

UNIVERSIDADE FEDERAL DE ALFENAS

**LUIS FELIPE PIGATTO MIRANDA SILVA**

**USO DE IMAGENS OBTIDAS A PARTIR DE DRONE NO  
MONITORAMENTO DO CULTIVO DE BATATA-DOCE POR ÍNDICES DE  
VEGETAÇÃO.**

Alfenas/MG

2020

**LUIS FELIPE PIGATTO MIRANDA SILVA**

**USO DE IMAGENS OBTIDAS A PARTIR DE DRONE NO  
MONITORAMENTO DO CULTIVO DE BATATA-DOCE POR ÍNDICES DE  
VEGETAÇÃO.**

Dissertação de Mestrado apresentada  
como requisito parcial para obtenção do  
título de Mestre em Ciências Ambientais  
pela Universidade Federal de Alfenas.  
Área de concentração: Ciências  
Ambientais.

Orientador: Prof. Dr. Ronaldo Luiz  
Mincato (UNIFAL-MG)  
Coorientador: Prof. Dr. Marx Leandro  
Naves Silva (UFLA)

Alfenas/MG

2020

Dados Internacionais de Catalogação-na-Publicação (CIP)  
Sistema de Bibliotecas da Universidade Federal de  
AlfenasBiblioteca Central – Campus Sede

Silva, Luis Felipe Pigatto Miranda

S586u Uso de imagens obtidas a partir de drone no monitoramento do cultivo de batata-doce por índices de vegetação / Luis Felipe Pigatto Miranda Silva. – Alfenas, MG, 2021.

53 f.: il. –

Orientador: Ronaldo Luiz Mincato.

Dissertação (Mestrado em Ciências Ambientais) – Universidade Federal de Alfenas, 2020.

Ficha Catalográfica elaborada por Marlom Cesar da  
SilvaBibliotecário-Documentalista CRB6/2735

**Luis Felipe Pigatto Miranda Silva**

**USO DE IMAGENS OBTIDAS POR SENSOR EMBARCADO EM VANT NO MONITORAMENTO  
DO CULTIVO DE BATATA-DOCE A PARTIR DE ÍNDICES DE VEGETAÇÃO**

A Banca examinadora abaixo-assinada aprova a Dissertação apresentada como parte dos requisitos para a obtenção do título de Mestre em Ciências Ambientais pela Universidade Federal de Alfenas. Área de concentração: Ciências Ambientais.

Aprovada em: 30 de novembro de 2020

Prof. Dr. Ronaldo Luiz Mincato  
Instituição: Universidade Federal de Alfenas

Prof. Dr. Joaquim Ernesto Bernardes Ayer  
Instituição: Centro Universitário de Paulínia

Dr. Rodrigo dos Santos Moreira  
Instituição: Pós-Doutor pela Universidade Federal de Alfenas



Documento assinado eletronicamente por **Ronaldo Luiz Mincato, Professor do Magistério Superior**, em 30/11/2020, às 16:42, 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 **Rodrigo Santos Moreira, Usuário Externo**, em 30/11/2020, às 16:43, 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 **Joaquim Ernesto Bernardes Ayer, Usuário Externo**, em 30/11/2020, às 16:43, 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://sei.unifal-mg.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.unifal-mg.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0414308** e o código CRC **FF55222C**.

---

Dedico à família e amigos

## AGRADECIMENTOS

À minha família, meu pai José Ronaldo, minha mãe Sandra Beatriz e meu irmão João Paulo; à minha avó Gilda, ao meu avô Ronaldo (*In memorian*), à minha avó Maria de Lourdes (*In memorian*), e ao meu avô Angelino Pigatto (*In memorian*), tios e tias, primos e primas pelo exemplo de vida, ensinamentos e amor,

Ao professor Ronaldo Luiz Mincato, pela amizade e orientação, por todo apoio, confiança e incentivo na realização deste projeto; ao professor Marx Leandro Naves Silva, Coorientador, pelo apoio, colaboração e recomendações, e o professor Marcos Coelho Bissoli, por toda ajuda, colaboração e disponibilidade,

A todos e todas colegas do Laboratório de Geologia e Paleontologia: Alexandre (Alê), Alvanil, André (Xuxa), Augusto (Baraka), Benedito (Ditim), Derielsen (Belo), Filipe (Magrinho), Gabriel, Guilherme (Porvinha), Indira, Leonardo (Léo), Lucas (Mané), Natanael (Japanael), Rodrigo, Talyson e Taya, por toda ajuda, companheirismo e ensinamentos; a técnica Marcilene Teodoro;

Às secretárias Elizangela e Márcia do ICN, às funcionárias terceirizadas que trabalham no ICN, à Denise e Viviane, secretárias do PPGCA;

Ao Joaquim, egresso do PPGCA,

A todo corpo docente do PPGCA - UNIFAL-MG,

Ao pessoal de UFLA - Lavras, Jeferson e Tom, por todo apoio, amizade, empenho e dedicação comigo, ao professor Valter pelas explicações, e à toda equipe do setor de Olericultura da UFLA;

Ao Eugenio (Chuck) e a Mayara por me acolherem muito bem nos respectivos lares durante minhas idas a Lavras.

Aos irmãos de Campinas e Paulínia, Guizão, Jão Mineiro, Pivatto e Thom Brasil que estiveram em Alfenas me visitando, além do Fernando (Textitude) e à Dani que puderam conviver comigo por um breve período em Alfenas;

A toda equipe que me incentivou mesmo não estando presente e ao meu amigo Billy, e também ao meu grande amigo José Luiz (Zé), Dona Marisa, Karen e Bruna por me acolherem nesta reta final.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“Eu não estou interessado em nenhuma teoria, nem nessas coisas do oriente, romances astrais. A minha alucinação é suportar o dia-a-dia, e meu delírio é a experiência por coisas reais... Um preto, um pobre, uma estudante, uma mulher sozinha, blue jeans e motocicletas, pessoas cinzas normais. Garotas dentro da noite, revólver, cheira cachorro, os humilhados do parque com os seus jornais...”

(Antônio Carlos Gomes BELCHIOR Fontenelle Fernandes, 1976).

## RESUMO

Veículos aéreos não tripulados têm sido cada vez mais utilizados para o monitoramento de cultivos agrícolas, visando o aumento da produtividade, com custos menores, e para promover a sustentabilidade dos recursos naturais. O objetivo deste estudo foi aplicar a análise de séries temporais de imagens do espectro visível (RGB) obtidas por sensor embarcado em Veículo Aéreo Não Tripulado no cultivo de batata-doce em área experimental no Município de Lavras, sul do Estado de Minas Gerais, Brasil. Assim, cinco índices de vegetação (Índice de Cor de Extração da Vegetação, Excesso de Verde, Índice de Folha Verde, Índice de Diferença Verde-Vermelho Normalizado e Índice de Resistência Atmosférica Visível) foram correlacionados com a produção das ramas do cultivo e também foram determinados os índices de cobertura superficial. As imagens foram processadas e classificadas em software específico e posterior análise estatística. Dessa forma, o estudo apresentou resultados com potencial na contribuição para o acesso às novas tecnologias espaço-temporais e com potencial de embasar o planejamento do manejo em sistemas agroambientais, para o aumento da produtividade de modo sustentável aos recursos naturais.

Palavras-chave: *Ipomoea batatas*. L. RGB. Monitoramento Drone



## ABSTRACT

Unmanned aerial vehicles have been increasingly used to monitor agricultural crops, aiming to increase productivity, at lower costs, and to promote the sustainability of natural resources. The objective of this study was to apply the analysis of time series of visible spectrum (RGB) images obtained by a sensor embedded in Unmanned Aerial Vehicle in the cultivation of sweet potatoes in an experimental area in the municipality of Lavras, south of the State of Minas Gerais, Brazil. Thus, five vegetation indices (Vegetation Extraction Color Index, Excess Green, Green Leaf Index, Normalized Green-Red Difference Index and Visible Atmospheric Resistance Index) were correlated with the production of the crop branches and were also surface coverage indexes determined. The images were processed and classified using specific software and later statistical analysis. Thus, the study showed results with potential to contribute to access to new space-time technologies and with the potential to support management planning in agro-environmental systems, in order to increase productivity in a sustainable manner to natural resources.

Keywords: *Ipomoea potatoes. L.* RGB. Drone Monitoring

## LISTA DE FIGURAS

### PARTE 1

Figura 1 - Cultivo de Batata-doce .....	16
Figura 2 - Tipos de VANT .....	19
Figura 3 - Assinatura Espectral .....	23

### PARTE 2

Figura 1 - Localização da área de estudo .....	37
Figura 2 - Mapa de produtividade por classes.....	42
Figura 3 - Regressão linear entre os rendimentos .....	44
Figura 4 - Índice de cobertura vegetal entre junho e outubro.....	45
Figura 5 - Comparação visual no espectro RGB .....	47

## LISTA DE TABELAS

### PARTE 1

Tabela 1 - Tecnologias para Agricultura de Precisão .....	15
---	----

### PARTE 2

Tabela 1 - Índices de vegetação utilizados .....	39
Tabela 2 - Classes de produtividade das ramas .....	40
Tabela 3 - Valores médios dos índices de vegetação .....	42
Tabela 4 - Resultados dos modelos de regressão linear .....	43
Tabela 5 - Índices de cobertura vegetal nos meses de junho e outubro .....	46

## SUMÁRIO

### PARTE 1 INTRODUÇÃO - REVISÃO BIBLIOGRÁFICA DO TEMA ESTUDADO

<b>1 INTRODUÇÃO</b> .....	<b>11</b>
<b>2 REVISÃO DE LITERATURA</b> .....	<b>14</b>
2.1 AGRICULTURA DE PRECISÃO .....	14
2.2 BATATA-DOCE .....	16
2.3 VEÍCULOS AÉREOS NÃO TRIPULADOS .....	17
2.4 REGULAMENTAÇÃO E LEGISLAÇÃO SOBRE VANT .....	21
2.5 SENSORIAMENTO REMOTO E ÍNDICES DE VEGETAÇÃO .....	22
<b>REFERÊNCIAS</b> .....	<b>25</b>

### PARTE 2 ARTIGO - USO DE IMAGENS OBTIDAS A PARTIR DE DRONE NO MONITORAMENTO DO CULTIVO DE BATATA-DOCE POR ÍNDICES DE VEGETAÇÃO

<b>INTRODUÇÃO</b> .....	<b>34</b>
<b>MATERIAIS E MÉTODOS</b> .....	<b>37</b>
<b>RESULTADOS E DISCUSSÃO</b> .....	<b>41</b>
<b>CONCLUSÕES</b> .....	<b>48</b>
<b>REFERENCIAS</b> .....	<b>49</b>

## PARTE 1

### 1 INTRODUÇÃO

O emprego de tecnologias de sensores remotos aerotransportados associados às práticas de manejos sustentáveis tem impactado positivamente a agricultura, facilitando o monitoramento da vegetação e dos solos em escala de maior detalhe, o que pode resultar em maior produtividade e maior eficiência no aproveitamento de recursos naturais, econômicos e humanos (DALCHIAVON, 2012). Para tanto, é necessário planejamento para que as terras agrícolas sejam uma oportunidade e não o contrário em relação ao desenvolvimento sustentável (PARSIPOUR *et al.*, 2019).

A aplicação e a consolidação dos Veículos Aéreos Não Tripulados (VANT) ou Remotely Piloted Aircraft (RPA), como plataformas de imageamento terrestre, após um histórico de aplicações militares e civis, estão se firmando como uma ferramenta de uso amplo na agricultura (SALAMÍ *et al.*, 2014). Tal fato, se justifica pela redução dos custos e flexibilidade destas aeronaves em avaliar áreas remotas empregando sensores multiespectrais, os quais possibilitam avaliar diferentes atributos ligados as culturas agrícolas. Estes equipamentos operam em diferentes configurações e permitem avaliações com distintas resoluções espectrais, radiométricas, temporais e espaciais o que fazem destes instrumentos e tecnologias potentes aliados quando se trata de investigação ambiental (RASI, 2008; PÁDUA *et al.*, 2017).

Diante disso, ao considerarmos as estimativas futuras de padrões de consumo e de crescimento demográfico, a análise espacial suportada por sensores remotos e VANTs, são uma ferramenta para fiscalização e conservação dos recursos naturais, além de uma técnica que pode ser utilizada para melhorar o zoneamento agrícola, especialmente nas áreas com maiores necessidades de mitigação dos impactos e de correções da fertilidade, que leva a ganhos de produtividade e de tempo, configurando assim em uma ferramenta que possibilita aos gestores adotarem medidas de curto, médio e longo prazo. Por estas funcionalidades, estas técnicas hoje são empregadas nos mais diversos campos, como por exemplo, no geológico, em que Eisenbeiss (2009) aplicou para mapeamento tectônico tridimensional, de uma área montanhosa na Suíça; para monitorar o estresse hídrico e fisiológico de plantas; para o

mapeamento de áreas de preservação como demonstra Ferrier e Drielsma (2010); Franke *et al.* (2012) e Jorge *et al.* (2014); no mapeamento e modelagem de erosão (D'OLEIRE-OLTMANN *et al.*, 2012) e, assim, contribui efetivamente para o planejamento sustentável dos sistemas de produção (EMBRAPA, 2014).

O uso destas aeronaves apresenta resultados relevantes no monitoramento de uma série de cultivos agrícolas, como café (*Coffea spp.*) (FELIX, 2019; PARREIRAS *et al.*, 2020), arroz (*Oryza sativa*) (SWAIN *et al.*, 2010; ZHOU *et al.*, 2017); batatas (*Solanum tuberosum L.*) (SANKARAN *et al.*, 2017; HUNT JUNIOR *et al.*, 2018); da cana-de-açúcar (*Saccharum spp.*) (SOUZA *et al.*, 2017); feijão (*Phaseolus vulgaris L.*) (BENIAICH *et al.*, 2019); trigo (*Triticum aestivum*) (RISSINI *et al.*, 2015); mandioca (*Manihot esculenta*) (ARANTES *et al.*, 2019) e tomate (*Lycopersicon esculentum*) (ABDULRIDHA *et al.*, 2020). Todos exemplos citados ilustram resultados representativos da aplicação destas novas tecnologias às práticas tradicionais de cultivo.

Em geral, para o emprego agrossilvopastoril tais abordagens são baseadas em índices de vegetação (IV) (QUINTO *et al.*, 2012), ou seja, combinações matemáticas entre as bandas espectrais utilizadas pelos sensores aerotransportados a fim de se detectar anomalias, como doenças, pragas, estresse hídrico, áreas para correção de fertilidade, para estimar a produção, avaliar áreas suscetíveis a maiores riscos naturais ou simplesmente mapear áreas de interesse que possuam sua distribuição sobre a superfície terrestre e sejam passíveis de georreferenciamento.

Atualmente, são encontrados diversos IV na literatura, tais como Color Index of Vegetation (CIVE) (KATAOKA *et al.*, 2003), Excess Green (ExG) (WOEBBECKE *et al.*, 1995), Green Leaf Index (GLI) (LOUHAICHI *et al.*, 2001), Normalized Green-Red Difference Index (NGRDI) (TUCKER *et al.*, 1979), o Visible Atmospherically Resistant Index (VARI) (GITELSON *et al.*, 2002). No entanto, o IV mais utilizado é o Normalized Difference Vegetation Index (NDVI) (ROUSE *et al.*, 1974), que consiste na combinação das bandas do vermelho e infravermelho próximo (do inglês, “Near-Infrared” – NIR) para realçar a vegetação em relação ao solo exposto, sendo empregado principalmente na determinação da biomassa.

O ápice na tecnologia de emprego dos IV a partir de aerolevantamentos com VANT é na sua utilização como dado de entrada para modelagem e

classificação de imagens (CHAVES; ALVES, 2019). Assim, são conduzidas análises robustas que permitem correlacionar diversas variáveis à resposta espectral dos alvos. Esta prática vem ganhando força principalmente devido ao uso de softwares livres e a inserção de cidadãos na ciência, que é uma iniciativa que visa automatizar e divulgar rotinas a longo prazo. Tais rotinas e protocolos para classificações possibilitam uma melhor compreensão da dinâmica natural (nutrientes, gases, etc.) em diferentes sistemas de manejos, o que pode racionalizar as tomadas de decisões em diversos níveis e escalas administrativos (BIAU, 2012; OSCO *et al.*, 2019).

Em geral, os pequenos produtores familiares não têm acesso ao uso destas ferramentas. Porém, pode ilustrar o uso destas ferramentas para outros cultivos agrícolas mais expressivos na agropecuária brasileira que poderão incorporar estas tecnologias no controle do desenvolvimento fenológico e da produção dos cultivos, a partir da agricultura de precisão (AP).

## 2 REVISÃO DE LITERATURA

### 2.1 AGRICULTURA DE PRECISÃO

O desenvolvimento da AP está em expansão no mundo todo. Pois, permite corrigir impactos negativos e corrigir as deficiências produtivas com maior exatidão, reduzindo assim o consumo de insumos, de tal modo, reduz o impacto gerado pelas atividades agrícolas em toda a sua cadeia produtiva. Em virtude disto, reduz custos, aumenta a produtividade e diminui os impactos ambientais. Pois, consome menos recursos e produz mais por área plantada. Estas técnicas permitem, pelo planejamento das ações de fertilização, de irrigação e controle de doenças, melhorar a produtividade e a renda dos produtores (VEGA *et al.*, 2015, HUNT JUNIOR *et al.*, 2018), principalmente dos que produzem batata-doce, que são, em sua maioria, os pequenos agricultores.

Assim, o emprego de tecnologias na melhoria das práticas de conservação ambiental, a fim de proporcionar condições ideais às espécies cultivadas na agricultura, sejam elas químicas, físicas ou biológicas, possibilitam a utilização de recursos de forma eficiente, melhorando a rentabilidade, produtividade e reduzindo os impactos deletérios gerados. De tal modo, a AP está associada à utilização de técnicas modernas para avaliar e acompanhar, de maneira mais precisa, as condições das áreas de atividades agronômicas, com base na variabilidade do solo, do clima, da paisagem, da geologia entre outras características biofisiográficas, que permitem melhorar a sustentabilidade dos sistemas agrícolas (TORKY; HASSANEIN, 2020).

O uso de sensores remotos aerotransportados permite, assim, reduzir significativamente o tempo necessário para a extração de informações das imagens e, conseqüentemente, para que os produtores agrícolas melhorem as práticas de manejo. Integrando, portanto, as habilidades dos pesquisadores com as dos agricultores para definir os meios mais adequados de exploração destas tecnologias de AP, promovendo a sustentabilidade agrícola (ZHANG; KOVACS, 2012). A Tabela 1 apresenta uma síntese das vantagens de se utilizar estes sensores e tecnologias da AP por imageamento remoto aerotransportado.



Tabela 1 – Tecnologias para agricultura de precisão.

<b>Tipo de tecnologia</b>	<b>Objetivos e Benefícios</b>
Ferramentas de decisão computacional	Obter dados para desenvolver recomendações para gerenciamento e otimização de várias tarefas.
Armazenamento em Nuvem	Fornecer dados eficientes, baratos e centralizados, visa o armazenamento e a comunicação no gerenciamento agrícola.
Sensores	Reunir informações sobre o funcionamento do equipamento e recursos agrícolas para apoiar decisões de gerenciamento.
Robôs	Implementação de tarefas com eficiência e mínimo de mão-de-obra humana.
Ferramentas de comunicação digital (móvel, banda larga)	Permitir comunicação frequente e em tempo real entre o produtor, trabalhadores, gerentes e recursos em apoio à gestão.
Localização geográfica (GPS, RTK, PPK)	Fornecer a localização precisa dos recursos da lavoura (campo equipamentos, animais etc.), geralmente combinados com medições (rendimento, etc.) ou usado para direcionar o equipamento.
Sistemas de Informação Geográfica	Mapeamento computadorizado para ajudar no gerenciamento do inventário e fazer prescrições geográficas de entrada de culturas (fertilizantes, etc.).
Monitores de rendimento	Empregue sensores e GPS nas colheitadeiras para continuamente medir a taxa de colheita e fazer mapas de produtividade que permitam na identificação da variabilidade local da produção.
Amostragem precisa do solo	Amostra de solo em alta resolução espacial (em zonas) para detectar e gerenciar padrões de fertilidade em campos.
Detecção de refletância espectral (proximal e remota)	Medir a refletância da luz no solo ou da colheita usando satélite, avião ou drone, imagem ou equipamento de campo, sensores para determinar o padrão do solo, a colheita ou desempenho animal ou em problemas de nutrientes / pragas.
Direção automática e orientação	Redução do trabalho ou a fadiga com a tecnologia autônoma para equipamento agrícola (incluindo robôs); guiando com precisão o equipamento nos campos para permitir uma colheita altamente precisa, posicionamento e gerenciamento de entrada.
Tecnologia de taxa variável	Permite o ajuste contínuo das taxas de aplicação para corresponder com precisão as necessidades de culturas localizadas em áreas de campo com aplicadores de campo para insumos agrícolas (produtos químicos, sementes, etc.).
Computadores de bordo	Coleta e processamento de dados de campo com computadores especializados (hardware e software) em tratores, colheitadeiras, etc., geralmente conectados a sensores e controladores.
Identificação de rádio frequência	Transmitir dados de identidade com taxas anexadas a unidades de produção (principalmente animais) que permitem a coleta de dados em desempenho, bem como gestão individualizada.

Fonte: VEKIC *et al.*, 2017. Adaptado.

## 2.2 BATATA-DOCE

A batata-doce, *Ipomoea batatas*. L. é uma hortaliça, raiz tuberosa da família das convolvuláceas muito popular e cultivada em todo o território brasileiro, rústica e de ampla adaptação, alta tolerância à seca e fácil cultivo (EMBRAPA, 1995; GONÇALVES NETO, 2011). A planta tem origem no continente americano, relatos de seu uso mencionam em mais de dez mil anos, com base em análise de batatas secas encontradas em cavernas localizadas no Vale de Chilca Canyon, no Peru e em evidências contidas em escritos arqueológicos encontradas na região ocupada pelos Maias, na América Central e do Norte (EMBRAPA, 2008) (FIGURA 1).

Figura 1 – A) O cultivar durante o ciclo de desenvolvimento na área onde ocorreu o experimento; B) Destaque para a própria raiz colhida no experimento.



Fonte: SILVA (2019).

Dentre os diversos usos, a batata-doce é tradicionalmente utilizada na alimentação humana, animal e, recentemente, na produção de etanol (CAMARGO *et al.*, 2016). O cultivar se adapta melhor em áreas tropicais e fornece alimento humano de bom conteúdo nutricional, fonte de energia e de proteínas. A batata-doce tem grande importância também na alimentação animal e na produção industrial de farinha, amido e álcool. É considerada uma cultura rústica, pois apresenta grande resistência a pragas e doenças, pouca resposta à aplicação de fertilizantes, baixo custo de produção e cresce em solos pobres e degradados, além de atuar na proteção do solo pelo seu dossel (EMBRAPA, 2008).

A batata-doce é cultivada principalmente pela agricultura familiar (AZEVEDO *et al.*, 2014). De maneira geral, pelo baixo nível tecnológico praticado, resulta num rendimento insatisfatório (SANTOS, 2018) e na maioria das vezes é utilizada apenas para alimentação humana, sem aproveitamento das ramas e as raízes que não atendem ao padrão comercial, podendo ser utilizadas para a alimentação animal (FIGUEIREDO *et al.*, 2012). O cultivar pode ser selecionado para maior produção de ramas e raízes para alimentação animal (VIANA *et al.*, 2011; ANDRADE JÚNIOR *et al.*, 2012).

Cultivo alimentar que apresenta certa relevância, depois do arroz, trigo, milho e a batata inglesa, as raízes e folhas apresenta excelente valor nutricional exigido pela dieta humana. Pesquisas sobre a extração e as propriedades estruturais, físicas e químicas dos componentes funcionais da batata-doce e dos subprodutos do processamento industrial ganharam ampla atenção, e importância para promover o aumento do consumo de batata-doce na dieta humana. Esta é uma tendência inevitável para o desenvolvimento sustentável da produção agrícola e a melhoria dos hábitos alimentares da humanidade. A maior produção de batata-doce é na Ásia, seguida pela África, América e Oceania (MU; SINGH, 2019).

### 2.3 VEÍCULOS AÉREOS NÃO TRIPULADOS (VANT)

O termo “drone” descreve qualquer aeronave com alto grau de automatismo. Em geral, todo drone é considerado uma aeronave não tripulada categorizada como aeromodelo, aeronaves remotamente pilotadas (RPA) ou Aeronave Não Tripulada Autônoma. Pelo regulamento da Agência Nacional de Aviação Civil – ANAC, aeromodelos são aeronaves não tripuladas utilizadas para lazer. RPA são aeronaves não tripuladas usadas para outros fins, como corporativo ou comercial. Aeronaves Não Tripuladas Autônomas, nas quais há interferência do piloto durante o voo, não estão contempladas na norma e sua utilização permanece proibida no Brasil. De acordo com a ANAC (2017), são subdivididas pelo peso médio de decolagem (PMD) em três classes: a primeira classe cujo peso para decolagem é maior do que 150 kg, a segunda delimita um intervalo de peso entre 25 kg e 150 kg e a terceira classe aponta o peso máximo de decolagem de até 25 kg.

Atualmente, os drones (Figura 2) possuem uma natureza e caráter multidisciplinar, realizando tarefas a custos relativamente baixos em comparação às aeronaves tripuladas. Apresentam maior flexibilidade de operação, elevada resolução espacial e temporal, em geral não necessitam de pistas de pouso, são de fácil transporte, acessam locais remotos sem riscos à aeronave e à tripulação e são, especialmente, úteis, na aerofotogrametria e na coleta de dados para o monitoramento ambiental (JORGE, 2001). Além disso, sofrem pouca influência de fatores relacionados as perturbações atmosféricas, como a presença de nuvens e aerossóis, que influenciam diretamente nos sensores dos satélites. Também, não são afetados pela presença de nuvens e chuvas, que podem interromper o monitoramento por imagens orbitais durante o desenvolvimento do cultivo (OLIVETTI, 2019).

Existem três tipos de Drones, o multirotor, o de asa fixa e os híbridos (FIGURA 2). O multirotor é mais utilizado para a realização de serviços em áreas menores. O de asa fixa tem a capacidade de cobrir áreas maiores, devido sua estrutura, que garante mais sustentação durante o voo (MARQUES; SOUZA, 2019) e há uma nova categoria, que concilia as vantagens das categorias mencionadas anteriormente, denominados de drones híbridos, devem se tornar uma terceira categoria (LUCENA; FREIRE JUNIOR, 2018).

A estação de controle no solo é outro componente importante do conjunto que complementa esta ferramenta, é composta por um dispositivo móvel, como um laptop ou tablet, com softwares devidamente configurados para controle de voo autônomo e ou um rádio controlador, que permite ao operador o planejamento das missões de voo, o monitoramento e o controle da aeronave durante o voo. De tal forma, que o sistema de telecomunicação entre a aeronave e a estação de controle permita ao controlador receber informações da aeronave, como velocidade, altitude de voo, autonomia e posição geográfica, bem como enviar informações de comando para modificações na trajetória da aeronave e acionamento dos dispositivos de sensoriamento remoto (SR), além de outros mecanismos com funções específicas (SIQUEIRA JUNIOR, 2018).

O interesse nos drones tem crescido em todo mundo. Avanços recentes na tecnologia computacional, desenvolvimento de softwares, materiais mais leves, sistemas globais de navegação, avançados links de dados, sofisticados sensores e a miniaturização são os motivos do aumento de desenvolvimentos

de drones. Assim, mais de 40 países têm trabalhado no desenvolvimento de drones para diferentes mercados, e os Estados Unidos aparecem como um dos líderes em termos de tamanhos, tipos e sofisticações dos sistemas, voltados principalmente para o mercado militar ao lado de Israel, junto com Japão, China, Coreia do Sul, Austrália, França, Inglaterra, Itália, Alemanha e África do Sul (EMBRAPA, 2014).

Figura 2 – A) Modelo de Drone multirrotor; B) Modelo de Drone asa fixa; C) Modelo de Drone híbrido.



Fonte: Disponível em: <<https://www.dji.com/br/phantom-3-se>>; <<https://xmrobots.com.br/echar-20d/>>; <<https://technology.nasa.gov/patent/LAR-TOPS-241>>. Acesso em 11 novembro 2019.

De acordo com Colomina e Molina (2014), o uso dos drones no campo da fotogrametria e sensoriamento remoto compreende uma gama diversificada de aspectos, incluindo tecnologia, direitos de privacidade, segurança e regulamentações. A fotogrametria moderna identificou o potencial das imagens por meio de drones há mais de trinta anos. Nos últimos anos, desenvolveram tecnologias e métodos que desafiam a atual estrutura regulatória aeronáutica e os métodos tradicionais de aquisição e processamento. Simplicidade e engenhosidade combinaram equipamentos de baixo custo, com sofisticada visão

computacional, robótica e engenharia geomática, tendo como resultado produtos de resolução e precisão de alto nível, que podem ser gerados mesmo com câmeras de baixo custo.

De acordo com Siqueira Junior (2018), para a obtenção de imagens aéreas e modelos digitais de elevação com finalidades relacionadas à AP e ao monitoramento ambiental se utilizam, geralmente, câmeras digitais de pequeno a médio formato, não métricas e de captura do espectro visível (RGB) ou infravermelho (NIR), sensores *light detection and ranging* (LIDAR), sensores multiespectrais e hiperespectrais.

Uma outra abordagem é a fotogrametria de estrutura a partir de movimento (SfM), com base em imagens tiradas de várias perspectivas enquanto um Drone voa sobre um campo, as câmeras digitais fornecem imagens de alta resolução e baixo custo que podem ser usadas para SfM e medição de alguns fenótipos de plantas, incluindo população, altura, acomodação, tempo de floração e rendimento (SHI *et al.*, 2016).

Os drones estão apresentando boa acurácia em usos ambientais, sendo muito utilizados na AP e monitoramento de habitats, permitindo a obtenção de dados em curto espaço de tempo; tornaram-se uma ferramenta poderosa para fenotipagem de plantas de alto rendimento em ambos os campos nos últimos anos. A avaliação de cultura de emergência, nesta abordagem provou ser mais adequada, capacidade maior do que em outras técnicas de sensoriamento remoto, devido à flexibilidade, alta resolução espacial e temporal (SANTOS *et al.*, 2015; LI *et al.*, 2019).

No caso desta pesquisa, o uso no controle agrícola com destaque no monitoramento mensal da batata-doce, correlacionando os valores obtidos da produtividade das ramas e das batatas com os cinco índices de vegetação (IV) e no acompanhamento dos índices de cobertura durante o período analisado.

#### 2.4 REGULAMENTAÇÃO E LEGISLAÇÃO SOBRE VANT

A regulação dos voos, no Brasil, ocorre desde 2017 por conta do grande aumento do número de usuários (NACKAERTS, 2010; ANAC, 2018), já nos EUA, a Advisory Circular N. 107-2 (EUA, 2020) informa que os voos sobre pessoas, voos durante a noite e além da linha de visada sejam permitidos principalmente

para o mercado militar, de forma idêntica à Israel. Países como a Austrália são pioneiros na regulamentação dos VANT desde 2002 e focam muito na segurança (AUSTRÁLIA, 2020; STÖCKER, 2017). Na África do Sul não é permitido voar a 50 m ou mais perto de qualquer pessoa ou grupo de pessoas (ÁFRICA DO SUL, 2020). Já, no Japão, segundo a *Japanese Aviation Act* e o *Ministry of Land, Infrastructure, Transport and Tourism* (MLIT), a norma estabelece a proibição de uma altura de voo igual ou superior a 150 metros do nível do solo (JAPÃO, 2020) e, no Canadá, os VANT podem ser operados por qualquer pessoa, a partir de 14 anos para obter a licença básica e aos 16 anos para obter a licença avançada. Porém, as crianças menores de 14 anos devem ser supervisionadas por alguém com licença (CANADÁ, 2020). A Agência Europeia para a Segurança da Aviação (EASA) designa que quando a pessoa se registra como operador de Drone, recebe um número de registro exclusivo, válido para um período definido, após o qual precisará renová-lo e toda informação estará disponível num sistema único acessível às Autoridades da Aviação Nacional da União Europeia (EUROPA, 2020).

## 2.5 SENSORIAMENTO REMOTO E ÍNDICES DE VEGETAÇÃO

O SR é definido como o conjunto de tecnologias empregadas para capturar, transmitir dados do ambiente terrestre a partir da sua interação com a radiação eletromagnética (REM). Assim, registra imagens digitais e outros tipos de dados mediante reflexão ou emissão de energia pela superfície terrestre (JENSEN, 2010). Visa obter informações contidas nas imagens e a sua codificação em documentos que possam ser lidos na forma de gráficos, mapas ou tabelas (MENESES; SANO, 2012).

O surgimento do avião acompanhado das câmeras fotográficas, uma forma primordial de SR, estimulou as aplicações das fotografias aéreas na análise e monitoramento de tropas nas guerras. Posteriormente, com os satélites, na década de 1970, essas finalidades foram expandidas para interesses em meteorologia e recursos terrestres (NOVO; PONZONI, 2001; MENESES; ALMEIDA, 2012).

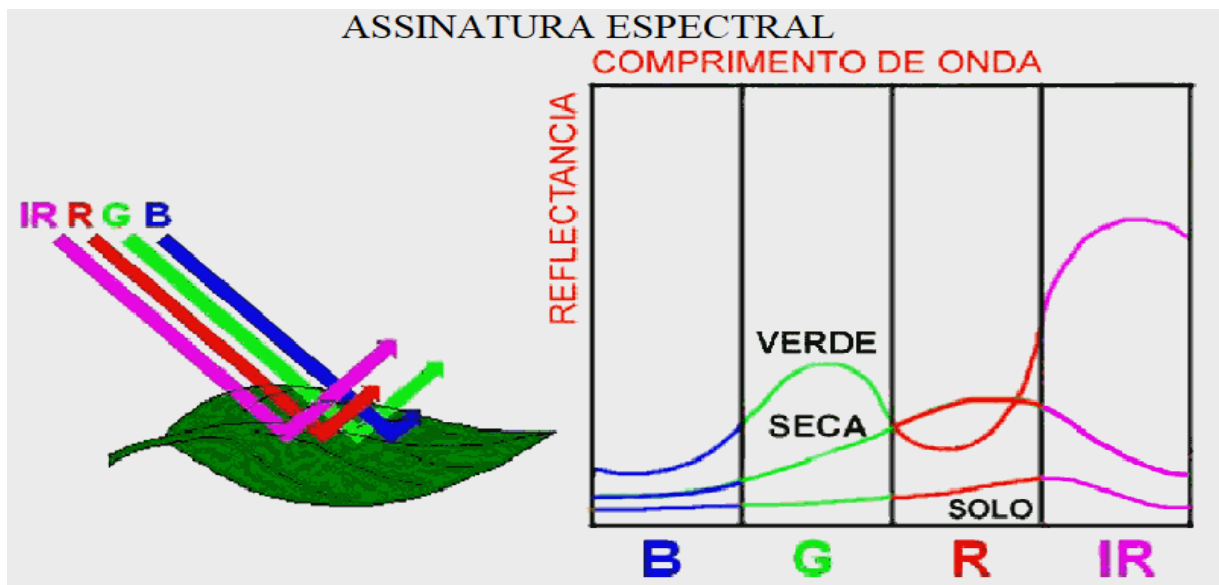
No domínio da fotogrametria e SR, o uso dos VANT compreende uma gama diversificada de aspectos, incluindo tecnologia, direitos de privacidade,

segurança e regulamentação. A fotogrametria moderna identificou o potencial das imagens por meio de VANT há mais de trinta anos (COLOMINA; MOLINA, 2014). Segundo estes autores, neste século, foram desenvolvidos tecnologias e métodos que desafiam a atual estrutura regulatória aeronáutica e os próprios métodos tradicionais de aquisição e processamento dos dados obtidos. A normalização de imagens é um desses métodos, consiste no tratamento de imagens multitemporais, retificadas com relação a imagem-referência (HALL *et al.*, 1991; YUAN; ELVIDGE, 1996). A engenhosidade dos equipamentos, a sofisticação computacional, a robótica e a engenharia geomática (COLOMINA *et al.*, 2008) propiciam produtos de resolução e precisão elevada, que podem ser gerados mesmo com câmeras convencionais não-métricas (SIMARD *et al.*, 2011).

Imagens de SR podem ser utilizadas para mapear propriedades do solo (D'OLEIRE-OLTMANN *et al.*, 2012), classificação de espécies de culturas (TORRES-SÁNCHEZ *et al.*, 2013), detecção de estresse hídrico (ZARCO-TEJADA *et al.*, 2012; HOFFMAN *et al.*, 2016; PARK *et al.*, 2017; GHAZOUANI *et al.*, 2017) monitoramento de ervas daninhas (SALAMÍ *et al.*, 2014; ARANTES *et al.*, 2019) e doenças de cultivos (SUGIURA *et al.*, 2016; MAES; STEPPE, 2019) e mapeamento do rendimento das plantações (JORGE *et al.*, 2014; ANDRADE *et al.*, 2019; MAES; STEPPE, 2019). A sua aplicação é difundida na agricultura de precisão e na análise ambiental (COLOMINA; MOLINA, 2014). Tais aplicações são baseadas em medidas da radiação em diferentes comprimentos de onda, para determinar as assinaturas espectrais (FIGURA 3) e os diagnósticos (LEONARD, 2016).



Figura 3 – Folha verde com valores diferentes de reflectância para cada comprimento de onda, do azul ao infravermelho.



Fonte: Disponível em: <http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>. Acesso em 26 novembro 2019. B = Blue; G = Green; R = Red e IR = Infrared.

Para tanto são utilizados IV, que buscam relacionar as informações captadas pelos sensores a partir de relações matemáticas entre as bandas empregadas, normalmente entre as bandas do Visível e infravermelho. Assim, é possível a estimativa indireta da biomassa, quantidades de clorofila, do índice de área foliar (IAF) e da umidade, baseadas em atributos espectrais de determinado objeto ou cobertura terrestre (JENSEN, 2010; SISDAGRO, 2019).

A aplicação dos IV possuem uma importante função no manejo e monitoramento de coberturas vegetais, principalmente quando incorporados com os VANT e demais plataformas tecnológicas de precisão (YANG *et al.*, 2006; BRYSON *et al.*, 2010).

Um dos IV utilizados é o *Normalized Difference Vegetation Index* (NDVI) (ROUSE *et al.*, 1974) é o índice de vegetação mais difundido, com valores que variam de 0 a 1 e que utiliza das bandas do vermelho e do NIR (EQUAÇÃO 1).

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

Em que: NDVI = Normalized Difference Vegetation Index; NIR = Reflectividades da banda no infravermelho; Red = Reflectividades da banda no vermelho.

Todavia, o objetivo deste estudo foi de usar índices que utilizem apenas frequências do espectro visível

Em se tratando sobre a vegetação, vale salientar a relevância da cobertura vegetal na defesa natural do solo contra a erosão hídrica (BERTONI; LOMBARDI NETO, 2017) pois a cobertura vegetal assegura a eficácia em relação às perdas de solo (SOUZA *et al.*, 2010), e o índice de cobertura (IC) que é a porcentagem de área coberta pela vegetação em relação ao total da área (ZHONGMING *et al.*, 2010) deve ser quantificado, conforme foi aplicado neste trabalho (EQUAÇÃO 2).

$$ICV = CP/TP \quad \text{(Equação 2)}$$

Em que: CP – número de pixels atribuídos à determinada classe; TP – número total de pixels da área de estudo.

## REFERÊNCIAS

ABDULRIDHA, J. *et al.* Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. **Precision Agriculture**, Baltimore, v. 21, n. 5, p. 955–978, 2020. DOI: 10.1007/s11119-019-09703-4

ÁFRICA DO SUL. **South African Civil Aviation Authority (SACAA)**. 2020. Disponível em: <<http://www.caa.co.za/>> - Acesso em: 30 out. 2020.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). **Normas de Voo segundo a ANAC**. 2018. Disponível em: <[http://www.anac.gov.br/assuntos/paginastematicas/VANTs/orientacoes\\_para\\_usuarios.pdf](http://www.anac.gov.br/assuntos/paginastematicas/VANTs/orientacoes_para_usuarios.pdf)> - Acesso em: 26 mar. 2018.

AGISOFT. **Agisoft PhotoScan User Manual**. Petersburg: Agisoft LLC, 2017. Disponível em: <<http://www.agisoft.ru>>. Acesso em: 20 fev. 2019.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, n. 6, p. 711-728, 2013.

ANDRADE JÚNIOR, V. C. *et al.* Características produtivas e qualitativas de ramas e raízes de batata-doce. **Horticultura brasileira**, Vitória da Conquista, v. 30, n. 4, p. 584-589, 2012. DOI: 10.1590/S0102-05362012000400004

ANDRADE, R. G. *et al.* **Uso de veículo aéreo não tripulado (VANT) como plataforma para monitoramento da produção agropecuária: estudo de caso para o milho forrageiro**. Juiz de Fora: Embrapa Gado de Leite, 2019. 20 p. (INFOTECA-E)

ARANTES, B. H. T. *et al.* Drone aplicado na agricultura digital. **Ipê Agronomic Journal**, Goianésia, v. 3, n.1, p.14-18, 2019. DOI: 10.37951/2595-6906.2019v3i1.4323

AUSTRÁLIA. **Civil aviation safety authority: Flying drones/remotely piloted aircraft in Australia**. 2018. Disponível em: <<https://www.casa.gov.au/aircraft/landing-page/flying-drones-australia>>. Acesso em: 30 out. 2020.

AZEVEDO, A. M. *et al.* Influence of harvest time and cultivation sites on the productivity and quality of sweet potato. **Horticultura Brasileira**, Vitória da Conquista, v. 32, n. 1, p. 21-27, 2014. DOI: 10.1590/S0102-05362014000100004

BERTONI, J.; LOMBARDI NETO, F. **Conservação do solo**. 10.ed. São Paulo: Ícone, 2017. 355p.

BENIAICH, A. *et al.* Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. **Semina: Ciências Agrárias**,

Londrina, v. 40, n.1, p.49-66. 2019. DOI: 10.5433/1679-0359.2019v40n1p49

BIAU, G. Analysis of a Random Forests model. **Journal of Machine Learning Research**, New York, v. 13, n.4, p.1063-1095, 2012. DOI: 10.5555/2188385.2343682

BRYSON, Mitch *et al.* Airborne vision-based mapping and classification of large farmland environments. **Journal of Field Robotics**, New Jersey. v. 27, n. 5, p. 632-655, 2010.

CAMARGO, L. K. P. *et al.* Uso de índice de seleção na identificação de genótipos de batata-doce com diferentes aptidões. **Horticultura Brasileira**, Vitória da Conquista, v. 34, n. 4, p. 514-519. 2016. DOI: 10.1590/s0102-053620160410.

CANADÁ. **Transport Canada**: Flying an unmanned aircraft recreationally. Quebec, 2015. Disponível em: <[http://www.tc.gc.ca/eng/civilaviation/standards/general-recavi-uav-2265.htm?WT.mc\\_id=1zfhj#safety](http://www.tc.gc.ca/eng/civilaviation/standards/general-recavi-uav-2265.htm?WT.mc_id=1zfhj#safety)> - Acesso em: 07 nov. 2020.

CHAVES, M. E. D.; ALVES, M. de C. Recent applications of the MODIS sensor for soybean crop monitoring and deforestation detection in Mato Grosso, Brazil. **CAB Reviews**, Wallingford, v.14, n.7, p.1-9, 2019. DOI: 10.1079/PAVSNR201914007

COLOMINA, I. *et al.* Towards a new paradigm for high-resolution low-cost photogrammetry and remote sensing. **Remote Sensing Spatial Information**, London, v. 37, n.1, p.1201-1206, 2008. DOI: 10.3390/rs4113390

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 92, n.1, p. 79-97, 2014. DOI: 10.1016/J.ISPRSJPRS.2014.02.013

DALCHIAVON, F. C. **Correlações de Pearson e geoestatísticas entre a produtividade de cana-de-açúcar, estabelecida em dois métodos de colheita, e atributos físico-químicos do solo**. 2012. 112 f. Tese (Doutorado em Sistemas de Produção) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

D'OLEIRE-OLTMANN, S. *et al.* Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. **Remote Sensing**, Basel, v. 4, n. 11, p. 3390-3416, 2012. DOI: 10.3390/rs4113390

EISENBEISS, H. **UAV Photogrammetry**. 2009. 203 f. Doctoral Thesis (PhD em Ciências) - Institut für Geodesie und Photogrammetrie ETH, Zurich, 2009.

EMBRAPA. A cultura da batata-doce. Centro Nacional Pesquisa de Hortaliças. Brasília: Editora da Embrapa, 1995. 56 p.

\_\_\_\_\_ Manejo do solo no sistema de produção orgânico de hortaliças. Centro Nacional Pesquisa de Hortaliças. Brasília: Editora da Embrapa, 2008. 87 p.

\_\_\_\_\_ Sistema de produção da batata doce. 2008. Disponível em: [https://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Batata-doce/Batata-doce\\_Ipomoea\\_batatas/introducao.html](https://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Batata-doce/Batata-doce_Ipomoea_batatas/introducao.html)>. Acesso em: 06 nov. 2019.

\_\_\_\_\_ O produtor pergunta, a Embrapa responde. Centro de Pesquisas de Geotecnologia e Geoinformação. Brasília: Editora da Embrapa, 2014. 111 p.

ESRI - Environmental Systems Research Institute. ARCGIS Professional GIS for the desktop [version 10.5.] Redlands, Califórnia, Software. 2017.

ESTADOS UNIDOS DA AMÉRICA. **Unmanned Aircraft Systems (sUAS)**. Advisory Circular Nº107-2. 2016. Disponível em: <[https://www.faa.gov/documentLibrary/media/Advisory\\_Circular/AC\\_107-2.pdf](https://www.faa.gov/documentLibrary/media/Advisory_Circular/AC_107-2.pdf)>. Acesso em: 31 out. de 2020.

EUROPA. **Normas da Agência Europeia para a segurança da Aviação (Aesa)**. Disponível em: <<https://www.easa.europa.eu/domains/civil-drones-rpas>> - Acesso em: 11 nov. 2019.

FELIX, F. C. **Comportamento sazonal de coberturas vegetais a partir de imagens de sensores embarcados em veículo aéreo não tripulado**. 2019. 152 f. Dissertação (Mestrado em Ciências Ambientais -Tecnologias Ambientais Aplicadas). Universidade Federal de Alfenas, Alfenas, 2019.

FERRIER, S.; DRIELSMA, M. Synthesis of pattern and process in biodiversity conservation assessment: a flexible whole-landscape modelling framework. **Diversity and Distributions**, New Jersey, v. 16, n. 3, p. 386-402, 2010. DOI: 10.1111/j.1472-4642.2010.00657.x

FIGUEIREDO, J. A. *et al.* Avaliação de silagens de ramas de batata-doce. **Horticultura Brasileira**, Vitória da Conquista, v. 30, n. 4, p. 708-712, 2012. DOI: 10.1590/S0102-05362012000400024.

FRANKE, J. *et al.* Assessment of grassland use intensity by remote sensing to support conservation schemes. **Journal for Nature Conservation**, Amsterdam, v. 20, n. 3, p. 125-134, 2012. DOI: US201400008381

GITELSON, A. A. *et al.* Vegetation and soil lines in visible spectral space: a concept and technique for remote estimation of vegetation fraction. **International Journal of Remote Sensing**, Amsterdam, v. 23, n. 13, p. 2537-2562, 2002. DOI: 10.1080/01431160110107806

GHAZOUANI H. *et al.* Potential of Thermal Images and Simulation Models to Assess Water and Salt Stress: Application to Potato Crop in Central Tunisia.

**Chemical Engineering Transactions**, Milano, v.58, n. 1, p. 709-714, 2017.  
DOI: 10.3303/CET1758119

GONÇALVES NETO, A. C. **Aptidões para consumo humano, produção de etanol e alimentação animal em clones de batata-doce**. 2011. 77 f. Tese (Doutorado em Agronomia). Universidade Federal de Lavras, Lavras, 2011.

HALL, F. G. *et al.* Radiometric rectification: toward a common radiometric response among multirate, multisensor imagens. **Remote Sensing of Environment**, New York, v.35, n.1, p.11-27, 1991.

HUNT JUNIOR, E. R. *et al.* Monitoring nitrogen status of potatoes using small-unmanned aerial vehicles. **Precision Agriculture**, Baltimore, v.19, n.2, p. 314-333, 2018. DOI: 10.1007/s11119-017-9518-5

JAPÃO. Japan's safety rules on Unmanned Aircraft (UA)/Drone. XXXX.  
Disponível em: <<http://www.mlit.go.jp/en/koku/uas.html>>. Acesso em: 30 out de 2020.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 3. ed. Saddle River: Pearson Prentice Hall, 2010. 1076 p.

JORGE, L. A. C. **Determinação da cobertura de solo em fotografias aéreas do projeto ARARA**. 2001. 111 f. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2001.

JORGE, L. A. C. *et al.* Insights and recommendations of use of UAV platforms in Precision agriculture in Brazil. **Remote Sensing**, Amsterdam, v. 33, n. 7, p. 911-923, 2014. DOI: 10.13140/2.1.2710.4328

KATAOKA, T. *et al.* Crop growth estimation system using machine vision. **Advanced Intelligent Mechatronics**, Kobe, v. 2, n. 1, p. 1079-1083, 2003.

LEONARD, E. C. **Precision Agriculture**. Maitland: Agri Knowhow, 2016.567 p.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. **Geocarto International**, Oxford, v. 16, n. 1, p. 65-70, 2001. DOI: 10.1080/10106040108542184

LUCENA, A. N.; FREIRE JUNIOR, R. C. S. **Desenvolvimento de um Veículo Aéreo não Tripulado com sustentação e propulsão híbrida**. 2018. 141 f. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharias, Universidade Federal do Rio Grande do Norte, Natal, 2018.

MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science**, Amsterdam, v. 24, n. 2, p.152-164, 2019. DOI: 10.1016/j.tplants.2018.11.007

MARQUES, G. R. R. C.; SOUZA P. G. Georreferenciamento de Imóvel Rural Utilizando VANT (ARP). **Brazilian Journal of Technology**, Curitiba, v. 2, n. 1, p. 424-438, 2019.

MENESES, P. R.; SANO E. E. **Classificação pixel a pixel de imagens**. In: MENESES, P. R.; ALMEIDA, T. Introdução ao Processamento de Imagens de Sensoriamento Remoto. 1. ed Brasília: UnB, cap.12, p.191-208, 2012.

MU, T. H.; SINGH, J. **Sweet Potato Chemistry, Processing, and Nutrition**. London: Elsevier Inc, 2019. 286 p.

NACKAERTS, K. *et al.* Evaluation of a lightweighth UAS-prototype for hyperspectral imaging. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, Newcastle, v. 38, n. Part 1, 2010.

NOVO, E. M. de M.; PONZONI, F. J. **Introdução ao Sensoriamento Remoto**. São José dos Campos: Editora do INPE. 2001. 68p.

OLIVETTI, D. **Câmeras Multi e Hiperespectrais Aerotransportadas: Contribuições para monitoramento de qualidade de águas continentais**. 2019. 145 f. Tese (Doutorado em Geociências Aplicadas e Geodinâmica) – Instituto de Geociências da Universidade de Brasília, Brasília, 2019.

OSCO, L. P. *et al.* Predicting Canopy Nitrogen Content in Citrus-Trees Using Random Forest Algorithm Associated to Spectral Vegetation Indices from UAV-Imagery. **Remote Sensing**, Amsterdam, v. 11, n. 24, p.2925-2932, 2019. DOI: 10.3390/rs11242925

PÁDUA, L. *et al.* UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International Journal of Remote Sensing**, London, v. 38, n. 9, p. 2349-2391, 2017. DOI: 10.1080/01431161.2017.1297548

PAJARES, G. Overview and Current Status of Remote Sensing Applications Based on Unmanned Aerial Vehicles (UAVs). **Photogrammetric Engineering & Remote Sensing**, Amsterdam, v.81, n.1, p. 281-329, 2015. DOI: 10.14358/PERS.81.4.281

PARREIRAS, T. C. *et al.* Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee. **Coffee Science**, Lavras, v.15, n. 17, p.36-45, 2020. DOI: 10.25186/, v15i.1736.

PARSIPOUR, H. *et al.* Cities expansion and land use changes of agricultural and garden lands in peri-urban villages (case study: Bojnurd). **Agriculture and Forestry**, Niksik, v.65 n.3, p.173-187, 2019.

QUINTO, V. M. *et al.* Análise temporal da dinâmica florestal por meio de índices de vegetação em uma área reflorestada no sul do estado do Espírito Santo. In: SANTOS, A. R. dos, *et al.* (Orgs.). **Geotecnologias aplicadas aos recursos florestais**. 1ª ed. Alegre: Caufes, v. 1, p. 83-98, 2012.

- RASI, J. R. **Desenvolvimento de um veículo aéreo não tripulado para aplicação em pulverização agrícola**. 2008. 70f. Especialização (Pós-Graduação em Engenharia Rural), Universidade Federal de Pelotas, Rio Grande do Sul, 2008.
- RISSINI, A. L. L. *et al.* Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 39, n. 6, p. 1703-1713, 2015. DOI: 10.1590/01000683rbcS20140686.
- ROUSE, J. W. *et al.* **Monitoring vegetation systems in the Great Plains with ERTS**. Third ERTS Symposium, NASA SP-351 I, New York, p.309–317, 1974.
- SALAMÍ, E. *et al.* UAV flight experiments applied to the remote sensing of vegetated areas. **Remote Sensing**, Amsterdam, v. 6, n. 11, p. 81-93, 2014. DOI: 10.3390/rs61111051
- SANKARAN, S. *et al.* High-Resolution Aerial Imaging Based Estimation of Crop Emergence in Potatoes. **American Journal of Potato Research**, Basel, v. 94, n. 6, p. 658-663, 2017. DOI: 10.1007/s12230-017-9604-2
- SANTOS, E. A. S. *et al.* Geração de imagens 3D com veículo aéreo não tripulado para determinação de índice de cobertura vegetal na cultura do feijoeiro. *In: X CONGRESSO BRASILEIRO DE AGROINFORMÁTICA*, 10, 2015, Ponta Grossa, PR, Brasil. *Anais...* Ponta Grossa: Sociedade Brasileira de Agroinformática – SBIAGRO, 2015.
- SANTOS, A. A. **Efeito da remoção das ramas de batata-doce sobre sua produtividade e qualidade**. 2018. 60 f. Dissertação (Mestrado em Produção Vegetal) - Universidade Federal Vale do Jequitinhonha e Mucuri, Diamantina, Minas Gerais, 2018.
- SIMARD, M. *et al.* Mapping forest canopy height globally with spaceborne Lidar. **Journal of Geophysical Research**, New Jersey, v.116, n.4, p. 1-12, 2011. DOI: 10.1029/2011JG001708
- SISDAGRO - Sistema de Suporte à Decisão na Agropecuária. **Manual técnico**. Disponível em: <<http://sisdagro.inmet.gov.br/sisdagro/app/indiceVegetacao>> - Acesso em: 20 set. 2019.
- SILVA, J. C. O. **Seleção de clones de batata-doce para diferentes aptidões agronômicas**. 2019. 87f. Dissertação (Mestrado em Agronomia/Fitotecnia) – Universidade Federal de Lavras, Lavras, Minas Gerais, 2019.
- SIQUEIRA JUNIOR, P. **Avaliação metrológica de modelos digitais de elevação obtidos por Veículo Aéreo Não Tripulado, aplicados a estudos de processos erosivos do solo**. 2018. 55f. Dissertação (Mestrado Profissional em Tecnologias e Inovações Ambientais) - Universidade Federal de Lavras, Lavras, Minas Gerais, 2018.



SOUZA, F. S. de *et al.* Plant cover index in the period of intensive rainfall for corn crop at south of Minas Gerais state, Brazil. **Ciência e Agrotecnologia**, Lavras, v. 34, n. 2, p. 345-351, 2010.

SOUZA, C. H. W. *et al.* Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture**, Amsterdam, v.143, n.7, p. 49-56, 2017. DOI: 10.1016/j.compag.2017.10.006

SUGIURA, R. *et al.* Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. **Biosystems Engineering**, Amsterdam, v.148, n.1, p.1-10, 2016. DOI: 10.1016/j.biosystemseng.2016.04.010

SWAIN, K. C. *et al.* Adoption of an unmanned helicopter for low-altitude remote sensing to estimate yield and total biomass of a rice crop. **Transactions of the ASAE American Society of Agricultural Engineers**, Saint Joseph, v.53, n.1, p. 21-27, 2010. DOI: 10.13031/2013.29493

SWAIN, M. R.; MISHRA, J.; THATOI, H. Bioethanol production from sweet potato (*Ipomoea batatas L.*) flour using co-culture of *Trichoderma sp.* and *Saccharomyces cerevisiae* in solid-state fermentation. **Brazilian Archives of Biology and Technology**, Curitiba, v. 56, n. 2, p.171-179, 2013. DOI: 10.1590/S1516-89132013000200002

TORKY, M.; HASSANEIN, A. E. Integrating block chain and the internet of things in precision agriculture: Analysis, opportunities, and challenges. **Computers and Electronics in Agriculture**. Amsterdam, v.178, 2020. DOI: org/10.1016/j.compag.2020.105476

TORRES-SÁNCHEZ, J. *et al.* Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management. **PLoS ONE**, Adelaide, v. 8, n. 3, p. 10-18, 2013. DOI: 10.1371/journal.pone.0058210

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, Amsterdam, v.8, n. 4, p. 127-150, 1979. DOI: 10.1016/0034-4257(79)90013-0

VEGA, F. A. *et al.* Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. **Biosystems Engineering**, Amsterdam, v. 132, n. 1, p.19-27, 2015. DOI: 10.1016/j.biosystemseng.2015.01.008

VEKIC, A. *et al.* Development of Innovation in Field of Precision Agriculture. In: 28TH DAAAM INTERNATIONAL SYMPOSIUM, 2017, Vienna. Proceedings... Vienna: DAAAM International Vienna, 2017. p. 787-795.

VIANA, D. J. S. *et al.* Potencial de silagens de ramas de batata-doce para alimentação animal. **Ciência Rural**, Santa Maria, v. 41, n. 8, p. 1466-1471, 2011. DOI: 10.1590/S0103-84782011000800027

WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the American Society of Agricultural Engineers**, St Joseph, v. 38, n.1, p.259-269, 1995.

YANG, W. Analysis of leaf area index and fraction of PAR absorbed by vegetation products from the terra MODIS sensor: 2000-2005. **IEEE Transactions on Geoscience and Remote Sensing**, Pasadena, v. 44, n. 7, p. 1829-1842, 2006.

YUAN, D.; ELVIDGE, C.D. Comparison of relative radiometric normalization techniques. **ISPRS Journal of Photogrammetry & Remote Sensing**, New York, v.94, n.51, p.117-126, 1996.

ZHANG, C.; KOVACS, J. M. The application of small-unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, Basel, v. 13, n. 6, p. 693-712. 2012. DOI: 10.1007/s11119-012-9274-5

ZHONGMING, W. *et al.* Stratified vegetation cover index: A new way to assess vegetation impact on soil erosion. **Catena**, Amsterdam, v. 83, n. 1, p. 87-93, 2010.

ZHOU, X. *et al.* Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. **Journal of Photogrammetry and Remote Sensing**, Amsterdam, v.130, n. 2, p. 246-255, 2017. DOI: 10.1016/j.isprsjprs.2017.05.003

**PARTE 2****ARTIGO - USO DE IMAGENS OBTIDAS A PARTIR DE DRONE NO MONITORAMENTO DO CULTIVO DE BATATA-DOCE POR ÍNDICES DE VEGETAÇÃO**

Submetido conforme as normas da revista *Engenharia Agrícola – EAgri*.

## USO DE IMAGENS OBTIDAS A PARTIR DE DRONE NO MONITORAMENTO DO CULTIVO DE BATATA-DOCE POR ÍNDICES DE VEGETAÇÃO.

**Resumo:** O uso de drones com sensores embarcados tem crescido muito na última década, e tem fornecido excelentes resultados no monitoramento agrícola. O objetivo deste estudo foi aplicar uma análise multitemporal de imagens do espectro visível, obtidas com drone, em área cultivo de batata-doce. O estudo foi realizado em uma área experimental, com voos em junho e outubro. Foram utilizados cinco índices de vegetação (Índice de Cor de Extração da Vegetação, Excesso de Verde, Índice de Folha Verde, Índice de Diferença Verde-Vermelho Normalizado e Índice de Resistência Atmosférica Visível) para determinar o coeficiente de correlação destes com a produção das ramas. O rendimento das ramas foi também correlacionado com o rendimento das raízes para verificar se o monitoramento da cobertura vegetal pode ser um bom indicador da produtividade da cultura. Todos os índices de vegetação obtiveram altos coeficientes de correlação, em junho ( $R^2 > 0,72$ ) e outubro ( $R^2 > 0,88$ ), com a produtividade das ramas. Contudo, esta não foi eficiente para estimar a produtividade da raiz. Dessa forma, o estudo atestou a eficiência de índices de vegetação de altíssima resolução no monitoramento da cobertura vegetal da batata-doce e a capacidade da ferramenta em embasar o planejamento do manejo em sistemas agrícolas.

Palavras-chave: *Ipomoea batatas*. L; veículos aéreos não-tripulados; agricultura; sustentabilidade.

### INTRODUÇÃO

O emprego de tecnologias de sensores remotos aerotransportados, associados a práticas de manejos sustentáveis, tem impactado positivamente a agricultura, facilitando o monitoramento das áreas agrícolas em escala de maior detalhe, o que pode resultar em ganhos de produtividade e eficiência no aproveitamento de recursos naturais e humanos (Maes & Steppe, 2018), uma vez que é necessário o planejamento para que as terras agrícolas adotem a busca pelo desenvolvimento sustentável (Parsipour *et al.*, 2019).

Neste contexto, ressalta-se a aplicação e a consolidação dos veículos aéreos não tripulados (VANT), também conhecidos por RPA (Remotely-Piloted Aircraft), como plataformas de imageamento terrestre que estão se firmando

como uma ferramenta de amplo uso na agricultura, o que se justifica pela redução dos custos e flexibilidade destas aeronaves em avaliar áreas remotas empregando sensores multiespectrais, os quais possibilitam avaliar diferentes atributos ligados as culturas agrícolas, com alta resolução espacial e temporal (Maes & Steppe, 2018; Manfreda *et al.*, 2018).

Por estas funcionalidades, os VANT têm sido empregados em estudos agrícolas e apresentado resultados promissores no monitoramento de parâmetros biofísicos, ocorrência de deficiência hídrica e nutricional e de doenças com diversas culturas, tais como o café (*Coffea spp.*) (Parreiras *et al.*, 2020; Santos *et al.*, 2020; Cunha, Sirqueira Neto & Hurtado, 2019); batatas (*Solanum tuberosum L.*) (Hunt Jr. *et al.*, 2018; Sankaran *et al.*, 2017); arroz (*Oryza sativa*) (Wen *et al.*, 2018; Stavrakoudis *et al.*, 2019); cana-de-açúcar (*Saccharum spp.*) (Souza *et al.*, 2017); mandioca (*Manihot esculenta*) (Arantes *et al.*, 2019); algodão (*Gossypium L.*) (Ballester *et al.*, 2017); feijão (*Phaseolus vulgaris L.*) (Beniaich *et al.*, 2019); tomate (*Lycopersicon esculentum*) (Abdulridha *et al.*, 2020), entre outras.

Em geral, para emprego agrosilvopastoril, tais abordagens são baseadas em índices de vegetação (IV), que são combinações matemáticas entre as bandas espectrais a fim de se detectar zonas que necessitam intervenção agrônômica, áreas para correção de fertilidade, e também para estimar a produção, avaliar áreas suscetíveis a maiores riscos naturais, ou simplesmente mapear áreas de interesse (Quinto *et al.*, 2013).

Atualmente, são encontrados diversos IV na literatura, como Color Index of Vegetation (CIVE) (Kataoka *et al.*, 2003), Excess Green (ExG) (Wöbbecke *et al.*, 1995), Green Leaf Index (GLI) (Louhaichi *et al.*, 2001), Normalized Green-Red

Difference Index (NGRDI) (Tucker *et al.*, 1979), o Visible Atmospherically Resistant Index (VARI) (Gitelson *et al.*, 2002). No entanto, o IV mais utilizado é o Normalized Difference Vegetation Index (NDVI) (Rouse *et al.*, 1974), que consiste na combinação das bandas do vermelho e infravermelho próximo (do inglês, “Near-Infrared” – NIR) para realçar a vegetação em relação ao solo exposto, sendo empregado principalmente na determinação da biomassa.

O ápice na tecnologia de emprego dos IV a partir de aerolevantamentos com VANT está na sua utilização como dado de entrada para modelagem e classificação de imagens (Chaves & Alves, 2019). Assim, são conduzidas análises robustas que permitem correlacionar diversas variáveis à resposta espectral dos alvos. Tais rotinas e protocolos para classificações possibilitam uma melhor compreensão da dinâmica natural (nutrientes, gases, etc.) em diferentes sistemas de manejos, o que pode racionalizar as tomadas de decisões em diversas níveis e escalas administrativos (Biau, 2012; Osco *et al.*, 2019).

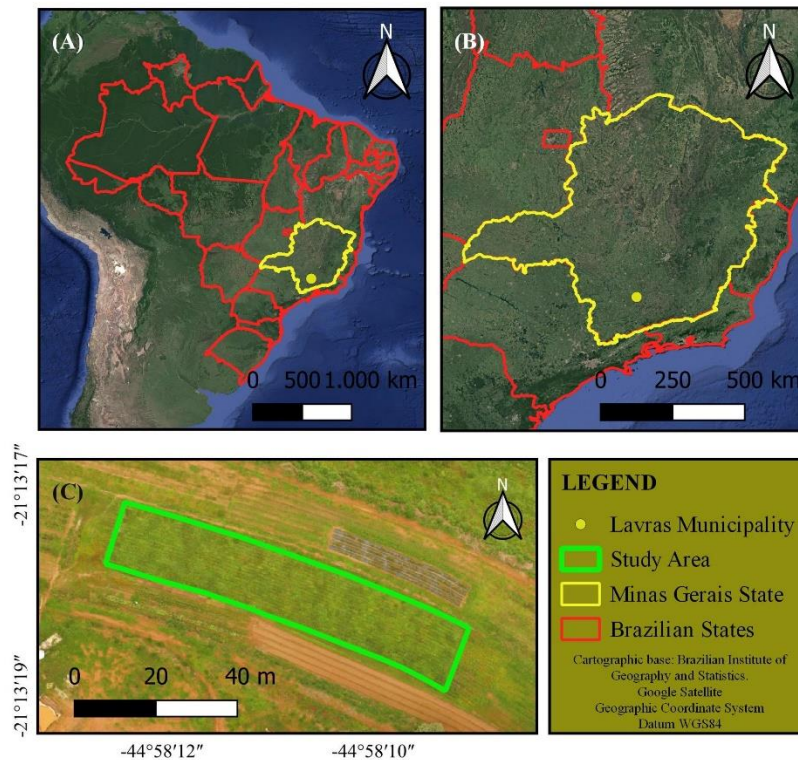
Dessa forma, este estudo teve por objetivo verificar a utilidade dos IV oriundos de imagens de cores reais, obtidas com VANT de baixo custo, no monitoramento da produtividade das ramas e das raízes, bem como da cobertura vegetal, em uma área experimental de cultivo de batata-doce.

## **MATERIAL E MÉTODOS**

O estudo foi conduzido numa área experimental no Setor de Olericultura do Departamento de Agricultura (DAG) da Universidade Federal de Lavras (UFLA), no Município de Lavras, sul do Estado de Minas Gerais (Figura 1). De acordo com a classificação climática de Köppen, o clima da área é o tipo *Cwa*, caracterizado por invernos secos e verões úmidos. A precipitação total média e

a temperatura média anual são 1530 mm e 19,4°C, respectivamente (Alvares *et al.*, 2013).

FIGURE 1. Location of the study area, being (A) location of the state of Minas Gerais in relation to the Brazilian territory, (B) of the municipality of Lavras in relation to the Brazilian territory, and (C) area of study.



A área de estudo contava com aproximadamente 1700,00 m<sup>2</sup>, e nela estava sendo realizado um estudo acerca do rendimento de diferentes genótipos da batata-doce, a partir do qual foram adquiridos, em 1700 parcelas de 1 x 1 m, dados referentes à produtividade das ramas e das raízes.

As imagens foram adquiridas utilizando uma aeronave multirrotora modelo Phantom 3 Professional (DJI, Shenzhen, China), que possui uma câmera Sony EXMOR 1/2.3", que capta imagens em cores reais (RGB) em tamanho máximo de 4000 x 3000 *pixels* por uma lente com *Field of View* (FOV) de 94° 20 mm.

Foram realizados dois voos, um em junho e um em outubro de 2018. Os voos foram planejados utilizando o aplicativo Pix4D *Capture* (Prilly, Suíça), no

qual foram definidas as sobreposições lateral e frontal como 80% 80%, e a altura de voo como 50 m.

O georreferenciamento e a mosaicagem das imagens foi feita pelo *software* PhotoScan Pro 1.2.7 (Agisoft, 2017), que inicialmente alinha e georreferencia as imagens utilizando as coordenadas e a agregação de elementos das imagens, e em seguida gera uma nuvem de pontos, responsável por gerar um modelo digital de superfície (MDS), que é usado pelo *software* para ortorretificar as imagens e gerar os ortomosaicos.

Os ortomosaicos RGB foram submetidos ao procedimento de separação das bandas no QGIS 3.8.3 (QGIS Development Team, 2020), no qual foi utilizada a Calculadora Raster para gerar os mapas espectrais em *Red*, *Green* e *Blue*. Em seguida, com a mesma ferramenta, cada banda foi normalizada para obtenção dos níveis cromáticos, utilizando a Equação 1, conforme Arroyo, Guijarro e Pajares (2016).

$$R = \frac{R}{R+G+B}, G = \frac{G}{R+G+B}, B = \frac{B}{R+G+B}$$

(1)

Em que,

R – banda vermelha;

G – banda verde;

B – banda azul.

Os índices de vegetação (IV) foram gerados utilizando a Calculadora Raster, do QGIS 3.8.3 (QGIS Development Team, 2020), onde as bandas espectrais foram empregadas conforme a equação de cada índice. Os índices usados, bem como suas equações, estão descritos na Tabela 1.



TABLE 1. Vegetation indices used in the study, their equations and sources.

Índice de Vegetação	Sigla	Equação	Fonte
Green Leaf Index	GLI	$\frac{2 * G - R - B}{2 * G + R + B}$	Louhaichi <i>et al.</i> (2001)
Excess Green	ExG	$2 * G - R - B$	Wöbbecke <i>et al.</i> (1995)
Normalized Green Red Difference	NGRDI	$\frac{G - R}{G + R}$	Tucker (1979)
Visible Atmospherically Resistant Index	VARI	$\frac{G - R}{G + R - B}$	Gitelson <i>et al.</i> (2002)
Color Index of Vegetation	CIVE	$0.441R - 0.881G + 0.385B + 18.78745$	Kataoka <i>et al.</i> (2003)

O CIVE foi aplicado no estudo pela sua ampla utilização na diferenciação de planta e solo, e também no monitoramento do desenvolvimento dos cultivos para estimar a produção de biomassa da cobertura vegetal (Zhang *et al.*, 2018). O ExG é um índice que apresenta boa aplicabilidade, em condições de luz solar não sombreada e sombreada, no reconhecimento de ervas daninhas para planejamento da pulverização em lavouras (Wöbbecke *et al.*, 1995). Assim, sua aplicação no monitoramento do desenvolvimento da cobertura vegetal foi também testada neste estudo.

O GLI é utilizado, principalmente, como um indicador de clorofila, pois diferencia plantas vivas baseado na cor verde de uma planta saudável (Louhaichi *et al.*, 2001). O NGRDI é um IV com larga aplicação no monitoramento da fenologia da vegetação, e o VARI, por sua vez, foi desenvolvido para estimar a cobertura vegetal com baixo índice de erros, pois sua estruturação é capaz de reduzir efeitos atmosféricos (Gitelson *et al.*, 2002).

Para aquisição e análise dos dados espectrais, a área total do estudo foi dividida em 1700 parcelas de 1 m x 1 m, de forma que as parcelas de coleta dos dados de produtividade das ramas e das raízes durante a colheita, que ocorreu no final de outubro, coincidissem com a área de extração dos valores dos IV. Contudo, diversas parcelas que apresentaram produção abaixo de 1,2 kg foram removidas do estudo, restando 733 parcelas para as análises. O valor médio de cada IV foi, e então, adquirido para cada parcela utilizando a ferramenta *Zonal Statistics* do ArcMap 10.5 (ESRI, Redland).

Em seguida, a produtividade das ramas foi classificada em 4 classes, em relação ao maior valor obtido, que foi considerado como 100%, conforme mostrado na Tabela 2.

TABLE 2. Productivity classes of the branches from the reference values in relation to the highest value obtained.

Classe	Referência	Nível de produtividade
A	0 - 25%	Baixo
B	26 - 50%	Médio
C	51 - 75%	Alto
D	76 - 100%	Muito alto

Posteriormente, foram construídos modos de regressão linear para verificar como cada índice de vegetação, em junho e outubro, se correlaciona com as classes de produtividade das ramas, e se esta, por sua vez, é útil para estimar o rendimento das raízes, considerando um nível de significância de  $p < 0,05$ .

Por fim, um processo de classificação supervisionada foi realizado para gerar o mapa do ICV utilizando o algoritmo Maximum Likelihood Classifier (MLC), presente no pacote Image Classifier, do ArcGIS 10.5 (ESRI, Redlands), a partir do CIVE. Para isso, foram selecionadas, em cada mês, 100 amostras, sendo 50 delas referentes ao cultivo da batata-doce e 50 de solo exposto. Tais amostras

foram definidas de maneira aleatória e representadas por geometrias retangulares de tamanho variados, distribuídas em toda a área de estudo. Posteriormente, as mesmas foram divididas em duas classes: (a) vegetação e (b) solo exposto.

Assim, foram calculados os ICV para cada mês monitorado, segundo o método de Beniaich *et al.* (2019) conforme a Equação 2.

$$ICV = CP/TP$$

(2)

Em que,

CP – número de pixels atribuídos à determinada classe;

TP – número total de pixels da área de estudo.

## RESULTADOS E DISCUSSÃO

A produtividade das ramas e das raízes variou, nas 733 parcelas do estudo, entre 1,11 e 77,78 Mg ha<sup>-1</sup>, e 1,06 e 52 Mg ha<sup>-1</sup>, respectivamente. A Tabela 3 mostra os valores médios de cada IV em relação aos níveis de produtividade das ramas em junho e outubro, e a Figura 2 mostra a distribuição das classes de produtividade das ramas na área de estudo.

FIGURE 2. Productivity classes of the branches at the 733 points (or plots) of analysis.

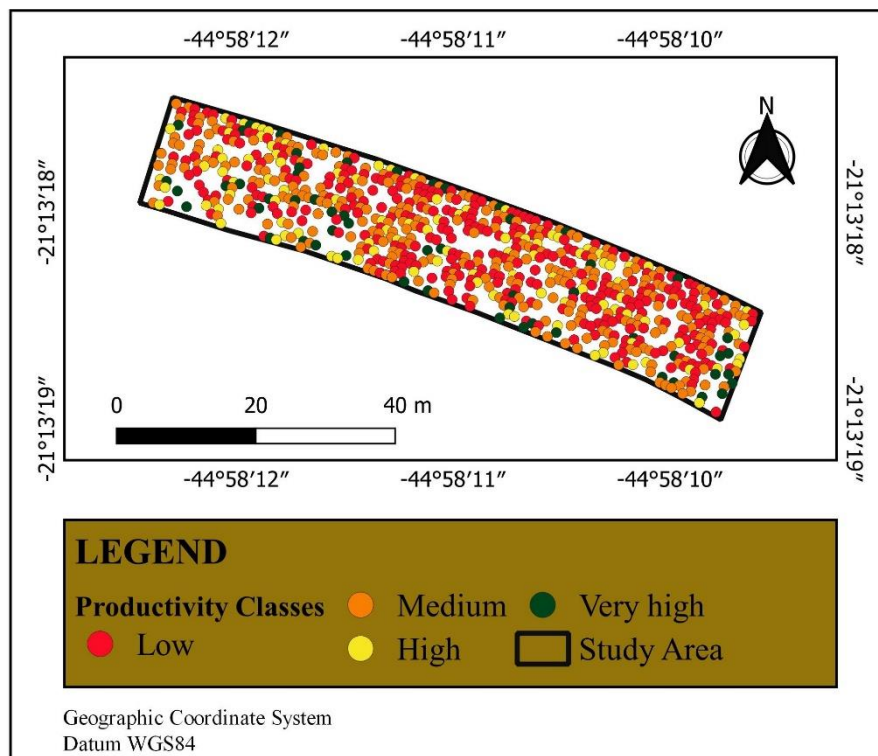


TABLE 3. Average values of the vegetation indices in relation to the productivity levels of the branches in June and October.

	Junho					Outubro				
	CIVE	ExG	GLI	NGR	VARI	CIVE	ExG	GLI	NGR	VARI
A				-	-					
	18,743	0,076	0,052	0,112	0,151	18,608	0,394	0,268	0,048	0,055
B				-	-					
	18,727	0,114	0,078	0,086	0,117	18,607	0,396	0,269	0,050	0,058
C				-	-					
	18,717	0,136	0,094	0,074	0,101	18,602	0,406	0,276	0,057	0,065
D				-	-					
	18,718	0,135	0,093	0,074	0,101	18,602	0,408	0,277	0,058	0,067

Em que A (baixa produtividade,  $\leq 25\%$ ), B (média produtividade, entre 25,1 – 50%), C (alta produtividade, entre 50,1 - 74%) e D (muito alta produtividade,  $\geq 75\%$ ).

Como era esperado, todos os índices de vegetação aumentaram entre junho e outubro, tendo em vista a evolução do período vegetativo da planta. A

única exceção é o CIVE que, baseado na banda *Red*, tende a diminuir conforme aumenta a área foliar.

Os resultados dos modelos de regressão linear construídos com os valores médios de cada IV em relação às classes de produtividade, para junho e outubro, estão descritos na Tabela 4. Entre todos os índices, o NGRDI e o VARI apresentaram as duas maiores significâncias nas correlações, ambas altas e positivas no mês de outubro,  $R^2 = 0,92$  e  $R^2 = 0,93$ , respectivamente. O VARI já foi utilizado em outros estudos e também apresentou uma resposta favorável na estimativa da produção de arroz (Zhou *et al.*, 2017). Portanto, os resultados apoiam aplicações futuras de IV do espectro visível na estimativa da produção de diferentes cultivos.

TABLE 4. Linear regression coefficients ( $R^2$ ), with Residual Standard Error (RSE) and significance level ( $p$  value), between vegetation indices and productivity classes in June and October 2018.

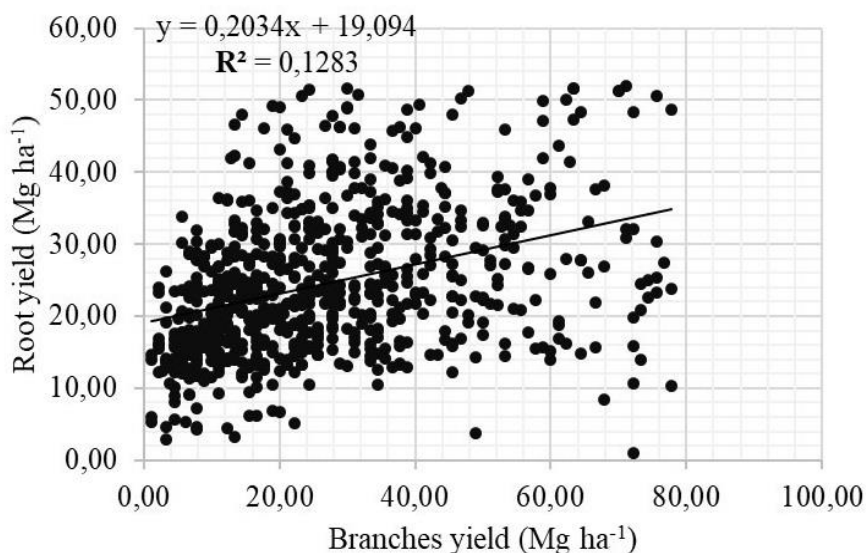
Índice de Vegetação	Junho			Outubro		
	$R^2$	RSE	$p$ value	$R^2$	RSE	$p$ value
CIVE	0,73 <sup>ns</sup>	0,0065	0,092	0,88*	0,0011	0,041
ExG	0,74 <sup>ns</sup>	0,0144	0,092	0,88*	0,0025	0,042
GLI	0,73 <sup>ns</sup>	0,0100	0,093	0,88*	0,0015	0,042
NGRDI	0,72 <sup>ns</sup>	0,0096	0,098	0,92*	0,0014	0,026
VARI	0,72 <sup>ns</sup>	0,0127	0,099	0,93*	0,0015	0,024

Os resultados mostraram que todos os índices de vegetação foram eficientes na estimativa do rendimento das ramas em outubro, obtendo correlações significativas e erros inferiores a 28%. Em junho, apesar das altas correlações entre os índices e as classes de produtividade, estas não foram significativas, o que indica que a previsão de rendimento das ramas utilizando IV fica mais acurada próximo da colheita.

A Figura 3 mostra o resultado da regressão linear realizada entre o rendimento, em  $\text{Mg ha}^{-1}$ , das ramas e das raízes, cujo objetivo era verificar se a ramas foram um bom indicador de rendimento das raízes, portanto, da cultivar.

O resultado mostrou que, embora seja possível monitorar o nível de produtividade das ramas da batata-doce, estas não são um bom indicador do rendimento da raiz. Portanto, ainda são necessários novos estudos para determinar se os IV podem ser úteis no monitoramento da produtividade da cultivar. Contudo, a cobertura vegetal, representada pelas ramas, é um elemento de proteção do solo contra a erosão hídrica, e os IV oriundos de imagens RGB têm se mostrado eficientes no acompanhamento da fração de cobertura vegetal, como mostrado por Beniaich *et al.* (2019).

FIGURE 3. Linear regression between the branches yield and the root yield, in  $\text{Mg ha}^{-1}$ .



Schirrmann *et al.* (2016) obtiveram altas correlações significativas entre o índice de área foliar do trigo de inverno e o ExG, correlações estas que aumentavam conforme avançava o ciclo da cultura.

Hunt Jr. *et al.* (2018) afirmam que à alta resolução das imagens RGB obtidas com os VANT podem ser mais úteis, em áreas de cultivo de batatas, no monitoramento de ervas daninhas, e danos por pragas e insetos, e neste cenário, o VANT multirotor é uma excelente ferramenta para complementação na análise multi-temporal de atividades agroambientais em áreas de pequena a média extensão (Mogili & Deepak, 2018).

Verificou-se por meio de análise do índice de cobertura vegetal (ICV), mostrado na Figura 4, que entre junho (segundo mês de cultivo) e outubro (mês da colheita), que a porção da área ocupada pelas ramas da cultivar aumentou 263%, passando de 35,4% do total da área, para 93,4% (Tabela 5).

FIGURE 4. Vegetation cover index from June and October, 2018.




TABLE 5. Vegetation coverage indices during the months of June and October 2018.

Mês	Feição	Nº Pixels classificados	Nº total de pixels	Índice de Cobertura
Junho	Solo	1199079	1856751	0.646
	Cultivar	657672	1856751	0.354
Outubro	Solo	116387	1866977	0.066
	Cultivar	1750590	1866977	0.934

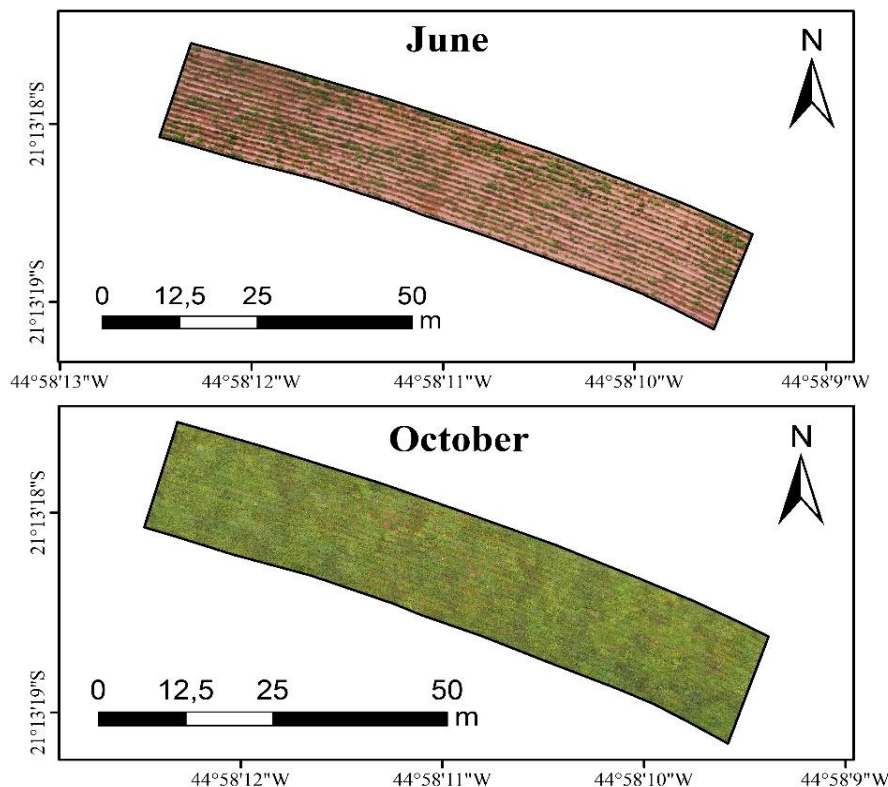
Os resultados do ICV a partir do algoritmo MLC apresentaram o grande potencial do VANT na determinação de áreas com solo exposto, e estas podem representar áreas de falhas de plantio, informação de extrema relevância para a produtividade agrícola.

O acompanhamento na evolução do ICV do cultivo indica o período em que o vegetal apresenta maior potencial de crescimento das ramas e a fase em que o desenvolvimento fenológico está mais vulnerável à doenças, como verificado por Sugiura *et al.* (2016) no cultivo de batata (*Solanum tuberosum* L.), cujo erro da severidade estimada pelo processamento da imagem foi mínimo quando comparado à avaliação visual na comparação das curvas de progresso da doença numa série temporal das imagens RGB obtidas por VANT.

A resolução espacial média de 2,36 cm dos ortomosaicos (Figura 5) permite individualização das plantas e reforça que a altitude utilizada, 50 m, é adequada para este tipo abordagem. Assim, embora não tenha sido o objetivo deste estudo, é possível visualizar zonas de amarelamento das folhas que podem revelar possível perda das folhas por déficit hídrico ou nutricional, ou ataque de pragas específicas (Maes & Steppe, 2018).



FIGURE 5. True-color Orthomosaics of the study area in June and October.



Os resultados da avaliação da produção com IV em RGB de altíssima resolução são relevantes por direcionarem a utilização destas ferramentas em diferentes contextos agrícolas. Ao considerarmos que os VANT são uma tendência à longo prazo (Nonami, 2016), a consolidação e divulgação de métodos que facilitam a automação de rotinas é indispensável na agricultura (Wilkesmann & Wilkesmann, 2018; Manavalan & Jayakrishna, 2019).

Em síntese, no geral, os VANT representam uma maior autonomia na obtenção de dados e informações dos sistemas agrícolas. Apresentam tendência de terem menor tamanho, porte e peso, menor custo e maior eficiência (Vergouw *et al.*, 2016). Berni *et al.* (2009) ressaltaram a singularidade na coleta de imagens de difícil acesso e na obtenção de imagens sem interferência de nuvens, uma vez que o conteúdo de altíssima resolução das imagens dos VANT

permite detectar detalhes normalmente não visíveis em imagens aéreas ou orbitais (Candiago *et al.*, 2015). Tal característica é fundamental no monitoramento multi-temporal, como neste estudo e, apesar de terem poucos estudos científicos na agricultura de precisão sobre o cultivo de batata-doce, as pesquisas realizadas por Sankaran *et al.* (2017), Ghazouani *et al.* (2017) e Sugiura *et al.* (2016) alcançaram resultados satisfatórios.

## **CONCLUSÕES**

Os índices de vegetação baseados em imagens em cores verdadeiras (RGB) foram eficientes no monitoramento dos níveis de produtividade das ramas da batata-doce, em especial, próximo à colheita. Por outro lado, a produtividade das ramas não se relacionou significativamente com o rendimento das raízes. Entretanto, o uso dos sensores RGB, de altíssima resolução e baixo custo, embarcados em drones, pode colaborar com a melhora na precisão da obtenção de dados para o manejo de sistemas agrícolas, visando ampliar a produtividade e a sustentabilidade na agricultura.

## REFERÊNCIAS

Abdulridha J, Ampatzidis Y, Kakarla SC, Roberts P (2020) Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. *Precision Agriculture* 21(5): 955-978. DOI: 10.1007/s11119-019-09703-4.

Agisoft. **Agisoft PhotoScan User Manual**. Petersburg: Agisoft LLC (2017) Disponível em: <<http://www.agisoft.ru>>. Acesso em: 20 fev. 2019.

Alvares CA, Stape JL, Sentelhas PC, Gonçalves JLM, Spavorek G (2013) Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift* 22(6): 711-728.

Arantes BHT, Arantes LT, Costa EM, Ventura MVA (2019) Drone aplicado na agricultura digital. *Ipê Agronomic Journal* 3(1): 14-18. DOI: 10.37951/2595-6906.2019v3i1.4323.

Arroyo J, Guijarro M, Pajares G (2016) An instancebased learning approach for thresholding in crop images under different outdoor conditions. *Computers and Electronics in Agriculture* 127(3): 669-679. DOI: 10.1016/j.compag.2016.07.018.

Ballester C, Hornbuckle J, Brinkhoff J, Smith J, Quayle W (2017) Assessment of In-Season Cotton Nitrogen Status and Lint Yield Prediction from Unmanned Aerial System Imagery. *Remote Sensing* 9(1149): 1-18. DOI: 10.3390/rs9111149.

Beniaich A, Silva MLN, Avalos FAP, Menezes MD, Cândido BM (2019) Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera. *Semina: Ciências Agrárias* 40(1): 49-66. DOI: 10.5433/1679-0359.2019v40n1p49.

Berni JAJ, Zarco-Tejada PJ, Suarez L, Fereres E (2009) Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring from an Unmanned Aerial Vehicle. *Transactions on Geoscience and Remote Sensing* 47(3): 722-738. DOI: 10.1109/TGRS.2008.2010457.

Biau, G (2012) Analysis of a Random Forests model. *Journal of Machine Learning Research* 13(4): 1063-1095. DOI: 10.5555/2188385.2343682.

Candiago S, Remondino F, De Giglio M, Dubbini M, Gattelli M (2015) Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sensing* 7(4): 4026-4047. DOI: 10.3390/rs70404026.

Chaves MED, Alves MC (2019) Recent applications of the MODIS sensor for soybean crop monitoring and deforestation detection in Mato Grosso, Brazil. *CAB Reviews* 14(7): 1-9. DOI: 10.1079/PAVSNNR201914007.

Cunha JPA, Sirqueira Neto MA, Hurtado SMC (2019) Estimating Vegetation volume of coffee crops using images from unmanned aerial vehicle. *Engenharia Agrícola*, 39: 41-47.

ESRI - Environmental Systems Research Institute. *ARCGIS Professional GIS for the desktop [version 10.5.]* (2017) Redlands, Califórnia, Software.

Ghazouani H, Capodici F, Ciraolo G, Maltese A, Rallo G, Provenzano G (2017) Potential of Thermal Images and Simulation Models to Assess Water and Salt Stress: Application to Potato Crop in Central Tunisia. *Chemical Engineering Transactions* 58(1): 709-714. DOI: 10.3303/CET1758119.

Gitelson AA, Kaufman YJ, Stark R, Rundquist, D (2002) Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment* 80(1): 76-87. DOI: 10.1016/S0034-4257(01)00289-9.

Hunt Jr ER, Horneck DA, Spinelli CB, Turner RW, Bruce AE, Gadler DJ, Brungardt JJ, Hamm PB (2018) Monitoring nitrogen status of potatoes using small unmanned aerial vehicles. *Precision Agriculture* 19: 314-333. DOI: 10.1007/s11119-017-9518-5.

Kataoka T, Kaneko T, Okamoto H, Hata S (2003) Crop growth system using machine vision. *Proceedings 2003 IEEE/ASME International Conference on Advanced Intelligent Mechatronics* 2(1): 1079-1083.

Louhaichi M, Borman MM, Johnson DE (2001) Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International* 16(1): 65-70. DOI: 10.1080/10106040108542184.

Maes WH, Steppe K (2019) Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in Plant Science* 24(2): 152-164. DOI: 10.1016/j.tplants.2018.11.007.

Manavalan E, Jayakrishna K (2019) A review of Internet of Things (IoT) embedded sustainable supply chain for industry 4.0 requirements. *Computers & Industrial Engineering* 127(4): 925-953. DOI: 10.1016/j.cie.2018.11.030.

Manfreda, S.; Dvorak, P.; Mullerova, J.; Herban, S.; Vuono, P.; Arranz Justel, J.J.; Perks, M (2018) Accuracy Assessment on Unmanned Aerial System Derived Digital Surface Models. *Preprints*. DOI: 10.20944/preprints201809.0579.v1).

QGIS Development Team (2020) **QGIS Geographic Information System**. Open-Source Geospatial Foundation Project. Available in: <http://www.qgis.org>.

Quinto VM, Magalhães IAL, Omena MS, Pena FER, Chiba ML, Dos Santos AR (2013) Análise temporal da dinâmica florestal em área de reflorestamento por meio de índices de vegetação. *Revista Geográfica Venezuelana* 54(2): 225-239.

Mogili UR, Deepak BBVL (2018) Review on Application of Drone Systems in Precision Agriculture. *Procedia Computer Science* 133(1): 502-509. DOI: 10.1016/j.procs.2018.07.063.

Nonami K (2016) Drone Technology, Cutting-Edge Drone Business, and Future Prospects. *Journal of Robotics and Mechatronics* 28(3): 262-272. DOI: 10.20965/jrm.2016.p0262.

Oscó LP, Ramos AP, Pereira DR, Moriya EAS, Imai NN, Matsubara ET, Estrabis N, Souza M, Marcato Junior J, Gonçalves WN, Li, J, Liesenberg V, Creste JE (2019) Predicting canopy nitrogen content in citrus-trees using random forest algorithm associated to spectral vegetation indices from UAV-Imagery. *Remote Sensing* 11(2925): 1-17. DOI: 10.3390/rs11242925.

Parreiras TC, Lense GHE, Moreira RS, Santana DB (2020) Using unmanned aerial vehicle and machine learning algorithm to monitor leaf nitrogen in coffee. *Coffee Science* 15(17): 36-45. DOI: 10.25186/v15i.1736.

Parsipour H, Popović S, Behzadfar M, Škatarić G, Spalevic V (2019) Cities expansion and land use changes of agricultural and garden lands in peri-urban villages (case study: Bojnurd). *Agriculture and Forestry* 65(3): 173-187. DOI: 10.17707/AgricultForest.65.3.14.

Rouse JW, Haas RH, Schell JA, Deering DW (1974) Monitoring vegetation systems in the Great Plains with ERTS. In: *Third ERTS Symposium*, New York, NASA Goddard Space Flight Center.

Sankaran S, Quirós JJ, Knowles NR, Knowles LO (2017) High-Resolution Aerial Imaging Based Estimation of Crop Emergence in Potatoes. *American Journal of Potato Research* 96(4): 658-663. DOI: 10.1007/s12230-017-9604-2.

Santos LM, Ferraz GAS, Barbosa BDS, Diotto AV, Maciel DT, Xavier LAG (2020) Biophysical parameters of coffee crop estimated by UAV RGB images. *Precision Agriculture*. DOI: 10.1007/s11119-020-09716-4.

Schirrmann M, Giebel A, Gleiniger F, Pflanz M, Lentschke J, Dammer KH (2016) Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery. *Remote Sensing* 8-9(706): 1-19. DOI: 10.3390/rs8090706.

Souza CHW, Lamparelli RAC, Rocha JV, Magalhães PSG (2017) Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. *Computers and Electronics in Agriculture* 143(7): 49-56. DOI: 10.1016/j.compag.2017.10.006.

Stavroukoudis D, Katsantonis D, Kadoglidou K, Kalaizidis A, Gitas IZ (2019) Estimating rice agronomic traits using drone-collected multispectral imagery. *Remote Sensing* 11(545): 1-25. DOI: 10.3390/rs11050545.

Sugiura R, Tsuda S, Tamiya S, Itoh A, Nishiwaki K, Murakami N, Shibuya Y, Hirafuji M, Nuske S (2016) Field phenotyping system for the assessment of

potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering* 148(1): 1-10. DOI: 10.1016/j.biosystemseng.2016.04.010.

Tucker CJ (1979) Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* 8(4): 127-150. DOI: 10.1016/0034-4257(79)90013-0.

Vergouw B, Nagel H, Bondt G, Custers B (2016) Drone Technology: Types, Payloads, Applications, Frequency Spectrum Issues and Future Developments. In: Custers B. *The Future of Drone Use*. Haia, Information Technology and Law Series, p. 21-45.

Wen D, Tongyu X, Fenghua Y, Chunling C (2018) Measurement of nitrogen content in rice by inversion of hyperspectral reflectance data from an unmanned aerial vehicle. *Ciência Rural* 48(6): 1-10. DOI:10.1590/0103-8478cr20180008.

Wilkesmann M, Wilkesmann U (2018) Industry 4.0 – organizing routines or innovations? *Journal of Information and Knowledge Management Systems* 48(2): 238-254. 238-254, 2018. DOI: 10.1108/VJIKMS-04-2017-0019.

Wöbbecke DM, Meyer GE, Von Bargen K, Mortensen DA (1995) Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE* 38(1): 259-269. DOI: 10.13031/2013.27838.

Zhang C, Mansaray LR, Jin H, Sun H, Kuang Z, Huang J (2018) A universal estimation model of fractional vegetation cover for different crops based on time series digital photographs. *Computers and Electronics in Agriculture* 151(1): 93-103. DOI: 10.1016/j.compag.2018.05.030.

Zhou X, Zheng HB, Xu XQ, He JY, Ge XK, Yao X, Cheng T, Zhu Y, Cao WX, Tian YC (2017) Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *Journal of Photogrammetry and Remote Sensing* 130(2): 246-255. DOI: 10.1016/j.isprsjprs.2017.05.003.

# Submission Confirmation

 Print

Thank you for your submission

**Submitted to**

Engenharia Agrícola

**Manuscript ID**

EAGRI-2021-0038

**Title**

Uso de imagens obtidas por drone e índices de vegetação no monitoramento do cultivo de batata-doce

**Authors**

Silva, Luis

FelipeSilva,

Jeferson

Silva, Marx

Leandro Andrade

Júnior, Valter

Mincato, Ronaldo

**Date Submitted**

05-Mar-2021

© Clarivate Analytics | © ScholarOne, Inc., 2021. All Rights Reserved.

ScholarOne Manuscripts and ScholarOne are registered trademarks of ScholarOne,

Inc. ScholarOne Manuscripts Patents #7,257,767 and #7,263,655.

[@ScholarOneNews](#) |  System Requirements |  Privacy Statement |  Terms of Use