



Universidade Estadual de Campinas
Faculdade de Engenharia Agrícola



Fernanda Duarte Pereira

Análise da variabilidade espaço-temporal da cultura da soja por imagens de drone

Campinas

2020



Universidade Estadual de Campinas
Faculdade de Engenharia Agrícola



Fernanda Duarte Pereira

Análise da variabilidade espaço-temporal da cultura da soja por imagens de drone

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de Engenheira Agrícola à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

Orientador: Lucas Rios do Amaral

Campinas

2020

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

P414a Pereira, Fernanda Duarte, 1988-
Análise da variabilidade espaço-temporal da cultura da soja por imagens de drone / Fernanda Duarte Pereira. – Campinas, SP : [s.n.], 2021.

Orientador: Lucas Rios do Amaral.

Coorientador: Rodrigo Greggio de Freitas.

Trabalho de Conclusão de Curso (graduação) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Sensoriamento remoto. 2. Agricultura de precisão. 3. Aeronaves não tripuladas. I. Amaral, Lucas Rios do, 1985-. II. Freitas, Rodrigo Greggio de. III. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. IV. Título.

Informações adicionais complementares

Título em outro idioma: Analysis of spatio-temporal variability of soybean crop using drone images

Palavras-chave em inglês:

Remote sensing

Precision agriculture

Unmanned air vehicles

Titulação: Engenharia Agrícola

Banca examinadora:

Lucas Rios do Amaral [Orientador]

Gleyce Kelly Dantas Araújo Figueiredo

Mauricio Martello

Data de entrega do trabalho definitivo: 15-01-2021



Universidade Estadual de Campinas
Faculdade de Engenharia Agrícola



Fernanda Duarte Pereira

BANCA EXAMINADORA

.....
Prof. Dr. Lucas Rios do Amaral
Orientador

.....
Profa. Dra. Gleyce Kelly Dantas Araújo Figueiredo

.....
Doutorando Mauricio Martello

DEDICATÓRIA

Dedico à Luiza Passarella, minha bisavó e anjo mais velho. E a tua ausência fazendo silêncio em todo lugar. Anna Scolfaro, minha melhor avó e Ângela de Almeida, minha mãe.

AGRADECIMENTOS

Gostaria de agradecer primeiramente ao meu professor Lucas, pela orientação deste trabalho. Pelas ajudas, conselhos e paciência depositada ao longo desta pesquisa. Juntamente com o professor, agradeço também ao meu coorientador Rodrigo, que sempre estava disposto a me ouvir e me ajudar, inclusive aos finais de semana e no meio de uma pesquisa de campo. Agradeço também à Isabela, companheira de voos e aventuras em Araras; não teria sido tão divertido e menos cansativo sem você lá. Não deixaria de agradecer a todos que pertencem ao Laboratório de Agricultura de Precisão, e que também são grandes colegas e nunca mediram esforços para me ajudar. Agradeço de coração. Não poderia deixar de agradecer à UFSCar e ao Danilo, que gentilmente cederam o campo de análise para que essa pesquisa pudesse ser feita! Meu muito obrigada!

Agradeço também à minha família, que esteve presente em todo o meu aprendizado dentro e fora da faculdade. Que sempre entendeu minhas ausências para que eu me dedicasse à Unicamp, desde 2007. Que Deus esteja sempre por perto de vocês. Agradeço à turma FEAGRI 015 pelas amizades, aulas e auxílios quando necessário nestes mais de seis anos de convivência. Não poderia deixar de citar aqueles que foram primordiais: Bárbara, Isabela, Ana Flávia, Jones, Juliana, Gabi; vou levar pra vida toda. Aos amigos de fora da faculdade, que estão no meu coração e nas minhas pegadas deixadas durante todo o meu trajeto.

Por último, mas não menos importante, agradeço à Carol, pessoa que mais esteve presente durante esse meu amadurecimento. Muitas vezes foi amiga, mãe, companheira e esteve ao meu lado em muitos momentos importantes. Não deixaria de agradecer em nenhum momento pelo amor em mim depositado, e espero que esse mesmo amor tenha sido reformulado e sentido por você durante esses anos todos!

RESUMO

A soja é o produto agrícola mais produzido e exportado no país. Novas tecnologias, advindas da Agricultura de Precisão auxiliam a melhorar o manejo da área no campo, aumentando sua produtividade. A utilização de sensores embarcados em drones flexibiliza o intervalo entre as imagens obtidas, assim como a resolução espacial que pode ser definida em função da altura do voo. O objetivo do presente trabalho foi avaliar se o sensoriamento remoto com drone é capaz de identificar e quantificar a variabilidade espacial e temporal da soja, representada por parâmetros biofísicos coletados *in loco* (biomassa, altura e índice de área foliar). A área utilizada para o estudo está localizada no município de Araras/SP, com 6,4 hectares, utilizados para melhoramento da cana de açúcar e onde oportunamente é cultivada a soja. Para obtenção das imagens foi utilizado um drone quadricóptero com uma câmera multiespectral com cinco bandas espectrais (azul, verde, vermelho, infravermelho próximo e borda do vermelho). Foram realizadas cinco avaliações nos estádios fenológicos V9, V15, R3, R6 e R8, onde foram levantados parâmetros biofísicos da cultura e obtenção de imagens via drone. Foram calculados seis índices de vegetação (IV) para cada avaliação: NDVI, NDRE, IRVI, MPRI, NPCI e VARI. A variabilidade temporal da soja foi comprovada através dos gráficos apresentados ao longo das cinco avaliações, onde foi possível verificar o crescimento da cultura e sua senescência. Todos os índices de vegetação foram suficientes para identificar a variabilidade espaço-temporal da soja, com exceção, entre a segunda e quarta avaliação, onde houve saturação dos IVs NDVI, IRVI, MPRI e VARI. Todos utilizam a banda do vermelho, muito suscetível à saturação em casos de alta densidade vegetal. É necessário ter em mente outros IV's quando se quer mapear a variabilidade da soja nesses estádios fenológicos. Os índices que apresentaram saturação são indicados para acompanhamento em início e final do cultivo da soja, sendo então o limite para utilização o estágio fenológico V15 (obtido na segunda avaliação), podendo ser novamente utilizado no estágio R8 (última avaliação deste estudo, onde foi encontrada a fase final do desenvolvimento da soja). Uma alternativa a esses índices saturados é o NDRE, que se demonstrou capaz de acompanhar todo o desenvolvimento da soja, comprovando que o monitoramento espaço-temporal é possível através de imagens obtidas por um drone.

Palavras-chave: Sensoriamento remoto, Agricultura de precisão, Aeronaves não tripuladas.

ABSTRACT

Soybean is the most produced and exported agricultural product in Brazil. New technologies coming from Precision Agriculture help to improve the management of area in the field, increasing its productivity. The use of sensors embedded in drone facilities the interval between complementary images, does not depend on revisiting satellites and, when the flight height was configured, changes the spatial resolution. The objective of this study was to evaluate if remote sensing by drone is able to identify and quantify the spatial and temporal variability of soybean, represented by biophysical parameters collected in loco (biomass, height and leaf area index). The area used for the study is located in the city of Araras/SP, with 6.4 hectares, used for the improvement of sugar cane and where soy is opportunely cultivated. To obtain the images, a quadrotor drone with a five-band multispectral camera (blue, green, red, near infrared and infrared edge) was used. Five evaluations were carried out (growth stages V9, V15, R3, R6 and R8) in which biophysical parameters of the crop development were collected and images obtained via drone. Six vegetation indices were calculated for each assessment: NDVI, NDRE, IRVI, MPRI, NPCI and VARI. The temporal variability of soybean was proven through the indicators throughout the five evaluations, where it was possible to verify the growth of the crop and its senescence. For the spatial variability, all 6 vegetation indexes were sufficient, with the exception in the period between the second and the fourth evaluation where there was saturation of the NDVI, IRVI, MPRI and VARI IVs. They all use the red band, very susceptible to saturation in cases of high plant density. It is necessary to keep in mind other IV's when you want to map the variability of soybean in these growth stages. The indexes that had saturation are indicated for monitoring at the beginning and end of soybean cultivation, and then the limit for use is the growth stage V15 (found in the second evaluation), and they can be used again in the R8 stage (last evaluation of this study, where it was found the final stage of soybean development). An alternative to these saturated indices is the NDRE, which is able to monitor the entire development of this crop.

Keywords: Remote sensing, precision agriculture, Unmanned air vehicles.

LISTA DE FIGURAS

Figura 1. Exportações Brasileiras do Agronegócio por setores, em 2019	16
Figura 2. Área plantada e produtividade dos principais estados produtores de soja	17
Figura 3. Principais fatores que influenciam o custo de produção da soja	18
Figura 4. Comportamentos Espectrais dos objetos mais importantes para a agricultura.....	21
Figura 5. Fluxograma das etapas do processamento das imagens.....	32
Figura 6. Imagens em cor verdadeira das cinco avaliações... ..	35
Figura 7. Comparação de análise de NDRE: 1. Não considerando a quinta avaliação; 2. Considerando a quinta avaliação	38
Figura 8. Imagens utilizando o NDVI, das cinco avaliações realizadas em ordem cronológica.	40
Figura 9. Gráficos de dispersão para parâmetros biofísicos coletados e NDVI	40
Figura 10. Imagens utilizando o Índice NDRE, das cinco avaliações realizadas em ordem cronológica	42
Figura 11. Gráficos de dispersão para parâmetros biofísicos coletados e NDRE.....	42
Figura 12. Gráficos de dispersão demonstrando saturação de alguns dos Índices de Vegetação avaliados. Os IVs dos gráficos 2, 3 e 4 são constituídos das bandas do visível, enquanto somente o IV do gráfico 1 utiliza banda fora do visível.	43
Figura 13. Gráficos de dispersão relacionando NDVI e MPRI.....	44

LISTA DE TABELAS

Tabela 1. Datas de coleta de dados e voos com o drone.	28
Tabela 2. Índices de Vegetação usados no trabalho e autores que os propuseram.....	33

LISTA DE SIGLAS

CONAB	Companhia Nacional de Abastecimento
EUA	Estados Unidos da América
GNSS	Sistema Global de Navegação por Satélites (do inglês <i>Global Navigation Satellite System</i>)
GSD	Ground sample distance
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
IRVI	Índice de Vegetação com Razão Inversa (do inglês <i>Inverse Ratio Vegetation Index</i>)
IV	Índices de Vegetação
LiDAR	<i>Light Detection And Ranging</i>
MDE	Modelo Digital de Elevação
MPRI	Índice de Reflectância Fotoquímico Modificado (do inglês <i>Modified Photochemical Reflectance Index</i>)
N	Nitrogênio
NDRE	Índice da Diferença Normalizada da Borda do Vermelho (do inglês <i>Normalized Difference Red Edge Index</i>)
NDVI	Índice de Vegetação por Diferença Normalizada (do inglês <i>Normalized Difference Vegetation Index</i>)
NIR	Infravermelho Próximo
NPCI	Índice Normalizado de Pigmento da Clorofila (do inglês <i>Normalized Pigment Chlorophyll Ratio Index</i>)
PIB	Produto Interno Bruto

RE	Borda do Vermelho
RGB	Composição do espectro visível
RPAS	Sistema da Aeronave Remotamente Pilotada
SIG's	Sistemas de Informação Geográfica
SR	Sensoriamento Remoto
UFSCar	Universidade Federal de São Carlos
VANT	Veículo aéreo não tripulado.
VARI	Índice Resistente À Atmosfera na Região Visível (do inglês <i>Visible Atmospherically Resistant Index</i>)

Sumário

1. INTRODUÇÃO	14
2. REVISÃO DE LITERATURA	17
2.1. A soja.....	17
2.2. Agricultura de Precisão (AP).....	19
2.3. Sensoriamento Remoto.....	21
2.4. Índices de Vegetação.....	22
2.5. Utilização de Drones na Agricultura.....	25
3. METODOLOGIA 29	
3.1. Área Experimental.....	29
3.2. Alocação dos Pontos.....	30
3.3. Avaliações de Campo.....	31
3.4. Drone e Coleta de Imagens.....	32
3.5. Processamento de Imagens.....	32
3.6. Índices de Vegetação.....	33
3.7. Análise de Dados.....	34
4. RESULTADOS E DISCUSSÃO 36	
4.1. Qualidade das Imagens no tempo.....	36
4.2. Índices de Vegetação versus parâmetros biofísicos.....	40
5. CONCLUSÕES 47	
REFERÊNCIAS 48	
APÊNDICES 55	

1. INTRODUÇÃO

A soja é o principal produto agrícola no Brasil, presente no topo do ranking de produtos nacionais mais exportados. Desde 1997 o país aumentou a área plantada de soja, passando de 11,3 milhões para aproximadamente 36 milhões de hectares (CONAB, 2020). É importante notar que o aumento na produção nacional de soja não se deu somente pelo aumento de área plantada, mas também pelo aumento de produtividade, passando de 39,7 sacas para até 83 sacas por hectare (CONAB, 2020).

Cuidados com o preparo e manejo do solo, desenvolvimento de novas variedades de sementes e utilização de insumos com mais qualidade auxiliaram no aumento da produtividade e da rentabilidade da soja por hectare (DALL'AGNOL, 2019). Recentemente, a introdução de novas tecnologias no campo auxilia e dá força ao aumento da produtividade da soja (DALL'AGNOL, 2019).

As áreas de cultivo na agricultura são espacialmente heterogêneas, podendo apresentar comportamento desuniforme durante o desenvolvimento de uma cultura (MAPA, 2009). Diferenças no solo e no relevo podem indicar necessidades diferenciadas em uma mesma área (MOLIN; AMARAL; COLAÇO, 2015). É comum perceber plantas de diferentes tamanhos, em diferentes estádios fenológicos e com diferentes demandas nutricionais, já que o solo – responsável por ofertar os nutrientes – possui também variabilidade no espaço (MOLIN; AMARAL; COLAÇO, 2015). Com a soja não é diferente, é natural que o agricultor se preocupe em obter uma cultura mais uniforme, a fim de obter melhor produtividade.

A utilização da Agricultura de Precisão (AP) e seus conceitos tem por finalidade a identificação de fatores limitantes à produção visando o manejo específico (FRANCHINI *et al.*, 2018). As áreas utilizadas para a agricultura não são necessariamente uniformes; podem haver grandes diferenças no solo e no relevo, que acabam por demandar tratamentos diferenciados (MOLIN; AMARAL; COLAÇO, 2015). Portanto, existe a vantagem de mensurar a variabilidade das áreas de produção agrícola, a fim de garantir melhor produtividade e rentabilidade para a cultura em questão. A Agricultura de Precisão se destaca como uma importante aliada para o agricultor, oferecendo ferramentas rápidas e precisas ao identificar áreas menos produtivas, indicar os possíveis fatores que afetam a produção, bem como

proporcionar uma distribuição adequada de insumos para uniformizar a área e aumentar a produtividade (CARNEIRO, 218).

Molin, Amaral e Colaço (2015) afirmam que em alguns casos os sensores orbitais embarcados em satélites, muito utilizados pela AP para mapear áreas de interesse na agricultura, ainda possuem limitações. O custo de aquisição dos produtos é elevado para os agricultores, ainda que esteja em processo de barateamento (FRANCHINI *et al.*, 2018). Ainda, a baixa periodicidade com que os satélites revisitam a mesma área (resolução temporal), e em alguns casos, a baixa resolução espacial, podem comprometer a resposta ideal do que foi analisado (FRANCHINI *et al.*, 2018).

A baixa resolução temporal pode comprometer o bom acompanhamento da cultura, já que estádios fenológicos importantes para seu desenvolvimento podem não estar sendo acompanhados de maneira ideal pois o satélite demora a passar novamente no mesmo local (JORGE; INAMASU, 2014). Ainda, com uma baixa resolução espacial, o tamanho do pixel da imagem não permite registrar de maneira ideal os objetos da superfície analisada, comprometendo a visualização e identificação dos possíveis problemas no campo agrícola analisado (LUIZ, 2002). Luiz (2002) analisa que uma resolução espacial na casa de centenas de metros é insuficiente para observar solo e vegetação, mas boa para as feições regionais, como por exemplo cidades. O mesmo autor afirma que para estimativa de área plantada, uma resolução espacial entre 10 e 30 metros é suficiente; para correção de manchas de fertilidade no solo por exemplo, uma resolução boa está na casa entre 2 a 5 metros.

Apesar de atualmente já existirem satélites com alta resolução espacial (como o KOMPSAT 3A com 55 centímetros de resolução espacial (ZHANG; MARZOUGUI; SANKARAN, 2020)), uma saída é a utilização de sensores embarcados em drones para obtenção de imagens aéreas de alta resolução. Com seu uso, é possível diminuir o intervalo entre as imagens obtidas, não dependendo de revisitação de satélites (BREUNIG; GALVÃO; NETO, 2019). A aquisição da imagem é flexível, uma vez que configurando a altura de voo, altera-se conseqüentemente a resolução espacial da imagem (BREUNIG; GALVÃO; NETO, 2019). Essa flexibilidade de resolução espacial é interessante, pois além de permitir o acompanhamento de grandes talhões, também permite a aproximação do drone, aumentando o detalhamento, para identificação de pragas, deficiências nutricionais ou falhas na semeadura em pontos específicos da

lavoura (ARANTES *et al.*, 2019). Com essa aproximação, juntamente com a alta periodicidade de voo, é possível visualizar e corrigir falhas de plantio, identificar linhas de plantio e fazer contagem de plantas, por exemplo (ARANTES *et al.*, 2019).

O mapeamento periódico da área plantada é uma maneira de facilitar a investigação e tomada de decisão frente aos problemas e dificuldades que o manejo do solo e da cultura podem apresentar (AMADO *et al.*, 2007). Contudo, tal manejo requer acompanhamento periódico, análise de mapas e conhecimento da produtividade de safras anteriores, para que as variabilidades espacial e temporal possam ser evidenciadas ao longo do desenvolvimento da planta (BREUNIG; GALVÃO; NETO, 2019). Tendo conhecimento da variabilidade espaço-temporal de toda a área plantada, é possível prescrever aplicação de fertilizantes e herbicidas em doses variadas, detectar pontos de estresse hídrico e nutricional e acompanhar o desenvolvimento da cultura até o ponto de colheita, mesmo que o desenvolvimento da cultura em toda a área aconteça de forma desuniforme (JORGE, INAMASU, 2014).

O uso de drones para o acompanhamento do desenvolvimento da soja na agricultura ainda não é muito relatado cientificamente. A sua utilização pode ajudar durante avaliações durante seus estádios fenológicos e de seus genótipos e nas práticas de manejo, auxiliando na tomada de decisão dos produtores de maneira mais rápida e assertiva (FRANCHINI *et al.*, 2018). A estimativa de parâmetros biofísicos de uma cultura através do imageamento, como método não destrutivo, gerando maior precisão em seus resultados e diminuindo custos para o produtor, pode alavancar a produtividade da área analisada e auxiliar na evolução de técnicas de manejo, objetivo da Agricultura de Precisão (VIBHUTE; BODHE, 2012).

Portanto, o objetivo do presente trabalho é avaliar se o sensoriamento remoto com drone é capaz de identificar e quantificar a variabilidade espacial e temporal da soja, representada por parâmetros biofísicos, como biomassa, altura e índice de área foliar.

2. REVISÃO DE LITERATURA

2.1. A soja

Segundo o Instituto Brasileiro de Geografia e Estatística IBGE (2017), o setor do agronegócio representou 21% do Produto Interno Bruto (PIB) do país. O setor também foi responsável por metade de toda a exportação brasileira, sendo um importante fator positivo para a balança comercial nacional (IBGE, 2017). Dados da Companhia Nacional de Abastecimento (CONAB, 2019) informam também que o agronegócio é responsável direto por empregar cerca de 16,5 milhões de pessoas, demonstrando a importância do setor para o país.

A soja está entre as culturas que mais movimentam a economia agrícola brasileira. Segundo dados da CONAB (2019), o Brasil é o segundo maior produtor mundial do grão, com cerca de 115 milhões de toneladas, perdendo apenas para os Estados Unidos da América (EUA), estes com cerca de 124 milhões de toneladas. Sua finalidade pode ser para alimentação humana e animal, produção de óleo vegetal e biocombustível, por exemplo (CONAB, 2019).

O Brasil faturou, em 2018, U\$40,9 bilhões com exportação do chamado complexo soja: soja em grão (81,18%), farelo de soja (16,38%) e óleo de soja (2,44%) (AGROSTAT, 2019). A Figura 1 apresenta o complexo soja como maior responsável (36,44%) pelo faturamento das exportações brasileiras no agronegócio em 2019, com um aumento de 3,6% comparado ao ano anterior.

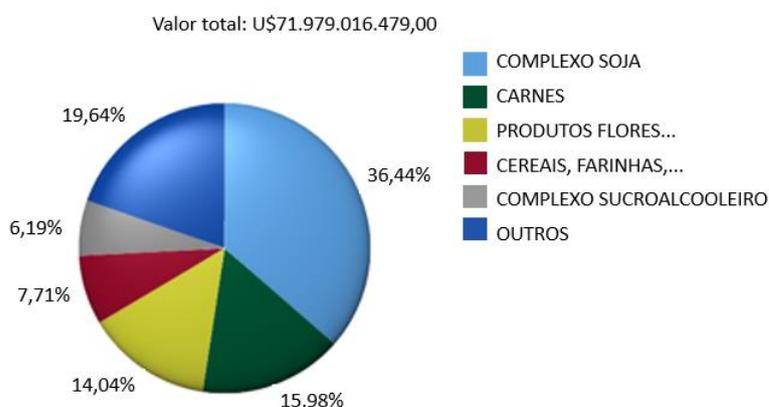


Figura 1. Exportações Brasileiras do Agronegócio por setores, em 2019 (Adaptado de CONAB, 2020).

A região Centro-Sul do país é o principal polo produtor da soja. Em primeiro lugar está o estado do Mato Grosso (Figura 2), com uma área de 10 milhões de hectares, e produtividade de 59,8 sacas por hectare (CONAB, 2020). Em seguida está o Rio Grande do Sul, com 5,9 milhões de hectares plantados, mas apenas 32,3 sacas por hectare de produtividade (CONAB, 2020). Os dois outros estados com destaque na produção nacional são Paraná e Goiás, o primeiro com 5,5 milhões de hectares e produtividade de 65,4 sacas por hectare; o segundo com 3,5 milhões de hectare e apresentando a melhor produtividade entre esses quatro estados: 61,9 sacas por hectare (CONAB, 2020).

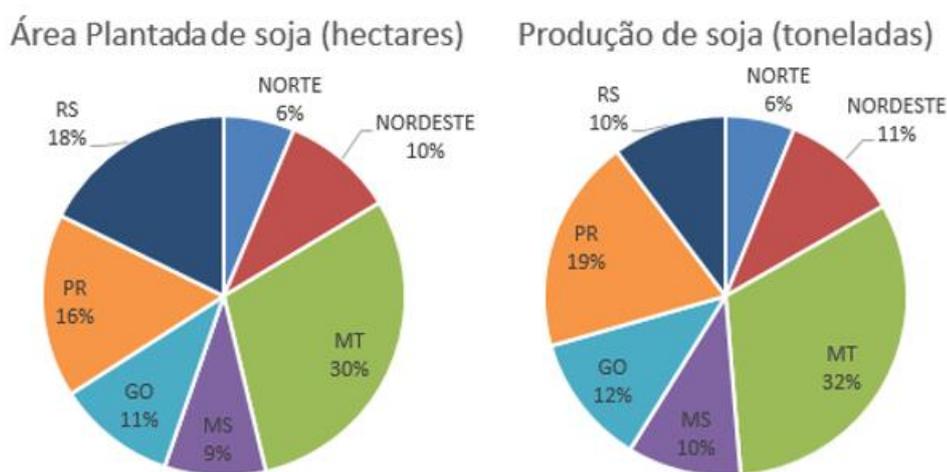


Figura 2. Área plantada e produção dos principais estados produtores de soja (Adaptado de CONAB, 2020)

A soja necessita de um total hídrico entre 450 a 800 mm/ciclo, visando obtenção de máximo rendimento (EMBRAPA *et al*, 2013). Esse valor varia desta maneira pois depende de condições climáticas, do manejo aplicado e da duração total de seu ciclo (EMBRAPA *et al*, 2013). A água é presente em cerca de 90% do peso da planta, e atua em todos os processos fisiológicos e bioquímicos ao longo de seu ciclo (EMBRAPA *et al*, 2013). A disponibilidade de água deve estar em condições normais principalmente durante a germinação/emergência da semente e floração/enchimento dos grãos (EMBRAPA *et al*, 2013). Ainda segundo a EMBRAPA *et al*. (2013), a cultura da soja obtém melhor produção com temperaturas entre 20°C e 30°C, onde sua temperatura ideal de cultivo está na casa dos 30°C.

É importante ressaltar os principais custos da cultura para facilitar o entendimento de quais pontos demandam maior atenção de controle de consumo, a

fim de diminuí-los e conseqüentemente aumentar a rentabilidade da produção da soja. A Figura 3 apresenta estes principais gastos, bem como sua importância na composição do custo final para produção de soja. Os dados obtidos são referentes à cotação para Safra 2020/2021 (IMEA, 2020).



Figura 3. Principais fatores que influenciam o custo de produção da soja (Adaptado de IMEA, 2020).

As despesas com defensivos e fertilizantes representam 64% dos custos demonstrados (IMEA, 2020). A AP, ao mapear as áreas específicas que demandam a aplicação desses insumos, também atua em suas recomendações de uso em taxa variável, resultando em uma melhor distribuição de insumos, podendo gerar maior uniformidade na área (tanto em termos de solo quanto de cultura) bem como ganhos em produtividade (MOLIN; AMARAL; COLAÇO, 2015).

2.2. Agricultura de Precisão (AP)

Segundo Molin, Amaral e Colaço (2015), AP é uma forma de gestão da lavoura que leva em consideração a sua desuniformidade em relação ao tempo e ao espaço, permitindo analisar e tratar a área com estratégias adequadas. Segundo esses autores, este conjunto de tecnologias e ferramentas visa o aumento do retorno econômico e a redução de impacto ao meio ambiente, tanto pelo aumento de produtividade quanto pela redução no uso de insumos.

Coelho (2003) relembra que em tempos onde a agricultura familiar era predominante e pequenas áreas eram exploradas, os agricultores conseguiam

observar e analisar a variabilidade espacial de suas terras. Segundo o autor, eles enxergavam as diferenças e alteravam o manejo destas áreas, a fim de obter uma melhor produção. Com a chegada da mecanização na agricultura, o manejo em grandes áreas perde essa propriedade de observação e análise, pois as áreas agora são muito grandes (COELHO, 2003). Assim, a aplicação de insumos de forma uniforme ganha força e é amplamente utilizada. O uso do GNSS (*Global Navigation Satellite System* - Sistema Global de Navegação por Satélites), ao ser associado a equipamentos com capacidade de medir a variabilidade e de aplicar insumos em taxas variáveis, demonstra que a possibilidade de manejar as culturas de modo específico novamente se torna uma real possibilidade (COELHO, 2003).

Shiratsuchi *et al.* (2014) apresenta alguns benefícios da AP, dando destaque à sustentabilidade, segurança alimentar, desenvolvimento econômico, rentabilidade e qualidade da cultura. Esse conjunto de técnicas apresenta um importante papel no campo, já que através dela é possível gerar diagnósticos, como por exemplo necessidades hídricas, deficiências nutricionais, detecção de pragas/doenças e estimativa de produtividade (SHIRATSUCHI *et al.*, 2014).

Algumas tecnologias levantadas por Molin, Amaral e Colaço (2015) possuem diferentes finalidades. Visando o acompanhamento localizado da produtividade, os monitores de produtividade estão no mercado desde a década de 1990. Esses monitores, segundo os mesmos autores, através de vários sensores, são capazes de oferecer a localização, a umidade do grão e a quantidade colhida em cada ponto georreferenciado. Contudo, os monitores de produtividade ainda não são utilizados em larga escala no Brasil, seja pela falta de conhecimento sobre as aplicações dessa tecnologia ou ainda pela dificuldade em se trabalhar com os recursos e o processamento dos dados em si (MENDES, 2020).

Outro exemplo onde o aparecimento de técnicas de AP auxilia o agricultor é o mapeamento de solo para manejo da fertilidade (MENDES, 2020). Esse mapeamento pode ser feito manualmente, via trado ou sonda, porém os sistemas automatizados e mecanizados aceleram todo esse processo, tornando-o mais eficiente (MENDES, 2020). No mapeamento, são realizadas amostragens georreferenciadas do solo que tem como objetivo a representação de toda a sua área. Essas amostras são enviadas para análise em laboratório, para que cada um destes pontos apresente as suas informações nutricionais. A partir destes valores, é possível aplicar fertilizantes e

corretivos de solo na quantidade que aquele local necessita, economizando insumos e diminuindo custos (MENDES, 2020).

A chegada da internet auxilia o desenvolvimento da Agricultura de Precisão no campo (ZAPAROLLI, 2020). Com a melhoria na conectividade é possível interligar as máquinas em tempo real em uma fazenda, permitindo a coleta de dados em tempo real, e conseqüentemente realizando a atuação em tempo real (ZAPAROLLI, 2020). O controle de pragas e plantas daninhas neste novo sistema diminui a perda na lavoura e evita nova ida ao campo, ganhando tempo e economizando dinheiro (ZAPAROLLI, 2020). No setor pecuário, a inteligência artificial vem sendo usada juntamente com câmeras 3D para acompanhar o ritmo de engorda do gado, identificando o momento ideal para o abate (ZAPAROLLI, 2020).

2.3. Sensoriamento Remoto

A área de análise e estudo do SR está ligada com a compreensão da interação da radiação eletromagnética com qualquer alvo na superfície terrestre (NOVO; PONZONI, 2001). Essas medidas, advindas de alguma fonte de energia, são transformadas em um produto interpretável (MOREIRA, 2011). O SR possui como principal característica a obtenção de informações de um objeto sem qualquer contato físico com ele. Tal técnica, possui como vantagens o fácil acesso a locais onde o homem ou a máquina teriam dificuldades em chegar, além de cobrir grandes áreas geográficas (CARNEIRO, 2018).

A Figura 4 traz comportamentos espectrais de componentes importantes para a agricultura. O comportamento saudável da vegetação pode ser identificado pela região do visível, em virtude da concentração de clorofila absorver maiores taxas na faixa do vermelho (0,6 μ m a 0,7 μ m) e azul (0,44 a 0,5 μ m); e refletir na banda do verde (0,5 a 0,6 μ m) (BRANDÃO *et al.*, 2008). Desse modo, é possível identificar na curva espectral características da vegetação por vales (absorção) e por picos (reflexão). Valores entre 1,3 e 1,9 μ m permitem observar a influência da quantidade de água na planta, já que os vales presentes nessa região representam locais de absorção da radiação pela água (PEÑUELAS *et al.*, 1997).

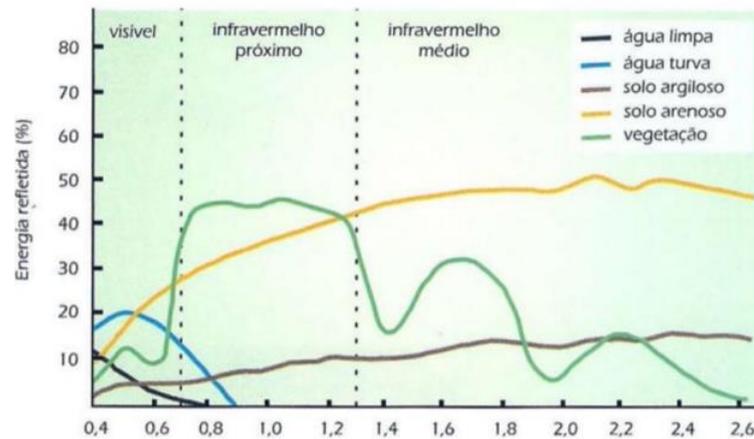


Figura 4. Comportamentos Espectrais dos objetos mais importantes para a agricultura (Fonte: Araújo, 2016)

O SR permite identificar diferenças na reflectância de plantas, referentes à densidade da cobertura vegetal (BRANDÃO, 2009). Segundo o autor, a avaliação de estágio fenológico de culturas, produtividade, estimativa de biomassa e monitoramento de vigor e de estresse hídrico são algumas das aplicações na agricultura onde o SR é utilizado.

Considerando a variabilidade espacial presente na agricultura, os dados obtidos via SR se tornam importantes ferramentas da AP para gerenciar o tratamento localizado das lavouras (SHIRATSUCHI *et al.*, 2014). O SR facilita a geração de um diagnóstico, promovendo a tomada de decisão no manejo agrícola (BRANDÃO, 2009). Como exemplo, dados do SR são utilizados para prever a quantidade de Nitrogênio (N) presente na planta (SHIRATSUCHI *et al.*, 2014). A diminuição de N presente na planta acarreta na diminuição de pigmentos de clorofila. Essa alteração de concentração de nitrogênio pode ser capturada pela banda do infravermelho (SHIRATSUCHI *et al.*, 2014), indicando ao agricultor a possível necessidade de aplicar fertilizante.

2.4. Índices de Vegetação

Existem inúmeros Índices de Vegetação (IV's), cada qual utilizando bandas específicas com finalidades diversas de acordo com os interesses sobre os alvos (BRANDÃO, 2009). Os IV's, ao realçar o comportamento espectral da vegetação, torna possível correlacioná-los com parâmetros biofísicos, como biomassa, Índice de

Área Foliar (IAF), percentual de cobertura vegetal e atividade fotossintética, mensurando a eficiência da absorção de luz ou quantidade de clorofila de determinada cultura (BRANDÃO *et al.*, 2008). Ainda, IV's são responsáveis por diminuir possíveis variações de radiância que podem aparecer em imagens, devido a efeitos de topografia ou declividade (MARCUSI *et al.*, 2010).

São vários os fatores que podem afetar os IV's. O período de tempo entre a captação das imagens a serem analisadas (resolução temporal), a fonte de radiação, o espalhamento atmosférico e presença de sombras (ANTUNES *et al.*, 2015).

As bandas do vermelho e infravermelho próximo são as mais utilizadas na criação dos IV's. Isso acontece pois elas são responsáveis por identificar cerca de 90% da resposta espectral referente à vegetação, um dos alvos de interesse da Agricultura de Precisão (ROSA, 2007). Um dos IV's mais conhecidos é o Índice de Vegetação por Diferença Normalizada (do inglês – *Normalized Difference Vegetation Index* – NDVI), criado por Rouse *et al.* (1974). Esse Índice utiliza as duas bandas supracitadas em sua composição, se mostra eficiente para estimar valores biofísicos (SILVA, 2004). O NDVI, utilizado em larga escala (TARNAVSKY; GARRIGUES; BROWN, 2008), é empregado por demonstrar correlação com rendimento de biomassa verde de culturas (PERALTA *et al.*, 2016). Em contrapartida, esse IV é suscetível à saturação se utilizado com altos valores de IAF e vegetação densa (JENSEN, 2009).

Outro IV comumente utilizado na agricultura é o Índice da Diferença Normalizada da Borda do Vermelho (do inglês *Normalized Difference Red Edge Index* – NDRE), capaz de ultrapassar a barreira criada pelo dossel da cultura, se aprofundamento mais da vegetação e se tornando menos propenso à saturação em comparação ao NDVI (TAIPALE, 2018). Ele é composto pelas bandas do infravermelho próximo e da borda do vermelho, este último responsável por tornar esse IV mais sensível à clorofila (BUSCHMANN; NAGEL, 1993). É indicado para culturas com ampla densidade vegetativa e de maior altura, representando melhor a variabilidade da cultura em relação ao NDVI (TAIPELE, 2018). O NDRE tem sido utilizado para gerar uma análise mais precisa em uma transição entre plantas mais ou menos saudáveis, além de não saturar rapidamente como o NDVI (BONFIL, 2017).

Um IV que não utiliza bandas fora do espectro visível que auxilia no acompanhamento durante o desenvolvimento de culturas como a soja é o Índice de Reflectância Fotoquímico Modificado (do inglês *Modified Photochemical Reflectance Index* – MPRI) (YANG *et al.*, 2008), baseado na diferença normalizada entre as bandas do vermelho e do verde. O comportamento entre essas duas bandas é similar ao comportamento das bandas do infravermelho e do vermelho que compõe o NDVI ao observar solo e vegetação (BARCELOS, 2017; PADOLFI; RAMALDES; SANTOS, 2018). Para a corpos d'água, esse IV é inverso em relação ao NDVI (LINHARES; ROCHA; AMARAL, 2013). Assim, o MPRI pode ser um bom indicativo para áreas de desmatamento, reflorestamento e manejo de áreas agrícolas (LINHARES; ROCHA; AMARAL, 2013). Áreas de pastagem também podem ser um foco de utilização deste IV, já que estudos comprovaram a uma forte correlação entre o MPRI e a variabilidade temporal e espacial de gramíneas (GONÇALVES *et al.*, 2017).

O Índice de Vegetação com Razão Inversa (do inglês *Inverse Ratio Vegetation Index* – IRVI), segundo Bolfe, Batistella e Ferreira (2012), tem sido utilizado para prever biomassa em áreas com grande densidade vegetativa, já que o NDVI pode saturar nessa condição de vegetação. O Índice de Reflectância Fotoquímico Modificado (do inglês *Modified Photochemical Reflectance Index* – MPRI) avalia a diferença normalizada da resposta espectral entre as regiões do verde e do vermelho, a fim de realçar a cobertura verde das folhas e é alternativa no caso em que se utiliza câmeras RGB. O Índice Normalizado de Pigmento da Clorofila (do inglês *Normalized Pigment Chlorophyll Ratio Index* – NPCI) está relacionado à senescência da planta, segundo Peñuelas *et al.* (1994). E, por fim, o Índice Resistente À Atmosfera na Região Visível (do inglês *Visible Atmospherically Resistant Index* – VARI) se baseia, segundo Viña *et al.* (2004), na variabilidade de estresse e vigor de planta de acordo com a 'quantidade' de verde, de acordo com a boa sensibilidade de resposta devido ao teor de clorofila.

2.5. Utilização de Drones na Agricultura

Os termos mais comuns ao se referir a um drone podem variar. A palavra drone, na realidade, é um nome genérico que caracteriza qualquer objeto voador não tripulado, independente de finalidade ou origem (DECEA, 2020). Esse termo não é encontrado como definição de objeto na legislação. A terminologia oficial utilizada pelos órgãos reguladores nacionais é VANT – veículo aéreo não tripulado (DECEA, 2020). VANT é considerada qualquer aeronave que não utiliza piloto a bordo, porém sem finalidade recreativa (DECEA, 2020). Existem dois tipos diferentes de terminologia para VANT's. O primeiro é o RPA (Aeronave Remotamente Pilotada), ou seja, o drone em si, e possui caráter não recreativo (DECEA, 2020). O segundo tipo de VANT é conhecido como RPAS (Sistema da Aeronave Remotamente Pilotada), caracterizado pelo conjunto do sistema de RPA, e trata-se do drone e todos os equipamentos que participam do voo de um RPA como computadores, celulares, controle remoto ou outra interface (DECEA, 2020).

Os drones, como serão chamados no presente estudo, estão ganhando cada vez mais espaço na agricultura, pois sua capacidade de voo está cada vez mais estável, suas câmeras possuem alta resolução, além de os softwares estarem cada vez mais dinâmicos e automatizados (PADOLFI; RAMALDES; SANTOS, 2018). Ainda, Molin, Amaral e Colaço (2015) descrevem a agilidade e a flexibilidade como as principais vantagens da utilização de VANT's. O agricultor passa a não mais depender de resolução temporal de satélites ou de fretamento de aviões tripulados para obter dados de sua plantação. A utilização de drones pode ser praticamente automatizada e, portanto, é descrito como método prático, rápido e barato (MOLIN; AMARAL; COLAÇO, 2015).

A utilização dos drones permite um planejamento independente de revisitas dos voos, diferentemente de sensores embarcados em satélites, onde a resolução temporal das imagens obtidas é fixa e pode demorar dias a acontecer novamente no mesmo local (JORGE; INAMASU, 2014). Assim, os drones têm capacidade de acompanhar de forma mais próxima a fenologia das culturas agrícolas, das demandas de processos de manejo de lavoura, facilitando e direcionando a tomada de decisão (BARCELOS, 2017). Amaral *et al.* (2019) afirmam que o uso de drone na agricultura permite, além do acompanhamento mais frequente e com mais detalhamento da

lavoura, ainda facilitam o monitoramento do campo em relação a somente visitar e visualizá-lo.

Segundo Breunig, Galvão e Neto, (2019), uma imagem de drone pode chegar a uma resolução espacial de até menos de um centímetro dependendo da altura do voo e da qualidade da câmera. Ao considerar a demanda das aplicações de imagens de alta resolução espacial na agricultura de precisão, esse é um dos maiores atrativos dos drones (JORGE; INAMASU, 2014). Um dos pontos potenciais para a aplicação de drones na agricultura é a identificação de plantas daninhas e sua pulverização (BREUNIG; GALVÃO; NETO, 2019). Segundo Reips e Gubert (2019), é possível utilizar a boa resolução espacial dos sensores embarcados em drones para identificação de locais na lavoura atacados por doenças ou pragas, principalmente nos estádios fenológicos mais iniciais, antes que uma grande área (visível em larga escala posteriormente em sensores com baixa resolução espacial) seja perdida. Atualmente existem drones cuja função é pulverização localizada no campo (JONES, 2019). Após analisar a área e verificar a variabilidade espacial, a aplicação localizada de defensivos pode ser efetuada com o auxílio de drones. Assim, a proximidade com a planta garante a correta aplicação, além de não colocar nenhum piloto em risco (JONES, 2019).

Outra aplicação utilizada para a agricultura é a verificação de perda de solo. Diferenças bruscas na altimetria, principalmente em solos expostos, permitem a inferência de solos erosivos ou com potencial de erosão, podendo gerar, a tempo, planos de controle (REIPS; GUBERT, 2019).

Pensando na atividade pecuária, drones estão sendo pesquisados para contagem de rebanho, além de já serem utilizados para buscar animais perdidos, muitas vezes localizados em pontos distantes e de difícil acesso; drones também são utilizados para acompanhar a pastagem e a necessidade de serem reformadas (ITARC, 2020). Outro ponto interessante do uso de drones é auxiliar na identificação de focos de incêndio florestal, uma vez que é perigoso ao ser humano se aproximar do fogo, e em muitos casos não há acesso facilitado (MOURA, 2019). A partir do momento em que o foco é localizado, bolas extintoras são lançadas nos focos, facilitando sua extinção (MOURA, 2019).

Grande parte dos dados adquiridos pelos sensores embarcados nos drones atualmente vem da faixa do visível (sensores RGB) e também infravermelho próximo (sensores multiespectrais) (SEBBANE, 2018). Sensores hiperespectrais (utiliza maior número de bandas estreitas e unidas), termais e também o LiDAR (*Light Detection And Ranging*) vem sendo incorporados nesta realidade, primeiramente em universidades e empresas voltadas à produção de novos produtos para agricultura (SEBBANE, 2018).

Apesar de todas essas possíveis vantagens e aplicações, Mendes (2020) relaciona algumas desvantagens do uso do drone em relação aos satélites. A escolha entre uma ou outra plataforma deve ser baseada na finalidade e no tempo disponível para obtenção de seus dados, uma vez que para as imagens advindas de drone é necessário tempo para sua aquisição, bem como para seu processamento (JORGE, INAMASU, 2014). É válido enfatizar que em ambos os casos podem haver custos. Com os drones, o custo vem com a aquisição do equipamento e de softwares necessários para processamento das imagens (MENDES, 2020). Por outro lado, algumas imagens de satélite, principalmente as que possuem resolução alta espacial, podem ser cobradas (MENDES, 2020). Ainda, como desvantagem, Amaral *et al.* (2019) afirmam que o processamento das imagens advindas de drones demanda mais capacidade computacional. Essas imagens passam por mosaicagem e ortorretificação nas mãos do usuário, o que justifica tal demanda, diferentemente das imagens de satélites já processadas e disponibilizadas pela agência responsável (JORGE, INAMASU, 2014). Outro ponto que deve ser levantado nesta discussão é a presença de nuvens nas imagens. Em imagens de drones, as nuvens não capturadas nas imagens, como nas advindas de satélite, pois seu voo é realizado abaixo delas (COLOMINA; MOLINA, 2014). Porém suas sombras ainda permanecem no solo, gerando problemas em caso de céu parcialmente encoberto (ECHER. MARTINS; PEREIRA, 2006). Neste caso, os autores afirmam que o ideal é voar com céu aberto ou uniformemente nublado.

Franchini *et al.* (2018) descrevem a utilização de imagens do espectro visível (RGB) em câmera embarcada em drone para a cultura da soja. Foram feitas análises de qualidade e fertilidade de solo, identificação de áreas erosivas, correlação de IV's com produtividade e identificação de áreas com a doença ferrugem-asiática e com

nematoides. Em todas as análises realizadas, as imagens advindas de drone apresentaram resultados positivos, identificando os problemas e auxiliando na tomada de decisão, inclusive na aplicação de agro defensivos no caso de doença e praga (FRANCHINI *et al.*, 2018).

3. METODOLOGIA

3.1. Área Experimental

A área utilizada para o presente estudo está localizada dentro da Universidade Federal de São Carlos (UFSCar), no município de Araras/SP, onde o solo predominante é o latossolo vermelho escuro. São aproximadamente 6,43 hectares utilizados para plantação e melhoramento da cana de açúcar e oportunamente é cultivada soja como rotação de cultura.

A semeadura da soja aconteceu em 11/11/2019. O cultivar de soja utilizado foi o MONSOY 6410 IPRO, com ciclo de produção entre 110 a 120 dias, aproximadamente. A semeadura foi realizada com 0,50m de espaçamento entre linhas e 0,10m de espaçamento entre plantas. O cronograma utilizado para coleta de dados está descrito na Tabela 1, com os respectivos estádios fenológicos encontrados. A colheita da soja ocorreu uma semana após a última coleta de dados, em 10/03/2020.

Tabela 1. Datas de coleta de dados e voos com o drone; destaque das imagens obtidas em composição colorida mostrando a distribuição dos pontos amostras em cada avaliação.

<u>Avaliação</u>	<u>Data</u>	<u>Dias após a semeadura</u>	<u>Estádio Fenológico</u>	<u>Distribuição dos Pontos Amostrais</u>
1	26/12/2019	45	V9	
2	13/01/2020	63	V15	

3	28/01/2020	78	R3	
4	18/02/2020	99	R6	
5	03/03/2020	113	R8	

3.2. Alocação dos Pontos

Para a primeira avaliação foi criada, via sistema de informação geográfica, uma grade regular na área estudada, a fim de gerar os dez pontos amostrais georreferenciados. A grade regular foi utilizada por não haver conhecimento prévio da área. Assim, optou-se por dividir a área em 10 áreas semelhantes, e escolher o ponto central de cada área como ponto de partida para essa pesquisa. Para as avaliações subsequentes, os dez pontos amostrais de cada avaliação eram criados a partir da variabilidade identificada pela reflectância da avaliação anterior. Os pontos amostrais de cada avaliação estão demonstrados na Tabela 1.

Durante a primeira e segunda avaliações, as condições climáticas permaneceram estáveis, com o céu inteiramente coberto de nuvens durante todo o sobrevoo da área. Para a terceira avaliação, o céu estava aberto sem presença de nuvens. Durante a quarta avaliação o tempo estava aberto no início, porém durante os 10 minutos de voo, o céu ficou coberto de nuvens esparsas. Na última avaliação o céu também estava aberto.

3.3. Avaliações de Campo

Os pontos amostrais, para todas as visitas, possuíam as dimensões 2m x 1m estando presente em cada ponto amostral duas linhas de plantio com extensão de dois metros. Esta marcação foi feita *in loco* através de um quadro de canos pvc de meia polegada medindo 2 por 1 m em cada ponto. Antes de cada avaliação, os pontos iniciais e finais de cada parcela foram destacados utilizando folhas de papel branco nas extremidades de sua marcação, para que fosse possível encontrá-los nas imagens obtidas. Após a marcação de tais pontos, foi realizado o voo, e posteriormente, a coleta dos parâmetros biofísicos para cada avaliação.

A altura das plantas foi mensurada utilizando uma trena, medindo do solo até o ápice da haste principal da planta de soja (AMORIM *et al.*, 2011). A cada ponto georreferenciado, 10 plantas ao acaso ali presentes foram mensuradas.

A área foliar (af, em m²) foi mensurada através da medida do folíolo central de um trifólio completamente desenvolvido localizado na parte superior da planta. A maior largura do folíolo (L, em metros) foi multiplicada pelo seu maior comprimento (C, em metros), através da Equação 1 (RICHTER *et al.*, 2014).

$$af = 2,0185 * C * L \quad (1)$$

Posteriormente, a quantidade de folhas da planta e a quantidade de plantas presentes em apenas uma das linhas de 2 metros lineares da grade foram contadas. A Equação 2 descreve então o valor de área foliar (AF) que será utilizado. Para, enfim, obter o índice de área foliar (IAF), divide-se AF pela área de solo ocupada por uma planta (1 m²) (ZANON *et al.*, 2015).

$$AF = af * nfp * npm^2 \quad (2)$$

Onde: AF = Área Foliar (m²); af = área de uma folha (m²); nfp = número de folhas por planta; npm² número de plantas por m².

Para a coleta de biomassa úmida, a planta de soja foi cortada rente ao chão. Posteriormente, as plantas foram alocadas em sacos de papel e suas massas foram aferidas em campo para obtenção de sua massa úmida. Após tal procedimento, as amostras foram alocadas em uma estufa com circulação forçada de ar para determinação de sua massa seca. As amostras permaneceram na estufa por 72h a 65°C (GOBBI *et al.*, 2009).

3.4. Drone e Coleta de Imagens

Para obtenção das imagens, foi utilizado um drone modelo quadricóptero. A ele foi acoplada uma câmera multiespectral modelo Micasense Rededge, de cinco bandas espectrais: azul (B- centro de 475 nm, largura de banda de 20 nm), verde (G- centro de 560 nm, largura de banda de 20 nm), vermelho (R- centro de 668 nm, largura de banda de 10 nm), borda do vermelho (RE – *rededge*- centro de 717 nm, largura de banda de 10 nm) e infravermelho próximo (NIR- centro de 840 nm, 40 nm de largura de banda). A câmera possui resolução radiométrica de 12 bits e é equipada com um sensor de irradiância, permitindo corrigir a variação de luminosidade das imagens entre os voos, o que permite a comparação de dados de reflectância entre diferentes datas de coleta.

Os voos das cinco avaliações foram realizados a uma altura de 72 metros, determinando um nível de detalhamento do terreno (do inglês GSD - *ground sample distance*) de 5 cm/pixel, com recobrimento fotográfico de 75% frontal e lateral. A velocidade utilizada foi de 8 m/s. Para sobrevoar a área de estudo, em cada avaliação foram necessárias 332 imagens, que passaram por mosaicagem e ortorretificação. Todos os voos foram realizados entre 11 e 13 horas, evitando o sombreamento da cultura.

3.5. Processamento de Imagens

A junção das imagens obtidas via drone foi realizada pelo processo de mosaicamento local de interesse. Tal método permite uma visão ampla sobre a área imageada, dando a impressão de continuidade (CHAVES *et al.*, 2015). Inicialmente, todas as imagens do mesmo voo foram inseridas no software e automaticamente foram separadas das imagens referentes ao painel calibrador de reflectância. Foi realizada uma seleção e filtragem para que somente as imagens da área de interesse fossem processadas. Posteriormente, houve o alinhamento de imagens utilizando a otimização de câmera (para aumentar a acurácia do alinhamento), criação da nuvem densa de pontos (a fim de otimizar a reconstrução da superfície, aumentando a qualidade do ortomosaico), construção do Modelo Digital de Elevação (MDE) para

que, por fim, o ortomosaico pudesse ser gerado. A Figura 5 apresenta o fluxograma do processamento das imagens.



Figura 5. Fluxograma das etapas do processamento das imagens.

3.6. Índices de Vegetação

Os dados do sensoriamento remoto foram utilizados para cálculo de seis índices de vegetação: NDVI, NDRE, IRVI, MPRI, NPCI e VARI. Os três primeiros IV's trabalham com bandas além do espectro visível presentes na câmera multiespectral (Tabela 2). Porém, muitos levantamentos com drone estão sendo realizados com câmeras RGB, pois são mais baratas e o funcionamento é simplificado. Portanto, os outros três IVs utilizados no presente trabalho são compostos somente com essas bandas.

Tabela 2. Índices de Vegetação usados no trabalho e autores que os propuseram.

Índice de Vegetação	Equação	Referência
NDVI	$NDVI = \frac{NIR - R}{NIR + R}$	Rouse <i>et al.</i> , 1974
MPRI	$MPRI = \frac{G - R}{G + R}$	Yang <i>et al.</i> , 2008
NDRE	$NDRE = \frac{NIR - RE}{NIR + RE}$	Buschmann; Nagel, 1993
IRVI	$IRVI = \frac{R}{NIR}$	Kapp Júnior <i>et al.</i> , 2016
NPCI	$NPCI = \frac{R - B}{R + B}$	Merzlyak, 1999
VARI	$VARI = \frac{G - R}{G + R - B}$	Gitelson <i>et al.</i> , 2003

NIR = reflectância na região do infravermelho próximo; R = reflectância na região do vermelho. G = reflectância na região do verde; RE = reflectância na região do *RedEdge*. B = reflectância na região do azul.

3.7. Análise de Dados

Foi utilizado um SIG para criação de *buffers* (polígonos), referentes às áreas de 2 m² dos pontos amostrais para cada uma das cinco avaliações realizadas, gerando então 5 arquivos no formato *shapfile*. Um software de linguagem R foi utilizado para calcular os IV's estudados, recortar cada imagem desses IV's utilizando o arquivo *shapfile* (mantendo assim somente as áreas de interesse nas imagens). Posteriormente, foi calculada a média de reflectância das áreas delimitadas em cada imagem de cada avaliação, gerando uma planilha. Cada avaliação contém então um arquivo do tipo *shapfile* com dez *buffer's*, referentes aos dez pontos coletados, um ortomosaico e uma imagem para cada IV analisado. Cada avaliação apresenta uma planilha contendo a média de reflectância de 2 m² de cada um dos dez pontos amostrais referentes aos IV's analisados. Nesta planilha, foram adicionados os valores coletados dos parâmetros biofísicos (altura de planta, biomassa úmida e seca e IAF).

As avaliações dos resultados foram realizadas através de análise de correlação e regressão linear. Os Índices de Vegetação, bem como as bandas individuais, foram utilizados para cálculo de correlação e plotados em gráficos de dispersão com os

parâmetros biofísicos coletados *in loco*. Assim, tornou-se possível estudar a relação entre os dados e entender se é possível analisar a evolução temporal da cultura da soja, bem como identificar a variabilidade espacial durante o seu desenvolvimento.

4. RESULTADOS E DISCUSSÃO

4.1. Qualidade das Imagens no tempo

Nas imagens em composição colorida apresentadas anteriormente na Figura 6 é interessante notar que existem diferenças visuais entre cada avaliação, o que permite visualizar a variabilidade temporal da cultura. Na primeira avaliação (Figura 6.1) é possível verificar a existência de espaços entre as linhas de cultivo, indicando que o dossel ainda não havia se fechado a ponto de cobrir todo o solo. A partir da segunda avaliação, a cor verde se torna mais presente, indicando em toda a área que a cultura segue em desenvolvimento.

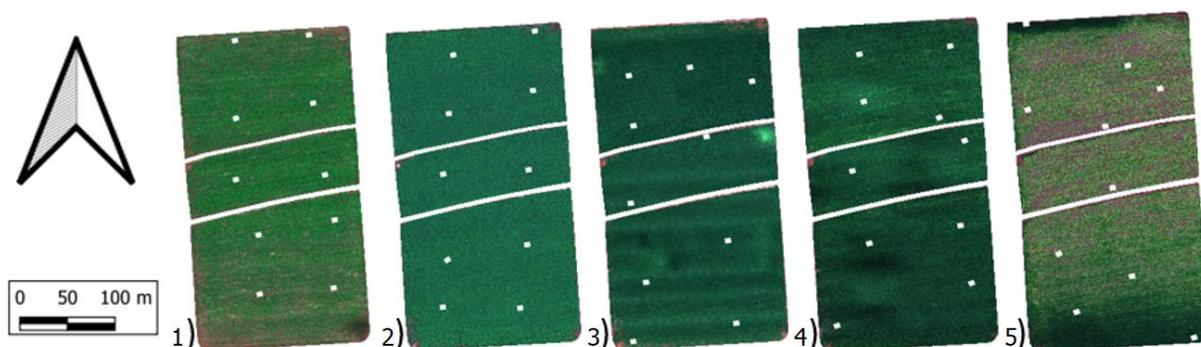


Figura 6. Imagens em cor verdadeira das cinco avaliações.

Na terceira avaliação (Figura 6.3) é possível identificar, nos dois talhões inferiores, diversas linhas brancas na direção horizontal. Este fenômeno é chamado de *sunspot* e é o reflexo gerado a cada tomada de foto pelo drone, como a explosão do flash em fotografias comuns. Essa situação acontece, segundo a própria fabricante da câmera (MICASENSE, 2020), pelo voo ter sido realizado ao meio dia, com condições muito ensolaradas (ângulo solar maior que 52°). O sol, por estar exatamente acima do drone, causa essas manchas solares brancas. Ainda segundo a fabricante, o ideal é evitar realizar o plano de voo neste exato momento, e esperar a angulação do sol diminuir (mantendo o voo no intervalo de 2 horas e meia deste momento), pois esse fator pode alterar os valores de reflectância das bandas espectrais. Com isso, os valores dos IV's se tornam duvidáveis. É válido destacar que os pontos amostrais desta avaliação não estão localizados nessas regiões, portanto, o estudo não foi prejudicado.

Já na Figura 6.4 aparecem manchas escuras espalhadas por toda a área. Para conferir se este problema foi causado durante a mosaicagem da imagem, todo o processamento foi refeito duas vezes, alterando configurações de software, a fim de aumentar a qualidade da construção da nuvem densa de pontos, do MDE e do ortomosaico. Tais procedimentos aumentam o tempo de processamento e utilização de memória computacional, mas caso as manchas tivessem sido geradas durante a mosaicagem, com o aumento na qualidade de processamento, elas desapareceriam. Porém, as manchas persistiram em todas as tentativas realizadas. Buscamos então alguma influência ambiental que explicasse tal fenômeno. No dia desta quarta avaliação, 18/02/2020, havia muitas nuvens no céu, e durante o voo elas estavam parcialmente cobrindo a área de estudo. A fabricante Micasense (2020) afirma que nuvens presentes nas imagens de drone acabam por tornar os valores de reflectância das bandas (e por consequência, dos Índices de Vegetação) questionável em toda a área. A condição de luz deve se manter consistente e constante ao longo de todo o voo com o drone, para que a luz incidente permaneça uniforme em todos os alvos da imagem, gerando valores confiáveis (MICASENSE, 2020), ou seja, céu parcialmente nublado pode comprometer a eficácia do sensor de radiação da câmera, pois as nuvens alteram a energia radiante oriunda do sol que chega até o solo ou o alvo (ECHER. MARTINS; PEREIRA, 2006). Então, concluiu-se que tais manchas foram causadas pela presença de nuvens. É válido destacar que, como na avaliação anterior, os pontos amostrais também não coincidiram com os locais manchados pelas sombras na imagem.

Um outro ponto a se aferir diz respeito à visível senescência das plantas de soja, presente na última imagem (Figura 6.5). É possível verificar que áreas outrora em cor verde passaram a ter uma coloração mais amarronzada. Isso indica que a planta está eliminando água dos grãos e das folhas, estando próxima a seu estágio de maturação. Isso começa a ocorrer no estágio fenológico R8, caracterizado por queda das folhas, diminuição do IAF e alteração na coloração da planta (passando de verde para marrom) (SYNGENTA, 2020; NEUMAIER *et al.*, 2000). Esse processo é comum, visto que a soja deve ser colhida com apenas 13% de umidade (NEUMAIER *et al.*, 2000). O peso da biomassa úmida também confirma a senescência comentada. Enquanto os pontos onde as plantas ainda estão em estágio vegetativo (extremos norte e sul da imagem) possuem média de peso de 8,43kg, os valores dos pontos

centrais da imagem estão entre 2,9kg e 3,7kg. Esse tipo de imagem pode auxiliar o produtor a verificar o melhor momento de colher a soja, já que a análise visual a nível de solo pode mascarar o real estágio de maturação de todo o talhão, principalmente em sua porção central. Caso a área esteja desuniforme, essas imagens podem guiar uma aplicação localizada de dessecantes, por exemplo, auxiliando a uniformizar a área para uma colheita mais eficiente e economizando insumo, já que a aplicação de dessecante não será na área total (GIRALDELI, 2019). Dessa forma, os valores de correlação gerados nesta avaliação podem não retratar a realidade vista no campo. A falta de água e clorofila na planta seria indicativo de problemas como doenças, pragas ou deficiência nutricional, e não de tempo de maturação, o que poderia comprometer a interpretação dos resultados. A Figura 7 demonstra a diferença entre dois gráficos de dispersão do Índice de Vegetação NDRE e biomassa seca como exemplo, onde o primeiro (Figura 7.1) não apresenta os dados utilizando a quinta avaliação, enquanto a Figura 7.2 mantém tais variáveis. É possível observar que a maioria dos valores de biomassa diminuíram da quarta avaliação (pontos na cor amarela) para a quinta avaliação (pontos na cor verde), demonstrando perda de massa, acarretada pela perda de folhas supracitada. Essa diferença de valores poderia vir a comprometer a análise do conjunto de avaliação, já que os valores de NDRE também diminuíram, mascarando o comportamento temporal da soja. Desta maneira, a quinta avaliação não será considerada nas análises de correlações para verificar se a variabilidade espaço-temporal é identificada para a soja neste estudo.

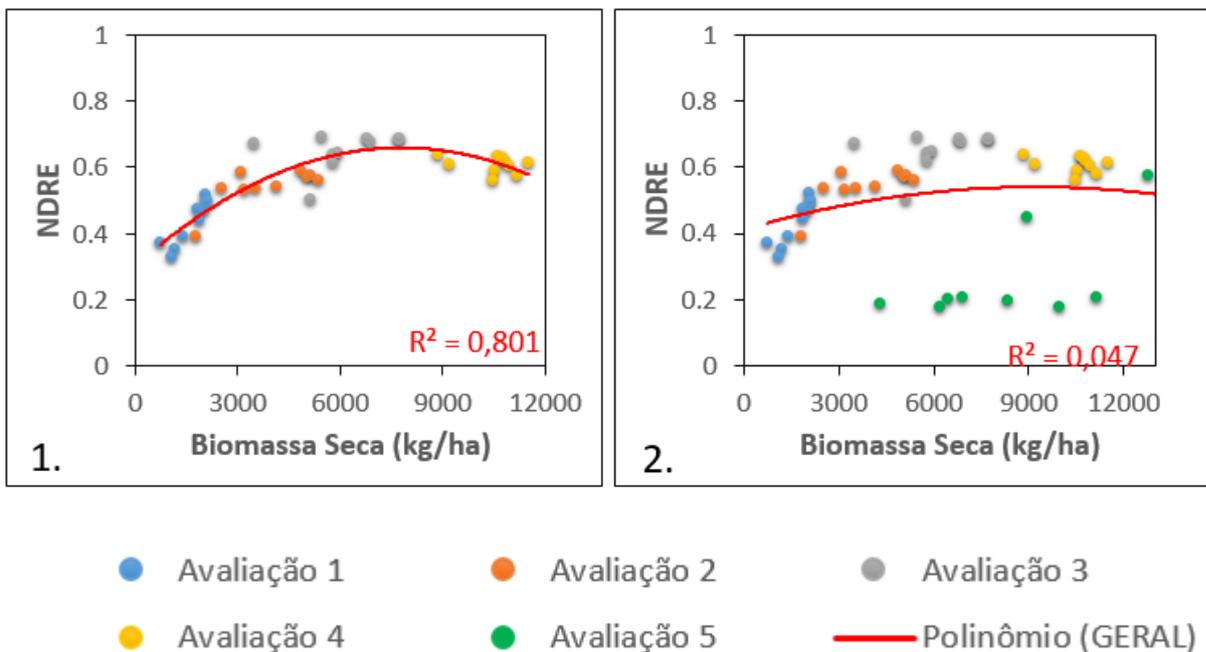


Figura 7. Comparação de análise de NDRE: 1. não considerando a quinta avaliação; 2. Considerando a quinta avaliação.

Ainda sobre a Figura 6.5, vê-se uma cor verde intensa nas extremidades norte e sul da área. Essas áreas apresentam plantas que não seguiram o mesmo período de maturação do resto da cultura. Enquanto o restante do campo segue em senescência, estas áreas estão com as plantas em seu estágio vegetativo ainda, contendo muita biomassa. Essa afirmação se confirma ao verificar os valores coletados em campo. O peso médio da biomassa seca dos pontos localizados nessas regiões está acima de 2,7 kg, enquanto os valores localizados na região central da imagem (onde o verde dá espaço ao tom amarronzado) estão entre 0,86 e 1,9 kg. O responsável pela área informou que isso acontece na porção norte da imagem pois ali existem árvores que impedem a passagem da luz solar durante grande parte do dia, comprometendo o fotoperíodo e atrasando o desenvolvimento das plantas. Já para a porção sul isso não é possível de ser argumentado, visto que a extensão dessa extremidade (cerca de 50 metros) não condiz com a altura de árvores que seria responsável por bloquear a luz solar deste ponto da área estudada. Neste caso, é interessante analisar outros atributos que podem ter causado essa variabilidade espacial, como solo ou declividade do terreno.

4.2. Índices de Vegetação versus parâmetros biofísicos

A Figura 8 traz o NDVI ao decorrer das cinco avaliações. Os valores gerados na Figura 8.1 demonstram um crescimento inicial (estádio V9) mais desenvolvido na parte central da imagem, como já esperado ao analisar as imagens em cor verdadeira (Figura 6.1), onde já era possível verificar a discrepância de desenvolvimento da soja nesta área em relação às extremidades norte e sul. Esse desenvolvimento aparenta se tornar mais uniforme a partir da segunda avaliação (Figura 8.2), e permanece igual até a quarta avaliação (Figura 8.4), indicativo de que o dossel se fechou por completo, o que se confirma com a visita ao campo. Porém, ao verificar os gráficos de dispersão presente na Figura 9, é perceptível que o valor de NDVI se concentra em seu limite máximo (próximo a 1) entre as segunda e quarta avaliações, embora os valores de biomassa e altura de planta continuem aumentando. Dessa maneira, é possível afirmar que o Índice se torna saturado. Almeida *et al.* (2008) afirmam que valores de NDVI saturados inutilizam as análises que poderiam surgir com este índice, como por exemplo monitoramento da cultura, detecção e localização de pragas e estimativas de produção. Segundo Oliveira, Furlani e Zerbato (2017), os solos cobertos com plantas possuem pico de absorção no comprimento de onda da região do vermelho. Com isso, o NDVI se torna insensível para detectar a alteração de biomassa, o que reflete erroneamente na predição de produtividade. Desse modo, quando o objetivo do levantamento é utilizar o NDVI para fazer acompanhamento da cultura, ele não deve ser utilizado para medir variabilidade nos estádios V15 a R8.

Outro ponto é que seria esperado que o NDVI fosse um bom indicativo do IAF da soja. Alguns autores (XAVIER, 2002; HOLBEN; TUCKER, 1980) afirmam que o NDVI é eficiente para mapear o IAF, gerando boa relação entre essas duas variáveis. Porém, nota-se que tal parâmetro biofísico também sofreu com a saturação do NDVI (Figura 9.4). Estudos afirmam que para valores de IAF acima de 4, o NDVI já sofre com a saturação (ALMEIDA *et al.*, 2008; FONSECA, 2002; FIDELES FILHO, 2005), sendo que nas avaliações 2, 3 e 4, os valores médios de IAF foram, respectivamente 5,28, 5,49 e 6,32, comprovando esse efeito de saturação. Ainda analisando a Figura 9, é perceptível que os valores obtidos de IAF não permitem gerar uma análise temporal sobre a soja, pois não há acurácia nem precisão em seus valores, impossibilitando afirmar que esse parâmetro biofísico na soja é acompanhado pelo NDVI.

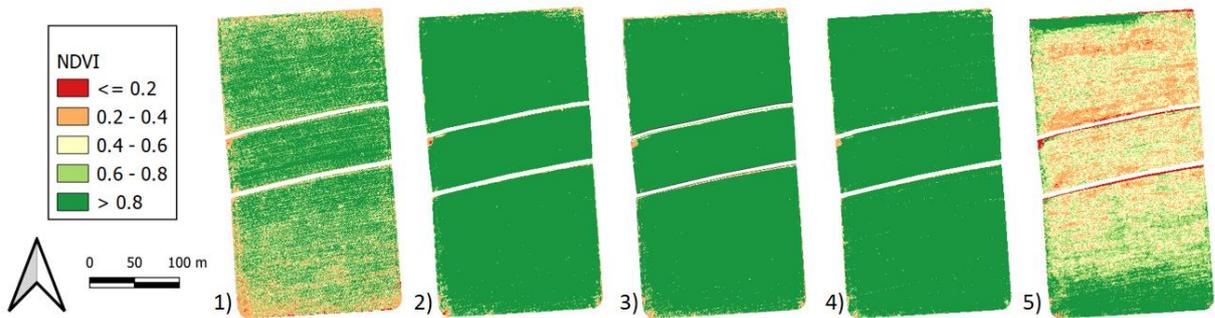


Figura 8. Imagens utilizando o NDVI, das cinco avaliações realizadas em ordem cronológica.

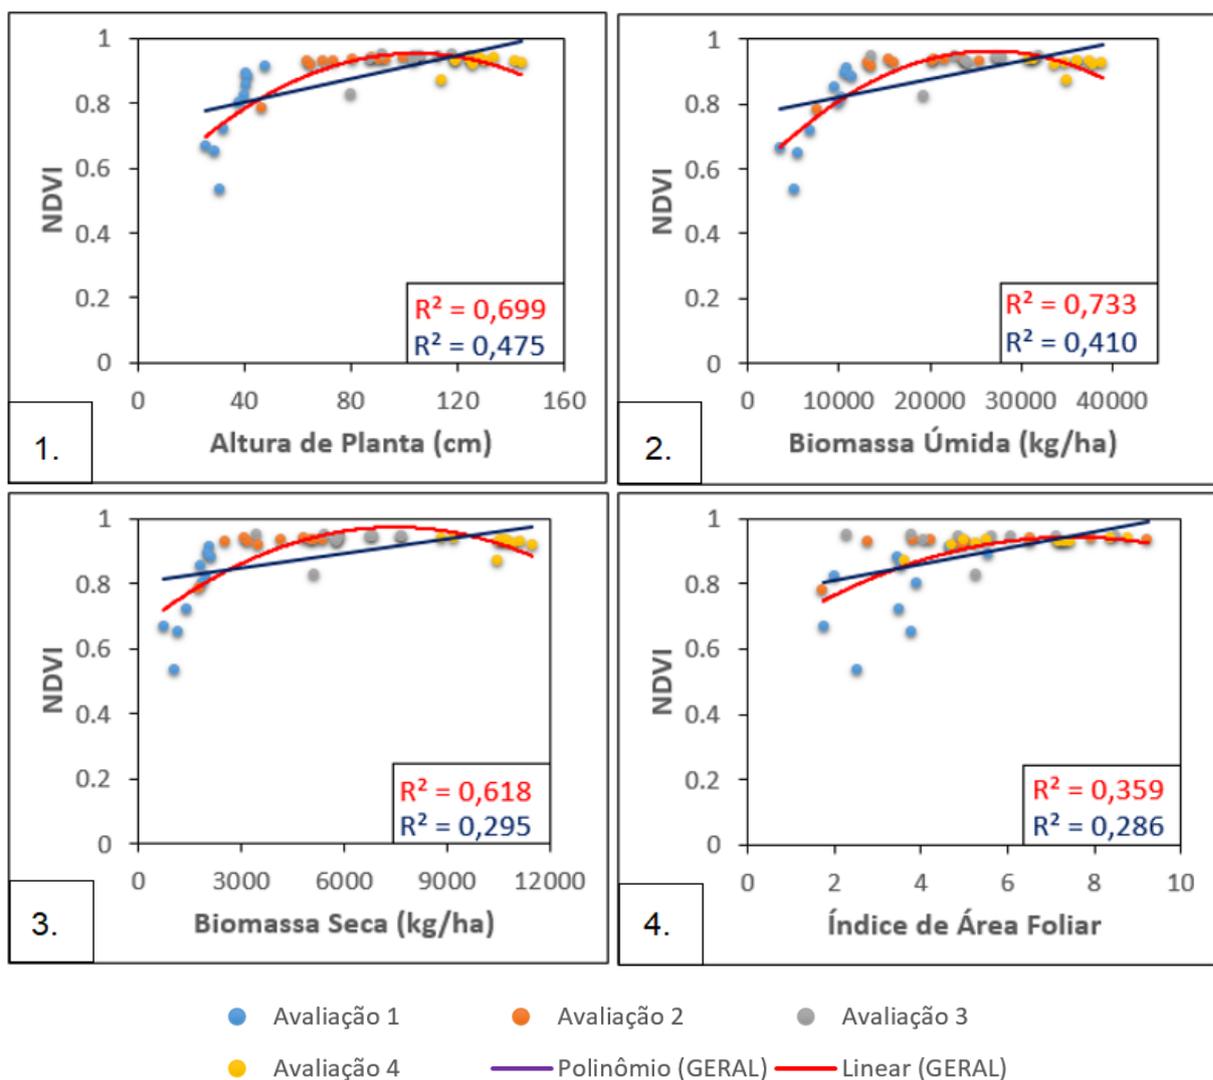


Figura 9. Gráficos de dispersão para parâmetros biofísicos coletados e NDVI.

O NDRE muitas vezes é apontado como alternativa ao NDVI porque é menos suscetível à saturação, permitindo a visualização e análise da imagem em casos de elevados valores de biomassa (HOLLAND; CHEPERS, 2010). Avaliando o comportamento do NDRE (Figura 10), é perceptível que não o mesmo tipo de

uniformidade de cor esverdeada entre as diferentes imagens (como aconteceu com as imagens em NDVI), comprovando a não saturação neste índice. Isso se confirma ao observar os gráficos de dispersão relativos ao NDRE versus parâmetros biofísicos (Figura 12). A banda borda do vermelho é menos suscetível ao problema de saturação do que a banda do vermelho utilizada no NDVI (BONFIL,2017). Tal banda penetra profundamente na cobertura vegetal da planta, tendo maior sensibilidade com a clorofila (e não com a quantidade de material vegetal, como o NDVI), diminuindo a possibilidade de ocorrer saturação (OLIVEIRA; FURLANI; ZERBATO, 2017). Diferentemente do NDVI, os gráficos de dispersão envolvendo o NDRE não apresentaram um patamar horizontal onde os pontos se concentram próximo ao valor de 1 do Índice. É possível verificar nos gráficos que há uma relação entre o IV e os parâmetros biofísicos, indicando que a variabilidade espacial pode ser verificada através desse uso do SR. Ainda, a partir da quarta avaliação (pontos em amarelo na Figura 11), o valor de NDRE começa a diminuir. Isso se deve ao início da senescência da soja, onde a coloração verde das plantas e vagens dá espaço à coloração amarelada, além do começo da perda de água em seus componentes. Isso se comprova ao verificar o estágio fenológico que ela se encontra. Segundo a Embrapa *et al.* (2013), o estágio R6 se caracteriza por iniciar esse processo de perdas de folhas e amarelecimento de forma contínua, até o estágio fenológico R8, ponto de maturação plena, com a presença de 95% das vagens maduras. Assim, pode-se dizer que o NDRE é uma boa alternativa ao NDVI para estádios fenológicos onde a produção de biomassa seja elevada. Neste estudo, recomenda-se a utilização do NDRE desde o início do acompanhamento do desenvolvimento da cultura da soja, pois o mesmo se apresenta capaz de acompanhar o crescimento e a variabilidade espacial em todas as avaliações.

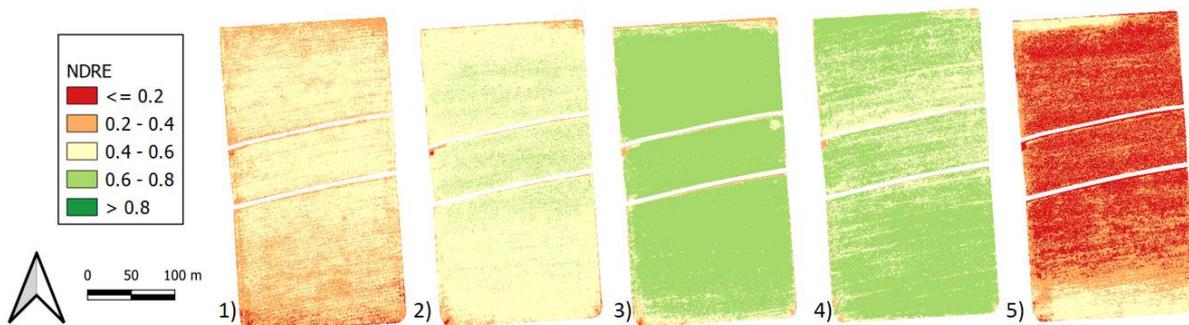


Figura 10. Imagens utilizando o Índice NDRE, das cinco avaliações realizadas em ordem cronológica.

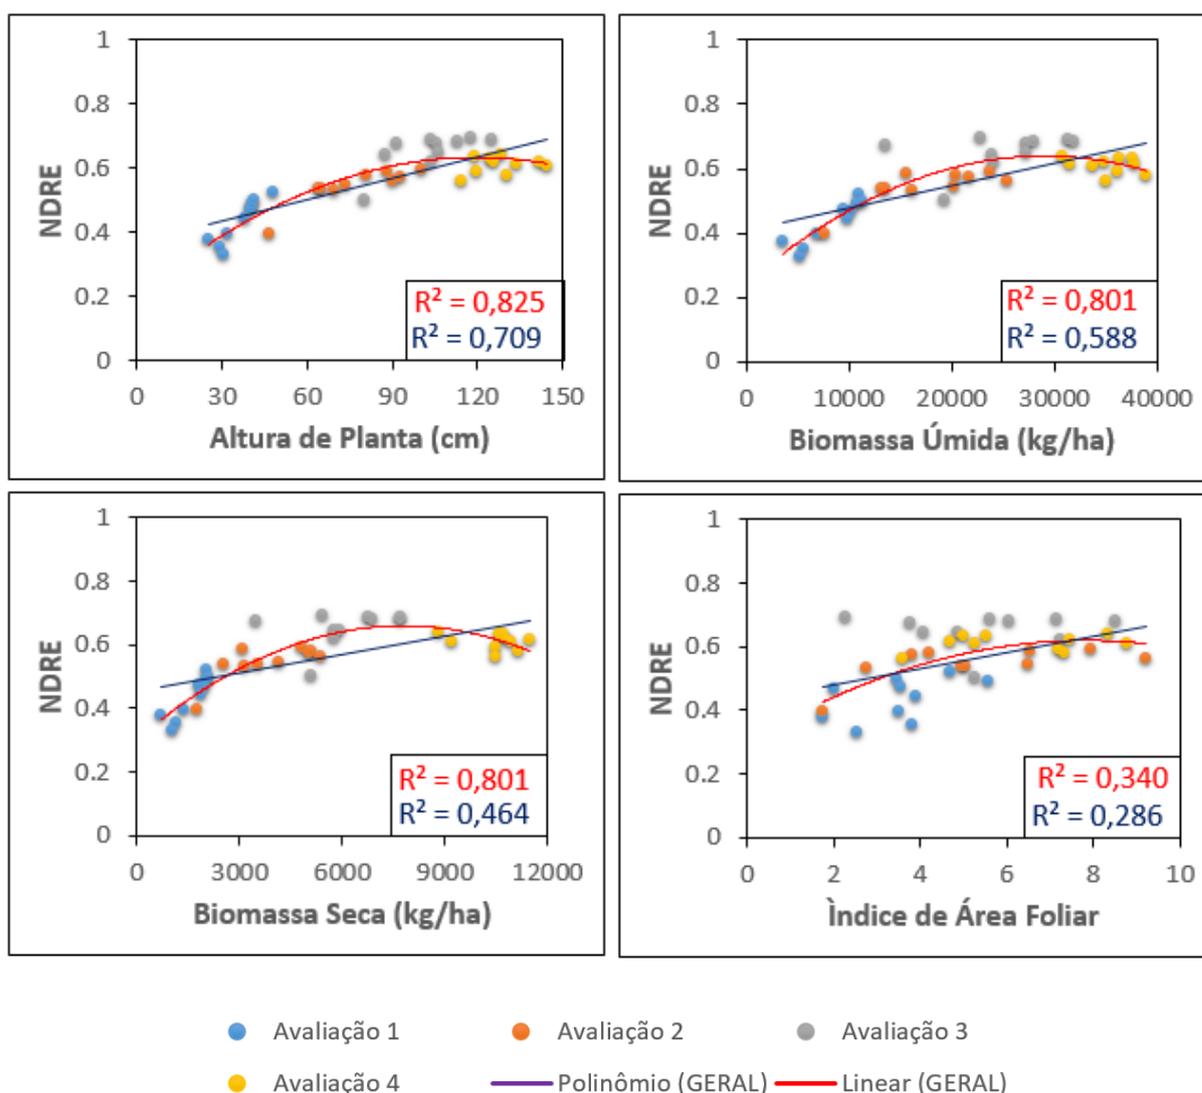


Figura 11. Gráficos de dispersão para parâmetros biofísicos coletados e NDRE.

Os demais IV's analisados obtiveram comportamento semelhante ao NDVI. Desta forma, apenas alguns casos serão particularmente analisados. Na Figura 12 estão contidos alguns dos gráficos de dispersão dos demais IV's em que os seus

valores também saturaram. O IRVI (Figura 12.1), segundo Bolfe *et al.* (2012), é menos suscetível à saturação que o NDVI, e é utilizado para predição de biomassa de áreas com alta atividade vegetativa. Esse IV apresenta valores próximos a 0 em culturas com bom desenvolvimento, inverso ao NDVI (próximo a 1). Mesmo Bolfe *et al.* (2012) afirmando que esse IV é menos suscetível à saturação, é possível verificar no gráfico da Figura 12.1 que os valores de IRVI também saturaram, igualmente o NDVI. Como esse IV também utiliza a banda do vermelho em sua composição, a saturação continuará sendo um problema.

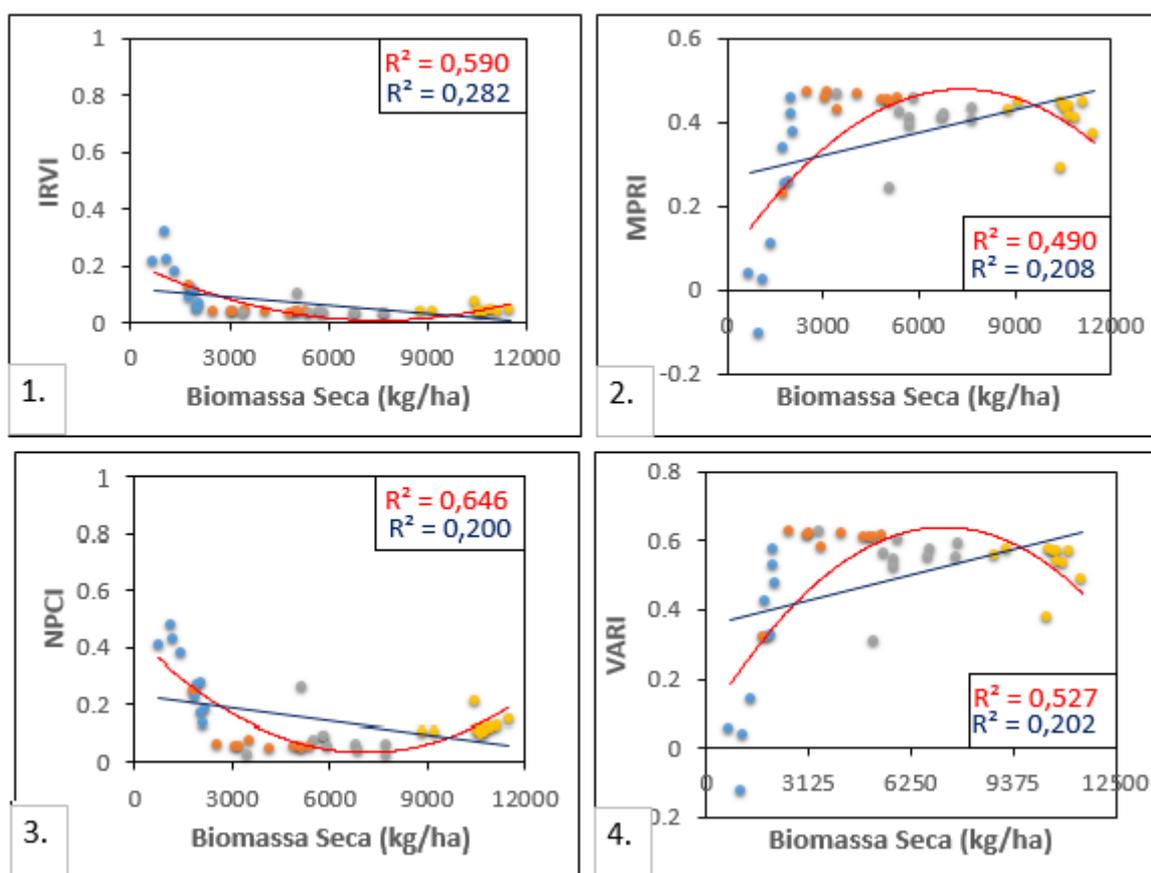


Figura 12. Gráficos de dispersão demonstrando saturação de alguns dos Índices de Vegetação avaliados. Os IVs dos gráficos 2, 3 e 4 são constituídos das bandas do visível, enquanto somente o IV do gráfico 1 utiliza banda fora do visível.

A Figura 12.2 apresenta o gráfico de dispersão utilizando o MPRI, IV que utiliza somente bandas do visível (verde e vermelho). O MPRI é correlato ao NDVI

(PADOLFI; RAMALDES; SANTOS, 2018), porém utilizando apenas bandas do RGB (banda do verde ao invés da banda do infravermelho próximo). Foram escolhidos alguns IV's compostos apenas por tais bandas, já que muitas câmeras embarcadas em drones possuem somente as bandas do visível. Yang *et al.* (2008) afirmam ser possível observar o comportamento da vegetação através das bandas do RGB e perceber que a relação existente entre as bandas verde e vermelho (componentes do MPRI) se aproxima do comportamento entre as bandas vermelho e infravermelho próximo (componentes do NDVI). Valores próximos a -1 representam ausência de vegetação ou solo exposto, portanto valores negativos podem ser encontrados nos gráficos de dispersão. Os valores próximos a 0 apresentam pontos com baixa densidade de vegetação, enquanto os valores mais próximos de 1 representam de média a alta densidade de vegetação (PADOLFI; RAMALDES; DOS SANTOS, 2018). Porém, esse índice também apresentou saturação a partir da segunda avaliação, semelhante ao NDVI. De qualquer forma, Linhares, Rocha e Amaral (2013) demonstraram alta correlação entre NDVI e MPRI para alvos como vegetação e solo. É possível notar que o valor de correlação encontrado entre esses dois Índices é alta (Figura 13), corroborando com a afirmação dos autores citados. Com isso, o MPRI se torna uma possibilidade para agricultores que não possuem câmera multiespectral em casos de culturas que não possuam grande crescimento ou densidade vegetativa.

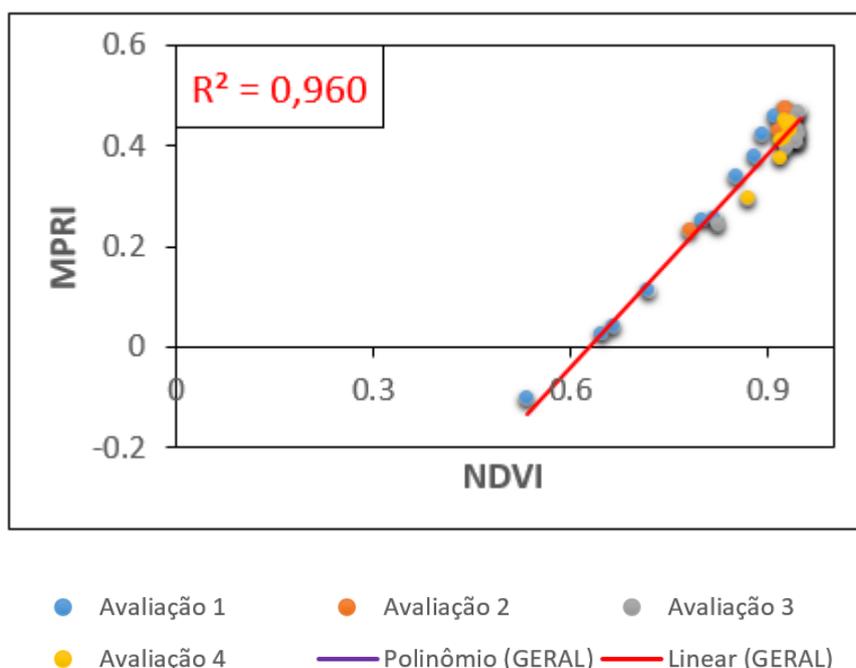


Figura 13. Gráfico de dispersão relacionado NDVI e MPRI.

O Índice NPCI (Figura 12.3) está relacionado diretamente com a senescência da planta. Valores próximo a 0 descrevem plantas saudáveis, enquanto valores próximos a 0,5 (limite superior do Índice) remetem a solo exposto e plantas senis, próximas à época da colheita (PEÑUELAS *et al.*, 1994). Tal Índice aparenta estar em seu limite de saturação, pois os pontos entre a segunda e terceira avaliação estão bem próximos a zero. Seus valores indicam vegetação saudável, quase a ponto de sua densidade vegetativa saturar o NPCI, já que ele também utiliza em sua composição a banda do vermelho que, como NDVI, MPRI e IRVI, tem saturado por alta densidade vegetativa neste estudo.

O mesmo problema de saturação também está presente no VARI (Figura 12.4). Valores negativos são comuns para áreas de solo exposto, enquanto valores próximos a 0,6 indicam áreas com concentração vegetativa (GITELSON *et al.*, 2003). O VARI, através da banda do vermelho, também presente em sua equação, é sensível à fração vegetativa presente na imagem, portanto sua saturação se explica da mesma maneira que os outros IV's aqui explicados. É possível ressaltar a semelhança entre os gráficos de dispersão desse IV com o MPRI (que utiliza as mesmas bandas que o VARI, com exceção da banda azul). A presença da banda azul funciona como um filtro para que não haja interferência da atmosfera na captação da biomassa verde presente na imagem (GITELSON, 2002). Como os gráficos são parecidos, estima-se que na área estudada há pouca interferência da atmosfera. Isso pode ser explicado pois, quando a luz solar penetra na atmosfera, ela se espalha devido a presença de gases, água e partículas no ar, com destaque para o comprimento de onda do azul, que tende a se espalhar mais que o resto do espectro visível (NOVO, 2010). Como as imagens deste estudo foram captadas por drone, não há tanta presença do efeito da banda azul, pois a altura em que voos são realizados é baixa se comparada a uma imagem orbital (OKUMURA, 2020).

Os mapas de cada um dos Índices destacados na Figura 12 podem ser encontrados nos Apêndices deste trabalho, bem como seus gráficos de dispersão relacionados com todos os parâmetros biofísicos analisados.

5. CONCLUSÕES

O objetivo do presente trabalho era identificar a variabilidade espaço-temporal de uma lavoura de soja por meio de imagens de drone. A variabilidade temporal da soja foi comprovada por meio da evolução nos valores dos índices de vegetação ao longo das avaliações, relacionando-se com os os parâmetros biofísicos coletados, demonstrando o crescimento da cultura, bem como sua senescência.

A variabilidade espacial da soja também foi captada pelas imagens obtidas pelo drone. A cada gráfico de dispersão foi possível identificar valores diferentes presentes na mesma avaliação, o que comprova que há diferenciação no desenvolvimento da cultura de acordo com a localização da planta. O NDRE se mostrou o IV mais eficiente para correlacionar os parâmetros biofísicos à essa variabilidade, e, portanto, o indicado para acompanhamento da soja.

Os IV's que apresentaram saturação neste estudo não são indicados para acompanhamento do cultivo da soja. No intervalo entre o estágio fenológico V15 (apresentado na segunda avaliação), e o estágio R6 (apresentado na quarta avaliação), o crescimento da biomassa passa a não ser acompanhado pelos IV's NDVI, IRVI, MPRI, NPCI e VARI.

REFERÊNCIAS

ALMEIDA, T.S. *et al.* Índices de vegetação para a cultura da soja em diferentes condições hídricas e de sistema de manejo do solo. **Anais. XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, 2005.

AMADO, T. J. C. *et al.* Variabilidade espacial e temporal da produtividade de culturas sob sistema de plantio direto. **Pesquisa Agropecuária Brasileira**, v. 42, n. 8, p. 1101-1110, 2007.

AMARAL, L. R. *et al.* Coletar, interpretar e agir. **Cultivar**, p. 10-14, out. 2019. Disponível em: <https://www.feagri.unicamp.br/gitap/images/artigos/boletim_drones.pdf> Acesso em: 20 nov. 2020.

AMORIM, *et al.* Época de semeadura no Potencial produtivo de Soja em Uberlândia-MG. **Semina Ciências Agrárias**, v. 32, n. 4, p. 1793-1802, 2011.

ANTUNES, J. F. G.; LAMPARELLI, R. A. C.; RODRIGUES, L. H. A. Avaliação da dinâmica do cultivo da cana-de-açúcar no estado de São Paulo por meio de perfis temporais de dados MODIS. **Engenharia Agrícola**, v. 4430, n. 6, p. 1127–1136, 2015.

ARANTES *et al.* Drone aplicado na agricultura digital. **Ipê Agronomic Journal**. v. 3, n. 1, p. 14–18, 2019. Disponível em < <http://anais.unievangelica.edu.br/index.php/ipeagronomicjournal/article/view/4323/2595>>. Acesso em 07 dez. 2020.

ARAÚJO, A. S. de. **Comportamento Espectral de Alvos**. Curitiba, 2016.

BARCELOS, A. C. **O uso de veículo aéreo não tripulado (VANT) em monitoramento de campo: aplicabilidades e viabilidades**. 58f. Monografia. Universidade Federal de Uberlândia, Uberlândia, 2017.

BOLFE, E. L.; BATISTELLA, M.; FERREIRA, M. C. Correlação de variáveis espectrais e estoque de carbono da biomassa aérea de sistemas agroflorestais. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1261-1269, 2012.

BONFIL, D. J. Wheat phenomics in the field by RapidScan: NDVI vs NDRE. **Israel Journal of plant Sciences**, v. 64, p. 3-4, 2017.

BRANDÃO, Z. N. **Estimativas da produtividade e estado nutricional da cultura do algodão irrigado via técnicas de sensoriamento remoto**. 152 f. Tese (Doutorado em Recursos Naturais). Universidade Federal de Campina Grande, Campina Grande, 2009.

_____ *et al.* Agricultura de precisão para gerenciamento de algodão. In AZEVÊDO, D. M. P.; BELTRÃO, N. E. M. **O agronegócio do algodão no Brasil**. Embrapa Informação Tecnológica, 2008.

BREUNIG, F. M.; GALVÃO, L. S.; NETO, R. P. M. Drones na Agricultura de Precisão. In: PRUDKIN, G.; BREUNIG, F. M. **Drones e Ciência: Teoria e Aplicações metodológicas**. v. 1, p. 92-111, 2019.

BUSCHMANN, C.; NAGEL, E. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. **International Journal of Remote Sensing**, v. 14, n. 4, p. 711-722, 1993.

CARNEIRO, F. M. **Sensores de dossel no monitoramento da variabilidade temporal das culturas da soja e do amendoim**. 2018. 122 f. Tese (Doutorado) - Curso de Agronomia, Universidade Estadual Paulista, Jaboticabal, 2018.

CHAVES, R. D. *et al.* Modelo digital de superfície a partir de imagens adquiridas num levantamento aereo com vant. **Anais da XVII ENPOS** - Encontro de Pós-Graduação da UFPel, Pelotas, 2015.

COELHO, A. M. Agricultura de precisão: manejo da variabilidade espacial e temporal dos solos e das culturas. In: NOVAIS, R.F *et al.* **Tópicos em ciência do solo**. Sociedade Brasileira de Ciência do Solo, v. 1, p.249-290, 2003.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS journal of photogrammetry and remote sensing**, v. 92, p. 79-97, 2014.

COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB. **Acompanhamento de safra brasileira: grãos, décimo segundo levantamento, setembro/2019**. Brasília: Conab, 2019. Disponível em < <https://www.conab.gov.br/info-agro/safras/graos/monitoramento-agricola>>. Acesso em 21 out. 2019.

_____. **Acompanhamento de safra brasileira: grãos, nono levantamento, junho/2020**. Brasília: Conab, 2020. Disponível em < <https://www.conab.gov.br/info-agro/safras/graos/monitoramento-agricola>>. Acesso em 21 nov. 2020.

DALL’AGNOL, A. Os caminhos que levam à alta produtividade da soja. **Campo & Negócios**, 2019. Disponível em <https://revistacampoenegocios.com.br/os-caminhos-que-levam-a-alta-produtividade-da-soja/>>. Acesso em 06 dez. 2020.

DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO (DECEA). **DECEA esclarece normas para voos de drones no Brasil**. Disponível em: <www2.fab.mil.br/cenipa/index.php/ultimas-noticias/871-decea-esclarece-normas-para-voos-de-drones-no-brasil>. Acesso em: 20 nov. 2020.

ECHER, M.P.; MARTINS, F.R.; PEREIRA, E.B. A importância dos dados de cobertura de nuvens e de sua variabilidade: metodologias para aquisição de dados. **Revista Brasileira de Ensino de Física**, v. 28, n. 3, p. 341-352, 2006. Disponível em <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-11172006000300011&lng=e n&nrm=iso>. Acesso em 29 nov. 2020.

EMBRAPA SOJA, **Tecnologias de produção de soja** – Região Central do Brasil 2014. – Londrina: Embrapa Soja, 2013.

ESTATÍSTICAS DE COMÉRCIO EXTERIOR DO AGRONEGÓCIO BRASILEIRO – AGROSTAT. **Indicadores Gerais Agrostat: Exportações do Agronegócio – 2019**. Brasília: Ministério da Agricultura, Pecuária e Abastecimento, 2019. Disponível em < <http://indicadores.agricultura.gov.br/index.htm>>. Acesso em 21 out. 2019.

FIDELES FILHO, J. *et al.* Monitoramento de área foliar e biomassa do feijoeiro usando índice de vegetação por diferença normalizada. **Revista Brasileira de Agrometeorologia**, v. 13, n.2, p.212-218, 2005.

FIAMENGHI, C. C. B.; ROSALEN, D. L.; ZERBATO, C. Determinação de índices de vegetação na cultura da soja (*Glycine max* (L.)) através de sensor terrestre. In: **XVLI Congresso Brasileiro de Engenharia Agrícola**. Maceió, 2017.

FONSECA, E. L.; ROSA, L. M. G.; FONTANA, D. C. Caracterização espectral de *Paspalum notatum* em diferentes níveis de adubação nitrogenada. **Pesquisa Agropecuária Brasileira**, v. 37, n. 3, p. 365-371, 2002.

FRANCHINI, J. C. *et al.* Imagens aéreas, parâmetros químicos e biológicos para o diagnóstico de regiões com potencial variável de produção em um campo de soja. **VIII Congresso Brasileiro de Soja**. Goiânia, 2018. Disponível em < <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1093396/imagens-aereas-parametros-quimicos-e-biologicos-para-o-diagnostico-de-regioes-com-potencial-variavel-de-producao-em-um-campo-de-soja> >. Acesso em 21 out. 2019.

FORMAGGIO, A. R.; SANCHES, IDEL'A. **Sensoriamento Remoto em agricultura**. São Paulo: Oficina de Textos, 2017.

GIRALDELI, A. L. **Drones na agricultura: como eles te ajudam a lucrar mais**. 2019. Disponível em < <https://blog.aegro.com.br/drones-na-agricultura/> > Acesso em 20 nov. 2020.

GITELSON, A., *et al.* Vegetation and Soil Lines in Visible Spectral Space: A Concept and Technique for Remote Estimation of Vegetation Fraction. **International Journal of Remote Sensing**, v. 23, p. 2537–2562, 2002.

_____. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v.80, p.76-87, 2002.

GOBBI, K. F. *et al.* Características morfológicas, estruturais e produtividade do capim-braquiária e do amendoim forrageiro submetidos ao sombreamento. **Revista Brasileira de Zootecnia**, v. 38, n. 9, 1645-1654, 2009.

GONÇALVES, L. M. *et al.* Variabilidade espacial e temporal do índice vegetação MPRI aplicado às imagens de grama São Carlos obtidas por aeronave remotamente pilotada. **Revista Brasileira de Engenharia de Biossistemas**, v. 11, n. 4, p. 340-349, 2017.

HOLBEN, B. N.; TUCKER, C. J.; FAN, C. J. Spectral assessment of soybean leaf area and leaf biomass. **Photogrammetric Engineering and Remote Sensing**, v. 46, p. 651-655, 1980.

HOLLAND, K. H.; SCHEPERS, J. S. Derivation of a variable rate nitrogen application model for in-season fertilization of corn. **Agronomy Journal**, v. 102, n 5, p.1415-1424, 2010.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Cartograma – soja**. 2017 Disponível em < <https://censos.ibge.gov.br/agro>

/2017/templates/censo_agro/resultadosagro/agricultura.html?localidade=0&tema=76518>. Acesso em 30 nov. 2020.

INSTITUTO DE TECNOLOGIA AERONÁUTICA REMOTAMENTE CONTROLADA – ITARC. **Saiba mais sobre o uso de drones na pecuária**. 2020. Disponível em: <<https://itarc.org/uso-de-drones-na-pecuaria/>>. Acesso em: 21 nov. 2020.

INSTITUTO MATO-GROSSENSE DE ECONOMIA AGROPECUÁRIA – IMEA. **16/11/2020 - Custo de produção - soja**. Disponível em <<http://www.imea.com.br/imea-site/relatorios-mercado-detalhe?c=4&s=3>>. Acesso em 21 nov. 2020.

JENSEN, J.R. **Sensoriamento Remoto: princípios e aplicações**. 3 ed. Parêntese, 2009.

JONES, F. **Pulverização por drones**. 2019. Disponível em: <<https://revistapesquisa.fapesp.br/pulverizacao-por-drones/>>. Acesso em: 21 nov. 2020.

JORGE, L. A. C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. In: BERNARDI, A. C. de C. *et al.* **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014.

KAPP JÚNIOR, C.; GUIMARÃES, A. M.; CAIRES, E. F. Uso de sensores ativos de dossel para discriminar a resposta do trigo à fertilização com nitrogênio sob plantio direto. **Engenharia Agrícola**, v. 36, n. 5, p. 886-894, 2016.

LINHARES, M. M. A.; ROCHA, N. C. C.; AMARAL, B. A. D. Análise do Índice MPRI como indicador vegetativo através da correlação do mesmo com o Índice NDVI. In: **XVI Simpósio Brasileiro de Sensoriamento Remoto**. Foz do Iguaçu: INPE, 2013.

LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. São Paulo: Blucher, 2015.

LUIZ, A. J. B. **Sensoriamento Remoto agrícola**. 95f. Tese (Doutorado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2002.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO – MAPA. **Agricultura de Precisão. Boletim Técnico**. Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Brasília: MAPA/ACS, 2009.

MARCUSSI, A. B. *et al.* Utilização de Índices de Vegetação para os Sistemas de Informação Geográfica. **Caminhos da Geografia**, Uberlândia. v. 11, n. 35, p. 41-53, 2010.

MENDES, L. G. **Drones e agricultura de precisão: 8 pontos para você considerar**. Disponível em: <<https://blog.aegro.com.br/drone-agricultura-de-precisao/>>. Acesso em: 20 nov. 2020.

MERZLYAK, M. N. *et al.* Nondestructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia plantarum**, v. 106, n. 1, p. 135- 141, 1999.

MICASENSE. **Best practices: Collecting Data with MicaSense Sensors.** MicaSense Knowledge Base, Guides and Documentation. Disponível em <<https://support.micasense.com/hc/en-us/articles/224893167>>. Acesso em: 10 jul. 2020.

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. F. **Agricultura de Precisão.** 1ºed. Oficina de Textos. São Paulo, 2015.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação.** 4. ed. Viçosa, 2011.

MOURA, L. S. B. **Drone de combate aos incêndios florestais.** 2019. 114 f. Dissertação (Mestrado) – Faculdade de engenharia da Universidade do Porto, Porto, 2019.

NEUMAIER, N. *et al.* Estádios de desenvolvimento da cultura de soja. In: Bonatto, E.R. **Estresses em soja.** Passo Fundo: Embrapa Trigo, 2000.

NOVO, E. M. L. **Sensoriamento Remoto: princípios e aplicações.** São Paulo: Blucher, 2010.

_____, PONZONI, F. J. **Introdução ao Sensoriamento Remoto.** INPE, São José dos Campos, 2009.

OKUMURA, R. **A utilização de drones e análise de imagens na agricultura.** Disponível em < <https://venturus.org.br/a-utilizacao-de-drones-e-analise-de-imagens-na-agricultura/>>. Acesso em 30 nov. 2020.

OLIVEIRA, M. F. de; FURLANI, C. E. A.; ZERBATO, C. **Modelos de predição de produtividade da cultura do milho por meio de NDVI em arranjos espaciais.** 2017. 44 f. Tese (Mestrado) - Curso de Agronomia, Universidade Estadual Paulista, Jaboticabal, 2017.

PADOLFI, A. S.; RAMALDES, G. P.; SANTOS, O. L. dos. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica da FAESA.** Vitória, v. 14, n. 1, p. 145-165, 2018. Disponível em < <http://revista.faesa.br/revista/index.php/Faesa/article/view/267>>. Acesso em 21 out. 2019.

PERALTA, N. R. *et al.* Mid-season high-resolution satellite imagery for forecasting site-specific corn yield. **Remote Sensing**, Basel, v. 8, p. 1-16, 2016.

PEÑUELAS, J.*et al.* Estimation of plant water concentration by the reflectance water index. **International Journal of Remote Sensing**, v. 18, p. 2869-2875, 1997.

_____ *et al.* Reflectance indices associated with physiological changes in nitrogen and water-limited sunflower leaves. **Remote Sensing of Environment**, v.48, n.2, p.135-146, 1994.

REIPS, L.; GUBERT, L. C. Drones como ferramenta de apoio para agricultores do Rio Grande do Sul. **RUFG**, Goiânia, v. 19, p. 1-19, 2019.

RICHTER, G. L.; *et al.* Estimativa da área de folhas de cultivares antigas e modernas de soja por método não destrutivo. **Bragantia**, v. 73, n. 4, p. 416-425, 2014.

ROSA, R. **Introdução ao Sensoriamento Remoto**, Uberlândia: EDUFU, 2007.

ROUSE, J. W. *et al.* **Monitoring the vernal advancement and retrogradation (greenwaveeffect) of natural vegetation**. Greenbelt, 1974.

SEBBANE, Y. B. **Intelligent Autonomy of UAVs : Advanced Missions and Future Use**. Disponível em < https://books.google.pt/books?id=OGNRDwAAQBAJ&dq=UAV+impact&hl=pt-PT&source=gbs_navlinks_s>. Acesso em 09 nov. 2020.

SILVA, E. T. J. B. **Utilização dos índices de Vegetação do Sensor MODIS para Detecção de Desmatamentos no Cerrado**: Investigação de Parâmetros e Estratégias. 2004, 146 f. Dissertação (Mestrado em Geologia) – Universidade de Brasília, Brasília, 2004.

SHIRATSUCHI, L. S. *et al.* Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão**: resultados de um novo olhar. Brasília: EMBRAPA, p.58-73, 2014.

SYNGENTA BRASIL. **Sementes Soja - estágios de evolução**. Disponível em <<https://portalsyngenta.com.br/sementes-soja-estagios-de-evolucao>>. Acesso em: 10 jul. 2020.

TAIPELE, E. **NDVI vs. NDRE: What's the Difference?** 2018. Disponível em < <https://sentera.com/ndvi-vs-ndre-whats-difference/>> Acesso em: 07 dez. 2020.

TARNAVSKY, E.; GARRIGUES, S.; BROWN, M. E. Multiscale geostatistical analysis of AVHRR, SPOT-VGT, and MODIS global NDVI products. **Remote Sensing of Environment**, Madison, v. 112, p. 535-549, 2008.

VIÑA, A. *et al.* Monitoring maize (*Zea mays* L.) phenology with remote sensing. **Agronomy Journal**, v.96, p.1139-1147, 2004.

VIBHUTE, A.; BODHE, S. K. Applications of image processing in agriculture: a survey. **International Journal of Computer Applications**, v. 52, p. 34-40, 2012.

YANG, Z.; WILLIS, P.; MUELLER, R. Impact of Band-Ratio Enhanced AWIFS Image to Crop Classification Accuracy. In: Pecora – The Future of Land Imaging. Going Operational, 17. 2008, Denver, Colorado, USA. **Anais**. Maryland, 2008.

XAVIER, A. C. **Estimativa da dinâmica do índice de área foliar em uma microbacia hidrográfica por meio de técnicas de sensoriamento remoto**. Tese (Doutorado em Irrigação e Drenagem). Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2002.

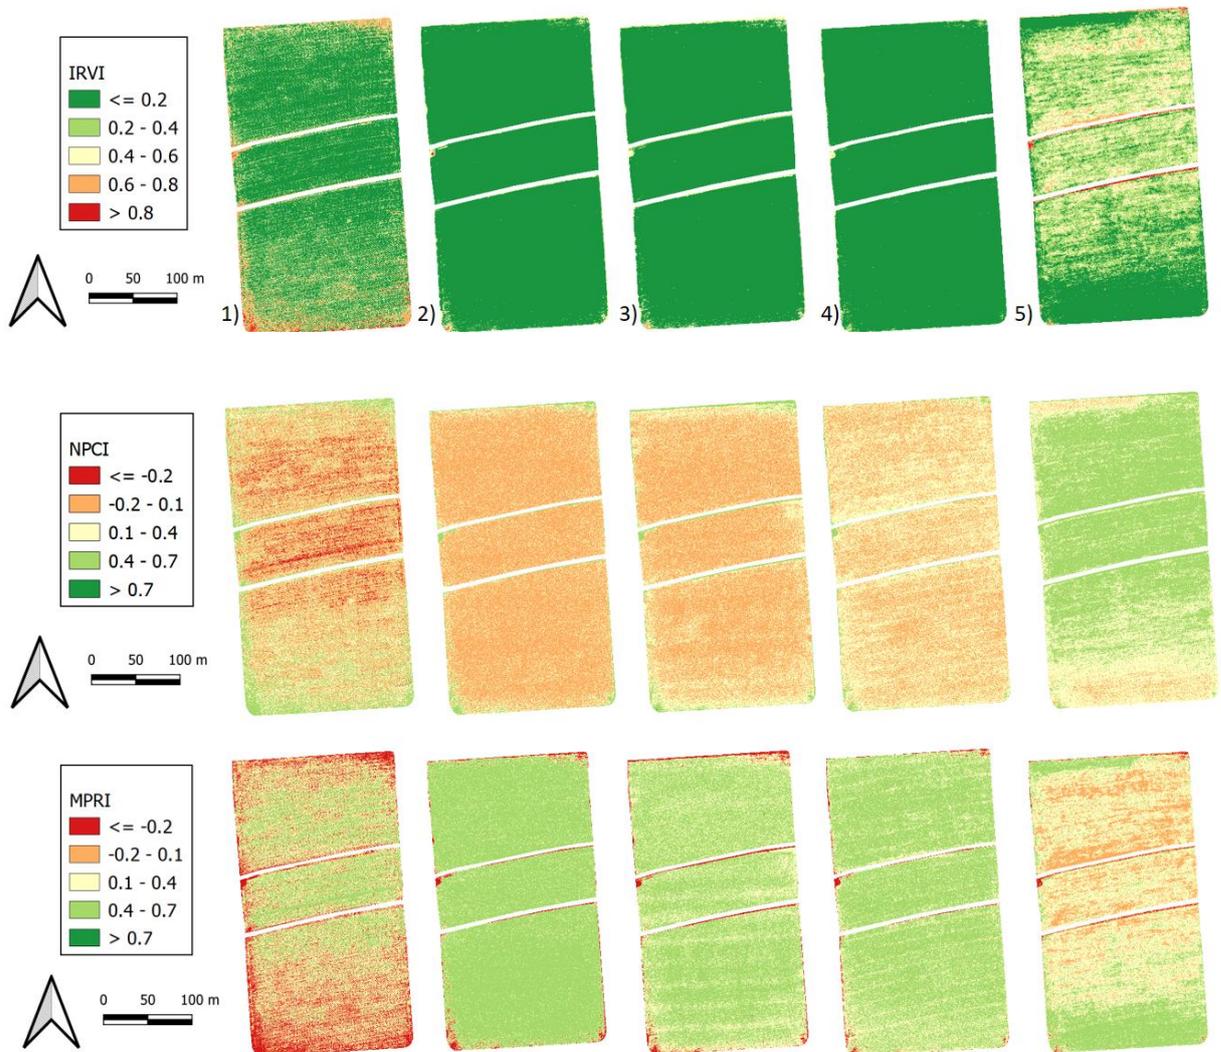
ZANON, A. J. *et al.*. Contribuição das ramificações e a evolução do índice de área foliar em cultivares modernas de soja. **Bragantia**, v. 74, n. 3, p. 279-290, 2015.

ZAPAROLLI, D. Agricultura 4.0. **Pesquisa Fapesp**, São Paulo, v. 1, n. 287, p. 3-5, 2020. Disponível em <<https://revistapesquisa.fapesp.br/agricultura-4-0/>>. Acesso em: 20 nov. 2020.

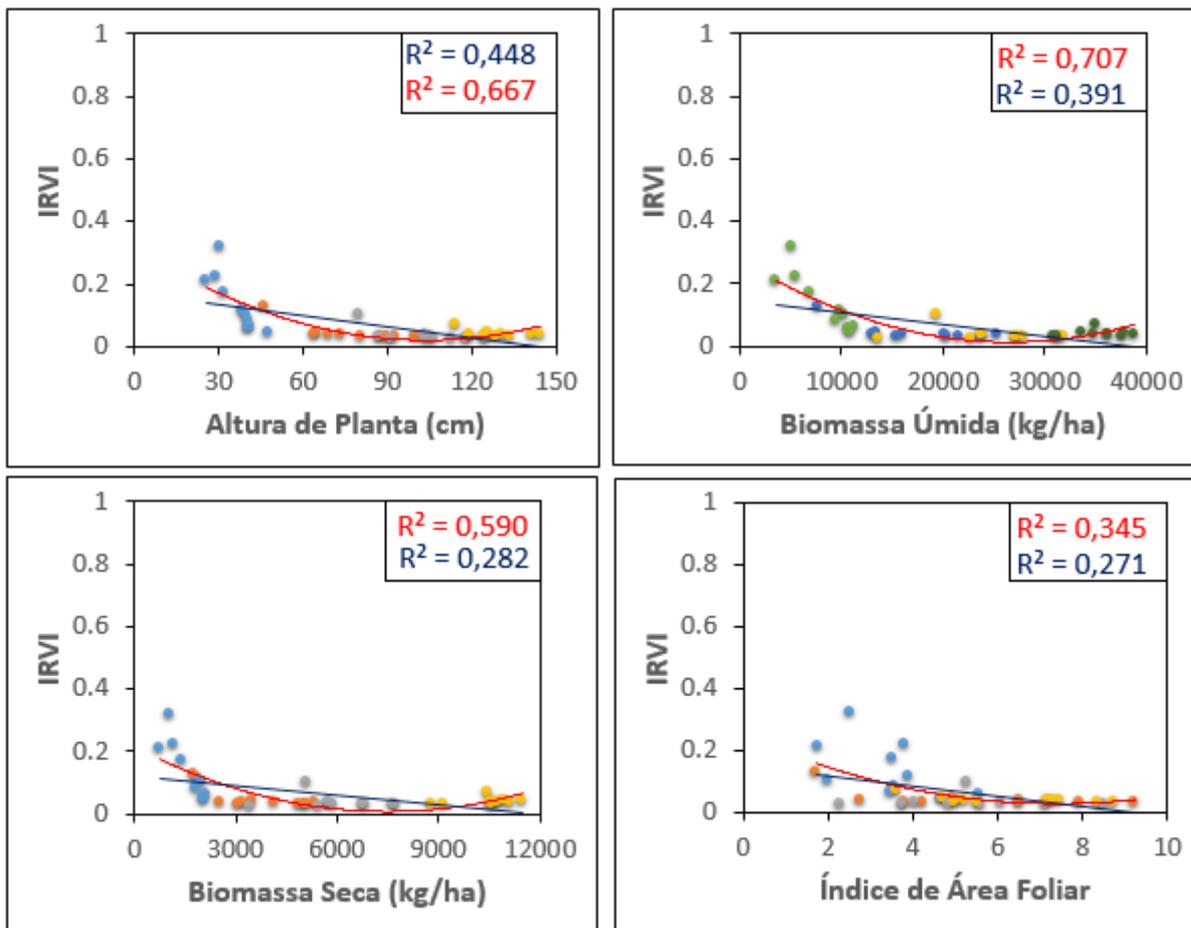
ZHANG, C.; MARZOUGUI, A.; SANKARAN, S. High-resolution satellite imagery applications in crop phenotyping: an overview. **Computers and electronics in Agriculture**, v. 175, 2020.

APÊNDICES

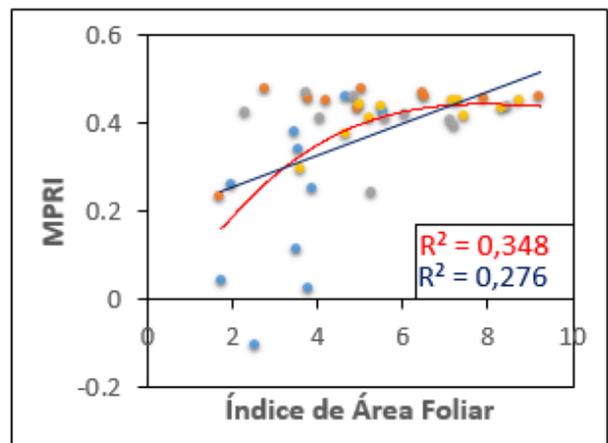
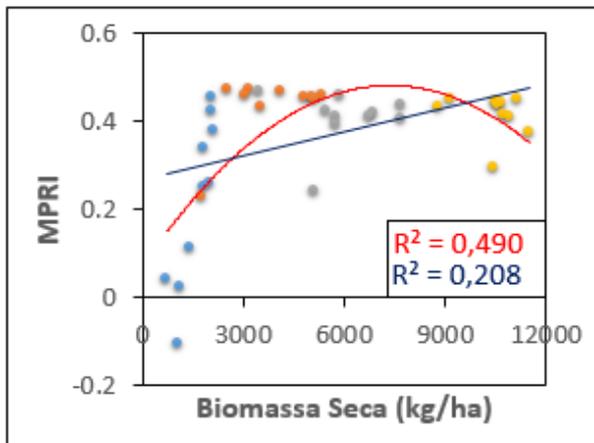
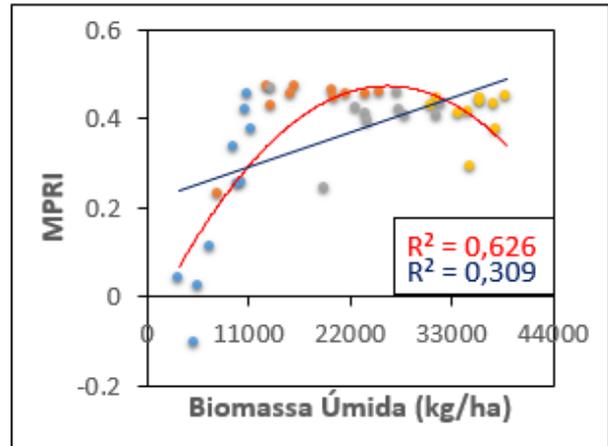
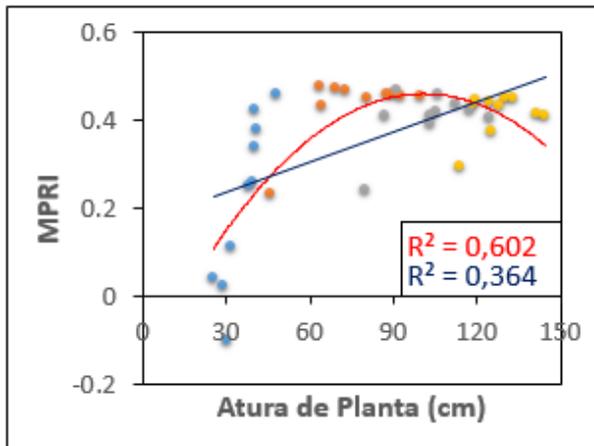
APÊNDICE A. Imagens utilizando o IRVI, NPCI e MPRI das cinco avaliações realizadas em ordem cronológica.



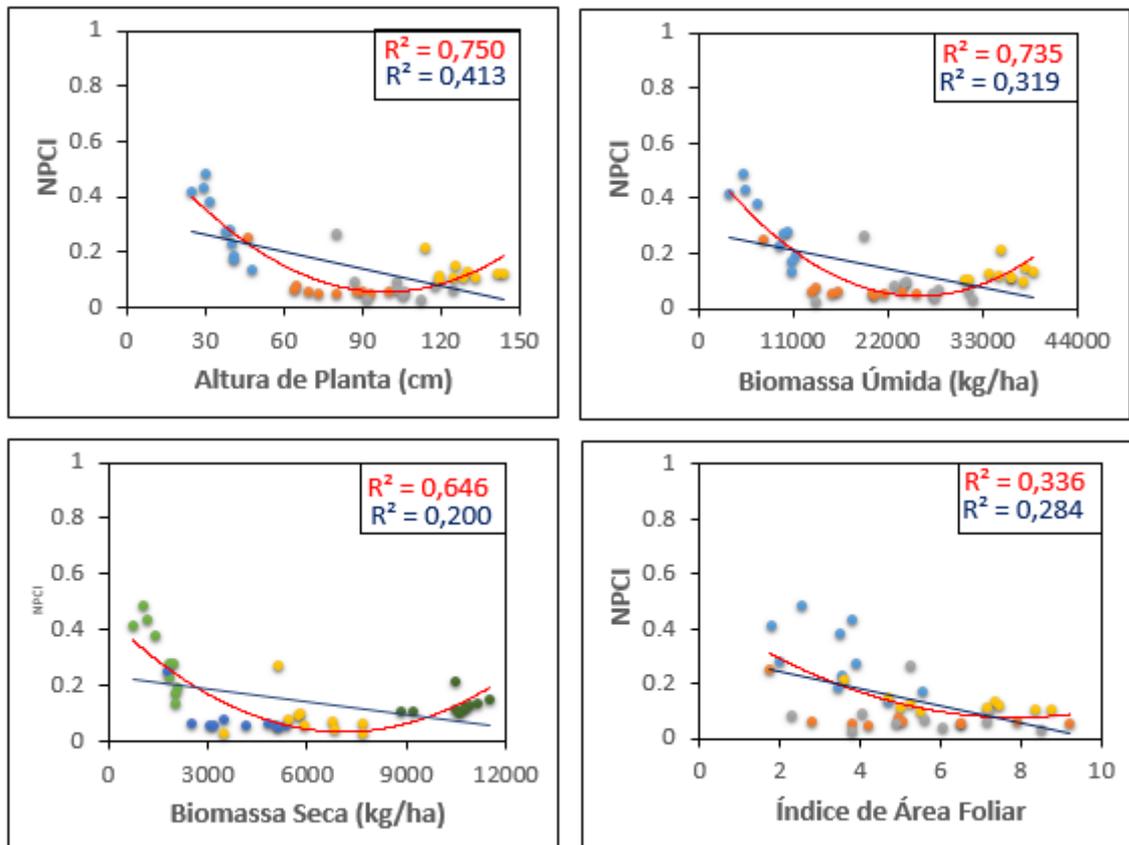
APÊNDICE B. Gráficos de dispersão para parâmetros biofísicos coletados e IRVI.



APÊNDICE C. Gráficos de dispersão para parâmetros biofísicos coletados e MPRI.



APÊNDICE D. Gráficos de dispersão para parâmetros biofísicos coletados e NPCI.



APÊNDICE E. Gráficos de dispersão para parâmetros biofísicos coletados e VARI.

