

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

CAMPUS UBERLÂNDIA

LARISSA SILVA DE OLIVEIRA

ESTIMATIVA DE PRODUÇÃO DO MORANGUEIRO POR ALGORITMOS DE
APRENDIZADO DE MÁQUINA A PARTIR DE IMAGENS MULTIESPECTRAIS

UBERLÂNDIA

2023

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
CAMPUS UBERLÂNDIA

LARISSA SILVA DE OLIVEIRA

ESTIMATIVA DE PRODUÇÃO DO MORANGUEIRO POR ALGORITMOS DE
APRENDIZADO DE MÁQUINA A PARTIR DE IMAGENS MULTIESPECTRAIS

Dissertação apresentada ao Programa de Pós-Graduação em Agronomia da Universidade Federal de Uberlândia, *Campus* Uberlândia, como parte das exigências para obtenção do título de Mestre.

Área de concentração: Olericultura

Orientadora: Prof.^a Dr.^a Renata Castoldi

Coorientador: Prof. Dr. George Deroco Martins

UBERLÂNDIA

2023

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

O48e
2023 Oliveira, Larissa Silva de, 1996-
Estimativa de produção do morangueiro por algoritmos de
aprendizado de máquina a partir de imagens multiespectrais [recurso
eletrônico] / Larissa Silva de Oliveira. - 2023.

Orientador: Renata Castoldi.

Coorientador: George Deroco Martins.

Dissertação (mestrado) - Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Agronomia.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2023.7002>

Inclui bibliografia.

1. Agronomia. I. Castoldi, Renata, 1982-, (Orient.). II. Martins,
George Deroco, 1987-, (Coorient.). III. Universidade Federal de
Uberlândia. Programa de Pós-Graduação em Agronomia. IV. Título.

CDU: 631

Glória Aparecida
Bibliotecária Documentalista - CRB-6/2047



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Secretaria da Coordenação do Programa de Pós-Graduação em Agronomia
 Rodovia BR 050, Km 78, Bloco 1CCG, Sala 206 - Bairro Glória, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 2512-6715/6716 - www.ppga.iciag.ufu.br - posagro@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

| | | | | | |
|-------------------------------|--|-----------------|-------|-----------------------|-------|
| Programa de Pós-Graduação em: | Agronomia | | | | |
| Defesa de: | Dissertação de Mestrado Acadêmico, 001/2023, PPGAGRO | | | | |
| Data: | Dezenove de janeiro de dois mil e vinte e três | Hora de início: | 08:00 | Hora de encerramento: | 11:30 |
| Matrícula do Discente: | 12112AGR007 | | | | |
| Nome do Discente: | Larissa Silva de Oliveira | | | | |
| Título do Trabalho: | Estimativa de produção do morangueiro por algoritmos de aprendizado de máquina a partir de imagens multiespectrais | | | | |
| Área de concentração: | Produção Vegetal | | | | |
| Linha de pesquisa: | Produção Vegetal em Áreas de Cerrado | | | | |

Reuniu-se por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agronomia, assim composta: Professores Doutores: George Deroco Martins - UFU; Sandro Manuel Carmelino Hurtado - UFU; Janaina Ferreira Guidolini - ITA; Renata Castoldi - UFU orientador(a) do(a) candidato(a).

Iniciando os trabalhos a presidente da mesa, Dra. Renata Castoldi, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovada

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Renata Castoldi, Professor(a) do Magistério Superior**, em 19/01/2023, às 12:00, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Sandro Manuel Carmelino Hurtado, Professor(a) do Magistério Superior**, em 19/01/2023, às 12:01, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **George Deroco Martins, Professor(a) do Magistério Superior**, em 24/01/2023, às 13:59, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Janaína Ferreira Guidolini, Usuário Externo**, em 25/01/2023, às 15:47, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4181066** e o código CRC **059E8B6F**.

Dedico

Aos meus pais Alexandra e Edmar, por me apoiarem durante toda minha trajetória.

À minha avó Luzia pelo apoio e ajuda.

Ao meu namorado Diego pelo apoio e incentivo durante minha trajetória acadêmica.

AGRADECIMENTOS

À Deus pela oportunidade.

Aos meus pais, Alexsandra da Silva André e Edmar Alves de Oliveira, minha avó Luzia Gonçalves de Oliveira, e meu namorado Diego Fernando Brasileiro Fagundes que me deram apoio e suporte para realização deste trabalho.

À Universidade Federal de Uberlândia (UFU), em especial ao Instituto de Ciências Agrárias (ICIAG) pelos recursos educacionais e físicos disponibilizados para a minha formação e para realização deste trabalho.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de mestrado.

Ao grupo de pesquisa NUPOL (Núcleo de Pesquisa em Olericultura) pela ajuda na condução do experimento em campo.

À Professora Dr^a. Renata Castoldi pela orientação e dedicação na condução deste trabalho.

Ao Professor Dr. George Deroco Martins pela orientação e disposição em compartilhar seus conhecimentos.

Ao servidor e Ms. Renan Zampiroli por realizar os voos e captura das imagens.

Ao aluno e técnico do LABOT, Matheus Henrique Medeiros por toda ajuda na condução do experimento.

A todos os docentes, técnicos e terceirizados da UFU que contribuíram com a realização deste trabalho.

À todas as pessoas que direta ou indiretamente contribuíram para o desenvolvimento deste trabalho.

RESUMO

A estimativa de produtividade do morangueiro é um processo manual, trabalhoso e subjetivo. Um processo de estimativa eficiente e preciso permitiria melhor gestão da cultura. Sendo assim, o objetivo do presente trabalho foi avaliar o desempenho de algoritmos de regressão: *Linear Regression* e *Support Vector Machine* na estimativa do número de frutos, massa média de frutos e número de folhas do morangueiro através de imagens multiespectrais obtidas por aeronave remotamente pilotada (ARP). O experimento foi conduzido na área experimental do Laboratório de Botânica, da Universidade Federal de Uberlândia – Campus Monte Carmelo. O delineamento experimental foi de blocos casualizados com seis tratamentos e quatro repetições. Os tratamentos consistiram de seis cultivares comerciais de morango: San Andreas, Albion, PR, Festival, Oso Grande e Guarani. O uso das diferentes cultivares teve por objetivo gerar variabilidade genética para testar a eficiência de estimativa dos algoritmos. Os voos para aquisição das imagens foram realizados semanalmente. As imagens passaram por pré-processamento para extração dos valores radiométricos de cada planta da área experimental. Tais valores foram então utilizados para treinamento dos algoritmos de predição da produção. No mesmo período coletaram-se dados de massa média de frutos, número de frutos por planta e número de folhas. Os resultados demonstraram que os algoritmos *Linear Regression* e *Support Vector Machine* são capazes de estimar no morangueiro, por meio de imagens multiespectrais obtidas por ARP, número de frutos (com acurácia de 99,55% e 84,26%, respectivamente), massa média de frutos (com acurácia de 99,91% e 89,62%, respectivamente) e número de folhas (com acurácia de 99,94% e 98,12%, respectivamente).

Palavras-chave: sensoriamento remoto; *linear regression*; *support vector machine*;

ABSTRACT

Estimating strawberry productivity is a manual, hard-working and subjective process. An efficient and accurate estimation process would allow better crop management. Thus, the objective of this work was to evaluate the performance of regression algorithms: Linear Regression and Support Vector Machine in estimating the number of fruits, average fruit mass and number of leaves of the strawberry plant through multispectral images obtained by remotely piloted aircraft (RPA). The experiment was carried out in the experimental area of the Botany Laboratory, at the Federal University of Uberlândia – Campus Monte Carmelo. The experimental design was randomized blocks with six treatments and four replications. The treatments consisted of six commercial strawberry cultivars: San Andreas, Albion, PR, Festival, Oso Grande and Guarani. The use of different cultivars aimed to generate genetic variability to test the estimation efficiency of the algorithms. Flights for image acquisition were performed weekly. The images passed through pre-processing, for the transmission of the radiometric values of each plant in the experimental area. These values were then used for training the production prediction algorithms. In the same period data were collected on average fruit mass, number of fruits per plant and number of leaves. The exciting results that the Linear Regression and Support Vector Machine algorithms are able to estimate in strawberry plants, through multispectral images transmitted by RPA, number of fruits (with accuracy of 99.55% and 84.26%, respectively), average mass of fruits (with accuracy of 99.91% and 89.62%, respectively), and number of leaves (with accuracy of 99.94% and 98.12%, respectively).

Keywords: remote sensing; *linear regression*; *support vector machine*.

SUMÁRIO

| | | |
|-------|---|----|
| 1 | INTRODUÇÃO | 8 |
| 2 | REVISÃO DE LITERATURA | 9 |
| 2.1 | Produtividade do morangueiro | 9 |
| 2.2 | Sensoriamento remoto na agricultura | 11 |
| 2.3 | Índices de vegetação | 15 |
| 2.4 | Aprendizado de máquina | 16 |
| 3 | MATERIAL E MÉTODOS | 23 |
| 3.1 | Experimento de campo | 23 |
| 3.2 | Aquisição das imagens | 26 |
| 3.3 | Pré-processamento das imagens | 26 |
| 3.3.1 | Criação de mosaicos | 26 |
| 3.3.2 | Correção atmosférica | 27 |
| 3.3.3 | Normalização radiométrica | 27 |
| 3.4 | Extração dos dados radiométricos e cálculo do índice da diferença normalizada (NDVI) | 28 |
| 3.5 | Regressão supervisionada | 29 |
| 3.6 | Análise dos algoritmos | 31 |
| 4 | RESULTADOS | 31 |
| 5 | DISCUSSÃO | 40 |
| 6 | CONCLUSÕES | 42 |
| | REFERÊNCIAS | 43 |

1 INTRODUÇÃO

A produção de morangos (*Fragaria x ananassa* Duch.) é crescente em âmbito mundial, sendo China, Polônia, Rússia e Estados Unidos os maiores produtores em área plantada. Embora o Brasil ocupe a 13ª posição no ranking produtivo mundial, destaca-se como o principal país produtor da América do Sul, com aproximadamente 165 mil toneladas de frutos produzidos, numa área de 4,5 mil hectares, sendo que, 76% da produção nacional é oriunda dos estados de Minas Gerais, Paraná e Rio Grande do Sul (ANTUNES; BONOW; REISSER JÚNIOR, 2020). Apesar da elevada produção, o cultivo do morangueiro é uma atividade agrícola que demanda conhecimento de alto nível técnico, utilização de inúmeras práticas culturais e metodologias modernas de manejo fitossanitário, além de acompanhamento contínuo, o qual normalmente é feito de forma manual no campo (DE CASTRO; SPALDING; RIEDER, 2013). Dessa forma, a utilização de ferramentas como o sensoriamento remoto pode agilizar o processo de gestão da cultura.

O sensoriamento remoto (SR) nos permite adquirir informações de objetos e superfícies por meio de sensores embarcados em plataformas, através do registro da energia eletromagnética absorvida ou refletida por esses alvos. De acordo com Franchini et al. (2018), a utilização das plataformas como aeronaves remotamente pilotadas (ARP) permite a obtenção de imagens com baixo custo e alta resolução (12 megapixels (4.000 x 3.000 px). Nesse sentido, a utilização de técnicas de sensoriamento remoto a partir da obtenção de imagens multiespectrais de alta e média resolução espacial para geração de modelos de estimativa e mapeamento da produtividade tem sido cada vez mais empregada (BERTOLIN et al., 2017).

Juntamente com o sensoriamento remoto, a aplicação de índices de vegetação e o aprendizado de máquina (IA) tem demonstrado alto desempenho na quantificação e compreensão de processos intensivos de dados em ambientes operacionais agrícolas (LIAKOS et al., 2018). Métodos de IA têm sido aplicado em diversos contextos agrícolas, incluindo fenotipagem de alto rendimento, previsão de rendimento, detecção de frutos, detecção de ervas daninhas e estudos de biomassa (MARTOS et al., 2021).

Através da inserção de dados de treinamento, a máquina aprende a realizar a tarefa com a experiência. Posteriormente, o modelo desenvolvido por meio do processo de treinamento pode ser utilizado para classificar, agrupar ou prever diversos parâmetros (BENOS et al., 2021), como fenotipar e gerenciar o cultivo de morangueiro (ZHENG; ABD-ELRAHMAN; WHITAKER, 2021), prever a coloração das folhas de morango (MADHAVI

et al., 2022), avaliar a qualidade dos frutos de morango (LI et al., 2022), identificar plantas daninhas (KHAN et al., 2021), detectar pragas e doenças em folhas de morango (SHIN et al., 2021; XIAO et al., 2020; ZHOU et al., 2021), classificar o solo cultivado com bananeira em relação a sua fertilidade (CEVALLOS; ROMERO; UNDA, 2020), estimar o tempo de colheita de morangos (YANG et al., 2019), prever o rendimento e preço de morango (NASSAR et al., 2020), reconhecer morangos maduros (LI; LI; TANG, 2018), realizar colheita automatizada de morangos (HUANG; SKLAR; PARSONS, 2020) e outras aplicações.

Apesar de existirem alguns trabalhos envolvendo a utilização do SR na cultura do morangueiro, esta técnica aplicada na estimativa de produção dessa hortaliça pode ser dificultada, já que as plantas são relativamente pequenas e, com hábito de crescimento indeterminado, ou seja, ao longo de todo o ciclo apresentam folhas, estolhos, inflorescências e frutos carnosos (ZHENG, ABD-ELRAHMAN, WHITAKER, 2021). O SR vem sendo muito aplicado na estimativa de produção de culturas anuais, as quais possuem um período específico de maturação, com uma única colheita ao longo do ciclo da cultura.

Segundo Chen et al (2019) é possível realizar a contagem de flores de morango e estimar sua produção de forma precisa utilizando sensoriamento remoto. A estimativa de produção eficiente e precisa para o morangueiro permitiria um planejamento de recursos para colheita, transporte e comercialização do produto. Normalmente, este processo de estimativa é realizado manualmente, o que é demorado, trabalhoso e subjetivo (CHEN et al., 2019). Dessa forma, o objetivo do presente trabalho foi avaliar o desempenho de algoritmos *Linear Regression* e *Support Vector Machine* na estimativa do número e massa média de frutos e número de folhas do morangueiro por meio de imagens multiespectrais obtidas por aeronave remotamente pilotada (ARP).

2 REVISÃO DE LITERATURA

2.1 Produtividade do morangueiro

A produtividade de uma cultura é determinada por um conjunto de fatores, compostos por propriedades químicas, físicas e biológicas do solo; fatores associados ao clima, como a temperatura, precipitação e suas interações com fatores bióticos como as pragas e doenças; além das características genéticas das plantas (FRANCHINI et al., 2018).

De acordo com Franchini et al. (2018) as interações das culturas com fatores bióticos e abióticos determinam alterações nos tecidos vegetais, que podem ser determinadas pela análise da radiação eletromagnética refletida. Os estresses sofridos pela planta irão causar mudanças no tecido vegetal que podem ser detectados por sensores na radiação refletida na faixa do visível ou infravermelho próximo.

Mesmo com os avanços tecnológicos utilizados atualmente na produção do morangueiro, permitindo frutos no mercado o ano todo, condições climáticas desfavoráveis podem afetar a oferta do produto, ocasionando oscilações de preços ao longo dos meses do ano. Na safra de 2019, o preço médio de mercado nos estados produtores variou de R\$ 6,78 em Minas Gerais a R\$ 20,42 em São Paulo (ANTUNES; REISSER JUNIOR, 2020). Segundo Antunes, Júnior e Schwengber (2016) o Brasil apresenta grande potencial para figurar entre os maiores produtores mundiais de morango, devido à entrada de novos produtores no mercado e a introdução de alta tecnologia em larga escala.

O Brasil é o 13º principal produtor mundial de morangos com produção média de 165.000 toneladas, ficando nas primeiras colocações China, Estados Unidos e México, com produção de 3,7 milhões, 1,4 milhões e 658 mil toneladas, respectivamente (ANTUNES; REISSER JUNIOR, 2019). A produtividade média brasileira se encontra em torno de 36 toneladas por hectare, bem abaixo dos Estados Unidos (67 toneladas/ha) e Espanha (52 toneladas/ha), ficando à frente do maior produtor mundial China, que apresenta produtividade de aproximadamente 28 toneladas por hectare (ANTUNES; REISSER JUNIOR, 2020).

No Brasil o cultivo de morango está presente em vários estados, destacando-se como principais produtores Minas Gerais, Paraná e Rio Grande do Sul, os quais apresentam produção média de 84.000 toneladas, 21.450 toneladas e 21.763 toneladas, respectivamente (ANTUNES; REISSER JUNIOR, 2019). A maior parte da produção da fruta provém de pequenas propriedades com menos de 1 hectare, sendo o custo médio de produção em sistemas convencionais de cultivo em torno de 90 mil reais ha⁻¹, e para os sistemas de cultivo fora do solo os custos giram em torno de 300 mil reais ha⁻¹ (ANTUNES; REISSER JUNIOR, 2020).

Com o avanço de novas tecnologias na agricultura e o surgimento da agricultura digital, a utilização de veículos aéreos não tripulados e imagens tem auxiliado o produtor na tomada de decisão com maior assertividade. Através destas tecnologias é possível realizar a gestão e acompanhamento de fatores atrelados à produtividade da cultura do morango.

Muhmud et al. (2020) fizeram detecção em tempo real de oídio em morangueiro, com precisão de 87%; já Sharpe; Schumann e Boyd (2020) detectaram *Eleusine indica* no cultivo de morango, com precisão de 93% e em tomate, com precisão de 77%.

Da mesma forma, Chen et al. (2019) e Abd-Elrahman et al. (2021) utilizaram imagens de alta resolução terrestre para prever o rendimento de morango.


Com o auxílio de imagens aéreas é possível ainda realizar contagem de plantas de forma a estimar a sua produção (SEREJO et al., 2021). A contagem de plantas de morango por meio de imagens obtidas de veículos aéreos não tripulados de acordo com Barreto et al. (2021) apresenta erros de previsão inferiores a 4%, demonstrando a viabilidade de estimativa automática de safras de morango.

2.2 Sensoriamento remoto na agricultura

O sensoriamento remoto (SR) dentre suas diversas interpretações pode ser definido, segundo Simonetti, Ulaby (1983) apud por Lorenzetti (2015), como a aquisição de informação de alguma propriedade de determinado objeto ou fenômeno sem que haja contato físico com o mesmo; sendo esta informação obtida pela detecção e medida de mudanças que o objeto impõe sobre o meio circundante. Ainda segundo os autores, o sensoriamento remoto é constantemente utilizado em conexão com técnicas eletromagnéticas de aquisição de informação.

Para melhor compreensão conceitual de sensoriamento remoto, é necessário identificar os quatro elementos fundamentais de suas técnicas, os quais podem ser visualizados no esquema apresentado na Figura 1.

Figura 1. Esquema representativo dos quatro elementos fundamentais das técnicas de SR.



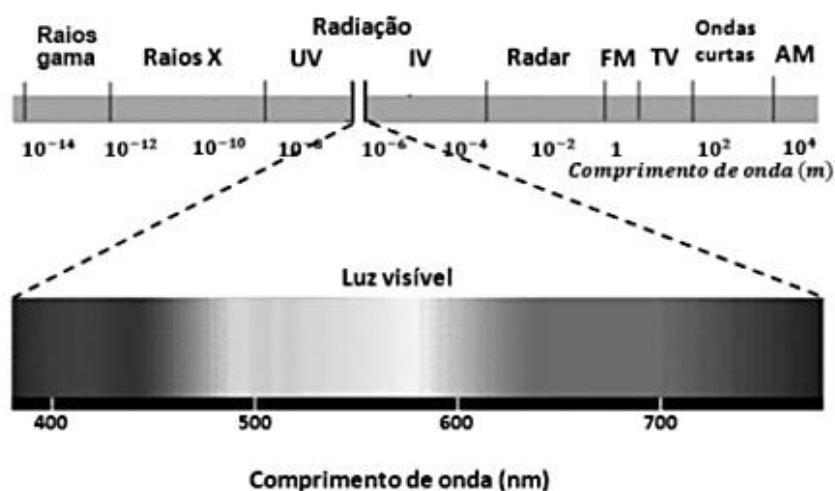
Fonte: Novo, Ponzoni (2001).

No centro do triângulo encontra-se a Radiação Eletromagnética (REM), que é o elemento de ligação entre todos os demais que se encontram nos vértices (NOVO; PONZONI,

2001). A REM é o meio pelo qual a informação de um determinado objeto na superfície terrestre é transmitida aos sensores (LIU, 2015). A fonte de REM, na aplicação das técnicas de sensoriamento remoto no estudo de recursos naturais, é o Sol; e o sensor, é o instrumento que coleta e registra a REM refletida ou emitida pelo objeto, também denominado de alvo, e que representa o elemento do qual se pretende extrair informação (NOVO; PONZONI, 2001).

O espectro eletromagnético representa a distribuição da radiação eletromagnética por regiões, de acordo com o comprimento de onda e a frequência, conforme apresentado na Figura 2 (FLORENZANO, 2007).

Figura 2. Faixas espectrais do espectro eletromagnético.



Fonte: Lorenzetti (2015).

A aplicação do sensoriamento remoto envolve um sensor montado em uma plataforma, que pode ser um satélite, aeronaves remotamente pilotadas (RPAs)/drones, veículos terrestres não tripulados ou robôs de campo (MARTOS et al., 2021). Entretanto, o uso de drones na agricultura tem se destacado por ser considerado uma plataforma útil na aquisição de dados de sensoriamento remoto adequados para medir a estrutura de cultivo de diversas culturas, uma vez que fornece maior resolução espacial e temporal e flexibilidade de operações (TU et al., 2019).

O sensor realiza a coleta da radiação eletromagnética refletida ou emitida pelas plantas, a qual é processada para produzir informações e produtos úteis na tomada de decisão agrícola. Essas informações consistem em características do sistema agrícola e suas variações no espaço e no tempo. O sensoriamento remoto fornece uma relação efetiva entre o brilho das plantas e as respectivas características bioquímicas, morfológicas, fenológicas, fisiológicas e

estruturais para extrair informações úteis, como por exemplo, índice de área foliar (IAF), teor de clorofila, teor de umidade do solo, dentre outros (MARTOS et al., 2021).

Os sensores remotos podem ser classificados como imageadores ou não imageadores, sendo que, na maioria dos casos se utilizam os sensores imageadores, com o intuito de obter imagens ou cenas de determinadas regiões ou alvos de interesse (LORENZZETTI, 2015). Atualmente, os sensores mais utilizados incluem radar de abertura sintética (SAR), infravermelho próximo (NIR), detecção e alcance de luz (LiDAR), espectroscopia e imagem de fluorescência, sensores multiespectrais e RGB, permitindo o estudo de vários parâmetros, de acordo com as necessidades (MARTOS et al., 2021).

Os sensores multiespectrais (MS) se destacam como uma das melhores opções para avaliar o crescimento das culturas, a quantidade de biomassa e vários outros indicadores bioquímicos. Os sensores MS mais comuns são capazes de registrar cinco ou seis bandas na região do espectro visível (vermelho, verde e azul - RGB) e infravermelho próximo (*Near Infra-Red* - NIR). Usando diferentes combinações algébricas dessas bandas, ampla gama de índices de vegetação pode ser calculada. (PLAZA et al., 2021).

Segundo Figueiredo (2005), a radiação solar incidente na superfície terrestre interage de modo diferente com cada tipo de alvo. Esta diferença será determinada principalmente pelas variações nas composições físico-químicas dos objetos ou feições terrestres em estudo. Estes fatores fazem com que cada alvo tenha seu próprio comportamento espectral, ou seja, cada alvo absorve ou reflete de modo diferente cada uma das faixas do espectro eletromagnético (FIGUEIREDO, 2005).

No espectro da vegetação ao longo da faixa entre 400 nm e 2.500 nm, verifica-se que, na região da luz visível (400 nm a 700 nm) há forte influência dos pigmentos foliares, que absorvem a radiação eletromagnética. Já na faixa entre 700 nm e 1.300 nm, correspondente ao infravermelho próximo ocorre predominância de reflexão devido à estrutura interna das folhas, e na faixa do infravermelho de ondas curtas (1.300 nm a 2.500 nm), existe a predominância de absorção por causa do conteúdo de umidade interna nas folhas (FORMAGGIO; SANCHES, 2017).

Revisando as aplicações de técnicas do sensoriamento remoto na cultura do morango Zheng, Abd-Elrahman, Whitaker (2021) citaram a complexidade de se trabalhar com SR na cultura, pelo fato de serem plantas relativamente pequenas em tamanho, e com hábito de crescimento complexo, incluindo a presença de folhas, estolhos, inflorescências e frutos carnosos. Para tal cultura, imagens de alta resolução espacial são necessárias para revelar a

estrutura do dossel e identificar os frutos. Sensores portáteis, bem como sensores montados em aeronaves remotamente pilotadas (ARP) e plataformas terrestres, têm sido usados para estudar várias características de fenotipagem do morango (ZHENG; ABD-ELRAHMAN; WHITAKER, 2021).

Li et al. (2021) aplicaram as técnicas de sensoriamento remoto para melhorar a estimativa de produtividade da cultura da batata por meio do uso de veículos aéreos não tripulados. Messina et al. (2021) aplicaram o SR para monitoramento do desenvolvimento da cultura da cebola e da resposta de rendimento da cultura em relação às taxas variáveis de aplicação de fertilizantes nitrogenados por meio de imagens de ARPs.

Abd-Elrahman et al. (2021) previram o rendimento de morango por meio de imagens de alta resolução, sendo que, as contagens de flores e frutos foram previstas com erros de 26,3% e 25,7%, respectivamente. Chen et al. (2019) previram o rendimento de morango com base em uma rede neural profunda, usando ortoimagens aéreas de alta resolução, com precisão média de 83% para todos os objetos detectados a 2 m de altura e 72% para todos os objetos detectados a 3 m de altura.

Diversos outros trabalhos tem sido desenvolvidos aplicando o SR na área agrícola com diferentes finalidades, como por exemplo, previsão da presença de metais no solo (TU et al., 2021); estimativa do teor de umidade do solo (GREIFEBEDER; NOTARNICOLA; WAGNER, 2021); monitoramento espacial da seca agrícola (SHAHZAMAN et al., 2021); detecção de estresse biótico em plantas (KASHYAP; KUMAR, 2021); detecção do estado nutricional das plantas (FIORENTINI; ZENOBI; ORSINI, 2021); certificação de culturas orgânicas (DENIS et al., 2021); monitoramento de pragas e doenças agrícolas (GAO et al., 2020); estimativa de biomassa (ACORSI et al., 2019); dentre outros.

A dinâmica fenológica ao longo do ciclo de uma cultura é elemento relevante para extrair informações de interesse agrícola a partir de imagens. Uma vez que, as alterações fenológicas ocasionadas em diferentes quantidades de cobertura e biomassa verde sobre a superfície do solo ao longo do ciclo da cultura, influenciam o comportamento espectral registrado nas imagens, definindo-se assim diferentes padrões em função dos tipos de cultivo, época de plantio, períodos de maior vigor vegetativo, épocas de amadurecimento e épocas de colheita (FORMAGGIO; SANCHES, 2017).

De acordo com Martos et al. (2021), as técnicas de Sensoriamento Remoto têm potencial para ser uma das tecnologias mais importantes para a agricultura atual, sendo muito

utilizado dentro da agricultura de precisão, pois permite observar lavouras em grande escala de forma sinótica, remota e não destrutiva.

2.3 Índices de vegetação

A análise de imagens da vegetação pode ser realizada através da aplicação de índices espectrais de vegetação, sendo esta a forma mais simples e eficiente identificada para análise (FERREIRA; FERREIRA; FERREIRA, 2008; apud CAMBRAIA FILHO, 2019). Os índices de vegetação (IVs) são expressões quantitativas que são calculadas a partir dos valores de reflectância dos dados de SR e estão principalmente relacionados ao estado da vegetação ou biomassa (PERROS; KALIVAS; GIOVOS, 2021). Os IVs são muito utilizados para os mais diversos estudos sobre ambientes florestais e cultivos agrícolas, servindo como base para diversas aplicações e produtos (GAIDA et al., 2020).

Existem vários IVs disponíveis para extração de informações da vegetação, sendo que, a definição do melhor índice a ser aplicado para determinadas situações é um desafio, dependendo principalmente do cenário sob investigação (SAPONARO et al., 2021). Os IV têm buscado explorar as propriedades espectrais da vegetação (folhas e outros componentes fotossinteticamente ativos), principalmente nas regiões do visível e do infravermelho próximo do espectro eletromagnético (BERGER et al., 2019).

Os índices de vegetação são obtidos pela combinação de bandas espectrais, oferecendo um mecanismo de monitoramento da dinâmica da vegetação (PASTOR-GUZMAN; DASHA; ATKINSON, 2018 apud SILVA FILHO et al., 2020). Esses índices nada mais são do que combinações de reflectâncias espectrais de duas ou mais bandas, escolhidas com o objetivo de agrupar e intensificar a relação desses dados com os parâmetros biológicos e físicos da vegetação (LOURENÇO et al., 2015 apud SILVA FILHO et al., 2020).

Um dos índices de vegetação mais utilizados tem sido o índice de vegetação por diferença normalizada (NDVI). Sua simplicidade e sua alta sensibilidade à densidade da cobertura vegetal tornaram possíveis comparações espaciais e temporais da atividade fotossintética terrestre, bem como o monitoramento sazonal, interanual e variações de longo prazo dos parâmetros estruturais, fenológicos e biofísicos da vegetação em escala global (FERREIRA; FERREIRA; FERREIRA, 2008).

O NDVI é calculado a partir da subtração da banda referente ao infravermelho próximo (NIR) e a banda do vermelho (RED), dividido pela soma das mesmas (GUEDES; DA SILVA, 2018), como pode ser visualizado na Equação 1.

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

Em que:

NIR: valor de refletância na faixa espectral do infravermelho próximo;

RED: valor de refletância na faixa espectral do vermelho.

O NDVI é um indicador sensível da quantidade e condição da vegetação verde, podendo variar de -1 até 1 (FERREIRA JÚNIOR; DANTAS, 2018). Os resultados próximos a 1 representam áreas com maior quantidade de vegetação fotossintetizante ativa, enquanto os resultados próximos a -1 geralmente representam regiões com solo nu ou corpos d'água (FRANCISCO et al., 2020).

A correlação entre a atividade fotossintética e índices vegetativos é importante no monitoramento agrícola com sensoriamento remoto e tem sido amplamente estudada (PERROS; KALIVAS; GIOVOS, 2021). Alordzinu et al. (2021) revelaram em seu estudo que o NDVI é um dos índices mais sensíveis para estimativa de estresse hídrico na cultura do tomate. Robinson (2019) demonstrou que o NDVI pode ser usado para prever a tolerância de cultivares de trigo ao nematoide *Pratylenchus thornei*. Moraes (2020) constatou que o uso do NDVI permite estimar a produção de adubos verdes, com precisão variando de acordo com a espécie.

A aplicação do NDVI e técnica de sensoriamento remoto fornecem uma série de possibilidades de monitoramento agrícola, culminando em uma melhor gestão da produção, além de antecipar a tomada de decisão em diversas culturas.

2.4 Aprendizado de máquina

O Aprendizado de Máquina (*Machine Learning* - ML) é uma área de pesquisa da inteligência artificial que tem por objetivo desenvolver programas de computador com a capacidade de aprender a executar uma dada tarefa com sua própria experiência (FACELI et al., 2011 apud CERRI; CARVALHO, 2017). O aprendizado de máquina surgiu junto com tecnologias de “*Big data*” e computação de alto desempenho, a fim de criar novas oportunidades para desvendar, quantificar e compreender processos intensivos de dados em ambientes operacionais agrícolas (LIAKOS et al., 2018).

De modo geral, os sistemas de ML operam em duas etapas: o aprendizado (usado para treinamento) e o teste. Para facilitar o processo de treinamento, vetores são criados, podendo

estes ser do tipo binário, numérico, ordinal ou nominal. Estes vetores são utilizados para inserir a informação na fase de aprendizagem (BENOS et al., 2021). Com os dados de treinamento inseridos na fase de aprendizado, a máquina aprende a realizar a tarefa com a experiência. Uma vez que o desempenho de aprendizagem atinge um ponto satisfatório (expresso por meio de relações matemáticas e estatísticas) ele termina. Posteriormente, o modelo desenvolvido por meio do processo de treinamento pode ser usado para classificar, agrupar ou prever (BENOS et al., 2021).

Segundo Liakos et al. (2018), as tarefas de aprendizado de máquina normalmente são classificadas em diferentes categorias amplas: dependendo do tipo de aprendizagem (supervisionado ou não supervisionado), modelos de aprendizagem (classificação, regressão, agrupamento e redução de dimensionalidade) ou modelos de aprendizagem empregados para implementar a tarefa selecionada. Os modelos de aprendizagem que podem ser empregados incluem: regressão, agrupamento, árvores de decisão, redes neurais artificiais (RN), máquinas de vetor de suporte (SVMs), modelos bayesianos, dentre outros. Associados a estes modelos de aprendizagem, existem algoritmos que irão atuar na realização da tarefa determinada, como por exemplo, os algoritmos *Sequential Minimal Optimization* (SMO), *Multilayer Perceptron* (MP), *Linear Regression* (RL), dentre vários outros.

A aprendizagem supervisionada utiliza dados com classes especificadas, ou seja, a instância contém um atributo classe que especifica a qual classe ela pertence. Há diversos métodos de mineração que trabalham com este tipo de aprendizado, geralmente técnicas preditivas, pois tentam prever qual a classe de uma instância não vista, baseado nos exemplos utilizados em seu treinamento (DAMASCENO, 2015).

A aprendizagem não supervisionada utiliza instâncias sem determinar o atributo de classe, sendo este método utilizado para análise exploratória dos dados por meio de técnicas de agrupamento ou associação (DAMASCENO, 2015). Técnicas de associação têm por objetivo encontrar regras que procuram associações entre atributos presentes no conjunto de dados. Já os agrupamentos têm por objetivo relacionar instâncias com características em comum (DAMASCENO, 2015).

Comparando o desempenho de algoritmos de aprendizagem de máquina na estimativa de salinidade do solo, Wang et al. (2019) verificaram que o desempenho do modelo de regressão floresta aleatória (RF) é o melhor método e o mais adequado para estimar a salinidade do solo usando dados hiperespectrais. Segundo os autores, este estudo pode

fornecer uma referência para a seleção de métodos de regressão em estudos subsequentes sobre a estimativa da salinidade do solo usando dados hiperspectrais.

Makey; Pathak; Dara (2019) em estudo comparando modelos de previsão de produção de morangos utilizando preditivo de regressão de componente principal (PPCR), redes neurais (NN) e florestas aleatórias (RF) verificaram que as três abordagens demonstraram potencial na previsão da produção de morango usando informações meteorológicas, sendo que o aprendizado de máquina forneceu previsões mais robustas quando comparadas à abordagem estatística. Mais especificamente, as NN apresentaram as melhores habilidades na previsão da produção de morango em escala de campo quando comparado aos outros métodos.

Chen et al. (2019) desenvolveram um sistema automático de detecção de flores de morangueiro utilizando redes neurais e ortoimagens. O sistema foi capaz de detectar e localizar flores e frutos de morangos no campo, bem como quantificá-los. Segundo os autores o sistema poderia ser usado para construir mapas de estimativa de produção, que poderiam ajudar os agricultores a prever a produção semanal de morangos e monitorar o resultado de cada área, a fim de economizar tempo e custos com mão-de-obra.

Sharpe, Schumann, Boyd (2020) avaliaram a incidência de capim pé-de-galinha (*Eleusine indica*) em morango e tomate, utilizando redes neurais convolucionais. Tal técnica permitiu detectar a erva daninha na produção de morangos, porém isso não foi possível na produção de tomate. Segundo os autores, a rede em estudo fornece a capacidade de detecção on-line, em tempo real e *in situ* para aplicações no manejo de ervas daninhas, como pulverização de precisão.

De modo geral, o objetivo dos algoritmos de ML é otimizar o desempenho de uma tarefa, por meio de exemplos de exploração ou de experiências anteriores. Em particular, o ML pode gerar relacionamentos eficientes em relação às entradas de dados e reconstruir um esquema de conhecimento. Nesta metodologia baseada em dados, quanto mais dados são usados, melhor funciona o ML (BENOS et al., 2021). Métodos de IA têm sido aplicados em diversos contextos agrícolas, incluindo fenotipagem de alto rendimento, previsão de rendimento, detecção de frutos, detecção de ervas daninhas e estudos de biomassa (MARTOS et al., 2021).


2.4.1. *Support Vector Machine (SVM)*

As máquinas de vetores de suporte (SVMs) constituem técnicas de aprendizado de máquina (LORENA; CARVALHO, 2007). Fundamentada na teoria da aprendizagem

estatística, as SVMs foram desenvolvidas por Vapnick (1995) com o intuito de resolver problemas de classificações padrões (GONÇALVES, 2015), sendo utilizadas em problemas de classificação e regressão (CERRI; CARVALHO, 2017).

A técnica SVM constrói um hiperplano como superfície de decisão, de forma com que a separação entre os dados seja máxima, considerando padrões linearmente separáveis. Já para padrões não linearmente separáveis, a técnica busca uma função de mapeamento para tornar o conjunto mapeado em linearmente separável, assim como demonstrado na Figura 3 (GONÇALVES, 2015).


Figura 3. Transformação de um conjunto de dados não linearmente separável em um conjunto linearmente separável.



Fonte: Lorena e Carvalho (2003).

Um hiperplano pode ser definido como um subespaço que divide um espaço único em duas partes, correspondendo aos dados de duas classes diferentes (LIMA, 2002 apud GONÇALVES, 2015). Como pode ser visualizado na Figura 4, no hiperplano é gerado uma margem que é obtida através da distância entre o hiperplano e os dados mais próximos a ele, chamados de vetores de suporte (identificados na imagem com um círculo externo). Estes vetores de suporte são utilizados como padrão crítico e fazem a determinação do hiperplano ótimo, que possui a margem máxima de separação no hiperplano, pressupondo um conjunto de dados linearmente separáveis.

Figura 4. Identificação de margem e vetores de suporte.



Fonte: Gonçalves (2015).

Dentre as principais características que tornam o uso das SVMs atrativas podemos destacar a capacidade de generalização, que os classificadores gerados por esta técnica alcançam. Essa capacidade de generalização demonstra a eficiência de um classificador em classificar dados que não pertençam ao conjunto de treinamento, além de possuírem uma teoria bem definida dentro das áreas estatística e matemática (LORENA; CARVALHO, 2003).

As SVMs apresentam menor velocidade de processamento quando comparada a outras técnicas como, por exemplo, as Redes Neurais; e quando há grande número de dados inseridos para treinamento, esse problema é ainda mais agravado. Sendo assim, algoritmos que possuem a capacidade de reduzir e melhorar o tempo de processamento e desempenho das máquinas de vetores de suporte podem ser muito úteis, como o algoritmo *Sequential Minimal Optimization* (SMO).

O algoritmo SMO busca diminuir a quantidade de operações aritméticas, reduzindo, consequentemente, o tempo de processamento das máquinas de vetores de suporte. O algoritmo também possui a capacidade de tratar conjuntos de dados esparsos, os quais possuem quantidade substancial de elementos com valor zero. Dentre os algoritmos que codificam as SVMs, o SMO é um dos algoritmos mais rápidos e que menos consomem memória (TEIXEIRA, 2014).

O SMO é utilizado para treinamento de modelos de regressão de vetor de suporte. Este algoritmo é considerado um método de regressão que possibilita a opção por parâmetros de ajuste C, podendo indicar ao algoritmo a necessidade ou não da normalização dos dados para o processo de regressão (TEIXEIRA, 2014). O parâmetro de ajuste C faz a determinação de equilíbrio entre a maximização da margem e a minimização do erro de classificação (BONESSO, 2013 *apud* TEIXEIRA, 2014).

Vários estudos têm demonstrado a versatilidade de aplicação das SVMs na agricultura. Jiang et al. (2020) aplicaram a técnica para avaliar a incidência de doenças em folhas de arroz. Chen et al. (2020) conseguiram fazer a detecção precisa de plantas daninhas em plantas de milho utilizando SVMs. Boudibi et al. (2021) aplicaram as SVMs na previsão da variabilidade espacial da salinidade do solo.

Abbas et al. (2020) testaram o potencial de quatro algoritmos: regressão linear (RL), rede elástica (EM), K-vizinho mais próximo (k-NN) e regressão de vetor de suporte (SVR) para a previsão da produção de tubérculos de batata. Os modelos SVR superaram todos os outros modelos em todos os quatro conjuntos de dados, mas em geral, todos os algoritmos funcionaram bem, explicando cerca de 60% da produção de tubérculos. Os 40% restantes de explicação podem ser de fatores externos, como mudanças climáticas e meio ambiente. Além disso, conjuntos de dados maiores podem gerar resultados mais precisos usando qualquer um dos modelos.

Peng, Zhao, Liu (2021) propuseram um novo método baseado no algoritmo de fusão de características (CCA) mais SVM, para identificação de diferentes variedades de uva. Os autores demonstraram que o método proposto pode permitir a identificação rápida e precisa de variedades de uvas. Com base no algoritmo proposto, existe o potencial de tomar medidas mais direcionadas de acordo com as diferentes características das variedades de uvas, melhorando ainda mais seu desempenho.

Li et al. (2021) utilizaram modelos de aprendizado de máquina de regressão de floresta aleatória e regressão de vetor de suporte combinados a índices de vegetação selecionados, atrelados a informações de cultivares, e constataram que há melhorias significativas na precisão da estimativa de rendimento da batata ($R^2 = 0,75-0,79$ para validação) em comparação a modelos de aprendizado de máquina usando apenas índices de vegetação ($R^2 = 0,48-0,51$ para validação).

Islam et al. (2021) avaliando a detecção precoce de ervas daninhas através de técnicas de processamento de imagem e aprendizado de máquina em cultivo de pimenta malagueta, constataram que os algoritmos floresta aleatória (RF) e máquina de vetor de suporte (SVM) são eficientes e práticos, na detecção de ervas daninhas por imagens coletadas a partir de aeronaves remotamente pilotadas (ARP).

2.4.2 *Linear Regression (RL)*

A regressão linear busca encontrar a melhor relação entre uma variável chamada de variável resposta Y e as demais variáveis da análise, que serão chamadas de variáveis independentes. A aplicação deste algoritmo busca prever valores futuros da variável resposta através da substituição dos valores das variáveis independentes em uma equação (NICOLA, 2021).

O modelo de regressão pode ser do tipo simples ou múltiplo dependendo do número de variáveis independentes existentes na análise. O modelo de regressão linear simples é definido pela relação linear entre uma variável dependente (Y) e uma variável independente (X). Já o modelo de regressão linear múltiplo se define pela relação linear existente entre uma variável dependente (Y) e várias variáveis independentes (X_1, \dots, X_p) (RODRIGUES, 2012).

Na agricultura, a aplicação de regressão linear tem sido aplicada para diferentes tipos de previsões, como por exemplo, estimativa de clorofila de folhas de citros (BARMAN; CHOUDHURY, 2020); estimativa de carbono orgânico do solo (WEHRHAN; SOMMER, 2021); previsão do rendimento de cultivares de batata (PIEKUTOWSKA et al., 2021); mapeamento da produtividade da cana-de-açúcar (CANATA et al., 2021); estimativa de produtividade da soja utilizando dados espectrais (MERCANTE et al., 2010); previsão do custo de produção da soja (LORENÇONE et al., 2019) e estimativa da produção de forragem em pastagem (DA COSTA et al., 2009).

3 MATERIAL E MÉTODOS

Na Figura 5 consta o fluxograma geral de como o estudo foi desenvolvido, sendo as etapas detalhadas posteriormente.

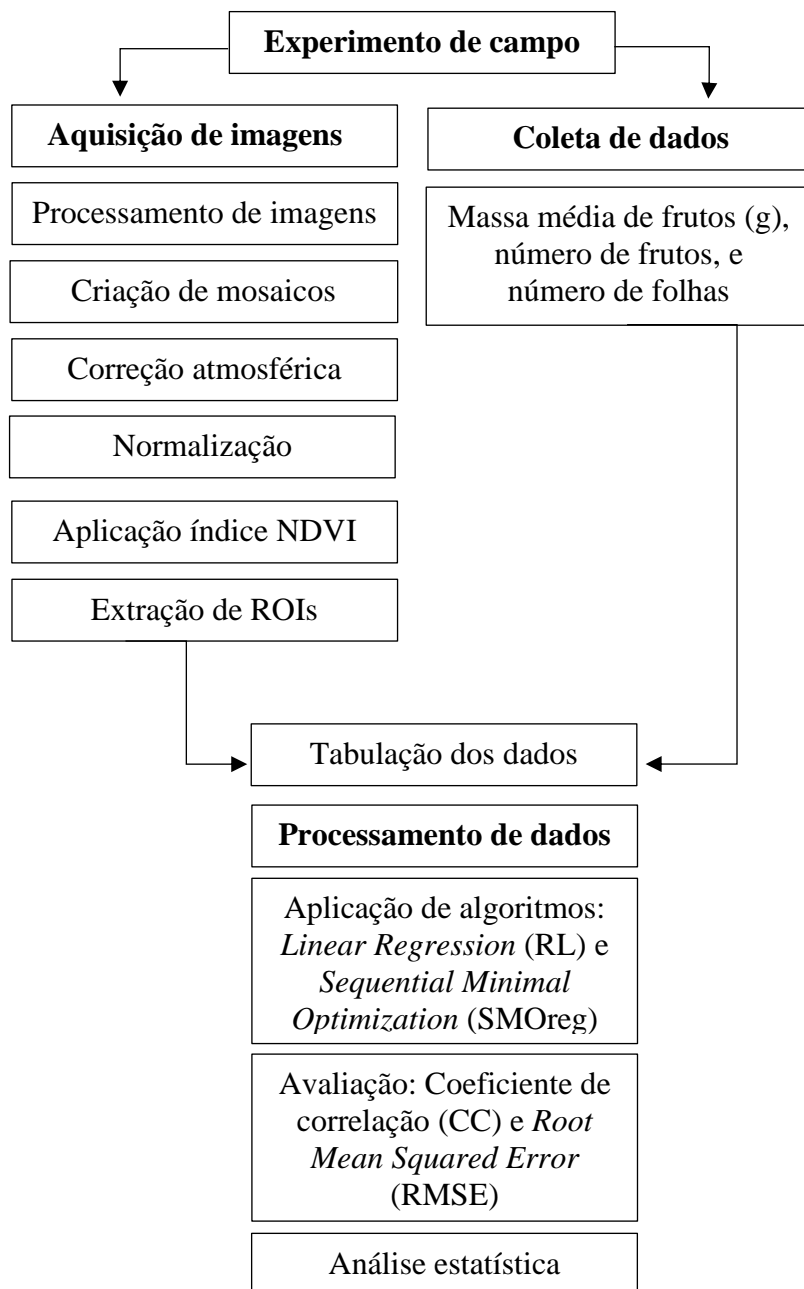


Figura 5. Fluxograma de desenvolvimento do estudo.

3.1 Experimento de campo

O experimento foi conduzido na área experimental do Laboratório de Botânica (LABOT), pertencente à Universidade Federal de Uberlândia – Campus Monte Carmelo,

localizada à 18°43'36.05" de latitude Sul, 47°31'31.77" de longitude Oeste e altitude média de 902 metros.

O solo da área experimental é classificado como Latossolo Vermelho Distrófico (EMBRAPA, 2013) e o clima da região, segundo a classificação de Köppen, é temperado úmido, caracterizado por verões quentes e invernos secos.

O delineamento experimental utilizado foi de blocos casualizados com seis tratamentos e quatro repetições, totalizando 24 parcelas experimentais. Os tratamentos consistiram de seis cultivares comerciais de morango, sendo: San Andreas, Albion, PR, Festival, Oso Grande e Guarani. O uso das diferentes cultivares teve por objetivo gerar variabilidade genética para testar a eficiência de estimativa dos algoritmos. Cada parcela experimental foi constituída de 18 plantas, distribuídas em duas linhas, espaçadas de 0,3 metros entre linhas e 0,3 metros entre plantas, sendo consideradas para avaliação dez plantas centrais de cada parcela, com área útil de 1,62 m².

As mudas foram produzidas em bandejas de polietileno de 50 células, contendo 100 mL de substrato comercial por célula, no município de Pouso Alegre – MG, por um produtor de mudas comerciais de morango.

Antes da instalação do experimento, o solo foi amostrado na profundidade de 0 a 0,2 m e levado para o laboratório de análise de solo para determinação das propriedades químicas e físicas, apresentando os seguintes resultados: textura muito argilosa com 25,5 % de areia, 7,5% de silte e 67,0 % de argila; pH em CaCl₂ = 5,4; P meq = 9,8 mg dm⁻³; K = 0,34 cmolc dm⁻³; Ca = 2,65 cmolc dm⁻³; Mg = 0,58 cmolc dm⁻³; B = 0,15 mg dm⁻³; Cu = 1,3 mg dm⁻³; Fe = 20,0 mg dm⁻³; Mn = 1,7 mg dm⁻³; Zn = 1,0 mg dm⁻³; H+Al = 1,9 cmolc dm⁻³; Zn = 1,0 mg dm⁻³; SB = 3,57 cmolc dm⁻³; T = 5,47 cmolc dm⁻³; V(%) = 65 %.

Para elevar a saturação por bases (V%) a 80%, realizou-se a calagem 60 dias antes do transplante das mudas, utilizando-se 1,7 t ha⁻¹ de calcário, distribuídos em área total (RIBEIRO; GUIMARÃES; ALVAREZ, 1999). O calcário utilizado tinha em sua composição mineral: 30% de CaO, 8% de MgO e PRNT de 80%.

Aos 50 dias após a calagem, com o auxílio de um roto-encanteirador de 1,20 metros de largura acoplada ao trator, foram feitos quatro canteiros de 21,4 metros de comprimento e 1,2 metros de largura, onde distribuíram-se os adubos de plantio.

A recomendação de adubação para todo o ciclo da cultura, seguindo as recomendações de Ribeiro, Guimarães e Alvarez (1999), foi de 220 kg ha⁻¹ de N, 200 kg ha⁻¹ de P₂O₅ e 80 kg ha⁻¹ de K₂O. A adubação de plantio representou 16% de nitrogênio, 100% de P₂O₅ e 70% de

K₂O do total, utilizando como fontes: uréia, superfosfato simples e nitrato de potássio, respectivamente. Já a adubação de cobertura foi realizada semanalmente através de fertirrigação, adicionando uréia e nitrato de potássio no sistema de irrigação, para distribuir 84% e 30% do N e K₂O restantes, respectivamente, totalizando 23 aplicações de adubo via fertirrigação em 164 dias de condução do experimento.

No dia 16 de março de 2020 realizou-se o transplante das mudas para os canteiros cobertos com filme plástico dupla face (mulching), cuja coloração preta ficou para o lado interno (contato com o solo) e a branca para o lado externo. As mudas foram colocadas nas perfurações de 75 mm de diâmetro, realizadas ao longo de todo o plástico dupla face, de acordo com a distribuição espacial das plantas nas parcelas experimentais.

O sistema de irrigação utilizado foi por gotejamento, através de dois tubos gotejadores por canteiro, com turno de rega diário, seguindo as recomendações de Kc da cultura do morango e evapotranspiração diária da estação meteorológica instalada a 200 m do local do experimento. Os gotejadores eram do tipo autocompensantes, com diâmetro de 25 mm e vazão de 1,6 L h⁻¹.

Para o controle de insetos pragas utilizaram-se o inseticida Abamectin Nortox® 400 WG, aplicado com bomba costal manual de 20 L na dosagem de 75 mL do produto para cada 100 L de calda. Para o controle de doenças aplicaram-se mensalmente os produtos Metiltiofan® na dose de 70 g do produto para cada 100 L de calda e Folicur® 200 EC com 75 g do produto para cada 100 L de calda, ambos aplicados com bomba costal de acionamento manual.

A colheita foi realizada semanalmente, iniciando-se 40 dias após o plantio (DAP) das mudas e finalizando-se 164 DAP, totalizando 16 colheitas, sendo o ponto de colheita dos frutos definido quando estes apresentavam 75% do tamanho total com coloração vermelha. Após a colheita, os frutos foram levados para o Laboratório de Botânica da Universidade Federal de Uberlândia para as avaliações produtivas. Foram determinados: número de frutos por planta e massa média dos frutos, calculado através da razão entre a massa total de frutos por planta e a quantidade de frutos por planta, sendo os valores expressos em gramas (g).

Além disso, quinzenalmente, foram avaliados número de folhas, contabilizando o número total de folhas de cada planta da área útil de todas as parcelas, totalizando para essa variável, 11 avaliações.

3.2 Aquisição das imagens

Os voos para aquisição das imagens foram realizados semanalmente entre 12 e 13 horas (horário com maior radiação), durante todo o ciclo produtivo da cultura do morango, pelo período de quatro meses (abril a agosto), totalizando dezesseis voos para as variáveis de número de frutos por planta e massa média dos frutos e; onze voos para a variável de número de folhas.

As imagens foram obtidas utilizando-se o drone Phantom 4 Pro desenvolvido pela DJI (*Da-Jiang Innovations Science and Technology Co*), o qual possui câmara visível convencional (RGB), com os canais do azul (480 nm), verde (550 nm) e vermelho (650 nm), com largura máxima a meia altura (do inglês Full Width at Half Maximum (FWHM)) de 10nm, e com resolução de 20 megapixels. Acoplada a ARP, a câmara Mapir Survey3W com resolução de 12 megapixels, com canais correspondentes ao verde (550 nm), vermelho (660 nm) e infravermelho próximo (850 nm) (RGN), e FWHMs de 40, 60 e 80nm, respectivamente.

O planejamento de voo foi elaborado utilizando-se o aplicativo gratuito Drone Deploy ©, sendo utilizada sobreposição frontal de 80% e lateral de 80%, ficando estabelecido 5 faixas, com altitude de 30 metros, velocidade de 3m/s e tempo de voo de aproximadamente 4 minutos e intervalo de captura de fotos de 3 segundos. Para todos os voos realizou-se a correção atmosférica das câmeras.

3.3 Pré-processamento das imagens


3.3.1 Criação de mosaicos

Após captura das imagens pelo sensor Mapir, os mosaicos foram construídos para cada voo realizado, no software AgisoftPhotoScan Professional. Neste software, as imagens passaram pelo alinhamento, encontrando a posição da câmara e os pontos comuns de cada imagem para combiná-las, formando uma nuvem de pontos esparsos. Posteriormente foi construída a nuvem de pontos densos, e com base nesta, foi gerada a superfície, utilizando o modelo de malha poligonal 3D, gerando os mosaicos de cada voo e sensor.

3.3.2 Correção atmosférica

A correção atmosférica visa minimizar os efeitos causados por interferências atmosféricas e topográficas nas imagens. Para realizar este processo, antes de cada voo, a câmara Mapir Survey3W capturou uma foto do alvo (Figura 6), o qual possui quatro paletes de diferentes cores (branco, preto, cinza claro e cinza escuro) de radiâncias conhecidas. A correção atmosférica foi realizada utilizando-se o software *Mapir Camera Control*.

Figura 6. Alvo de correção atmosférica da câmara Mapir Survey3W



Fonte: A autora (2021).

O processo de correção atmosférica foi realizado através da inserção dos mosaicos no software, onde especificou-se o modelo, lente (87° HFOV (19mm) f/2.8 Abertura, -1% distorção, lente de vidro) e filtro da câmara utilizada. Em seguida, fez-se a seleção da imagem contendo o alvo referente ao dia em que o voo foi realizado. A partir dessas informações, o software realizou, de forma automática, a correção atmosférica, gerando como produto final um ortomosaico corrigido.

3.3.3 Normalização radiométrica

Durante a aquisição de imagens pelos sensores, existem diversos fatores que ocasionam distorções radiométricas das imagens, como por exemplo, diferenças de iluminação, ângulo de posicionamento do sensor, velocidade do vento, presença de nuvens (SOUSA, 2012). Segundo Ponzoni, Dos Santos (2008), quando se trabalha com a caracterização espectral ao longo do tempo, e mediante a aplicação de dados de um mesmo sensor, a normalização radiométrica torna-se obrigatória.

Como sugerido por Hall et al. (1991) *apud* Ponzoni, Dos Santos (2008), o processo de normalização busca compatibilidades radiométricas entre imagens capturadas em diferentes datas. O objetivo é reduzir estas diferenças radiométricas existentes entre diferentes imagens, devido condições interferentes do momento da aquisição da imagem (MALUF et al., 2015). O intuito é que as imagens normalizadas tenham características radiométricas como se tivessem sido adquiridas sob as mesmas condições atmosféricas e de iluminação da imagem de referência (RAMIREZ; ANDERSON; FARMAGGIO, 2015).

O processo de normalização foi realizado através do programa ENVI 5.0 (*Environment for Visualizing Images*), no qual primeiramente se selecionou uma imagem de referência, e posteriormente a imagem a ser normalizada. Em seguida foi feita a seleção da região mais clara e mais escura presentes na imagem, sendo realizada a extração de valores de refletância das bandas da câmera Mapir (R – vermelho; G – verde; N – infravermelho próximo) de cada voo. Estes valores foram aplicados na Equação 2 para cada banda espectral e foram processados pela função *Band Math* do software ENVI 5.0.

$$T_i = m_i * x_i + b_i \quad (\text{Equação 2})$$

Onde:

$$m_i = (B_{ri} * D_{ri}) / (B_{si} - D_{si});$$

$$b_i = (D_{ri} * B_{si} - D_{si} * B_{ri}) / (B_{si} - D_{si});$$

T_i = refletância da imagem normalizada;

x_i = refletância da imagem original a ser normalizada;

B_{ri} = média do conjunto de referência clara;

D_{ri} = média do conjunto de referência escuro;

B_{si} = média do conjunto claro a ser normalizado;

D_{si} = média do conjunto escuro a ser normalizado;

i = bandas do sensor em estudo.

Após processamento da equação pela função *Band Math* do software ENVI 5.0, foram geradas imagens normalizadas separadas, uma para cada banda espectral, que ao final foram unidas pela ferramenta *Layer stacking* do ENVI 5.0 obtendo-se um único arquivo.

3.4 Extração dos dados radiométricos e cálculo do índice da diferença normalizada (NDVI)

Os dados radiométricos (reflectâncias da câmera Mapir) foram extraídos de 240 plantas, sendo realizado este processo para cada um dos 16 voos. A extração se deu por meio

das ortoimagens corrigidas, utilizando a função *Region of interest* (ROI) do software ENVI 5.0, no qual criou-se um polígono sobre a região de cada planta para extrair os valores radiométricos. Os valores foram tabulados para comporem o conjunto de dados.

O conjunto de dados radiométricos de 240 plantas passou pelo processo de retirada de *outliers* (dados que fogem do padrão) com o intuito de minimizar os erros gerados pelos classificadores. Os dados que fogem do padrão são referentes às plantas a qual foram atrelados valores nulos de produção, porém, não significa que tais plantas não tenham produzido, apenas que não havia frutos no ponto de colheita no momento da coleta de dados. Após retirada dos *outliers*, obteve-se um conjunto de 150 dados amostrais.

Com os valores médios das reflectâncias (câmera Mapir) calculou-se o índice da diferença normalizada, do inglês *Normalized Difference Vegetation Index* (NDVI) (Equação 3), por ser um dos índices de vegetação mais utilizados, e por apresentar alta sensibilidade à vegetação. Dentre as principais aplicações deste índice, pode-se citar: estimativa de biomassa, modelagem do rendimento de grãos e indicação da sanidade das plantas no monitoramento de doenças e deficiências nutricionais (SANTOS, 2018).

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (\text{Equação 3})$$

Em que:

NIR: valor de refletância na faixa espectral do infravermelho próximo;

RED: valor de refletância na faixa espectral do vermelho.

3.5 Regressão supervisionada

Os valores radiométricos tabulados foram utilizados para treinamento dos algoritmos classificadores disponíveis no software WEKA 3.9.4, sendo eles: *Linear Regression* e *Support Vector Machine* (SVM). A aplicação dos algoritmos foi feita utilizando as configurações padrões do software WEKA: RL (attributeselectionmethod: M5 method; batchsize: 100; debug: false; donotcheckcapabilities: false; eliminatedcolinearattributes: true; minimal: false; numdecimalplaces: 4; outputadditionalstats:false; ridge1.0E-8; useQRdecomposition:false) e SVM (batchsize: 100; c:1.0; debug: false; donotcheckcapabilities: false; filtertype: normalize raining data; kernel: Polykernel-E1.0-C250007; numdecimalplaces: 2; regoptimizer: RegSMOimproved), sendo o parâmetro de performance, a função *Cross validation*

(validação cruzada), com número de *folds* igual ao número de amostras presentes no conjunto de dados inseridos, totalizando 150 amostras por voo.

O *Cross Validation* é uma métrica que avalia o desempenho dos algoritmos classificadores, dividindo o conjunto inicial de dados em i subconjuntos, sendo i definido pelo número de *folds*. A partir dos i subconjuntos, um deles fica retido, servindo como dados de teste e o restante dos $i-1$ subconjuntos são utilizados como dados de treinamento (PIMENTA et al., 2009). Este processo é repetido i vezes, sendo que cada subconjunto é usado pelo menos uma vez como conjunto de teste. Ao final, o *Cross Validation* gera dados estatísticos a respeito do conhecimento induzido (PIMENTA et al., 2009).

O conjunto de dados utilizado para regressão, constituiu-se dos dados coletados em campo referente a massa média de frutos, número de frutos e número de folhas, bem como dos valores de dados radiométricos da câmera Mapir. Foram realizadas duas regressões no software WEKA, uma aplicando o algoritmo classificador *Linear Regression* e outra utilizando o algoritmo *SVM*, ambos foram aplicados para as três variáveis em análise (massa média de frutos, número de frutos e número de folhas).

O algoritmo *Linear Regression* busca uma função que mapeie os registros do banco de dados em valores reais, baseado no conjunto de dados, uma função linear é obtida e pode ser utilizada para fazer previsões de uma variável em função da outra. Obtendo-se um modelo que permite a detecção de padrões, previsão de saída, conclusões baseadas nos conjuntos de dados fornecidos (SCARAVONATTI, 2015). A análise do desempenho de predição de modelos de regressão linear não é fácil, uma vez que o valor a ser predito assume valores numéricos, não sendo possível afirmar se o valor predito está correto ou não. Sendo assim, a maioria das medidas de precisão utilizadas nos problemas de regressão se baseiam na diferença entre valor predito pelo algoritmo e o valor real (SCARAVONATTI, 2015).

O algoritmo *SVM* é uma implementação do SMO que codifica as SVMs, considerado um método de regressão. O algoritmo trabalha com a construção de um hiperplano como superfície de decisão, separando os dados com uma margem máxima para conjuntos de dados linearmente separáveis. Vários estudos têm demonstrado as possibilidades de aplicação deste algoritmo na área agrônômica, como estimativa de produtividade (MICHELON et al., 2017), classificação de doenças de plantas (ARAVIND et al., 2018), diferenciação de comportamento espectral de plantas de batata infestadas com virose (GRIFFEL; DELPARTE; EDWARDS, 2018), detecção de plantas daninhas (CHEN et al., 2021) e classificação de textura do solo (BARMAN; CHOUDHURY, 2020).

3.6 Análise dos algoritmos

O desempenho dos algoritmos de RL e SVM foi analisado por meio do coeficiente de correlação (CC) e erro quadrático médio (RMSE). O CC determina o quão relacionadas as variáveis de massa média, número de frutos e folhas do morangueiro estão com as bandas espectrais do NDVI (infravermelho próximo e vermelho). Já o RMSE determina o quanto o algoritmo erra em sua estimativa em relação ao valor real medido em campo.

Calculado o CC e o RMSE, aplicou-se o teste T de Student para os dados que atenderam os pressupostos exigidos para aplicação do teste (distribuição normal dos dados, normalidade residual, homogeneidade de variâncias e aditividade), a fim de analisar se havia diferença entre os algoritmos. Apenas a característica número de folhas, avaliada no voo 5 atendeu a esses pressupostos, sendo, portanto, aplicado o teste T de Student somente para tal característica e voo.

Para os demais voos que não atenderam aos pressupostos exigidos para aplicação do teste T de Student, aplicou-se o teste equivalente de Mann-Whitney-Wilcoxon, que apresenta mesma função. Porém, ao contrário do teste T de Student, que analisa as médias de dois grupos para determinada característica, o teste de Mann Whitney analisa as medianas de dois grupos, a fim de determinar se há ou não diferença entre eles para alguma característica. Os testes foram aplicados por meio do software estatístico R Studio, versão 4.1.2 (R CORE TEAM, 2021).

Foi realizada análise dos 16 voos em conjunto, bem como dos voos individualmente. Na análise geral dos voos, os valores de coeficiente de correlação (CC) e RMSE gerados pelos algoritmos RL e SVM, foram analisados pelo teste estatístico de Mann-Whitney-Wilcoxon, com o intuito de determinar se havia diferença entre ambos os algoritmos ao determinar CC e RMSE. Também se analisou os voos individualmente a fim de determinar qual algoritmo teve melhor desempenho de estimativa das variáveis de massa média de frutos, número de frutos e número de folhas para cada voo realizado.

4 RESULTADOS

Comparando os valores de correlação (CC) dos algoritmos RL e SVM, os quais determinam o quão relacionada duas ou mais variáveis estão, verifica-se que não houve diferença significativa entre os dois algoritmos ao tentar correlacionar massa média de frutos, número de frutos e número de folhas com as bandas espectrais do infravermelho próximo (NIR) e vermelho (R) (Tabela 1). Para a variável número de folhas, através do algoritmo RL,

obteve-se o maior valor médio de correlação (0,82) com as bandas espectrais NIR e R, as quais compõem o NDVI aplicado nas imagens em estudo (Tabela 1). Enquanto que os valores de correlação atrelados às variáveis massa média de frutos e número de frutos foram de 0,51 e 0,42, respectivamente, ou seja, correlação mais baixa quando comparada a correlação de número de folhas com as bandas espectrais (Tabela 1).

Tabela 1. Teste de Mann-Whitney-Wilcoxon para correlação entre as variáveis agronômicas e as bandas espectrais (CC) e RMSE das variáveis massa média de frutos, número de frutos e número de folhas referentes aos algoritmos RL e SVM de 16 voos.


| | Massa média de frutos | | Número de frutos | | Número de folhas | |
|--------------------|--------------------------------|--------------------------------|--------------------------------|--------------------------------|-------------------------------|-------------------------------|
| | CC | RMSE | CC | RMSE | CC | RMSE |
| M (p-valor) | 120 (0,7804 ^{ns}) | 131 (0,9260 ^{ns}) | 121 (0,8091 ^{ns}) | 121 (0,8065 ^{ns}) | 27 (0,1797 ^{ns}) | 10 (0,2403 ^{ns}) |
| MRL | 0,5180 | 14,2046 | 0,4290 | 1,5022 | 0,8213 | 2,8497 |
| MSVM | 0,5427 | 13,9049 | 0,4393 | 1,5268 | 0,7032 | 10,2891 |

CC: coeficiente de correlação. RMSE: erro quadrático médio. MRL: média do algoritmo de Regressão Linear. MSVM: média do algoritmo de Support Vector Machine. M: valor do teste de Mann-Whitney-Wilcoxon a 5% de significância. *P-valor*: probabilidade F de Snedecor.


Dentre as variáveis analisadas, o número de folhas foi a que se demonstrou mais correlacionada com as bandas espectrais, como pode ser visualizado na Tabela 1, sendo possível inferir que este parâmetro ocasionou em camuflagem das demais variáveis em estudo, no que tange a resposta espectral da planta.

Ao longo do ciclo da cultura do morango, os maiores valores de correlação entre as bandas espectrais do vermelho e infravermelho próximo com as variáveis massa média de frutos (Figura 7A) e número de frutos (Figura 7B) foram obtidos nos voos de 1 a 5 e nos voos 10 a 16, e os menores valores foram obtidos nos voos de 6 a 9. Para este mesmo período, os valores de correlação para o número de folhas (Figura 7C) foram acima de 0,8, confirmando que a reflectância atrelada a esta variável é mais sensível as características foliares em relação ao comportamento espectral das variáveis massa média de frutos e número de frutos.

Isso é comprovado, pois para a mesma janela de tempo em que se tem correlação mais alta (RL: 0,82 e SVM: 0,70) das bandas espectrais do vermelho e infravermelho próximo com o número de folhas, tem-se correlação mais baixa das bandas espectrais com os parâmetros de massa média de frutos (RL: 0,51 e SVM: 0,54) e número de frutos (RL: 0,42 e SVM: 0,43). Isso ocorreu pois no período dos voos de 6 a 9 houve aumento do número de folhas por planta e, na região do infravermelho próximo, as plantas tem sua reflectância afetada pelo aumento do índice de área foliar.



(B)



(C)

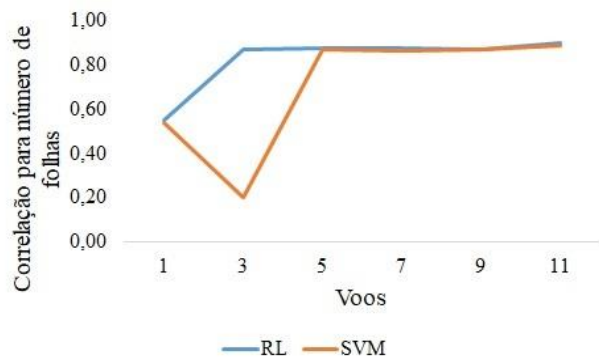


Figura 7. Valores de coeficiente de correlação dos algoritmos de RL e SVM referentes a massa média de frutos (A), número de frutos (B) e número de folhas (C) das seis cultivares de morangueiro, durante todos os voos realizados.

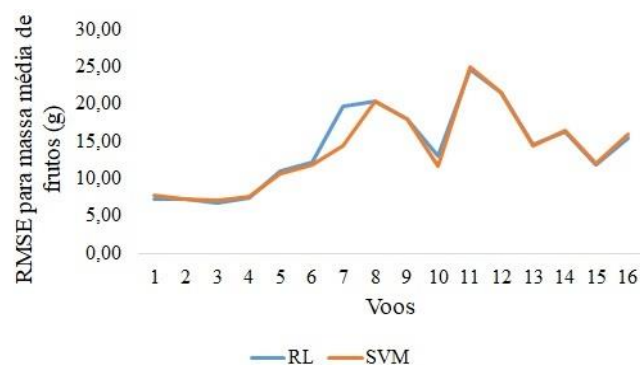
Em relação ao RMSE, que determina o erro entre o valor medido em campo e o estimado pelo algoritmo, podemos observar que não houve diferença significativa entre os algoritmos RL e SVM para as variáveis em estudo (Tabela 1). Para a variável massa de frutos, os erros médios entre os valores estimados e medidos em campo foram de 14,2 g planta⁻¹ e de 13,9 g planta⁻¹ para os algoritmos RL e SVM, respectivamente. Para a variável número de frutos, os erros médios foram de 1,5 e 1,53 frutos planta⁻¹ para os algoritmos RL e SVM, respectivamente. Já para o número de folhas, os erros médios foram de 2,8 e 10,28 para os algoritmos RL e SVM, respectivamente.

A variável massa média de frutos apresentou menores valores de RMSE nos voos 1 a 6, 10 e 13 a 16, havendo picos nos voos 7, 8, 9, 11 e 12, onde foi obtido maiores erros de estimativa em relação a massa real de frutos (Figura 8A). Neste mesmo período, a correlação de massa média de frutos com as bandas espectrais foi menor (Figura 7A), e o número de folhas por planta apresentou crescimento (Figura 7C), demonstrando que as plantas estavam passando por um momento de maior investimento energético em desenvolvimento vegetativo, no qual sua energia e fluxo de nutrientes estavam sendo fortemente direcionados para produção de folhas.

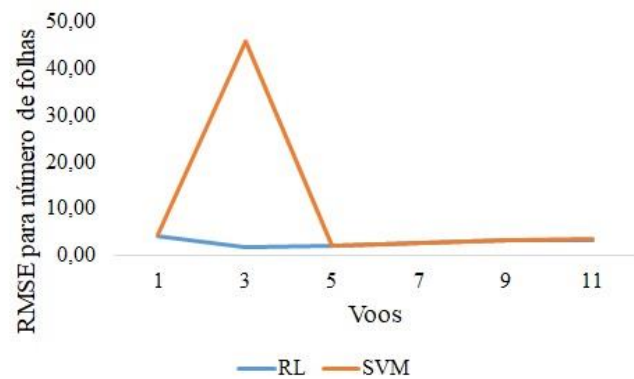
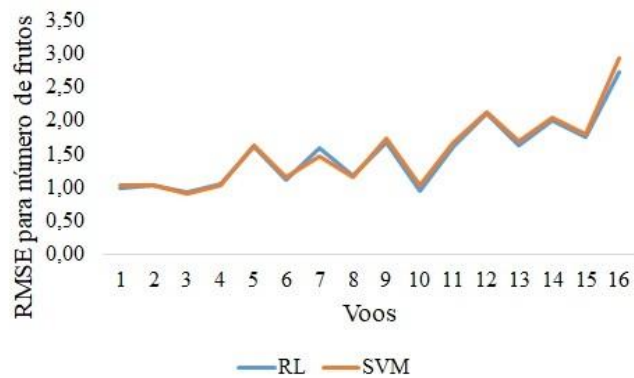
Na região do infravermelho próximo quanto maior o índice de área foliar, maior é a reflectância, pois a maior parte da energia refletida nessa faixa do espectro eletromagnético é atribuída a estrutura interna das folhas. Isso pode ter reduzido o comportamento espectral da planta em relação a variável massa média de frutos.

Em relação a variável número de frutos por planta, podemos observar que o comportamento dos algoritmos estimadores são semelhantes, com erros variando de 1 a 2 frutos para a maioria dos voos, com exceção dos voos 12 e 16 que atingiram erros acima de 2 frutos planta⁻¹ (Figura 8B). Já a variável número de folhas, apresentou o mesmo padrão de valores de RMSE ao longo de todo período analisado, com RMSE abaixo de 5 folhas planta⁻¹, exceto no voo 3, utilizando o algoritmo SVM, com pico de erro de 45,83 folhas planta⁻¹ (Figura 8C).

(A)



(B)



(C)

Figura 8. Valores da raiz do erro quadrático médio (RMSE) dos algoritmos RL e SVM, referentes a massa média de frutos (A), número de frutos (B) e número de folhas (C) de seis cultivares de morangueiro durante todos os voos realizados.

Comparando a massa média de frutos medido em campo (MMC) com os valores médios estimados pelos algoritmos RL e SVM, podemos observar que ambos são eficientes ao estimar massa média de frutos, com valores bem próximos aos obtidos em campo (Tabela 2).

Tabela 2. Valores de massa média de frutos medido em campo (MMC), massa média de frutos estimada pelos algoritmos de Regressão Linear (MRL) e *Support Vector Machine* (MSVM) referentes aos 16 voos realizados, e valores do teste de Mann-Whitney (M) e *P-valor*.

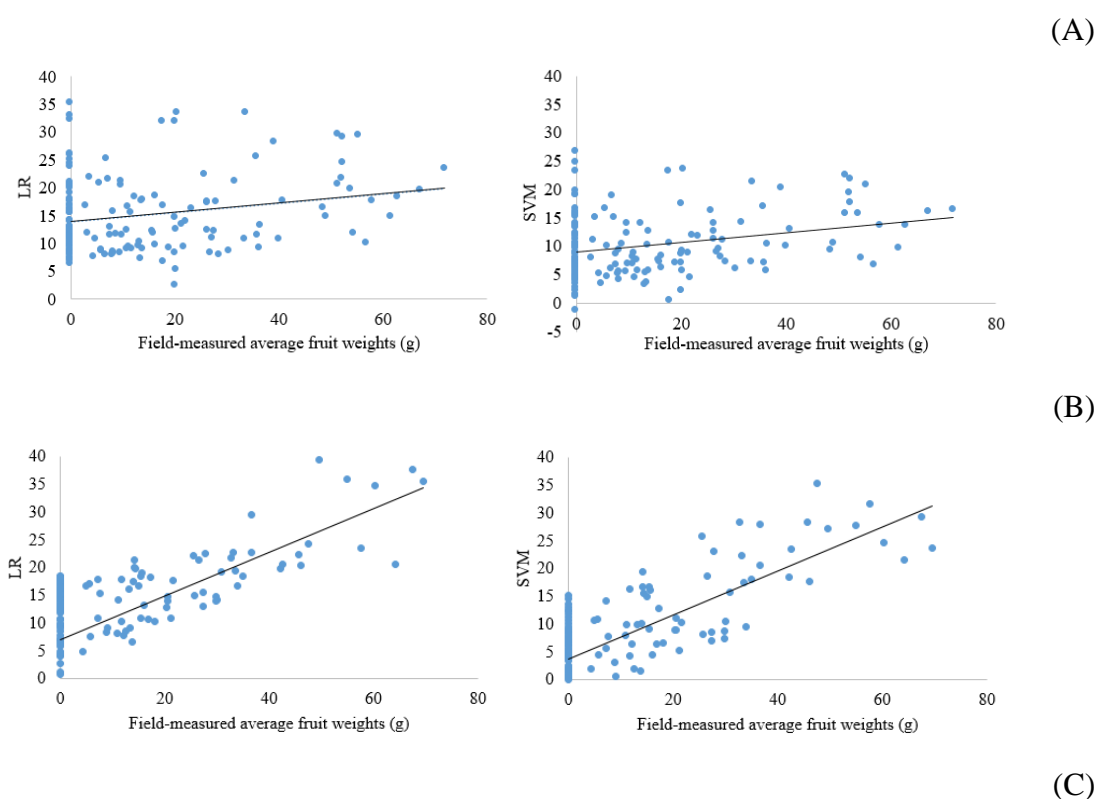
| Voo | MMC | MRL | MSVM | M | <i>P-valor</i> |
|-----|-------|-------|-------|-------|----------------|
| 1 | 13,40 | 13,45 | 12,56 | 10254 | 0,5028 |
| 2 | 14,91 | 14,92 | 14,45 | 11776 | 0,2423 |
| 3 | 13,43 | 13,48 | 12,15 | 13082 | 0,0148 |
| 4 | 12,91 | 12,91 | 11,65 | 12782 | 0,0416 |
| 5 | 18,24 | 18,16 | 17,62 | 11576 | 0,6643 |
| 6 | 14,77 | 14,80 | 13,46 | 13794 | 0,0007 |
| 7 | 12,90 | 11,69 | 11,35 | 12529 | 0,0888 |
| 8 | 20,93 | 20,95 | 17,20 | 13987 | 0,0002 |
| 9 | 14,79 | 15,17 | 10,28 | 16215 | <0,0001 |
| 10 | 10,94 | 11,33 | 8,06 | 14408 | <0,0001 |

| | | | | | |
|-----------|-------|-------|-------|-------|---------|
| 11 | 35,88 | 35,92 | 32,15 | 12736 | 0,0480 |
| 12 | 35,61 | 35,66 | 34,56 | 11632 | 0,6116 |
| 13 | 22,46 | 22,43 | 18,12 | 15231 | <0,0001 |
| 14 | 28,53 | 28,52 | 26,91 | 12168 | 0,2222 |
| 15 | 22,61 | 22,62 | 20,95 | 12372 | 0,1353 |
| 16 | 29,11 | 29,12 | 26,66 | 12814 | 0,0373 |

MMC: massa média de frutos medido em campo. MRL: massa média de frutos estimado pelo algoritmo de Regressão Linear. MSVM: massa média de frutos estimado pelo algoritmo de *Support Vector Machine*. M: valor do teste de Mann-Whitney-Wilcoxon a 5% de significância. *P-valor*: probabilidade F de Snedecor.

Analisando o desempenho dos algoritmos por voo, temos que o algoritmo RL apresentou maior precisão de estimativa de massa média de frutos para a maioria dos voos realizados. Para os voos 1, 2, 5, 7, 12, 14 e 15, os algoritmos RL e SVM não apresentaram diferença significativa (Tabela 2).

Na Figura 9 podemos visualizar os voos 9, 10 e 13 mais significativos, com as estimativas de massa média de frutos realizados pelos algoritmos.






Figura 9. Valores de massa média de frutos estimados pelos algoritmos RL e SVM referentes aos voos 9 (A), 10 (B) e 13 (C), em função dos valores medidos em campo.

De acordo com a Tabela 3, verifica-se que tanto o algoritmo RL, quanto o SVM, conseguem estimar o número de frutos por planta com valores próximos dos valores reais, se apresentando como uma alternativa para contagem de frutos a campo.

Tabela 3. Valores de número de frutos medido em campo (NFR), estimativa média de número de frutos feita pelos algoritmos de Regressão Linear (MRL) e *Support Vector Machine* (SVM) referentes aos 16 voos realizados, e valores do teste de Mann-Whitney (M) e *P-valor*.


| Voo | NFR | MRL | MSVM | M | <i>P-valor</i> |
|-----|------|--------|--------|-------|----------------|
| 1 | 1,57 | 1,5744 | 1,4630 | 10946 | 0,0901 |
| 2 | 1,72 | 1,7184 | 1,5614 | 12658 | 0,0609 |
| 3 | 1,53 | 1,5274 | 1,4421 | 11452 | 0,7880 |
| 4 | 1,41 | 1,4147 | 1,2213 | 13011 | 0,0191 |
| 5 | 1,85 | 1,8288 | 1,4734 | 14002 | <0,0001 |
| 6 | 1,36 | 1,3642 | 1,0128 | 20019 | <0,0001 |
| 7 | 1,24 | 1,1763 | 0,8772 | 17304 | <0,0001 |
| 8 | 1,58 | 1,5778 | 1,5085 | 12060 | 0,2815 |
| 9 | 1,28 | 1,2787 | 1,0365 | 16448 | <0,0001 |
| 10 | 0,87 | 0,8702 | 0,6689 | 12336 | 0,1487 |
| 11 | 2,53 | 2,5269 | 2,0925 | 14276 | <0,0001 |
| 12 | 3,05 | 3,0565 | 2,7142 | 13395 | 0,0043 |
| 13 | 2,08 | 2,0780 | 1,6193 | 15112 | <0,0001 |
| 14 | 2,57 | 2,5745 | 2,2054 | 13260 | 0,0075 |
| 15 | 2,54 | 2,5412 | 2,1691 | 14137 | 0,0001 |
| 16 | 3,49 | 3,4278 | 2,7874 | 15640 | <0,0001 |

NFR: média de número de frutos por planta medido em campo. MRL: média do número de frutos estimado pelo algoritmo de Regressão Linear. MSVM: média do número de frutos estimado pelo algoritmo de *Support Vector Machine*. M: valor do teste de Mann-Whitney-Wilcoxon a 5% de significância. *P-valor*: probabilidade F de Snedecor.

Para número de frutos por planta, o algoritmo RL demonstrou ser mais eficiente do que o SVM, pois os valores se aproximaram mais daqueles valores medidos em campo (Tabela 3). Ambos algoritmos foram estatisticamente iguais, ao tentar estimar o número de frutos nos voos de 1, 2, 3, 8 e 10.

Os voos que apresentaram as estimativas mais significativas para número de frutos por planta realizada pelos algoritmos de RL e SVM foram os voos 4 a 7; 9 e 11 a 16, entretanto apenas as estimativas referente aos voos 13 e 16 foram apresentadas (Figura 10).

(A)



(B)




Figura 10. Valores de número de frutos estimados pelos algoritmos RL e SVM referentes aos voos 13 (A) e 16 (B), em função dos valores medidos em campo.

Na Tabela 4, tem-se o desempenho dos algoritmos RL e SVM por voo, referentes a variável número de folhas por planta. Podemos observar que os algoritmos conseguem estimar a quantidade de folhas por planta com eficiência.

Tabela 4. Valores de número de folhas medido em campo (NFLC), estimativa média de número de folhas feita pelos algoritmos de Regressão Linear (MRL) e *Support Vector Machine* (MSVM) referentes aos 11 voos realizados, e valores do teste T de Student (T), de Mann-Whitney (M) e *P-valor*.

| Voo | NFLC | MRL | MSVM | T | M | <i>P-valor</i> |
|-----|-------|---------|---------|--------|-------|----------------|
| 1 | 9,28 | 9,2806 | 8,3424 | | 13377 | 0,0022 |
| 3 | 8,63 | 8,6644 | 12,5200 | | 10989 | 0,7288 |
| 5 | 10,24 | 10,2433 | 10,0480 | 0,4451 | | 0,6565 |
| 7 | 12,62 | 12,6194 | 12,7557 | | 10955 | 0,6950 |
| 9 | 13,32 | 13,3196 | 13,0958 | | 11392 | 0,8511 |
| 11 | 15,13 | 15,0989 | 14,9453 | | 11334 | 0,9115 |

NFLC: número de folhas medido em campo. MRL: média do número de folhas estimado pelo algoritmo de Regressão Linear. MSVM: média do número de folhas estimado pelo algoritmo de *Support Vector Machine*. T: valor do teste T de Student a 5% de significância. M: valor do teste de Mann-Whitney-Wilcoxon a 5% de significância. *P-valor*: probabilidade F de Snedecor.

Para o parâmetro número de folhas, os algoritmos RL e SVM apresentaram estimativas estatisticamente iguais, exceto no voo 1, no qual o algoritmo RL foi melhor, conforme pode ser visualizado na Figura 11, que traz a estimativa do número de folhas planta¹ feita pelos algoritmos de RL e SVM no voo 1.

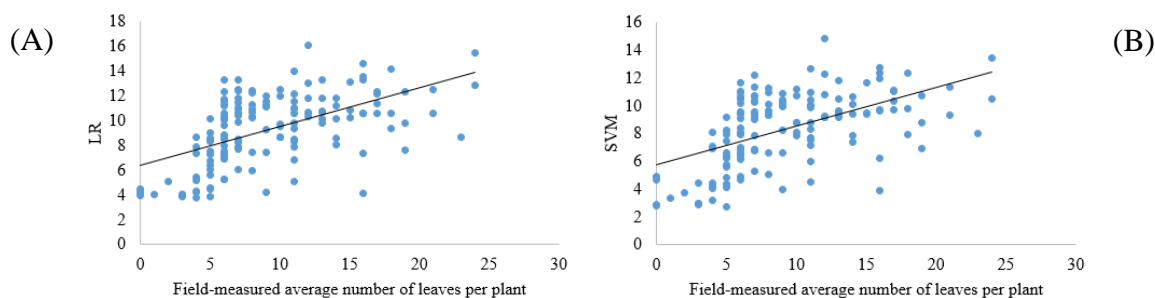


Figura 11. Valores de número de folhas estimados pelos algoritmos RL (A) e SVM (B), referentes ao voo 1, em função dos valores medidos em campo.

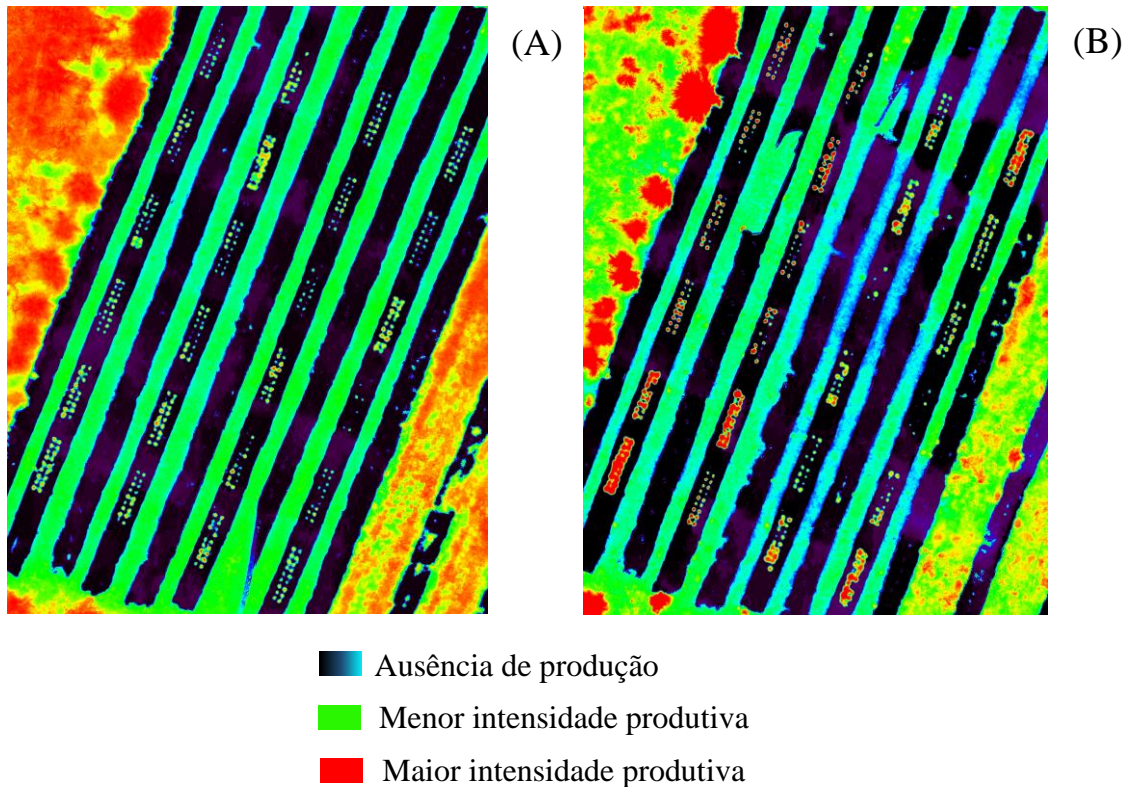
Em relação a estimativa total, quando comparada aos valores obtidos em campo, verifica-se que o algoritmo RL foi mais assertivo ao realizar sua estimativa em relação ao algoritmo SVM. A massa total de frutos obtida em campo foi de 48,08 kg em uma área útil de 21,6 m², o equivalente a 22.259,26 kg ha⁻¹. A estimativa de massa de frutos feita pelo algoritmo RL foi de 48,04 kg, cerca de 22.240,74 kg ha⁻¹. Já o algoritmo SVM, para massa de frutos, estimou 43,09 kg, cerca de 19.949,07 kg ha⁻¹. Comparando a estimativa total com o obtido em campo para massa média de frutos, observa-se que o algoritmo RL, conseguiu estimar cerca de 99,91% do valor real, enquanto SVM estimou 89,62%.

O número total de frutos obtido em campo foi de 4.585 frutos, sendo este parâmetro melhor estimado quando aplicado o algoritmo RL (99,55% do valor real de número de frutos), enquanto que ao aplicar o algoritmo SVM a estimativa ficou em torno de 84,26% do total de frutos obtidos a campo. Já para o número de folhas ambos os algoritmos conseguiram estimar valores próximos ao real. O total de folhas obtido em campo foi de 10.366 folhas, e os algoritmos RL e SVM estimaram 10.360,31 e 10.171,89 folhas, respectivamente. Para este parâmetro, os algoritmos RL e SVM estimaram 99,94% e 98,12% do valor real.

Na Figura 12, são apresentadas as imagens NDVI referentes ao primeiro e último voo realizados, a fim de demonstrar a diferença espectral entre os dois períodos de análise. Quanto mais próximas as plantas estão da coloração verde, menor a intensidade de produção, no momento em que a captura da imagem foi realizada. Enquanto que, quanto mais intensa a coloração vermelha destas plantas, maior a intensidade produtiva de área foliar e de frutos. Sendo assim, podemos distinguir as regiões mais e menos produtivas, bem como a diferença

de comportamento espectral das plantas nas diferentes fases do ciclo produtivo do morangueiro. Na imagem 12A, tem-se o primeiro voo, o qual foi realizado em fase inicial de desenvolvimento da cultura, caracterizado pelo crescimento e desenvolvimento vegetativo. Já na imagem 12B, tem-se a representação da fase de alto vigor da produção de frutos.

Figura 12. Imagem NDVI da área experimental referentes ao voo 1(A) e ao voo16 (B).



Fonte: A autora (2023).

5 DISCUSSÃO

Os algoritmos RL e SVM conseguiram estimar as variáveis analisadas, não apresentando diferenças entre os coeficientes de correlação e RMSE ao analisar todos os voos. Porém, ao analisar os voos separadamente, o algoritmo RL foi o que se destacou para estimar as variáveis massa média e número de frutos, sendo que para a variável número de folhas, não houve diferença significativa entre os algoritmos para a maioria dos voos. Da mesma forma, Li et al. (2020) ao estimarem a biomassa e rendimento de batata por meio de aprendizado de máquina e sensoriamento remoto, obtiveram que na estimativa de biomassa (RMSE = 5,8) e produtividade (RMSE <20%), o melhor método de análise foi o RL, o qual apresentou maior precisão de estimativa na fase de formação de tubérculo.

Dentre os parâmetros avaliados, o número de folhas foi o que apresentou maior correlação com as bandas espectrais (SVM: 0,70 e RL: 0,82), possivelmente pelo fato do dossel vegetativo das plantas, principalmente na região do infravermelho próximo absorver baixa quantidade de energia, ocasionando, conseqüentemente, alta refletância. Sendo assim, quando correlacionamos o número de folhas com as bandas aplicadas por meio do NDVI, esse parâmetro agrônômico se sobressai em relação às variáveis de massa média e número de frutos.

Os valores de correlação das variáveis massa média e número de frutos apresentaram baixa correlação com as bandas espectrais nos voos 6 a 9 e, neste mesmo intervalo de tempo, observou-se alta correlação com a variável número de folhas. Isso ocorreu possivelmente devido ao maior potencial em refletir energia nas bandas espectrais em questão, havendo maior expressão de energia para esta variável, quando comparada a resposta espectral atrelada a massa média e número de frutos. Isso pode ocorrer, pois a planta de morangueiro passa por vários estádios fisiológicos ao mesmo tempo (presença de folhas, frutos e inflorescências), dificultando a caracterização da resposta espectral da planta para determinados parâmetros agrônômicos.

Os valores de RMSE para as variáveis massa média e número de frutos podem ser considerados baixos, demonstrando que ambos os algoritmos são capazes de estimar estas variáveis. Para a variável número de folhas, o erro entre valor medido em campo e estimado pelo algoritmo SVM foi elevado, pelo fato de que no voo de número 3 (Figura 8C), devido a presença de um *outlier* no banco de dados, gerou-se um alto erro de número de folhas por planta (45,83 folhas planta⁻¹), o que elevou o valor de RMSE desta variável. Já o algoritmo RL, para esta mesma variável e mesmo voo conseguiu estimar normalmente, com baixo valor de erro médio (2,84 folhas planta⁻¹). Levando em consideração, que o algoritmo SVM conseguiu estimar o número de folhas, com baixos valores de erros para os voos de 1 a 11, com exceção do voo 3; e que o algoritmo RL, utilizando o mesmo banco de dados que SVM, conseguiu estimar número de folhas com baixos erros, podemos inferir que a elevação do RMSE ocasionada pelo voo 3 é devido a presença de algum *outlier*.

Chen et al. (2019) realizaram a previsão de rendimento de morango utilizando rede neural profunda por meio de ortoimagens aéreas de alta resolução, obtendo como resultado, precisão média de 91,0% para detecção de frutos maduros da variedade Sensation, com aquisição de imagem a 2 m de altura, e precisão média de 84,1% para contagem de flores. Isso demonstra que o uso deste sistema pode fornecer contagens precisas de flores e frutos de

morango. Abd-Elrahman et al. (2021) também conseguiram prever o rendimento de morango por meio de imagens, sendo que as contagens de flores e frutos foram previstas com erros de 26,3% e 25,7%, respectivamente.

Analisando os voos separadamente, constatou-se que o algoritmo RL é mais eficiente em relação ao SVM, para as variáveis massa média e número de frutos, enquanto que para a variável número de folhas, ambos os algoritmos são eficientes.

Avaliando algoritmos de aprendizado de máquina na previsão de rendimento de milho, Mupangwa et al. (2020) concluíram que algoritmos lineares (*Linear discriminant analysis* (LDA) e *Logistic Regression* (LR)) previram o rendimento de milho mais próximo dos rendimentos observados quando comparado com ferramentas não lineares Naive Bayes (NB), *K-nearest neighbour* (KNN), *Classification and regression trees* (CART) e *Support Vector Machine* (SVM). No geral, o algoritmo LDA foi a melhor ferramenta, e o SVM foi o pior algoritmo na previsão de produtividade de milho.

6 CONCLUSÕES

Os algoritmos de Regressão Linear e *Support Vector Machine* são capazes de estimar a produção de morangos, bem como número de frutos e folhas do morangueiro, por meio de imagens multiespectrais obtidas por meio de veículo aéreo não tripulado.

O algoritmo de Regressão Linear se apresentou mais eficiente para realizar as estimativas produtivas na cultura, com acurácia de 99,91% para massa média de frutos; 99,55% para número de frutos e 99,94% para número de folhas.

O algoritmo SVM apresentou acurácia de 89,62% para massa média de frutos, 84,26% para número de frutos e 98,12% para número de folhas.

REFERÊNCIAS

ABBAS, Farhat; ABBAS, Farhat; AFZAAL, Hassan; FAROOQUE, Aitazaz A.; TANG, Skylar. Crop yield prediction through proximal sensing and machine learning algorithms. **Agronomy**, [s.l.], v. 10, n. 7, p. 1046, 2020. DOI: <https://doi.org/10.3390/agronomy10071046>. Disponível em: <https://www.mdpi.com/2073-4395/10/7/1046>. Acesso em: 03 mar. 2022.

ABD-ELRAHMAN, Amr; WU, Feng; AGEHARA, Shinsuke; BRITT, Katie. Improving Strawberry Yield Prediction by Integrating Ground-Based Canopy Images in Modeling Approaches. **ISPRS International Journal of Geo-Information**, [s.l.], 2021, 10, 239. DOI: <https://doi.org/10.3390/ijgi10040239>. Disponível em: <https://www.mdpi.com/2220-9964/10/4/239>. Acesso em: 03 mar. 2022.

ACORSI, Matheus Gabriel; MIRANDA, Fabiani das Dores Abati; MARTELLO, Mauricio; SMANIOTTO, Danrley Antonio; SARTOR, Laercio Ricardo. Estimating biomass of black oat using UAV-based RGB imaging. **Agronomy**, [s.l.], v. 9, n. 7, p. 344, 2019. DOI: <https://doi.org/10.3390/agronomy9070344>. Disponível em: <https://www.mdpi.com/2073-4395/9/7/344>. Acesso em: 03 mar. 2022.

ALORDZINU, Kelvin Edom; LI, Jiu hao; LAN, Yubin; APPIAH, Sadick Amoakohene; AASMI, Alaa Al; WANG, Hao; LIAO, Juan; SAM-AMOA, Livingstone Kobina; QIAO, Songyang. Ground-Based Hyperspectral Remote Sensing for Estimating Water Stress in Tomato Growth in Sandy Loam and Silty Loam Soils. **Sensors**, [s.l.], v. 21, n. 17, p. 5705, 2021. DOI: <https://doi.org/10.3390/s21175705>. Disponível em: <https://www.mdpi.com/1424-8220/21/17/5705>. Acesso em: 03 mar. 2022.

ANTUNES, L. E. C.; BONOW, S.; REISSER JÚNIOR, C. Morango: crescimento constante em área e produção. **Anuário Campo & Negócio HF**, [s.l.], v. 37, p. 88-92, 2020a. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1122535/morango-crescimento-constante-em-area-e-producao>. Acesso em: 15 abr. 2022.

ANTUNES, Luis Eduardo Corrêa; REISSER JÚNIOR, Carlos; SCHWENGBER, José Ernani (ed.). **Morangueiro**. Brasília - DF: Embrapa, 2016a. 590 p.

ANTUNES, Luis Eduardo Corrêa; REISSER JUNIOR, Carlos. Morango: qualidade dita o preço. **Anuário HF-2019**, [s.l.] Uberlândia - MG, n. 7, janeiro, p. 93-98, 2019b. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1120835/morango-qualidade-dita-o-preco>. Acesso em: 15 abr. 2022.

ANTUNES, Luis Eduardo Corrêa; REISSER JUNIOR, Carlos. Morango: crescimento constante em área e produção. **Anuário HF-2020**, [s.l.] Uberlândia-MG, n. 8, Julho, p. 88-92, 2020c. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1122535/morango-crescimento-constante-em-area-e-producao>. Acesso em: 15 abr. 2022.

ARAVIND, K. R.; PAJA, P. MUKESH, K. V.; ANIIRUDH, R.; ASHIWIN, R.; SZCZEPANSKI, Cezary. Disease classification in maize crop using bag of features and multiclass support vector machine. *In: 2018 2nd International Conference on Inventive Systems and Control (ICISC)*. **IEEE**, Coimbatore – India, 2018. p. 1191-1196. DOI: 10.1109/ICISC.2018.8398993. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8398993>. Acesso em: 05 mar. 2022.

BARMAN, Utpal; CHOUDHURY, Ridip Dev. Soil texture classification using multi class support vector machine. **Information processing in agriculture**, [s.l.], v. 7, n. 2, p. 318-332, 2020. DOI: <https://doi.org/10.1016/j.inpa.2019.08.001>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317318301239>. Acesso em: 25 mar. 2022.

BARMAN, Utpal; CHOUDHURY, Ridip Dev. Smartphone image based digital chlorophyll meter to estimate the value of citrus leaves chlorophyll using Linear Regression, LMBP-ANN and SCGBP-ANN. **Journal of King Saud University-Computer and Information Sciences**, [s.l.], 2020. DOI: <https://doi.org/10.1016/j.jksuci.2020.01.005>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1319157819313679>. Acesso em: 28 mar. 2022.

BARRETO, Abel; LOTTES, Philipp; YAMATI, Facundo Ramón Ispizua; BAUMGARTEN Stephen; WOLF, Nina Anastasia; STACHNISS, Cyrill; MAHLEIN, Anne-Katrin; PAULUS, Stefan. Automatic UAV-based counting of seedlings in sugar-beet field and extension to maize and strawberry. *Computers and Electronics in Agriculture*, [s.l.], v. 191, p. 106493, 2021. DOI: <https://doi.org/10.1016/j.compag.2021.106493>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816992100510X>. Acesso em: 28 mar. 2022.

BENOS, Lefteris; TAGARAKIS, Aristotelis C.; DOLIAS, Georgios; BERRUTO, Remigio; KETRIS, Dimitrios; BOCHTIS, Dionysis. Machine Learning in Agriculture: A Comprehensive Updated Review. **Sensors**, [s.l.], v. 21, n. 11, p. 3758, 2021. DOI: <https://doi.org/10.3390/s21113758>. Disponível em: <https://www.mdpi.com/1424-8220/21/11/3758>. Acesso em: 15 abr 2022.

BERGER, Rute et al. Índices de vegetação para a estimativa do índice de área foliar em plantios clonais de *Eucalyptus saligna* Smith. **Ciência Florestal**, Santa Maria - RS, v. 29, p. 885-899, 2019. DOI: <https://doi.org/10.5902/1980509816942>. Disponível em: http://old.scielo.br/scielo.php?script=sci_arttext&pid=S1980-50982019000200885. Acesso em 17 abr. 2022.

BERTOLIN, N. O. *et al.* Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v. 11, n. 4, p. 1627-1638, 2017. DOI: <https://doi.org/10.7127/rbai.v11n400567>. Disponível em: http://www.inovagri.org.br/revista/index.php/rbai/article/view/567/pdf_375. Acesso em: 16 fev. 2022.

BOUDIBI, Samir; SAKAA, Bachir; BENGUEGA, Zineeddine; FADLAOUI, Haroun; OTHMAN, Tarek; BOUZIDI, Narimen. Spatial prediction and modeling of soil salinity using simple cokriging, artificial neural networks, and support vector machines in El Outaya plain, Biskra, southeastern Algeria. **Acta Geochimica**, [s.l.], v. 40, n. 3, p. 390-408, 2021. DOI: <https://doi.org/10.1007/s11631-020-00444-0>. Disponível em: <https://link.springer.com/article/10.1007/s11631-020-00444-0#citeas>. Acesso em: 12 abr.2022.

CAMBRAIA FILHO, Dácio José. **Utilização de índices de vegetação baseados na porção visível do espectro eletromagnético para monitoramento de fitofisionomias do Cerrado**. 2019. 147 f. Dissertação (Mestrado) – Curso de Programa de Pós-graduação em Geociências Aplicadas e Geodinâmicas, Instituto de Geociências da Universidade de Brasília, Universidade de Brasília, Brasília - DF, 2019. Disponível em: <https://repositorio.unb.br/handle/10482/35980>. Acesso em: 12 abr. 2022.

CANATA, Tatiana Fernanda; WEI, Marcelo Chan Fu; MALDANER, Leonardo Felipe; MOLIN, José Paulo. Sugarcane Yield Mapping Using High-Resolution Imagery Data and Machine Learning Technique. **Remote Sensing**, [s.l.], v. 13, n. 2, p. 232, 2021. DOI: <https://doi.org/10.3390/rs13020232>. Disponível em: <https://www.mdpi.com/2072-4292/13/2/232>. Acesso em: 07 mar. 2022.

CERRI, Ricardo; CARVALHO, André Carlos Ponce de Leon Ferreira De. Aprendizado de máquina: breve introdução e aplicações. **Cadernos de Ciência & Tecnologia**, Brasília – DF, v. 34, n. 3, p. 297-313, 2017. Disponível em: <https://seer.sct.embrapa.br/index.php/cct/article/view/26381>. Acesso em: 04 mar. 2022.

CEVALLOS, Harry Vite; ROMERO, Héctor Carvajal; UNDA, Salomón Barrezueta. Aplicación de algoritmos de aprendizaje automático para clasificar la fertilidad de un suelo bananero. **Conrado**, Cienfuegos – Cuba, v. 16, n. 72, p. 15-19, 2020. Disponível em: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442020000100015. Acesso em: 07 mar. 2022.

CHEN, Yajun; WU, Zhangnan; ZHAO, Bo; FAN, Caixia. Weed and Corn Seedling Detection in Field Based on Multi Feature Fusion and Support Vector Machine. **Sensors**, [s.l.], v. 21, n. 1, p. 212, 2021. Disponível em: <https://doi.org/10.3390/s21010212>. Acesso em: 12 abr. 2022.

CHEN, Yajun; WU, Zhangan; ZHAO, Bo; FAN, Caixia; SHI, Shuwei. Weed and corn seedling detection in field based on multi feature fusion and support vector machine. **Sensors**, [s.l.], v. 21, n. 1, p. 212, 2020. DOI: <https://doi.org/10.3390/s21010212>. Disponível em: <https://www.mdpi.com/1424-8220/21/1/212>. Acesso em: 15 abr. 2022.

CHEN, Yang; LEE, Won Suk; GAN, Hao; PERES, Natalia; FRAISSE, Clyde; ZHANG, Yanchao; HE, Yong. Strawberry yield prediction based on a deep neural network using high-resolution aerial orthoimages. **Remote Sensing**, [s.l.], v. 11, n. 13, p. 1584, 2019. DOI: <https://doi.org/10.3390/rs11131584>. Disponível em: <https://www.mdpi.com/2072-4292/11/13/1584>. Acesso em: 16 mar. 2022.

DA COSTA, B. M.; LEDO, C. A. S.; SILVA, M. C.; TEIXEIRA. Estimativa da produção de forragem em pastagem de *Brachiaria decumbens*. **Archivos de zootecnia**, Córdoba – Argentina, v. 58, n. 221, p. 141-144, 2009. Disponível em: https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S0004-05922009000100019#:~:text=%C3%89%20poss%C3%ADvel%20estimar%20a%20produ%C3%A7%C3%A3o%20de%20forragem%20em%20pastagem%20de,bx%20para%20ajustamento%20das%20estimativas. Acesso em: 03 abr. 2022.

DAMASCENO, Marcelo. **Introdução a mineração de dados utilizando o weka**. Macau – RN. Disponível em: <http://connepi.ifal.edu.br/ocs/anais/conteudo/anais/files/conferences/1/schedConfs/1/papers/258/public/258-4653-1-PB.pdf>. Acesso em: 18 set. 2022.

CASTRO, Andreison de; SPALDING, Luiz Eduardo Schardong; RIEDER, Rafael. **Plataforma embarcada para monitoramento da cultura do morangueiro**. 2017. 107 f. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Computação Aplicada, Instituto de Ciências Exatas e Geociências, Universidade de Passo Fundo, Passo Fundo, 2017. Disponível em: <http://tede.upf.br/jspui/bitstream/tede/1426/2/2017AndreisondeCastro.pdf>. Acesso em: 06 mar. 2022.

DENIS, Antoine; DESCLEE, Baudouin; MIGDALL, Silke; HANSEN, Herbert; BACH, Heike; OTT, Pierre; KOUADIO, Amani Louid; TYCHON, Bernand. Multispectral Remote Sensing as a Tool to Support Organic Crop Certification: Assessment of the Discrimination Level between Organic and Conventional Maize. **Remote Sensing**, [s.l.], v. 13, n. 1, p. 117, 2021. DOI: <https://doi.org/10.3390/rs13010117>. Disponível em: <https://www.mdpi.com/2072-4292/13/1/117>. Acesso em: 06 mar. 2022.

FERREIRA JÚNIOR, José Jeová; DANTAS, Maria Jorgiana Ferreira. Análise do albedo da superfície e índices de vegetação por sensoriamento remoto na bacia hidrográfica no rio Pacoti/CE. **Revista Tecnologia**, Fortaleza, v. 39, n. 2, p. 1-18, 2018. DOI: <https://doi.org/10.5020/23180730.2018.8132>. Disponível em: <https://ojs.unifor.br/tec/article/view/8132#:~:text=Os%20resultados%20de%20albedo%20da,e%20aumento%20do%20solo%20exposto>. Acesso em: 04 mar. 2022.

FERREIRA, Laerte Guimarães; FERREIRA, Nilson Clementino; FERREIRA, Manuel Eduardo. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, [s.l.], v. 30, n. 4, p. 379-390, 2008. Disponível em: <https://www.redalyc.org/pdf/1871/187116040006.pdf>. Acesso em: 12 abr. 2022.

FIGUEIREDO, Divino. **Conceitos básicos de sensoriamento remoto**. São Paulo, 2005. (Apostila). Disponível em: https://clickgeo.com.br/wp-content/uploads/2013/04/conceitos_sm.pdf. Acesso em: 07 mar. 2022.

FIORENTINI, Marco; ZENOBI, Stefano; ORSINI, Roberto. Remote and Proximal Sensing Applications for Durum Wheat Nutritional Status Detection in Mediterranean Area. **Agriculture**, [s.l.], v. 11, n. 1, p. 39, 2021. DOI: <https://doi.org/10.3390/agriculture11010039>. Disponível em: <https://www.mdpi.com/2077-0472/11/1/39>. Acesso em: 13 mar. 2022.

FLORENZANO, Teresa Galloti. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina de Textos, 2011. 123 p. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=18GkH5X81XcC&oi=fnd&pg=PT6&dq=Inicia%C3%A7%C3%A3o+em+sensoriamento+remoto.&ots=yJWqiHV04U&sig=69OtueuOdTpoaZh0NaZQuW3GDu4#v=onepage&q=Inicia%C3%A7%C3%A3o%20em%20sensoriamento%20remoto.&f=false>. Acesso em: 10 mar. 2022.

FORMAGGIO, Antonio Roberto; SANCHES, Ieda Del'Arco. **Sensoriamento remoto em agricultura**. 1. ed. São Paulo: Oficina de Textos, 2017. 288 p. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=hk88DwAAQBAJ&oi=fnd&pg=PT4&dq=Sensoriamento+remoto+em+agricultura.&ots=2MgmOdTGjo&sig=A5NjjcQx11HfNL7B5VeJ03ytO7U#v=onepage&q=Sensoriamento%20remoto%20em%20agricultura.&f=false>. Acesso em: 10 mar. 2022.

FRANCHINI, Júlio Cezar; BALBINOT JUNIOR, Alvadi Antônio; JORGE, Lúcio André de Castro; DEBIASI, Henrique; DIAS, Waldir Pereira; GODOY, Claudia Vieira; DE OLIVEIRA JUNIOR, Adilson; CORRÊA, Fabricio Bueno; DE OLIVEIRA, Maria Cristina Neves. Uso de imagens aéreas obtidas com drones em sistemas de produção de soja. 1. ed. **Embrapa Soja**. Londrina – PR, 39 p. Documentos (INFOTECA-E), 2018. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/190247/1/Doc-408-OL-alta.pdf>. Acesso em: 13 mar. 2022.

FRANCHINI, J. C.; JORGE, L. A. C.; CORREA, F. B.; GREGGIO, F.; DEBIASI, H.; BALBINOT JR, A. A.; PEREIRA, G. S. Estimativa da produtividade da soja pelo uso de imagens aéreas. *In*: CONGRESSO BRASILEIRO DE SOJA, 8., 2018. Goiânia – GO. Anais: Inovação, tecnologias digitais e sustentabilidade da soja: Brasília, DF: Embrapa, 2018.p. 380-382. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1093204/estimativa-da-produtividade-da-soja-pelo-uso-de-imagens-aereas>. Acesso em: 15 abr. 2022.

FRANCISCO, Cristiane Nunes; RUIZ, Paulo Roberto da Silva; ALMEIDA, Cláudia Maria; GRUBER, Nina Cardoso; DOS ANJOS, Camila Souza. Análise do impacto da correção atmosférica no cálculo do Índice de Vegetação por Diferença Normalizada a partir de Imagem Landsat 8/OLI. **Revista Brasileira de Geografia Física**, [s.l.], v. 13, n. 01, p. 076-086, 2020. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/view/242936/34938>. Acesso em: 10 abr. 2022.

GAIDA, William; BREUNIG, Fábio Marcelo; GALVÃO, Lênio Soares; PONZONI, Flávio Jorge. Correção Atmosférica em Sensoriamento Remoto: Uma Revisão. **Revista Brasileira de Geografia Física**, [s.l.], v. 13, n. 01, p. 229-248, 2020. Disponível em: http://mtc-m21c.sid.inpe.br/col/sid.inpe.br/mtc-m21c/2020/05.08.12.48/doc/gaida_correcao.pdf. Acesso em: 15 abr. 2022.

GAO, Demin; SUN, Quan; HU, Bin; ZHANG, Shuo. A framework for agricultural pest and disease monitoring based on internet-of-things and unmanned aerial vehicles. **Sensors**, [s.l.], v. 20, n. 5, p. 1487, 2020. Disponível em: <https://www.mdpi.com/1424-8220/20/5/1487>. Acesso em: 17 mar. 2022.

GONÇALVES, André Ricardo. Máquina de vetores suporte. *s.n.*, [s.l.], v. 21, 2015. Disponível em: <https://andreric.github.io/files/pdfs/svm.pdf>. Acesso em: 15 mar. 2022.

GREIFENEDER, Felix; NOTARNICOLA, Claudia; WAGNER, Wolfgang. A Machine Learning-Based Approach for Surface Soil Moisture Estimations with Google Earth Engine. **Remote Sensing**, [s.l.], v. 13, n. 11, p. 2099, 2021. DOI: <https://doi.org/10.3390/rs13112099>. Disponível em: <https://www.mdpi.com/2072-4292/13/11/2099>. Acesso em: 04 mar. 2022.

GRIFFEL, L. M.; DELPARTE, D.; EDWARDS, J. Using Support Vector Machines classification to differentiate spectral signatures of potato plants infected with Potato Virus Y. **Computers and electronics in agriculture**, [s.l.], v. 153, p. 318-324, 2018. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918306306>. Acesso em: 12 mar. 2022.

GUEDES, Jânio; DA SILVA, Sebastião Milton Pinheiro. SENSORIAMENTO REMOTO NO ESTUDO DA VEGETAÇÃO: PRINCÍPIOS FÍSICOS, SENSORES E MÉTODOS. **Acta Geográfica**, Boa Vista, v. 12, n. 29, p. 127-144, 2018. Disponível em: <https://revista.ufrb.br/actageo/article/view/4001/2522>. Acesso em: 04 abr. 2022.

HUANG, Zhuoling; SKLAR, Elizabeth; PARSONS, Simon. Design of automatic strawberry harvest robot suitable in complex environments. *In: Companion of the 2020 ACM/IEEE International Conference on Human-Robot Interaction*. 2020. s.l, p. 567-569. Disponível em: <https://dl.acm.org/doi/abs/10.1145/3371382.3377443>. Acesso em: 13 mar. 2022.

ISLAM, Nahina; RASHID, Md Mamunur; WIBOWO, Santoso; XU, Cheng-Yuan; MORSHED, Ahsan; WASIMI, Saleh A.; MOORE, Steven; RAHMAN, Sk Mostafizur. Early Weed Detection Using Image Processing and Machine Learning Techniques in an Australian Chilli Farm. **Agriculture**, [s.l.], v. 11, n. 5, p. 387, 2021. DOI: <https://doi.org/10.3390/agriculture11050387>. Disponível em: <https://www.mdpi.com/2077-0472/11/5/387>. Acesso em: 13 mar. 2022.

JIANG, Feng; LU, Yang; CHEN, Yu; LI, Gongfa. Image recognition of four rice leaf diseases based on deep learning and support vector machine. **Computers and Electronics in Agriculture**, [s.l.], v. 179, p. 105824, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105824>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016816992030795X>. Acesso em: 13 mar. 2022.

KASHYAP, Bhuwan; KUMAR, Ratnesh. Sensing Methodologies in Agriculture for Monitoring Biotic Stress in Plants Due to Pathogens and Pests. **Inventions**, [s.l.], v. 6, n. 2, p. 29, 2021. DOI: <https://doi.org/10.3390/inventions6020029>. Disponível em: <https://www.mdpi.com/2411-5134/6/2/29>. Acesso em: 03 mar. 2022.

KHAN, Shahbaz; TUFAIL, Muhammad; KHAN, Muhammad Tahir; KHAN, Zubair Ahmad; ANWAR, Shahzad. Deep learning-based identification system of weeds and crops in strawberry and pea fields for a precision agriculture sprayer. **Precision Agriculture**, [s.l.], v. 22, n. 6, p. 1711-1727, 2021. DOI: <https://doi.org/10.1007/s11119-021-09808-9>. Disponível em: <https://link.springer.com/article/10.1007/s11119-021-09808-9#citeas>. Acesso em: 12 mar. 2022.

LI, Xuchen; CAI, Changlong; ZHENG, Hao; ZHU, Hongfei. Recognizing strawberry appearance quality using different combinations of deep feature and classifiers. **Journal of Food Process Engineering**, [s.l.], v. 45, n. 3, p. e13982, 2022. DOI: <https://doi.org/10.1111/jfpe.13982>. Disponível em: <https://onlinelibrary.wiley.com/doi/epdf/10.1111/jfpe.13982>. Acesso em: 12 mar. 2022.

LI, Dan; MIAO, Yuxin; GUPTA, Sanjay K.; ROSEN, Carl J.; YUAN, Fei; WANG, Chongyang; WANG, Li; HUANG, Yanbo. Improving Potato Yield Prediction by Combining Cultivar Information and UAV Remote Sensing Data Using Machine Learning. **Remote Sensing**, [s.l.], v. 13, n. 16, p. 3322, 2021. DOI: <https://doi.org/10.3390/rs13163322>. Disponível em: <https://www.mdpi.com/2072-4292/13/16/3322>. Acesso em: 04 mar. 2022.

LI, Changchun; MA, Chunyan; PEI, Haojie; FENG, Haikuan; SHI, Jinjin; WANG, Yilin; CHEN, Weinan; LI, Yacong; FENG, Xiaowei; SHI, Yonglei. Estimation of Potato Biomass and Yield Based on Machine Learning from Hyperspectral Remote Sensing Data. **J. Agric. Sci. Technol. B**, [s.l.], v. 10, p. 195-213, 2020. DOI: doi: 10.17265/2161-6264/2020.04.001. Disponível em: <https://www.davidpublisher.com/Public/uploads/Contribute/5faf83183d080.pdf>. Acesso em: 12 mar. 2022.

LI, Xin; LI, Jun; TANG, Jing. A deep learning method for recognizing elevated mature strawberries. In: 2018 33RD YOUTH ACADEMIC ANNUAL CONFERENCE OF CHINESE ASSOCIATION OF AUTOMATION (YAC). IEEE, Nanjing - China, 2018. p. 1072-1077. DOI: 10.1109/YAC.2018.8406530. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8406530>. Acesso em: 04 mar. 2022.

LIAKOS, Konstantinos G.; BUSATO, Patrizia; MOSHOU, Dimitrios; PEARSON, Simon; BOCHTIS, Dionysis. Machine learning in agriculture: A review. **Sensors**, [s.l.], v. 18, n. 8, p. 2674, 2018. DOI: <https://doi.org/10.3390/s18082674>. Disponível em: <https://www.mdpi.com/1424-8220/18/8/2674>. Acesso em 04 mar. 2022.

LIU, William Tse Horng. **Aplicações de sensoriamento remoto**. 2. ed. São Paulo: Oficina de Textos, 2015. 908 p. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=YNEtCQAAQBAJ&oi=fnd&pg=PT811&dq=Aplica%C3%A7%C3%B5es+de+sensoriamento+remoto.+&ots=vyhqvZMFxr&sig=erINRcUCgMvLlvHHA VE98wK6MU8#v=onepage&q=Aplica%C3%A7%C3%B5es%20de%20sensoriamento%20remoto.&f=false>. Acesso em: 04 mar. 2022.

LIU, Zhijie; GUO, Pengju; LIU, Heng; FAN, Pan; ZENG, Pengzong; LIU, Xiangyang; FENG, Ce; WANG, Wang; YANG, Fuzeng. Gradient Boosting Estimation of the Leaf Area Index of Apple Orchards in UAV Remote Sensing. **Remote Sensing**, [s.l.], v. 13, n. 16, p. 3263, 2021. DOI: <https://doi.org/10.3390/rs13163263>. Disponível em: <https://www.mdpi.com/2072-4292/13/16/3263>. Acesso em: 12 mar. 2022.

LORENA, Ana Carolina; DE CARVALHO, André C. P. L. F. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, [s.l.], v. 14, n. 2, p. 43-67, 2007. DOI: <https://doi.org/10.22456/2175-2745.5690>. Disponível em: https://www.seer.ufrgs.br/index.php/rita/article/view/rita_v14_n2_p43-67. Acesso em: 12 mar. 2022.

LORENÇONE, João; LORENÇONE, Pedro Antônio; APARECIDO, Lucas Eduardo de Oliveira; MORAIS, Leucivaldo Carneiro. Previsão do custo da produção de soja usando técnicas de modelagem computacional. *In: ENCONTRO INTERNACIONAL DE GESTÃO, DESENVOLVIMENTO E INOVAÇÃO (EIGEDIN)*, Naviraí, v. 3, n. 1, 2019. **Anais do III Encontro Internacional de Gestão, Desenvolvimento e Inovação (EIGEDIN)**. 2019.

LORENÇONE, João A. **Princípios físicos de sensoriamento remoto**. 5. ed. São Paulo: Edgard Blucher Ltda., 2015. 292 p. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=VENiDwAAQBAJ&oi=fnd&pg=PA15&dq=Princ%C3%ADpios+f%C3%ADsicos+de+sensoriamento+remoto.+&ots=TVU28cvKU4&sig=NtKn-Z-3CnDc1vKxxO0-IsmxCtM#v=onepage&q=Princ%C3%ADpios%20f%C3%ADsicos%20de%20sensoriamento%20remoto.&f=false>. Acesso em: 04 mar. 2022.

MADHAVI, Bolappa Gamage Kaushalya; BASAK, Jayanta Kumar; PAUDEL, Bhola; KIM, Na Eun; CHOI, Gyeong Mun; KIM, Hyeon Tae. Prediction of Strawberry Leaf Color Using RGB Mean Values Based on Soil Physicochemical Parameters Using Machine Learning Models. **Agronomy**, [s.l.], v. 12, n. 5, p. 981, 2022. DOI: <https://doi.org/10.3390/agronomy12050981>. Disponível em: <https://www.mdpi.com/2073-4395/12/5/981>. Acesso em: 12 mar. 2022.

MAHMUD, Md Sultan; ZAMAN, Qamar U.; ESAU, Travis J.; CHANG, YoungK.; PRICE G. W.; PRITHIVIRAJ, Balakrishnan. Real-time detection of strawberry powdery mildew disease using a mobile machine vision system. **Agronomy**, [s.l.], v. 10, n. 7, p. 1027, 2020. DOI: <https://doi.org/10.3390/agronomy10071027>. Disponível em: <https://www.mdpi.com/2073-4395/10/7/1027>. Acesso em: 03 mar. 2022.

MALUF, Victor Buznello de Vacconcellos; DAMASCO, Fernando Souza; GOMES, Isabel Santos de Lima; SANTOS, Liliâne Ronquette da Silva; DIAS, Luisa Schneider Moreira; CARVALHO, Marcus Vinicius Alves de; CORREA, Marvin de Almeida; VICENS, Raúl Sanchez. Eficácia de um método de normalização radiométrica utilizando imagens Landsat 5 TM. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, v. 17, 2015 João Pessoa – PB. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto – SBSR**. 2015. p. 5491-5497. Disponível em: <http://www.dsr.inpe.br/sbsr2015/files/p1097.pdf>. Acesso em: 12 mar. 2022.

MASKEY, Mahesh L.; PATHAK, Tapan B.; DARA, Surendra K. Previsões de produtividade de morango com base no clima em escala de campo usando modelos estatísticos e de aprendizado de máquina. **Atmosfera**, [s.l.], v. 10, n. 7, pág. 378, 2019.

MARTOS, Vanesa et al. Ensuring Agricultural Sustainability through Remote Sensing in the Era of Agriculture 5.0. **Applied Sciences**, [s.l.], v. 11, n. 13, p. 5911, 2021. DOI: <https://doi.org/10.3390/app11135911>. Disponível em: <https://www.mdpi.com/2076-3417/11/13/5911>. Acesso em: 03 mar. 2022.

MERCANTE, Erivelto; LAMPARELLI, Rubens A. C.; URIBE-OPAZO, Miguel A.; ROCHA, Jansley V. Modelos de regressão lineares para estimativa de produtividade da soja no oeste do Paraná, utilizando dados espectrais. **Engenharia Agrícola**, Jaboticabal – SP, v. 30, p. 504-517, 2010. DOI: <https://doi.org/10.1590/S0100-69162010000300014>. Disponível em: <https://www.scielo.br/j/eagri/a/5zHjK83X6Qzh9rXFzrkv6xF/abstract/?lang=pt>. Acesso em: 15 mar. 2022.

MESSINA, Gaetano; PRATICÒ, Salvatore; BADAGLIACCA, Giuseppe; FAZIO, Salvatore Di; MONTI, Michele; MODICA, Giuseppe. Monitoring Onion Crop “Cipolla Rossa di Tropea Calabria IGP” Growth and Yield Response to Varying Nitrogen Fertilizer Application Rates Using UAV Imagery. **Drones**, [s.l.], v. 5, n. 3, p. 61, 2021. DOI: <https://doi.org/10.3390/drones5030061>. Disponível em: <https://www.mdpi.com/2504-446X/5/3/61>. Acesso em: 04 mar. 2022.

MICHELON, Gabriela Karoline; MENEZES, Paulo Lopes de; CANDIDO JUNIOR, Arnaldo; BAZZI, Claudio Leones; BARBOSA, Marcela Marques. Máquina De Vetores De Suporte Para Estimar A Produtividade Da Soja. **Revista Engenharia na Agricultura-REVENG**, Viçosa – MG, v. 25, n. 3, p. 240-248, 2017. DOI: <https://doi.org/10.13083/reveng.v25i3.745>. Disponível em: <https://periodicos.ufv.br/reveng/article/view/669/445>. Acesso em 12 abr. 2022.

MORAES, Sandra Thatiza Padovani de. **Índice de Vegetação por Diferença Normalizada (NDVI) visando estimativa de fitomassa de adubos verdes**. 2020. Dissertação (Mestrado em Ciências). Universidade de São Paulo, Piracicaba, 2020. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/11152/tde-09032020-170235/en.php>. Acesso em: 12 mar. 2022.

MUPANGWA, W.; CHIPINDU, L.; NYAGUMBO, I.; MKUHLANI, S.; SISITO, G. Evaluating machine learning algorithms for predicting maize yield under conservation agriculture in Eastern and Southern Africa. **SN Applied Sciences**, [s.l.], v. 2, n. 5, p. 1-14, 2020. Disponível em: <https://link.springer.com/article/10.1007/s42452-020-2711-6>. Acesso em: 16 mar. 2022.

NASSAR, Lobna; OKWUCHI, Ifeanyi Emmanuel; SAAD, Muhammad; KARRAY, Fakhri; PONNAMBALAM, Kumaraswamy; AGRAWAL, Prarabdha. Prediction of strawberry yield and farm price utilizing deep learning. *In: 2020 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN)*. Glasgow - UK. IEEE, 2020. p. 1-7. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9206998>. Acesso em: 10 abr. 2022.

NICOLA, Márcio José. **Adoção de random forest e regressão linear para previsão de falhas em equipamentos agrícolas**. 2021. 95 f. Dissertação (Mestrado) - Curso de Programa de Mestrado Profissional em Matemática, Estatística e Computação Aplicada À Indústria, Universidade de São Paulo, São Carlos, 2021. Disponível em: https://www.teses.usp.br/teses/disponiveis/55/55137/tde-16072021-083711/publico/MarcioJoseNicola_revisada.pdf. Acesso em: 05 abr. 2022.

NOVO, Evlyn Márcia Leão De Moraes; PONZONI, Flávio Jorge. INTRODUÇÃO AO SENSORIAMENTO REMOTO. 2001. PENG, Yun; ZHAO, Shenyi; LIU, Jizhan. Fused Deep Features-Based Grape Varieties Identification Using Support Vector Machine. **Agriculture**, [s.l.], v. 11, n. 9, p. 869, 2021. DOI: <https://doi.org/10.3390/agriculture11090869>. Disponível em: <https://www.mdpi.com/2077-0472/11/9/869>. Acesso em: 10 mar. 2022.

PENG, Yun; ZHAO, Shenyi; LIU, Jizhan. Fused Deep Features-Based Grape Varieties Identification Using Support Vector Machine. **Agriculture**, [s.l.], v. 11, n. 9, p. 869, 2021. DOI: <https://doi.org/10.3390/agriculture11090869>. Disponível em: <https://www.mdpi.com/2077-0472/11/9/869>. Acesso em: 12 mar. 2022.

PERROS, Nikolas; KALIVAS, Dionissios; GIOVOS, Rigas. Spatial Analysis of Agronomic Data and UAV Imagery for Rice Yield Estimation. *Agriculture*, [s.l.], v. 11, n. 9, p. 809, 2021. DOI: <https://doi.org/10.3390/agriculture11090809>. Disponível em: <https://www.mdpi.com/2077-0472/11/9/809>. Acesso em: 10 mar. 2022.

PIEKUTOWSKA, Magdalena; NIEDBALA, Gniewko; PISKIER, Tomasz; LENARTOWICZ, Tomasz; PILARSKI, Krzysztof; WOJCIECHOWSKI, Tomasz; PILARSKA, Agnieszka A.; CZECHOWSKA-KOSACKA, Aneta. The Application of Multiple Linear Regression and Artificial Neural Network Models for Yield Prediction of Very Early Potato Cultivars before Harvest. *Agronomy*, [s.l.], v. 11, n. 5, p. 885, 2021. DOI: <https://doi.org/10.3390/agronomy11050885>. Disponível em: <https://www.mdpi.com/2073-4395/11/5/885>. Acesso em: 12 abr. 2022.

PIMENTA, A.; VALENTIM, P.; SANTOS, D.; NETO, M. WEKA-G: mineração de dados paralela em grades computacionais. *Revista de Sistemas de Informação da FSMA*, [s.l.], v. 4, p. 2, 2009. Disponível em: http://www.fsma.edu.br/si/edicao4/FSMA_SI_2009_2_Estudantil_1.pdf. Acesso em: 15 ago 2022.

PLAZA, Javier; CRIADO, Marco; SÁNCHEZ, Nilda; PÉREZ-SÁNCHEZ, Rodrigo; PALCIOS, Carlos; CHARFOLÉ, Francisco. UAV Multispectral Imaging Potential to Monitor and Predict Agronomic Characteristics of Different Forage Associations. *Agronomy*, [s.l.], v. 11, n. 9, p. 1697, 2021. DOI: <https://doi.org/10.3390/agronomy11091697>. Disponível em: <https://www.mdpi.com/2073-4395/11/9/1697>. Acesso em: 10 mar. 2022.

R CORE TEAM. **R: A language and environment for statistical computing. R Foundation for Statistical Computing**, Vienna, Austria. 2021. Disponível em: <https://www.R-project.org/>. Acesso em: 20 set. 2022.

RAMÍREZ, Fátima L. Benítez; ANDERSON, Liana O.; FORMAGGIO, Antônio R. Normalização radiométrica automatizada para geração de mosaicos de imagens RapidEye sobre paisagens amazônicas, através da transformação IR-MAD. *In: Simpósio Brasileiro de Sensoriamento Remoto – SBSR. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR 2015*. p. 1292-1299. Disponível em: <http://www.dsr.inpe.br/sbsr2015/files/p0236.pdf>. Acesso em: 04 mar. 2022.

ROBINSON, Neil A. **Use of Normalised Difference Vegetation Index (NDVI) to assess tolerance of wheat cultivars to root-lesion nematodes (*Pratylenchus thornei*)**. 2019. Tese (Doutorado em Ciências). University of Southern Queensland. [s.l.], 2019.

RODRIGUES, Sandra Cristina Antunes. Modelo de regressão linear e suas aplicações. 2012. Dissertação (Mestrado em Ensino de Matemática no 3º Ciclo do Ensino Básico e no Ensino Secundário). Universidade da Beira Interior. Covilhã. 2012.

SANTOS, Leonardo Nascimento dos. Entendendo o índice NDVI. *In: Salão UFRGS 2018: SIC - XXX SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS*. Rio Grande do Sul. 2018. p.2. Disponível em: https://www.lume.ufrgs.br/bitstream/handle/10183/191438/Resumo_59053.pdf?sequence=1. Acesso em: 14 abr. 2022.

SAPONARO, Mirko; AGAPIOU, Athos; HADJIMITSIS, Diofantos G.; TARANTINO, Eufemia. Influence of spatial resolution for vegetation indices extraction using visible bands from unmanned aerial vehicles' orthomosaics datasets. **Remote Sensing**, [s.l.], v. 13, n. 16, p. 3238, 2021. DOI: <https://doi.org/10.3390/rs13163238>. Disponível em: <https://www.mdpi.com/2072-4292/13/16/3238>. Acesso em: 10 abr. 2022.

SEREJO, Gerson L.; SANTOS, Viviane A.; GOMES, Ana C. S.; SILVA, Alexandre F. B. Estimativa da produção de uma lavoura de agricultura familiar através de imagens digitais capturadas por veículo aéreo não tripulado (VANT). In: WORKSHOP DE COMPUTAÇÃO APLICADA À GESTÃO DO MEIO AMBIENTE E RECURSOS NATURAIS (WCAMA), 12., 2021, Evento Online. **Anais do XII Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais**. Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 79-86.

SERVIÇO NACIONAL DE APRENDIZAGEM RURAL - SENAR. **Olericultura: cultivo do morango**. 238. ed. Brasília: Senar, 2019. 80 p. Disponível em: https://www.cnabrazil.org.br/assets/arquivos/238_Olericultura-cultivo-do-morango.pdf. Acesso em: 03 mar. 2022.

SHAHZAMAN, Muhammad; ZHU, Weijun; BILAL, Muhammad; HABTEMICHEAL, Birhanu Asmerom; MUSTAFA, Farhan; ARSHAD, Muhammad; ULLAH, Irfan; ISHFAQ, Shazia; IQBAL, Rashid. Remote Sensing Indices for Spatial Monitoring of Agricultural Drought in South Asian Countries. **Remote Sensing**, [s.l.], v. 13, n. 11, p. 2059, 2021. DOI: <https://doi.org/10.3390/rs13112059>. Disponível em: <https://www.mdpi.com/2072-4292/13/11/2059>. Acesso em: 12 abr. 2022.

SHARPE, Shaun M.; SCHUMANN, Arnold W.; BOYD, Nathan S. Goosegrass detection in strawberry and tomato using a convolutional neural Network. **Scientific Reports**, [s.l.], v. 10, n. 1, p. 1-8, 2020. Disponível em: <https://www.nature.com/articles/s41598-020-66505-9>. Acesso em: 10 abr. 2022.

SHIN, Jaemyung; CHANG, Young K.; HEUNG, Brandon; NGUYEN-QUANG, Tri; PRICE, Gordon W.; AL-MALLAHI, Ahmad. A deep learning approach for RGB image-based powdery mildew disease detection on strawberry leaves. **Computers and Electronics in Agriculture**, [s.l.], v. 183, p. 106042, 2021. DOI: <https://doi.org/10.1016/j.compag.2021.106042>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921000600>. Acesso em: 15 mar. 2022.

SILVA FILHO, R. da; VASCONCELOS, R. S.; GALVÃO, C. de O.; CUNHA, J. E. de B. leite; RUFINO, I. A. A. Representação matemática do comportamento intra-anual do NDVI no Bioma Caatinga. **Ciência Florestal**, [s.l.], v. 30, n. 2, p. 473-488, 2020. DOI: [10.5902/1980509837279](https://doi.org/10.5902/1980509837279). Disponível em: <https://periodicos.ufsm.br/cienciaflorestal/article/view/37279>. Acesso em: 5 mar. 2022.

SOUSA, Willamys Rangel Nunes de. **Estimativa de tendência de séries temporais de imagens de sensoriamento remoto para análise de evolução de processos de desertificação**. 2012. 87 f. Dissertação (Mestrado em Ciência da Computação) - Curso de Ciência da Computação, Universidade do Estado do Rio Grande do Norte, Mossoró, 2012.

TEIXEIRA, Sandro. **Determinação de modelo de estimativa de teores de carbono em solos utilizando máquina de vetor de suporte e reflectância espectral**. 2014. 64 f. Dissertação (Mestrado em Computação Aplicada) - Curso de Programa de Pós Graduação Computação Aplicada, Universidade Estadual de Ponta Grossa, Ponta Grossa, 2014. Disponível em: <https://tede2.uepg.br/jspui/handle/prefix/122>. Acesso em: 03 abr. 2022.

TU, Yu-Hsuan et al. Measuring canopy structure and condition using multi-spectral UAS imagery in a horticultural environment. **Remote Sensing**, [s.l.], v. 11, n. 3, p. 269, 2019. DOI: <https://doi.org/10.3390/rs11030269>. Disponível em: <https://www.mdpi.com/2072-4292/11/3/269>. Acesso em: 10 abr. 2022.

VIGNOLO, Gerson Kleinick; PICOLOTTO, Luciano; GONÇALVES, Michel Aldrighi; COCCO, Carine; ANTUNES, Luis Eduardo Correa. Origem e botânica. In: ANTUNES, Luis Eduardo Corrêa; REISSER JÚNIOR, Carlos; SCHWENGBER, José Ernani (org.). **Morangueiro**. Brasília - DF: Embrapa, 2016. cap. 2. p. 35-46.

WANG, Sijia; CHEN, Yunhao; WANG, Mingguo; LI, Jing. Performance comparison of machine learning algorithms for estimating the soil salinity of salt-affected soil using field spectral data. **Remote Sensing**, [s.l.], v. 11, n. 22, p. 2605, 2019. DOI: <https://doi.org/10.3390/rs11222605>. Disponível em: <https://www.mdpi.com/2072-4292/11/22/2605>. Acesso em: 07 abr. 2022.

WEHRHAN, Marc; SOMMER, Michael. A Parsimonious Approach to Estimate Soil Organic Carbon Applying Unmanned Aerial System (UAS) Multispectral Imagery and the Topographic Position Index in a Heterogeneous Soil Landscape. **Remote Sensing**, [s.l.], v. 13, n. 18, p. 3557, 2021. DOI: <https://doi.org/10.3390/rs13183557>. Disponível em: <https://www.mdpi.com/2072-4292/13/18/3557>. Acesso em: 12 mar. 2022.

XIAO, Jia-Rong; CHUNG, Pei-Che; WU, Hung-Yi; PHAN, Quoc-Hung; YEH, Jer-Liang Andrew; HOU, Max Ti-Kuang. Detection of strawberry diseases using a convolutional neural network. **Plants**, [s.l.], v. 10, n. 1, p. 31, 2020. DOI: <https://doi.org/10.3390/plants10010031>. Disponível em: <https://www.mdpi.com/2223-7747/10/1/31>. Acesso em: 10 mar. 2022.

YANG, Mi-Hye; NAM, Won-Ho; KIM, Taegon; KIM, Younghwa. Machine learning application for predicting the strawberry harvesting time. **Korean Journal of Agricultural Science**, [s.l.], v. 46, n. 2, p. 381-393, 2019. Disponível em: <https://koreascience.kr/article/JAKO201917767633116.page>. Acesso em: 10 mar. 2022.

ZHENG, Caiwang; ABD-ELRAHMAN, Amr; WHITAKER, Vance. Remote Sensing and Machine Learning in Crop Phenotyping and Management, with an Emphasis on Applications in Strawberry Farming. **Remote Sensing**, [s.l.], v. 13, n. 3, p. 531, 2021. DOI: <https://doi.org/10.3390/rs13030531>. Disponível em: <https://www.mdpi.com/2072-4292/13/3/531>. Acesso em: 10 mar. 2022.

ZHOU, Congliang; LEE, Won Suk; LIBURD, Oscar e; AYGUN, Ikbal; SCHUELLER, John K.; AMPATZIDIS, Yiannis. Smartphone-based Tool for Two-Spotted Spider Mite Detection in Strawberry. In: 2021 ASABE ANNUAL INTERNATIONAL VIRTUAL MEETING. American Society of Agricultural and Biological Engineers, 2021. Michigan. **Anais** 2021 ASABE Annual International Virtual Meeting 2100558. p. 1. Disponível em: <https://elibrary.asabe.org/abstract.asp?aid=52834>. Acesso em: 10 abr. 2022.

