



BRENON DIENNEVAN SOUZA BARBOSA

**APLICAÇÃO DE IMAGENS RGB OBTIDAS POR VANT
NA CAFEICULTURA DE PRECISÃO.**

LAVRAS – MG

2020

BRENON DIENNEVAN SOUZA BARBOSA

**APLICAÇÃO DE IMAGENS RGB OBTIDAS POR VANT NA CAFEICULTURA
DE PRECISÃO.**

Tese apresentada a Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Máquinas e Mecanização agrícola, para obtenção do título de Doutor.

Prof. Dr. Gabriel Araújo e Silva Ferraz

Orientador

**LAVRAS – MG
2020**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Barbosa, Brenon Diennevan Souza.

Application of RGB images obtained by UAV in precision
agriculture / Brenon Diennevan Souza Barbosa. - 2020.

81 p. : il.

Orientador(a): Gabriel Araújo e Silva Ferraz.

Tese (doutorado) - Universidade Federal de Lavras, 2020.
Bibliografia.

1. coffee. 2. precision agriculture. 3. Unmanned Aerial
Vehicles - UAV. I. Ferraz, Gabriel Araújo e Silva. II. Título.

BRENON DIENNEVAN SOUZA BARBOSA

**APLICAÇÃO DE IMAGENS RGB OBTIDAS POR VANT NA CAFEICULTURA
DE PRECISÃO.**

**APPLICATION OF RGB IMAGES OBTAINED BY UAV IN PRECISION
COFFEE FARMING**

Tese apresentada a Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Máquinas e Mecanização agrícola, para obtenção do título de Doutor.

APROVADO em 20 de novembro de 2020.

Dr. Fábio Moreira da Silva	DEG - UFLA
Dr. Rubens José Guimarães	DAG - UFLA
Dr. Flávio Castro da Silva	UFF
Dr. Luis Marcelo Tavares de Carvalho	DCF – UFLA

Prof. Dr. Gabriel Araújo e Silva Ferraz
Orientador

**LAVRAS - MG
2020**

A Deus,
OFEREÇO,

A Siroleide Airam, minha mãe, Genevan Mendes, meu pai, Gessy e Albetina, minhas avós, Helber (in memorian), meu tio, por sempre acreditarem neste sonho e apoiá-lo.

A Fernanda, por todo companheirismo, amor e dedicação.

A Gabriel Ferraz, meu orientador, por sempre apoiar em todos os momentos.

DEDICO

AGRADECIMENTOS

Gostaria de agradecer primeiramente aos meus pais, Siroleide, minha mãe, e Genevan, meu pai, que sempre apoiaram todas minhas decisões para que cada sonho fosse realizado.

Agradeço também a Fernanda, minha companheira, por estar ao meu lado nesta trajetória dando apoio e motivação em todos os momentos.

Gostaria de agradecer de maneira especial ao meu orientador Gabriel Araújo e Silva Ferraz, por sempre, sempre apoiar em todas as decisões e desafios que nos foram propostos ao longo desta trajetória. Gostaria de agradecer também sua orientação e compreensão que diante de todas as dificuldades da vida acadêmica e pessoal sempre esteve me apoiando, nunca deixando desistir.

Aos companheiros de república Lucas, Fernando e Jacineumo, meu muito obrigado por partilhar grandes momentos de alegria, sabedoria e tristezas, que com certeza contribuíram no meu crescimento.

A Luana, meu obrigado pela parceria nos diversos trabalhos e projetos ao longo deste período e por todo apoio. Aos colegas do NESA por grandes momentos e aprendizagem.

Aos amigos Victor Buono, Rafael Faria, Rafael Barata, Diego Marin, Lucas Santana, Diego Alonso por grandes momentos de alegria.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelas bolsas de estudo para que este trabalho fosse concluído,

Muito obrigado!

RESUMO GERAL

O café é uma commodity de importância significativa na balança comercial brasileira. Para dar incremento a produtividade do café novas tecnologias como sensores de solo, desenvolvimento de cultivares mais resistentes a pragas e a déficit hídrico, aplicação a taxa variável e monitoramento da cultura por meio de imagens são utilizados. O monitoramento agrícola por imagens em conjunto com técnicas de Sensoriamento Remoto (SR) traz grandes benefícios ao produtor, pelo fornecimento de informações no tempo desejado e resolução adequada para identificar e possibilitar soluções quanto às anomalias em campo, economizando recursos e garantindo a qualidade da produção. Neste cenário o uso de UAV (unmanned aerial vehicle) fornece ao agricultor o monitoramento preciso e no tempo ideal. Este trabalho teve como objetivo avaliar o uso e aplicação de uma UAV e de imagens RGB no monitoramento de uma lavoura de cafeeira, avaliando o comportamento de Índices de Vegetação (IV) e a predição da produtividade por meio de produtos derivados de imagens RGB. No artigo 1, foi avaliado o potencial de aplicação prática de UAV e IV RGB no monitoramento de uma lavoura de cafeeira durante um ciclo produtivo. Foram avaliados nove IV RGB, onde utilizou-se como métrica de seleção de IV a correlação de Pearson com o Índice de Área Foliar (IAF). Percebe-se pelos resultados que dentre os IV avaliados, o GLI e MPRI apresentaram maior correlação com o IAF (estimados por meio de parâmetros biofísicos derivados das imagens), mas ambas fracas. Durante as fases do ciclo de produção do café ambos IVs ilustram a variabilidade da cultura e do solo. O aumento de plantas daninhas também foi observado nas áreas marginais e entre as linhas de plantio. Esses resultados permitem inferir que o uso de um UAV e câmera RGB de baixo custo tem potencial para uso prático no monitoramento do café em seu ciclo de produção, permitindo ao gestor decidir por um manejo mais adequado da cultura de forma rápida e simples. Dado o potencial de uso de imagens UAV e RGB, no artigo 2 se investiga ainda mais o potencial de previsão da produtividade de café usando imagens RGB, na avaliação das variáveis: altura, diâmetro da copa (usado para estimar o IAF) e valores de brilho das bandas espectrais RGB e algoritmos de regressão múltipla em um período de 12 meses. Os resultados permitiram também concluir que o IAF e diâmetro de copa são mais influentes para gerar o modelo de predição, no qual foram usados quatro algoritmos de regressão diferentes - Máquinas de Vetor de Suporte Linear, Gradient Boosting Regression, Random Forest Regressão, Regressão Mínima Quadrada Parcial e um algoritmo genético - NEAT (Neuroevolution of augmenting topologies). O melhor resultado foi obtido com um erro médio percentual absoluto de 31% para o NEAT. As seleções de variáveis sugerem que um conjunto de dados do mês de dezembro foi o mais importante para o modelo de previsão de rendimento, reduzindo assim a necessidade de coleta extensiva de dados para todos os doze meses.

Palavras-chave: Aprendizagem profunda de máquina, imagens de UAV, previsão de produtividade, café, agricultura de precisão, Unmanned Aerial Vehicles – UAV, drone

ABSTRACT

Coffee is a commodity of significant importance in the Brazilian trade balance. To increase coffee productivity, new technologies such as soil sensors, development of cultivars that are more resistant to pests and water deficit, application at variable rates, and crop monitoring through images are used. Agricultural monitoring by images together as remote sensing techniques brings significant benefits to the producer by providing information in the desired time and with adequate resolution to identify and solve anomalies in the field, saving resources and ensuring the quality of production. In this scenario, the use of UAV (unmanned aerial vehicle) provides the farmer with accurate and timely monitoring. This work aimed to evaluate the use and application of a UAV and RGB images in the monitoring of a coffee crop, evaluating the behavior of Vegetation Indexes (IV) and the productivity prediction through products derived from RGB images. In article 1, the potential for practical application of UAV and IV RGB in monitoring a coffee crop during a production cycle was evaluated. Nine IV RGB were evaluated, using Pearson's correlation with the Leaf Area Index (LAI) as the metric for selecting IV. The results show that among the IV evaluated, the GLI and MPRI showed a higher correlation with the LAI (estimated through biophysical parameters derived from the images), but both were weak. During the phases of the coffee production cycle, both IVs illustrate the variability of the crop and soil. The increase of weeds was also observed in the marginal areas and between the planting lines. These results show that the use of a low-cost UAV and RGB camera has the potential for practical use for monitoring coffee in its production cycle, allowing the manager to decide for more assertive crop management quickly and simply. Given the potential for using UAV and RGB images described above, article 2 further investigates the potential for predicting coffee production using RGB images, using the variables: height, crown diameter (used to estimate the LAI) and brightness values of the RGB bands and multiple regression algorithms in 12 months, in which four different regression algorithms were used - Linear Support Vector Machines (SVM), Gradient Boosting Regression (GBR), Random Forest Regression (RFR) and Partial Minimum Square Regression (PLSR) - and a genetic algorithm - NEAT (Neuroevolution of augmenting topologies). The best result was obtained with a mean absolute percentage error (MAPE) of 31% for NEAT. Feature selections suggest that a December data set was the most important for the yield model, thus reducing the need for extensive data collection for all twelve months.

Keywords: Deep machine learning, UAV images, Yield estimate, coffee, precision agriculture, Unmanned Aerial Vehicles - UAV, drone

SUMARIO

PRIMEIRA PARTE	23
1. INTRODUÇÃO GERAL	24
2. REFERENCIAL TEÓRICO	25
3 CONSIDERAÇÕES FINAIS.....	32
REFERENCIAS.....	34
SEGUNDA PARTE - ARTIGOS	39
ARTIGO 1 - ÍNDICES DE VEGETAÇÃO RGB NA CAFEICULTURA DE PRECISÃO	40
ARTIGO 2 - COFFEE CROP YIELD PREDICTION BY UAV RGB IMAGES AND REGRESSION ALGORITHMS	69

LISTA DE FIGURAS

SEGUNDA PARTE

ARTIGO 1

Fig 1 Localização da área de estudo.	45
Fig 2 Fluxo para cálculo dos IV e correlação com IAF (A). Buffer de 0.8m para cálculo de valor médio de IV em cada amostra.	51
Fig 3 Exemplo de Outlier.....	52
Fig 4 Altura de plantas estimado x medido em campo (A). Diâmetro de copa de planta estimado x medido (B).	53
Fig 5 Comportamento do IAF estimado por UAV.	55

SEGUNDA PARTE

ARTIGO 2

Fig. 1. Workflow of the study.....	73
Fig. 2. Study site location with marked sampled trees.	74
Fig. 3. Comparison of the average UAV and manual measurements for tree diameter and tree height for 12 months.....	82
Fig. 4. Bland and Altman plot for tree diameter measurements.	83
Fig. 5. Bland and Altman plot for tree height.....	83
Fig. 6. Bland and Altman plot for tree height.....	85

LISTA DE TABELAS

SEGUNDA PARTE

ARTIGO 1

Tabela 1. Índices de Vegetação.....	50
Tabela 2. Correlação entre IV e IAF na 2º fase do ciclo fenológico do café.....	56
Tabela 3 Correlação entre IV e IAF na 3º fase do ciclo fenológico do café.....	56
Tabela 4. Correlação entre IV e IAF na 4º fase do ciclo fenológico do café.....	57
Tabela 5 Correlação entre IV e IAF na 5º fase do ciclo fenológico do café.....	57

SEGUNDA PARTE

ARTIGO 2

Table 1. Regression model parameters	79
Table 2. Dataset analysis of the yield data.	81
Table 3. Dataset analysis of the UAV data vs the manual data.....	81
Table 4. Top 10 features to estimate yield in coffee.	85
Table 5. The models MAPE for yield prediction based on different feature selections.	86

PRIMEIRA PARTE

1. INTRODUÇÃO GERAL

Como maior produtor e exportador de café do mundo, o Brasil e seus cafeicultores buscam, a cada dia, tornar seu produto mais competitivo no mercado. A busca para uma melhor produtividade e qualidade do café engloba um conjunto de novas técnicas e ferramentas que auxiliam o produtor na tomada das melhores decisões de como manejar sua lavoura.

O uso de tecnologias, dentre elas os sensores de umidade no solo para evitar a redução da produtividade por déficit hídrico, o melhoramento genético de cultivares tolerantes a seca e doenças e o monitoramento da lavoura por meio de imagens são alguns exemplos. Uma das técnicas utilizadas para otimizar a produção da lavoura é a Agricultura de Precisão (AP). AP é um conjunto de técnicas e ferramentas de base tecnológica, como exemplo de receptores de GNSS, para que tratores possam seguir corretamente o traçado de linhas de plantio, adubação localizada e por taxa variável, imagens e cálculos matemáticos (ex: geoestatística), que quando inseridos no manejo da cultura, permite ao agricultor ter maior embasamento técnico para que seu produto seja mais competitivo por meio da redução de custos de produção e aumento da qualidade.

Na AP umas das ferramentas mais utilizadas são as imagens, sejam elas obtidas por meio de satélites, aviões ou UAV. O objetivo primário das imagens é indicar a variabilidade espacial e temporal de uma cultura, podendo relacionar tal heterogeneidade com as devidas causas por meio de levantamentos em campo, criando padrões na imagem. Plataformas orbitais (satélites) são mais utilizadas na agricultura devido a sua escala de mapeamento e pela diversidade de sensores acoplados nestas plataformas. O mapeamento de áreas com aviões também já foi utilizado, tendo neste método uma melhor resolução espacial. Esses dois métodos têm em comum o elevado custo para um monitoramento mais frequente e também uma resolução espacial menor, o que pode comprometer o trabalho para algumas culturas onde a frequência e a precisão são mais exigidas. Os UAV apareceram como alternativa de menor custo para ao monitoramento agrícola, fornecendo maior resolução espacial e temporal, no entanto sua escala de mapeamento é reduzida principalmente devido a limitações de energia para voo em grandes áreas.

Para a cultura do café, objeto deste estudo, a AP quando aplicada no manejo desta cultura pode ser denominada cafeicultura de precisão, onde ferramentas e técnicas descritas para a AP são utilizadas para identificar comportamento espacial de algumas

características da planta como a força de desprendimento de frutos, teor de nitrogênio, umidade do solo e doenças no cafeeiro. No entanto o monitoramento do cafeeiro por imagens utilizando técnicas de AP são relatados na literatura apenas com imagens de satélites.

Neste cenário imagens obtidas por UAV são uma grande oportunidade para investigações e aplicações no manejo do café, devido ao seu baixo custo quando comparados a imagens de satélites de alta resolução, flexibilidade no período de monitoramento e facilidade de operação e obtenção de imagens. Tais vantagens são descritas em estudos nos cultivos de grãos, amendoeiras, oliveiras e de videiras.

Desta maneira objetivou-se com este estudo investigar o potencial de aplicações de imagens RGB obtidas por meio de uma UAV em uma lavoura de café, identificando oportunidades de melhoria no manejo da cultura e estimativas de produtividade.

2. REFERENCIAL TEÓRICO

Como maior produtor de café do mundo, o Brasil teve em sua produção de café para a safra 2019/2020 uma queda de 10,9% em relação à safra anterior, tendo a espécie *Coffea arabica* L. apresentado uma queda de 17,4%, pois a referida safra foi considerada de baixa no ciclo produtivo bienal (OIC, 2020). Para minimizar efeitos da bienalidade e buscar por maior produtividade, qualidade e competitividade da produção, tem se intensificado a adoção de novas tecnologias no cultivo do café, com a denominada Cafeicultura de Precisão (CP) (CARVALHO et al., 2017).

A cafeicultura de precisão, prática derivada da Agricultura de Precisão (AP), consiste em um conjunto de técnicas e sensores geoespaciais para o auxílio de tecnologias no manejo da cultura, identificando anomalias em campo em função das variáveis analisadas, com o objetivo de minimizar estes efeitos na produção, reduzir custos e garantir a qualidade necessária do produto. (ZHANG E KOVACS, 2012; FERRAZ et al., 2012).

Dentre as tecnologias utilizadas na AP e na CP, o Sensoriamento Remoto (SR) por imagens destaca-se devido aos produtos gerados, pelo recobrimento em uma maior escala da área e o menor tempo e custo de amostragem, quando comparado a métodos tradicionais. O uso de imagens orbitais, obtidas por sensores ópticos acoplados em satélites tem sido bastante útil no monitoramento agrícola (SANKARAN et al, 2015), sendo que na cultura do café têm sido utilizadas para diversos fins, tais como o mapeamento de áreas com plantio de café (GAERTNER et al., 2017; TSAI E CHAN,

2017), déficit hídrico (MACIEL et al., 2020; CHEMURA et al., 2017) , deficiência nutricional (CHEMURA et al., 2018; PUTRA E SONI et al., 2017) e ataque de doenças (KATSUHAMA et al., 2018; DA ROCHA MIRANDA et al., 2020).

Imagens de satélites de alta resolução já são empregadas no monitoramento agrícola, no entanto a sua disponibilidade e custo impedem o uso amplo desta tecnologia, o que sugere a busca por novas alternativas, de menor custo e de maior disponibilidade (ZHANG et al., 2012). Outro ponto a ser destacado com um empecilho ao uso destas imagens é a capacitação da mão de obra para o tratamento do grande volume de dados e correta interpretação das imagens (MURAKAMI et al., 2007), além da falta de evidências de retornos econômicos (LAMB et al., 2008). Desta maneira, Veículos Aéreos Não Tripulados (VANT ou em inglês Unmanned Aerial Vehicles -UAV) aparecem como uma segunda alternativa para o monitoramento agrícola devido ao baixo custo de aquisição e de obtenção de imagens, maior resolução espacial e temporal e de fácil operação (ZHANG et al. 2012; MATESE et al., 2015).

UAV podem ser equipados com diversos tipos de sensores que captam imagem RGB (luz visível), multiespectrais, sensores térmicos e radar (LIDAR) permitindo obter informações sobre a planta em diferentes estágios de desenvolvimento (ZHANG E KOVAKS, 2012; RAHAMAN et al., 2015). Como exemplo, o uso de parâmetros biofísicos das plantações (altura de planta, diâmetro de copa, volume de copa) derivados de imagens de UAV fornecem informações importantes sobre o status atual da cultura e para a confecção de mapas de prescrição para as ações a serem implementadas na área (TORRES-SÁNCHEZ et al., 2015).

No entanto os UAV e os sensores embarcados podem apresentar algumas restrições para o seu uso como o tempo útil de voo (MATESE et al., 2015). Zhang e Kovacs (2012) trazem em seu trabalho algumas considerações sobre o acréscimo no custo de aquisição de um UAV quando equipados com sensores mais robustos e sistema GPS de alta precisão. Estes autores também citam as dificuldades encontradas no processamento de imagens, em especial de sensores multiespectrais, o que em conjunto com o custo pode agravar o desestímulo do agricultor ao uso deste sistema e da adoção da AP. No entanto, o potencial de uso de UAV tende a ser maior em um futuro próximo com o avanço da tecnologia, redução de custos e maiores investigações no meio agrícola.

A importância de estudos de viabilidade se torna ainda mais evidente de uso UAV em relação a outras plataformas de imageamento, evidenciando a relação custo com o

objetivo do monitoramento (Matese et al., 2015). Tais investigações são essenciais para maior adoção de AP utilizando UAV, principalmente as de baixo custo e com sensores menos robustos. Zhang e Kovacs (2012) afirmam que os atuais estudos de potencial de uso de UAV na AP devem ser feitos em áreas comerciais e com gestores de campo envolvidos, o que não é observado na maioria das investigações.

Um dos produtos derivados do SR mais utilizados na agricultura são os Índices de Vegetação (IV), que originalmente foram desenvolvidos para sensores orbitais e aerotransportados (YEOM et al., 2019). A fundamentação para o uso destes IV na agricultura deve-se as características de absorção e reflexão entre as bandas espectrais nas folhas da cultura, com forte absorção nas bandas da visível e alta reflexão na banda do infravermelho próximo.

A definição empírica dos IV é descrita por meio de operações algébricas entre os dados de refletância de diversas bandas espectrais podendo gerar uma gama de IV (YANG et al., 2017). A Aplicação destes IV podem ser utilizados, por exemplo, para estimar parâmetros físicos e biológicos da planta, como descrito em Zhang et al. (2019). Quando uma análise temporal destes IV é realizada, é possível identificar classes de culturas assim como o padrão de crescimento das mesmas (SOUZA et al., 2015) e até previsão de produtividade (LUSSEM et al., 2018; RAMOS et al., 2020; ZHOU et al., 2017)

Como descrito anteriormente, a planta reflete a radiação eletromagnética incidente nas folhas na região espectral do infravermelho e, desta forma, sensores que captam essa faixa do espectro são bastante utilizados na agricultura por meio de IV. Existem diversos IV derivados da banda do infravermelho, no entanto, o NDVI (Normalized Difference Vegetation Index), que utiliza as bandas vermelho e infravermelho em seu cálculo é bastante utilizado em pesquisas agrícolas (YEOM et al., 2019). Diversas aplicações do NDVI são descritas na literatura, como: a correlação do grau de severidade de *Cercospora* em beterraba (JANSEN et al., 2014); indicador de regiões com estresse hídrico (GAGO et al., 2015); fenotipagem do milho e deficiência de nitrogênio (ZAMAN ALLAH et al., 2015); estimativa do Índice de Área Foliar (IAF), que é um parâmetro correlacionado com o crescimento da cultura, estimativa da biomassa e rendimento (DUCHEMIN et al., 2008; LIU et al., 2019) .

Para a cultura do café, estudos utilizando o NDVI em sua maioria estão relacionados a imagens de satélite (MACIEL et al., 2020; KATSUHAMA et al., 2016).

A aplicação do NDVI e UAV obtido por meio de uma UAV na cafeicultura, na literatura especializada há poucas investigações como Santos et al. (2020) e Cunha et al. (2019). Sott et al. (2020) em seu trabalho de revisão reforçam o baixo número de investigações do uso e aplicação dos UAV no setor cafeeiro, e concluem que ainda há oportunidades de investigação.

Uma limitação ao utilizar sensores multiespectrais em UAV são o grau de conhecimento necessário para calibração destas imagens, que são altamente influenciadas pela iluminação e necessitam de equipamentos adicionais como uma placa de calibração (SANKARAN et al., 2015). Isso eleva o custo de implantação e a relação custo benefício em função do objetivo de avaliação que deve ser considerado, principalmente quando comparados com os produtos gerados por câmeras comuns RGB que já vêm acopladas no UAV.

Câmeras digitais RGB são as mais utilizadas em pesquisas de fenotipagem das culturas (YANG et al., 2017). Nestes sensores, imagens RGB são apresentadas em matrizes com valores de brilho corresponde as bandas vermelha (R - red) verde (G - green) e azul (B – blue) da luz visível. O uso destas imagens tem destaque pelo baixo custo, facilidade de operação e manutenção (LI et al., 2014).

Yang et al. (2017) relatam em sua pesquisa que estas imagens podem ser coletadas em diferentes condições de iluminação, mas cuidados devem ser tomados na exposição de brilho. Os produtos derivados destas imagens permitem inferir sobre a estrutura da planta como no estudo de Castro et al. (2018), em que imagens RGB foram utilizadas na aplicação de técnicas de processamento de imagem orientado ao objeto (OBIA) para a reconstrução em modelo 3D de vinhedos.

Santos et al. (2020) estimaram os parâmetros biofísicos de plantas de café, alcançando uma correlação forte com valores medidos em campo. Já Hairmansis et al. (2014) utilizaram imagens RGB para detectar tolerância a salinidade de duas espécies de arroz. Bendig et al. (2014) utilizaram estas imagens para estimar a biomassa da cevada por meio da altura da planta e modelos de superfície. Barbosa et al. (2019) analisaram de forma qualitativa IV RGB em uma área de cultivo de grama, encontrando melhores resultados pra o IV MPRI.

Bareth et al (2016), avaliando IV RGB (RGBVI) não calibrado com o NDVI em um experimento para avaliar a o trigo de inverno em diferentes tratamentos de nitrogênio, encontraram resultados promissores, com R^2 0,71. Estes autores ressaltam o potencial do

RGBVI quando o NDVI se encontra com valores saturados em uma determinada fase do crescimento da cultura por ainda detectar certa variabilidade nestes estágios.

Marcial-Pablo et al. (2019) avaliaram a fração de cobertura vegetal em um campo de milho utilizando IV RGB e multiespectrais. Estes autores encontraram uma maior eficiência para detecção de cobertura vegetal para o IV ExG (Excess of green) nas fases iniciais de desenvolvimento, e acrescentam que os IV baseados em NIR tem melhor desempenho nas outras fases de crescimento, no entanto a seleção do sensor a ser utilizado deve ser avaliada em função do objetivo de monitoramento.

Para a cultura do café, estudos utilizando IV RGB são poucos e necessitam de maiores investigações acerca do seu uso e potencial de aplicação no setor. Um exemplo é o trabalho de Santos et al (2020), em que os autores avaliaram o uso do MGVRI (Modified Green Red Vegetation Index) para monitorar o crescimento do cafeeiro em épocas diferentes, no entanto o resultado não foi significativo devido este IV não diferenciar solo e vegetação.

Para melhorar os resultados dos IV para predição e biomassa da cevada, Bendig et al (2015) mostram que as combinações com dados de altura da planta provem um menor erro na estimativa.

Yang et al. (2017) em seu trabalho de revisão mostram que a estimativa da produção agrícola é o foco principal das pesquisas agrícolas. O SR e o uso de UAV aparecem neste contexto como alternativa aos métodos tradicionais que utilizaram amostras em campo e relação entre variáveis agrônômicas e climáticas utilizando métodos estatísticos (SAKARAN et al., 2016). Yang et al. (2017) ressaltam que é necessário melhorar a precisão dos modelos de predição gerados por SR baseado em UAV por meio de integração de parâmetros fisiológicos da cultura com produtos de SR.

Trabalhos como os de Zhou et al. (2018) utilizando câmera multiespectral e termal encontraram para a cultura do feijão, um R^2 de 0,71 com o GNDVI (Green Normalized Difference Vegetation Index) para a parcela experimental avaliada, no período inicial de desenvolvimento. Khanal et al. (2018) integraram dados de sensoriamento remoto (imagens multiespectrais) com dados de propriedades de solo e de elevação do terreno e alguns algoritmos de aprendizagem de máquina para predição da produtividade do milho, onde o melhor resultado foi para o modelo Random Forest ($R^2= 0,53$).

Nevavuori et al. (2019) utilizaram dados de NDVI e RGB e Redes Neurais Convolucionais (CNNs) para estimar produtividade agrícola, onde as melhores

estimativas foram para os períodos iniciais de crescimento, com um erro médio absoluto (MAPE) utilizando imagens RGB.

Ramos et al. (2020) trabalhando com a cultura do milho utilizaram dados derivados de imagens multiespectrais e o algoritmo Random Forest (RF) encontrando bons resultados, com erro médio absoluto de 0,78 para os IV NDVI, NDRE (Normalized Difference Red Edge) e GNDVI. Segundo esses mesmos autores, a estimativa de produtividade por meio de SR ainda é um cenário desafiador devido a necessidade de desenvolvimento de soluções computacionais mais simples para coleta e processamento de dados e com baixo custo para o produtor.

Na literatura especializada, até o momento de escrita deste trabalho, pesquisas acerca da estimativa de produtividade da cultura do café utilizando dados de imagens obtidas por UAV não foram encontrados, evidenciando a necessidade de maiores investigações tanto em campos experimentais quanto em áreas comerciais.

Diante do contexto apresentado, foram desenvolvidos nesta tese dois artigos com objetivo de demonstrar o uso e aplicação de UAV e câmera RGB no monitoramento da cultura do café, avaliando a variabilidade da lavoura e realizando a estimativa de produtividade utilizando produtos de SR aéreo.

O primeiro artigo intitulado “Índices de vegetação RGB na cafeicultura de precisão: Uma aplicação prática”, será submetido à revista *Precision Agriculture*. Este trabalho avaliou o potencial de aplicação prática de um UAV e índices de vegetação (IV) RGB no monitoramento de uma lavoura de café durante um ciclo produtivo. Foram avaliados neste estudo nove IV (MPRI, MGVRI, GLI, ExG, ExR, ExGR, VARI, RGBVI, VEG). Estes IV avaliados foram submetidos a uma análise de correlação de Pearson com o Índice de Área Foliar (IAF), e uma posterior seleção do IV com maiores valores de R^2 foi realizada. Dentre os IV avaliados, os que apresentaram maior correlação com IAF foram o MPRI (0.31) e GLI (0.41). A Evolução de plantas daninhas nas entrelinhas de plantio é perceptível em ambos IV, o que permite ao gestor a tomada de decisão para o início dos tratos culturais, economizando recursos. Os resultados mostram que uso de UAV e câmera RGB de baixo custo tem potencial de uso prático para o monitoramento do café em seu ciclo de produção, subsidiando o produtor com informações práticas para um manejo mais preciso da lavoura de forma rápida, simples.

O segundo artigo intitulado “Coffee Crop yield prediction by UAV RGB images and regression algorithms” será submetido a revista *Computers and Electronics in*

Agriculture. Objetivou-se com esse artigo utilizar dados de SR provenientes de imagens RGB obtidas por UAV para estimar a produtividade do cafeeiro. Foram utilizados valores de altura de planta, diâmetro da copa e refletância da banda RGB referentes a 144 plantas, entre junho de 2017 e maio de 2018. Uma seleção de variáveis mostrou que o IAF e o diâmetro da copa foram os parâmetros mais importantes para previsão de produtividade, onde o algoritmo NEAT teve um melhor desempenho com um MAPE de 31,75%, considerando neste estudo um conjunto de dados reduzido contendo apenas as características mais importantes e os meses mais importantes. Os resultados do modelo sugerem que um conjunto de dados do mês mais importante pode ser usado para o modelo de previsão de produtividade, reduzindo assim a necessidade de coleta extensiva de dados.

3 CONSIDERAÇÕES FINAIS

Este trabalho foi desenvolvido com o intuito de avaliar o potencial de uso e aplicação de um UAV e imagens RGB no monitoramento de uma lavoura de cafeeira em ciclo de produção. Os produtos derivados das imagens (IV e parâmetros biofísicos) foram utilizados para avaliar de forma qualitativa a distribuição espacial da vegetação e estimativa da produção durante o período de monitoramento.

Foi possível observar heterogeneidade acentuada da lavoura e presença de plantas daninhas e sua evolução nas áreas marginais e nas entre linhas de plantio de forma rápida simples e prática, utilizando poucos recursos computacionais e equipamentos de baixo custo quando comparados a sensores multiespectrais, por exemplo.

A estimativa da produtividade alcançou resultados positivos e promissores, visto que a seleção e variáveis sugere a possibilidade de redução de variáveis e missões de retorno a campo, sendo mais assertivo para um determinado período do ciclo produtivo do café.

A determinação de parâmetros biofísicos da planta (altura e diâmetro de copa) por meio de técnicas de processamento de imagem apresentou uma assertividade considerável quando comparado com valores medidos em solo. Estes resultados permitem ao avaliador estimar de forma rápida o IAF, que é um parâmetro essencial na estimativa de modelos de crescimento e produtividade da planta, economizando tempo e recursos financeiros quando comparado a metodologias de medição em campo.

Os IV avaliados (GLI e MPRI) apesar de apresentarem uma fraca correlação com IAF, permitiram uma análise qualitativa da variabilidade espacial da lavoura, assim como a presença e evolução de plantas daninhas na área, fornecendo informações para que o gestor de área possa planejar e otimizar o manejo da lavoura no tempo e dimensões adequados de forma rápida e prática.

A metodologia proposta para estimar a produtividade do café usando técnicas de aprendizado de máquina sobre os dados obtidos de imagens aéreas baseadas em UAV (a altura da planta, o diâmetro de copa e os valores de refletância RGB), mostrou por meio da seleção de feições que o IAF e o diâmetro da copa eram as feições mais dominantes no modelo de predição. O IAF, em particular, foi a variável de maior importância em um ranking de 10 variáveis. Outro aspecto importante das classificações de variáveis foi a significância de dois meses (dezembro de 2017 e abril de 2018) para a previsão da produtividade. Este é um resultado importante para estudos futuros porque reduz a

necessidade de extensa coleta de dados durante todo o ano e permite que os pesquisadores se concentrem nos parâmetros dominantes dentro de um período mais importante. Oportunidades futuras a respeito da utilização de dados hiperespectrais e multiespectrais e outros índices de vegetação para melhorar a estimativa do modelo de predição são aconselháveis. Embora os resultados obtidos neste estudo sejam promissores, ainda existem oportunidades de melhoria, como a utilização de amplo banco de dados de produtividades e em áreas comerciais.

REFERENCIAS

- BARBOSA, B. D. S. et al. RGB vegetation indices applied to grass monitoring: a qualitative analysis. **Agronomy Research**, v. 17, n. 2, p. 349-357, 2019.
- BARETH, G. et al. Comparison of uncalibrated rgbvi with spectrometer-based NDVI derived from UAV sensing systems on field scale. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 41, 2016.
- BENDIG, Juliane et al. Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. **Remote sensing**, v. 6, n. 11, p. 10395-10412, 2014.
- CARVALHO, Luis C. C. et al . Geostatistical analysis of Arabic coffee yield in two crop seasons. **Rev. bras. eng. agríc. ambient.**, Campina Grande , v. 21, n. 6, p. 410-414, June 2017 . Available from <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662017000600410&lng=en&nrm=iso>. access on 08 Oct. 2020. <https://doi.org/10.1590/1807-1929/agriambi.v21n6p410-414>.
- CHEMURA, Abel et al. Mapping spatial variability of foliar nitrogen in coffee (*Coffea arabica* L.) plantations with multispectral Sentinel-2 MSI data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 138, p. 1-11, 2018.
- CHEMURA, Abel; MUTANGA, Onisimo; DUBE, Timothy. Remote sensing leaf water stress in coffee (*Coffea arabica*) using secondary effects of water absorption and random forests. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 100, p. 317-324, 2017.
- CUNHA, João P. A. R.; SIRQUEIRA NETO, Matheus A.; HURTADO, Sandro. Estimating vegetation volume of coffee crops using images from unmanned aerial vehicles. **Engenharia Agrícola**, v. 39, n. SPE, p. 41-47, 2019.
- DA ROCHA MIRANDA, Jonathan et al. Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p. 101983, 2020.
- DUCHEMIN, Benoît et al. A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index. **Environmental Modelling & Software**, v. 23, n. 7, p. 876-892, 2008.

FERRAZ, Gabriel AE S. et al. Variabilidade espacial e temporal do fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola**, v. 32, n. 1, p. 140-150, 2012.

GAERTNER, Julie et al. Vegetation classification of Coffea on Hawaii Island using WorldView-2 satellite imagery. **Journal of Applied Remote Sensing**, v. 11, n. 4, p. 046005, 2017.

GAGO, Jorge et al. UAVs challenge to assess water stress for sustainable agriculture. **Agricultural water management**, v. 153, p. 9-19, 2015.

HAIRMANSIS, Aris et al. Image-based phenotyping for non-destructive screening of different salinity tolerance traits in rice. **Rice**, v. 7, n. 1, p. 1-10, 2014.

JANSEN, Marcus et al. Non-invasive spectral phenotyping methods can improve and accelerate cercospora disease scoring in sugar beet breeding. **Agriculture**, v. 4, n. 2, p. 147-158, 2014.

KATSUHAMA, Naoya et al. Development of monitoring method of coffee leaf rust fungus (*Hemileia vastatrix*) infected area using satellite remote sensing. **AGUFM**, v. 2016, p. GC51B-1152, 2016.

KATSUHAMA, Naoya et al. Discrimination of areas infected with coffee leaf rust using a vegetation index. **Remote Sensing Letters**, v. 9, n. 12, p. 1186-1194, 2018.

LAMB, David W.; FRAZIER, Paul; ADAMS, Peter. Improving pathways to adoption: Putting the right P's in precision agriculture. **Computers and Electronics in Agriculture**, v. 61, n. 1, p. 4-9, 2008.

LI, Lei; ZHANG, Qin; HUANG, Danfeng. A review of imaging techniques for plant phenotyping. **Sensors**, v. 14, n. 11, p. 20078-20111, 2014.

LIU, YINUO et al. Estimating biomass of winter oilseed rape using vegetation indices and texture metrics derived from UAV multispectral images. **Computers and Electronics in Agriculture**, v. 166, p. 105026, 2019.

LUSSEM, U. et al. Evaluation of RGB-based vegetation indices from UAV imagery to estimate forage yield in grassland. **ISPRS—Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.**, v. 42, n. 3, p. 1215-1219, 2018.

MACIEL, Daniel Andrade et al. Leaf water potential of coffee estimated by landsat-8 images. **Plos one**, v. 15, n. 3, p. e0230013, 2020.

MARCIAL-PABLO, Mariana de Jesús et al. Estimation of vegetation fraction using RGB and multispectral images from UAV. **International journal of remote sensing**, v. 40, n. 2, p. 420-438, 2019.

MATESE, Alessandro et al. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. **Remote Sensing**, v. 7, n. 3, p. 2971-2990, 2015.

MURAKAMI, Edson et al. An infrastructure for the development of distributed service-oriented information systems for precision agriculture. **Computers and Electronics in agriculture**, v. 58, n. 1, p. 37-48, 2007.

NEVAVUORI, P., NARRA, N., LIPPING, T. Crop yield prediction with deep convolutional neural networks. *Computers and electronics in agriculture*, 163, 104859. 2019

Organização Internacional do Café –OIC. **Relatório sobre o mercado de café**. agosto de 2020. Acessado em: 20 de agosto de 2020. Disponível em: http://consorciopesquisacafe.com.br/arquivos/consorcio/publicacoes_tecnicas/relatorio_oic_agosto_2020.pdf

PUTRA, Bayu Taruna Widjaja; SONI, Peeyush. Enhanced broadband greenness in assessing Chlorophyll a and b, Carotenoid, and Nitrogen in Robusta coffee plantations using a digital camera. **Precision Agriculture**, v. 19, n. 2, p. 238-256, 2018.

RAHAMAN, Md et al. Advanced phenotyping and phenotype data analysis for the study of plant growth and development. **Frontiers in plant science**, v. 6, p. 619, 2015.

RAMOS, Ana Paula Marques et al. A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. **Computers and Electronics in Agriculture**, v. 178, p. 105791, 2020.

SANKARAN, Sindhuja et al. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. **European Journal of Agronomy**, v. 70, p. 112-123, 2015.

SANTOS, Luana Mendes et al. Biophysical parameters of coffee crop estimated by UAV RGB images. **Precision Agriculture**, p. 1-15, 2020.

SANTOS, Luana Mendes et al. Monitoring of Coffee Tree Growth Through Crop Surface Models and MGRVI with Images Obtained with RPA. In: **International Mid-Term Conference of the Italian Association of Agricultural Engineering**. Springer, Cham, 2019b. p. 757-763.

SOTT, Michele Kremer et al. Precision Techniques and Agriculture 4.0 Technologies to Promote Sustainability in the Coffee Sector: State of the Art, Challenges and Future Trends. **IEEE Access**, v. 8, p. 149854-149867, 2020.

SOUZA, Carlos Henrique Wachholz et al. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809-1824, 2015.

TORRES-SÁNCHEZ, Jorge; LÓPEZ-GRANADOS, Francisca; PEÑA, José M. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. **Computers and Electronics in Agriculture**, v. 114, p. 43-52, 2015.

TSAI, Du-Ming; CHEN, Wan-Ling. Coffee plantation area recognition in satellite images using Fourier transform. **Computers and electronics in agriculture**, v. 135, p. 115-127, 2017.

YANG, Guijun et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. **Frontiers in plant science**, v. 8, p. 1111, 2017.

YEOM, Junho et al. Comparison of vegetation indices derived from UAV data for differentiation of tillage effects in agriculture. **Remote Sensing**, v. 11, n. 13, p. 1548, 2019.

ZAMAN-ALLAH, Mainassara et al. Imagem multiespectral baseada em plataforma aérea não tripulada para fenotipagem de campo de milho. **Métodos de planta**, v. 11, n. 1, pág. 1-10, 2015.

ZHANG, Chunhua; KOVACS, John M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision agriculture**, v. 13, n. 6, p. 693-712, 2012.

ZHANG, Xianlong et al. New research methods for vegetation information extraction based on visible light remote sensing images from an unmanned aerial vehicle (UAV). **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 215-226, 2019.

ZHOU, J. et al. Low altitude remote sensing technologies for crop stress monitoring: a case study on spatial and temporal monitoring of irrigated pinto bean. **Precision Agric** 19, 555–569 (2018). <https://doi.org/10.1007/s11119-017-9539-0>

ZHOU, X. et al. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 246-255, 2017.

SEGUNDA PARTE - ARTIGOS

**ARTIGO 1 - ÍNDICES DE VEGETAÇÃO RGB NA CAFEICULTURA DE
PRECISÃO**

Artigo elaborado de acordo com as normas da revista *Precision Agriculture*,
ISSN: 1573-1618 (versão preliminar), fator de impacto 4.54 (2019)

Índices de vegetação RGB na cafeicultura de precisão

RGB vegetation indices in precision coffee crop

Brenon Diennevan Souza Barbosa¹, Gabriel Araújo e Silva Ferraz¹, Luana Mendes Gonçalves dos Santos¹.

¹ Agricultural Engineering Department, Federal University of Lavras, P.O BOX 3037, CEP 37200-000, Lavras, MG, Brazil.

Author for correspondence: Brenon Diennevan Souza Barbosa

b.diennevan@outlook.com

+55 35 3829-4566

Resumo A busca por um produto cada vez mais competitivo, faz com que o setor cafeeiro demande por novas tecnologias de monitoramento das lavouras, identificando e prevenindo anomalias no campo. Objetivou-se com este trabalho avaliar o potencial de aplicação prática de Unmanned Aerial Vehicles (UAV) e índices de vegetação (IV) RGB no monitoramento de uma lavoura de café durante um ciclo produtivo. O estudo foi desenvolvido em uma lavoura experimental de café da Universidade Federal de Lavras em um período de 12 meses. Foi utilizada uma câmera digital RGB acoplada a um UAV. Foram avaliados neste estudo nove IV (MPRI, MGVRI, GLI, ExG, ExR, ExGR, VARI, RGBVI, VEG). Estes IV avaliados foram submetidos a uma análise de correlação de Pearson com o índice de área foliar (IAF), e uma posterior seleção do IV com maiores valores de R^2 foi realizada. O IAF foi estimado por meio de valores de altura de planta (He) e diâmetro de copa (De) estimados por imagem, sendo estes correlacionados com valores de altura de planta (H) e Diâmetro de Copa (D) medidos em campo.. Um R^2 de 0.52 foi encontrado para os valores de He e H. Para os dados de De e D o R^2 foi maior, 0.76.. Dentre os IV avaliados, os que apresentaram maior correlação com IAF foram o MPRI (0.31) e GLI (0.41), porém uma correlação fraca. Mapas temáticos de dos IV no período avaliado mostram variabilidade presente na lavoura.. A Evolução de plantas daninhas nas entrelinhas de plantio é perceptível em ambos IV, o que permite ao gestor a

tomada de decisão para o início dos tratamentos culturais, economizando recursos. Os resultados mostram que o uso de UAV e câmera RGB de baixo custo tem potencial de uso prático para o monitoramento do café em seu ciclo de produção, subsidiando o produtor com informações práticas para um manejo mais preciso da lavoura de forma rápida, simples.

Palavras chave: café, agricultura de precisão, Unmanned Aerial Vehicles – UAV, drone

Abstract

.

Keywords: coffee, precision agriculture, Unmanned Aerial Vehicles – UAV, drone

Introdução

As exportações de café pelo Brasil em 2019 geraram receita de US\$ 2,6 bilhões, sendo a espécie de café arábica responsável por 79% deste volume. Somente o estado de Minas Gerais é responsável pela produção de 33,96 milhões de sacas (54 % da produção nacional), sendo o estado que mais produz café no país, superando o segundo maior produtor de café do mundo, o Vietnã em 1, 2 milhão de sacas. Um dos fatores responsáveis por este resultado é a adoção de novas práticas e tecnologias no cultivo do café. Neste pacote tecnológico, além da implantação de novas cultivares mais resistentes, destaca-se o monitoramento agrícola do café por meio de mapeamento da área cultivada auxiliando na quantificação de área plantada, uso do solo e condições meteorológicas, contribuindo para previsões relevantes e precisas acerca da produção do café (Conab, 2020).

O sensoriamento Remoto (SR), amplamente utilizado no monitoramento de lavouras, com o avanço da tecnologia tem aumentado a aquisição e disponibilidade de dados em nível aéreo pela recente popularização dos Veículos Aéreos Não Tripulados (Unmanned Aerial Vehicles - UAV), também identificados como Sistemas de Aeronaves Pilotadas Remotamente (Remotely Piloted Aircraft Systems - RPAS). O UAV, quando comparado a plataformas para aquisição de imagens orbitais (satélite), apresenta

vantagens devido a realização de voos em baixas altitudes, que permitem uma maior resolução do alvo em campo, e pelo uso irrestrito sob demanda e momentos críticos (Jiménez-Brenes et al., 2019). Outro fator que contribui para o uso desta plataforma é a facilidade de operação (Holman et al., 2016). Países como Estados Unidos, França e Reino Unido já estudam o potencial de UAV na AP. Na China esta plataforma é vista como promissora para o desenvolvimento da agricultura moderna (Yue et al. 2012,).

Desde 2009, como descrito em Berni et al., (2009) o uso de UAV e SR tinham tendência a se popularizar devido a evolução da tecnologia, na qual refletiria em uma redução de custos de aquisição e de processamento de dados, sendo tecnologias de uso cotidiano no meio agrícola. Diante da evolução tecnológica Gago et al., (2015) acreditavam que o próprio produtor seria capaz de monitorar sua cultura e diagnosticar falhas em tempo real, como exemplo, regiões onde há ocorrência de estresse hídrico, podendo assim planejar ações no gerenciamento da irrigação prevenindo perdas de produtividade.

Atualmente UAV são encontradas com preços mais acessíveis, motivando um grande número de pequenas empresas a utilizarem UAV com sistemas operacionais mais simples e de fácil compreensão, utilizadas principalmente para prestação de serviços como o monitoramento de lavouras e medição de áreas. No entanto, o pequenos e médios produtores ainda encontram dificuldades na adoção desta tecnologia, por motivos de capacitação e em alguns casos a falta de demonstração técnica de retorno financeiros a curto e médio prazos.

Um dos produtos derivados do SR e mais utilizados na agricultura são os índices de vegetação (IV). Estes permitem ao avaliador realizar um monitoramento espacial e temporal da cultura por meio de técnicas de processamento de imagem, aprendizado de máquina e análises estatísticas, podendo inferir como exemplo sobre a sanidade da planta e estresse hídrico (Al-Gaadi et al., 2014; Jorge et al. 2019), contagem e determinação de características estruturais do dossel em citrus (Ampatzidis e Patel, 2019), quantificação de invasão de plantas daninhas na vinha (Jiménez-Brenes et al. 2019), estimativa de volume da planta de videiras (Castro et al., 2018) e detecção de doenças (Kerkech et al., 2018), predição de rendimento da cultura do trigo em determinadas na fase inicial de crescimento (Fernandez-Gallego et al., 2019), são alguns exemplos de aplicação de IV na agricultura.

No Brasil algumas pesquisas sobre o uso e aplicação do SR no monitoramento do café estão em desenvolvimento, como: a detecção de doenças no café por meio de técnicas de SR por meio de imagens de satélite (Barbedo et al., 2016a; Barbedo et al., 2016b; Mengitsu et al., 2016; Katsuma et al., 2018; Chemura et al., 2018, Marin et al. 2018) e avaliação do estresse hídrico (Chemura et al., 2018). Em relação ao uso de UAV e câmeras RGB na cultura do café, estudos mostram aplicações sobre detecção em falhas de plantio (Oliveira et al., 2018), estimativa de volume de frutos colhidos (Carrijo et al., 2017), estimativa de volume de planta (Cunha et al., 2019), detecção de nematoides (Oliveira et al., 2019) e determinação de parâmetros biofísicos do café (Santos et al., 2020) que foram desenvolvidos, mostrando o potencial destas ferramentas.

A maioria dos estudos citados acima utilizaram técnicas de processamento de imagem e algoritmos de classificação robustos que requerem conhecimento e poder computacional para tal desempenho, o que para alguns agricultores pode dificultar a aceitação do produto devido ao alto custo. Neste contexto o uso de IV RGB, que tem potencial para indicar anormalidades no campo e são de simples execução, aparecem como alternativa às técnicas robustas de segmentação e classificação de solo e vegetação como mostra o estudo de Barbosa et al. (2019), podendo ser utilizado como uma ferramenta primária de investigação e no manejo do café.

O uso de UAV e câmeras e seus produtos no manejo da lavoura de café ainda carece de maiores investigações, principalmente estudos que mostrem ao consumidor final e ao produtor, o potencial de uso destas tecnologias. Diante deste cenário, objetivou-se avaliar o potencial de um UAV e de IV RGB no monitoramento do cafeeiro durante um ciclo de produção, identificando as variabilidades existentes na lavoura no período.

2. Material e métodos

2.1 Área de estudo

A área de estudo está localizada nas dependências da Universidade Federal de Lavras (21°13'33"S, 44°58'17"W). A lavoura de café em estudo foi implantada em uma área de 0,10 ha em fevereiro de 2009 com a espécie *Coffea arabica* L., cultivar MGS Travessia, com espaçamento de plantio igual a 2,60 x 0,60m (Figura 1). Esta lavoura passou pelo processo de poda (esqueletamento) em julho de 2016. Segundo Silva et al.

(2016) quando esta atividade é realizada, espera-se a recuperação da produtividade da lavoura em média de dois anos.

O clima da região, segundo a classificação de Koppen, é do tipo Cwa, caracterizado por uma estação seca no inverno e uma estação chuvosa no verão.

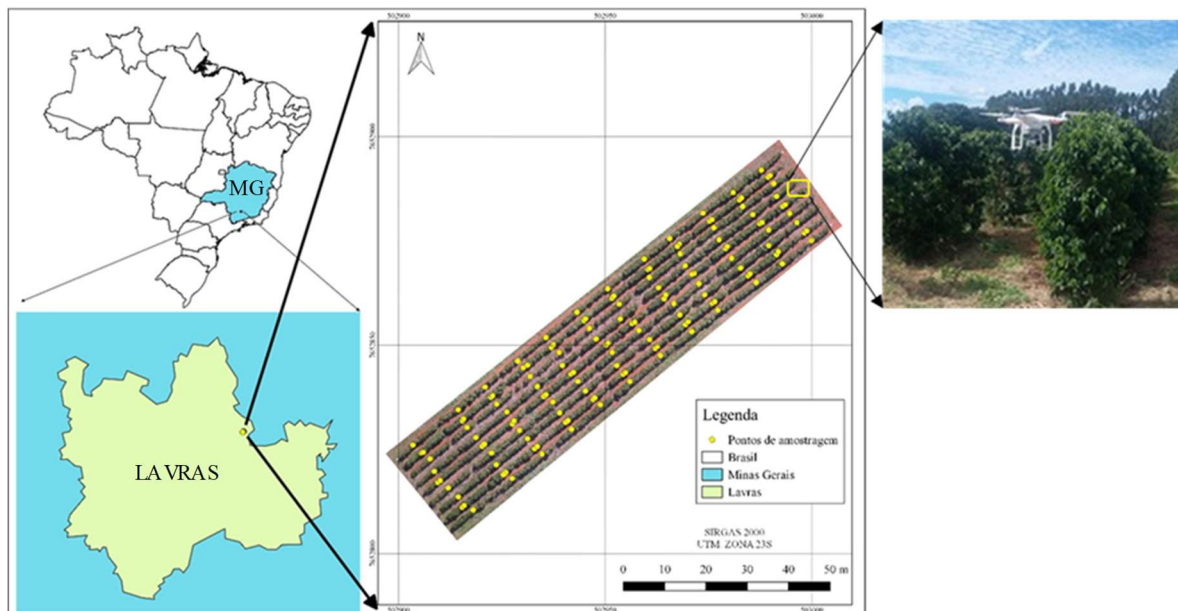


Fig 1 Localização da área de estudo.

2.3. Sistema UAV e Câmera

A coleta de imagens foi realizada utilizando uma UAV modelo DJI Phantom 3 profissional (DJI, Shenzhen, China) (Fig. 1). Este UAV é equipada com uma câmera digital RGB (Red-R, Green-G, Blue-B) acoplada, marca Sony, modelo EXMOR 1/2.3'', com resolução de 4000 x 3000 pixels (Fig. 2), com sensor de 6,16 x 6,62 mm, FOV de 94°, com taxa de amostragem de 0,5 quadros por segundo (Zhang et al., 2020) equipado com um receptor GPS interno. O sistema de controle da UAV é composto por uma estação de controle em solo conectada a um aparelho smartphone no qual está instalado um aplicativo para planejamento e controle de voo Drone Deploy (DroneDeploy, San Francisco, CA, USA), que foi utilizado em todas as missões em campo.

Os parâmetros utilizados para o planejamento foram a altitude de voo de 30m, velocidade de voo de $3\text{m}\cdot\text{s}^{-1}$, sobreposição frontal e lateral de 80% entre imagens. A escolha da sobreposição é baseada no estudo de Mesas-Carrascosa et al. (2017), onde a sobreposição longitudinal mínima de 80% no planejamento de voo é necessária para obter uma precisão e qualidade do ortomosaico.

As imagens foram georreferenciadas usando as coordenadas obtidas pelo GPS do UAV em cada waypoint como descrito em Zhang et al. (2020).

O período de retorno para coleta de imagens foi de 30 dias. As imagens foram coletadas entre 11:00 a 14:00 horas, que segundo Bater et al. (2011), imagens de câmeras RGB são fortemente influenciadas por mudanças de iluminação horárias, diárias e sazonais.

Em todas as missões foram envolvidas duas pessoas, o piloto, responsável pela estação de controle de solo (decolagem e pouso da UAV), e o observador, que tinha como função alertar o piloto sobre potenciais obstáculos durante o período de voo, conforme procedimento descrito em Torres-Sánchez et al., (2013)

2.4. Processamento de imagens

O processamento das imagens foi realizado com o software Photoscan Professional versão 1.2.4 (Agisoft LLC, St. Petersburg, Russia). O processo para a obtenção do ortomosaico foi realizado de acordo com a metodologia descrita por Jiménez-Brenes et al. (2019) seguindo os seguintes passos: (1) nuvem de pontos tridimensional (3D), para aplicar a técnica SfM (Structure-from-Motion); (2) Modelo Digital de Superfície (Digital Superfície Model- DSM) gerado a partir do modelo da nuvem de pontos 3D e: (3) confecção do ortomosaico da área. Neste processo os parâmetros inseridos no software para cálculo de posicionamento de imagens, orientação, correlação com as imagens vizinhas e sobreposição foram alta qualidade (Higt quality), e filtro de profundidade (depth filtering) como moderado. Para que a nuvem densa de pontos tivesse maior acurácia foram removidos outliers, de acordo com processo descrito em Hobart et al. (2020).

O georreferenciamento das imagens foi realizado com o auxílio de pontos de controle no solo (Ground Control Points - GCP) distribuídos seis pontos na área (sendo quatro nas extremidades e dois na porção central da área de estudo. As coordenadas dos GCP's foram obtidas por um aparelho de recepção de sinal do sistema diferencial de posicionamento global (DGPS; Trimble Navigation Limited, Sunnyvale, Califórnia, EUA) com precisão horizontal e vertical de 0,007 m.

Atualmente as UAV de baixo custo já produzem imagens georreferenciadas (geotag), no entanto faz necessário o ajuste de posicionamento real com auxílio de GCP para melhor acurácia do produto (Gómez-Cádon et al. 2014). O software utilizado para o

processamento das imagens realiza o processo de união das imagens por meio de identificação das coordenadas das imagens obtidas com as coordenadas do GCP na respectiva imagem, tornando mais simples o processo de calibração da câmera. A identificação GCP's foi feita de forma manual nas imagens antes da confecção do mosaico.

Após o alinhamento das imagens, a nuvem de pontos 3D foi gerada por meio da técnica SfM que é usada para a confecção do DSM. O DSM consiste em uma malha geométrica irregular que representa superfície do terreno. A confecção do orthomosaico é feita pela junção das imagens geradas após DSM (Dandois e Ellis, 2013; Jiménez-Brenes et al. 2019). Este processo de confecção de ortomosaico segundo Xiang e Tian (2011) é uma reprodução das imagens aéreas após uma correção para a inclinação da câmera, deslocamento entre imagens e distorção causada pela lente do sensor.

A precisão de um orthomosaico é definida em função de diversos parâmetros, dentre eles pode-se citar as coordenadas geográficas de localização das imagens, altitude do sensor, ângulos de rotação da câmera (roll, pitch e yaw). Em AP os orthomosaicos devem ser elaborados visando a sua precisão espacial fina, compatível como alvo a ser observado. Após a correção geométrica das imagens a resolução espacial média dos orthomosaicos no período de avaliação foi de 1,3cm.

O DSM e o orthomosaico gerados foram exportados no formato Geotiff para o software de geoprocessamento Quantum Gis v. 2.16.3 (Equipe de Desenvolvimento do QGIS, Open Source Geospatial Foundation) em um arquivo formato GeoTiff, projeção Universal Transverso Mercator (UTM), zona SIRGAS 2000 / UTM 23S,

2.4. Obtenção de dados de campo

Foram selecionadas para este estudo um total de 144 plantas conforme metodologia descrita por Ferraz et al. (2017), sendo estas georreferenciadas utilizando o mesmo equipamento descrito para os GCP's. Os dados da altura da planta (H) e diâmetro da copa (D) foram coletados no período em estudo, utilizando uma fita métrica de 0,01 m de largura e comprimento máximo de 2,50 m. O Dm foi medido no terço médio de cada planta.

2.5 Estimativa do índice de área foliar

O índice de área foliar (IAF) foi utilizado neste estudo por ser um parâmetro que reflete as alterações fisiológicas da planta em seu dossel, que por sua vez está relacionado com o rendimento da cultura, desta forma o IAF pode ser aplicado em modelagem, manejo em geral na agricultura de precisão (Hasan et al, 2019). Para a cultura do café, segundo Costa et al. (2019), o IAF varia de acordo com o manejo aplicado, alterando assim seu volume foliar. Desta forma, visou neste estudo selecionar e avaliar o comportamento temporal dos IV de maior correlação com o IAF. A determinação do IAF seguiu a metodologia descrita por Favarin et al. (2002) (Equação 1), por ser uma metodologia rápida, não destrutível e passível de ser utilizada com dados de D e H estimados por meio de UAV.

$$IAF = 0.0134 + 0.7276 \times D^2 \times H \quad (1)$$

Em que,

D – Diâmetro da planta, m;

H – Altura da planta, m.

Os dados de altura estimado por imagens aéreas de UAV (He), foi seguindo a metodologia descrita por Panagiotidis et al. (2016) e Surovy et al. (2018) (Equação 2), onde a He é estimada pela diferença entre o DSM e MDT (Modelo digital de terreno). O MDT foi gerado no mesmo software onde foi gerado o MDS, após uma classificação da nuvem densa de pontos, onde foram definidas três classes: superfície, vegetação e edificações, sendo a superfície pontos com altitude menor igual a 0,1 m.

O diâmetro de copa estimado por imagem (De) foi estimado de manualmente no próprio orthomosaico referente a cada período de avaliação no software QGIS em todos os pontos amostrais.

$$He = DSM - MDT \quad (2)$$

Os dados de He gerados pela Equação 2 nos pontos de medição foram extraídos para uma tabela de atributos de cada ponto amostral com o auxílio da ferramenta Point Sampling Tool do QGIS.

Após a obtenção dos dados de He e De obtidos por meio de imagens, estes foram submetidos um teste de correlação com os dados obtidos em campo.

2.6 Análises estatísticas

A validação dos dados de H e D obtidos por meio de medidas em campo e por imagens (He e De) foram submetidos a uma análise estatística descritiva (média, máximo, mínimo).

As análises estatísticas foram realizadas no software estatístico R (R Development Core Team. R, 2018).

2.7 Índices de vegetação

Neste estudo foram avaliados nove índices de vegetação (IV) (Tabela1). Os valores de brilho das bandas R (Red) G (green) B (Blue) foram normalizados (-1 a 1), conforme descrito na equação 3 (Torres-Sánchez et al., 2014; Saberioon et al., 2014; Zhou et al., 2017; Zhang et al., 2019). A escolha dos IV dentre os diversos existentes na literatura, teve como base as evidências e potenciais aplicações destes na AP, como descritos em Peña-Barragán et al., 2011; Castro et al., 2015; Camargo Neto, 2004; Torres-Sánchez et al., 2015; Bareth et al., 2015; Bendig et al., 2015) na avaliação de diferentes cultivos agrícolas. O fluxo do processo para o cálculo dos IV é ilustrado na Fig. 2-A.

$$r = \frac{R}{R+G+B}; g = \frac{G}{R+G+B}; b = \frac{B}{R+G+B} \quad (3)$$

Onde R, G e B são os valores de brilho das bandas espectrais vermelho, verde e azul.

Os IV foram calculados por meio da ferramenta “raster calculator” no QGIS.

Tabela 1. Índices de Vegetação

IV	Nome	Equação	Referencia
MGVRI	Modified Green Red Vegetation Index	$\frac{(G)^2 - (R)^2}{(G)^2 + (R)^2}$	Bendig, et al. (2015)
GLI	Green Leaf Index	$\frac{2G - R - B}{2G + R + B}$	Louhaichi, Borman & Johnson, (2001)
MPRI	Modified Photochemical Reflectance Index	$\frac{G - R}{G + R}$	Yang et al.(2008)
RGVBI	Red Green Blue Vegetation Index	$\frac{G - (BxR)}{(G)^2 + (BxR)}$	Bendig, et al.(2015)
ExG	Excess of green	$2G - R - B$	Woebbecke et al., (1995)
VEG	Vegetativen	$\frac{G}{(R)^a * B^{(1-a)}}$	Hague et al., (2006)
ExR	Excess of red	$1.4R - G$	Meyer al. (1999)
ExGR	Excess Green-Red	$ExG - ExR$	Camargo Neto (2004)
VARI	Visible atmospherically resistant index	$\frac{G - R}{G + R - B}$	Gitelson et al., (2002)

a= constante com valor de 0,667

B=blue, G=green, R=red.

Após o cálculo dos IV, foram extraídos o valor médio de cada IV em um buffer de 0,8m de diâmetro (Fig. 2-B), de cada planta amostrada, utilizando a ferramenta “estatísticas por zona” (Zhang et al., 2019). Estes valores foram submetidos a uma análise correlação entre com os dados de IAF no período.

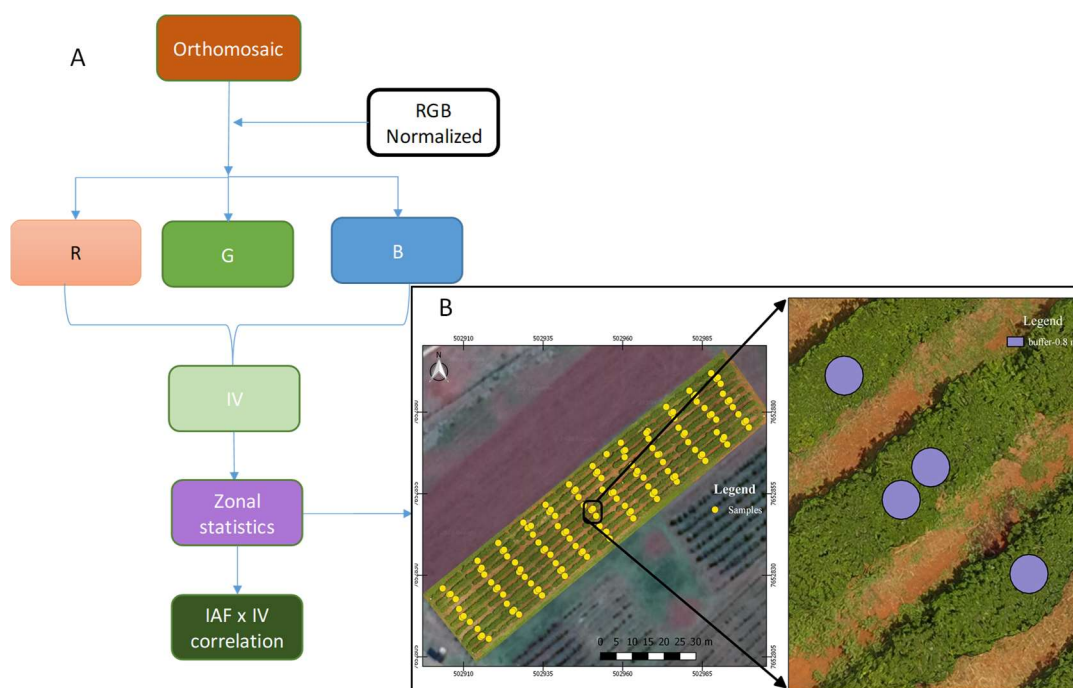


Fig 2 Fluxo para cálculo dos IV e correlação com IAF (A). Buffer de 0.8m para cálculo de valor médio de IV em cada amostra.

3. Resultados e Discussão

Altura de planta e diâmetro de copa

A validação dos dados de He e De em relação aos dados de campo foi feita com um conjunto de dados inicial de 1728 pares para cada parâmetro avaliado. Um pré-processamento dos dados, indicou a presença de outliers nos dados de He referentes a uma amostra em específico, nos meses de abril e maio de 2018 (Fig. 3). Acredita-se que a ausência de vegetação alterou a estimativa de altura da planta. Desta forma esta amostra específica foi retirada do banco de dados para as análises, gerando um total de 1716 pares de amostras para cada parâmetro.

Análise descritiva dos dados de altura de planta (H) e diâmetro de copa (D) medidos em campo, altura da planta (He) e diâmetro de copa (De) estimados por imagem obtidas por UAV, estão ilustrados na Fig. 4, onde nos boxplots estão representados os valores mínimos, primeiro quartil, média, terceiro quartil e valores máximos.




Fig 3 Exemplo de Outlier

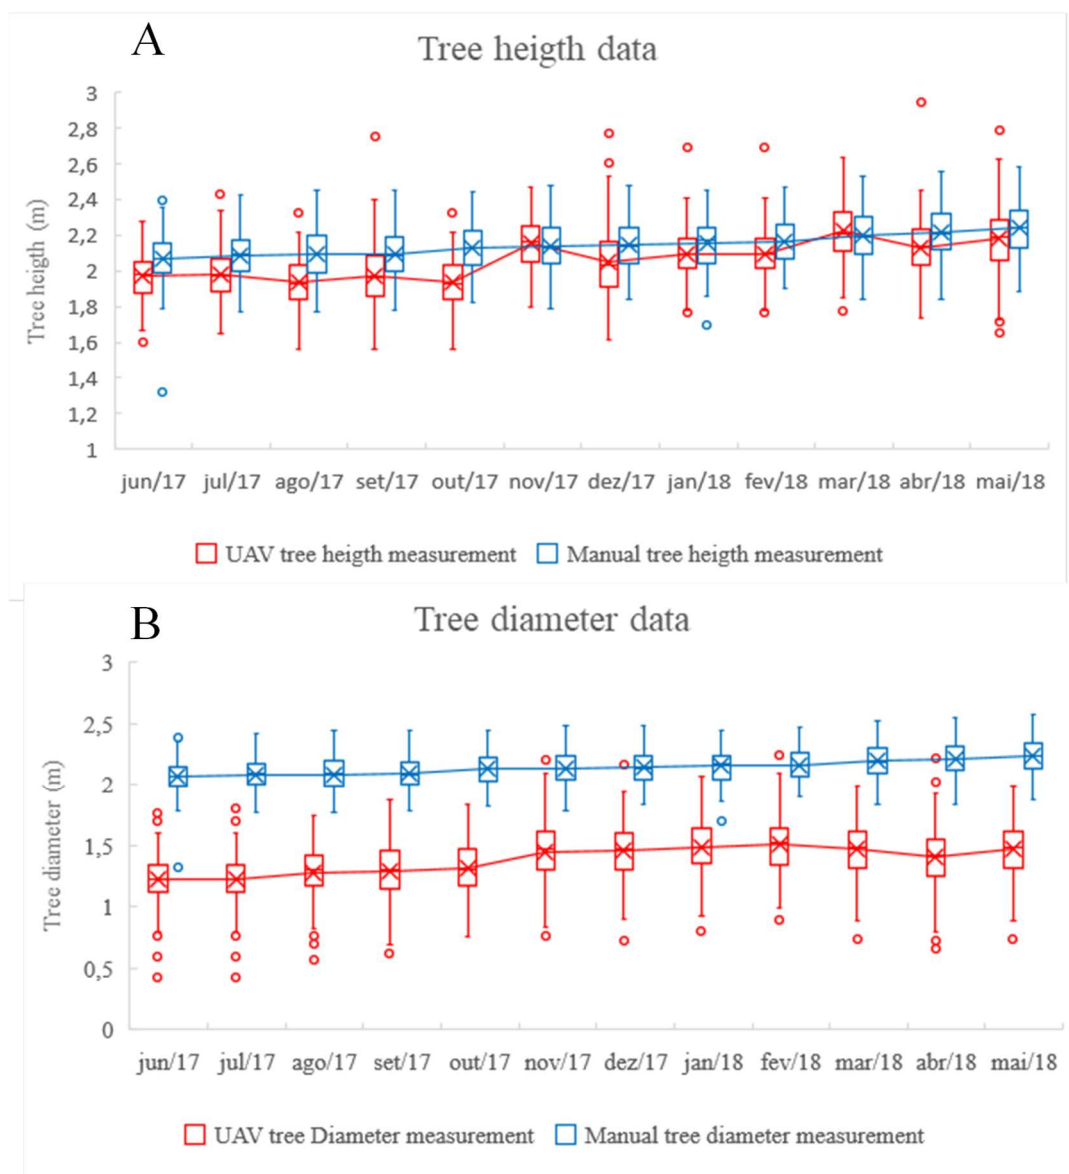


Fig 4 Altura de plantas estimado x medido em campo (A). Diâmetro de copa de planta estimado x medido (B).

Em todo o período avaliado, a média dos valores de altura e diâmetro estimados, foram menores em comparação com os dados de campo (Fig. 4). As maiores variações entre os dois métodos de avaliação são observadas para os dados estimados pelo UAV, sendo maior para os dados de altura, no qual a maior variância ocorre nos meses de julho e outubro (máximo). Para os dados de diâmetro a maior variância ocorre no mês de setembro. Outliers são observados em ambos os métodos de obtenção dos parâmetros biofísicos da planta, tendo uma maior frequência no conjunto de dados estimados pelo UAV. Surovy et al. (2015) relatam em seu estudo que a altura das rvores (pinheiro) tem

interferência direta na estimativa da altura por imagem, em que árvores menores tendem a ter uma forma de copa irregular, produzindo erros maiores

Erros de medição em solo para a altura e diâmetro podem estar associados a presença de outliers. A inclinação da régua em função do terreno deve ser mantida em nível durante toda as medições, o que neste estudo não foi possível garantir devido das limitações dos equipamentos utilizados. Para os erros associados a medição do diâmetro a densidade de galhos e folhas de algumas plantas não permitiram uma medição da secção transversal da copa com um paralelismo ideal entre as extremidades. Para os valores estimados por imagens, um dos fatores podem ser o enfolhamento (Fig. 3). Como o diâmetro de copa foi estimado de acordo com a percepção do observado nas imagens, a definição correta de para cada amostra foi prejudicado devido aos dosséis estarem praticamente unidos entre duas plantas.

Uma análise de regressão aplicada aos dados de altura e diâmetro foram aplicadas as duas metodologias. O valor de R^2 igual a 0.52 para a altura da planta, sendo considerada uma correlação moderada. Para o diâmetro de copa, o valor de R^2 entre os dois métodos foi de 0.72, também aceitável para a utilização destes dados em substituição de medições em campo, de forma mais rápida e econômica.

Índice de Área foliar (IAF)

Os resultados ilustrados nas Fig. 5-A e Fig. 5-B, indicam que os dados de altura (H_e) e diâmetro (D_e) estimados por imagem podem ser usados para estimar o IAF de cada amostra. O comportamento do IAF está ilustrado na Fig. 5.

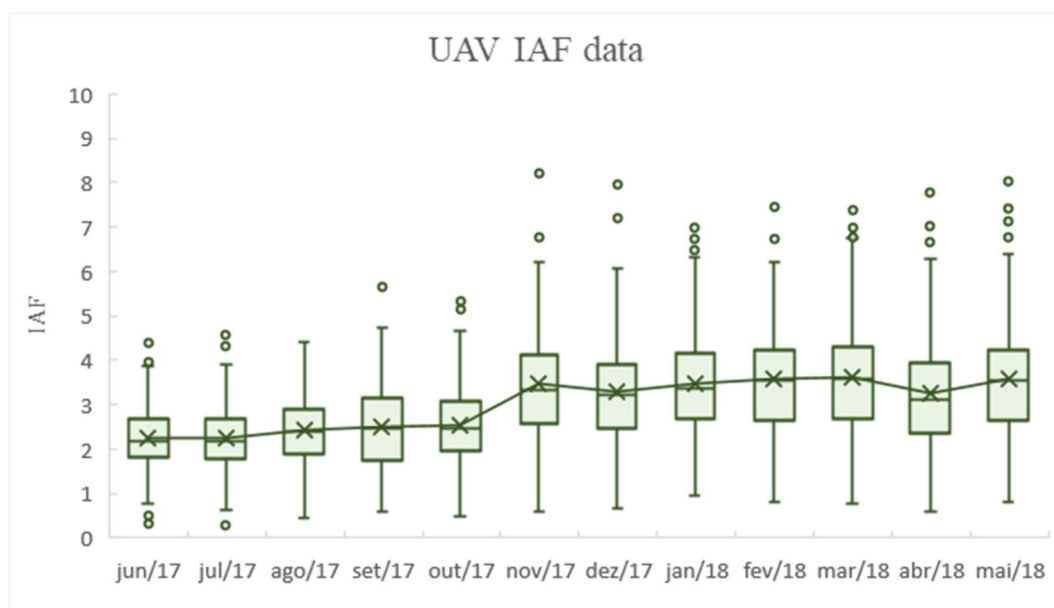


Fig 5 Comportamento do IAF estimado por UAV.

O comportamento dos dados de IAF mostra uma pequena variação positiva entre os meses de junho a outubro. Entre outubro e novembro houve um acréscimo de 22% no valor da média, se mantendo praticamente estável (aproximadamente 3,4) entre novembro de 2017 a maio de 2018. A maior variação ocorre no mês de novembro de 2017, e menor para junho de 2017. O valor máximo de IAF foi 8,21 foi referente ao mês de novembro de 2017, valor mínimo de 0,018 em maio de 2018, e valor médio no período de 3,04.

As variações observadas, assim como outliers, estão associados principalmente a erros de medição de altura por imagem, como já descrito acima. No entanto percebe-se um padrão de crescimento ao longo do período avaliado. A variância ilustrada na Fig. 5 indica que a lavoura tem plantas com desfolhamento, no entanto uma análise espacial é indicada para identificação da causa e tomadas de decisões para minimizar a amplitude de valores.

Índices de vegetação (IV) x IAF

Foram avaliados nove IV em todo o período de estudo, onde o comportamento dos valores médios dos IV foram segmentados em função das fases fenológicas do café, conforme relatado no estudo de Camargo e Camargo (2001). Desta forma, foram extraídos os valores médios de cada IV dentro de um buffer de 0,8m em cada amostra. Esta amostragem teve como objetivo reduzir a contaminação de pixels de galhos. Uma análise correlação de Pearson foi realizada entre os pares de IV e IAF, onde o resultado pode ser observado na Tabela 2, 3, 4 e 5.

Tabela 2. Correlação entre IV e IAF na 2° fase do ciclo fenológico do café.

	VARI	ExGR	RGBVI	VEG	ExG	ExR	GLI	MGVRI	MPRI	IAF
VARI	1									
ExGR	-0.09	1.00								
RGBVI	0.60	0.11	1.00							
VEG	0.85	-0.25	0.64	1.00						
ExG	-0.30	0.26	-0.06	-0.17	1.00					
ExR	0.05	-0.99	-0.12	0.24	-0.12	1.00				
GLI	-0.44	0.33	-0.17	-0.34	0.87	-0.21	1.00			
MGVRI	-0.14	-0.45	-0.16	-0.01	0.62	0.55	0.52	1.00		
MPRI	-0.14	-0.45	-0.16	-0.01	0.62	0.55	0.52	1.00	1.00	
IAF	0.36	0.08	0.24	0.25	0.11	-0.07	0.06	0.16	0.16	1.00

Tabela 3 Correlação entre IV e IAF na 3° fase do ciclo fenológico do café.

	VARI	ExGR	RGBVI	VEG	ExG	ExR	GLI	MGVRI	MPRI	IAF
VARI	1.00									
ExGR	0.95	1.00								
RGBV	-0.77	-0.79	1.00							
VEG	0.57	0.68	-0.40	1.00						
ExG	0.90	0.99	-0.78	0.70	1.00					
ExR	-0.99	-0.94	0.73	-0.58	-0.89	1.00				
GLI	0.80	0.84	-0.60	0.82	0.82	-0.81	1.00			
MGVRI	0.84	0.83	-0.60	0.68	0.78	-0.86	0.93	1.00		
MPRI	0.99	0.96	-0.77	0.59	0.92	-0.99	0.81	0.86	1.00	
IAF	-0.05	-0.11	0.26	0.04	-0.14	0.03	0.00	-0.03	-0.06	1.00

Tabela 4. Correlação entre IV e IAF na 4° fase do ciclo fenológico do café.

	VARI	ExGR	RGBVI	VEG	ExG	ExR	GLI	MGVRI	MPRI	IAF
VARI	1.00									
ExGR	0.49	1.00								
RGBVI	0.20	0.30	1.00							
VEG	0.29	0.24	0.78	1.00						
ExG	0.54	0.43	0.89	0.74	1.00					
ExR	-0.58	-0.73	-0.11	-0.12	-0.33	1.00				
GLI	0.68	0.36	0.66	0.58	0.77	-0.20	1.00			
MGVRI	0.93	0.52	0.26	0.33	0.59	-0.63	0.58	1.00		
MPRI	0.93	0.52	0.27	0.33	0.60	-0.63	0.58	1.00	1.00	
IAF	0.34	0.22	0.03	0.07	0.16	-0.38	0.15	0.39	0.39	1.00

Tabela 5 Correlação entre IV e IAF na 5° fase do ciclo fenológico do café.

	VARI	ExGR	RGBVI	VEG	ExG	ExR	GLI	MGVRI	MPRI	IAF
VARI	1.00									
ExGR	0.49	1.00								
RGBVI	0.74	0.26	1.00							
VEG	0.67	0.24	0.95	1.00						
ExG	0.86	0.35	0.97	0.91	1.00					
ExR	0.46	0.93	0.25	0.21	0.31	1.00				
GLI_mai	0.15	-0.26	0.19	0.18	0.22	-0.46	1.00			
MGVRI	1.00	0.50	0.71	0.66	0.85	0.45	0.16	1.00		
MPRI	1.00	0.50	0.71	0.66	0.85	0.45	0.16	1.00	1.00	
IAF	0.31	-0.18	0.33	0.34	0.33	-0.18	0.40	0.30	0.30	1.00

Todos os IV apresentaram fracas correlações (menor que 0.5) com o IAF no período de avaliação, como pode ser observado nos valores destacados em verde nas Tabelas 2 a 6. A segunda fase do ciclo vegetativo (Tabela 3) teve o IV VARI com a maior correlação, valor igual a 0,36, com o IAF. A terceira fase (fase da florada) o IV que teve a melhor correlação dentre os IV avaliados foi o RGBVI com valor de 0.26. A quarta fase, a de granação dos frutos, o IV que obteve maior correlação com o IAF neste período foi o MPRI (0.39). A 5° fase (maturação dos frutos) o IV GLI teve a maior correlação encontrada dentre todas as fases e IV avaliados. Diante do resultado, a variação dos valores médios de cada IV selecionado em cada fase são ilustrados na Fig. 6, e estes comportamentos serão discutidos posteriormente.

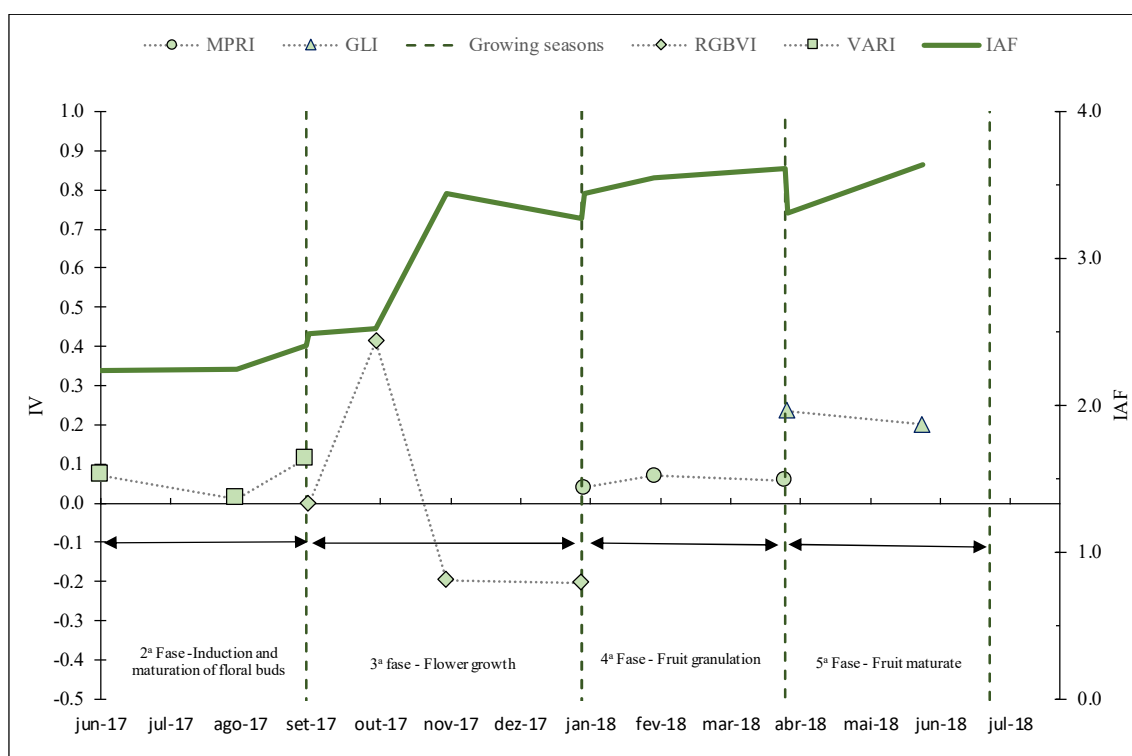


Fig. 6 Comportamento do MPRI, GLI e IAF no ciclo produtivo do café.

De forma geral, apenas a partir da quarta fase os IV apresentam um comportamento semelhante ao IAF, um dos possíveis fatores é a correlação observada ser maior apenas na quarta e quinta fases (Fig. 6). Outro fator passível de estar influenciando a baixa correlação e baixa similaridade no comportamento dos valores de IV em relação ao IAF é de que os IV são representados apenas por uma visão bidimensional da planta, da copa, não sendo representativo para toda área foliar. A mistura de pixels entre galhos e folhas na copa também interferem no valor médio do IV.

O IAF apresentou um comportamento crescente no período, no entanto, como observado na Fig. 6, houve decréscimo nos valores no final de terceira e quarta fase, o que pode ser ocasionado por erros de medidas em campo, conforme observado nos outliers no período, ilustrados nas Figs 4 e 6.

Avaliações espaciais da evolução de área vegetativa do café, em suas diferentes fases, são ilustradas nas Figuras 7-10.

O VARI, na segunda fase (indução das gemas florais) (Fig. 7), apresenta um comportamento crescente em seus valores (junho a agosto), enquanto o IAF teve uma pequena variação positiva no mesmo período. Na Fig. 7, observa-se que o VARI conseguiu distinguir solo de vegetação. Ao analisar as Fig. 7A (junho) e Fig. 7B (agosto)

nota-se um tom de verde mais escuro nas linhas de plantio, o que corrobora com o comportamento ilustrado na Fig. 6. Observa-se também nestas Figuras a evolução de plantas daninhas nas extremidades e entre linhas.




Fig. 7 2º fase do ciclo vegetativo do café evidenciado pelo VARI

Na fase da florada (Fig 8), o RGBVI apresentou um comportamento distinto do IAF entre setembro a outubro, já no final desta fase o comportamento entre as variáveis foi similar, fatores estes que corroboram com o baixo valor de correlação encontrado. O

RGBVI em todos os meses da quarta fase também consegue distinguir solo e vegetação, mas nas linhas de plantio este IV tem um desempenho não satisfatório qualitativamente quando comparado aos outros IV em outras fases. Observa-se também o crescimento de plantas daninhas do mês de outubro (Fig. 8-A) a dezembro (Fig 8-D).




Fig 8 3º fase do ciclo vegetativo do café evidenciado pelo RGVBI.

Na quarta fase (Fig 9), o MPRI apresentou comportamento semelhante ao IAF, ambos com acréscimos em seus valores, indicando um aumento do dossel do cafeeiro. O

solo e vegetação foram bem segmentados pelo MPRI. A intensidade de mato competição nas extremidades da área e nas entre linhas é ilustrada na Fig. 9B. Posteriormente uma redução da mato competição é observado no mês de março (Fig 9-C), indicando que o monitoramento por meio de IV tem potencial para planejamento de atividades de controle (Fig.9).

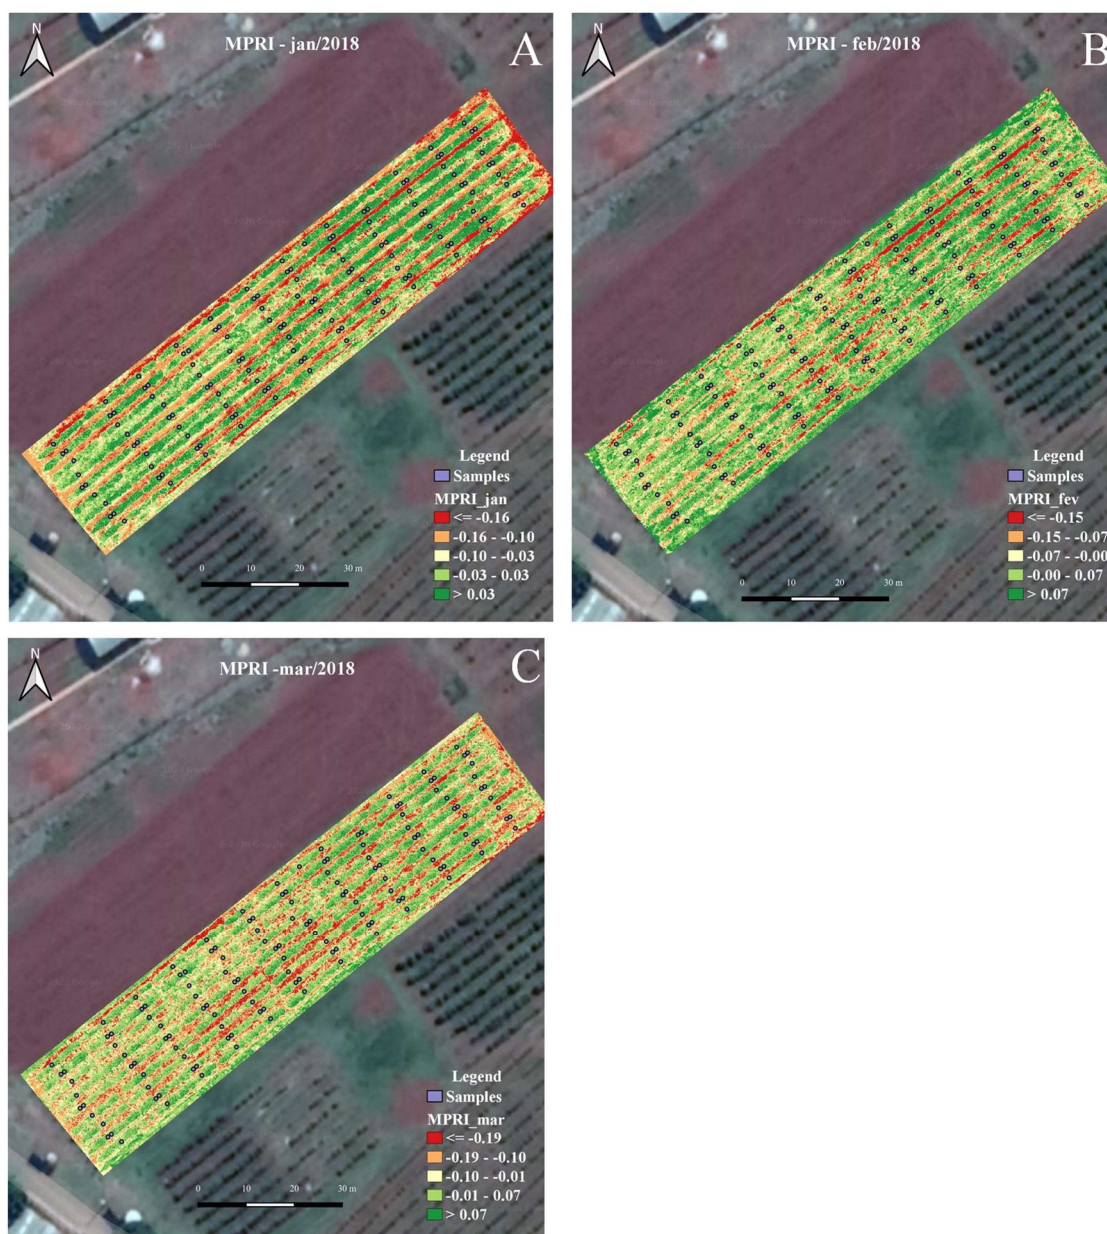


Fig. 9 4º fase do ciclo vegetativo do café evidenciado pelo MPRI.

Na quinta fase (Fig. 10) O GLI, IV com maior correlação apresentou comportamento diferente do IAF, tendo uma redução no seu valor neste período. Esta variabilidade pode ser explicada pela mistura de pixels entre galhos e folhas nos pontos

amostrais. O GLI assim como os outros IV conseguiu distinguir solo e vegetação. Fig. 10 – A mostra um maior tom de verde nas plantas de café do que na Fig. 10- B (maio), principalmente na porção central da área.

A determinação de parâmetros biofísicos da planta como altura (He) e diâmetro de copa (De) por meio de técnicas de processamento de imagem apresentou uma assertividade considerável quando comparado com valores medidos em solo. Estes resultados permitem o avaliador a estimar de forma rápida o IAF da planta, economizando tempo e recursos financeiros quando comparado a metodologias de medição em campo.

Um maior valor de R^2 pode ser alcançado quando no planejamento de voo, uma maior sobreposição entre imagens é adotada, conforme descrito em López-Granados et al. (2019). Uma outra oportunidade de investigação para melhorar a estimativa do IAF é determinar o volume da planta utilizando técnicas de reconstrução 3D por meio da nuvem de pontos gerada, como descrito em Torres-Sánchez et al. (2018).

O uso de câmeras multiespectrais para determinação de diâmetro de copa de forma automática como descrito em Ampatzidis et al (2019), pode ampliar os resultados, no entanto esta precisão deve ser avaliada em função dos alvos a serem observados e no acréscimo no custo quando comparados aos resultados obtidos por câmeras RGB.

A variabilidade dos dados de IAF, ao longo do período pode ser explicado pela ação de fatores climáticos, por exemplo, a ocorrência de chuvas extremas, que reduz a área foliar, conforme descrito em Bréda et al. (2003).

Resende et al. (2014) destaca que o monitoramento do IAF é importante para o planejamento de atividades na lavoura como o manejo de irrigação, adubação, combate a plantas invasoras. No entanto a relação dos fatores que afetam o IAF e sua correlação com os IV derivados de UAV não foram avaliadas neste trabalho, ficando assim como sugestão para investigações futuras. O ganho de tempo na estimativa do IAF por sensoriamento remoto quando comparado com métodos tradicionais é corroborado por Zheng e Moskal (2009), mas estes autores ressaltam que a estrutura de cada cultura requer pesquisa para desenvolvimentos de algoritmos em diferentes escalas.

A variação entre os dados de IAF em cada mês, corroborado pela Fig. 8, mostra que o MPRI e GLI tiveram êxito em representar a variabilidades espacial de cobertura vegetal nas linhas de plantio, o que auxilia o produtor na tomada de decisões, para que a produtividade da área não seja reduzida.

O GLI apresenta maior potencial para análise de solo e cobertura vegetal, o que vai de acordo com o resultado descrito na Tabela 6. Além do monitoramento da cultura, a distinção de solo e visualização de plantas invasoras pode auxiliar no planejamento de atividades de controle de mato competição de forma mais precisa, economizando recursos ao produtor.

A seleção de IV RGB é também descrita em Jiménez-Brenes et al. (2019), onde estes autores utilizaram o IV RGB para gerar mapas de vegetação e solo para apoio ao manejo de videiras, o que após investigações na área, os produtores decidiram que o melhor manejo a ser adotado era a reforma da lavoura.

Os resultados observados neste trabalho estão de acordo com as considerações descritas em Glenn et al. (2008), onde a aplicação dos IV na agricultura geralmente não apresentam relação linear com atributos do dossel da planta, e que estes devem usados de uma forma simplificada, e não como um índice que expressa as características detalhadas do dossel da planta.

5. Conclusões

O uso de imagens RGB na cafeicultura de precisão apresentou resultados positivos, podendo ajudar o agricultor no monitoramento de anomalias em campo com resolução espacial e temporal adequadas, de forma rápida, simples e objetiva.

Referências Bibliográficas

Al-Gaadi, K. A.; Patil, V. C.; Tola, E.; Rangasawamy, M.; Marey, S. A. In-season assessment of wheat crop health using vegetation indices based on ground measured hyper spectral data. *Am. J. Agri. Biol. Sci*, v. 9, n. 2, p. 138-146, 2014.

Ampatzidis, Y., & Partel, V. (2019). UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sensing*, 11(4), 410.

Baluja, J. ; Diago, MP; Balda, P; Zorer, R. ; Meggio, F. ; Morales, F. ; Tardaguila, J. Avaliação da variabilidade do estado da água do vinhedo por imagens térmicas e multiespectrais usando um veículo aéreo não tripulado (UAV). *Irrig. Sci.* 2012 , 30 , 511-522. [Google Scholar] [CrossRef]

Barbedo, J. G. A. (2016a). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems engineering*, 144, 52-60. <https://doi.org/10.1016/j.biosystemseng.2016.01.017>

Barbedo, J. G. A., Koenigkan, L. V., & Santos, T. T. (2016b). Identifying multiple plant diseases using digital image processing. *Biosystems Engineering*, 147, 104-116. doi:10.1016/j.biosystemseng.2016.03.012

Barbosa, B. D. S., Ferraz, G. A. S., Gonçalves, L. M., Marin, D. B., Maciel, D. T., Ferraz, P. F. P., & Rossi, G. (2019). RGB vegetation indices applied to grass monitoring: a qualitative analysis. *Agronomy Research*, 17(2), 349-357.

Barbosa, J., Pozza, E. A., de Souza, P. E., Oliveira e Silva, M. D. L., Pozza, A. A., & Guimarães, R. J. (2017). Irrigation drip and phosphorus managements in the rust coffee progress. *Coffee Science*, 12(2), 187-196. doi: <http://dx.doi.org/10.25186/cs.v12i2.1214>

Bareth, G. E. O. R. G., Bolten, A. N. D. R. E. A. S., Hollberg, J. E. N. S., Aasen, H., Burkart, A., & Schellberg, J. (2015). Feasibility study of using non-calibrated UAV-based RGB imagery for grassland monitoring: Case study at the Rengen Long-term Grassland Experiment (RGE), *Germany. DGPF Tagungsband*, 24(2015), 1-7.

Bater, C. W., Coops, N. C., Wulder, M. A., Hilker, T., Nielsen, S. E., McDermid, G., et al. (2011). Using digital time-lapse cameras to monitor species-specific understorey and overstorey phenology in support of wildlife habitat assessment. *Environmental Monitoring and Assessment*, 180(1-4), 1-13. <https://doi.org/10.1007/s10661-010-1768-x>

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., ... & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87. <https://doi.org/10.1016/j.jag.2015.02.012>

Berni, J. A., Zarco-Tejada, P. J., Suárez, L., & Fereres, E. (2009). Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Transactions on geoscience and Remote Sensing*, 47(3), 722-738.

Breda, N. J. (2003). Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. *Journal of experimental botany*, 54(392), 2403-2417. <https://doi.org/10.1093/jxb/erg263>

Bréda, N. J. J. Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. *Journal of Experimental Botany*, Oxford, v. 54, n. 392, p. 2403-2417, nov. 2003

Camargo Neto J. A combined statistical-soft computing approach for classification and mapping weed species in minimum-tillage systems. Univ Neb Linc. 2004; Available: <http://digitalcommons.unl.edu/dissertations/AAI3147135/>

Camargo, Â. P. D., & Camargo, M. B. P. D. (2001). Definition and schematization of the phenological phases of Arabica coffee in tropical conditions in Brazil. *Bragantia*, 60 (1), 65-68. <http://dx.doi.org/10.1590/S0006-87052001000100008>

Carrijo, G. L., Oliveira, D. E., de Assis, G. A., Carneiro, M. G., Guizilini, V. C., & Souza, J. R. (2017, November). Automatic detection of fruits in coffee crops from aerial images. In *Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR), 2017 Latin American* (pp. 1-6). IEEE.

Castro A. I, Ehsani R, Ploetz R, Crane JH, Abdulridha J. Optimum spectral and geometric parameters for early detection of laurel wilt disease in avocado. (2015). *Remote Sens Environ.*; 171: 33-44. <https://doi.org/10.1016/j.rse.2015.09.011>

Castro, A. I., Jimenez-Brenes, F. M., Torres-Sánchez, J., Peña, J. M., Borrás-Serrano, I., & López-Granados, F. (2018b). 3-D characterization of vineyards using a novel UAV imagery-based OBIA procedure for precision viticulture applications. *Remote Sensing*, 10(4), 584. <https://doi.org/10.3390/rs10040584>

Castro, A.I., J. Torres-Sánchez, J.M. Peña, F. Jiménez-Brenes, O. Csillik, F. López-Granados. 2018. Título: An automatic Random Forest-OBIA algorithm for early weed

mapping between and within crop rows using UAV imagery. *Remote Sensing*, 2018a, 10(2), 285; doi:10.3390/rs10020285 (Open access)

Chemura, A., Mutanga, O., Sibanda, M., & Chidoko, P. (2018). Machine learning prediction of coffee rust severity on leaves using spectroradiometer data. *Tropical Plant Pathology*, 43(2), 117-127. <https://doi.org/10.1007/s40858-017-0187-8>

CONAB- Companhia Nacional de Abastecimento. Acompanhamento da Safra Brasileira de café: Monitoramento agrícola, v. 5– Safra 2018, n. 4 - Quarto levantamento, Brasília, p. 1-84,

Costa, J. D. O., Coelho, R. D., Barros, T. H. D. S., Fraga Junior, E. F., & Fernandes, A. L. T. (2019). Leaf area index and radiation extinction coefficient of a coffee canopy under variable drip irrigation levels. *Acta Scientiarum. Agronomy*, 41. <https://doi.org/10.4025/actasciagron.v41i1.42703>

Cunha, J. P., Neto, S., Matheus, A., & Hurtado, S. (2019). Estimating vegetation volume of coffee crops using images from unmanned aerial vehicles. *Engenharia Agrícola*, 39(SPE), 41-47. <http://dx.doi.org/10.1590/1809-4430>

Dandois, J. P., & Ellis, E. C. (2013). High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. *Remote Sensing of Environment*, 136, 259-276. <https://doi.org/10.1016/j.rse.2013.04.005>

Favarin, J. L., Dourado Neto, D., García y García, A., Villa Nova, N. A., & Favarin, M. D. G. G. V. (2002). Equations for estimating the coffee leaf area index. *Pesquisa agropecuária brasileira*, 37(6), 769-773. <https://doi.org/10.1590/S0100-204X2002000600005>

Fernandez-Gallego, J. A., Kefauver, S. C., Vatter, T., Gutiérrez, N. A., Nieto-Taladriz, M. T., & Araus, J. L. (2019). Low-cost assessment of grain yield in durum wheat using RGB images. *European Journal of Agronomy*, 105, 146-156. <https://doi.org/10.1016/j.eja.2019.02.007>

Ferraz, G. A., Silva, F. M. D., Oliveira, M. S. D., Custódio, A. A. P., & Ferraz, P. F. P. (2017). Spatial variability of plant attributes of a coffee crop. *Revista Ciência Agronômica*, 48(1), 81-91 <http://dx.doi.org/10.5935/1806-6690.20170009>.

Gago, J.; Douthe, C.; Coopman, R.E.; Gallego, P.P.; ribas-carbo, M.; FLEXAS, J.; Escalona, J.; Medrano, H. (2015). UAVs challenge to assess water stress for sustainable agriculture. *Agricultural Water Management*, v. 153, p. 9-19, 2015. doi: <https://doi.org/10.1016/j.agwat.2015.01.020>

Gitelson, A. A., Stark, R., Grits, U., Rundquist, D., Kaufman, Y., & Derry, D. (2002). Vegetation and soil lines in visible spectral space: a concept and technique for remote estimation of vegetation fraction. *International Journal of Remote Sensing*, 23(13), 2537-2562. <https://doi.org/10.1080/01431160110107806>

Glenn, E.P; Huete, A.R.; NagleR, P.L.; Nelson, S.G.. Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: what vegetation indices can and cannot tell us about the landscape. *Sensors*, v. 8, n. 4, p. 2136-2160, 2008. doi: 10.3390/s8042136

Gómez-Candón, D., De Castro, A. I., & López Granados, F. (2014). Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. *Precision Agriculture*, 15, 44–56. <https://doi.org/10.1007/s11119-013-9335-4>.

Hague, T., Tillett, N. D., & Wheeler, H. (2006). Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 7(1), 21-32.

Hasan, U., Sawut, M., & Chen, S. (2019). Estimating the Leaf Area Index of Winter Wheat Based on Unmanned Aerial Vehicle RGB-Image Parameters. *Sustainability*, 11(23), 6829. <https://doi.org/10.3390/su11236829>

Hobart, M., Pflanz, M., Weltzien, C., & Schirrmann, M. (2020). Growth Height Determination of Tree Walls for Precise Monitoring in Apple Fruit Production Using UAV Photogrammetry. *Remote Sensing*, 12(10), 1656.. <https://doi.org/10.3390/rs12101656>

Jiménez-Brenes, F. M., López-Granados, F., Torres-Sánchez, J., Peña, J. M., Ramírez, P., Castillejo-González, I. L., & de Castro, A. I. (2019). Automatic UAV-based detection of *Cynodon dactylon* for site-specific vineyard management. *PloS one*, 14(6), e0218132.

Jorge, M. Vallbé & J. A. Soler (2019) Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images, *European Journal of Remote Sensing*, 52:1, 169-177, DOI: 10.1080/22797254.2019.1572459

Katsuhama, N., Imai, M., Naruse, N., & Takahashi, Y. (2018). Discrimination of areas infected with coffee leaf rust using a vegetation index. *Remote Sensing Letters*, 9(12), 1186-1194. <https://doi.org/10.1080/2150704X.2018.1519269>

Kaufman YJ, Remer LA. Detection of forests using mid-IR reflectance: an application for aerosol studies. *IEEE Trans Geosci Remote Sens*. 1994; 32: 672–683. <https://doi.org/10.1109/36.297984>

Kerkech, M., Hafiane, A., & Canals, R. (2018). Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and electronics in agriculture*, 155, 237-243. <https://doi.org/10.1016/j.compag.2018.10.006>

López-Granados, F., Torres-Sánchez, J., Jiménez-Brenes, F. M., Arquero, O., Lovera, M., & de Castro, A. I. (2019). An efficient RGB-UAV-based platform for field almond tree phenotyping: 3-D architecture and flowering traits. *Plant Methods*, 15(1), 1-16. <https://doi.org/10.1186/s13007-019-0547-0>

Louhaichi, M., Borman, M. M., & Johnson, D. E. (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, 16(1), 65-70.

Marin, D. B., de Carvalho Alves, M., Pozza, E. A., Belan, L. L., & de Oliveira Freitas, M. L. (2019). Multispectral radiometric monitoring of bacterial blight of coffee. *Precision Agriculture*, 20(5), 959-982. <https://doi.org/10.1007/s11119-018-09623-9>

Mengistu, A. D., Mengistu, S. G., & Alemayehu, D. M. (2016). Image Analysis for Ethiopian Coffee Plant Diseases Identification. *International Journal of Biometrics and Bioinformatics (IJBB)*, 10(1), 1.

Mesas-Carrascosa, F. J., Clavero Rumbao, I., Torres-Sánchez, J., García-Ferrer, A., Peña, J. M., & López Granados, F. (2017). Accurate ortho-mosaicked six-band multispectral UAV images as affected by mission planning for precision agriculture proposes. *International journal of remote sensing*, 38(8-10), 2161-2176.. <http://dx.doi.org/10.1080/01431161.2016.1249311>

Meyer GE, Hindman TW, Laksmi K. Machine vision detection parameters for plant species identification. *SPIE Proceedings*, 1999. pp. 327–335. <https://doi.org/10.1117/12.336896>

Oliveira A.J., Assis G.A., Guizilini V., Faria E.R., Souza J.R. (2019) Segmenting and Detecting Nematode in Coffee Crops Using Aerial Images. In: *Tzovaras D., Giakoumis D., Vincze M., Argyros A. (eds) Computer Vision Systems. ICVS 2019. Lecture Notes in Computer Science*, vol 11754. Springer, Cham. https://doi.org/10.1007/978-3-030-34995-0_25

Oliveira, H. C., Guizilini, V. C., Nunes, I. P., & Souza, J. R. (2018). Failure Detection in Row Crops From UAV Images Using Morphological Operators. *IEEE Geoscience and Remote Sensing Letters*.

Panagiotidis, D., Abdollahnejad, A., Surovy, P., & Chiteculo, V. (2017). Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing*, 38(8–10), 2392–2410. <https://doi.org/10.1080/01431161.2016.1264028>

Pena-Barragan JM, Ngugi MK, Plant RE, Six J. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sens Environ*. 2011; 115: 1301–1316. <https://doi.org/10.1016/j.rse.2011.01.009>

Rezende, F. C., Caldas, A. L. D., Scalco, M. S., & Faria, M. A. D. (2014). Leaf area index, plant density and water management of coffee. *Coffee Science*, v. 9, n.3, p.374-384.

Richardson, M. D.; Karcher, D. E.; Purcell, L. C. Quantifying turfgrass cover using digital image analysis. *Crop Science*, v. 41, n. 6, p. 1884-1888, 2001.

Saberioon, M. M., Amin, M. S. M., Anuar, A. R., Gholizadeh, A., Wayayok, A., and Khairunniza-Bejo, S. (2014). Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale. *Int. J. Appl. Earth Obs. Geoinf*. 32, 35–45. doi: 10.1016/J.JAG.2014.03.018

Santos, L. M., Ferraz, G. A. E. S., Barbosa, B. D. D. S., Diotto, A. V., Maciel, D. T., & Xavier, L. A. G. (2020). Biophysical parameters of coffee crop estimated by UAV RGB images. *Precision Agriculture*, 1-15. <https://doi.org/10.1007/s11119-020-09716-4>

Silva, V. A., de Rezende, J. C., de Carvalho, A. M., Carvalho, G. R., Rezende, T. T., & Ferreira, A. D. (2016). Recovery of coffee cultivars under the ‘skeleton cut’ pruning after 4.5 years of age. *Coffee Science*, 11(1), 55-64.

Surovy, P., Almeida Ribeiro, N., & Panagiotidis, D. (2018). Estimation of positions and heights from UAVsensed imagery in tree plantations in agrosilvopastoral systems. *International Journal of Remote Sensing*, 39(14), 4786–4800. <https://doi.org/10.1080/01431161.2018.1434329>

Torres-Sanchez, J., de Castro, A. I., Pena, J. M., Jimenez-Brenes, F. M., Arquero, O., Lovera, M., & Lopez-Granados, F. (2018). Mapping the 3D structure of almond trees using UAV acquired photogrammetric point clouds and object-based image analysis. *Biosystems engineering*, 176, 172-184. <https://doi.org/10.1016/j.biosystemseng.2018.10.018>

Torres-Sanchez, J., Lopez-Granados, F., & Pena, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114, 43-52. <https://doi.org/10.1016/j.compag.2015.03.019>

Torres-Sanchez, J., Lopez-Granados, F., De Castro, A. I., & Pena-Barragan, J. M. (2013). Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. *PloS one*, 8(3), e58210. <https://doi.org/10.1371/journal.pone.0058210>

Torres-Sanchez, J., Pena, J. M., de Castro, A. I., & Lopez-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104-113. doi: <http://dx.doi.org/10.1016/j.compag.2014.02.009>

Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269.

Xiang, H., & Tian, L. (2011). Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. *Biosystems Engineering*, 108(2), 104-113. <https://doi.org/10.1016/j.biosystemseng.2010.11.003>

Yue, J., Lei, T., Li, C., & Zhu, J. (2012). The application of unmanned aerial vehicle remote sensing in quickly monitoring crop pests. *Intelligent Automation & Soft Computing*, 18(8), 1043-1052.

Zhang, J., Virk, S., Porter, W., Kenworthy, K., Sullivan, D., & Schwartz, B. (2019). Applications of unmanned aerial vehicle based imagery in turfgrass field trials. *Frontiers in Plant Science*, 10, 279. <https://doi.org/10.3389/fpls.2019.00279>

Zhang, M., Zhou, J., Sudduth, K. A., & Kitchen, N. R. (2020). Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. *Biosystems Engineering*, 189, 24-35. <https://doi.org/10.1016/j.biosystemseng.2019.11.001>

Zheng, G., & Moskal, L. M. (2009). Retrieving leaf area index (LAI) using remote sensing: theories, methods and sensors. *Sensors*, 9(4), 2719-274

Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., ... & Tian, Y. C. (2017). Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>.

**ARTIGO 2 - COFFEE CROP YIELD PREDICTION BY UAV RGB
IMAGES AND REGRESSION ALGORITHMS**

Artigo elaborado de acordo com as normas da revista *Computers and Electronics
in Agriculture*, fator de impacto 3,85. ISSN: 0168-1699.

Coffee Crop yield prediction by UAV RGB images and regression algorithms

Brenon Diennevan Souza Barbosa¹; Gabriel Araújo e Silva Ferraz¹; Lucas Costa²; Vinay Vijayakumar²; Yiannis Ampatzidis²; Luana Mendes dos Santos¹

¹ Agricultural Engineering Department, Federal University of Lavras.

² Agricultural and Biological Engineering Department, Southwest Florida Research and Education Center, University of Florida

Abstract

Precision agricultural techniques such as the use of data from Unmanned Aerial Vehicles (UAVs) combined with machine learning algorithms have a great potential for yield estimation. Tree height, crown diameter, and RGB band reflectance values were collected from the UAVs for 144 trees, between June 2017 and May 2018, in the Minas Gerais region of Brazil. The tree height and diameter data were used to determine the Leaf Area Index (LAI) and all these six parameters - the LAI, tree height, crown diameter, and the individual RGB band values - were evaluated using multiple regression algorithms to generate a feature ranking of these parameters for the twelve month period. Based on the feature rankings, the LAI and the crown diameter were determined as the most important parameters and were used to generate yield prediction models through four different regression algorithms - Linear Support Vector Machines (SVM), Gradient Boosting Regression (GBR), Random Forest Regression (RFR), and Partial Least Square Regression (PLSR) - and a genetic algorithm - NEAT (Neuroevolution of augmenting topologies). The Mean Absolute Percentage Error (MAPE) was used as the criteria to evaluate the yield prediction models for a dataset of all months as well as a selected combination of the most important months. The best result (an MAPE of 31.75% for NEAT) was obtained for a reduced dataset containing only the most important features and the most important months, both of which were identified using feature ranking. The model results suggest that a dataset of the most important month could be used for the yield prediction model, thus reducing the need for extensive data collection for all the twelve months.

Keywords: Deep-learning, UAV imagery, Yield Prediction

1. Introduction

Brazil is responsible for one third of the world's coffee production, surpassing other countries in the production of this fruit such as Colombia and Vietnam. The production for the year 2020 is estimated between 57 and 62 million bags of coffee. These estimates are based on an increase in the productive area of about 4% (1,885 million ha) compared to the 2019 harvest. Only the state of Minas Gerais has an estimated production of 30 to

32 million bags (approximately 50% of the national production). This increase in relation to the 2019 harvest is related to the negative biennially, and in this period the producers take the opportunity to make treatments in the crops, thus reducing the productive area (CONAB, 2020).

The increase in the productivity of crops today can be achieved with the help of new techniques and technologies, among them is precision agriculture. It stands out for subsidizing the agricultural manager with accurate information so that decisions can be made to optimize resources, especially in the current scenario of difficult territorial expansion, high cost of inputs, treatments, and preservation of the environment (Das et al. 2018). Not different for coffee, the application of precision agriculture shows potential, as can be seen in Araújo e Silva Ferraz et al. (2012), where these authors, through geostatistical techniques, characterized the spatial distribution of the fruit's detachment force, generating maps of selective harvesting of fruits at the appropriate place and time.

The constant evolution of technology in the agricultural environment and the availability of remote sensing data have reinforced the popularization of Unmanned Aerial Vehicles (UAVs) due to the ease of operation, efficiency in obtaining high spatial and temporal resolution images (Holman et al., 2016). According to Gago et al., (2015) and Berni et al. (2009), UAVs can be accessible to any farmers due to new technologies associated with the use of this equipment, and also due to the reduction in acquisition cost. When precision agriculture is applied in coffee farming, some studies such as Santos et al. (2020) show the potential of this technology to generate information that supports decision making for precise management in the most adequate time and dimension of the crop, such as obtaining biophysical characteristics of the plant (height and diameter) that are fast and non-destructive.

In the context of agricultural monitoring, the use of machine learning algorithms, neural networks are in constant use, mainly associated with precision agriculture application techniques. Ampatzidis et al. (2019) and Ampartzidis et al. (2020) have shown promising and low-cost solutions where it is possible to identify plants and evaluate plant health using image processing techniques from UAVs.

Mathematical models for predicting the behavior and productivity of the crop as a function of measurable variables that interfere in the development are a great longing of the agricultural market, in which one can highlight the search for predictability of yield. Such studies are currently widely used in large producers, banks, financial institutions,

investors, and clients to predict the risk of financial loans, crop estimates, and future markets. Several studies to estimate productivity in other crops such as onion (Ballesteros et al. 2018), beet (Olson et al. 2019) soy (Maimaitijiang et al. 2020), corn (Maresma et al. 2018; Maresma et al. 2020), forage crops (Feng et al. 2020), are being developed, mainly with the use of aerial images from UAVs.

For coffee, studies using remote sensing and orbital image processing techniques carried out in Brazil such as monitoring diseases in coffee plants (Barbedo et al., 2016a; Barbedo et al., 2016b; Mengistu et al., 2016; Katsuhama et al. , 2018; Chemura et al., 2018), water stress assessment (Chemura et al., 2018), detection of planting failures (Oliveira et al., 2018), estimated volume of harvested fruits (Carrijo et al., 2017), plant volume estimation (da Cunha et al., 2019) and nematode detection (Oliveira et al., 2018) are some examples. Using low-cost UAVs, Santos et al. (2020) shows the potential of this tool to generate information to support decision making for precise management in the most adequate time and dimension of the crop, such as obtaining biophysical parameters of the plant (height and diameter) that are fast and non-destructive.

Some studies, such as de Carvalho et al. (2020), show techniques for estimating productivity through genomic selection to reduce the effect of bienniality in coffee field. De Oliveira Aparecido et al. (2018) used climatic data to create a forecast model for coffee production in the Minas Gerais region, finding results considered satisfactory for up to 5 months before harvest, and are examples of the potential of the tools. However, studies that explore the potential of UAV to predict the yield of a coffee crop are scarce in the specialized literature.

This study aims to estimating coffee productivity by using data from aerial images obtained by remotely piloted aircraft (UAV). Tree height and diameter data were collected using drones and compared with the manual measurements of the same variables collected in the crop field. The measure of agreement of the UAV data, with respect to the manual data, is estimated to understand the level of reliability of the UAV data. Then, the UAV data was used along with LAI and the actual yield value to generate a model that can predict yield with an acceptable error limit.

2. Materials and Methods

2.1 Experimental Design

An UAV with an RGB camera and a GPS sensor was used to collect the coffee trees' images. The images were then processed and stitched to create an orthomosaic image. The manual measurements of tree height and crown diameter were taken on 144 trees and the Leaf Area Index (LAI) was determined using these values, while the Canopy Height Model (CHM) was determined from the orthomosaic using the Digital Height Model (DHM) and the Digital Terrain Model (DTM) information. Data was collected monthly between June 2017 and May 2018.

The UAV measurements were compared to the manual data to evaluate if UAVs are a reliable substitute to manual labor for collecting tree data from the field. Classical statistical techniques were used to analyse the dataset for creating a prediction model. A feature selection process was used to rank all parameters (measurements) of the dataset. This ranking shows the effect of a specific parameter of a given month on the final yield prediction. The feature rankings provided the most important parameters and the months when they were most significant for the yield prediction model. Multiple regression algorithms are tested to generate a model for yield prediction. Fig. 1 presents the workflow of this study.

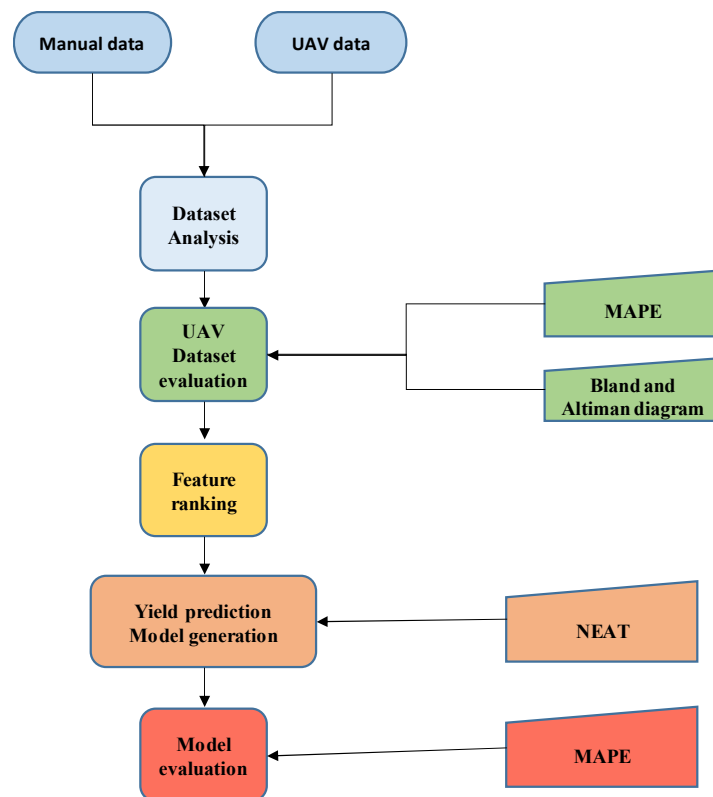


Fig. 1. Workflow of the study

2.2 Study Site

The study area is located on the Federal University of Lavras (23K 502906. 23m E, 7652838.84m S, 936 m altitude), in the state of Minas Gerais, Brazil. The species *Coffea arabica* L., cultivar MG Travessia, was implanted in the area in February 2009 with planting spacing equal to 2.60 x 0.60 m (Fig. 2). The crop underwent pruning (skeleton) in July 2016. Productivity recovery is expected within an average time of two years after pruning (Silva et al. 2016). The climate of the region, according to the Köppen classification, is of the ‘Cwa’ type, characterized by a dry season in winter and a rainy season in summer (Barbosa Junior et al., 2017).

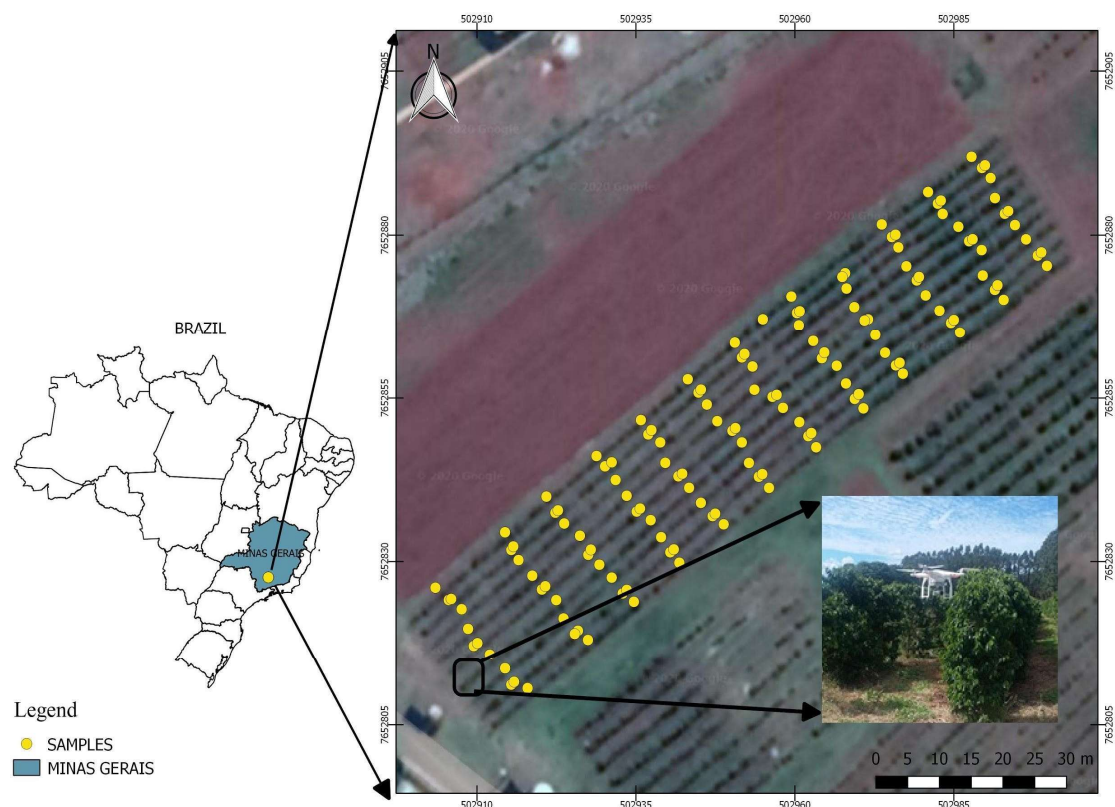


Fig. 2. Study site location with marked sampled trees.

2.3 UAV and camera

Image collection was performed using UAV model DJI Phantom 3 professional (DJI, Shenzhen, China). The UAV was equipped with a digital RGB camera (Red-R, Green-G, Blue-B), Sony brand, model EXMOR 1 / 2.3 ", with a resolution of 4000 x 3000

pixels, a sensor size 6.16 x 6.62 mm, 94 ° FOV, and a sample rate of 0.5 frames per second (Zhang et al., 2020) equipped with an internal GPS receiver. The UAV control system included a remote controller and a ground control station connected to a smartphone device in which an application for flight planning and control was installed. This application collected information and photo parameters from the UAV during the mission that was later used by image processing software for generating the orthomosaic (Torres-Sánchez et al., 2018; Zhang et al., 2020).

In this study, the Drone Deploy application (DroneDeploy, San Francisco, CA, USA) was used in all missions. The parameters used for flight planning were: altitude of 30m, speed of 3m/s, frontal and lateral overlap of 80% between images. The overlap and flight speed were selected based on the study by Torres-Sánchez et al. (2015) where overlap was determined as a factor that interfered with the precision and quality of the final product. The flight parameters entered in application were programmed to be constant throughout the flight time. The images were georeferenced using the coordinates obtained by the UAV GPS at each waypoint (Zhang et al., 2020). The return period for image collection was 30 days. The time of capture of the images was defined between 11:00 to 14:00 hours. Two people were involved in all the missions: the pilot who was responsible for taking off and landing the UAV, and the observer, whose function was to alert the pilot about potential obstacles during the flight period.

2.4 *Image Processing*

The images collected by the RGB camera were processed using Photoscan Professional software version 1.2.4 (Agisoft LLC, St. Petersburg, Russia). The geomatic products were obtained according to the methodology described by Jiménez-Brenes et al. (2019) which involved i) generation of a three-dimensional (3D) point cloud to apply the SfM (Structure-from-Motion) technique; ii) generation of the Digital Terrain Model (DTM) and Digital Surface Model (DSM) from the 3D point cloud, using a maximum angle of 15 ° and a maximum distance of 0.1m as parameters for a cell size of 40 m; iii) creation of the orthomosaic of the area. ‘High’ quality and ‘moderate’ depth filtering were used as parameters in the software for calculating image position, orientation, correlation with neighboring images, and overlap. This ensured that the dense points cloud had greater accuracy and outliers were removed (Hobart et al. 2020).

For georeferencing of the images, six control points were fixed, with four at the ends and two in the central portion of the study area. The coordinates of the Ground Control Points (GCP's) were obtained by a signal receiver that received signals from a global positioning differential system (DGPS; Trimble Navigation Limited, Sunnyvale, California, USA) with a horizontal and vertical accuracy of 0.007 m. These GCP's were manually identified in the images before the mosaic was made.

After the geometric correction of the images, the average spatial resolution of the orthomosaic in the evaluation period was 1.3 cm. The generated MDT, DSM, and orthomosaics were exported in Geotiff format to the geoprocessing software Quantum Gis v. 2.16.3 (QGIS Development Team, Open Source Geospatial Foundation) in a GeoTiff file, in the Universal Transversal Mercator (UTM) projection, in the SIRGAS 2000 / UTM 23S zone

2.5 Data Collection

A total of 144 plants were selected for this study according to the methodology described by Ferraz et al. (2017). They were georeferenced using the same equipment described for the GCP's georeferencing. The plant height and crown diameter data were collected using a measuring tape. The diameter of the tree was measured in the middle third of each plant.

The Leaf Area Index (LAI) was estimated based on the methodology described by Favarin et al. (2002), as it is a fast, non-destructible methodology that can be used with crown diameter (D) and plant height (H) (Eq. 1).

$$LAI = 0.0134 + 0.7276 \times D^2 \times H \quad (1)$$

The estimation of plant height from UAV images was performed following the workflow described by Panagiotidis et al. (2016) and Surovy et al. (2018) (Eq. 2), where plant height is estimated by the difference between DSM and DTM. The crown diameter (D) was estimated in the orthomosaic itself generated in the QGIS software at all sample points. The height values were extracted with the help of the QGIS Point Sampling Tool.

$$H = DSM - DTM \quad (2)$$

2.6 Dataset analysis

Classical statistical techniques such as mean, minimum, maximum, standard deviation, skewness and coefficient of variation were calculated for the yield dataset. Skewness is a measure of the symmetry of the data around its mean, where zero corresponds to a symmetric distribution. Negative skewness indicates that the data is skewed left (with the mean value less than the median) and positive skewness represents a distribution that is clustered on higher values and is skewed right (with the mean value greater than the median). The coefficient of variation is a measurement of the variance around the mean value.

2.7 *Feature selection*

Feature selection is a data preprocessing strategy proved to be effective and efficient in preparing datasets for multiple machine learning problems. The objectives of feature selection include building simpler and more comprehensible models, improving data-mining performance, and preparing clean, understandable data. (Li et al., 2017). Feature selection works by removing irrelevant and redundant data in a dataset.

Feature selection algorithms work by giving weights and ranking the best features (measurement) from a dataset that generate an output (prediction) of the target (yield). With these weights it is possible to determine what features to keep for the model and what to ignore. In this study we have monthly data collected for coffee, and the feature selection algorithm provides the best months and data for this process. To perform the feature selection either one or multiple algorithms can be used. In this study we use multiple algorithms that rank each feature and evaluate the resulting final ranking.

The Pearson correlation coefficient (Schober et al., 2018) is a statistical measurement of the linear correlation between two variables. In this instance, for all features of the model the coefficient is calculated and used to rank their importance in a prediction. The Spearman's rank correlation coefficient (de Winter et al., 2016) is a nonparametric measurement of statistical dependence between the rankings of two variables. It assesses the relationship between two variables using a monotonic function. The Spearman correlation between two variables is equal to the Pearson correlation between the rank values of those two variables; while Pearson's correlation assesses linear relationships, Spearman's correlation assesses monotonic relationships (whether linear or not).

The F-test is a scoring function used in feature selection procedures. This is done in two steps: i) the correlation between each feature and the target is computed as Eq. 3, where X_i is feature i , Y is the target and std is the standard deviation; ii) The correlations are converted to an F score value and ranked.

$$\text{Correlation} = (X_i - \text{mean}(X_i)) * (Y - \text{mean}(Y)) / (\text{std}(X_i) * \text{std}(Y)) \quad (3)$$

The Mutual Information (MI) is a powerful method for detecting relationships between data sets.. It estimates mutual information for a continuous target variable. MI between two random variables is equal to zero if and only if two random variables are independent, and higher values mean higher dependency. The function relies on nonparametric methods based on entropy estimation from k-nearest neighbors distances as described in Kraskov et al., 2004 and Ross, 2014. Mutual information methods can capture any kind of statistical dependency.

Recursive feature elimination with cross-validation (RFECV) is a recursive function based on elimination of features to rank their importance to an estimator (regression). It works by eliminating a feature from the dataset, running a regression algorithm and evaluating the impact on the estimation. This effect is used to rank the importance of each feature. In this instance the following regression algorithms are used: Support Vector Machine (Chang and Lin, 2011), Gradient Boosting Regression Trees (Friedman, 2002) and Random Forest Regressor (Breiman, 2001).

2.8 Regression Model

For this study multiple regression algorithms such as Linear SVM, PLSR, Random Forest, and Gradient Boosting regression were evaluated on their ability to generate a model in such small datasets. Linear Support Vector Machine (SVM) algorithm segregates classes using a line or a hyper-plane and classifies them by maximizing the distance between the nearest data points (margins) that are separated by the line or hyper plane. A higher margin usually points to a higher confidence in classification (Bzdok et al., 2018).

Random Forest regression method is an ensemble based learning method, where multiple weak base models are combined to generate an optimal ensemble model. Random Forest regression runs efficiently on large datasets, is robust to outliers and is less sensitive to overfitting (Zhou et al., 2017).

A Gradient Boosting regression tree is also an ensemble-based method where base models are generated sequentially and difficult training cases are emphasized more, to improve the prediction accuracy.

Partial Least Squares (PLS) regression model links a dependent variable to a set of independent variables and can be used to derive a sound and robust model from a large dataset (Costa et al., 2014).

A genetic algorithm called NEAT (NeuroEvolution of Augmenting Topologies) was implemented on the dataset. NEAT is an approach to Artificial Intelligence which uses both topology and weight parameters to evolve the artificial neural network (Ibrahim et al., 2019). NEAT was used to adjust the weight and topology of the Artificial Neural Network (ANN) which generates the yield prediction model based on the UAV data.

The parameters used in the SVM, Random Forest, and Gradient Boosting regression algorithms are described in Table 1, the others were used the standard parameters.

Table 1. Regression model parameters

Regression Model	Parameters
SVM	Kernel = 'linear' other parameters = 'default'
Gradient Boosting	n_estimators': 500, 'max_depth': 4 'min_samples_split': 2, 'learning_rate': 0.01, 'loss': 'ls' other parameters = 'default'
Random Forest Regressor	n_estimators = 100 random_state = 42 other parameters = 'default'

2.9 Evaluation Metrics

The following evaluation metrics were used in this study: i) Mean Absolute Percentage Error (MAPE) and ii) Measure of Agreement

2.9.1 Mean Absolute Percentage Error (MAPE)

The mean absolute percentage error is a commonly used statistical tool. It is a measure of the accuracy of a forecast system. The MAPE (Eq. 4) is given by the average

of the ratio of the absolute difference between the ground truth (Gt) and the prediction (P) to the ground truth. The formula for the MAPE is given below.

$$MAPE = \frac{1}{n} \sum \left| \frac{Gt - P}{Gt} \right| \quad (4)$$

Where:

n = number of individual items

Gt = ground truth; P = Prediction.

2.10 Measure of Agreement

The agreement between measurements refers to the degree of agreement between two or more sets of measurements of a dataset by the same individual or by two different individuals using similar methodologies. In this study, the Bland and Altman diagram was used as a measure of agreement instead of the Pearson correlation coefficient which is often inappropriately used as a measure for agreement (Watson and Petrie, 2010). The Bland and Altman diagram (Bland and Altman, 1999) is a display of the pattern and agreement of one variable being measured by two different methodologies (Watson and Petrie, 2010). The diagram plots the difference between a measurement pair (in our case, the difference between the UAV and manual measurement) on the vertical axis and the mean of the pair on the horizontal axis. To determine the repeatability of the proposed approach, the method assumes a normal distribution of differences, where 95% of them are expected to lie between $d \pm 1.96s$, where d is the mean of observed differences and s is the standard deviation. This can be used as a range of error in application, where the top and bottom ranges define the limits which to expect the measurement error to be included.

3. Results

3.1 Dataset analysis

The yield dataset is analyzed for mean, minimum-maximum, standard deviation, skewness and coefficient of variance (CV). Table 2 presents this analysis. The CV of 51.70% shows a good variation for the dataset.

Table 2. Dataset analysis of the yield data.

Statistic	Value
Mean	3.23
Min-Max	0.5-8
Std. deviation	1.67
Skewness	0.62
CV	51.70%

This variability in productivity may be associated with reduction of the productive area in 2016, affecting grain production within two years after this interference in the plants (Silva et al. 2006). The range between maximum and minimum values found can be explained by the fact that when the experiment was conducted, some plants located at the south end of the area, did not show a recovery in their vegetative area unlike the other plants in the northern region of the field.

3.2 UAV measurement evaluation

The pairs of observations between values measured with the UAV (height and diameter of the tree) and manual measurements were compared with the twelve months data. The relative error of the data with respect to each other was measured using minimum and maximum error, standard deviation, and MAPE (Mean Absolute Percentage Error) (Table 3). The following table shows the evaluation of UAV measurements compared to the manual measurements.

Table 3. Dataset analysis of the UAV data vs the manual data

Parameter	Max error	MAPE
Tree height	63.42 %	5.88 %
Tree diameter	72.61 %	6.83 %

The maximum error for tree height was 63.42% and for tree diameter was 72.61%. Large errors such as these can happen either during the stitching process of the maps due to a lack of key points while creating an orthomosaic, or due to errors in the 3D point cloud generation. The MAPE was under 6% and 7% for the tree height and diameter,

respectively. This means that the maximum error for both height and diameter could be safely considered as mere outliers and not the norm.

Fig. 3 presents the comparison by month of the average values of height (Fig. 3A) and diameter (Fig. 3B) between UAV and manual measurements. For tree diameter, the maximum variation in measurement is seen in September (4.86%), October (4.27%) and April (6.42%) while every other month has less than 4% variation in the average values, with August showing the least variation in measurement (0.18%). For the tree height measurement, most variation is seen in July-October, with the maximum in October (9.05%). All other months have less than a 5% variation in the measurement. Comparing the plots for the tree height and diameter, we can see that there is more variation in the measurement of tree height (average variation of 4.21%) as opposed to tree diameter (average variation of 3.20%).

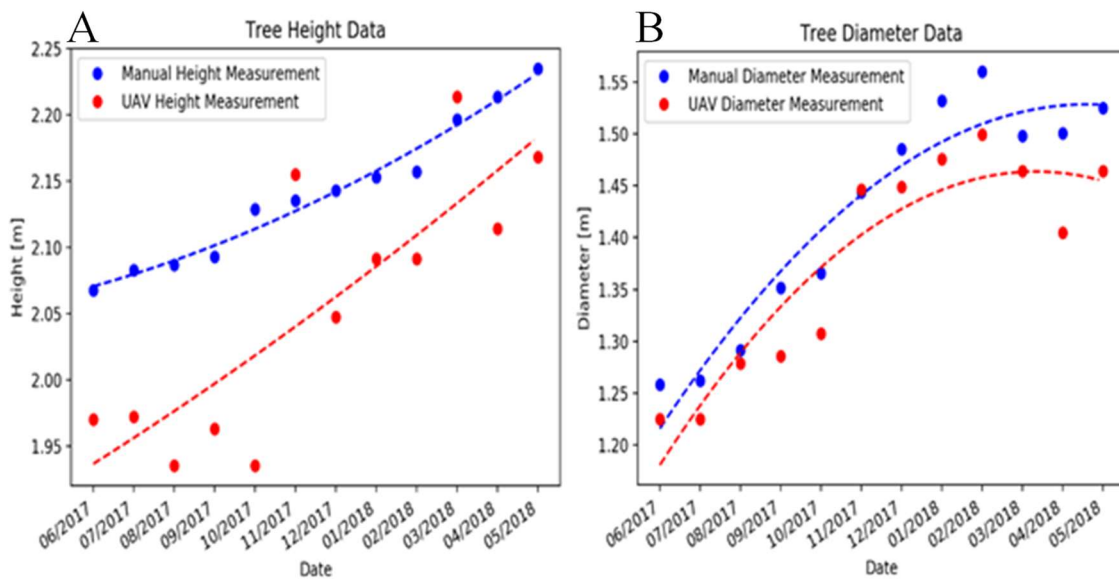


Fig. 3. Comparison of the average UAV and manual measurements for tree diameter and tree height for 12 months.

Using the Bland and Altman diagram, the measure of agreement between the UAV and manual height and diameter values were determined. The difference of the values obtained through UAV and manual data is plotted on the Y-axis, while the mean of the data is plotted on the X-axis. The upper dashed line represents the upper limit of agreement given by $d + 1.96s$ and the lower dashed line represents the lower limit of agreement given by $d - 1.96s$, where d is the mean of observed differences and s is the standard deviation. The solid black line through the center represents d .

Fig. 4 presents the diagram for the tree diameter measurements. This shows an error of operation of +0.3 to -0.21 meters. Since the manual measurements can be considered perfect measurements, this is essentially the error expected from the UAV on this measurement.




Fig. 4. Bland and Altman plot for tree diameter measurements.

Fig. 5 presents the Bland and Altman diagram for the tree height measurements. It shows an upper limit of error of +0.34 and a bottom limit of -0.17 meters.

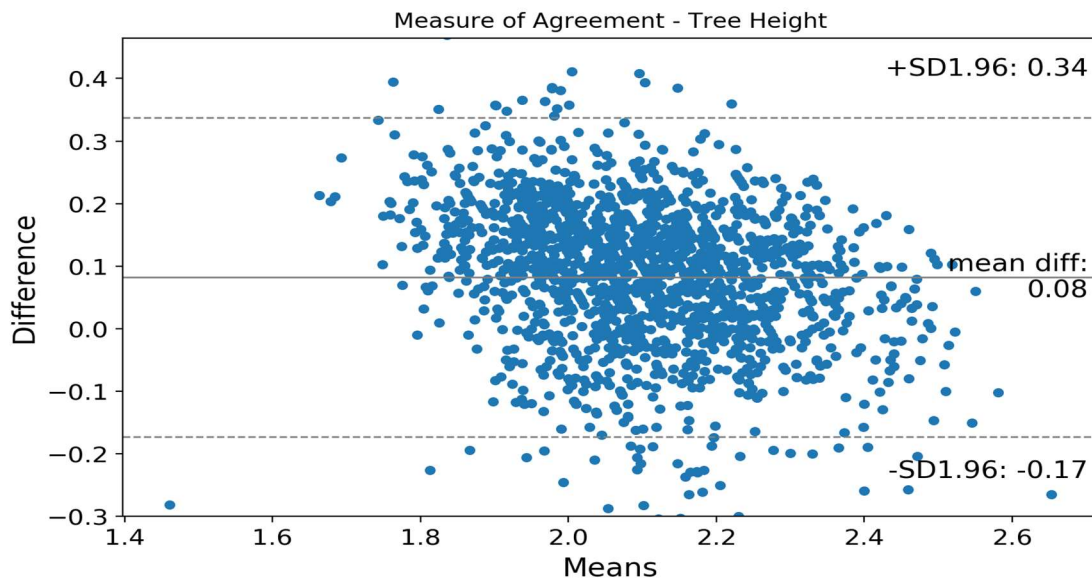


Fig. 5. Bland and Altman plot for tree height.

Field measurements can have similar errors for height and diameter. For height is associated with measuring tape inclination factors in relation to the soil and vertical axis

of the plant. For the diameter, this factor may also be associated due to the topology (branches and leaves) of the plant, that did not allow in some sample points the ideal parallelism for this measurement.

Considering the ranges of operation, it is assumed that the UAV measurements are reliable enough for the task of measuring tree height and diameter. Assuming that the UAV measurement is reliable, we can substitute a slow and laborious manual task with a fast and precise tool.

3.3 *Feature Selection and Ranking*

The feature rankings were determined for the Leaf Area Index (LAI), crown diameter, tree height, and the individual bands of the RGB data. This was done for all the months under consideration. Seven different algorithms - Pearson, Spearman, F-test, Mutual Info, SVM, Gradient Boosting, and Random Forest - were used as tools to determine the rankings and then the cumulative effect was calculated to determine the final rankings.


The final rankings show the effect of a specific parameter of a given month on the final yield prediction. The higher the ranking of a component, the higher is its effect on the yield prediction model. Table 3 shows the top 10 components ranked on the basis of their performance when tested using the seven algorithms.

The most significant parameters in terms of the effect on yield prediction are the LAI and the diameter. The LAI of two months - december and april - had the most effect on the yield prediction model. The tree height shows up once in the top 10 rankings (table 4), with the effect of the month of July more prominent than the other months, but LAI is the most dominant feature considering 70% of the top 10 is made up of LAI. The diameter of the tree during the months of December and April are also a part of the top 10 features, making the months of December and April highly important months in terms of the yield prediction contribution. The rankings of the RGB bands were also calculated in these rankings and it was observed that because of their low rankings (they occupied the lower half of the rankings table), their significance in the yield prediction model was very little.

Table 4. Top 10 features to estimate yield in coffee.

Components	Final rank	Pearson	Spearman	F-test	Mutual Info	SVM	Gradient Boosting	Random Forest
LAI (12/2017)	1	1	1	1	7	1	1	1
LAI (04/2018)	2	2	2	2	3	10	1	1
Dia (12/2017)	3	3	3	3	8	11	1	1
Dia (04/2018)	4	8	6	8	10	13	1	1
Hei (07/2017)	5	16	18	16	4	1	1	1
LAI (01/2018)	6	4	5	4	1	31	1	1
LAI (05/2018)	7	5	4	5	6	20	1	1
LAI (10/2017)	8	7	8	7	13	25	3	2
LAI (03/2018)	9	6	7	6	5	19	6	1
LAI (11/2017)	10	9	14	9	22	22	1	1

With the ranking values we can generate weights for each feature as the inverse of the sum of the rankings. Fig. 6 presents a graph of these weights by month. The rankings of RGB are summed together. The graph shows that the most prominent months for this dataset are December 2017 and April 2018.

**Fig. 6.** Bland and Altman plot for tree height.

3.4. Models

After the feature selection step, the chosen regressors are used to predict the yield. We evaluate the use of the whole dataset and the features from the most important months based on the feature ranking. The models are evaluated in a 5-Fold cross validation setting, we present the overall MAPE. Table 5 presents the MAPE for the models using different feature selections.

Table 5. The models MAPE for yield prediction based on different feature selections.

Algorithm*	MAPE				
	All months	Top 4 months	Top 3 months	Top 2 months	Top 1 month
GBR	36.79%	37.83%	36.99%	35.71%	37.39%
Linear SVM	47.68%	37.76%	35.79%	35.05%	32.99%
RFR	36.13%	37.83%	35.05%	34.07%	37.13%
PLSR	34.80%	35.84%	36.63%	35.92%	33.48%
NEAT	100.00%	56.86%	31.91%	32.18%	31.75%

* GBR: Gradient Boosting Regression, Linear SVM: Linear Support Vector Machine, RFR: Random Forest Regression, PLSR: Partial Least Square Regression

The table shows that the GBR, RFR and PLSR models have similar results using different numbers of features that can be explained by these algorithms' ability to work with high-dimensionality data and small datasets. The Linear SVM and NEAT shows that reducing the number of features can improve the prediction. The NEAT algorithm, being a convergent genetic algorithm, did not converge in the full dataset. It only started converging correctly from the top 3 months data. The small differences in the MAPE between the top 3, top 2 and top 1 months can be explained by the graph of Feature Contribution by month (Fig. 7), where the top 1 month carries almost double the importance of the second most important month. This means that for this dataset, using data from 3 months of 1 month has small differences that can be neglected.

4. Discussion

The plant height and diameter, and the product of these two parameters, the LAI, can be estimated with confidence through image areas and image processing techniques.

When the combination of height and diameter of the coffee tree are modeled to estimate the LAI (Eq. 1), they obtained the first and second position in the ranking of features in the performance of the yield prediction model (Table 3). Results found in the

study by Chu et al. (2016) reinforce the potential of using biophysical parameters of cotton derived from RGB images coupled to UAV to predict yield. These authors find greater performance in the prediction model when a combination of height and canopy is made, followed by canopy coverage as the second highest correlation between estimated and observed yield in the field. The ranking of variables (Table 3 and Fig. 4) shows that LAI data is more promising for estimating coffee productivity by UAV imagery in December and April for height, diameter, and brightness values RGB. These results show that it is possible to reduce the monitoring time of the crop during the production year. According to Camargo & Camargo (2001) the explanation of these results are in the phenological cycle of Coffee arabica. These authors show that in the second phenological year (evaluation period of this study), the month of December marks the end of the third phase of this cycle, which is the flowering, and the beginning of the fruit granulation phase. For the month of April, the fifth and last phase of the cycle, it is where the fruit matures, which ends in June (harvest date). The results obtained by Aparecido and Rolim (2018) enhance those found in this study (Table 3), where the months of December (flowering) and April (fruit granation) are decisive times in coffee productivity

5. Conclusion

The proposed methodology to estimate coffee productivity using machine learning techniques on data obtained from aerial images based on UAVs was effective. The LAI, in particular, was the most dominant feature, contributing to 70% of the top 10 feature rankings.

The other important aspect of the feature rankings was the importance of two months - December 2017 and April 2018 to the yield prediction. This is an important result for future studies because it reduces the need for extensive year round data collection and allows researchers to focus on the dominant parameters of certain most important months. So, the results obtained in this study shows promise.

Funding

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brazil (CAPES) and Council for Scientific and Technological Development (CNPq).

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgments

The authors would like to thank the Federal University of Lavras and the Coffee Innovation Agency (InovaCafé) for providing a study area. To the Agricultural and Biological Engineering Department of the University of Florida for their support in data processing.

REFERENCES

- Abdi, H., 2010. Partial least squares regression and projection on latent structure regression (PLS Regression). *Wiley interdisciplinary reviews: computational statistics*, 2(1), pp.97-106.
- Ampatzidis, Y., Partel, V., Meyering, B., & Albrecht, U. (2019). Citrus rootstock evaluation utilizing UAV-based remote sensing and artificial intelligence. *Computers and Electronics in Agriculture*, 164, 104900. <https://doi.org/10.1016/j.compag.2019.104900>
- Aparecido, Lucas Eduardo de Oliveira, & Rolim, Glauco de Souza. (2018). Forecasting of the annual yield of Arabic coffee using water deficiency. *Pesquisa Agropecuária Brasileira*, 53(12), 1299-1310. <https://doi.org/10.1590/s0100-204x2018001200002>
- Araújo e Silva Ferraz, G., da Silva, F.M., de Carvalho Alves, M. Bueno, R. F., da Costa, P. A. N. (2012). Geostatistical analysis of fruit yield and detachment force in coffee. *Precision Agriculture*, 13, 76–89. <https://doi.org/10.1007/s11119-011-9223-8>
- Ballesteros, R., Ortega, J. F., Hernandez, D., & Moreno, M. A. (2018). Onion biomass monitoring using UAV-based RGB imaging. *Precision agriculture*, 19(5), 840-857. doi:10.1007/s11119-018-9560-y
- Barbedo, J. G. A. (2016a). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems engineering*, 144, 52-60. <https://doi.org/10.1016/j.biosystemseng.2016.01.017>
- Barbedo, J. G. A., Koenigkan, L. V., & Santos, T. T. (2016b). Identifying multiple plant diseases using digital image processing. *Biosystems Engineering*, 147, 104-116. doi:10.1016/j.biosystemseng.2016.03.012
- Barbosa, J., Pozza, E. A., de Souza, P. E., Oliveira e Silva, M. D. L., Pozza, A. A. A., & Guimarães, R. J. (2017). Irrigation drip and phosphorus managements in the rust coffee progress. *Coffee Science*, 12(2), 187-196. doi: [doi:10.25186/cs.v12i2.1214](https://doi.org/10.25186/cs.v12i2.1214)
- Breiman, L., 2001. Random forests. *Machine learning*, 45(1), pp.5-32. <https://doi.org/10.1023/A:1010933404324>

- Camargo, Â. P. D., & Camargo, M. B. P. D. (2001). Definition and schematization of the phenological phases of Arabica coffee in tropical conditions in Brazil. *Bragantia*, 60 (1), 65-68. <http://dx.doi.org/10.1590/S0006-87052001000100008>
- Carrizo, G. L., Oliveira, D. E., de Assis, G. A., Carneiro, M. G., Guizilini, V. C., & Souza, J. R. (2017). Automatic detection of fruits in coffee crops from aerial images. In *Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR), 2017 Latin American*, (pp. 1-6). IEEE. doi.org/10.1109/SBR-LARS-R.2017.8215283
- Carvalho, F. H., Galli, G., Ferrão, L.F. V., Nonato, J. V. A., Padilha, L., Maluf, M. P., Resende Júnior, M. F. R., Filho, O. G., Fritsche-Neto, R. (2020). The effect of bienniality on genomic prediction of yield in arabica coffee. *Euphytica*, 216, 101. <https://doi.org/10.1007/s10681-020-02641-7>
- Chang, C. C., & Lin, C. J. (2011). LIBSVM: A library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 1-27. <https://doi.org/10.1145/1961189.1961199>
- Chemura, A., Mutanga, O., Sibanda, M., & Chidoko, P. (2018). Machine learning prediction of coffee rust severity on leaves using spectroradiometer data. *Tropical Plant Pathology*, 43(2), 117-127. doi:10.1007/s40858-017-0187-8
- Chu, T., Chen, R., Landivar, J. A., Maeda, M. M., Yang, C., & Starek, M. J. (2016). Cotton growth modeling and assessment using unmanned aircraft system visual-band imagery. *Journal of Applied Remote Sensing*, 10(3), 036018. <https://doi.org/10.1117/1.JRS.10.036018>
- CONAB- Companhia Nacional de Abastecimento. Acompanhamento da Safra Brasileira de café: (2020). *Monitoramento agrícola (Monitoring of the Brazilian coffee crop: Agricultural monitoring)* 6– Safra 2020, (1) - First survey, Brasília.
- Cunha, J. P., Neto, S., Matheus, A., & Hurtado, S. (2019). Estimating vegetation volume of coffee crops using images from unmanned aerial vehicles. *Engenharia Agrícola*, 39(SPE), 41-47. doi.org/10.1590/1809-4430-eng.agric.v39nep41-47/2019
- Dandois JP, Ellis EC. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. *Remote Sens Environ*. 2013; 136: 259–276. <https://doi.org/10.1016/j.rse.2013.04.005>.
- de Oliveira Aparecido, L. E., de Souza Rolim, G., Camargo Lamparelli, R. A., de Souza, P. S., & dos Santos, E. R. (2017). Agrometeorological models for forecasting coffee yield. *Agronomy Journal*, 109(1), 249-258. doi.org/10.2134/agronj2016.03.0166
- de Winter, J. C., Gosling, S. D., & Potter, J. (2016). Comparing the Pearson and Spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data. *Psychological methods*, 21(3), 273. <https://doi.org/10.1037/met0000> <https://doi.org/10.1037/met0000079>
- dos Santos, L. M., Ferraz, G. A. E. S., Barbosa, B. D. D. S., Diotto, A. V., Maciel, D. T., & Xavier, L. A. G. (2020). Biophysical parameters of coffee crop estimated by UAV RGB images. *Precision Agriculture*, 1-15. <https://doi.org/10.1007/s11119-020-09716-4>
- Favarin, J. L., Dourado Neto, D., García y García, A., Villa Nova, N. A., & Favarin, M. D. G. G. V. (2002). Equations for estimating the coffee leaf area index. *Pesquisa Agropecuária Brasileira*. 37(6), 769-773. <https://doi.org/10.1590/S0100-204X2002000600005>
- Feng, L., Zhang, Z., Ma, Y., Du, Q., Williams, P., Drewry, J., & Luck, B. (2020). Alfalfa Yield Prediction Using UAV-Based Hyperspectral Imagery and Ensemble Learning. *Remote Sensing*, 12(12), 2020. doi.org/10.3390/rs12122028

- Ferraz, G. A., Silva, F. M. D., Oliveira, M. S. D., Custódio, A. A. P., & Ferraz, P. F. P. (2017). Spatial variability of plant attributes of a coffee crop. *Revista Ciência Agrônômica*, 48(1), 81-91. <http://dx.doi.org/10.5935/1806-6690.20170009>
- Friedman, J.H., 2002. Stochastic gradient boosting. *Computational statistics & data analysis*, 38(4), pp.367-378.
- Gómez-Candón, D., De Castro, A. I., & López Granados, F. (2014). Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. *Precision Agriculture*, 15, 44–56. <https://doi.org/10.1007/s11119-013-9335-4>.
- Hobart, M., Pflanz, M., Weltzien, C., & Schirrmann, M. (2020). Growth Height Determination of Tree Walls for Precise Monitoring in Apple Fruit Production Using UAV Photogrammetry. *Remote Sensing*, 12(10), 1656. <https://doi.org/10.3390/rs12101656>
- Holman, F. H., Riche, A. B., Michalski, A., Castle, M., Wooster, M. J., & Hawkesford, M. J. (2016). High throughput field phenotyping of wheat plant height and growth rate in field plot trials using UAV based remote sensing. *Remote Sensing*, 8(12), 1031.
- Jing, Z., Virk, S., Porter, W., Kenworthy, K., Sullivan, D., & Schwartz, B. (2019). Applications of unmanned aerial vehicle based imagery in turfgrass field trials. *Frontiers in Plant Science*, 10, 279. <https://doi.org/10.3389/fpls.2019.00279>
- Katsuhama, N., Imai, M., Naruse, N., & Takahashi, Y. (2018). Discrimination of areas infected with coffee leaf rust using a vegetation index. *Remote Sensing Letters*, 9(12), 1186-1194. doi.org/10.1080/2150704X.2018.1519269
- Kraskov, A., Stögbauer, H., & Grassberger, P. (2004). Estimating mutual information. *Physical review E*, 69(6), 066138. <https://doi.org/10.1103/PhysRevE.69.066138>
- Li, J., Cheng, K., Wang, S., Morstatter, F., Trevino, R. P., Tang, J., & Liu, H. (2017). Feature selection: A data perspective. *ACM Computing Surveys (CSUR)*, 50(6), 1-45. <https://doi.org/10.1145/3136625>
- López-Granados, F., Torres-Sánchez, J., Jiménez-Brenes, F. M., Arquero, O., Lovera, M., & de Castro, A. I. (2019). An efficient RGB-UAV-based platform for field almond tree phenotyping: 3-D architecture and flowering traits. *Plant Methods*, 15(1), 1-16. <https://doi.org/10.1186/s13007-019-0547-0>
- Maes, W. H., & Steppe, K. (2019). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in plant science*, 24(2), 152-164. <https://doi.org/10.1016/j.tplants.2018.11.007>
- Maes, W. H., & Steppe, K. (2019). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in plant science*, 24(2), 152-164.
- Maimaitijiang, M., Sagan, V., Sidike, P., Hartling, S., Esposito, F., & Fritschi, F. B. (2020). Soybean yield prediction from UAV using multimodal data fusion and deep learning. *Remote Sensing of Environment*, 237, p. 111599. doi.org/10.1016/j.rse.2019.111599
- Maresma, Á., Ariza, M., Martínez, E., Lloveras, J., & Martínez-Casasnovas, J. A. (2016). Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (*Zea mays* L.) from a standard UAV service. *Remote Sensing*, 8(12), 973. doi.org/10.3390/rs8120973
- Maresma, A., Chamberlain, L., Tagarakis, A., Kharel, T., Godwin, G., Czymmek, K. J., ... & Ketterings, Q. M. (2020). Accuracy of NDVI-derived corn yield predictions is impacted by time of sensing. *Computers and Electronics in Agriculture*, 169, 105236. doi.org/10.1016/j.compag.2020.105236

- Mengistu, A. D., Mengistu, S. G., & Alemayehu, D. M. (2016). Image Analysis for Ethiopian Coffee Plant Diseases Identification. *International Journal of Biometrics and Bioinformatics (IJBB)*, 10(1), 1.
- Mesas-Carrascosa, F. J., de Castro, A. I., Torres-Sánchez, J., Triviño-Tarradas, P., Jiménez-Brenes, F. M., García-Ferrer, A., & López-Granados, F. (2020). Classification of 3D point clouds using color vegetation indices for precision viticulture and digitizing applications. *Remote Sensing*, 12(2), 317. <https://doi.org/10.3390/rs12020317>
- Nevavuori, P., Narra, N., & Lipping, T. (2019). Crop yield prediction with deep convolutional neural networks. *Computers and electronics in agriculture*, 163, 104859
- Oliveira, A. J., Assis, G. A., Guizilini, V., Faria, E. R., & Souza, J. R. (2019). Segmenting and Detecting Nematode in Coffee Crops Using Aerial Images. *In International Conference on Computer Vision Systems*, pp. 274-283. Springer, Cham. doi.org/10.1007/978-3-030-34995-0_25
- Oliveira, H. C., Guizilini, V. C., Nunes, I. P., & Souza, J. R. (2018). Failure detection in row crops from UAV images using morphological operators. *IEEE Geoscience and Remote Sensing Letters*, 15(7), 991-995. doi.org/10.1109/LGRS.2018.2819944.
- Olson, D., Chatterjee, A., Franzen, D. W., & Day, S. S. (2019). Relationship of Drone-Based Vegetation Indices with Corn and Sugarbeet Yields. *Agronomy Journal*, 111(5), 2545-2557. doi.org/10.2134/agronj2019.04.0260
- Rezende, F. C., Caldas, A. L. D., Scalco, M. S., & de Faria, M. A. (2014). Leaf area index, plant density and water management of coffee. *Coffee Science*, 9(3), 374-384. <https://doi.org/10.25186/cs.v9i3.653>
- Ross, B. C. (2014). Mutual information between discrete and continuous data sets. *PLoS one*, 9(2), e87357. <https://doi.org/10.1371/journal.pone.0087357>
- Silva, V. A., de Rezende, J. C., de Carvalho, A. M., Carvalho, G. R., Rezende, T. T., & Ferreira, A. D. Recovery of coffee cultivars under the 'skeleton cut' pruning after 4.5 years of age. *Coffee Science*, 11(1), 55-64, (2016).
- Schober, P., Boer, C., & Schwarte, L. A. (2018). Correlation coefficients: appropriate use and interpretation. *Anesthesia & Analgesia*, 126(5), 1763-1768. <https://doi.org/10.1213/ANE.0000000000002864>
- Torres-Sánchez, J., López-Granados, F., Borra-Serrano, I. et al. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precision Agriculture*, 19, 115–133 (2018). <https://doi.org/10.1007/s11119-017-9502-0>
- Torres-Sánchez, J., López-Granados, F., Serrano, N., Arquero, O., & Peña, J. M. (2015). High-throughput 3-D monitoring of agricultural-tree plantations with unmanned aerial vehicle (UAV) technology. *PLoS one*, 10(6), e0130479.
- Xiang, H., & Tian, L. (2011). Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. *Biosystems Engineering*, 108(2), 104-113. <https://doi.org/10.1016/j.biosystemseng.2010.11.003> .
- Zhang, M., Zhou, J., Sudduth, K. A., & Kitchen, N. R. (2020). Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. *Biosystems Engineering*, 189, 24-35. <https://doi.org/10.1016/j.biosystemseng.2019.11.001>
- Zheng, G., & Moskal, L. M. (2009). Retrieving leaf area index (LAI) using remote sensing: theories, methods and sensors. *Sensors*, 9(4), 2719-2745. <https://doi.org/10.3390/s90402719>

Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., ... & Tian, Y. C. (2017). Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>