

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**TÉCNICAS DE AGRICULTURA DIGITAL PARA PREDIÇÃO DA
MATURAÇÃO DO AMENDOIM**

Jarlyson Brunno Costa Souza

Engenheiro Agrícola

2021

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**TÉCNICAS DE AGRICULTURA DIGITAL PARA PREDIÇÃO DA
MATURAÇÃO DO AMENDOIM**

Jarlyson Brunno Costa Souza

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientadores: Prof. Dr. Adão Felipe dos Santos

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Mestre em Agronomia (Produção Vegetal).

2021

P328e Souza, Jarlyson Bruno Costa
Técnicas de agricultura digital para predizer a maturação do amendoim/
Jarlyson Bruno Costa Souza. -- Jaboticabal, 2020
vi, 81 p. : il. ; 29 cm

Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias, 2020
Orientador: Rouverson Pereira da Silva
Coorientador: Adão Felipe dos Santos
Banca examinadora: Marcelo José da Silva, Leonardo Campos de Assis
Bibliografia

1. Agricultura de precisão. 2. *Arachis hypogaea*. 3. Sensoriamento remoto.
I. Título. II. Jaboticabal-Faculdade de Ciências Agrárias e Veterinárias.

CDU 639.3.43

DADOS CURRICULARES DOS AUTORES

JARLYSON BRUNNO COSTA SOUZA – nascido em São Luís, Maranhão, no dia 03 de outubro de 1990, filho de Waldirene Márcia Alves Costa e José Maria Souza. Coursou do Ensino Fundamental ao Médio na escola Centro Educacional São Francisco de Assis – CEFTRAN, tendo finalizado o ensino básico e médio no ano de 2008. Ingressou no ensino superior no ano de 2014 no curso de Engenharia Agrícola pela Universidade Federal do Estado do Maranhão (UFMA), Câmpus de Chapadinha, obtendo o título de Engenheiro Agrícola em julho de 2019. Durante a graduação foi bolsista de Iniciação Científica durante um ano, com bolsa da UFMA, nas áreas de máquinas e mecanização e agricultura de precisão, sob orientação dos professores Dr. Washington da Silva Sousa e Edmilson Igor Bernardo de Almeida. Participou de projetos de pesquisa na área de Pós-Colheita. Também colaborou na execução e apresentação de trabalhos publicados em congressos e revistas científicas. Fundou juntamente com o Prof. Dr. Washington da Silva Sousa o grupo de pesquisa GETAD (grupo de estudos em tecnologia e agricultura digital). Em 2019 no mês de agosto, iniciou o curso de Mestrado Acadêmico em Agronomia (Produção Vegetal), com concentração nas áreas de Máquinas Agrícolas e Agricultura de Digital, pela Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, São Paulo, no Laboratório de Máquinas e Mecanização Agrícola, localizado no Departamento de Engenharia Rural da UNESP. No decorrer do curso realizou pesquisas com ênfase em Agricultura de Digital, principalmente sensoriamento remoto aéreo e orbital na cultura do amendoim. Participou de pesquisas para avaliar sistemas mecanizados de colheita em soja, amendoim e café. Em julho de 2021 submeteu-se à banca examinadora para obtenção do título de Mestre em Agronomia (Produção Vegetal).

**“A vida me ensinou a nunca desisti,
nem ganhar, nem perder,
mas procurar evoluir.”**

(Chorão)

Aos meus pais José Maria Souza e Waldirene Márcia Alves Costa que sempre fizeram de tudo para colocar eu e minha irmã no caminho certo, as minhas avós Irene Alves da Costa e Raimunda Pereira de Sousa por todo amor e carinho. A minha irmã que sempre me apoiou, e a pessoa mais importante da minha vida, minha filha Ana Sofia.

A vocês, DEDICO!

A todos os meus familiares e amigos, OFEREÇO!

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus por não desisti de mim e me transformar em uma pessoa melhor a cada dia. Agradeço a ele pela minha família poder presenciar o meu crescimento como pessoa e como profissional e por ele colocar pessoas maravilhosas na minha vida.

A Universidade Federal do Maranhão, “Centro de Ciências Agrárias e Ambientais” Campus de Chapadinha, que me formou como profissional, que me fez engenheiro agrícola e a todos os professores que de alguma forma contribuíram para que eu chegasse até aqui. Agradeço aos amigos Mádilo Lages, Carlos Augusto, Ana Karla, João Vitor, Mirla Monteles e Eduardo Arouche pela parceria no nosso grupo de pesquisa da graduação (GETAD), que sem dúvidas foi o divisor de águas para todos nós.

A Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Aos meus pais Waldirene Márcia Alves Costa e José Maria Souza que nunca deixaram de acreditar no meu potencial. Por se sacrificarem por mim e minha irmã para que nós dois pudéssemos estudar. Obrigado por todo esforço de vocês. Agradeço a minha irmã Jarlyanne Nargylla Costa Souza por todo amor e carinho e por não deixar eu desistir nunca. A minha amada filha Ana Sofia Cutrim Souza, que é o grande amor da minha vida e que sem a vinda dela a este mundo eu nunca teria me tornado a pessoa que eu sou hoje. A minha namorada Samira Luns Hatum de Almeida que foi a pessoa que mais sofreu comigo nos dias que antecederam à defesa e que me ajuda incondicionalmente.

Ao Professor Dr. Rouverson, ao qual eu tenho grande admiração e respeito, que é a minha inspiração como pessoa e profissional. E como ele sempre diz: “Você será o espelho do seu orientador”. E eu quero aqui reafirmar a vontade que eu tenho em ser pelo menos metade da pessoa e do profissional que você é. Obrigado por todos ensinamentos, por todas as oportunidades e por acreditar no meu potencial. Como já é de costume, obrigado por esse paizão para todos nós, orientandos e orientados.

Aos meu coorientador Adão Felipe dos Santos, pelos puxões de orelhas, por esta sempre preocupado com o meu crescimento e principalmente por ser um dos responsáveis pela minha paixão pela ciência. Aos meus amigos e mentores de graduação Prof. Dr. Edmilson Igor Bernardo de Almeida e o Prof. Dr. Washington da Silva Sousa

que nunca mediram esforços para que eu pudesse me tornar um grande profissional, abrindo muitas portas que elevaram o meu conhecimento e me deram forças para que eu continuasse trilhando este caminho. Sem vocês nada disso seria possível, muito obrigado.

Aos Professores. Dr. Carlos Eduardo Angeli Furlani e Cristiano Zerbato, ao técnico David Trevizoli e ao Maranhão, obrigado por toda ajuda, conhecimento e experiências trocadas, e a todos os outros funcionários do Departamento de Engenharia Rural.

A toda família da República TOca Fogo, Edgard Silva, Mailson Oliveira, João Godinho, Luan Oliveira, Everton Carvalho, Bruno Rafael, Armando Lopes, Eduardo Arouche, Francisco Amaral, Jardel Souza, Ancelmo Cazuza e a Neuza Helena por toda a parceria, pelas festas e brincadeiras sadias. Sem vocês os meus dias longe de casa e da minha família seriam mais difíceis.

Aos meus amigos e parceiros do Laboratório de Máquinas e Mecanização Agrícola, Alex Gonzaga, Aline Alcântara, Bruno Rocca, Danilo Tedesco, Francieli Ferreira, Francieli Morlin, Jean Lucas, Mailson Oliveira, Marcelo Junior, Romário Porto, Danilo Tedesco, Tulio Marra, Vinicius Carrera, Olavo Betiol, Edcarla Nicolal, e principalmente Armando Lopes e Samira Luns que estiveram comigo em todos os dias no campo coletando os dados.

Aos meus amigos de infância, Francisco Inaldo, Anderson Soares, Rafael Ribeiro, Gustavo Mendes, Nando Trindade e Thiago Santos, que estão sempre felizes com os objetivos alcançados e sempre torcendo por mim de longe e mandando mensagens de incentivo.

Enfim, a todos que de alguma forma contribuíram para que eu chegasse até aqui, e que sempre estiveram ao meu lado em momentos tristes e felizes, o meu muito obrigado!

SUMÁRIO

RESUMO:	11
ABSTRACT	11
CAPITULO 1: CONSIDERAÇÕES GERAIS	12
INTRODUÇÃO	12
HIPÓTESES	13
OBJETIVOS	13
REVISÃO BIBLIOGRÁFICA	14
AMENDOIM	14
MATURAÇÃO DO AMENDOIM	15
AGRICULTURA DIGITAL	16
SENSORIAMENTO REMOTO NA AGRICULTURA	19
CONCEITOS	20
INTELIGÊNCIA ARTIFICIAL (IA) NA AGRICULTURA	23
CONTROLE ESTATÍSTICO DE QUALIDADE	25
REFERÊNCIAS BIBLIOGRÁFICAS	27
CAPÍTULO 2: UAV E SATÉLITE: QUAL APRESENTA MELHOR QUALIDADE NO MONITORAMENTO DA CULTURA DO AMENDOIM?	37
RESUMO:	37
ABSTRACT:	38
INTRODUÇÃO	38
MATERIAL E MÉTODOS	41
ÁREA DE ESTUDO	41
AVALIAÇÕES EM CAMPO	41
AQUISIÇÃO DE IMAGENS DRONE	42
AQUISIÇÃO DAS IMAGENS PLANETSCOPE	43
ÍNDICES DE VEGETAÇÃO	44
ANÁLISES ESTATÍSTICAS DOS DADOS	45
RESULTADOS	46
ANÁLISE DESCRITIVA	46
VARIABILIDADE DAS BANDAS ESPECTRAIS E IVs	47
REDE CORRELAÇÃO	54
DISCUSSÃO	55
QUALIDADE DE LEITURA DAS PLATAFORMAS	55

RESPOSTA ESPECTRAL PARA OS SENSORES EM UAV E SATÉLITE	56
ÍNDICES DE VEGETAÇÃO GERADOS PELO UAV E SATÉLITE	57
CONCLUSÃO	58
REFERÊNCIAS BIBLIOGRÁFICAS.....	58
CAPÍTULO 3: REDES NEURAIAS ARTIFICIAIS APLICADAS AO SENSORIAMENTO REMOTO: NOVO MÉTODO DE PREDIÇÃO DA MATURAÇÃO DO AMENDOIM.....	64
RESUMO:	64
ABSTRACT:	64
INTRODUÇÃO	65
MATERIAL E MÉTODOS	67
ÁREA DE ESTUDO.....	67
AVALIAÇÕES EM CAMPO.....	67
AQUISIÇÃO DE IMAGENS DRONE	68
AQUISIÇÃO DAS IMAGENS PLANETSCOPE	69
ÍNDICES DE VEGETAÇÃO (IVS).....	69
ANÁLISE ESTATÍSTICA	70
MAPAS DA VARIABILIDADE ESPAÇO-TEMPORAL	ERRO! INDICADOR NÃO DEFINIDO.
DESCRIÇÃO DOS MODELOS DE RNAs PARA PREDIÇÃO DO PMI	71
REDES NEURAIAS PERCPTRON MULTICAMADAS (MLP)	71
REDES NEURAIAS DE FUNÇÃO DE ATIVAÇÃO DE BASE RADIAL (RBF)	73
TREINAMENTO E VALIDAÇÃO DO BANCO DE DADOS	ERRO! INDICADOR NÃO DEFINIDO.
TESTE DE DESEMPENHO	ERRO! INDICADOR NÃO DEFINIDO.
RESULTADOS E DISCUSSÃO.....	75
CONCLUSÕES	83
REFERÊNCIAS BIBLIOGRÁFICAS.....	84
CAPÍTULO 4: CONSIDERAÇÕES FINAIS	89

Resumo:

Técnicas como o Sensoriamento Remoto (SR) e Aprendizado de Máquinas estão sendo amplamente utilizadas no estudo da vegetação e têm mostrado potencial em seu uso para monitoramento e estimativa de diversos parâmetros agronômicos. No entanto, o uso destas técnicas para a cultura do amendoim ainda se encontra incipiente. Dessa forma, os objetivos deste trabalho foram: (i) avaliar a qualidade das plataformas de sensoriamento remoto por meio de cartas de controle e verificar qual tem melhor potencial para o monitoramento da cultura. (ii) prever a maturação do amendoim utilizando técnicas de Redes Neurais Artificiais (RNA) e SR. No primeiro capítulo encontra-se a revisão de literatura. No segundo, realizou-se análise de variabilidade com auxílio de cartas de controle para verificar a qualidade da reflectância espectral e dos índices de vegetação gerados a partir de imagens de Veículo Aéreo Não Tripulado (UAV) e Satélite de alta resolução. Os resultados demonstraram que o satélite apresenta melhor qualidade no monitoramento espaço-temporal para as bandas e índices de vegetação, enquanto que o UAV saturou todas as bandas ao longo do tempo. No terceiro capítulo foram utilizados modelos de RNA'S para predição da maturação do amendoim, utilizando imagens de UAV e satélite. Verificou-se potencial nas duas plataformas para prever a maturação, com os índices de vegetação NDVI do satélite e NDRE do UAV. Os modelos de redes MLP e RBF obtiveram resultados semelhantes em relação ao desempenho dos modelos gerados. Por fim, no capítulo cinco, tem-se as considerações finais, em que são apresentadas recomendações e trabalhos futuros para contribuir para o avanço do conhecimento.

Palavras-chaves: Sensoriamento remoto, Aprendizado de máquina, Redes neurais artificiais, Controle estatístico de qualidade

Abstract

Techniques such as Remote Sensing (RS) and Machine Learning are being widely used in the study of vegetation and have shown potential in their use for monitoring and estimation of several agronomic parameters. However, the use of these techniques for peanut cultivation is still incipient. Thus, the objectives of this work were (i) evaluate the quality of remote sensing platforms by means of control charts and verify which has the best potential for crop monitoring. (ii) to predict peanut maturity using Artificial Neural Networks (ANN) and SR techniques. The first chapter contains the literature review. In the second, variability analysis was performed using control charts to verify the quality

of spectral reflectance and vegetation indices generated from Unmanned Aerial Vehicle (UAV) and high-resolution satellite images. The results showed that the satellite has better spatio-temporal monitoring quality for the bands and vegetation indices, while the UAV saturated all bands over time. In the third chapter, ANN models were used for peanut maturity prediction, using UAV and satellite images. Potential was found in both platforms to predict maturity, with the satellite NDVI and UAV NDRE vegetation indices. The MLP and RBF network models obtained similar results regarding the performance of the generated models. Finally, in chapter five, there are the final considerations, in which recommendations and future work are presented to contribute to the advancement of knowledge.

Keywords: Remote sensing, Machine learning, Artificial neural networks, Statistical quality control

CAPITULO 1: CONSIDERAÇÕES GERAIS

Introdução

Esta dissertação está estruturada em quatro capítulos, os quais abordam técnicas de sensoriamento remoto e inteligência artificial para desenvolvimento de método de predição da maturação do amendoim. Este estudo demonstra relevância, pois traz uma metodologia inovadora e atual dentro do contexto da agricultura digital, o que demonstra importância para área acadêmica e principalmente, inserção da Unesp na vanguarda do desenvolvimento de pesquisas voltadas para a cultura do amendoim.

Os produtores do Brasil, assim como todo o mundo, utilizam o método *Hull-Scrape* para determinar o índice de maturação do amendoim. No entanto, este método é destrutivo, subjetivo e pouco representativo quanto à variabilidade da maturação, principalmente em grandes áreas. Diante disto, visando melhorar a precisão e acurácia da determinação da maturação do amendoim, acredita-se que técnicas de sensoriamento remoto junto com a inteligência artificial possam trazer resultados satisfatórios para predição da maturação do amendoim.

No primeiro Capítulo é apresentado o referencial teórico que embasa a hipótese de que é possível utilizar o sensoriamento remoto e aprendizado de máquinas como forma não-destrutiva para predição da maturação da cultura do amendoim, bem como a importância da utilização da agricultura digital no contexto do sensoriamento remoto para agricultura moderna.

No sensoriamento remoto existem diversas variáveis que afetam o desenvolvimento desta técnica. Plataformas como os veículos aéreos não tripulados e satélites, apresentam características e respostas distintas para cada alvo. Logo, o segundo capítulo buscou verificar qual destas plataformas apresenta melhor qualidade na aquisição dos dados para a cultura do amendoim. Foi utilizado imagens do satélite de alta resolução (~3 m), PlanetScope, e para as imagens aéreas, utilizou-se câmera multiespectral micasense. Para estudar o a variabilidade dos dados e conseqüentemente a qualidade do processo (sensoriamento remoto), utilizou-se ferramentas do controle estatístico de processo.

No terceiro capítulo são apresentados os resultados dos modelos de previsão utilizando sensoriamento remoto e aprendizado de máquinas. O estudo foi realizado em área comercial e os dados foram obtidos através de sensores orbital e aéreo. Para o sensor orbital utilizou-se imagens do PlanetScope que dispõe de 4 comprimentos de ondas (*green, red, blue e nir*) que foram utilizadas para calcular os índices NDVI, GNDVI, NLI, MNLI, EVI e SAVI. Para as imagens aéreas, foi utilizada câmera multiespectral micasense acoplada a UAV DJI Matrice 100. Como o sensor possui 5 bandas espectrais (*green, red, near infrared e red edge*), a gama de índices de vegetação utilizados foi maior que para os satélites, sendo eles, NDVI, GNDVI, NLI, MNLI, NDRE, EVI e SAVI.

Por fim, no quarto capítulo, são apresentadas as considerações finais da dissertação, os quais demonstram os melhores resultados obtidos de forma objetiva e coesa, bem como recomendações e perspectivas de estudos futuros.

Hipóteses

Há diferença na qualidade de leitura do monitoramento da variabilidade de parâmetros biofísicos da cultura do amendoim para plataformas aérea e orbital.

O uso de plataformas de sensoriamento remoto pode ser utilizado para prever a maturação do amendoim de forma não destrutiva.

A partir da combinação de tecnologias de sensoriamento remoto e Inteligência Artificial é possível criar modelos capazes de prever a maturação de forma precisa e acurada utilizando bandas espectrais e índices de vegetação.

Objetivos

Indicar qual plataforma (UAV e satélite) tem o sensor com melhor qualidade para estudar parâmetros biofísicos da cultura do amendoim.

Desenvolver e validar uma metodologia de predição para a cultura do amendoim utilizando informações de sensoriamento remoto e técnicas de aprendizado de máquinas.

Verificar qual índice de vegetação e quais plataformas de sensoriamento remoto são melhores para prever a maturação do amendoim utilizando inteligência artificial.

REVISÃO BIBLIOGRÁFICA

Amendoim

Em meados da década de 70, os estados de São Paulo e Paraná eram responsáveis por 90% da produção de amendoim do País (Ferrari-neto et al., 2012). No entanto, com a expansão da soja, que foi facilitada por fatores políticos e econômicos, o amendoim que era a principal matéria-prima do mercado das oleaginosas no Brasil, acabou perdendo espaço e a cultura passou a ser marcada pela instabilidade na oferta, principalmente em decorrência da falta de tecnologia (Lourenzani., et al 2006). A partir dos anos 2000, a cultura voltou mostrar força, e a produção de amendoim no Brasil encontra-se em expansão.

A cultura do amendoim vem crescendo nas últimas décadas em decorrência dos grandes avanços tecnológicos, como mecanização, ajustes no manejo da cultura, sistemas de GNSS e aplicações de sensoriamento remoto (Sampaio, 2021; Santos et al., 2019; Morlin, 2018, Zerbato et al., 2019, Oliveira, 2021). O amendoim destaca-se na alimentação humana pois é bastante consumido *in natura* e seu fruto é rico em nutrientes e proteínas, com produção direcionada para o óleo, farelo e grãos (Ferrari-neto et al., 2012). A produção de biodiesel também surge como aplicação promissora para a cultura do amendoim, por sua matéria-prima apresentar alto teor de óleo em suas sementes (Nakagawa & Rosolém 2011; Santos e Todeschini, 2011).

Os continentes africano, asiático e americano destacam-se na produção de amendoim com a China, Índia e Nigéria no topo de produção com 18,2, 6,0 e 4,4 milhões de toneladas, respectivamente (USDA, 2021). Tratando-se da produção no continente americano, os Estados Unidos aparece como maior produtor (2,9 milhões de toneladas), seguido de Argentina e Brasil, que produzem 1,4 e 0,7 milhões de toneladas respectivamente (USDA, 2021). No Brasil seu cultivo se estende por diversas regiões devido a ampla adequação da cultura em diferentes condições de climáticas, como regiões

tropicais e subtropicais (Peixoto et al., 2008; Godoy, 2002). No Brasil a produção de amendoim é realizada nas regiões Sudeste, Sul, Centro-Oeste e Nordeste (Conab, 2021).

A produção nacional de amendoim vem se consolidando e batendo recordes a cada ano. Para o período de 2020/2021, estima-se incremento em área semeada e em produção para a cultura do amendoim de 3,1 e 7,0 %, respectivamente. Em relação à produção por área, o Sudeste destaca-se com 155,3 mil kg há⁻¹ seguido do Sul, Centro-Oeste e Nordeste com área de 5,7, 2,0 e 2,5 mil kg há⁻¹, respectivamente. Em decorrência das maiores áreas cultivadas, o Estado de São Paulo é responsável por 94% de toda produção nacional com 524,5 toneladas com produtividade média de 3,666 kg há⁻¹ (Conab, 2021).

Especificamente no estado de São Paulo, a cultura do amendoim é produzida em sucessão à reforma de pastagem e cana de açúcar. O amendoim produzido no estado é dividido em duas regiões, em que a região conhecida com Alta Mogiana (Ribeirão Preto e Jaboticabal, entre outras) tem o cultivo predominantemente realizado com a sucessão em canaviais, enquanto que, na região da Alta Paulista (Tupã e Marília, e outras) os cultivos são realizados em áreas de pastagem e cana de açúcar, com produção de safra principal (safra das águas) e a safrinha (safra da seca) (Martins, 2010).

Maturação do amendoim

Dentro de todo ciclo do amendoim, decidir o momento ideal para arrancar o amendoim é uma das decisões mais importantes para o produtor não sofrer danos econômicos (Rowland et al., 2006). Em relação à lucratividade, o produtor deve atentar-se para não realizar o arranquio de forma prematura ou tardia, pois podem causar perdas excessivas com vagens muito maduras e perdas na qualidade do produto final para vagens imaturas. A determinação da maturidade do amendoim se torna um processo complexo devido ao amendoim apresentar características de crescimento e desenvolvimento indeterminado, com seu fruto sendo formado ao longo da estação de crescimento e cultivado abaixo do solo (Sanders et al., 1982).

O desenvolvimento das vagens abaixo do solo é crucial para a cultura do amendoim, devido à formação das vagens serem responsivas à luz, logo, o processo ocorre da seguinte forma: a presença de luz aumenta a taxa de alongamento do ginóforo, enquanto que a ausência da mesma, promove o desenvolvimento das vagens (Moctezuma, 2003; Ziv e Zamski, 1975; Zamski e Ziv, 1976; Thompson, Ziv e Deitzer, 1985, Zhu et al., 2013).

Diante da importância da maturação do amendoim, diversos métodos foram criados ao longo dos anos. No entanto, a metodologia mais difundida e aceita pelos

produtores de amendoim é a determinação do índice de maturação a partir do quadro de maturação de Williams e Drexler (1981). Estes autores descrevem a relação da maturação do amendoim com cores expostas do mesocarpo, e a partir desta classificação identificam os estádios de desenvolvimento das vagens. O quadro é composto por classes de cores que vão do branco, amarelo 1, amarelo 2, laranja, marrom e preto. Estas classes de cores são divididas em colunas individuais (25 sub-classes) para representarem os estádios das vagens dentro de cada classe de cor (Tabela 1).

Tabela 1. Classes e sub-classes apresentadas no quadro de maturação do amendoim.

Classes de cores	Maturação	Sub-Classes
Branco	Imaturo	1,2,3,4
Amarelo 1	Imaturo	5,6,7,8
Amarelo 2	Imaturo	9,10,11,12
Laranja	Maturação precoce	13,14,15,16
Marrom	Maduro	17,18,19
Preto	Maturação tardia	20,21,22,23,24,25

Para facilitar a tomada de decisão em função da distribuição das vagens no quadro de maturação, Rowland et al. (2006) desenvolveram o *Peanut Maturity Index* (PMI), que visa estabelecer o momento ideal de colheita, a partir da soma de todas as vagens distribuídas nas classes marrom e preta dividida pelo número total de vagens utilizadas na amostra. Esses valores de PMI variam entre 0 e 1, com 0.7 sendo indicador para o momento ideal para o início da colheita.

Por mais que o quadro de maturação seja amplamente utilizado, fatores como subjetividade, e a alta demanda de avaliações para verificação da maturação em intervalos que antecedem o arranquio do amendoim, tornam o método bastante trabalhoso (Rowlad et al., 2006; Colvin et al., 2014). Diante disto, pesquisadores têm buscado desenvolver alternativas que facilitem a identificação da maturação do amendoim com métodos não-destrutivos e menos subjetivos.

Agricultura Digital

A Agricultura Digital tem se desenvolvido de forma rápida dentro do agronegócio, e suas aplicações são essenciais para o momento atual em que vivemos, com alta demanda por produção de alimentos visando o desenvolvimento sustentável (FAO, 2019). A

agricultura está diretamente relacionada com os Objetivos de Desenvolvimento Sustentável (ODS). Dentre as 17 ODS criadas pela a Organização das Nações Unidas, 10 podem ser atendidas por ações relacionadas com a agricultura (Figura 1). A transformação digital na agricultura surge com grande potencial para solucionar os problemas enfrentados pelo o setor agrícola (Trendov et al., 2019).



Figura 1. Objetivos de desenvolvimento sustentável relacionados a agricultura.
 Fonte: Adaptado de Project Breakthrough (2017).

As tecnologias digitais podem ser classificadas em cinco grupos. No primeiro grupo estão as técnicas associadas à organização e a representação da informação. Logo, o objetivo de tecnologias, como por exemplo big data, é anotar, classificar, estruturar e prover mecanismos de acesso para que a informação seja encontrada e reutilizada no futuro. No segundo grupo encontra-se a modelagem matemática e estatística, com destaque para a Ciência de Dados, que incorpora técnicas e teorias das mais diversas áreas de conhecimento como computação, engenharia, matemática, estatística, economia, mineração de dados e inteligência artificial, com o objetivo de coletar dados, processá-los, integrá-los e analisá-los visando à criação de produtos e serviços de dados (Amaral, 2016). No terceiro grupo classifica-se a Inteligência Artificial que são tecnologias que reconhecem e aprendem padrões. Em seguida temos o grupo que estão os sensores orbitais, proximais e aéreos que permitem o monitoramento terrestre. E por último, a chamada tecnologia convergente, que é representada pelo armazenamento de dados em nuvens, para que sejam processados com calma, e também para o atendimento de uma demanda recorrente na agricultura, que é a rastreabilidade de seus produtos e processos (Souza et al., 2020).

Devido à vasta quantidade de dados obtidos, o processamento e análise em infraestruturas de alto desempenho computacional, como por exemplo a computação em nuvens, são necessários para o desenvolvimento de informações confiáveis e robustas para gestões agrícolas automatizadas (Basso et al., 2019). A agricultura digital também conhecida como “4.0” engloba métodos de alto desempenho por meio do uso de computadores, rede de sensores, conectividade entre dispositivos móveis, armazenamento de dados em nuvem, modelos analíticos que são capazes de processar grande quantidade de dados e gerar informações para auxiliar no desenvolvimento agrícola, melhorando a produtividade, qualidade, rentabilidade e sustentabilidade, reduzindo custos e riscos (Massruhá e Leite, 2017; Queiroz et al., 2020).

O’ Malley et al. (2020) estudando as perspectivas da agricultura, verificaram que o setor agrícola tem mudado de forma positiva com a implementação de tecnologias digitais. Segundo os mesmos autores, ferramentas como sistemas de informação geográficas (SIG) e sensores remotos são vistos como principais impulsionadores destas transformações na agricultura. Tecnologias digitais como Inteligência Artificial, Robótica, Big Data, Internet das Coisas (IoT), Conectividade e Aprendizado de Máquinas têm sido combinados com atividades de monitoramento agrícola, resultando na otimização de atividades operacionais com o apoio à tomada de decisão (Alm et al., 2016; Porter e Heppelmann, 2014; Kempenaar et al., 2016). O uso e aplicações de tecnologias digitais na agricultura é evidenciado em grande quantidade na literatura, principalmente em tópicos envolvendo análise de big data, veículos aéreos não tripulados (UAV), inteligência artificial e robótica, impressão 3D, IoT (de Amorim et al., 2019; Dick et al., 2019; Hunt and Daughtry, 2018; Kamilaris et al., 2017; Mogili e Deepak, 2018; Portanguen et al., 2019 ; Shamshiri et al., 2018 ; Skvortsov et al., 2018 ; Smith, 2018 ; Verdouw et al., 2013; Voon et al., 2019; Weersink et al., 2018; Zhang e Wei, 2017; Zhao et al., 2019).

A implementação de tecnologias digitais em propriedades rurais é vista como algo imprescindível para o sucesso no setor agropecuário. Neste contexto, a transformação da agricultura com tecnologias digitais pode trazer benefícios com inovações dentro de todo o ciclo produtivo, passando a agregar valor não somente à produção, mas para todos os processos que envolvam produto e cliente, promovendo desenvolvimento para os setores agrícolas como, fabricantes de insumos (otimização de recursos, eficiência produtiva e novos produtos e mercados), produtores rurais, (produtividade agrícola, sustentabilidade e tomada de decisões), processadores, (planejamento e ações gerenciais, agregação de

valor e redução de perdas), distribuidores (diversidade de produtos, novos nichos de mercados e plataformas de comercialização) e consumidores (conectividade, protagonismo digital e novos negócios) (Barbedo e Massruhá, 2020).

Sensoriamento remoto na agricultura

Práticas utilizando o Sensoriamento Remoto (SR) na agricultura têm sido estudadas desde a década de 1970 (Formaggio e Sanches, 2017), com os Estados Unidos sendo pioneiros em pesquisas por meio do lançamento do primeiro satélite da série Landsat, colocado em órbita em 1972 (Macdonald et al., 1975). Depois do sucesso do programa americano Landsat, diversos países buscaram desenvolver seus próprios satélites, cada um, procurando atender a necessidades específicas, em função das características geográficas de cada região do globo terrestre. Atualmente, a superfície da Terra é imageada por dezenas de sensores orbitais, com alta capacidade de detalhamento com possibilidade de detectar objetos da superfície em escalas de 50 cm (Meneses e Almeida 2012).

No Brasil, em meados da década de 1980, pesquisas com SR foram incentivadas para realizar mapeamento extensivo da cobertura vegetal de culturas como cana-de-açúcar e feijão (Ponzoni et al., 2012). No entanto, desde o início da década de 70, o INPE (Instituto Nacional de Pesquisas Espaciais) demonstra aplicações do SR a nível nacional de forma pioneira, consolidando a tecnologia e destacando o Brasil no uso do SR na América do Sul (Formaggio e Sanches, 2017). Nos dias atuais o Brasil conta com a série de satélites em parceria com a China, denominado de China-Brazil Earth Resources Satellite (CBERS) que fora lançando em 1999 e já se encontra na sua quarta edição.

O SR é uma tecnologia que fornece coleta de dados a partir do uso de imagens, para o levantamento e o monitoramento dos recursos da Terra de forma não destrutiva, rápida e econômica, sendo reconhecida, como importante ferramenta na agricultura (Becker-Reshef et al., 2010). A principal vantagem das aplicações do SR na agricultura, é a possibilidade do monitoramento quase em tempo real do crescimento e vigor das plantas, auxiliando o produtor com medidas preventivas para aumentar a produtividade agrícola (Maimaitijiang et al., 2020; Sagan et al., 2021). Segundo Formaggio e Sanches, (2017) o SR pode contribuir com agricultura em estimativas de biomassa e de produtividade, mapeamentos de distúrbios, de estresse e do desenvolvimento fenológico das culturas, entre outros.

As plataformas mais utilizadas para o monitoramento agrícola são os satélites e os veículos aéreos não tripulados (UAV). Usando sensores multiespectrais e hiperespectrais, estas plataformas geram imagens que podem ser usadas para calcular índices de vegetação e determinar a variabilidade das lavouras (Hassler e Baysal-Gurel, 2019).

O uso de satélites na agricultura apresenta diversas aplicações como, mapeamento de áreas agrícolas, identificação de espécies, época de plantio e colheita, mapeamento de áreas irrigadas por pivô central, entre outros. No entanto, problemas como resolução espaço-temporal e cobertura de nuvens limitam o uso de satélites em diversas aplicações agrícolas, como por exemplo o monitoramento fenológico das culturas e detecção de plantas daninhas (Peña et al., 2015; Mink et al., 2018; Rasmussen et al., 2019 Wang et al., 2020). No entanto, com incremento de novas tecnologias no SR, a resolução espacial aumentou de 80 m com LANDSAT 1 para menos de um metro (0,31 m) com o WorldView-4. Satélites como Quick Bird, IKONOS, GeoEYE, WorldView-3 e 4 (WV) e PlanetScope (PS) então surgem como sensores de alta resolução espaço-temporal apresentando grande potencial no estudo da vegetação. Logo, estudos apontam que estas plataformas provaram ser uma alternativa viável para monitorar o desempenho de rendimento da cenoura, soja, milho, e índice de maturação do amendoim (Santos et al., 2021; Suarez et al., 2020, Sagan et al., 2021;

Os UAV's apresentam imagens com alta resolução espacial e temporal. No entanto, requisitos operacionais como autonomia de voo podem inibir o uso desta ferramenta em grandes áreas (Gevaert et al., 2014). A tecnologia UAV tem adquirido destaque por se tornar mais acessível devido ao baixo custo de aquisição, baixa manutenção e capacidade de transmissão de dados em tempo real (Mukherjee et al., 2019). Estudos demonstraram que o UAV tem potencial para monitoramento de culturas como trigo (Duan et al. 2017), cevada (Bendig et al. 2015), milho (Castaldi et al. 2017) e arroz (Zhou et al. 2017).

Conceitos de sensoriamento remoto

O uso de sensores em plataformas orbitais, aéreas e terrestres pode proporcionar o manejo eficiente da variabilidade espaço-temporal dos campos de produção agrícolas, de forma rápida e com baixo custo (Mouazen et al., 2020). Estes sensores obtêm informações geradas dos alvos a partir da reflexão e emissão da energia eletromagnética (Crepani, 1993). Essa energia é propagada e captada por meio da radiação de fótons que

percorrem através dos diferentes comprimentos de ondas do espectro eletromagnético. (Figura 2). (Heege, 2013).




Figura 2. Espectro eletromagnético da radiação elétrica e magnética. Fonte: Adaptado de Oliveira et al. (2017).

Dentro de todos os comprimentos de ondas do espectro eletromagnético, as faixas comumente utilizadas na agricultura são do infravermelho próximo e do espectro do visível (Molin et al., 2015). Na região do visível (vermelho, verde e azul), a maior parte da radiação emitida sobre o dossel das plantas, é absorvida pelos pigmentos fotossintéticos (clorofila “a” e “b” em maior quantidade, carotenoide, xantofilas e antocianinas). Na região do infravermelho, o comportamento da radiação depende das estruturas celulares internas, que de modo geral, sofrem contribuição indireta do conteúdo de água na folha. Nessa região a absorção é baixa (menos de 15%) e a reflectância pode chegar a 50% (Tucker e Garratt, 1977).

A radiação incidente na superfície interage de modo distinto com cada tipo de objeto, e essa diferença é captada, devido às diferentes características físico-químicas e biológicas de cada alvo ou feições terrestres. Diante disto, cada alvo vai absorver transmitir e refletir cada uma das faixas do espectro eletromagnético de forma diferente, fazendo com que cada alvo tenha sua própria assinatura espectral (Figura 3) (Figueiredo, 2005). A energia que é refletida pelo dossel das plantas é influenciada por fatores intrínsecos à cultura, no entanto, pode ocorrer alterações devido a fatores como, déficit hídrico, ataque de pragas e doenças, estado nutricional, alterações climáticas, entre outros. Além disto, as condições do meio ambiente podem ser responsáveis pela distorção da energia que é percorrida entre alvo e os sensores (Moreira, 2005). Isso ocorre devido às

trocas e interações da energia carregada pelas ondas eletromagnéticas com a energia contida nos átomos e moléculas que compõem os alvos (Fomaggio e Sanches, 2017).

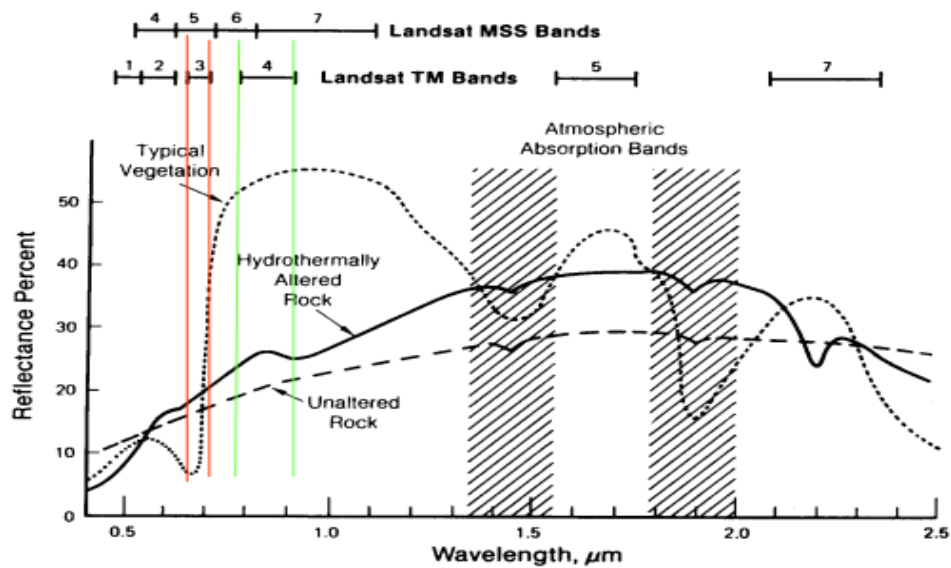


Figura 3. Comportamento espectral das bandas do satélite Landsat. Fonte: Figueiredo, (2005).

Os sensores utilizados em plataformas de SR, que têm por finalidade captar a energia eletromagnética proveniente da superfície, podem ser classificados como ativos e passivos. Os ativos transmitem a própria radiação que incide sobre o alvo, comuns em sensores proximais, enquanto que os sensores passivos dependem da radiação solar, como por exemplo, sensores embarcados em satélites (Molin et al., 2015). Os sensores ativos também estão presentes nos satélites e são produzidos por radares. Estes sensores tem como principal vantagem, a capacidade das ondas produzidas atravessarem as nuvens, podendo ser operados em diferentes condições atmosféricas. No entanto, quando se trata principalmente da aplicação destes sensores na agricultura, tais sensores podem não oferecer respostas interessantes, devido não conseguirem captar as características físicas e químicas tão detalhadamente (Figueiredo, 2005).

A qualidade dos sensores é determinada a partir da capacidade destes em obter medidas detalhadas da energia eletromagnética. A qualidade dos sensores pode ser classificada em função das características relacionadas com as resoluções espacial, espectral, temporal e radiométrica. A resolução espacial representa a capacidade do sensor em distinguir os alvos, enquanto que a resolução espectral está relacionada com a largura espectral em que o sensor opera. Já a resolução temporal determina a repetibilidade em que o sensor pode adquirir os dados referente ao objeto de estudo. Por último temos a resolução radiométrica que define o quanto o sensor é capaz de detectar

sinais e ruídos, captando diferenças na energia eletromagnética que é refletida e/ou emitida pelos alvos (Moraes, 2002).

O monitoramento e a estimativa de parâmetros biofísicos das culturas agrícolas são as principais contribuições que o SR oferece para agricultura. Logo, a caracterização da dinâmica temporal e do vigor vegetativo podem ser monitorados por Índices de Vegetação (IVs). Os IVs são desenvolvidos a partir de cálculos aritméticos com bandas espectrais que permitem estudar o comportamento da variabilidade espaço-temporal das plantas. O uso dos índices de vegetação, visa melhorar as informações e estimar variáveis de plantas como, a biomassa das culturas, área foliar, cobertura do solo, biomassa, teor de clorofila foliar, cobertura de resíduos (Khanal et al., 2017).

Diversos IVs foram desenvolvidos com intuito de estudar a vegetação, utilizando características de absorção dos componentes bioquímicos das plantas. Estes índices podem ser usados para avaliar parâmetros de crescimento do dossel, propriedades fisiológicas e bioquímicas, produtividade, índice de área foliar, teor de nitrogênio, infestação de plantas daninhas. Além da aplicabilidade em fenômenos fitopatológicos como por exemplo a incidência e severidade de doenças, patologia de sementes, grãos ardidos, entre outros (Zhang et al., 2019; Wang et al., 2012; Torres-Sánchez et al., 2013; Ma et al., 1996; Raun et al., 2002; Shanahan et al., 2001; Solari et al., 2008; Uebel, 2015; Motomiya et al., 2012; Molin et al., 2010).

Inteligência Artificial (IA) na agricultura

A agricultura está entrando no universo digital com o advento de tecnologias que unem o cérebro normal a um artificial. O processo pelo qual o homem cria uma máquina inteligente é denominado de Inteligência Artificial (IA), que é um termo amplamente utilizado para se referir aos métodos, ferramentas e máquinas, que têm a capacidade de racionar, reconhecer padrões, planejar e solucionar problemas. Técnicas de IA envolvem o processo de Aprendizado de Máquinas ou *Machine Learning* (ML), que tem como propósito aplicar abordagens matemáticas para construir máquinas inteligentes e a partir disto, executar tarefas a fim de resolver problemas complexos (Jha et al., 2019). A inteligência artificial também envolve a ferramenta de aprendizado profundo ou *Deep Learning* (DL). Diante disto, podemos classificar o ML como um subconjunto da IA e o DL como sendo, subconjunto do ML (Figura 4).




Figura 4. Diagrama de Venn da inteligência artificial: ligação entre inteligência artificial, aprendizado de máquina e aprendizado profundo. Fonte: Mellir e Kalogirou, (2021).

O aprendizado de máquinas envolve técnicas capazes de proporcionar aos computadores a capacidade de aprender automaticamente. As etapas para implementação do ML começa com o banco de dados brutos, pré processamento de recursos, treinamento e validação do modelo (Arthur, 1967). Os métodos de ML são capazes de esclarecer os efeitos de variáveis colineares e analisar as relações não lineares entre as variáveis independentes e dependentes, o que proporciona melhores resultados de desempenho em comparação com modelos convencionais de regressão (Belayneh et al., 2014 ; Guzmán et al., 2018

Os métodos de ML combinados com técnicas de SR apresentam capacidade de armazenar características não lineares e lineares de sistemas agrícolas, devido à crescente disponibilidade de dados. Em decorrência disto, aplicações de técnicas de ML no contexto do sensoriamento tem ganhado notoriedade e confiabilidade em trabalhos de estimativa de rendimento com o uso de índices de vegetação (Chlingaryan et al., 2018; Cai et al., 2019; Maimaitiyiming et al., 2019; Maimaitijiang et al., 2020).

Diversas lógicas e métodos são aplicadas a partir do aprendizado de máquinas visando melhorar o processo de soluções dos problemas. Dentre todos métodos (Lógica Fuzzy, Redes Neurais Artificiais (RNA's), Lógica Neuro-Fuzzy e Sistemas Especializados), as classes de RNA's, estão sendo amplamente utilizada na agricultura, como na previsão de biomassa, produção de batata, valor energético de silagens, classificação de doenças, identificação de plantas daninhas e produtividade (Jha et al., 2019; Abrougui et al., 2019; Kowalczyk-Juśko et al., 2020; Paswan e Begum 2013; Picon et al., 2019; Lamba e Dhaka 2014; Dyrmann et al., 2016). Este tipo

de abordagem vem ganhando espaço em estudos agrícolas, devido as RNA's apresentarem métodos precisos e auto adaptativos na previsão de parâmetros agronômicos (Jiang et al., 2004).

Os modelos de RNA's foram inspirados no sistema nervoso do ser humano, mas de forma simplificada. As redes são geradas a partir da análise de propagação de impulsos elétricos pela membrana celular dos neurônios biológicos (Silva et al., 2010). Estes neurônios artificiais visam identificar padrões e relações intrínsecas entre os dados para aprender (Haykin, 2001). Devido às características de reconhecimento e aprendizado de padrões nos conjuntos de dados, estudos indicam que as RNA's apresentam desempenho preditivo melhor do que técnicas de regressão linear múltipla (Altikat et al., 2020).

Existem diversos tipos de RNA's e estas redes diferenciam-se pelas arquiteturas, que são as diversas formas com que os neurônios se conectam uns com os outros. As redes Perceptron Multicamadas (MLP) e redes de Ativação de Base Radial (RBF) estão entre as arquiteturas mais utilizadas. A MLP é treinada pelo algoritmo *backpropagation*, que é responsável pelos ajustes dos erros. A arquitetura destas redes é composta por uma camada de entrada que recebe o sinal, uma camada de saída que irá tomar a decisão ou prever a partir das entradas, e mais de uma camada oculta (Haykin, 2001). Já a rede RBF, apresenta uma estrutura simples no que diz respeito ao fluxo de informação. Elas apresentam uma camada de entrada, uma camada oculta e uma camada de saída (Han et al., 2011). O treinamento da RBF é dividido em duas etapas. A primeira é correspondente aos parâmetros de base de ativação pertencente à camada oculta, enquanto que na segunda etapa são determinados através de mínimos quadrados, os pesos da camada de final (Ghodsi e Schuurmans, 2003).

Controle Estatístico de Qualidade

O uso de técnicas do Controle Estatístico de Qualidade (CEQ) tornou-se realidade no estudo de diversas operações agrícolas (Silva et al., 2007; Silva et al., 2008; Soela et al., 2020; Cassia, 2016; Voltarelli et al., 2015; Milan et al., 2002; Silva et al., 2016; Cunha et al., 2018). Identificar o quão adequada as operações estão sendo realizadas é um dos fatores mais importantes para auxiliar a tomada de decisão na agricultura (Morlin, 2019). Com o avanço da competitividade no agronegócio, a importância da qualidade das operações agrícolas vem tornando-se o divisor de água para obter altas produtividades.

O CEQ é aplicado em diversos segmentos para estabelecer parâmetros uniformes durante diversas etapas produtivas de serviços ou produtos (Fernandes, 2005). Deste

modo, a preocupação com processos não padronizados converteu-se em um sistema de gestão estratégica, que compreende principalmente, a redução da variabilidade e eliminação de falhas nas operações agrícolas (Noronha et al., 2011). A variabilidade está exposta em todos os processos de produção e serviços, podendo ser medida por variáveis ou por atributos (Souza, 2006).

Com uso do CEQ para minimizar a variabilidade decorrente dos processos, é possível observar a variabilidade com causas comuns ou aleatórias sendo inerentes ao processo, e as causas especiais ou não-comuns que podem e devem ser diagnosticadas para garantir que a qualidade da operação fique em padrões desejados. Para a operação ser considerada sob controle estatístico, o processo deve apresentar somente variação de causas comuns as quais são dificilmente eliminadas (Ramos, 2003; Veit, 2003) (Figura 5), porém, a correta análise e interpretação do conjunto de dados são essenciais para futuras tomadas de decisões.




Figura 5. Estrutura das cartas de controle. Quando nenhum ponto é destacado na carta de controle, não há observação falha no processo, ou seja, não existem causas especiais de variação e, conseqüentemente, o processo está sob controle estatístico.

Dentre as ferramentas do CEQ, as cartas de controle (CEP) surgem com grande potencial para melhorar a qualidade dos processos agrícolas, com análises de interpretação de dados, visando melhorar o gerenciamento e a tomada de decisão, monitorando a condição de fontes externas de variação (Silva et al., 2008). Diante disto, as cartas de controle podem apresentar estratégias para auxiliar o gerenciamento da operação com a criação de um plano de melhorias para redefinir, se necessário, os padrões

de qualidade de determinados serviços no campo e ainda avaliar se as melhorias surtiram efeitos a fim de manter a qualidade das operações (Voltarelli et al., 2014).

Diversas análises estatísticas podem identificar e interpretar a variabilidade de um processo agrícola, entretanto, a estatística descritiva é fundamentada em medidas de tendência central (média aritmética, mediana e modo), medidas de dispersão (amplitude, desvio padrão e coeficiente de variação) medidas de assimetria e de curtose e técnicas ou gráficos como histogramas e diagramas de caixa (box-plots), dentre outros. A interpretação dos fatores e suas correlações em uma análise de variância, também se relacionam a variabilidade do processo (Alves, 2003; Bonilla, 1995). De todo modo, a associação destas análises ao CEP, apresenta maior visão e entendimento do comportamento do processo ao longo do tempo, o que favorece a identificação de momentos críticos que afetam a qualidade do processo (Paixão, 2015).

Referências bibliográficas

Abrougui, K., Gabsi, K., Mercatoris, B., Khemis, C., Amami, R., & Chehaibi, S. (2019). Prediction of organic potato yield using tillage systems and soil properties by artificial neural network (ANN) and multiple linear regressions (MLR). *Soil and Tillage Research, 190*, 202-208.

Alm, E., Colliander, N., Lind, F., Stohne, V., Sundström, O., Wilms, M., & Smits, M. (2016). Digitizing the Netherlands: How the Netherlands can drive and benefit from an accelerated digitized economy in Europe. *Boston Consulting Group*.

Altikat, S., Gulbe, A., Kucukerdem, H. K., & Altikat, A. (2020). Applications of artificial neural networks and hybrid models for predicting CO₂ flux from soil to atmosphere. *International Journal of Environmental Science and Technology, 17*, 4719-4732.

ALVES, C. C. Gráficos de controle CUSUM: um enfoque dinâmico para a análise estatística de processos. 2003. 119 f. *Dissertação* (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2003.

Arthur, S. (1967). Some studies in machine learning using the game of checkers ii-recent progress. *IBM J of Research and Development ll, (6)*, 601-617.

Bassoí, L. H., Inamasu, R. Y., BERNARDI, A. D. C., Vaz, C. M. P., Speranza, E. A., & Cruvinel, P. E. (2019). Agricultura de precisão e agricultura digital. *Embrapa Pecuária Sudeste-Artigo em periódico indexado (ALICE)*.

Becker-Reshef, I., Justice, C., Sullivan, M., Vermote, E., Tucker, C., Anyamba, A., ... & Doorn, B. (2010). Monitoring global croplands with coarse resolution earth observations: The Global Agriculture Monitoring (GLAM) project. *Remote Sensing*, 2(6), 1589-1609.

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., ... & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87.

Bolfe, E., Barbedo, J. G. A., Massruhá, S. M. F. S., de Souza, K. X. S., & Assad, E. D. (2020). Desafios, tendências e oportunidades em agricultura digital no Brasil. *Embrapa Informática Agropecuária-Capítulo em livro científico (ALICE)*.

BONILLA, J. A. Métodos quantitativos para qualidade total na agricultura. Contagem: Littera Maciel, 1995. 250 p.

Carneiro, F. M. (2018). *Tese*. Sensores de dossel no monitoramento da variabilidade temporal das culturas da soja e do amendoim.

Cassia, M. T. (2016). *Tese* Cartas de controle para gerenciamento de operações agrícolas mecanizadas.

Castaldi, F., Pelosi, F., Pascucci, S., & Casa, R. (2017). Assessing the potential of images from unmanned aerial vehicles (UAV) to support herbicide patch spraying in maize. *Precision Agriculture*, 18(1), 76-94.

Chlingaryan, A., Sukkariéh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and electronics in agriculture*, 151, 61-69.

Colvin, B., D. Rowland, J., Ferrell, Faircloth, W.H. (2014). Development of a digital analysis system to evaluate peanut maturity. *Peanut Science*, 41(1):8-16.

CONAB. Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira: grãos, safra 2020/2021, sexto levantamento: março/2021. Brasília: Conab, 2021.

Correa-Díaz, A., Silva, L. C. R., Horwath, W. R., Gómez-Guerrero, A., Vargas-Hernández, J., Villanueva-Díaz, J., ... & Suárez-Espinoza, J. (2019). Linking remote sensing and dendrochronology to quantify climate-induced shifts in high-elevation forests over space and time. *Journal of Geophysical Research: Biogeosciences*, 124(1), 166-183.

Crepani, E. (1993). Princípios básicos de sensoriamento remoto. São José dos Campos: CNPq/INPE, 45p.

Cunha, J. P. B., Castro, M. S., Costa, A. G., DE Barros, M. M., Machado, T. A., Honorato, L. P., & Duarte, C. M. (2018). Controle estatístico de processo (CEP) aplicado na colheita mecanizada do sorgo. *Revista Brasileira de Milho e Sorgo*, 17(3), 490-501.

de Amorim, W. S., Deggau, A. B., do Livramento Gonçalves, G., da Silva Neiva, S., Prasath, A. R., & de Andrade, J. B. S. O. (2019). Urban challenges and opportunities to promote sustainable food security through smart cities and the 4th industrial revolution. *Land Use Policy*, 87, 104065.

de Moraes, E. C. (2002). Capítulo 1 fundamentos de sensoriamento remoto.

de Queiroz, D. M., de Freitas Coelho, A. L., Valente, D. S. M., & Schueller, J. K. (2020). Sensors applied to Digital Agriculture: A review. *Revista Ciência Agronômica*, 51, 1-15.

Duan, T., Chapman, S. C., Guo, Y., & Zheng, B. (2017). Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle. *Field Crops Research*, 210, 71-80.

Dyrmann, M., Karstoft, H., & Midtby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems engineering*, 151, 72-80.

elayneh, A., Adamowski, J., Khalil, B., & Quilty, J. (2016). Coupling machine learning methods with wavelet transforms and the bootstrap and boosting ensemble approaches for drought prediction. *Atmospheric research*, 172, 37-47.

Fernandes, J. M. R. (2005). Proposição de abordagem integrada de métodos da qualidade baseada no FMEA. 104 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas). Pontifícia Universidade Católica do Paraná.

Figueiredo, D. (2005). Conceitos básicos de sensoriamento remoto. *São Paulo*.

Food and Agriculture Organization of the United Nations. (2019). *World Livestock: transforming the livestock sector through the sustainable development goals*. Food and Agriculture Organization of the United Nations.

Formaggio, A. R., & Sanches, I. D. A. (2017). *Sensoriamento remoto em agricultura*. Oficina de Textos.

Gevaert, C. M., Tang, J., García-Haro, F. J., Suomalainen, J., & Kooistra, L. (2014, June). Combining hyperspectral UAV and multispectral Formosat-2 imagery for precision agriculture applications. In *2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)* (pp. 1-4). IEEE.

Ghodsi, A., & Schuurmans, D. (2003). Automatic basis selection techniques for RBF networks. *Neural Networks*, 16(5-6), 809-816.

Godoy, I. J. (2002). Principais características de cultivares IAC. Campinas: IAC, Folheto.

Gonçalves, J. A., Peixoto, C. P., Ledo, C. A. D. S., Pinto, M. D. F. D. S., Sampaio, H. S. D. V., Sampaio, L. S. D. V., & de Almeida, N. S. (2004). Componentes de produção e rendimento de amendoim em diferentes arranjos espaciais no recôncavo Baiano. *Revista Brasileira de Oleaginosas e Fibrosas*, 8(2-3).

Han, H. G., Chen, Q. L., & Qiao, J. F. (2011). An efficient self-organizing RBF neural network for water quality prediction. *Neural networks*, 24(7), 717-725.

Hassler, S. C., & Baysal-Gurel, F. (2019). Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy*, 9(10), 618.

HAYKIN, S. (2001). Redes neurais: princípios e prática. (2 ed.), Bookman, Porto Alegre.

Heege, H.J. (2013). Precision in crop farming. London: Springer, 300p.

Hunt Jr, E. R., & Daughtry, C. S. (2018). What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture?. *International journal of remote sensing*, 39(15-16), 5345-5376.

Jha, K., Doshi, A., Patel, P., & Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2, 1-12.

Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2017). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, 143, 23-37.

Kempenaar, C., Lokhorst, C., Bleumer, E. J. B., Veerkamp, R. F., Been, T., van Evert, F. K., ... & Noorbergen, H. (2016). *Big Data analysis for smart farming: results of TO2 project in theme food security* (Vol. 655). Wageningen University & Research.

Khanal, S., Fulton, J., & Shearer, S. (2017). An overview of current and potential applications of thermal remote sensing in precision agriculture. *Computers and Electronics in Agriculture*, 139, 22-32.

Kick, A., Bhandari, B., & Prakash, S. (2019). 3D printing of meat. *Meat science*, 153, 35-44.

Kowalczyk-Juśko, A., Pochwatka, P., Zaborowicz, M., Czekala, W., Mazurkiewicz, J., Mazur, A., ... & Dach, J. (2020). Energy value estimation of silages for substrate in biogas plants using an artificial neural network. *Energy*, 202, 117729.

Lajoie-O'Malley, A., Bronson, K., van der Burg, S., & Klerkx, L. (2020). The future (s) of digital agriculture and sustainable food systems: An analysis of high-level policy documents. *Ecosystem Services*, 45, 101183.

Lamba, V., & Dhaka, V. S. (2014). Wheat yield prediction using artificial neural network and crop prediction techniques (A Survey). *IJRASET*, 2(IX), 330-341.

Lourenzani, W. L., & Lourenzani, A. E. B. S. (2006). *Potencialidades do agronegócio brasileiro de amendoim* (No. 1347-2016-106506).

Ma, B. L., Morrison, M. J., & Dwyer, L. M. (1996). Canopy light reflectance and field greenness to assess nitrogen fertilization and yield of maize. *Agronomy Journal*, 88(6), 915-920.

MacDonald, R. B., Hall, F. G., & Erb, R. B. (1975, January). The use of Landsat data in a large area crop inventory experiment (LACIE). In *LARS Symposia* (p. 46).

Maimaitijiang, M., Sagan, V., Sidike, P., Daloye, A. M., Erkbol, H., & Fritschi, F. B. (2020). Crop Monitoring Using Satellite/UAV Data Fusion and Machine Learning. *Remote Sensing*, 12(9), 1357.

Maimaitijiang, M., Sagan, V., Sidike, P., Maimaitiyiming, M., Hartling, S., Peterson, K. T., ... & Fritschi, F. B. (2019). Vegetation index weighted canopy volume model (CVMVI) for soybean biomass estimation from unmanned aerial system-based RGB imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151, 27-41.

Maimaitiyiming, M., Sagan, V., Sidike, P., Maimaitijiang, M., Miller, A. J., & Kwasniewski, M. (2020). Leveraging very-high spatial resolution hyperspectral and thermal UAV imageries for characterizing diurnal indicators of grapevine physiology. *Remote Sensing*, 12(19), 3216.

Martins, R., & Vicente, J. R. (2010). DEMANDAS POR INOVAÇÃO NO AMENDOIM PAULISTA1. *Economia*, 28, 2Administradora.

Massruhá, S. M. F. S., & Leite, M. D. A. (2017). Agro 4.0-rumo à agricultura digital. In *Embrapa Informática Agropecuária-Artigo em anais de congresso (ALICE)*. In: Magnoni júnior, L.; Stevens, D.; Silva, W.T.L. da; Vale, J.M.F do; Purini, SR de M.; Magnoni, M. da G.M; Sebastião, E.; Branco Júnior, G.; Adorno Filho, EF; Figueiredo, W. dos S.; Sebastião, I. (Org.). *JC na Escola Ciência, Tecnologia e Sociedade: mobilizar o conhecimento para alimentar o Brasil*. 2. ed. São Paulo: Centro Paula Souza.

Meneses, P. R., & Almeida, T. D. (2012). Introdução ao processamento de imagens de sensoriamento remoto. *Universidade de Brasília, Brasília*.

Milan, M., & Fernandes, R. A. T. (2002). Qualidade das operações de preparo de solo por controle estatístico de processo. *Scientia Agrícola*, 59, 261-266.

Mink, R., Dutta, A., Peteinatos, G. G., Sökefeld, M., Engels, J. J., Hahn, M., & Gerhards, R. (2018). Multi-temporal site-specific weed control of *Cirsium arvense* (L.) Scop. and *Rumex crispus* L. in maize and sugar beet using unmanned aerial vehicle based mapping. *Agriculture*, 8(5), 65.

Moctezuma, E. (2003). The peanut gynophore: A developmental and physiological perspective. *Canadian Journal of Botany*, 81(3):183-190.

Mogili, U. R., & Deepak, B. B. V. L. (2018). Review on application of drone systems in precision agriculture. *Procedia computer science*, 133, 502-509.

Molin JP, Amaral LR, Colaço AF (2015) Agricultura de precisão. Oficina de Textos: São Paulo, p. 119-153.

Molin, J. P., Frasson, F. R., Amaral, L. R., Povh, F. P., & Salvi, J. V. (2010). Capacidade de um sensor ótico em quantificar a resposta da cana-de-açúcar a doses de nitrogênio. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 14, 1345-1349.

Moreira, M. A. (2005). *Fundamentos do sensoriamento remoto e metodologias de aplicação*. UFV.

Motomiya, A. V. D. A., Molin, J. P., Motomiya, W. R., & Rojo Baio, F. H. (2012). Mapeamento do índice de vegetação da diferença normalizada em lavoura de algodão. *Pesquisa Agropecuária Tropical*, 42, 112-118.

Mouazen, A. M., Alexandridis, T., Buddenbaum, H., Cohen, Y., Moshou, D., Mulla, D., ... & Sudduth, K. A. (2020). Monitoring. In *Agricultural internet of things and decision support for precision smart farming* (pp. 35-138). Academic Press.

Mukherjee, A., Misra, S., & Raghuvanshi, N. S. (2019). A survey of unmanned aerial sensing solutions in precision agriculture. *Journal of Network and Computer Applications*, 148, 102461.

Nakagawa, J., Rosolem, C.A. (2011). O amendoim: tecnologia de produção. Botucatu, FEPAF. 325p.

Neto, J. F., da Costa, C. H. M., & Castro, G. S. A. (2012). Ecofisiologia do amendoim. *Scientia Agraria Paranaensis*, 11(4), 01-13.

Noronha, R. H. D. F., Silva, R. P. D., Chioderoli, C. A., Santos, E. P. D., & Cassia, M. T. (2011). Controle estatístico aplicado ao processo de colheita mecanizada diurna e noturna de cana-de-açúcar. *Bragantia*, 70, 931-938.

Paixão CSS. (2015). Tempos, movimentos e qualidade da operação de colheita mecanizada de soja em função do formato dos talhões. Dissertação de mestrado. Universidade Estadual Paulista, Jaboticabal, Brasil. 149pp.

Paswan, R. P., & Begum, S. A. (2013). Regression and neural networks models for prediction of crop production 1.

Peixoto, C. P.; Gonçalves, J. A.; Peixoto, M. F. S. P.; Carmo, D. O. (2008). Características agronômicas e produtividade de amendoim em diferentes espaçamentos e épocas de semeadura no recôncavo baiano. *Bragantia*, v. 67, n. 3, p. 563-568.

Peña, J. M., Torres-Sánchez, J., Serrano-Pérez, A., De Castro, A. I., & López-Granados, F. (2015). Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution. *Sensors*, 15(3), 5609-5626.

Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., & Johannes, A. (2019). Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, 161, 280-290.

Ponzoni, F. J., & Epiphanyo, J. C. N. (2012). In-flight absolute calibration of Cbers sensors. *Revista Brasileira de Cartografia*, 64(4).

Portanguen, S., Tournayre, P., Sicard, J., Astruc, T., & Mirade, P. S. (2019). Toward the design of functional foods and biobased products by 3D printing: A review. *Trends in food science & technology*, 86, 188-198.

Porter, M. E., & Heppelmann, J. E. (2014). How smart, connected products are transforming competition. *Harvard business review*, 92(11), 64-88.

Ramos, E. M. L. S. (2003). Aperfeiçoamento e desenvolvimento de ferramentas do controle estatístico da qualidade – Utilizando quartis para estimar o desvio padrão. 2003. 130 f. Tese (Doutorado Engenharia da Produção) – Universidade Federal de Santa Catarina, Florianópolis.

Rasmussen, J., Nielsen, J., Streibig, J. C., Jensen, J. E., Pedersen, K. S., & Olsen, S. I. (2019). Pre-harvest weed mapping of *Cirsium arvense* in wheat and barley with off-the-shelf UAVs. *Precision Agriculture*, 20(5), 983-999.

Raun, W. R., Solie, J. B., Johnson, G. V., Stone, M. L., Mullen, R. W., Freeman, K. W., ... & Lukina, E. V. (2002). Improving nitrogen use efficiency in cereal grain production with optical sensing and variable rate application. *Agronomy Journal*, 94(4), 815-820.

Rowland, D.L., R.B. Sorensen, C.L. Butts, and W.H. Faircloth. (2006). Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Sci.* 33:125-136.

Sagan, V., Maimaitijiang, M., Bhadra, S., Maimaitiyiming, M., Brown, D. R., Sidike, P., & Fritschi, F. B. (2021). Field-scale crop yield prediction using multi-temporal WorldView-3 and PlanetScope satellite data and deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 174, 265-281.

Sampaio, R. M., & Fredo, C. E. (2021). Características socioeconômicas e tecnologias na agricultura: um estudo da produção paulista de amendoim a partir do Levantamento das Unidades de Produção Agropecuária (LUPA) 2016/17. *Revista de Economia e Sociologia Rural*, 59.

Sanders, °., E. J Williams, SOU. Schubert, eELE. Pattee. 1980. Avaliações do método de maturidade do amendoim. I. Sudeste. *Peanut Sci.* 7:78-82.

Santos, R. F., & Todeschini, A. (2012). Evolução e perspectiva da cultura do amendoim para biocombustível no Brasil¹. *Revista Brasileira de Energias Renováveis*, 1, 197-220.

Shamshiri, R. R., Hameed, I. A., Balasundram, S. K., Ahmad, D., Weltzien, C., & Yamin, M. (2018). Fundamental research on unmanned aerial vehicles to support precision agriculture in oil palm plantations. *Agricultural Robots-Fundamentals and Application*, 91-116.

Shanahan, J. F., Schepers, J. S., Francis, D. D., Varvel, G. E., Wilhelm, W. W., Tringe, J. M., ... & Major, D. J. (2001). Use of remote-sensing imagery to estimate corn grain yield. *Agronomy Journal*, 93(3), 583-589.

Silva, I.N., Spatti, D., e Flauzino, R. A. (2010). Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. Artliber Editora Ltda, São Paulo.

Silva, J. E. R. D., Cunha, J. P. A. R. D., & Nomelini, Q. S. S. (2016). Controle estatístico de processo em pulverização hidropneumática na cultura do café.

Silva, R. P. D., Corrêa, C. F., Cortez, J. W., & Furlani, C. E. (2008). Controle estatístico aplicado ao processo de colheita mecanizada de cana-de-açúcar. *Engenharia Agrícola*, 28, 292-304.

Silva, R. P., Souza, F. G., Cortez, J. W., Furlani, C. E., & Vigna, G. P. (2007). Variabilidade espacial e controle estatístico do processo de perdas na colheita mecanizada do algodoeiro. *Engenharia Agrícola*, 27, 742-752.

Skvortsov, E. A., Skvortsova, E. G., Sandu, I. S., & Iovlev, G. A. (2018). Transition of agriculture to digital, intellectual and robotics technologies. *Ekonomika regiona*, (3), 1014.

Smith, M. J. (2018). Getting value from artificial intelligence in agriculture. *Animal Production Science*, 60(1), 46-54.

Soela, D. M., da Vitória, E. L., de Oliveira, R. F., Crause, D. H., s Freitas, I. L. D. J., & Locatelli, T. (2020). Controle estatístico de processo em pulverização usando veículo aéreo não tripulado na cultura do café conilon: control spraying process statistics using unproved air vehicle in conilon coffee culture. *Brazilian Journal of Production Engineering-BJPE*, 52-63.

Solari, F., Shanahan, J., Ferguson, R., Schepers, J., & Gitelson, A. (2008). Active sensor reflectance measurements of corn nitrogen status and yield potential. *Agronomy Journal*, 100(3), 571-579.

Thompson, L.K., Ziv, M., Deitzer, G.F. (1985). Photocontrol of peanut (*Arachis hypogaea* L.) embryo and ovule development in vitro. *Plant Physiol*, 78(2):370-373.

Torres-Sánchez, J., López-Granados, F., De Castro, A. I., & Peña-Barragán, J. M. (2013). Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. *PloS one*, 8(3), e58210.

Trendov, M., Varas, S., & Zeng, M. (2019). Digital technologies in agriculture and rural areas: status report. *Digital technologies in agriculture and rural areas: status report*.

Tucker, C. J.; Garratt, M. W. (1977). Leaf optical system modelled as a stochastic process. *Applied Optics*, v.16, n.3, p.635-642.

Uebel, J. D. (2015). Avaliação de fungicidas no controle de doenças foliares, grãos ardidos e efeito no ndvi (índice de vegetação por diferença normalizada) em híbridos de milho.

USDA. (2021). ARMS data. USDA-ERS, Washington, DC. https://ipad.fas.usda.gov/cropexplorer/cropview/commodityView.aspx?startrow=1&cropid=2221000&sel_year=2021&rankby=Production (acessado 03 Juno. 2021).

Veit, E. (2003). Aplicação do controle estatístico de processos em indústrias de cabinas: um estudo de caso. 2003. 104 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis.

Verdouw, C. N., Beulens, A. J. M., & Van Der Vorst, J. G. A. J. (2013). Virtualisation of floricultural supply chains: A review from an Internet of Things perspective. *Computers and electronics in agriculture*, 99, 160-175.

Voltarelli, M. A., Silva, R. P. D., Zerbato, C., Paixão, C. S., & Tavares, T. D. O. (2015). Monitoring of mechanical sugarcane harvesting through control charts. *Engenharia Agrícola*, 35, 1079-1092.

Voon, S. L., An, J., Wong, G., Zhang, Y., & Chua, C. K. (2019). 3D food printing: a categorised review of inks and their development. *Virtual and Physical Prototyping*, 14(3), 203-218.

Wang, J., Yang, D., Detto, M., Nelson, B. W., Chen, M., Guan, K., ... & Wu, J. (2020). Multi-scale integration of satellite remote sensing improves characterization of dry-season green-up in an Amazon tropical evergreen forest. *Remote Sensing of Environment*, 246, 111865.

Wang, W., Yao, X., Yao, X., Tian, Y., Liu, X., Ni, J., ... & Zhu, Y. (2012). Estimating leaf nitrogen concentration with three-band vegetation indices in rice and wheat. *Field Crops Research*, 129, 90-98.

Weersink, A., Fraser, E., Pannell, D., Duncan, E., & Rotz, S. (2018). Opportunities and challenges for big data in agricultural and environmental analysis. *Annual Review of Resource Economics*, 10, 19-37.

Williams, E.J., Drexler, J.S. (1981). A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2):134-141.

Zamski, E., Ziv, M. (1976). Pod formation and its geotropic orientation in the peanut, *Arachis hypogaea* L., in relation to light and mechanical stimulus. *Annals of Botany*, 40(3):631-636.

Zhang, C., Valente, J., Kooistra, L., Guo, L., & Wang, W. (2019). Opportunities of uavs in orchard management. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*.

Zhang, D., & Wei, B. (Eds.). (2017). *Robotics and mechatronics for agriculture*. CRC Press.

Zhao, G., Liu, S., Lopez, C., Lu, H., Elgueta, S., Chen, H., & Boshkoska, B. M. (2019). Blockchain technology in agri-food value chain management: A synthesis of applications, challenges and future research directions. *Computers in Industry*, 109, 83-99.

Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., ... & Tian, Y. C. (2017). Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255.

Zhu, W., Zhang, E., Li, H., Chen, X., Zhu, F., Hong, Y., Liao, B., Liu, S., Liang, X. (2013). Comparative proteomics analysis of developing peanut aerial and subterranean pods identifies pod swelling related proteins. *Journal of Proteomics*, 91(1):172-187.

Ziv, M., Zamskj, E. (1975). Geotropic responses and pod development in gynophore explants of peanut (*Arachis hypogaea* L.) cultured in vitro. *Annals of Botany*, 39(3):579-583.

CAPÍTULO 2: UAV E SATÉLITE: QUAL APRESENTA MELHOR QUALIDADE NO MONITORAMENTO DA CULTURA DO AMENDOIM?

Resumo:

Ferramentas de sensoriamento remoto demonstram-se úteis para auxiliar no monitoramento e gerenciamento da produção agrícola. No entanto, cada tecnologia dentro do sensoriamento remoto responde à variabilidade das culturas de forma distinta. Desta forma, objetivou-se comparar sensores embarcados em plataformas aérea e orbital, e observar qual apresenta melhor qualidade para determinar o comportamento da variabilidade da cultura do amendoim. O delineamento experimental seguiu as premissas do Controle Estatístico de Qualidade (CEQ), com as amostras coletadas ao longo do tempo. A área experimental foi composta por 30 pontos amostrais espaçados entre si a cada 50 metros. Foram realizadas avaliações de biomassa fresca e seca, bem como a maturação das vagens aos 75, 105, 120 e 125 dias após a semeadura. Foram realizados voos com o auxílio do Unmanned Aerial Vehicle (UAV) modelo DJI Matrice 100 com câmera Micasense RedEdge-M e para as imagens de satélite foram utilizados dados do sensor da plataforma PlanetScope CubeSat. Foi verificado que em todos os períodos avaliados para as bandas espectrais e os índices de vegetação, as imagens de satélite apresentaram melhor qualidade do processo. O EVI e o NDVI gerados a partir de imagens de satélites conseguiram expressar melhor a variação da cobertura vegetal do amendoim. O comportamento das bandas e os IVs gerados a partir das imagens do Planet, mostram qualidade para o monitoramento da cultura do amendoim. Já o UAV apresentou

sensibilidade para detectar a saturação das bandas, dificultando a visualização da variabilidade temporal.

Palavras-Chave: Sensoriamento remoto; Agricultura digital; Controle estatístico de processo; Índices de vegetação; Bandas espectrais.

Abstract:

Remote sensing tools have proven useful to assist in the monitoring and management of crop production. However, each remote sensing technology responds to crop variability differently. In this way, the objective was to compare sensors on airborne and orbital platforms, and to observe which one has the best quality to determine the behavior of the peanut crop variability. The experimental design followed the premises of the Statistical Quality Control (SPQ), with samples collected over time. The experimental area was composed of 30 sampling points spaced every 50 meters. Assessments of fresh and dry biomass, as well as pod maturation were performed at 75, 105, 120 and 125 days after sowing. Flights were performed with the aid of the Unmanned Aerial Vehicle (UAV) model DJI Matrice 100 with Micasense RedEdge-M camera and for satellite images data from the PlanetScope CubeSat platform sensor were used. It was verified that in all periods evaluated for spectral bands and vegetation indices, satellite images presented better process quality. The EVI and NDVI generated from satellite images were able to better express the peanut vegetation cover variation. The behavior of the bands and the IVs generated from the Planet images show quality for peanut crop monitoring. The UAV showed sensitivity to detect the saturation of the bands, making it difficult to visualize the temporal variability.

Keywords: Remote sensing; Digital agriculture; Statistical process control; Vegetation indices; Spectral bands.

Introdução

O monitoramento frequente das culturas agrícolas, visa o alto rendimento da lavoura com foco em gestões mais sustentáveis, procurando diminuir os impactos sociais, econômicos e ambientais (Areal et al., 2018). Dito isto, é importante o aumento da produção visando evitar, ao máximo, a escassez de alimento, com enfoque no desenvolvimento sustentável, em meio a mudanças climáticas e recursos restritos. Os avanços em tecnologia, computação e processamento de informações dos campos de

cultivo, com destaque para a Agricultura Digital, podem fornecer novas soluções neste cenário complexo e desafiador de produção (Shepherd et al., 2018).

Entre as diversas práticas de agricultura digital, que procuram obter maiores rendimentos econômicos e manejo mais sustentável, destaca-se o sensoriamento remoto (SR) com tecnologias importantes para o monitoramento das lavouras (Hassler e Baysal-Gurel 2019; Shafi et al. 2019). Técnicas de SR utilizadas a partir de sensores embarcados em plataformas aéreas, orbitais e terrestres, têm obtido sucesso em estimativas do desenvolvimento vegetativo, saúde da cultura e demonstrado precisão ao explicar a variabilidade espacial e temporal de diversos parâmetros agronômicos (Gilliot et al. 2020; Magney et al. 2017). As informações obtidas utilizando SR contribuem para tomada de decisão por parte do produtor, torna-se mais assertiva no que diz respeito ao uso eficiente dos recursos nas operações agrícolas.

Dentre as plataformas de SR, as tecnologias de satélites e os UAVs (Unmanned Aerial Vehicle), destacam-se em diversas aplicações agrícolas (Hassler e Baysal-Gurel 2019; Shafi et al., 2019). A escolha de qual plataforma deve ser utilizada para coleta dos dados, depende de quais informações deseja-se adquirir. Aspectos como tipo de sensor, resolução espaço-temporal e espectral, condições climáticas, correção radiométrica e atmosférica, são fatores que irão interferir na qualidade de leitura destas plataformas (Bansod et al. 2017), principalmente de imagens orbitais.

Embora a utilização do espectro eletromagnético no comprimento de onda do infravermelho próximo (NIR), o qual possui relação direta com a saúde da vegetação, esteja presente nas imagens obtidas por satélite de plataforma livres (Sentinel e Landsat), fatores como a baixa cobertura espaço-temporal e a dependência de imagens claras e sem nuvens, limitam o uso dos satélites em atividades agrícolas, principalmente, quando as informações precisam ser adquiridas em curto espaço de tempo (Inoue et al., 2012 ; Launay e Guerif, 2005). Por outro lado, constelações de satélites constituídas por nano satélites têm ganhado espaço no cenário agrícola. Este tipo de serviço entrega imagens diárias (duas imagens da mesma área por dia) com alta resolução espacial (Planet Team, 2017) e imagens compostas pelas bandas BGR e NIR (Dash e Ogutu, 2016 , Jain et al., 2016), o que permite melhoria no monitoramento das lavouras agrícolas devido ao aumento da frequência de revisita e da resolução espacial em comprimentos de onda BGR e NIR (Dash e Ogutu, 2016 , Jain et al., 2016).

Apesar das vantagens dos nano satélites em relação às demais plataformas orbitais, estes ainda estão sujeitos a interferências de perturbações atmosféricas, como

nuvens densas. Assim, uma alternativa às dificuldades presentes no sensoriamento orbital é a utilização de UAVs, os quais apresentam vantagens como alta resolução espacial e, especialmente, imagens sem perturbações atmosféricas (Rasmussen et al., 2020). Mesmo que os UAVs apresentem vantagens frente a aplicação dos satélites, a coleta de dados aérea ainda se mostra um desafio. A baixa autonomia de voo, com a necessidade de métodos para processamento das imagens complexos e caros, são aspectos a se melhorar. Embora existam fatores que possam afetar o uso desta plataforma, os UAVs, demonstram amplo potencial para monitorar a produtividade da soja (Zhao et al., 2017), índice de área foliar do algodão (Tian et al., 2016), indicadores nutricionais de N (Swain et al., 2007) e biomassa (Bendig et al., 2015).

Independente da plataforma utilizada para aquisição das imagens, a combinação das bandas espectrais para gerar Índices de Vegetação (IV) é o esperado para o monitoramento temporal e espacial das culturas. O Índice de Vegetação da Diferença Normalizada (NDVI) é sem dúvidas o IV mais utilizado no monitoramento da vegetação (Loranty et al., 2018). O NDVI captura o contraste na refletância entre os comprimentos de onda do vermelho e do infravermelho (NIR) e foi desenvolvido pela primeira vez para estimar a biomassa da vegetação (Rouse, 1974). Entretanto, a variabilidade espaço-temporal encontrada quando se utiliza IVs é atualmente estudada por meio de estatística descritiva, em associação com mapas interpolados. Estudar fatores de variabilidade espaço-temporal dos IVs por meio de métodos estatísticos como Controle Estatístico de Qualidade (CEQ) pode ser extremamente relevante para aferir o estado fisiológico e fenológico da planta, a fim de compreender melhor o seu desenvolvimento.

Apesar de ser uma abordagem nova no contexto de agricultura de precisão, o CEQ, tem apresentado resultados satisfatórios no monitoramento da qualidade de processos agrícolas (Zerbato et al., 2017; Santos et al., 2018; Tavares et al., 2018), ajudando a identificar as causas da variabilidade, padrões e erros ao longo do tempo, tornando possível a sua correção. Para verificar o desempenho das operações agrícolas, deve-se levar em consideração fatores críticos que são difíceis de identificar. Logo, ferramentas para verificar a qualidade das operações são determinantes para o sucesso dos sistemas produtivos, principalmente, por estes apresentarem elevada variabilidade devido à diversas condições desfavoráveis (Paulini et al., 2009; Zerbato et al., 2014).

Assim, acredita-se que este modelo estatístico, que visa principalmente melhorar a qualidade das operações com a redução da variabilidade, aplicado ao sensoriamento remoto ajudará a avaliar o comportamento espectral da cultura do amendoim a partir dos

IVs gerados em diferentes plataformas. Desta forma, seria possível identificar qual das plataformas do SR, apresenta melhor qualidade e estabilidade dos dados por meio de análise espaço-temporal na cultura do amendoim.

Desta forma, objetivou-se avaliar a qualidade dos dados gerados a partir dos sensores embarcados em UAV e Satélite, utilizando como ferramenta o controle estatístico de qualidade para analisar quatro bandas espectrais e quatro índices de vegetação, correlacionando-os com parâmetros biofísicos da cultura do amendoim.

Material e métodos

Área de estudo

O experimento foi conduzido em talhão comercial na safra do ano 2019/20 no município de Dumont – SP (Figura 1). em área de reforma de canavial e se encontrava em sistema de meiosi. A cultivar utilizada foi a IAC OL3 tipo Runner com espaçamento entre linhas de 0.9 m. A semeadura ocorreu no dia 2 de novembro de 2019, com colheita no dia 5 de março de 2020. O clima da região é classificado como Aw, tropical com inverno seco, de acordo com a classificação climática de Köppen (Alvares et al., 2013).

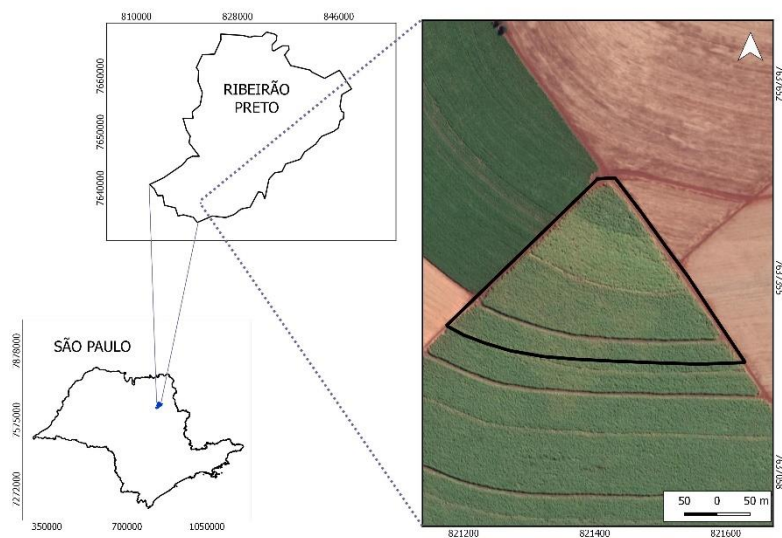


Figura 1. Localização da área experimental. EPSG:32723 - WGS 84 / UTM zone 23S.

Avaliações em campo

O delineamento experimental seguiu as premissas do controle estatístico de qualidade (CEQ), com as amostras coletadas ao longo do tempo. A área experimental foi composta por 30 pontos amostrais espaçados entre si a cada 50 metros, em área total de

8 ha. O espaçamento entre pontos foi definido de modo a atingir a quantidade ideal de amostragem segundo as premissas do CEP. Foram realizadas avaliações de biomassa fresca e seca, bem como a maturação das vagens aos 75, 105, 120 e 125 dias após a semeadura (DAS). Estas datas foram escolhidas a partir dos estádios de maturação, sendo definidas duas datas no início e duas no final. Todas as avaliações foram realizadas visando monitorar o comportamento da variabilidade espaço-temporal do amendoim.

A biomassa fresca (“*in natura*”) da parte aérea foi coletada com o auxílio de uma armação com área de 0,25 m² (0,5 x 0,5 m), cortando as plantas rente ao solo. Em seguida, no laboratório de máquinas e mecanização agrícola (LAMMA) as amostras foram pesadas para registrar a massa úmida, e posteriormente, estas foram colocadas em estufa com circulação na temperatura de 65°C por 72 h (Gobbi et al., 2009) para a obtenção da massa seca. Por fim, as amostras secas tiveram suas massas avaliadas por meio de uma balança semi-analítica (modelo BL 3200H), com precisão de 0.001g (gramas). A biomassa foi reportada neste estudo para ajudar a identificar qual o melhor sensor sob a óptica da variabilidade.

Para a análise de maturação utilizou-se o método *Peanut Maturity Index* (PMI), que calcula a porcentagem de vagens maduras para cada amostra (Rowland et al. 2006). Foram retiradas todas as vagens das plantas que continham na amostra (5 plantas por ponto) obtendo em média 150 a 250 vagens para análise de maturação em cada ponto amostral. Em seguida, todas as vagens foram submetidas ao processo de remoção do exocarpo com o auxílio de lavadora de alta pressão. As vagens foram dispostas sobre o quadro de classificação de maturação (Hull Scrape), que determina a maturação do amendoim a partir das cores apresentadas pelas vagens (Williams e Drexler, 1981).

Aquisição de imagens drone

Para as avaliações foram realizados voos com o auxílio do UAV modelo DJI Matrice 100 (Shenzhen, China), com câmera Micasense RedEdge-M (MicaSense, RedEdge, USA) que captura imagens em 5 bandas espectrais, Azul (465-485), Verde (550-570 nm), Vermelho (658-678 nm), Red Edge (712-722 nm) e Infravermelho próximo (820-860 nm). Antes de cada voo foi realizada a captura de imagens do painel de calibração radiométrica, as quais foram utilizadas para correção das imagens. Para os pontos de controle, foram colocados alvos no formato de “x” materializados com cal em cada vértice da área. Para identificar os pontos de coletas nas imagens, utilizou-se o mesmo princípio de marcação com cal nos pontos amostrais coletados.

Todos os voos foram efetuados com plano de voo no aplicativo GSPro, nas mesmas datas em que se realizou as avaliações da cultura em campo. Os voos foram feitos entre dez da manhã e meio dia com altitudes de 90 m e sobreposição lateral e frontal de 90%. Para esta altura de voo a resolução espacial da câmera foi de 7,96 cm. Devido a indisponibilidade de imagens no mesmo dia dos voos realizados, considerou-se 3 dias para mais ou para menos na escolha das imagens para efeito de comparação entre as duas plataformas.

Após cada voo as imagens foram processadas no software Pix4D (Pix4D SA, Lausanne, Suíça), gerando os ortomosaicos com correção radiométrica das imagens. Após criar os ortomosaicos, o software livre Qgis (QGIS, Chicago, IL, EUA), foi utilizado para identificar os pixels referente ao solo para remoção nas imagens por meio de classificação não supervisionada (método k-means), exclusivamente para as imagens do UAV, para evitar que a reflectância do solo influenciasse na leitura do alvo de interesse (plantas). Criou-se um buffer de 1 m a partir dos pontos de coleta, de modo, a abranger o maior número de pixel. Posteriormente, o valor médio da refletância de cada ponto amostral foi extraído. Vale ressaltar que para este trabalho não foi utilizada a banda da borda do vermelho (RedEdge) para padronizar as bandas espectrais utilizadas para calcular os IVs das duas plataformas.

Aquisição das imagens PlanetScope

Para as imagens de satélite foram utilizados dados do sensor da plataforma PlanetScope CubeSat. O Planet é uma constelação de satélites que compõe diferentes tipos de satélites com alta resolução. Atualmente, o PlanetScope possui 148 satélites em órbita, os quais possuem capacidade de coletar imagens diariamente em qualquer lugar do planeta. A resolução das imagens baixadas para este estudo foram de 3 m e as 4 bandas disponibilizadas pelo satélite foram utilizadas (BGR + NIR) com larguras nominais de 455-515 nm no Azul, 500-590 nm no Verde, 590-670 nm no vermelho e 780-860 para o NIR (Planet Team, 2019).

Para a correção das imagens, o PlanetScope disponibilizou o produto Surface Reflectance (SR). Este produto garante consistência em condições atmosféricas localizadas, que minimizam a incerteza na resposta espectral temporal e espacial. O SR está disponível para todas as cenas ortorretificadas. O produto SR é fornecido como uma imagem GeoTIFF de 16 bits com valores de refletância dimensionados em 10.000. A correção das imagens é determinada a partir da refletância do topo da atmosfera (TOA),

e é calculada a partir dos coeficientes fornecidos com o produto Planet Radiance. O cálculo de SR é uma operação pixel a pixel usando tabelas de pesquisa (LUTs) que foram geradas usando o código de transferência radiativa 6SV2.1. Os LUTs mapeiam a refletância no topo da atmosfera (TOA) para refletância de fundo da atmosfera (BOA) para todas as combinações faixas selecionadas. Um conjunto separado de LUTs é usado para cada tipo de sensor do satélite usando a resposta individual do espectro (Planet Team, 2021).

Índices de vegetação

Além das bandas BGR + NIR, quatro índices de vegetação (Tabela 1) foram avaliados e correlacionados com os parâmetros de biomassa fresca e seca e o índice de maturação do amendoim (NDVI, GNDVI, MNLI e EVI). Estes IVs foram escolhidos por contemplarem as bandas avaliadas para as duas plataformas e por serem usuais em diversos trabalhos que avaliam o comportamento espectral da vegetação (Skakun et al., 2021; Peng et al., 2021; Santos et al., 2021). A figura 2 demonstra todo processamento das imagens das plataformas até a geração dos índices de vegetação.

Tabela 1. Índices de vegetação (IV) utilizados para o drone e satélite.

IV *	Equação	Referência
NDVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Rouse et al. (1974)
GNDVI	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson e Merzlyak (1996)
MNLI	$(\text{NIR}^2 - \text{Red}) (1 + \text{L}) / (\text{NIR}^2 + \text{Red} + \text{L})$ **	Gong et al. (2003)
EVI	$2,5 * (\text{NIR} - \text{Red}) / (\text{L} + \text{NIR} + \text{C1 Red} - \text{C2Blue})$	Justice et al. (1998)

NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; MNLI: modified non-linear index; EVI: Enhanced Vegetation Index; NIR: infravermelho próximo; Red: vermelho; Green: verde; Blue: azul **L = 0.5; C1 = 6; C2 = 7,5.

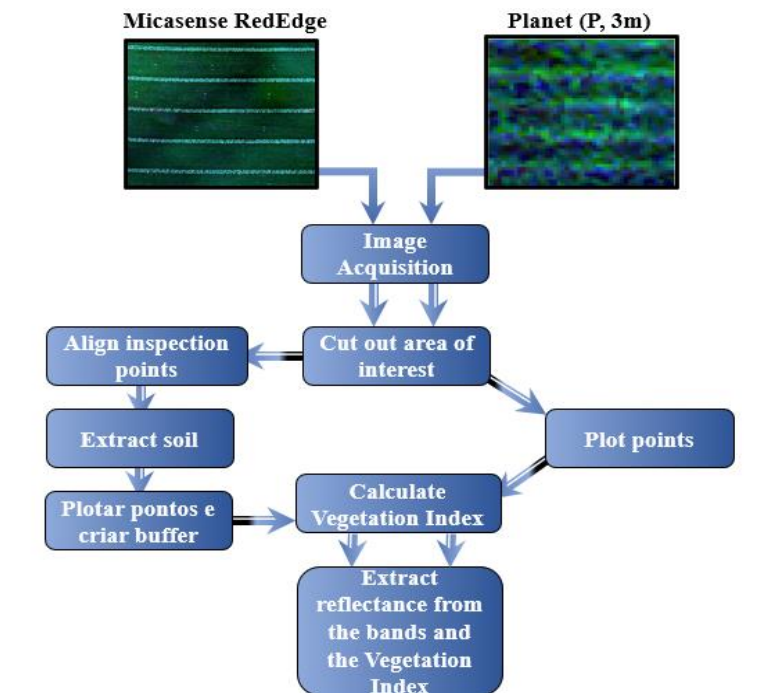


Figura 2. Esquema representativo dos passos adotados para extração da reflectância em cada banda espectral e obtenção dos índices de vegetação para os sensores de drone e satélite.

Análises estatísticas dos dados

Realizou-se análise descritiva para as bandas espectrais e os índices de vegetação para verificar o comportamento dos dados. A média, desvio padrão e o coeficiente de variação foram calculados com o auxílio do Minitab[®].

Para verificar a qualidade de leitura da reflectância e dos índices de vegetação com os dois sensores, analisou-se os indicadores por meio do Controle Estatístico de Qualidade, utilizando as cartas de controle de valores individuais que é uma das ferramentas do Controle Estatístico de Processo (CEP), que permitiu o monitoramento temporal e espacial dos dados. O modelo de CEP selecionado foi o Individual de Amplitude Móvel (I-MR: Individual-Moving Range) que contém dois gráficos: o superior, correspondendo aos valores individuais amostrados em cada ponto e o inferior, obtido pela amplitude calculada entre duas observações sucessivas conforme Eq. (1) e (2)

$$UCL = \bar{X} + 3\sigma \quad (1)$$

$$LCL = \bar{X} - 3\sigma \quad (2)$$

Em que UCL é o limite superior de controle; \bar{x} é a média geral da variável; σ é desvio padrão; e LCL é o limite inferior de controle.

Além disso, neste trabalho também foi realizada a análise de correlação a partir da rede de correlação entre os indicadores de qualidade (bandas espectrais, índices de vegetação, biomassa fresca e seca e maturação). Correlações positivas são destacadas em verde e as negativas são representadas em vermelho. A espessura da linha é proporcional à correlação e indica magnitude. Essas análises foram utilizadas visando verificar a inter-relação entre as bandas espectrais e os índices de vegetação sobre variáveis biofísicas (índice de maturação, biomassa fresca e seca) da cultura.

Resultados

Análise descritiva

Na Tabela 2 constata-se que as bandas espectrais demonstram valores de leituras distintos entre as plataformas (UAV e satélite) ao longo do tempo, mas, no entanto, observa-se que as bandas do Blue e NIR apresentaram, ao 105 DAS, valores absolutos de média semelhantes entre as plataformas. Já para a banda do Green, aos 120 e 125 DAS os valores absolutos em ambas as plataformas foram semelhantes entre si e entre UAV e satélite. Constatou-se picos dos valores médios de reflectância para a banda do Red, aos 105 e 120 DAS, para o UAV e satélite, respectivamente. Para a banda do Blue e do Green o maior nível de refletância foi observado aos 105 DAS e para o NIR aos 120 DAS.

Tabela 2. Parâmetros da estatística descritiva para as bandas espectrais e índice de vegetação (IV), obtidos por sensoriamento remoto orbital e aéreo, aos 75, 105, 120 e 125 dias após a semeadura (DAS) de amendoim.

Bandas/IV	75		105		120		125	
	UAV	Satélite	UAV	Satélite	UAV	Satélite	UAV	Satélite
Red	0,019	0,027	0,028	0,039	0,019	0,050	0,018	0,045
Green	0,050	0,039	0,089	0,066	0,053	0,054	0,052	0,049
Blue	0,020	0,025	0,036	0,037	0,021	0,031	0,020	0,032
NIR	0,706	0,564	0,602	0,583	0,787	0,589	0,785	0,428
EVI	1,036	0,872	0,954	0,881	1,097	0,814	1,097	0,656
GNDVI	0,869	0,871	0,741	0,796	0,873	0,832	0,875	0,796

MNLI	0,715	0,515	0,562	0,513	0,787	0,496	0,786	0,282
NDVI	0,947	0,907	0,910	0,874	0,953	0,843	0,954	0,809
---- CV (%) ----								
Red	7,55	5,46	13,77	3,22	6,97	2,76	6,47	3,86
Green	5,54	2,30	11,19	1,40	6,49	2,22	6,57	2,96
Blue	5,81	4,49	11,08	2,60	5,60	5,36	5,71	2,55
NIR	6,91	2,45	5,90	1,78	8,53	1,58	8,65	2,33
EVI	4,84	2,13	4,18	1,54	4,76	1,44	4,82	1,72
GNDVI	0,70	0,57	2,58	0,45	0,69	0,55	0,67	0,56
MNLI	8,39	3,89	7,32	2,71	8,03	2,75	8,16	4,27
NDVI	0,44	0,68	1,16	0,50	0,35	0,62	0,31	0,67

NDVI: índice de vegetação da diferença normalizada; GNDVI: verde do índice de vegetação da diferença normalizada; MNLI: índice modificado não-linear; EVI: índice de vegetação melhorado; NIR: infravermelho próximo;

Assim como as bandas espectrais, os valores dos índices de vegetação apresentaram distinção nos valores das médias para a plataforma orbital e aérea. É importante destacar a diferença do comportamento dos índices ao 125 DAS, no qual demonstram redução dos valores dos IVs gerados pelo satélite, enquanto o UAV, não apresentou alteração para esta data (Tabela 2). Tal fato ocorreu devido à queda na refletância do NIR no satélite, banda comum para todos os índices. As médias demonstram indicativo de saturação para a plataforma aérea nas bandas do visível (RGB), o que o influenciou de forma negativa nos IVs gerados, os quais apresentam indícios de saturação, dificultando o monitoramento da variabilidade ao longo do tempo.

Variabilidade das bandas espectrais e IVs


Foi verificado que em todos os períodos avaliados para as bandas espectrais e os índices de vegetação, as imagens de satélite apresentaram melhor qualidade do processo, por ter menor variabilidade (Figura 1).

Pelas cartas de controle (Figura 1 e 2) observa-se que a utilização de UAV proporcionou alta variabilidade no processo na segunda coleta (105DAS) em todas as bandas (Red, Green, Blue e NIR). Esta variabilidade é representada pelo maior distanciamento entre o limite superior e inferior de controle e comportamento crescente nas médias para esta data, exceto o NIR que apresentou decréscimo na média (Tabela 2). A alta variabilidade e os pontos fora de controle para esta mesma data, podem ser

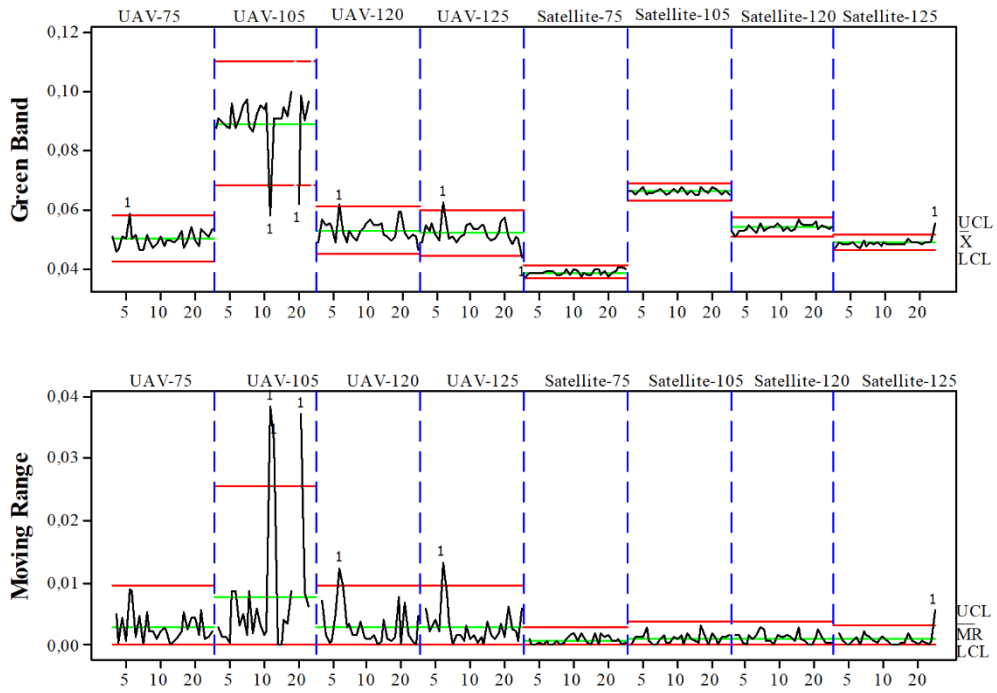
atribuídos à elevada quantidade de nuvens presentes no momento da aquisição das imagens do UAV, o que prejudica a qualidade do processo devido as sombras nas imagens provocadas pelas nuvens. A influência negativa das nuvens pode ser confirmada na Tabela 2 com o CV e o desvio padrão apresentando valores elevados para o UAV aos 105 DAS, quando comparados com demais datas.

É perceptível pontos fora dos limites de controle em todas as leituras para o drone, enquanto que para o satélite o processo mostrou-se instável apenas na última leitura (125DAS) para as bandas do visível. Já no NIR, observou-se pontos fora de controle em todos os períodos avaliados. No entanto, o infravermelho próximo, do satélite, apresentou a melhor qualidade devido à baixa variabilidade do processo ao longo do tempo (Figura 3D).


A)



B)



C)



D)




Figura 3. Análise da qualidade de leitura das bandas espectrais Blue (A), Green (B), Red (C) e Nir (D) utilizando imagens de UAV e satélite de alta resolução por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

UCL: Limite Superior de Controle, LCL: Limite Inferior de Controle, \bar{x} média, MR: Amplitude móvel. ($\alpha = 0.05$).

Tratando-se das leituras com o satélite, os resultados mostram que a reflectância das plantas do amendoim tendem a aumentar em todas as bandas, e ao passo que quando aproxima-se da colheita é observada a redução na reflectância do Red, do Green e do Nir, o que evidencia a variabilidade ao longo do tempo. Contrapondo ao satélite, o UAV apresentou menor variabilidade temporal para todas as bandas, excetuando-se os 105 DAS.

Em relação à qualidade de leitura do UAV x satélite, o comportamento das bandas espectrais para a plataforma orbital apresentou menores níveis de variabilidade, o que caracteriza melhor qualidade do processo em todas as avaliações. No entanto, ao considerar a variabilidade das plantas de amendoim, as duas plataformas mostraram valores no gráfico de amplitude móvel semelhantes para as bandas do Red e Blue.


Para os índices de vegetação (IV) o comportamento da plataforma aérea seguiu os mesmos padrões das bandas espectrais para a segunda leitura (105 DAS), no qual foi possível observar nas cartas de amplitude móvel a discrepância dos índices na variabilidade do processo para esta data (Figura 4). Ao avaliar a variabilidade dos IVs aos

75 e 105 DAS, observa-se aumento de: 76,47; 74,25; 37,00 e 30,00 % para os IVs NDVI, GNDVI, EVI e MNLI, respectivamente. De todo modo, os resultados obtidos pelo UAV quando comparados com o satélite, evidenciaram maior amplitude de variação para todos os índices, exceto o NDVI. Tal característica pode ter sido influenciada por fatores determinantes, que levaram à ocorrência de pontos fora de controle.

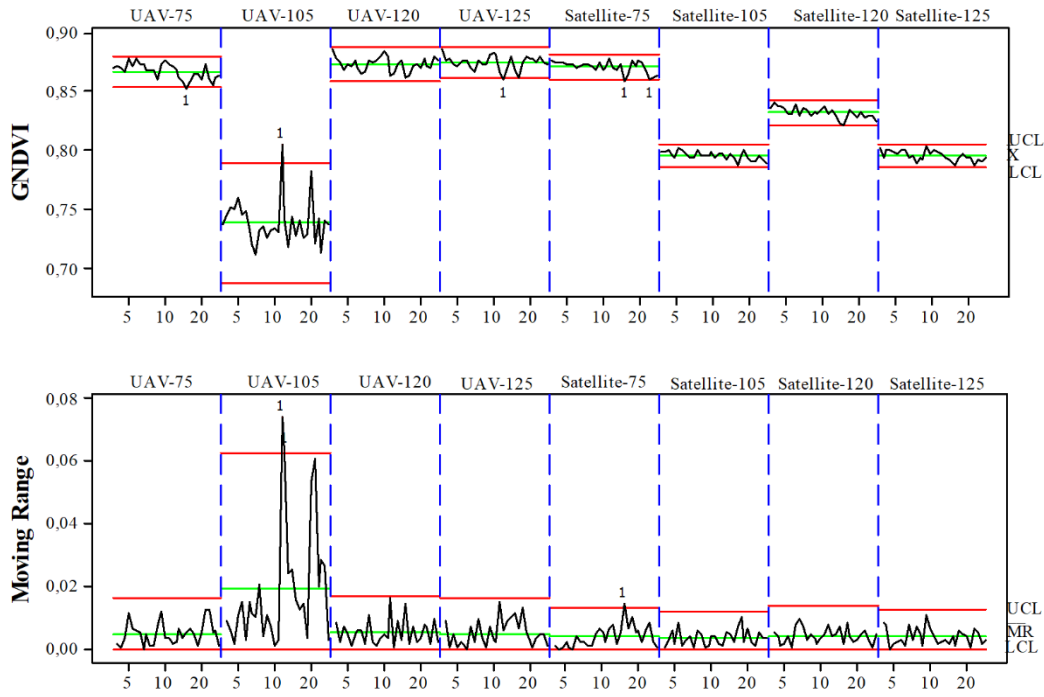
Os IVs do satélite apresentaram melhor qualidade do processo por ter menor variabilidade (Figura 4). Os pontos fora de controle para as duas plataformas, podem ser explicados por causas especiais que afetam a atuação das bandas, provocadas pelos chamados fatores 6 Ms, como por exemplo, largura do dossel, geometria e pigmentos da folha, estágio de desenvolvimento, (matéria prima), nuvens (meio ambiente), calibrações (método).

Ainda avaliando os resultados obtidos pelas leituras do satélite, notou-se redução gradual do EVI e NDVI ao longo do tempo, com o NDVI detectando maior amplitude de variação e variabilidade temporal do amendoim no campo. Logo, esses dois índices foram os que conseguiram expressar melhor a variação da cobertura vegetal do amendoim que demonstrou diminuição da biomassa ao longo do tempo (Figura 1 do material suplementar). O desempenho desses índices corroboram com o comportamento das bandas que os compõe (Red e Nir) nos quais apresentaram resultados semelhantes em sua atuação (Figura 3A e 3D). Outro fator a destacar nos resultados obtidos é a diferença de valores dos IV encontrados, em que os valores do satélite foram mais baixos que o UAV. O MNLI apresentou sinais de saturação em todas as datas avaliadas exceto aos 125 DAS.


A)



B)



C)



D)




Figura 4. Análise da qualidade dos índices de vegetação utilizando UAV e satélite, EVI (A), GNDVI (B), MNLVI (C) e NDVI (D) por meio das cartas de controle individual e amplitude móvel ao longo do tempo

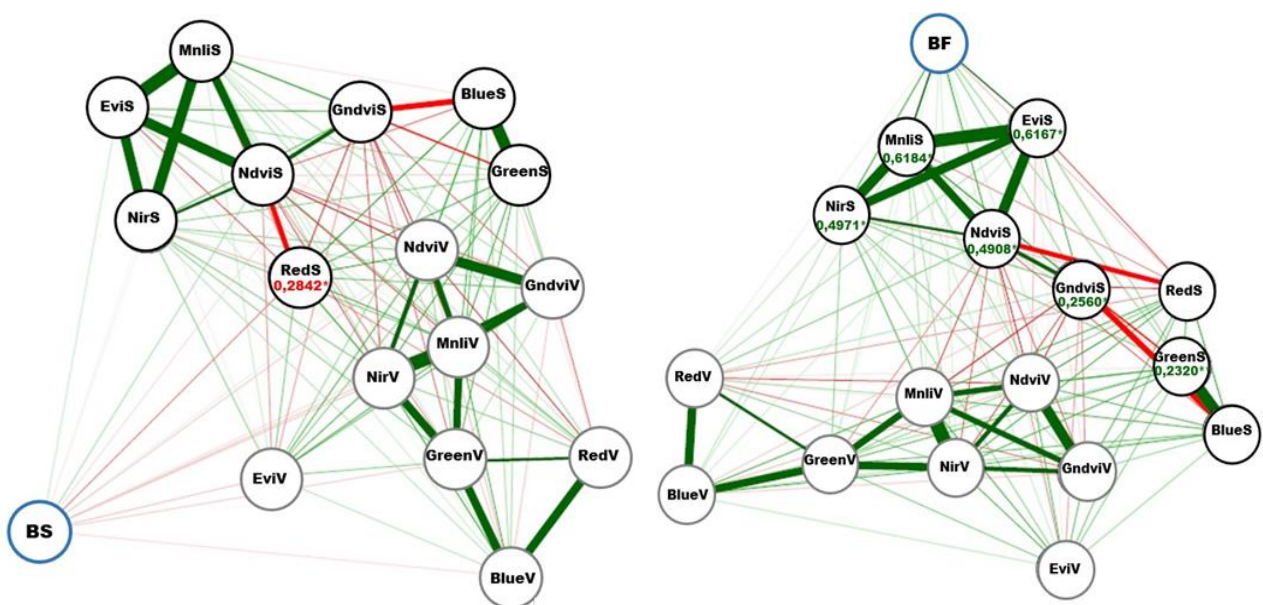
UCL: Limite Superior de Controle, LCL: Limite Inferior de Controle, \bar{x} média, MR: Amplitude móvel. ($\alpha = 0.05$).

Rede correlação

Realizou-se a rede correlação para confrontar os resultados observados nas cartas de controle de valores individuais e observar se o comportamento apresentado reflete na interação das bandas e dos IVs, com variáveis importantes da cultura do amendoim. É importante resaltar que o objetivo desta análise não é verificar em qual data as variáveis melhor se correlacionam, e sim, qual plataforma apresentar as melhores respostas com aparatos biosféricos da cultura. Embora a rede de correlação apresente a correlação entre todas as variáveis, neste trabalho levou-se em consideração apenas as correlações dos IVs e as bandas espectrais com as variáveis PMI, BF, BS.

De acordo com a classificação de Dancy e Reidy (2006) foram encontrados valores de correlação fraca ($r = 0,20$ até $0,39$) moderada ($r = 0,40$ até $0,69$) e fortes ($r = 0,70$ até $0,89$). Para a rede de correlação gerada a partir da matriz de correlação de Pearson, é observada correlação fraca e negativa entre a variável biomassa seca (BS) e a banda do Red para o satélite. Para a biomassa fresca notou-se correlação significativa para todos os índices do satélite e as bandas do Nir e Green.

Quanto a correlação entre PMI e IV (Figura 5), destacaram-se o EVI, MLI e NDVI ($-0,7517$, $-0,6557$ e $-0,8610$, respectivamente) utilizando imagens de satélite. Em contrapartida, o GNDVI foi o IV com a menor força de correlação ($-0,2011$). O UAV apresentou correlações significativas com o PMI somente para os IVs NDVI e GNDVI ($0,3814$ e $0,3224$, respectivamente).



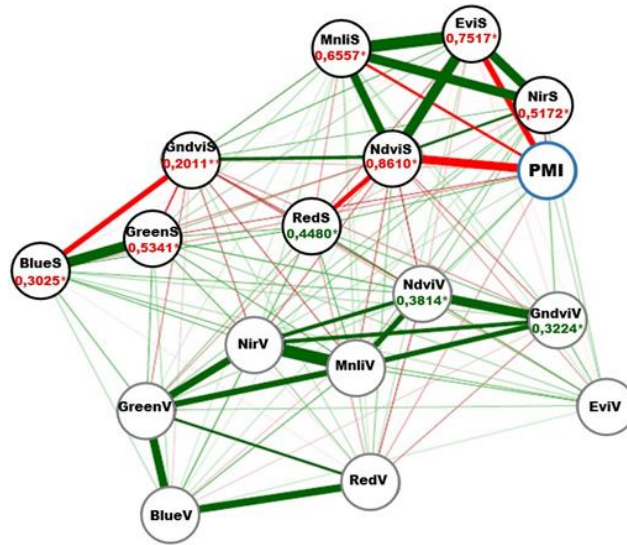


Figura 5. Redes de correlações entre Biomassa seca (BS), Biomassa fresca (BF), Índice de maturação (PMI) do amendoim, os Índices de vegetação (EVI, MNL, NDVI e GNDVI) e as bandas (Red, Green, Blue e NIR) para UAV (V) e Satélite (S).

**Significativo a $p < 0,01$; *Significativo a $p < 0,05$ para as variáveis (BS, BF e PMI); Linhas espessas indicam maior coeficiente de correlação; Linhas vermelhas correlação negativa; Linha verde correlação positiva. As correlações avaliadas foram: todos os índices com PMI, BS e BF; todas as bandas com PMI, BS e BF.

Discussão

Qualidade de leitura das plataformas

Diversos fatores influenciam na qualidade de aquisição das imagens de satélite e UAV, tais como, efeitos atmosféricos, ângulo de visão, resolução espaço-temporal e espectral e calibrações radiométricas (Svensgaard et al. 2019; Wang et al. 2019; Rasmussen et al. 2020). Essas diferenças foram constatadas por meio das cartas de controle (Figuras 1 e 2), principalmente no que tange a resolução espacial, em que é possível de se observar variações e diferenças entre as duas plataformas as quais influenciaram na qualidade do processo.

As inconsistências entre sensores, já que os satélites PlanetScope não são idênticos, era fator limitante para o uso dos CubeSat por apresentarem resposta espectral única (McCabe et al. 2017). As condições atmosféricas afetam a radiação captada pelos sensores, de modo a interferir na relação sinal/ruído (Sadeh et al. 2019). Desta forma, é fundamental realizar a correção da reflectância da vegetação em relação aos efeitos atmosféricos. Diante disto, neste estudo utilizou-se a ferramenta desenvolvida pela PlanetScope, Surface Reflectance (SR), que realiza a correção atmosférica (BOA e TOA) para solucionar os problemas de calibração e baixa relação sinal/ruído.

O principal desafio associado à plataforma aérea, que pode influenciar nos dados obtidos, é a calibração radiométrica (Rasmussen et al. 2020). O fator nuvem não interfere na aquisição das imagens caso a área apresente condições de sombreamento homogêneas no momento do voo. No entanto, as imagens do UAV sofreram interferência do sombreamento causado pelas nuvens, o que pode explicar os pontos fora de controle aos 105 DAS. Santos (2019), verificou qualidade similar em ambas as plataformas no monitoramento da vegetação do amendoim. Mas, no entanto, os autores sugerem maior confiabilidade para as análises com satélites, tendo em vista que, para o UAV fez-se necessário retirar parcelas da avaliação, devido à interferência do sombreamento das nuvens. O aumento da refletância nas bandas do visível aos 105 DAS, pode ter sido influenciado pela aplicação de defensivos, que apresentou manchas brancas nas folhas ocasionando aumento dos valores de refletância para as bandas RGB.

Resposta espectral para os sensores em UAV e satélite

A partir de imagens geradas pelas plataformas aéreas e orbitais é possível identificar o comportamento de refletância apresentados pelas culturas. Características como radiação, sensores, parâmetros da cultura e o tipo de solo, são combinações complexas que influenciam no comportamento espectral do dossel. Estas características, podem justificar o comportamento das bandas para o UAV, o qual apresentou saturação nas bandas visível e NIR. Devido as imagens do UAV não apresentarem influência do solo (solo foi retirado das imagens) e terem melhor resolução espacial, pode-se inferir que tais aspectos tenham sido preponderantes para a saturação das bandas, tendo em vista a alta densidade de biomassa apresentada pela cultura do amendoim. Índices que contem a banda do vermelho, tendem a saturar mais facilmente em áreas com maior porcentagem de biomassa, em razão da alta absorção dos pigmentos de clorofila captados pelos sensores (Baret e Guyot, 1991). Outro aspecto que pode contribuir para a saturação das bandas é o nível moderado ou alto de N nas folhas (Li et al., 2014a; Li et al., 2014b). A diferença existente entre a larguras das bandas dos sensores estudados podem explicar a saturação para o UAV, tendo em vista que este sensor dispõe de bandas estreitas, o que melhora o detalhamento do alvo tornando as medições espectrais mais precisas para detectar a influência da alta densidade das plantas.

Em termos de bandas espectrais para o Planet, o green e o NIR demonstraram melhor estabilidade para explicar a variabilidade da vegetação e apresentaram as melhores correlações com índice de maturação e biomassa fresca. Skakun et al., (2021)

observaram que as bandas do green e NIR, foram importantes para explicar a variabilidade da produção do milho e da soja utilizando imagens do Planet. A banda espectral do green, indica em diversos estudos, maior sensibilidade à concentração de clorofila e biomassa utilizando imagens de satélites, sobressaindo-se à banda do red no monitoramento da vegetação do milho, batata e trigo (Gitelson et al., 1996; Gitelson et al., 2003; Nguy Robertson et al., 2014; Vinã et al., 2011).

Índices de vegetação gerados pelo UAV e satélite

A resposta dos IVs gerados pelo sensor embarcado no UAV, foi altamente afetada pela alta densidade de biomassa do amendoim. Fatores como alta variabilidade na biomassa e Índice de Área Foliar (LAI), afetam a reflectância do dossel e podem causar saturação dos IVs no amendoim (Santos et al., 2021). Carneiro et al. (2020) estudando o comportamento de sensores proximais na cultura da soja, observaram que o aumento da biomassa nos estágios R4 e R6, apresentou saturação do NDVI. A busca pela redução do contraste da reflectância, em condições com alta densidade de biomassa, deve ser a saída para melhor uso da plataforma aérea em relação à saturação. Logo, índices de vegetação (por exemplo: WDRVI, NDRE, mNDSI) que permitam melhor caracterização das propriedades biofísicas da vegetação surgem como alternativa para reduzir a saturação (Gitelson, 2004; Cao et al., 2015, 2016 e 2017; Li et al., 2014)

Apesar de diversos trabalhos apresentarem resultados pouco satisfatórios com o uso do NDVI, principalmente por motivo da saturação, no presente estudo este IV gerado a partir das imagens de satélite, apresentou bons resultados para detectar a variabilidade temporal da lavoura, com correlação forte e moderada para as variáveis PMI e BF, respectivamente. Santos et al. (2021) em estudo utilizando satélite de alta resolução, observaram que o NDVI e o GNDVI não saturaram após o fechamento do dossel. No entanto, o GNDVI demonstrou menor sensibilidade para detectar as mudanças do dossel da cultura. Rowland et al. (2008), observaram o mesmo comportamento em estudo realizado com a cultura do amendoim.

O Índice de Vegetação Aprimorado (EVI) apresentou resultados satisfatórios para previsão da BF e PMI, principalmente por responder bem às variações estruturais do dossel da planta (Gao et al., 2000). O EVI foi desenvolvido para trabalhar em áreas com alta densidade de biomassa com fator de correção para influências atmosféricas que caracteriza este IV como ótima opção para as plataformas orbitais (referencia). O MNLi apresentou sinais de saturação e tal resultado pode ter sido influenciado devido ao ajuste

do solo que é feito para este IV. A correção do solo para o índice MNLI, visa minimizar o brilho do solo, e seu valor varia com base nas condições do dossel da cultura (Huete, 1988).

Conclusão

Este estudo avaliou a qualidade dos sensores embarcados em plataformas aérea e orbital para o monitoramento da cultura do amendoim. O desempenho apresentado pelo UAV e o satélite, demonstram a importância da avaliação dos diversos parâmetros que, influenciam na aquisição de imagens para o monitoramento agrícola.

Diante disto, o comportamento das bandas e os IVs gerados a partir das imagens do Planet, mostram qualidade para o monitoramento da cultura do amendoim. O UAV apresentou sensibilidade para detectar a saturação das bandas, dificultando a visualização da variabilidade temporal. Já o satélite, com base nas cartas de controle, evidenciou variabilidade espaço-temporal com melhor qualidade e não apresentou saturação para bandas e para os IVs, exceto o MNLI.

O NDVI, EVI, MNLI e o GNDVI indicaram potencial para estimativa de biomassa e índice de maturação da cultura com correlações forte, moderadas e fraca, respectivamente, para PMI, e moderada e fraca para BF.

É importante ressaltar que mais estudos com sensoriamento remoto são necessários para entender o comportamento da variabilidade do amendoim, tendo em vista a incipiência de trabalhos para a cultura, e principalmente, por apresentar características distintas em função das cultivares e condições climáticas, a fim de obter maiores informações para melhor aplicação das plataformas do SR.

Referências Bibliográficas

- Alvares, C. A., Stape, J. L., Sentelhas, P. C., de Gonçalves, J. L. M., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>.
- Areal, F. J., Jones, P. J., Mortimer, S. R., & Wilson, P. (2018). Measuring sustainable intensification: Combining composite indicators and efficiency analysis to account for positive externalities in cereal production. *Land use policy*, 75, 314-326. <https://doi.org/10.1016/j.landusepol.2018.04.001>

- Bansod, B., Singh, R., Thakur, R., & Singhal, G. (2017). Uma comparação entre a tecnologia de sensoriamento remoto baseada em satélite e drone para alcançar o desenvolvimento sustentável: uma revisão. *Journal of Agriculture and Environment for International Development*, 111, 383-407. <https://doi.org/10.12895/jaeid.20172.690>
- Baret, F., & Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote sensing of environment*, 35(2-3), 161-173. [https://doi.org/10.1016/0034-4257\(91\)90009-U](https://doi.org/10.1016/0034-4257(91)90009-U)
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., ... & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87. <https://doi.org/10.1016/j.jag.2015.02.012>
- Cao, Q., Miao, Y., Feng, G., Gao, X., Li, F., Liu, B., et al. (2015). Active canopy sensing of winter wheat nitrogen status: An evaluation of two sensor systems. *Computers and Electronics in Agriculture*, 112, 54–67. <https://doi.org/10.1016/j.compag.2014.08.012>.
- Cao, Q., Miao, Y., Feng, G., Gao, X., Liu, B., Liu, Y., et al. (2017). Improving nitrogen use efficiency with minimal environmental risks using an active canopy sensor in a wheat-maize cropping system. *Field Crops Research*, 214, 365–372. <https://doi.org/10.1016/j.fcr.2017.09.033>.
- Cao, Q., Miao, Y., Shen, J., Yu, W., Yuan, F., Cheng, S., et al. (2016). Improving in-season estimation of rice yield potential and responsiveness to topdressing nitrogen application with Crop Circle active crop canopy sensor. *Precision Agriculture*, 17(2), 136–154. <https://doi.org/10.1007/s11119-015-9412-y>.
- Carneiro, F.M., Furlani, C.E.A., Zerbato, C., Menezes, P.C., Gírio, L.A.S., Oliveira, M.F. (2020) Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. *Precision Agriculture*, 21, 979–1007 <https://doi.org/10.1007/s11119-019-09704-3>
- Dancey, C., & Reidy, J. (2006). *Estatística Sem Matemática para Psicologia: Usando SPSS para Windows* (3rd ed., p. 608). Artmed: Porto Alegre.
- Dash, J., & Ogutu, B. O. (2016). Recent advances in space-borne optical remote sensing systems for monitoring global terrestrial ecosystems. *Progress in Physical Geography*, 40(2), 322-351. <https://doi.org/10.1177/0309133316639403>

dos Santos, A. F., da Silva, R. P., Zerbato, C., de Menezes, P. C., Kazama, E. H., Paixão, C. S., et al. (2018). Use of real-time extend GNSS for planting and inverting peanuts. *Precision Agriculture*. <https://doi.org/10.1007/s11119-018-9616-z>.

dos Santos, A.F., Corrêa, L.N., Lacerda, L.N. et al. High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agric* (2021). <https://doi.org/10.1007/s11119-021-09791-1>

Embrapa—Empresa Brasileira de Pesquisa Agropecuária. (2013). *Sistema Brasileiro de Classificação de Solos* (3rd ed. Rev. ampl., p. 353). Brasília, DF: Empresa Brasileira de Pesquisa Agropecuária (Embrapa).

Gao, X., Huete, A. R., Ni, W., & Miura, T. (2000). Optical–biophysical relationships of vegetation spectra without background contamination. *Remote sensing of environment*, 74(3), 609–620. [https://doi.org/10.1016/S0034-4257\(00\)00150-4](https://doi.org/10.1016/S0034-4257(00)00150-4)

Gilliot, J.M., Michelin, J., Hadjard, D. (2020). An accurate method for predicting spatial variability of maize yield from UAV-based plant height estimation: a tool for monitoring agronomic field experiments. *PrecisionAgriculture* <https://doi.org/10.1007/s11119-020-09764-w>

Gitelson, A. A. (2004). Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology*, 161, 165–173.

Gitelson, A. A., Viña, A., Arkebauer, T. J., Rundquist, D. C., Keydan, G., & Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical research letters*, 30(5).

Gitelson, Anatoly A.; Kaufman, Yoram J.; Merzlyak, Mark N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, v. 58, n. 3, p. 289-298, [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

Gobbi, K. F., Garcia, R., Garcez Neto, A. F., Pereira, O. G., Ventrella, M. C., & Rocha, G. C. (2009). Características morfológicas, estruturais e produtividade do capim-braquiária e do amendoim forrageiro submetidos ao sombreamento. *Revista Brasileira de Zootecnia*, 38(9), 1645–1654. <https://doi.org/10.1590/S1516-35982009000900002>.

Hassler, S.C, & Baysal-Gurel, F. (2019). Tecnologia e aplicações de sistemas de aeronaves não tripuladas (UAS) na agricultura. *Agronomy*, 9, 618. <https://doi.org/ez87.periodicos.capes.gov.br/10.3390/agronomy9100618> .

Huete, Alfredo R.A. (1998) soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, v. 25, n. 3, p. 295-309, [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)

- Inoue, Y., Sakaiya, E., Zhu, Y., & Takahashi, W. (2012). Diagnostic mapping of canopy nitrogen content in rice based on hyperspectral measurements. *Remote Sensing of Environment*, 126, 210-221. <https://doi.org/10.1016/j.rse.2013.07.018>
- Jain, M., Srivastava, A. K., Joon, R. K., McDonald, A., Royal, K., Lisaius, M. C., & Lobell, D. B. (2016). Mapping smallholder wheat yields and sowing dates using micro-satellite data. *Remote sensing*, 8(10), 860. <https://doi.org/10.3390/rs8100860>
- Launay, M., & Guerif, M. (2005). Assimilating remote sensing data into a crop model to improve predictive performance for spatial applications. *Agriculture, ecosystems & environment*, 111(1-4), 321-339.
- Li, F., Miao, Y., Feng, G., Yuan, F., Yue, S., Gao, X., ... & Chen, X. (2014). Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. *Field Crops Research*, 157, 111-123. <https://doi.org/10.1016/j.fcr.2013.12.018>
- Li, Y., Zhou, Q., Zhou, J., Zhang, G., Chen, C., & Wang, J. (2014). Assimilating remote sensing information into a coupled hydrology-crop growth model to estimate regional maize yield in arid regions. *Ecological modelling*, 291, 15-27. <https://doi.org/10.1016/j.ecolmodel.2014.07.013>
- Loranty, M.M., Davydov, S.P., Kropp, H., Alexander, H.D., Mack, M.C., Natali, S.M., Zimov, N.S. (2018). Vegetation indices do not capture forest cover variation in upland siberian larch forests. *Remote Sens.* 10, 1686.
- Magney, T. S., Eitel, J. U., & Vierling, L. A. (2017). Mapping wheat nitrogen uptake from RapidEye vegetation indices. *Precision Agriculture*, 18(4), 429-451. <https://doi.org/10.1007/s11119-016-9463-8>
- McCabe, M. F., Aragon, B., Houborg, R., & Mascaro, J. (2017). CubeSats in hydrology: Ultrahigh-resolution insights into vegetation dynamics and terrestrial evaporation. *Water Resources Research*, 53(12), 10017-10024. <https://doi.org/10.1002/2017WR022240>
- Nguy-Robertson, A. L., Peng, Y., Gitelson, A. A., Arkebauer, T. J., Pimstein, A., Herrmann, I., ... & Bonfil, D. J. (2014). Estimating green LAI in four crops: Potential of determining optimal spectral bands for a universal algorithm. *Agricultural and forest meteorology*, 192, 140-148. <https://doi.org/10.1016/j.agrformet.2014.03.004>
- Paulini, D. G.; Milan, M.; Salvi, J. V. Qualidade total. Cultivar Máquinas, v.85, 2009.
- Peng et al., 2021; Peng, X.; Han, W.; Ao, J.; Wang, Y. Assimilation of LAI Derived from UAV Multispectral Data into the SAFY Model to Estimate Maize Yield. *Remote Sens.* 2021, 13, 1094. <https://doi.org/10.3390/rs13061094>

Planet Team. (2019). Planet Application Program Interface: In Space for Life on Earth. San Francisco, CA. <https://api.planet.com> Accessed 15 June 2020.

Planet. (2020). Planet Imagery Product Specification. https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf. Accessed 15 June 2020.

Rasmussen, J., Azim, S., Boldsen, S. K., Nitschke, T., Jensen, S. M., Nielsen, J., & Christensen, S. (2020). The challenge of reproducing remote sensing data from satellites and unmanned aerial vehicles (UAVs) in the context of management zones and precision agriculture. *Precision Agriculture*, 1-18. <https://doi.org/10.1007/s11119-020-09759-7>

Rouse, (1974) ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. *NASA special publication*, v. 351, n. 1974, p. 309, 1974.

Rowland, D. L., Sorensen, R. B., Butts, C. L., & Faircloth, W. H. (2006). Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33, 125–136. <https://doi.org/10.3146/0095->

Rowland, D. L., Sorensen, R. B., Butts, C. L., Faircloth, W. H., & Sullivan, D. G. (2008). Canopy characteristics and their ability to predict peanut maturity. *Peanut Science*, 35(1), 43–54. <https://doi.org/10.3146/PS06-052.1>.

Sadeh, Y., Zhu, X., Chenu, K., & Dunkerley, D. (2019). Sowing date detection at the field scale using CubeSats remote sensing. *Computers and electronics in agriculture*, 157, 568-580. <https://doi.org/10.1016/j.compag.2019.01.042>

Santos, A. F. D. (2019). Método não destrutivo para predição da maturação de amendoim (*arachis hypogaea* l.) utilizando sensoriamento remoto. Tese.

Shafi, U., Mumtaz, R., García-Nieto, J., Hassan, SA, Zaidi, SAR, & Iqbal, N. (2019). Técnicas e práticas de agricultura de precisão: das considerações às aplicações. *Sensors*, 19, 3796. <https://doi-org.ez87.periodicos.capes.gov.br/10.3390/s19173796> .

Shepherd, J.D., Bunting, P., Dymond, J.R. (2019) Operational Large-Scale Segmentation of Imagery Based on Iterative Elimination. *Remote Sens.* 11, 658. <https://doi.org/10.3390/rs11060658>

Skakun, S., Kalecinski, NI., Brown, MGL., Johnson, DM., Vermote, EF., Roger, J.-C.; Franch, B. (2021) Avaliando a variação de rendimento de milho e soja no campo a partir de imagens de satélite WorldView-3, Planet, Sentinel-2 e Landsat 8. *Remote Sens.* 13, 872. <https://doi.org/10.3390/rs13050872>

- Svensgaard, J., Jensen, S. M., Westergaard, J. C., Nielsen, J., Christensen, S., & Rasmussen, J. (2019). Can reproducible comparisons of cereal genotypes be generated in field experiments based on UAV imagery using RGB cameras? *European Journal of Agronomy*, 106, 49–57. <https://doi.org/10.1016/j.eja.2019.03.006>.
- Swain, K. C., Jayasuriya, H. W., & Salokhe, V. M. (2007). Low-altitude remote sensing with unmanned radio-controlled helicopter platforms: A potential substitution to satellite-based systems for precision agriculture adoption under farming conditions in developing countries. *Agricultural Engineering International: CIGR Journal*.
- Tavares, T. D. O., Borba, M. A. D. P., de Oliveira, B. R., da Silva, R. P., Voltarelli, M. A., & Ormond, A. T. S. (2018). Effect of soil management practices on the sweeping operation during coffee harvest. *Agronomy Journal*, 110(5), 1689–1696. <https://doi.org/10.2134/agronj2017.10.0598>.
- Team, P. (2017). Planet application program interface: In space for life on Earth. *San Francisco, CA, 2017*, 40.
- Tian, M., Ban, S., Chang, Q., You, M., Dan, L., Li, W., Wang, S. (2016) Use of hyperspectral images from UAV-based imaging spectroradiometer to estimate cotton leaf area index. *Trans. Chin. Soc. Agric. Eng.* 32, 102–108.
- Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468-3478. <https://doi.org/10.1016/j.rse.2011.08.010>
- Wang, K., Huggins, DR, & Tao, H. (2019). Mapeamento rápido da produção, proteína e absorção de nitrogênio do trigo de inverno usando sensoriamento remoto e proximal. *International Journal of Applied Earth Observation and Geoinformation*, 82 ,101921. <https://doi.org.ez87.periodicos.capes.gov.br/10.1016/j.jag.2019.101921> .
- Williams, E. J., & Drexler, J. S. (1981). A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2), 134–141. <https://doi.org/10.3146/i0095-3679-8-2-15>.
- Zerbato, C., Furlani, C. E. A., Ormond, A. T. S., da Silva Gírio, L. A., Carneiro, F. M., & da Silva, R. P. (2017). Statistical process control applied to mechanized peanut sowing as a function of soil texture. *PLoS ONE*, 12(7), e0180399. <https://doi.org/10.6084/m9.figshare.4204665>.

Zerbato, C.; Furlani, C. E. A.; Voltarelli, M. A.; Bertonha, R. S.; Silva, R. P. Quality control to seeding systems and densities in peanut crop. *Australian Journal of Crop Science*, v. 8, n. 6, p. 992-998, 2014.

Zhao, L., Yang, J., Li, P., Shi, L., & Zhang, L. (2017). Characterizing lodging damage in wheat and canola using Radarsat-2 polarimetric SAR data. *Remote Sensing Letters*, 8(7), 667-675. <https://doi.org/10.1080/2150704X.20>

CAPÍTULO 3: REDES NEURAIS ARTIFICIAIS APLICADAS AO SENSORIAMENTO REMOTO: NOVO MÉTODO DE PREDIÇÃO DA MATURAÇÃO DO AMENDOIM

Resumo:

Técnicas de sensoriamento remoto e o aprendizado de máquinas são ferramentas importantes para o setor agropecuário, e podem trazer melhorias significativas no gerenciamento agrícola. Diante disto, objetivou-se criar um método de predição da maturação do amendoim a partir de imagens de veículo aéreo não tripulado (UAV) e do satélite PlanetScope, utilizando redes neurais artificiais (RNA). O experimento foi conduzido em talhão comercial na safra do ano 2019/20 no município de Dumont – SP. A coleta dos dados do UAV foi obtida através da câmera multiespectral Micasense RedEdge. Dois modelos de RNA's (RBF e MLP) foram utilizados para prever o índice de maturação do amendoim, com as bandas espectrais disponíveis por cada sensor. Para os índices de vegetação (IV's), 7 foram calculados para o UAV e 6 para o satélite, os quais foram utilizados na camada de entrada. Para validação dos modelos, foram utilizados 20% dos dados e para treinamento 80%. o NDRE foi capaz de prever o PMI com precisão (0.90 e 0.88) e acurácia (0.06 e 0.06) para as redes MLP e RBF respectivamente. O NDVI do satélite também foi capaz de prever a maturação do amendoim com boa acurácia e precisão. A avaliação de desempenho dos modelos indica que as redes RBF e MLP são semelhantes para prever a maturação do amendoim. Conclui-se com este trabalho que o índice de maturação pode ser previsto utilizando imagens de satélite e UAV.

Palavras chaves: PlanetScope, Veículo aéreo não tripulado, Aprendizado de máquina, Perceptron Multicamadas, Função de base radial

Abstract:

Remote sensing techniques and machine learning are important tools for the agricultural sector, and can bring significant improvements in agricultural management. In view of this, the objective was to create a method to predict peanut maturity from unmanned aerial vehicle (UAV) and PlanetScope satellite images, using artificial neural networks (ANN). The experiment was conducted in a commercial field in the 2019/20 crop year in Dumont - SP. The UAV data collection was obtained through the Micasense RedEdge multispectral camera. Two ANN models (RBF and MLP) were used to predict the peanut maturity index, with the spectral bands available by each sensor. For the vegetation indices (IV's), 7 were calculated for the UAV and 6 for the satellite, which were used in the input layer. The NDRE was able to predict the PMI with accuracy (0.90 and 0.88) and precision (0.06 and 0.06) for the MLP and RBF networks respectively. Satellite NDVI was also able to predict peanut maturity with good acuity and accuracy. The performance evaluation of the models indicates that the RBF and MLP networks are similar for predicting peanut maturity. It is concluded from this work that the ripeness index can be predicted using satellite and UAV images.

Keywords: PlanetScope, Unmanned Aerial Vehicle, Machine Learning, Multilayer Perceptron, Radial Basis Function

Introdução

A Agricultura Digital surge em meio a grandes desafios e novas perspectivas que o agronegócio e a segurança alimentar enfrentam, como recursos limitados, preservação ambiental, redução de terras agricultáveis e crescente demanda de alimentos devido ao aumento populacional (West et al., 2014). No entanto, a agricultura digital pode fornecer soluções para mitigar esses problemas (Radoglou-Grammatikis et al., 2020). Há uma busca constante na agricultura pela geração de informações que facilitem a tomada de decisão e o gerenciamento de recursos, e em relação à esta necessidade, o sensoriamento remoto e o aprendizado de máquinas são tecnologias que podem apresentar grande disponibilidade de dados que podem ser transformados em informações importantes para auxiliar no monitoramento agrícola (Atzberger, 2013; Mulla , 2013; Kattenborn et al., 2020).

A alta produtividade e redução das perdas para a cultura do amendoim, dependem de informações precisas sobre o nível de maturação em que a lavoura se encontra para facilitar a tomada de decisão e maximizar a produção. A determinação do índice de maturação do amendoim e, conseqüentemente, o ponto ideal de arranquio, é sem dúvidas

um dos maiores desafios dentro do ciclo produtivo da cultura (Colvin et al., 2018). A colheita realizada em tempo inadequado (muito cedo ou muito tarde), pode reduzir a produção quantitativa e qualitativamente.

O método Hull-Scrape (Williams e Drexler, 1981) é o mais utilizado por pesquisadores e produtores, porém é trabalhoso e extremamente subjetivo, necessitando de amostragens significativas devido ao amendoim apresentar grande variabilidade no campo (Vellidis e Beasley, 2013; Ashapure et al., 2019). Este método leva em consideração amostras retiradas do campo, em que os níveis de maturação são classificados com base na coloração do mesocarpo. Nos últimos anos pesquisadores têm buscado por soluções alternativas para modernizar este método, tornando-o mais assertivo, reduzindo ao máximo o erro humano.

Pesquisas foram desenvolvidas com tecnologias digitais e de sensoriamento remoto para criar métodos preditivos para o índice de maturação do amendoim (PMI). No entanto, tais estudos não apresentaram validação dos métodos, demonstrando apenas a relação linear e o ajuste de modelos (Rowland et al., 2008; Santos et al., 2019; Santos et al., 2021). Li et al. (2021), criaram um software para coletar informações de amostras de amendoim (método destrutivo) para determinar o momento ideal de colheita de forma remota. O método, inovador, visa principalmente acabar com a subjetividade do avaliador, no entanto, os mesmos autores concluíram que é necessário para que o modelo atinja níveis melhores de precisão, maior quantidade de amostragens, o que demonstra que além de ser um método destrutivo é bastante trabalhoso.

Visando desenvolver um método analítico eficiente, preciso, inovador e não destrutivo, para determinar o PMI do amendoim, pesquisas envolvendo tecnologias de Redes Neurais Artificiais (RNA's) e Sensoriamento Remoto (SR) geram grande expectativas para o setor. O uso do SR oferece alternativas com sensores embarcados em satélites de alta resolução e UAV (Unmanned Aerial Vehicle), fornecendo grande quantidade de dados com a utilização de técnicas (índices de vegetação) que são sensíveis às propriedades fisiológicas e morfológicas da vegetação (Kattenborn. et al., 2021). Pelo comportamento da vegetação ser influenciado por diversos fatores, é conveniente o uso de técnicas robustas com capacidade de aprender padrões complexos e não lineares (por exemplo: RNA's) para predição de parâmetros da vegetação associados ao uso do sensoriamento remoto (Oliveira et al., 2021).

Pesquisas recentes com predição de produtividade, biomassa, parâmetros biofísicos e detecção de plantas daninhas, demonstram o potencial uso dos modelos de

RNA's combinados com dados gerados a partir de sensoriamento remoto (Khan et al., 2020; Xie et al., 2019; Hasan et al., 2021; Ma et al 2021; Oliveira et al., 2021). Logo, o uso de plataformas de SR com o auxílio de RNA's podem criar modelos capazes de prever o PMI do amendoim de forma precisa e acurada. Até onde sabemos, não há nenhum estudo com métodos que envolvam RNA's com uso de imagens aérea e orbital para prever a maturação do amendoim.

Diante disto, os objetivos deste estudo são: 1) avaliar o potencial dos sensores de UAV e satélite para prever a maturação do amendoim, utilizando técnicas de aprendizado de máquinas; 2) Validar o desempenho de predição da maturação utilizando bandas espectrais e índices de vegetação com dois tipos de RNA's, a perceptron multicamadas (MLP) e a função de ativação de base radial (RBF).

Material e métodos

Área de estudo

O experimento foi conduzido em talhão comercial na safra do ano 2019/20 no município de Dumont – SP. A cultivar utilizada foi a IAC OL3 tipo Runner. O clima da região é classificado como Aw, tropical com inverno seco, de acordo com a classificação climática de Köppen (Alvares et al., 2013).

Avaliações em campo

O experimento foi implementado em área de aproximadamente 8 ha, na qual foram distribuídos 30 pontos centrais equidistantes a 50 metros. Foram realizadas avaliações da maturação do amendoim aos 75, 105, 120 e 125 dias após a semeadura (DAS), sendo a última data 3 dias antes do arranquio. Todas as avaliações foram realizadas visando monitorar o comportamento da variabilidade espaço-temporal do amendoim.

Para a análise de maturação utilizou-se o método *Peanut Maturity Index* (PMI), que calcula a porcentagem de vagens maduras para cada amostra (Rowland et al. 2006). Foram retiradas todas as vagens das plantas contidas na amostra (5 plantas por ponto), obtendo-se em média 150 a 250 vagens para análise de maturação em cada ponto amostral. É importante ressaltar que, a cada data de coleta, os pontos eram escolhidos aleatoriamente dentro de um raio de 10 m a partir do centro de cada parcela. Em seguida, todas as vagens foram submetidas ao processo de remoção do exocarpo com o auxílio de

lavadora de alta pressão em laboratório. As vagens foram dispostas sobre o quadro de classificação de maturação (Hull-Scrape), que apresenta 24 classificações de cores, determinando a maturação do amendoim a partir das cores apresentadas pelas vagens

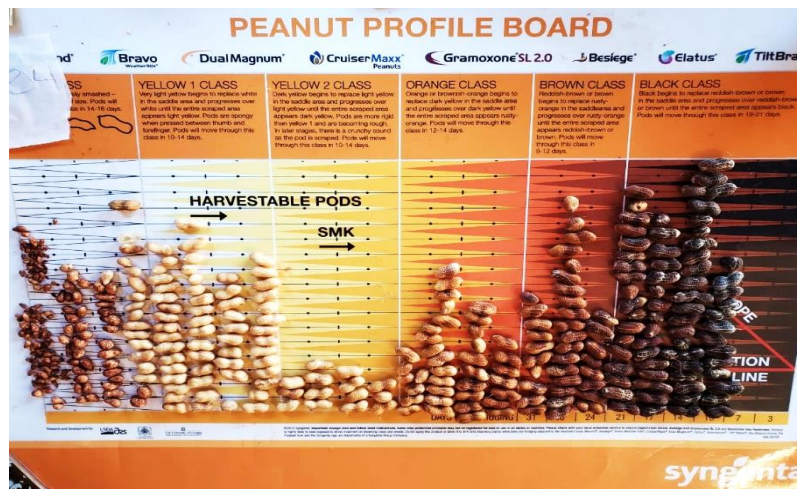


Figura 1. Quadro com as vagens dispostas e classificadas de acordo com a coloração do exocarpo.

(Williams e Drexler, 1981) (Figura 1).

Aquisição de imagens do UAV

Para as avaliações com imagens aéreas foi utilizada a câmera Micasense RedEdge-M, que captura imagens em 5 bandas espectrais: Azul (465-485nm), Verde (550-570 nm), Vermelho (658-678 nm), Infravermelho (820-860 nm) e Red Edge (712-722 nm), embarcada na aeronave remotamente pilotada (UAV) modelo DJI Matrice 100 (Shenzhen, China). Antes de cada voo utilizou-se a câmera para capturar imagens do painel de calibração, as quais foram utilizadas para correção das imagens da área. Para os pontos de controle, foram colocados alvos desenhados com cal em formato de cruz em cada vértice da área. Para identificar os pontos de coletas nas imagens, demarcou-se com cal as entrelinhas do ponto em que foram feitas as avaliações de maturação do amendoim, a fim de determinar os locais exatos em que foram aferidas todas as informações da cultura na lavoura. Todos os voos da aeronave seguiram as mesmas datas das avaliações da cultura em campo com horários de voos variando entre dez da manhã e meio dia, com altitudes de 90 m e sobreposição lateral e frontal de 90%. Para esta altura de voo a resolução espacial da câmera foi de 7,96 cm.

O plano de voo foi elaborado no software GSPRO. Para fazer o processamento das imagens foi utilizado o software Pix4D, versão Student, que foi aplicado para gerar os ortomosaicos e a correção radiométrica das imagens. O software livre Qgis (QGIS

Development Team, Open Source Geospatial Foundation, Chicago, IL, EUA) foi utilizado para extrair os pixels do solo das imagens aéreas por meio de classificação não supervisionada (método k-means), para evitar a mistura espectral do alvo de interesse (planta) com a refletância do solo. Criou-se um buffer de 1 m de raio (equivalente à 3,14 m²) a partir dos pontos de coleta, de modo, a abranger o maior número de pixel. Posteriormente, o valor médio da refletância do pixel de cada ponto amostral foi extraído.

Aquisição das imagens PlanetScope

Para as imagens de satélite foram utilizados dados do sensor da plataforma PlanetScope CubeSat. O Planet é uma constelação de satélites que compõe diferentes tipos de satélites com alta resolução espacial e temporal. Atualmente, o PlanetScope possui 148 satélites em órbita solar, os quais possuem capacidade de coletar imagens diariamente em qualquer lugar do planeta com resolução de 3-5 m e possuem 4 bandas espectrais (RGB + NIR) (Planet Team, 2019).

Para a correção das imagens, o PlanetScope disponibilizou o produto Surface Reflectance. Este produto garante consistência em condições atmosféricas localizadas, que minimizam a incerteza na resposta espectral espaço-temporal. O surface reflectance está disponível para todas as cenas ortorretificadas. As correções das imagens são determinadas a partir da refletância do topo da atmosfera (TOA), e é calculada a partir dos coeficientes fornecidos com o produto Planet Radiance. O cálculo de SR é uma operação pixel a pixel usando tabelas de pesquisa (LUTs) que foram geradas usando o código de transferência radiativa 6SV2.1. Os LUTs mapeiam a refletância no topo da atmosfera (TOA) para refletância de fundo da atmosfera (BOA) para todas as combinações selecionadas (Planet, 2020). Em decorrência da baixa disponibilidade de imagens de satélite para o período, devido estação chuvosa com presença de nuvens na região, foram utilizadas imagens planet com intervalo máximo de 3 dias em relação às imagens obtidas a partir de drone (PlanetScope, 2020).

Índices de vegetação (IVs)

A partir dos valores de refletância extraídos dos ortomosaicos para as imagens aéreas e orbitais, foram calculados 7 IVs para o UAV e 6 IVs para o satélite. Os valores médios dos IVs e das bandas espectrais foram usados como entradas para criar modelos não lineares para verificar o potencial das plataformas (aérea e orbital) em gerar

informações capazes de prever a variabilidade da maturação do amendoim. Todos esses índices foram escolhidos por apresentarem grande aplicação na previsão de parâmetros agronômicos em diversas culturas (Tabela 1).

Tabela 1. Índices de vegetação (IV) utilizados para o drone e satélite.

IV *	Equação	Referência
NDVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Rouse et al. (1974)
GNDVI	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson e Merzlyak (1996)
MNLI	$(\text{NIR}^2 - \text{Red}) (1+L) / (\text{NIR}^2 + \text{Red} + L)$ **	Gong et al. (2003)
EVI	$2.5 * (\text{NIR} - \text{Red}) / (L + \text{NIR} + C1 \text{Red} - C2\text{Blue})$	Justice et al. (1998)
NLI	$(\text{NIR}^2 - \text{Red}) / (\text{NIR}^2 + \text{Red})$	Goel and Qin (1994)
SAVI	$(1+L) (\text{NIR} - \text{Red}) / (L + \text{NIR} + \text{Red})$	Huete (1988)
NDRE**	$(\text{NIR} - \text{RE}) / (\text{NIR} + \text{RE})$	Filzgerald et al. (2010)

NDVI: Normalized Difference Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; MNLI: Modified Non-Linear Index; EVI: Enhanced Vegetation Index; NLI: Non-Linear Index; SAVI: Adjusted Vegetation Index; NDRE: Normalized Difference Red Edge Index; **L = 0.5; C1 = 6; C2 = 7.5
 ** IV não utilizado para o satélite devido o sensor não disponibilizar a banda do RedEdge.

Análise estatística

O comportamento dos índices de maturação ao longo do tempo foi avaliado por meio de estatística descritiva utilizando Box Plot (Diagrama de caixa), o qual foi apresentado em função dos graus dias acumulado (GDA) (equação 1), tendo em vista que o acúmulo de graus dias é essencial para a planta do amendoim atingir a maturidade. Para Brunini et al. (1976) o GDA é a quantidade de calor que a planta acumula efetivamente durante o dia que favorece o crescimento do vegetação. Para realização do cálculo de GDA foi instalada uma estação meteorológica que coletou dados de temperatura mínima e máxima ao longo de toda safra.

$$GDA = \frac{TM + Tm}{2} - Tb \quad (1)$$

Em que, TM é a temperatura máxima, Tm é a temperatura mínima e Tb é a temperatura basal inferior.

A fim de auxiliar análise de box plot e obter melhor visualização do comportamento da maturação em relação ao acúmulo de graus dias, foram gerados mapas de índice de maturação (PMI) interpolados pelo método IDW (Inverso da Distância Ponderada) no software Qgis para cada data coleta.

Descrição dos modelos de RNAs para predição do PMI

Para prever o índice de maturação do amendoim através de índices de vegetação, foram realizadas técnicas de modelagem dos dados nos quais foram utilizados dois modelos de Redes Neurais Artificiais (RNA), do tipo função de ativação de base radial (RBF) e perceptron de multicamadas (MLP). As RNA's são modelos computacionais que desempenham funções similares aos neurônios humanos, no entanto, os seus sistemas consistem em neurônios artificiais (Jiang et al 2004) que podem aprender relações entre variáveis e reconhecer padrões por meio de exemplos, generalizando as informações aprendidas e desenvolvendo modelos não lineares (Savegnago et al 2011; Soares et al., 2015). Outro fator que impulsiona o uso de técnicas de aprendizado de máquinas na agricultura é a função de ajuste universal dos modelos, que admitem perdas de dados não paramétricos e que não requerem informações prévias do fenômeno a ser modelado (Barbosa et al., 2020; Jiang et al., 2020; Jung et al., 2020).

Redes neurais Percptron multicamadas (MLP)

As redes MLP têm sido aplicadas com sucesso através de seu treinamento de forma supervisionada com o algoritmo de retropropagação do erro. Essa rede é treinada com as entradas ajustadas à variável de saída (PMI) em duas fases (*forward* e *backward*). Escolhas como arquitetura de rede neural, algoritmo de treinamento e parâmetros associados são operações importantes em análises de RNA. Procurando evitar uma abordagem de tentativa e erro para determinar estas operações, a ferramenta Intelligent Problem Solver (IPS) que faz parte do software Statistica 7 foi utilizada a fim de obter a combinação heurística para tornar a definição da topologia fácil e rápida (técnica mínima-becketing e algoritmo simulado de annealing) (Miao et al., 2006). A partir do uso do software foi possível testar automaticamente mil modelos diferentes para predição, arquitetura de redes e parâmetros associados.

As redes MLP são compostas de uma ou mais camadas de entrada, uma ou mais camadas ocultas e uma camada de saída (Figura 2). As camadas de entrada da rede foram compostas pelos índices de vegetação e bandas espectrais dos sensores aéreo e orbital e a camada de saída pelo PMI. O número de neurônios variou de 1 a 20 para as redes MLP.




Figura 2. Arquitetura de uma rede neural perceptron multicamadas. Fonte: Fath et al. (2020)

As combinações utilizadas para os modelos foram: Bandas satélite; Bandas UAV, IVs satélite; IVs UAV; bandas e IVs satélite; bandas e IVs UAV; bandas satélite e UAV; IVs satélite e UAV; bandas/IVs satélite/UAV; todos os IVs e bandas separadamente.

As redes são interconectadas por forças de conexão representadas por valores que são chamados de pesos sinápticos, os quais são responsáveis pelo armazenamento do conhecimento adquirido. Os valores usados nas camadas de entrada foram normalizados de acordo com a Equação 2.

$$y_i = \frac{x_i + x_{\max}}{x_{\max} - x_{\min}} \quad (2)$$

Em que:

y_i é o valor do vetor de entrada (exemplo: bandas), x_{\min} é o mínimo valor, x_{\max} é o máximo valor observados.

O valor de saída de cada neurônio na cama k é expresso por $y_k = g(a_k)$ em que g é a função de ativação de a_k e a_k é a função sináptica, a qual é uma combinação linear dos valores de entrada normalizada e os pesos sinápticos como mostrado na Equação 3.

Em que:

$$a_k = \sum_j y_j \cdot w_{kj} \quad (3)$$

w_{kj} são os pesos sinápticos ligando os y_j valores de entrada com cada k neurônio.

A transferência ou função de ativação nos neurônios de cada camada foi a função hiperbólica.

$$g(a_k) = \frac{e^{ak} - e^{-ak}}{e^{ak} + e^{-ak}} \quad (4)$$

Redes neurais de função de ativação de base radial (RBF)

As camadas que envolvem as redes RBF são a camada de entrada, uma camada oculta que aplica uma transformação não linear do espaço de entrada para o espaço oculto e camada de saída que é linear e procura classificar os padrões recebidos da camada oculta (Figura 3). Para determinar a topologia de uma rede RBF também é necessário especificar alguns parâmetros, no entanto a quantidade é inferior quando comparado com as redes MLP. Para as redes RBF é necessário definir somente o algoritmo de treinamento e um fator de alisamento ou suavidade, os quais foram determinados pela ferramenta IPS. As redes RBF são utilizadas por apresentarem muita tolerância aos ruídos de entrada e apresentam treinamento rápido e abrangente.




Figura 3. Arquitetura de uma rede neural de função de base radial. Fonte: Fath et al. (2020)

As redes RBF, assim como as redes MLP, são redes multicamadas, no entanto, a função de ativação sigmóide, dos neurônios da camada oculta da RBF, é alterada por outra classe de função, cujo valor diminui ou aumenta em relação a distância de um ponto central (Haykin 1999). Neste estudo a função de base radial que foi utilizada para a rede RBF foi a função *Gaussiana* (Eq. 5).

$$\varphi = \exp\left(-\frac{v^2}{2\sigma^2}\right) \quad (5)$$

Em que, $v = \|x - \mu\|$ é a distância Euclidiana entre o vetor de entrada e o centro μ da função *Gaussiana* e σ é a largura. A distância Euclidiana do vetor de entrada para o centro μ é a entrada para função *Gaussiana*, a qual fornece o valor de ativação da unidade radial.

Treinamento, validação e teste de desempenho

Para as redes RBF durante a fase de treinamento as RNAs foram treinadas mil vezes cada modelo, pois os parâmetros livres são obtidos de forma aleatória. As camadas de entrada e saída seguiram o mesmo princípio das redes MLP e as simulações para a rede RBF também foram as mesmas, assim como o número de neurônios, que variou de 1 a 20.

O banco de dados foi dividido em 80% para treinamento e 20% para validação dos modelos. Os procedimentos de treinamento e validação dos modelos das redes neurais foram implementados no pacote Neural Networks do software de análise de dados Statistica (Statistica 7.0, Statsoft Inc., Tulsa, OK).

A eficiência das redes foi analisada por meio de gráficos com a relação 1:1. Quanto à acurácia e precisão, estas foram analisadas com a utilização do MAE para o erro das previsões e o coeficiente de determinação (R^2) para precisão, demonstrando por meio destes cálculos a confiabilidade dos dados obtidos das previsões das variáveis, e ainda, foram realizadas análises comparativas entre os dados preditos com os observados.

As avaliações em termos de acurácia e precisão pelo cálculo do erro médio absoluto (MAE) e o coeficiente de determinação (R^2) estão representadas pelas equações 7 e 8 respectivamente.

$$MAE = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i) \quad (7)$$

Em que, n é o número de dados, Y_i é o valor da variável estimada pela rede e \bar{Y} é o valor da variável observada.

$$R^2 = \frac{SQR}{SQT} \quad (8)$$

Em que SQR é a soma dos quadrados dos resíduos e SQT é a soma dos quadrados totais.

Para responder qual o melhor modelo para predição da maturação do amendoim e qual índice de vegetação apresentou melhor desempenho na etapa de validação dos modelos de RNAs, foi considerado o melhor aquele que apresentou menor valor de MAE, ou seja, apresentou melhor acurácia (até 0,06).

Resultados e discussão

Para avaliar a variabilidade do PMI ao longo dos Graus-Dias Acumulados (GDA), foi realizada análise do diagrama de caixa (Box Plot) juntamente com mapas interpolados do PMI. A figura 4 mostra a dispersão dos valores de PMI, que variam significativamente ao longo do tempo. Aos 1423 GDA a área não apresentou níveis de maturação satisfatórios, o que indica que o amendoim estava completamente imaturo em toda área. É possível observar que a maior variabilidade foi aos 1778 GDA, e ao passo que aumentava o acúmulo de graus-dia, a variabilidade diminuiu e o índice de maturação aumentou. Para a cultura do amendoim o desenvolvimento e crescimento das vagens é relativamente sensível à temperatura do ar, principalmente na faixa de 20-25 C°, logo o acúmulo de graus dias é o que determina a taxa de desenvolvimento fenológico da cultura (Bell e Wright, 1998; Awal et al., 2003). O diagrama de caixa mostra que aos 2099 GDA o PMI apresentou mediana mais próxima do primeiro quartil, o que indica distribuição assimétrica positiva, enquanto que as demais apresentaram distribuição assimétrica negativa.

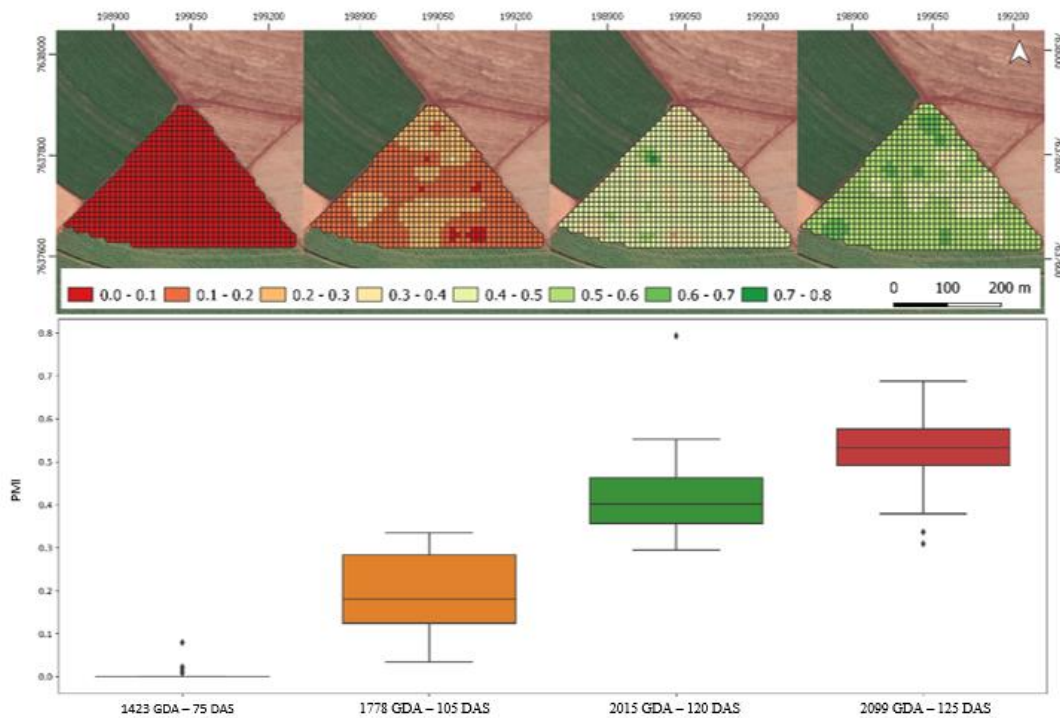


Figura 4. Mapas interpolados da variabilidade espaço-temporal em função dos graus dias (GDA) e distribuição de box plot para maturação do amendoim.

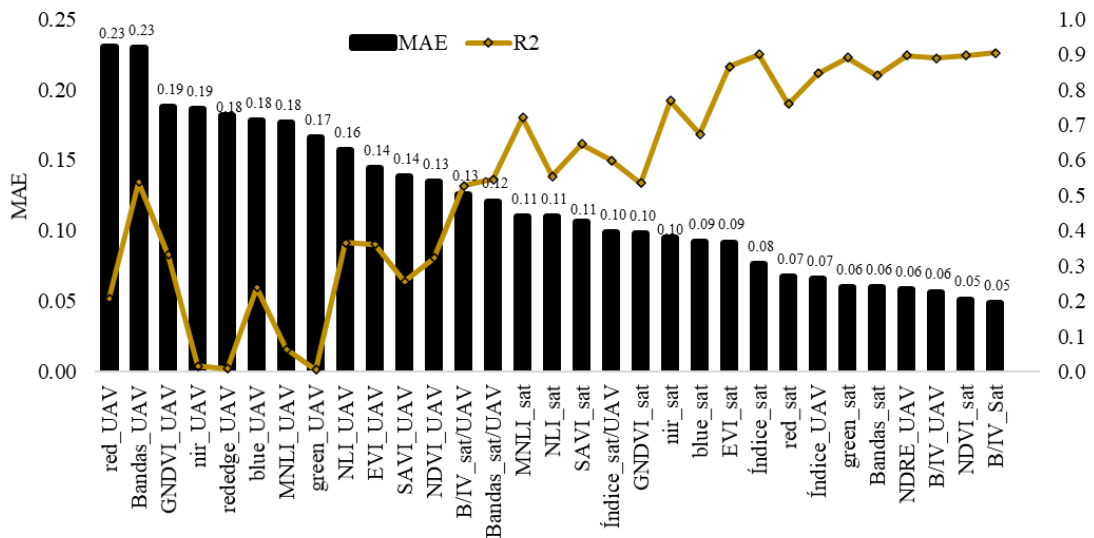
A utilização de tecnologias como o sensoriamento remoto e o aprendizado de máquinas têm sido bastante úteis para o setor agrícola, principalmente por apresentarem informações de forma rápida e não destrutiva (Shiratsuchi et al., 2014). Neste estudo a proposta é verificar o potencial das plataformas de sensoriamento remoto, para predição da maturação do amendoim utilizando redes neurais artificiais. O amendoim é uma cultura com características distintas, devido seu crescimento vegetal acontecer de forma indeterminada, o que causa bastante variabilidade e dificulta a identificação do ponto ideal de maturação. Outro aspecto a considerar, é o fato de a cultura não apresentar indícios fisiológicos que sejam visíveis para indicar o processo de senescência na planta.

Hoje o método mais difundido entre produtores e pesquisadores para determinação do PMI é o Hull-Scrape (Williams e Drexler, 1981), que é uma metodologia destrutiva e bastante subjetiva na qual a cada safra pode apresentar um padrão de identificação de cores diferentes. Determinar o ponto ideal de maturação de forma precisa e sem subjetividade é extremamente importante para realizar uma colheita mais assertiva. Durante os anos diversas pesquisas foram desenvolvidas para determinar o melhor momento para colheita do amendoim, no entanto, os métodos propostos apresentam limitações significativas e incertezas (Rui Li et al., 2021).

Para cada combinação de topologia, dez modelos foram selecionados pela ferramenta IPS. Considerou-se a melhor arquitetura de modelo aquelas que apresentaram MAE entre 0.05 e 0.06 e R^2 acima de 0.85 para os modelos validados. Diante disto, apenas 6 modelos RBF e 6 modelos MLP apresentaram os melhores resultados (Figura 5). A rede RBF utilizou 3 entradas para todos os modelos combinados (B/IV_sat; Bandas_sat; Índice_UAV) enquanto que a rede MLP usou 4 e 5 entradas (Tabela 2).

Para os modelos de simulações que utilizaram as bandas espectrais e os índices de vegetação do satélite (B/IV_sat) e (Bandas_sat), a rede RBF apresentou melhor acurácia (MAE = 0,05). O modelo de rede RBF para a combinação Índices_UAV, também apresentou melhor acurácia (MAE = 0,05) que o MLP. Os modelos MLP tiveram acurácia de 0.06, exceto o NDVI_sat e o B/IV_sat que o MAE foi igual a 0,05 para ambos os modelos (RBF e MLP) (Figura 5).

(A)



(B)

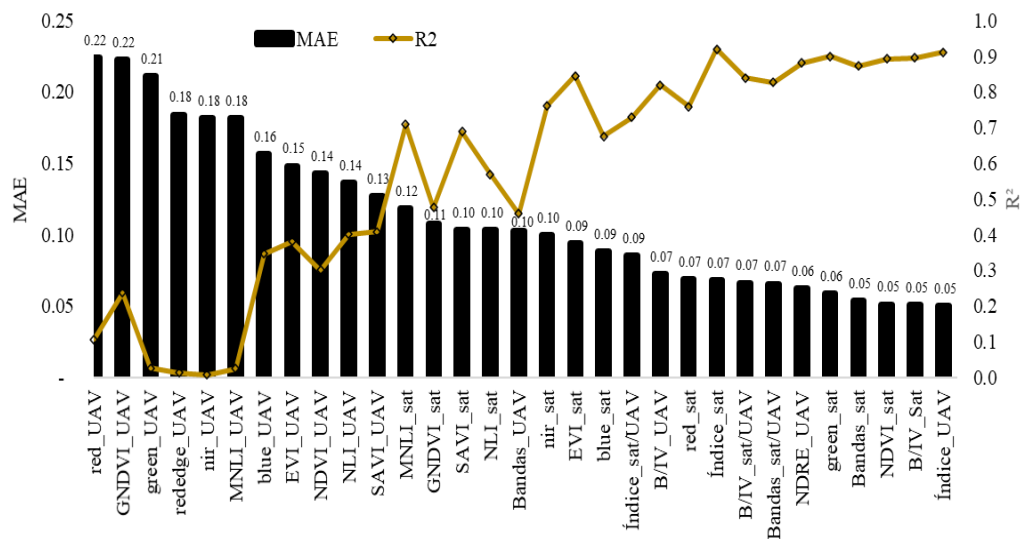


Figura 5. Acurácia (Mean Absolute Error) e precisão (R²) da validação dos modelos para as redes, perceptron de multicamadas-MLP (A) e redes neurais ativação de base radial-RBF (B)

Quando os modelos foram treinados e validados com as variáveis separadamente, a banda do green do satélite foi a variável que estimou o PMI com maior precisão e acurácia com a rede neural RBF. A banda do green já demonstrou em diversos estudos, maior sensibilidade ao conteúdo de clorofila (clorofila *a* e *b*) e biomassa no monitoramento da produção do milho, soja, batata e trigo (Skakun et al., 2021; Gitelson et al., 1996; Gitelson et al., 2003; Nguy Robertson et al., 2014; Vinã et al., 2011). Para a cultura do amendoim, Rowland et al. (2008) e Monsef et al. (2019) utilizando sensor radiômetro multiespectral e câmera multiespectral em UAV respectivamente, não verificaram potencial no uso da banda do green, devido a sua baixa capacidade de determinar a variabilidade da maturação em diferentes estádios, contrapondo aos resultados deste estudo. O reflexo da geração de modelos não-lineares das RNA's e a diferença entre sensores, podem justificar os resultados distintos entre os estudos.

Os IVs NDVI_sat e o NDRE_UAV apresentaram os melhores modelos para a rede MLP, que estimou o PMI com acurácia 0.05 e 0.06 respectivamente e precisão de 0.90 para ambas entradas (Figura 5). O NDVI apresenta limitações para vegetações com alta densidade, em razão da alta absorção da radiação no comprimento de onda do vermelho pelos pigmentos de clorofila. No entanto, Santos et al. (2021) utilizando imagens de alta resolução para a cultura do amendoim, não verificaram indícios de saturação para o

NDVI, resultado também observado neste trabalho, em que o modelo gerado a partir do NDVI foi capaz de expressar a variabilidade real do PMI. Em contrapartida, o NDRE apresenta maior sensibilidade à alta densidade vegetal, isto pode explicar o bom desempenho deste IV para o modelo com o UAV. Morlin et al. (2020) ao avaliarem o comportamento do NDVI e NDRE para a cultivar da soja, verificaram que o segundo IV não apresentou indícios de saturação para sensores proximais.

Nesta pesquisa os resultados dos modelos de RNA's desenvolvidos, demonstraram boa precisão e acurácia para prever a maturação do amendoim a partir do uso do sensoriamento remoto. Tanto o UAV quanto o satélite apresentaram potencial para prever o PMI. O satélite apresentou maiores possibilidades de modelos para prever a maturação, no entanto, quando se leva em consideração a melhor acurácia e maior precisão, a simulação com os índices de vegetação do UAV, apresentaram a melhor desempenho (Tabela 2). Embora as diferenças entre os sensores sejam óbvias, é importante observar os modelos gerados a partir de diferentes tipos de sensores, para gerar modelos mais robustos (Schuerger et al., 2003). Diante disto, é muito importante pesquisas que busquem estudar a fundo as respostas e informações geradas a partir dos diferentes tipos de plataformas no sensoriamento remoto, tendo em vista as distintas características dos sensores e das culturas.

Dentre as topologias testadas, as RNA's usaram 20 neurônios na primeira camada oculta para as simulações (B/IV_sat; Bandas_sat; Índice_UAV). A rede MLP usou 11 neurônios para B/IV_UAV na primeira camada oculta e 10 na segunda. Para as simulações feitas para cada variável separadamente, o modelo RBF utilizou apenas 1 neurônio na camada oculta para o NDRE_UAV enquanto que o MLP utilizou 20 neurônios na primeira camada oculta e 10 na segunda, no entanto, ambos os modelos apresentaram a mesma acurácia (0.06) com diferença apenas na precisão (RBF = 0.88 e MLP = 0.90). Com isso, constata-se que a quantidade de neurônios na camada oculta não é fator determinante para obter bons modelos de RNA's. (Tabela 2).

Esses dois tipos de redes neurais pertencem a uma mesma classe de RNA's chamadas redes *feed-forward*, em que as informações processadas na rede, seguem uma direção dos neurônios de entrada para os de saída. Existem algumas diferenças entre as redes MLP e RBF (Xie et al., 2011). As redes RBF são mais simples e geralmente apresentam treinamento mais fácil devido à estrutura simples e fixa de três camadas. As redes MLP funcionam universalmente e diferentemente da RBF, as saídas da rede são definidas por

todos os neurônios, enquanto que, as RBF atuam como redes de aproximação com as saídas sendo obtidas por neurônios ocultos específicos (Fath et al., 2020).

Tabela 2. Modelos resultantes, topologias, precisão e acurácia das RNA's

Simulações	Nome do modelo	Estrutura do modelo	Treinamento		Validação	
			MAE	R ²	MAE	R ²
B/IV_sat*	RBF	3:3-20-1:1	0.05	0.89	0.05	0.90
	MLP	4:4-20-10-1:1	0.06	0.90	0.05	0.90
green_sat	RBF	1:1-14-1:1	0.06	0.90	0.06	0.90
	MLP	1:1-20-10-1:1	0.06	0.89	0.06	0.89
NDVI_sat	RBF	1:1-13-1:1	0.05	0.89	0.05	0.89
	MLP	1:1-6-1:1	0.05	0.90	0.05	0.90
NDRE_UAV	RBF	1:1-1-1-1:1	0.06	0.88	0.06	0.88
	MLP	1:1-20-10-1:1	0.06	0.90	0.06	0.90
Bandas_sat	BRF	3:3-20-1:1	0.05	0.87	0.05	0.87
	MLP	4:4-20-8-1:1	0.06	0.86	0.06	0.84
Índice_UAV	BRF	3:3-20-1:1	0.05	0.91	0.05	0.91
B/IV_UAV**	MLP	5:5-11-10-1:1	0.06	0.89	0.06	0.89

RBF: Função de base radial ; MLP : Multilayer Perceptron; A arquitetura da rede neural é apresentada na forma de I:N1-N2-N3:O, onde "I", "N1", "N2", "N3" e "O" são os números de neurônios na entrada, Ocultos e as camadas de saída, respectivamente. *B/IV_sat = bandas/índices de vegetação do satélite; **B/IV_UAV = bandas/índices de vegetação do UAV.


A análise de sensibilidade foi utilizada pra classificar a importância de cada variável de entrada usada nos modelos para prever a maturação do amendoim (Tabela 1 do material suplementar). Com base na análise de desempenho, acurácia e precisão, o melhor modelo de RNAs com a plataforma orbital para estimar o PMI foi a combinação das bandas espectrais com IVs para o satélite (B/IV_sat) com as redes RBF e MLP. A

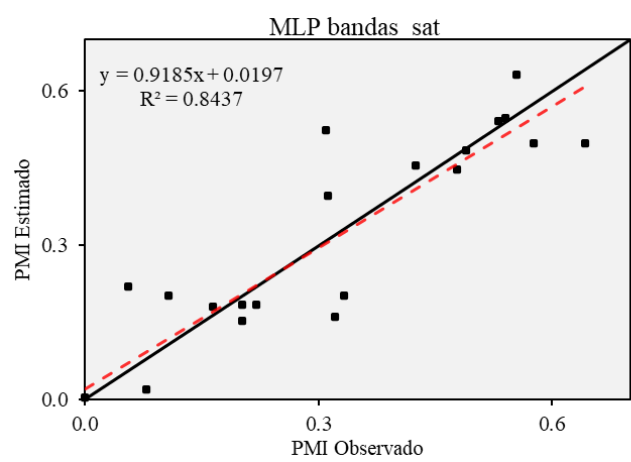
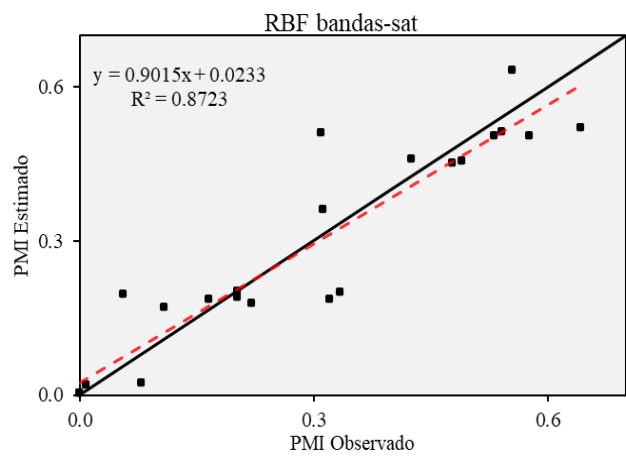
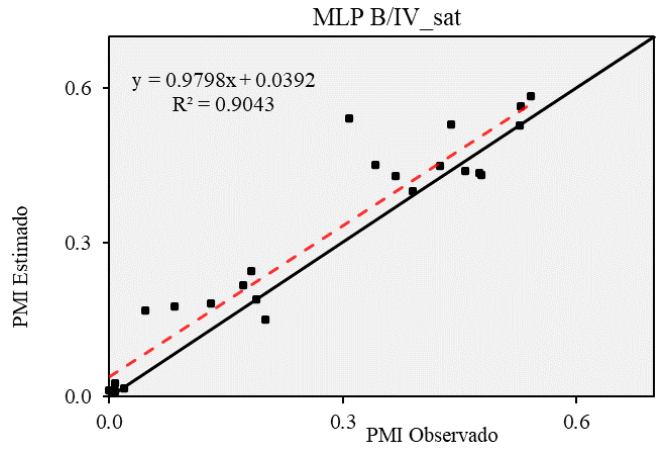
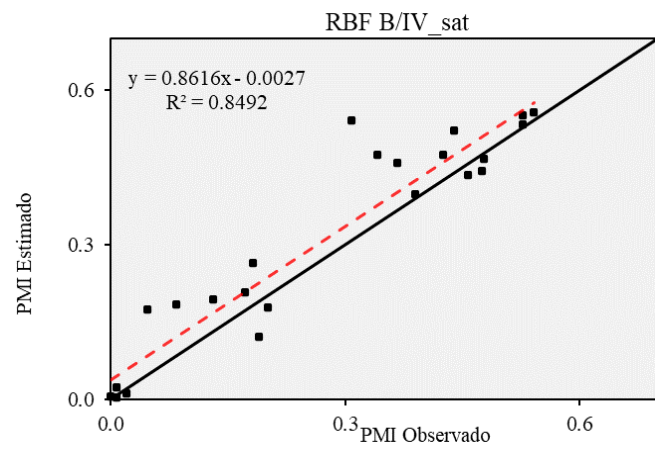
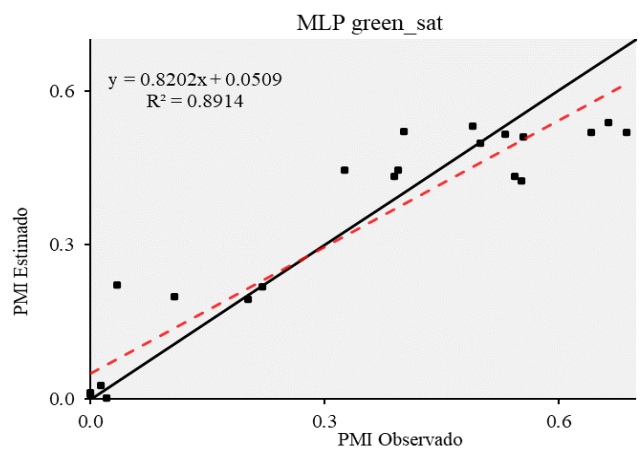
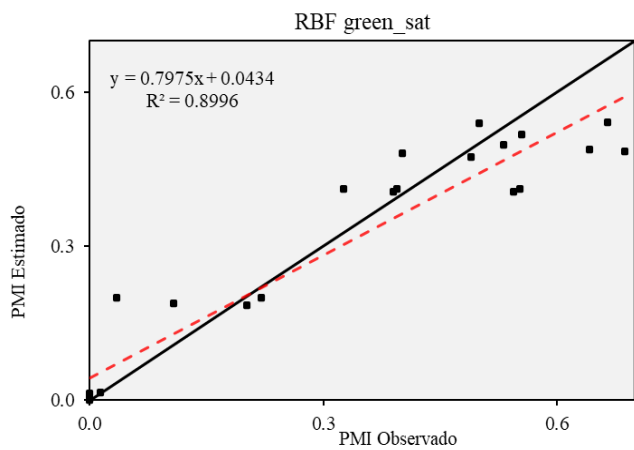
análise de sensibilidade para o modelo RBF utilizou 3 entradas e teve como variável mais importante, a banda do NIR seguida dos IVs, EVI e MNLI. Já a rede MLP utilizou 4 entradas, com ordem de importância NDVI, blue, green e GNDVI.

A plataforma aérea também apresentou potencial para prever a maturação do amendoim com os índices de vegetação para a rede RBF. A arquitetura utilizou as variáveis NDRE, NLI e SAVI com ordem de importância 1º, 2º e 3º respectivamente. Índices que contêm a banda da borda do vermelho (red-edge), como é o caso do NDRE, vem se destacando em estudos com vegetações altamente densas (Taubinger et al 2012; Amaral et al., 2015; Morlin et al., 2020). Santos et al. (2021) observaram resultados promissores com o NLI e o SAVI, com ambos, apresentando forte correlação negativa com o PMI na cultura do amendoim, boa precisão (R^2) e acurácia (RMSE).

Na figura 6 é demonstrada a avaliação de desempenho dos modelos RBF e MLP que foram escolhidos em função da melhor acurácia e precisão. O índice de maturação estimado pelo modelo resultante foi comparado com o PMI determinado pelo método Hull Scrap (método de campo). A avaliação de desempenho dos modelos indica que as redes RBF e MLP são semelhantes para prever a maturação do amendoim. Os modelos que utilizaram a variáveis de entrada separadamente, demonstram que o NDVI_sat apresentou o melhor desempenho (Figura 6), pois a reta ajustada e os valores de predição encontram-se próximos a linha 1:1. Para os modelos combinados o modelo RBF para os índices de vegetação do UAV apresentam o melhor desempenho com os melhores resultados em acurácia e precisão.

(A)





(B)

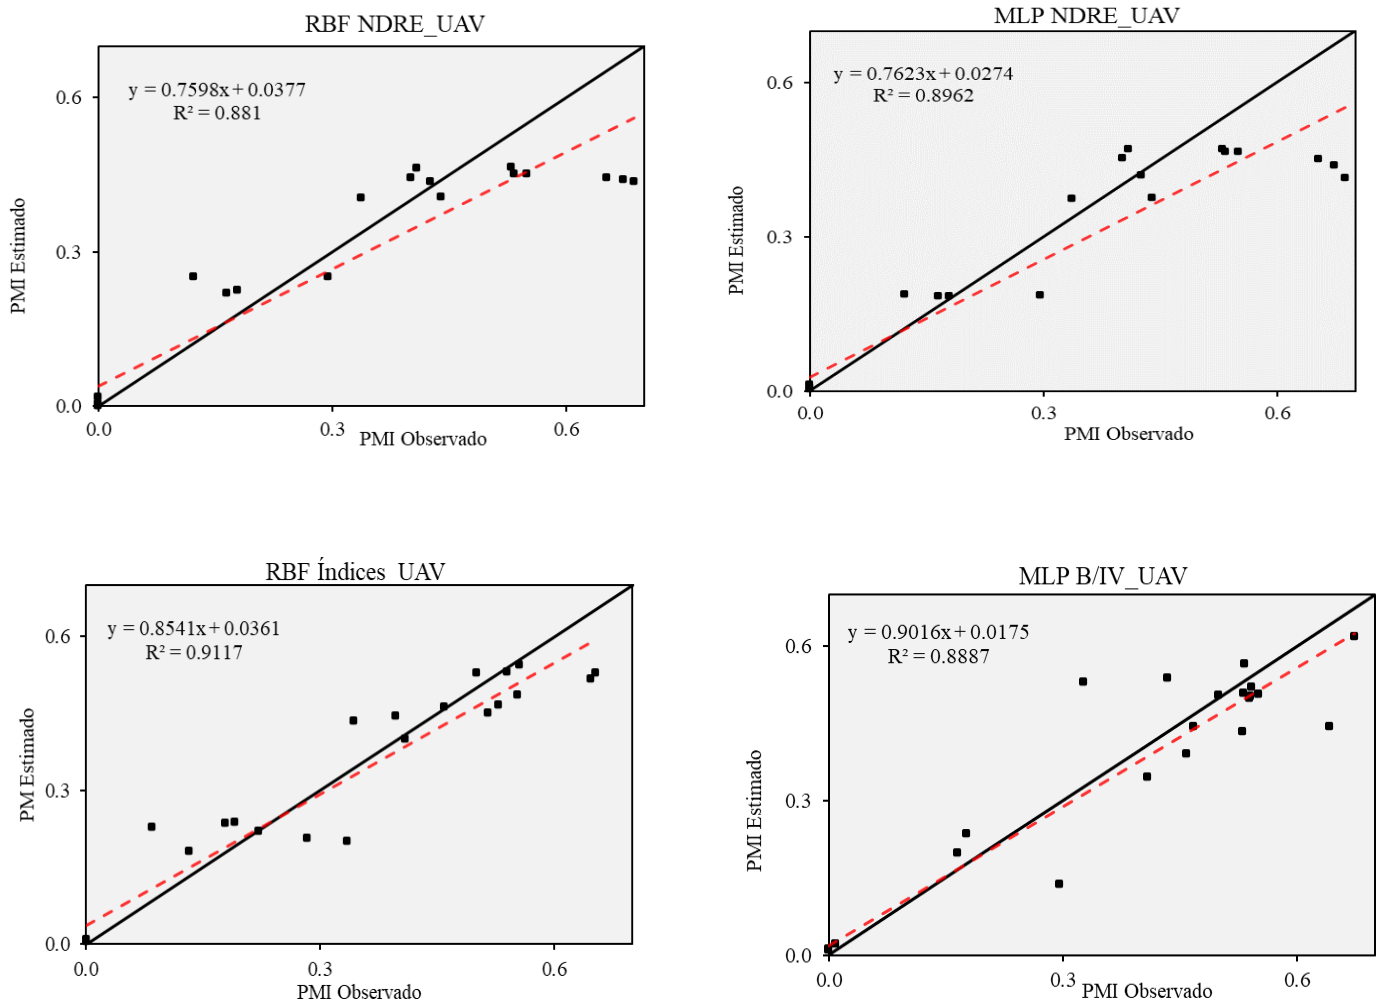


Figura 6. Desempenho dos modelos utilizando as variáveis que apresentaram melhor acurácia (MAE) para as duas redes neurais (RBF e MLP). Modelos para o satélite (A) e modelos para UAV (B)

Conclusões

Os modelos de previsão para índice de maturação do amendoim a partir de imagens de UAV e satélite foram satisfatórios, obtendo simulações precisas e acuradas. O uso das bandas espectrais e dos índices de vegetação de ambas as plataformas, apresentaram-se como variáveis predictoras da variabilidade da maturação do amendoim. As redes neurais MLP e RBF tiveram desempenhos semelhantes em relação aos modelos criados, o que permite inferir que essas RNA's são capazes de estimar o PMI com elevada acurácia e precisão. As duas plataformas têm potencial para prever o PMI, assim como as redes MLP e RBF. No entanto, diante das configurações apresentadas pode-se recomendar o uso do satélite com o índice NDVI utilizando o algoritmo MLP.

Este trabalho apresentou um dos primeiros estudos sobre o uso do sensoriamento remoto para a cultura do amendoim com arquiteturas de redes neurais artificiais para predição da maturação. Devido às características distintas da cultura do amendoim, avaliações em diferentes condições são ideais para criar modelos mais robustos, logo, faz-se necessário estudos, a fim de verificar a aplicabilidade dos modelos gerados utilizando sensoriamento remoto e RNA, para prever a maturação do amendoim em função da interação entre genótipo e ambiente.

Referências Bibliográficas

- Amaral, L. R., Molin, J. P., Portz, G., Finazzi, F. B., & Cortinove, L. (2015). Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. *Precision Agriculture*, 16(1), 15-28. <https://doi.org/10.1007/s11119-014-9377-2>
- Ashapure, A., Jung, J., Chang, A., Oh, S., Maeda, M., & Landivar, J. (2019). A comparative study of RGB and multispectral sensor-based cotton canopy cover modelling using multi-temporal UAS data. *Remote sensing*, 11(23), 2757. <https://doi.org/10.3390/rs11232757>
- Atzberger, C. (2013). Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. *Remote sensing*, 5(2), 949-981. <https://doi.org/10.3390/rs5020949>
- Awal, M. A., & Ikeda, T. (2003). Effect of elevated soil temperature on radiation-use efficiency in peanut stands. *Agricultural and Forest Meteorology*, 118(1-2), 63-74. [https://doi.org/10.1016/S0168-1923\(03\)00070-4](https://doi.org/10.1016/S0168-1923(03)00070-4)
- Bell, MJ, & Wright, GC (1998). Crescimento e desenvolvimento do amendoim em ambientes contrastantes. 2. Acumulação da unidade de calor e efeitos fototérmicos no índice de colheita. *Experimental Agriculture*, 34 (1), 113-124.
- Brunini, O., Lisbão, R. S., Bernar-DI, J. B., Fornasier, J. B., & Pedro Júnior, M. J. (1976). Temperatura-base para alface cultivar " White Boston", em um sistema de unidades térmicas. *Bragantia*, 35, 213-219. <https://doi.org/10.1590/S0006-87051976000100019>
- Carneiro, F. M., Furlani, C. E. A., Zerbato, C., de Menezes, P. C., da Silva Gírio, L. A., & de Oliveira, M. F. (2020). Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. *Precision Agriculture*, 21(5), 979-1007. <https://doi.org/10.1007/s11119-019-09704-3>
- Colvin, B. C., Tseng, Y. C., Tillman, B. L., Rowland, D. L., Erickson, J. E., Culbreath, A. K., & Ferrell, J. A. (2018). Consideration of peg strength and disease severity in the

decision to harvest peanut in southeastern USA. *Journal of crop improvement*, 32(3), 287-304.

de Oliveira, M. F., dos Santos, A. F., Kazama, E. H., de Souza Rolim, G., & da Silva, R. P. (2021). Determination of application volume for coffee plantations using artificial neural networks and remote sensing. *Computers and Electronics in Agriculture*, 184, 106096. <https://doi.org/10.1016/j.compag.2021.106096>

dos Santos, A. F., Correa, L. N., Lacerda, L. N., Tedesco-Oliveira, D., Pilon, C., Vellidis, G., & da Silva, R. P. (2021). High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agriculture*, 1-15. <https://doi.org/10.1007/s11119-021-09791-1>

dos Santos, A. F., Correa, L. N., Lacerda, L. N., Tedesco-Oliveira, D., Pilon, C., Vellidis, G., & da Silva, R. P. (2021). High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agriculture*, 1-15. <https://doi.org/10.1007/s11119-021-09791-1>

Fath, A. H., Madanifar, F., & Abbasi, M. (2020). Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems. *Petroleum*, 6(1), 80-91. <https://doi.org/10.1016/j.petlm.2018.12.002>

Fitzgerald, G., Rodriguez, D., & O'Leary, G. (2010). Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index (CCCI). *Field Crops Research*, 116(3), 318-324. <https://doi.org/10.1016/j.fcr.2010.01.010>

Gitelson, A. A., Viña, A., Arkebauer, T. J., Rundquist, D. C., Keydan, G., & Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical research letters*, 30(5).

Gitelson, A.A., Merzlyak, M.N., 1996. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *J. Plant Physiol.* 148, 494–500.

Goel, N. S. and W. Qi. 1994. “Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation.” *Remote Sensing Review* 10: 309–347.

Gong, P., R. Pu, G. S. Biging, and M. R. Larrieu. 2003. “Estimation of Forest Leaf Area Index Using Vegetation Indices Derived from Hyperion Hyperspectral Data.” *IEEE Transactions on Geoscience and Remote Sensing* 41:6.

- Hasan, A. M., Sohel, F., Diepeveen, D., Laga, H., & Jones, M. G. (2021). A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture*, 184, 106067. [s://doi.org/10.1016/j.compag.2021.106067](https://doi.org/10.1016/j.compag.2021.106067)
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.
- Jiang, D., Yang, X., Clinton, N., & Wang, N. (2004). An artificial neural network model for estimating crop yields using remotely sensed information. *International Journal of Remote Sensing*, 25(9), 1723-1732. <https://doi.org/10.1080/0143116031000150068>
- Justice, C. O., Vermote, E., Townshend, J. R., Defries, R., Roy, D. P., Hall, D. K., ... & Barnsley, M. J. (1998). The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. *IEEE transactions on geoscience and remote sensing*, 36(4), 1228-1249.
- Kattenborn, T., Eichel, J., Wisser, S., Burrows, L., Fassnacht, F. E., & Schmidlein, S. (2020). Convolutional Neural Networks accurately predict cover fractions of plant species and communities in Unmanned Aerial Vehicle imagery. *Remote Sensing in Ecology and Conservation*, 6(4), 472-486.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24-49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>
- Khan, M. S., Semwal, M., Sharma, A., & Verma, R. K. (2020). An artificial neural network model for estimating Mentha crop biomass yield using Landsat 8 OLI. *Precision Agriculture*, 21(1), 18-33. <https://doi.org/10.1007/s11119-019-09655-9>
- Li, R., Zhao, Z., Monfort, W. S., Johnsen, K., Zion, T. H., & Leo, D. J. (2021). Development of a smartphone-based peanut data logging system. *Precision Agriculture*, 22(3), 1006-1018. <https://doi.org/10.1007/s11119-020-09758-8>
- Ma, Y., Zhang, Z., Kang, Y., & Özdoğan, M. (2021). Corn yield prediction and uncertainty analysis based on remotely sensed variables using a Bayesian neural network approach. *Remote Sensing of Environment*, 259, 112408. <https://doi.org/10.1016/j.rse.2021.112408>
- MIAO, Yuxin; MULLA, David J.; ROBERT, Pierre C. Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture*, v. 7, n. 2, p. 117-135, 2006.

- Monsef, H.A., Smith, S.E., Rowland, D.L., Rasol, N.A.E. (2019). Using multispectral imagery to extract a pure spectral canopy signature for predicting peanut maturity. *Computers and Electronics in Agriculture*, 162(1):561-572. <https://doi.org/10.1016/j.compag.2019.04.028>
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114(4), 358-371. <https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Nguy-Robertson, A. L., Peng, Y., Gitelson, A. A., Arkebauer, T. J., Pimstein, A., Herrmann, I., ... & Bonfil, D. J. (2014). Estimating green LAI in four crops: Potential of determining optimal spectral bands for a universal algorithm. *Agricultural and forest meteorology*, 192, 140-148. <https://doi.org/10.1016/j.agrformet.2014.03.004>
- Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T., & Moscholios, I. (2020). A compilation of UAV applications for precision agriculture. *Computer Networks*, 172, 107148.
- Rouse, J.W., J.R.H. Haas, J.A. Schell, and D.W. Deering. 1974. In Proc. ERTS-1 Symp., Greenbelt, MD. 10–15 Dec. 1974. NASA, Washington, D.C. 1974. Monitoring vegetation systems in the Great Plains with ERTS. 309-317.
- Rowland, D. L., Sorensen, R. B., Butts, C. L., Faircloth, W. H., & Sullivan, D. G. (2008). Canopy characteristics and their ability to predict peanut maturity. *Peanut Science*, 35(1), 43-54. <https://doi.org/10.3146/PS06-052.1>
- Santos, A. F., Lacerda, L. N., Gobbo, S., Tofannin, A., Silva, R. P., & Vellidis, G. (2019, January). Using remote sensing to map in-field variability of peanut maturity. In Precision Agriculture'19, Proceedings of the 12th European Conference on Precision Agriculture (pp. 605-661).
- Savegnago, R. P., Nunes, B. N., Caetano, S. L., Ferraudo, A. S., Schmidt, G. S., Ledur, M. C., & Munari, D. P. (2011). Comparison of logistic and neural network models to fit to the egg production curve of White Leghorn hens. *Poultry Science*, 90(3), 705-711. <https://doi.org/10.3382/ps.2010-00723>
- Schuerger, A. C., Capelle, G. A., Di Benedetto, J. A., Mao, C., Thai, C. N., Evans, M. D., ... & Stryjewski, E. C. (2003). Comparison of two hyperspectral imaging and two laser-induced fluorescence instruments for the detection of zinc stress and chlorophyll concentration in bahia grass (*Paspalum notatum* Flugge.). *Remote sensing of environment*, 84(4), 572-588.

Schuerger, A. C., Capelle, G. A., Di Benedetto, J. A., Mao, C., Thai, C. N., Evans, M. D., ... & Stryjewski, E. C. (2003). Comparison of two hyperspectral imaging and two laser-induced fluorescence instruments for the detection of zinc stress and chlorophyll concentration in bahia grass (*Paspalum notatum* Flugge.). *Remote sensing of environment*, 84(4), 572-588. [https://doi.org/10.1016/S0034-4257\(02\)00181-5](https://doi.org/10.1016/S0034-4257(02)00181-5)

Shiratsuchi, L. S., Brandão, Z. N., Vicente, L. E., VICTORIA, D. D. C., Ducati, J. R., de Oliveira, R. P., & VILELA, M. D. F. (2014). Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. Embrapa Agrossilvipastoril-Capítulo em livro científico (ALICE).

SIMON, Haykin. *Neural networks: a comprehensive foundation*. Prentice hall, 1999.

Skakun, S., Kalecinski, NI., Brown, MGL., Johnson, DM., Vermote, EF., Roger, J.-C.; Franch, B. (2021) Avaliando a variação de rendimento de milho e soja no campo a partir de imagens de satélite WorldView-3, Planet, Sentinel-2 e Landsat 8. *Remote Sens.* 13, 872. <https://doi.org/10.3390/rs13050872>

Soares, P. L. B., Silva, J. P., & Santos, M. D. (2015). Artificial, neural, networks applied to reduce the noise type of ground roll. *Journal of seismic exploration*, 24(1), 1-14.

Taubinger, L., Amaral, L. R., & Molin, J. P. (2012, July). Vegetation indices from active crop canopy sensor and their potential interference factors on sugarcane. *In 11th International Conference on Precision Agriculture* (p. 13).

Vellidis, G. and J. Beasley. 2013. Using vegetation indices to determine peanut maturity. Report to the Georgia Agricultural Commodity Commission for Peanuts. 2013 Research Reports – <http://www.gapeanuts.com>

Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468-3478. <https://doi.org/10.1016/j.rse.2011.08.010>

Williams, E. J., & Drexler, J. S. (1981). A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2), 134-141. <https://doi.org/10.3146/i0095-3679-8-2-15>


Xie, B., Zhang, HK, & Xue, J. (2019). Rede neural convolucional profunda para mapear a agricultura de pequenos proprietários usando imagens de satélite de alta resolução espacial. *Sensors*, 19 (10), 2398. <https://doi.org/10.3390/s19102398>

Xie, T., Yu, H., & Wilamowski, B. (2011, June). Comparison between traditional neural networks and radial basis function networks. In 2011 *IEEE International Symposium on Industrial Electronics* (pp. 1194-1199). IEEE. 10.1109/ISIE.2011.5984328

Yu, H., Xie, T., Paszczynski, S., & Wilamowski, B. M. (2011). Advantages of radial basis function networks for dynamic system design. *IEEE Transactions on Industrial Electronics*, 58(12), 5438-5450.

MATERIAL SUPPLEMENTAR

(A)



(B)




Figura 1. Análise da qualidade da Biomassa fresca (A) e seca (B) por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

Tabela 1. Análise de sensibilidade para as combinações com múltiplas entradas

Rede RBF				
Bandas e IV's	Combinações			
	B/IV_sat	Bandas_sat	IV_UAV	B/IV_UAV
blue_sat		3		
green_sat		2		
NIR_sat	1	1		
NDRE_UAV			1	
NLI_UAV			2	
SAVI_UAV			3	
EVI_sat	2			
MNLI_sat	3			

Rede MLP				
Bandas e IV's	Combinações			
	B/IV_sat	Bandas_sat	IV_UAV	B/IV_UAV
green_UAV				1
blue_sat	3	3		
green_sat	2	4		
NIR_sat		2		
red_sat		1		
GNDVI_UAV			5	
NDRE_UAV			2	2
NDVI_UAV			4	
MNLI				3

NLI_UAV		1	1
SAVI_UAV		3	
EVI			4
NDVI_sat	1		
GNDVI_sat	4		

CAPÍTULO 4: CONSIDERAÇÕES FINAIS

A qualidade final do fruto e a possibilidade de altas produtividades para a cultura do amendoim dependem diretamente do ponto ideal da maturação no momento da colheita. No entanto, a avaliação realizada para obter o índice de maturação demanda tempo e mão de obra, além do método ser altamente subjetivo. Diversas pesquisas foram realizadas ao longo de todos esses anos, a fim de desenvolver métodos precisos e não destrutivos para determinar a maturação do amendoim.

Técnicas de sensoriamento remoto permitem o estudo da variabilidade das lavouras com monitoramento espacial e temporal. Desta forma, o uso de plataformas como UAV e satélites surgem como excelentes alternativas para facilitar a identificação do momento ideal de colheita para a cultura do amendoim. Além disso, a possível identificação da variabilidade da maturação, a partir do uso de imagens aéreas e orbitais, utilizando bandas espectrais e índices de vegetação de ambas as plataformas, podem ser usadas como entradas em modelos de redes neurais artificiais para prever o índice de maturação de forma precisa e acurada.

Neste trabalho, observou-se que o satélite de alta resolução (PlanetScope) apresentou maior qualidade no processo de monitoramento da cultura de amendoim, apresentando correlações forte, moderada e fraca dos índices NDVI, EVI, MNLI e o GNDVI, com a biomassa e o PMI. Já o sensor embarcado no UAV, demonstrou maior susceptibilidade à alta densidade de biomassa da cultura, apresentando indícios de saturação em todas as bandas espectrais. Os índices de vegetação do UAV, não demonstraram correlação com os parâmetros biofísicos da cultura (PMI, biomassa seca e fresca). Recomendam-se mais estudos em relação aos parâmetros que influenciam na aquisição das imagens do UAV, para poder confirmar qualidade de aquisição das imagens desta plataforma para a cultura do amendoim.

No que diz respeito aos modelos de RNA's, foi possível prever o PMI utilizando bandas espectrais e índices de vegetação do UAV e satélite, com o uso de técnicas de aprendizado de máquinas. Por meio de modelos de RNA's do tipo MLP e RBF é possível determinar o momento ideal de colheita do amendoim. Foram encontrados neste estudo, 12 modelos capazes de prever o PMI, com 8 combinações para imagens do satélite e 4 combinações com imagens do UAV. Os índices NDVI e NDRE para o satélite e o UAV respectivamente, são capazes de prever a maturação do amendoim de forma precisa e acurada.

Os resultados deste trabalho podem ser considerados bastante promissores, pois com a determinação da maturação do amendoim de forma remota, o produtor pode gerenciar melhor as áreas a serem colhidas em função do nível de maturação em que se encontram as lavouras de amendoim, realizando assim, a colheita inteligente. Conseqüentemente, ocorrerá diminuição das perdas na colheita mecanizada, aumentando de forma significativa a lucratividade final do produtor.

Para o método de previsão da maturação do amendoim é importante a realização de pesquisas futuras que visem observar o comportamento das bandas espectrais e dos índices de vegetação em diferentes condições de cultivo e cultivares. Em relação à aplicação prática, o próximo passo é expandir as condições de coleta de dados, para desenvolver um software capaz de determinar a maturação do amendoim com base em informações extraídas de imagens aéreas e orbitais.