

ROBSON ARGOLO DOS SANTOS

**DEMANDA HÍDRICA E MODELAGEM DE PARÂMETROS
BIOFÍSICOS DA CULTURA DO MILHO A PARTIR DO SENSOR RGNIR A
BORDO DE UM VANT**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2019

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

S237d
2019 Santos, Robson Argolo dos, 1990-
Demanda hídrica e modelagem de parâmetros biofísicos da
cultura do milho a partir do sensor RGNIR a bordo de um VANT
/ Robson Argolo dos Santos. – Viçosa, MG, 2019.
x, 69f. : il. (algumas color.) ; 29 cm.

Orientador: Everardo Chartuni Mantovani.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f.62-69.

1. Milho - Cultivo. 2. Sensoriamento remoto. 3. Balanço
hidrológico. 4. Vegetação - Mapeamento. I. Universidade
Federal de Viçosa. Departamento de Engenharia Agrícola.
Programa de Pós-Graduação em Engenharia Agrícola. II. Título.

CDD 22 ed. 633.155

ROBSON ARGOLO DOS SANTOS

**DEMANDA HÍDRICA E MODELAGEM DE PARÂMETROS BIOFÍSICOS DA
CULTURA DO MILHO A PARTIR DO SENSOR RGNIR A BORDO DE UM
VANT**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

APROVADA: 16 de julho de 2019.



Thomé Simpliciano Almeida



Elpídio Inácio Fernandes Filho
(Coorientador)



Everardo Chartuni Mantovani
(Orientador)

“Nas grandes batalhas da vida, o primeiro passo para a vitória é o desejo de vencer”
(Mahatma Gandhi).

AGRADECIMENTOS

Aos meus pais pela confiança, esforço, dedicação e ensinamento.

Aos meus irmãos e familiares pelo apoio e incentivo.

Ao meu avô materno, Artur (*in memoriam*), minha avó paterna, Luísa (*in memoriam*) e a minha tia, Berenisse (*in memoriam*) que estiveram ligados diretamente com minha formação.

À Universidade Federal de Viçosa e ao Programa de Pós-Graduação em Engenharia Agrícola, pela oportunidade de realização do curso de Mestrado.

Ao meu orientador Professor Everardo Chartuni Mantovani, pelos ensinamentos, amizade e apoio durante todo mestrado.

Ao meu coorientador professor Elpídio Inácio Fernandes Filho, pelo auxílio durante a execução do experimento.

Ao Departamento de Solos da Universidade Federal de Viçosa pelo fornecimento de equipamento para realização do experimento.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudos.

Ao colega e amigo Roberto Filgueiras pelos ensinamentos, compreensão e doação do VANT para execução da pesquisa.

A colega e amiga Adelaide Cristielle Barbosa da Silva pela permissão do desenvolvimento da pesquisa em conjunto.

Aos meus amigos da pós-graduação e todos os colegas e professores do GESAI pela amizade e companheirismo.

Aos meus amigos da graduação em Engenharia Agrônômica que trilharam outros caminhos e outros programas de pós-graduação.

Aos funcionários da Universidade Federal de Viçosa que auxiliaram de forma direta e indireta todas as etapas durante o mestrado.

Enfim, a todos que me ajudaram de alguma forma na execução desse projeto, fica minha total gratidão.

BIOGRAFIA

ROBSON ARGOLO DOS SANTOS nasceu no dia 22 de fevereiro de 1990 em Taperoá, BA, filho de Romilton Jesus dos Santos e Nilzete Argolo dos Santos, irmão de Romário Argolo dos Santos e Ronald Argolo dos Santos.

Em março de 2012, ingressou no curso de Engenharia Agrônômica na Universidade Estadual de Feira de Santana, concluindo em julho de 2017.

Em agosto de 2017, ingressou no curso de Mestrado em Engenharia Agrícola na área de Recursos Hídricos e linha de pesquisa Manejo de Água/Planta na Agricultura Irrigada, submetendo-se à defesa em julho de 2019.

SUMÁRIO

LISTA DE ABREVIATURAS E SÍMBOLOS	vii
RESUMO	ix
ABSTRACT	x
Introdução geral	1
Capítulo 1	4
Modelos quantitativos e análise espaço-temporal da cultura do milho a partir de sensor RGNIR a bordo de um VANT	4
Resumo.....	4
1 Introdução	5
2 Material e métodos	7
2.1 Descrição da área de estudo	7
2.2 Semeadura e manejo da Cultura	8
2.3 Aquisição e processamento de dados	9
2.3.1 Aquisição de dados aéreos.....	10
2.3.2 Aquisição dos dados de campo.....	15
2.4 Desenvolvimento dos modelos.....	16
2.5 Validação dos modelos desenvolvidos.....	17
3 Resultados e discussão	18
3.1 Calibração radiométrica.....	18
3.2 Variabilidade espacial e temporal do NDVI	23
3.3 Modelo dos parâmetros biofísicos.....	28
3.4 Validação dos modelos para os parâmetros biofísicos.....	31
4 Conclusão.....	32
Capítulo 2.....	34
Evapotranspiração e biomassa da cultura do milho a partir do sensor RGNIR a bordo de um VANT.....	34
Resumo.....	34
1 Introdução	35
2 Material e Métodos	37
2.1 Descrição da área de estudo	37
2.2 Implantação e manejo da cultura.....	38
2.3 Coleta de dados em campo	38
2.4 Aquisição de dados aéreos	39
2.5 Processamento dos dados	41
2.5.1 Correção geométrica.....	42
2.5.2 Conversão de ND para valores físicos.....	42

2.5.3	Índices de vegetação (IV)	43
2.5.4	Evapotranspiração real da cultura a partir do IV	44
2.5.5	Estimativa do incremento diário da biomassa	47
2.6	Validação da biomassa estimada	48
3	Resultados e Discussão	49
3.1	K_{cb} derivado dos IV's	49
3.1.1	Transpiração e evapotranspiração real da cultura do milho	52
3.2	Estimativa da biomassa seca acima do solo	57
4	Conclusão	60
	Conclusões gerais	61
	Referências	62

LISTA DE ABREVIATURAS E SÍMBOLOS

ADT	Água disponível total na zona radicular do solo
AFA	Água prontamente disponível
AP	Altura da planta
APAR	Radiação fotossinteticamente ativas absorvida
MBE	Erro de viés médio
BIO	Biomassa
BIO _c	Biomassa do caule
BIO _F	Biomassa da folha
BIO _T	Biomassa total
DAE	Dias após a emergência
D _r	Depleção da umidade na zona radicular
d _s	Densidade do solo
E	Evaporação
<i>E_f</i>	Fração evaporativa
ET	Evapotranspiração
ET _o	Evapotranspiração de referência
ET _{pc}	Evapotranspiração potencial da cultura
ET _r	Evapotranspiração real da cultura
FAO	<i>Food and Agriculture Organization</i>
GNSS	<i>Global Navigation Satellite System</i>
IAF	Índice de áreas foliar
IV	Índice de vegetação
K	coeficiente da arquitetura da folha
K'	coeficiente que leva em consideração o índice de vegetação
K _{cb}	Coeficiente basal da cultura
K _{cbmax}	Coeficiente máximo de cultivo
K _e	Coeficiente de evaporação
K _s	Coeficiente de estresse hídrico da cultura
MAE	Erro médio absoluto
ND	Número digital
NDVI	Índice de vegetação por diferença normalizada
NDVI _a	Índice de vegetação por diferença normalizada acumulada

NPK	Nitrogênio-fósforo-potássio
OMM	Organização Meteorológica Mundial
P	Precipitação
P_d	Precipitação do dia
P_{d-1}	Precipitação do dia anterior
P_{ei}	Precipitação entre os imageamento
R^2	Coefficiente de determinação
RMSE	Erro quadrático médio
R_s	Radiação solar incidente
RTK	<i>Real Time Kinematic</i>
SAVI	Índice de vegetação ajustado ao solo
T	Temperatura média
T_c	Razão da transpiração em condições sem estresse
T_{max}	Temperatura máxima
T_{min}	Temperatura mínima
T_r	Transpiração real da cultura
U_R	Umidade relativa média
U_{rmax}	Umidade relativa máxima
U_{rmin}	Umidade relativa mínima
VANT	Veículo aéreo não tripulado
V_v	Velocidade do vento
Z_r	Profundidade da zona radicular efetiva
ϵ_{max}	Máxima eficiência no uso de radiação
θ_{CC}	Capacidade de campo em base volumétrica
θ_{PM}	Ponto de murcha em base volumétrica

RESUMO

SANTOS, Robson Argolo, M.Sc., Universidade Federal de Viçosa, julho de 2019. **Demanda hídrica e modelagem de parâmetros biofísicos da cultura do milho a partir do sensor RGNIR a bordo de um VANT.** Orientador: Everardo Chartuni Mantovani. Coorientador: Elpídio Inácio Fernandes Filho.

Em função do crescimento populacional estimado para 2050, a produção agrícola precisa aumentar em 70%, porém, de forma sustentável ambientalmente e viável economicamente. O uso do imageamento aéreo com sensores de baixo custo apresenta-se como alternativa para manejar a lavoura nos pressupostos da agricultura de precisão de forma mais econômica. Contudo, existem poucos estudos na literatura científica que avaliam a capacidade destes sensores em monitorar a lavoura agrícola, bem como prever parâmetros biofísicos e demanda hídrica. Pensando nisso, esta dissertação teve como objetivo avaliar a capacidade de um sensor RGNIR a bordo de um veículo aéreo não tripulado (VANT) em identificar variabilidade espaço-temporal, assim como prever parâmetros biofísicos e estimar a demanda evapotranspirométrica na cultura do milho. Foram capturados, utilizando-se o sensor RGNIR a bordo de um VANT, 15 conjuntos de imagens durante 61 DAE. Cada conjunto de imagens foram mosaicadas, gerando 15 imagens unitárias. Cada imagem foi georreferenciada e corrigida radiometricamente. Posteriormente, foram realizados os cálculos dos índices de vegetação. Para gerar modelos preditivos e validá-los, foram coletadas 54 plantas sobre quais foram determinadas a altura, área foliar e massa da folha, caule, espiga e panícula. Também, no intuito de realizar o balanço hídrico da área, coletou-se amostras de solo para determinar a capacidade de campo, ponto de murcha e densidade do solo. O sensor, após correções radiométricas, mostrou-se confiável em monitorar a lavoura agrícola, sendo possível identificar perturbações na mesma. Os modelos dos parâmetros biofísicos estimados a partir dos índices de vegetação apresentaram, de modo geral, bons resultados estatísticos, principalmente aquele que se relaciona com a biomassa seca total e produção de grãos. A transpiração e evapotranspiração real da cultura estimada, em que foram utilizados os índices de vegetação, mostraram bons resultados para determinar a demanda hídrica necessária à lavoura. O sensor RGNIR embarcado em um VANT foi satisfatório para o monitoramento agrícola da cultura do milho, bem como na estimativa dos parâmetros biofísicos.

ABSTRACT

SANTOS, Robson Argolo, M.Sc., Universidade Federal de Viçosa, July, 2019. **Water demand and modeling of biophysical parameters of maize crop from the RG NIR sensor aboard a UAV.** Adviser: Everardo Chartuni Mantovani. Co-adviser: Elpídio Inácio Fernandes Filho.

Due to the estimated population growth for 2050, agricultural production needs to increase by 70%, but in a sustainable and economically viable way. The use of aerial imagery with low-cost sensors presents itself as an alternative to manage crops in the assumptions of precision farming for a higher economic return. However, there are few studies in the scientific literature that evaluate the ability of these sensors to monitor agricultural crops, as well as to predict biophysical parameters and water demand. The aim of this dissertation was to evaluate the ability of a modified RGB sensor on a Unmanned aerial vehicle (UAV) to identify spatio-temporal variability, as well as to predict biophysical parameters and to estimate evapotranspirometric demand in maize. Using the modified RGB sensor on a UAV, 15 sets of images were captured during the first 61 days after emergence. Each set of images were mosaicated, generating 15 unit images. Each image was georeferenced and radiometrically corrected. Subsequently, vegetation indices were calculated. To generate predictive models and to validate them, 54 plants were collected on which the height, leaf area and leaf, stem, ear and panicle mass were determined. Also, in order to perform the water balance of the area, soil samples were collected to determine the field capacity, wilt point and soil density. The sensor, after radiometric corrections, proved to be reliable in monitoring the agricultural crop, making it possible to identify disturbances in the same. The models of the biophysical parameters estimated from the vegetation indexes presented, in general, good statistical results, mainly the one for estimating total dry biomass and grain production. The actual transpiration and evapotranspiration of the estimated crop, in which the vegetation indices were used, showed good results to determine the water demand necessary for the crop. The modified RGB sensor embedded in a UAV was satisfactory for the agricultural monitoring of the corn crop, as well as in the estimation of the biophysical parameters.

1 Introdução geral

Avaliar as dinâmicas que ocorrem durante o desenvolvimento da cultura é fundamental para o sucesso da lavoura agrícola e aumento na produção da mesma. Em função, principalmente, do crescimento acelerado da população mundial. Contudo, este aumento deve estar aliado com a sustentabilidade ambiental e a viabilidade econômica do setor. A FAO (*Food and Agriculture Organization*) alerta que até 2050 a população deve alcançar 9,1 bilhões de pessoas e, para atender esse contingente, será necessário que a produção de alimentos cresça 70% (TILMAN *et al.*, 2011). Segundo esses mesmos autores, para o milho, uma das principais culturas do cenário mundial, será preciso aumentar a produção, até 2050, em 35%.

Avaliar o desenvolvimento da lavoura *in situ* é dispendioso e moroso, sendo difícil a abrangência de todo o talhão Battude *et al.* (2016) e Wang *et al.* (2016)(BATTUDE *et al.*, 2016; WANG, LI'AI *et al.*, 2016). Pensando nisso, técnicas de sensoriamento remoto aplicadas à agricultura se tornaram fundamentais, visto que essas possuem a capacidade de avaliar as variações espaço-temporais em toda área agricultada de modo sistemático e econômico (KHANAL; FULTON; SHEARER, 2017). Desta forma, aliam-se positivamente à agricultura de precisão.

O sensoriamento remoto voltado para agricultura utiliza, majoritariamente, sensores a bordo de uma plataforma orbital (satélites) ou sub orbital (aviões, VANT-veículos aéreos não tripulados) que estimam informações da lavoura através de energia eletromagnética refletida e/ou emitida pelas plantas (TUNCA *et al.*, 2018). Os sensores para estas plataformas podem ser passivos, utilizando a energia eletromagnética proveniente do sol, ou ativos, emitindo a própria energia eletromagnética (PETROPOULOS; IRELAND; BARRETT, 2015). Porém, usualmente, os sensores passivos são mais aplicáveis na agricultura.

Os sensores orbitais, normalmente aplicados no monitoramento agrícola, disponibilizam as informações em forma de imagem, que, por sua vez, são administradas por empresas responsáveis pelos equipamentos. Assim, as imagens podem ser disponibilizadas gratuitamente ou comercialmente. As gratuitas apresentam limitações para o monitoramento diário e em alta resolução especial, enquanto as comerciais, pelo custo de aquisição. Outro limitante, independente da gratuidade, é a impossibilidade de adquirir informações das superfícies a serem imageadas em dias com

nebulosidade. Estas limitações inviabilizam o sensoriamento remoto orbital em algumas regiões do mundo, principalmente em pequenas áreas agrícolas. Desta forma, os sensores embarcados em plataforma sub orbitais mostram-se como importante alternativa frente às limitações dos orbitais.

Os VANT's, em função do seu preço e versatilidade, estão se tornando um dos principais meios para embarcar sensores que captam mudanças espaço-temporal da superfície terrestre em nível sub orbital. Com ele, é possível realizar voos diariamente, abaixo das nuvens e com grande riqueza de detalhes, haja vista que o mesmo possui alta resolução espacial.

Nos VANT's podem ser embarcados sensores hiperespectrais, multiespectrais, RGNIR (*red-green-near infrared*) e termiais. Os multiespectrais são sensores que possuem, no mínimo, quatro bandas espectrais, sendo os mais utilizados nessas aeronaves. A eficiência e a confiabilidade deste sensor a bordo do VANT foram observadas nas culturas do girassol (TUNCA *et al.*, 2018), arroz (GUAN *et al.*, 2019), citrus (AMPATZIDIS; PARTEL, 2019) e milho (HAN *et al.*, 2019), entre outras. Já para monitorar as condições de estresse térmico e hídrico, assim como determinar a quantidade de água a ser aplicada na lavoura, geralmente são utilizados sensores termiais a bordo nos VANT's Brenner *et al.* (2018) e Park *et al.* (2017). Os hiperespectrais foram avaliados em vinicultura (ZARCO-TEJADA *et al.*, 2013) e na silvicultura (NÄSI *et al.*, 2015). Entretanto, os sensores hiperespectrais, multiespectrais e termiais aprestam custo de aquisição elevado, quando comparado ao RGNIR.

Os RGNIR's são sensores que apresentam uma lente óptica com três filtros que separam a radiação eletromagnética nos comprimentos de onda, geralmente, do vermelho, verde e infravermelho próximo. Este sensor é do tipo RGB (*red-green-blue*) modificado, e essa modificação é realizada pela remoção do filtro do azul e adição do filtro do infravermelho próximo (NIJLAND *et al.*, 2014; RABATEL; GORRETTA; LABBÉ, 2014). Desta forma, com as modificações realizadas torna-se possível calcular índices de vegetação comumente encontrado na literatura e identificar variabilidade nas áreas agricultadas. Contudo, há poucos estudos relacionados com este tipo de sensor, sendo necessário testá-lo, então, para avaliar sua capacidade e limitações no monitoramento agrícola.

Através dos comprimentos de onda do vermelho e infravermelho é possível analisar o comportamento espacial e temporal do cultivo agrícola, bem como desenvolver modelos preditivos de parâmetros biofísicos. Também é possível, a partir

destes comprimentos de onda, estimar a demanda hídrica da cultura como apresentado por (CAMPOS *et al.*, 2018; ER-RAKI *et al.*, 2007; GONZÁLEZ-DUGO; MATEOS, 2008). No entanto, apesar de existirem estudos com estimativa da demanda hídrica e parâmetros biofísicos com as bandas do vermelho e infravermelho próximo, esses estudos foram realizados a partir de sensores multiespectrais em plataformas orbitais e sub orbitais. Não obstante, não foram encontrados na literatura científica estudos que abordem essa temática com sensores RGNIR's

Baseado na importância do monitoramento das variáveis biofísicas e no elevado custo que se tem em obter esses parâmetros com sensores multiespectrais e termais, torna-se relevante a busca por alternativas mais econômicas utilizando sensores RGNIR's. Esta alternativa poderá ser de grande interesse ao agricultor que deseja realizar o manejo agrícola nos pressupostos da agricultura de precisão de forma mais econômica.

Capítulo 1

Modelos quantitativos e análise espaço-temporal da cultura do milho a partir de sensor RGNIR a bordo de um VANT

Resumo

O imageamento aéreo através de sensores embarcados em veículos aéreos não tripulados (VANT's) é uma alternativa para suprir as limitações que os sensores orbitais apresentam ao monitorar lavouras agrícolas. Entre os sensores possíveis de serem embarcados nos VANT's, o RGNIR é o mais viável economicamente. Avaliar espacialmente e temporalmente, bem como desenvolver modelos em culturas agrícolas a partir deste sensor é de grande valia ao produtor rural, principalmente o de menor poder econômico. Este trabalho teve como objetivo avaliar temporalmente e espacialmente o desenvolvimento da cultura do milho a partir de um sensor RGNIR a bordo de um VANT, bem como desenvolver modelos quantitativos para prever parâmetros biofísicos. Utilizando um sensor RGNIR da Mapir *survey 3* a bordo de um VANT, foram capturados 15 conjuntos de imagens durante 61 dias após a emergência da cultura. Cada conjunto de imagens foi mosaicado no *software PhotoScan Agisoft*, gerando 15 imagens com 3 bandas espectrais. As imagens já mosaicadas tiveram seus números digitais convertidos para números físicos de reflectância. Após a correção, aplicou-se o cálculo do NDVI. Em campo, foram coletadas 54 plantas, que tiveram a altura, áreas foliar e massas (folha, caule, espiga, panícula) mensuradas. Posteriormente, determinou o modelo do NDVI e NDVI acumulado (NDVIa) com a biomassa coletada. A banda do infravermelho próximo exerceu influência na banda do vermelho, entretanto, esse ruído foi atenuado a partir da conversão dos números digitais em valores físicos. O NDVI, por este sensor, mostrou capacidade em detectar variações sazonais e espaciais na lavoura do milho, bem como de identificar influências das plantas daninhas e super adensamento na cultura. O modelo a partir do NDVI para estimar a biomassa seca total acima do solo teve melhor resultado com o NDVI do dia, gerando RMSE de 68,68 g m⁻² e R² de 0,81, enquanto o modelo pelo NDVIa obteve RMSE de 84,65 g m⁻² e R² de 0,72. Já nos modelos para estimar a produtividade, o

resultado foi melhor com o NDVIa, com RMSE de 134,00 g m⁻² e R² de 0,63, enquanto, para o NDVI ao 61 dias após a emergência (DAE), o RMSE e R² foram de 194,00 g m⁻² e 0,1, respectivamente. A correção dos números digitais em físicos se mostrou importante para atenuar o ruído entre as bandas. Logo, é confiável estimar produtividade utilizando-se NDVIa até os 61 DAE a partir deste sensor.

Palavras-chave: Sensoriamento remoto, agricultura de precisão, NDVI, biomassa

1 Introdução

A tecnologia voltada para o seguimento da agricultura tem avançado muito nos últimos anos, com destaque para uso do imageamento orbital e suborbital. Segundo G. Yang et al. (2017), identificar a variabilidade em toda área cultivada é uma importante estratégia para propor um manejo diferenciado dentro do campo agrícola. Para o monitoramento da variabilidade dos cultivos agrícolas é comum a aplicação das técnicas do sensoriamento remoto. Essa consiste em adquirir informações espaciais e temporais das culturas sem estar em contato direto com elas. Segundo Tunca et al. (2018), a aquisição destas informações pode ser realizada através de sensores orbitais, sensores aéreos e sensores terrestres - este último mais oneroso economicamente.

Sensores orbitais são aqueles que estão embarcados em satélites e captam informação da superfície terrestre por meio da interação da energia eletromagnética. As informações capturadas por esses sensores são disponibilizadas em formato de imagens e podem ser gratuitas ou com custo de aquisição. Geralmente, as imagens gratuitas apresentam baixa resolução espacial e temporal (MOZGERIS *et al.*, 2018), o que pode se tornar inviável para o monitoramento diário da agricultura. Porém, as imagens comerciais possuem alta resolução temporal e espacial, dependendo do sensor, abaixo de 1 metro (CHEN *et al.*, 2019). Contudo, o custo de aquisição pode ser um entrave ao produtor.

Os sensores orbitais que necessitam da luz solar, independente da gratuidade do acesso, se mostram totalmente inviáveis quando a área a ser monitorada apresenta nebulosidade, uma vez que as nuvens bloqueiam a captura da energia eletromagnética que chega até o sensor. Assim, este tipo de sensor apresenta limitações em determinadas regiões e em determinadas épocas do ano.

Já os sensores aéreos são equipamentos que estão embarcados em aeronaves e capturam informações da superfície terrestre em baixa altitude. Na última década, a tecnologia dos VANT's (veículos aéreos não tripulados) evoluiu rapidamente e se tornou uma das principais plataforma para embarcar estes sensores (ZHANG, YAWEI *et al.*, 2018). Assim, esses veículos com sensores embarcados se tornaram uma ferramenta robusta para amenizar as impossibilidades da aplicação dos sensores orbitais (MANFREDA *et al.*, 2018).

Os VANT's são pequenas aeronaves que têm como características a fácil pilotagem e a flexibilidade para realizar voos diários em baixas altitudes, respeitando as legislações locais, e permitindo imagear em qualquer região do mundo, sob condições climáticas diversas. A característica destas aeronaves de realizar voos diários e em baixas altitudes permite monitorar as áreas agrícolas em alta resolução espacial e elevada frequência temporal (MANFREDA *et al.*, 2018) sem influência da nebulosidade. Estas características espaciais e temporais permitem o monitoramento não apenas em extensas áreas agrícolas, mas também em pequenas propriedades rurais.

Um dos principais sensores que podem ser embarcados nos VANT's é o multiespectral. Ele pode ser usado para adquirir informações relativas à radiação em diferentes espectros eletromagnéticos das culturas, em alta resolução espacial (DENG *et al.*, 2018). Com os dados adquiridos pelo sensor multiespectral, é possível calcular índices de vegetação que permitem avaliar o comportamento espaço-temporal da cultura ao longo de seu crescimento e desenvolvimento, propiciando uma tomada de decisão mais assertiva e pontual da lavoura agrícola (POBLETE; ORTEGA-FARÍAS; RYU, 2018; ZAMAN-ALLAH *et al.*, 2015).

Os sensores multiespectrais a bordo dos VANTS's comumente empregados em pesquisa são os que dispõem de lentes óptico separado, a exemplo dos sensores Sequoia Parrot e MicaSense. Contudo, possuem custo elevado de aquisição e pode ser inviável economicamente ao produtor ou órgão de pesquisa que detém de pouco capital econômico. A eficiência e a confiabilidade destes sensores foram observadas nas culturas do girassol (TUNCA *et al.*, 2018), arroz (GUAN *et al.*, 2019), citrus (AMPATZIDIS; PARTEL, 2019) e milho (HAN *et al.*, 2019).

Com o intuito de oferecer um produto economicamente alternativo, alguns fabricantes modificam as câmeras RGB (*red-green-blue*), que possui apenas uma lente óptica, para monitorar a vegetação (RABATEL; GORRETTA; LABBÉ, 2014). A modificação consiste na remoção de um bloqueador do comprimento de onda do

infravermelho próximo e adição de um filtro do mesmo (NIJLAND *et al.*, 2014; RABATEL; GORRETTA; LABBÉ, 2014). A adição do filtro do infravermelho próximo permite calcular os índices de vegetação, a exemplo do NDVI. Porém, poucas pesquisas abordam os sensores RGNIR em análise espaço-temporal e modelagem em culturas agrícolas, principalmente a do milho, sendo esta uma importante cultura no cenário mundial. Daí a necessidade de um estudo que possa investigar a eficiência e a confiabilidade deste sensor na cultura do milho voltadas, principalmente, ao pequeno produtor.

No Brasil, quase 50% da produção do milho é realizada por pequenos produtores (HOFFMANN, 2014). Todavia, apesar da expressiva participação, são observadas baixas produtividades desta cultura por estes agricultores em função, principalmente, da ausência de tecnologias para os mesmos.

Pensando na importância da cultura do milho no cenário mundial praticada nas grandes e, principalmente, nas pequenas propriedades agrícolas, bem como na eficiência da aplicação do sensoriamento remoto através de sensores aéreos, o presente estudo teve como objetivo avaliar temporal e espacialmente o desenvolvimento da cultura do milho a partir de um sensor RGNIR, a bordo do VANT, assim como desenvolver modelos quantitativos desta cultura baseados no NDVI para prever parâmetros biofísicos.

2 Material e métodos

2.1 Descrição da área de estudo

O estudo foi realizado no campo experimental Prof. Diogo Alves de Mello, Vale da Agronomia, pertencente à Universidade Federal de Viçosa, localizada no município de Viçosa, estado Minas Gerais, Brasil (Figura).

O município de Viçosa possui clima subtropical úmido, classificado, segundo a metodologia de Köppen, como Cwa (ALVARES *et al.*, 2013). De acordo a normal climatológica, o município possui temperatura média máxima de 26,7 °C e temperatura média mínima de 15,4 °C. A umidade relativa média anual é de 81,1% e a precipitação acumulada média anual é de 1250 mm (INMET, 2018).

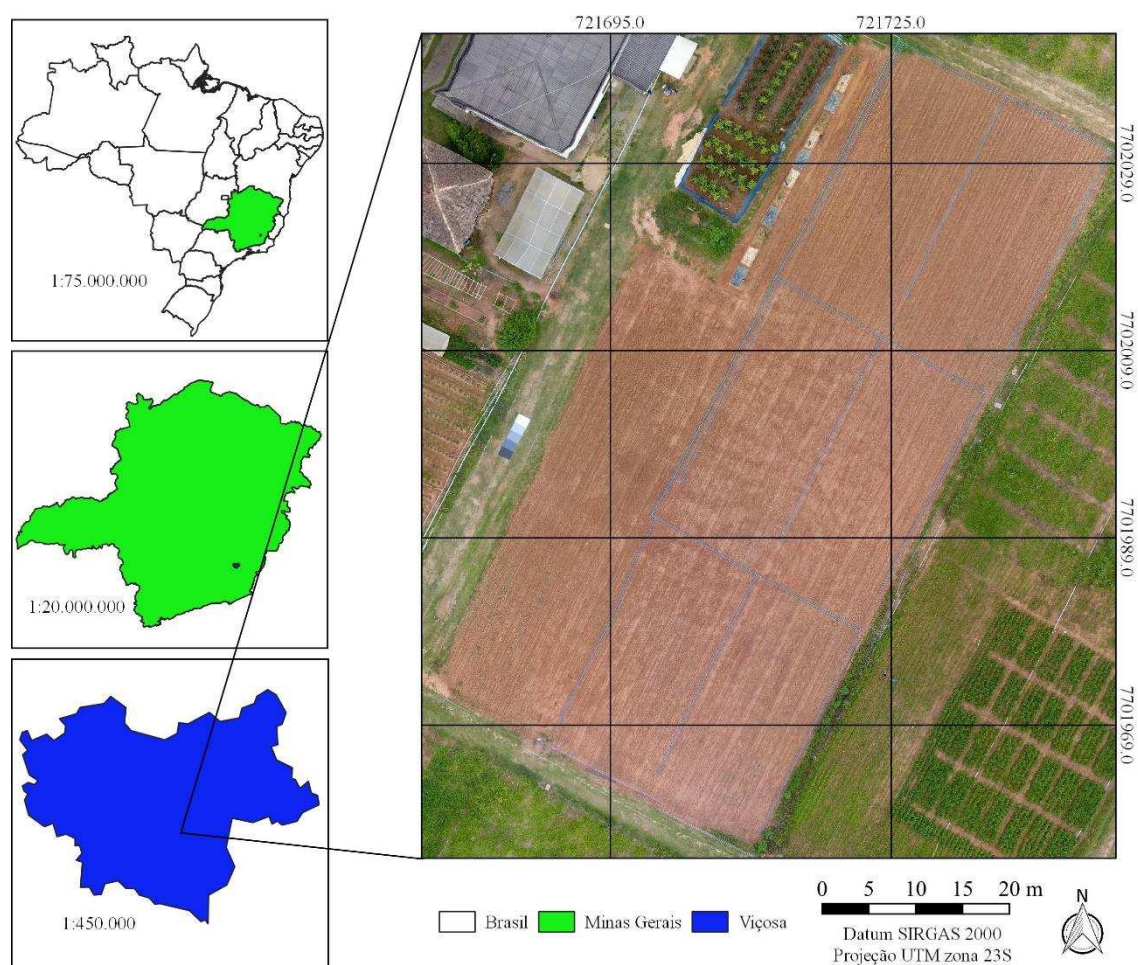


Figura 1: Localização da área de estudo em relação ao município de Viçosa, estado de Minas Gerais e ao Brasil.

2.2 Semeadura e manejo da Cultura

A pesquisa foi conduzida em uma área de 2600 m² (Figura 1) em solo classificado como Latossolo Amarelo, que tem como característica a textura argila (EMBRAPA, 2018). Nesta área, fez-se o preparo do solo com uma aração seguida de uma gradagem, com intuito de melhorar as condições físicas do mesmo para o crescimento e desenvolvimento da cultura. Após o preparo do solo e o adequado teor de umidade, realizou-se a semeadura do milho (*Zea mays* L.).

A semeadura foi realizada no dia 15 de outubro de 2018, com espaçamento de 0,28 m entre plantas e 0,5 m entre linhas. A emergência das plântulas iniciou-se no dia 20 de outubro de 2018. No plantio foi realizada a adubação, com 300 kg ha⁻¹ do formulado 8:28:16 e, ao completar 38 DAE (dias após a emergência), foi realizada a adubação nitrogenada com 300 kg ha⁻¹ de nitrogênio por hectare via ureia. Ao completar

25 DAE, foi realizado o controle químico das plantas daninhas com o ingrediente ativo glifosato na dosagem de $0,89 \text{ kg ha}^{-1}$.

2.3 Aquisição e processamento de dados

Na Figura 2 pode ser observado o desenvolvimento metodológico realizado durante a execução deste estudo.

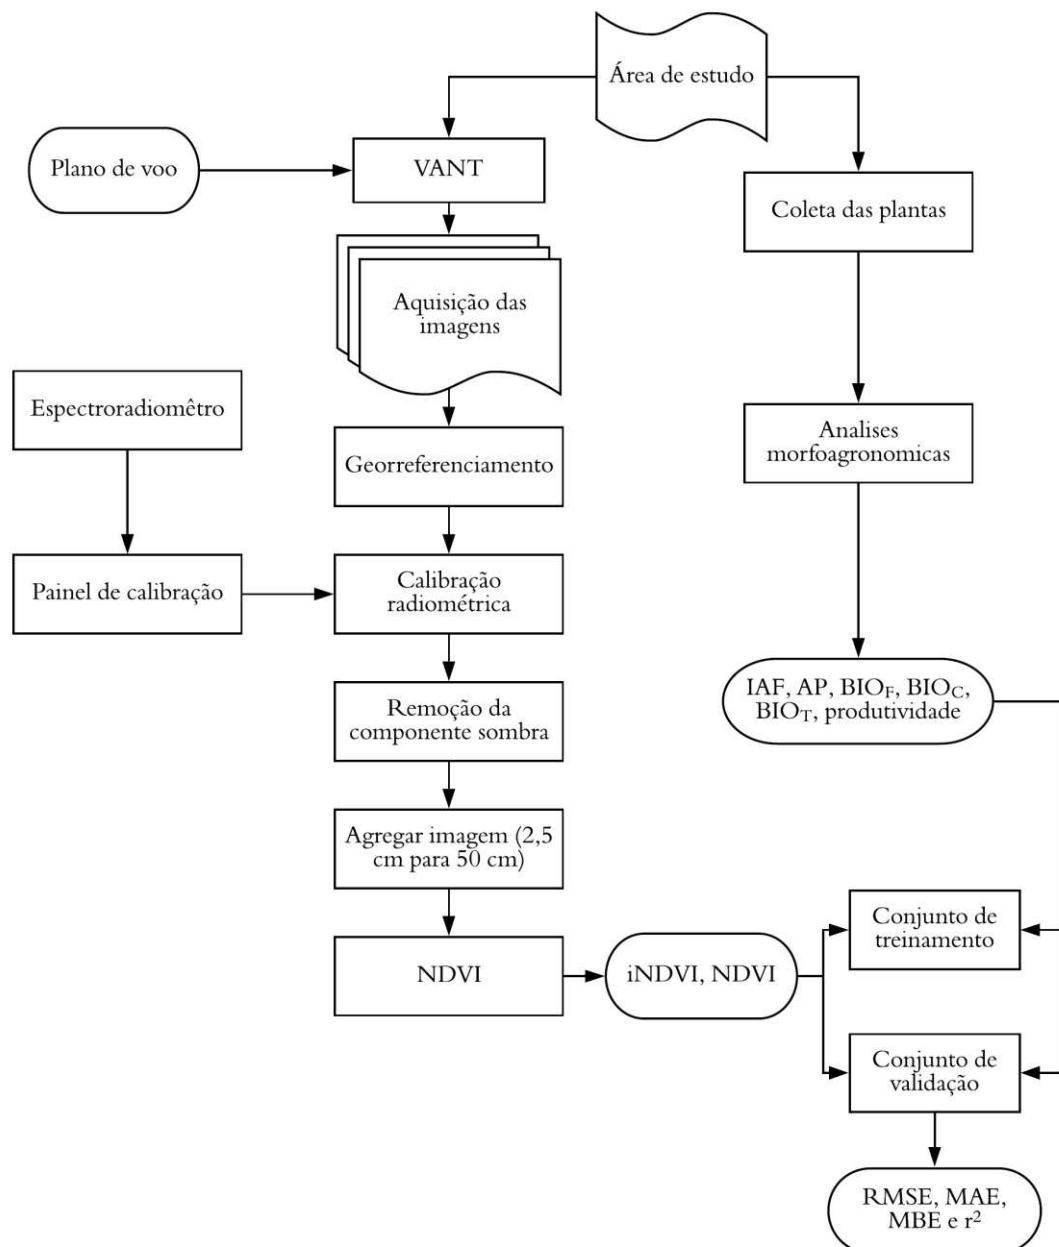


Figura 2: Fluxograma do desenvolvimento metodológico realizada durante a execução da pesquisa.

2.3.1 Aquisição de dados aéreos

Foram adquiridas 15 conjunto de imagens, sempre as 10 horas (UTC/GMT-3), sendo a primeira aos 03 DAE e a última aos 61 DAE (Tabela 1). Devido a condições operacionais do sensor RGNIR, o monitoramento foi interrompido aos 61 DAE.

Tabela 1. Datas da aquisição das imagens e as condições climáticas no horário do imageamento.

Data	DAE	T _{max} °C	T _{min} °C	U _{rmáx} %	U _{rmin} %	V _v m s ⁻¹	R _s MJ m ⁻² d ⁻¹	P mm
22/10/2018	03	20,5	18,8	76,0	67,0	2,7	16,42	0,0
31/10/2018	12	25,0	22,9	76,0	66,0	2,5	17,53	0,0
02/11/2018	14	25,5	23,3	78,0	69,0	1,3	22,46	0,0
07/11/2018	19	25,4	23,1	72,0	62,0	2,0	14,88	0,0
12/11/2018	24	26,1	23,4	72,0	63,0	1,9	20,25	0,0
15/11/2018	27	25,0	24,2	75,0	71,0	3,5	18,56	0,0
23/11/2018	35	23,4	22,4	73,0	69,0	3,3	17,10	0,0
28/11/2018	40	24,5	21,4	77,0	64,0	1,1	24,38	0,0
30/11/2018	42	25,1	23,4	72,0	65,0	3,2	23,76	0,0
04/12/2018	46	23,5	22,0	78,0	70,0	0,9	14,67	0,0
10/12/2018	52	20,2	19,4	84,0	77,0	0,2	15,07	0,0
12/12/2018	54	24,8	23,5	70,0	65,0	2,0	26,74	0,0
14/12/2018	56	26,1	24,6	69,0	58,0	2,5	29,65	0,0
17/12/2018	59	26,2	24,2	71,0	62,0	3,0	28,70	0,0
19/12/2018	61	28,5	27,0	66,0	55,0	2,5	27,05	0,0

DAE = Dias após a emergência; T_{máx} = Temperatura máxima do ar; T_{min} = Temperatura mínima do ar; U_{Rmáx} = Umidade relativa máxima; U_{Rmín} = Umidade relativa mínima; V_v = velocidade média do vento; R_s = Radiação solar incidente; P = Precipitação.

Para a aquisição das imagens aéreas foi utilizado o VANT (veículo aéreo não tripulado) modelo DJI *Phantom 4* (Figura 3). A linha *Phantom* está categorizada dentro dos veículos multirrotores (YANG, HYUNSOO *et al.*, 2017), possuindo autonomia de voo de, aproximadamente, 30 minutos.




Figura 3: VANT utilizado para realização da pesquisa: a) vista lateral do equipamento; b) vista frontal do equipamento destacando o sensor Mapir *Survey 3*.

Utilizou-se um sensor RGNIR a bordo do VANT (Figura 3b) para a captura das imagens. O sensor é de fabricação da empresa Mapir e o modelo do equipamento é a *Survey 3*. Tal sensor, segundo o fabricante, possui três filtros Bayer para diferenciar os comprimentos de onda no vermelho, verde e infravermelho próximo. A faixa do comprimento de onda para os filtros vermelho, verde e infravermelho próximo é de 640 - 680 nm, 525 - 575 nm e 820 - 880 nm, respectivamente (MAPIR, 2019). O sensor pode capturar imagens com resolução de 12 Megapixels (4000 x 3000 pixels); o mesmo estava configurado para capturar as imagens a cada 2 segundos e, automaticamente, armazenar em um micro cartão de memória em formato jpeg e resolução radiométrica de 8 bits.

Elaborou-se o plano de voo com o auxílio do aplicativo DroneDeploy para que as imagens mantivessem sempre o mesmo padrão de captura. Assim, o plano de voo foi configurado para altitude de 50 metros, sobreposição frontal de 85% e lateral de 75%, com velocidade fixada em 3 m s^{-1} (Figura 4). Com essa configuração, o tempo de voo para englobar a área de estudo foi de 3 minutos. Após a captura, as imagens foram processadas no *software PhotoScan Agisoft* para a reconstrução de cada arquivo GeoTIF mosaicadas das 3 bandas do sensor. As imagens exportadas deste *software* apresentavam pixels de 2,5 cm de resolução espacial.

Para que as informações de campo sejam estimadas a partir do sensor, deve-se proceder com a correção geométrica e a conversão radiométrica das imagens para posterior computo dos índices de vegetação.

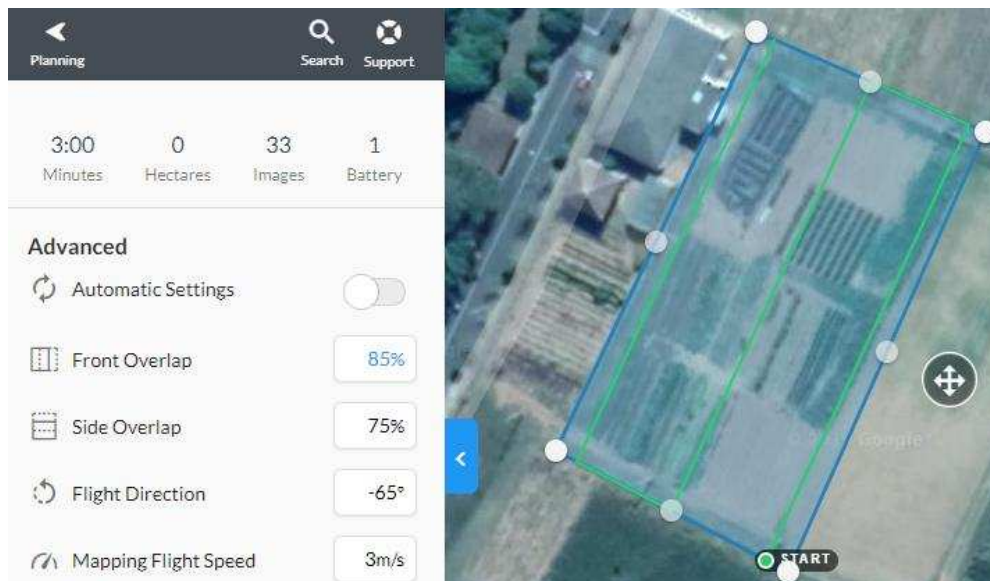


Figura 4: Configuração do plano de voo para o monitoramento.

2.3.1.1 Correção geométrica

O sensor possui um receptor GPS USB externo para marcar geograficamente cada imagem, porém, o GPS é de baixa precisão e gera erros de deslocamento aleatórios em cada imageamento. Para corrigir a localização das imagens, foram instalados em campo pontos de controle (Figura 5a e 5b), a partir dos quais foram obtidas as coordenadas. As coordenadas, em cada ponto, foram capturadas por um receptor GNSS (*Global Navigation Satellite System*) RTK (*Real Time Kinematic*) Topmap T10 (Figura 5c) de alta precisão. Assim, todas as imagens foram georreferenciadas a partir dos pontos de controle.



Figura 5: a) Espacialização dos pontos de controle em campo; b) ponto de controle instalado em campo; c) RTK Topmap usado na captura dos pontos de controle.

2.3.1.2 Calibração radiométrica

O sensor *Survey 3* disponibiliza imagens em valores de números digitais (ND) que, por sua vez, correspondem a uma estratificação singular por banda da energia eletromagnética que chega até o sensor. Caso o intuito seja comparar temporalmente as imagens, ou realizar operações algébricas entre bandas do sensor, torna-se necessária a conversão desses valores para valores físicos de reflectância. Essa conversão tem como objetivo caracterizar espectralmente os alvos, assim como a aplicação de cálculos de índices de vegetação que permitam identificar a diferenciação espacial e temporal na cultura estudada (PONZONI; SHIMABUKURO; KUPLICH, 2012).

A conversão foi realizada a partir da calibração radiométrica das imagens. Para isso, foram instalados painéis com reflectância conhecida nas proximidades da área experimental (Figura 6a). Os painéis utilizados foram do tipo napa, material que possui composição à base de PVC (policloreto de vinila) e parte têxtil de poliéster.

Foram utilizados cinco painéis abrangendo diferentes níveis de cinza. As cores utilizadas em cada painel foram: preta (P), cinza escuro (C1), cinza intermediário (C2), cinza claro (C3) e branco (B), com dimensões de 1,5 m² cada um (Figura 6b). A reflectância de cada painel foi determinada em laboratório com o auxílio do espectrorradiômetro modelo FieldSpec 4 da empresa ASD. Esse aparelho abrange os comprimentos de onda de 300 a 2500 nm. Contudo, foram extraídas dos painéis as médias da reflectância correspondentes às bandas do sensor abordo do VANT.




Figura 6: Painéis de calibração instalados em campos no momento dos voos.

Com o auxílio do *software* QGIS® 2.18 (QGIS DEVELOPMENT TEAM, 2016), recortou-se das imagens mosaicadas a área referente a cada painel. Posteriormente, foram extraídas as médias dos ND das bandas do vermelho e

infravermelho próximo, correspondente a cada painel e, então, procedeu-se com uma regressão para a determinação da equação de calibração entre ND dos painéis com as médias da refletância obtidas pelo espectroradiômetro. Ressalta-se que a calibração foi realizada em todos os voos, para que fosse possível uma padronização e análise temporal das imagens.

2.3.1.3 Cálculo do NDVI

Antes de realizar o cálculo do NDVI, foi necessário realizar dois processamentos na imagem: 1) remoção da sombra e 2) reamostragem do *pixel*.

Por se tratar de imageamento com alta resolução espacial, notava-se grande interferência dos *pixels* de sombra no interior do dossel da cultura. Objetivando reduzir esse efeito, foi aplicada uma classificação supervisionada nas imagens para remoção do mesmo. Essa etapa foi realizada com auxílio do *software* QGis® 2.18 (QGIS DEVELOPMENT TEAM, 2016) e do plugin *Semiautomatic classification* (CONGEDO, 2016), utilizando o algoritmo *minimum distance*. Após a classificação, os *pixels* das imagens correspondiam apenas à vegetação e ao solo exposto.

Com o intuito de melhorar o desempenho computacional do processamento das imagens, foram agregados os pixels das imagens de 2,5 cm para 50 cm. Assim, as imagens foram reduzidas de 4.100.000 de *pixels* para 10.400 *pixels*. Esse processo foi realizado no *software* R (R CORE TEAM, 2019) utilizando-se o pacote raster (HIJMANS *et al.*, 2015), que permitiu a otimização no tempo do processamento das imagens sem perda da qualidade na análise.

Finalizando todas as etapas descritas acima, procedeu-se com o cálculo do índice de vegetação, NDVI, necessário para acompanhar a evolução da cultura ao longo do tempo, assim como para correlacionar com os parâmetros biofísicos mensurados em campo.

O índice de vegetação NDVI é a razão normalizada entre a refletância medida na faixa de comprimento de onda do vermelho (V) e a faixa de comprimento de onda do infravermelho próximo (IVP) usando a Equação 1 (ROUSE; HAAS; DEERING, 1974).

$$NDVI = \frac{IVP - V}{IVP + V} \quad (1)$$

2.3.2 Aquisição dos dados de campo

Na área experimental foram coletadas amostras das plantas de milho em diferentes estágios da cultura, para que fossem determinados o IAF (índice de área foliar), a biomassa das folhas, do caule, total, altura de planta e a produtividade (Figura 7). Estes parâmetros foram necessários para gerar os modelos biofísicos.



Figura7: Mensuração dos parâmetros para modelagem biofísicos da cultura do milho.

Para mensurar os parâmetros da cultura, foram coletadas 54 plantas nos períodos de 46, 52 e 59 DAE (dias após a emergência). As plantas coletadas foram levadas ao laboratório (Figura 7a), onde tiveram as folhas retiradas (Figura 7b) e a altura mensurada (Figura 7c). A área foliar foi determinada a partir das folhas retiradas através do medidor de área foliar da marca Licor, modelo LI 3100C (Figura 7d). De posse da área foliar de cada planta, utilizou-se a Equação 2 para determinar o IAF.

$$IAF = \frac{AF}{El \times Ep} \quad (2)$$

em que: AF é a área foliar (m²); El é o espaçamento entre linha de plantio (m); Ep espaçamento entre plantas (m).

Ao finalizar as medidas de área foliar, as folhas, colmo, panícula (quando presente na planta) e espigas (quando presente na planta) foram acondicionadas separadamente em sacolas de papel e levadas à estufa de circulação forçada de ar, a uma temperatura de 70 °C em um período de 72h. Após decorrido o tempo, as amostras foram retiradas da estufa e foram determinadas as massas. Assim, quantificou-se a

biomassa da folha, do caule e total, sendo a última determinada pela soma da biomassa da folha, caule, panícula (quando presente) e espiga (quando presente).

Para determinar a produtividade em campo, foram selecionadas 26 parcelas de 2 m², de forma aleatória, na área experimental. Cada parcela continha 14 plantas. As espigas de cada planta foram colhidas manualmente e debulhadas em máquina de tração manual. Levou-se uma amostra dos grãos para determinar a umidade no ponto de colheita. Para isso, utilizou-se o medidor G600 da empresa Gehaka, o qual registrou 17% de umidade. Então, as massas das amostras de cada parcela foram determinadas em balança de precisão. As massas das amostras foram corrigidas para o nível de 14% de umidade, ponto indicado para colheita do milho.

2.4 Desenvolvimento dos modelos

Foram desenvolvidos modelos que estimassem parâmetros biofísicos baseados em regressão linear a partir do NDVI do imageamento do dia da coleta e NDVIa (NDVI acumulado) até as datas de coletas.

A partir dos dados de campo e da coleta das imagens aéreas foram desenvolvidos os modelos para biomassa da folha (BIO_F), caule (BIO_C), total (BIO_T), altura da planta (AP), índice de área foliar (IAF) e produtividade (P). Para tal, foi necessário georreferenciar cada planta coletada, bem como as 26 parcelas de 2 m² que foram destinadas à produtividade. O georreferenciamento foi realizado com o mesmo receptor GNSS RTK (Figura 8).

Para modelar a BIO_F, BIO_C, BIO_T, AP e IAF foi necessário extrair a média do NDVI e, para isso, determinou-se um raio de 1 metro do ponto georreferenciado, o qual gerou uma área circular representativa de cada planta coletada de 3,14 m². Posteriormente, correlacionou-se os valores de NDVI com os dados dos parâmetros referente à cultura mensurados em campo, gerando equações de regressão linear entre as variáveis dependentes (parâmetros da cultura) e as imagens de NDVI (variável independente). Foi realizada a correlação dos dados destes parâmetros com o NDVIa. Essa foi determinada a partir da integração numérica do NDVI extraído de todas as imagens capturadas até o último dia do imageamento. Esse procedimento foi realizado para cada ponto amostral e foi executado usando integração numérica no *software* R (R CORE TEAM, 2019).

Já o modelo desenvolvido para produtividade com o NDVI do dia foi determinado pela correlação da produtividade medida em campo com o NDVI aos 61 DAE, época de maior vigor fotossintético da planta e maior acúmulo de biomassa entre os dias imageados. O modelo desenvolvido para o NDVI acumulado seguiu-se da mesma forma que descrito acima.

Foram utilizados 70% do conjunto de dados para o treinamento dos modelos.



Figura 8: Equipamento RTK utilizado para coleta de pontos georreferenciados: a) base do equipamento; b) rover do equipamento.

2.5 Validação dos modelos desenvolvidos

As validações dos modelos foram feitas utilizando 30% do conjunto de dados. As análises estatísticas aplicadas na validação foram: coeficiente de determinação (R^2), equação 6, erro quadrático médio (RMSE), equação 7, erro médio absoluto (MAE), equação 8, e erro de viés médio (MBE), equação 9.

$$R^2 = \frac{[\sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O})]^2}{[\sum_{i=1}^n (P_i - \bar{P})^2][\sum_{i=1}^n (O_i - \bar{O})^2]} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (8)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (9)$$

em que: P_i é valor predito pelo modelo; O_i é valor observado; \bar{P} é valor médio pelo modelo; \bar{O} é valor médio observado e n é número de amostra.

O RMSE é responsável por avaliar a magnitude dos erros dos valores preditos em relação ao observado, seu valor será sempre positivo e quanto mais próximo de zero melhor será o modelo de predição. Assim, como o RMSE, o MAE mede a magnitude média dos erros dos valores preditos em relação ao observado. Contudo, o RMSE, por ser quadrático, atribui peso elevado em diferenças maiores entre o predito e o observado.

Nesse sentido, o MBE possibilita inferir se os valores preditos podem superestimar ou subestimar os valores observados.

3 Resultados e discussão

3.1 Calibração radiométrica

Está apresentada na Figura 9 a reflectância espectral dos painéis de calibração utilizados durante a pesquisa. Analisa-se, nessa Figura, o aumento na reflectância associado ao aumento do nível de cinza dos painéis em todos os comprimentos de onda, com exceção do cinza intermediário (C2) que, a partir de 750 nm, apresentou reflectância superior ao cinza claro (C3). O comportamento da C2 pode estar relacionado com composição diferente aos demais, uma vez que, visando alternativa econômica para calibração, os painéis foram adquiridos em lojas comuns sem o perfeito controle da composição que o constitui. Já a Tabela 2 mostra os valores médios com o desvio padrão da reflectância de cada alvo na região espectral na banda 1 (vermelho) e banda 3 (infravermelho próximo).




Figura 9: Assinatura espectral dos painéis de calibração de baixo custo usado na calibração radiométrica.

Tabela 2. Reflectância média extraído dos painéis de calibração na faixa das bandas do sensor utilizada para o cálculo do NDVI.

Painéis	Vermelho	Infravermelho
P	0,0252±0,0001	0,0241±0,0001
C1	0,0742±0,001	0,0695±0,0002
C2	0,1644±0,005	0,2528±0,0018
C3	0,2195±0,001	0,2101±0,0006
B	0,7929±0,005	0,7801±0,0028

Os valores médios dos números digitais (ND) e refletâncias extraídos dos painéis nas bandas do vermelho (V) e infravermelho próximo (IVP) permitiram desenvolver equações de calibração para as respectivas bandas do sensor, as quais podem ser observados na Figura 10. Nota-se na Figura 10a e 10b que, para a banda do vermelho, o modelo exponencial apresentou melhor ajuste para correção do número digital em valores físicos de reflectância, em que o coeficiente de determinação foi de 0,97 enquanto o mesmo coeficiente para o modelo linear foi de 0,86.

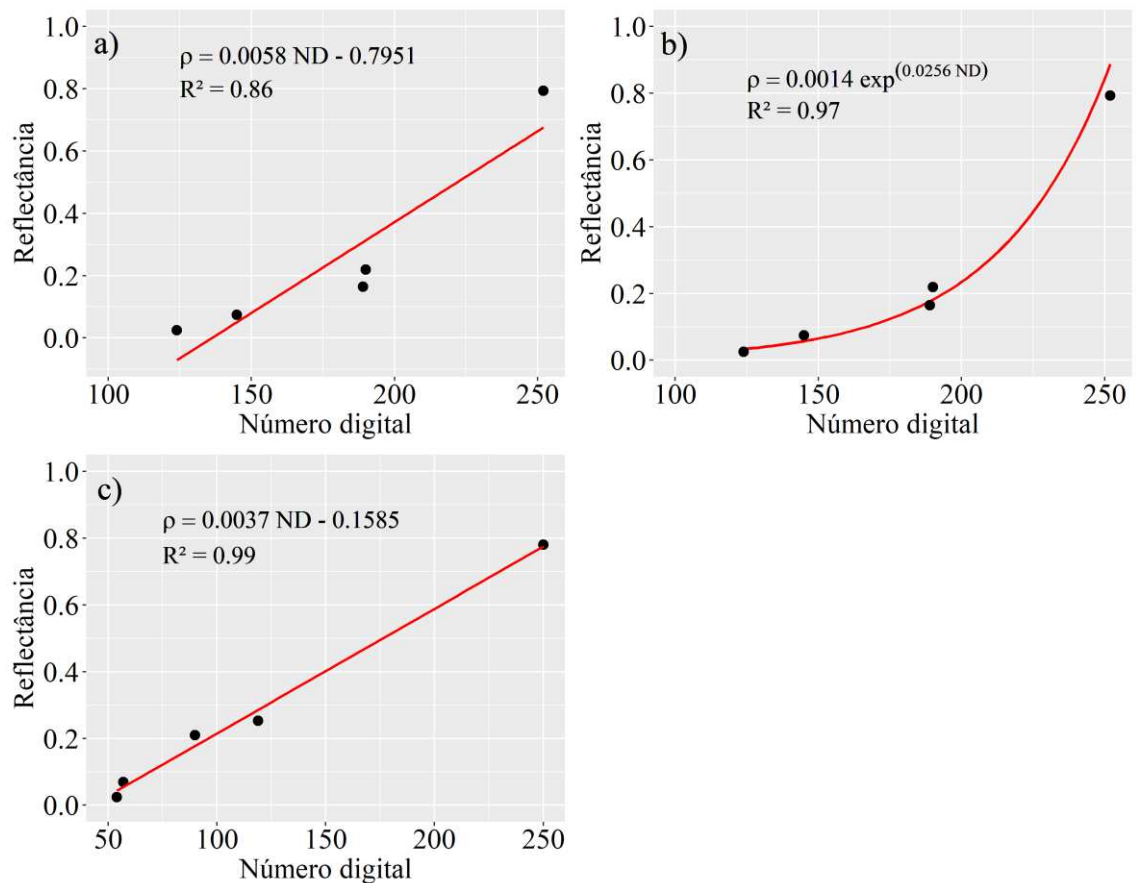


Figura 10: a) Modelo de calibração linear para banda do vermelho; b) modelo de calibração exponencial para banda do vermelho; e c) modelo de calibração linear para banda do infravermelho próximo.

Pesquisas desenvolvidas para calibração radiométrica, utilizando painéis de baixo custo, com sensores embarcado em VANT's mostraram relação linear entre o número digital da banda do vermelho com a refletância destes painéis previamente determinado em laboratório (CAO *et al.*, 2019; HERRERO-HUERTA *et al.*, 2015; IQBAL; LUCIEER; BARRY, 2018). Contudo, esses autores utilizaram sensores que possuem lentes ópticas individualizados, um para cada banda, ou seja, os comprimentos de onda são capturados separadamente, o que evita influência entre elas, enquanto o sensor Mapir *Survey 3* possui apenas um sensor óptico com filtro do tipo bayer modificado para diferenciar os comprimentos de onda. Assim, neste último, pode ocorrer influência de uma banda na outra alterando o valor verdadeiro do número digital. Gowravaram *et al.* (2018) mencionam que a banda do vermelho e verde do sensor PeauPro82 GoPro Hero 4 Black são sensíveis a banda do infravermelho, ou seja, nas bandas verde e vermelho ocorre contaminação pela banda infravermelho. Da mesma forma, foi observado a influência na banda do vermelho no sensor Mapir *Survey3*

utilizado nessa pesquisa. É importante frisar que a PeauPro82 GoPro Hero 4 Black e a Mapir *Survey3* são do mesmo fabricante e ambos são sensores RGB (*red-green-blue*) modificados.

Os sensores RGB matricial padrão bayer possuem naturalmente ação de filtragem limitada na região do visível (RABATEL; GORRETTA; LABBÉ, 2014). Ainda de acordo com os autores acima referenciados, os fabricantes desses equipamentos são obrigados a adicionar um bloqueador próximo à região do infravermelho para corresponder aos requisitos colorimétricos-padrão. Porém, com intuito de monitoramento vegetal, remove-se dos sensores RGB este bloqueador e é adicionado um filtro infravermelho próximo ao equipamento. A remoção do bloqueador pode influenciar na contaminação do comprimento de onda do infravermelho próximo nas bandas do visível, provocando alterações em seus números digitais.

A banda do infravermelho próximo apresentou correlação linear (Figura 10c) entre o número digital, determinado pelo sensor, e a refletância, determinada pelo espectrorradiômetro, uma vez que não foram notados ruídos como descrito para banda do vermelho.

Na Tabela 3 estão disponíveis os coeficientes a e b gerados na calibração durante cada imageamento, sendo exponencial, para banda do vermelho, e linear, para banda do infravermelho próximo. Nota-se que os valores de R^2 foram superiores a 92%, ou seja, baixa dispersão entre os números digitais nos painéis, registrados a partir do sensor *Survey3*, com a refletância deles, mensurado com espectrorradiômetro.

Tabela 1. Coeficientes da calibração radiométrica para cada dia do imageamento.

DAE	V			IVP		
	a	b	R^2	a	b	R^2
3	0,0014	0,0256	0,97	0,0037	-0,1585	0,99
12	0,0014	0,0255	0,97	0,0035	-0,1160	0,99
14	0,0008	0,0274	0,99	0,0040	-0,1301	0,92
19	0,0013	0,0257	0,97	0,0038	-0,1529	0,98
24	0,0008	0,0276	0,99	0,0037	-0,1433	0,99
27	0,0009	0,0274	0,98	0,0037	-0,1503	0,99
35	0,0021	0,0238	0,97	0,0039	-0,1159	0,96
40	0,0007	0,0281	0,99	0,0041	-0,1677	0,98

42	0,0021	0,0235	0,98	0,0038	-0,1173	0,95
46	0,0012	0,0261	0,97	0,0038	-0,1454	0,99
52	0,0008	0,0276	0,97	0,0045	-0,2555	0,99
54	0,0011	0,0265	0,96	0,0041	-0,1538	0,98
56	0,0016	0,0248	0,98	0,0042	-0,1052	0,95
59	0,0007	0,0286	0,98	0,0039	-0,1498	0,99
61	0,0011	0,0265	0,96	0,0044	-0,1395	0,95

Na Figura 11a é possível notar com nitidez a influência pela banda do infravermelho próximo no vermelho, como discutido anteriormente. O número digital (ND) da banda do vermelho foi superior à banda do infravermelho próximo ao longo do ciclo da cultura. Em condição em que não ocorre influência de uma banda na outra, espera-se que o número digital do vermelho seja inferior ao infravermelho próximo quando se monitora vegetação. Contudo, apesar da influência, é possível observar, ao longo do monitoramento, um antagonismo entre estas duas bandas, ou seja, a mediada que vai aumentando o infravermelho próximo reduz-se o vermelho.

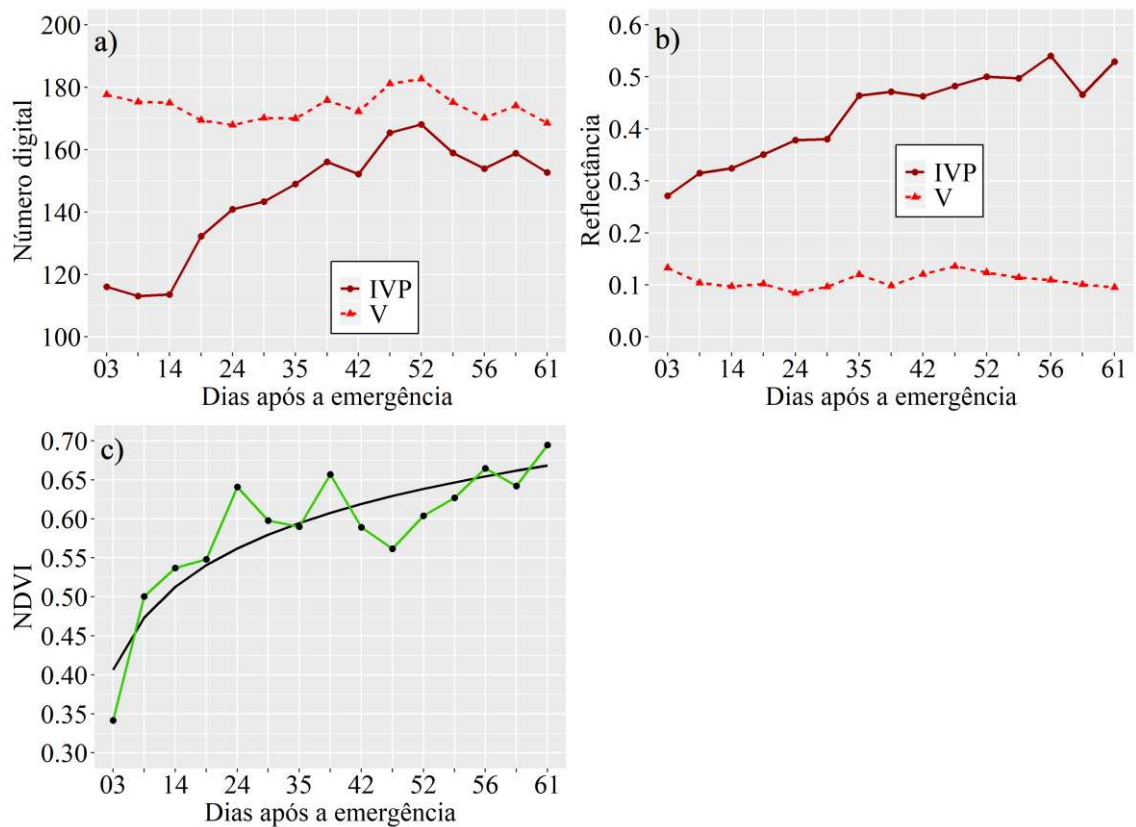


Figura 111: a) Número digital médio das bandas do vermelho (V) e infravermelho próximo (IVP); b) reflectância média das bandas V e IVP; c) NDVI médio da cultura ao longo do ciclo.

Na Figura 11b nota-se os valores das bandas do vermelho e infravermelho próximo após a calibração radiométrica. Fica evidenciado, nesta Figura, que a calibração exponencial amenizou o ruído provocado pelo infravermelho próximo. O antagonismo é mais proeminente após a correção, em que a refletância da banda do infravermelho próximo aumenta enquanto a refletância da banda vermelho tende a reduzir ao longo do ciclo. Assim, constata-se que a calibração radiométrica foi necessária para atenuar a influência entre as bandas do sensor estudado.

Alta reflectância no comprimento de onda do infravermelho próximo e baixa reflectância no comprimento de onda do vermelho é comum em vegetação, pois a planta absorve, em maior quantidade, a energia solar da região do vermelho pelos pigmentos fotossintetizantes, e à medida que a planta vai evoluindo aumenta a eficiência da absorção deste comprimento de onda (Le Maire et al., 2004; Ponzoni et al., 2012 Ling et al., 2019). Já o inverso pode ser observado no infravermelho próximo, pois, segundo (JENSEN, 2009), a planta possui um sistema de defesa que não permite que a mesma absorva a radiação no infravermelho próximo com igual eficiência da radiação do visível, fato que, se ocorresse, causaria danos irreversíveis em suas proteínas. Com isso, a planta tende a dissipar essa energia, o qual é observado pela maior reflectância na Figura 11b.

Nas Figuras 11a e 11b, as retas contendo os valores do vermelho e infravermelho próximo não têm constância ao longo do monitoramento; podem ser observadas oscilações em seus valores. Tal situação está atrelada aos fatores ambientais, bem como ao desenvolvimento e manejo da cultura. As variações nos valores destes comprimentos de onda influenciaram os valores médios do NDVI ao longo do ciclo de 61 dias da cultura (Figura 11c).

3.2 Variabilidade espacial e temporal do NDVI

É observada na Figura 12 a variabilidade espacial e temporal do NDVI até os 61 dias após a emergência (DAE) da cultura do milho. Aos 03 DAE, a maior parte da área é solo exposto, o qual registrou o NDVI em valores baixos. Por estar ainda no início do crescimento e desenvolvimento, a planta apresenta área foliar reduzida, o que implica em menor interceptação da radiação eletromagnética que chega até a superfície. Desta forma, maior parte da radiação que chega até a superfície interage com o solo exposto e com as plantas daninhas. Segundo Ren *et al.* (2018), o solo possui como característica

espectral refletir em maior porcentagem o comprimento de onda no vermelho, o que gera redução nos valores de NDVI.

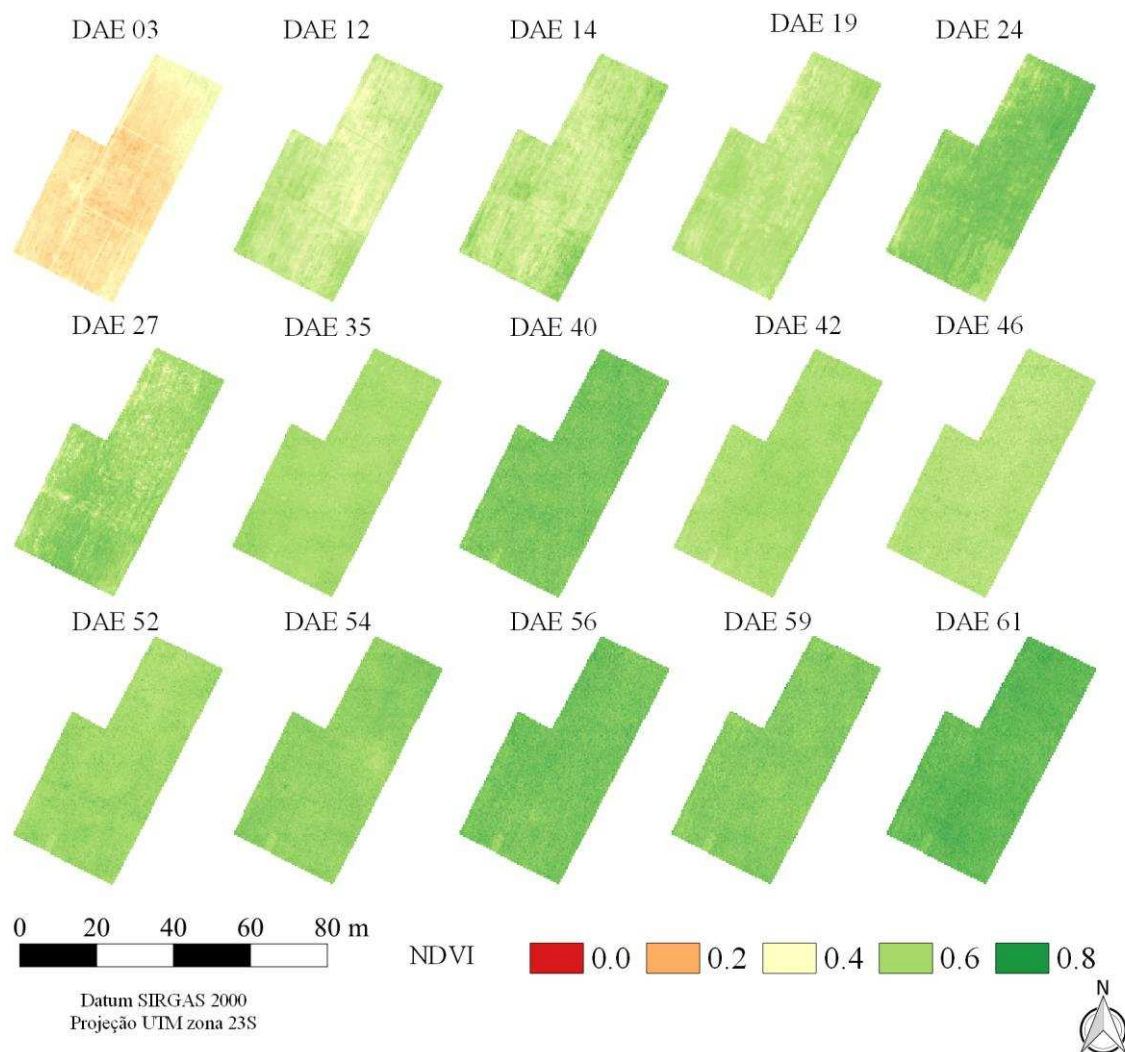


Figura 12. Variabilidade espacial e temporal do NDVI na cultura do milho registrado pelo sensor Mapir Survey3.

Ainda aos 03 DAE, na parte nordeste, observa-se NDVI um pouco elevado, influenciado pelo início da infestação do capim-marmelada (*Brachiaria plantaginea* (Link) Hitchc.), comum em área cultivada com milho. Aos 12 DAE, o capim-marmelada, na parte nordeste, mantém seu desenvolvimento, elevando ainda mais o NDVI. Também são registrados valores altos de NDVI na parte sudeste, sudoeste e oeste, provocados por infestação de outras espécies de plantas daninhas. Na parte sudeste há uma ocorrência elevada de infestação de batata (*Solanum tuberosum* L.). Anterior ao milho, nesta área foi cultivada a batata para finalidade didática para os cursos de ciências agrárias da universidade. As batatas foram colhidas e, em seguida,

implantado o milho; contudo, alguns tubérculos persistiram no solo e emitiram brotação, tendo maior desenvolvimento na parte sudeste da imagem. Nas demais áreas da imagem, desenvolveram-se diversas espécies de plantas daninhas. Na imagem do dia 14 DAE fica mais evidente o desenvolvimento das plantas invasoras em relação ao milho, onde, nas partes nordeste, sudeste, sudoeste e oeste os valores de NDVI aumentam em velocidade maior que no restante da imagem.

Aos 24 DAE nota-se alta variabilidade espacial do NDVI e queda nas áreas sudeste e sudoeste, influenciadas pela competição entre plantas daninhas e milho. Ao longo do crescimento, as plantas vão aumentando a exigência nutricional, hídrica e luminosidade, forçando então uma maior competição no agroecossistema. Na imagem seguinte (27 DAE), o NDVI apresenta queda significativa em seus valores, explicada pela aplicação de herbicida realizada aos 25 DAE, ou seja, dois dias antes do imageamento. Na Figura 13 pode ser observada a clorose das plantas daninhas provocada pela toxidez do herbicida três dias após a aplicação.




Figura 13: Toxidez do herbicida na: a) batata (*Solanum tuberosum*, L.); b) trevo (*Oxalis latifolia* Kunth); c) Nabiça (*Raphanus raphanistrum* L); d) Capim-marmelada (*Brachiaria plantaginea* (Link.) Hitchc.).

O herbicida paralisa a fotossíntese das plantas, exceto o milho que possui resistência contra o glifosato, levando à morte os componentes fotossintéticos, o que conduz a se absorver menos o comprimento de onda do vermelho, reduzindo os valores de NDVI. Huang *et al.* (2015) verificaram que o NDVI reduz seus valores em até 200% com o aumento nas dosagens do princípio ativo glifosato em plantas de soja que não possui resistência ao princípio ativo glifosato. Outros autores observaram o mesmo efeito em gramíneas (ASKEW; ASKEW; GOATLEY, 2019). Um resultado similar foi observado no presente estudo. A morte das plantas invasoras também se relaciona com a redução da cobertura vegetal da área experimental, deixando o solo exposto.

Após o controle químico, notou-se que a variabilidade espacial na área foi reduzida apresentando maior homogeneidade, visto que a partir dos 35 DAE, apenas a cultura do milho permaneceu na área, e as plantas daninhas não mais exercia influência no NDVI. Tal premissa pode ser observada na Figura 14, em que até os 27 DAE há um maior intervalo entre o primeiro e terceiro quartil do *boxplot* e pela média suavemente afastada da mediana. Após os 35 DAE ocorre o inverso, há menor distância entre o intervalo do primeiro e terceiro quartil e a média centraliza na mediana.




Figura 14: Estatística descritiva da variabilidade espacial e temporal do NDVI ao longo do ciclo de 61 DAP do milho.

Ao realizar o imageamento aos 40 DAE, constatou-se que o NDVI apresentou valor elevado, média, aproximadamente, de 0,65 (Figura 12 e Figura 14), diferente das quatro imagens subsequentes, que registraram menores valores. Tal resultado foi influenciado pela adução nitrogenada realizada aos 38 DAE. Aos 38 e 39 DAE choveu

o equivalente a 10 mm, o que foi necessário para umedecer o solo e facilitar a absorção instantânea do nutriente pela cultura. Segundo Zhou e Yin (2018) elevado nível de nitrogênio das folhas resulta em alto teor de clorofila e, conseqüentemente, maiores taxas fotossintética. O aumento no teor de clorofila nas folhas absorve em maior quantidade a energia, para o processo fotossintético, no comprimento da onda no vermelho, o qual é observado pela redução da reflectância neste comprimento de onda aos 40 DAE (Figura 11b). Zhao *et al.* (2005) encontram correlação significativa e negativa entre concentração de clorofila no tecido foliar do algodoeiro e reflectância do comprimento de onda no vermelho.

Após os 40 DAE, percebe-se uma queda influenciada, possivelmente, pela baixa absorção dos nutrientes, uma vez que no dia 41 não houve precipitação pluviométrica, reduzindo a umidade do solo. Aos 46 DAE (Figura 12 e Figura 14), nota-se o NDVI menor, possivelmente por estar relacionado com excesso de umidade no solo (do dia 42 aos 45 choveu a equivalente 33,4 mm), o qual pode ter provocado lixiviação excessiva do nitrogênio.

Em uma pequena área da parte sul das imagens (Figura 12 e Figura 15), após 40 DAE é observada redução no NDVI influenciado pelo aumento na reflectância do comprimento de onda do vermelho.




Figura 15: Adensamento das plantas em função da sementeira manual.

O aumento da reflectância do vermelho na pequena porção do sul da imagem foi provocado pelo super adensando das plantas (Figura 15). A plantadora que distribuiu as sementes no campo encontrou uma barreira física, que não lhe permitiu prosseguir; com isso, fez-se a semeadura de forma manual e, por isso, a distribuição foi totalmente irregular, não respeitando os 0,28 m entre plantas. Após os 40 DAE, o grau de desenvolvimento nessa região foi maior, gerando alta competição entre as plantas, reduzindo seu potencial fotossintético e, conseqüentemente, elevou a reflectância do vermelho, o qual é registrado pelo NDVI.

3.3 Modelo dos parâmetros biofísicos

O conhecimento dos parâmetros biofísicos da cultura permite inferir o avanço do crescimento e desenvolvimento da lavoura, bem como estimar produtividade antes mesmo da colheita. Assim, podem ser observados na Figura 16 os modelos de regressão do NDVI e NDVIa (NDVI acumulado) com os parâmetros mensurados em campo, assim como as suas significâncias. O NDVI do dia apresentou melhor coeficiente de determinação em todos os parâmetros analisados em relação ao NDVIa, com exceção da altura da planta e produtividade (Figura 17).

Entre os parâmetros analisados, a biomassa total apresentou o melhor coeficiente de determinação, sobressaindo-se aos demais. Kross *et al.* (2015), utilizando imagens do RapidEye para a cultura do milho, encontraram relação exponencial entre NDVI e biomassa total da planta e R^2 equivalente a 0,42. Zheng *et al.* (2018), em estudo com a cultura do arroz utilizando o sensor Tetracam mini-MCA6 embarcado em VANT, também encontraram relação exponencial com R^2 igual a 0,55. Estes autores justificam a exponencialidade no fato da saturação do NDVI, principalmente em plantas C4. Cheng *et al.* (2017), utilizando espectroscopia na cultura do arroz, identificaram relação exponencial e linear com R^2 igual a 0,68 e 0,47, respectivamente. Assim, pode-se inferir que não existe um padrão do comportamento correlacionado entre NDVI e biomassa total. Possivelmente, essa variação está relacionada com as condições locais, manejo, estágio fenológico e sensor utilizado. É importante destacar que o monitoramento do presente trabalho foi interrompido aos 61 DAE, não alcançando o pico máximo de vigor do milho, que, segundo Toureiro *et al.* (2017) e Zhang *et al.* (2019), está em torno de 80 dias após emergência.

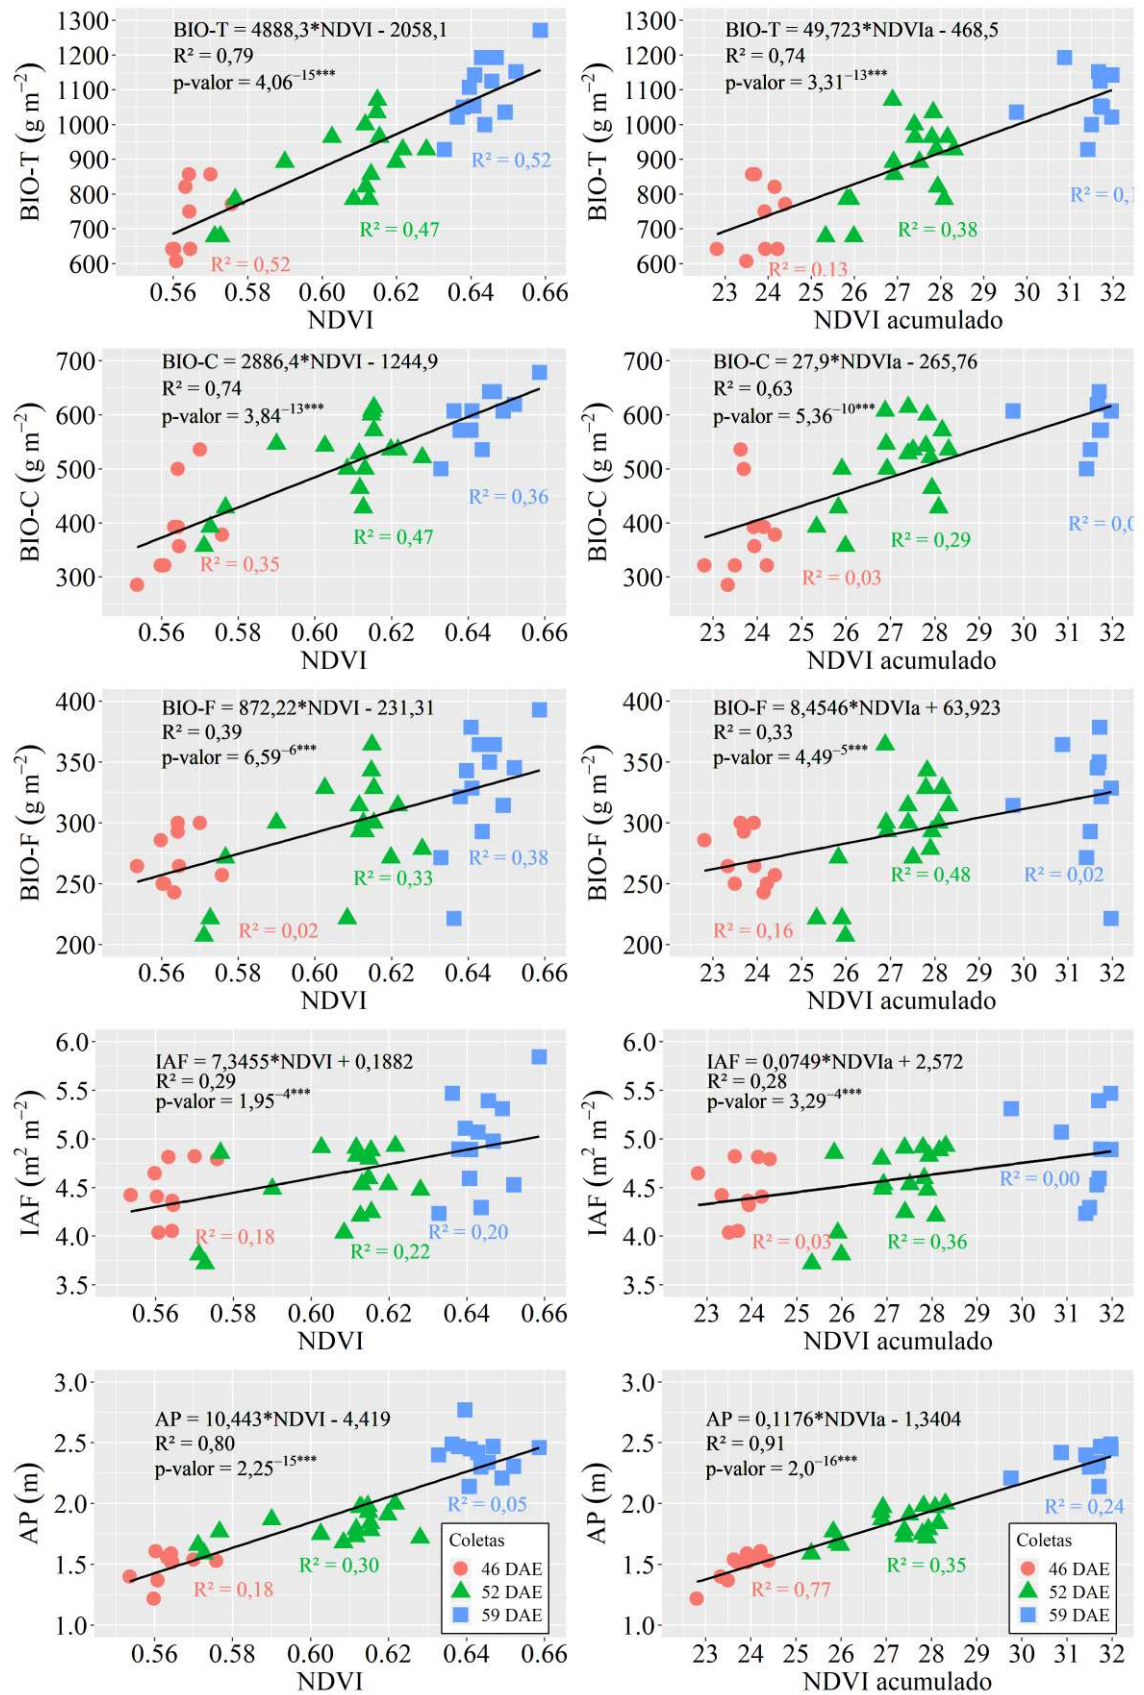


Figura 16: Modelos desenvolvidos para os parâmetros biofísicos a partir do imageamento aéreo.
 *** significativo no nível de probabilidade $p \leq 0,001$.

Ainda na Figura 16, a biomassa do caule apresentou R^2 de 0,77 e 0,63 para o NDVI e NDVIa, respectivamente. O caule não possui componentes fotossinteticamente ativos, porém, parte dos fotoassimilados é direcionada para sua estrutura, ou seja, a planta que apresenta alto vigor fotossintético apresentará maior teor de biomassa no caule e, conseqüentemente, este será registrado pelo NDVI. Ao analisar a biomassa da folha (Figura 16), nota-se menor coeficiente de determinação, principalmente quando comparado ao caule. Para a cultura do milho, Kross *et al.* (2015) encontraram R^2 de 0,86 em um modelo exponencial da biomassa da folha com NDVI. Cheng *et al.* (2017), para a orizicultura, verificaram R^2 maior para biomassa das folhas, quando comparada com a biomassa do caule. O baixo valor do coeficiente de determinação da biomassa da folha em relação à biomassa do caule, neste trabalho, pode estar relacionado com a sobreposição de folhas entre as plantas e, desta forma, o sensor pode ter registrado o comportamento espectral de folhas de outras plantas que não foi mensurado a massa. O coeficiente de determinação do índice de área foliar (Figura 16) também apresentou valores inferiores, o que pode estar justificado pela mesma situação ocorrida da biomassa foliar, como discutido acima. Kross *et al.* (2015) encontraram coeficiente de determinação alta em modelo exponencial para o índice de área foliar do milho.

Os coeficientes de determinação entre a produtividade e o NDVI e NDVIa podem ser visualizados na Figura 17.




Figura 17: Modelos desenvolvidos para produtividade com NDVI e NDVIa e suas respectivas significâncias. ^{ns}não significativo no nível de probabilidade $p \leq 0,05$; ^{***} significativo no nível de probabilidade $p \leq 0,001$.

Para o NDVI, foi utilizado o último dia do imageamento, 61 DAE, o qual apresentou R^2 abaixo de 0,1 e valor-p acima de 5%, ou seja, não foi significativo estatisticamente. Este resultado pode estar relacionado com o fato de o milho não ter atingido o pico máximo do NDVI, assim como o NDVI do dia não ser tão bem

representativo para produtividade, uma vez que foram percebidas diversas variações do NDVI em cada dia do imageamento em função, principalmente, do manejo da cultura, como discutido anteriormente. Assim, fica invalidado estimar produtividade da cultura do milho utilizando o NDVI derivado do sensor Mapir *Survey 3* aos 61 DAE. Ainda, na Figura 17, observa-se o comportamento superior do NDVIa em relação ao NDVI. O NDVIa apresentou coeficiente de determinação equivalente a 0,89 e significância nas análises de regressão.

O NDVIa representa o acúmulo dos valores de NDVI ao longo do tempo, ou seja, concentra toda variabilidade do NDVI ao longo do ciclo em um único valor. Daí a possível explicação do modelo com NDVIa apresentar bom coeficiente de determinação e ser significativo estatisticamente. De acordo com Lai *et al.* (2018), o NDVIa reflete melhor o ciclo fenológico de uma cultura em comparação com uma abordagem de data única. Esta metodologia tem se demonstrada bastante útil na aplicação das culturas do milho (KROSS *et al.*, 2015), no trigo (LAI *et al.*, 2018), em pastagem (PRINGLE, 2013) e na identificação de tipos de culturas (ZHENG, BAOJUAN *et al.*, 2015).

3.4 Validação dos modelos para os parâmetros biofísicos

Nas Tabela 4 e Tabela 5 estão disponíveis as validações dos modelos desenvolvidos para os parâmetros biofísicos.

As métricas mostram que, para BIO_T , BIO_C , BIO_F , IAF e AP, os modelos que utilizam NDVI do dia apresentaram comportamento melhor em relação ao NDVIa. Assim, as estimativas destes parâmetros podem ser realizadas por estes modelos.

Tabela 2. Validação dos modelos para o NDVI.

Parâmetros	μ_o	σ_o	RMSE	MAE	MBE	R^2
BIO_T ($g\ m^{-2}$)	782,56	155,78	69,62	54,31	22,45	0,90
BIO_C ($g\ m^{-2}$)	430,67	91,66	40,24	35,18	14,88	0,90
BIO_F ($g\ m^{-2}$)	279,41	43,40	36,47	29,37	0,96	0,50
IAF ($m\ m^{-1}$)	4,51	0,34	0,28	0,21	-0,02	0,54
AP (m)	1,67	0,29	0,09	0,07	0,03	0,96

μ_o = média amostral; σ_o = desvio padrão amostral

Tabela 3. Validação dos modelos para o NDVIa.

Parâmetros	μ_o	σ_o	RMSE	MAE	MBE	R ²
BIO _T (g m ⁻²)	776,79	155,78	84,48	71,61	9,22	0,84
BIO _C (g m ⁻²)	428,57	91,66	46,58	41,27	9,58	0,86
BIO _F (g m ⁻²)	277,77	43,40	39,87	30,89	-0,54	0,38
IAF (m m ⁻¹)	4,50	0,34	0,30	0,23	-0,04	0,49
AP (m)	1,67	0,29	0,10	0,09	-0,03	0,97

Para o NDVI, a BIO_T, BIO_C, BIO_F e AP superestimaram os dados observados, enquanto o IAF obteve leve subestimativa. Já o NDVIa superestimou apenas para BIO_T, BIO_C, ao passo em que subestimou para os demais parâmetros.

Podem ser visualizadas na Tabela 6 as métricas para estimativa da produtividade utilizando o NDVI do dia e o NDVI acumulado, o qual teve média observada de 1390,94 g m⁻² com desvio padrão de 213,71 g m⁻².

Tabela 4. Validação dos modelos de produtividade.

Modelos	RMSE (g m ⁻²)	MAE (g m ⁻²)	MBE (g m ⁻²)	R ²
NDVIa	134,00	125,74	53,42	0.63
NDVI	194,10	186,74	41,70	0.10

Como apresentado na Figura 17, o NDVI do dia não obteve resultados satisfatórios, sendo observado que as métricas demonstraram erros elevados nas suas estimativas. O NDVIa apresentou erros menores, sendo pertinente a estimativa da cultura agrícola com o sensor RGNIR Mapir *Survey* 3 até os 61 DAE com o NDVI acumulado.

4 Conclusão

A partir do um experimento montado em campo, foi possível analisar a eficiência de um sensor RGNIR a bordo de um VANT para monitorar a cultura, bem como desenvolver modelos que permitem prever parâmetros agrônômicos.

Os resultados mostraram que este sensor apresenta empecilhos quanto ao ruído da banda do infravermelho próximo na banda do vermelho, porém, o problema foi

atenuado quando se aplicou a calibração radiométrica com painéis de calibração de baixo custo.

O NDVI calculado pelo sensor RGNIR permitiu visualizar diferenciação espacial e temporal ao longo do crescimento da cultura, principalmente quanto à infestação de plantas daninhas na área, demonstrando ser uma ferramenta importante para averiguar os possíveis problemas no desenvolvimento da cultura. O NDVI mostrou-se sensível a influências climáticas, principalmente à radiação solar e ao manejo empregado na cultura, destacando o efeito do herbicida e da adubação nitrogenada.

A partir do NDVI e dos dados de campo foram gerados modelos aplicáveis para prever os parâmetros agronômicos. O modelo desenvolvido para estimar a biomassa total apresentou significância estatística com NDVI e NDVIa. A biomassa total permite analisar o grau de desenvolvimento da cultura, bem como estimar a produção de biomassa da lavoura.

A predição da produtividade de grãos a 14% de umidade pelo NDVI do dia foi insatisfatória por este sensor. De forma contrária, o modelo que envolve o NDVI acumulado apresentou-se satisfatório com R^2 de 0,63 e RMSE de 134,00 g m⁻², sendo possível de aplicação para estimar o rendimento em grão da lavoura de milho.

Capítulo 2

Evapotranspiração e biomassa da cultura do milho a partir do sensor RGNIR a bordo de um VANT

Resumo

O sensoriamento remoto utilizando-se o veículo aéreo não tripulado (VANT) é um importante auxílio na agricultura de precisão, principalmente a agricultura de média e pequena escala. Através das imagens adquiridas pelo VANT, é possível estimar, aplicando índices de vegetação, a reposição de água necessária para manter a cultura em conforto hídrico, bem como prever a produtividade da lavoura antes da colheita. O objetivo deste estudo foi estimar, utilizando-se os índices de vegetação NDVI e SAVI, a evapotranspiração e a biomassa da cultura do milho a partir de um sensor RGNIR, embarcado em um VANT. Para isto, foram capturadas 15 conjuntos de imagens ao longo de 61 dias do monitoramento da cultura do milho. Todas as imagens capturadas passaram por correções geométricas e radiométricas, e posterior computo dos índices de vegetação e estimativa do K_{cb} utilizando os mesmos. Com propósito de avaliar estatisticamente os modelos, foram coletadas, em campo, 54 plantas, que tiveram suas massas mensuradas e cada planta georreferenciada. O K_{cb} derivado do SAVI mostrou-se mais sensível que o modelo utilizando o NDVI, apresentando os maiores valores de K_e e K_s . A transpiração real da cultura utilizando K_{cb} derivado do SAVI apresentou R^2 de 0,74, com a biomassa observada, enquanto a transpiração derivada do NDVI apresentou R^2 de 0,69. A biomassa estimada utilizando a fração evaporativa pelo modelo do SAVI apresentou, em relação à biomassa observada, RMSE de 0,092 kg m⁻² e R^2 de 0,76, enquanto, ao utilizar a fração evaporativa pelo NDVI, o RMSE foi de 0,104 kg m⁻² e R^2 de 0,74. O sensor RGNIR a bordo de um VANT revelou-se satisfatório para estimar a demanda hídrica e a biomassa da cultura ao utilizar os modelos empíricos do K_{cb} derivado dos índices de vegetação.

Palavras-chave: sensoriamento remoto, índice de vegetação, K_{cb} , balanço hídrico

1 Introdução

A agricultura moderna enfrenta os grandes desafios de alimentar a população mundial, que cresce em ritmo acelerado, uma vez que necessita ser rigorosamente sustentável em termos ambientais (ZHENG, HUIFANG *et al.*, 2019). Espera-se, para o ano de 2050, o dobro da produção de alimentos para abastecer o elevado contingente estimado para os anos seguintes (TILMAN *et al.*, 2011). O milho, por ser um dos alimentos mais consumidos no mundo, está entre as principais culturas para elevar a disponibilidade de alimentos. Segundo Tilman *et al.* (2011), entre os anos de 2016 a 2050, esta cultura precisará aumentar sua produção em 35% para atender a demanda populacional. Contudo, para atingir essa meta, serão necessárias inovações tecnológicas em diversas áreas dentro da agricultura, aliadas à expansão da agricultura de precisão nas médias e pequenas propriedades.

A agricultura de precisão, segundo Mulla (2013), pode ser conceituada como o sistema agrícola em que o manejo na lavoura é realizado no local exato, na intensidade correta e no tempo certo. Para isso, é necessário o auxílio de técnicas que possam monitorar a lavoura constantemente, mas que seja eficaz operacionalmente e viável economicamente. Assim, enquadram-se nesses requisitos as técnicas de sensoriamento remoto como ferramentas no auxílio da agricultura de precisão (HUNT; DAUGHTRY, 2018). O sensoriamento remoto consiste em utilizar sensores que captam informação da lavoura em forma ondas eletromagnéticas (TUNCA *et al.*, 2018). Porém, estes sensores, para um amplo campo de visada, devem estar embarcados em plataformas orbitais (satélites) ou suborbitais (aviões, VANT- veículos aéreos não tripulados).

Em nível suborbital, os aviões de pequeno porte foram bastante utilizados para embarcar os sensores, apesar de apresentarem elevado custo de investimento. Em função do custo, os aviões estão sendo substituído pelos VANT's, que são pequenas aeronaves que não necessitam de piloto a bordo e são versáteis quanto ao transporte e pilotagem. Os VANT's têm como vantagem a possibilidade de capturar imagens em alta resolução espacial e temporal, permitindo realizar monitoramento agrícola com grandes riquezas de detalhes (MANFREDA *et al.*, 2018), tornando-se, pois, importantes ferramentas para a agricultura de precisão em grandes e, principalmente, em médias e pequenas áreas agrícola.

Os sensores possíveis de serem embarcados nos VANT's podem ser: RGNIR (*red-green-near infrared*); multiespectrais; hiperspectrais e termiais. Os três últimos

são sensores que aprestam custo financeiro de aquisição elevado quando comparados às RGNIR's, porém, possuem mais bandas espectrais e capturam cada banda por uma única lente óptica, exceto o termal que apresenta uma única banda (MAES; STEPPE, 2019).

Os sensores RGNIR's são equipamentos com custo financeiro de aquisição menor que os sensores supracitados. No entanto, apresentam limitações ao número de bandas, bem como probabilidade de ocorrer ruído entre elas, uma vez que este tipo de sensor possui apenas uma lente óptica. O RGNIR é um sensor RGB (*red-green-blue*) modificado, e essa modificação se dá pela remoção do bloqueador do comprimento de onda do infravermelho próximo e adição de um filtro para o mesmo comprimento de onda (NIJLAND *et al.*, 2014; RABATEL; GORRETTA; LABBÉ, 2014), sendo, muitas vezes, removida a banda respectiva ao comprimento de onda do azul. Com isso, este sensor passa a capturar três informações espectrais da lavoura nos comprimentos de onda do vermelho, verde e infravermelho próximo. Dessa forma, utilizando tais sensores a bordo de um VANT, é possível, a partir das informações espectrais da lavoura agrícola, modelar e quantificar diversos parâmetros relacionados ao crescimento e ao desenvolvimento do cultivo, bem como avaliar as condições hídricas.

O estado hídrico da lavoura via sensoriamento remoto pode ser quantificado aplicando índices de vegetação que consistem em uma relação espectral. Estudos consolidados demonstram uma relação confiável entre os índices de vegetação (IV) e o coeficiente basal da cultura (K_{cb}) (BAUSCH; NEALE, 1987; CAMPOS *et al.*, 2018; ER-RAKI *et al.*, 2007; GONZÁLEZ-DUGO; MATEOS, 2008). Esta relação para solo exposto, segundo Campos *et al.* (2018), geralmente, tem o valor de K_{cb} próximo a zero, não obstante o valor de K_{cb} será máximo quando a cultura atingir o máximo vigor vegetativo, ou seja, IV será máximo.

A partir do K_{cb} e da evapotranspiração de referência, é possível estimar a demanda hídrica potencial da cultura no campo (ALLEN *et al.*, 1998). Ainda, conhecendo os parâmetros físicos-hídricos do solo, é possível calcular quanto de água está sendo perdido para a atmosfera pelo processo físico da evaporação. A transpiração, somada à evaporação, resulta no processo da evapotranspiração da cultura, parâmetro importante para saber a reposição necessária de água ao sistema agrícola. É possível, também, conhecendo os processos evapotranspirativos associados a índices de vegetação e dados climáticos, determinar o incremento diário de biomassa seca acima

do solo de uma lavoura, uma vez que a transpiração tem relação com a entrada de CO₂ na planta, que é convertida pelo processo fotossintético em biomassa (LI *et al.*, 2018).

Sabendo-se que a água é um importante insumo para agricultura e que o sensoriamento remoto é um importante aliado da agricultura de precisão, o presente trabalho teve como objetivo aplicar e avaliar, a partir de um sensor RGNIR a bordo de um VANT, modelos empíricos para estimar a evapotranspiração real da cultura pela normalização dos índices de vegetação NDVI (Índice de Vegetação por Diferença Normalizada) e SAVI (Índice de Vegetação Ajustado ao Solo), bem como aplicar, a partir dos parâmetros evapotranspirométricos, modelos para estimar a biomassa da cultura do milho.

2 Material e Métodos

2.1 Descrição da área de estudo

Conduziu-se esta pesquisa em uma área equivalente a 2.600 m², locada no campo experimental “Prof. Diogo Alves de Mello”, Vale da Agronomia, que pertence à Universidade Federal de Viçosa, no município de Viçosa, estado Minas Gerais, Brasil (Figura 1) O solo dessa área é classificado como Latossolo Amarelo, profundo e textura argila (EMBRAPA, 2018).

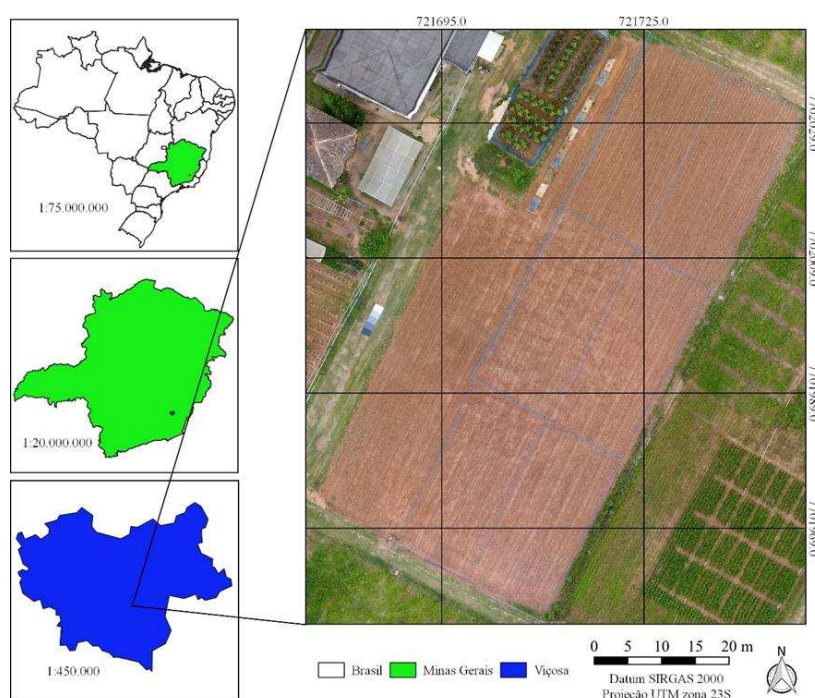


Figura 1: Localização da área de estudo em relação ao município de Viçosa, estado de Minas Gerais e ao Brasil.

De acordo com a série histórica climática disponibilizada pela estação meteorológica Viçosa-A510 (OMM: 86824), pertencente ao Instituto Nacional de Meteorologia (INMET), a região apresenta temperatura média máxima de 26,7 °C e temperatura média mínima de 15,4 °C. A umidade relativa média anual é de 81,1% e a precipitação média anual acumulada é de 1250 mm (INMET, 2018). Esta estação meteorológica está locada a menos de 1000 m da área de estudo, com uma diferença de cota positiva de 37 m. O município de Viçosa possui clima subtropical úmido, classificado, segundo a metodologia de Köppen, como Cwa (ALVARES *et al.*, 2013).

2.2 Implantação e manejo da cultura

A área foi arada e gradeada e, posteriormente, a cultura do milho (*Zea mays* L.) foi semeada. A semeadura do milho (*Zea mays* L.) foi realizada no dia 15 de outubro de 2018 com espaçamento de 0,28 m entre as plantas e 0,50 m entre as linhas. A emergência das plântulas iniciou-se cinco dias após a semeadura. Ao completar 25 dias após a emergência (DAE), foi realizado o controle químico das plantas daninhas com uso do ingrediente ativo glifosato na dosagem de 0,89 kg ha⁻¹. Realizou-se duas adubações, uma junto a semeadura com 300 kg ha⁻¹ do formulado NPK 8:28:16 e outra aos 38 DAE com adubação nitrogenada via ureia na recomendação de 300 kg ha⁻¹.

2.3 Coleta de dados em campo

Em campo foram coletadas 54 plantas de milho nos períodos de 46, 52 e 59 DAE para quantificar a biomassa seca total acima do solo. Após a coleta, as plantas foram acondicionadas, separadamente, em sacolas de papel e levadas à estufa de circulação forçada de ar, a uma temperatura de 70 °C em um período de 72 h. Após decorrido o tempo, as amostras foram retiradas e a massa das plantas foi mensurada. Cada planta coletada foi georreferenciada com um receptor GNSS (*Global Navigation Satellite System*) RTK (*Real Time Kinematic*) Topmap T10. Esse receptor foi utilizado por possuir alta precisão e no intuito de conhecer o local exato de cada planta coletada.

2.4 Aquisição de dados aéreos

O imageamento aéreo iniciou-se a partir dos 03 DAE, com término aos 61 DAE (Tabela 1), sempre as 10 horas (UTC/GMT - 3). O fim do imageamento aos 61 DAE foi em função das condições técnicas do equipamento.

Tabela 1. Datas da aquisição das imagens e as condições climáticas no horário do imageamento.

Data	DAE	T (°C)	U _R (%)	V _v (m s ⁻¹)	R _s (MJ m ⁻² d ⁻¹)	ET _o (mm)	P _d (mm)	P _{d-1} (mm)	P _{ei} (mm)
22/10/2018	3	19,65	71,50	2,70	16,42	3,41	0,00	0,00	21,2
31/10/2018	12	23,95	71,00	2,50	17,53	3,83	0,00	1,60	42,6
02/11/2018	14	24,4	73,50	1,30	22,46	4,38	0,20	13,20	13,4
07/11/2018	19	24,25	67,00	2,00	14,88	3,29	0,00	0,200	32
12/11/2018	24	24,75	67,50	1,90	20,25	4,34	0,00	0,00	67,6
15/11/2018	27	24,6	73,00	3,50	18,56	4,31	7,00	0,00	7,00
23/11/2018	35	22,9	71,00	3,30	17,10	4,02	0,00	0,00	139,8
28/11/2018	40	22,95	70,50	1,10	24,38	4,73	0,20	10,20	13,8
30/11/2018	42	24,25	68,50	3,20	23,76	5,05	5,00	0,00	5,00
04/12/2018	46	22,75	74,00	0,90	14,67	3,15	0,00	3,40	29,4
10/12/2018	52	19,8	80,50	0,20	15,07	3,19	0,20	1,80	64,2
12/12/2018	54	24,15	67,50	2,00	26,74	5,49	0,00	0,00	0,00
14/12/2018	56	25,35	63,50	2,50	29,65	6,07	0,00	0,00	0,00
17/12/2018	59	25,20	66,50	3,00	28,70	5,95	0,00	0,00	0,00
19/19/2018	61	27,75	60,50	2,50	27,05	5,8	0,00	0,00	0,00

DAE = Dias após a emergência; T = Temperatura média do ar; UR = Umidade relativa média; V_v = velocidade média do vento; R_s = Radiação solar incidente; ET_o = evapotranspiração de referência; P = Precipitação; P_{i-1} = Precipitação do dia anterior; P_{ei} = Precipitação entre os imageamento.

As imagens aéreas foram capturadas a partir de um sensor RGNIR com três bandas (verde, vermelho e infravermelho próximo) a bordo de um VANT modelo DJI *Phantom 4* (Figura 2), fabricado pela DJI *Innovations*. A linha *Phantom* está categorizada dentro dos veículos multirrotores (YANG, HYUNSOO *et al.*, 2017), possuindo autonomia de voo de aproximadamente 30 minutos.




Figura 2: VANT utilizado para realização da pesquisa: a) vista lateral do equipamento; b) vista frontal do equipamento destacando o sensor Mapir *Survey3*.

O sensor (Figura 2b) é de fabricação da empresa Mapir e o modelo do equipamento é a *Survey 3*. Segundo a fabricante, o sensor possui três filtros tipo Bayer para diferenciar os comprimentos de onda no vermelho, verde e infravermelho próximo. A faixa do comprimento de onda para os respectivos filtros são 640 - 680 nm, 525 - 575 nm e 820 - 880 nm, nessa ordem (MAPIR, 2019). O sensor pode capturar imagens com resolução de 12 Megapixels (4000 x 3000 pixels), em intervalos de tempo que são ajustáveis - que no caso do presente estudo foi de 2 segundos. Essas imagens eram armazenadas automaticamente em um microcartão de memória, em formato jpeg, com resolução radiométrica de 8 bits.

Para que as imagens mantivessem sempre o padrão de captura, a fim de não interferir nos resultados, elaborou-se o plano de voo com o auxílio do aplicativo DroneDeploy. O plano de voo foi configurado para altitude de 50 metros com sobreposição frontal de 85%, lateral de 75% e velocidade fixada em 3 m s^{-1} (Figura 3). O tempo percorrido pelo VANT na área de estudo foi de, aproximadamente, 3 minutos. Posterior à aquisição das imagens, as mesmas foram mosaicadas para formar uma única imagem abrangendo toda área de estudo. O processo de mosaicagem das imagens foi realizado no software *Agisoft PhotoScan*, gerando arquivo em formato GeoTIF com as 3 bandas. As imagens exportadas desse software apresentavam pixels de 2,5 cm de resolução espacial. Para que as informações de campo fossem estimadas a partir do sensor, foi necessário proceder com a correção geométrica e conversão radiométrica das imagens para posterior computo dos índices de vegetação.

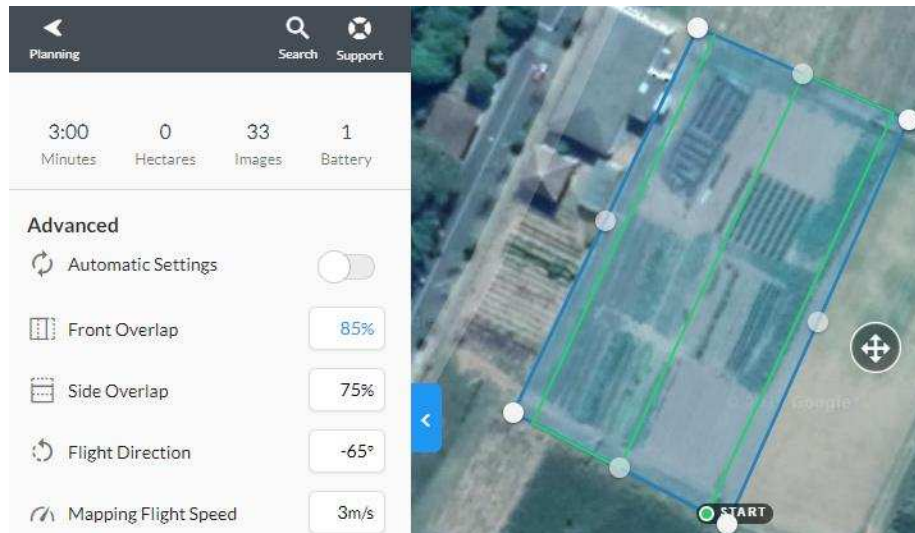


Figura 3: Configuração do plano de voo para o monitoramento.

2.5 Processamento dos dados

De modo resumido, a Figura 4 aborda todo o procedimento metodológico adotado na realização desta pesquisa.

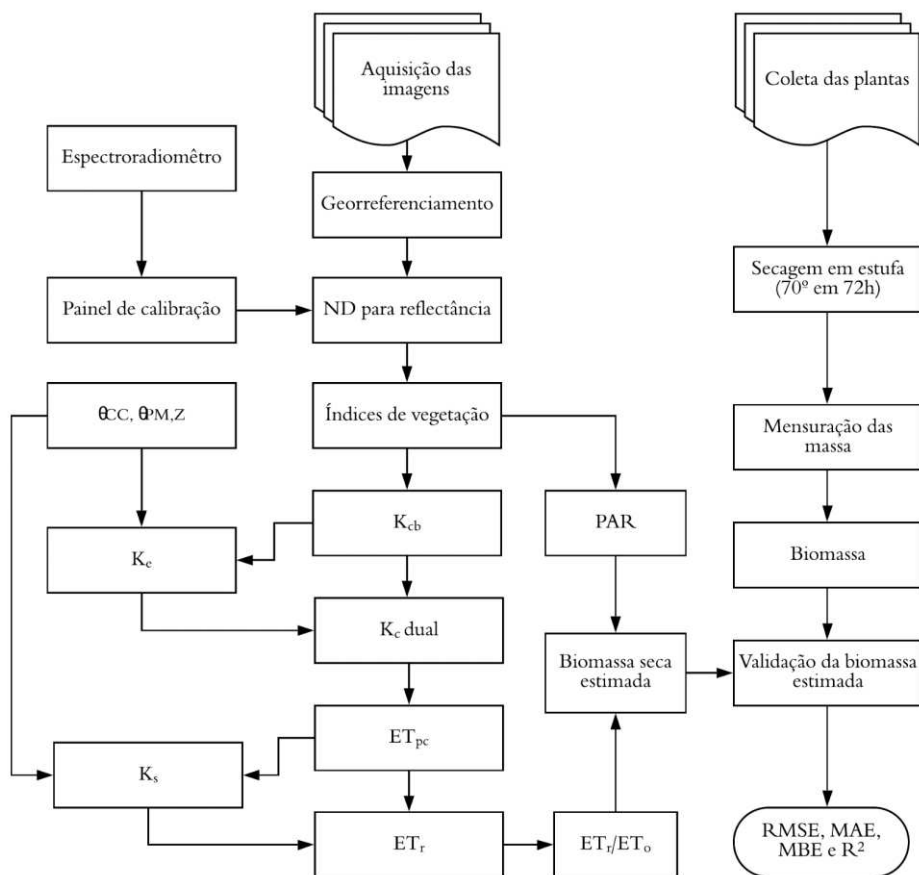


Figura 4: Fluxograma dos procedimentos metodológicos adotado neste estudo.

2.5.1 Correção geométrica

O Sensor MAPIR *survey* 3 utiliza um receptor GNSS que possibilita capturar as imagens georreferenciadas. Contudo, o receptor é de baixa precisão e gera erros de deslocamento aleatórios em cada imageamento, necessitando assim, de um georreferenciamento acurado. Para tanto, instalou-se, na área destinada ao experimento, oito piquetes de madeira, os quais tiveram as coordenadas obtidas pelo receptor GNSS RTK Topmap T10. Esses piquetes serviram de ponto de controle para o georreferenciamento. A Correção geométrica foi realizada nas imagens após o processo de mosaicagem.

2.5.2 Conversão de ND para valores físicos

O sensor embarcado ao VANT disponibiliza imagens em valores de números digitais (ND) que, por sua vez, correspondem a uma estratificação singular da energia para cada uma das bandas referentes ao comprimento de onda da radiação eletromagnética que chega até o sensor. Assim, é necessário converter os valores de ND para valores de reflectância, processo que foi denominado de conversão de ND para valores físicos. Para tanto, foram utilizados cinco painéis em diferentes escalas de cinza em todos os voos realizados. Esses painéis eram colocados sempre nas proximidades da área de estudo. A reflectância de cada um dos painéis foi pré-determinada em laboratório, sendo os painéis do tipo napa - material que possui composição à base de PVC e parte têxtil de poliéster.

As cores utilizadas em cada painel foram: preta; cinza escuro; cinza intermediário cinza claro; e branco, com dimensões de 1,5 m² cada um. A reflectância de cada painel foi determinada com auxílio do espectrorradiômetro modelo *FieldSpec* 4 da empresa ASD. Esse aparelho abrange os comprimentos de onda de 300 a 2500 nm com resolução espectral de 1 nm. Contudo, foram extraídas dos painéis as médias das reflectâncias correspondentes apenas das bandas do sensor a bordo do VANT.

Com o auxílio do software QGIS® 2.18 (QGIS DEVELOPMENT TEAM, 2016), as imagens mosaicadas foram recortadas para a área referente a cada painel. Posteriormente, foram extraídas as médias dos ND das bandas do vermelho e infravermelho, correspondentes a cada painel, e procedeu-se com uma regressão para determinar uma equação de conversão entre os ND dos painéis, quantificado pelo sensor

com as médias da reflectância dos mesmos, obtidas pelo espectrorradiômetro. Ressalta-se que esse procedimento foi realizado em cada imageamento realizado.

Esta conversão teve como objetivo analisar temporalmente as imagens e realizar operações algébricas entre as bandas do sensor.

2.5.3 Índices de vegetação (IV)

Para analisar o comportamento da cultura ao longo do ciclo, bem como aplicar modelos de evapotranspiração da cultura do milho, foram utilizados os IV NDVI e SAVI, sendo esses dois comumente aplicados na agricultura e dependentes apenas das reflectâncias do vermelho e infravermelho próximo.

2.5.3.1 *Índice de Vegetação por Diferença Normalizada (NDVI)*

O Índice de Vegetação por Diferença Normalizada (NDVI) foi desenvolvido por Rouse et al. (1974), e tem como vantagem monitorar as mudanças sazonais que ocorrem durante o desenvolvimento da vegetação. Este é determinado pela relação entre a reflectância do infravermelho próximo (ρ_{IVP}) e o vermelho (ρ_V), Equação 1.

$$NDVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V} \quad (1)$$

2.5.3.2 *Índice de Vegetação Ajustado ao Solo (SAVI)*

O SAVI (Equação 2) foi desenvolvido por Huete (1988) e consiste em uma modificação no NDVI como alternativa para minimizar o efeito do solo, efeitos da variabilidade, do tipo e densidade da vegetação.

$$SAVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V + L} * (1 + L) \quad (2)$$

em que L é um fator de ajuste do solo. Este fator varia em função da densidade do dossel, podendo ser adotado 0,25 a 1,0. Contudo, neste trabalho foi adotado 0,5 como recomendado por (HUETE, 1988) e aplicado em uma abordagem geral por García and

Pérez (2016) e Gilabert et al. (2002) e específico na cultura do milho por Zhang et al. (2019).

2.5.4 Evapotranspiração real da cultura a partir do IV

A evapotranspiração real da cultura (ET_r) é a soma da transpiração e da evaporação (Equação 3).

$$ET_r = T_r + E \quad (3)$$

em que T é a transpiração pela cultura (mm); e E é a evaporação da água presente em uma camada superficial do solo (mm).

A transpiração real (Equação 4) é um processo biofísico que consiste na perda de água pelos estômatos presentes nas folhas após terem sido envolvidos nos processos fisiológicos da planta, levando em consideração as condições de umidade do solo.

$$T_r = K_{cb} * K_s * ET_o \quad (4)$$

em que K_{cb} é o coeficiente basal da cultura; K_s é o coeficiente de estresse; ET_o é a evapotranspiração de referência calculado a partir de dados meteorológicos pelo método da FAO-56 (ALLEN *et al.*, 1998).

A Evaporação (Equação 5), por sua vez, é um processo físico da perda de água presente no solo ou na superfície das plantas, na forma líquida para vapor.

$$E = K_e * ET_o \quad (5)$$

em que K_e é o coeficiente de evaporação.

2.5.4.1 K_{cb} estimado pelo IV

De acordo com Choudhury et al. (1994), existe uma relação exponencial entre o coeficiente de transpiração (T_c), disposto na Equação 6, com o IAF (índice de área foliar). Desta forma, quando o IAF for máximo, a cultura apresentará maior coeficiente

de transpiração. O T_c é descrito como a razão da transpiração em condições sem estresse pela evapotranspiração máxima da cultura quando a vegetação cobre totalmente o solo. Assim, o K_{cb} será dado pelo produto do máximo valor de K_{cb} (K_{cbmax}), valor tabelado (ALLEN *et al.*, 1998), e coeficiente de transpiração (Equação 7).

$$T_c = 1 - e^{-K \cdot IAF} \quad (6)$$

em que T_c é o coeficiente de transpiração; K é um coeficiente da arquitetura da folha e varia de 0,5 a 0,7; e IAF é o índice de área foliar.

$$K_{cb} = K_{cbmax} \cdot T_c \quad (7)$$

Visando o cálculo do coeficiente de transpiração a partir do IV, a Equação 6 foi reorganizada e o IV foi adicionado (Equação 8).

$$T_c = 1 - \left(\frac{IV_{max} - IV}{IV_{max} - IV_{min}} \right)^n \quad (8)$$

em que “n” corresponde à razão entre K/K' . K' é um coeficiente que varia na faixa de 0,5 a 0,7 e de 0,8 a 1,3 quando os índices de vegetação utilizados são SAVI e NDVI, nessa ordem (CHOUDHURY *et al.*, 1994).

Substituindo-se o T_c da Equação 7 pela Equação 8, tem-se o K_{cb} a partir do IV (Equação 9).

$$K_{cb} = K_{cbmax} \left[1 - \left(\frac{IV_{max} - IV}{IV_{max} - IV_{min}} \right)^n \right] \quad (9)$$

A Equação 9 é um modelo generalizado para determinar o K_{cb} da cultura a partir do IV.

Neste trabalho foram utilizados os IV da Equação 1 e 2 para determinar o K_{cb} da cultura do milho ao longo do seu crescimento. Para o NDVI, bastou substituir o IV da Equação 9 pelos valores de NDVI e assumindo valor médio de K e K' . Contudo, para o SAVI, a Equação 9 sofre modificação, como proposto por (CHOUDHURY *et al.*, 1994). Segundo esses autores, a razão de K e K' é igual a 1 quando se utiliza o IV

SAVI. Assim, o K_{cb} para o SAVI foi determinado pela Equação 10. O K_{cbmax} adotado para a cultura do milho foi de 1,15 (Allen et al., 1998).

$$K_{cb} = K_{cbmax} \left(\frac{SAVI - SAVI_{min}}{SAVI_{max} - SAVI_{min}} \right) \quad (10)$$

2.5.4.2 Coeficiente de evaporação (K_e)

Para quantificar o K_e foi necessário determinar o balanço diário da água no solo ao longo dos 61 dias em que a cultura foi monitorada. Coletou-se, na área de estudo, solo para mensurar a capacidade de campo em base volumétrica (θ_{CC}), ponto de murcha em base volumétrica (θ_{PM}) e densidade do solo (d_s). Esses parâmetros físicos-hídricos foram quantificados no laboratório de física do solo do Departamento de Engenharia Agrícola, na Universidade Federal de Viçosa. A umidade do solo na capacidade de campo e no ponto de murcha foi determinada a partir do extrator de Richards nos pontos de tensão de 0,3 bar e 1,5 bar, respectivamente. A densidade do solo foi determinada pela relação entre massa do solo, seco a 105 °C por 48 h, e volume de solo coletado. Assim, o solo da área de estudo apresentou θ_{CC} de 0,33 m³ m⁻³, θ_{PM} de 0,21 m³ m⁻³ e densidade de 1,2 kg m⁻³. A partir da θ_{CC} e θ_{PM} calculou-se a lâmina máxima de água que poderia ser evaporada como sugerido por Allen et al. (1998), utilizando 0,10 m da camada do solo sujeito à evaporação. Todo procedimento do balanço hídrico seguiu-se rigorosamente como descrito no boletim 56 publicado pela FAO (ALLEN *et al.*, 1998).

2.5.4.3 Coeficiente de estresse (K_s)

Assim como para o K_e , o K_s foi quantificado através do balanço diário de água no solo, porém, levando em consideração a profundidade ocupada pelo sistema radicular efetivo (Z_r). A umidade do solo na zona radicular efetiva é calculada pela depleção da umidade nessa zona (D_r). Quando a umidade do solo se encontra na capacidade de campo, a depleção na zona radicular efetiva é igualada a zero ($D_r=0$) e o coeficiente de estresse é 1 ($K_s = 1$), ou seja, a cultura nessa condição está em conforto hídrico. Quando a água é retirada do solo pelo processo de evapotranspiração, aumentará a depleção da umidade no mesmo. Não ocorrendo eventos de irrigação ou chuva, a depleção se iguala a AFA (água prontamente disponível) e, assim, inicia-se a

condição de estresse hídrico. Se essa condição se mantiver, a D_r ultrapassará a AFA ($D_r > AFA$) gerando condição de estresse suficientemente alto para limitar a evapotranspiração a valores menores que o seu potencial (ALLEN *et al.*, 1998).

Quando a $D_r > AFA$, o K_s será dado pela Equação 11.

$$K_s = \frac{ADT - D_r}{ADT - AFA} \frac{ADT - D_r}{(1-p) AFA} \quad (11)$$

onde ADT é a água disponível total na zona radicular do solo (mm) e p é fração da ADT que a planta pode extrair da zona radicular sem sofrer estresse hídrico ($D_r \geq AFA$).

O ADT é calculado pela profundidade diária de enraizamento da cultura (Z_r) e pela θ_{CC} e θ_{PM} (Equação 12)

$$ADT = 1000(\theta_{CC} - \theta_{PM})Z_r \quad (12)$$

A AFA foi calculada pela Equação 13

$$AFA = pADT \quad (13)$$

Segundo o boletim 56 da FAO (ALLEN *et al.*, 1998), o p para cultura do milho quando a ET potencial da cultura (ET_{pc}) for igual a 5 mm d^{-1} é 0,55. Quando a ET_{pc} for diferente de 5 mm d^{-1} , utiliza-se a Equação 14 para corrigir.

$$p = 0,55 + 0,04 (5 - ET_{pc}) \quad (14)$$

Após a finalização de todos os processos acima, foram determinadas a transpiração e a evapotranspiração real da cultura.

2.5.5 Estimativa do incremento diário da biomassa

Segundo Teixeira *et al.* (2009), a biomassa acumulada diária (BIO) corresponde ao acúmulo de matéria seca acima do solo a partir da conversão de energia solar de ondas curtas, fotossinteticamente ativas e absorvidas (APAR) pela clorofila, em biomassa.

O incremento diário foi determinado por unidade de área seguindo o modelo desenvolvido por Monteith (1972), de acordo com a Equação 15.

$$\text{BIO} = \varepsilon_{\max} \cdot E_f \cdot \text{APAR} \cdot 0,864 \quad (15)$$

em que: BIO é a biomassa seca em $\text{kg ha}^{-1} \text{ d}^{-1}$; ε_{\max} é a máxima eficiência no uso de radiação, sendo $3,5 \text{ g MJ}^{-1}$ para a cultura do milho (BASTIAANSEN; ALI, 2003); E_f a fração evaporativa, APAR é a radiação fotossinteticamente ativa absorvida (W m^{-2}), e 0,864 corresponde à conversão de unidade.

A fração evaporativa foi substituída pela razão entre evapotranspiração real da cultura e evapotranspiração de referência por alguns autores (COAGUILA *et al.*, 2017; TEIXEIRA; FREITAS LEIVAS, 2017), o que também foi adotado neste trabalho.

A APAR foi obtida pelo produto entre NDVI e radiação solar incidente (R_s) (ASRAR; MYNENI; CHOUDHURY, 1992; HATFIELD; ASRAR; KANEMASU, 1984; MORAN; MAAS; PINTER, 1995), de acordo com a Equação 16.

$$\text{APAR} = (1,26 \cdot \text{NDVI} - 0,16) \cdot (0,48 \cdot R_s) \quad (16)$$

No intuito de comparar estatisticamente a biomassa estimada pelos modelos acima e a biomassa observada em campo, estabeleceu-se, a partir das coordenadas geográficas de cada planta coletada, um raio de 1 metro do ponto georreferenciado, a partir do qual foi gerada uma área circular representativa de cada planta coletada de $3,14 \text{ m}^2$. Desta área foi extraída a média do incremento da biomassa em cada dia do imageamento até as datas de coletas das plantas. Posteriormente, foram acumulados os valores da biomassa acumulada diária em função do tempo, chegando-se ao valor de biomassa acumulado total da planta.

2.6 Validação da biomassa estimada

A validação, por intermédio das medidas de biomassa, visto que esse foi um parâmetro medido em campo, foi realizada com intuito de verificar a confiabilidade dos modelos de evapotranspiração (ET) estimado pelos IV, uma vez que não foi possível mensurar a ET em campo durante o período de execução do experimento.

Para as comparações estatísticas entre biomassa estimada e observada, foram aplicadas as métricas estatísticas da Equação 17, 18, 18 e 20 para quantificar a relação e o erro entre a biomassa mensurada em campo com a biomassa estimada pelas imagens do VANT.

$$R^2 = \frac{[\sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O})]^2}{[\sum_{i=1}^n (P_i - \bar{P})^2][\sum_{i=1}^n (O_i - \bar{O})^2]} \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (18)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (19)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (20)$$

em que: P_i é valor predito pelo modelo; O_i é valor observado; \bar{P} é valor médio pelo modelo; \bar{O} é valor médio observado e n é número de amostra.

3 Resultados e Discussão

3.1 K_{cb} derivado dos IV's

Os valores médios dos índices de vegetação (IV's) NDVI e SAVI podem ser visualizados na Figura 5. Nota-se que os IV's aumentam ao longo do tempo, ou seja, acompanhando o crescimento da planta.

O NDVI apresenta valores superiores aos valores do SAVI em função do coeficiente L de atenuação do brilho do solo presente na metodologia do SAVI. Para ambos os índices, observa-se que entre 03 a 27 DAE houve maior variabilidade espacial, notado pelo maior intervalo entre o primeiro e terceiro quartil dos *boxplots*. Tal situação ocorreu em função da elevada infestação de plantas daninhas na área experimental, associado ao fato de a cultura ainda não cobrir totalmente área cultivada. Dez dias após o controle químico a variabilidade é reduzida e apenas a as plantas de

milho é presente na área, fato que pode ser notado pelo menor intervalo entre o primeiro e terceiro quartil dos *boxplots* a partir dos 35 DAE.

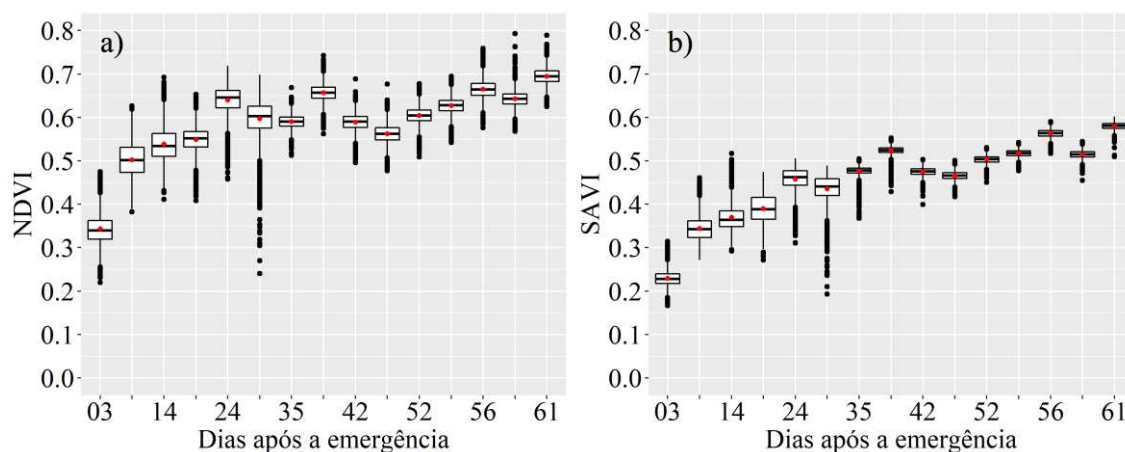


Figura 5: Estatística descritiva da variabilidade temporal e espacial da cultura do milho pelo NDVI (a) e SAVI (b).

Para o NDVI, o máximo valor registrado foi de 0,69 e SAVI de 0,58 - ambos aos 61 DAE. Zhang *et al.* (2019) encontraram utilizando sensor MicaSense Red Edge a bordo de um VANT, os valores máximos de NDVI e SAVI para cultura do milho aos 75 DAE, sendo estes iguais a 0,85 e 0,65, respectivamente. Para o NDVI, Toureiro *et al.* (2017), utilizando imagens do Landsat 5, encontraram valor máximo de 0,80 aos 85 DAS (dias após a semeadura) na cultura do milho. Já Taghvaeian *et al.* (2012) ao utilizar sensores terrestre encontraram, para o SAVI, valor máximo de 0,69, afirmando que nesse momento o milho cobre totalmente o solo.

Na Figura 6 estão presentes os valores médios do K_{cb} (coeficiente basal da cultura), K_e (coeficiente de evaporação), K_c dual (coeficiente duplo de cultivo) e K_s (coeficiente de estresse) da cultura do milho em cada dia do imageamento. Como observado na Figura 5, o IV tende ao aumento com o crescimento da cultura. Assim, os valores de K_{cb} derivados desses índices tendem também a aumentar (Figura 6a) acompanhando o crescimento dos IV's. Contudo, é observada discrepância com o K_{cb} determinado pelo modelo empírico do SAVI e NDVI. Tal fato pode estar relacionado ao coeficiente "n" aplicado ao modelo empírico de determinação do K_{cb} pelo NDVI proposto por (CHOU DHURY *et al.*, 1994), enquanto o SAVI é isento a esse coeficiente.

Estudos utilizando K_{cb} derivado do NDVI têm demonstrado boa relação linear com coeficiente de determinação acima de 0,80 entre K_{cb} e NDVI (BAUSCH; NEALE,

1987; TOUREIRO *et al.*, 2017). Da mesma forma, foi observado neste trabalho linearidade entres esses dois parâmetros, com R^2 de 0,81. Enquanto isso, SAVI e sua relação com K_{cb} apresentou resultado de R^2 de 0,99. Tal diferença entre os dois índices está relacionada ao coeficiente “n” discutido anteriormente. González-Dugo e Mateos (2008), ao aplicarem ambos os modelos empíricos para determinar o K_{cb} , observaram melhor resultado empregando o SAVI.

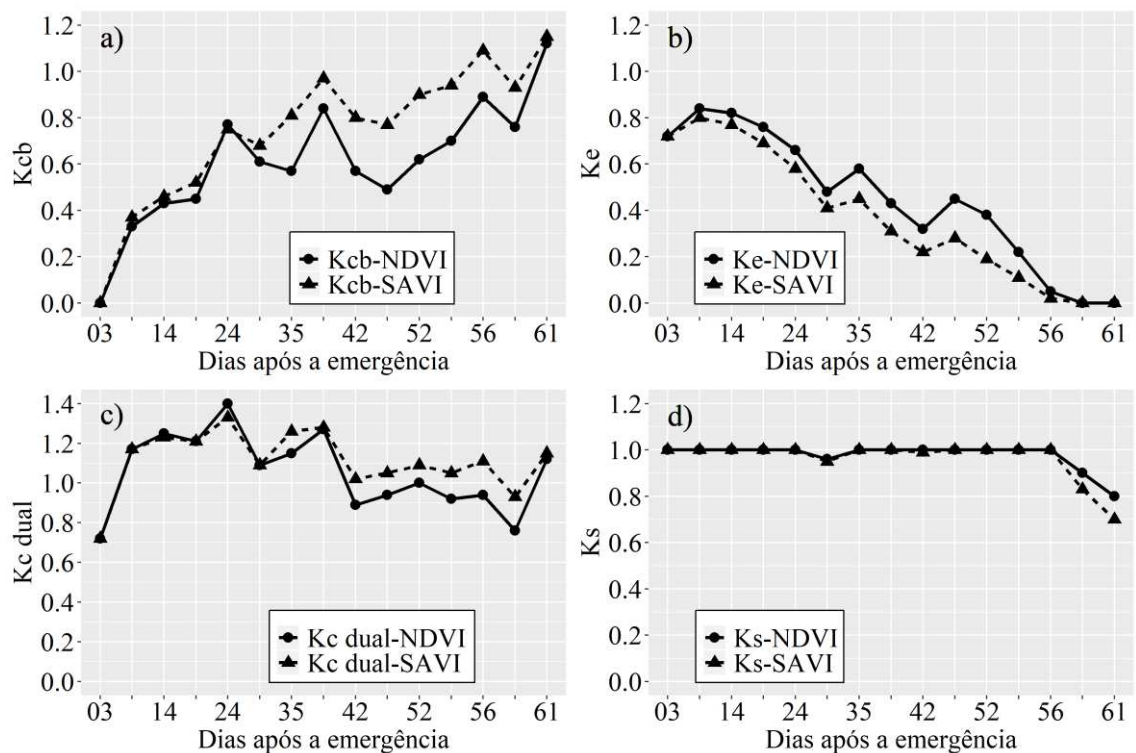


Figura 6: Valores médios do K_{cb} (a), K_e (b), K_c dual (c) e K_s (d) da cultura do milho ao longo dos 61 DAE.

Contrário ao valor de K_{cb} (Figura 6a), o K_e (Figura 6b) tende ao declínio à medida que a cultura vai crescendo e se desenvolvendo. Esta é a condição normal, pois esse coeficiente tem seu efeito reduzido com o aumento da cobertura vegetal. A expansão da área foliar intercepta a radiação solar, que chegaria até o solo, reduzindo o calor latente de vaporização. Conseqüentemente, com a menor energia interagindo com o solo úmido, haverá menor evaporação da água presente no solo. Outro fator que afeta o valor de K_e são as condições de umidade do solo, pois o solo mais úmido e mais exposto tem maior potencial de evaporação (ROSA; RAMOS; PEREIRA, 2016). Desta forma, nota-se, na Figura 6b, que a queda do K_e não é constante, apresentando variações nos valores proporcionados, principalmente, pelas precipitações (Tabela 1). Assim como o K_{cb} , os valores de K_e apresentam diferenças para o mesmo imageamento, o qual

está relacionado com o cálculo do mesmo, conforme proposto pelo boletim 56 da FAO (ALLEN *et al.*, 1998), que leva em consideração os valores de K_{cb} .

Na Figura 6c é apresentado o valor do K_c dual obtido pela soma entre K_{cb} e K_e . Durante todo o ciclo da cultura, os valores do K_c dual foram elevados, quase sempre próximo de 1,0. No início do ciclo, os valores do K_c dual são influenciados, principalmente, pelo alto valor do K_e em função da disponibilidade de água no solo e vai reduzindo com o crescimento do milho. Verifica-se, ainda na Figura 6c, que alguns valores de K_c dual ultrapassam o valor de 1,2. Em termos teóricos não deveria acontecer, uma vez que no cálculo do K_e adota-se o valor de 1,2 para o K_c máximo permitido para cultura do milho, segundo Allen *et al.* (1998). Assim, até o momento que o K_e estiver exercendo influência no K_c dual, o mesmo não deveria ultrapassar de 1,2 e quando deixasse de exercer influência não ultrapassar 1,15 (K_{cb} máximo para o milho). Contudo, em função da presença de plantas daninhas, o K_{cb} apresentou comportamento mais elevado no início do ciclo.

Durante o monitoramento foi registrada a precipitação pluviométrica total de 436,00 mm (Tabela 1) com ocorrência, em pelo menos uma vez na semana, até 52 DAE. A partir desse dia, até os 61 DAE não houve registro de precipitação. Assim, é de esperar, até os 52 DAE, que o solo mantivesse sempre próximo da capacidade de campo. A Figura 6d representa o coeficiente de estresse (K_s) na área experimental, em que foi observado leve estresse aos 27 DAE, proporcionado pela baixa precipitação (7 mm) em um intervalo de 3 dias. O K_s mostrou ligeiro declínio após os 56 DAE, se agravando aos 59 e 61 DAE. Como houve estiagem a partir dos 52 DAE, a água presente na zona do sistema radicular efetivo foi demandada para atmosfera pela evaporação e transpiração e, conseqüentemente, reduziu o teor de água disponível para a cultura, ou seja, aumentando a depleção da umidade fazendo com que a planta exercesse um gasto de energia maior para retirar a água quimicamente ligada ao solo. O modelo SAVI para determinar o K_{cb} foi mais sensível para o estresse hídrico, pois este modelo tende a apresentar o coeficiente basal maior influenciando, assim, a maior transpiração potencial da cultura.

3.1.1 Transpiração e evapotranspiração real da cultura do milho

A transpiração real da cultura (T_r) obtida pelo K_{cb} , derivada dos índices de vegetação, K_s e ET_o pode ser visualizada na Figura 7.

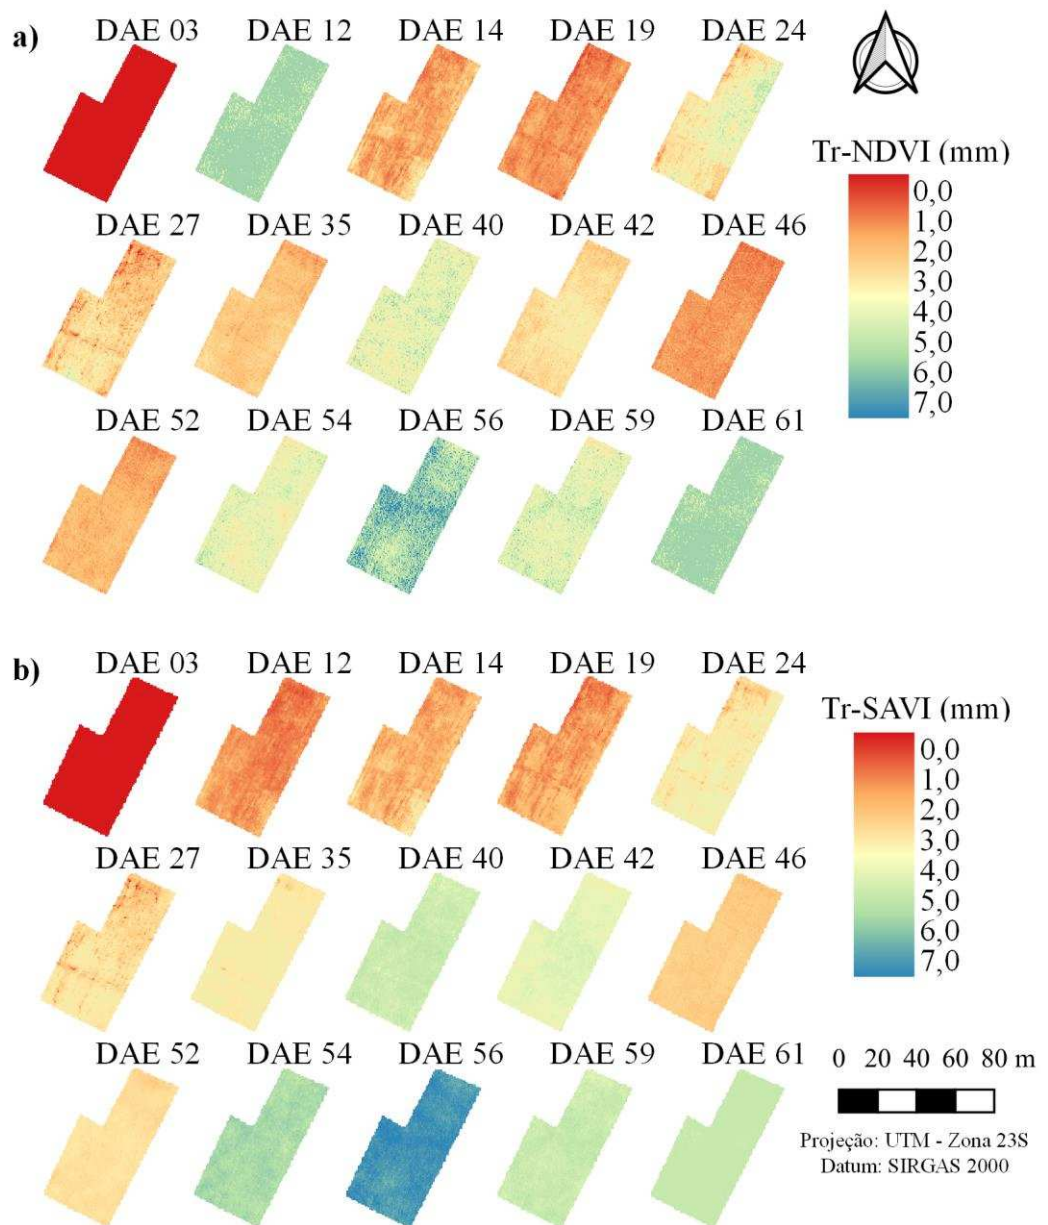


Figura 7: Transpiração real da cultura do milho determinada a partir das metodologias derivadas do: a) NDVI e b) SAVI (a).

Baixos valores podem ser notados no início do ciclo em função da menor densidade vegetal, ou seja, menor componente fotossintético e, conseqüentemente, menor transpiração. Aos 14 DAE podem ser observadas áreas isoladas na imagem com a transpiração em torno de 3 mm, proporcionada pela incidência das plantas daninhas presentes na área e pela ET_o de 4,58 mm (Tabela 1). No imageamento do dia 19, as plantas daninhas apresentam desenvolvimento mais avançado que no imageamento anterior contudo, a T_r foi menor em função da ET_o desse dia (3,29 mm). No dia 24 DAE é notada uma alta variabilidade da T_r , influenciada pelo alto desenvolvimento das plantas daninhas e pelo alto valor de ET_o .

Aos 25 DAE foi aplicado o herbicida. Após a aplicação, ocorreu redução na taxa de T_r causada pela influência do efeito tóxico dos herbicidas nas plantas daninhas. O princípio ativo glifosato impede a assimilação de CO_2 pela redução da condutância estomática e, conseqüentemente, a transpiração das plantas (NASCENTES *et al.*, 2017). Outro fator que influenciou a T_r neste dia foi o K_s (Figura 6d), que reduziu a transpiração da cultura pelo estresse hídrico. A partir dos 35 DAE, apenas a cultura do milho predominava na área, assim, a transpiração proveniente na área experimental era influenciada pela cultura e pelas condições ambientais durante o imageamento. Aos 46 e 52 DAE ocorreu uma brusca redução na T_r . Tal fato é atribuído à baixa radiação nesses dias, que reduziu a fotossíntese e a taxa de transpiração, além do baixo valor estimado de ET_o (Tabela 1). A imagem do dia 56 teve forte influência da ET_o (Tabela 1) e ausência de estresse hídrico, $K_s = 1,0$, (Figura 6d). Assim, aos 56 DAE, a cultura apresentou maior T_r . Para os dias 59 e 61, a transpiração da cultura foi limitada pelo estresse hídrico ocasionado pela estiagem. Assim, apesar da cultura estar com alto vigor vegetativo, os valores de ET_o estavam próximos de 6 mm (Tabela 1). Logo, a T_r foi inferior, em média, a 5,5 mm.

A T_r determinada pelo modelo empírico do K_{cb} derivado do NDVI apresentou maior variabilidade espacial do que o modelo empírico do K_{cb} derivado do SAVI. Tal afirmação pode ser observada na Figura 7 e Figura 8. Na Figura 8a é facilmente notado um maior intervalo entre o primeiro quartil e terceiro quartil em relação à Figura 8b. A discrepância entre os modelos está relacionada com o coeficiente “n” discutido anteriormente.

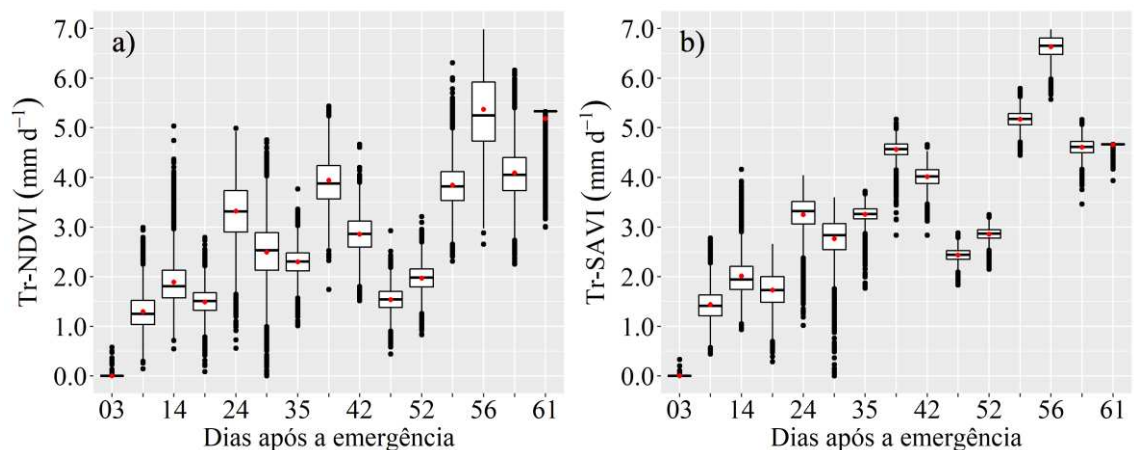


Figura 8: Estatística descritiva da transpiração real da cultura do milho pelo modelo derivado do NDVI (a) e SAVI (b).

A transpiração da cultura corresponde ao efluxo da água pelos estômatos e, simultaneamente, ao influxo de CO₂ para o processo fotossintético (KIM *et al.*, 2010). Diversos estudos demonstram que a elevação da entrada de CO₂ na planta de milho, até um certo limite, com água disponível no solo para a mesma, impacta positivamente no aumento da biomassa da cultura (DRISCOLL *et al.*, 2006; KANG *et al.*, 2002; LI *et al.*, 2018). Assim, é compreendido que o aumento da transpiração possibilita o acúmulo da biomassa seca.

Na Figura 9 é observada a relação entre a biomassa seca acima do solo das plantas de milho coletadas em campo, com a integração da transpiração real da cultura para os modelos derivados do NDVI (Figura 9a) e do SAVI (Figura 9b).

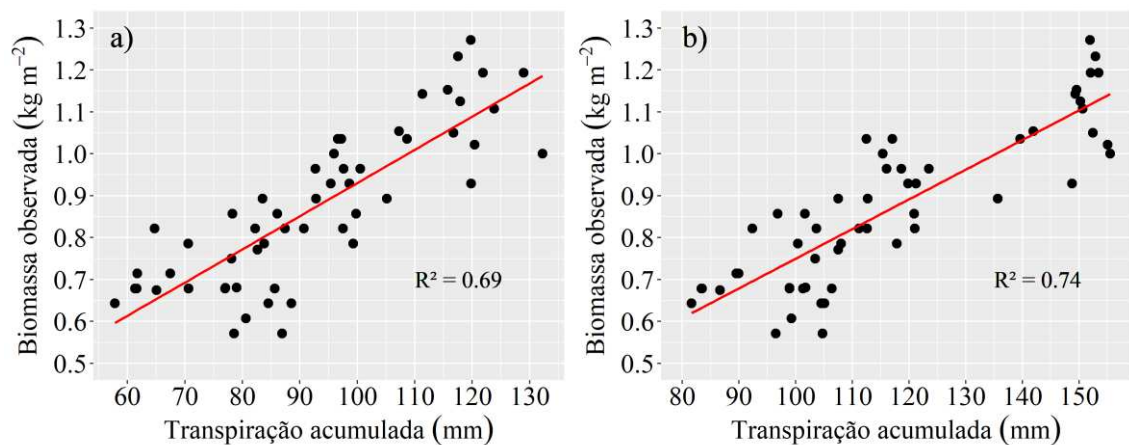


Figura 9: Regressão linear entre transpiração real acumulada (iT_r) da cultura pelo modelo derivado do NDVI (a) e SAVI (b) com a biomassa do milho.

É evidenciado, na Figura 9, que o modelo empírico baseado no SAVI apresentou maior capacidade preditiva quando comparado ao modelo baseado no NDVI, apresentando R² de 0,74 com a biomassa do milho. Campos *et al.* (2018b), utilizando valores de K_{cb} derivado do SAVI e corrigido pelos coeficientes de estresse hídrico e térmico, encontraram R² de 0,94 com a biomassa desta mesma cultura em área de sequeiro e 0,96 em áreas irrigadas, porém, utilizando imagens de satélites - diferente deste estudo que utiliza sensor de baixo custo. Já Twohey *et al.* (2019), mensurando a transpiração direta do milho em casa de vegetação, encontraram R² de 0,92 com a biomassa da mesma. Assim, pode-se afirmar que o modelo que deriva do SAVI apresenta melhor resultado com a biomassa da cultura, sendo possível, a partir deste índice, estimar a transpiração real da cultura com dados de um sensor de baixo custo financeiro embarcado em um VANT. Estes aspectos tornam-se importantes para

monitoramento agrícola e para quantificação da reposição de água na lavoura em pequenas propriedades que, geralmente, têm menor poder econômico.

A evapotranspiração real da cultura (ET_r), obtida pelos coeficientes da planta, solo e ET_0 é visualizada na Figura 10.

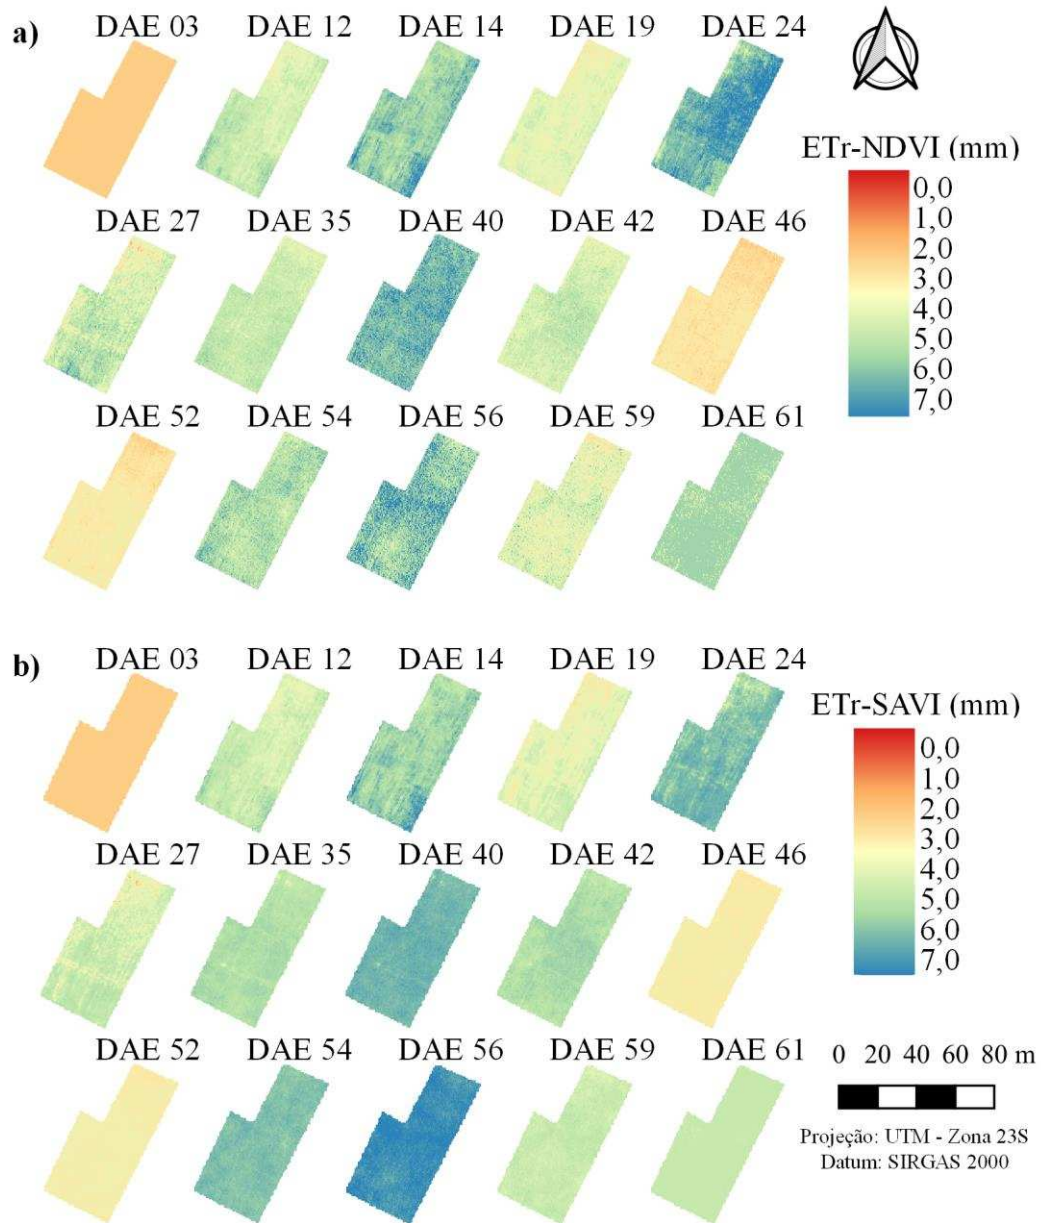


Figura 10: Evapotranspiração real da cultura pelo modelo empírico derivado do NDVI e SAVI.

Na Figura 10, a ET_r é alta no início do ciclo da cultura, contrariamente da T_r , principalmente quando o solo se encontra desprotegido da cobertura vegetal. Esses valores maiores da ET_r se devem à evaporação da água presente no solo. Isso indica que a transpiração foi baixa durante esses dias, e que a evaporação a partir da difusão de vapor de água presente na camada evaporante foi alta. Tais situações foram observadas

por Rosa *et al.* (2016) na cultura do milho. O mesmo comportamento da variabilidade espacial e temporal observado na T_r é também observado na ET_r . A influência do componente evaporativo é até aos 56 DAE (Figura 6b). A partir desse dia, a demanda hídrica da área é em função do componente transpirométrico, como discutido anteriormente.

A partir da Figura 11 é possível a melhor visualização da influência do K_c na demanda hídrica pela cultura na área experimental

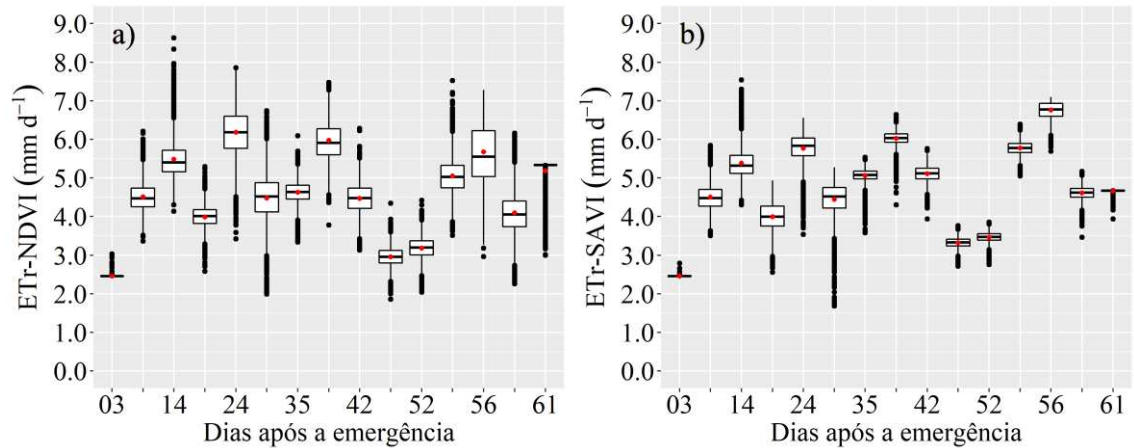


Figura 11: Estatística descritiva da evapotranspiração real da cultura derivado dos modelos do NDVI e SAVI.

Nota-se, nesta Figura, que a média dos boxplot já inicia-se acima de 2 mm, contrariamente à Figura 8. A metodologia baseada no K_c dual tende, normalmente, a ter maiores valores de evapotranspiração no início do ciclo da cultura, pois leva em consideração a quantificação de dois coeficientes isolados que se somam (ROSA; RAMOS; PEREIRA, 2016). De modo contrário, quando se quantificar o conteúdo de água utilizando o K_c *single*, tende a ser menor, posto que esse K_c representa o valor médio entre evaporação de água do solo e transpiração da cultura (FANDIÑO *et al.*, 2012).

3.2 Estimativa da biomassa seca acima do solo

Estimar a biomassa da cultura do milho através do sensoriamento remoto é importante para determinar a quantidade de grãos que será colhido, bem como a quantidade de silagem sem a necessidade da realização da amostragem em campo, pois esta última é onerosa economicamente (BATTUDE *et al.*, 2016; WANG, LI'AI *et al.*, 2016). Predizendo tais parâmetros, é possível estabelecer estratégias de logística,

armazenamento e lucro financeiro antes mesmo da colheita. Assim, aplicando a Equação 15, calculou-se o incremento diário da biomassa seca acima do solo utilizando a fração evaporativa derivada do NDVI e SAVI. Na Figura 12 pode ser observada a variação espacial e temporal do incremento diário da biomassa seca acima do solo.

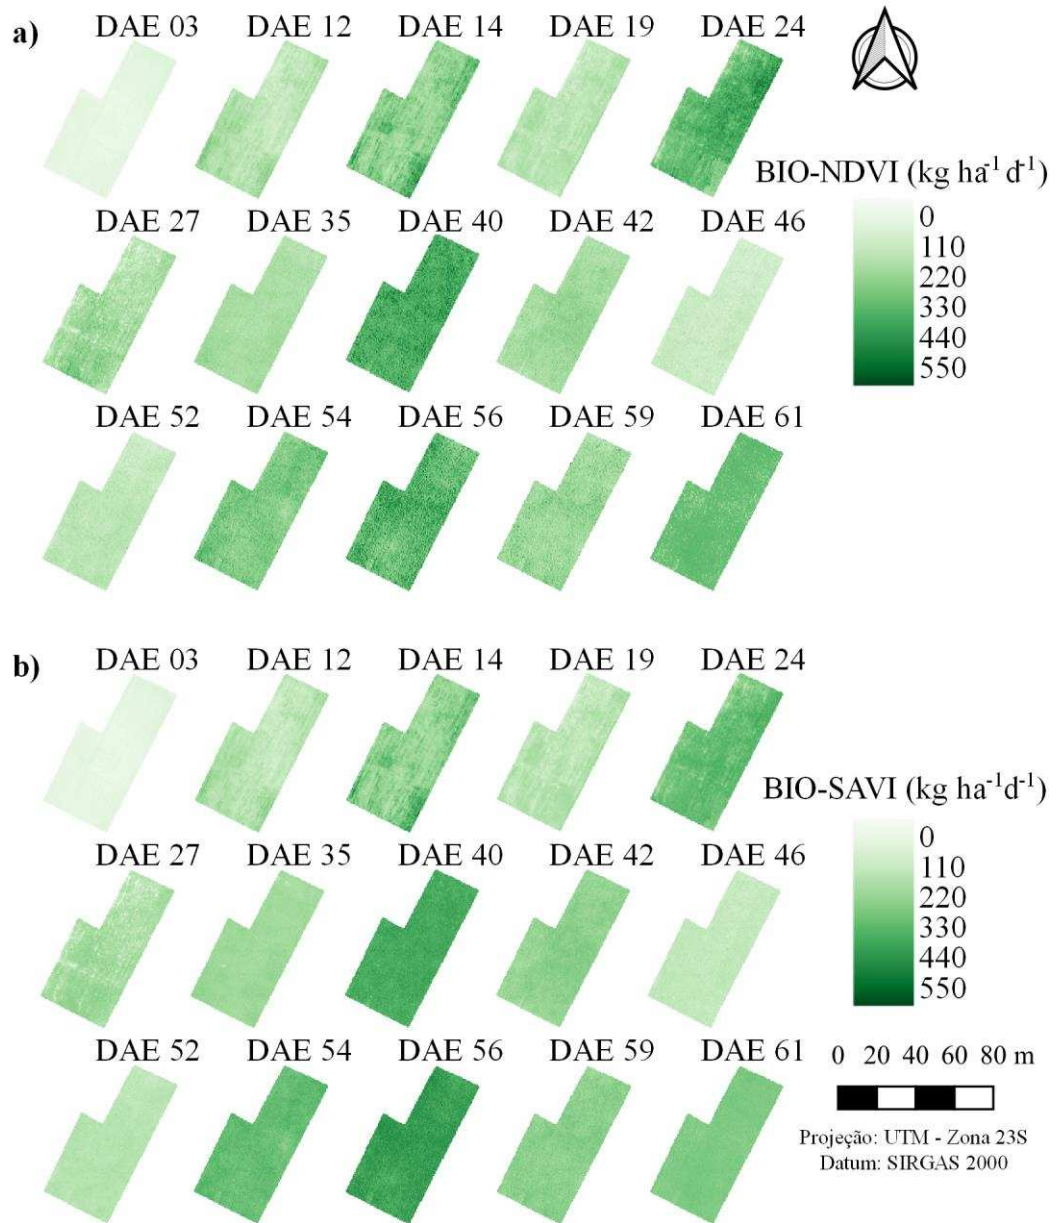


Figura 12: variabilidade espacial e temporal o incremento diário da biomassa seca acima do solo.

Nota-se, na Figura 12, que até o dia 24 DAE o incremento diário era proporcionado tanto pela cultura, ainda no início do crescimento, quanto pelas plantas daninhas presentes na área, como discutido anteriormente. Após o dia 27, o maior incremento diário ocorreu aos 40 e 56 DAE, e os menores incrementos ocorreram nos dias 46 e 52 DAE para ambos modelos. Nos dias 40 e 56, a radiação solar incidente

diária era equivalente a 23,38 e 29,25 MJ m⁻² d⁻¹ (Tabela 1), respectivamente. Enquanto nos dias 46 e 52, a radiação foi registrada no valor de 14,67, 15,07 MJ m⁻² d⁻¹ (Tabela 1), nessa ordem. Assim, percebe-se que a radiação proporcionou ganhos no incremento diário da biomassa.

A radiação solar é o parâmetro para calcular a radiação fotossinteticamente ativa estabelecida por Monteith (1972). Desta forma, quanto maior a radiação, maior será o incremento de biomassa. A radiação solar estimula a fotossíntese, a formação e o desenvolvimento de órgãos das plantas, bem como a produtividade (YANG, YUNSHAN *et al.*, 2019). Outro fator que influencia na produção da biomassa pelo modelo da Equação 15 é fração evaporativa, razão entre evapotranspiração real da cultura pela evapotranspiração de referência. No imageamento do dia 59 e 61, o coeficiente de estresse encontrava-se abaixo de 1 (Figura 6d), reduzindo a fração evaporativa e, conseqüentemente, reduzindo o incremento diário da biomassa. Alguns trabalhos recentes mostram a influência negativa do estresse hídrico na biomassa do milho (KILLI *et al.*, 2017; LIAO *et al.*, 2019; TROUT; DEJONGE, 2017; WANG, YAOSHENG *et al.*, 2017). Contudo, tal premissa já está consolidada na ciência.

Ao analisar a Figura 13, percebe-se o mesmo comportamento da variabilidade apresentada para ET_r (Figura 10), em que o primeiro e terceiro quartil da Figura 13a são superiores ao da Figura 13b. Tal ocorrência é explicada pela fração evaporativa de entrada no modelo advir da ET_r.

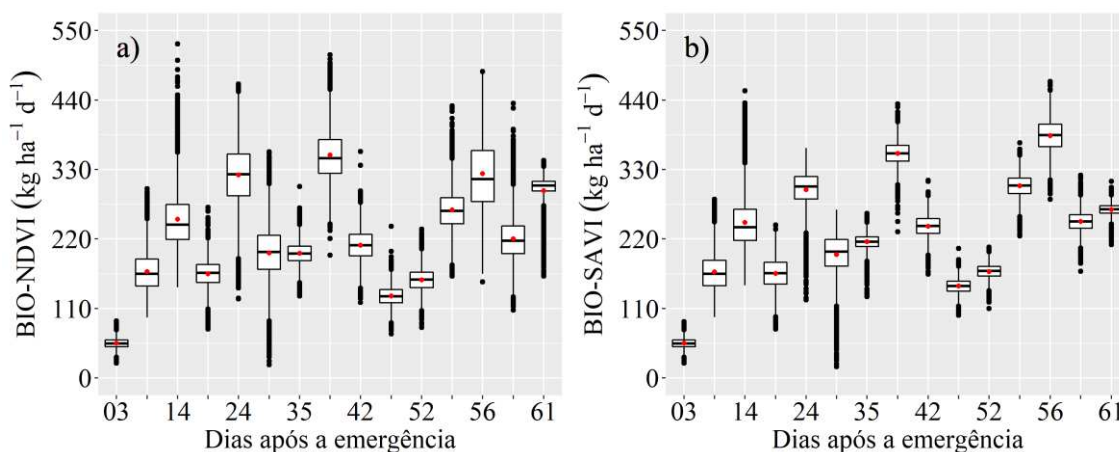


Figura 13: Estatística descritiva para o incremento diário da biomassa seca acima do solo pelos modelos derivado do NDVI (a) e SAVI (b).

No intuito de verificar qual modelo melhor se aproxima dos valores reais da biomassa, aplicou-se as métricas estatísticas, as quais podem ser visualizadas na Figura 14, juntamente com a regressão da biomassa predita versus a observada.

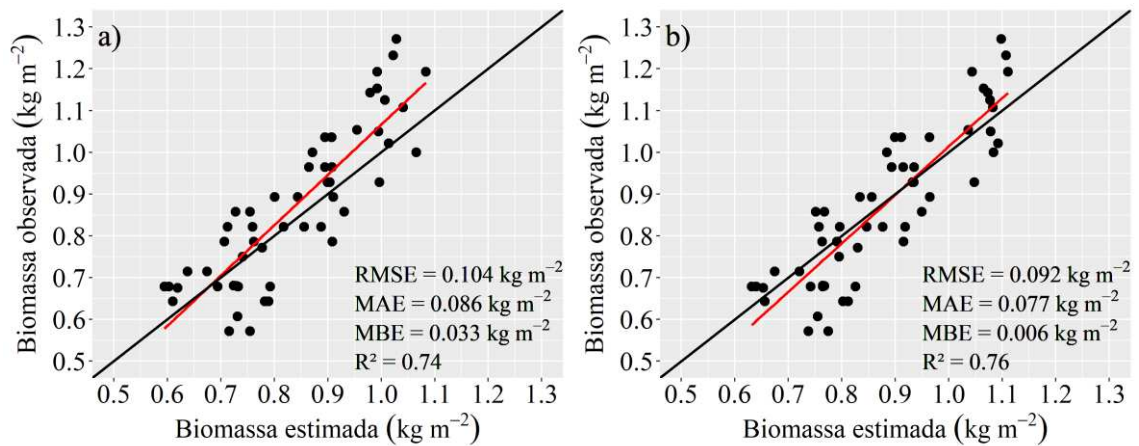


Figura 14: Avaliação estatística entre biomassa estimada pelos modelos derivado do NDVI (a) e SAVI (b) e biomassa mensurada em campo.

A biomassa estimada utilizando a fração evaporativa derivada do NDVI tem tendência de superestimar, em média, $0,033 \text{ kg m}^{-2}$ os valores verdadeiros e RMSE de $0,104 \text{ kg m}^{-2}$ e R^2 equivalente a $0,74$. Já a estimativa da biomassa utilizando a fração evaporativa pelo modelo do SAVI tendeu em superestimar, em média, $0,006 \text{ kg m}^{-2}$ com RMSE igual a $0,092 \text{ kg m}^{-2}$ e R^2 igual a $0,76$. Com isso, fica evidente o desempenho superior em estimar a biomassa seca acima do solo utilizando o modelo baseado no SAVI para calcular o K_{cb} .

Em termos gerais, a utilização de um sensor RGNIR para quantificar a fração evaporativa e aplicar o modelo para estimar o incremento da biomassa diária mostrou-se relativamente precisa. Assim, mostra-se uma interessante alternativa para predizer o teor da biomassa seca acima do solo que poderá ser produzida, sendo de grande importância ao pequeno agricultor.

4 Conclusão

A utilização de um sensor RGNIR embarcado em um VANT se mostrou satisfatória para identificar variabilidade espacial e temporal na cultura do milho. Este é um fato importante, pois esse equipamento possui baixo custo financeiro para aquisição. Ao aplicar os índices de vegetação NDVI e SAVI foi possível perceber perturbações na área experimental provocadas, principalmente, pela infestação das plantas daninhas, radiação solar e estresse hídrico.

O K_{cb} estimado pelos modelos empíricos baseados nos índices de vegetação pelo sensoriamento remoto aéreo demonstrou ser uma alternativa viável para o manejo da água nas lavouras agrícolas, sendo de grande interesse nas pequenas propriedades rurais, pelo custo financeiro e versatilidade no manuseio dos equipamentos.

A transpiração real da cultura utilizando o K_{cb} derivado do SAVI apresentou melhor relação com a biomassa coletada em campo em relação à transpiração calculada pelo K_{cb} derivado do NDVI. A abertura estomática é uma rota dupla, saída de água (transpiração) e entrada de dióxido de carbono. Quanto maior a quantidade de CO_2 , não excedendo o limite, que atravessa os estômatos, maior será a taxa fotossintética e, conseqüentemente, maior será sua biomassa. Assim, modelos de transpiração que melhor relacionam-se com a biomassa tendem a apresentar melhor acurácia.

As análises estatísticas revelaram que a biomassa estimada pelos modelos da fração evaporativa derivada dos índices de vegetação possui tendência em superestimar a biomassa medida em campo. A abordagem que estima a biomassa utilizando a fração evaporativa derivado do SAVI foi mais satisfatória, apresentando menores erros e melhor coeficiente de determinação em comparação ao modelo derivado do NDVI.

Conclusões gerais

A calibração radiométrica utilizando painéis de baixo custo mostrou-se necessária para atenuar o ruído pela banda do infravermelho próximo na banda do vermelho no sensor que possui apenas uma lente óptica e filtro para separar os comprimentos de onda.

A partir do NDVI computado pelas bandas do sensor de baixo custo RNGIR, foi possível identificar influências das plantas daninhas na área cultivada com milho, em que se notou elevada variabilidade espacial e temporal até o controle delas.

Os modelos preditivos dos parâmetros biofísicos da cultura do milho utilizando o NDVI do dia e NDVI acumulado revelou ser uma importante ferramenta para avaliar o grau de desenvolvimento e prever parâmetros da produção da cultura do milho. Para os parâmetros biomassa da folha, do caule e total os modelos preditivos baseados no NDVI do dia apresentaram melhores resultados estatísticos. Enquanto para estimar a produtividade de grãos a 14% da umidade o NDVI acumulado foi superior estatisticamente.

Aplicando os modelos baseado no NDVI e SAVI para estimar o K_{cb} e parâmetros relacionado ao solo e clima é possível definir zonas de manejo para reposição necessária da água na cultura do milho utilizando sensoriamento remoto de baixo custo. Para maior assertividade na reposição da água na lavoura deve-se utilizar a metodologia com a abordagem do SAVI, pois se mostrou mais confiável na estimativa da transpiração real da cultura.

Ao utilizar a abordagem da fração evaporativa e radiação fotossinteticamente ativa absorvida para estimar a biomassa seca acima do solo percebeu-se que é possível prever com confiança tal biomassa. E que, fração evaporativa derivado do SAVI apresentou menor erro na estimativa da biomassa seca do solo que a derivada pelo NDVI. O RMSE e R^2 para o SAVI foi, respectivamente, 0,092 kg m⁻² e 76, enquanto o RMSE e R^2 para NDVI foi 0,104 kg m⁻² e 0,74, nessa ordem.

Referências

ALLEN, R. G. *et al.* **Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56**. 9. ed. Food and Agriculture Organization of the United Nations, Rome: [s.n.], 1998. 300 p. .92-5-104219-5.

ALVARES, Clayton Alcarde *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift** v. 22, n. 6, p. 711–728 , 2013.

AMPATZIDIS, Yiannis; PARTEL, Victor. UAV-Based High Throughput Phenotyping in Citrus Utilizing Multispectral Imaging and Artificial Intelligence. **Remote Sensing** v. 11, n. 4, p. 410 , 2019.

ASKEW, Shawn D.; ASKEW, Whitnee B.; GOATLEY, J. Michael. Fineleaf Fescue Species and Variety Tolerance to Glyphosate. **Weed Technology** v. 33, n. 1, p. 185–191 , 2019.

ASRAR, G.; MYNENI, R. B.; CHOUDHURY, B. J. Spatial heterogeneity in vegetation canopies and remote sensing of absorbed photosynthetically active radiation: A modeling study. **Remote Sensing of Environment** v. 41, n. 2–3, p. 85–103 , 1992.

BASTIAANSEN, Wim G.M.; ALI, Samia. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan. **Agriculture, Ecosystems and Environment** v. 94, n. 3, p. 321–340 , mar. 2003. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0167880902000348>>.

BATTUDE, Marjorie *et al.* Estimating maize biomass and yield over large areas using high spatial and temporal resolution Sentinel-2 like remote sensing data. **Remote Sensing of Environment** v. 184, p. 668–681 , 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.07.030>>.

BAUSCH, W C; NEALE, Christopher M. U. Crop coefficients derived from reflected canopy radiation - a concept. **Transactions of the Asae** v. 30, n. 3, p. 703–709 , 1987.0001-2351.

BRENNER, Claire *et al.* Estimation of evapotranspiration of temperate grassland based on high-resolution thermal and visible range imagery from unmanned aerial systems. **International Journal of Remote Sensing** v. 39, n. 15–16, p. 5141–5174 , 2018. Disponível em: <<https://doi.org/10.1080/01431161.2018.1471550>>.

CAMPOS, Isidro *et al.* Water productivity and crop yield: A simplified remote sensing driven operational approach. **Agricultural and Forest Meteorology** v. 249, n. July, p. 501–511 , 2018.

CAO, Sen *et al.* Radiometric calibration assessments for UAS-borne multispectral cameras: Laboratory and field protocols. **ISPRS Journal of Photogrammetry and Remote Sensing** v. 149, n. January, p. 132–145 , 2019. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2019.01.016>>.

CHEN, Yun *et al.* Remote sensing for vegetation monitoring in carbon capture storage regions: A review. **Applied Energy** v. 240, n. November 2018, p. 312–326 , 2019. Disponível em: <<https://doi.org/10.1016/j.apenergy.2019.02.027>>.

CHENG, Tao *et al.* Spectroscopic estimation of biomass in canopy components of paddy rice using dry matter and chlorophyll indices. **Remote Sensing** v. 9, n. 4 , 2017.

CHOUDHURY, Bhaskar J. *et al.* Relations between evaporation coefficients and vegetation indices studied by model simulations. **Remote Sensing of Environment** v. 50, n. 1, p. 1–17 , 1994.

COAGUILA, Daniel N. *et al.* Water productivity using SAFER - Simple Algorithm for Evapotranspiration Retrieving in watershed. **Revista Brasileira de Engenharia Agrícola e Ambiental** v. 21, n. 8, p. 524–529 , 2017.

CONGEDO, Luca. Semi-Automatic Classification Plugin Documentation Release 4.8.0.1. **Release** v. 4, n. 0.1, p. 29 , 2016. Disponível em: <<https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-v4/latest/semiautomaticclassificationmanual-v4.pdf>>.

DENG, Lei *et al.* UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras. **ISPRS Journal of Photogrammetry and Remote Sensing** v. 146, n. March, p. 124–136 , 2018.

DRISCOLL, S. P. *et al.* Specification of adaxial and abaxial stomata, epidermal structure and photosynthesis to CO₂ enrichment in maize leaves. **Journal of Experimental Botany** v. 57, n. 2 SPEC. ISS., p. 381–390 , 2006.

EMBRAPA. **Sistema brasileiro de classificação de solos**. 5th. ed. [S.l: s.n.], 2018. 356 p. .9788570358004.

ER-RAKI, S. *et al.* Combining FAO-56 model and ground-based remote sensing to estimate water consumptions of wheat crops in a semi-arid region. **Agricultural**

Water Management v. 87, n. 1, p. 41–54 , 2007.

FANDIÑO, M. *et al.* Using the dual-K c approach to model evapotranspiration of Albariño vineyards (*Vitis vinifera* L. cv. Albariño) with consideration of active ground cover. **Agricultural Water Management** v. 112, p. 75–87 , 2012.

GARCÍA, Pilar; PÉREZ, Eugenia. Mapping of soil sealing by vegetation indexes and built-up index: A case study in Madrid (Spain). **Geoderma** v. 268, p. 100–107 , 2016. Disponível em: <<http://dx.doi.org/10.1016/j.geoderma.2016.01.012>>.

GILABERT, M. A. *et al.* A generalized soil-adjusted vegetation index. **Remote Sensing of Environment** v. 82, n. 2–3, p. 303–310 , 2002.

GONZÁLEZ-DUGO, M. P.; MATEOS, L. Spectral vegetation indices for benchmarking water productivity of irrigated cotton and sugarbeet crops. **Agricultural Water Management** v. 95, n. 1, p. 48–58 , 2008.

GOWRAVARAM, Saket *et al.* UAS-based Multispectral Remote Sensing and NDVI Calculation for Post Disaster Assessment. **2018 International Conference on Unmanned Aircraft Systems, ICUAS 2018** p. 684–691 , 2018.9781538613535.

GUAN, Senlin *et al.* Assessing Correlation of High-Resolution NDVI with Fertilizer Application Level and Yield of Rice and Wheat Crops using Small UAVs. **Remote Sensing** v. 11, n. 2, p. 112 , 2019.

HAN, Liang *et al.* Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. **Plant Methods** v. 15, n. 1, p. 1–19 , 2019.

HATFIELD, J. L.; ASRAR, G.; KANEMASU, E. T. Intercepted photosynthetically active radiation estimated by spectral reflectance. **Remote Sensing of Environment** v. 14, n. 1–3, p. 65–75 , 1984.

HERRERO-HUERTA, Mónica *et al.* Vineyard yield estimation by automatic 3D bunch modelling in field conditions. **Computers and Electronics in Agriculture** v. 110, p. 17–26 , 2015.

HIJMANS, Robert J *et al.* *Package ‘raster’ .R package.* [S.l.: s.n.] , 2015

HOFFMANN, Rodolfo. A agricultura familiar produz 70% dos alimentos consumidos no Brasil? **Segurança Alimentar e Nutricional** v. 21, n. 1, p. 417–421 , 2014. Disponível em: <<http://periodicos.bc.unicamp.br/ojs/index.php/san/article/view/1386>>.

HUANG, Yanbo *et al.* Assessment of soybean injury from glyphosate using airborne multispectral remote sensing. **Pest Management Science** v. 71, n. 4, p. 545–552 , 2015.

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment** v. 25, n. 3, p. 295–309 , ago. 1988. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/003442578890106X>>.

HUNT, E. Raymond; DAUGHTRY, Craig S.T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? **International Journal of Remote Sensing** v. 39, n. 15–16, p. 5345–5376 , 2018. Disponível em: <<https://doi.org/10.1080/01431161.2017.1410300>>.

INMET. *Normais climatológicas (1961-2018)*. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=clima/normaisClimatologicas>>. Acesso em: 5 mar. 2019.

IQBAL, Faheem; LUCIEER, Arko; BARRY, Karen. Simplified radiometric calibration for UAS-mounted multispectral sensor. **European Journal of Remote Sensing** v. 51, n. 1, p. 301–313 , 2018. Disponível em: <<https://doi.org/10.1080/22797254.2018.1432293>>.

JENSEN, John R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. [S.l.]: Parêntese, 2009. 598 p. .9788560507061.

KANG, Shaozhong *et al.* Benefits of CO₂ enrichment on crop plants are modified by soil water status. **Plant and Soil** v. 238, n. 1, p. 69–77 , 2002.

KHANAL, Sami; FULTON, John; SHEARER, Scott. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture** v. 139, p. 22–32 , 2017. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2017.05.001>>.

KILLI, Dilek *et al.* Adaptation to high temperature mitigates the impact of water deficit during combined heat and drought stress in C₃ sunflower and C₄ maize varieties with contrasting drought. p. 130–147 , 2017.

KIM, Tae-Houn *et al.* Guard Cell Signal Transduction Network: Advances in Understanding Abscisic Acid, CO₂ , and Ca²⁺ Signaling. **Annual Review of Plant Biology** v. 61, n. 1, p. 561–591 , 2010. Disponível em: <<http://www.annualreviews.org/doi/10.1146/annurev-arplant-042809-112226>>.

KROSS, Angela *et al.* Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. **International Journal of Applied Earth Observation and Geoinformation** v. 34, n. 1, p. 235–248 , 2015. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.08.002>>.

LAI, Y.R. *et al.* An empirical model for prediction of wheat yield, using time-integrated Landsat NDVI. **International Journal of Applied Earth Observation and Geoinformation** v. 72, n. July, p. 99–108 , 2018. Disponível em: <<https://doi.org/10.1016/j.jag.2018.07.013>>.

LE MAIRE, G.; FRANÇOIS, C.; DUFRÊNE, E. Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. **Remote Sensing of Environment** v. 89, n. 1, p. 1–28 , 2004.3316915567.

LI, Xiaojie *et al.* Deficit irrigation provokes more pronounced responses of maize photosynthesis and water productivity to elevated CO₂. **Agricultural Water Management** v. 195, p. 71–83 , 2018. Disponível em:

<<http://dx.doi.org/10.1016/j.agwat.2017.09.017>>.

LIAO, Chunhua *et al.* Using spatio-temporal fusion of Landsat-8 and MODIS data to derive phenology, biomass and yield estimates for corn and soybean. **Science of the Total Environment** v. 650, p. 1707–1721 , 2019. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2018.09.308>>.

LING, Bohua *et al.* Hyperspectral Analysis of Leaf Pigments and Nutritional Elements in Tallgrass Prairie Vegetation. **Frontiers in Plant Science** v. 10 , 2019.

MAES, Wouter H.; STEPPE, Kathy. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. **Trends in Plant Science** v. 24, n. 2, p. 152–164 , 2019. Disponível em: <<https://doi.org/10.1016/j.tplants.2018.11.007>>.

MANFREDA, Salvatore *et al.* *On the use of unmanned aerial systems for environmental monitoring* .**Remote Sensing**. [S.l.: s.n.]. Disponível em: <<http://www.mdpi.com/2072-4292/10/4/641>>. , 20 abr. 2018

MAPIR. *Mapir.pdf*. Disponível em: <<https://www.mapir.camera/products/survey3w-camera-red-green-nir-rgn-ndvi>>. Acesso em: 16 jan. 2019.

MONTEITH. Solar Radiation and Productivity in Tropical Ecosystems Author (s): J . L . Monteith Source : Journal of Applied Ecology , Vol . 9 , No . 3 (Dec . , 1972), pp . 747-766 Published by: British Ecological Society Stable URL : <http://www.jstor.org/stable/>. **Society** v. 9, n. 3, p. 747–766 , 1972.

MORAN, M. S.; MAAS, S. J.; PINTER, P. J. Combining remote sensing and modeling for estimating surface evaporation and biomass production. **Remote Sensing Reviews** v. 12, n. 3–4, p. 335–353 , 1995.

MOZGERIS, G. *et al.* Imaging from manned ultra-light and unmanned aerial vehicles for estimating properties of spring wheat. **Precision Agriculture** v. 19, n. 5, p. 876–894 , 16 out. 2018. Disponível em: <<https://doi.org/10.1007/s11119-018-9562-9>>.

MULLA, David J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering** v. 114, n. 4, p. 358–371 , 2013. Disponível em: <<http://dx.doi.org/10.1016/j.biosystemseng.2012.08.009>>.

NASCENTES, Renan F *et al.* Low doses of glyphosate enhance growth , CO₂ assimilation , stomatal conductance and transpiration in sugarcane and eucalyptus. n. August , 2017.

NÄSI, Roope *et al.* Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. **Remote Sensing** v. 7, n. 11, p. 15467–15493 , 2015.

NIJLAND, Wiebe *et al.* Monitoring plant condition and phenology using infrared sensitive consumer grade digital cameras. **Agricultural and Forest Meteorology** v. 184, p. 98–106 , 2014. Disponível em: <<http://dx.doi.org/10.1016/j.agrformet.2013.09.007>>.

PARK, Suyoung *et al.* Adaptive estimation of crop water stress in nectarine and peach orchards using high-resolution imagery from an unmanned aerial vehicle (UAV). **Remote Sensing** v. 9, n. 8 , 2017.

PETROPOULOS, George P.; IRELAND, Gareth; BARRETT, Brian. Surface soil moisture retrievals from remote sensing: Current status, products & future trends. **Physics and Chemistry of the Earth** v. 83–84, p. 36–56 , 2015. Disponível em: <<http://dx.doi.org/10.1016/j.pce.2015.02.009>>.

POBLETE, Tomas; ORTEGA-FARÍAS, Samuel; RYU, Dongryeol. Automatic Coregistration Algorithm to Remove Canopy Shaded Pixels in UAV-Borne Thermal Images to Improve the Estimation of Crop Water Stress Index of a Drip-Irrigated Cabernet Sauvignon Vineyard. **Sensors** v. 18, n. 2, p. 397 , 30 jan. 2018. Disponível em: <<http://www.mdpi.com/1424-8220/18/2/397>>.

PONZONI, Flavio Jorge; SHIMABUKURO, Yosio Edemir; KUPLICH, Tatiana Mora. **Sensoriamento remoto da vegetação**. 2. ed. [S.l.]: Oficina de Textos, 2012. .978-85-7975-053-3.

PRINGLE, M. J. Robust prediction of time-integrated NDVI. **International Journal of Remote Sensing** v. 34, n. 13, p. 4791–4811 , 2013. Disponível em: <<http://dx.doi.org/10.1080/01431161.2013.782117>>.

QGIS DEVELOPMENT TEAM. *QGIS geographic information system* .**Open Source Geospatial Foundation Project, Versão**. [S.l.: s.n.]. Disponível em: <<https://www.qgis.org>>. , 2016

R CORE TEAM. *R: A language and environment for statistical computing, version 3.3. 1. Vienna, Austria: R Foundation for Statistical Computing; 2016* . [S.l.: s.n.]. Disponível em: <<https://www.r-project.org/>>. , 2019

RABATEL, Gilles; GORRETTA, Nathalie; LABBÉ, Sylvain. Getting simultaneous red and near-infrared band data from a single digital camera for plant monitoring applications: Theoretical and practical study. **Biosystems Engineering** v. 117, n. 1, p. 2–14 , 2014.

REN, Hongrui; ZHOU, Guangsheng; ZHANG, Feng. Using negative soil adjustment factor in soil-adjusted vegetation index (SAVI) for aboveground living biomass estimation in arid grasslands. **Remote Sensing of Environment** v. 209, n. 79, p. 439–445 , 2018. Disponível em: <<https://doi.org/10.1016/j.rse.2018.02.068>>.

ROSA, R. D.; RAMOS, T. B.; PEREIRA, L. S. The dual Kc approach to assess maize and sweet sorghum transpiration and soil evaporation under saline conditions: Application of the SIMDualKc model. **Agricultural Water Management** v. 177, p. 77–94 , 2016. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2016.06.028>>.

ROUSE, R W H; HAAS, J A W; DEERING, D W. Monitoring Vegetation Systems in the Great Plains with ERTS. **Third Earth Resources Technology Satellite-1 Symposium- Volume I: Technical Presentations. NASA SP-351** p. 309–317 , 1974. Disponível em: <<https://ntrs.nasa.gov/search.jsp?R=19740022614>>.

TAGHVAEIAN, Saleh; CHÁVEZ, José L; HANSEN, Neil C. Infrared

Thermometry to Estimate Crop Water Stress Index and Water Use of Irrigated Maize in Northeastern Colorado. n. 122 mm, p. 3619–3637 , 2012.

TEIXEIRA *et al.* Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle São Francisco River basin, Brazil. Part B: Application to the regional scale. **Agricultural and Forest Meteorology** v. 149, n. 3–4, p. 477–490 , 2009.

TEIXEIRA; FREITAS LEIVAS, Janice. Determinação da Produtividade da Água com Imagens Landsat 8 na Região Semiárida do Brasil. **Conexões - Ciência e Tecnologia** v. 11, n. 1, p. 22–34 , 2017.

TILMAN, David *et al.* Global food demand and the sustainable intensification of agriculture. **Proceedings of the National Academy of Sciences** v. 108, n. 50, p. 20260–20264 , 13 dez. 2011. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22106295>>. Acesso em: 26 jun. 2019.

TOUREIRO, Célia *et al.* Irrigation management with remote sensing: Evaluating irrigation requirement for maize under Mediterranean climate condition. **Agricultural Water Management** v. 184, p. 211–220 , 2017. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2016.02.010>>.

TROUT, Thomas J; DEJONGE, Kendall C. Water productivity of maize in the US high plains. **Irrigation Science** v. 35, n. 3, p. 251–266 , 2017.0123456789.

TUNCA, Emre *et al.* Yield and leaf area index estimations for sunflower plants using unmanned aerial vehicle images. **Environmental monitoring and assessment** v. 190, n. 11, p. 682 , 2018.

TWOHEY, Robert J.; ROBERTS, Lucas M.; STUDER, Anthony J. Leaf stable carbon isotope composition reflects transpiration efficiency in Zea mays. **Plant Journal** v. 97, n. 3, p. 475–484 , 2019.

WANG, Li'ai *et al.* Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **Crop Journal** v. 4, n. 3, p. 212–219 , 2016. Disponível em: <<http://dx.doi.org/10.1016/j.cj.2016.01.008>>.

WANG, Yaosheng *et al.* Effect of irrigation regimes and nitrogen rates on water use efficiency and nitrogen uptake in maize. **Agricultural Water Management** v. 179, p. 271–276 , 2017. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2016.06.007>>.

YANG, Guijun *et al.* Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science** v. 8, n. June , 2017. Disponível em: <<http://journal.frontiersin.org/article/10.3389/fpls.2017.01111/full>>.

YANG, Hyunsoo *et al.* Multi-rotor drone tutorial: systems, mechanics, control and state estimation. **Intelligent Service Robotics** v. 10, n. 2, p. 79–93 , 2017.

YANG, Yunshan *et al.* Improving maize grain yield by matching maize growth and solar radiation. **Scientific Reports** v. 9, n. 1, p. 1–11 , 2019. Disponível em: <<http://dx.doi.org/10.1038/s41598-019-40081-z>>.

ZAMAN-ALLAH, M. *et al.* Unmanned aerial platform-based multi-spectral imaging for field phenotyping of maize. **Plant Methods** v. 11, n. 1, p. 1–10 , 2015.

ZARCO-TEJADA, P. J. *et al.* Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). **Agricultural and Forest Meteorology** v. 171–172, p. 281–294 , 2013. Disponível em: <<http://dx.doi.org/10.1016/j.agrformet.2012.12.013>>.

ZHANG, Liyuan *et al.* Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. **Remote Sensing** v. 11, n. 6, p. 605 , 13 mar. 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/6/605>>.

ZHANG, Yawei *et al.* A promising trend for field information collection: An air-ground multi-sensor monitoring system. **Information Processing in Agriculture** v. 5, n. 2, p. 224–233 , 2018. Disponível em: <<https://doi.org/10.1016/j.inpa.2018.02.002>>.1350126659.

ZHAO, Duli *et al.* Selection of Optimum Reflectance Ratios for Estimating Leaf Nitrogen and Chlorophyll Concentrations of Field-Grown Cotton. **Agronomy Journal** v. 97, n. 1, p. 89 , 2005. Disponível em: <<https://www.agronomy.org/publications/aj/abstracts/97/1/0089>>.

ZHENG, Baojuan *et al.* A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. **International Journal of Applied Earth Observation and Geoinformation** v. 34, n. 1, p. 103–112 , 2015. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.07.002>>.

ZHENG, Hengbiao *et al.* Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice. **Remote Sensing** v. 10, n. 6 , 2018.

ZHENG, Huifang *et al.* Irrigation leads to greater maize yield at higher water productivity and lower environmental costs: a global meta-analysis. **Agriculture, Ecosystems and Environment** v. 273, n. October 2018, p. 62–69 , 2019. Disponível em: <<https://doi.org/10.1016/j.agee.2018.12.009>>.

ZHOU, Guisu; YIN, Xinhua. ASSESSING NITROGEN NUTRITIONAL STATUS, BIOMASS AND YIELD OF COTTON WITH NDVI, SPAD AND PETIOLE SAP NITRATE CONCENTRATION. **Experimental Agriculture** v. 54, n. 4, p. 531–548 , 19 ago. 2018. Disponível em: <https://www.cambridge.org/core/product/identifier/S0014479717000229/type/journal_article>.0014479717000.