



UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA
CAMPUS BELÉM
CURSO DE AGRONOMIA

ADYLSO PEREIRA CAMPOS JUNIOR

**USO DE IMAGENS REGISTRADAS POR AERONAVES REMOTAMENTE
PILOTADAS (RPAS) COMO SUBSÍDIO AO MANEJO DE PASTAGENS**

BELÉM - PA
2024

ADYLSO PEREIRA CAMPOS JUNIOR

**USO DE IMAGENS REGISTRADAS POR AERONAVES REMOTAMENTE
PILOTADAS (RPAS) COMO SUBSÍDIO AO MANEJO DE PASTAGENS**

Trabalho de Conclusão de Curso apresentado ao curso de Agronomia da Universidade Federal Rural da Amazônia, como requisito para obtenção do grau de Bacharel em Agronomia.

Orientador: Prof. Dr. Francisco José de Oliveira Parise.

Coorientador: Pesq. Dr. Orlando dos Santos Watrin.

**BELÉM - PA
2024**

Dados Internacionais de Catalogação na Publicação (CIP)
Bibliotecas da Universidade Federal Rural da Amazônia
Gerada automaticamente mediante os dados fornecidos pelo(a) autor(a)

Campos Junior, Adylson Pereira

USO DE IMAGENS REGISTRADAS POR AERONAVES REMOTAMENTE PILOTADAS
(RPAS) COMO SUBSÍDIO AO MANEJO DE PASTAGENS. /

Adylson Pereira Campos Junior. - 2024.

39 f. : il. color.

Trabalho de Conclusão de Curso (Graduação) - Curso de Agronomia, Campus
Universitário de Belém, Universidade Federal Rural Da Amazônia, Belém, 2024.

Orientador: Prof. Dr. Francisco José de Oliveira Parise

Coorientador: Pesq. Dr. Orlando dos Santos Watrin.

1. Degradação de pastagem. 2. Agricultura de precisão. 3. Drones. 4. NDVI. I. Parise,
Francisco José de Oliveira Parise, orient. II. Título

CDD 631

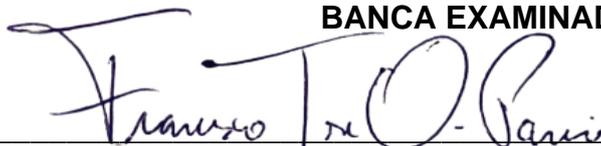
ADYLSON PEREIRA CAMPOS JUNIOR

**USO DE IMAGENS REGISTRADAS POR AERONAVES REMOTAMENTE
PILOTADAS (RPAS) COMO SUBSÍDIO AO MANEJO DE PASTAGENS**

Trabalho de Conclusão de Curso
apresentado ao curso de Agronomia da
Universidade Federal Rural da
Amazônia, como requisito para
obtenção do grau de Bacharel em
Agronomia.

Aprovado em novembro de 2024

BANCA EXAMINADORA



Prof. Dr. Francisco José de Oliveira Parise
Orientador

Universidade Federal Rural da Amazônia – UFRA

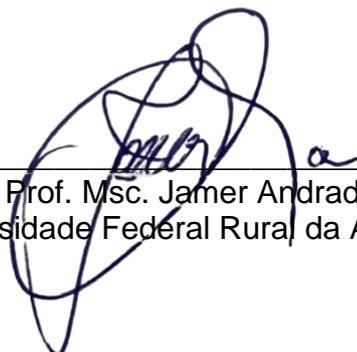


Pesq. Dr. Orlando dos Santos Watrin
Coorientador

Embrapa Amazônia Oriental – EMBRAPA/CPATU



Prof. Dra. Daniele Cristina de Brito Lima Soares
Universidade Federal Rural da Amazônia – UFRA



Prof. Msc. Jamer Andrade da Costa
Universidade Federal Rural da Amazônia – UFRA

DEDICATÓRIA

Dedico este trabalho ao meu amado pai, Adilson Pereira Campos (*in memoriam*), que sempre me incentivou a buscar e alcançar os meus objetivos.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, fonte de força e sabedoria ao longo de toda essa caminhada.

À minha família, que esteve sempre ao meu lado, oferecendo o apoio necessário para que eu pudesse alcançar mais esse objetivo. Em especial, à minha mãe, Vera Lúcia Costa Campos, ao meu pai, Adilson Pereira Campos (*in memoriam*), e ao meu irmão, Mike Jhony Costa Campos, minha eterna gratidão por estarem sempre presentes nos momentos mais importantes da minha vida.

Aos amigos que estiveram comigo ao longo dessa caminhada universitária, compartilhando desafios e conquistas a qual fizeram parte, Sheila Tavares, Paulo Santana, Bianca Gomes, Lívia Prata, e aos demais discentes desta instituição que de alguma forma contribuíram ao longo desta trajetória.

Ao meu orientador, Prof. Dr. Francisco Parise, que não mediu esforços para me que esse trabalho ocorresse em todos os sentidos, e ao meu coorientador da Embrapa Amazonia Oriental, Pesq. Dr. Orlando Watrin, que também foi fundamental para o desenvolvimento deste trabalho. Agradeço ainda aos membros da banca, Professores Jamer Andrade e Daniele Soares, pela disponibilidade e valiosas contribuições para a melhoria deste trabalho.

A todos vocês, minha sincera gratidão por terem feito parte desse momento tão importante na minha vida.

RESUMO

Este trabalho objetivou realizar levantamento aerofotogramétrico com o uso de *Remotely Piloted Aircraft System* (RPAS) equipado com sensor multiespectral, a fim de apresentar uma abordagem voltada para a região amazônica sobre o Índice de Vegetação por Diferença Normalizada (NDVI), realizado em área de pastagem do setor de Zootecnia da Universidade Federal Rural da Amazônia, *campus* Belém, PA. Em que, buscou-se explorar estudos semelhantes com intuito de validar a metodologia, a qual apresentaram resultados satisfatórios em suas avaliações e principalmente em relação as características de cada local analisado, assim, apresentando as melhores aderências sobre os Índices Vegetativos (IVs) com as análises laboratoriais para serem replicadas na condução das pastagens. Uma vez que, a saúde da vegetação ou o declínio sofre influência do manejo, o que pode levar a perda de vigor, deficiências nutricionais e infestações de plantas não palatáveis, o que posteriormente demandará intervenções eficientes para evitar a degradações extremas e de difícil reversão. Nesse contexto, a Agricultura de Precisão (AP) mostra-se efetiva com soluções a serem inseridas no manuseio das gramíneas, pois essas ferramentas como o RPA, combinado com a metodologia do NDVI, permitem monitorar o estágio atual sobre as condições do vegetal, promover economia de recursos, maior assertividade no manejo, possibilitando rápida intervenção em áreas de cultivos, otimização da produtividade e contribuindo para a sustentabilidade das práticas agropecuárias.

Palavras-chave: Degradação de pastagem, Agricultura de Precisão, *Drones*, NDVI.

ABSTRACT

This study aimed to perform an aerophotogrammetric survey using a Remotely Piloted Aircraft System (RPAS) equipped with a multispectral sensor, in order to present an approach focused on the Amazon region on the Normalized Difference Vegetation Index (NDVI), carried out in a pasture area of the Animal Science sector of the Federal Rural University of the Amazon, Belém, PA campus. In this study, we sought to explore similar studies in order to validate the methodology, which presented satisfactory results in their evaluations and mainly in relation to the characteristics of each analyzed location, thus presenting the best adherences on the Vegetative Indices (VIs) with laboratory analyzes to be replicated in the management of pastures. Since the health of the vegetation or its decline is influenced by management, which can lead to loss of vigor, nutritional deficiencies and infestations of unpalatable plants, which will subsequently require efficient interventions to avoid extreme and difficult-to-reverse degradation. In this context, Precision Agriculture (PA) proves to be effective with solutions to be inserted in the management of grasses, as these tools such as RPA, combined with the NDVI methodology, allow monitoring the current stage of the plant's conditions, promoting resource savings, greater assertiveness in management, enabling rapid intervention in crop areas, optimizing productivity and contributing to the sustainability of agricultural practices.

Keywords: Pasture degradation, Precision agriculture, Drones, NDVI.

LISTA DE FIGURAS

Figura 1 - Esquema simplificado do processo de degradação de pastagens em função de suas diferentes fases no tempo	16
Figura 2 - Mapa de localização da área do levantamento aerofotogramétrico no setor de Zootecnia da Universidade Federal Rural da Amazônia	24
Figura 3 - RPA Phantom 4 Pro com sensor Parrot Sequoia	25
Figura 4 - Detalhamento do Sensor Multiespectral Parrot Sequoia	26
Figura 5 - Representação esquemática do comportamento do NDVI	29
Figura 6 - Mapa de detalhamento da pastagem do setor de Zootecnia - UFRA	30
Figura 7 - Imagem de sensor remoto: aplicação de índice de vegetação NDVI em área de pastagem do setor de Zootecnia - UFRA	32

LISTA DE TABELAS

Tabela 1 - Tipos de operação	21
Tabela 2 - Critérios para a classe de RPA	22
Tabela 3 - Comprimento de onda e largura de banda do sensor Parrot Sequoia	26

SUMÁRIO

1. INTRODUÇÃO	12
2. OBJETIVOS	14
2.1 OBJETIVO GERAL.....	14
2.2 OBJETIVOS ESPECÍFICOS.....	14
3. REVISÃO DE LITERATURA	15
3.1 DEGRADAÇÃO EM PASTAGENS CULTIVADAS.....	15
3.2 AGRICULTURA DE PRECISÃO.....	17
3.3 GEOTECNOLOGIAS	18
3.4 <i>DRONES</i> NA AGRICULTURA DE PRECISÃO	19
4. MATERIAL E MÉTODOS	24
4.1 CARACTERIZAÇÃO DA ÁREA	24
4.2 <i>DRONE</i>	25
4.3 SENSOR MULTIESPECTRAL.....	26
4.4 COLETA DOS DADOS	27
4.5 PROCESSAMENTO DAS IMAGENS	28
4.6 OBTENÇÃO DO NDVI.....	28
5. RESULTADOS ESPERADOS	29
6. CONCLUSÃO	34
7. REFERÊNCIAS	35

1. INTRODUÇÃO

A pecuária mundial vem atingindo grandes resultados, sendo em quantidade de cabeças de gado, exportação ou receitas. Esse mercado movimentou no Brasil em 2022 a quantia de 12,97 bilhões de dólares, sendo exportados 2,26 milhões de toneladas de carne para 150 países (ABIEC, 2023). Conforme o relatório anual de estoque de gado do Departamento de Agricultura dos Estados Unidos (USDA), o efetivo internacional de bovinos em 2024 apontou a valores aproximados de 932 milhões de cabeças (USDA, 2024). E ainda, concentra-se basicamente em sete regiões, entre elas estão Índia, seguido de Brasil, China, Estados Unidos, União Europeia, Argentina e Austrália (USDA, 2024). Segundo os dados da Pesquisa da Produção da Pecuária Municipal de 2022 (IBGE, 2023), o rebanho brasileiro atingiu as seguintes quantidades em milhões de cabeças: bovinos (234,4), bubalinos (1,6), caprinos (12,4) e ovinos (21,5).

A área de pastagem no Brasil ocupa 177,3 milhões de hectares (LAPIG/UFG, 2022), sendo a Amazônia o bioma com a maior extensão de pastagens cultivadas no país, totalizando 54,5 milhões de hectares. Entre 1985 e 2020, foi observado um aumento expressivo de 200% nas áreas de pastagem na Amazônia, correspondendo a 38 milhões de hectares acrescidos nesse período (MAPBIOMAS, 2021). Por outro lado, a grande quantidade de áreas exige maior empenho nas questões de manejo correto. Os pastos brasileiros são comumente afetados com a degradação em todas as regiões do país, tornando-as improdutivas e insustentáveis nos âmbitos agrônômicos, econômicos e ambientais (DIAS-FILHO, 2023).

A atividade pecuária deve ter por finalidade ser autossuficiente em todos os aspectos para atender a demanda do mundo inteiro por alimentos. Segundo as previsões da Organização para a Cooperação e Desenvolvimento Econômico (OECD, 2023) e a Organização das Nações Unidas para a Alimentação e a Agricultura (FAO, 2023), deve ocorrer um aumento na demanda por alimentos em 13% até 2032, com acréscimo de 1,3% por ano, em decorrência do crescimento da população mundial, pois de acordo com as últimas projeções das Nações Unidas apontam que a população mundial deve chegar em 8,5 bilhões

em 2030 e 9,7 bilhões em 2050 (NAÇÕES UNIDAS, 2022). Seguindo essas premissas, o aumento da pressão por novas áreas para implantação de pasto é esperado, principalmente em regiões menos desenvolvidas tecnicamente no setor agropecuário.

A Amazônia brasileira é fortemente afetada com desmatamento ilegal, inclusive a criação de gado em áreas protegidas. Estima-se que 70% de florestas desmatadas agora sejam utilizadas para pecuária, mesmo que o Brasil possua leis rígidas para punir quem faz uso dessas práticas, sendo tais crimes burlados através do contrabando, onde o gado é declarado e abatido em área legal (LARADJI *et al.*, 2020).

Nesse contexto, elevar a produtividade aliada a sustentabilidade das áreas de pastagens cultivadas é estratégica e necessária. Para atingir esse objetivo, a Agricultura de Precisão, a partir do recurso das geotecnologias, se mostra como uma excelente alternativa para auxiliar os produtores a otimizarem suas áreas para o melhor aproveitamento em questões de tomada de decisão sobre o manejo de pastagens tropicais. De acordo com D'Oliveira *et al.* (2023), uma das principais funções do sensoriamento remoto voltado à agricultura são detectar as diferenças na reflectância relacionadas à cobertura vegetal. A partir disso, essas informações podem ser verificadas para determinar características como índice de área foliar, biomassa e fotossíntese.

2. OBJETIVOS

2.1 OBJETIVO GERAL

A utilização de RPAS no ambiente agrícola, voltado ao monitoramento e gestão sustentável de pastagens cultivadas.

2.2 OBJETIVOS ESPECÍFICOS

- Realizar o levantamento com sensor multiespectral acoplado em RPA para obtenção de imagens em área de pastagem experimental;
- Processar as imagens obtidas pelo RPA visando a obtenção de índice de vegetação (NDVI);
- Avaliar se o índice de vegetação obtido expressa, de forma qualitativa, a situação de vigor da pastagem selecionada, como preconizado pela literatura científica.

3. REVISÃO DE LITERATURA

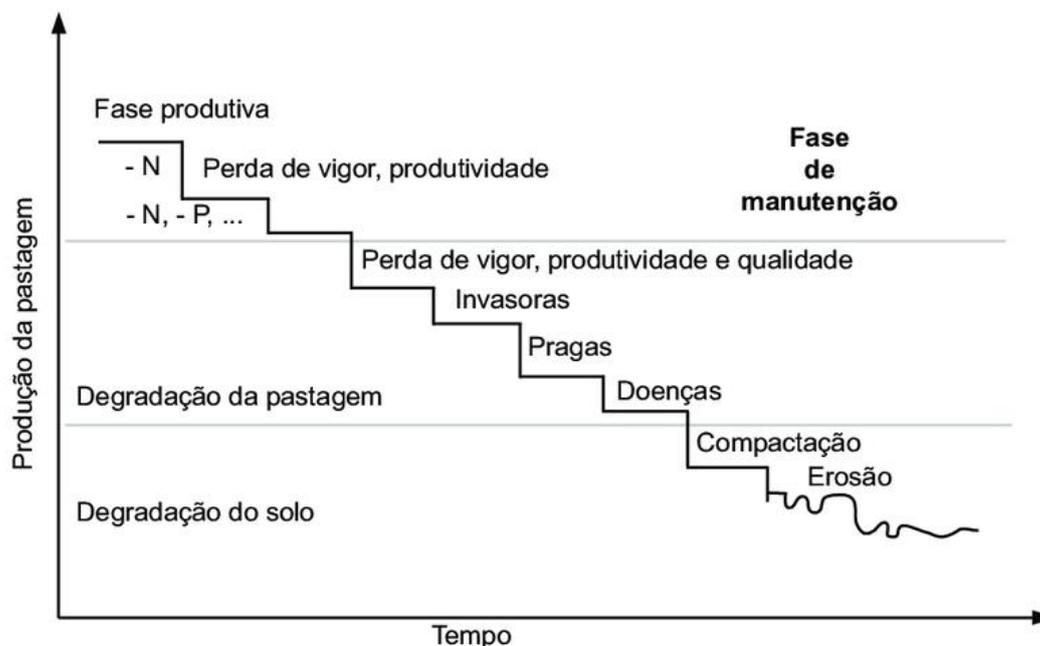
3.1 DEGRADAÇÃO EM PASTAGENS CULTIVADAS

No Brasil as pastagens cultivadas ocupavam até 2021 cerca de 151 milhões de hectares (MAPBIOMAS, 2022). Em levantamento realizado entre 1985 e 2020 apontou que, pelo menos, 252 milhões de hectares são ou já foram em algum período, destinados ao uso de pastagens (MAPBIOMAS, 2021). Em vista disso, houve uma dinâmica intensa ao longo do tempo em relação à cobertura do solo nas áreas de pastagem. Algumas foram convertidas em outros tipos de uso agrícola ou vegetação secundária, pastagens naturais foram substituídas por cultivadas e áreas que antes não eram destinadas a pastagens passaram a ser utilizadas para essa finalidade. Dias-Filho (2011) aponta o valor estimado de 20% das pastagens plantadas e nativas do mundo que estejam degradadas ou em processo de degradação, sendo na Região Centro-Oeste do Brasil, tal cenário é ainda pior, com cerca de 80% nessa situação.

O processo de degradação de pastagem possui entre os indicadores, a baixa produtividade e a baixa quantidade de matéria orgânica. Além de surgirem espécies de plantas invasoras, redução da cobertura vegetal e, conseqüentemente, maior susceptibilidade a ocorrência de erosão do solo, acidez, compactação e menor biomassa microbiana (FONTE *et al.*, 2014). Nesse contexto, as pastagens cultivadas podem sofrer um processo de degradação até chegar ao estágio final a qual denomina-se com o termo “degradada”, muito em função do manejo inadequado. Diversos fatores estão diretamente relacionados à saúde da pastagem, desde a sua formação, como a fertilidade do solo, o controle da taxa de lotação de animais, até o manejo de pragas, doenças e plantas invasoras (DIAS-FILHO, 2023). Em resumo, a degradação de pastagens refere-se ao declínio da produtividade causada por práticas inadequadas de manejo. Como pode ser observado de forma simplificada na Figura 1, o processo contínuo de degradação das pastagens, inicia com a queda do vigor e produtividade e a medida que tal processo avança pode-se chegar ao nível crítico de degradação do solo (MACEDO *et al.*, 2013). A fase de reposição nutricional é limitante para a pastagem manter o seu vigor e produtividade, pois neste momento já começam a ser sentidos os primeiros sinais associados a deficiência de macronutrientes essenciais, principalmente N – Nitrogênio e P – Fósforo. A fase de degradação do

solo é o último estágio do processo de degradação, sendo de difícil reversão, pois relaciona-se aos aspectos físicos do solo.

Figura 1 - Esquema simplificado do processo de degradação de pastagens em função de suas diferentes fases no tempo.



Fonte: TORRES *et al.*, 2018.

Bernardi e Perez (2014) e Silveira *et al.* (2022) apontaram que o sucesso da produção animal a pasto está diretamente relacionado com manejo estratégico e bem planejado, visando o equilíbrio entre a oferta e a demanda de forragem. O bom planejamento, em conjunto com de estratégias corretas de manejo, reflete positivamente a oferta da forragem. No entanto, é fator primordial também se atentar para as questões relacionadas a qualidade dessa forragem, de maneira a atender plenamente as necessidades nutricionais do ruminante. Além de que, a forrageira necessita de condições adequadas para sua permanência de forma efetiva, que inclui ações de manutenção suficientes para promover sua rebrotação rápida e vigorosa. Bernardi e Perez (2014) e Silveira *et al.* (2022) apontam a importâncias do estabelecimento de critérios de manejo como a altura das plantas e a interceptação luminosa (IL), especialmente em torno de 90-95% de IL, pois são práticas importantes levados em conta para definir o momento ideal de pastejo e ajuste da carga animal. As vantagens de adotar estes critérios no monitoramento, permitem que o produtor atinja níveis elevados de produtividade a partir de decisões mais precisas, principalmente sobre o ajuste da carga ou a rotação dos animais, conseqüentemente alcançando a maximização da eficiência em seu manejo animal.

3.2 AGRICULTURA DE PRECISÃO

No final do século XX, no início da década de 80, teve início as primeiras práticas que hoje chamamos de Agricultura de Precisão (AP) (RAMALHO e RODRIGUES, 2021). A mesma pode ser definida como uma estratégia de gestão que utiliza o conceito da geoestatística para abordar questões como as variabilidades espaciais e temporais em campos agrícolas (KARUNATHILAKE *et al.*, 2023). Essa ferramenta fornece “*insights*” baseadas em dados obtidos em campo ou remotamente das mais variadas possibilidades, como por exemplo análise de solo, saúde da vegetação, infestação de plantas invasoras, pragas, doenças, entre outras. A partir disso, podemos otimizar a lavoura com as análises realizadas localmente, ou seja, gera uma economia para os produtores com a racionalização dos insumos e maiores ganhos de produtividade comparado ao método convencional. A metodologia entende como uma superfície heterogênea, que constantemente sofre mudanças devido ao ambiente, com isso, munidos de indicadores para aplicações sítio-específica de fertilizantes, sementes, pesticidas, água e outros recursos (BASSOI *et al.*, 2019).

Historicamente a Agricultura de Precisão observou um avanço desde a substituição da tração animal pela mecanização e o advento da digitalização computacional na agricultura. Para Sharma *et al.* (2021), a revolução da agricultura no primeiro momento ocorreu com a mecanização e depois com a revolução verde, posteriormente a AP se tornaria a terceira revolução. Em 1983, nos EUA, foi aberto para uso civil a tecnologia GPS. Com isso, algumas fazendas adotaram a ferramenta, entretanto, foi explorada pioneiramente em AP na Alemanha e na Dinamarca, em 1988, onde foi inserida a questão das taxas variáveis de insumos como resultado do mapeamento (KARUNATHILAKE *et al.*, 2023). Por outro lado, Molin *et al.* (2015) aponta os EUA como país pioneiro, quando a Universidade de Minnesota reuniu um grupo de pesquisadores da área de solos, que observaram a variabilidade espacial ocasionada pela própria interferência humana no manejo do solo e também ocorrendo a aplicação automatizada de adubos com taxas variáveis. Em 1992 foi criada na Universidade de Minnesota a *International Conferences on Precision Agriculture* (ICPAs), uma iniciativa do Professor Pierre C. Robert que fazia parte do departamento de solos e considerado “pai” da Agricultura de Precisão. Outro fato importante na história

da AP, ocorreu em 2010 por iniciativa do também professor Raj Khosla, docente da Universidade Estadual do Colorado, que criou a *International Society of Precision Agriculture* (ISPA), em Forte Collins, EUA (ARNÓ *et al.*, 2016).

A ferramenta da AP só foi introduzida no Brasil por volta de 1990, através da importação de maquinário embarcado com a tecnologia GPS, mais especificamente colhedoras com monitor de produtividade. Por outro lado, o uso de fertilizantes com taxas variáveis foi inserido apenas no final desta década, com máquinas nacionais que permitiam trabalhos de aplicação de taxas variáveis (MOLIN *et al.*, 2015).

Atualmente, vivemos uma nova era da Agricultura de Precisão, denominada Agricultura 4.0, a qual representa a evolução dos processos agrícolas, com a coleta automatizada de dados no campo por meio de sensores e fontes externas, possibilitando a análise e integração de informações (SPONCHIONI *et al.*, 2019). Com isso, gera-se informações mais completas para a tomada de decisão. A Agricultura 4.0 é um neologismo que surge a partir do conceito de Indústria 4.0, pois remete a Revolução Digital Agrícola, onde podemos apontar as tecnologias como a Inteligência Artificial (IA), *Big Data*, Computação em Nuvem, Robótica, *Internet of Things* (IoT), Sensoriamento Remoto e *Blockchain* (BERTOGLIO *et al.*, 2021).

Schellberg *et al* (2008) apresentou estudos em relação as suas potencialidades, benefícios e limitações do uso da AP em sistemas de pastagens. As ferramentas de AP são comumente utilizadas em culturas de grãos, hortícolas, fruteiras e silvicultura, entretanto, existe grande potencial para uso nos sistemas de produção animal aplicados no manejo de pastagens tropicais para ruminantes (BERNARDI e PEREZ, 2014).

3.3 GEOTECNOLOGIAS

As geotecnologias surgiram como ferramentas de suporte para gerenciamento de dados sobre informações espaciais nas mais variadas áreas, sendo no ambiente rural, relevante desde o levantamento de dados à tomada de decisão (SOUZA *et al.*, 2015; SANTOS e SILVA, 2017). Assim, sua utilização torna-se cada vez mais presente no campo por proporcionarem variadas soluções para as atividades agrícolas (ALMEIDA, 2016). Essas tecnologias envolvem unidades para aquisição, armazenamento, processamento e análise de dados

geoespaciais, que, direta ou indiretamente, permeiam alguma dinâmica da atividade agrícola (MACÁRIO *et al.*, 2020). As geotecnologias podem ser definidas como, pacote de inovações tecnológicas voltadas às geociências e suas correlações, buscando trazer avanços significativos às áreas nas quais está inserida, como a pesquisa, o planejamento, a gestão e o manejo do espaço geográfico (FITZ, 2008).

As geotecnologias as quais envolvem soluções em *hardware*, *software* e *peopleware*, contemplam poderosas ferramentas, como os Sistemas de Informação Geográfica (GIS), a Cartografia Digital, o Sensoriamento Remoto, o Sistema de Posicionamento Global (GPS) e a Topografia (ROSA, 2005). A inserção dessas ferramentas em alguma etapa das atividades agrícolas é de grande importância, pois contribui significativamente para uma ampla gama de aplicações e geração de dados. Nesse sentido, a partir da obtenção dos dados de sensoriamento remoto, por exemplo, pode-se identificar diferentes níveis de degradação por meio da análise do comportamento espectral dos alvos de interesse (GAO *et al.*, 2006).

As aplicações de métodos modernos com base nas geotecnologias estão sendo utilizados para desenvolver novas técnicas para identificação, acompanhamento e qualificação de pastagens em diferentes escalas espaço-temporais (ANDRADE *et al.*, 2023). Geralmente, tais análises sobre o monitoramento de pastagens a partir do uso de sensores remotos são encontradas na literatura através da aplicação de Índices Vegetativos (IVs).

3.4 DRONES NA AGRICULTURA DE PRECISÃO

Historicamente os *drones* foram relatados pioneiramente em 1849, a partir do uso militar pelo exército austríaco. Posteriormente, em 1940, Reginald Denny e Walter Righter são considerados como os primeiros a utilizarem os modelos guiados via rádio "*radioplane*". Desde então, a ferramenta seguiu com seu uso majoritário para fins militares, com significativos avanços técnicos observados durante a Segunda Guerra Mundial, pelos alemães, e a Guerra do Golfo, pelos norte-americanos (MCDAID e OLIVER, 2003). O engenheiro norte-americano Abraham Karem, em 1980, lançou o primeiro *drone* moderno com o objetivo de provar que veículos aéreos não tripulados poderiam ser confiáveis e capazes de voar por longos períodos (HOMBURG, 2017). Esse pioneirismo foi

obtido a partir da construção do aeromodelo *Albatross* que estabeleceu um recorde ao voar por 56 horas consecutivas e completar 500 voos sem acidentes.

A Agricultura de Precisão tem desempenhado um papel crucial no avanço do setor agrícola, sendo que uma de suas principais contribuições vêm dos *Remotely Piloted Aircraft System* (RPAS), popularmente conhecidos como "drones". Atualmente, os RPAS estão se tornando uma parte essencial da agricultura de precisão, contribuindo para a sustentabilidade do setor agrícola (RANI *et al.*, 2019). O equipamento utilizado na agricultura de precisão agrega muitos benefícios para os produtores, sendo o principal deles a economia de recursos financeiros no manejo de suas colheitas, aumentando o rendimento e a produtividade (MAKHDZIR, 2017). Além disso, são ferramentas muito versáteis, visto que, podem ser utilizados nas mais variadas situações e especificidades. Por exemplo, são eficazes em fases fenológicas específicas das plantas, permitindo coletas de dados de alta qualidade e intensidade. São ideais para uso em áreas onde maquinários maiores não podem operar, garantindo acesso a terrenos de difícil acesso. Os *drones* podem ser amplamente aplicados na agricultura de precisão para diversas atividades, como a contagem de plantas, pulverização de insumos como, fertilizantes, sementes e defensivos agrícolas, além de serem utilizados para mapeamento e monitoramento da saúde vegetal (KHORRAMNIA *et al.*, 2014; MAKHDZIR, 2017).

O equipamento, além de sua aeronave, conta com uma Estação de Controle em Solo, chamada *Ground Control Station* (GCS), que transmite comandos por meio de um *Joystick*. Muito embora seja possível controlá-lo manualmente, é recomendável planejar uma missão previamente, permitindo que sua execução seja acompanhada remotamente (OLIVEIRA *et al.*, 2020). Dessa maneira, a partir da GCS é possível visualizar em tempo real a execução da missão por meio do posicionamento de referência do drone. A localização e sua acurácia sobre os pontos de GPS, dependem de uma conexão com uma base fixa de correção dos pontos dos sinais de satélites GNSS.

No Brasil, a popularização dos *drones* exigiu que os órgãos competentes criassem uma regulamentação específica, visto que a facilidade de aquisição desses equipamentos poderia acarretar em consequências negativas se fossem usados para fins inadequados ou criminosos, além de aumentar o risco de acidentes. Nesse sentido, foram tomadas medidas regulatórias, culminando na

aprovação do Regulamento Brasileiro de Aviação Civil Especial (RBAC-E nº 94) pela ANAC, em 2 de maio de 2017. O referido regulamento complementa outros atos normativos já existentes, como as do Departamento de Controle do Espaço Aéreo (DECEA) e da Agência Nacional de Telecomunicações (ANATEL), reforçando o controle sobre o uso dos *drones* e garantir maior segurança e legalidade em suas operações (BRUM *et al.*, 2019).

Pelo regulamento da ANAC, **Aeromodelos** são aeronaves não tripuladas utilizadas para lazer. **RPA** são aeronaves não tripuladas usadas para outros fins, como corporativo ou comercial. **Aeronaves Não Tripuladas Autônomas**, nas quais não há interferência do piloto durante o voo, não estão contempladas na norma e sua utilização continua proibida no Brasil (ANAC, 2017).

A partir da regulamentação da ANAC sobre RPAS, são estabelecidas normativas específicas para autorizações de voo, a depender da classe do *drone*. Esses requisitos incluem também aeromodelos em algumas situações específicas. Entre os critérios regulamentados, é importante que a operação siga os preceitos de segurança, como a visibilidade do drone durante todo o voo (Tabela 1), o que é conhecido como BVLOS, VLOS e EVLOS.

Tabela 1 - Tipos de operação.

Operação BVLOS (<i>Beyond Visual Line-Of-Sight</i>)	Operação VLOS (<i>Visual Line-Of-Sight</i>)	Operação EVLOS (<i>Extended Visual Line-Of-Sight</i>)
Operação na qual o piloto não consegue manter a RPA dentro de seu alcance visual, mesmo com a ajuda de um observador.	Operação na qual o piloto mantém o contato visual direto com a RPA (sem auxílio de lentes ou outros equipamentos).	Operação na qual o piloto remoto só é capaz de manter contato visual direto com a RPA com auxílio de lentes ou de outros equipamentos e de observadores de RPA.

Fonte: Adaptado de ANAC, 2017.

De acordo com a regulamentação, as categorias de aeronaves e seus respectivos requisitos técnicos são detalhados em documentos como o RBAC-E nº 94 e normativas do DECEA. Na (Tabela 2), podem ser observados de maneira

resumida os principais critérios para operadores seguirem os requisitos para enquadramento em suas respectivas classes de operação do RPA, e também sobre a categoria de Aeromodelos (ANAC, 2017).

Tabela 2 - Critérios para a classe de RPA.

Resumo da Regulamentação da ANAC				
	RPA Classe 1 Máx >150 Kg	RPA Classe 2 Máx >25 kg e até 150 kg	RPA Classe 3 Máx até 25 kg	Aeromodelos
Registro da aeronave?	Sim	Sim	BVLOS: Sim VLOS: Sim ¹	Sim ¹
Aprovação ou autorização do projeto?	Sim	Sim ²	Apenas BVLOS ou acima de 400 pés ²	Não
Limite de idade para operação?	Sim	Sim	Sim	Não
Certificado médico?	Sim	Sim	Não	Não
Licença e habilitação?	Sim	Sim	Apenas para operações acima de 400 pés	Apenas para operações acima de 400 pés
Local de operação	A distância da aeronave não tripulada NÃO poderá ser inferior a 30 metros horizontais de pessoas não envolvidas e não anuentes com a operação. O limite de 30 metros não precisa ser observado, caso haja uma barreira mecânica suficientemente forte para isolar e proteger as pessoas não envolvidas e não anuentes. Esse limite não é aplicável para operações por órgão de segurança pública, de polícia, de fiscalização tributária e aduaneira, de combate a vetores de transmissão de doenças, de defesa civil e/ou do corpo de bombeiros, ou operador a serviço de um destes.			

¹ Todos os aeromodelos acima de 250 gramas e RPA entre 250 gramas e 25 kg que se destinem a operações na linha de visada visual (VLOS) até 400 pés acima do nível do solo, devem ser cadastrados por meio de ferramenta online disponível no endereço sistemas.anac.gov.br/sisant.

² Para todos os sistemas de RPA Classe 2 e os de RPA Classe 3 que se destinam a operações além da linha de visada visual (BVLOS) ou acima de 400 pés, o fabricante pode optar pelo processo de certificação de tipo estabelecido no RBAC nº 21 ou pela autorização de projeto na Subparte E do RBAC-E nº 94.

Fonte: Adaptado de ANAC, 2017.

Dentre essas três classes, temos o peso máximo de decolagem, onde devem ser considerados os pesos do equipamento, da bateria ou combustível, e da carga eventualmente transportada. Seguindo com os critérios de

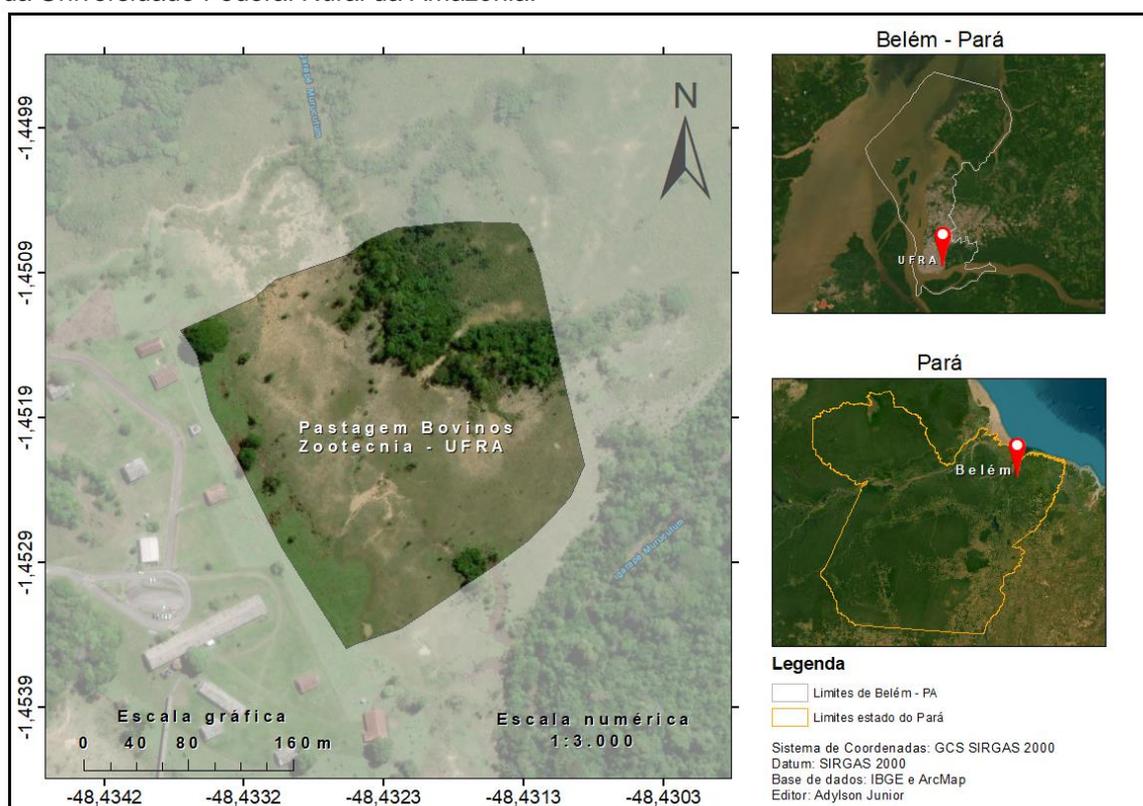
enquadramento, temos a visualização de operação que foi tratada anteriormente na (Tabela 1), registro do equipamento (obrigatório para as classes 1 e 2, por outro lado, para a classe 3 e Aeromodelos somente em casos de peso acima de 250g, em relação a aprovação do projeto ou autorização de operação de voo (em situações específicas ou no caso de aeronaves com propósitos experimentais). O CA padrão ou restrito pode ser substituído por um Certificado de Autorização de Voo Experimental (CAVE) ou uma Autorização Especial de Voo (AEV), limite de idade (idade mínima de 18 anos para pilotar ou auxiliar a operação como observador para as classes 1, 2 e 3), certificado médico para as classes 1 e 2 (Certificado Médico Aeronáutico (CMA) de 1ª, 2ª ou 5ª classe concedidos pela ANAC ou de 3ª classe expedido pelo Comando da Aeronáutica), habilitação e local de operação (ANAC, 2017).

4. MATERIAL E MÉTODOS

4.1 CARACTERIZAÇÃO DA ÁREA

O levantamento aerofotogramétrico ocorreu dia 31 de janeiro de 2024 nas dependências da Universidade Federal Rural da Amazônia, *Campus Belém*, situada na parte sudeste do Município, às margens do rio Guamá (ao sul) e da Baía do Guajará (ao oeste), em área de pastagem de capim braquiária (*Urochloa* spp.) (NUNES *et al.*, 2022), com sistema de manejo extensivo destinada a criação de bovinos do setor de Zootecnia, localizada nas seguintes coordenadas: latitude $1^{\circ}27'10.0''S$ e longitude $48^{\circ}25'58.3''W$, que possui altitude de aproximadamente 10m.

Figura 2 - Mapa de localização da área do levantamento aerofotogramétrico no setor de Zootecnia da Universidade Federal Rural da Amazônia.



Fonte: Autor, 2024.

A área total da instituição possui a quantidade de 196 hectares, sendo 71 hectares em terra firme, o restante da área compreende as áreas de igapó, várzea ou de preservação ambiental (SANTOS, 2014). O levantamento aerofotogramétrico deste trabalho ocorreu em pastagem estabelecida em área de várzea. A predominância do solo da região é do tipo latossolo amarelo de textura argilosa (BASTOS *et al.*, 2002). O clima da cidade de Belém - PA, segundo a

classificação de Köppen, é do tipo Afi, caracterizado como equatorial quente e úmido. Nessa região, a temperatura e a precipitação anual são altas, não havendo período seco definido (SANTOS *et al.*, 1983).

4.2 DRONE

O RPA utilizado no levantamento aerofotogramétrico de modelo Phantom 4 Pro da fabricante DJI, é um *drone* portado com sistema de posicionamento por satélite GPS/GLONASS. O mesmo passou por uma adaptação para receber o sensor multiespectral *Sunshine*, sendo utilizado uma acoplagem em material plástico projetado e posteriormente reproduzida em impressora 3D. O quadricóptero utilizado (Figura 3), possui detecção de obstáculos em cinco direções, utilizando sensores de visão estereoscópico na frente, atrás e abaixo, além de sensores de infravermelhos nas laterais. Há também sensores de ultrassom e visão na parte inferior para garantir estabilidade durante voos em ambientes internos ou sem GPS. Em relação a sua velocidade máxima no modo P (Posicionamento) é de 50 Km/h e sua resistência ao vento é de 10 km/h. A bateria oferece uma autonomia de aproximadamente 30 minutos de voo.

Figura 3 - RPA Phantom 4 Pro com sensor *Parrot Sequoia*.



Fonte: Autor, 2024.

4.3 SENSOR MULTIESPECTRAL

O sensor *Sunshine Parrot Sequoia* multiespectral utilizado para obtenção das imagens, foi produzida a partir de uma parceria entre as empresas *Parrot* e *Micasense*. Esse sensor é específico para operações agrícolas para captura de dados em diferentes bandas espectrais (Verde, Vermelho, Borda do Vermelho, Infravermelho Próximo e RGB), como observado na (Figura 4). A resolução das bandas possui uma resolução de 1,2 megapixels e 16 bits de resolução radiométrica. O sensor possui ainda uma câmera RGB integrada com 16 megapixels.

Figura 4 - Detalhamento do Sensor Multiespectral *Parrot Sequoia*.



Fonte: Adaptado de (SIS, 2018) por (TEIXEIRA, 2019).

A utilização do sensor permite capturar imagens em diversas faixas espectrais, possibilitando uma análise detalhada do estado da vegetação. As faixas espectrais, juntamente com seus comprimentos de onda e larguras de banda podem ser observados na (Tabela 3).

Tabela 3 - Comprimento de onda e largura de banda do sensor *Parrot Sequoia*.

Banda	Sigla	Comprimento de onda (nm)	Largura de banda (nm)
Verde	GRE	530 - 570	40
Vermelho	RED	640 - 680	40
Borda do vermelho	REG	730 - 740	10
Infravermelho próximo	NIR	770 - 810	40

Fonte: (PARROT, 2018).

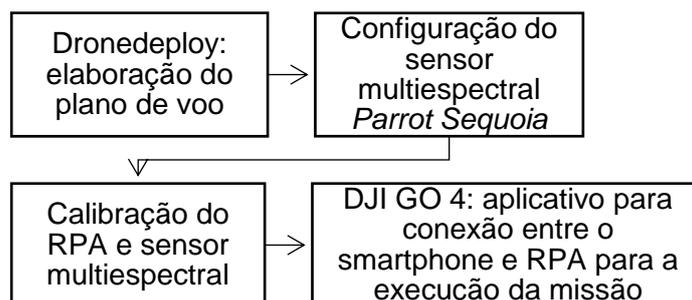
4.4 COLETA DOS DADOS

Com base no planejamento, o drone foi programado para voar sobre a área de pastagem que compreende a 6,6 hectares, com o RPA sobrevoando a 100m de altura, velocidade de voo de 5,5 Km/h. Com relação as configurações do sensor *Parrot Sequoia*, selecionamos o *Overlap* (sobreposição de imagens) longitudinal de 80% e lateral 70%. A captura foi configurada para o modo *Timelapse* para 1,1 segundos de intervalo de captura de imagens. A resolução das câmeras mono foi configurada em 1,2 megapixels, imagens de 8 bits e resolução espacial de 12,4cm. A câmera RGB foi configurado para resolução de 16 megapixels. Adquirindo imagens multiespectrais com as bandas espectrais da faixa do visível (RGB), borda do vermelho (Red Edge) e infravermelho próximo (NIR). A vantagem de usar *drones* é a versatilidade, pois temos maior autonomia de escolha em períodos exatos a qual necessitamos, superando a limitação de imagens de satélite causada pela constante nebulosidade da região.

Nesta etapa serão usados:

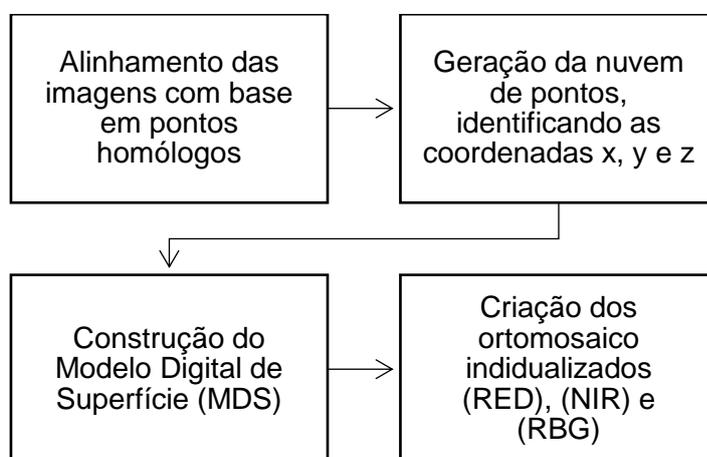
- I. Dronedeploy: aplicativo que irá realizar a orientação dos voos autônomos do RPA com base nos parâmetros determinados no planejamento.
- II. DJI GO 4: aplicativo do fabricante DJI para fazer a conexão entre o RPA e o smartphone, permitindo que o Dronedeploy transmita as informações para o equipamento.
- III. Sensor multiespectral: com (bandas do Verde, Vermelho, Borda do Vermelho e Infravermelho Próximo e imagem RGB), além do sensor Sunshine para correção radiométrica e GPS integrado para sincronização de posicionamento das fotos.
- IV. RPA: Phantom 4 Pro equipamento dotado de sensor RGB para capturar imagens aéreas, adaptado ao sensor *Parrot Sequoia*.

As etapas para a obtenção das imagens capturadas pelo sensor acoplado ao RPA seguiram as seguintes etapas do fluxograma abaixo:



4.5 PROCESSAMENTO DAS IMAGENS

As imagens capturadas pelo drone serão processadas para criar mosaicos e ortomosaicos, de modo a permitir uma visualização completa e detalhada da área mapeada. Para isso, serão usados os *softwares* WebODM (*Open Drone Map*) e ArcGIS. A criação dos ortomosaicos foi realizada de forma individualizada no WebODM, com o processamento de cada banda separadamente. Foram gerados ortomosaicos específicos para a banda vermelha (RED), infravermelho próximo (NIR) e banda do visível (RGB). O processamento para a obtenção do ortomosaico pelo *software* WebODM seguiu as etapas do fluxograma abaixo:



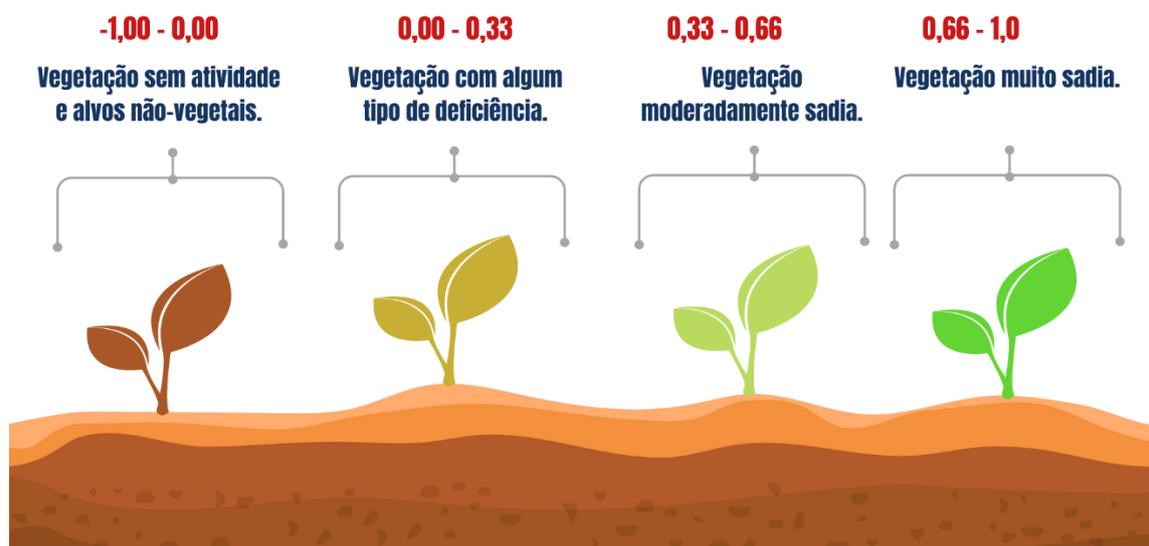
Posteriormente, no *software* ArcGIS, foi realizado o processamento do índice vegetativo NDVI. Foram levantados dados referentes a esses respectivos índices, utilizando a ferramenta *ArcToolbox (Zonal Statistics as Table)* para calcular os parâmetros dos índices, como a média e o desvio padrão a modo comparativo aos disponíveis na literatura científica.

4.6 OBTENÇÃO DO NDVI

Existem inúmeros índices espectrais disponíveis na literatura científica sendo a melhor opção condicionada em função dos interesses específicos dos usuários. Nesse contexto, por ser um índice muito utilizado pela robustez dos resultados gerados, fez-se a opção neste trabalho em utilizar o NDVI (Índice de Vegetação de Diferença Normalizada), o qual foi pioneiramente proposto por (ROUSE *et al.*, 1973), com a finalidade de estimar a biomassa vegetal (TEIXEIRA, 2019). É uma métrica amplamente utilizada para quantificar a saúde e a densidade

da vegetação usando dados de sensores remotos, como podemos observar em (Figura 5).

Figura 5 - Representação esquemática do comportamento do NDVI.



Fonte: Adaptado de *Earth Observing System (EOS)*, 2019.

Os dados gerados com NDVI são apresentados em uma escala de valores variável entre -1 e 1, onde os valores mais próximos de 1, indicando presença de vegetação enquanto mais próximo de -1, maior indicativo da presença de vegetação morta e solo exposto (BOIARSKII; HASEGAWA, 2019). Tal situação é apresentada através da fórmula (Eq. 1), apresentada a seguir:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (\text{Eq. 1}).$$

Onde:

NIR – Banda do Infravermelho próximo;

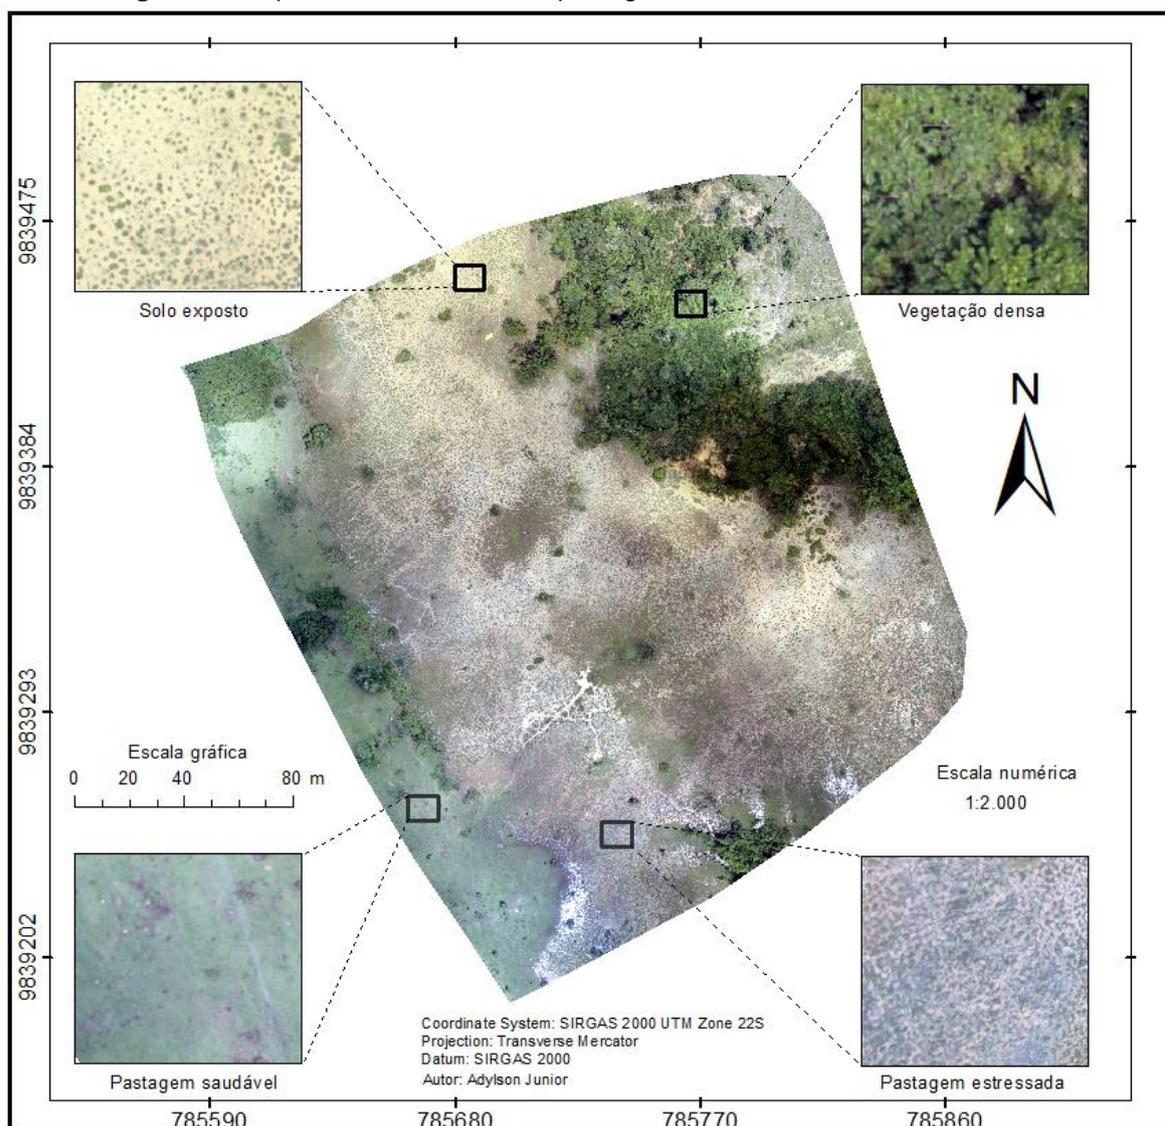
RED – Banda do Vermelho do espectro eletromagnético.

5. RESULTADOS ESPERADOS

A partir das imagens capturadas com sensores embarcados em equipamentos e posteriormente processadas, analisadas em conjunto as realizadas em laboratório, podemos correlacionar os aspectos biométricos aos valores encontrados a partir de processamento dos (IVs). Assim, será possível realizar o comparativo utilizando índices espectrais. Esses índices oferecem

informações muito relevantes sobre qual índice apresenta melhor acurácia ao que foi analisado em laboratório. Entre as análises a partir de processamentos e modelos estatísticas sobre os estágios de crescimento da forragem, a quantidade de biomassa verde, plantas invasoras e solo exposto, áreas com *stress* hídrico, ataques de pragas e doenças entre outras características fisiológicas passíveis de detecção. E ainda, com base nas informações geradas, é possível obter elementos que refletem algum tipo de interferência no manejo a ser realizado nas áreas cultivadas. A (Figura 6) demonstra, de maneira detalhada, a cobertura vegetal e o solo exposto aplicados sobre a área de pastejo. Dessa forma, com a posse de tais informações, fundamentais para a interpretação dos resultados posteriormente encontrados, é importante considerar os fatores específicos de cada área mapeada.

Figura 6 - Mapa de detalhamento da pastagem do setor de Zootecnia - UFRA.



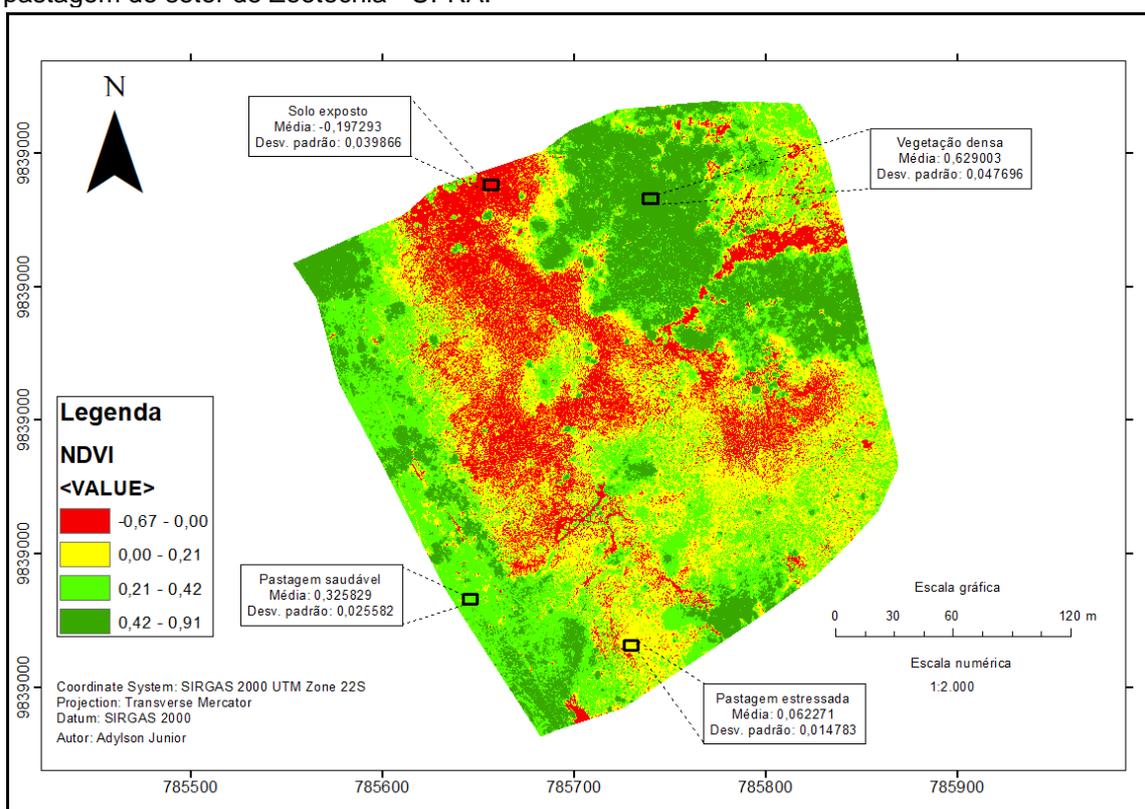
Fonte: Autor, 2024.

O manejo eficiente e preciso de pastagens constitui fator chave para aumentar a sustentabilidade produtiva e ambiental das áreas de produção pecuária. Para dar suporte aos produtores em suas decisões de planejamento e manejo, quanto ao momento ideal para a entrada dos animais ao pastejo, as pastagens devem apresentar condições de disponibilidade nutritiva para suprir as necessidades dos animais, sendo necessárias informações atualizadas sobre a situação predominante do campo e da forragem colhida (SCHELLBERG *et al.*, 2008). As abordagens atuais utilizadas para avaliar rendimento e altura da pastagem envolvem uma avaliação visual, e se dá por amostragens. Apesar dos resultados obtidos auxiliarem o desenvolvimento e manutenção das pastagens, no entanto não trazem uma visão de conjunto, além de implicarem no emprego de grande mão de obra e tempo a serem gastos no monitoramento da pastagem. Além disso, os parâmetros de qualidade de gramínea não são frequentemente monitorados, uma vez que sua avaliação depende de análises laboratoriais, o que aumenta os custos operacionais e a complexidade dos métodos de avaliação convencionalmente usados. Nesse contexto, o uso de sensores multiespectrais acoplados em *drones* representa uma alternativa mais flexível, que traz resultados e auxiliam diretamente no monitoramento das pastagens (SILVEIRA *et al.*, 2022). Além de possibilitar uma atuação estratégica, economizando insumos, essa tecnologia permite uma visão sistêmica da área produtiva. Em suma, são indicadores que podem otimizar o monitoramento da produção forrageira em menos tempo e com maior frequência.

Entretanto, a maioria dos trabalhos realizados nessa abordagem foram realizados para culturas agrícolas, principalmente culturas anuais (SCHELLBERG *et al.*, 2008), e em menor número para culturas perenes (SILVEIRA *et al.*, 2022). Trabalhos de correlação de imagens registradas por drones com parâmetros de produtividade em pastagens são proporcionalmente mais escassos. Por sua vez, pesquisas voltadas ao clima tropical úmido, típico da Amazônia, com suas particularidades, inexistem. Assim, trabalhos como o proposto podem ser o ponto de partida para o desenvolvimento de modelos de avaliação de pastagens com base em índices de vegetação na região amazônica. Aliado as formas de medição tradicionais, podem potencializar o monitoramento e previsão da produção de forragem animal, o que impactaria positivamente os produtores pecuários dessa região.

Conforme o processamento demonstrado em (Figura 6), a área apresenta alguns fatores importantes a serem considerados para avaliação do índice vegetativo. Segundo D'Oliveira *et al.* (2023), o excesso de solo exposto, aliado ao teor de água no solo, influencia a reflectância, pois quanto mais úmido o solo, mais escuro ele se torna. Além disso, as superfícies do relevo refletem a luz em diferentes direções. Outro fator importante, que retrata o inverso do que foi apresentado anteriormente, deve-se ao excesso de vegetação, ou seja, vegetação frondosa, com copas de árvores grandes do estrato arbustivo-arbóreo, influenciando na resposta espectral. Esse excesso pode apresentar uma falsa qualidade da pastagem sobre a resposta para o índice vegetativo. Com isso, esse cenário foi encontrado na área, como podemos observar os valores de média e desvio padrão de cada extrato do processamento do índice vegetativo NDVI (Figura 7).

Figura 7 - Imagem de sensor remoto: aplicação de índice de vegetação NDVI em área de pastagem do setor de Zootecnia - UFRA.



Fonte: Autor, 2024.

As variações ocorrem devido às superfícies que apresentam comportamentos espectrais diferentes, pois os sinais da vegetação no sensoriamento remoto podem ser mascarados por outros alvos, dificultando a distinção entre eles (SOUZA *et al.*, 2023). Portanto, é de grande importância a

utilização dos diversos IVs para encontrar as melhores informações sobre a área em questão a qual se busca otimizar. Essa abordagem permite uma análise mais precisa e abrangente, considerando diferentes aspectos da cobertura vegetal e minimizando possíveis interferências.

Os resultados obtidos no estudo de Neves *et al.* (2019a) mostraram que o sensor multiespectral utilizado apresentou grande potencial para monitorar e quantificar a infestação por capim-annoni (*Eragrostis plana* Nees) em pastagens naturais. As bandas 4 (REG) e 5 (NIR) apresentaram correlações negativas fortes com a presença do capim-annoni, fazendo-se viável a modelagem ao nível de infestação com base na banda 4, que obteve a maior significância no modelo de regressão (R^2 ajustado = 0,9341). Ou seja, a reflectância na banda que correspondente à borda do vermelho é inversamente proporcional ao nível de infestação.

Os resultados encontrados para o Índice de Cobertura Verde (ICV), obtido a partir de bandas no espectro visível (RGB), possui grande potencial para ser trabalhado no monitoramento de desenvolvimento de culturas agrícolas como em pastagem de azevém. A pesquisa de Neves *et al.*, (2019b) destacou que, o ICV apresentou melhor desempenho em áreas com menor biomassa, a qual, apresentou medidas quantitativas das diferenças entre as áreas da parcela. Por outro lado, o índice teve indicativo de saturação em regiões com maior cobertura vegetal, limitando sua capacidade de distinguir variações de biomassa nas regiões mais densas. Ainda que o ICV seja promissor, especialmente em estágios iniciais das culturas ou em áreas de baixa biomassa, necessita de maiores estudos e aplicações específicas.

6. CONCLUSÃO

Os RPAS, aplicados como ferramentas para otimizar atividades agrícolas, demonstram grande potencial, especialmente em tarefas que exigem elevado esforço e maiores desprendimento de tempo. Aliado ao uso de sensores multiespectrais e RGB, os produtores têm acesso a uma ampla gama de informações que podem ser analisadas e trabalhadas para alcançar maiores produtividades em pastagens cultivadas. Desta maneira, as análises dos índices vegetativos, quando respeitadas as especificidades de cada local e associada a dados qualiquantitativo, como por exemplo sobre a biomassa verde, massa total, massa seca e infestação de plantas invasoras e quantidade de solo exposto, oferecem subsídios necessários para identificar os métodos com maior acurácia para os objetivos pretendidos. Esse potencial se mostra particularmente relevante para a região amazônica, onde há escassez de estudos que utilizem índices vegetativos a partir de RPAS para avaliar pastagens.

No entanto, é fundamental que esse tipo de estudo seja ampliado, principalmente com análises laboratoriais complementares, a fim de validar e comparar a eficiência dos métodos e consolidar as melhores práticas para a agricultura de precisão.

7. REFERÊNCIAS

ABIEC – ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNE. Beef REPORT: perfil da pecuária no Brasil 2023. Disponível em: <https://www.abiec.com.br/catpub/impessos/>. Acesso em: 20 jan. 2024.

ALMEIDA, F. L. **Geotecnologias e o futuro da agricultura de precisão**. Revista de Geociências e Agricultura, v. 12, n. 3, p. 89-101, 2016.

ANAC. AGENCIA NACIONAL DE AVIAÇÃO CIVIL. Orientação para usuários de drones. Brasília, DF. Brasil, 2017. Disponível em: <https://www.gov.br/anac/pt-br>. Acesso em: 22 fev. 2024.

ANDRADE, R. G.; HOTT, M. C.; MOTTA, M. B.; MAGALHAES JUNIOR, W. C. P. de; GALDINO, S.; RODRIGUES, C. A. G.; RONQUIM, C. C.; SILVEIRA, H. L. F. da; OLIVEIRA, P. S. d'. **Monitoramento e avaliação qualitativa de pastagens a partir de dados NDVI/MODIS**. Revista Contemporânea, v. 3, n. 11, 2023. Disponível em: <https://doi.org/10.56083/RCV3N11-169>. Acesso: 18 fev. 2024.

ARNÓ, S. J.; ESCOLÀ, I A. A.; MARTÍNEZ, C. J. A. Precision Agriculture: What's behind the name?. **New Ag International**, 2016, vol. Nov/Dec 2016, núm. 64, p. 18-27, 2016.

BASSOI, L. H.; BERNARDI, A. C. C.; INAMASU, R. Y.; MOLIN, J. P.; COELHO, A. M.; DELALIBERA, H. C. **Agricultura de precisão e agricultura digital**. Pontifícia Universidade Católica de São Paulo (PUC-SP). Revista Digital de Tecnologias Cognitivas (TEC COGS), v. 20, p. 20-35, 2019.

BASTOS, T. X.; PACHECO; N. A.; NECHET, D.; SÁ, T. D. A. **Aspectos climáticos de Belém nos últimos cem anos**. 1. ed. Belém, PA: Embrapa Amazônia oriental. 2002. 31 p.

BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, Á. V. de; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão: resultados de um novo olhar**. Embrapa, Brasília, DF, 2014. 596 p.

BERTOGLIO, Riccardo; CORBO, Chiara; RENGA, Filippo; MATTEUCCI, Matteo. The Digital Agricultural Revolution: A Bibliometric Analysis Literature Review. **IEEE Access**. PP. 1-1. 10.1109/ACCESS. 2021.

BOIARSKII, B.; HASEGAWA, H. Comparison of NDVI and NDRE indices to detect differences in vegetation and chlorophyll content. **J. Mech. Contin. Math. Sci**, v. 4, p. 20-29, 2019.

BRUM, C. B. DE; MAURICIO, M.; DA SILVA, R. O.; BASTOS, Y. **Uso dos drones nos procedimentos civis e criminais no brasil**: considerações sob a ótica dos direitos fundamentais. In: PRUDKIN, G.; BREUNIG, F. M. DRONES E CIÊNCIA Teoria e aplicações metodológicas. Santa Maria/RS: FACOS-UFSM, Volume I, 2019. p.28-37.

D'OLIVEIRA, P. S.; HOTT, M. C.; ANDRADE, R. G.; MAGALHÃES JUNIOR, W. C. P. de. **Aplicações da agricultura de precisão em pastagens**. EMBRAPA, CIRCULAR TÉCNICA 127, ISSN 1678-037X, Juiz de Fora, MG. 2023. p1-29

USDA. United States Department of Agriculture. Foreign Agricultural Service. Cattle Stocks - Top Countries Summary, 2024.

DIAS-FILHO, M. B. **Degradação de pastagens**. Livro eletrônico, ed autor, Belém, PA. 2023. Disponível em: <https://diasfilho.com.br/degradacaodepastagens/>. Acesso em: 22 jan. 2024.

DIAS-FILHO, M. B. **Degradação de pastagens: processos, causas e estratégias de recuperação**. 4. ed. reimp. Belém, PA: Embrapa Amazônia Oriental, 2011. 215 p.

Earth Observing System (EOS). FAQ NDVI: Tudo o que você precisa saber sobre o índice. 2019. Disponível em: <https://eos.com/blog/ndvi-faq-all-you-need-to-know-about-ndvi/>. Data de acesso: 20 fev. 2014.

FITZ, P. R. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008. 160p.

FONTE, S. J.; NESPER, M.; HEGGLIN, D.; VELÁSQUEZ, J. E.; RAMIREZ, B.; Rao, I. M.; Bernasconi, S. M.; Bünemann, E. K.; Frossard, E.; Oberson, A. Pasture degradation impacts soil phosphorus storage via changes to aggregate-associated soil organic matter in highly weathered tropical soils. **Soil Biology and Biochemistry**, v. 68, p. 150-157, 2014.

GAO, Q.; LI, Y.; WAN, Y.; LIN, E.; XIONG, W.; JIANGCUN, W.; WANG, B.; LI, W. Grassland degradation in Northern Tibet based on remote sensing data. **J. Geographical Sciences**, v. 16, n. 2, p. 165-173, 2006.

HOMBURG JR, N. Aerial eyewitness: A pilot study of drone use in journalism. **Doctoral dissertation**. Kansas State University. 2017.

IBGE. Sistema IBGE de Recuperação Automática – SIDRA. Pesquisa da Pecuária Municipal: tabela 3939: efetivo dos rebanhos, por tipo de rebanho. 2022. Disponível em: <https://sidra.ibge.gov.br/tabela/3939>. Acesso em: 21 jan. 2024.

KARUNATHILAKE, E. M. B. M.; LE, A. T.; HEO, S.; CHUNG, Y.S.; MANSOOR, S. The Path to Smart Farming: Innovations and Opportunities in Precision Agriculture. **Agriculture**, 2023.

KHORRAMNIA, K; SHARIFF, A; RAHIM, A; MANSOR, S. Toward Malaysian sustainable agriculture in 21st century. **8th International Symposium of the Digital Earth (ISDE8)**. IOP Conference Series: Earth and Environmental Science. 2014. (pp. 1-5).

LARADJI, I.; RODRIGUEZ, P.; KALAITZIS, F.; VAZQUEZ, D.; YOUNG, R.; DAVEY, E.; LACOSTE, A. Counting cows: Tracking illegal cattle ranching from high-resolution satellite imagery. **ArXiv preprint arXiv**, 2020.

MACÁRIO, C. G. do N.; ESQUERDO, J. C. D. M.; COUTINHO, A. C.; SPERANZA, E. A.; SILVA, J. dos S. V. da; ANTUNES, J. F. G.; VENDRÚSCULO, L. G.; CRUZ, S. A. B. da. Geotecnologias na agricultura digital. In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; OLIVEIRA, S. R. de M.; MEIRA, C. A. A.; LUCHIARI JUNIOR, A.; BOLFE, E. L. (Ed.). **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília, DF: Embrapa, 2020. cap. 4, p. 94-118.

MACEDO, M. C. M.; ZIMMER, A. H.; KICHEL, A. N.; ALMEIDA, R. G. de; ARAÚJO, A. R. de. **Degradação de pastagens, alternativas de recuperação e renovação, e formas de mitigação**. 2013.

MAKHDZIR, A. Application of Artificial Intelligence and Drone Technology in Malaysian Plantation. **International Proceedings of Irc**, 2017. (pp. 146-164).

MAPBIOMAS. Coleção 6 Mapeamento Anual de Cobertura e Uso da Terra no Brasil. Brasília: Mapbiomas, 2021. Disponível em: <https://mapbiomas.org/>. Acesso em: 22 jan. 2024.

MAPBIOMAS. Coleção 7 (1985 –2021) da série anual de mapas de cobertura e uso de solo do Brasil. Brasília: Mapbiomas, 2022. Disponível em: <https://mapbiomas.org/>. Acesso em: 21 jan. 2024.

MCDALD, H.; OLIVER, D. Remote piloted aerial vehicles: An anthology. **Remote Piloted Aerial Vehicles**, 2003.

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. F. **Agricultura de precisão**. 1, ed. Oficina de Textos. São Paulo, SP, 2015.

NAÇÕES UNIDAS. World Population Prospects 2022: Summary of Results. Department of Economic and Social Affairs, Population Division, 2022. Disponível em: <https://www.un.org/>. Acesso em: 09 nov. 2024.

NEVES, M. C.; PEREZ, N. B.; LUIZ, A. J. B.; DEIBLER, A.; PINHO, L. B de. **Avaliação de sensor multiespectral em mapeamentos da infestação de pastagens naturais pelo capim-annoni**. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19, Santos. Anais. São José dos Campos: INPE, 2019a. p1-4.

NEVES, M. C.; LUIZ, A. J. B; PEREZ, N. B. C; DEIBLER, A. **Aplicação do índice de cobertura verde em pastagem de azevém**. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19, Santos. Anais. São José dos Campos: INPE, 2019b. p1-4.

NUNES, R.; PEREIRA, K.; SILVA, L.; SOUZA, M.; RODRIGUES, C.; GOMES, D.; RODRIGUES, T.; SANTOS, V.; OLIVEIRA, E.; JUNIOR, V.; CASTRO, W.; VIANA,

R.; RIBEIRO, T. J.; SANTOS, J.; GOMES, M. Estudo fitossociológico de plantas espontâneas em áreas de pastagens da UFRA, Campus de Belém, Pará, Brasil. **Research, Society and Development**. 2022.

OECD – Organisation for Economic Co-Operation and Development; **FAO** – Food and Agriculture Organization of the United Nations. *Agricultural Outlook 2023–2032*; OECD Publishing: Paris, France, 2023.

OLIVEIRA, A. J. de; SILVA, G. F. da; SILVA, G. R. da; SANTOS, A. A. C. dos; CALDEIRA, D. S. A.; VILARINHO, M. K. C.; BARELLI, M. A. A.; OLIVEIRA, T. C. de. **Potencialidades da utilização de drones na agricultura de precisão**. *Brazilian Journal of Development*, [S. l.], v. 6, n. 9, p. 64140–64149, 2020. Disponível em: <https://doi.org/10.34117/bjdv6n9-010>. Acesso em: 19 mar. 2024.

PARROT. **Datasheet Specs sheet Sequoia : the multi-band sensor designed for agriculture**. 2018. Disponível em: www.parrot.com. Acesso em: 16 fev. 2024.

RAMALHO, A. C. da S. M. C.; RODRIGUES, G. P. F. C. **Agricultura de Precisão em Culturas Arvenses Índice de Vegetação vs Condutividade Elétrica vs Produtividade em Trigo Mole e a sua Correlação**. Dissertação. Universidade de Lisboa, 2021.

RANI, A.; CHAUDHARY, A.; SINHA, N.; MOHANTY, M.; CHAUDHARY, R. Drone: The green technology for future agriculture. **Har. Dhara**. 2019, 2, 3–6.

ROSA, R. **Geotecnologias na Geografia aplicada**. RDG - Revista do Departamento de Geografia. São Paulo, v. 16, p. 81-90, 2005.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. **Progress Report RSC** 1978-1, [s. l.], 1973.

SANTOS, P. C. T. C dos.; VIEIRA, L, S.; VIEIRA, M. de N. F.; CARDOSO, A. **Os solos da faculdade de ciências agrárias do Pará**. FCAP. Informe Didático: 05, Belém, PA. 1983.

SANTOS, R. F.; SILVA, T. R. **A importância das geotecnologias no levantamento de dados espaciais no meio rural**. *Revista de Tecnologia e Inovação Rural*, v. 5, n. 1, p. 45-57, 2017.

SANTOS, W. H. **Registros históricos: contribuição à memória da Universidade Federal Rural da Amazônia**. Belém: Universidade Federal Rural da Amazônia. 2014.186 p.

SCHELLBERG, J., Hill, M. J., GERHARDS, R., ROTHMUND, M., BRAUN, M. Precision agriculture on grassland: Applications, perspectives and constraints. **European Journal of Agronomy**. 2008, v. 29, n. 2–3, p. 59–71. Disponível em: <https://doi.org/10.1016/j.eja.2008.05.005>. Data de acesso:

SHARMA, A.; JAIN, A.; GUPTA, P.; CHOWDARY, V. Machine Learning Applications for Precision Agriculture: A Comprehensive Review, **IEEE Access**, vol. 9, pp. 4843-4873, 2021.

SILVEIRA, M. C. T.; ALMEIDA, P. H. A.; ANDRADE, C. V. P. A.; ALBUQUERQUE-FILHO, M. R.; BREMM, C.; Santos, F. C. **Aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por VANTs e aplicado no manejo de pastagens**. Embrapa Pecuária Sul, 2022. PDF (59 p.). (Boletim de pesquisa e desenvolvimento / Embrapa Pecuária Sul, ISSN 1983-0467; 51).

SOUZA, A. A.; SILVA, J. P.; CARVALHO, M. **Aplicações de geotecnologias no setor agrícola: estudo de caso em propriedades rurais**. Revista Brasileira de Geografia e Meio Ambiente, v. 8, n. 2, p. 123-134, 2015.

SOUZA, L. S. B. de; MAIA, Í. C.; Costa, D. dos S.; SANTOS, C. V. B. dos; CARNEIRO, A. de S. R.; MOURA, M. S. B. de. Análise comparativa entre o NDVI obtido por imagens multiespectrais e visíveis (RGB) em câmera acoplada em drone em área de videira. **Journal of Hyperspectral Remote Sensing**. v.13, n.6 2023. p741-751.

SPONCHIONI, G.; VEZZONI, M.; BACCHETTI, A.; PAVESI, M. The 4.0 revolution in agriculture: A multi-perspective definition. **In Proceedings of the XXIV Summer School “Francesco Turco”** - Industrial Systems Engineering Platforms, Brescia, Italy, 11–13 September 2019; p143–149.

TEIXEIRA, A. A. D. **Avaliação da acurácia radiométrica de imagem dos sensores sequoia e MSI na cultura da aveia preta**. Dissertação (Mestrado em Sensoriamento Remoto e Geoprocessamento). Universidade Federal do Rio Grande do Sul. Porto Alegre-RS. 2019.

TORRES, José Luiz; ASSIS, Renato; LOSS, Arcangelo. **Evolução entre os sistemas de produção agropecuária no Cerrado: convencional, Barreirão, Santa Fé e Integração Lavoura-Pecuária**. Informe Agropecuário, Belo Horizonte, MG, v.39, n.302, p.7-17, 2018. Disponível em: <https://www.researchgate.net>. Acesso: 22 jan. 2024.

UNIVERSIDADE FEDERAL DE GOIÁS. Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás (LAPIG-UFG). Atlas digital das pastagens brasileiras. Área de pastagem Brasil 2021. Disponível em: <https://pastagem.org/atlas/map>. Acesso: 22 jan. 2024.