



Estimativa de altura de vegetação com imagens obtidas de drone utilizando técnicas de inteligência artificial

José Vinícius de Sousa Florêncio¹ Maria do Socorro Bezerra de Araújo², Josicléda Domiciano Galvêncio³, Rodrigo de Miranda Queiroga⁴

¹Bacharel em Geografia pela Universidade Federal de Pernambuco, e-mail: jvini22@gmail.com, ORCID: <https://orcid.org/0000-0003-4752-6440>

²Professora do Departamento de Ciências Geográficas da Universidade Federal de Pernambuco, e-mail: maria.baraujo@ufpe.br ORCID: <https://orcid.org/0000-0001-8816-8569>

³Professora do Departamento de Ciências Geográficas da Universidade Federal de Pernambuco, e-mail: josicleda.galvencio@ufpe.br

⁴Doutor em Desenvolvimento e Meio Ambiente pela Universidade Federal de Pernambuco, e-mail: rodrigo.qmiranda@ufpe.br

Artigo recebido em 15/07/2024 e aceito em 26/08/20224

RESUMO

As geotecnologias são ferramentas recentes que podem ser utilizadas para avaliar condições florestais, com vantagens sobre outras técnicas pela rapidez e praticidade de levantar dados sobre a estrutura de vegetação. O uso de VANT (Veículo aéreo não tripulado) se sobressai sobre outras técnicas utilizadas no sensoriamento remoto, por ter o potencial de gerar dados de alta qualidade e resolução. O objetivo da pesquisa é estimar a altura do dossel de um fragmento florestal de manguezal, utilizando imagens de drone. As imagens foram associadas a softwares de geoprocessamento que permitiram a criação de nuvem de pontos e ortomosaico. Em um fragmento de floresta de manguezal foi escolhido de maneira aleatória doze árvores para serem utilizadas como pontos de referência, foram estimadas as alturas, e registrado as coordenadas geográficas por meio de GPS. Os valores foram aproximados utilizando três tipos de aprendizado de máquina: equações lineares no Excel, árvores de regressão no Rstudio e um interpretador python. Os resultados apresentaram boa aproximação com os dados de altura das árvores estimados em campo, com índice de correlação de $r^2 = 0,90$ e RMSE de 1,34 metro. Podendo, por exemplo, ser aplicado em pesquisas futuras com maiores amostras de espécies, ou em outros tipos de vegetações.

Palavras-Chave: Manguezal, modelagem, sensoriamento remoto, vant.

Estimation of vegetation height with drone-acquired images using artificial intelligence techniques

ABSTRACT

Geotechnologies are recent tools that can be used to assess forest conditions, with advantages over other techniques due to the speed and practicality of gathering data on vegetation structure. The use of UAVs (Unmanned Aerial Vehicles) stands out among other remote sensing techniques, as it has the potential to generate high-quality, high-resolution data. The research aims to estimate the canopy height of a mangrove forest fragment using drone images. The images were associated with geoprocessing software that allowed the creation of point clouds and orthomosaics. In a fragment of mangrove forest, twelve trees were randomly chosen to be used as reference points, their heights were estimated, and their geographical coordinates were recorded using GPS. The values were approximated using three types of machine learning: linear equations in Excel, regression trees in Rstudio, and a Python interpreter. The results showed a good approximation with the tree height data estimated in the field, with a correlation index of 0.90 and RMSE of 1.34 meters. This could, for example, be applied in future research with larger samples of species or in other types of vegetation.

Keywords: mangrove, modeling, remote sensing, uav.

Introdução

Em florestas de grande densidade, destacando aquelas com regeneração natural abundante, o pesquisador pode ter dificuldade em visualizar a base e o dossel da árvore, ocorrendo erros na estimativa de altura (Soares C.P.B. et al.). Hufkens, K, et al. (2017) em pesquisa de sensoriamento remoto próximo à superfície, relatam que estudos de fenologia

baseados em câmera surge como uma ferramenta valiosa para caracterizar o desenvolvimento da planta em escalas reduzidas. O uso de sensores LiDAR (Método de sensoriamento remoto próximo à superfície que utiliza laser pulsado para medir distâncias, presente em câmeras de alta resolução) pode adentrar no dossel florestal, estimando sua

altura e dos estratos, para caracterizar a estrutura do manguezal (Pereira, F. R. De Souza, 2016). Segundo Richardson et al. (2009) o sensoriamento remoto próximo a superfície usando instrumentos radiométricos ou imagens sensoriadas, tem grande potencial para melhorar o monitoramento fenológico, porque pode ser feito em alta frequência temporal.

Imagens capturadas por veículo aéreo não tripulado (VANT) apresentam alta resolução e dispõem de métodos práticos e rápidos, visando obter índices relacionados ao monitoramento florestal (Pontes & Freitas, 2015). Essa ferramenta pode auxiliar tanto nas ações de manejo de árvores, como na elaboração de um inventário florestal. Pesquisas recentes apontaram que é possível criar imagens 3D com imagens obtidas por VANT utilizando técnicas de estereoscopia (Dandois; Ellis, *et al.*, 2013). O uso de VANT em levantamentos aéreos torna-se uma importante ferramenta pois gera dados aéreos de SR com altas resoluções temporais e espaciais a custos mais baixos para coberturas de áreas pequenas e médias (SÁ, *et al.*, 2021). Comparado ao sensoriamento remoto orbital por imagens de satélites, ou outros métodos tradicionais de sensoriamento remoto (SR); como por meio de sensores Lidar e radares, o uso da tecnologia de VANT aplicado a essa área, se mostra como uma alternativa viável por poder gerar dados com maior precisão (GRAÇA, *et al.*, 2017).

Barcelos & Danelon (2019) relataram que relacionado à resolução espacial e temporal, o uso de VANTs abrem novos paradigmas, o que antes era de difícil acesso, nos dias de hoje essas tecnologias facilitam a aquisição de imagens de alta qualidade e resolução em um curto intervalo de tempo se comparado as imagens de satélites, podendo o pesquisador obter as imagens com periodicidade, o que produz resultados de alta qualidade de resolução espacial já mais vista pelos métodos tradicionais. As metodologias convencionais de sensoriamento remoto requerem um grande intervalo de tempo no andamento da atividade para a coleta de informações, como por exemplo, depender da sazonalidade das imagens de satélite (Ribeiro *et al.*, 2018). De acordo com Iizuka *et al.* (2018) a altura da árvore e o DAP (diâmetro da altura do peito) são informações cruciais para avaliar condições florestais, e baseado em dados obtidos através de VANT auxiliam não

apenas na coleta de parâmetros florestais, mas também no monitoramento contínuo da área. Informações auxiliares de VANT para estimar volume florestal tem alta precisão comparado a dados obtidos em campo. A combinação de ambos os métodos aumenta a margem de precisão das estimativas, e se apresenta como alternativa de menor custo (Puliti *et al.*, 2017). (Galvncio, Popescu 2016) consideram que os dados gerados por SR para obter altura de vegetação de mangue são importantes, permitindo em um curto intervalo espacial e temporal informações precisas de maneira econômica.

Com o desenvolvimento das geotecnologias é possível relacionar, combinar e sobrepor as informações geoespaciais em softwares. Assim, modelos foram e são desenvolvidos para representar a realidade em outros espaços, utilizando o meio matemático (Câmara; Medeiros, 2005). A vantagem principal da aplicação de modelos é de ter a possibilidade do estudo de diversos cenários diferentes e de forma breve. Além disso, outro ponto importante da utilização de simulação de cenários está associado ao baixo custo. Em grande parte das aplicações, o custo de executar softwares computacionais é menor do que executar o mesmo modo de maneira experimental (Pessoa *et al.*, 1997). Esses modelos têm o potencial de serem utilizados em diversas áreas da ciência, tornando-se uma ferramenta fundamental para as geociências, porque podem ser utilizados para a análise ambiental, identificação e representação de processos dinâmicos, como o movimento de massa e inundações (Ferreira *et al.*, 2023).

Os manguezais se encontram distribuídos praticamente por toda costa brasileira, cobrindo toda zona tropical. É um ecossistema complexo, altamente resiliente e resistente, considerado como uma das biosistemas mais produtivas do planeta (Schaeffer, N., 2008). Exceto o Rio Grande do Sul não tem a presença da cobertura vegetal típica de manguezal. Há uma diversidade de ambientes por todo litoral, desde 04° 20'N (Oiapoque, AP) até 28°30'S (Laguna, SC), exibindo diferentes feições de desenvolvimento estrutural (ICMBio, 2018). As árvores características de manguezal sequestram o sedimento em suas raízes e troncos, mesmo processo que aprisiona os poluentes, prevenindo que a poluição contamine águas costeiras adjacentes. Assim como, ajudam como cortina de vento, amenizando as consequências de

tempestades nas áreas costeiras e atenuam o movimento das marés (ICMBio, 2018). Esse ecossistema se encontra em uma situação alarmante nas cidades brasileiras, embora exista leis que o conservem, há lançamentos de esgoto doméstico e produtos químicos nos rios que chegam a esses manguezais, aterramentos e descarte inadequado de resíduos sólidos, isso tudo relacionado ao conflito em torno do uso e ocupação do solo. Refletindo na perda da qualidade ambiental desse ecossistema (Andrade, A., 2008).

Embora o uso de VANT em recentes pesquisas de sensoriamento remoto tenha crescido, é escassa a produção científica sobre a estimativa de altura de vegetação de manguezal com essa tecnologia (Boa Morte, 2020; Bueno, 2019; Almeida, 2019; Ribeiro, 2019). No qual é um ecossistema importante para o meio ambiente e sociedade, pois promove um equilíbrio ambiental de grande importância, e que se encontra bastante degradados pela ação humana por se encontrarem geralmente nos grandes centros urbanos, causando uma grande perda de biodiversidade. As regiões de manguezal são até certo ponto hostis a estudos em campo que precisam de periodicidade para monitoramento, são locais de difícil acesso por conta das raízes das árvores e tem solo inconsistente, por conta dos movimentos de maré, o que dificulta a locomoção in situ. O uso de VANT se apresenta como alternativa viável para pesquisas que visão estimar altura de vegetação de manguezal.

O sensoriamento remoto próximo a superfície com o uso de VANT se apresenta como instrumento valioso para pesquisas. Com sensores cada vez mais precisos, capazes de levantar dados sobre a estrutura da vegetação, com alta qualidade e sem nenhuma interferência externa, como ventos e nuvens. Além de poder gerar modelos 3d individuais de árvores com os dados obtidos, e também DSMs (Digital Surface Models) ou em português MDS, (Modelo Digital de Superfície), que servem para estimar altura de vegetação, servindo como parâmetro a outras técnicas de SR. Já outros métodos convencionais de SR como o de imagens de satélite tem escala espacial e temporal limitadas, e precisam de fotografias limpas, sem interferências de nuvens. Assim como, métodos dendométricos, como o DAP (Diâmetro na Altura do Peito), que requer equipamentos específicos, tempo e paciência para colher dados individuais de árvores, onde aplicado a área de mangue encontraria bastante dificuldade, por conta das condições físicas do terreno e de necessitar tempo

e paciência. Deste modo, o uso de VANTs se apresenta de maneira viável para estudos em área de manguezal, onde podem gerar dados de qualidade para pesquisas relacionadas a esse tipo de vegetação. O projeto se insere de maneira inovadora nessa área de pesquisa, agregando novas tecnologias a técnicas de geoprocessamento, podendo ser desenvolvido para pesquisas futuras.

O objetivo geral da pesquisa é estimar a variação de altura de árvores em um fragmento de floresta de manguezal, e especificamente produzir e validar modelos matemáticos que sirvam como parâmetro as alturas recolhidas em campo, utilizando as imagens de Drone, softwares de geoprocessamento e aprendizado de máquina.

Material e métodos

Área de estudo

A área de estudo localiza-se no Manguezal do Pina (Figura 1), também chamado de Parque dos Manguezais, na zona urbana da cidade do Recife, entre as coordenadas de 8°5'30" e 8°6'30" S; 34°54'30" e 34°54'00" W, onde abrange uma área de 320,34 hectares. Segundo a classificação de Köppen a área é influenciada pelo clima tipo As', Tropical Quente Úmido, caracterizado em duas estações, seca (primavera-verão) e chuvosa (outono-inverno) (Souza, 2012).

Trata-se de um território que pertence a Marinha do Brasil, área de preservação ambiental permanente de acordo com o Novo Código Florestal, lei nº 4771/1965, localizado em uma área de estuário cuja conservação é de fundamental importância para a manutenção de serviços ambientais. Como provimento de alimentos, regulação de marés, sequestro de carbono e amenização climática, além de se constituir como espaço com potencial para educação ambiental, lazer e visitação. O manguezal tem funções biológicas muito importantes, no qual, serve como renda para atividades primárias, como a carcinicultura e a coleta de mariscos; a vegetação fixa a terra na superfície, impedido que as intemperes causem erosão, além de funcionar como filtro na retenção de alimentos e sedimentos (Sobrinho & Andrade, 2009).

Dentre as maiores cidades do Brasil, o Recife tem a maior área de mangue conservado, que é onde se localiza o manguezal do Pina. Para onde se direciona a drenagem de vários cursos de água (Veras, 1996). É pressionado por interesses políticos e econômicos, além de sofrer com a poluição de resíduos sólidos que veem com a maré e se fixam nas raízes. Serve como uma barreira natural que protege os bairros litorâneos da erosão

costeira e das águas da bacia do Pina, além de amenizar a força das enchentes nas regiões que ficam nos arredores do manguezal (Veras, 1996). Pôr a área estar em uma planície fluviomarinha os solos são classificados como hidro mórficos, solos indiscriminados de manguezal e areias quartzosas,

ou seja, são sedimentos ou solos incipientes, derivados de sedimentos fluviomarinhos (Souza, 2012).




Figura 1: Mapa de localização da área de estudo, elaboração: autor (2021)

Procedimentos metodológicos

O VANT (Veículo aéreo não tripulado) utilizado para o estudo foi o drone DJI Matrice 600 Pro UAV, equipado com câmera que tem sensores RGB, NIR e TIR da Micasense. Foi adotado uma sobreposição lateral e frontal mínima de 80%, com câmera posicionada com ângulo de 90° em relação ao drone, ou seja, diretamente apontando o solo; em configuração manual de acordo com a iluminação da cena.

O planejamento de voo foi realizado no aplicativo Pix4Dcapture, disponível na plataforma play store, em smartphone, onde é feito todo o plano de voo que será realizado de maneira automática. A aeronave está registrada segundo as normas brasileiras, o plano de voo foi realizado obedecendo a legislação vigente, com o voo em altura máxima de 120m. Na área de estudo o VANT de maneira automática capturou 134 imagens, sendo 67 imagens na faixa do visível e 67 imagens na faixa do termal. Para o objetivo da pesquisa só foram utilizadas as imagens da faixa do visível.

A pesquisa de campo foi realizada no dia 03/02/2021, onde foram definidos doze pontos na superfície associados a árvores, de forma aleatória, no qual foram registrados a latitude e a longitude que se encontravam através do GPS Garmim etrex 10. Para que sejam posteriormente convertidas em coordenadas geográficas em

ambiente SIG (Sistema de coordenadas geográficas) (Datum WGS 84) e utilizadas como parâmetro, com a finalidade de estabelecer uma relação entre o SIG das imagens com as coordenadas do terreno.

Os processamentos foram realizados em diferentes softwares. No AgiSoft Metashape, no Quick Terrain Modeler (Qt Model), no ArcGis Desktop, e em um interpretador python (Todos os softwares de licença do laboratório SERGEO-UFPE).

A identificação das espécies in situ foi feito de maneira aleatória, estimando a altura das árvores utilizando o método DAP (Diâmetro acima do peito). Depois, as alturas das árvores registradas foram adicionadas em uma planilha no excel.

Os processamentos nos softwares foram realizados de maneira remota e presencial nos hardwares do laboratório de Sensoriamento Remoto e Geoprocessamento da Universidade Federal de Pernambuco (SERGEO) que dispõe de um computador com 120 núcleos em 10 processadores i7 (3.2-3.33 GHz), 80 GB de memória RAM (DDR3; 1,333 MHz), e 10 TB de HDD, 20 placas de rede Gigabit.

Após a realização do voo, as imagens obtidas pelo VANT foram processadas e transformadas em ortomosaico, que significa a junção de todas as imagens em uma só, para se

extrair os dados da área em questão. Esta etapa do processo foi feita através do software Agisoft Metashape (figura 3), que permite processar imagens de câmeras RGB ou multiespectrais, em que constroi nuvens de pontos densas, modelos poligonais texturizados, georreferenciados, ortomosaicos e DSMs/ DTMs (Digital Surface Model e Digital Terrain Model). As 67 imagens da faixa do visível foram inseridas no software AgiSoft Metashape, logo após, foram georreferenciadas e alinhadas. Na próxima etapa

foi criada a nuvem de pontos do terreno com 41.114 pontos, para posteriormente gerar o modelo 3D e o modelo digital de elevação (MDE). E por fim foi gerado com o processamento, um Ortomosaico da área estudada (Figura 2).

Para fins do objetivo da pesquisa apenas a nuvem de pontos e o Ortomosaico foram utilizados




Figura 2: Ortomosaico da área em estudo. Fonte: autor, 2021.




Figura 3: Fluxograma de trabalho no Agisoft Metashape

Posteriormente, foi utilizado o software Quick Terrain Model ou Qt Model (licença do laboratório SERGEO/UFPE), onde em um primeiro processamento gerou um MDE (Modelo de elevação digital), depois no software foi utilizado a ferramenta AGL (Above Ground Level) ou (Altura acima do solo) que gerou um modelo da altura da vegetação acima do solo (Figura 3). O AGL e o Ortomosaico foram importados no ArcGis 10.8 junto com uma shape dos doze pontos de altura

coletados em campo, separadamente foi utilizada a ferramenta zonal statistics, que tem a função de resumir os valores de um raster dentro das zonas de outro conjunto de dados e relata os resultados em um arquivo txt. Os dados exportados foram adicionados em uma planilha base para serem utilizadas nas modelagens.




Figura 4: AGL (Above Ground Level. Fonte: Autor (2021)

A nuvem de pontos processada foi importada no software QT Model onde foi gerado um modelo de elevação digital e depois foi utilizado a ferramenta AGL (Above Ground Level) que gera

um modelo com a altura das árvores que estão presente na área acima do solo (fluxograma 2), com dados estatísticos da área.




Figura 5: Fluxograma de trabalho no QtModel

Foram adicionados no Arcgis o Ortomosaico e uma shape dos doze pontos observados. Onde foi cruzado as coordenadas dos pontos observados com o Ortomosaico (Figura 6), e feito um buffer de 3 metros ao redor desses pontos, e depois foi utilizado a ferramenta zonal statistics gerando uma tabela com as alturas de todos os pontos nas três bandas do infravermelho, red, green e blue, onde foi exportada em txt. O mesmo foi feito com o AGL (Figura 4) gerado no Qtmodel, foi adicionado no Arcgis junto com a shape dos pontos observados, também foi feito um buffer de 3 metros

ao redor dos pontos e depois foi utilizado a ferramenta zonal statistics. Essa ferramenta resume os valores de um raster dentro das zonas de outro conjunto de dados e relata os resultados em uma tabela. Com os dados estatísticos gerados na tabela, apenas a estatística MEAN foi exportada para a planilha base no Excel, ela calcula a média de todas as células no raster de valor que pertencem à mesma zona da célula de output. Foi colocada na planilha base todos os dados MEAN, das três bandas extraídas do Ortomosaico e do AGL.




Figura 6: Mapa de localização da área de estudo com o recorte do Ortomosaico e do AGL.
Fonte: Autor, 2021

Com esses dados, no Excel foi realizado a primeira modelagem cruzando os dados de altura do Ortomosaico e do AGL, extraídos do ArcGis, com os dados de altura de campo. Utilizando o

coeficiente de correlação Pearson (Equação 1). Os valores de altura foram aproximados utilizando três diferentes métodos de aprendizado de máquina:




Figura 7: Fluxograma das modelagens de dados de altura extraídos do ArcGis

1. A primeira parte da validação dos dados foi realizada através de teste de acurácia com regressão linear simples no Excel (Figura 7). Em uma planilha no Excel foram adicionados os dados de altura extraídos do AGL, os dados de altura dos doze pontos observados em campo, e os dados de altura das faixas do visível, Red, Green e Blue extraídos do Ortomosaico. Foi utilizado o coeficiente de correlação Pearson (Equação 1). A

função Pearson retorna o coeficiente de correlação, produto ou momento r^2 de Pearson. Nesse caso, ' r^2 ' é um índice que está entre -1.0 e 1.0 que indica o grau de dependência linear entre dois conjuntos de dados, onde foram correlacionados os conjuntos de valores independente, o AGL e as bandas RGB com os dados observados em campo que entra como um conjunto de valor dependente. A equação do coeficiente de correlação Pearson, r^2 , é:

$$r = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}}$$

Equação 1

Onde $\bar{x}$ é média de amostra das alturas observadas em campo e $\bar{y}$ a média de amostra dos valores independentes.

Também foi utilizado no Excel a equação da raiz do erro quadrático médio (RMSE), para se obter um maior índice de correlação entre os dados

de altura de campo e os dados processados das imagens. A equação RMSE (Equação 2) é a medida que calcula "a raiz quadrática média" dos erros entre os valores observados (reais) e previsões (hipóteses) em metros, que é comumente usada para expressar a acurácia dos resultados numéricos. A equação se dá dessa maneira:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}$$

Equação 2

Onde X_{obs} são os valores de altura observada e X_{model} são os valores de altura do RGB e do AGL.

2. Para a modelagem foi utilizada uma planilha com os dados das alturas do AGL e das faixas do visível e inseridas no modelo de árvores de regressão com condicionais Cubist no software Rstudio (Figura 7). O pacote Cubist constroi modelos preditivos baseados em regras que produzem valores (Rulequest Research 2020), em que uma árvore é cultivada onde

as folhas terminais contêm modelos de regressão linear. Esses modelos são baseados nos preditores usados nas divisões anteriores. É uma ótima ferramenta que fornece resultados mais precisos que aqueles produzidos por técnicas simples, como da regressão linear multivariadas que utilizamos anteriormente na primeira modelagem foi gerado uma modelagem de altura apenas com as faixas do visível, e uma modelagem de altura do Above ground level (AGL) + as faixas do visível.




Figura 8: Fluxograma de trabalho no Rstudio

No próprio script foi designado um comando para exportar em txt as modelagens de altura produzidas apenas com as bandas, e o AGL + as bandas, respectivamente em duas tabelas. Foram adicionados numa planilha no Excel e foram aplicadas as equações Pearson (Equação 1) e do RMSE (Equação 2) tendo como parâmetro as alturas estimadas em campo.

3. Na terceira modelagem foi utilizado um interpretador Python 2.7.15 desenvolvido pelo grupo de pesquisa (SERGEO-UFPE) para criar modelos de forma interativa, utilizando uma planilha base cruzando as alturas das árvores de campo e as alturas obtidas com o AGL e as faixas do visível, com o objetivo de agregar a metodologia utilizada e ter maior precisão nos resultados. Dentro do modelo foi desenvolvido o script que teve como referência à altura modelada x altura de campo

(Equação 3). Quanto maior o valor do parâmetro (nc) a cada processamento, maior serão a quantidade de cálculos realizadas pelo programa, necessitando de um hardware que consiga suportar. O correlator tem a capacidade de se ajustar a vários modelos com base nas combinações de séries de entrada, funções lineares, logarítmicas, exponenciais, de potência, operações matemáticas básicas. A partir do parâmetro estabelecido (nc) ele realiza todas as combinações de cálculos, a modelagem é produzida através de um exaustivo processamento de (>106 interações), e seleciona o melhor coeficiente Pearson (r2) com o menor coeficiente RMSE (Miranda R, et al., 2020). (Ele está disponível gratuitamente em: <https://github.com/razeayres/correlator>). Os cálculos foram feitos com as faixas do visível e o AGL, variando o valor do parâmetro de entrada.

Equação 3

$$f(nc) = C^{nc} \begin{bmatrix} red \\ gren \\ blue \\ AGL \end{bmatrix} + (nc-1) \times C^{nc} \begin{bmatrix} x & 1/x & \ln(x) \\ \log_{10}(x) & \sqrt{x} & x^2 \\ e^x \end{bmatrix} + (nc-1) \\ \times \begin{cases} 1, & nc = 1 \\ C^{(nc-1)} \begin{bmatrix} + & - \\ \times & \div \end{bmatrix} + (nc-2), & nc \geq 2 \end{cases}$$

Resultados e discussão

Na área foram registradas doze espécies típicas de vegetação de manguezal. Sendo registrado uma altura média de 8,12 metros entre as doze árvores selecionadas. A maioria das espécies tinham alturas semelhantes, apenas algumas sobressaíram.

Dos dados registrados com o primeiro processamento realizado no Qtmodel, a altura máxima da área registrada foi de 28.21 metros, a altura mínima foi de 2.79m com uma média de 12.94 metros, com um desvio padrão de 6.19 m, como mostra a (figura 9). Esse processamento leva em conta os dados estatísticos de todos os objetos físicos presentes na

área. Existe a predominância de vegetação, mas é importante constatar a presença de algumas construções em ruínas na área que podem influenciar nesses dados.




Figura 9: Dados estatísticos do AGL (Above Ground Level) produzidos no software QtModel

Dos resultados obtidos com o teste de acurácia realizado no Excel com a equação 1 e 2). O modelo AGL (above ground level) teve um índice de correlação com os dados de altura de campo $r^2 = 0,66$ e RMSE = 2,34 m. Para melhor visualização, os resultados dos cálculos foram adicionados a um

gráfico de dispersão com uma linha de tendência linear reta, onde x é o AGL e y os dados de altura de campo. Quando os valores de r^2 estão mais próximos de 1 significa que mais confiáveis e ajustados o modelo está (Figura 10).




Figura 10: Gráfico de dispersão com linha de tendência cruzando as alturas extraídas do arcgis com as mensuradas em campo (AC)

Posteriormente os resultados obtidos com a segunda modelagem realizada no Rstudio com o modelo de árvores de decisão Cubist e no Excel (equações 1 e 2), tiveram melhor aproximação com os dados de altura de campo, sendo: o modelo apenas com as bandas teve um índice de correlação $r^2 = 0,74$ e erro médio foi de 2,38 metros. Já o modelo com o AGL + as combinações de bandas tiveram um índice de correlação de $r^2 = 0,90$ e erro médio de 1,34 metros (Figura 11), modelagem com melhor performance registrada, assim, esse método de árvores de regressões teve melhor desempenho comparado aos outros métodos.




Figura 11: Gráfico de dispersão com linha de tendência cruzando as alturas mensuradas em campo com as estimadas pela modelagem .

E por último os resultados obtidos com a segunda modelagem (equação 3) no correlator também foram bons, tendo boas aproximações. O resultado da modelagem no correlator com 1 parâmetro de entrada teve o coeficiente Pearson $r^2 = 0,71$ e RMSE = 2,21 metros, com 2 parâmetros de entrada $r^2 = 0,81$ e RMSE = 2,09 metros, e 3 parâmetros de entrada $r^2 = 0,85$ e RMSE 1,93 metros. Os valores seguiram uma tendência de mais ajuste a partir dos parâmetros de entrada, o terceiro resultado processado com cubist, foi produto de milhares de combinações de cálculos realizados pelo aprendizado de máquina. Os resultados dos índices da equação da raiz do erro quadrático médio e do índice de correlação estão na tabela 2 organizados na ordem de processamento: Equações lineares no Excel, árvore de decisão no Rstudio e o software correlator, onde AC é a altura de campo, e faixas do visível as três bandas: RGB.

Tabela 1: Resultados RMSE e r^2 para os três métodos de obtenção de altura

Métodos	Modelagens	RMSE (m)	r^2
Excel (teste de acurácia)	AGL (Above ground level0 x AC (altura de campo)	2,38	0,66
Cubist+excel	AGL + Faixas do Visível (Bandas RGB) x AC	1,34	0,90
Correlator	3 parâmetros de entrada	1,93	0,85

A combinação das faixas do visível RGB + o AGL teve o menor erro médio em relação à altura real, junto com a segunda modelagem no correlator, com diferença de alguns centímetros, fruto de métodos distintos (tabela 2). Dados de alta qualidade que podem ser usados em pesquisas futuras, como no monitoramento ambiental por exemplo.

Em pesquisas de drone e análises de vegetação Boa Morte (2018 e 2020) e Coelho (2019), avaliaram que as estimativas de altura de árvores fiquem próximo de 1 metro. Rabadán et al. (2016), aplicando dados LIDAR, em um plantio de *P. sylvestris*, obtendo a altura em função do diâmetro/área de dossel e DAP (diâmetro acima do peito), teve resultado de erro médio quadrático de 1,35 m. Desse modo, isso mostra que a metodologia aplicada na pesquisa desenvolvida é viável, apresentando dados precisos de estimativa de altura de vegetação, comparado a pesquisas com dados LIDAR que são muito mais trabalhosas.

Calculando a altura de árvores coníferas ((*Chamaecyparis obtusa* (Sieb. Et Zucc.) e *Pinus densiflora*)) tendo como referência a diferença entre o modelo digital de superfície e o modelo digital do terreno utilizando VANT, Iizuka et al. (2017), teve estimativa de altura com erro quadrático médio de 1,72 metros.

Galvêncio & Popescu (2016), em pesquisa de estimativa de altura individual de árvore e diâmetro do dossel de espécies de manguezal com

sensores LIDAR em aeromodelo, teve resultado de erro médio quadrático de 2,8 m correlacionado as alturas das árvores.

Comparado a esses outros métodos, os resultados mostram que a aplicação das metodologias de modelagem para pesquisas que buscam estimar altura de vegetação de manguezal utilizando VANT, mostraram boa precisão com a possibilidade de melhor ajuste se utilizada uma maior amostra de espécies para pesquisas posteriores é indicado utilizar GPS geodésico de melhor precisão para colher os pontos em campo, é técnicas mais acuradas para medir altura das árvores.

A modelagem produziu estimativas de altura significantes como $r^2 = 0,90$ e RMSE = 1,34 m e $r^2 = 0,85$ e RMSE 1,93 metros, que tiveram melhores índices, o que mostra ótima relação do modelo com os dados de altura extraídos do campo, satisfazendo os objetivos projetados. Os três métodos de modelagem tiveram diferentes resultados, mas a de se destacar que ambos se completam, o que se buscou com isso foi ajustar o máximo possível os resultados para que tivessem dentro de uma margem considerável.

O manguezal do Pina é um fragmento de manguezal que se encontra em uma área de intensa ação humana, tendo grande importância geoambiental para a região. A partir das medidas obtidas com os processamentos das imagens de VANT os resultados das estimativas de altura tiveram boa correlação com a altura real, esses dados mostram que as árvores estavam com altura ideal conforme as espécies identificadas, apesar de sofrerem com grande acúmulo de lixo em suas

raízes. Podendo ser aplicado para um monitoramento ambiental da área.

E de se destacar a abordagem inovadora da pesquisa na área de sensoriamento remoto, agregando essas metodologias de modelagem com o uso de imagens obtidas de drone. Em uma área onde dominam as pesquisas com imagens de satélite, essa alternativa de tecnologia é mais acessível é ideal para estudos de vegetação em escala reduzida, tendo um grande potencial de contribuição para a área.

Conclusão

Os resultados mostram uma boa correlação dos dados de altura das árvores de manguezal determinados em campo com os de altura processadas nas modelagens a partir das imagens georreferenciadas de VANT.

Assim, esta tecnologia se mostra adequada e promissora para aplicações relacionadas ao monitoramento ambiental, inventário florestal, agricultura de precisão, com potencial para pesquisas em outros tipos de vegetações ou em outras áreas de mata atlântica pelo litoral do Brasil. E também a possibilidade de dar caminho a pesquisas futuras com maior amostra de espécies que podem resultar em dados ainda mais ajustados, sendo obtidos de maneira mais rápidas que outros métodos convencionais.

Agradecimentos

Agradecimentos ao laboratório de sensoriamento remoto e geoprocessamento da UFPE (SERGEO), ao CNPq pelo financiamento de minha iniciação científica e aos meus orientadores.

Referências

- Andrade, A. C. D. (2008). Gestão de áreas verdes em ambientes urbanos:(uma contribuição á análise e resolução de conflitos sócioambientais) (Master's thesis, Universidade Federal de Pernambuco).
- de Almeida, D. R. A., Broadbent, E., Zambrano, A. A., Christopher, S., & Brancalion, S. (2019). Monitoramento da estrutura de plantios de restauração florestal estabelecidos sob diferentes intensidades de manejo usando drone-lidar. Disponível em: <https://proceedings.science/sbsr-2019/trabalhos/monitoramento-da-estrutura-de-plantios-de-restauracao-florestal-estabelecidos-so?lang=pt-br>
- Boa morte, C. L.; Salvo, D. G. D.; Coelho, R. C. S.; Barros, R. S (2018). “Avaliação da qualidade de ortofotomosaico e mde gerado a partir de vant multirrotor”. 40ª Jornada Giulio Massarani de Iniciação Científica, Artística e Cultural da UFRJ.
- Morte, C. D. L. B., de Carvalho, L. F. S. G., & de Barros, R. S. (2020). Uso de vant como ferramenta para estimativa de altura de dossel em manguezal: um estudo investigativo em guaratiba, rio de janeiro, brasil. Revista Tamoios, 16(3). Doi: <https://doi.org/10.12957/tamoios.2020.55745>
- Bueno, J. O. A., Bourscheidt, V., Pezzopane, J. R. M., BERNARDI, A. D. C., & Crestana, S. (2019). Metodologia para estimar altura de

- árvores com base em imagens aéreas capturadas por drone.
- Jorge, L. D. C., & Inamasu, R. Y. (2014). Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão.
- Câmara, G., & MEDEIROS, J. S. D. (2005). Modelagem de dados em geoprocessamento. *Sistemas de Informação Geográfica: aplicações na agricultura* (ED Assad & EE Sano, eds). EMBRAPA, Brasília, 47-66.
- Dandois, JP, & Ellis, EC (2013). Mapeamento tridimensional de alta resolução espacial da dinâmica espectral da vegetação usando visão computacional. *Remote Sensing of Environment*, 136, 259-276. Doi: <https://doi.org/10.1016/j.rse.2013.04.005>
- Galvêncio, J. D. Popescu, S. C (2016). Medindo a altura individual das árvores e o diâmetro da copa para árvores de mangue com dados LiDAR aerotransportados. *International Journal of Advanced Engineering, Management and Science*, 2 (5), 239456. Doi: <https://ijaems.com/detail/measuring-individual-tree-height-and-crown-diameter-for-mangrove-trees-with-airborne-lidar-data/>
- Graça, N. L. S. de S., A. Mitishita, E., & Gonçalves, J. E.. (2017). Use of uav platform as an autonomous tool for estimating expansion on invaded agricultural land. *Boletim De Ciências Geodésicas*, 23(3), 509–519. <https://doi.org/10.1590/S1982-21702017000300034>
- Hufkens, K., Friedl, M., Sonnentag, O., Braswell, BH, Milliman, T., & Richardson, AD (2012). Vinculando medições de sensoriamento remoto próximo à superfície e por satélite da fenologia da floresta decídua de folha larga. *Sensoriamento Remoto do Meio Ambiente*, 117, 307-321. Doi:10.1016/j.rse.2011.10.006
- Almeida, R., Júnior, C. (2018). Atlas dos Manguezais do Brasil. Ministério do Meio Ambiente, Instituto Chico Mendes de Conservação da Biodiversidade, Brasília.
- Iizuka, K., Yonehara, T., Itoh, M., & Kosugi, Y. (2017). Estimation of tree height and diameter at breast height (DBH) from digital surface models and orthophotos obtained with an unmanned aerial system for a Japanese cypress (*Chamaecyparis obtusa*) forest. *Remote Sensing*, 10(1), 13. <https://doi.org/10.3390/rs10010013>
- De Queiroga Miranda, R., Nóbrega, R. L. B., de Moura, M. S. B., Raghavan, S., & Galvêncio, J. D. (2020). Realistic and simplified models of vegetation and leaf area indices for a seasonally dry tropical forest. *International Journal of Applied Earth Observation and Geoinformation*, 85, 101992. <https://doi.org/10.1016/j.jag.2019.101992>
- Ortega-Farías, S., Ortega-Salazar, S., Poblete, T., Kilic, A., Allen, R., Poblete-Echeverría, C., ... & Sepúlveda, D. (2016). Estimation of energy balance components in a drip-irrigated olive orchard using thermal and multispectral cameras placed on a helicopter-based unmanned aerial vehicle (UAV). *Remote Sensing*, 8(8), 638. <https://doi.org/10.3390/rs8080638>
- De Souza Pereira, F. R. (2016). LiDAR and optical remote sensing applied to above-ground biomass estimation in mangroves: A case study in the Guapimirim APA, RJ. Unpublished Master's thesis, Universidade Federal do Rio de Janeiro.
- Pessoa, M. C. P. Y., Luchiani Junior, A., & Fernandes, E. N. (1997). Principais modelos matemáticos e simuladores utilizados para análise de impactos ambientais das atividades agrícolas. Relatório técnico não publicado.
- Puliti, S., Ene, L. T., Gobakken, T., & Næsset, E. (2017). Use of partial-cover UAV data in sampling for large-scale forest inventories. *Remote Sensing of Environment*, 194, 115-126. <https://doi.org/10.1016/j.rse.2017.03.01>
- Pontes, F., & Freitas, S. (2015). Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, n. 1, p. 6381–6388, 25 a 29 de abril de 2015, INPE.
- Ribeiro, G. G., Pesck, V. A., Dlugosz, F. L., Stepka, T. F., Konkol, I., & Lisboa, G. D. S. (2019). Determinação de altura em *Pinus taeda* L. utilizando veículo aéreo não tripulado. *Nativa*, 7(4), 431-436. <https://doi.org/10.31413/nativa.v7i4.7512>
- Schaeffer-Novelli, Y. (2008). Situação atual do grupo de ecossistemas: Manguezal, marisma e apicum, incluindo os principais vetores de pressão e as perspectivas para sua conservação e uso sustentável. Brasília: Agência Nacional de Petróleo, Gás Natural e Biocombustíveis.
- Soares, C. P. B., de Paula Neto, F., & de Souza, A. L. (2011). *Dendrometria e Inventário Florestal* (2ª ed.). Viçosa: Editora UFV.
- Richardson, A. D., Braswell, B. H., Hollinger, D. Y., Jenkins, J. P., & Ollinger, S. V. (2009). Near-surface remote sensing of spatial and temporal variation in canopy phenology. *Ecological Applications*, 19(6), 1417-1428. <https://doi.org/10.1890/08-2022.1>

- RuleQuest Research. (2020). Data mining with Cubist. Retrieved from <https://www.rulequest.com/cubist-info.html>
- Da Motta Sobrinho, M. A., & de Andrade, A. C. (2009). O desafio da conservação de manguezais em áreas urbanas: Identificação e análise de conflitos socioambientais no Manguezal do Pina–Recife–PE–Brasil. *Revista Unimontes Científica*, 11(1/2), 8-16.
- Souza, C. P. D. (2012). Políticas públicas ambientais e gestão do ecossistema manguezal da Bacia do Pina–Recife/PE: Análise do licenciamento ambiental do Sistema Viário Via Mangue (Master's thesis, Universidade Federal de Pernambuco).
- Rabadán, M. Á. V., Peña, J. S., & Adán, F. S. (2016). Estimation of diameter and height of individual trees for *Pinus sylvestris* L. based on crown delineation using airborne LiDAR data and the National Forest Inventory. *Forest Systems*, 25(1), e001. <https://doi.org/10.5424/fs/2016251-08324>
- Veras, L. (1996). *Ecossistemas de manguezais: Potencialidades e possibilidades*. Recife: Secretaria de Planejamento Urbano e Ambiental.