

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

RIENE FILGUEIRAS DE OLIVEIRA

ESTIMATIVA DA PRODUTIVIDADE DO ALGODOEIRO A PARTIR DE
ÍNDICES DE VEGETAÇÃO DERIVADOS DE IMAGENS ORBITAIS DE ALTA
RESOLUÇÃO ESPACIAL

PORTO ALEGRE

2019

RIENE FILGUEIRAS DE OLIVEIRA

ESTIMATIVA DA PRODUTIVIDADE DO ALGODOEIRO A PARTIR DE
ÍNDICES DE VEGETAÇÃO DERIVADOS DE IMAGENS ORBITAIS DE ALTA
RESOLUÇÃO ESPACIAL

Dissertação apresentada ao
programa de Pós-Graduação em
Sensoriamento Remoto, da
Universidade Federal do Rio Grande
do Sul como requisito para obtenção
do grau de Mestre em
Sensoriamento Remoto.

Orientador: Prof. Dr. Cláudio
Wilson Mendes Jr.

PORTO ALEGRE

2019

RIENE FILGUEIRAS DE OLIVEIRA

ESTIMATIVA DA PRODUTIVIDADE DO ALGODOEIRO A PARTIR DE
ÍNDICES DE VEGETAÇÃO DERIVADOS DE IMAGENS ORBITAIS DE ALTA
RESOLUÇÃO ESPACIAL

Banca examinadora:

Prof. Dr. Christian Bredemeier – FAGRO/UFRGS

Prof. Dra. Denise Cybis Fontana – PPGSR/UFRGS

Prof. Dr. Marcos Wellausen Dias de Freitas – PPGSR/UFRGS

Prof. Dr. Cláudio Wilson Mendes Júnior (Orientador) – PPGSR/UFRGS

Aprovado em 06 de setembro de 2019

*Dedico aos meus pais,
Arlete Filgueiras de Oliveira
&
Marcus Vinícius de Oliveira (in memorian)*

AGRADECIMENTOS

À Deus, que sempre foi soberano na minha vida e me deu força e coragem durante esta caminhada.

Agradeço à Universidade Federal do Rio Grande do Sul e ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, pela estrutura disponibilizada para o desenvolvimento desta dissertação.

À CAPES, pela bolsa de estudos em nível de pós-graduação, essencial para o desenvolvimento deste trabalho.

Ao meu orientador, Prof. Cláudio Mendes Junior, pela paciência, dedicação, conselhos e incentivo a mim dados, para o desenvolvimento deste trabalho.

Ao Prof. Dr. Christian Bredemeier, pela parceria e apoio no trabalho.

À Empresa Terra Santa, em especial ao meu amigo Gabriel Benhossi, pela confiança e disponibilidade das informações que foram fundamentais para realização deste trabalho.

Ao Laboratório de Modelagem Ricardo Norberto Ayup Zouain – LabModel.

À minha mãe Arlete Filgueiras pelo amor incondicional e apoio, obrigada por tudo, sempre.

Aos queridos colegas Pâmela Pithan e Diniz Arruda pelo bom convívio, que ao longo desses dois anos se tornaram grandes amigos, obrigada pela companhia, pelos conselhos e até pelas discussões que sempre acabaram em boas risadas. Vocês trouxeram leveza e alegria nessa jornada.

Aos demais amigos e familiares que contribuíram com energias positivas para que os objetivos vislumbrados fossem atingidos.

Sou super grata!

Que nada nos limite, que nada nos defina, que nada nos sujeite, que a liberdade seja a nossa própria substância, já que viver é ser livre.

Simone de Beauvoir

RESUMO

O Brasil é o sexto maior produtor mundial de algodão, que é um cultivo de grande relevância para o agronegócio. A utilização de dados do Sensoriamento Remoto orbital vem ganhando destaque para o monitoramento dessa cultura. No algodão, é crescente a necessidade de estimativas de safra confiáveis para o planejamento adequado das unidades produtoras, entidades de classe e governo. Neste contexto, esta dissertação tem por objetivo principal estimar a produtividade do algodoeiro por meio de índices espectrais de vegetação, derivados de imagens MSI - Sentinel 2. Este estudo foi realizado em três talhões de algodão (C-01, D-07, E-01) em uma Unidade de Produção (UP) com 612 hectares, localizada no município de Nova Mutum-MT. Quatro imagens do sensor MSI foram utilizadas para a caracterização da resposta espectral do dossel do algodoeiro, entre o período de início da floração e da frutificação completa do algodão, referente às datas 17/abr, 07/mai, 27/mai e 16/jun de 2018. Foi feita a correção atmosférica das imagens MSI das bandas espectrais do Visível (RGB), Infravermelho Próximo (IVP) e Red Edge (RE) para seu uso no cálculo de 23 índices de vegetação (IVs). Foram também avaliados os dados espectrais na forma acumulada, ou seja, somando-se os valores das quatro imagens de IVs. Foram aplicados métodos estatísticos de regressão linear e polinomial quadrática entre os dados de IVs derivados das imagens MSI e de dados de produtividade de três talhões de algodão, obtidos por meio de um sensor instalado numa colhedora John Deere 7760. As equações de regressão foram geradas a partir de 70% dos dados observados e o restante dos dados (30%) serviram para validar o modelo gerado. Os resultados foram avaliados pelo nível de significância, coeficiente de determinação (R^2), pela Raiz do Erro Quadrático Médio (RMSE), e pelo Erro Médio Absoluto (MAE), entre os dados de produtividade observada e estimada. Os índices SAVI e RGBVI foram os que melhor explicaram a produtividade do algodoeiro, com coeficiente de determinação de $R^2 = 0,62$ e $0,64$, respectivamente, no talhão E-01 para a imagem de 16/jun. Entretanto, o índice RGBVI obteve os menores valores do RMSE e MAE, demonstrando sua maior potencialidade para estimar a produtividade de algodão.

Palavras-chave: Índices de Vegetação, Sentinel 2, Algodão, NDVI, SAVI

ABSTRACT

Brazil is the world's largest producer of cotton, which is a crop of great relevance to agribusiness. The use of orbital remote sensing data has gained prominence for monitoring this culture. In cotton, there is a growing need to identify crops for proper planning of production units, class entities and government. In this context, this dissertation has as main objective to estimate cotton yield by spectral vegetation indices derived from MSI - Sentinel 2 images. This study was carried out in three cotton beads (C-01, D-07, E-01) in a 612 hectare Production Unit (UP) located in Nova Mutum-MT. Four images of the MSI sensor were used to characterize the spectral reflectance of cotton, between the beginning of flowering and the complete fruiting, referring to April 17th, May 7th, May 27th and June 16th of 2018. The atmospheric correction of the MSI images of the visible (RGB), near infrared (NIR) and red edge (RE) spectral bands was performed for their use in the calculation of 23 vegetation indices (VI). We also evaluated the spectral data in the accumulated form, that is, by summing the values of these four VI images. Statistical methods of linear and quadratic polynomial regression were applied between the IVs data derived from the MSI images and yield data from three cotton plots obtained by a sensor installed on a John Deere 7760 harvester. Regression equations were generated at From 70% of the observed data and the rest of the data (30%) served to validate the generated model. Results were evaluated by significance level, coefficient of determination (R^2), Root Mean Square Error (RMSE), and Absolute Mean Error (MAE), between observed and estimated yield data. The SAVI and RGBVI indices best explained the cotton yield, with a coefficient of determination of $R^2 = 0.62$ and 0.64 , respectively, in field E-01 for the 16 / jun image. However, the RGBVI index obtained the lowest values of RMSE and MAE, demonstrating its greater potentiality to estimate cotton yield.

Keywords: Spectral Vegetation Indexes, Sentinel 2, Cotton, NDVI, SAVI

LISTA DE FIGURAS

Figura 1. Estádios fenológicos da cultura do algodão.....	16
Figura 2. Satélite SENTINEL 2, com destaque para seu sensor MSI.....	21
Figura 3. Sensor de produtividade de algodão instalado numa colhedora.....	30
Figura 4: Localização da área de estudo.....	34
Figura 5. Fluxograma de etapas de aplicação do processo de filtragem de dados brutos.....	36
Figura 6: Mapa da produtividade média do talhão C-01 disposta em sete intervalos.....	39
Figura 7: Mapa da produtividade média do talhão D-07 disposta em sete intervalos.....	40
Figura 8: Mapa da produtividade média do talhão E-01 disposta em sete intervalos.....	40
Figura 9. Correlograma entre os índices de vegetação e a produtividade na data de 17/04/18.....	47
Figura 10. Correlograma entre os índices de vegetação e a produtividade na data de 07/05/18.....	47
Figura 11. Correlograma entre os índices de vegetação E a produtividade na data de 27/05/18.....	48
Figura 12. Correlograma entre os índices de vegetação e a produtividade na data de 16/06/18.....	48

LISTA DE TABELAS

Tabela 1. Bandas espectrais do sensor MSI, a bordo dos satélites do Sentinel 2A e 2B.....	22
Tabela 2. Sumário de índices de vegetação que incluem apenas o espectro do Visível (RGB).....	27
Tabela 3. Sumário de índices de vegetação que incluem o espectro do Red Edge.....	27
Tabela 4. Sumário de índices de vegetação que incluem o Infravermelho Próximo (IVP).....	28
Tabela 5. Dados de plantio do algodão.....	36
Tabela 6. Estatística descritiva dos dados de produtividade do algodão devidamente filtrados e interpolados.....	41
Tabela 7. Coeficientes de determinação entre a produtividade real e os índices de vegetação para o talhão C-01 nas quatro datas analisadas.....	42
Tabela 8. Coeficientes de determinação entre a produtividade real e os índices de vegetação para o talhão D-07 nas quatro datas analisadas.....	43
Tabela 9. Coeficientes de determinação entre a produtividade real e os índices de vegetação para o talhão E-01 nas quatro datas analisadas.....	44
Tabela 10: Resultado da análise de regressão linear e polinomial quadrática entre os melhores índices de vegetação em relação à produtividade do algodoeiro e seus respectivos valores acumulados nas quatro datas analisadas para o talhão D-07.....	50
Tabela 11: Resultado da análise de regressão linear e polinomial quadrática entre os melhores índices de vegetação em relação à produtividade do algodoeiro e seus respectivos valores acumulados nas quatro datas analisadas para o talhão E-01.....	51
Tabela 12. Estatística descritiva da produtividade estimada a partir das melhores correlações lineares entre os índices de vegetação e a produtividade real para toda a área estudada.....	53
Tabela 13. Estatística descritiva da produtividade estimada a partir das melhores correlações polinomiais quadráticas entre os índices de vegetação e a produtividade real para toda a área estudada.....	54
Tabela 14. Resultado do RMSE entre a produtividade observada e a estimada.....	55
Tabela 1A: Estatística descritiva dos dados espectrais (índices de vegetação) nas quatro datas analisadas para o talhão C-01.....	58
Tabela 2A: Estatística descritiva dos dados espectrais (índices de vegetação) nas quatro datas analisadas para o talhão D-07.....	63
Tabela 3A: Estatística descritiva dos dados espectrais (índices de vegetação) nas quatro datas analisadas para o talhão E-01.....	67

LISTA DE SIGLAS

AP - Agricultura de Precisão
BOA - *Bottom of Atmosphere*
CCCI - Canopy Chlorophyll Content index
CDA - Conselho de Desenvolvimento Agrícola
DN - *Digital Number*
GARI - índice verde de resistência atmosférica
GNSS - Sistemas de Navegação Global por Satélites
GPS - Global Positioning System
GRARI - índice verde-vermelho de resistência atmosférica
IAF - Índice de Área Foliar
IV - Índices de Vegetação
MAE – Erro Médio Absoluto
MSI - Multi-Spectral Imager
MSI - *MultiSpectral Instrument*
MTR - Modelo de Transferência Radiativa
N - Nitrogênio
NDRE - Índice da Borda Vermelha
NDVI - Índice de Vegetação por Diferença Normalizada
PROALMAT - Programa de incentivo à cultura do algodão de Mato Grosso
REM - Radiação Eletromagnética
RGBVI - Índice de Vegetação RGB
RMSE - Root Mean Square Error
SAVI - Índice de vegetação ajustado ao solo
SIG - Sistemas de Informação Geográfica
SR - Sensoriamento Remoto
TOA - Refletância ao Topo da Atmosfera
TSAVI - Índice de vegetação transformado e ajustado ao solo
TVI - Índice de Vegetação Transformado
TVI - Índice de vegetação transformado
UP - Unidade de Produção
VRT - Tecnologias de taxa variável

SUMÁRIO

1. INTRODUÇÃO.....	12
1.1 Objetivo Geral.....	14
1.2 Objetivos Específicos	14
2. FUNDAMENTAÇÃO TEÓRICA.....	15
2.1 Aspectos gerais da cultura do algodão.....	15
2.1.1. Cultura do algodão no Brasil.....	17
2.2. Sensoriamento Remoto e Agricultura de precisão	18
2.2.1. Satélites e sensores remotos	20
2.2.1.1. SENTINEL 2 - Sensor MSI.....	21
2.2.1.2. Borda Vermelha (Red Edge).....	23
2.2.2. Índices de vegetação.....	24
3. MATERIAIS E MÉTODOS	33
3.1 Localização e Caracterização da Área de Estudo.....	33
3.2 Aquisição das Imagens de Satélite.....	34
3.3 Processamento das imagens e Cálculo dos Índices de Vegetação	35
3.3.1 Produtividade da lavoura de algodão	35
3.3.2 Análise estatística e validação.....	38
4. RESULTADOS E DISCUSSÃO.....	39
5. CONCLUSÕES.....	57
REFERÊNCIAS	58
APÊNDICE A.....	70

1. INTRODUÇÃO

O gerenciamento local específico da agricultura, intitulado como Agricultura de Precisão (AP), baseia-se na utilização de tecnologias espaciais, como Sistemas de Navegação Global por Satélites (GNSS), monitores de rendimento, Sistemas de Informação Geográfica (SIG) e tecnologias de taxa variável (VRT), que usam controladores no equipamento de aplicação para variar a entrada de quantidades de insumos em uma lavoura, entre outros, podendo ser aplicado no monitoramento, controle e gestão da variabilidade espacial e temporal de áreas agrícolas.

Nos últimos anos, a AP vem se destacando como uma ferramenta cada vez mais frequente e necessária, proporcionando uma maneira mais eficiente para reduzir custos e/ou aumentar os rendimentos para os agricultores. Com o apoio do Sensoriamento Remoto (SR), abrange técnicas de obtenção de informação das áreas cultivadas de forma não destrutiva, devido à inexistência do contato físico entre o sensor e esses alvos.

Dentre as tecnologias existentes de AP no mercado, a geotecnologia é uma ferramenta que possibilita a visualização espaço-temporal da cobertura e uso do solo. Assim, aplicada a informações de imagens de sensores remotos, permitem identificar diferentes características da vegetação ou do solo. Com a obtenção de informações da resposta espectral dos alvos, é possível o emprego de índices de vegetação no manejo de culturas, quando está relacionado a uma medida do dossel de plantas em crescimento e no percentual de cobertura do solo, como o índice de área foliar e produtividade de biomassa (BARNES *et al.*, 1996). Esses índices também são empregados na exploração de informações sobre a variabilidade espacial na lavoura, a fim de atender necessidades de culturas em diferentes áreas do campo, cujas aplicações exigem a consideração de vários fatores em relação à vegetação local, textura do solo, entre outros (BRANDÃO *et al.*, 2011).

Em relação à produtividade de biomassa, diversos são os índices de vegetação que possuem boa correlação com essa variável e que poderiam ser utilizados na estimativa de culturas agrícolas. Dentre estes, destaca-se o Índice de Vegetação por Diferença Normalizada (NDVI), que utiliza dados de reflectância do espectro eletromagnético, funcionando como um indicador da quantidade e condição da vegetação, representando o vigor da cultura.

Pode-se destacar também o índice biofísico IAF (Índice de Área Foliar), que serve de avaliador das condições da cobertura vegetal e estimativa da produtividade, especialmente por estar associado ao status de nitrogênio foliar e conteúdo de clorofila da planta (ZHAO *et al.*, 2005). Deste modo, através de dados de reflectância espectral, agregando-se a evolução temporal de imagens espaciais, surge um método eficaz e de menor custo, que pode responder a questões relativas aos fatores determinantes que regulam a produtividade de diferentes tipos de culturas, como a do algodão (BRANDÃO *et al.*, 2005).

O Brasil atualmente é um forte produtor no mercado mundial de algodão, sendo que, no ano 2018, foi o sexto maior do mundo, ficando atrás somente da Índia, China, Estados Unidos, Paquistão e Uzbequistão (ICAC, 2017). Já no território brasileiro, o estado de Mato Grosso ocupa a primeira posição em área plantada e produção de pluma (ABRAPA, 2017). De maneira geral, os cotonicultores brasileiros cultivam-no com elevado nível de tecnologia (AGUIAR *et al.*, 2005), permitindo ganhos de produtividade e qualidade da pluma, fatores estes fundamentais para a comercialização.

A estimativa da cultura de uma determinada cultura e o conhecimento de sua distribuição no espaço geográfico são essenciais para o planejamento estratégico do país e são subsídios importantes para a formulação de políticas públicas, fornecimento e segurança alimentar da população e treinamento. preços nos mercados interno e externo. No caso do algodão, o alto valor e os custos da produção juntamente com a crescente demanda no mercado interno e as perspectivas de intensificação das exportações de algodão atraíram investimentos financeiros e acadêmicos significativos para a expansão da capacidade produtiva do Brasil e adoção da AP. Pesquisas sobre uso atual e as perspectivas futuras de tecnologias agrícolas de precisão são importantes para os produtores agrícolas, buscando ferramentas que possam ser utilizadas por qualquer produtor, pesquisador, administrador, de forma eficiente e econômica.

Dentro deste contexto, o presente trabalho tem como objetivo avaliar a potencialidade do uso de índices de vegetação, derivados a partir de imagens de sensor remoto orbital, na estimativa da produtividade da cultura do algodoeiro.

1.1 Objetivo Geral

O objetivo geral deste trabalho é avaliar o potencial do uso de índices de vegetação derivados de imagens dos sensores *MultiSpectral Instrument* (MSI – satélites Sentinel-2), na estimativa da produtividade da cultura de algodão.

1.2 Objetivos Específicos

Para que o objetivo geral seja alcançado, os seguintes objetivos específicos foram realizados:

- Análise e seleção de quatro estádios fenológicos do algodão, por meio de imagens MSI do satélite Sentinel 2;
- Identificação do estágio mais adequado para as estimativas da produtividade, através de índices de vegetação, utilizando-se das faixas espectrais do Visível, Red Edge e Infravermelho Próximo;
- Análise e comparação das bandas espectrais do sensor MSI, para a obtenção desses índices de vegetação, com a produtividade do algodão;
- Validação dos modelos gerados.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Aspectos gerais da cultura do algodão

O algodoeiro herbáceo (*Gossypium hirsutum* L.r. *latifolium* Hutch) é uma das espécies mais antigas cultivadas no mundo. Há vestígios de que na América já havia a manipulação do algodão há mais de 4.500 anos (PASSOS, 1977). É a fibra mais cultivada pelo homem e a mais importante para o ramo têxtil (RICHETTI e MELLO FILHO, 1998), encarregado hoje por mais de 50% da produção de tecidos do mundo, e se caracteriza por ser uma celulose em sua forma quase pura.

A planta do algodoeiro tem seu crescimento e desenvolvimento fortemente influenciados pela temperatura, sendo aproximadamente 30°C o valor ideal. Necessita de elevada radiação solar e insolação, além de considerar o ciclo (considera-se da emergência até a primeira colheita) do cultivar (AZEVEDO e SILVA, 2007). Dependendo da duração do ciclo, o algodoeiro necessita de 700 a 1.300 mm de água, sendo que entre 50 e 60 % dessa água é necessária durante o período de floração (50 a 70 dias), considerando a cobertura foliar completamente fechada (EMBRAPA, 2001). Seus estádios fenológicos (Figura 1) são caracterizados em função de sua fase vegetativa (V), formação de botões florais (B), abertura da flor (F) e abertura do capulho (C), tendo as subfases de desenvolvimento Vn, Bn, Fn e Cn, respectivamente (MARUR e RUANO, 2001).

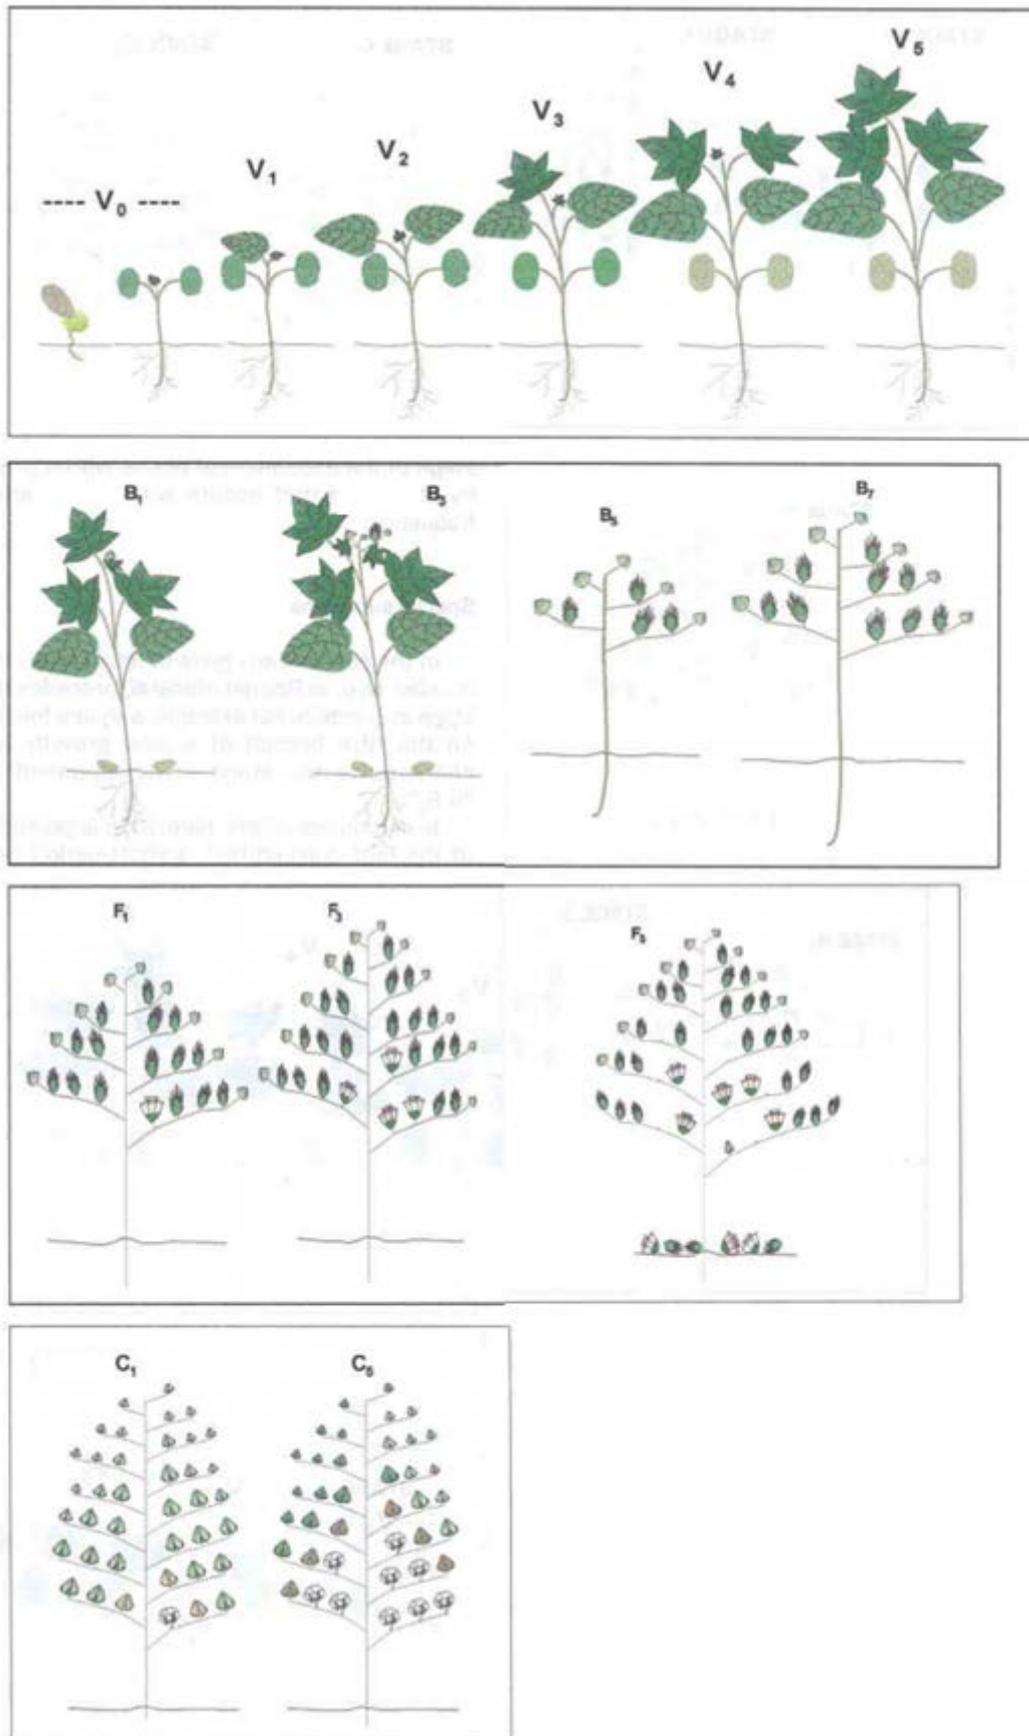


Figura 1. Estádios fenológicos da cultura do algodão. Fonte: Adaptado de MARUR e RUANO (2001).

A duração de cada fase do algodão é bastante variável, verificando-se diferenças dentro e entre períodos determinados principalmente, pelas condições fornecidas às plantas durante o seu ciclo vegetativo, época de semeadura e cultivar. Segundo Silva *et al* (2011), para o sucesso na germinação do algodoeiro, devem prevalecer condições térmicas e hídricas que permitam à semente, em suas condições normais, emergir entre 5 e 10 dias. Esta malvácea necessita para emergência e estabelecimento, temperaturas do solo superior a 20°C e temperaturas do ar entre 25 e 30°C.

Após a emergência do algodoeiro (*Gossypium hirsutum L.*), inicia-se o desenvolvimento vegetativo, com a formação de folhas, que tem como principal função a interceptação da luz solar e produção de fotoassimilados. O sistema radicular do algodoeiro cresce em comprimento até a época do florescimento. Na fase de primeiro botão até a primeira flor, acentuam-se o crescimento em altura e a acumulação de matéria seca pela planta, que entra na fase linear de crescimento, durando usualmente de 25 a 35 dias. Do primeiro capulho até a colheita é a fase final de desenvolvimento da cultura, que dura de 4 a 6 semanas, dependendo da produtividade, suprimento de água, nutrientes e temperatura. É nesta fase também que se faz a aplicação de desfolhantes/maturadores (SILVA *et al.*, 2011). De acordo com Lamas (2006), dependendo do sistema de produção utilizado, a cultura do algodoeiro pode ser conduzida com técnicas que variam desde as mais simples, como operações manuais e tração animal, até lavouras altamente mecanizadas.

2.1.1. Cultura do algodão no Brasil

O algodão está entre as mais importantes culturas de fibras do mundo. Todos os anos, uma média de 35 milhões de hectares de algodão é plantada em todo o planeta. A demanda mundial tem aumentado gradativamente desde a década de 1950, a um crescimento anual médio de 2%. O comércio mundial do algodão movimenta anualmente cerca de US\$ 12 bilhões e envolve mais de 350 milhões de pessoas em sua produção, desde as fazendas até a logística, descaroçamento, processamento e embalagem. Atualmente, o algodão é produzido por mais de 60 países, nos cinco continentes (ABRAPA, 2017).

No âmbito brasileiro, nas últimas décadas a agricultura brasileira vivenciou demasiadas transformações, uma vez que em pouco tempo a cultura do algodão passou de cultivo familiar para produção em grande escala, com elevados investimentos de

capitais e tecnologia, principalmente nos cerrados da região Centro-Oeste, transferido das regiões tradicionais de São Paulo e Paraná, apoiado por um programa do Governo estadual (PROALMAT¹), e estimulado pelo crescimento da demanda pela fibra nacional (ELEUTÉRIO, 2001).

No bioma Cerrado, o algodão se destaca como importante produto do agronegócio brasileiro devido à topografia favorável para a mecanização, pela baixa declividade do terreno, e às condições climáticas favoráveis ao seu crescimento, além de incentivos governamentais e aplicação de tecnologias modernas de usos intensivos. Nesse cenário, o cerrado possui a maior produtividade de algodão no Brasil e no mundo, considerando áreas não irrigadas (ABRAPA, 2017).

No estado do Mato Grosso, a cotonicultura que se desenvolve é similar à realizada nos Estados Unidos, sendo baseada em propriedades de grande tamanho e com uso intensivo de maquinário e tecnologia, sendo totalmente distinta da tradicional cotonicultura que era realizada em São Paulo e Paraná na década de 90. No início dos anos 2000 já se previa que esta região substituiria por completo as regiões tradicionais, devido aos menores custos de terra e maior produtividade, transformando-se no maior produtor de algodão de todo território brasileiro (COELHO, 2002).

2.2. Sensoriamento Remoto e Agricultura de precisão

O Sensoriamento Remoto envolve a obtenção de informações de determinado alvo, sem que haja contato físico com o mesmo, por meio de análise de dados coletado por sensores em plataformas terrestres, aéreas ou acoplados em satélites (NOVO, 2010). O mecanismo mais primitivo e imediato de SR é a visão humana. Por intermédio das pesquisas e empenho da Astronomia, foram desenvolvidos os sensores óticos, que captam a radiação eletromagnética (REM) refletida ou emitida do alvo em questão. Conforme foram se aprimorando, o campo de aplicação se expandiu e esses sensores se fizeram proficientes nas áreas da Meteorologia, Agricultura, Geologia, Geografia, Engenharias, dentre vários outros campos do conhecimento.

¹ O Programa de incentivo à cultura do algodão de Mato Grosso (PROALMAT) foi criado pela Lei Estadual 6.883 de 02 de junho de 1997, regulamentado pelo Decreto nº 1.589 de 18 de julho de 1997, concedendo redução de até 75% do ICMS do produto, destinando-se aos produtores rurais, pessoas físicas ou jurídicas, inscritos no Cadastro de Contribuintes do Estado, mediante a apresentação de Laudo Técnico Inicial encaminhado à Câmara Setorial de Incentivo e Tributação do CDA (Conselho de Desenvolvimento Agrícola).

O SR vem sendo utilizado de forma extensiva pela Agricultura de Precisão (AP), ao se considerar a variabilidade espacial e temporal de uma área agrícola, principalmente devido a constante busca por uma redução de custos e impactos ambientais, através de uma menor utilização de insumos a serem aplicados em uma produção agrícola. Milani (2006) estabelece que o método de manejo de culturas que tem como objetivo o tratamento diferenciado de pequenas áreas dentro de um mesmo talhão, levando em conta o seu potencial produtivo é o que define o conceito de Agricultura de precisão.

A AP está relacionada a um conjunto de técnicas que auxiliam na obtenção de dados relacionados ao vigor da vegetação e aos atributos físico-químicos do solo. Através de sensores acoplados em plataformas aéreas, orbitais ou terrestres, esses dados são obtidos por meio de medições das reflectâncias de dosséis e dos solos, que orientam tratamentos diferenciados em função da variabilidade espacial e temporal apresentadas pelas características do solo e da vegetação (LEE *et al.*, 2010; SINGH *et al.*, 2011).

A importância do uso de técnicas de SR para a agricultura se justifica pela redução de custos e de tempo que proporcionam, comparadas às medições feitas em campo (SEELAN *et al.*, 2003), além de proporcionar vantagens de um melhor conhecimento do campo de produção, propiciando assim, tomadas de decisões com melhores embasamentos (CAPELLI, 1999). Por outro lado, também engloba o manejo sustentável da terra, associado à manutenção dos índices de produtividade (MANTOVANI *et al.*, 1998).

Entre os diversos objetivos das técnicas de SR na agricultura, desde a disponibilização das imagens orbitais, têm-se gerado inúmeros estudos, tanto na escala regional quanto global, que se propõem na medição de reflectâncias da radiação solar refletida e emitida pelas folhas da vegetação, com objetivo de estimar a produtividade de culturas agrícolas a partir de índices de vegetação.

O mapeamento da produtividade é considerado por muitos autores como sendo a parte essencial da Agricultura de precisão, devido a heterogeneidade das áreas, sendo um dos métodos mais corretos para estimá-la. Segundo Molin (2000) a geração dos mapas de produtividade exige uma certa sofisticação para a obtenção dos dados essenciais. O mapa é composto por um conjunto de pontos e cada ponto representa uma pequena porção da lavoura delimitada pela largura da plataforma da coletora e distância entre duas leituras.

Através da normalização e comparação desses mapas de produtividade define-se as áreas com a mesma tendência, produzindo um banco de dados com as informações necessárias para a área de estudo e classificando as regiões por faixas de importância criando assim as zonas de manejo. Araújo *et al.* (2004) demonstra que a produtividade da cultura pode ser estimada a partir de sua relação com o vigor da cultura que, por sua vez, pode ser determinada através de IVs gerados a partir de imagens multiespectrais.

Silva *et al.* (2017) e Brandão *et al.* (2011), utilizaram imagens orbitais para cálculo do Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação Ajustado ao Solo (SAVI) e o Índice de Área Foliar (IAF), para a determinação de biomassa verde da cultura do algodão, com a finalidade de estimar a produtividade da cultura e gerar zonas de manejo, alcançando altos valores de correlação e acurácia. Nesse âmbito, Sousa *et al.* (2011) fizeram uso do mesmo método de estimativa de produtividade para a cultura da Manga, assim como Picoli *et al.* (2009) para a cultura da cana-de-açúcar.

Visando métodos mais precisos, Rudorff (1985), Rudorff e Batista, (1990; 1991), Rudorff *et al.* (1995), Fontana *et al.* (2001), Berka *et al.* (2003), Rizzi e Rudorff (2007), Picoli *et al.* (2009), Rocha (2012) e Barbosa *et al.* (2012; 2013), empregaram modelos agrometeorológicos-espectrais da produtividade potencial e real de culturas, que utilizam imagens de satélites como entrada e que produzem resultado eficiente e em larga escala.

Blackmer *et al.* (1996) citam a fotografia aérea como uma ferramenta promissora para o monitoramento da variabilidade da produtividade na cultura do milho tendo como base o nível de nitrogênio nas plantas. Assim, Diker *et al.* (2001) usaram fotografias aéreas para estimar a variabilidade da produtividade e monitorar o desenvolvimento espaço-temporal na cultura do milho irrigado em escala comercial. Calcularam os índices de vegetação NDVI, GNDVI (Green NDVI), RS e IR/G e compararam com a produtividade. O melhor coeficiente de determinação (R^2) foi de 0,8 obtido entre o NDVI no estágio R5 e a produtividade.

2.2.1. Satélites e sensores remotos

Verifica-se uma necessidade do uso de SR para estimativa do potencial produtivo durante o desenvolvimento de culturas agrícolas. Desse modo, o auxílio por meio de sensores ópticos para a geração de índices de vegetação pode fornecer informações

significativas para o conhecimento do comportamento e relação temporal destes índices com parâmetros produtivos das culturas agrícolas. (OLIVEIRA, 2017)

Atualmente, existem diversos sensores orbitais para a obtenção de informações para os mais diversos fins. Dentre os sensores a bordo dos satélites mais utilizados para extração de dados para pesquisas relacionadas a diversos temas da área agrária, podemos destacar o LANDSAT, IKONOS, CBERS, WORLDVIEW, REIS RAPIDEYE, KOMPSAT e, mais recentemente, os sensores MSI dos satélites da constelação SENTINEL. Nesta dissertação serão utilizadas imagens do sensor MSI do SENTINEL 2 de diferentes datas.

2.2.1.1. SENTINEL 2 - Sensor MSI

Os dois satélites da constelação SENTINEL 2 são relativamente recentes: Sentinel 2A (lançado em junho de 2015) e 2B (março de 2017). Surgiram da necessidade de um sistema aprimorado de monitoramento da superfície terrestre em termos de cobertura espectral, temporal e espacial. De acordo com a Agência Espacial Europeia, o Sentinel-2 tem como propósito a aquisição de imagens multiespectrais da superfície terrestre com resolução de 10 metros (VIVP) e cinco dias de temporalidade aliando os dois satélites, com órbitas circulares heliossíncronas opostas, com período de 98,46 minutos e altitude de 786 Km.

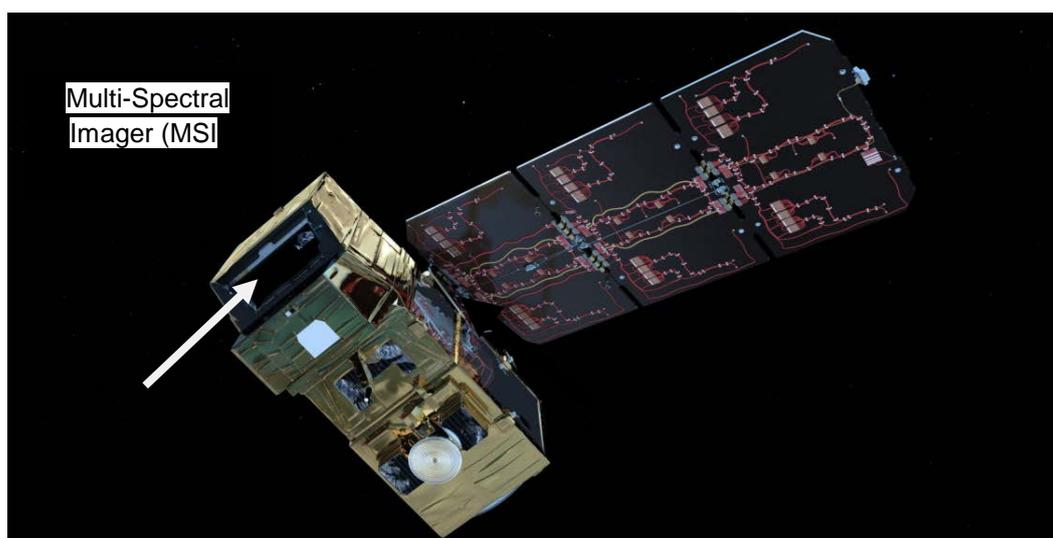


Figura 2. Satélite SENTINEL 2, com destaque para seu sensor MSI. Fonte: ESA (2018).

Cada um dos satélites carrega um sensor Multi-Spectral Imager (MSI), que obtém imagens com largura de 290 km e resolução radiométrica de 12 bits. Fornece um

conjunto versátil de 13 bandas espectrais abrangendo do infravermelho visível e próximo ao infravermelho de ondas curtas, apresentando quatro bandas com resolução espacial de 10 m, seis bandas com 20 m e três bandas com 60 m. Além disso, o Sentinel 2 incorpora três novas bandas na região de borda vermelha, que estão centradas em 705, 740 e 783 nm ENGESAT (2016).

As principais características das imagens MSI-Sentinel 2 são as seguintes: a) resolução temporal de 5 dias; b) resolução radiométrica de 12 bits, ou 4.096 tons de cinza; c) resolução espectral e espacial: três bandas cobrindo visível (10m), uma banda cobrindo o infravermelho próximo (IVP – 10m), quatro bandas da borda vermelha (RedEdge – RE – 20m), duas bandas do infravermelho médio (SWIR - 20m), e três bandas cobrindo a parte atmosférica, com 60 metros de resolução espacial (Tabela 1). A órbita do satélite é circular, heliossíncrona e descendente.

Tabela 1. Bandas espectrais do sensor MSI, a bordo dos satélites do Sentinel 2A e 2B.

Resolução	Bandas	Comprimento de onda central (nanômetros)	Largura de banda (nanômetros)
10m	B02	Blue (Azul)	496,6
	B03	Green (Verde)	560
	B04	Red (Vermelho)	664,5
	B08	IVP (Infravermelho Próximo)	835,1
20m	B05	Red Edge 1	709,3
	B06	Red Edge 2	740,2
	B07	Red Edge 3	782,5
	B08A	Red Edge 4	864,8
	B11	SWIR 1	1613,7
	B12	SWIR 2	2202,4
60m	B01	Aerossol	443,9
	B09	Water Vapor	945
	B10	Cirrus	1373,5

Fonte: Adaptado de Engesat (2016)

As imagens do sensor MSI podem ser obtidas como produtos nível 1-C, ortoretificadas, projetadas e com dados de refletância ao topo da atmosfera (TOA), que podem ser corrigidas para produtos de reflectância superficial (BOA - *Bottom of*

Atmosphere), por meio do programa Sen2Cor, desenvolvido pela ESA, que utiliza como base o Modelo de Transferência Radiativa (MTR) LIBRADTRAN (MAYER e KYLLING, 2005).

O modelo de transferência radiativa LibRadtran é uma evolução do modelo uvspec, desenvolvido para calcular a irradiância espectral nas faixas UV e visível. Em 1997, o código do modelo uvspec foi completamente reescrito para que fosse aplicável a todo o espectro solar, sendo renomeado como LibRadtran. O modelo resolve as equações de transferência em três etapas: Primeiro, as propriedades ópticas da atmosfera são calculadas a partir dos perfis de NO₂, O₃, temperatura, pressão, presença de nuvens e aerossóis, albedo superficial etc. Essas propriedades ópticas são introduzidas nas equações de transferência radiativa. Segundo, as equações de transferência de radiação são resolvidas de acordo com as propriedades ópticas introduzidas, calculando as radiações e irradiações. E por fim, a solução das equações de transferência pode ser corrigida pela distância Sol-Terra, multiplicada pelo espectro extraterrestre, integrada com relação ao comprimento de onda, conforme necessário (ANDREY, 2011).

Nas imagens de SR devem ser corrigidos os efeitos de espalhamento e absorção da REM pelos constituintes atmosféricos, tais como gases, aerossóis, material particulado em suspensão e vapor d'água, que interferem na radiação que chega aos alvos terrestres ou ao sensor (PONZONI e SHIMABUKURO, 2010). Como resultado dessas correções atmosféricas pode-se obter produtos de refletância superficial dos alvos da superfície terrestre (BOA) Os dados de reflectância superficial (BOA) são importantes principalmente no que tange à geração de índices de vegetação e à classificação digital de imagens de satélite (MANSOUR *et al.*, 2012).

2.2.1.2. Borda Vermelha (Red Edge)

A borda vermelha (Red Edge: 700-740 nm) é uma região de transição de mudança rápida na reflectância da folha, causada pela absorção de pigmentos fortes no espectro vermelho e na dispersão das folhas no espectro IVP. A radiação na região da borda vermelha penetra mais profundamente nas copas do dossel do que a luz visível (especialmente a radiação azul e vermelha) devido à absorção de clorofila muito menor na região, ocasionando uma maior sensibilidade aos níveis médio a alto de teor de clorofila, e, com isso, torna-se um bom indicador da saúde das culturas de fase média a tardia, onde a concentração de clorofila é relativamente maior (LI *et al.*, 2014).

Estudos demonstram que a borda vermelha é sensível à clorofila da copa das culturas e ao estado nutricional da planta em relação ao nitrogênio (N) (HATFIELD *et al.*, 2008; NGUY-ROBERTSON *et al.*, 2012). Por conseguinte, até certo ponto, os índices espectrais de borda vermelha podem superar os problemas de saturação relatados com NDVI (VAN NIEL e MCVICAR, 2004; NGUY-ROBERTSON *et al.*, 2012). Kanke *et al.* (2012) utilizaram o índice de borda vermelha (NDRE), em comparação com o NDVI, para detectar diferenças no status de N na cultura de trigo. Eles descobriram que a sensibilidade do NDVI diminuiu com a taxa de N, enquanto a sensibilidade do NDRE aumentou com taxa de N e estágios de crescimento avançado, indicando o potencial do NDRE para superar o problema de saturação. Fitzgerald *et al.* (2006) utilizaram a fórmula do NDRE, tendo como resultado um indicador mais confiável de estado de clorofila ou nitrogênio em trigo irrigado.

Novos sensores orbitais de alta resolução espacial, com largas bandas de borda vermelha, como o MSI-Sentinel-2 (705-745 nm) e REIS-RapidEye (690-730 nm) podem ser fontes importantes de dados para o monitoramento regional do crescimento das culturas e gerenciamento de precisão. Li *et al.* (2012) usaram dados hiperespectrais para simular as faixas espectrais do WorldView-2 e RapidEye. Eles descobriram que o índice bidimensional de conteúdo de clorofila (CCCI - Canopy Chlorophyll Content index) e o novo índice de domínio planar de nitrogênio proposto (NPDI) envolvendo a banda do red-edge eram mais estáveis e melhores preditores da estimativa de concentração de N na planta de trigo após o espigamento e na avaliação da absorção de N da planta antes do espigamento.

Pouco foi relatado na avaliação do potencial do uso de índices espectrais baseados na borda vermelha para melhorar a estimativa da produtividade e concentração e da absorção de N das plantas de milho, soja e algodão em estágios de crescimento críticos para o diagnóstico e gerenciamento de precisão, em comparação com os índices de vegetação comumente usados, como o NDVI, EVI, SAVI, e o índice biofísico IAF.

2.2.2. Índices de vegetação

O Sensoriamento Remoto é uma ferramenta que permite a visualização espacial e temporal do uso do solo. Assim sendo, se aplicada à interpretação de imagens de sensores remotos e, em particular, por meio de Índices de Vegetação (IV), que se utiliza de medidas radiométricas, proporcionam grande auxílio na avaliação de áreas verdes,

biomassa, índice de área foliar, teor de clorofila, deficiência nutricional, radiação fotossinteticamente ativa absorvida, entre outros (JENSEN, 2011).

Índices de Vegetação nada mais são que resultantes de combinações lineares de dados espectrais, que realçam o sinal da vegetação e que minimizam as variações na irradiância solar e os efeitos do substrato do dossel vegetal (JACKSON e HUETE, 1991), envolvendo comprimentos de ondas específicos do espectro eletromagnético, permitindo determinar a cobertura vegetal e sua densidade (CRUZ *et al.*, 2011). São combinações de dados espectrais de duas ou mais bandas, geralmente nas faixas do vermelho (V) e infravermelho próximo (IVP) do espectro eletromagnético, em que resulta em um valor adimensional (MOREIRA, 2000).

As bandas do vermelho e do infravermelho próximo são as mais utilizadas, por conter mais de 90% da variação da resposta espectral da vegetação; com isso, estes índices realçam o comportamento espectral da vegetação, correlacionando-os com os parâmetros biofísicos da mesma (ROSA, 2003).

Existem inúmeros índices de vegetação (IV) para o estudo da quantidade de biomassa verde e dos parâmetros de crescimento e desenvolvimento da vegetação. Estes IVs são ferramentas geradas por técnicas de sensoriamento remoto que têm sido amplamente empregados em diversos trabalhos e buscam relacionar as informações captadas pelos sensores com a vegetação presente na área imageada (RIBEIRO, 2012).

Os primeiros estudos (JORDAN, 1969; PEARSON; MILLER, 1972) iniciaram com aplicação da razão simples entre bandas, no caso do infravermelho próximo (IVP) e vermelho (V), gerando os índices de vegetação NRVI (Índice de Vegetação de Proporção Normalizada) e RVI (Índice de Vigor Relativo), onde constatou melhor equiparação com a biomassa, salientando a resposta da vegetação.

Com igual propósito foram criados por Rouse *et al.* (1973) o índice de vegetação por diferença normalizada (NDVI) e o índice de vegetação transformado (TVI), na tentativa de atenuar as intervenções do solo, atmosfera e variações do ângulo do sol. Segundo Wang *et al.* (2004), o NDVI é intensamente relacionado com o IAF; todavia, esta relação pode não ser tão forte nesses períodos de máximo IAF, ao que tudo indica, em virtude da saturação do NDVI quando o IAF é muito alto.

Dentre as variações do NDVI, surgiu o índice de vegetação ajustado ao solo (SAVI) por Huete (1988), objetivando diminuir o efeito do solo sobre diferentes densidades de cobertura vegetal, por meio do desvio do par ordenado V versus IVP para

o ponto de junção da linha do solo com a linha da vegetação, pela inclusão de uma constante L.

Foi elaborado, com os mesmos objetivos acima citados, o índice de vegetação transformado e ajustado ao solo (TSAVI), sendo uma medida do ângulo entre a linha de solo e a linha de vegetação (BARET *et al.*, 1989; BARET; GUYOT, 1991).

Tentando atenuar a dependência do NDVI aos parâmetros atmosféricos, Kaufman e Tanré (1992) apontaram uma alteração na elaboração do índice, inferindo a informação atmosférica inclusa na banda azul.

A mesma ótica de atenuação dos efeitos atmosféricos utilizados no Índice de Vegetação Resistente às Variações da Atmosfera (ARVI) foi aplicada por Gitelson *et al.* (1996) destacando o uso do canal verde, obtendo o índice verde de resistência atmosférica (GARI) e o índice verde-vermelho de resistência atmosférica (GRARI). Entre os índices aplicados por Gitelson *et al.*, (1996) é importante indicar o índice de vegetação por diferença normalizada verde (“Green” NDVI).

Os índices decorrentes da transformação ortogonal “Tasseled Cap”, como o GVI, utilizam as seis bandas não termais do sensor TM e conferem pesos diferentes para cada uma delas por meio de equações lineares. Como produto, são originadas três imagens-síntese: “brightness”, “greenness” e wetness” (CRIST; CICONE, 1984).

O Índice de Vegetação por Diferença Normalizada (NDVI) é representativo de vários índices de vegetação espectrais (KAZMIERCZAK, 1996). Este índice é uma técnica bastante importante utilizada para melhor visualizar os alvos no que diz respeito a variação da vegetação e é a razão entre as bandas de alta correlação entre si, serve para realçar os alvos de interesse e a biomassa vegetal (FREIRE; PACHECO, 2005). O NDVI tem, portanto, uma relação direta com o vigor da vegetação. Sendo assim, é possível o mapeamento de áreas com diferentes índices de cobertura vegetal e vigor de biomassa.

Dentre os exemplos de aplicação dos índices de vegetação, pode-se encontrar no trabalho de Huete (1988), que estudou a influência dos solos sobre os IVs, encontrando uma boa correlação dos índices NDVI e do SAVI (com o IAF) em culturas de algodão e com a relação de biomassa de gramíneas.

Outros exemplos de aplicação de índices, como os ensaios realizados por Andrade *et al.* (2015), demonstraram a viabilidade da utilização de técnicas em SR, a fim de detectar processos de degradação em pastagens. Aplicaram técnicas de obtenção do IAF, NDVI e SAVI em imagens de satélite Landsat 5 em suas análises e descrições,

procurando demonstrar três níveis de degradação em microbacias hidrográficas. Neste sentido, Knox *et al.* (2013), usaram seis índices de vegetação para determinar o estágio fenológico e as variedades de gramíneas: NDVI, NDWI, CAI, EVI, EVI2 e PhIX.

Alguns dos IVs mais utilizados nos espectros do visível, *Red Edge* e IVP estão listados nas Tabelas 2, 3 e 4, com suas respectivas equações e referências.

Tabela 2. Sumário de índices de vegetação que incluem apenas o espectro do Visível (*RGB*)

Índice de Vegetação	Equação	Referências
Índice de Reflectância de Carotenoides 1	$CRI1 = \frac{1}{\rho B} - \frac{1}{\rho G}$	(GITELSON <i>et al.</i> , 2002)
Excesso de Verde	$ExG = 2\rho G - \rho R - \rho B$	(MAO; WANG; WANG, 2003; MEYER; NETO, 2008)
Excesso de Verde menos Excesso de Vermelho	$ExGR = ExG - (1,4\rho R - \rho B)$	(MEYER; NETO, 2008)
Índice de Vegetação do Verde Vermelho Modificado	$MGRVI = \frac{\rho G^2 - \rho R^2}{\rho G^2 + \rho R^2}$	(BENDIG <i>et al.</i> , 2015)
Índice da Diferença Normalizada ou Índice de Vegetação do Verde Vermelho	$NDI \text{ ou } GRVI = \frac{\rho G - \rho R}{\rho G + \rho R}$	(TUCKER, 1979; WOEBBECKE <i>et al.</i> , 1992)
Índice de Vegetação RGB	$RGBVI = \frac{\rho G^2 - (\rho B \times \rho R)}{\rho G^2 + (\rho B \times \rho R)}$	(BENDIG <i>et al.</i> , 2015)

ρB é a reflectância no Azul; ρIVP é a reflectância no IVP; ρRE é a reflectância no *Red Edge*; ρG é a reflectância no Verde, e ρR a reflectância no Vermelho.

Tabela 3. Sumário de índices de vegetação que incluem o espectro do *Red Edge*

Índice de Vegetação	Equação	Referências
Índice de Vegetação <i>Red Edge</i>	$NDRE = \frac{\rho IVP - \rho RE}{\rho IVP + \rho RE}$	(BARNES <i>et al.</i> , 2000; EITEL <i>et al.</i> , 2011)
Índice de Reflectância de Carotenoides 2	$CRI2 = \frac{1}{\rho B} - \frac{1}{\rho RE}$	(GITELSON <i>et al.</i> , 2002)
Índice de Reflectância da Senescência de Plantas	$PSRI = \frac{\rho R - \rho B}{\rho RE}$	(MERZLYAK <i>et al.</i> , 1999)

ρB é a reflectância no Azul; ρIVP é a reflectância no IVP; ρRE é a reflectância no *Red Edge*; ρG é a reflectância no Verde, e ρR a reflectância no Vermelho.

Tabela 4. Sumário de índices de vegetação que incluem o Infravermelho Próximo (IVP)

Índice de Vegetação	Equação	Referências
Índice de Vegetação por Diferença Normalizada	$NDVI = \frac{\rho IVP - \rho R}{\rho IVP + \rho R}$	(ROUSE <i>et al.</i> , 1973)
O Índice de Vegetação Resistente às Variações da Atmosfera	$ARVI = \frac{\rho IVP - (2\rho R - \rho B)}{\rho IVP + (2\rho R - \rho B)}$	(KAUFMAN E TANRÉ <i>et al.</i> , 1992)
Índice de Vegetação Realçado	$EVI = G \frac{\rho IVP - \rho R}{\rho IVP + C_1\rho R + C_2\rho B + L} (1 + L)$	(HUETE; HUIQING LIU; VAN LEEUWEN, 1997)
Índice Verde de Vegetação Ajustado para o Solo	$GSAVI = 1,5 \frac{\rho IVP - \rho G}{\rho IVP + \rho G + 0,5}$	(SRIPADA <i>et al.</i> , 2006)
Índice Verde de Vegetação	$GVI = \frac{\rho G}{\rho IVP}$	(DAUGHTRY <i>et al.</i> , 2000)
Índice da Água por Diferença Normalizada	$NDWI = \frac{\rho G - \rho IVP}{\rho G + \rho IVP}$	(JI <i>et al.</i> , 2009)
Razão Simples	$SR \text{ ou } RVI = \frac{\rho IVP}{\rho R}$	(BIRTH; MCVEY, 1968; HUETE; JACKSON, 1987)
Índice de Vegetação por Diferença Renormalizada	$RNDVI = \frac{\rho IVP - \rho R}{\sqrt{\rho IVP + \rho R}}$	(ROUJEAN; BREON, 1995)
Índice de Vegetação Ajustado ao Solo	$SAVI = \frac{\rho IVP - \rho R}{\rho IVP + \rho R} (1 + L)$	(HUETE, 1988)
Índice de Vegetação Ajustado ao Solo Otimizado	$OSAVI = \frac{1,5(\rho IVP - \rho R)}{\rho IVP + \rho R + 0,16}$	(RONDEAUX; STEVEN; BARET, 1996)
Índice de Vegetação por Diferença Normalizada Realçado	$ENDVI = \frac{\rho IVP + \rho G - 2\rho B}{\rho IVP + \rho G + 2\rho B}$	(BULANON <i>et al.</i> , 2016; STORY; KACIRA, 2015)
Índice Vegetação por Diferença Normalizada do Verde	$GNDVI = \frac{\rho IVP - \rho G}{\rho IVP + \rho G}$	(GITELSON; KAUFMAN; MERZLYAK, 1996)
Índice de Vegetação de Percentagem do Infravermelho	$IPVI = \frac{\rho IVP}{\rho IVP + \rho R}$	(CANDIAGO <i>et al.</i> , 2015; CRIPPEN, 1990)
Índice Não-linear	$NLI = \frac{\rho IVP^2 - \rho R}{\rho IVP^2 + \rho R}$	(GOEL; QIN, 1994)

ρB é a reflectância no Azul; ρIVP é a reflectância no IVP; ρRE é a reflectância no Red Edge; ρG é a reflectância no Verde, e ρR a reflectância no Vermelho; C_1 e C_2 são coeficientes empíricos que descrevem o uso da banda do Azul para correção da banda do Vermelho quanto ao espalhamento atmosférico por aerossóis; e L é o coeficiente empírico de ajuste para solos (0,5); G é o fator de ganho.

Segundo Baio (2018), o algodoeiro se caracteriza pela alta resposta aos estímulos climáticos, principalmente, enquanto jovem. É coerente imaginar que seu dossel sofra frequentemente alterações de vigor e na quantidade de biomassa verde ao longo de seu ciclo. Essas considerações motivaram a utilização de dados espectrais acumulados a fim de diminuir a influência dos efeitos momentâneos sobre o dossel da cultura e sua resposta espectral, na tentativa de melhorar a explicação da produtividade pelos dados espectrais, conforme descrito a seguir (Equação 1):

$$IVAcum = IV17abr + IV07mai + IV27mai + IV16jun \quad (1)$$

Onde,

IVAcum = índice de vegetação acumulado

IV17abr = índice de vegetação em 17 de abril

IV05mai = índice de vegetação em 07 de maio

IV27mai = índice de vegetação em 27 de maio

IV16jun = índice de vegetação em 16 de junho

A produtividade individual (por talhão) do algodão pode ser obtida através de colhedoras. Por exemplo, na colhedora John Deere, modelo 7760, há um sensor ultrassônico (Figura 3), instalado nos tubos de descarga do cesto, que emite sinais através da tubulação de plástico e sem contato com a pluma, no qual realiza a medição do volume de plumas através de sua densidade e o converte em massa. Esse sensor é acoplado a um monitor que coleta informações sobre a produtividade das culturas com frequência relativamente alta, de 1 a 5 segundos. Essa informação é associada com o posicionamento fornecido por um receptor de Global Positioning System (GPS), e então é possível obter um mapa de produtividade, que nada mais é que um conjunto de pontos espacialmente distribuídos que possuem uma representação gráfica da produtividade pontual (BLACKMORE e MARSHALL, 1996).

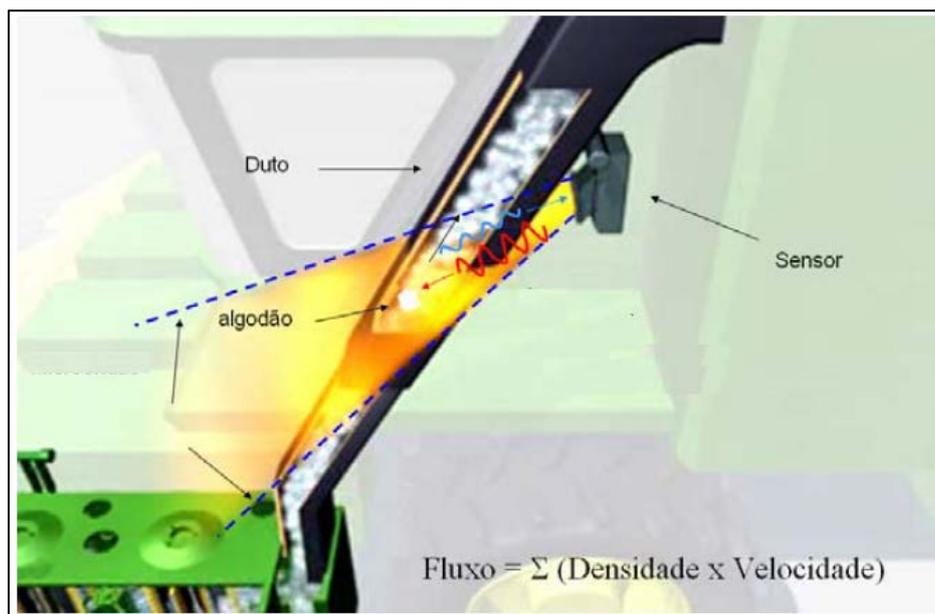


Figura 3. Sensor de produtividade de algodão instalado numa colhedora. (Fonte: John Deere, 2007)

Moore (1998) utilizou dados de seis anos consecutivos de mapeamento de produtividade e identificou os seguintes erros provenientes da colheita automatizada: suavização, calibração de volume, largura incorreta da plataforma e tempo de enchimento da colhedora. Blackmore e Marshall (1996) mencionaram ainda erros de posicionamento, devido à recirculação de grãos no mecanismo de trilha e retrilha, perdas de grãos pela colhedora e a acurácia do sensor de fluxo.

Os dados pontuais e discretos obtidos com a colhedora podem ser usados para obter dados contínuos de produtividade de lavouras, por meio de métodos de interpolação. Um dos mais utilizados é o método de Krigagem Ordinária (*Ordinary Kriging*), no qual utiliza-se a Geoestatística, que, em muitos casos, é uma grande vantagem sobre outros métodos de interpolação (BETZEK et al., 2017). A Krigagem interpola os valores com as condições de estimativa sem tendenciosidade e com variância mínima em relação aos valores conhecidos, considerando a estrutura de variabilidade espacial encontrada para o atributo (GREGO; VIEIRA, 2005). Sua eficiência se deve ao fato de fornecer um algoritmo dos erros associados aos resultados obtidos, por meio de um modelo contínuo de variação espacial e, assim, é considerado um método de interpolação flexível e robusto, procurando expressar as tendências direcionais que os dados sugerem, evitando, assim, o efeito de “olho-de-touro” (*Bull-eye*), que por ocorrer no caso de interpoladores como o inverso da distância elevado a uma dada potência (IDP) (CRESSIE, 1993). A krigagem ordinária é o mais difundido

dos vários métodos de estimativa existentes. Sua utilização resulta em valores com mínima variância de erro e proporciona precisão local (BETZEK et al., 2017).

O desempenho de Krigagem pode ser influenciado pela variabilidade e estrutura espacial dos dados e pela escolha do modelo de semivariograma, o raio de busca e o número dos pontos vizinhos mais próximos que são utilizados nas estimativas (GUASTAFERRO et al., 2010). A escolha do modelo de ajuste do semivariograma representa a interpretação da estrutura de correlação espacial a ser utilizada nos procedimentos de inferenciais da Krigagem. Todavia, a sensibilidade para detectar a variabilidade espacial das amostras está diretamente relacionada ao melhor ajuste entre os dados experimentais e os modelos teóricos do semivariograma (CRESSIE, 1993). Os modelos geralmente avaliados são: esférico, exponencial, gaussiano, e Família Matérn com diferentes valores no parâmetro de forma κ .

Os dados contínuos de produtividade podem ser correlacionados com diferentes IVs, para obter equações que possam ser usadas posteriormente para a estimativa dessa grandeza. É importante que na análise de correlação entre essa variável biofísica e radiométrica seja obtida significância estatística. Stevenson (1986) esclarece que a correlação mede a força, ou grau, de relacionamento entre duas variáveis; a regressão dá uma equação que descreve o relacionamento em termos matemáticos. Peternelli (2007) define a regressão linear como uma análise estatística com o objetivo de verificar a existência de uma relação funcional entre uma variável dependente com uma ou mais variáveis independentes. Em outras palavras, consiste na obtenção de uma equação que tenta explicar a variação da variável dependente pela variação dos níveis das variáveis independentes. O modelo linear em sua forma mais simples pode ser obtido por uma aproximação de primeira ordem de uma função e que aproximações de maior ordem geram termos que podem induzir heterogeneidade de variâncias e assimetrias, o que motiva extensões nas alternativas de modelagem, como a utilização de modelos não lineares, tal como modelo polinomial quadrático. A regressão polinomial baseia-se em considerações teóricas inerentes ao fenômeno que se tem interesse em estudar, abrangendo melhor a extensão da associação incluindo sua curvatura. Quanto maior o grau do polinômio, maior será o coeficiente de determinação dessa correlação (NUNES, 2002).

Outra análise estatística importante para a avaliação da precisão das estimativas de produtividade a partir de IVs é o cálculo da Raiz do Erro Quadrático Médio (*Root Mean Square Error* - RMSE) e do Erro Médio Absoluto (Mean Absolute Error - MAE), mais

comumente usados para aferir a qualidade do ajuste do modelo (Equação 2 e 3). É a raiz do erro médio quadrático da diferença entre a predição e o valor real, é uma boa medida, porque geralmente representa explicitamente o que vários métodos tendem a minimizar, e apresenta valores do erro nas mesmas dimensões da variável analisada (OLIVEIRA *et al*, 2012).

$$RMSE = \frac{\sqrt{\sum_{i=1}^n (X_{obs,i} - X_{mod,i})^2}}{n} \quad (2)$$

Em que:

n: número de amostras

X_{obs}: produtividade observada (real)

X_{mod}: produtividade estimada

$$MAE = \frac{\sum_{i=1}^n |X_{obs,i} - X_{mod,i}|}{n} \quad (2)$$

Em que:

n: número de amostras

X_{obs}: produtividade observada (real)

X_{mod}: produtividade estimada

3. MATERIAIS E MÉTODOS

3.1 Localização e Caracterização da Área de Estudo

No município de Nova Mutum (Estado do Mato Grosso) situa-se a Unidade de Produção (UP) Ribeiro do céu, onde está localizada a área de estudo (Figura 4). A UP Ribeiro do céu (latitude 13°49'24" Sul e longitude 57°37'52" Oeste) tem área total de cerca de 27.000 hectares, destinada aos cultivos de algodão, soja e milho safrinha durante o ano agrícola.

O município de Nova Mutum localiza-se na mesorregião Norte Mato-grossense e na microrregião de Alto Teles Pires, a aproximadamente 242 km da capital Cuiabá. A região é conhecida por ser o segundo maior produtor de grãos de Mato Grosso e um dos maiores do Brasil, possuindo cerca de 60% do território destinado à agricultura com enfoque para a produção de soja, milho e algodão (IBGE, 2017). O escoamento da safra local é facilitado pela ligação deste município a importantes rodovias federais e estaduais, como a BR 364, MT 235, MT 358 e MT 170.

Segundo Portela e Parpinelli (2009), na região de estudo predomina o clima Tropical Quente e Úmido (classificação climática de Koppen-Geiger: Aw), com verão chuvoso e inverno seco, e Equatorial (classificação de Koppen), com temperatura média anual de 24 °C, além de precipitação média anual de 2.200mm.

Sua superfície encontra-se sobre o relevo do Chapadão dos Parecis, caracterizado por possuir uma topografia plana, suavemente ondulada, com predomínio de latossolos, em especial os de textura média, que se caracterizam por serem bem ou até acentuadamente drenados, e altitude média de 450 m (MINAMI et al, 2017).

Objetivando uma melhor manipulação e processamento dos dados deste estudo, foram considerados somente três talhões de lavoura de algodão do ano de 2018, localizados na UP (C-01, D-07, E-01) (Figura 4), com área de 176, 216 e 219 ha, respectivamente, totalizando aproximadamente 612 hectares.



Figura 4: Localização da área de estudo.

3.2 Aquisição das Imagens de Satélite

Foram utilizadas imagens orbitais do sensor MSI-Sentinel 2, por apresentarem bandas que cobrem as principais feições da curva espectral dos vegetais, com cenas suficientemente abrangentes ($10.000\text{km}^2 - 100$ por 100 km), por serem viáveis do ponto de vista econômico em larga escala e por possuírem qualidade radiométrica (12 bits). As imagens MSI foram adquiridas gratuitamente pelo site EarthExplorer do USGS (*United States Geological Survey*), onde estão disponibilizados os produtos nível 1A, que são ortorretificados, ou seja, corrigidos dos deslocamentos do relevo e com correções atmosféricas (modelo ATCOR3), prontas para uso em Sistemas de Informações Geográficas (SIGs).

Somente foram selecionadas imagens sem cobertura de nuvens nos 3 talhões de algodão. A data de aquisição das imagens para esta análise foi determinada conforme o estágio fenológico da cultura do algodoeiro na região norte do Mato Grosso, sendo determinadas quatro datas para o estudo: 17/04/2018, 07/05/2018, 27/05/2018 e 16/06/2018. A data da primeira imagem é mais próxima ao início da floração; a segunda

abrange uma fase intermediária do algodão; a data seguinte representa a época de florescimento pleno; e a quarta e última data a frutificação completa do algodão.

3.3 Processamento das imagens e Cálculo dos Índices de Vegetação

As imagens MSI foram pré-processadas no software QGIS, que é um SIG com ferramentas de processamento de imagens de SR, livre e com código aberto. Realizou-se a conversão do DN (*Digital Number*) dessas imagens para valores de reflectância ao topo da atmosfera (TOA), através do *plugin Geosud Toa Reflectance*. Posteriormente, foi necessário fazer a correção atmosférica das imagens, por meio do programa Sen2Cor, aplicando o MTR LIBRADTRAN (MAYER; KYLLING, 2005).

Após o pré-processamento, foram feitas operações algébricas com as imagens, para o cálculo dos IVs apresentados nas Tabelas 2, 3, e 4 (Capítulo 2.2.2). Visando o reconhecimento do IV que melhor se ajustasse à estimativa de produtividade do algodão, e sua correlação com as diferentes propriedades espectrais da vegetação, relacionadas aos parâmetros biofísicos e bioquímicos da cobertura vegetal, foram testados diversos IVs comumente utilizados em SR orbital, sobretudo nas faixas espectrais do Visível (Tabela 3), Red Edge (Tabela 4) e IVP (Tabela 5).

3.3.1 Produtividade da lavoura de algodão

A área do estudo é de lavoura comercial, sendo seus dados de plantio, dos talhões estudados (C-01, D-07 e E-0) apresentados na tabela 5. Segundo Anselmo (2015), as variedades FM 975 WS e TMG 44 B2RF tem como característica de serem variedades de elevada produtividade, com capacidade de retenção de estruturas e enchimento de carga reprodutiva.

Tabela 5. Dados de plantio do algodão.

Variedade	Talhão	Plantio	Emergência	Ciclo dias	Colheita	Nº Plantas por ha	Área Plantada (ha)	Entrelinhas (m)
FM 975 WS	C-01	17/01/2017	20/01/2018	180	18/07/2018	20.192.237	176,00	0,76
FM 975 WS	D-07	04/02/2017	06/02/2018	180	04/08/2018	32.065.790	216,50	0,76
TMG44 B2RF	E-01	03/02/2017	06/02/2018	165	19/07/2018	32.065.790	219,23	0,76

A produtividade individual (por talhão) foi obtida de acordo com os procedimentos normais de colheita da unidade produtora, UP Ribeiro do céu, através de colhedora John Deere 7760. Os dados de produtividade foram cedidos do banco de dados da fazenda, do ano de 2018, sem nenhum tipo de pré-processamento realizado. Dessa forma, foi preciso eliminar os dados imprecisos ou incoerentes com relação aos talhões.

Para a filtragem dos dados de produtividade, foi utilizada a metodologia proposta por Menegatti e Molin (2004), que consistiu em seis passos, conforme fluxograma ilustrado na figura 5:

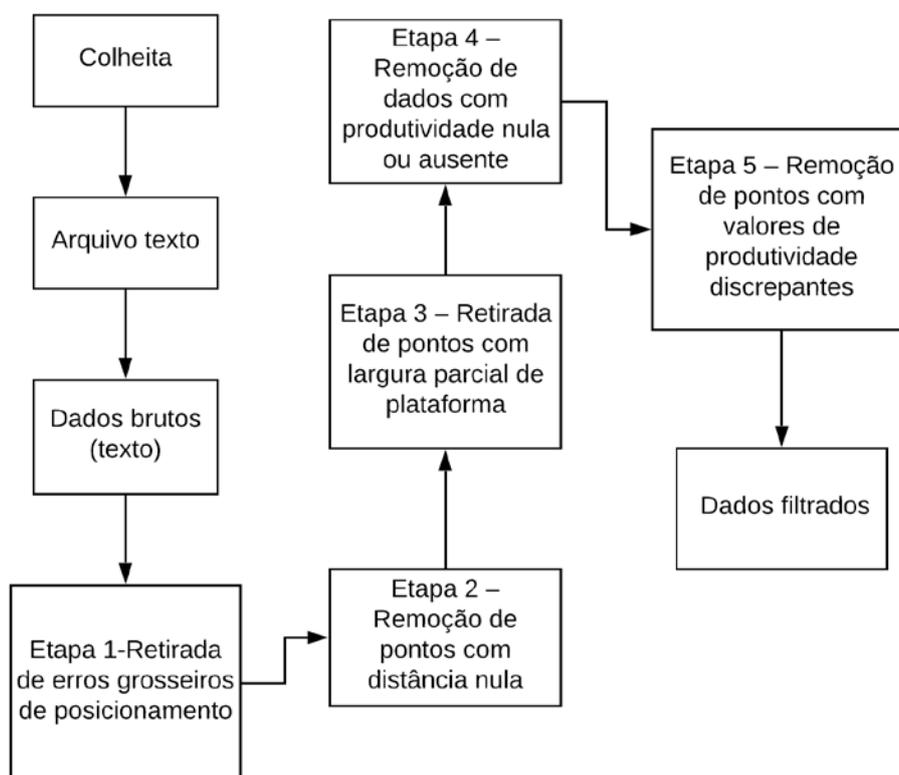


Figura 5. Fluxograma de etapas de aplicação do processo de filtragem de dados brutos.

O primeiro passo foi a análise visual dos pontos de produtividade no QGIS, em busca de pontos localizados fora dos talhões (erros grosseiros de posicionamento). Tais pontos foram selecionados e eliminados do conjunto de dados (etapa 1). Com base na distância entre os pontos e a velocidade de operação da máquina, foi possível identificar e excluir pontos coletados no mesmo local, com distância nula (etapa 2). Na etapa 3, foram eliminados pontos no arquivo cuja largura de plataforma era diferente daquela

informada como teórica, correspondendo a erros na largura de corte da plataforma da colhedora. Tais erros ocorrem quando a largura parcial efetiva da plataforma é diferente da informada ao sistema e gravada no arquivo, sendo provavelmente devido à interpretação errônea por parte do operador.

A etapa 4 baseou-se na identificação e eliminação de pontos com valores de produtividade nula ou que não possuíssem qualquer valor. Por fim, foi conduzida uma análise estatística exploratória dos dados, com cálculo da média, mediana, quartil superior, quartil inferior e variância. Com base nos quartis, foram calculados os limites superior e inferior para os valores de produtividade, de acordo com metodologia sugerida por Tukey (1977) para a determinação dos dados discrepantes (etapa 5). As equações 3 e 4 mostram a forma de cálculo desses limites superior e inferior para a filtragem dos valores de produtividade.

$$LS = QS + 1,5.AI \quad (3)$$

$$LI = QI - 1,5.AI \quad (4)$$

onde:

LS é o limite superior;

LI é o limite inferior;

QS é o quartil superior;

QI é o quartil inferior e

AI é amplitude interquartílica.

Os dados filtrados e normalizados foram interpolados no *software* ArcMap 10.0, através do método Geoestatístico de Krigagem ordinária. Os dados foram interpolados para uma grade de pixels de tamanho 10x10 m, para coincidir com o tamanho do pixel da imagem orbital do sensor MSI, visando a invariabilidade de resoluções espaciais na comparação entre dados. Utilizou-se o modelo esférico para o ajuste do modelo, e o alcance foi limitado à metade da distância máxima entre dois pontos (cutoff = 50%).

Após a interpolação dos dados de produtividade, foi realizada a geração de um buffer interior ao limite do talhão, na distância equivalente a cinco vezes o tamanho de pixel da imagem MSI (50 m), para assegurar que os valores de reflectância espectral cada pixel das imagens orbitais sejam oriundos apenas da reflectância do dossel das plantas do algodoeiro, sem influência das áreas circunvizinhas, como estradas ou talhões adjacentes.

3.3.2 Análise estatística e validação

As imagens dos diferentes IVs (Tabelas 2, 3 e 4) foram recortadas conforme os limites de cada talhão, sendo então calculados os valores médios dos pixels. Foram realizadas análises de regressões estatísticas (linear simples e polinomial quadrática) para todos os pixels do lote, sendo a produtividade a variável dependente e o valor espectral a variável independente, para obter os melhores modelos na estimativa da produtividade, nas quatro fases de desenvolvimento do algodão. A seleção do modelo de melhor desempenho foi realizada a partir do nível de significância estatística da análise de variância (valor de p), associado ao coeficiente de determinação de ajuste do modelo (valor de R^2) e classificado de acordo com o coeficiente de correlação (R).

A análise estatística foi feita no software BioStat, que gerou as regressões polinomiais, tendo como finalidade gerar uma equação para aplicar novamente aos índices de vegetação, sendo deste modo possível estimar a produtividade. O resultado de tal análise permitiu então a determinação de qual das imagens índices, geradas no processamento, teve sua variação explicando melhor a variação dos dados de produtividade. A partir das melhores imagens-índices selecionadas, para cada talhão, os dados de produtividade foram divididos aleatoriamente em cerca de 70% para geração do modelo de estimativa (banco de dados com cerca de 8.640 amostras) e 30% para validação do modelo (3.710 dados amostrais). Em seguida converteram-se as imagens de índices em produtividade estimada. Para fins de validação dos modelos gerados, calcularam-se a Raiz do Erro Quadrático Médio (RMSE) e o Erro Médio Absoluto (MAE).

4. RESULTADOS E DISCUSSÃO

Os mapas das Figuras 6, 7 e 8 mostram a produtividade interpolada ($t\cdot ha^{-1}$) dos talhões de algodão C-01, D-07 e E-01, respectivamente.

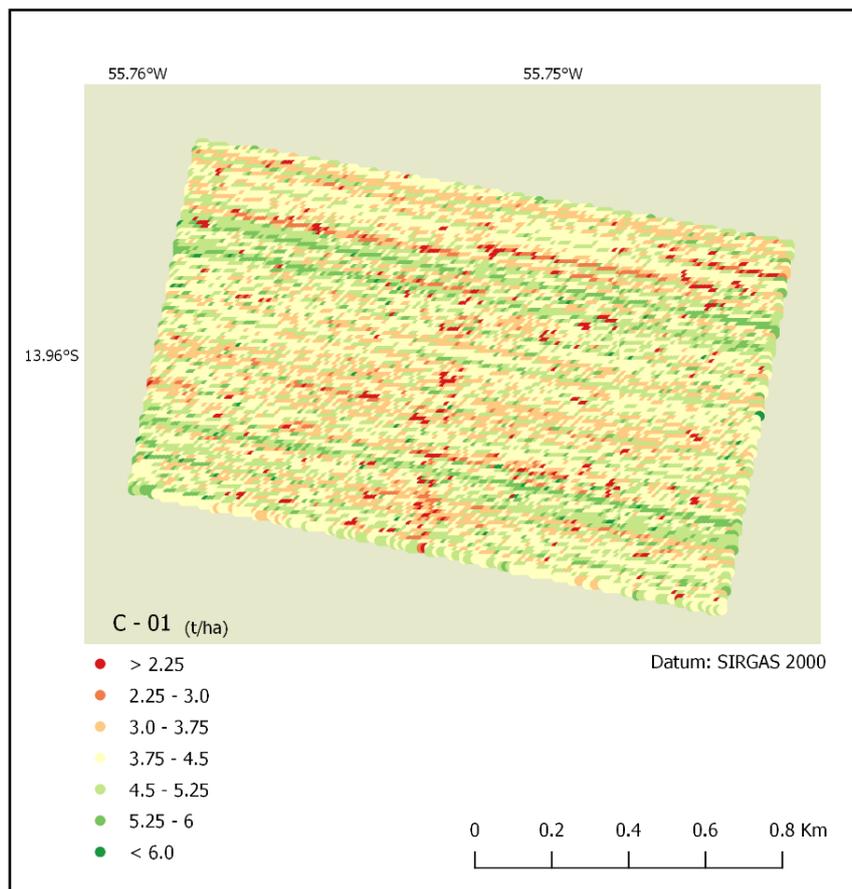


Figura 6: Mapa da produtividade média do talhão disposta em sete intervalos.

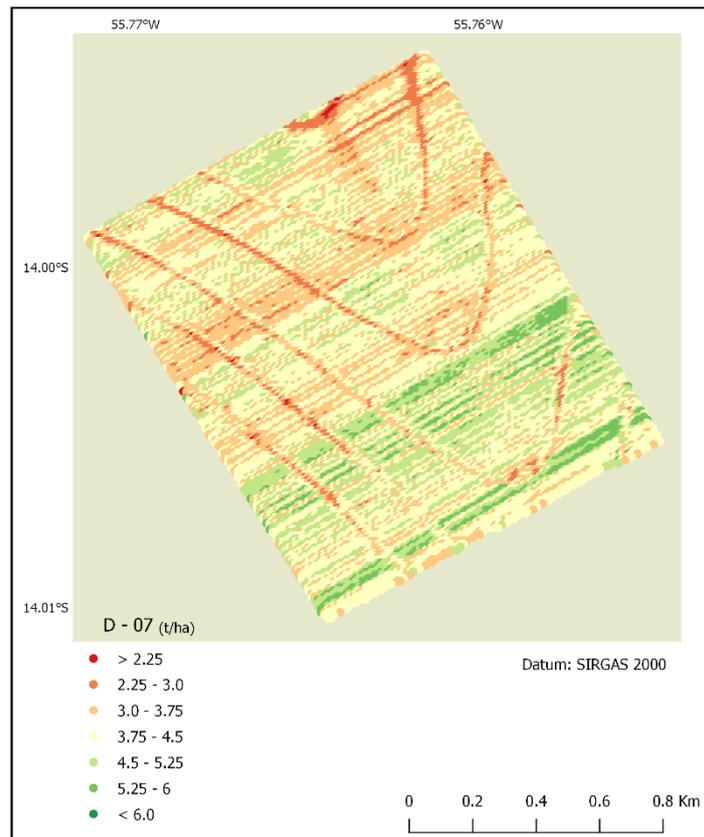


Figura 7: Mapa da produtividade média do talhão D-07 disposta em sete intervalos.

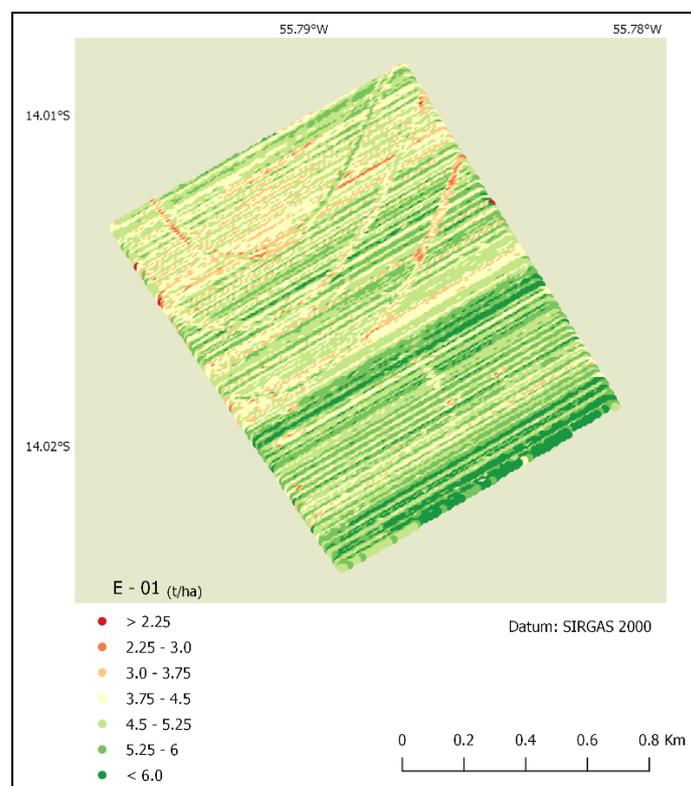


Figura 8: Mapa da produtividade média do talhão E-01 disposta em sete intervalos.

A Tabela 6 resume os resultados da análise exploratória, apresentando os parâmetros estatísticos descritivos das medidas de tendência central e dispersão. A produtividade média do algodão na área de estudo foi de $4,33 \text{ t.ha}^{-1}$, com desvio padrão de $0,53 \text{ t.ha}^{-1}$ e coeficiente de variação de 12%.

Tabela 6. Estatística descritiva dos dados de produtividade do algodão devidamente filtrados e interpolados.

Descrição	Produtividade (t/ha)			
	C-01	D-07	E-01	Total
Média	4,57	3,75	4,66	4,33
Mediana	4,58	3,75	4,60	4,35
Desvio padrão	0,19	0,31	0,44	0,53
Coeficiente de variação	0,04	0,08	0,09	0,12
Amplitude	0,85	1,64	1,82	2,94
Mínimo	4,09	2,68	3,81	2,68
Máximo	4,94	4,32	5,63	5,63

Embora não se trate da mesma variedade de algodão plantada em toda área, observa-se uma amplitude da variação da produtividade relativamente grande, de cerca de $2,94 \text{ t.ha}^{-1}$. Esses resultados mostram grande variação da produtividade ao longo da safra analisada.

Diversos fatores podem contribuir para a variação de produtividade do algodoeiro. Lamas (2011) cita importantes fatores para produtividade de algodão na região de cultivo, destacando a adoção de tecnologia e investimento realizados pelo produtor, disponibilidade de novas variedades e biotecnologias e rotação de culturas. Outras variáveis de natureza climáticas experimentadas ao longo do ciclo, também são importantes na definição da produtividade.

Os dados de produtividade da área de estudo comportaram-se conforme uma distribuição normal pelo teste de Shapiro-Wilk, com valores de W entre 0,89 e 0,93 e valor p de 0,01. As Tabelas do Apêndice A (1, 2 e 3), apresentam as estatísticas descritivas dos dados espectrais do dossel do algodão, avaliados sob a forma de IVs, nas quatro datas analisadas. Analisando-se o comportamento multitemporal dos dados espectrais, nota-se que os dados espectrais apresentam a mesma tendência temporal para os três talhões analisados. Em sua maioria, os maiores valores médios de produtividade foram observados na imagem MSI-Sentinel 2 de 07/05/18, quando a cultura

encongrava-se com aproximadamente 100 dias, estando na sua fase de maior potencial vegetativo e com maior acúmulo de biomassa (florescimento pleno).

O coeficiente de variação dos IVs variou de 0,5%, para o índice SAVI, a 226% para o índice PSRI, tendo com média geral em 7,18%. A consideração do valor do coeficiente de variação depende do tipo de variável analisada. Para produtividade de cultivos agrícolas, valores maiores de 16% podem ser considerados como elevados para a produtividade de soja e 22% para o milho (Carvalho et al. 2003). Brandão *et al.* (2014) obtiveram coeficiente de variação de índices como o NDVI de 3,4% calculado por imagens orbitais em um único talhão de algodão em 2011.

Os coeficientes de determinação (R^2) entre as os valores dos índices de vegetação e a produtividade de algodão estão descritos nas Tabelas 7, 8 e 9.

Tabela 7. Coeficientes de determinação entre a produtividade real e os índices de vegetação para o talhão C-01 nas quatro datas analisadas.

C-01	14/abr		07/mai		27/mai		16/jun	
	Linear	Polinomial	Linear	Polinomial	Linear	Polinomial	Linear	Polinomial
NDVI	0,13**	0,13**	0,10**	0,10**	0,02**	0,03**	0,04	0,04**
ARVI	0,06**	0,06**	0,04**	0,04**	0,04**	0,05**	0,01	0,01**
EVI	0,06**	0,06**	0,42**	0,05**	0,01**	0,02**	0,01	0,01**
GSAVI	0,05**	0,06**	0,04**	0,05**	0,00**	0,01**	0,00	0,01**
GVI	0,06**	0,06**	0,04**	0,05**	0,01**	0,01**	0,01	0,01**
NDWI	0,06**	0,06**	0,05**	0,05**	0,01**	0,01**	0,01	0,01**
SR	0,07**	0,07**	0,08**	0,08**	0,01**	0,03**	0,04	0,04**
RDVI	0,10**	0,10**	0,15**	0,16**	0,02**	0,02**	0,03	0,03**
SAVI	0,13**	0,13**	0,13**	0,13**	0,02**	0,03**	0,04	0,04**
OSAVI	0,12**	0,23**	0,14**	0,15**	0,02**	0,02**	0,03	0,03**
ENDVI	0,15**	0,21**	0,11**	0,11**	0,01**	0,02**	0,02	0,02**
GNDVI	0,11**	0,31**	0,13**	0,13**	0,01**	0,01**	0,04	0,04**
IPVI	0,13**	0,32**	0,10**	0,10**	0,02**	0,03**	0,04	0,04**
NLI	0,14**	0,33**	0,14**	0,14**	0,02**	0,03**	0,04	0,04**
NDRE	0,14**	0,14**	0,09**	0,09**	0,00**	0,02**	0,04	0,04**
CRI2	0,25**	0,26**	0,00**	0,02**	0,03**	0,10**	0,04	0,04**
PSRI	0,12**	0,23**	0,06**	0,06**	0,02**	0,03**	0,07	0,07**
CRI1	0,25**	0,33**	0,01**	0,02**	0,01**	0,04**	0,00	0,00**
ExG	0,19**	0,29**	0,06**	0,06**	0,02**	0,03**	0,03	0,03**
ExGR	0,15**	0,32**	0,06**	0,06**	0,02**	0,03**	0,04	0,04**
MGRVI	0,12**	0,32**	0,06**	0,06**	0,02**	0,03**	0,05	0,05**
NDI	0,11**	0,32**	0,05**	0,05**	0,02**	0,03**	0,05	0,05**
RGBVI	0,15**	0,32**	0,06**	0,06**	0,02**	0,02**	0,03	0,03**

* e ** : significativo ao nível de 0,05 e 0,01 de probabilidade pelo teste F.

Tabela 8. Coeficientes de determinação entre a produtividade real e os índices de vegetação para o talhão D-07 nas quatro datas analisadas.

D-07	14/abr		07/mai		27/mai		16/jun	
	Linear	Polinomial	Linear	Polinomial	Linear	Polinomial	Linear	Polinomial
NDVI	0,19**	0,58**	0,52**	0,74**	0,50**	0,75**	0,62**	0,82**
ARVI	0,18**	0,47**	0,49**	0,50**	0,69**	0,74**	0,22**	0,33**
EVI	0,18**	0,56**	0,35**	0,42**	0,64**	0,74**	0,64**	0,74**
GSAVI	0,26**	0,58**	0,39**	0,44**	0,62**	0,74**	0,62**	0,75**
GVI	0,47**	0,63**	0,61**	0,62**	0,53**	0,78**	0,53**	0,58**
NDWI	0,47**	0,63**	0,61**	0,63**	0,53**	0,78**	0,54**	0,58**
SR	0,22**	0,60**	0,56**	0,57**	0,52**	0,74**	0,65**	0,76**
RDVI	0,13**	0,61**	0,31**	0,43**	0,47**	0,73**	0,62**	0,75**
SAVI	0,21**	0,59**	0,66**	0,66**	0,51**	0,76**	0,62**	0,82**
OSAVI	0,16**	0,62**	0,38**	0,73**	0,48**	0,74**	0,55**	0,56**
ENDVI	0,19**	0,58**	0,50**	0,73**	0,47**	0,72**	0,52**	0,53**
GNDVI	0,44**	0,65**	0,62**	0,73**	0,57**	0,73**	0,59**	0,60**
IPVI	0,19**	0,58**	0,52**	0,74**	0,50**	0,75**	0,54**	0,55**
NLI	0,17**	0,61**	0,44**	0,75**	0,49**	0,76**	0,54**	0,55**
NDRE	0,12**	0,44**	0,53**	0,53**	0,60**	0,64**	0,61**	0,72**
CRI2	0,30**	0,32**	0,38**	0,56**	0,70**	0,75**	0,43**	0,43**
PSRI	0,07**	0,26**	0,48**	0,66**	0,50**	0,72**	0,55**	0,55**
CRI1	0,36**	0,44**	0,01**	0,02**	0,25**	0,29**	0,40**	0,53**
ExG	0,31**	0,57**	0,02**	0,38**	0,23**	0,69**	0,43**	0,69**
ExGR	0,17**	0,51**	0,07**	0,30**	0,32**	0,51**	0,52**	0,71**
MGRVI	0,01**	0,39**	0,34**	0,48**	0,41**	0,50**	0,58**	0,70**
NDI	0,01**	0,39**	0,34**	0,41**	0,41**	0,53**	0,49**	0,61**
RGBVI	0,14**	0,48**	0,16**	0,33**	0,30**	0,54**	0,62**	0,75**

* e ** : significativo ao nível de 0,05 e 0,01 de probabilidade pelo teste F.

Tabela 9. Coeficientes de determinação entre a produtividade real e os índices de vegetação para o talhão E-01 nas quatro datas analisadas.

E-01	14/abr		07/mai		27/mai		16/jun	
	Linear	Polinomial	Linear	Polinomial	Linear	Polinomial	Linear	Polinomial
NDVI	0,54**	0,55**	0,70**	0,72**	0,65**	0,68**	0,60**	0,64**
ARVI	0,33**	0,33**	0,41**	0,43**	0,12**	0,18**	0,28**	0,31**
EVI	0,36**	0,36**	0,47**	0,48**	0,46**	0,48**	0,50**	0,63**
GSAVI	0,37**	0,37**	0,45**	0,46**	0,44**	0,47**	0,56**	0,61**
GVI	0,35**	0,35**	0,27**	0,29**	0,10**	0,18**	0,40**	0,57**
NDWI	0,36**	0,36**	0,27**	0,29**	0,09**	0,18**	0,41**	0,57**
SR	0,57**	0,59**	0,73**	0,74**	0,66**	0,68**	0,60**	0,62**
RDVI	0,55**	0,57**	0,75**	0,77**	0,64**	0,66**	0,61**	0,64**
SAVI	0,70**	0,72**	0,70**	0,71**	0,65**	0,67**	0,61**	0,64**
OSAVI	0,55**	0,56**	0,74**	0,74**	0,65**	0,68**	0,61**	0,64**
ENDVI	0,52**	0,53**	0,71**	0,73**	0,68**	0,70**	0,60**	0,63**
GNDVI	0,59**	0,60**	0,54**	0,54**	0,34**	0,39**	0,06**	0,24**
IPVI	0,54**	0,55**	0,70**	0,72**	0,65**	0,68**	0,60**	0,64**
NLI	0,54**	0,55**	0,73**	0,74**	0,65**	0,68**	0,61**	0,65**
NDRE	0,49**	0,55**	0,70**	0,72**	0,67**	0,68**	0,61**	0,64**
CRI2	0,43**	0,43**	0,10**	0,35**	0,55**	0,55**	0,32**	0,43**
PSRI	0,55**	0,55**	0,62**	0,64**	0,52**	0,55**	0,61**	0,64**
CRI1	0,30**	0,33**	0,18**	0,32**	0,41**	0,42**	0,56**	0,61**
ExG	0,33**	0,39**	0,25**	0,27**	0,32**	0,32**	0,73**	0,73**
ExGR	0,42**	0,45**	0,35**	0,38**	0,39**	0,39**	0,72**	0,72**
MGRVI	0,48**	0,51**	0,41**	0,45**	0,50**	0,51**	0,51**	0,61**
NDI	0,49**	0,51**	0,41**	0,47**	0,48**	0,50**	0,53**	0,59**
RGBVI	0,42**	0,45**	0,39**	0,43**	0,44**	0,44**	0,73**	0,73**

* e ** : significativo ao nível de 0,05 e 0,01 de probabilidade pelo teste F.

Foi possível observar, através dos coeficientes de determinação (R^2), que o talhão C-01, em sua totalidade, não possuiu boa correlação com a produtividade do algodão em todo o ciclo estudado. Gutierrez *et al.* (2012) demonstraram que o uso de IVs na estimativa da produtividade pode ter restrições em algumas situações, principalmente quando há desequilíbrio entre o crescimento vegetativo e o reprodutivo. O algodoeiro é uma planta com sistema fotossintético C3, cuja produção de biomassa não apresenta correlação direta com a produtividade, diferentemente ao que ocorre com as plantas C4, como as gramíneas (THENKABALL *et al.* 2000).

Os valores dos IVs podem sofrer influência de outros fatores além dos relacionados com a reflectância do dossel dos cultivos. Jones *et al.* (2012) estudaram o efeito de diferentes solos, orientação do sensor em relação ao alinhamento de plantio, tipo de palhada e teor de umidade do solo no valor do NDVI calculado por um sensor

ótico ativo de vegetação. Os autores concluíram que a variação de todos esses fatores induziu em diferenças no valor do índice. As variações levaram a erros da ordem de 15 a 35% sobre o valor calculado do NDVI; essa diferença significa até 500 kg.ha⁻¹ na estimativa da produtividade da cultura do milho.

Essa situação também pode estar associada às calibrações realizadas nas máquinas tal como pela época de colheita, que quanto mais tardia, ocorre o escorrimento do algodão no capulho. A produtividade obtida pelo sensor tende a ser superestimada quando a produtividade da lavoura é alta: por exemplo, na variedade TMG 47 B2RF é subestimada quando a produtividade da lavoura é baixa, casos em que é aconselhável realizar a calibração, sempre ao trocar de lavoura e, indispensavelmente, ao mudar de cultivar. De acordo com Blackmore *et al.* (2003) o mapa de produtividade da cultura é o melhor indicador entre todos os fatores que influenciam o rendimento; entretanto, a coleta de dados pela colhedora deve ser acompanhada de cuidados operacionais, como a largura efetiva de linhas na plataforma, entrada e saída da lavoura, número de manobras. Por essa questão, nas discussões subsequentes, o talhão C-01 não será incluído.

Em contrapartida, os talhões D-07 e E-01 apresentaram ótimos valores de correlações com a produtividade do algodão nas quatro datas analisadas, tendo correlações positivas entre as médias de valores de índice de vegetação com a produtividade do algodão. Venteris *et al.* (2015) relataram que análises interanual de dados de IVs com a produtividade de cultivos agrícolas podem ser prejudicadas devido à interferência de vários fatores, dentre os quais pode-se destacar as diferenças na data de aquisição das imagens e a interação com o estágio de crescimento da cultura, o que valida o estudo atual em um ano/ciclo do algodão.

A adoção de equações não-lineares por Pellegrino (2000) e por Machado (2003) melhorou a explicação da produtividade pelos dados espectrais. Faz sentido imaginar que as variáveis biológicas envolvidas, pela própria natureza, condicionem interações complexas e, portanto, mais ajustáveis a equações não-lineares. O modelo de regressão polinomial quadrático obteve melhores desempenhos em relação ao modelo linear, como por exemplo no caso do índice OSAVI no talhão D-07 para a data de 17/04, em que o valor da correlação polinomial quadrática foi quase quatro vezes maior que o obtido na correlação linear (indo de 0,16 para 0,62), indicando que o modelo quadrático conseguiu explicar melhor os valores dependentes, ou seja, os valores observados (reais), indicando ser capaz de estimar a produtividade satisfatoriamente.

Pode-se observar que por meio do coeficiente de determinação, que o SAVI foi o que melhor explicou a produtividade dos talhões, por ser um índice de vegetação que leva em consideração a banda do vermelho, infravermelho próximo, além de ter uma certa vantagem na redução do sinal do solo e da atmosfera, correspondendo melhor na detecção de regiões com maiores densidades de biomassa. O NDVI, assim como o RDVI apresentaram também boas correlações com a produtividade, por serem índices que também utilizam essas duas bandas espectrais, e que tem uma relação direta com o vigor da vegetação. A Razão Simples (SR), apesar de ser considerada um índice de fácil cálculo, e de sofrer influências da atmosfera, obteve boas correlações durante o ciclo estudado do algodão. Já o índice CRI1 apresentou menor correlação, ou seja, os valores dos determinantes foram baixos, o que pode significar que para o CRI1, que se utiliza somente das bandas do azul e verde, os valores não foram suficientes para corresponder à produtividade do algodão. O ARVI também não teve bons valores de correlação com a produtividade do algodão, apesar de ser considerado, em média, quatro vezes menos sensível aos fatores atmosféricos que o NDVI, sendo ideal para casos em que os efeitos atmosféricos são mais influentes que os fatores do solo, como é o caso de uma superfície totalmente coberta por vegetação (ROCHA, 2012).

O NDWI, apesar de ser um índice da água, apresentou ótima correlação (0,78) com a produtividade do talhão D-07 em 27/05, fase em que a planta se encontra em seu florescimento pleno, retendo maior quantidade de água nas folhas e, conseqüentemente, os índices que exploram as bandas da água, tendem a apresentar melhores resultados.

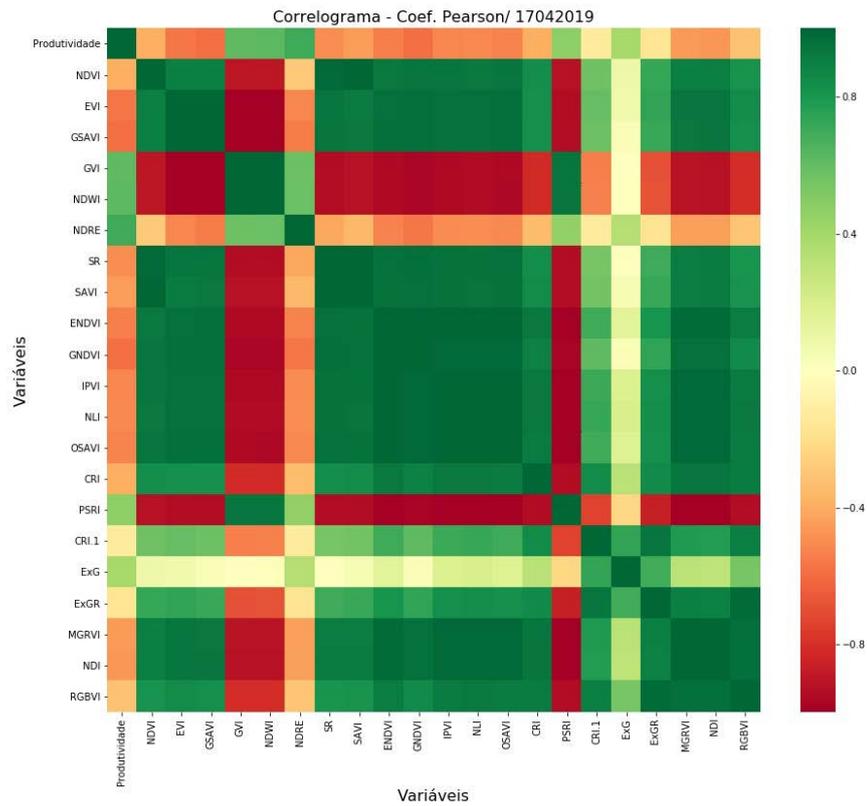


Figura 9. Correlograma entre os índices de vegetação entre si e a produtividade na data de 17/04/18.

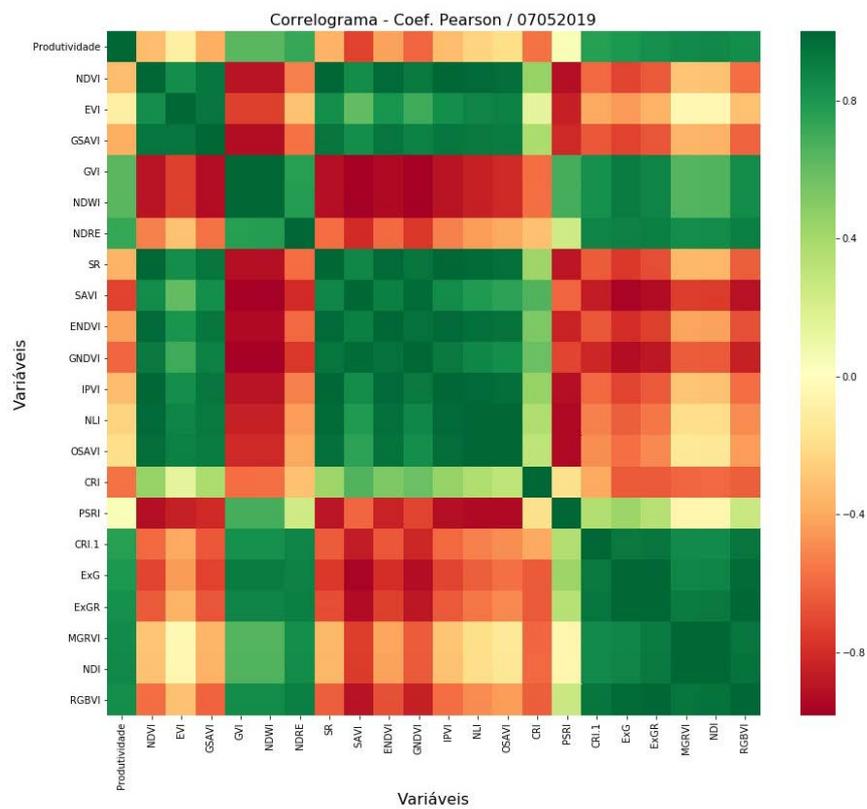


Figura 10. Correlograma entre os índices de vegetação entre si e a produtividade na data de 07/05/18.

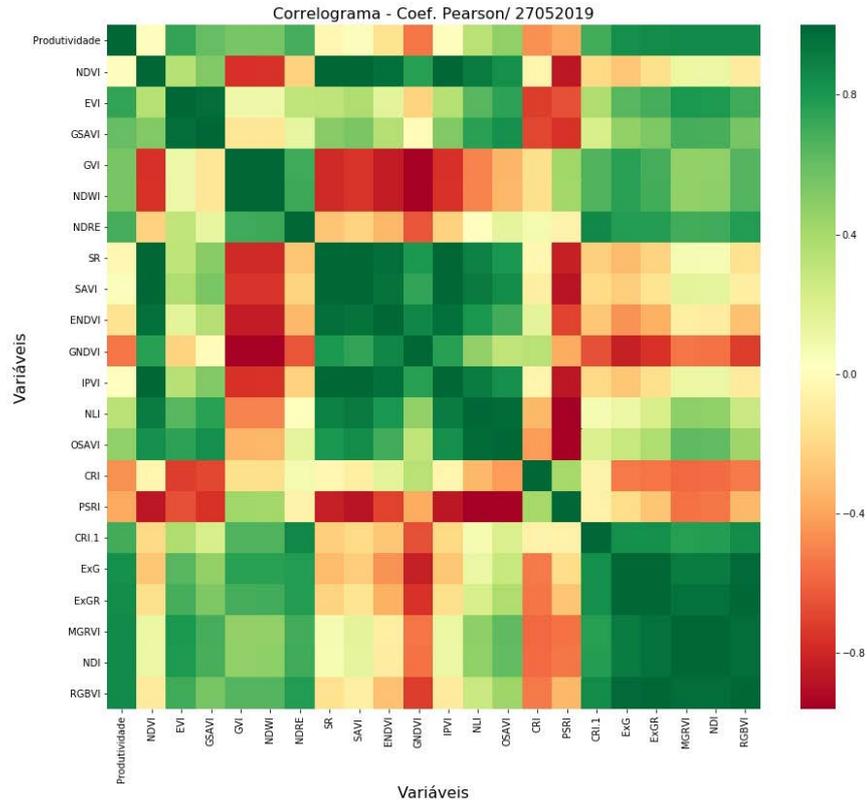


Figura 11. Correlograma entre os índices de vegetação e a produtividade na data de 27/05/18.

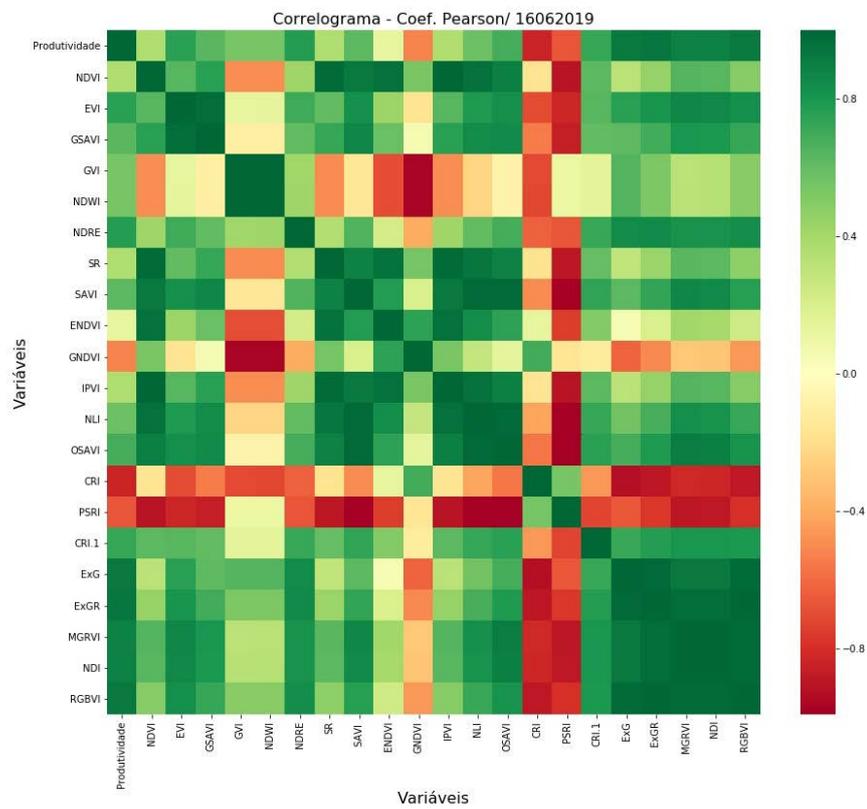


Figura 12. Correlograma entre os índices de vegetação e a produtividade na data de 16/06/18.

Pelas análises estatísticas pode-se inferir que a correlação entre os dados espectrais e a produtividade é dependente da idade do algodoeiro e do seu estágio fenológico. A data de 17/04 corresponde ao início do florescimento do algodão, que se mostrou a fase menos indicada para se estimar a produtividade da cultura, com os menores coeficientes de determinação, como pode ser observado na faixa mais clara da Figura 9. Comportamento contrário ocorreu na fase da frutificação completa do algodão, representada pela data de 16/06, onde obtiveram-se as melhores correlações entre a produtividade e os índices de vegetação, podendo ser visualizada pela faixa mais escura da Figura 12. Nesta fase, os índices NDVI e SAVI obtiveram os maiores valores de correlação de toda a área analisada (0,82) (Tabela 9). Essa constatação corrobora com a afirmação de Gutierrez (2012), que alega que para a estimativa da produtividade do algodão, o momento de aquisição durante a frutificação é a fase que apresenta maior correlação. Iqbal *et al.* (2013) também concluíram que uma única imagem multiespectral durante a fase fenológica de frutificação é suficiente para estimar a variabilidade espacial do rendimento de fibra de algodão.

Os índices que se utilizam somente das 3 bandas do visível (RGB), ExG, ExGR, e RGBVI, obtiveram um aumento considerável do seu valor de correlação ($>0,70$) na data de 16/06 (Tabela 10), que se refere à frutificação completa do algodão. Segundo Brandão (2011), nessa fase os capulhos encontram-se abertos em pelo menos 80% das plantas. Uma explicação é que o algodão nessa fase já está com praticamente todos seus capulhos abertos e que os mesmos possuem a cor branca como característica, o que resulta numa alta reflectância nos comprimentos de onda das bandas do visível, sendo que a junção das cores primárias (RGB) concebem a cor branca.

De acordo com Hopkins (2000), quanto maior for o valor absoluto do coeficiente, mais forte é a relação entre as variáveis, o coeficiente de determinação varia entre 0 e 1, no qual indica em porcentagem quanto o modelo consegue explicar os valores observados em campo. Com isso, foram considerados os melhores índices os que tiveram os melhores desempenhos através do R^2 , tanto para o modelo linear, quanto para o polinomial, visando a utilização de todos as bandas espectrais avaliadas. As Tabelas 10 e 11 apresentam os resultados da análise de regressão linear e polinomial quadrática, a partir dos melhores índices, ou seja, os que obtiveram maiores valores de correlação com a produtividade, e seus valores acumulados (IVacum) para as quatro datas analisadas.

Tabela 10: Resultados da análise de regressão linear e polinomial quadrática entre os melhores índices de vegetação em relação à produtividade do algodoeiro e seus respectivos valores acumulados nas quatro datas analisadas para o talhão D-07.

D-07		Linear			Polinomial		
		R2	p-valor	Equação	R2	p-valor	Equação
IV	NDVI 16/jun	0,64	<0,001	$y = 11,043x - 5,8948$	0,65	<0,001	$y = 44,203x^2 - 63,073x + 25,12$
	NDRE 16/jun	0,15	0,0018	$y = 7,6857x + 0,5327$	0,44	<0,001	$y = -429,96x^2 + 341,41x - 63,976$
	SAVI 16/jun	0,64	<0,001	$y = 8,8572x - 5,9606$	0,65	<0,001	$y = 28,89x^2 - 51,973x + 26,006$
	CRI2 27/mai	0,67	<0,001	$y = -0,3058x + 9,2887$	0,67	<0,001	$y = 0,0047x^2 - 0,4835x + 10,97$
	NDVI	0,61	<0,001	$y = 5,9029x - 17,191$	0,61	<0,001	$y = 1,3479x^2 - 3,4907x - 0,8303$
	NDRE	0,03	<0,001	$y = -1,814x + 6,616$	0,05	<0,001	$y = -66,319x^2 + 213,66x - 168,35$
IVacum	SAVI	0,61	<0,001	$y = 4,939x - 18,344$	0,61	<0,001	$y = 1,7229x^2 - 10,215x + 14,969$
	CRI2	0,67	<0,001	$y = -0,1177x + 13,901$	0,67	<0,001	$y = -0,0044x^2 + 0,6548x - 19,834$

Tabela 11: Resultados da análise de regressão linear e polinomial quadrática entre os melhores índices de vegetação em relação à produtividade do algodoeiro e seus respectivos valores acumulados nas quatro datas analisadas para o talhão E-01.

E-01		Linear			Polinomial		
		R ²	P-valor	Equação	R ²	p-valor	Equação
IV	SAVI 17/abr	0,58	<0,001	$y = 43,658x - 43,86$	0,58	<0,001	$y = 663,41x^2 - 1424,8x + 768,7$
	RDVI 07/mai	0,55	<0,001	$y = 29,047x - 13,816$	0,56	<0,001	$y = -285,76x^2 + 389,87x - 127,69$
	OSAVI 07/mai	0,57	<0,001	$y = 26,716x - 22,377$	0,57	<0,001	$y = -99,074x^2 + 226,06x - 122,64$
	ExR 16/jun	0,58	<0,001	$y = 47,567x + 3,1041$	0,58	<0,001	$y = -855,2x^2 + 97,522x + 2,3965$
	RGBVI 16/jun	0,58	<0,001	$y = 8,8382x + 1,1181$	0,59	<0,001	$y = -38,047x^2 + 37,939x - 4,4181$
	SAVI	0,62	<0,001	$y = 10,115x - 38,163$	0,62	<0,001	$y = -8,3149x^2 + 80,249x - 186,05$
	RDVI	0,59	<0,001	$y = 5,2984x - 8,1261$	0,60	<0,001	$y = -13,915x^2 + 71,881x - 87,738$
	OSAVI	0,57	<0,001	$y = 4,2824x - 12,001$	0,63	<0,001	$y = -4,2811x^2 + 37,348x - 75,835$
IVacum	ExR	0,58	<0,001	$y = 36,324x - 0,3708$	0,62	<0,001	$y = -969,18x^2 + 300,77x - 18,354$
	RGBVI	0,59	<0,001	$y = 4,3523x - 2,3392$	0,64	<0,001	$y = -15,993x^2 + 55,363x - 42,945$

Comparando o IV acumulado e o IV individual, observou-se o aumento dos valores de correlação, em sua maioria, dos dados acumulados superaram os dados individuais, como é possível ver no talhão E-01, onde o índice RGBVI obteve maior R^2 individual: esse dado explicou 59% da variação da produtividade, enquanto o RGBVI acumulado explicou 64%, que foi o maior R^2 obtido dos dados dos IV's acumulados. Caso contrário em relação ao talhão D-07, em que entre os valores de R^2 dos dados individuais e acumulados não há uma diferença entre eles. Considera-se esse um bom resultado, uma vez que a variável espectral sozinha explicou 82% da variação da produtividade algumas semanas antes da colheita, como é o caso do CRI2. Em relação à correlação linear e polinomial, nota-se que não houve uma diferença significativa entre os modelos, exceto no caso do NDRE no talhão D-07, em que o seu valor de R^2 de 0,15 para o modelo linear, foi para 0,44 no modelo polinomial, fato este que faz-se questionar do quão assertivo foi o ajuste da curva do modelo na estimativa da produtividade do algodão. no qual o dado espectral acumulado não superou a correlação obtida pelo índice referente à uma data de análise.

As Tabela 12 e 13 apresentam a estatística dos valores da predição da produtividade através dos melhores IVs analisados para cada talhão, sendo possível a realização da comparação entre a produtividade observada.

Apesar da diferença entre os coeficientes de determinação entre os IVs, quando aplicada a equação de regressão para estimativa da produtividade, nota-se que todas as estimativas, tanto para o modelo linear quanto para o polinomial, superestimaram a média e mediana dos dados reais, com exceção do NDRE no talhão D-07, que apesar de subestimado, foi a estimativa mais próxima do real. Já para o desvio padrão e o coeficiente de variação, os dados estimados se destacam pelos valores obtidos bem abaixo dos valores reais para todos os IVs, indicando uma boa estimativa dos dados de produtividade, o que corrobora com o estudo de Guo *et al.* (2012) que relacionaram a maior produção de algodão ao longo de cinco safras, quando a variabilidade espacial da produtividade no talhão analisado indicado pelo coeficiente de variação foi menor. Outra observação interessante, é a baixa amplitude dos dados estimados, podendo ser efeito da interpolação dos dados de produtividade, em que todo o talhão se comporte de maneira menos heterogênea.

A Tabela 14 apresenta os resultados do RMSE e MAE entre a produtividade observada e a estimada.

Tabela 12. Estatística descritiva da produtividade estimada a partir das melhores correlações lineares entre os índices de vegetação e a produtividade real para toda a área estudada.

Talhão	Dado Espectral	Produtividade Média Estimada (t.ha⁻¹)	Mediana	Desvio Padrão	Coefficiente de Variação	Amplitude	Mínimo	Máximo
D - 07	CRI2 - 27/05	3,89	3,89	0,05	1,23	0,37	3,62	4,00
	NDVI - 16/06	3,83	3,83	0,03	0,74	0,14	3,74	3,88
	SAVI - 16/06	3,83	3,83	0,03	0,70	0,13	3,75	3,88
	NDRE - 16/06	3,62	3,62	0,04	1,06	0,18	3,53	3,71
	CRI2 - Acum	3,95	3,94	0,07	1,74	0,42	3,83	4,25
	NDVI - Acum	3,80	3,82	0,06	1,52	0,28	3,64	3,92
	SAVI - Acum	3,80	3,82	0,05	1,41	0,25	3,66	3,91
	NDRE - Acum	3,73	3,73	0,03	0,84	0,14	3,67	3,81
E - 01	SAVI - 17/04	4,81	4,89	0,16	3,41	0,76	4,23	4,99
	RDVI - 07/05	4,98	5,01	0,17	3,45	0,76	4,43	5,19
	OSAVI - 07/05	4,94	4,98	0,16	3,30	0,76	4,37	5,13
	ExR - 16/06	4,89	5,00	0,24	4,97	0,89	4,27	5,15
	RGBVI - 16/06	4,90	5,00	0,24	4,95	0,86	4,26	5,12
	SAVI - Acum	4,81	4,89	0,16	3,41	0,76	4,23	4,99
	RDVI - Acum	4,99	5,04	0,16	3,16	0,65	4,52	5,17
	OSAVI - Acum	4,96	5,00	0,15	2,98	0,63	4,49	5,12
	ExR - Acum	5,15	5,28	0,31	6,08	1,22	4,32	5,54
	RGBVI - Acum	5,13	5,23	0,26	5,15	1,03	4,37	5,40

Tabela 13. Estatística descritiva da produtividade estimada a partir das melhores correlações polinomiais quadráticas entre os índices de vegetação e a produtividade real para toda a área estudada.

Talhão	Dado Espectral	Produtividade			Coeficiente de Variação	Amplitude	Mínimo	Máximo
		Média Estimada (t.ha ⁻¹)	Mediana	Desvio Padrão				
D - 07	CRI2 - 27/05	3,90	3,89	0,05	1,27	0,38	3,63	4,01
	NDVI - 16/06	3,85	3,86	0,04	0,97	0,19	3,73	3,92
	SAVI - 16/06	3,86	3,86	0,04	0,92	0,17	3,75	3,92
	NDRE - 16/06	3,78	3,79	0,03	0,72	0,12	3,68	3,80
	CRI2 - Acum	4,07	4,07	0,05	1,24	0,29	3,98	4,27
	NDVI - Acum	3,80	3,82	0,06	1,52	0,28	3,64	3,92
	SAVI - Acum	3,81	3,82	0,06	1,49	0,27	3,65	3,92
	NDRE - Acum	3,69	3,72	0,06	1,57	0,26	3,48	3,74
E - 01	SAVI - 17/04	4,80	4,88	0,16	3,31	0,75	4,22	4,97
	RDVI - 07/05	4,93	4,96	0,13	2,73	0,61	4,45	5,07
	OSAVI - 07/05	4,92	4,96	0,15	3,03	0,71	4,38	5,09
	ExR - 16/06	4,83	4,93	0,20	4,06	0,74	4,27	5,01
	RGBVI - 16/06	4,82	4,91	0,19	3,86	0,70	4,26	4,96
	SAVI - Acum	4,80	4,88	0,16	3,31	0,75	4,22	4,97
	RDVI - Acum	4,92	4,96	0,11	2,21	0,46	4,56	5,02
	OSAVI - Acum	4,93	4,96	0,13	2,58	0,55	4,51	5,06
	ExR - Acum	4,90	4,97	0,17	3,38	0,66	4,32	4,98
	RGBVI - Acum	4,91	4,96	0,14	2,85	0,57	4,40	4,97

Tabela 14. Resultados do RMSE entre a produtividade observada e a estimada.

Talhão	Dado Espectral	RMSE		MAE	
		Polinomial	Linear	Polinomial	Linear
D - 07	CRI2 - 27/05	0,11	0,15	0,29	0,35
	NDVI - 16/06	0,06	0,05	0,19	0,20
	SAVI - 16/06	0,06	0,05	0,18	0,20
	NPRE - 16/06	0,17	0,07	0,38	0,24
	CRI2 - Acum	0,06	0,12	0,19	0,30
	NDVI - Acum	0,07	0,07	0,23	0,23
	SAVI - Acum	0,07	0,07	0,15	0,15
	NPRE - Acum	0,10	0,12	0,28	0,32
E - 01	SAVI - 17/04	0,08	0,10	0,23	0,27
	RDVI - 07/05	0,15	0,14	0,33	0,32
	OSAVI - 07/05	0,09	0,10	0,26	0,27
	ExR - 16/06	0,11	0,14	0,29	0,34
	RGBVI - 16/06	0,03	0,03	0,15	0,14
	SAVI - Acum	0,06	0,06	0,14	0,15
	RDVI - Acum	0,07	0,10	0,22	0,27
	OSAVI - Acum	0,09	0,10	0,24	0,27
ExR - Acum	0,08	0,12	0,21	0,30	
RGBVI - Acum	0,04	0,14	0,13	0,13	

Estudos têm sido desenvolvidos avaliando a região espectral Red-edge como alternativa para substituição do NDVI, situando-se entre 680-740 nm nas bandas do vermelho e infravermelho próximo (KANKE et al., 2012). Os índices baseados nessa faixa do espectro eletromagnético são mais eficazes em comparação aos índices que utilizam a banda do vermelho para a predição de produtividade, mas que não foi o caso para a cultura do algodão. Apesar de ter obtido o maior valor de significância (p-valor) (Tabela 11), o índice NDRE obteve os maiores valores de CV (Tabela 13) e os maiores valores do RMSE e MAE (Tabela 14) na produtividade estimada por ele, tanto em uma data como em seu acumulado, se mostrando não indicado para a estimativa do algodoeiro.

Apesar da relação não linear do modelo polinomial quadrático teoricamente melhorar a explicação dos dados espectrais com a produtividade do que o modelo linear,

quando observados os resultados dos R^2 (Tabelas 10 e 11) e da estatística descritiva dos dados estimados (Tabela 12 e 13), vemos que não existe uma diferença significativa entre eles na estimativa da produtividade. Ao contrário do que se observa nos resultados do RMSE e MAE, em que é visto uma diferença de até $0,13 \text{ ton.ha}^{-1}$ entre os modelos, caso este do RGBVI, evidenciando a explicação teórica do uso de um modelo não linear em estudos como esse.

É possível observar que o índice RGBVI, apesar de ter obtido o segundo maior valor do coeficiente de variação (Tabela 12), ele obteve os mais baixos valores do RMSE e MAE, o que indica ser um bom preditor da produtividade do algodão na fase de frutificação completa, apesar de Bending *et al.* (2015) indicarem que esse índice é mais eficiente nos estágios iniciais de desenvolvimento da cultura.

Além do R^2 , a análise exploratória do valor médio dos dados espectrais (Tabelas 12 e 13), revelaram que além dos CVs do SAVI serem menores em relação aos demais, também possuem os baixos valores do RMSE e MAE (Tabela 14). Esse fato sugere menor sensibilidade do SAVI em detectar variações no dossel do algodão tanto em relação à variação entre os talhões por imagem, quanto ao comportamento multitemporal entre as imagens.

5. CONCLUSÕES

Os dados espectrais do dossel do algodoeiro têm relação direta com a produtividade da cultura, sendo indicada para tal análise alguma data que se refira à fase de frutificação completa da cultura. Os experimentos deste estudo demonstraram que IVs derivados de imagens do sensor MSI- Sentinel 2 podem ser utilizados para estimativas de produtividade de safras de algodão nessa fase.

O índice de vegetação que se mostrou mais adequado para a predição da produtividade, mesmo sem a utilização da banda do infravermelho, foi o RGBVI, tanto para uma única imagem (16/jun), quanto para o acumulado das quatro imagens (IVacum). A utilização dos dados espectrais na forma acumulada não obteve uma diferença significativa para a estimativa da produtividade, sendo então sugerido a não utilização do mesmo, por resultarem em maior tempo de análise e processamento.

Deste modo conclui-se que o RGBVI pode ser utilizado como um fator estimador da cultura do algodão, podendo ser úteis em programas de monitoramento e previsões de safras, porém a equação obtida para esse índice é aplicável somente para a área e safra estudada.

Outros estudos podem ser realizados a partir do conjunto de dados deste experimento, como na junção com dados agrometeorológicos e dados SAR para geração de um modelo agrometeorológico-espectral para prever a produtividade do algodoeiro de forma mais precisa.

REFERÊNCIAS

- ABRAPA. Associação Brasileira dos Produtores de Algodão. Disponível em: <<http://www.abrapa.com.br>>. Acesso em 16 de Novembro de 2017.
- AGUIAR, P. H.; MELO, J. C. F.; BARROS, J. J.; COSTA, M. C.; BRANCO, E. O. Ensaio de Competição de Cultivares de Algodão no Estado de Mato Grosso, Safra 2003/2004. In: **V Congresso Brasileiro de Algodão. Salvador, BA. 2005.**
- ANDRADE, A. C. de; FRANCISCO, C. N.; ALMEIDA, C. M. Desempenho de classificadores paramétrico e não paramétrico na classificação da fisionomia vegetal. In: **XVII Simpósio Brasileiro de Sensoriamento Remoto – SBSR, João Pessoa-PB, INPE. Anais. 2015.**
- ANDREY, Javier. Impacto de las nubes de polvo sahariano sobre las medidas de la columna de ozono desde fotómetros orbitales orientados al nadir. 2011. TESE
- ANSELMO, J. L., ANDRADE, B. G. M., DA SILVA, D. C., VIANA, D. R., DE ÁVILA, J., DA SILVA, T. R., MUDINUTTI, L., TEIXEIRA, D. S., & MERLOTI, L. F. Ensaio comparativo de variedade de algodão em época e espaçamento distintos, Chapadão do Sul-MS (Comparative cotton variety test at different time and spacing, Chapadão do Sul-MS). Fundação Chapadão, 5, 18-23, 2015.
- Anuário Estatístico de Mato Grosso - 2016.** Secretaria de Estado de Planejamento e Coordenação Geral. Cuiabá: SEPLAN - MT: Central do Texto, 2007. Disponível em: http://www.seplan.mt.gov.br/-/anuario-estatistico?ciclo=cv_gestao_inf.
- ARAÚJO, J. *et al.* Estimativa da produtividade e determinação de zonas de manejo, em culturas de grãos, por meio de videografia aérea multiespectral. **Acta Scientiarum. Agronomy**, v. 27, n. 3, p. 437-447, Julho/Setembro. 2004. Disponível em: <http://periodicos.uem.br/ojs/index.php/ActaSciAgron/article/view/1406>
- AZEVEDO, P. V.; SILVA, F. D. S. Risco climático do algodoeiro na região nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 22, p.408-416, 2007.
- BAIO, F. H. R. et al. Relationship between cotton productivity and variability of NDVI obtained by landsat images. **Bioscience Journal**, v. 34, n. 6, 2018.
- BARBOSA, H; ROCHA, D; KUMAR, L; BAMUTAZE, Y. Quantification of sugarcane crop productivity using agrometeorological-spectral mode: a study case in northeastern of Brazil. **Revista Agrollanía**, v. 9, pág. 69-75, 2012.

BARBOSA, H; TOTE, C; KUMAR, L; BAMUTAZE, Y. **Harnessing Earth Observation and Satellite Information for Monitoring Desertification, Drought and Agricultural Activities in Developing Countries, Environmental Change and Sustainability**, Dr. Steven Silvern (Ed.), ISBN: 978-953-51- 1094-1, InTech, DOI: 10.5772/55499. 2013.

BARET, F.; GUYOT, G.; MAJOR, D. J. TSAVI: a vegetation index which minimizes soil brightness effects on LAI or APAR estimation. In: International Geoscience and Remote Sensing Symposium, 1989; Canadian Symposium on Remote Sensing, 12., 1989, Vancouver. **Proceedings...** Piscataway: IEEE, 1989. v. 1, p. 1355-1358.

BARET, F.; GUYOT, G. Potentials and Limits of vegetation Indices for LAI and APAR assessment. **Remote Sensing of Environment**, New York, v. 35, n. 2-3, p. 161-173, 1991.

BARNES, E. M., MORAN, M. S., PINTER, JR., P. J., CLARKE, T. R. Multispectral Remote Sensing and SiteSpecific Agriculture: Examples of Current Tecnology and Future Possibilities. In: Precision Agriculture: Proceedings of the **III International Conference on Precision Agriculture**. 1996. Robert, P.C., R.H. Rust and L.E. Larson (ed.). Minnesota, June 23-26, 1996. ASA,CSSA, SSSA, Madison,WI.

BARNES, E. M. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington, MN, USA**. 2000.

BENDIG, J. *et al.* Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79–87, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2015.02.012>>.

BERKA, L. M. S.; RUDORFF, B. F. T.; SHIMABUKURO, Y.E. Soybean yield estimation by an agrometeorological model in a GIS. **Scientia Agricola**, v.60, p.433-440, 2003.

BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L; SOBJAK, R. ; BIER, V. A. ; MERCANTE, E. . Interpolation methods for thematic maps of soybean yield and soil chemical attributes. **Semina. Ciências agrárias** (ONLINE), v. 38, p. 1059-1069, 2017.

BIRTH, G. S.; MCVEY, G. R. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer1. **Agronomy Journal**, v. 60, n. 6, p. 640, 1968. Disponível em: <<https://www.agronomy.org/publications/aj/abstracts/60/6/AJ0600060640>>.

BLACKMER, T. M.; SCHEPERS, J. S.; VARVEL, G. E.; MEYER, G. E. Analysis of aerial photography for nitrogen stress within corn fields. **Agronomy Journal**, v. 88, p.729-733, 1996.

BLACKMORE, B. S.; GODWIN, R. J.; FOUNTAS, S. The analysis of spatial and temporal trends in yield map data over six years. **Biosystems Engineering**, v.84, p.455-466, 2003.

BLACKMORE, B.S.; MARSHALL, C.J. Yield mapping; errors and algorithms. In: International Conference On Precision Agriculture, 3, Minneapolis,1996. **Proceedings**, Madison, WI, 1996, p.403-415.

BRANDÃO, Z. N.; BEZERRA, M. V. C.; FREIRE, E. C; SILVA, B. B. Determinação de índices de vegetação usando imagens de satélite para Agricultura de precisão. In: 5º Congresso Brasileiro de Algodão. **Anais...** Salvador, BA. 2005.

BRANDÃO, Z. N.; SOFIATTI, V.; BEZERRA, J. R. C.; FERREIRA, G. B. Estimativa da produtividade do algodoeiro através de imagens de satélite. In: 8º Congresso Brasileiro de Algodão & I Cotton Expo. **Anais...** São Paulo, SP. 2011.

BRANDÃO, Z. N., GREGO, C. R., INAMASU, R. Y., & JORGE, L. A. (2014). Spectral reflectance of satellite images using geostatistics methods to estimate growth and cotton yield. In XVI Remote Sensing for Agriculture, Ecosystems, and Hidrology (pp. 923920-1 - 923920-8). **Anais...** Amsterdam: International Society for Optics and Photonics.

BULANON, D. *et al.* Evaluation of Different Irrigation Methods for an Apple Orchard Using an Aerial Imaging System. **ISPRS International Journal of Geo-Information**, v. 5, n. 6, p. 79, 2016. Disponível em: <<http://www.mdpi.com/2220-9964/5/6/79>>.

CANDIAGO, S. *et al.* Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. **Remote Sensing**, v. 7, n. 4, p. 4026–4047, 2015.

CAPELLI, N. L. **Agricultura de precisão - Novas tecnologias para o processo produtivo.** LIE/DMAQAG/ FEAGRI/UNICAMP, 1999. Disponível em: <http://wwwbases.cnptia.embrapa.br/cria/gip/gipap/capelli.doc>

CARVALHO, C. G. P. D., ARIAS, C. A. A., TOLEDO, J. F. F. D., ALMEIDA, L. A. D., KIIHL, R. A. D. S., OLIVEIRA, M. F. D., HIROMOTO, D. M.; TAKEDA, C. (2003). Proposta de classificação dos coeficientes de variação em relação à produtividade e altura da planta de soja (Proposed classification of the coefficients of variation in relation to productivity and soybean plant height). **Pesquisa Agropecuária Brasileira**, 38, 187-193.

COELHO, A. B. **A cultura do algodão e a questão da interação entre preços internos e externos.** 2002. Dissertação (Mestrado em Economia) - Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo.

- CRESSIE, N. A. C. **Statistics for spatial data**. Revised ed. New York: Wiley-Interscience Publication, 1993. 900 p.
- CRIPPEN, R. E. Calculating the vegetation index faster. **Remote Sensing of Environment**, v. 34, n. 1, p. 71–73, 1990.
- CRIST, E. P.; CICONE, R. C. Application of the tasseled cap concept to simulated thematic mapper data. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v. 50, p. 343-352, 1984.
- CRUZ, M. A. S.; SOUZA, A. M. B.; JESUS, J. S. Avaliação da cobertura vegetal por meio dos Índices de Vegetação SR, NDVI, SAVI e EVI na bacia do rio Japarutuba-Mirim em Sergipe. In: Simpósio Brasileiro de Sensoriamento Remoto, 15, 2011, Curitiba, Brasil. **Anais...** São José dos Campos: INPE, 2011. p. 1357-1365.
- DIKER, K.; BAUSCH, W. C.; HEERMANN, D. F. Monitoring temporal changes of irrigated corn by aerial images. **Annual International ASAE Meeting**. Sacramento, California, USA Paper No. 01-1144, 2001.
- DAUGHTRY, C.S.T.; WALTHALL, C.L.; KIM, M.S.; BROWN DE COLSTOUN, E.; MCMURTREY III, J.E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing Environment**. v. 74 , p. 229-239, 2000.
- EITEL, J. U. H. *et al.* Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. **Remote Sensing of Environment**, v. 115, n. 12, p. 3640–3646, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.09.002>>.
- EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Algodão: tecnologia de produção**. Embrapa Agropecuária Oeste, 296 p. 2001.
- ELEUTÉRIO, J.R. Colheita mecânica: avaliação das perdas e otimização. In: Congresso Brasileiro De Algodão, 3., 2001, Campo Grande. **Anais...** Campina Grande: EMBRAPA/ CNPA, 2001, p.11-14, 2001.
- ESA. European Space Agency. Disponível em: <www.esa.int/Our_Activities/Operations/Sentinel-2_operations>. Acesso em 02 de Abril de 2018
- FREIRE, N. C. F.; PACHECO, A. Aspectos da detecção de áreas de risco à desertificação na região de Xingó. **Anais...** XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, p. 16-21, 2005.
- FITZGERALD, G.J., RODRIGUEZ, D., CHRISTENSEN, L.K., BELFORD, R., SADRAS, V.O., CLARKE, T.R. **Precision Agriculture**, v.7, p. 233–248, 2006.

FONTANA, D.C.; BERLATO, M.A.; LAUSCHNER, M.H.; MELO, R.W. Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 36, p.399-403, 2001.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, New York, v. 58, n. 3, p. 289-298, dec. 1996.

GITELSON, A. A. *et al.* Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochemistry and Photobiology**, v. 75, n. 3, p. 272, 2002. Disponível em:<[http://doi.wiley.com/10.1562/0031-8655\(2002\)075%3C0272:ACCIPL%3E2.0.CO;2](http://doi.wiley.com/10.1562/0031-8655(2002)075%3C0272:ACCIPL%3E2.0.CO;2)>.

GOEL, N. S.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: a computer simulation. **Remote Sensing Reviews**, v. 10, n. 4, p. 309–347, 1994.

GREGO, R. C.; VIEIRA, S. R. Variabilidade espacial de propriedades físicas do solo em uma parcela experimental. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, n. 2, p.169-177, 2005.

GUASTAFERRO, F.; CASTRIGNANÒ, A.; BENEDETTO, D.; SOLLITTO, D.; TROCCOLI, A.; CAFARELLI, B. A comparison of different algorithms for the delineation of management zones. **Precision Agriculture**, v. 11, n. 6, p. 600-620, 2010.

GUO, W., MAAS, S. J., & BRONSON, K. F. Relationship between cotton yield and soil electrical conductivity, topography, and Landsat imagery. **Precision Agriculture**, 13, 678-692, 2012.

GUTIERREZ, M., NORTON, R., THORP, K. R., WANG, G. Association of spectral reflectance indices with plant growth and lint yield in upland cotton. **Crop Science**, v. 52, p. 849–857, 2012.

HATFIELD, J.L., GITELSON, A.A., SCHEPERS, J.S., WALTHALL, C.L. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, v.100, p.117–131, 2008.

HOPKINS, W. G. **Correlation coefficient: a new view of statistics**. 2000. Disponível em: <<http://www.sportsci.org/resource/stats/correl.html>>. Acesso em: 12 jul. 2019

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, New York, v. 25, n. 3, p. 295-309, 1988.

HUETE, A. R.; HUIQING LIU; VAN LEEUWEN, W. J. D. The use of vegetation indices in forested regions: issues of linearity and saturation. *International Geoscience and Remote Sensing Symposium Proceedings*. Remote Sensing - A Scientific Vision for Sustainable Development, v. 4, n. 1, p. 1966–1968, 1997. Disponível em: <<http://ieeexplore.ieee.org/document/609169/>>.

HUETE, A. R.; JACKSON, R. D. Suitability of spectral indices for evaluating vegetation characteristics on arid rangelands. *Remote Sensing of Environment*, v. 23, n. 2, p. 213–232, 1987.

ICAC. **International Cotton Advisory Committee**. Disponível em: <<http://www.icac.org/>>. Acesso em 16 janeiro de 2018.

IQBAL, J., READ, J. J., WHISLER, F. D. Using remote sensing and soil physical properties for predicting the spatial distribution of cotton lint yield. *Turkish Journal of Field Crops*, v. 18, p. 158–165, 2013.

Instituto Brasileiro de Geografia e Estatísticas - IBGE. **Anuário Estatístico do Brasil 2017**. Disponível em: <<https://www.ibge.gov.br/estatisticas-novoportal/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html?edicao=16787&produto=true>>

JACKSON, R.D., HUETE, A. R. Interpreting vegetation indices. *Journal of Preventive Veterinary Medicine*, v.11, p.185-200, 1991.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. Tradução: José Carlos Epiphânio *et al.* – São José dos Campos, SP: Parêntese, 2011.

JI, L.; ZHANG, L.; WYLIE, B. Analysis of Dynamic Thresholds for the Normalized Difference Water Index. *Photogrammetric Engineering & Remote Sensing* Vol. 75, Nº. 11, November 2009, pp.1307-1317.

JONCKHEERE, I., FLECK, S., NACKAERTS, K., MUY, B., COPPIN, P., WEISS, M. BARET, F., Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. *Agricultural and Forest Meteorology*, v. 121, p.19–35, 2004.

JONES, J. R., FLEMING, C. S., PAVULURI, K., ALLEY, M. M., REITER, M. S., THOMASON, W. E. Influence of soil, crop residue, and sensor orientations on NDVI readings. *Precision Agriculture*, 16(6), 690-704. 2015.

JORDAN, C. F. Derivation of leaf area index from quality of light on the forest floor. *Ecology*, Washington, DC, v. 50, n. 4, p. 663-666, 1969.

KANKE, Y., RAUN, W., SOLIE, J., STONE, M., TAYLOR, R. Red edge as a potential index for detecting differences in plant nitrogen status in winter wheat. **Journal Plant Nutrition**, v. 35, p.1526–1541, 2012.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. **IEEE Transactions Geoscience and Remote Sensing**, Piscataway, v. 30, n. 2, p. 261-270, 1992.

KAZMIERCZAK, M. L. Uso de dados AVHRR/NOAA GAC para análise da sazonalidade da caatinga. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 8, p. 513-518, 1996.

KNOX, N. M; SKIDMORE, A. K; WERFF, H. M. A van der; GROEN, T. A; BOER, W. F. de; PRINS, H. H. T; KOHI, E; PEEL, M. Differentiation off plant age in grasses using remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, p.54-62, 2013.

LAMAS, F. M. Semeadura, espaçamento e densidade. In: MORESCO, E. (Org.). **Algodão: pesquisas e resultados para o campo**. Cuiabá: Fundo de Apoio à Cultura do Algodão, p. 82–93, 2006.

LAMAS, F. M.; FERREIRA, A. C. B. Reguladores de crescimento, desfolhantes e maturadores. In E. C. Freire 2 Ed. **Algodão no Cerrado do Brasil** (2nd E. pp. 777-790). Brasília: ABRAPA. 2011

LEE, W. S.; ALCHANATIS, V.; YANG, C.; HIRAFUJI, M.; MOSHOU, D.; LI, C. Sensing technologies for precision specialty crop production. **Computers and Electronics in Agriculture**, v. 74, n. 1, p. 2-33, 2010.

LI, F.; MIAO, Y.; FENG, G.; YUAN, F.; YUE, S.; GAO, X.; LIU, Y.; LIU, B.; USTIN, S. L.; CHEN, X. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation índices. **Field Crops Research**, n.157, p.111–123. 2014

LI, F., MISTELE, B., HU, Y., YUE, X., YUE, S., MIAO, Y., CHEN, X., CUI, Z., MENG, Q., SCHMIDHALTER, U. Remotely estimating aerial N status of phenologically differing winter wheat cultivars grown in contrasting climatic and geographic zones in China and Germany. **Field Crops Research**. v.138, p.21–32, 2012.

MACHADO, H. M. **Determinação da biomassa da cana-de-açúcar considerando a variação espacial de dados espectrais do satélite Landsat 7 – ETM+**. 71p. Dissertação (Mestrado em Engenharia Agrícola) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2003.

MANSOUR, K; MUTANGA, O; EVERSON, T. Remote sensing base indicators of vegetation species for assessing rangeland degradation: Opportunities and challenges. In: **African Journal of Agricultural Research**, v.7(22), p. 3621-3270, 2012.

MANTOVANI, E.C.; QUEIROZ, D.M.; DIAS, G.P. **Máquinas e operações utilizadas na agricultura de precisão.** In: SILVA, M. da.(Coord.). Mecanização e agricultura de precisão. Poços de Caldas : UFLA/SBEA, p.109-15, 1998.

MARUR, J.M.; RUANO, O. A reference system for determination of developmental stages of upland cotton. **Revista Brasileira de Oleaginosas e Fibrosas**, v.5, p. 313-317, 2001.

MAO, W.; WANG, Y.; WANG, Y. Real-time detection of between-row weeds using machine vision. **2003 ASAE Annual Meeting**, v. 300, n. 3, p. 1–9, 2003.

MAYER, B.; KYLLING, A. Technical note: The libRadtran software package for radiative transfer calculations – description and examples of use. **Atmospheric Chemistry and Physics Discussions**, [s. l.], v. 5, n. 2, p. 1319–1381, 2005. Disponível em: <<http://www.atmos-chem-phys-discuss.net/5/1319/2005/>>

MENEGATTI, L.; MOLIN, J. P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.8, n.1, p.126-134, 2004.

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

MEYER, G. E.; NETO, J. C. Verification of color vegetation indices for automated crop imaging applications. **Computers and Electronics in Agriculture**, v. 63, n. 2, p. 282–293, 2008.

MILANI, L.; *et al.* Unidades de manejo a partir de dados de produtividade. **Acta Scientiarum. Agronomy**, v.28, n.1, p.591-598, 2006. Disponível em: <http://dx.doi.org/10.4025/actasciagron.v28i4.937>

MINAMI, P.; RIBEIRO, E. S.; MARTINS, V. G.; MOREIRA, E. L. Florística e fitossociologia em mata de galeria e cerradão no município de Nova Mutum – MT, Brasil. **Revista Biodiversidade**, v.16, n1, 2017.

MOLIN, J. P. Geração e Interpretação de Mapas de Produtividade para Agricultura de Precisão. In: Borém, A.; Giúdice, M. P.; Queiroz, D. M.; Mantovani, E. C.; Ferreira, L. R.; Valle, F. X. R.; Goide, R. L. **Agricultura de Precisão**. Viçosa: Universidade Federal de Viçosa, 2000. P 237-258.

MOORE, M. **An investigation into the accuracy of yield maps and their subsequent use in crop management**, Cranfield: Cranfield University, 1998, 379p. PhD Thesis

MOREIRA, R.C. **Influência do posicionamento e da largura de bandas de sensores remotos e dos efeitos atmosféricos na determinação de índices de vegetação.** 114 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto de Pesquisas Espaciais, São José dos Campos, 2000.

NGUY-ROBERTSON, A.; GITELSON, A.; PENG, Y.; VINA, A.; ARKEBAUER, T.; RUNDQUIST, D. Green leaf area index estimation in maize and soybean: combining vegetation indices to achieve maximal sensitivity. **Agronomy Journal**, v.104, p.1336–1347, 2012.

NOVO, E. M. L. de M. **Sensoriamento Remoto: princípios e aplicações**. 4ed., São Paulo: Edgard, p.351-357. 2010.

NUNES, C. C. F. **Variâncias do ponto crítico de equações de regressão quadrática**. 2002. Dissertação (Mestrado em Agronomia) - Universidade Federal de Lavras, Lavras. 2002.

OLIVEIRA, M. F. **Modelos de predição de produtividade da cultura do milho por meio de NDVI em arranjos espaciais**. 2017. Dissertação (Mestrado em Agronomia) - Universidade Estadual Paulista, São Paulo, 2017.

OLIVEIRA, R. A.; DOS SANTOS, R. S.; RIBEIRO, A.; ZOLNIER, S.; BARBOSA, M. H. P. Estimativa da produtividade da cana-de-açúcar para as principais regiões produtoras de Minas Gerais usando-se o método ZAE. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16, n.5, p.549–557, 2012.

PASSOS, S.M.G. **Algodão**. Campinas: Instituto Campineiro de Ensino Agrícola, 424p. 1977.

PEARSON, R. L.; MILLER, L. D. Remote mapping of standing crop biomass for estimation of the productivity of the short grass prairie. Pawnee National Grasslands, Colorado. In: International Symposium on Remote Sensing of Environment, 8., 1972, Ann Arbor. **Proceedings...** Ann Arbor: ERIM, 1972. v. 2, p. 1355-1379.

PELLEGRINO, G. Q. **Utilização de Dados Espectrais do Satélite NOAA14/AVHRR como Fonte de Dados para Modelos Matemáticos de Estimativa da Fitomassa da Cana-de-Açúcar**. 113p. Tese (Doutorado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, 2000.

PETERNELLI, L. A; MELLO, M. P. **Conhecendo o R: Uma visão Estatística**. Viçosa: Editora UFV. 2007.

PICOLI, M.C.A.; RUDORFF, B.F.T.; RIZZI, GIAROLLA, A. Índice de vegetação do sensor MODIS na estimativa da produtividade agrícola da cana-de-açúcar. **Bragantia**. v.68, p. 789-795, 2009.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. 2010. ed. São José dos Campos: Parêntese, 128 p, 2010.

PORTELA, A. L. S.; PARPINELLI, N. L. Caracterização de uma cidade pequena inserida no contexto do agronegócio mato-grossense. **Anais... IXI Encontro Nacional de Geografia Agrária**, p. 1-18, São Paulo, 2009.

RIBEIRO, E. **Operações aritméticas com o Spring para o estudo da vegetação**. Presidente Prudente. Editora Azimute, Volume 1. 2012. Disponível em: www.geosaude.com

RICHETTI, A.; MELO FILHO, G.A. Aspectos socioeconômicos do algodoeiro herbáceo. In: EMBRAPA. Centro de Pesquisa Agropecuária do Oeste (Dourados – MS). Algodão: informações técnicas. Dourados: EMBRAPA – CPAO; Campina Grande: EMBRAPA – CNPA, 267p (**Circular Técnica, 7**), p.11-25. 1998.

RIZZI, R.; RUDORFF, B.F.T. Imagens do sensor MODIS associadas a um modelo para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, v. 42, p.73-80, 2007.

ROCHA, D. da S. R. **Estimativa de produtividade de cana-de-açúcar no estado de São Paulo através de um modelo agrometeorológico espectral**. 2012. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas – UFAL, Maceió.

ROSA, R. **Introdução ao Sensoriamento Remoto**, Uberlândia: EDUFU, 2003.

ROUSE, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. Monitoring vegetation systems in the great plains with ERTS. In: Third ERTS Symposium, **Proceedings**, NASA SP-351, NASA, Washington, DC, v. 1, p. 309-317, 1973.

ROUJEAN, J. L.; BREON, F. M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote Sensing of Environment**, v. 51, n. 3, p. 375–384, 1995.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, 1996.

RUDORFF, B.F.T. **Dados Landsat na estimativa da produtividade agrícola da cana-de-açúcar**. 1985. 114p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos.

RUDORFF, B.F.T.; BATISTA, G.T. Yield estimation of sugarcane based on agrometeorological - Spectral models. **Remote Sensing of Environment**, v.33, p.183-192, 1990.

RUDORFF, B.F.T.; BATISTA, G.T. Wheat yield estimation at the farm level using Landsat- TM and agrometeorological data. **International Journal of Remote Sensing**, v. 2, p.2477-2484, 1991.

RUDORFF, B. F. T., SHIMABUKURO, Y.E., BATISTA, G.T., LEE, D. The contribution of qualitative variables to a sugarcane yield model based on spectral vegetation index. In: SIMPOSIO LATINOAMERICANO DE PERCEPCIÓN

REMOTA, P. V. **Anais...** Puerto Vallarta: Sociedad de Especialistas Latinoamericanos en Percepción Remota, 1995. p.705-708, 1995.

SEELAN, S. K.; LAGUETTE, S.; CASADY, G. M.; SEIELSTAD, G. A. Remote sensing applications for precision agriculture: A learning community approach. **Remote Sensing of Environment**, v. 88, n. 1–2, p. 157-169, 2003.

SILVA, I.P.F.; JUNIOR, J.F.S.; ARALDI, R.; TANAKA, A.A.; GIROTTO, M.; BOSQUÊ, G.G.; LIMA, F.C.C. Estudo das fases fenológicas do algodão (*Gossypium hirsutum* L.). **Revista científica eletrônica de agronomia**. n.20. 2011.

SILVA, M. A. V.; MOSCON, E. S.; SANTANA, C. C. Determination of biomass production of cotton using satellite images and spectral indexes. **Journal of Hyperspectral Remote Sensing**, v. 7, p. 73-81, 2017.

SINGH, D. Generation and evaluation of gross primary productivity using Landsat data through blending with MODIS data. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 1, p. 59-69, 2011.

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER, A. D. Aerial color infrared photography for determining early in-season nitrogen requirements in corn. **Agronomy Journal**. v.98, p.968-977, 2006.

STEVENSON, William J. **Estatística aplicada à administração**. São Paulo: Ed. Harbra, 1986.

STORY, D.; KACIRA, M. Design and implementation of a computer vision-guided greenhouse crop diagnostics system. **Machine Vision and Applications**, v. 26, n. 4, p. 495–506, 2015. Disponível em: <<http://dx.doi.org/10.1007/s00138-015-0670-5>>.

THENKABAILL, P. S., SMITH, R. B., De PAUW, E. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. **Remote sensing of Environment**, 71(2), 158-182. 2000.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

Tukey, J.W. **Exploratory data analysis**. 1 ed. Reading, Massachusetts, v.1, 1977.

VAN NIEL, T.G., MCVICAR, T.R. Current and potential uses of optical remote sensing in rice-based irrigation systems: a review. **Australian Journal Agricultural Reserach**, v.55 (2), p.155–185, 2004.

VENTERIS, E. R.; TAGESTAD, J. D.; DOWNS, J. L.; MURRAY, C. J. Detection of anomalous crop condition and soil variability mapping using a 26 year Landsat record

and the Palmer crop moisture index. **International Journal of Applied Earth Observation and Geoinformation**, v.39, p.160-170, 2015.

WANG, Q.; ADIKU, S.; TENHUNEN, J. On the relationship of NDVI with leaf area index in a deciduous forest site. **Remote Sensing of Environment**, New York, v. 94, n. 2, p. 244-255, 2004.

WOEBBECKE, D. M. et al. Plant species identification, size, and enumeration using machine vision techniques on near-binary images. **SPIE Optics in Agriculture and Forestry**, v. 1836, p. 208–219, 1992.

ZHAO, H. D.; LI, L. J.; QI, G. J. Identification of red and IVP spectral regions and vegetative indices for discrimination of cotton nitrogen stress and growth stage. **Computers and Electronics in Agriculture**, v. 48, p. 155–169, 2005.

APÊNDICE A

Tabela 1A: Estatística descritiva dos dados espectrais (índices de vegetação) nas quatro datas analisadas para o talhão C-01.

Dado espectral	Data da imagem	Idade da cultura (dias)	Média	Mediana	Desvio Padrão	Coefficiente de Variação	Amplitude	Mínimo	Máximo
NDVI	17/04/18	90	0,85	0,85	0,02	0,019	0,08	0,80	0,88
	07/05/18	110	0,88	0,88	0,00	0,005	0,03	0,87	0,89
	27/05/18	130	0,87	0,87	0,00	0,005	0,02	0,85	0,88
	16/06/18	150	0,85	0,85	0,01	0,010	0,04	0,83	0,86
ARVI	17/04/18	90	0,85	0,85	0,02	0,028	0,11	0,78	0,89
	07/05/18	110	0,87	0,87	0,01	0,008	0,03	0,86	0,89
	27/05/18	130	0,59	0,56	0,10	0,174	0,36	0,52	0,88
	16/06/18	150	0,85	0,85	0,01	0,010	0,04	0,83	0,86
EVI	17/04/18	90	0,68	0,68	0,04	0,053	0,16	0,59	0,75
	07/05/18	110	0,75	0,75	0,01	0,019	0,07	0,71	0,78
	27/05/18	130	0,78	0,78	0,02	0,019	0,06	0,75	0,81
	16/06/18	150	0,63	0,62	0,02	0,028	0,07	0,59	0,66
GSAVI	17/04/18	90	0,56	0,56	0,02	0,039	0,10	0,51	0,60
	07/05/18	110	0,63	0,63	0,01	0,014	0,65	0,60	0,65
	27/05/18	130	0,62	0,62	0,01	0,013	0,03	0,61	0,64
	16/06/18	150	0,56	0,56	0,01	0,018	0,04	0,54	0,58

GVI	17/04/18	90	0,12	0,12	0,01	0,073	0,03	0,10	0,14
	07/05/18	110	0,09	0,09	0,00	0,022	0,09	0,09	0,09
	27/05/18	130	0,10	0,11	0,00	0,020	0,01	0,10	0,11
	16/06/18	150	0,10	0,10	0,00	0,024	0,01	0,09	0,10
NDWI	17/04/18	90	-0,79	-0,79	0,01	-0,015	0,05	-0,81	-0,76
	07/05/18	110	-0,83	-0,83	0,00	-0,004	-0,83	-0,84	-0,83
	27/05/18	130	-0,81	-0,81	0,00	-0,004	0,02	-0,82	-0,80
	16/06/18	150	-0,83	-0,83	0,00	-0,005	0,02	-0,83	-0,82
SR	17/04/18	90	13,80	13,72	1,56	0,114	6,75	10,07	16,82
	07/05/18	110	16,95	16,99	0,69	0,041	18,54	14,83	18,54
	27/05/18	130	15,07	15,11	0,55	0,037	2,55	13,71	16,26
	16/06/18	150	12,69	12,61	0,72	0,057	2,98	11,18	14,15
RDVI	17/04/18	90	0,56	0,56	0,02	0,040	0,10	0,50	0,61
	07/05/18	110	0,62	0,62	0,01	0,015	0,64	0,59	0,64
	27/05/18	130	0,59	0,59	0,01	0,015	0,04	0,57	0,61
	16/06/18	150	0,54	0,54	0,01	0,021	0,04	0,52	0,56
SAVI	17/04/18	90	1,06	1,06	0,02	0,019	0,10	1,00	1,10
	07/05/18	110	0,96	0,96	0,01	0,006	0,97	0,94	0,97
	27/05/18	130	1,09	1,09	0,01	0,005	0,03	1,08	1,11
	16/06/18	150	0,88	0,88	0,02	0,020	0,06	0,86	0,91

OSAVI	17/04/18	90	0,93	0,93	0,03	0,031	0,13	0,85	0,99
	07/05/18	110	1,00	1,00	0,01	0,010	1,02	0,96	1,02
	27/05/18	130	0,96	0,97	0,01	0,010	0,05	0,94	0,99
	16/06/18	150	0,91	0,91	0,01	0,016	0,06	0,88	0,94
ENDVI	17/04/18	90	0,75	0,76	0,01	0,017	0,06	0,72	0,78
	07/05/18	110	0,81	0,81	0,00	0,005	0,82	0,80	0,82
	27/05/18	130	0,77	0,77	0,00	0,006	0,02	0,76	0,78
	16/06/18	150	0,78	0,78	0,01	0,008	0,02	0,77	0,79
GNDVI	17/04/18	90	0,79	0,79	0,01	0,015	0,05	0,76	0,81
	07/05/18	110	0,83	0,83	0,00	0,004	0,84	0,82	0,84
	27/05/18	130	0,82	0,82	0,00	0,004	0,02	0,81	0,83
	16/06/18	150	0,83	0,83	0,00	0,005	0,02	0,82	0,84
IPVI	17/04/18	90	0,93	0,93	0,01	0,009	0,04	0,90	0,94
	07/05/18	110	0,94	0,94	0,00	0,003	0,95	0,93	0,95
	27/05/18	130	0,93	0,93	0,00	0,003	0,01	0,93	0,94
	16/06/18	150	0,92	0,92	0,00	0,004	0,02	0,91	0,93
NLI	17/04/18	90	0,66	0,67	0,05	0,072	0,23	0,52	0,75
	07/05/18	110	0,76	0,76	0,01	0,018	0,79	0,71	0,79
	27/05/18	130	0,71	0,72	0,01	0,020	0,07	0,67	0,75
	16/06/18	150	0,64	0,64	0,03	0,040	0,10	0,58	0,68

NDRE	17/04/18	90	0,38	0,38	0,02	0,056	0,10	0,32	0,42
	07/05/18	110	0,38	0,38	0,01	0,027	0,40	0,35	0,40
	27/05/18	130	0,34	0,34	0,01	0,023	0,04	0,32	0,36
	16/06/18	150	0,37	0,37	0,01	0,026	0,05	0,34	0,39
CRI2	17/04/18	90	18,13	18,10	0,38	0,021	2,40	17,15	19,55
	07/05/18	110	22,00	22,02	0,27	0,012	22,59	21,24	22,59
	27/05/18	130	16,93	16,93	0,19	0,011	0,87	16,52	17,39
	16/06/18	150	25,03	25,02	0,43	0,017	2,45	23,83	26,29
PSRI	17/04/18	90	0,00	0,00	0,00	1,969	0,02	0,00	0,02
	07/05/18	110	0,03	0,03	0,01	0,251	0,07	0,02	0,07
	27/05/18	130	0,01	0,00	0,01	1,373	0,04	-0,01	0,03
	16/06/18	150	0,08	0,08	0,01	0,123	0,05	0,06	0,11
CRI1	17/04/18	90	10,85	10,83	0,31	0,029	1,94	9,94	11,88
	07/05/18	110	13,62	13,65	0,27	0,019	14,13	12,92	14,13
	27/05/18	130	9,57	9,55	0,23	0,025	1,09	8,97	10,06
	16/06/18	150	12,19	12,18	0,40	0,033	1,76	11,25	13,02
ExR	17/04/18	90	0,03	0,03	0,00	0,050	0,01	0,03	0,03
	07/05/18	110	0,03	0,03	0,00	0,036	0,03	0,03	0,03
	27/05/18	130	0,02	0,02	0,00	0,043	0,00	0,02	0,03
	16/06/18	150	0,02	0,02	0,00	0,088	0,01	0,01	0,02

ExGR	17/04/18	90	0,03	0,03	0,00	0,121	0,02	0,02	0,04
	07/05/18	110	0,03	0,03	0,00	0,066	0,03	0,02	0,03
	27/05/18	130	0,02	0,02	0,00	0,079	0,01	0,02	0,03
	16/06/18	150	0,01	0,01	0,00	0,320	0,01	0,00	0,01
MGRVI	17/04/18	90	0,37	0,37	0,05	0,128	0,23	0,22	0,45
	07/05/18	110	0,35	0,36	0,02	0,057	0,39	0,28	0,39
	27/05/18	130	0,32	0,32	0,02	0,057	0,08	0,27	0,35
	16/06/18	150	0,16	0,16	0,03	0,213	0,15	0,08	0,22
NDI	17/04/18	90	0,19	0,19	0,03	0,136	0,13	0,11	0,24
	07/05/18	110	0,39	0,39	0,01	0,033	0,41	0,35	0,41
	27/05/18	130	0,16	0,17	0,01	0,060	0,04	0,14	0,18
	16/06/18	150	0,08	0,08	0,02	0,215	0,07	0,04	0,11
RGBVI	17/04/18	90	0,38	0,38	0,02	0,065	0,12	0,31	0,43
	07/05/18	110	0,18	0,18	0,01	0,060	0,20	0,15	0,20
	27/05/18	130	0,32	0,33	0,01	0,039	0,05	0,29	0,35
	16/06/18	150	0,25	0,25	0,02	0,083	0,09	0,20	0,29

Tabela 2A: Estatística descritiva dos dados espectrais (índices de vegetação) nas quatro datas analisadas para o talhão D-07.

Dado espectral	Data da imagem	Idade da cultura (dias)	Média	Mediana	Desvio Padrão	Coefficiente de Variação	Amplitude	Mínimo	Máximo
NDVI	17/04/18	74	0,90	0,90	0,00	0,005	0,03	0,88	0,90
	07/05/18	94	0,92	0,90	0,01	0,006	0,03	0,87	0,90
	27/05/18	114	0,88	0,88	0,01	0,008	0,05	0,84	0,89
	16/06/18	134	0,87	0,88	0,02	0,023	0,11	0,78	0,88
ARVI	17/04/18	74	0,91	0,91	0,01	0,006	0,03	0,88	0,91
	07/05/18	94	0,89	0,90	0,01	0,010	0,05	0,86	0,91
	27/05/18	114	0,58	0,60	0,05	0,080	0,26	0,40	0,67
	16/06/18	134	0,87	0,88	0,02	0,023	0,11	0,78	0,88
EVI	17/04/18	74	0,83	0,83	0,02	0,018	0,08	0,77	0,85
	07/05/18	94	0,81	0,81	0,02	0,023	0,10	0,73	0,83
	27/05/18	114	0,69	0,70	0,05	0,064	0,24	0,51	0,74
	16/06/18	134	0,69	0,70	0,04	0,064	0,23	0,51	0,74
GSAVI	17/04/18	74	0,66	0,66	0,01	0,015	0,05	0,62	0,67
	07/05/18	94	0,66	0,66	0,01	0,016	0,68	0,62	0,68
	27/05/18	114	0,60	0,61	0,03	0,042	0,13	0,49	0,62
	16/06/18	134	0,60	0,61	0,03	0,042	0,13	0,49	0,62
GVI	17/04/18	74	0,09	0,09	0,00	0,031	0,01	0,08	0,10
	07/05/18	94	0,08	0,08	0,00	0,033	0,09	0,08	0,09
	27/05/18	114	0,09	0,08	0,01	0,066	0,03	0,08	0,11
	16/06/18	134	0,09	0,08	0,01	0,066	0,03	0,08	0,11
NDWI	17/04/18	74	-0,84	-0,84	0,00	-0,005	0,02	-0,84	-0,82
	07/05/18	94	-0,85	-0,85	0,00	-0,005	-0,83	-0,85	-0,83
	27/05/18	114	-0,84	-0,85	0,01	-0,011	0,05	-0,85	-0,80
	16/06/18	134	-0,84	-0,85	0,01	-0,011	0,05	-0,85	-0,80
SR	17/04/18	74	20,05	20,18	0,70	0,035	4,27	16,97	21,25
	07/05/18	94	19,60	19,89	0,96	0,048	20,91	15,74	20,91

	27/05/18	114	16,38	16,66	0,88	0,053	5,04	12,66	17,70
	16/06/18	134	15,23	15,93	1,78	0,112	8,74	8,22	16,95
RDVI	17/04/18	74	0,65	0,66	0,01	0,015	0,06	0,61	0,67
	07/05/18	94	0,65	0,65	0,01	0,018	0,67	0,60	0,67
	27/05/18	114	0,62	0,62	0,02	0,025	0,09	0,55	0,64
	16/06/18	134	0,58	0,59	0,03	0,049	0,15	0,46	0,61
	17/04/18	74	1,13	1,13	0,00	0,004	0,03	1,11	1,14
SAVI	07/05/18	94	1,14	1,14	0,01	0,005	1,14	1,11	1,14
	27/05/18	114	1,11	1,11	0,01	0,008	0,05	1,06	1,12
	16/06/18	134	1,09	1,10	0,02	0,023	0,14	0,97	1,11
	17/04/18	74	1,03	1,04	0,01	0,010	0,06	0,99	1,05
OSAVI	07/05/18	94	1,03	1,04	0,01	0,012	1,05	0,98	1,05
	27/05/18	114	0,99	1,00	0,02	0,017	0,10	0,92	1,02
	16/06/18	134	0,96	0,97	0,04	0,037	0,19	0,80	0,99
	17/04/18	74	0,80	0,80	0,00	0,006	0,03	0,78	0,81
ENDVI	07/05/18	94	0,82	0,82	0,00	0,005	0,83	0,81	0,83
	27/05/18	114	0,79	0,79	0,01	0,007	0,04	0,76	0,80
	16/06/18	134	0,81	0,81	0,01	0,016	0,07	0,75	0,82
	17/04/18	74	0,84	0,84	0,00	0,005	0,03	0,82	0,85
GNDVI	07/05/18	94	0,85	0,85	0,00	0,005	0,85	0,83	0,85
	27/05/18	114	0,83	0,83	0,01	0,006	0,03	0,81	0,84
	16/06/18	134	0,84	0,85	0,01	0,011	0,06	0,80	0,85
	17/04/18	74	0,95	0,95	0,00	0,002	0,01	0,94	0,95
IPVI	07/05/18	94	0,95	0,95	0,00	0,003	0,95	0,94	0,95
	27/05/18	114	0,94	0,94	0,00	0,004	0,02	0,92	0,94
	16/06/18	134	0,93	0,94	0,01	0,011	0,05	0,89	0,94
	17/04/18	74	0,80	0,81	0,01	0,015	0,07	0,75	0,82
NLI	07/05/18	94	0,80	0,81	0,02	0,019	0,82	0,74	0,82
	27/05/18	114	0,75	0,76	0,02	0,032	0,15	0,64	0,78
	16/06/18	134	0,71	0,73	0,06	0,084	0,34	0,42	0,76

NDRE	17/04/18	74	0,43	0,43	0,01	0,018	0,04	0,41	0,44
	07/05/18	94	0,42	0,42	0,01	0,018	0,43	0,40	0,43
	27/05/18	114	0,37	0,37	0,01	0,029	0,05	0,35	0,40
	16/06/18	134	0,41	0,41	0,01	0,033	0,08	0,34	0,42
CRI2	17/04/18	74	18,17	18,18	0,20	0,011	1,33	17,55	18,88
	07/05/18	94	22,94	22,87	0,42	0,018	25,20	22,17	25,20
	27/05/18	114	18,18	17,85	0,77	0,043	3,92	17,31	21,23
	16/06/18	134	26,96	26,71	1,08	0,040	5,90	23,49	29,39
PSRI	17/04/18	74	-0,01	-0,01	0,00	-0,162	0,01	-0,01	0,00
	07/05/18	94	0,01	0,01	0,01	0,941	0,06	0,00	0,06
	27/05/18	114	0,01	0,00	0,01	7,986	0,07	-0,01	0,06
	16/06/18	134	0,07	0,06	0,03	0,429	0,15	0,03	0,18
CRI1	17/04/18	74	10,49	10,50	0,21	0,020	1,05	9,95	11,00
	07/05/18	94	14,00	13,99	0,15	0,011	14,41	13,42	14,41
	27/05/18	114	9,82	9,82	0,15	0,016	1,19	9,47	10,66
	16/06/18	134	13,52	13,60	0,52	0,038	3,56	10,73	14,30
ExR	17/04/18	74	0,03	0,03	0,00	0,034	0,00	0,03	0,03
	07/05/18	94	0,03	0,03	0,00	0,034	0,03	0,03	0,03
	27/05/18	114	0,02	0,02	0,00	0,046	0,01	0,02	0,03
	16/06/18	134	0,02	0,02	0,00	0,168	0,02	0,01	0,02
ExGR	17/04/18	74	0,04	0,04	0,00	0,046	0,01	0,03	0,04
	07/05/18	94	0,03	0,03	0,00	0,056	0,04	0,03	0,04
	27/05/18	114	0,02	0,03	0,00	0,093	0,01	0,01	0,03
	16/06/18	134	0,01	0,02	0,01	0,433	0,03	-0,01	0,02
MGRVI	17/04/18	74	0,45	0,45	0,01	0,032	0,07	0,41	0,48
	07/05/18	94	0,40	0,41	0,02	0,052	0,43	0,30	0,43
	27/05/18	114	0,32	0,33	0,03	0,077	0,16	0,20	0,36
	16/06/18	134	0,21	0,24	0,08	0,332	0,39	-0,10	0,29
NDI	17/04/18	74	0,24	0,24	0,01	0,035	0,04	0,22	0,25
	07/05/18	94	0,21	0,21	0,01	0,055	0,23	0,16	0,23

	27/05/18	114	0,17	0,17	0,01	0,079	0,09	0,10	0,19
	16/06/18	134	0,11	0,12	0,04	0,334	0,20	-0,05	0,15
RGBVI	17/04/18	74	0,41	0,41	0,01	0,024	0,04	0,39	0,43
	07/05/18	94	0,41	0,42	0,01	0,026	0,43	0,37	0,43
	27/05/18	114	0,33	0,33	0,01	0,040	0,09	0,26	0,36
	16/06/18	134	0,29	0,31	0,04	0,147	0,23	0,12	0,34

Tabela 3A: Estatística descritiva dos dados espectrais (índices de vegetação) nas quatro datas analisadas para o talhão E-01.

Dado espectral	Data da imagem	Idade da cultura (dias)	Média	Mediana	Desvio Padrão	Coefficiente de Variação	Amplitude	Mínimo	Máximo
NDVI	17/04/18	73	0,81	0,81	0,03	0,031	0,09	0,76	0,85
	07/05/18	93	0,89	0,88	0,01	0,006	0,02	0,86	0,89
	27/05/18	113	0,85	0,87	0,00	0,006	0,02	0,86	0,88
	16/06/18	133	0,80	0,86	0,01	0,011	0,03	0,85	0,88
ARVI	17/04/18	73	0,78	0,78	0,04	0,046	0,14	0,72	0,86
	07/05/18	93	0,87	0,87	0,01	0,009	0,03	0,85	0,89
	27/05/18	113	0,54	0,54	0,02	0,033	0,07	0,51	0,58
	16/06/18	133	0,81	0,86	0,01	0,011	0,03	0,85	0,88
EVI	17/04/18	73	0,65	0,64	0,04	0,070	0,19	0,57	0,76
	07/05/18	93	0,78	0,78	0,02	0,023	0,06	0,75	0,82
	27/05/18	113	0,78	0,78	0,02	0,019	0,06	0,75	0,81
	16/06/18	133	0,73	0,73	0,03	0,041	0,10	0,68	0,78
GSAVI	17/04/18	73	0,54	0,54	0,02	0,046	0,10	0,50	0,60
	07/05/18	93	0,63	0,63	0,01	0,016	0,65	0,61	0,65
	27/05/18	113	0,62	0,62	0,01	0,013	0,03	0,61	0,64
	16/06/18	133	0,61	0,61	0,01	0,024	0,05	0,58	0,64
GVI	17/04/18	73	0,14	0,14	0,01	0,082	0,04	0,12	0,15
	07/05/18	93	0,10	0,10	0,00	0,026	0,11	0,10	0,11
	27/05/18	113	0,10	0,11	0,00	0,020	0,01	0,10	0,11
	16/06/18	133	0,10	0,10	0,00	0,019	0,01	0,10	0,11
NDWI	17/04/18	73	-0,76	-0,76	0,01	-0,020	0,05	-0,79	-0,73
	07/05/18	93	-0,81	-0,81	0,00	-0,005	-0,80	-0,82	-0,80
	27/05/18	113	-0,81	-0,81	0,00	-0,004	0,02	-0,82	-0,80
	16/06/18	133	-0,82	-0,82	0,00	-0,004	0,02	-0,83	-0,81

SR	17/04/18	73	9,87	9,55	1,41	0,147	5,22	7,61	12,83
	07/05/18	93	15,88	15,80	0,73	0,046	17,11	14,35	17,11
	27/05/18	113	15,42	15,35	0,55	0,036	1,94	14,33	16,27
	16/06/18	133	14,67	14,40	1,01	0,070	3,51	12,83	16,34
RDVI	17/04/18	73	0,54	0,53	0,03	0,054	0,11	0,49	0,60
	07/05/18	93	0,63	0,63	0,01	0,018	0,65	0,61	0,65
	27/05/18	113	0,62	0,62	0,01	0,016	0,04	0,60	0,64
	16/06/18	133	0,60	0,60	0,02	0,032	0,07	0,57	0,63
SAVI	17/04/18	73	1,11	1,11	0,01	0,006	0,03	1,09	1,12
	07/05/18	93	0,91	0,91	0,01	0,009	0,93	0,90	0,93
	27/05/18	113	1,10	1,10	0,01	0,005	0,02	1,09	1,11
	16/06/18	133	1,10	1,10	0,01	0,009	0,04	1,08	1,12
OSAVI	17/04/18	73	0,89	0,89	0,04	0,043	0,14	0,82	0,97
	07/05/18	93	1,01	1,01	0,01	0,012	1,03	0,98	1,03
	27/05/18	113	0,99	0,99	0,01	0,010	0,04	0,97	1,01
	16/06/18	133	0,98	0,97	0,02	0,022	0,07	0,94	1,01
ENDVI	17/04/18	73	0,73	0,73	0,02	0,025	0,07	0,69	0,76
	07/05/18	93	0,81	0,81	0,00	0,006	0,81	0,80	0,81
	27/05/18	113	0,78	0,78	0,00	0,006	0,02	0,77	0,78
	16/06/18	133	0,80	0,80	0,01	0,008	0,02	0,79	0,81
GNDVI	17/04/18	73	0,76	0,76	0,02	0,020	0,06	0,73	0,79
	07/05/18	93	0,81	0,81	0,00	0,006	0,82	0,80	0,82
	27/05/18	113	0,81	0,81	0,00	0,005	0,01	0,80	0,82
	16/06/18	133	0,82	0,82	0,00	0,004	0,01	0,81	0,82
IPVI	17/04/18	73	0,90	0,90	0,01	0,014	0,05	0,88	0,93
	07/05/18	93	0,94	0,94	0,00	0,003	0,94	0,93	0,94
	27/05/18	113	0,93	0,93	0,00	0,003	0,01	0,93	0,94

	16/06/18	133	0,93	0,93	0,00	0,005	0,02	0,92	0,94
NLI	17/04/18	73	0,58	0,58	0,07	0,116	0,25	0,45	0,70
	07/05/18	93	0,77	0,77	0,02	0,020	0,79	0,73	0,79
	27/05/18	113	0,74	0,74	0,01	0,019	0,05	0,71	0,77
	16/06/18	133	0,72	0,72	0,03	0,041	0,10	0,66	0,77
	17/04/18	73	0,44	0,45	0,01	0,026	0,05	0,42	0,47
NDRE	07/05/18	93	0,44	0,45	0,01	0,026	0,47	0,42	0,47
	27/05/18	113	0,40	0,39	0,02	0,042	0,06	0,37	0,43
	16/06/18	133	0,43	0,43	0,01	0,027	0,05	0,40	0,45
	17/04/18	73	16,71	16,85	0,79	0,047	2,90	14,96	17,85
CRI2	07/05/18	93	22,30	22,31	0,30	0,014	23,06	21,67	23,06
	27/05/18	113	17,38	17,17	0,43	0,025	1,53	16,71	18,24
	16/06/18	133	23,55	23,44	0,51	0,022	2,09	22,64	24,72
	17/04/18	73	0,02	0,02	0,01	0,449	0,03	0,00	0,03
PSRI	07/05/18	93	0,03	0,03	0,01	0,314	0,05	0,01	0,05
	27/05/18	113	0,01	0,00	0,01	1,380	0,02	-0,01	0,02
	16/06/18	133	0,06	0,06	0,01	0,244	0,05	0,04	0,08
	17/04/18	73	9,99	10,04	0,62	0,062	2,49	8,64	11,13
CRI1	07/05/18	93	14,90	14,93	0,31	0,020	15,48	14,04	15,48
	27/05/18	113	10,30	10,23	0,31	0,030	1,20	9,77	10,96
	16/06/18	133	13,86	13,70	0,43	0,032	1,76	13,12	14,87
	17/04/18	73	0,03	0,03	0,00	0,115	0,01	0,02	0,04
ExR	07/05/18	93	0,04	0,04	0,00	0,044	0,04	0,04	0,04
	27/05/18	113	0,03	0,03	0,00	0,059	0,01	0,03	0,04
	16/06/18	133	0,03	0,03	0,00	0,130	0,01	0,03	0,04
	17/04/18	73	0,03	0,03	0,01	0,298	0,03	0,01	0,04
ExGR	07/05/18	93	0,05	0,05	0,00	0,064	0,05	0,04	0,05

	27/05/18	113	0,04	0,04	0,00	0,088	0,01	0,03	0,05
	16/06/18	133	0,03	0,03	0,01	0,231	0,02	0,02	0,04
MGRVI	17/04/18	73	0,27	0,25	0,07	0,274	0,26	0,14	0,40
	07/05/18	93	0,45	0,46	0,02	0,051	0,50	0,41	0,50
	27/05/18	113	0,38	0,38	0,02	0,058	0,09	0,34	0,44
	16/06/18	133	0,32	0,31	0,05	0,174	0,18	0,23	0,41
NDI	17/04/18	73	0,14	0,13	0,04	0,285	0,14	0,07	0,21
	07/05/18	93	0,24	0,24	0,01	0,056	0,27	0,21	0,27
	27/05/18	113	0,20	0,20	0,01	0,063	0,05	0,18	0,23
	16/06/18	133	0,17	0,16	0,03	0,185	0,10	0,12	0,21
RGBVI	17/04/18	73	0,34	0,34	0,04	0,124	0,15	0,26	0,42
	07/05/18	93	0,48	0,49	0,02	0,033	0,51	0,44	0,51
	27/05/18	113	0,39	0,39	0,02	0,045	0,07	0,36	0,43
	16/06/18	133	0,39	0,38	0,04	0,094	0,12	0,34	0,45