

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

GRADUAÇÃO EM ENGENHARIA FLORESTAL

BRUNA DE CARLO ARAUJO

DRONES COMO FERRAMENTA DE GESTÃO FLORESTAL:

Desempenho dos índices IRAV (Índice Resistente à Atmosfera na Região Visível) e ITV (Índice Triangular Verde) na estimativa de volume de Eucalyptus.

Macaíba
2022

Bruna De Carlo Araujo

DRONES COMO FERRAMENTA DE GESTÃO FLORESTAL:
Desempenho dos índices IRAV (Índice Resistente à Atmosfera na
Região Visível) e ITV (Índice Triangular Verde) na estimativa de
volume de Eucalyptus.

Trabalho de Conclusão de Curso
apresentado ao curso de graduação em
Engenharia Florestal da Universidade
Federal do Rio Grande do Norte, como
requisito parcial para obtenção do título
de Engenheiro Florestal.

Orientador: Flavo Elano Soares de
Souza

Macaíba
2022

Bruna De Carlo Araujo

**DRONES COMO FERRAMENTA DE GESTÃO FLORESTAL:
Desempenho dos índices IRAV (Índice Resistente à Atmosfera na
Região Visível) e ITV (Índice Triangular Verde) na estimativa de
volume de Eucalyptus.**

Araujo, Bruna de Carlo.

Drones como ferramenta de gestão florestal: desempenho dos índices IRAV (Índice Resistente à Atmosfera na Região Visível) e ITV (Índice Triangular Verde) na estimativa de volume de Eucalyptus / Bruna de Carlo Araujo. - 2022.

50f.: il.

Monografia (graduação) - Universidade Federal do Rio Grande do Norte, Unidade Acadêmica Especializada em Ciências Agrárias, curso de Engenharia Florestal. Macaíba, RN, 2022.

Orientador: Prof. Dr. Flavio Elano Soares de Souza.

1. Silvicultura de precisão - Monografia. 2. Estimativa de volume - Monografia. 3. Índices de vegetação - Monografia. I. Souza, Flavio Elano Soares de. II. Título.

RN/UF/BSPRH

CDU 630*2

Aprovado em 22 de julho de 2022.

BANCA EXAMINADORA

Dr. Flavo Elano Soares de Souza
EAJ - UFRN

Dra. Juliana Lorensi do Canto
EAJ - UFRN

Dr. Getúlio Fonseca Domingues
EAJ - UFRN

Este trabalho é dedicado aos meus pais, Antônia De Carlo Salerno e Ivo Cidinei Lopes de Araujo, que sempre me incentivaram e me deram todo apoio e suporte não só durante a graduação, mas durante toda a minha vida.

AGRADECIMENTOS

Agradeço a todos os colaboradores, que de diversas formas, diretas e indiretas, contribuíram para realização deste trabalho, em especial o professor Flavo Elano Soares de Souza Soares, que foi meu orientador, que me deu o auxílio e as ferramentas necessárias para construção e análise dos dados, ao professor Gualter Silva e professora, Rosimeire Cavalcante dos Santos e a colega mestranda Maria Kelly Ales Gomes da Silva, que permitiram acesso os dados de volumetria da pesquisa dos Efeitos do adensamento de plantio na produtividade e potencial energético da madeira de genótipos de *Eucalyptus* cultivados no Nordeste Brasileiro, que foi estudo de base para comparação com os índices de vegetação gerados.

“Um passo à frente e você já não está mais no mesmo lugar”

(Chico Science)

RESUMO

DRONES COMO FERRAMENTA DE GESTÃO FLORESTAL: Desempenho dos índices IRAV (Índice Resistente à Atmosfera na Região Visível) e ITV (Índice Triangular Verde) na estimativa de volume de *Eucalyptus*.

Este trabalho teve como objetivo associar dados de reflectância de fotografias aéreas RGB capturadas por drone e compara-los com valores de volume de madeira por meio de dois índices de vegetação (IRAV e ITV). O estudo foi conduzido em Macaíba-RN no plantio experimental de eucalipto que integra o programa de pesquisa TECHS-UFRN. As fotografias capturadas foram processadas utilizando o software QGIS, gerando um mapa para cada índice avaliado. Para comparação com os valores de volume das árvores de cada talhão, foi gerado um valor do índice da média dos pixels no raio de 1,5 m da cada árvore que, posteriormente ao voo, foram abatidas para cubagem. A análise de correlação foi feita por regressão linear multivariável, sendo o valor do índice a variável dependente, e o valor do volume a variável independente. O índice IRAV apresentou a maior correlação com os valores de volume das árvores, respondendo melhor estatisticamente do que o índice ITV, principalmente o talhão C3 (*E. grandis* x *E. camaldulensis*), foi o que apresentou a melhor correlação com volume (m³), com valor de $r = 0,60$. O índice ITV apresentou menor correlação com o volume das árvores, se obtendo uma diferença significativa entre os dois índices avaliados. Foi realizada análise de regressão não linear onde foram escolhidos por comparação via AIC, os modelos de regressão que melhor representaram os índices em cada genótipo. As regressões escolhidas foram aplicadas ao mapa índice para comparação com os valores de produção volumétrica (m³/há) por meio do processo de segmentação. Os dois índices mostraram relação positiva com os valores estimados pelo método direto mostrando a maior produção volumétrica nos espaçamentos mais adensados. Os resultados obtidos com este estudo mostram o potencial da utilização dos drones ferramenta de monitoramento para estimativa da produtividade florestal, por meio de análise de regressão de índices de vegetação obtido por aerofotos.

Palavras-chave: Índices de vegetação. Estimativa de volume. Silvicultura de precisão.

GENERAL ABSTRACT

DRONES AS A FOREST MANAGEMENT TOOL: Performance of the IRAV (Index Resistant to the Atmosphere in the Visible Region) and ITV (Green Triangular Index) indexes in the estimate of eucalyptus volume.

This work aimed to associate reflectance data of RGB aerial photographs captured by drone and to compare them with wood volume values using two vegetation indices (IRAV and ITV). The study was conducted in Macaíba-RN in the experimental eucalyptus plantation that is part of the TECHS-UFRN research program. The captured photographs were processed using the QGIS software, generating a map for each index evaluated. To compare with the volume values of the trees of each plot, a value of the index of the average of the pixels in the radius of 1.5 m of each tree was generated, which, after the flight, were felled for cubation. The correlation analysis was performed by multivariable linear regression, with the index value being the dependent variable, and the volume value being the independent variable. The IRAV index showed the highest correlation with the volume values of the trees, accounting better statistically than the ITV index, especially the C3 plot (*E. grandis* x *E. camaldulensis*), was the one that presented the best correlation with volume (m^3), with a value of $r = 0.60$. The ITV index showed lower correlation with the volume of the trees, obtaining a significant difference between the two indexes evaluated. Nonlinear regression analysis was performed where regression models that best represented the indices in each genotype were chosen by comparison via AIC. The chosen regressions were applied to the index map for comparison with the volumetric production values (m^3/ago) through the segmentation process. The two indices showed a positive relationship with the values estimated by the direct method, showing the highest volumetric production in the most dense spacings. The results obtained with this study show the potential of the use of drones monitoring tool to estimate forest productivity, through regression analysis of vegetation indices obtained by aerophotos.

Keywords: Vegetation indexes. Volume estimation. Precision forestry.

LISTA DE FIGURAS

	Página
Figura 1. Assinatura espectral da vegetação.....	09
Figura 2. Mapa da área do experimento TECHS-UFRN.....	16
Figura 3. Delimitação experimental	17
Figura 4. Drone DJI Mavic PRO utilizado para aquisição das imagens.....	18
Figura 5. Câmera Hasselblad modelo L1D-20c, com sensor CMOS de 20MP	19
Figura 6. Distribuição dos pontos de controle no terreno.	21
Figura 7. Ortomosaico TECHS-UFRN	21
Figura 8. Marcação das árvores em cada talhão.....	22
Figura 9. Mapa índice IRAV e ITV	25
Figura 10. Mapa índice IRAV dos talhões R9, E5 e C3.	25
Figura 11. Mapa índice ITV dos talhões R9, E5 e C3.....	26
Figura 12. Relação entre os índices IRAV e ITV para cada genótipo.....	26
Figura 13. Relação índices x volume em m ³ talhão C3, IRAV e ITV.....	27
Figura 14. Relação índices x volume em m ³ talhão R9, IRAV e ITV.	27
Figura 15. Relação índices x volume em m ³ talhão E5, IRAV e ITV	27
Figura 16. Inclinação e roturas observadas na Ortofoto	28
Figura 17. Marcação das árvores no talhão R9.....	29
Figura 18. Exemplo de representação das copas talhão C3	29
Figura 19. Distorções na posição dos objetos por erros de sobreposição	30
Figura 20. Diferenças de brilho e contraste observadas na Ortofoto.....	30
Figura 21. Mapa índice IRAV ajustado pelo modelo de Von Bertalanffy	31
Figura 22. Mapa índice ITV ajustado pelo modelo Exponencial	31
Figura 23. Mapa índice IRAV segmentado por espaçamento.....	31
Figura 24. Mapa índice ITV segmentado por espaçamento.	32

LISTA DE TABELAS

	Página
Tabela 1. Equações dos índices avaliados aplicadas a ortofoto no QGIS.	22
Tabela 2. Relação índice x volume para os talhões analisados.....	23
Tabela 3. Teste de normalidade da média dos valores dos índices IRAV e ITV extraídas por árvore pelo teste de Shapiro-Wilk.	23
Tabela 4. Regressões aplicadas ao QGIS.	24
Tabela 5. Produção volumétrica (m ³ / hectare)	24

LISTA DE ABREVIATURAS

AIC – Akaike Information Criterion

ANAC – Agência Nacional de Aviação Civil

EVI – Enhanced Vegetation Index

GSD – Ground Surface Distance

IBGE – Instituto Brasileiro de Geografia e Estatística

IRAV – Índice Resistente à Atmosfera na Região Visível

ITV – Índice triangular Verde

MDS – Modelo Digital de Superfície

MDT – Modelo Digital de Terreno

NDVI – Normalized Difference Vegetation Index

NDRE – Normalized Difference Red Edge Index

PDI – PROCESSAMENTO DIGITAL DE IMAGENS

SIG – Sistema de Informação Geográfica

SP – Silvicultura de Precisão

SR – Sensoriamento Remoto

TECHS – Tolerance of Eucalyptus Clones to Hydric and Thermal Stresses

VANT – Veículo Aéreo Não Tripulado

VRT – Variable Rate Technology

SUMÁRIO

	Página
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	3
2.1. ÍNDUSTRIA 4.0	3
2.2. SILVICULTURA 4.0	3
2.3. GEOTECNOLOGIA.....	4
2.3.1 Sistema de Informação Geográfica - SIG	5
2.3.2 Sensoriamento Remoto - SR.....	5
2.4. DRONES NA SILVICULTURA 4.0	5
2.4.1. TIPOS DE DRONE	6
2.4.2.1. <i>Multirotor</i>	6
2.4.2.2. <i>Asa fixa</i>	7
2.4.2.3. <i>Regulamentação</i>	7
2.5. AEROFOTOGRAMETRIA	7
2.5.1. Sensores e câmeras.....	8
2.5.2. Composição RGB.....	9
2.6 MODELOS DIGITAIS DE ELEVAÇÃO (MDT E MDS).....	10
2.7. ÍNDICES DE VEGETAÇÃO	11
2.3.1. Índices gerados por sensores multiespectrais	11
2.3.2. Índices gerados por sensores RGB.....	12
2.4.2.1. <i>IRAV</i>	13
2.4.2.2. <i>ITV</i>	13
2.8. ESTIMATIVA DE VOLUME EM FLORESTAS PLANTADAS	14
3. OBJETIVOS	15
3.1. OBJETIVO GERAL	15

3.2. OBJETIVO ESPECÍFICO	15
4. MATERIAL E MÉTODOS	16
4.1. CARACTERIZAÇÃO DA ÁREA.....	16
4.2. ESTIMATIVA DE VOLUME POR CUBAGEM RIGOROSA.....	17
3.1. AQUISIÇÃO DAS EOROFOTOS.....	18
3.1.1. Escala.....	18
3.1.2. Câmera.....	18
3.1.4. Sobreposição das imagens	19
3.1.3. Altura do voo	19
3.1.3. GSD.....	19
3.2. PROCESSAMENTO DIGITAL DE IMAGENS (PDI)	19
3.2.1. Pontos de controle.....	20
3.1.1.2. <i>Tipos de pontos de controle</i>	21
3.2.3. ÍNDICES GERADOS (IRAV e ITV).....	22
5. RESULTADOS E DISCUSSÃO	25
6. CONCLUSÃO	33
7. LITERATURA CITADA	34

1. INTRODUÇÃO

Com os avanços tecnológicos, os processos de produção silvicultural e agrícola têm passado por transformações. A silvicultura de precisão (SP), é um modelo de gestão baseado na coleta e análise de dados geoespaciais, que permite, através do geoprocessamento e cruzamento de dados, a correlação das variáveis que influenciam na produtividade florestal (VETTORAZZI e FERRAZ, 2000). Essas ferramentas viabilizam uma tomada de decisão rápida, diminuindo custos operacionais, tempo de execução das atividades, aumentando a produtividade, tornando os processos de manejo e gestão florestal mais eficientes (ORTIZ et al.2003).

Dentro desse modelo de gestão, a utilização dos drones se destaca pela coleta informações e dados. Por meio de sensores ópticos embarcados de alta resolução espacial e integrados com sistemas de posicionamento geográfico (GPS/GNSS), são capazes de compilar uma grande quantidade de informação cobrindo grandes áreas em um curto período de tempo e com baixos custos operacionais, permitindo coleta de dados em locais de difícil acesso, além de flexibilizar as operações para um momento específico de interesse, como fase fenológica da planta, ou condições meteorológicas, por exemplo. Esses dados associados a conhecimentos técnicos de fotogrametria e ferramentas de geoprocessamento geram informações de alta precisão que vão auxiliar em diversos processos dentro da cadeia de produção silvicultural (GONÇALVES 2015).

A estimativa de volume é um levantamento essencial dentro dos processos de produção florestal, sendo uma das principais finalidades do inventário florestal, essas estimativas podem ser feitas por métodos diretos ou indiretos (MANTOVANI et al, 2005). O método direto consiste na estimativa realizada por cubagem rigorosa, onde as árvores são seccionadas, e o fuste é dividido em várias partes menores, que são mensurados individualmente, e depois são somados para se obter o valor do volume total do fuste, são medições são bastante precisas, porém, são feitas por amostragem destrutiva, demandam bastante tempo e tem o custo elevado. Os métodos indiretos envolvem a estimativa do volume por cálculos dendométricos baseados em dados de diâmetro e altura das árvores, não sendo necessária a destruição da árvore, mas também são bastante onerosos e demorados. A estimativa por sensoriamento remoto

é um método indireto alternativo para a medição de volume, com custo de operação significante reduzido, com o uso de imagens de satélite ou imagens capturadas por drones, por meio de cálculos entre as bandas das informações espectrais da vegetação, correlacionando os resultados com o volume florestal através dos índices de vegetação (LIMA JÚNIOR, C. de et al. 2014).

Com os crescentes avanços nas tecnologias aplicadas á aerofotogrametria, tem se obtido cada vez melhores resultados de estimativas de volume e biomassa em plantios florestais pelos métodos de processamento digital de imagens (PDI). A maior parte dos estudos para estimativa de produção florestal é realizada a partir de imagens do satélite LANDSAT, e câmeras multiespectrais embarcadas em drones, que apresentam informação espectral das bandas em que a vegetação mais responde o infravermelho e infravermelho próximo. O uso dos drones apresenta vantagens em relação ao uso dos satélites, principalmente a maior resolução espacial, e maior nível de detalhamento. As câmeras multiespectrais apresentam uma limitação de uso devido ao valor de mercado, porém é possível se obter informações da vegetação com câmeras comuns RGB, que captam a reflectância da vegetação, na região visível do espectro eletromagnético, considerando a relação entre a atividade fotossintética onde a planta absorve a banda vermelha e azul e o teor de clorofila, onde a planta reflete a banda verde. O bom desempenho desses índices RGB permitiria que qualquer drone embarcado com uma câmera RGB comum fosse utilizado para realizar levantamentos para estimativa de produtividade. Esse estudo foi delineado a fim de associar dados de reflectância gerados a partir de imagens capturadas por câmera comum RGB embarcada em drone de baixo custo, e compra-los aos valores de volume de um povoamento experimental de eucalipto através de dois índices de vegetação, IRAV e ITV.

2. REVISÃO DE LITERATURA

2.1. ÍNDUSTRIA 4.0

A indústria 4.0 se caracteriza pela incorporação de tecnologias de inteligência artificial para execução de atividades e tarefas dentro dos processos de produção, tais como informatização das máquinas e robôs, e conexão dos equipamentos, através da internet das coisas (IoT). Essas tecnologias permitem o gerenciamento e monitoramento de forma remota e em tempo real de todos os processos dentro da cadeia produtiva (SANTOS et al; 2018)

Dentro desse conceito, são fundamentais as ferramentas de computação, baseada na captura e registros de dados de imagens, que viabiliza a análise de um ambiente específico, equipamento ou componente do sistema, as ferramentas de aprendizagem, o aprendizado de máquina (*machine learning*), que através dos fornecimentos de dados o sistema executa tarefas inteligentes, e o aprendizado profundo (*deep learning*) elaborado para o sistema aprender sozinho, interpretando padrões de dados e executando tarefas a partir de várias camadas de dados, que armazenam informações e geram um arquivo de conhecimento. Em relação aos processos operacionais a ferramenta que se destaca é a computação de bordo (edge computing), onde o maquinário possui sensor de IoT, que executa parte do processamento das informações e dados, as enviando em tempo real para uma central, máquina ou equipamento de interesse (SANTOS et al, 2018).

No setor agrário, silvicultura, agricultura e pecuária, a indústria 4.0 emprega essas tecnologias para construir sistemas de suporte ao manejo, gerando aumento da produção, melhorando a segurança nas operações, aumentando a eficiência no uso dos recursos e insumos, inimizando os impactos ambientais e reduzindo os custos operacionais (SANTOS et al, 2019).

2.2. SILVICULTURA DE PRECISÃO

Silvicultura de precisão ou silvicultura 4.0, é um modelo de manejo baseado na coleta de dados georreferenciados de diversos elementos como, topografia, características do solo, produtividade e saúde do plantio, que vão auxiliar nas tomadas de decisões. No manejo convencional, se considera a homogeneidade da área, independentemente do tamanho, sendo adotada uma prática de manejo para toda

área, não considerando suas variações. Porém, as propriedades físicas, químicas e biológicas do solo podem variar em uma mesma área, bem como a produtividade e sanidade do plantio e suas variáveis biométricas (LANÇAS, 2002). Com a análise dos dados fotogramétricos do comportamento espectral da vegetação pode-se obter informações do cultivo de forma rápida, prática e eficiente, por meio de técnicas de fotointerpretação, sendo possível identificar as variabilidades dos elementos dentro de uma mesma área. As imagens georreferenciadas podem ser obtidos por satélites, fotografias aéreas de aviões e drones, e com a utilização de ferramentas e softwares de geoprocessamento, é possível gerar de mapas digitais que servem como base para levantamentos e estimativas de parâmetros biofísicos como volume de madeira e biomassa, orientando o manejo, e as intervenções que serão necessárias no campo de forma localizada e precisa, auxiliando no trabalho de máquinas e equipamentos, permitindo aplicação de insumos em taxa variável (VRT), que permite a aplicação de insumos (defensivos, fertilizantes, adubos) de forma minimizada e localizada, diminuindo os impactos e os riscos de contaminação do solo e dos recursos hídricos, reduzindo tempo de aplicação (RIBEIRO, 2000).

2.3. GEOTECNOLOGIA

As geotecnologias são o conjunto de ferramentas tecnológicas para aquisição, processamento, e análise de dados espaciais, que contém informações de posicionamento geográfico, como satélites, sensores, radares, GPS, computadores, câmeras, e softwares (ROSA, 2011). No monitoramento florestal e na estimativa de produtividade, as geotecnologias são aplicadas na aquisição e cruzamento dos dados espaciais e sensoriamento remoto para amostragem do plantio. Aeronaves que possuem sensor LiDAR (Light Detection and Ranging) e os drones com câmeras multiespectrais tem sido amplamente utilizados para o levantamento de informações de produtividade, inventário florestal, estimativa de volume e biomassa, realizando a coleta dos dados de forma individualizada, árvore por árvore, aumentando a quantidade de informações sobre o povoamento e a precisão das estimativas. Os drones com câmeras RGB apresentam potenciais de uso para esses levantamentos de produtividade por meio de índices de vegetação dentro do espectro visível (LIMA JÚNIOR, C. de et al. 2014).

2.3.1. Sistemas de Informações Geográficas - SIG

Os sistemas de informações geográficas são softwares especializados na aquisição, edição, armazenamento, integração, análise e saída de dados distribuídos espacialmente. Podem analisar uma grande quantidade e variedade de dados com informações espaciais em grandes áreas e diversas regiões geográficas, extraindo novas informações de interesse, avaliando com rapidez fatores isolados ou em conjunto pela triangulação e cruzamento dos dados (CÂMARA E MEDEIROS, 1998). Essa tecnologia está presente nos diversos processos do manejo e da gestão florestal, sendo cada vez mais utilizadas em trabalhos de análise e diagnóstico ambiental, monitoramento, manejo e exploração florestal. Através do SIG é possível fazer a integração dos dados, o sistema é capaz de fazer uma análise combinada e relacionar, através da localização espacial, diversas informações de fontes diferentes fazendo combinações de dados gerando novas informações. O SIG é uma importante ferramenta nos processos de manejo e gestão florestal, que proporciona umas análises mais abrangentes do plantio, tornando as intervenções e tomadas de decisões mais direcionadas e precisas, melhorando os resultados e a produtividade (PANQUESTOR, 2002).

2.3.2. Sensoriamento Remoto - SR

Sensoriamento remoto é a ciência que obtém informações sobre de todas as coisas que estão presentes no globo terrestre sem nenhum contato físico com elas, através da radiação eletromagnética refletida pelos alvos. Essa radiação de reflectância eletromagnética pode ser gerada por fontes naturais, luz do Sol, ou fontes artificiais, satélites e lasers (MOREIRA, 2003). As informações são coletadas por sensores que estão distantes do objeto de interesse ou da área analisada, os dados adquiridos proporcionam a análises de diversos locais de cobertura vegetal, em diferentes escalas (BLASCHKE 2010).

2.4. DRONES NA SILVICULTURA DE PRECISÃO

Drone, do inglês “zangão”, é o nome popular utilizado para caracterizar veículos aéreos não tripulados, remotamente pilotados (VANTs). Os drone são aeronaves autônomas ou controladas por controle remoto, projetadas para não receber piloto humano. A Agência Nacional de Aviação Civil (ANAC), diferencia os drones como aeromodelos, ou aeronaves remotamente pilotadas (RPA), sendo que os aeromodelos

são utilizados para atividades de lazer e recreação, e os RPAs são utilizados para fins agrícolas ou comerciais.

Os drones começaram a ser utilizados na agricultura nos anos 80, sendo amplamente empregados em trabalhos de sensoriamento remoto (MEDEIROS et al 2008). Comparados com satélites os drones apresentam vantagens, principalmente a maior resolução espacial, o maior nível de detalhamento, e o sobrevoo abaixo das nuvens, que elimina os recobrimentos e diminuem as interferências na imagem. Essa tecnologia, foi inserida rapidamente no setor florestal, sendo utilizada em diversas aplicações (NEVALAINEN et al., 2017), cada vez mais agregada aos processos de produção pela facilidade e redução dos custos das operações. Geram dados de alta resolução, com flexibilidade das operações e capacidade da utilização de mais de um sensor embarcado em um único equipamento, conforme a necessidade do levantamento (SALAMÍ et al., 2014). Os sensores, câmeras e sistemas de posicionamento geográfico embarcados (GPS e GNSS) aumentam a velocidade do levantamento, a quantidade e a qualidade dos dados adquiridos, permitindo um manejo de preciso e pontual. Podem ser utilizados em toda cadeia de produção silvicultural, no planejamento operacional são utilizados na prospecção de áreas, e identificação de problemas ambientais, como reserva legal e área de preservação permanente, no planejamento e monitoramento das atividades silviculturais são utilizados para realizar levantamento de informações topográficas para planejamento da mecanização, e controle de pragas, nos inventários florestais são utilizados para estimativa de produtividade e volume, contagem de plantas, acompanhamento do ciclo produtivo e monitoramento do plantio e nas atividades de colheita e transporte são utilizados para cálculos volumétricos de planejamento (FENG, et al, 2020).

2.4.1. Tipos de drones

Dos drones mais utilizados na silvicultura e agricultura podem-se destacar os tipos asa fixa, multirotores. Sendo a sua utilização bastante ampla e diversa, tanto no planejamento com na execução de atividades.

2.4.1.1. Multirotor

Modelo semelhante aos helicópteros, que através de asas móveis de alta rotação por minuto (rotores), permite o voo da aeronave. É um modelo acessível, e de baixo custo, e simples de ser pilotado, porém possui limitações de autonomia e velocidade, sendo inviável a sua utilização para monitoramento quando se trata de

áreas muito extensas. Os motores são elétricos, e os modelos mais avançados têm autonomia de 20 a 30 min.

2.4.1.2. *Asa fixa*

Modelo semelhantes aos aviões, possui a asa em delta que cria a sustentação para o voo e um motor hélice na parte traseira que impulsiona o drone para frente. Necessita de energia apenas para a decolagem, são mais eficientes energeticamente do que os multirrotores. Os motores podem ser elétricos ou de combustão, com autonomia de 40 min a 16 horas, que permite cobrir grandes, e percorrer grandes distâncias.

2.4.1.3. *Regulamentação*

A regulamentação dos drones no Brasil é feita pela Agência Nacional de Aviação Civil (ANAC) através do Regulamento Brasileiro de Aviação Civil (RBAC) nº 94, em vigor desde 2017 (ANAC, 2017). O regulamento determina que todos os drones com peso máximo de decolagem superior a 250 gramas, de uso recreativo (aeromodelos) ou uso profissional (RPAs) devem ser cadastrados no Sistema de Aeronaves não Tripuladas (SISANT 2020).

O cadastramento das aeronaves no SISANT iniciou no ano de vigência do regulamento e, em 2020 a ANAC já tinha mais de 64 mil pessoas cadastradas com quase 80 mil aeronaves, sendo 40% cadastradas para uso profissional (SISANT 2020).

2.5. AEROFOTOGRAMETRIA DE BAIXA ALTITUDE

A Fotogrametria é a medição das distâncias e das dimensões reais dos objetos (tamanho, forma e posição) por meio da fotografia, através de processos de gravação, medição e interpretação de imagens fotográficas e padrões de energia eletromagnética radiante. São registradas por câmeras de alta resolução embarcadas em balões, dirigíveis, aviões e drones (TEMBA 2000).

A aerofotogrametria com drones é semelhante a convencional com aviões, sendo necessários os mesmos processos para geração da ortofoto (fotografia aérea produzida em escala e livre de distorções) de determinada área. É necessário que se faça o planejamento de voo, a sinalização e checagem dos pontos de controle. Comparadas as aerofotogrametrias com aviões, as imagens geradas por câmeras embarcadas em drones têm as etapas de aquisição e processamento mais rápidas,

com maior resolução espacial e temporal e maior autonomia e facilidade das operações, o que permite o monitoramento periódico com menor custo, maior detalhamento, e menor período de tempo para as coletas dos dados (MEDEIROS et al., 2008).

2.5.1. Sensores e câmeras

As câmeras possuem sensores ópticos que se baseiam nas medidas da reflexão da radiação eletromagnética após o contato com as superfícies. Essa onda tem um comportamento específico em resposta à superfície de cada material, e pode ser medida baseada na relação entre energia incidente (irradiância) e energia refletida (radiância). Cada objeto tem um comportamento espectral específico, respondendo conforme sua estrutura atômica e suas propriedades físicas e químicas. Entender o comportamento das ondas espectrais da vegetação e as características que influenciam suas respostas nas diferentes regiões do espectro eletromagnético permite monitorar o plantio, estimar produtividade, e identificar estresses e estado fisiológico das plantas (JORGE e INAMASU, 2014).

Existem diversos tipos de sensores e câmeras que podem ser utilizadas no monitoramento florestal. Como indicador de estresse, os sensores detectam a transpiração e a redução de absorção de CO₂ nas plantas ou a redução na fotossíntese, no caso de estresse hídrico, a temperatura aumenta, podendo ser detectada com câmeras térmicas ou termais, no caso de estresse nutricional pode ser observada a degradação do pigmento fotossintético, o verde. Nos comprimentos de onda na região do infravermelho próximo a reflectância da vegetação é influenciada pela estrutura interna das folhas, seu tamanho, forma e distribuição e absorção de água no interior e pela presença de bioquímicos como celulose, amido, lignina, nitrogênio e proteínas nas folhas (KUMAR, 1998), Nas bandas RGB (red, green e blue), região visível do espectro, a reflectância da vegetação está relacionada aos pigmentos fotossintéticos, basicamente a quantidade de verde presente na imagem, que é associada a presença das clorofilas, antocianinas e carotenoides (CHISHOLM, 2001).

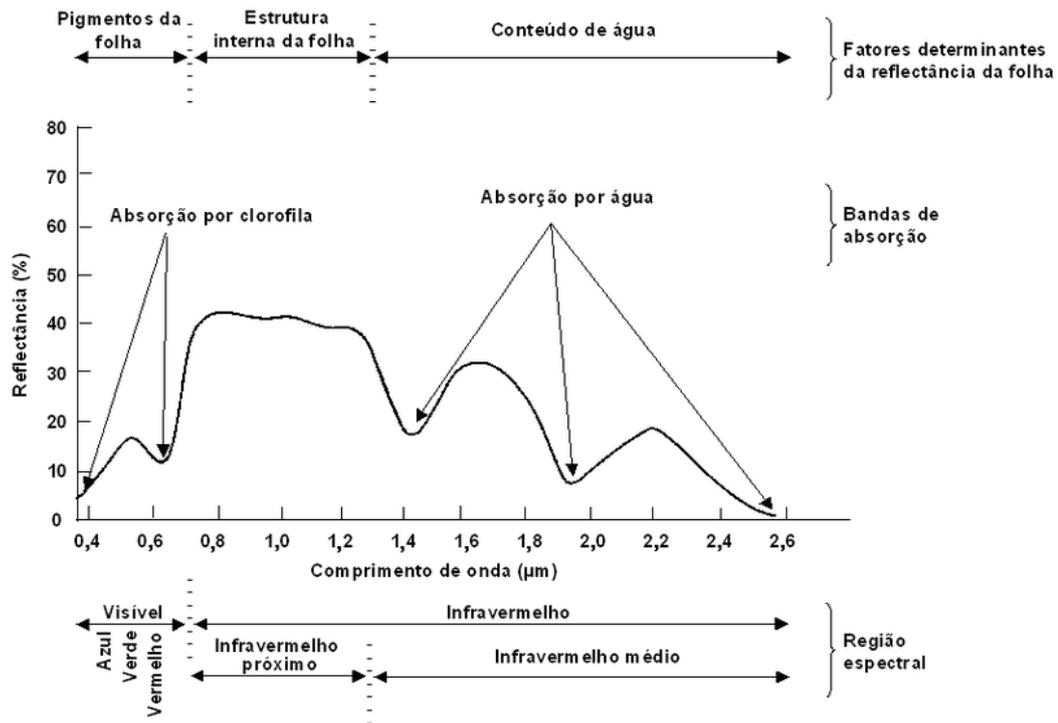


Figura 1. Assinatura espectral da vegetação (RIZZI, 2004).

As câmeras que são mais utilizadas embarcadas em drones dentro da silvicultura e agricultura de precisão são as multiespectrais que possuem múltiplos sensores capazes de captar diferentes bandas do espectro que são refletidas pela vegetação que as câmeras RGB não captam principalmente o infravermelho próximo onde a vegetação tem a maior resposta no espectro eletromagnético, com isso através das imagens geradas por elas é possível identificar estresse nutricional. As câmeras RGB são as mais comuns e capturam as imagens como o olho humano vê. As imagens RGB permitem medir distâncias e áreas, identificar falhas de plantio, monitorar a formação das plantas e desenvolvimento inicial das mudas, monitorar o desenvolvimento da cultura, gerar mapas de declividade e elevação da superfície e do terreno (MDT e MDS) e gerar índices de vegetação.

2.5.1.1. Composição RGB

A imagem RGB (red, green, blue), se refere as faixas do espectro eletromagnético que podem ser vistas pelo olho humano. Uma cor no modelo de cores RGB pode ser descrita pela indicação da quantidade de vermelho, verde, e azul que ela possui. A intensidade das cores varia entre o mínimo, completamente escuro, um e máximo, completamente intenso. Essas imagens possuem informações sobre alvos na superfície, que podem ser obtidos através de técnicas de processamento

para gerar índices de vegetação. A razão de bandas é o método de processamento digital mais utilizado para a geração dos índices, é o processo utilizado para realçar as diferenças de comportamento espectral dos alvos em bandas específicas (CASSEMIRO e PINTO, 2014).

2.6. MODELOS DIGITAIS DE ELEVAÇÃO E SUPERFÍCIE (MDT E MDS)

O MDT e o MDS são produtos muito utilizados dentro dos processos de levantamento, e caracterização de uma área. A representação espacial digital tem objetivo de representar graficamente o relevo e a superfície do terreno, através de dados coletados e processados matematicamente por ferramentas digitais. Podem ser gerados dois principais produtos: o Modelo Digital de Elevação (MDT) e o Modelo Digital de Superfície (MDS), que são de grande importância para a interpretação de dados de elevação (REICHEL e SAMPAIO 2018).

O MDT representa as altitudes da superfície topográfica agregada aos elementos geográficos existentes sobre ela, como cobertura vegetal e edificações, é gerado a partir de um conjunto de pontos criado através do processamento das imagens e cálculos das coordenadas georreferenciadas com dados de elevação, utilizados para representação da superfície física do terreno, não incluindo os objetos acima do solo como vegetação ou edificações. Através do processamento do Modelo Digital de Terreno (MDT) é possível a geração da planta técnica de curvas de nível (CRUZ, 2011).

O MDS também pode ser criado através de um conjunto de pontos com dados de elevação, porém, os pontos gerados da superfície são os reflexos dos objetos acima do solo, das árvores, edificações e volumes sobre o solo. O MDS detalha todos os objetos acima do solo e o MDT detalha apenas o terreno. O produto básico gerado através da Fotogrametria é o MDS e através de um processo de filtragem é gerado o MDT. A filtragem é o processo que exclui, de forma matemática e automática através algoritmos, os objetos presentes acima da superfície do solo (SANTOS et al. 2016).

2.7. ÍNDICES DE VEGETAÇÃO

Índices de vegetação são algoritmos baseados na reflectância do espectro eletromagnético da vegetação, podendo ser indicadores de desenvolvimento fisiológico e saúde do plantio. Cada objeto na superfície terrestre apresenta uma curva única de reflectância (assinatura espectral), essa assinatura, permite que a vegetação

seja detectada e medida por sensores das câmeras em diferentes bandas, possibilitando a classificação de seus elementos (estrutura, pigmentos, conteúdo e absorção de água e temperatura) (LIU 2015).

Os índices de Vegetação são algoritmos desenvolvidos para combinação matemática de duas ou mais bandas espectrais que mostram os diferentes padrões da vegetação. Através de um mapa com coloração indicativa, permite identificar as variabilidades e analisar parâmetros que medem vigor, sanidade, deficiência nutricional, estresse hídrico, ataque pragas e doenças (BASSOI, L. H. et al, 2014).

2.7.1. Índices gerados por sensores multiespectrais

O Índice de Vegetação da Diferença Normalizada (IVDN), é o índice mais utilizado em trabalhos de silvicultura e agricultura de precisão. Está diretamente relacionado com teor de biomassa, densidade e vigor da planta, também pode ser correlacionado com produtividade e área foliar. Foi desenvolvido em 1975 para análise dos dados espectrais do satélite Landsat, para avaliação global da agricultura e silvicultura.

O IVDN é calculado, pela comparação matemática entre a quantidade de luz vermelha visível absorvida e a infravermelho próximo refletido pela vegetação. A clorofila em uma planta saudável absorve a maior parte da luz vermelha visível, e sua estrutura celular reflete a maior parte do infravermelho próximo NIR, a alta atividade fotossintética ou vegetação mais adensada, em menor reflectância na banda vermelha e maior reflectância na banda do infravermelho próximo, relacionando índice IVDN com a densidade o volume e os valores de biomassa.

Fórmula 1: Equação para o cálculo do NDVI:

$$IVDN = (NIR - Vermelho) / (NIR + Vermelho)$$

Outro índice muito utilizado é Índice da diferença normalizada na borda do vermelho (IDNBV). como indicativo nutricional, para avaliar o teor de clorofila e a variabilidade nas necessidades de fertilizantes ou nitrogênio foliar.

A diferença do IVDN e do IDNBV, é que o IDNBV utiliza a banda na borda do vermelho (vermelho próximo). A máxima absorção da clorofila se dá nas ondas vermelhas, entretanto, a luz penetra mais profundamente nas folhas na borda vermelha e verde. Com isso, a sensibilidade aos níveis de clorofila e, conseqüentemente, de nitrogênio, são maiores.

Fórmula 2: Equação para o cálculo do NDRE:

$$IDNBV = (NIR - \text{vermelho próximo}) / (NIR + \text{vermelho próximo})$$

Existem diversos outros índices calculados a partir das bandas espectrais do infravermelho e infravermelho próximo, desenvolvidos para fins específicos como o Índice de Vegetação Aprimorado (IVA), desenvolvido para promover a redução das influências atmosféricas e do solo do dossel no monitoramento da vegetação, sendo utilizado quando a vegetação possui um alto teor de volume e biomassa, onde o IVDN se torna impreciso pela formação de sombras no interior do dossel. O EVI é mais sensível à variação da estrutura do dossel, como área foliar, arquitetura do dossel, e fisionomia da planta e a (HUETE, 2002).

Fórmula 3: Equação para o cálculo do EVI:

$$IVA = 2,5 [(NIR - \text{Vermelho}) / (NIR + 6 \text{ Vermelho} - 7,5 \text{ Azul} + 1)]$$

Uma limitação do uso destes índices é a necessidade de uma câmera multiespectral que capta a reflectância do espectro eletromagnético na região do infravermelho. Essas câmeras possuem um alto valor de mercado, sendo necessário um investimento relativamente alto para sua aquisição, limitando o acesso a essa tecnologia. Porém com uma câmera RGB comum, embarcada na maior parte dos drones de baixo custo, também é possível gerar índices de vegetação para análises fisiológicas do plantio.

2.7.2. Índices gerados por sensors RGB

Sensores RGB são comuns e de baixo custo e podem fornecer informações que auxiliam o manejo e a produção florestal. Os principais índices gerados por câmera RGB são o IRAV (Índice Resistente a Atmosfera), o ITV (Índice Triangular Verde).

2.7.2.1. IRAV (Índice Resistente a Atmosfera)

O Índice Resistente à Atmosfera na Região Visível é baseado na variação de vigor e estresse da planta, a partir da quantidade de verde visível na imagem. Com ele é possível interpretar o desenvolvimento e os estresses do plantio. É usado para análise da vegetação em um ambiente com baixa sensibilidade aos efeitos atmosféricos (GITELSON 2002).

Fórmula 4: Equação para o cálculo do IRAV:

$$IRAV = (Verde - Vermelho) / (Verde + Vermelho - Azul)$$

2.7.2.2. *ITV (Índice Triangular Verde)*

O Índice Triangular Verde se relaciona a quantidade de verde da imagem ao teor de clorofila presente na planta e se aproxima da área de um triângulo que delimita um espectro de reflectância de folha, onde os vértices estão nos comprimentos de onda vermelho, verde e azul. Os valores TGI são positivos quando a reflectância verde é maior do que uma linha entre os vértices do vermelho e do azul e corresponde a vegetação verde. O TGI é negativo quando a reflectância verde é menor que a linha entre os vértices do vermelho e do azul e corresponde ao solo (HUNT, 2011).

Fórmula 5: Equação para o cálculo do ITV:

$$ITV = [(\lambda \text{ Vermelho} - \lambda \text{ Azul}) (\rho \text{ Vermelho} - \rho \text{ Verde}) - (\lambda \text{ Vermelho} - \lambda \text{ Verde}) (\rho \text{ Vermelho} - \rho \text{ Azul})] / 2$$

Onde (λ) representa os comprimentos de onda centrais das respectivas bandas e (ρ) representa os valores de pixel dessas bandas.

Estudos recentes estão comparando os índices IRAV e ITV com o NDVI, apesar de não serem aplicáveis como medidores de saúde da planta, os resultados são significativos, podendo ser utilizado para gerar diversos produtos dentro agricultura e silvicultura de precisão. Gerar índices com câmera RGB traz inúmeros benefícios aos produtores, abrindo o mercado para que qualquer drone que tenha embarcado uma câmera comum RGB, possa ser utilizado para fins agrícolas (QUEIROZ, 2022).

2.8. ESTIMATIVA DE VOLUME EM FLORESTAS PLANTADAS

A estimativa de volume de um povoamento florestal é fundamental, principalmente quando o objetivo é exploração da madeira. É utilizada para avaliar o potencial de crescimento e estimar a produtividade dos plantios, fornecendo informações essenciais para o planejamento da produção (AZEVEDO et al., 2011). Essas estimativas são feitas através de métodos diretos ou indiretos. A utilização do método direto consiste nas derrubadas das árvores, e na mensuração de seus componentes pelo método de Smalian de cubagem rigorosa, no método indireto são aplicadas equações volumétricas com base em dados de altura e diâmetro. Apesar de

eficientes para estimativa de produção de volume ($m^3/há$), são medições que demandam tempo e mão de obra qualificada para serem realizadas, muitas vezes se tornando complicadas, principalmente em regiões de difícil acesso, e áreas com grande declividade ou povoamentos muito densos, o que gera um custo operacional bastante elevado (SANQUETTA e BALBINOT, 2004) Outras limitações ocorrem por quando são necessárias avaliações periódicas ou um levantamento de diferentes fases do plantio, como uma fase fenológica.

Técnicas de sensoriamento remoto podem ser utilizadas como mensuração indireta, para gerar estimativas de volume, por meio de satélites ou fotografias aéreas capturadas por câmeras embarcadas em aviões ou drones, utilizando ferramentas, técnicas e processos de fotointerpretação para correlação entre variáveis estimadas por cubagem rigorosa e equações alométricas de volume que utilizam valores de medições de diâmetro e altura das plantas, com dados de reflectância da vegetação gerados a partir de uma imagem monocromática por meio da combinação das bandas espectrais, permitindo a caracterização da estrutura florestal e mensuração de volume e biomassa, através dos índices de vegetação (WATZLAWICK, 2009).

3. OBJETIVOS

3.1. OBJETIVO GERAL

Avaliar o uso dos drones dentro dos processos de gestão e manejo florestal, com ênfase na parametrização de índices de vegetação aplicados em fotos aéreas coloridas digitais compostas em bandas RGB.

3.2. OBJETIVO ESPECÍFICO

Associar o volume de madeira de um plantio experimental de eucalipto com dados de reflectância gerados a partir de imagens aerofotogramétricas capturadas com câmera RGB comum embarcada em um drone, e compara-las com medições diretas pelo método de cubagem rigorosa por meio de dois índices de vegetação, o Índice Resistente à Atmosfera na Região Visível e o Índice Triangular Verde (IRAV e ITV).

4. MATERIAIS E MÉTODOS

4.1. CARACTERIZAÇÃO DA ÁREA

O estudo foi conduzido no município de Macaíba-RN, utilizando três talhões de eucalipto do plantio experimental TECHS_UFRN, que integra o programa de pesquisa internacional TECHS (*Tolerance of Eucalyptus Clones to Hydric and Thermal Stresses*), parceria entre empresas privadas do setor florestal, e institutos de pesquisa, tendo como objetivo de buscar soluções para os principais tipos de estresse que afetam o cultivo do eucalipto (STAPE, 2014). Em 2013 a Universidade Federal do Rio Grande do Norte (UFRN) passou a fazer parte da rede TECHS com a implantação do 35° experimento TECHS_UFRN, instalado na Escola Agrícola de Jundiá (EAJ), campus de Macaíba/RN, buscado através de estudos e pesquisas, desenvolver modelos para viabilização da expansão do cultivo de eucalipto na região Nordeste, que apresenta limitações e desafios, principalmente as condições climáticas e a escassez hídricas.

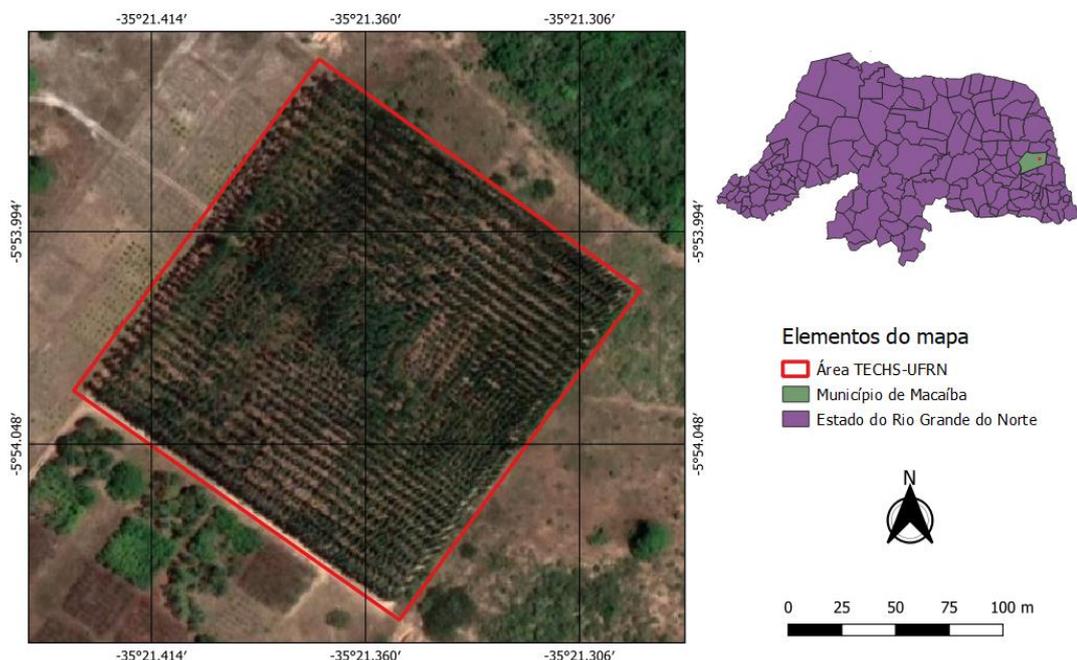


Figura 2. Mapa da área do experimento TECHS-UFRN

A área do experimento TECHS -UFRN é plana, com solo do tipo Latossolo Amarelo, de textura arenosa (BELTRÃO et al., 1975). O clima é subúmido, definido entre As e BSw (classificação de Köppen) com precipitação variando entre 800 a 1200 mm por ano (IDEMA, 2002). O plantio de Eucalipto é composto por 18 talhões de 21

m x 90 m (Figura 3 A). Cada talhão tem um delineamento de 7 linhas e 27 espaçamentos com aumento gradual de 30 cm (Figura 3 C).

Para testar o desempenho dos índices de vegetação IRAV e ITV pela correlação com o volume em metros cúbicos, foram utilizados dados de produção volumétrica de três clones de eucalipto que integram a pesquisa “Efeitos do adensamento de plantio na produtividade e potencial energético da madeira de genótipos de *Eucalyptus* cultivados no Nordeste Brasileiro” onde a autora investiga o potencial bioenergético da madeira de diferentes materiais genéticos que integram a pesquisa TECHS-UFRN. Na pesquisa o volume é estimado por meio da seleção amostral de três árvores em seis espaçamentos diferentes (3 x 0.25; 3 x 1; 3 x 2; 3 x 3; 3 x 5 e 3 x 7), (3C) por método direto de cubagem rigorosa. As árvores selecionadas foram abatidas e seccionadas a partir da base (0,1 m do solo); 1 m; 1,3 m; 2 m; 3 m; 4 m; seguido de pontos equidistantes de 2 m até a altura comercial (5 cm), calculando-se os volumes por secção e depois somando-os para se obter o volume total pelo método de Smalian (SOARES et al., 2006).

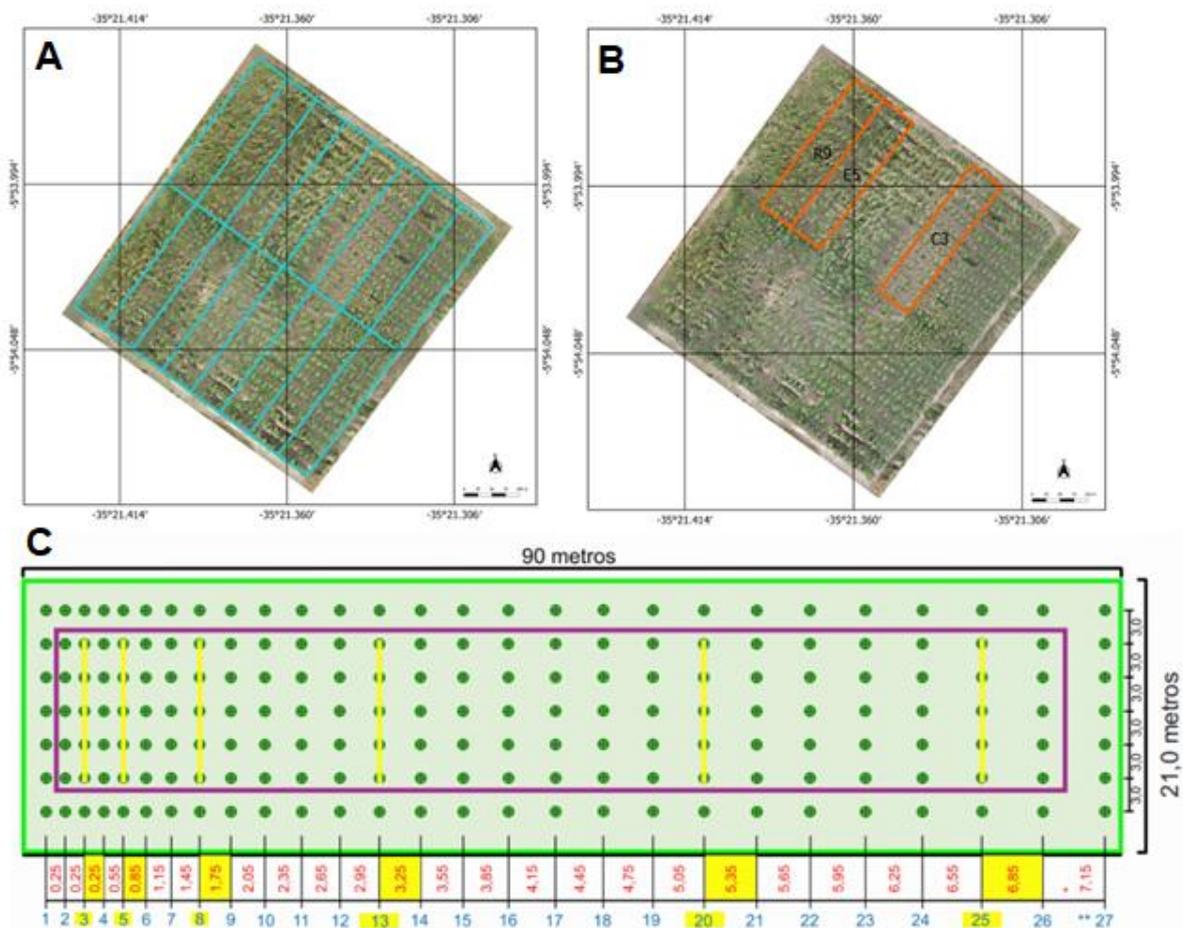


Figura 3. Delineamento experimental.

4.2. AQUISIÇÃO DAS AEROFOTOS

A aquisição das aerofotos ocorreu a partir de um plano de voo, que foi realizado especificamente para a área do TECHS_UFRN por meio do aplicativo DJI GO. As imagens foram capturadas por câmera RGB embarcada no drone da fabricante DJI modelo Mavic PRO (Figura 5). O voo foi realizado no dia 18 de novembro de 2020, às 13h22m.



Figura 4. Drone DJI Mavic PRO utilizado para aquisição das imagens.

Para precisão e confiabilidade dos dados obtidos foram considerados fatores de escala, sobreposição das imagens, altura do voo, GSD e resolução.

4.2.1. Escala

A escala é calculada pela razão entre altura de voo (H) e a distância focal da câmera (f) no momento que a fotografia é tirada (f/H). Pela escala foi dimensionada a área coberta por imagem, e o número de fotografias necessárias para cobertura da área de interesse. Neste trabalho foram tiradas 260 fotografias para cobertura completa da área.

Fórmula 6: Equação para cálculo da escala:

$$E=f/H = (0,028) / (130) = 0.00021538461 \text{ ou } 1:4643$$

4.2.2. Câmera

Foi utilizada a câmera da fabricante chinesa Hasselblad modelo L1D-20c, com sensor CMOS de 20MP, integrante padrão do drone modelo Mavic Pro da DJI.



Figura 5. Câmera Hasselblad modelo L1D-20c, com sensor CMOS de 20MP

4.2.3. Sobreposição das imagens

A sobreposição de imagens é fundamental para a geração do ortomosaico (mapas mosaicos, gerados a partir da união das fotografias capturadas com o drone). Através da sobreposição foi feita a conexão das fotos sequenciais capturadas. O drone utiliza os dados do GPS para conduzir o voo automático, e registra as informações de posicionamento e altitude em cada foto capturada através do GPS. As fotos sequenciais têm pontos em comum com a foto anterior e com a próxima (sobreposição), permitindo a triangulação dos dados em cada ponto. A taxa de sobreposição de imagens para este trabalho foi definida em 75% na faixa longitudinal, e de 25% na faixa lateral.

4.2.4. Altura do voo

A altura do voo, é a distância que a aeronave se mantém do solo durante o voo. Essa distância influencia diretamente na qualidade da imagem, e no número de fotografias necessárias para cobrir uma área. A altura do voo para este trabalho foi definida em 130m.

4.2.5. GSD (Ground Sample Distance)

O Ground Sample Distance (GSD), em português, distância da amostra do solo, é o tamanho em centímetro do pixel. Essa medida determina a resolução e qualidade das imagens, e vai definir o nível de detalhamento do levantamento. Quanto menor o pixel que forma a imagem, menor o GSD e melhor a resolução da fotografia, contendo mais qualidade e detalhamento na imagem final. O GSD para esse trabalho foi de alta resolução e detalhamento, definido em 2.65 cm.

4.3. PROCESSAMENTO DIGITAL DE IMAGENS (PDI)

No processamento digital das imagens realizou-se o processo de ortorretificação, para as correções das distorções dos ângulos de perspectiva da fotografia com a retificação e planificação da imagem, compensando a escala da fotografia em relação à escala do mapa, determinando a orientação real da imagem. Esse processo garante a precisão dos dados coletados em campo para extração dos valores de reflectância da imagem que foi a base deste estudo (Figura 8). Através do ortomosaico também podem ser realizadas medição de áreas, ângulos, distâncias, elevações e volumes. Para a ortorretificação das imagens foram utilizados pontos de controle.

4.3.1. Pontos de controle

Todas as imagens capturadas pelo drone são georreferenciadas pelo sistema de navegação embarcado na aeronave, o GPS (Global Positioning System) e o GNSS (Global Navigation Satellite). O GPS serve para guiar o voo automatizado e gerar as fotos georreferenciadas, porém o sistema GPS pode apresentar limitações, como perda de sinal, e retardo na atualização dos dados devido às condições topográficas e climáticas, gerando um erro de posicionamento geográfico que varia de 5 a 10 metros no mapeamento. Esses erros podem ser corrigidos através de pontos de controle, que são pontos coletados em solo como intersecções no terreno ou objetos alvo, que podem ser identificáveis nas fotografias aéreas capturadas pelo drone. Através desses pontos, se faz a relação entre o sistema de coordenadas da imagem com o sistema de coordenadas do terreno.

4.3.1.1. Tipos de pontos de controle

Existem, dois tipos de pontos de controle, os naturais e os artificiais. Os naturais utilizam elementos visíveis presentes no terreno e identificáveis na imagem, os artificiais, são mais utilizados em áreas rurais, onde o ambiente é mais homogêneo, sendo difícil identificar ndelementos que se destacam na paisagem, utilizando então, alvos artificiais espalhados no terreno. Para esse trabalho, foram escolhidos alvos naturais, sendo suas coordenadas coletadas com um GPS geodésico (GPS de alta precisão), estes receptores coletam as coordenadas de um determinado ponto com uma precisão milimétrica. As coordenadas coletadas pelo GPS geodésico foram inseridas no software QGIS para o geoprocessamento e através da triangulação dos dados as coordenadas foram transferidas para cada pixel da imagem, diminuindo o erro de posicionamento. A quantidade de pontos de controle distribuídos é relativa, variando de acordo com o tamanho da área e suas características. Neste trabalho foram utilizados 20 pontos de controle para realizar a ortorretificação (FIGURA 7).

É possível realizar a correção dos erros de posicionamento geográfico da imagem de forma automática sem a necessidade da marcação de pontos de controle, através dos sistemas RTK (Real Time Kinematic) e PPK (Post Processed Kinematic), erando dados mais precisos e aumentam a rapidez no processamento, otimização do processo de ortorretificação.

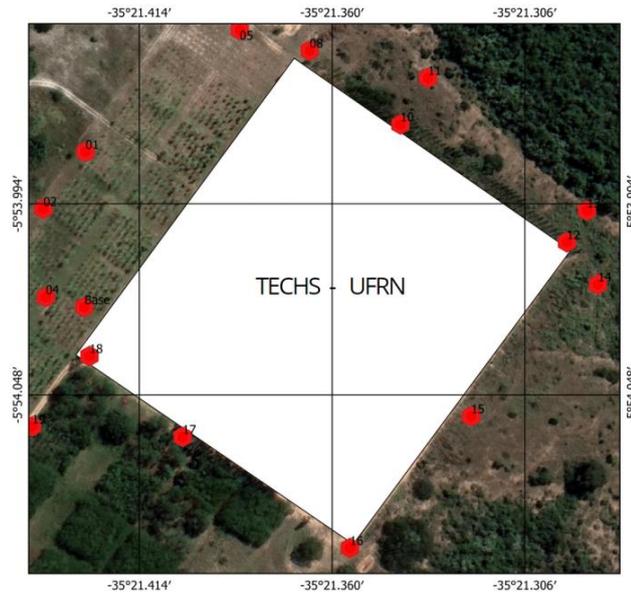


Figura 6. Distribuição dos pontos de controle no terreno.

A partir do ortomosaico foi possível extrair os dados de interesse e realizar os cálculos dos valores de refletância das bandas dos pixels da imagem em que o plantio responde no espectro eletromagnético para gerar os índices de vegetação.



Figura 7. Ortomosaico TECHS-UFRN

A localização das árvores na Ortofoto foi guiada por um croqui de distribuição do talhão indicando quais as que seriam abatidas posteriormente para cubagem e foram marcadas na imagem por meio da vetorização de pontos no o centro das copas, guiados por grade de linhas nas medidas dos espaçamentos conforme o delineamento

experimental TECHS-UFRN. Para extração dos dados de reflectância por árvore foi gerada uma circunferência no raio de 1,5 m a partir do ponto vetorizado representando a copa.



Figura 8. Marcação das árvores por talhão R9, E5 e C3 respectivamente.

4.4. ÍNDICE GERADOS

As equações realizadas entre as bandas dos pixels do ortomosaico pra gerar os índices testados nesse trabalho (IRAV e o TGI) foram calculadas no software de geoprocessamento Quantum GIS (QGIS), pela ferramenta “calculadora raster”.

Tabela 1. Equações dos índices avaliados aplicadas ao ortomosaico pelo QGIS.

ÍNDICE	EQUAÇÃO	AUTOR
IRAV	$(G - R) / (G + R - B)$	Gitelson et al, (2002)
ITV	$[(\lambda R - \lambda B) (\rho R - \rho G) - (\lambda R - \lambda G) (\rho R - \rho B)] / 2$	Hunt et al, (2011)

Onde: G = valores médios da banda do verde; R = valores médios da banda do vermelho; B valores médios da banda do azul; λ = comprimentos de onda bandas; ρ = valores de pixel das bandas.

A média dos índices das árvores de cada talhão foi extraída pela camada vetorial das circunferências das copas marcadas no ortomosaico, gerando um valor índice por árvore para comparação com os valores de volume estimados por cubagem (Tabela 2).

Tabela 2. Relação índice x volume dos genótipos avaliados R9, E5 e C3.

R9					E5					C3				
ARV	ESP	IRAV	ITV	VT	ARV	ESP	IRAV	ITV	VT	ARV	ESP	IRAV	ITV	VT
57	03	0,118	0,486	0,01	52	03	0,109	0,364	0,02	52	03	0,057	0,238	0,05
106	03	0,083	0,435	0,09	59	03	-	-	-	57	03	0,083	0,306	0,02
160	03	0,108	0,399	0,03	106	03	0,014	0,242	0,03	106	03	0,066	0,275	0,01
59	05	0,090	0,460	-	50	05	0,061	0,225	0,18	104	05	0,011	0,195	0,07
104	05	0,072	0,414	0,02	104	05	0,021	0,234	0,03	113	05	0,019	0,23	0,23
113	05	0,090	0,141	0,02	113	05	0,030	0,351	0,13	158	05	0,018	0,276	0,02
47	08	0,028	0,274	0,17	47	08	0,019	0,277	0,16	62	08	0,042	0,262	0,15
62	08	0,012	0,310	0,11	101	08	0,097	0,348	0,20	101	08	0,071	0,335	0,18
155	08	0,087	0,428	0,15	116	08	0,073	0,384	0,20	155	08	0,027	0,273	0,16
42	13	0,086	0,451	0,15	42	13	0,106	0,485	0,30	42	13	0,046	0,283	0,19
67	13	0,048	0,357	0,27	96	13	0,118	0,415	0,26	96	13	0,014	0,294	0,26
150	13	0,094	0,466	0,24	121	13	0,091	0,385	0,36	150	13	0,033	0,289	0,34
89	20	0,077	0,414	0,34	35	20	0,081	0,329	0,50	35	20	0,095	0,414	0,42
128	20	0,088	0,394	0,58	89	20	0,021	0,266	0,58	74	20	0,12	0,443	0,40
143	20	0,024	0,281	0,65	128	20	0,011	0,299	0,60	89	20	0,099	0,398	0,46
30	25	0,117	0,377	0,54	30	25	0,136	0,428	0,45	30	25	0,113	0,345	0,71
79	25	0,061	0,276	0,59	79	25	0,137	0,382	0,64	133	25	0,072	0,264	0,70
133	25	0,049	0,273	0,68	84	25	0,101	0,254	0,58	138	25	0,106	0,386	0,65

Duas amostras não foram incluídas nas análises estatísticas por ausência de dados de volumetria, árvore 59 no espaçamento 05 do talhão R9 (*E. Urophylla*), e árvore 107 espaçamento 03 do talhão E5 (*E. Urophylla*), (Tabela 2). A normalidade dos dados da média dos índices por árvore foi testada pelo teste de Shapiro-Wilk (Tabela 3). Os valores das médias dos dois índices IRAV e ITV, foram considerados normais com valores de “p” acima de 0,05.

Tabela 3. Teste de normalidade da média dos valores dos índices IRAV e ITV extraídas por árvore pelo teste de Shapiro-Wilk.

TALHÃO	ÍNDICE	SHAPIRO W
R9	VARI	p = 0.23
R9	TGI	p = 0.09
E5	VARI	p = 0.06
E5	TGI	p = 0.53
C3	VARI	p = 0.23
C3	TGI	p = 0.29

Foi realizada análise de regressão não linear utilizado o método Stepwise, que por meio do Akaike Information Criterion - AIC (AKAIKE, 1974), testou a qualidade da modelagem por comparação de modelos, utilizando o software PaSt., onde foi

escolhido o melhor modelo matemático para cada talhão considerando os diferentes materiais genéticos avaliados, aplicando as equações dos modelos escolhidos no mapa índice de cada talhão por meio da “calculadora raster” do QGIS, gerando mapas índices ajustados para cada genótipo. Após o ajuste dos modelos foi realizado o processo de segmentação do mapa índice, a fim de correlacionar os valores dos índices com a produção volumétrica (m³/há) estimada pela média dos valores de cubagem por espaçamento.

Tabela 4. Regressões aplicadas ao QGIS.

TALHÃO	ÍNDICE	MODELO	EQUAÇÃO
E5	IRAV	Von Bertalanffy	$25,598*(1-0,99159*\exp(-0,050629x))$
E5	ITV	Exponencial	$18,981*\exp(0,018579x)-18,791$
C3	IRAV	Von Bertalanffy	$110,8*(1-0,99958*\exp(-0,034409x))$
C3	ITV	Exponencial	$10,015*\exp(0,17362x)-10,285$

A partir dos mapas índices ajustados pelas regressões não lineares de Von Bertalanffy para o IRAV e Exponencial para o ITV, foi realizado um processamento para segmentação dos índices, onde o cada mapa índice foi dividido em seis partes, para correlação com os seis diferentes espaçamentos avaliados, 3 m x 0,25 m, 3 m x 0,85 m, 3 m x 1,75 m, 3 m x 3,25 m, 3 m x 5,35 m, 3 m x 6,85 m. Após a segmentação foi realizada a análise do comportamento do índice no mapa a fim de relacionar a distribuição do índice por segmento com as de produção volumétrica de cada genótipo (Figura 19 e 20). A estimativa de volume total em metro cúbico por hectare foi feita pela média dos valores de cubagem de cada espaçamento, multiplicado pelo número de covas. Os dados de mortalidade com base no banco de dados registrados nos inventários que ocorreram a cada seis da implantação do experimento até o abate foram considerados.

Tabela 5. Produção volumetria (m³ / hectare)

R9		E5		C3	
ESP	V (m ³ /ha)	ESP	V (m ³ /ha)	ESP	V (m ³ /ha)
03 x 0,25	400,00	03 x 0,25	120,00	03 x 0,25	285,69
03 x 0,85	46,26	03 x 0,85	461,20	03 x 0,85	514,29
03 x 1,75	316,67	03 x 1,75	397,92	03 x 1,75	337,50
03 x 3,25	234,41	03 x 3,25	287,54	03 x 3,25	243,31
03 x 5,35	341,67	03 x 5,35	389,74	03 x 5,35	272,44
03 x 6,85	318,91	03 x 6,85	215,71	03 x 6,85	339,30

5. RESULTADOS E DISCUSSÃO

Como resultado do processamento da Ortofoto, por meio dos cálculos das bandas de reflectância das imagens conforme descrito na metodologia, foram gerados dois mapas índices (IRAV e ITV), (Figura 10).

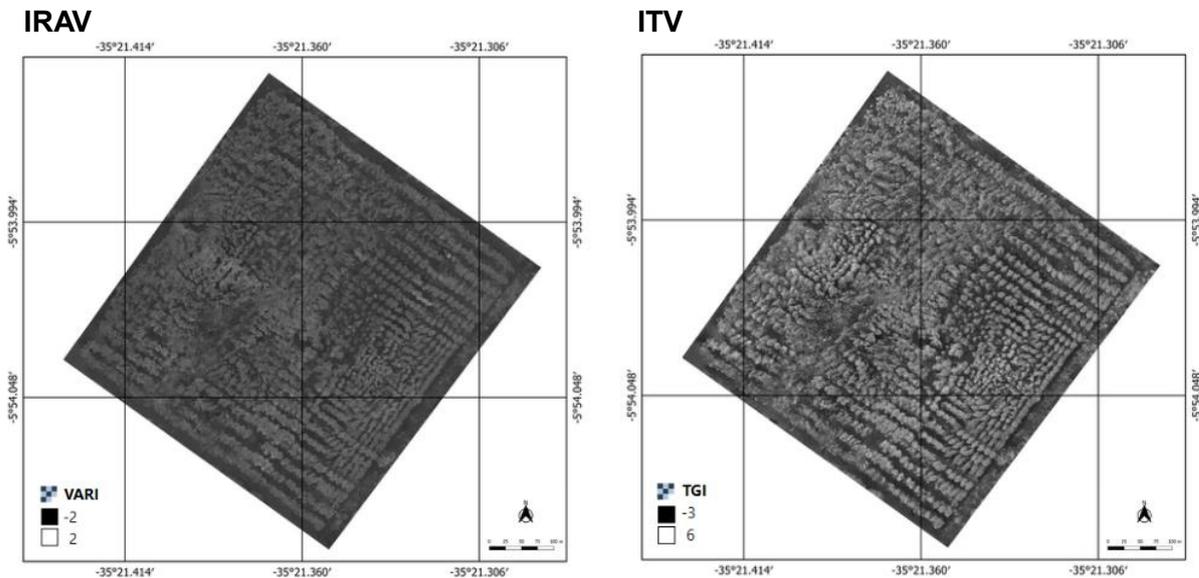


Figura 9. Mapas índices IRAV e ITV.

A fim de facilitar o processamento dos dados foi feito um recorte nos talhões de interesse aplicado uma falsa cor aos mapas índices onde os valores negativos são representados pela cor vermelha e os valores positivos pela cor verde permitindo uma melhor visualização dos mapas e análise das características e comportamento dos índices em cada talhão (Figuras 10 e 11).

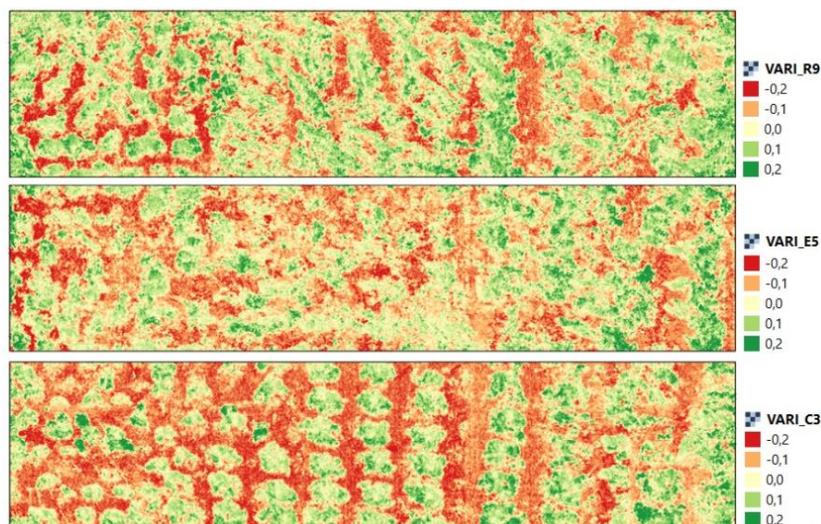


Figura 10. Mapa índice IRAV dos talhões R9, E5 e C3.

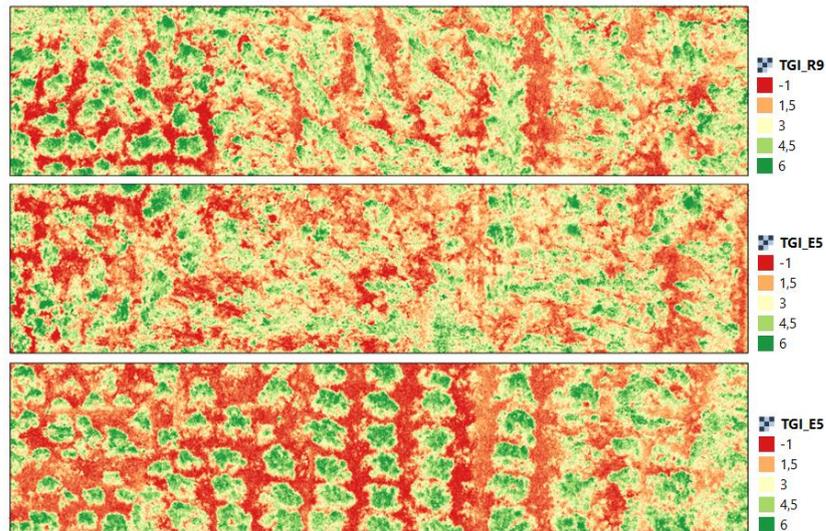


Figura 11. Mapa índice ITV dos talhões R9, E5 e C3.

A comparação entre os valores das médias dos índices IRAV e ITV foi feita por análise de correlação por regressão linear multivariável.

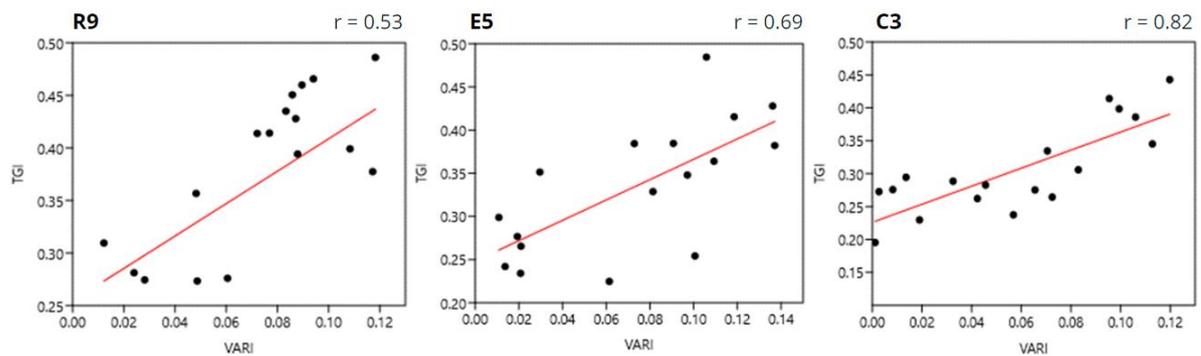


Figura 12. Relação entre os índices IRAV e ITV para cada genótipo.

A correlação entre os valores dos índices IRAV X ITV foi positiva para os três genótipos avaliados, com relação acima de 50% para todos os talhões. O talhão C3 foi o que mostrou maior correlação entre os valores dos índices, com $r = 0,82$, seguido do talhão E5 com de $r = 0,69$. Para correlação entre os valores dos índices com os valores de volume estimados por cubagem foi realizada por regressão linear multivariável sendo o valor do índice a variável dependente e o valor do volume a variável independente.

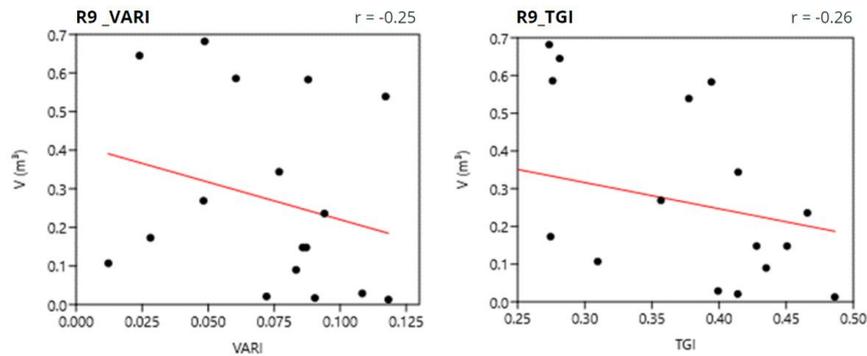


Figura 13. Relação dos índices x volume R9, IRAV e ITV.

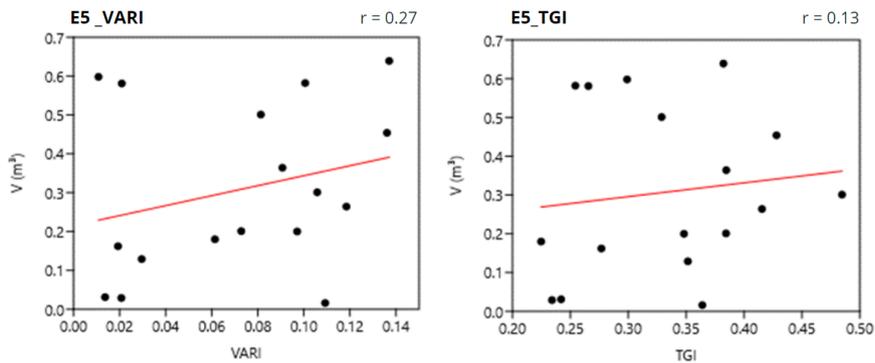


Figura 14. Relação dos índices x volumes talhão E5, IRAV e ITV.

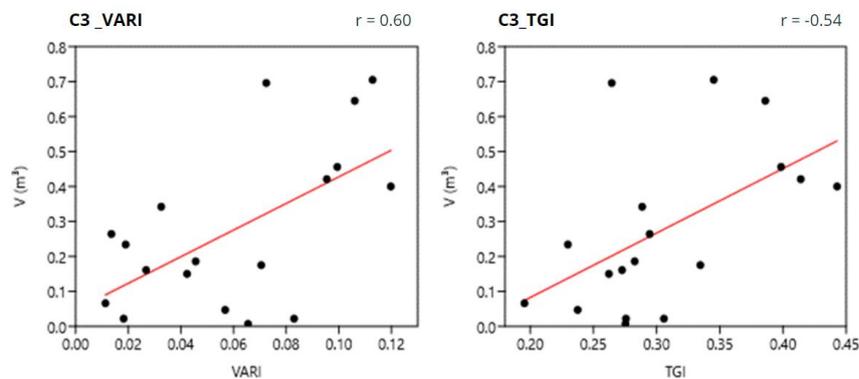


Figura 15. Relação dos índices x volume talhão C3, IRAV e ITV.

Os dois índices testados IRAV e ITV apresentaram relação positiva com o volume estimado por cubagem das árvores. O IRAV teve um melhor desempenho em relação ao ITV para os genótipos E5 (*E. Urophylla*) e C3 (*E. grandis* x *E. Camaldulensis*), com correlação positiva entre as variáveis, $r = 0,27$ genótipo E5, e $r = 0,60$ no genótipo C3. O genótipo R9 (*E. Urophylla*) mostrou relação negativa com os valores de volume para os dois índices avaliados.

A vegetação é um alvo complexo no sensoriamento remoto, e pode apresentar variações no comportamento de reflexão foliar eletromagnética em uma mesma planta

(EPIPHANIO 1996). Essas interferências e os possíveis erros de captura e sobreposição das imagens podem ter limitado as estimativas efetuadas utilizando os índices de vegetação IRAV e ITV, justificando a diferença estatística considerável entre o desempenho dos índices no talhão C3 para os demais. Os dados que foram utilizadas para os cálculos de reflectância entre as bandas, foram medidos a partir de um único sensor RGB embarcado no drone, sendo que o resultado dos valores de reflectância das bandas da vegetação dentro do espectro visível podem ter sofrido interferências e alterações por fatores que envolvem o desempenho do equipamento, como a altura do voo, a inclinação do drone no momento da captura da foto e seu deslocamento pelo vento (Figura 15).



Figura 16. Inclinação e roturas observadas na Ortofoto.

No talhão R9 (*E. Urophylla*) as inclinações das árvores na imagem são bastante acentuadas o que dificultou a marcação das copas pela vetorização de pontos no ápice da planta, gerando uma circunferência pouco representativa da copa, onde os cálculos dos índices sofreram uma interferência acentuada agregando valores negativos ao cálculo da média principalmente nos espaçamentos menos adensados devido à presença de galhos e solo dentro da circunferência que representa a copa (Figura 16).

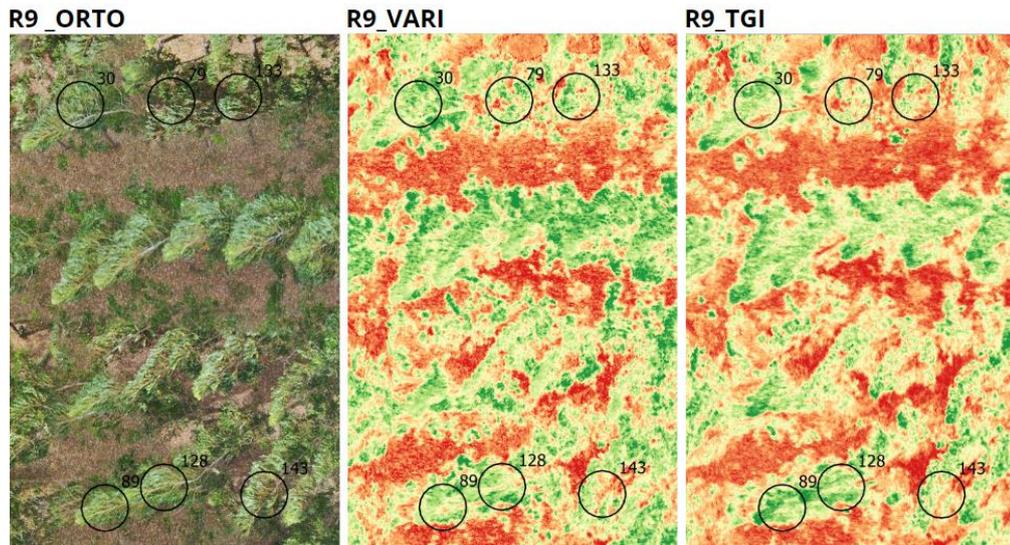


Figura 17. Marcação das árvores no talhão R9 nos espaçamentos 03 x 5,35 e 03 x 6,85.

O talhão E5 também sofreu interferências causadas por inclinações, dificultando a marcação das árvores, porém em menor grau. O talhão C3 foi o que teve a melhor representação das copas pelas circunferências (Figura 17).

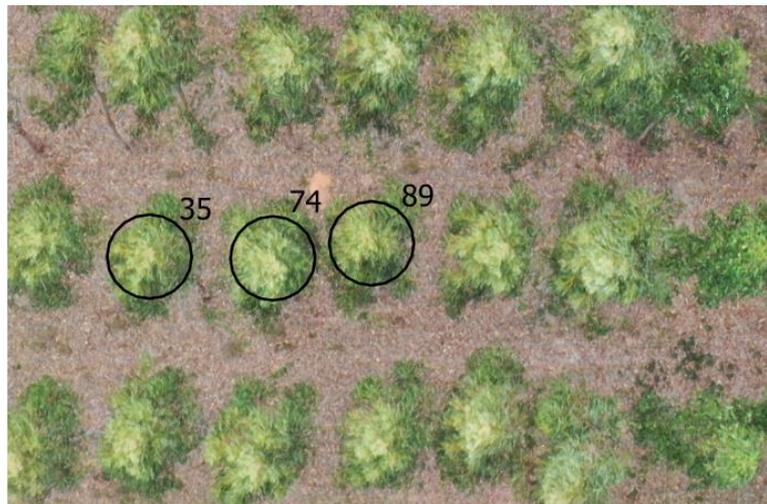


Figura 18. Exemplo de representação das copas talhão C3, espaçamento 03 x 5,35.

Além dos erros que podem ter ocorrido no levantamento das imagens, pela distância da aeronave do solo, e possíveis inclinações do drone causadas por arrasto da aeronave que acabam gerando roturas na imagem dificultando o processo de identificação e marcação das copas, a construção do mapa a partir da sobreposição das fotografias aéreas (aerofotomosaicagem) também pode ter sofrido interferências e alterações mudando a posição dos objetos alvo.



Figura 19. Distorções na posição dos objetos por erros de sobreposição.

Também foi observada a variação de contraste e brilho nas ortofotos, o que influencia diretamente os valores das bandas de cada pixel da imagem final do ortomosaico, que foi a base amostral para todo o estudo.



Figura 20. Diferenças de brilho e contraste.

As formulas dos modelos ajustados pelas regressões não lineares foram aplicadas através de equações matemáticas ao QGIS (Tabela 03) pela ferramenta “calculadora raster”, para melhor modelagem dos índices por genótipo, gerando um mapa índice ajustado. Após o ajuste foi feita a vetorização da camada raster dos índices para gerar um contorno nas copas e melhorar a visualização das árvores na imagem (Figuras 17 e 18).

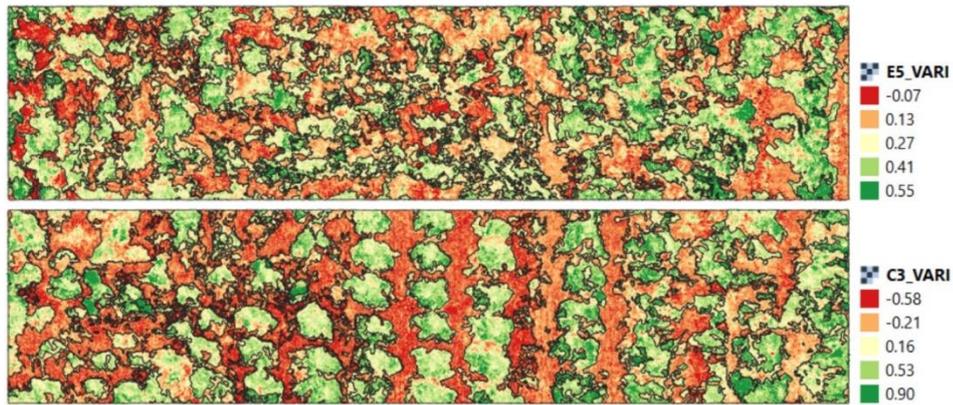


Figura 21. Mapa índice IRAV ajustado pelo modelo de Von Bertalanffy.

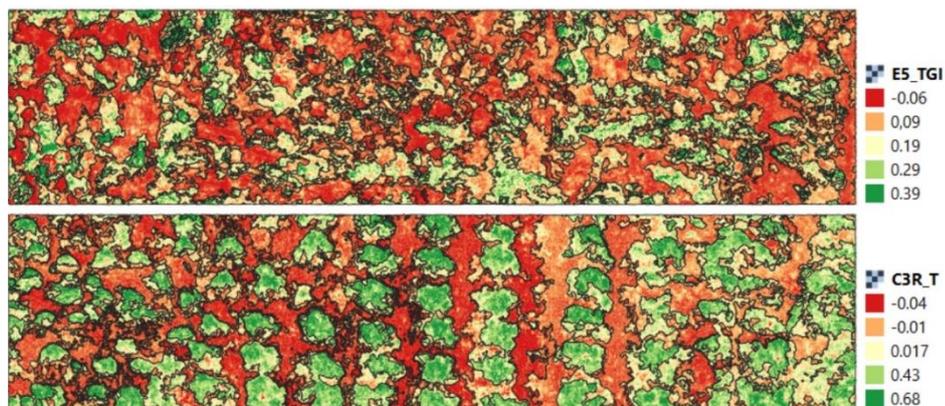


Figura 22. Mapa índice ITV ajustado pelo modelo Exponencial.

O processamento para segmentação do mapa índice foi realizado no QGIS, pela ferramenta “isegment” do GRASS. Onde os valores dos índices foram divididos em seis classes para correlação com a produção volumétrica (m^3/ha) nos seis diferentes espaçamentos avaliados.

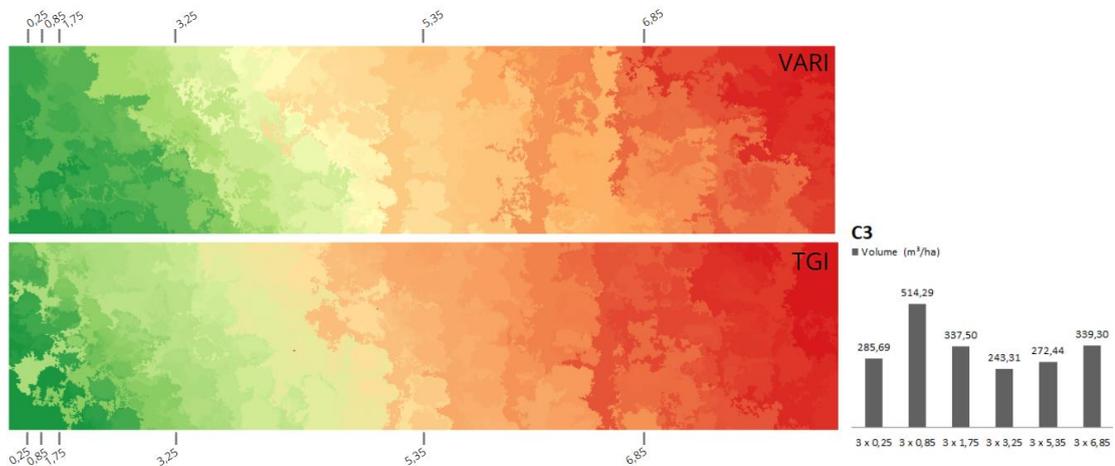


Figura 23. Mapas índices IRAV e ITV segmentados, talhão C3, comparados aos dados de produção volumétrica.

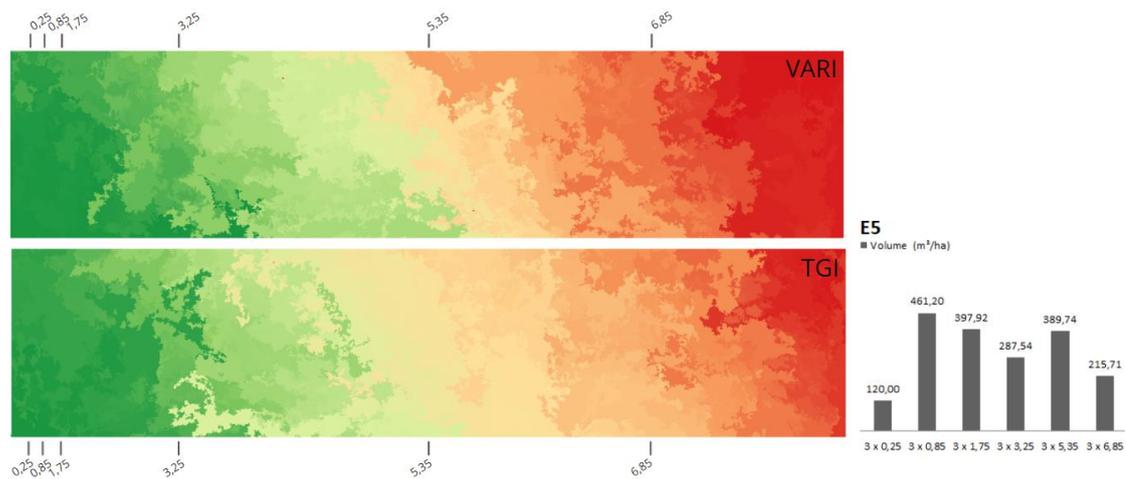


Figura 24. Mapas índices IRV e ITV segmentados, talhão E5, comparados aos dados de produção volumétrica.

Os espaçamentos nos mapas índices segmentados do talhão C3 foram mais bem representados do que no talhão E5, mostrando uma segmentação mais estratificada e visual, sendo mais nítida a representando dos diferentes espaçamentos testados no estudo, principalmente nos espaçamentos mais densos. Em comparação com os dados de volumetria do estudo dos efeitos do adensamento do plantio na produtividade estimados por cubagem os dois índices representaram os resultados apresentados, mostrando uma maior produtividade nos espaçamentos mais adensados (Figura 23 e 24).

6. CONCLUSÃO

Este trabalho mostrou que com o uso de um drone comum, utilizado para captura de imagens aéreas RGB, a partir da construção do ortomosaico, é possível por meio dos índices de vegetação, desenvolver modelos para monitoramento do desenvolvimento do plantio. Os índices avaliados IRAV e ITV, apresentaram potencialidades para estimativa de volume, apresentando relação positiva entre os valores dos índices e os valores de volume (m³) das árvores feitos por medição pelo método direto de Smalian, principalmente o índice IRAV como observado no talhão C3 (*E. grandis* x *E. camaldulensis*), onde a correlação foi superior a 70%, apresentando o melhor resultado entre as variáveis analisadas, índice e talhão. O índice ITV teve um menor desempenho na correlação entre as variáveis com diferença significativa entre os dois índices. Os mapas índices justados e segmentados representaram bem as estimativas de produção volumétrica (m³/ha), mostrando visualmente a maior produção volumétrica nos espaçamentos mais adensados.

Os índices gerados pela razão das bandas na região do visível, capturados por câmera RGB mostram potencial de uso para estimativa do volume florestal, principalmente quando não se tem a disponibilidade do uso de câmera multiespectral que capta informações nas bandas de maior resposta espectral da vegetação, proporcionando uma maior acessibilidade a tecnologia e permitindo que qualquer drone de baixo custo que tenha uma câmera comum RGB embarcada possa ser utilizado para fins de monitoramento do cultivo e estimativa de produtividade.

7. LITERATURA CITADA

ALEMDAG, I. S. National site-index and heightgrowth curves for white spruce growing in natural stands in Canada. *Canadian Journal of Forest Research*, v. 21 1991.

ANAC (Agência Nacional de Aviação Civil), 2017a. Regulamento Brasileiro de Aviação Civil Especial RBAC-E nº 94, de 02 de maio de 2017. Requisitos Gerais para Aeronaves Não Tripuladas de Uso Civil. Resolução nº 419.

ANDERSON, K, GASTON, J.K. Lightweight unmanned aerial vehicles will revolutionize espacial ecology. *Front Ecol Environ* 2013.

AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, Boston, v.19 (6), p.716–723, 1974.

BASSOI, L. H. et al. Agricultura de precisão: resultados de um novo olhar. 2014.

CÂMARA, G.; MEDEIROS, J. S. de. Tendências de Evolução do Geoprocessamento. In: ASSAD, E. D.; SANO, E. *Sistemas de Informações Geográficas*. 2 ed. Brasília: Embrapa, 2003.

CASSEMIRO, G. H. M.; PINTO, H.G. Composição e processamento de imagens aéreas de alta-resolução obtidas com Drone. Trabalho de Conclusão de Curso, Universidade de Brasília, Brasília, 2014.

CHISHOLM, L. A. Characterisation and evaluation of moisture stress in *E. camaldensis* using hyperspectral remote sensing. Sydney: University of New South Wales, 2001.

CRUZ, Carla Bernadete Madureira et al. Avaliação da precisão digital dos modelos de superfície (MDS) obtidos através do LIAR. *Anais XV Simpósio Brasileiro de Sensoriamento Remoto-SBSR*, Curitiba: INPE, v. 2011, p. 5463, 20

EPIPHANIO, José Carlos Neves, et al. "Índices de vegetação no sensoriamento remoto da cultura do feijão. *Pesquisa agropecuaria brasileira* 1996.

FENG Y.;AUDY J. Silvicultura 4.0: Um framework para a cadeia de suprimentos florestal no contexto da Indústria 4.0. *Gestão & Produção*, v. 27, n. 4, 2020.

GITELSON, A.A.; KAUFMAN, Y.J.; STARK, R. et al. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 2002.

HUETE, A., et al. Visão geral do desempenho radiométrico e biofísico dos índices de vegetação MODIS. *Remote Sensing of Environment* 83, 2002.

HUNT, E., C. DAUGHTRY, J. EITEL, and D. LONG. "Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index." *Agronomy Journal* 103, No. 4, 2011.

JORGE, L. A. C, INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. In: In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014. p. 109-134

KUMAR, L. Modeling forest resources using geographical information systems and hyperspectral remote sensing. 1998. 246 f. Tese (Doutorado)-University of New South Wales, Sydney, 1998.

LANÇAS, K.P. Instrumentação para avaliação do desempenho operacional de tratores e variabilidade espacial dos solos. In.: GONÇASVES, J.L.M; STAPE, J.L. Conservação e cultivo de solos para plantações florestais. Piracicaba: IPEF, 2002.

LIMA JÚNIOR, C. de et al. Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índice de vegetação. Embrapa Semiárido-Artigo em periódico indexado (ALICE), 2014.

LIU, W. T. H. Aplicações de sensoriamento remoto. Oficina de Textos, 2015.

MANTOVANI, A. et al. Amostragem, caracterização de estádios sucessionais na vegetação catarinense e manejo do palmitero (*euterpe edulis*) em regime de rendimento sustentável. Núcleo de pesquisas em florestas tropicais. Florianópolis, 2005.

MEDEIROS, F. A., ALONÇO, A. S., BALESTRA, M. R. G., DIAS, V. O., LANDERHAL Jr. M. L.; Utilização de um veículo aéreo não-tripulado em atividades de imageamento georreferenciado. *Ciência Rural*, Santa Maria, v-38, n.8, p.2375-2378, Nov, 2008.

MOREIRA, M.A. Fundamentos do sensoriamento remoto e metodologia de aplicação 2.ed. Viçosa: Universidade Federal de Viçosa, 2003. 307p.

NEVALAINEN, O. et al. Detecção e Classificação de Árvores Individuais com Nuvens de Pontos Fotogramétricas Baseadas em UAV e Imagem Hyperspectral. 2017.

ORTIZ, J.L. et al. Silvicultura de Precisão: mapeamento do potencial produtivo de um povoamento de eucalipto e atributos do solo e do relevo. Piracicaba, 2003.

PANQUESTOR, Evandro Klen et al. Associação de processamento digital de imagens ao uso de definição de parâmetros de unidades de paisagem da Bacia do Rio cCorrente-BA. 2002.

QUEIROZ, D. M. et al. Agricultura digital. Oficina de Textos, 2022.

REICHEL, H. R.; SAMPAIO, T. V. M. Geração de modelo digital do terreno (MDT) a partir da integração de métodos geoestatísticos e dados obtidos com uso de aeronaves remotamente pilotadas (RPAS). In: Anais do XII Simposio Nacional de Geomorfologia, Crato. Anais... Crato: 2018.

RIBEIRO, C.A.A.S. et al. Sistemas de Informações Geográficas. Agricultura de precisão. Ed. Aluizio Borém, Viçosa, MG. 2000. p. 381-407.

ROSA, R. Geotecnologias na Geografia aplicada. Revista Do Departamento De Geografia, 2011.

ROSENQVIST, A. et al. A review of remote sensing technology in support of the Kyoto protocol. Environmental Science & Policy, v. 6, 2003.

SALAMÍ, E.; BARRADO, C.; PASTOR, E. Experiências de Voo de UAV Aplicadas ao Sensoriamento Remoto de Áreas Vegetadas. *Sensor Remoto* 2014.

SANQUETTA, C. R; BALBINOT, C. R. R. Metodologias para determinação de biomassa florestal. In: Fixação de carbono: atualizações, projetos e pesquisas. Curitiba. 2004. p. 77-94.

SANTOS, A. P. et al. Avaliação da acurácia posicional planimétrica em modelos digitais de superfície com o uso de feições lineares. Boletim de Ciências Geodésicas 22, 2016.

SANTOS, BP, ALBERTO, A., LIMA. Indústria 4.0: desafios e oportunidades. Revista Produção E Desenvolvimento, 2018.

SILVA, M. K. A. G. Efeitos do adensamento de plantio na produtividade e potencial energético da madeira de genótipos de Eucalyptus cultivados no Nordeste Brasileiro. Dissertação de mestrado, Universidade Federal do Rio Grande do Norte, 2022.

SOARES, C. P. B., PAULA NETO, F., SOUSA, A. L. Dendrometria e inventário Florestal Viçosa, MG: Universidade Federal de Viçosa, 2006.

SOUSA, C. L., PONZONI, F. J. Avaliação de índices de vegetação e de bandas TM/Landsat para estimativa de volume de madeira em floresta implantada de Pinus spp. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9., 1998, Santos, SP. Anais.... INPE: São José dos Campos, v. 13, 1998.

TEMBA, Plínio. Fundamentos da fotogrametria. Belo Horizonte: UFMG, p. 22-31, 2000.

VETTORAZZI, C.A. e FERRAZ, S. F. B. Silvicultura de precisão: uma nova perspectiva para o gerenciamento de atividades florestais. Agricultura de Precisão. Tradução. Viçosa: Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, 2000.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucária utilizando imagens do satélite IKONOS II. Ciência Florestal, v. 19, p.169-181, 2009.