



AVALIAÇÃO DE DRONE PROFISSIONAL E ALGORITMOS DE APRENDIZAGEM DE MÁQUINA EM AÇAIZAL MANEJADO

Josué Henrique Borges Ramos¹, Verena Holanda da Costa², Jéssica Paula Monteiro Oliveira³,
Wuesley Pereira do Espírito Santo⁴, Aline Cordeiro da Silva Pacheco⁵ Cinthia Pereira de Oliveira⁶,
Marcelino Carneiro Guedes⁷

Universidade do Estado do Amapá¹²³⁴⁵⁶, Empresa Brasileira de Pesquisa Agropecuária⁷
jhenri101010@gmail.com¹

RESUMO

As geotecnologias, principalmente os drones podem colaborar na gestão e ordenação dos recursos florestais amazônicos, especialmente se tratando do uso da terra em relação aos açaizais que são muito rentáveis mas que nos últimos anos o manejo tem se tornado intensivo. Com a utilização de um drone e três modelos de classificação supervisionada (K-nésimo Vizinho Próximo, Random Forest, Máquinas de Vetores de Suporte) e um modelo de detecção de objetos construída com redes neurais (U-NET-EfficientNet-B0), foi analisada a viabilidade de seu uso em classificação de elementos e detecção de objetos dentro de uma área manejada na Ilha das Cinzas – Gurupá/PA. A acurácia para os modelos de classificação variou entre 0,23 – 0,36, sendo considerada uma péssima concordância de informações demonstrando que os modelos utilizados não suportam o volume de dados. Para a detecção de objetos, a acurácia foi de 0,90, considerada uma concordância “Muito boa”. Isso reforça que imagens de alta resolução como as imagens de drone dependem de modelos mais robustos e profundos, como os modelos de redes neurais para organização dos açaizais na Amazônia.

Palavras-chave: Geoprocessamento, Sensoriamento Remoto, Aprendizagem de Máquina, Manejo Florestal

INTRODUÇÃO

Nos últimos anos, tem se observado a popularidade do açaí (*Euterpe oleracea*) no cenário econômico brasileiro e internacional. Essa popularidade influencia diretamente na bioeconomia amazônica, onde a venda do fruto impacta significativamente na qualidade de vida da população amazônica que depende diretamente da venda do fruto para subsistência (GUEDES, 2018). Associado à venda do fruto, também está atrelada a intensificação do manejo de açaizais, onde cada vez mais a floresta de várzea vem sofrendo com a supressão vegetal o que em algum momento a biodiversidade poderá sofrer com o manejo intensivo. Alguns produtores no estuário amazônico, especialmente na Ilha das Cinzas – Gurupá/PA, tem utilizado soluções com drones para organização dos seus açaizais, mas ainda são necessárias metodologias de uso para fins de manejo e que tais fins possam contribuir com dados oriundos de imagens de satélites orbitais por pesquisadores da ciência florestal a fim de compreender o comportamento florestal local (Ramos; et al., 2024).

A utilização de inteligência artificial também tem colaborado nos levantamentos de dados nos últimos anos na Amazônia, especialmente os algoritmos de aprendizagem de máquina em adesão às tecnologias geoespaciais, coletando padrões de dados na floresta amazônica e desenvolvendo planos de manejo adequados e políticas públicas eficientes em relação a utilização dos recursos naturais. Embora drones e algoritmos de aprendizagem de máquina possam ser interessantes para ciência florestal, eles ainda não foram totalmente validados para floresta de várzea amazônica, sendo necessário testar a resolução de drones para classificação supervisionada de pixels e detecção de objetos, a fim de avaliar a eficácia dos algoritmos, como compreender o comportamento de algoritmos de máquinas em dados homogêneos e robustos (L'Heureux; et al., 2017; Ramos; et al., 2024).

As análises por esses modelos com drones poderão contribuir nas pesquisas dos açaizais no estuário amazônico, com imagens em alta resolução com alta proximidade do solo, especialmente em avaliações ecológicas da qualidade do solo, índices de vegetação, como o NDVI (Índice de Vegetação por Diferença Normalizada) nos açaizais; realizar contagem de açaizeiros, medição de altura, determinação de estratos fitossociológicos e contagem de árvores e residências nos açaizais na Ilha das Cinzas. Portanto, o objetivo desse trabalho foi avaliar a eficácia de algoritmos de classificação supervisionada para classificação de pixels e detecção de objetos em imagem de drone em açaizal manejado na Ilha das Cinzas – Gurupá/PA.

MATERIAL E MÉTODOS

Localização, caracterização e levantamento de dados com drone do local de estudo

O estudo foi realizado na Ilha das Cinzas, situada entre os estados do Amapá e Pará e administrado pelo município paraense de Gurupá (Ribeiro, 2017). A ilha possui vegetação classificada como Floresta Ombrófila Densa Aluvial (Ribeiro, 2017) e possui uma densidade elevada de palmeiras sob a região (Ribeiro, 2017). Para o levantamento de dados com o drone, foi selecionado por sorteio uma área manejada na Ilha das Cinzas para realização do sobrevoo com drone. O drone utilizado foi um DJI Phantom Pro 4, com câmera 4k, com sensor Sony Exmor de 41 cm de resolução espacial. O plano de voo foi realizado de forma automática com a utilização do software DroneDeploy configurado a 100 m de altura em relação ao solo. As imagens obtidas com o sobrevoo, foram tratadas e convertidas para uma ortofotografia do local através do software Agisoft Metashape.

Processos e algoritmos utilizados para classificação supervisionada e detecção de objetos

Primeiramente, para realização da classificação supervisionada, a ortofotografia foi exportada como arquivo .TIFF para o software QGIS 3.36 e utilizado o plugin Dzetsaka para realização da classificação supervisionada. Para realização da classificação, foram definidas 6 classes amostrais contendo 20 amostras por classes, identificadas por um número e uma cor. As classes eram: 1- Floresta (verde), 2- Casas (amarelo), 3- Solo exposto (rosa), 4- Sombras (preto), 5- Rio (azul), 6- Palmeiras (vermelho). Os algoritmos selecionados para classificação supervisionada foram: K-nésimo Vizinho Próximo, Random Forest com a Impureza de Gini e Máquinas de Vetores de Suporte.

$$\begin{aligned} 1 - d(x, y) &= \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \\ 2 - Gini &= 1 - \sum_{i=1}^c p_i^2 \\ 3 - y_i (w \cdot x_i + b) &\geq 1 \forall i \end{aligned}$$

Figura 1. Algoritmo K-nésimo Vizinho Próximo (1); Random Forest com Impureza de Gini (2); Máquinas de Vetores de Suporte (3)

Em relação a detecção de objetos, foi utilizado o software ArcGIS Pro 3.30, através da ferramenta de treinamento usando Auto ML. Para isso, foi utilizado o algoritmo de rede neural U-NET, com metadados chamados “Máscaras RCNN” que colabora na identificação de objetos e com o backbone (arquitetura de dados) EfficientNet-B0, cujo modelo possui o foco em detectar objetos com mais rapidez e eficácia. Para realização da detecção de objetos, a rede precisou ser treinada com as mesmas 6 classes e amostras definidas para classificação supervisionada, possuindo 20% para treinamento e 80% para validação.

Após o treinamento, o algoritmo foi executado para identificar apenas as classes “Árvores” e “Palmeiras” a fim de verificar se haveria confusão na detecção de objetos. Para expressar apenas as duas classes, as evidências de detecção foram marcadas em vermelho para as palmeiras e em azul para as árvores. Para avaliar a classificação supervisionada e detecção de objetos, foi utilizado o Índice de Kappa de Cohen para avaliação da acurácia. Foi avaliado também a precisão dos algoritmos em relação ao conjunto de dados.

$$K = \frac{Po - Pe}{1 - Pe}$$

Figura 2 – Índice de Kappa de Cohen

em que: Po: proporção de concordância observada entre avaliadores; Pe: Proporção de concordância ao acaso; K= valor de concordância.

RESULTADOS E DISCUSSÃO

Os três modelos utilizados para a classificação supervisionada, apresentaram resultados variados com relação à resolução do drone. Embora as classes fossem as mesmas para todos os algoritmos, os resultados em todos demonstraram dificuldades em realizar um classificação supervisionada considerando a alta resolução espacial que a imagem de drone possui. Abaixo, os resultados visuais dos algoritmos de classificação:

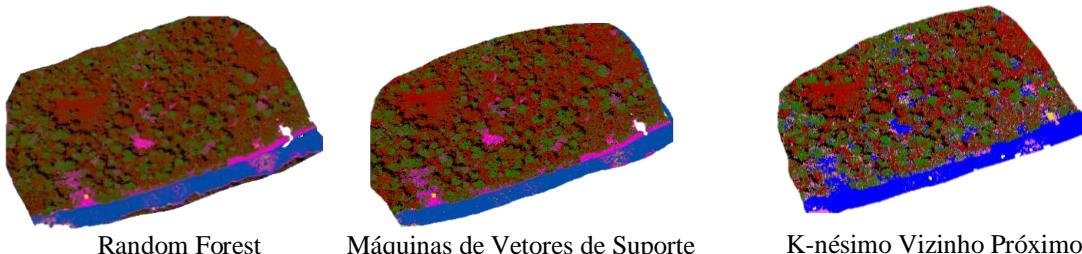


Figura 3. Resultado da classificação supervisionada pelos algoritmos de classificação supervisionada

Em relação a detecção de objetos, a rede neural treinada foi eficaz em detectar árvores e palmeiras na imagem de drone. Houve multiplas detecções no mesmo objeto, mas baixas confusões entre as classes, o que é um saldo positivo para o algoritmo. A imagem abaixo, demonstra as árvores (azul) e as palmeiras (vermelho) detectadas pela rede neural.

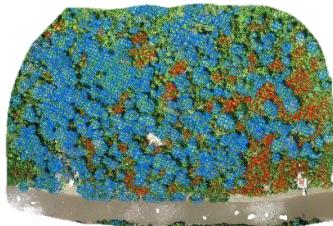


Figura 4. Resultado da detecção de objetos pelo modelo U-NET-EfficientNet-B0

Com relação à acurácia dos algoritmos na classificação supervisionada e detecção de objetos, os resultados obtidos demonstraram que por parte dos modelos de classificação conseguirem acertar alguns pixels referentes as classes determinadas, houve muitas inconsistências por esses modelos, especialmente influenciado pela homogeneidade de dados, ou seja, alguns pixels como os pixels das classes “Árvores” e “Palmeiras” são muito parecidos, o que resultou em confusão por parte do algoritmo. No entanto, a detecção de objetos com a rede neural, obteve valores excelentes o que demonstrou ser ideal para lidar com altas resoluções espaciais quando comparado aos modelos de classificação supervisionada. As tabelas 1 e 2, expõe o desempenho dos algoritmos utilizados durante o processo de classificação supervisionada e detecção de objetos.

Algoritmo	Acurácia	Precisão	Concordância de dados	Tempo de aprendizagem
Random Forest	0,36	0,39	Ruim	4h 21min
Máquinas de Vetores de Suporte	0,30	0,35	Péssima	2h56min
K-nésimo Vizinho Próximo	0,23	0,30	Péssima	2h43min
U-NET-EfficientNet-B0	0,90	0,91	Muito Boa	4h36min

Tabela 1. Acurácia e precisão dos modelos utilizados na imagem de drone

Algoritmo	Nº de detecções de palmeiras	Nº de detecções de árvores
U-NET-EfficientNet-B0	795	2.722

Tabela 2. Quantidade de detecções de objetos relacionados a palmeiras e árvores realizadas pela rede neural

Na classificação supervisionada, os algoritmos aplicados nesta pesquisa, possuem métodos diferentes de classificação de dados. Máquinas de Vetores de Suporte é utilizado em otimização de dados; Random Forest em procura de dados e K-nésimo Vizinho Próximo é baseado em proximidade de dados (Monteiro, 2015). A utilização do modelo U-NET-EfficientNet-B0 procura estabelecer uma relação de reconhecimento visual, ou seja, reconhecer de forma literal o objeto em vez de reconhecer os pixels que compõem o objeto a ser detectado, diferente na classificação supervisionada. Essa variação metodológica é fundamental na busca do melhor algoritmo para o uso do drone. De modo geral, a acurácia dos modelos de classificação supervisionada é ineficaz para imagens de alta resolução, obtendo uma péssima concordância de dados. A imagem original do açaizal possui 223 milhões de pixels, o que para modelos convencionais pode ser complexo a ser processado.

O nível de detalhes aumenta e consequentemente os algoritmos não conseguem suportar o volume de informação oferecida pela imagem de drone. Esse comportamento pode estar associado a configuração do próprio algoritmo que em casos muito prováveis, pode ocorrer o chamado “Underfitting” em que os modelos não conseguem acompanhar bem o volume de dados e desenvolve péssimas previsões ou o “Overfitting” em que os modelos são bem ajustáveis aos dados ao ponto de demonstrar uma acurácia perfeita (Bashir; et al., 2020). Na figura 5 é possível notar como as redes neurais apenas isolam o objeto, enquanto os modelos de classificação tentam segmentar os pixels do mesmo objeto em diferentes classes e acabam proporcionando um resultado confuso.

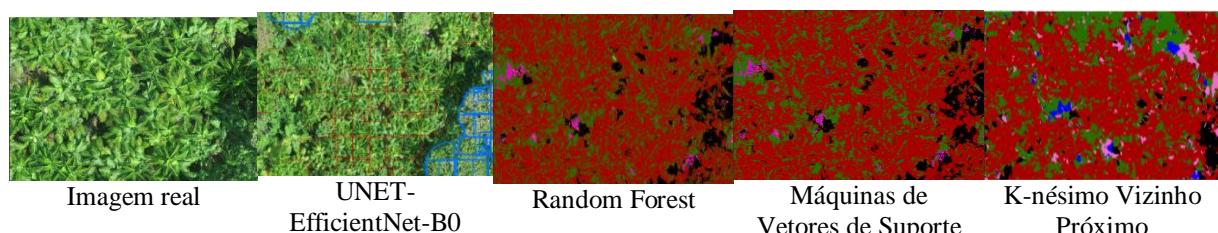


Figura 5. Comparação espacial dos resultados dos algoritmos em uma área da imagem de drone

Por outro lado, as redes neurais são flexíveis em relação ao conjunto de dados. Alguns modelos possuem a capacidade de aprender e melhorar com os erros e os modelos baseados em redes neurais são capazes de absorver as informações coletadas e buscar uma solução ideal para o problema enfrentado, geralmente avaliando-os por parâmetros básicos, como média, mediana ou desvio padrão (Lima; *et al.*, 2020). Quando analisamos os dados pela visão do algoritmo U-NET-EfficientNet-B0, é possível entender que a resolução do drone é favorável a detecção de objetos do que classificar pixels.

Os pixels classificados pelos modelos convencionais possuem características semelhantes, como a cor e textura, já que palmeiras e árvores possuem coloração verde, embora em tons diferentes a depender da influência do ambiente. Mas por outro lado, não cabia a rede neural reconhecer padrões de pixels, mas reconhecer formato geométrico dos objetos, o que é mais vantajoso em imagens de alta resolução, por apresentar menos erros de acurácia, o que pode colaborar mais na organização de açaizais na floresta amazônica.

É nítida a diferença de resultados e da qualidade dos algoritmos em relação a resolução de imagem, sendo apropriado lidar com reconhecimento de padrões geométricos para reconhecer objetos em vez de classificar pixels. Alguns algoritmos convencionais podem proporcionar resultados com alta acurácia, mas com os mesmos padrões de erros dos modelos de classificação testados neste trabalho, como o caso do Modelo de Mistura Gaussiana, testado por Ramos e *et al* (2024) com esta mesma imagem de drone.

Os modelos deste trabalho proporcionaram uma baixa acurácia, mas o Modelo de Mistura Gaussiana testado em 2024, proporcionou uma acurácia alta, sendo 0,91 de acurácia, mas o erro do algoritmo era semelhante aos erros dos modelos testados aqui, com o modelo apenas se ajustando aos dados e gerando uma falsa acurácia (Ramos; *et al*, 2024). Portanto, em imagens de alta resolução, onde há clareza dos formatos geométricos dos objetos, é mais eficaz o uso de algoritmos robustos como redes neurais.

CONCLUSÃO

Os algoritmos “K-nésimo Vizinho Próximo”, “Random Forest” e “Máquinas de Vetores de Suporte” são ineficazes em imagens de alta resolução espacial devido a incapacidade de lidar com dados complexos, influenciado pela grande quantidade de detalhes presentes na imagem de drone. O algoritmo de redes neurais como o U-NET-EfficientNet, focado em reconhecimento e detecção de objetos são ideais para imagens de alta resolução, apresentando uma acurácia de 0,90, considerada muito boa.

REFERÊNCIAS

- BASHIR, D.; *et al.* An Information-Theoretic Perspective on Overfitting and Underfitting. **33rd Australasian Joint Conference on Artificial Intelligence**. Harvey Mudd College. Claremont, Califórnia, EUA, 2020.
- GUEDES, M. C.; *et al.* Calendário Adaptado Para Monitoramento Da Produção de Açaí. **Comunicado técnico**. Embrapa Amapá. Macapá, Amapá, 2018.
- L'HEUREUX, A.; GROLINGER. K.; ELYAMANY. H. F; CAPRETZ. M. A. Machine Learning With Big Data: Challenges and Approaches. **IEEE Access**. London, Ontario, Canadá. v.5, p. 7776-7797, 2017.
- LIMA, G. A.; BRAVO, D. T.; ARAÚJO, S. A. Utilização de redes neurais convolucionais para a detecção de objetos em imagens aéreas adquiridas por drones. **Brazilian Journal of Development**. Curitiba, V. 6, p. 50702-50713, 2020.
- MONTEIRO, F. P.; FRANCÉS, C. R. L. ClasSIS: Uma Metodologia Para Classificação Supervisionada de Imagens de Satélite em Áreas de Assentamento Localizados na Amazônia. **Mestrado em Engenharia Elétrica**. Universidade Federal do Pará. Belém, Pará, 2015.
- RAMOS, J. H. B.; SARDINHA, M. A; OLIVEIRA, C. P.; GUEDES, M. C. Detecção de Áreas Manejadas Em Açaizais Na Amazônia Com Ferramentas De Sensoriamento Remoto. **Anais XI Simpósio Brasileiro de Pós-Graduação em Ciências Florestais**. Lages, Santa Catarina, 2024.