Após a normalização, são definidos os cálculos das médias e desvio padrão das alternativas, conforme as equações 2 e 3, respectivamente, já conhecidas na estatística.

$$\bar{x}_j = \frac{\sum_{i=1}^n x_{ij}}{n} \quad (2)$$

$$\sigma_j = \frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2}{n} \quad (3)$$

Com tais valores definidos, se torna possível determinar o fator gaussiano, utilizando a equação 4.

$$g_j = \frac{\sigma_j}{x} \quad (4)$$

Sendo assim, a Equação 5 descreve a determinação dos pesos de cada um dos critérios, onde o fator gaussiano é dividido pela soma de todos os fatores gaussianos.

$$w_j = \frac{g_j}{\sum_{j=1}^m g_j} \quad (5)$$

O processo de agregação é o ultimo cálculo realizado antes da ordenação das alternativas, e se trata da ponderação dos pesos individuais das alternativas em cada critérios, conforme os pesos previamente estabelecidos. Para isso, a Equação 6 é utilizada.

$$v_i = \sum_{j=1}^m w_j x_{ij} \quad (6)$$


Isto posto, quanto maior o valor obtido, melhor classificada será a alternativa, tornando possível a ordenação das mesmas.

3. Metodologia

O presente artigo caracteriza-se como uma pesquisa aplicada, de natureza exploratória e analítico-quantitativa, estruturada a partir de modelagem estatística, técnicas de aprendizado de máquina e análise multicritério de apoio à decisão. O delineamento metodológico foi composto por uma revisão da literatura que discute a modelagem alométrica da biomassa florestal, aos modelos multinível, às técnicas de machine learning e aos fundamentos do (MCDA), com ênfase no AHP-G proposto por (Santos *et al.*, 2021) e usado na seleção do modelo mais adequado à estimativa da biomassa acima do solo (AGB).

A etapa empírica foi desenvolvida com base em dados secundários provenientes do banco global de biomassa florestal disponibilizado por Chave *et al.* (2014), composto por 4004 árvores distribuídas em 27 países tropicais. As variáveis utilizadas incluíram biomassa aérea de referência (AGB_ref), diâmetro à altura do peito (DAP), altura total (Ht) e densidade básica da madeira (DB).

O estudo foi organizado em quatro etapas metodológicas, conforme a Figura 2.

Figura 2 – Etapas Metodológicas


No que se refere aos pacotes e funções, necessárias para a implementação dos algoritmos, foi usado o software R para toda modelagem realizada nesta pesquisa. O pacote nlme (Pinheiro et al., 2021) foi utilizado para realizar análises tradicionais e de modelos multinível de regressão linear, no caso desta pesquisa, de dois níveis: nível árvore e país de origem da árvore. A função nlme permite ajustar esses modelos, levando em consideração a correlação potencial entre as observações dentro dos grupos, incluindo efeitos aleatórios e fixos nas análises. Para ajuste do modelo de aprendizado de máquina, algoritmo genético, foi utilizado o pacote GA.


Para avaliar o erro dos modelos desenvolvidos para estimar a biomassa aérea das árvores foram utilizadas as seguintes métricas: MSE (*Mean Squared Error*), RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*), MAPE (*Mean Absolute Percentage Error*) e R^2 . Cada uma dessas métricas fornece uma perspectiva diferente sobre o desempenho do modelo e contribui para uma avaliação abrangente.

A utilização de uma abordagem quantitativa integrada à análise multicritério permitiu não apenas avaliar a precisão preditiva dos modelos, mas também estruturar a decisão metodológica de forma transparente e fundamentada. A combinação entre modelagem empírica e AHP Gaussiano estabeleceu uma base robusta para a seleção do modelo mais consistente para estimativas de biomassa em ecossistemas tropicais, ampliando o rigor analítico na interface entre modelagem ecológica e pesquisa operacional.

4. Descrição do Problema

Com o objetivo de selecionar o modelo mais adequado para estimar a biomassa aérea, foi empregado o método de tomada de decisão multicritério AHP Gaussiano. Nesse método, as diferentes métricas de avaliação de desempenho analisadas para cada um dos modelos (MSE, RMSE, MAE, MAPE e R^2) foram utilizadas como critérios para comparar as alternativas, que são os modelos ajustados: multinível, algoritmo genético e OLS, o mapa mental apresentado na Figura 3 auxilia no entendimento do problema.

Figura 3 – Mapa Mental



Fonte: Autoria Própria (2026)

De forma a aprofundar a compreensão sistêmica do problema de seleção do modelo mais adequado para estimar a biomassa florestal acima do solo, aplicou-se a ferramenta CATWOE,

oriunda da *Soft Systems Methodology*. Essa abordagem permite estruturar problemas complexos envolvendo múltiplos atores, interesses e impactos, contribuindo para uma definição mais clara do sistema decisório, como pode ser visualizado a Figura 4.

Figura 4 – CATWOE



Fonte: Autoria Própria (2026)

Nesse contexto, o método AHP Gaussiano foi empregado para integrar, de forma estruturada, múltiplos critérios de avaliação e produzir um ranking consistente das alternativas.

Foram consideradas três alternativas. A primeira consiste no modelo de Mínimos Quadrados Ordinários, do inglês, *Ordinary Least Squares* (OLS), amplamente utilizado em modelagem alométrica devido à sua facilidade de implementação. O OLS estima os parâmetros minimizando a soma dos quadrados dos resíduos, assumindo independência entre observações e estrutura linear entre as variáveis (ou linearidade após transformação). Embora seja um modelo robusto em cenários com dados homogêneos, sua principal limitação está na incapacidade de capturar estruturas hierárquicas, como a dependência entre árvores pertencentes a diferentes países.

A segunda alternativa é o modelo multinível (ou de efeitos mistos), que incorpora explicitamente a estrutura hierárquica dos dados florestais. Nesse modelo, as árvores são consideradas aninhadas por país, permitindo a inclusão simultânea de efeitos fixos (tendência média global) e efeitos aleatórios. Essa abordagem é particularmente relevante em estudos com

abrangência internacional, pois parte da variabilidade da biomassa pode estar associada a diferenças edafoclimáticas, estruturais e biogeográficas não capturadas apenas por variáveis dendrométricas individuais.

A terceira alternativa consiste no modelo ajustado por algoritmo genético, uma técnica metaheurística inspirada em princípios evolutivos, como seleção, cruzamento e mutação. O algoritmo genético realiza uma busca global no espaço de parâmetros, reduzindo o risco de convergência a mínimos locais e podendo oferecer soluções mais flexíveis em cenários com relações não lineares ou superfícies de erro complexas. Essa alternativa se destaca pela capacidade de otimização robusta, especialmente quando o ajuste do modelo depende de múltiplos parâmetros interdependentes.

Para comparar essas alternativas, foram definidos cinco critérios baseados em métricas estatísticas amplamente utilizadas na avaliação de modelos preditivos. Quatro deles são critérios de minimização: o *Mean Squared Error* (MSE), o *Root Mean Squared Error* (RMSE), o *Mean Absolute Error* (MAE) e o *Mean Absolute Percentage Error* (MAPE). O MSE mede a média dos quadrados dos erros e penaliza fortemente discrepâncias elevadas, sendo sensível a valores extremos. O RMSE, por sua vez, corresponde à raiz quadrada do MSE e mantém a unidade original da variável resposta, facilitando a interpretação do erro típico do modelo. O MAE calcula a média dos erros absolutos, oferecendo medida mais robusta em relação a outliers, enquanto o MAPE expressa o erro médio em termos percentuais, permitindo comparação relativa entre diferentes magnitudes de biomassa.

O quinto critério é o coeficiente de determinação (R^2), classificado como critério de maximização, indica a proporção da variabilidade observada explicada pelo modelo, refletindo sua capacidade explicativa global. Contudo, embora elevado R^2 seja desejável, ele não substitui as métricas de erro, pois um modelo pode explicar grande parte da variabilidade e ainda assim apresentar erros relevantes em valores extremos.

A combinação dessas métricas reflete a natureza conflituosa do problema decisório. Sendo assim, a utilização do AHP Gaussiano permite ponderar esses critérios de forma estruturada e estatisticamente fundamentada, integrando precisão e capacidade explicativa em uma única medida agregada. O resultado é a obtenção de um *ranking* final das alternativas, apoiando a seleção do modelo mais adequado para estimar a biomassa aérea com maior robustez científica e consistência metodológica.

5. Resultados e discussão

Para o problema apresentado foi utilizada a matriz de decisão apresentada na Tabela 1.

Tabela 1 – Matriz de Decisão


Alternativas	Critérios				
	MSE	RMSE	MAE	MAPE	R ²
AGB_OLS	1619751.095	1272.694	276.7802	0.2883	0.9091
AGB_MN	1082593.389	1040.477	217.4136	0.2297	0.9353
AGB_AG	1421294.713	1192.181	274.4561	0.2904	0.9105

Fonte: Autoria Própria (2026)

Onde AGB_OLS é a biomassa da árvore acima do solo (AGB) estimada por regressão linear simples (OLS), AGB_MN estimada por regressão multinível e AGB_AG estimada por algoritmo genético. A qualidade do ajuste dos modelos foi avaliada por meio de métricas estatísticas, incluindo erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE), erro percentual absoluto médio (MAPE) e coeficiente de determinação (R²).

A Aplicação do AHP-G foi realizada no *Software R*, onde a Figura 5 apresenta o resultado do fator Gaussiano normalizado, ou seja, os pesos dos critérios.

Figura 5 – Pesos dos Critérios




Fonte: Autoria Própria (2026)

A Figura 5 apresenta a importância relativa das métricas estatísticas utilizadas para avaliar o desempenho de um modelo de *machine learning*, com base no Fator Gaussiano

Normalizado do AHP-G. Para as métricas MSE, MAPE, MAE, RMSE e R^2 foram atribuídos diferentes pesos, refletindo sua relevância na avaliação global dos modelos. O MSE (0,3257) e o MAPE (0,2831) receberam os maiores pesos, indicando que essas métricas tiveram a maior influência na análise. Em contrapartida, o R^2 (0,0345) apresentou o menor peso, sugerindo que, nesse contexto, sua contribuição para a avaliação dos modelos foi menos significativa. Esses resultados destacam a necessidade de considerar múltiplos critérios para obter uma visão mais abrangente do desempenho dos modelos ajustados.

A Figura 6 exibe a comparação entre diferentes algoritmos utilizando a métrica AHP-G.

Figura 6 – Ordenação das Alternativas



Fonte: Autoria Própria (2026)

A análise multicritério utilizando o método AHP Gaussiano confirmou a superioridade do modelo multinível, seguido pelo Algoritmo Genético e do OLS, ao considerar múltiplos indicadores de qualidade de ajuste. A ponderação dos critérios estatísticos revelou que MSE e MAPE foram as métricas mais influentes na avaliação global dos modelos.

Os achados deste estudo têm implicações significativas para a gestão florestal e para políticas de conservação, pois fornecem estimativas mais confiáveis da biomassa florestal, fundamentais para a quantificação do carbono estocado em ecossistemas tropicais. A incorporação de abordagens mais sofisticadas, como modelos hierárquicos e algoritmos de aprendizado de máquina, pode melhorar substancialmente a precisão das estimativas, contribuindo para iniciativas globais de monitoramento e mitigação das mudanças climáticas

6. Considerações Finais

Os resultados deste estudo evidenciam a importância da combinação de modelos estatísticos e técnicas de *machine learning* para a estimativa da biomassa acima do solo (AGB) em ecossistemas tropicais. A elevada heterogeneidade das espécies e tamanhos das árvores amostradas reforça a necessidade de modelos flexíveis e generalizáveis, capazes de capturar a complexidade. A aplicação do método AHP Gaussiano mostrou-se decisiva para estruturar o problema de escolha do modelo como um processo formal de tomada de decisão multicritério. Ao integrar MSE, RMSE, MAE, MAPE e R^2 em uma hierarquia ponderada, o AHP-G permitiu avaliar simultaneamente diferentes dimensões da qualidade do ajuste, reduzindo vieses associados à análise isolada de indicadores. A atribuição diferenciada de pesos evidenciou maior relevância para métricas relacionadas à magnitude do erro absoluto e percentual, reforçando a importância da precisão prática nas estimativas de biomassa.

Os resultados indicaram a superioridade do modelo multinível no ranqueamento multicritério, seguido pelo algoritmo genético e pelo modelo OLS. Esse achado confirma que estruturas hierárquicas são mais adequadas para capturar variações intra e entre grupos em dados florestais globais. Contudo, o principal avanço do estudo reside na incorporação da análise multicritério como ferramenta metodológica de apoio à decisão, ampliando o rigor e a transparência na escolha de modelos preditivos.

Assim, a integração entre modelagem ecológica e Pesquisa Operacional, por meio do AHP Gaussiano, representa uma contribuição metodológica relevante para estudos de biomassa florestal e para aplicações futuras em monitoramento de carbono.

REFERÊNCIAS

- ABREU, J. C. D.; SILVA, J. A. A. D.; FERREIRA, R. L. C.; SOARES, C. P. B.; TORRES, C. M. M. E.; FARIAS, A. A.; TAVARES JÚNIOR, I. D. S. **Mixed models for biomass prediction in the semiarid zone of Pernambuco State, Brazil**. *Scientia Forestalis*, v. 48, n. 128, 2020.
- BECATTINI, V.; GABRIELLI, P.; FRATTINI, L.; WEISBACH, D.; MAZZOTTI, M. A **two-step carbon pricing scheme enabling a net-zero and net-negative CO₂-emissions world**. *Climatic Change*, v. 171, n. 1, p. 18, 2022.
- CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; CHIDUMAYO, E.; COLGAN, M. S.; DELITTI, W. B. C.; DUQUE, A.; EID, T.; FEARNSIDE, P. M.; GOODMAN, R. C. et al. **Improved allometric models to estimate the aboveground biomass of tropical trees**. *Global Change Biology*, v. 20, n. 10, p. 3177–3190, 2014.
- CYSNEIROS, V. C.; PELISSARI, A. L.; NASCIMENTO, R. G. M.; MACHADO, S. A. **Multilevel mixed-effect models to predict wood volume in a hyperdiverse Amazon forest**. *Acta Amazonica*, v. 54, n. 1, e54ag23208, 2024.
- EBBRECHT, M.; SEIDEL, D.; ANNIGHÖFER, P.; KREFT, H.; KÖHLER, M.; ZEMP, D. C. et al. **Global patterns and climatic controls of forest structural complexity**. *Nature Communications*, v. 12, n. 1, p. 519, 2021.
- FENG, H.; CHEN, Q.; HU, Y.; DU, Z.; LIN, G.; WANG, C.; HUANG, Y. **Estimation of forest aboveground biomass by using mixed-effects model**. *International Journal of Remote Sensing*, v. 42, n. 22, p. 8675–8690, 2021.
- FU, L. Y.; ZENG, W. S.; TANG, S. Z.; SHARMA, R. P.; LI, H. K. **Using linear mixed model and dummy variable model approaches to construct compatible single-tree biomass equations at different scales—A case study for Masson pine in Southern China**. *Journal of Forest Science*, v. 58, n. 3, p. 101–115, 2012.
- LI, Y.; LI, M.; LI, C.; LIU, Z. **Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms**. *Scientific Reports*, v. 10, n. 1, p. 9952, 2020.
- LIU, B.; BU, W.; ZANG, R. **Improved allometric models to estimate the aboveground biomass of younger secondary tropical forests**. *Global Ecology and Conservation*, v. 41, e02359, 2023.
- MA, T.; ZHANG, C.; JI, L.; ZUO, Z.; BECKLINE, M.; HU, Y.; LI, X.; XIAO, X. **Development of forest aboveground biomass estimation, its problems and future solutions: A review**. *Ecological Indicators*, v. 159, p. 111653, 2024. Disponível em: <https://doi.org/10.1016/j.ecolind.2024.111653>
- MOGHIMI, A.; TAVAKOLI DARESTANI, A.; MOSTOFI, N.; FATHI, M.; AMANI, M. **Improving forest above-ground biomass estimation using genetic-based feature selection from Sentinel-1 and Sentinel-2 data (case study of the Noor forest area in Iran)**. *Kuwait Journal of Science*, v. 51, n. 2, p. 100159, 2024.
- NUNES, L. J. R.; MEIRELES, C. I. R.; PINTO GOMES, C. J.; ALMEIDA RIBEIRO, N. M. C. **Forest contribution to climate change mitigation: Management oriented to carbon capture and storage**. *Climate*, v. 8, n. 2, p. 21, 2020.



SAATY, Thomas L. **A scaling method for priorities in hierarchical structures.** Journal of Mathematical Psychology, New York, v. 15, p. 234–281, 1987.

SANTOS, M. D.; COSTA, I. P. D. A.; GOMES, C. F. S. **Multicriteria decision-making in the selection of warships: A new approach to the AHP method.** International Journal of the Analytic Hierarchy Process, v. 13, n. 1, 2021.

SANTOS, M. D.; COSTA, I. P. D. A.; GOMES, C. F. S.; MOREIRA, M. A. L. **Ferramenta computacional de apoio à tomada de decisão.** Rio de Janeiro: Ed. dos Autores, 2023.

SILESHI, G. W. **A critical review of forest biomass estimation models, common mistakes and corrective measures.** Forest Ecology and Management, v. 329, p. 237–254, 2014.

.

SOLOMON, S.; PLATTNER, G.-K.; KNUTTI, R.; FRIEDLINGSTEIN, P. **Irreversible climate change due to carbon dioxide emissions.** Proceedings of the National Academy of Sciences, v. 106, n. 6, p. 1704–1709, 2009.

.

TEMESGEN, H.; AFFLECK, D.; POUDEL, K.; GRAY, A.; SESSIONS, J. **A review of the challenges and opportunities in estimating above ground forest biomass using tree-level models.** Scandinavian Journal of Forest Research, p. 1–10, 2015.

.