



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE CIÊNCIAS AGRÁRIAS
CURSO DE AGRONOMIA

AMANDA FERNANDES CANDIDO

**ESTIMATIVA DE SAFRA DO ALGODOEIRO COM PRODUTOS DE
SENSORIAMENTO REMOTO**

AREIA

2022

AMANDA FERNANDES CANDIDO

**ESTIMATIVA DE SAFRA DO ALGODOEIRO COM PRODUTOS DE
SENSORIAMENTO REMOTO**

Trabalho de Conclusão de Curso apresentado ao Programa de Graduação em Agronomia da Universidade Federal da Paraíba, como requisito parcial à obtenção do título de Engenheira Agrônoma.

Orientadora: Prof^a. Dr^a. Valéria Peixoto Borges

AREIA

2022

Catálogo na publicação
Seção de Catalogação e Classificação

C217e Candido, Amanda Fernandes.

Estimativa de safra do algodoeiro com produtos de sensoriamento remoto / Amanda Fernandes Candido. - Areia:UFPB/CCA, 2022.

42 f. : il.

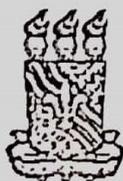
Orientação: Valéria Peixoto Borges.

TCC (Graduação) - UFPB/CCA.

1. Agronomia. 2. Índices de vegetação. 3. Produtividade. 4. Algodão. I. Borges, Valéria Peixoto. II. Título.

UFPB/CCA-AREIA

CDU 631/635(02)



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE CIÊNCIAS AGRÁRIAS
COORDENAÇÃO DE AGRONOMIA
CAMPUS II – AREIA - PB

DEFESA DO TRABALHO DE GRADUAÇÃO

Aprovada em 20/06/2022

**“ESTIMATIVA DE SAFRA DO ALGODOEIRO COM PRODUTOS
DE SENSORIAMENTO REMOTO”**

Autor: Amanda Fernandes Cândido

Banca Examinadora:

Valéria Peixoto Borges

Prof.^a Dr.^a Valéria Peixoto Borges
Orientadora – UFPB

Leossávio César de Souza

Prof. Dr. Leossávio César de Souza
Examinador – UFPB

Robson de Sousa Nascimento

Prof. Dr. Robson de Sousa Nascimento
Examinador – UFPB

AGRADECIMENTOS

Primeiramente agradeço a Deus, por sempre estar do meu lado me abençoando e me concedendo a oportunidade de vivenciar experiências ímpares como essa que agora finalizo.

Aos meus pais Marluce e Gilberto, por todo amor, dedicação para me proporcionar sempre o melhor, e por serem exemplos de vida. E a todos da minha família que torceram e me apoiaram nessa realização.

Ao Centro de Ciências Agrárias pela oportunidade e aos professores que contribuíram como minha formação, por toda troca de conhecimento. Em especial ao professor Robson de Sousa Nascimento pela oportunidade de ingressar no universo da pesquisa, por todas as orientações e exemplo de profissionalismo. Ao professor Leossávio César de Souza por aceitar participar da banca examinadora e pelas contribuições nesse trabalho.

A minha orientadora, Valéria Peixoto Borges, pela qual tenho grande admiração, carinho e respeito. Sou muito grata por todos ensinamentos durante esses três anos e meio de orientação, que me fizeram crescer no profissional e no pessoal. Nossa convivência foi um grande privilégio, deixando-me o desejo de seguir seu exemplo de profissionalismo, independente do rumo profissional que seguirei.

Aos meus colegas de turma, Anne Alícia Meneses, Edmilson Gomes, Kagiaany Meirele, Jackeline Germano, Guilherme Chaves, Laura Toledo, Maria Eduarda Macena, Aysla Mirelli Barreto, Robson Eduardo Monteiro, José Ilário Dantas, Jéssica Nóbrega, Erasmo Venâncio, João Paulo Fernandes, Vaneilson Araújo, Jordy Marinho, Antonio Fernando Filho e Aurélio Santiago, pelo companheirismo. Tenho muito orgulho de dizer que faço parte da turma 2016.2, a mais unida do CCA e sou muito grata pela oportunidade de ter vivenciado essa jornada com pessoas que me fizeram ser mais humana.

As Fazendas Busato, especialmente ao Eng. Agrônomo José Neto, por ceder os dados para realização do trabalho.

A todos que contribuíram de alguma forma com essa minha realização, muito obrigada.

RESUMO

O Brasil tem se mantido entre os cinco maiores produtores mundiais de algodão. Devido aos altos investimentos na cultura, o monitoramento das lavouras em escala espacial e temporal, é fundamental para a previsão das safras e planejamento de toda cadeia produtiva. Os objetivos deste trabalho foram desenvolver uma equação para estimar a produtividade com apenas os índices espectrais de vegetação (IV), validando-a com os valores de produção; e avaliar a estimativa da biomassa pelo Método de Monteith utilizando, além do índice de vegetação, imagens de evapotranspiração. Para tanto, foram utilizados dados de produção do algodoeiro cultivado no Cerrado da Bahia para validar as estimativas. Imagens dos satélites Sentinel-2A e 2B foram processadas na plataforma Google Earth Engine para determinar os valores médios e máximos dos índices de vegetação NDVI, SAVI e EVI, no ciclo de cada parcela cultivada, os quais foram usados na modelagem empírica. Produtos do satélite Landsat 8 (NDVI e Evapotranspiração), foram obtidos no aplicativo GEESebal para implementação no Modelo de Monteith. As estimativas foram comparadas com os dados de campo, por meio do Teste de Tukey, e avaliadas segundo os indicadores: Erro Absoluto Médio (EAM), Razão Média (RM); Raiz Quadrada do quadrado médio do erro (RQME) coeficientes de determinação (R^2), coeficiente de correlação de Pearson (r) e índice de desempenho de Willmott (d). As estimativas com IVs médios e máximos dos ciclos apresentaram desempenho mediano: médias estatisticamente iguais aos valores observados, porém $R^2 < 0,5$ e RQME por volta de 500 kg ha⁻¹. Os modelos gerados com EVI médio e com SAVI máximo apresentaram os melhores índices de desempenho. Apesar de boa correlação com a produtividade medida em campo, a estimativa com o método de Monteith apresentou superestimativa de cerca de 50%, o que pode estar relacionado à baixa cobertura de imagens no ciclo das parcelas estudadas.

Palavras-Chave: índices de vegetação; produtividade; algodão

ABSTRACT

Brazil has remained among the five largest cotton producers in the world. Due to high investments in cotton crops, the field monitoring on spatial and temporal scales is essential for forecasting harvests and planning the entire production chain. This work aimed to: develop an equation to estimate cotton productivity using only spectral vegetation indices (VI), validating it with field production values; and to assess the estimate of biomass by the Monteith Method using, in addition to the vegetation index, evapotranspiration images. For this purpose, production field data from cotton grown in the Cerrado of Bahia State were used to validate the estimates. Images from Sentinel-2A and 2B satellites were processed in the Google Earth Engine platform to determine the average and maximum values of the NDVI, SAVI and EVI vegetation indices, in the cycle of each cultivated plot, which were used in the empirical modeling. Landsat 8 satellite products (NDVI and Evapotranspiration) were obtained from the GEESebal application for implementation in the Monteith Model. Estimates were compared with field data, using Tukey's Test, and evaluated according to the following indicators: Mean Absolute Error (MAE), Mean Ratio (MR); Root Mean Square Error (RQME) coefficients of determination (R^2), Pearson's correlation coefficient (r) and Willmott performance index (d). The estimates with mean and maximum IVs of the crop cycles showed a median performance: means of estimated and observed values were statistically equal, but $R^2 < 0.5$ and RQME around 500 kg ha⁻¹. The models derived with average EVI and with maximum SAVI presented the best performance indices. Despite a good correlation with the productivity measured in the field, the estimate using the Monteith method showed an overestimation of about 50%, which may be related to the low image coverage in the cycle of the plots studied.

Keywords: vegetation indices; productivity; cotton.

SUMÁRIO

1. INTRODUÇÃO	7
2. REVISÃO DE LITERATURA	9
2.1. CULTURA DO ALGODOEIRO	9
2.2. ESTIMATIVA DE SAFRAS	11
2.3. USO DO SENSORIAMENTO REMOTO PARA MONITORAMENTO DA AGRICULTURA	12
2.3.1. Imagens Sentinel-2	13
2.3.2. Imagens Landsat 8	14
2.4. MODELAGEM DA ESTIMATIVA DE SAFRAS COM PRODUTOS DE SENSORIAMENTO REMOTO	15
2.4.1. Método de Monteith	15
2.4.2. Modelagem Empírica com Índices de Vegetação	16
3. METODOLOGIA	19
3.1. LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO	19
3.2. AQUISIÇÃO E PROCESSAMENTO DOS DADOS ORBITAIS	20
3.3. MODELAGEM DA PRODUTIVIDADE DA CULTURA	22
3.4 MÉTODO DE MONTEITH:	22
3.5. MODELAGEM EMPÍRICA COM REGRESSÃO LINEAR	24
3.6. AVALIAÇÃO DAS ESTIMATIVAS	24
4. RESULTADOS E DISCUSSÃO	26
4.1. MODELAGEM EMPÍRICA	26
4.2. MODELO DE MONTEITH	31
5. CONSIDERAÇÕES FINAIS	36
REFERÊNCIAS	37

1. INTRODUÇÃO

Nos últimos anos, o Brasil tem se mantido entre os cinco maiores produtores mundiais de algodão, ao lado de países como China, Índia, EUA e Paquistão. Além disso, permanece entre os líderes mundiais em exportação e consumo de algodão em pluma (ABRAPA, 2022). No cenário nacional, destacam-se os estados de Mato Grosso e da Bahia, que cultivaram mais de 88% da área de algodão na safra 2019/2020 (CONAB, 2021). Na Bahia esse cultivo acontece principalmente na região Oeste do estado, que possui grandes empresas agrícolas, cuja produção abastece o mercado de commodities e exportações.

Considerando que as empresas produtoras de algodão são caracterizadas pela alta tecnificação das lavouras, com altos investimentos em sementes, insumos e irrigação, interessa aos agricultores soluções de rápida implementação que permitam a análise dos cultivos e previsibilidade do retorno econômico. O monitoramento das lavouras em escala espacial e temporal é, portanto, fundamental para a previsão das safras e planejamento de toda cadeia produtiva.

Nesse sentido ressalta-se a importância do uso dos produtos de sensoriamento remoto (SR), que possibilitam a obtenção de informações da superfície terrestre sem existir um contato físico, a partir do uso de imagens, de forma não destrutiva e com boa relação custo/benefício. Tais imagens podem ser obtidas a partir de diversas plataformas, como satélites, aeronaves, veículos aéreos não tripulados (VANTs), entre outros (BRANDÃO; ZONTA; SHIRATSUCHI, 2018).

Dentre os principais produtos de sensoriamento remoto utilizados para o monitoramento agrícola, está o índice espectral de vegetação (IV), que consiste em um número que representa a biomassa ou vigor do vegetal, sendo obtido pela combinação de duas ou mais bandas espectrais (MESHESHA et al., 2020). Praticamente todos os índices utilizados em sensoriamento remoto utilizam canais refletidos do visível e o do infravermelho próximo, que produzem um contraste capaz de identificar áreas vegetadas e a condição da cobertura vegetal em superfície.

Para as estimativas de safras associam-se as variáveis agrônômicas, como área foliar, vigor e desenvolvimento, que podem ser utilizadas como indicadores da colheita (AL-GAADI et al., 2016). Tais características são intrinsecamente

correlacionadas com as reflectâncias do dossel vegetal nos canais do visível e do infravermelho próximo, o que torna os índices espectrais de vegetação (IVs) ferramentas adequadas para avaliar o crescimento das culturas, seu acúmulo de biomassa e prever a produção.

Assim, a estimativa da produtividade das culturas pode ser obtida com relações empíricas entre a biomassa vegetal e índices espectrais de vegetação. Diversos trabalhos levantaram essas relações entre o Normalized Difference Vegetation Index (NDVI) que através de dados de reflectância do espectro eletromagnético, funciona como um indicador da quantidade e condição da vegetação, representando o vigor da cultura e a produção registrada em campo (MOSLEH et al., 2016; MESHESHA, 2020; SHAMMI; MENG, 2021).

Muitas metodologias para estimativa de biomassa e produção consideram o uso de índices de vegetação para obter a produtividade primária líquida (PPL), a qual é a quantidade de carbono armazenada pelo vegetal, resultado do saldo entre a assimilação de CO₂ pela fotossíntese e sua liberação, via respiração (HE et al., 2018; LIU et al., 2019). A eficiência de uso de luz (EUL) consiste na razão entre o rendimento biológico (Kg/ha) e a radiação fotossinteticamente ativa (MJ) usada pelas plantas cultivadas (CAMPILO; FORTES; PIETRO, 2012). O método de Monteith, propõe uma correção para obter a EUL das culturas com parâmetros que representam as limitações devido às condições hídricas e térmicas, e essa modelagem é complexa, sendo por vezes aplicado algoritmos para balanço de energia à superfície (GOBBO et al., 2019; YANG et al., 2021).

Os objetivos deste trabalho foram desenvolver uma equação para estimar a produtividade com apenas os índices espectrais, validando-a com os valores de produção e avaliar a estimativa da biomassa pelo Método de Monteith utilizando, além do índice espectral, imagens de evapotranspiração. Além de realizar o mapeamento e análise da variabilidade da produtividade nas parcelas estudadas.

2. REVISÃO DE LITERATURA

2.1. CULTURA DO ALGODOEIRO

O algodoeiro herbáceo ou anual (*Gossypium hirsutum* L.), pertence à família *Malvaceae*. A depender da cultivar e das condições ambientais, o ciclo fenológico varia de 120 a 200 dias (CARDOSO et al., 2015; VASCONCELOS et al., 2018).

A cultura do algodão possui hábito de crescimento indeterminado, produzindo simultaneamente estruturas vegetativas e reprodutivas durante quase todo ciclo (ALI et al. 2011, 2013a, b, 2014a, b). Apesar de apresentar este hábito, o algodoeiro segue um padrão de desenvolvimento que pode ser subdividido em cinco estádios (Tabela 1). O equilíbrio entre o crescimento vegetativo e reprodutivo é fundamental para a produção e qualidade da fibra, sendo influenciado diretamente pelas condições do ambiente, como a temperatura, luminosidade, umidade, fertilidade do solo, bem como do manejo, densidade de plantas, espaçamento entre linhas, nutrientes, reguladores de crescimento (CHIAVEGATO; SALVATIERRA; GOTTARDO, 2009).

Tabela 1. Duração média de cada estágio de desenvolvimento do algodoeiro.

Estádio	Duração (dias)
Germinação – Emergência	5 a 10
Emergência – Primeiro Botão Floral	30 a 35
Primeiro Botão Floral – Primeira flor	20 a 25
Primeira flor – Primeiro capulho	50 a 55
Primeiro capulho – Colheita	45 a 50

Fonte: CHIAVEGATO; SALVATIERRA; GOTTARDO, (2009)

Dentre os fatores ambientais, a temperatura é um dos parâmetros que mais influenciam o desenvolvimento do algodoeiro, afetando significativamente a fenologia, a expansão foliar, a alongação dos internódios, a produção de biomassa e a partição dos assimilados pelas diferentes partes da planta, entre outros aspectos. A faixa de melhor desenvolvimento é de 20 °C a 30 °, com limite inferior de 15 °C e superior de 40 °C (DOORENBOS; KASSAM, 2000; EMBRAPA, 2014).

A depender do clima e da duração do ciclo, a quantidade de água necessária para atender às necessidades hídricas do algodoeiro, pode variar entre 500 e 1.500

mm. Cada estágio fenológico vai demandar a quantidade, em função do desenvolvimento da fitomassa, com maior requerimento na fase de floração (CHIAVEGATO; SALVATIERRA; GOTTARDO, 2009).

Em relação à importância econômica, o algodão ocupa o primeiro lugar entre as culturas de fibra em todo o mundo. Segundo a ABRAPA (2022) atualmente, o algodão é produzido por mais de 60 países, nos cinco continentes e movimenta anualmente no comércio mundial 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.

A cultura apresenta multiplicidade de uso doméstico e econômico, fornecendo como matéria-prima, fibras para uma indústria têxtil cada vez maior, sementes para produção de óleo para fins culinários e óleo comestível, além de resíduos de torta de óleo ricos em proteínas para o gado. São diversos produtos secundários fabricados com a utilização dos componentes do algodão (MUNIR et al., 2020).

Nacionalmente, o algodão também expressa grande importância socioeconômica, principalmente nas regiões onde seu cultivo está presente por ter uma cadeia produtiva complexa e de alto valor agregado, beneficiando desde os fornecedores de insumos, ao comércio de roupas. Destaca-se ainda o papel relevante na indústria química e como alimento animal, integrando-se às cadeias produtivas do leite e de proteína animal (SEVERINO et al., 2019).

Segundo Severino et al. (2019) a aplicação de novas técnicas de gerenciamento do campo, juntamente com o investimento, a pesquisa e o melhor beneficiamento aumentaram a qualidade e a quantidade do algodão brasileiro, adequando-o às necessidades das indústrias, garantindo ao país lugar privilegiado no cenário internacional como um dos cinco maiores produtores mundiais. Além disso, permitiu ao Brasil destinar uma fatia considerável de sua produção para o mercado externo, exportando algodão principalmente para Cazaquistão, Indonésia e Coreia do Sul

As perspectivas em relação a produção de algodão são promissoras, pois na safra 21/22, a produção deverá ser de 2,82 milhões de toneladas, o que representa um aumento de 19,6% em relação à safra 2019/20 (CONAB, 2022).

2.2. ESTIMATIVA DE SAFRAS

A estimativa de safra das culturas agrícolas é importante para o agronegócio, pois fornece subsídio para o planejamento do mercado, a logística, o armazenamento e todos demais processos relacionados à produção e distribuição de alimentos.

Os dois órgãos nacionais responsáveis pela previsão de safras são a Companhia Nacional de Abastecimento (CONAB) e o Instituto Brasileiro de Geografia e Estatística (IBGE), que contam com o apoio de outros órgãos estaduais e federais. Tradicionalmente esses órgãos fazem a previsão fundamentando-se em levantamentos subjetivos realizados com os produtores ou às entidades relacionadas à atividade agrícola em cada região. A metodologia baseia-se em reunir mensalmente representantes dessas entidades para coletar e analisar as informações, que são posteriormente compiladas para o ajuste final em nível nacional (IBGE, 2022).

Segundo Marin (2020), atualmente a previsão de safras conta com o suporte de recursos modernos, como as técnicas das geotecnologias, como as imagens orbitais, os Sistemas de Informações Geográficas (SIGs) e programas de dados climáticos para a estimativa da produtividade em todas as regiões produtoras do país.

Nesse sentido, a Conab realiza o monitoramento agrícola da safra de grãos nas principais regiões produtoras do país, com o propósito de avaliar as condições atuais das lavouras em decorrência de fatores agronômicos e eventos climáticos recentes, e assim auxiliar na estimativa da produtividade. Tais condições são analisadas através do monitoramento agrometeorológico e espectral, os dados espectrais mostram o desenvolvimento das lavouras através do Índice de Vegetação, refletindo o comportamento das plantas em relação a safras anteriores, sendo complementado com os dados de campo, isso resulta em diagnóstico preciso, auxiliando no aprimoramento das estimativas da produção agrícola nacionais obtidas pela Companhia (CONAB, 2020).

Pesquisadores também têm realizado trabalhos nesse sentido, visando o desenvolvimento desses modelos em escala regional ou estadual. Sarmiento et al. (2020) propuseram um modelo agrometeorológico espectral para estimar a produtividade de grãos de soja no Mato Grosso e obtiveram uma metodologia capaz de acompanhar o desenvolvimento e quantificar a produção e produtividade da soja

em determinadas regiões do estado. Os autores relataram que as análises do perfil do índice de vegetação NDVI foram capazes de identificar e monitorar as fases fenológicas do ciclo e se o desenvolvimento da cultura ocorreu dentro da produção de fitomassa esperada. O levantamento da evapotranspiração mostrou-se eficiente para o monitoramento das necessidades hídricas da cultura ao longo do ciclo, fornecendo informações para dados de restrição hídrica, que são importantes no cálculo da produtividade final.

Silva et al. (2021) desenvolveram um modelo agrometeorológico-espectral através de uma regressão linear múltipla para estimar a produtividade da cana-de-açúcar na região semiárida do Brasil. O modelo mostrou uma boa explicação da produtividade estimada da cana-de-açúcar em relação à produtividade medida para o período de calibração. Os autores sugerem que para ser utilizado e gerar resultados precisos esse deve ser calibrado e validado para as características locais de plantio.

2.3. USO DO SENSORIAMENTO REMOTO PARA MONITORAMENTO DA AGRICULTURA

O sensoriamento remoto (SR) tem como ponto central a análise dos objetos na superfície terrestre, sem contato direto, por meio da resposta desses objetos à radiação incidente. Novo (2010) define-o como um conjunto de sensores, equipamentos de processamento e transmissão de dados utilizados no estudo do ambiente terrestre através dessas análises. Meneses et.al (2012) afirmam que trata-se de uma ciência que visa a obtenção de imagens da superfície terrestre através da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres.

Uma característica interessante das culturas agrícolas que favorece o uso de dados de SR no seu monitoramento, é a dinâmica de comportamento fenológico ao longo do ciclo, que permite a extração de informações a partir de imagens orbitais, uma vez que destaca o perfil da cultura no decorrer do tempo. A variação da quantidade de cobertura e biomassa verde sobre a superfície ao longo do ciclo da cultura influencia no comportamento espectral registrado nas imagens e define as diferentes respostas espectrais, em função dos tipos de cultivo, épocas de plantio,

períodos de maior vigor vegetativo, épocas de amadurecimento, de colheita etc. (FORMAGGIO; SANCHES, 2017).

O uso do SR na agricultura tem sido estudado desde a década de 1970, com os Estados Unidos sendo os pioneiros em pesquisas por meio do lançamento do primeiro satélite da série Landsat, colocado em órbita em 1972, com o objetivo de avaliar a potencialidade e viabilidade do uso de imagens de sensor Multiespectral para estimar a área de trigo. Na mesma década o Brasil também começou a utilizar SR orbital, mas, ainda para conhecimento e levantamento das particularidades de ocupação do território nacional. Em meados da década de 80 que ocorreram as iniciativas de mapeamento de classes específicas incluindo culturas agrícolas como a cana-de-açúcar e o feijão que tinham grande importância econômica (FORMAGGIO; SANCHES, 2017; PONZONI; SHIMABUKURO; KUPLICH, 2012).

Ao longo desses anos, inúmeras pesquisas foram realizadas apresentando exemplos das diversas possibilidades de aplicações do SR na agricultura, mas, principalmente para a previsão de produtividade de safra e na estimativa de área plantada. Leda (2016) utilizou imagens do satélite Landsat 8 para obter os índices de vegetação e desenvolver uma modelagem para produtividade de cana-de-açúcar. Outros exemplos recentes são o de Venancio, et.al (2019) que utilizaram o NDVI acumulado para estimativa da biomassa e produtividade de grãos do milho irrigado e Gasparin, (2021) que analisou a variabilidade agrometeorológica e espectral e estimou a produtividade da soja com imagens de satélites.

Além disso Formaggio e Sanches (2017) relatam que as informações obtidas pelo SR, possibilitam ainda, o mapeamento de estresse hídrico e do vigor nas plantas, avaliação de eventos climáticos desastrosos sobre produções agrícolas, a avaliação da fenologia das culturas, e informações para auxiliar o entendimento de possíveis efeitos de mudanças climáticas entre outros.

2.3.1. Imagens Sentinel-2

A missão Copernicus Sentinel-2 compreende uma constelação de dois satélites idênticos que operam simultaneamente em uma órbita síncrona do sol a uma altitude média de 786 km. Destina-se a monitorar a variabilidade nas condições da

superfície terrestre, e possui 13 bandas espectrais, conforme apresentado na Tabela 2 (ESA,2022).

Os produtos Sentinel-2 apresentam um grande potencial de uso em mapeamento e monitoramento agrícola, previsão efetiva da produtividade de culturas agrícolas e aplicações relacionadas ao acompanhamento ou monitoramento de crescimento da vegetação da Terra, devido a ampla largura de faixa (290 km) e baixo tempo de revisita (10 dias no equador com um satélite e 5 dias com 2 satélites em condições sem nuvens) que os satélites apresentam (ESA, 2022).

Tabela 2. Comprimentos de onda e resolução espacial das bandas espectrais dos satélites Sentinel-2

Nº da banda	Nome da Banda	Resolução espacial (m)	Comprimento de onda central (nm)
B01	Aerossol	60	443
B02	Azul	10	490
B03	Verde	10	560
B04	Vermelho	10	665
B05	Borda Vermelha 1	20	705
B06	Borda Vermelha 2	20	740
B07	Borda Vermelha 3	20	783
B08A	Borda Vermelha 4	20	865
B08	Infravermelho Próximo	10	842
B09	Vapor de Água	60	940
B10	Cirrus	60	1375
B11	Infravermelho de Onda Curta 1	20	1610
B12	Infravermelho de Onda Curta 2	20	2190

Fonte: Adaptado de ENGESAT (2022).

2.3.2. Imagens Landsat 8

O Landsat 8 foi colocado em órbita no ano de 2013, a uma altitude média de 705 km carregando dois instrumentos: o Operational Land Imager (OLI) que coleta dados para bandas espectrais de infravermelho próximo, visível e infravermelho de ondas curtas, bem como uma banda pancromática e o Thermal Infrared Sensor

(TIRS) capta a radiação termal emitida pela superfície (NASA, 2022). As imagens do OLI têm resoluções espaciais pancromáticas de 15 metros e multiespectrais de 30 metros. O satélite apresenta 11 bandas revelando diferentes informações sobre a condição da cobertura da Terra (Tabela 2) e tempo de revisita (resolução temporal) de 16 dias (NASA, 2022).

Tabela 3. Características das bandas dos sensores OLI e TIRS do satélite Landsat 8.

Nº da banda	Nome da Banda	Resolução espacial (m)	Faixa espectral (µm)
Banda 1	Costal/Aerosol	30	0.435 - 0.451
Banda 2	Azul	30	0.452 - 0.512
Banda 3	Verde	30	0.533 - 0.590
Banda 4	Vermelho	30	0.636 - 0.673
Banda 5	Infravermelho Próximo	30	0.851 - 0.879
Banda 6	Infravermelho médio 1	30	1.566 – 1.651
Banda 7	Infravermelho médio 2	30	2,107 - 2.294
Banda 8	Pancromática	15	0.503 - 0.676
Banda 9	Cirrus	30	1.363 – 1.384
Banda 10	Infravermelho Termal 1	100	10.60 – 11.19
Banda 11	Infravermelho Termal 2	100	11.50 – 12.51

Fonte: Adaptado de <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>

2.4. MODELAGEM DA ESTIMATIVA DE SAFRAS COM PRODUTOS DE SENSORIAMENTO REMOTO

2.4.1. Método de Monteith

De acordo Campilo, Fortes, Pietro (2012) a radiação solar interceptada pela cultura é um dos fatores mais influentes no desenvolvimento das plantas, devido a energia que fornece para o seu metabolismo. O principal processo é a assimilação fotossintética que possibilita sintetizar componentes vegetais a partir da água, CO₂ e da energia luminosa. Ainda segundo esses autores, da radiação global incidente no dossel da planta, apenas uma proporção é usada para realizar a fotossíntese, sendo esta fração denominada radiação fotossintética ativa (RFA).

Monteith (1972) observou que para diferentes culturas e condições ambientais, a proporção de luz absorvida e assimilação de carbono durante a fase de crescimento é relativamente constante. Assim, propôs um modelo de eficiência de produção para estimar a quantidade de biomassa a partir da Radiação Fotossinteticamente Ativa Absorvida pela vegetação (RFAA) e a Eficiência Máxima de Uso da Luz (EUL máx). Em condições ambientais não limitantes, a quantidade de matéria seca produzida por uma cultura está linearmente relacionada à quantidade de radiação fotossinteticamente ativa interceptada (KINIRY et al., 1989 *apud* DALMAGO, et al., 2009 p.143).

Monteith (1977) demonstrou que a produção total de matéria seca da cevada, batata, beterraba e maçã apresentou forte correlação com a radiação interceptada, em condições de suprimento adequado de água no solo. Assim ele formalizou e estabeleceu plenamente os fundamentos experimentais e teóricos para a relação entre matéria seca acumulada da cultura e radiação solar, argumentando que esta abordagem é robusta e teoricamente apropriada para descrever o crescimento da cultura.

Utilizando esse método com produtos de sensoriamento remoto, determina-se a biomassa com dados do índice de vegetação, de evapotranspiração (para obter informações sobre a condição hídrica da cultura, juntamente com dados meteorológicos. O valor encontrado deve ser multiplicado pelo índice de colheita para gerar a estimativa da produtividade. Tao et al., (2005) utilizou o modelo Carnegie-Ames-Stanford-Approach (CASA) (POTTER et al., 1993) que se refere a uma variação do proposto por Monteith (1972) fazendo a eficiência do uso de luz uma função de temperatura, estresse hídrico e de nutrientes, para estimar a produção de milho na China. E observou que o modelo possui melhor desempenho nas áreas com colheita densa e dados climáticos para calibração.

2.4.2. Modelagem Empírica com Índices de Vegetação

Os índices de vegetação (IVs) podem ser obtidos através de modelos matemáticos, ou algoritmos baseados no sensoriamento remoto, que associam dados

de reflectância às características das plantas para avaliar e caracterizar a cobertura vegetal em uma determinada área.

Os IVs apresentam diferentes finalidades que se complementam, para avaliar o desenvolvimento das culturas. O Índice de Vegetação por Diferença Normalizada (NDVI), proposto por Rouse et al. (1973), relaciona a reflectância da vegetação nos comprimentos de onda do vermelho (V) e do infravermelho próximo (IVP). apresenta escala de variação linear entre -1 e 1 , onde valores negativos retratam nuvens ou corpos de água, o intervalo entre $0,0$ e $0,2$ representa solo exposto, e valores acima desse correspondem a vegetação, de forma que quanto mais próximo de um, maior o vigor vegetal. O NDVI apresenta uma forte correlação linear com o crescimento das culturas, sendo bastante utilizado para monitoramento agrícola, estimativa de produtividade entre outros (LIU, 2015).

Bertolin et al. (2017) desenvolveram uma equação empírica, utilizando a relação de IVs, obtidos via sensoriamento remoto, com a produtividade do milho para prever a produtividade das safras seguintes. E concluíram que o NDVI apresentou boa correlação com a produtividade (R^2 igual a $0,81$), demonstrando sua potencialidade para tal fim. Já Moreira (2019) utilizou o NDVI para observar padrões fenológicos e de produção nas lavouras de cana-de-açúcar e obter informações, como os distintos estágios de plantio entre os talhões.

Outros dois IVs comumente utilizados foram propostos por Huete (1988) e Huete et al. (1997) para atenuar os efeitos causados pelo solo e pelos aerossóis atmosféricos, o SAVI (Índice de Vegetação Ajustado ao Solo) e o EVI (Índice de Vegetação Melhorado), respectivamente. Ambos são calculados com as refletâncias do vermelho e do infravermelho próximo acrescido de fatores de correção. No SAVI é a constante L , que assume o valor 0 para cobertura de vegetação alta; $0,5$ em cobertura intermediária e 1 para um nível muito baixo de vegetação. Já no EVI, são os coeficientes $C1$ e $C2$ que consistem no coeficiente de correção dos efeitos atmosféricos para a banda do vermelho e para a banda do azul respectivamente. Esses são alterados de acordo com as condições regionais (LIU, 2015; LAURENTINO et al., 2011).

Shammi e Meng, (2021) desenvolveram 19 métricas de crescimento de cultura usando conjuntos de dados NDVI e EVI de séries temporais e aplicaram-nas à soja

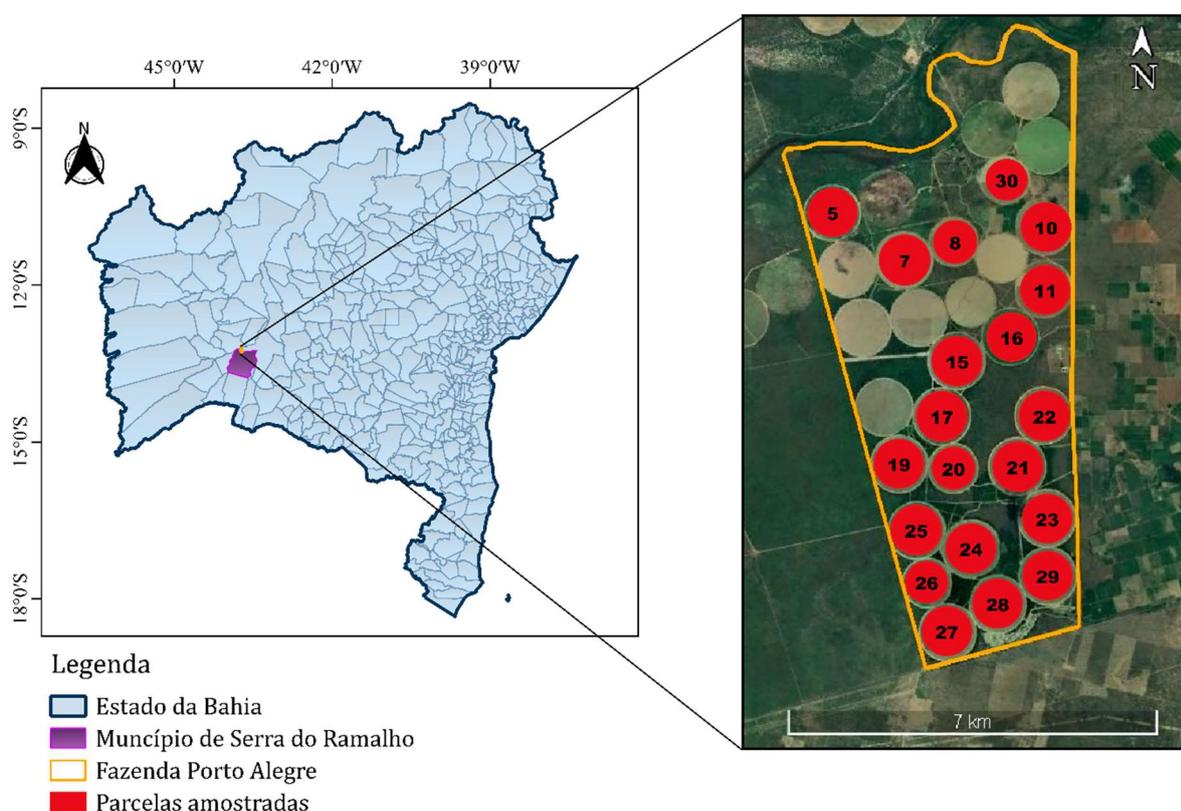
para modelagem de produtividade. Eles observaram que essas métricas baseadas em NDVI e EVI são bem executadas para prever a produtividade da soja no Delta do Mississippi, nos Estados Unidos. Ainda segundo os autores, a fenologia, o ciclo, as datas de plantio e de colheita em diferentes zonas de cultivo determinam as características das métricas de crescimento baseadas em NDVI e EVI. Estas métricas de crescimento de culturas são independentes de fatores climáticos e adequadas para qualquer zona agrícola para modelagem de rendimento de culturas. Os índices de crescimento de culturas projetados podem mostrar algumas anomalias nas previsões de rendimento

3. METODOLOGIA

3.1. LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo está localizada na Fazenda Porto Alegre ($13^{\circ}15'18''$ S, $43^{\circ}25'05''$ W, 436 m) no município de Serra do Ramalho, região Oeste do Estado da Bahia (Figura 1). Foram aplicados nesse estudo dados de produção do algodoeiro de 20 parcelas produtoras (Tabela 4), irrigadas em sistema de aspersão por pivô central, na safra 2020.

Figura 1. Localização da área de estudo.



Fonte: Elaborado pelo autor com imagens do Google Earth, 2022.

Para caracterização das condições ambientais, foram utilizados dados meteorológicos medidos em estação meteorológica da propriedade. O clima da região de estudo é classificado de acordo com Köppen como BSw_h, clima quente de caatinga com estação chuvosa no período de primavera-verão (SEI, 2021). As médias anuais de temperaturas máxima e mínima são $32,8^{\circ}\text{C}$ e 20°C , respectivamente, a precipitação média anual é de 798 mm e a evapotranspiração potencial 2163 mm (INMET, 2021).

Tabela 4. Área em hectares das parcelas produtoras de algodão na safra 2020.

Parcela	Área (ha)	Produção (kg)	Parcela	Área (ha)	Produção (kg)
Pivô 05	86,00	482.322	Pivô 21	90,00	495.758
Pivô 07	90,00	396.821	Pivô 22	90,00	487.690
Pivô 08	66,00	274.107	Pivô 23	90,00	432.138
Pivô 10	90,00	347.130	Pivô 24	90,00	475.675
Pivô 11	90,00	448.874	Pivô 25	90,00	481.068
Pivô 15	88,00	358.254	Pivô 26	66,00	324.158
Pivô 16	90,00	401.892	Pivô 27	86,00	437.150
Pivô 17	88,00	342.691	Pivô 28	89,00	402.504
Pivô 19	90,00	377.863	Pivô 29	90,00	432.771
Pivô 20	66,00	361.618	Pivô 30	33,00	173.189

Fonte: Elaborado pelo autor, 2022.

3.2. AQUISIÇÃO E PROCESSAMENTO DOS DADOS ORBITAIS

Foram utilizados os produtos do satélite Landsat 8 para implementação no Modelo de PPL: NDVI e Evapotranspiração. Estes mapas foram obtidos através do aplicativo GEE Surface Energy Balance Algorithm for Land (SEBAL) desenvolvido por Laipelt et al., (2021), disponível no endereço: <https://etbrasil.users.earthengine.app/view/geesebal>. Obteve-se 8 imagens para o período correspondente ao ciclo da cultura (fevereiro a agosto) que apresentaram ausência de nuvens sobre a área de estudo. Na plataforma de geoprocessamento QGIS, foram realizados os recortes das parcelas produtoras em arquivos individuais, para exportar os valores dos *pixels* para planilha eletrônica e obter as métricas (média do NDVI e ET de cada parcela, desvio padrão e coeficiente de variação).

Imagens dos satélites Sentinel-2A e 2B foram aplicadas para gerar os índices de vegetação NDVI, SAVI e EVI, os quais foram implementados na modelagem

empírica da produtividade da cultura. O processamento foi realizado na plataforma online gratuita Google Earth Engine (Figura 2), que possui alta capacidade de armazenamento de imagens de satélite e conjuntos de dados geospaciais, e de processamento de tais imagens permitindo ao usuário realizar diversas análises espaço-temporais, em nível regional e global, de forma mais rápida que com às técnicas de SIG convencionais (LOBO, 2020).

Na plataforma é possível realizar diversas operações utilizando técnicas de programação *JavaScript* ou *Phyton* (LOBO, 2020). Utilizou-se um código gerado com *Javascript* para realizar a filtragem de datas obtendo-se apenas as imagens correspondentes ao ciclo da cultura, utilizadas na obtenção do valor médio e máximo da série para cada *pixels*, máscara de nuvens para reduzir variações bruscas no comportamento dos índices de vegetação, bem como a exportação dos dados de cada parcela no formato de valores separados por vírgulas (csv) que facilita o uso desses em planilha eletrônica. O endereço para acessar o código é: <https://code.earthengine.google.com/52eb345d79bb2767fbce780d864cdb70>

Figura 2. Tela da plataforma Google Earth Engine.

```

Imports (1 entry)
var pivo_30: Table users/amadacandido/Pivo_30
//OBTENÇÃO DOS ÍNDICES DE VEGETAÇÃO MÁXIMOS E MÉDIOS PARA CADA PIVÔ CULTIVADO - FAZENDA BUSATO II
var parcela = pivo_30//Parcela produtora/pivô
//Período
var start = ee.Date.fromYMD(2019,12,1);//ano, mês, dia
var end = ee.Date.fromYMD(2020,7,1);
//-----SENTINEL-----
//Bandas que serão utilizadas
var S2 = ee.ImageCollection("COPERNICUS/S2_SR")
var bandas_S2 = ee.List(['B2', 'B4', 'B8']) //B2: azul; B4: vermelho; B8: IV;
//Função para criar máscara de nuvens
function maskS2srClouds(image) {
  var qa = image.select('QA60');//QA_060: máscara(nuvens)
  // Bits 10 and 11 are clouds and cirrus, respectively.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;
  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
  .and(qa.bitwiseAnd(cirrusBitMask).eq(0));
  return image.updateMask(mask).divide(10000);
}
//Filtrando as imagens para a data de estudo e pivô; aplicando máscara de nuvens
var dataset_S2 = S2.filterBounds(parcela)//geometria (shape file do pivô)
  .filterDate(start,end)
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',20))
  .map(maskS2srClouds)
  .select(bandas_S2);
print(dataset_S2);

```

Fonte: Google Earth Engine, 2022.

As equações para determinar os índices de vegetação estão descritas a seguir. O NDVI foi determinado a partir das imagens dos canais refletivos do vermelho e do infravermelho das imagens de satélite através da seguinte equação (ROUSE et al., 1973):

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

Em que ρ_{IVP} é a reflectância da vegetação no infravermelho próximo e ρ_V é a reflectância da vegetação na banda do vermelho.

O SAVI foi determinado pela equação 2 (HUETE, 1988). Em que o termo “L” é o fator de ajuste para a reflectância do solo na banda do infravermelho e assume os seguintes valores: 1,0 para vegetação esparsa/solo nu; 0,5 para cobertura média de vegetação e 0,25 para densa cobertura. Neste trabalho aplicou-se o valor de 0,5.

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

O EVI adota, além dos canais do vermelho e do infravermelho próximo, a banda do azul e foi determinado pela seguinte equação (HUETE et al., 1997)

$$EVI = G \cdot \frac{\rho_{IVP} - \rho_V}{(\rho_{IVP} + C_1) (\rho_V - C_2) (\rho_B + L)} \quad (3)$$

Em que G é um fator de ganho igual a 2,5; C_1 e C_2 são fatores de correção da atmosfera, respectivamente 6,0 e 7,5; L é um ajuste para a reflectância abaixo da cultura igual a 1,0 e ρ_B é a reflectância na banda do azul.

3.3. MODELAGEM DA PRODUTIVIDADE DA CULTURA

Duas metodologias para estimar a produtividade das culturas serão aplicadas e avaliadas: 1) Clássico Método de Monteith (1972) para determinar a Produção Primária Líquida (PPL) da vegetação, utilizando o NDVI, e a Evapotranspiração (ET) como produto de sensoriamento remoto e 2) Regressão para obter equação de estimativa da produtividade, a partir do NDVI.

3.4 MÉTODO DE MONTEITH:

A estimativa da biomassa, ou PPL ($g\ m^{-2}$), determinada com dados de sensoriamento remoto e medidas de radiação solar global é dada pela Equação 4:

$$PPL = \varepsilon \cdot RFAA \quad (4)$$

Onde ε é o fator de uso eficiente da luz (g MJ^{-1}) e RFAA é a radiação fotossinteticamente ativa absorvida (MJ m^{-2}).

Na impossibilidade de medidas diretas, a radiação fotossinteticamente ativa, RFA, pode ser determinada em função da radiação global diária, por PAR igual a $0,48 \cdot R_{g,24h}$ (MJ m^{-2}). A RFAA é uma porção da RFA, cuja relação pode ser demonstrada matematicamente por: $\text{RFAA} = f \cdot \text{RFA}$. O fator f foi derivado do NDVI (Landsat 8), conforme a Equação 5 (BASTIAANSSEN e ALI, 2003).

$$f = -0,161 + 1,257 \text{ NDVI} \quad (5)$$

A eficiência do uso de luz é dada pela seguinte relação:

$$\varepsilon = \varepsilon^* \cdot T_s \cdot W_s \quad (6)$$

Em que ε^* é a máxima eficiência de uso de luz; T_s e W_s são as correções da eficiência de uso de luz para temperatura e umidade, respectivamente. O valor de ε^* utilizado neste trabalho foi de 1.97 g MJ^{-1} , obtido por Gonias et al. (2012).

A correção da temperatura é dada por (PATEL et al., 2010):

$$T_s = \frac{(T - T_{\min}) \cdot (T - T_{\max})}{[(T - T_{\min}) \cdot (T - T_{\max})] - (T - T_{\text{ot}})^2} \quad (7)$$

Em que T é a temperatura média do mês; T_{ot} , T_{\max} e T_{\min} são, respectivamente, as temperaturas ótima, máxima e mínima para o desenvolvimento da cultura. Para o algodão foram utilizados 26 , 21°C , 40°C e 15°C respectivamente (CHIAVEGATO; SALVATIERRA; GOTTARDO, 2009).

Para obter da correção pela umidade, aplicou-se a relação utilizada por Tao et al. (2005), (Equação 8) na qual a restrição à eficiência fotossintética relativa à disponibilidade hídrica é a relação entre a evapotranspiração da cultura - ET_c (gerada pelo GEESEBAL) e a evapotranspiração de referência - ET_o calculada pela Equação 9 (ALLEN et al., 1998).

$$W_s = 0,5 + 0,5 \cdot \frac{ET_c}{ET_o} \quad (8)$$

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (9)$$

Em que R_n ($\text{MJ m}^{-2} \text{ dia}^{-1}$) é o saldo de radiação à superfície; G ($\text{MJ m}^{-2} \text{ dia}^{-1}$) é o fluxo de calor no solo; T ($^{\circ}\text{C}$) é a temperatura média do ar; u_2 (m s^{-1}) é a velocidade do vento a 2 m de altura; $(e_s - e_a)$ é o déficit de pressão de vapor (kPa); Δ é a inclinação da curva de pressão de vapor d'água ($\text{kPa } ^{\circ}\text{C}^{-1}$); γ é o fator psicrométrico (kPa).

Para obter a produção multiplicou-se o valor da PPL pelo Índice de Colheita (IC) que se refere ao quociente que mede a eficiência de conversão de produtos sintetizados em produtos de importância econômica (PEREIRA; MACHADO, 1987). Neste trabalho o IC utilizado foi de 0,3, um valor médio, obtido considerando os encontrados na literatura que variaram de 0,2 a 0,41 (QUIAN et al., 2020; IQBAL; KHAN; CHATTHA, 2020)

3.5. MODELAGEM EMPÍRICA COM REGRESSÃO LINEAR

Dados de produtividade de cada parcela produtiva – pivô, disponibilizados pela fazenda, foram aplicados em regressão com cada índice de vegetação (NDVI, SAVI e EVI) para obter equação de estimativa da produtividade para cultura. Para tanto, foram utilizados apenas dois valores de IV, para cada parcela produtora: o máximo – IV_{max} , que corresponde à data de máximo acúmulo de biomassa da cultura, portanto representa a biomassa que será convertida no produto final; e o médio - IV_{med} , representando a média dos valores do IV no ciclo da cultura em cada parcela. Para gerar o modelo, foram aplicados 2/3 de dados de um total de 800 *pixels* dos pivôs cultivados, na época estudada.

3.6. AVALIAÇÃO DAS ESTIMATIVAS

O modelo empírico de produção foi validado com o 1/3 de dados dos 800 *pixels* dos pivôs cultivados no período estudado. As estimativas (regressões e a modelagem com a radiação fotossinteticamente ativa - método de Monteith) foram comparadas com os dados de campo, as médias da segunda foram comparadas através do Teste de Tukey, ambas foram avaliadas segundo os indicadores: coeficientes de

determinação (R^2), coeficiente de correlação de Pearson (r); razão média (RM) (Equação 10); erro absoluto médio (EAM) (Equação 11); raiz quadrada do quadrado médio do erro, (RQME) (Equação 12) e índice de desempenho de Willmott (d) (Equação 13) (BORGES et al., 2010).

As equações dos indicadores de desempenho estão descritas a seguir:

$$RM = \frac{E_i}{O_i} \quad (10)$$

Em que, E_i é valor estimado da produtividade em kg/ha, O_i - valor observado a produtividade em kg/ha.

$$EAM = \frac{\sum_{i=1}^N |E_i - O_i|}{N} \quad (11)$$

Sendo: N o número de observações.

$$RQME = \left[\frac{\sum_{i=1}^N (E_i - O_i)^2}{N} \right]^{0,5} \quad (12)$$

$$d_w = 1 - \left[\frac{\sum_{i=1}^N (E_i - O_i)^2}{\sum_{i=1}^N (|E_i - \bar{O}| + |O_i - \bar{O}|)^2} \right] \quad (13)$$

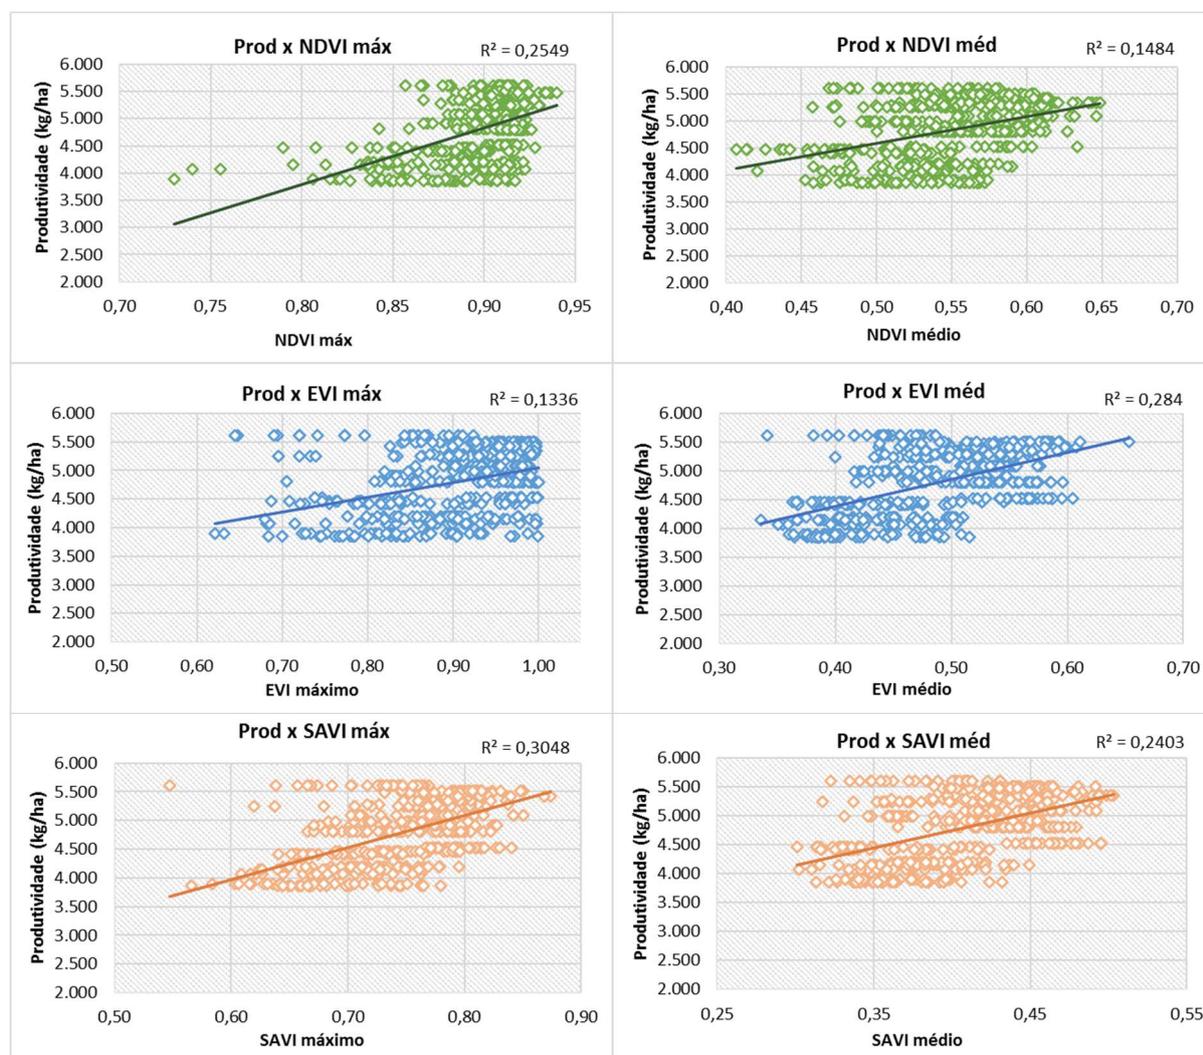
Em que \bar{O} é a média dos valores observados da produtividade em kg/ha.

4. RESULTADOS E DISCUSSÃO

4.1. MODELAGEM EMPÍRICA

A Figura 3 apresenta a relação entre os índices de vegetação NDVI, EVI e SAVI máximos e médios e a produtividade observada em campo. Observa-se que existe correlação positiva, pois ao passo que os valores de IVs aumentaram a produtividade também aumentou. Porém, o coeficiente de determinação (R^2), que determina a precisão da estimativa, foi baixo.

Figura 3. Relação entre os valores máximos e médios de NDVI, EVI e SAVI e a produtividade em kg/ha.



Na relação com os valores máximos, observa-se que o SAVI apresentou maior coeficiente de determinação, 0,3048, seguido pelo NDVI, com valor de 0,2549, o EVI apresentou menor valor, 0,1336. Já na relação com os valores médios, o EVI

apresentou maior coeficiente, 0,284, seguido pelo SAVI que foi de 0,2403 e o NDVI, com o menor valor 0,1484

Através da regressão entre os IVs e a produtividade em quilogramas por hectares, obteve-se os modelos lineares com as equações conforme apresentado na Tabela 5.

Tabela 5. Equações para estimativa de produtividade.

PN1	Produtividade = $10.438 * (NDVI_{máx}) - 4.560,6$
PN2	Produtividade = $4.955,6 * (NDVI_{méd}) + 2.108,9$
PE1	Produtividade = $2.551,7 * (EVI_{máx}) + 2.490$
PE2	Produtividade = $4.698 * (EVI_{méd}) + 2.5502,7$
PS1	Produtividade = $5.547,2 * (SAVI_{máx}) + 647,11$
PS2	Produtividade = $6.003,5 * (SAVI_{méd}) + 2.347,7$

Fonte: Elaborado pelo autor, 2022. PN1 - Modelo estimado com o NDVI máximo; PN2 - modelo estimado com o NDVI médio; PE1- modelo estimado com EVI máximo; PE2 - modelo estimado com EVI médio; PS2 - modelo estimado com SAVI máximo; PS2 - modelo estimado com SAVI médio.

A Tabela 6 resume os indicadores estatísticos de desempenho dos modelos. Observa-se que as médias de produtividade observadas em campo e estimada pelos modelos apresentaram valores próximos. O modelo PE2 foi o que apresentou maior coeficiente de correlação Pearson (r) 0,5553, os demais modelos com exceção do PE1 que apresentou coeficiente de 0,2975, apresentaram valores de (r) moderado acima de 0,4 que pode ser considerado uma correlação mediana segundo Dancey e Reidy (2006).

O índice de concordância de Willmott (d) apresentou desempenho mediano para o PE2 (0,6329), PS1 (0,5849) e PN1 (0,5418). Para os demais observou-se um mal desempenho, tendo em vista que apresentaram valores de (d) abaixo de 0,5, e que a concordância perfeita entre estimativas e dados observados é registrada com d igual a 1,0 (BORGES, et al., 2010).

As médias da produtividade medida em campo e estimadas foram estaticamente iguais, e a razão média mostrou que a estimativa não variou muito em relação ao observado, apresentando superestimativa menor que 5% para quase todos os modelos, apenas PE2 apresentou subestimativa.

O erro absoluto médio para os modelos PN1, PN2, PE1 e PS2 ficaram acima de 400 kg/ha, o que corresponde a cerca de 9% da produtividade média registrada em campo, que foi de 4.802,83 kg/ha. Em PE2 e PS1 esse valor foi um pouco menor, 386,70 e 398,93 kg/ha respectivamente.

Tabela 6. Índices estatísticos dos modelos de estimativa da produtividade do algodoeiro gerados com os índices NDVI, EVI e SAVI.

SAFRA 2020												
Indicadores	PN1		PN2		PE1		PE2		PS1		PS2	
	Est	Obs										
Média (kg ha⁻¹)	4.802,32	4.801,34	4.807,95	4.779,54	4.805,11	4.819,82	4.783,77	4.845,75	4.803,58	4.835,95	4.795,81	4.831,97
Dp	273,15	558,21	228,69	545,29	191,70	549,86	303,41	555,14	302,02	562,91	252,59	549,34
CV	6%	12%	5%	11%	4%	11%	6%	11%	6%	12%	5%	11%
RM Média	1,011		1,017		1,009		0,997		1,004		1,003	
EAM (kg ha⁻¹)	411,83		419,86		443,76		386,70		398,93		430,46	
REQM (kg ha⁻¹)	491,72		497,38		524,95		465,00		489,00		496,07	
d (Willmont)	0,5418		0,4514		0,3120		0,6329		0,5849		0,4926	
cor. Pearson (r)	0,4706		0,4095		0,2975		0,5553		0,4974		0,4320	
R²	0,2549		0,1484		0,1336		0,2840		0,3048		0,2403	
p-valor Teste T	0,9742		0,3507		0,6473		0,0288		0,2793		0,2334	

Fonte: Elaborado pelo autor, 2022. Est - produtividade estimada, Obs - produtividade observada em campo, Dp - desvio padrão, CV - coeficiente de variação, RM - Razão Média, EAM - Erro Absoluto Médio, REQM - Raiz Quadrada do quadrado médio do erro, d (Willmont) - índice de concordância de Wilmott, r - coeficiente de correlação de Pearson, R² - coeficientes de determinação, PN1 - Modelo estimado com o NDVI máximo, PN2 - modelo estimado com o NDVI médio, PE1 - modelo estimado com EVI máximo, PE2 - modelo estimado com EVI médio, PS1 - modelo estimado com SAVI máximo, PS2 - modelo estimado com SAVI médio.

Oliveira (2019) utilizando índices espectrais de vegetação derivados de imagens MSI - Sentinel 2 para estimar a produtividade do algodoeiro, observou que a correlação entre os dados espectrais e a produtividade é dependente da idade do algodoeiro e do seu estágio fenológico. De acordo com o autor, o início do florescimento da cultura se mostrou a fase menos indicada para se estimar a produtividade, apresentando os menores coeficientes de determinação. A fase da frutificação completa, apresentou as melhores correlações entre a produtividade e os índices de vegetação, NDVI e SAVI igual a 0,82.

Os modelos apresentaram mal desempenho para estimar a produtividade, pode-se atribuir esses resultados a outros fatores como condições meteorológicas, situação nutricional das plantas e do solo, ou a fitossanidade que interferem na alocação da biomassa verde para o produto final. Os valores dos IVs podem sofrer influência de outros fatores além dos relacionados com a reflectância do dossel dos cultivos (OLIVEIRA, 2019).

Jones et al. (2015) analisaram o efeito de diferentes solos, tipo de palhada e teor de umidade do solo no valor do NDVI calculado por um sensor ótico ativo de vegetação e concluíram que a variação de todos esses fatores induziu em diferenças no valor do índice. As variações foram na ordem de 15 a 35% sobre o valor calculado do NDVI, segundo os autores essa diferença significa até 500 kg na estimativa da produtividade da cultura do milho.

Gutierrez et al. (2012) estudando a associação de índices de refletância espectral com crescimento de plantas e produção de fibra em algodão, 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.

4.2. MODELO DE MONTEITH

Pelo teste de Tukey ao nível de significância de 5% (Tabela 7), as médias da produtividade estimada e observada de cada pivô apresentaram diferença significativa, pois foram maiores que a diferença média significativa (414,26 kg/ha).

Tabela 7. Comparação das médias de produtividade estimada e observada pelo teste Tukey e indicadores estatísticos da estimativa.

Produtividade (kg/ha)			
Parcela	Observada	Estimada	Diferença absoluta
Pivô 05	5.608,40	8.117,31	2.508,92
Pivô 07	4.409,12	6.510,96	2.101,83
Pivô 08	4.153,14	7.356,29	3.203,15
Pivô 10	3.857,00	6.593,13	2.736,13
Pivô 11	4.987,49	6.879,48	1.891,99
Pivô 15	4.071,07	5.690,44	1.619,37
Pivô 16	4.465,47	6.084,04	1.618,58
Pivô 17	3.894,22	7.214,07	3.319,85
Pivô 19	4.198,48	7.198,42	2.999,94
Pivô 20	5.479,06	7.734,28	2.255,22
Pivô 21	5.508,42	7.770,76	2.262,33
Pivô 22	5.418,78	7.844,41	2.425,63
Pivô 23	4.801,53	7.711,05	2.909,52
Pivô 24	5.285,28	7.571,84	2.286,56
Pivô 25	5.345,20	7.701,31	2.356,11
Pivô 26	4.911,48	7.297,22	2.385,73
Pivô 27	5.083,14	5.697,97	614,83
Pivô 28	4.522,52	6.903,16	2.380,65
Pivô 29	4.808,57	7.313,96	2.505,39
Pivô 30	5.248,15	7.511,03	2.262,88
Indicadores			
RM Média			1,497
EAM (kg ha⁻¹)			2.332,23
REQM (kg ha⁻¹)			2.405,92
d (Willmont)			0,1298
cor. Pearson (r)			0,5645

Fonte: Elaborado pelo autor, 2022. RM - Razão Média, EAM - Erro Absoluto Médio, REQM - Raiz Quadrada do quadrado médio do erro, d (Willmont) - índice de concordância de Willmott, r - coeficiente de correlação de Pearson,

O índice de concordância de Willmott (d) apresentou mal desempenho, tendo em vista que a concordância perfeita entre estimativas e dados observados é registrada com d igual a 1,0, e o valor aqui encontrado foi de 0,1298 (BORGES, et al., 2010).

O coeficiente de correlação Pearson apresentou correlação mediana com valor de 0,5645, considerado moderado de acordo com Dancey e Reidy (2006). O método não obteve desempenho satisfatório para a estimativa da produtividade do algodão, e esse resultado pode ser atribuído a extrapolação dos valores de biomassa calculados em escala diária dos índices, devido à baixa disponibilidade de imagens durante o ciclo da cultura. Como o Landsat 8 apresenta resolução temporal de 16 dias, nos meses em que apenas uma imagem estava livre de nuvens sobre a região estudada, foi necessário multiplicar o valor da biomassa por 30 dias. Desta forma, mudanças no ciclo da cultura não puderam ser identificadas, o que levou ao somatório da biomassa muito superior ao que pode ter sido registrado em campo.

He et al., (2018) usando um modelo de eficiência de uso de luz orientado por dados de satélite estimaram os rendimentos anuais de sete importantes culturas agrícolas em Montana, nos EUA, através da produtividade primária bruta (PPB). Os autores observaram que as estimativas capturaram os padrões característicos de produtividade de terras agrícolas e variações sazonais e que o desempenho dos rendimentos estimados das culturas em uma escala de campo não foi alto, mas ainda significativo r igual a 0,42. Revelaram também que os métodos e resultados são adequados para aplicações operacionais de monitoramento de produtividade de culturas em escalas regionais, sugerindo o potencial do uso de observações globais por satélite para melhorar a gestão agrícola.

Assim, apesar da superestimativa da produção apresentada pelo método de Monteith, observou-se uma correlação com a maior produtividade observada, e maior produtividade estimada evidenciando que existe uma relação entre biomassa acumulada e produção final e que o método pode ajudar a monitorar os cultivos e identificar falhas de crescimento das plantas, indicando locais com maior ou menor potencial de produção.

As Figuras 4 e 5 apresentam a variabilidade da produtividade dentro das parcelas estudadas. Observa-se na maioria dos pivôs, que em suas áreas existem diferenças bruscas no valor da produtividade, o que pode estar relacionado com a presença de sombra de nuvens nas imagens utilizadas para o mapeamento.

Figura 4. Mapeamento da produtividade em quilogramas por hectares nas parcelas estudadas.

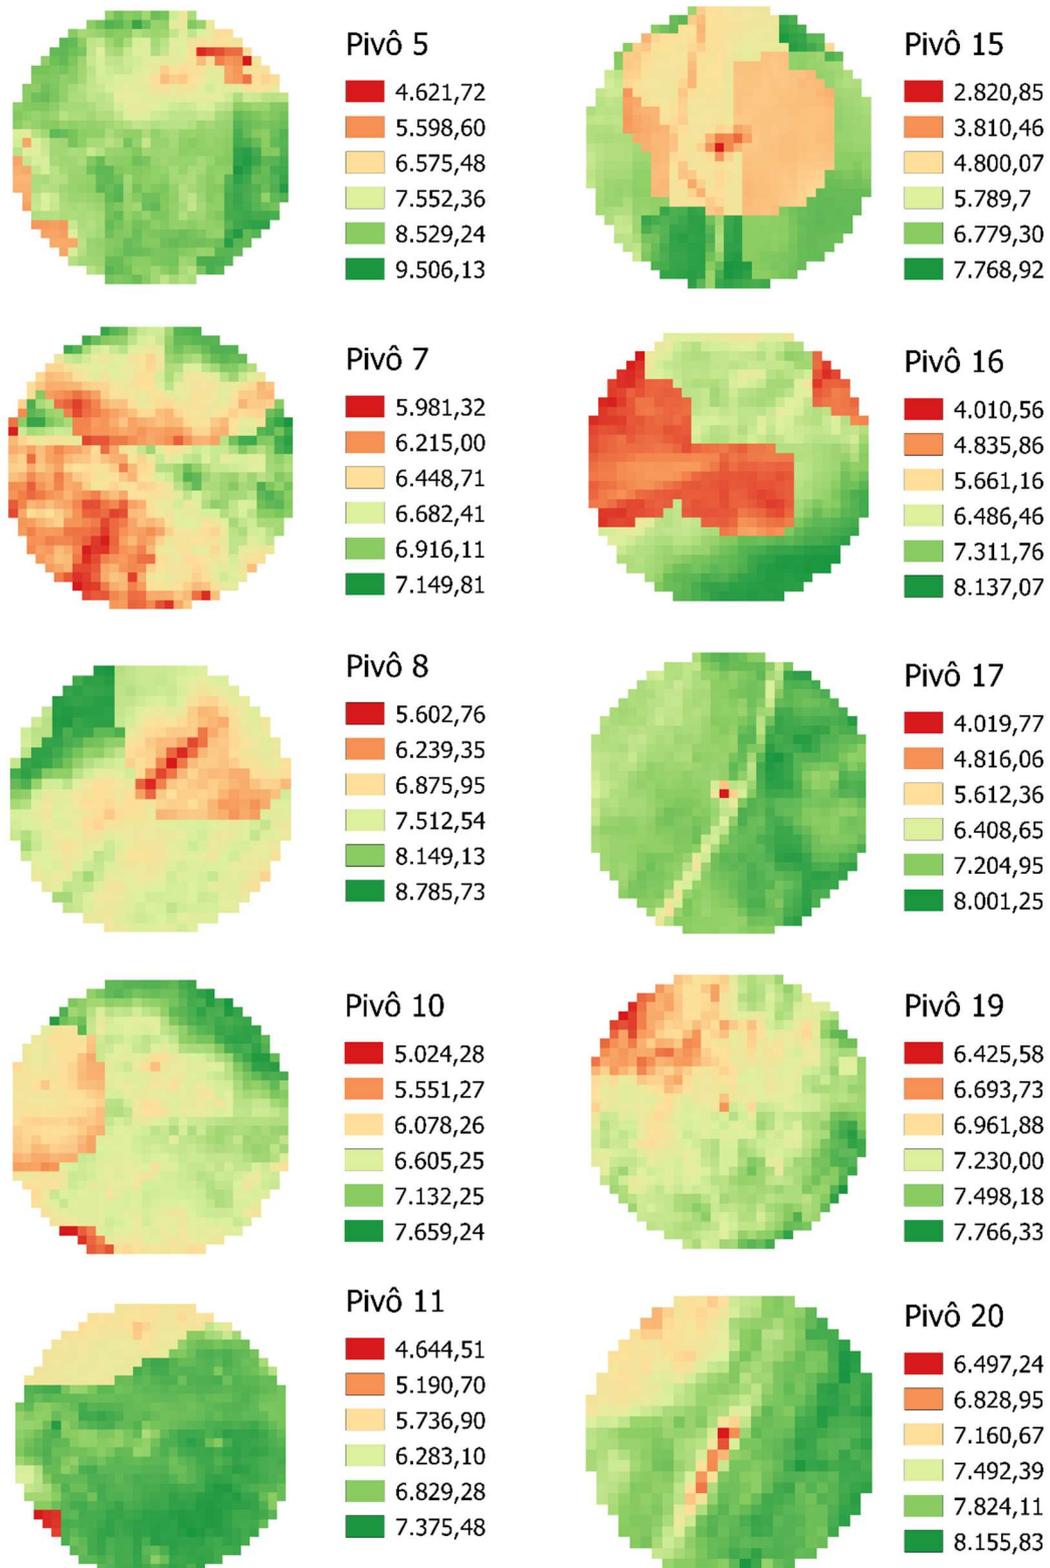
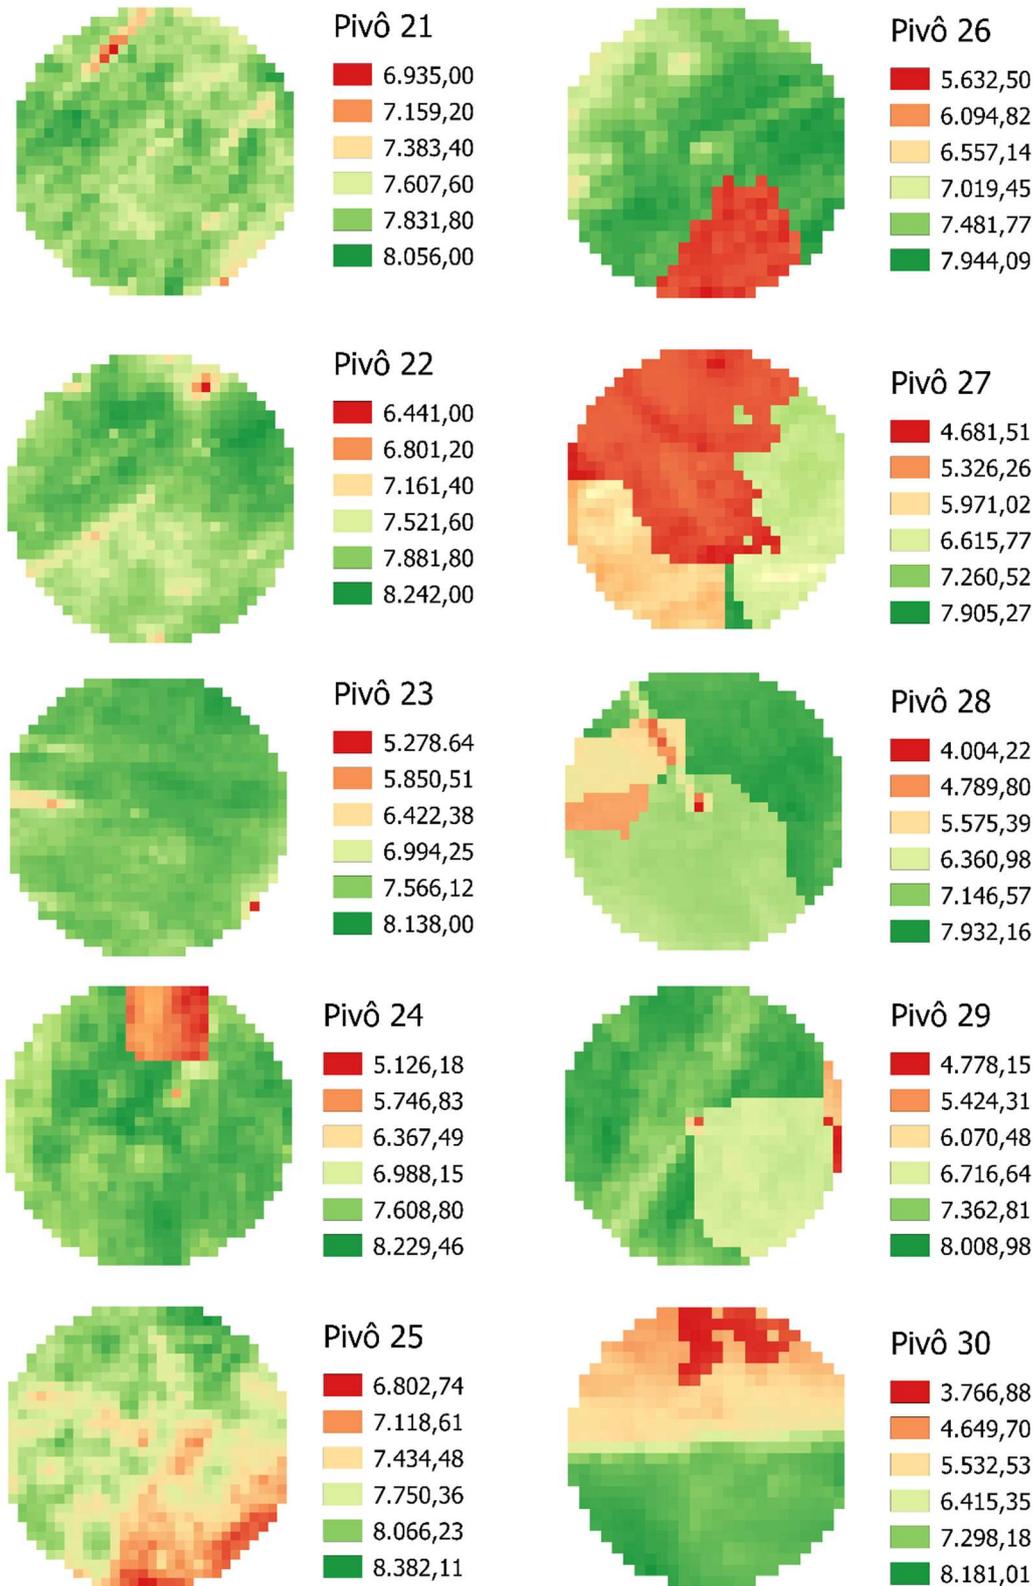


Figura 5. Mapeamento da produtividade em quilogramas por hectares nas parcelas estudadas.



Silva e Liporace (2016) relataram que uma das limitações do sensoriamento orbital é que, para imagens de satélite além do problema de oclusão de feições que reduz a área útil da imagem, causado pela nuvem e pela projeção de sua sombra no terreno, existe a interferência na análise quantitativa da imagem, uma vez que os pixels interferidos por nuvem e sombra são tratados como válidos e contaminam os valores calculados.

Aboutalebi et al. (2019) avaliaram diferentes métodos para detectar sombra em imagens ópticas de alta resolução e o impacto dessas no cálculo de NDVI e evapotranspiração, e observaram que os pixels sombreados no dossel da videira levaram a diferenças significativas no NDVI e ET calculados nas áreas afetadas. Afirmaram ainda que ignorar o efeito das sombras sobre essas variáveis pode levar a resultados e conclusões tendenciosas.

Os pivôs 21, 22, e 23 não apresentaram uma possível interferência de sombras de nuvens, e dentro desses é possível observar a variabilidade na produtividade da cultura, apesar de se tratar da mesma cultivar e manejo, pode-se atribuir esse resultado a fatores que não são diagnosticados pela análise remota, mas que podem ter influenciado na produção do algodão em caroço, de forma que, os métodos que consideram índices de vegetação não conseguem prever com boa acurácia a produção.

Segundo Vian et al., (2016) analisar a variabilidade espacial da produtividade de uma área agrícola é fundamental para o entendimento dos fatores que determinam a expressão do potencial produtivo da cultura, esta variabilidade pode estar associada a uma série de fatores que interagem de forma complexa e condicionam a expressão da cultura, como a situação nutricional do solo e a fitossanidade. Bernadi et al., (2014) utilizaram imagens do satélite Landsat 5 para calcular os parâmetros biofísicos de superfície e realizar o mapeamento da variabilidade espacial da cultura do sorgo e concluíram que sensoriamento remoto orbital tem grande utilidade para tal fim, e potencial para aplicação na agricultura de precisão.

A relação entre biomassa e produtividade do algodão é mais complicada em comparação com outras culturas pois quando não existe equilíbrio entre o crescimento vegetativo e crescimento reprodutivo isso afeta significativamente a produção da cultura (Gutierrez et al., 2012).

5. CONSIDERAÇÕES FINAIS

Os modelos gerados a partir de índices de vegetação apresentaram desempenho mediano para estimar a produtividade, apesar das médias entre produção estimada e medida terem sido consideradas estatisticamente iguais.

O método de Monteith não apresentou boa acurácia na estimativa, mesmo apresentando correlação com a produtividade medida a campo, o que pode estar relacionado à disponibilidade das imagens devido à presença de nuvens sobre a área de estudo.

O mapeamento e a análise da variabilidade da produção nas parcelas estudadas foram afetados pela sombra de nuvens em grande parte dos pivôs. Nos que foram possíveis realizar tais ações, observou-se que existe variabilidade na produção que pode estar relacionada com a situação nutricional do solo e a fitossanidade.

REFERÊNCIAS

- ABOUTALEBI, M.; TORRES-RUA, A. F.; KUSTAS, W. P.; NIETO, H.; COOPMANS, C.; MCKEE, M. Assessment of different methods for shadow detection in high-resolution optical imagery and evaluation of shadow impact on calculation of NDVI, and evapotranspiration. **Irrigation Science** (2019) 37:407–429
<https://doi.org/10.1007/s00271-018-0613-9>
- ABRAPA. ASSOCIAÇÃO BRASILEIRA DOS PRODUTORES DE ALGODÃO. **Algodão no Brasil**. Disponível em:
 <<https://www.abrapa.com.br/Paginas/Dados/Algod%C3%A3o%20no%20Brasil.asp>>. Acesso em: 25 mai. 2022.
- AL-GAADI, K. A.; HASSABALLA, A. A.; TOLA, E.; KAYAD, A. G.; MADUGUNDU, R.; ALBLEWI, B.; ASSIRI, F. Prediction of Potato Crop Yield Using Precision Agriculture Techniques. **PLOS ONE**, v. 11, n. 9, p. e0162219, 9 set. 2016.
- ALI, H.; ABID, S. A.; AHMAD, S.; SARWAR, N.; AROOJ, M.; MAHMOOD, A.; SHAHZAD, A. N. (2013a). Integrated weed management in cotton cultivated in the alternate-furrow planting system. **J Food Agri Environ** 11(3&4):1664–1669
- ALI, H.; ABID, S. A.; AHMAD, S.; SARWAR, N.; AROOJ, M.; MAHMOOD, A.; SHAHZAD, A. N. (2013b). Impact of integrated weed management on flat-sown cotton (*Gossypium hirsutum* L.). **J Anim Plant Sci** 23 (4):1185–1192
- ALI, H.; AFZAL, M. N.; AHMAD, F.; AHMAD, S.; AKHTAR, M.; ATIF, R. (2011). Effect of sowing dates, plant spacing and nitrogen application on growth and productivity on cotton crop. **Int J Sci Eng Res** 2 (9):1–6
- ALI, H.; HAMEED, R. A.; AHMAD, S.; SHAHZAD, A. N.; SARWAR, N. (2014a). Efficacy of different techniques of nitrogen application on American cotton under semi-arid conditions. **J Food Agric Environ** 12 (1):157–160
- ALI, H.; HUSSAIN, G. S.; HUSSAIN, S.; SHAHZAD, A. N.; AHMAD, S.; JAVEED, H. M. R.; SARWAR, N. (2014b). Early sowing reduces cotton leaf curl virus occurrence and improves cotton productivity. **Cercetări Agronomice în Moldova XLVII** (4):71–81
- ALLEN, R. G., PEREIRA, L. S., RAES, D., SMITH, M., 1998. **Crop evapotranspiration. Guidelines for computing crop water requirements**. FAO Irrigation and Drainage Paper 56, Roma, 300 p
- BASTIAANSEN, W. G. M.; ALLI, S. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin Pakistan. **Agriculture Ecosystems e Environment**, v 94, p. 321-340, 2003.
- BERNADI, A. C. C.; RABELLO, L. M.; INAMASU, R. Y.; GREGO, C. R.; ANDRADE, R. G. Variabilidade espacial de parâmetros físico-químicas do solo e biofísicos de superfície em cultivo do sorgo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.18, n.6, p.623–630, 2014.
- BERTOLIN, N. O.; FILGUEIRAS, R.; VENANCIO, L. P.; MANTOVANI, E. C. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Rev. Bras. Agric. Irr.** v. 11, nº 4, Fortaleza, p. 1627 - 1638, jul - Ago, 2017.

BORGES, V. P.; OLIVEIRA, A. S.; COELHO FILHO, M. A.; SILVA, T. S. M.; PAMPONET, B. M. Avaliação de modelos de estimativa da radiação solar incidente em Cruz das Almas, Bahia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, p.74-80, 2010.

BRANDAO, Z. N.; ZONTA, J. H.; SHIRATSUCHI, L. S. Sensoriamento remoto na cultura do algodão. *In*: TULLIO, L. (Org.). **Aplicações e princípios do sensoriamento remoto**. Ponta Grossa: Atena Ed., 2018. cap. 19, p. 209-224.

CAMPILLO, C.; FORTES, R.; PRIETO, M. H. (2012). Solar Radiation Effect on Crop Production. *In*: Prof. Elisha B. Babatunde (Ed.) **Solar Radiation**, ISBN: 978-953-51-0384-4, InTech. Disponível em: <http://www.intechopen.com/books/solar-radiation/solar-radiation-effect-on-crop-production>.

CARDOSO, D. B. O.; MUNDIM, F. M.; SOUSA, L. B. Variabilidade genética e coeficiente de determinação em genótipos de algodoeiro quanto a qualidade da fibra. **Revista Verde**. Pombal, v. 10, n. 3, p 66 71, jul.- set. 2015.

CHIAVEGATO, E. J.; SALVATIERRA, D. K.; GOTTARDO, L. C. B. Algodão. *In*: MONTEIRO, J. E. B. A. **Agrometeorologia dos Cultivos: o fator meteorológico na produção agrícola**. Parte II – Cultivos Temporários. Brasília – DF. Cap 2. p. 33 - 49, 2009.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Boletim Monitoramento Agrícola**, Brasília, v. 09, n. 7, Jul, 2020, p. 1-19.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da Safra Brasileira de Grãos**, Brasília, DF, v. 7, safra 2019/20, n. 12 décimo segundo levantamento, setembro. 2021.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da Safra Brasileira de Grãos**, Brasília, DF, v. 9, safra 2021/22, n. 8 oitavo levantamento, mai. 2022.

DALMAGO, G. A.; CUNHA, G. R.; TOMM, G. O.; SANTI, A.; PIRES, J. L. F. CANOLA. *In*: MONTEIRO, J. E. B. A. **Agrometeorologia dos Cultivos: o fator meteorológico na produção agrícola**. Parte II – Cultivos Temporários. Brasília – DF. Cap 8. p. 131 – 149, 2009.

DANCEY, C.; REIDY, J. Estatística sem matemática para psicologia: usando SPSS para Windows. Porto Alegre. **Artmed**. 2006.

DOORENBOSS, J.; KASSAN, A. H. Efeito da água no rendimento das culturas. Campina Grande: UFPB, 2000. 306p. (**Estudos FAO: Irrigação e Drenagem, 33**).

EMBRAPA ALGODÃO. Cultivo do Algodão Irrigado. Sistema de Produção. 3ª edição. **Versão Eletrônica**. jul. 2014. Disponível em: https://www.spo.cnptia.embrapa.br/conteudo?p_p_id=conteudoportlet_WAR_sistema_sdeproducaoif6_1ga1ceportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&p_r_p_-76293187_sistemaProducaoid=7717&p_r_p_-996514994_topicoid=7983. Acesso em: 31 mai. 2022.

ENGESAT. **Sentinel-2**. Disponível em: <http://www.engesat.com.br/sentinel-2/> Acesso em: 20 mai. 2022.

ESA. **Sentinel-2**. Disponível em:

<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. Acesso em: 25 mai. 2022.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. São Paulo, SP. 2017.

GASPARIN, P. P. **Análise da variabilidade agrometeorológica e espectral associada ao ciclo da soja e estimativa da produtividade com imagens de satélites**. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel, 2021.

GOBBO, S.; LO PRESTI, S.; MARTELLO, M.; PANUNZI, L.; BERTI, A.; MORARI, F. Integrating SEBAL with in-Field Crop Water Status Measurement for Precision Irrigation Applications—A Case Study. **Remote Sensing**, v.11, n.17, p.2069, 2019. <https://doi.org/10.3390/rs11172069>.

GONIAS, E. D.; OOSTERHIUS, D. M.; BIBI, A. C.; ROBERTS, B. A. Radiation Use Efficiency of Cotton in Contrasting Environments. **American Journal of Plant Sciences**, Vol. 3 No. 5, 2012, pp. 649-654. DOI: 10.4236/ajps.2012.35079.

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.

HE, M.; KIMBALL, J. S.; MANETA, M. P.; MAXWELL, B. D.; MORENO, A.; BEGUERÍA, S.; WU, X. Regional Crop Gross Primary Productivity and Yield Estimation Using Fused Landsat-MODIS Data. **Remote Sensing**, v.10, p.372, 2018. <https://doi.org/10.3390/rs10030372>

HUANG, Y; THOMSON, S. J. (2015). Remote Sensing for Cotton Farming. Guilford Road, Madison, WI 53711, USA. Cotton. 2nd. ed. David D. Fang and Richard G. Percy, editors. **Agronomy Monograph** 57. doi:10.2134/agronmonogr57.2013.0030

HUETE, A. R. A soil-adjusted vegetation index (savi). **Remote sensing of environment, Elsevier**, v. 25, n. 3, p. 295–309, 1988.

HUETE, A.R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v.59, p.440-451, 1997.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Levantamento Sistemático da Produção Agrícola**. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9201-levantamento-sistematico-da-producao-agricola.html?=&t=conceitos-e-metodos>. Acesso em: 31 mai. 2022.

INMET. **Normais Climatológicas do Brasil**, 2021. Disponível em: <https://portal.inmet.gov.br/normais> . Acesso em 22 dez. 2021.

IQBAL, M.; KHAN, M. A.; CHATTHA, W. S. (2020). Developing short-season cotton genotypes with high harvest index might be an advantageous option under late duration plantings. **Plant Genetic Resources: Characterization and Utilization**, (), 1–6. doi:10.1017/S1479262120000106

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.

LAIPELT, L. et al. Long-term monitoring of evapotranspiration using the SEBAL algorithm and Google Earth Engine cloud computing, *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 178, 2021, p. 81-96, 2021. DOI: <https://doi.org/10.1016/j.isprsjprs.2021.05.018>.

LAURENTINO, M. L. S.; SILVA, H. A.; SILVA, J. C. B.; SANTANA, S. H. C.; MORAIS, Y. C. B.; GALVINCIO, J. D. Aplicação dos índices de NDVI e EVI como análise da variação fisionômica da vegetação no Brejo de Altitude de Serra Negra-Bezerros/PE-Brasil. *In: Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.3182.

LEDA, V. C. **Modelagem da produtividade de cana-de-açúcar utilizando índices de vegetação**. 2016. Dissertação (Mestrado em Agronomia). Faculdade de Ciências Agrônomicas da Universidade Estadual Paulista “Júlio De Mesquita Filho, Botucatu, São Paulo, 2016.

LIU, H.; DAHLGREN, R. A.; LARSEN, R. E.; DEVINE, S. M.; ROCHE, L. M.; O’GEEN, A. T.; WONG, A. J. Y.; COVELLO, S.; JIN, Y. Estimating Rangeland Forage Production Using Remote Sensing Data from a Small Unmanned Aerial System (sUAS) and PlanetScope Satellite. *Remote Sensing*, v.11, p.595, 2019. <https://doi.org/10.3390/rs11050595>

LIU, W. T. H. **Aplicações de sensoriamento remoto**. 2. ed. Campo Grande, MS. 908 p. 2015.

LOBO, F. L. **Introdução ao Google Earth Engine**. Universidade federal de Pelotas, 2020. Apostila.

MARIN, F. R. **Previsão de safras** – Agência Embrapa de Informação Tecnológica, 2020. Disponível em: <http://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_65_22122006154840.html>. Acesso em: 20 mai. 2022.

MENESES, P. R.; ALMEIDA, T.; ROSA, A. N. C. S.; SANO, E. E.; SOUZA, E. B.; BAPTISTA, G. M. M.; BRITES, R. S. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB/CNPq, 2012.

MESHESHA, D. T., AHMED, M M., ABDI, D. Y., HAREGEWEYN, N. Prediction of grass biomass from satellite imagery in Somali regional state, eastern Ethiopia. *Helyon*, v. 6, p. 5272, 2020. <https://doi.org/10.1016/j.heliyon.2020.e05272>

MONTEITH, J. L. Climate and the efficiency of crop production in Britain. *Proceedings of the Royal Society of London*, London, v. 281, p. 277-294, 1977. Disponível em: <https://doi.org/10.1098/rstb.1977.0140>.

MONTEITH, J. L. Solar radiation and productivity in tropical ecosystems. *Journal of Applied Ecology*, Oxford, v. 9, n. 3, p. 747–766, 1972.

MOREIRA, D. S. S. **Monitoramento de Áreas de Cana-de-Açúcar por Sensoriamento Remoto**. Trabalho de Conclusão de Curso (Graduação em Agronomia). Universidade de Brasília, Faculdade UnB Gama, Brasília, DF, 2019.

MOSLEH, M. K.; HASSAN, Q. K.; CHOWDHURY, E. H. Development of a remote sensing-based rice yield forecasting model. *Spanish Journal of Agricultural Research*, v. 14, n. 3, p. 0907, 31 ago. 2016.

MUNIR, H.; RASUL, F.; AHMAD, A.; SAJID, M.; AYUB, S.; ARIF, M.; IQBAL, P.; KHAN, Amna.; FÁTIMA, Z.; AHMAD, S.; KHAN, Azam. Diverse Uses of Cotton: From Products to Byproducts. *In*: AHMAD, Shakeel; HASANUZZAMAN, Mirza. **Cotton Production and Uses: Agronomy, Crop Protection, and Postharvest Technologies**. Cingapura. 2020. p. 629 - 641.

NASA, 2022. **Landsat 8**. Disponível em: <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>. Acesso em: 15 mai.2022.

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

OLIVEIRA, R. F. **Estimativa da produtividade do algodoeiro a partir de índices de vegetação derivados de imagens orbitais de alta resolução espacial**. 2019. Dissertação (Mestrado em Sensoriamento Remoto). Programa de Pós-Graduação em Sensoriamento Remoto, Centro Estadual De Pesquisas Em Sensoriamento Remoto E Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

PATEL, N. R.; DADHWAL, V. K.; SAHA, S. K.; GARG, A.; SHARMA, N. Evaluation of Modis data potential to infer water stress for wheat NPP estimation. **Topical Ecology**, v.51, p.93-105, 2010.

PEREIRA, A. R.; MACHADO, E. C. Análise quantitativa do crescimento de comunidades vegetais. Campinas: Instituto Agronômico de Campinas, 1987. 1 v. (**Boletim técnico, 114**).

PONZONI, F. J.; SHIMABUKURO, Y. E.; KULPICH, T. M. **Sensoriamento Remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012.

POTTER, C. S.; RANDERSON, J. T.; FIELD, C. B.; MATSON, P. A.; VITOUSEK, P. M.; MOONEY, H. A.; KLOOSTER, S. A. Terrestrial ecosystem production: a process model based on global satellite and surface data. **Global Biogeochemical Cycles**, Washington, DC, v. 7, n. 4, p. 811- 841, 1993.

QUIAN, L.; CHEN, X.; WANG, X.; HUANG, S.; LUO, Y. The Effects of Flood, Drought, and Flood Followed by Drought on Yield in Cotton. **Agronomy** .2020, 10, 555; DOI:10.3390/agronomy10040555

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 SP351, NASA, Washignton, DC, v. 1, p. 309-317, 1973.

SARMIENTO, C. M.; COLTRI, P. P.; ALVES, M. C.; CARVALHO, L. G. Um modelo agrometeorológico espectral para estimar a produtividade de grãos de soja em Mato Grosso, Brasil. **Engenharia Agrícola**. 40: 405-412, 2020.

SEI, 2021. **Tipologia Climática Koppen**. Disponível em: http://www.sei.ba.gov.br/site/geoambientais/mapas/pdf/tipologia_climatica_segundo_koppen_2014.pdf. Acesso em: maio/2021.

SEVERINO, L. S.; RODRIGUES, S. M. M.; CHITARRA, L. G.; FILHO, J. L.; CONTINI, E.; MOTA, M.; MARRA, R.; ARAUJO, A. Produto: Algodão – Parte 01: Caracterização e Desafios Tecnológicos. **Série desafios do agronegócio Brasileiro (NT3)**. EMBRAPA. 2019.

SHAMMI, S. A.; MENG, Q. Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. **Ecological Indicators**, v. 121, p. 107124, 1 fev. 2021.

SILVA, A. S. D.; COSTA, M. A.; MOURA, G. B. A.; LOPES, P. M. O.; GUIMARÃES, M. J. M.; GOMES, A. W. A. Agrometeorological-spectral model for estimating sugarcane productivity in brazilian semi-arid. **Irriga, Botucatu**, v. 26, n. 3, p. 490–506, 2021. DOI: 10.15809/irriga.2021v26n3p490-506. Disponível em: <https://irriga.fca.unesp.br/index.php/irriga/article/view/4454>. Acesso em: 3 jun. 2022.

SILVA, M. A.; LIPORACE, F. S. Detecção automática de nuvem e sombra de nuvem em imagens de sensoriamento remoto. **Bol. Ciênc. Geod.**, Curitiba, v. 22, n 2, p.369-388, abr - jun, 2016. DOI: <http://dx.doi.org/10.1590/S1982-21702016000200021>.

TAO, F.; YOKOZAWA, M.; ZHANG, Z.; XU, Y.; HAYASHI, Y. Remote sensing of crop production in China by production efficiency models: models comparisons, estimates and uncertainties. **Ecological Modelling**, v.183, p.385-396, 2005.

VASCONCELOS, U. A. A.; CALVACANTI, J. J. V.; FARIAS, F. J. C.; VASCONCELOS, W. S.; SANTOS, R. C. Diallel analysis in cotton (*Gossypium hirsutum* L.) for water stress tolerance. *Crop Breeding and Applied Biotechnology*. 18. 24-30. DOI: <http://dx.doi.org/10.1590/1984-70332018v18n1a4>.

VENANCIO, L. P.; MANTOVANI, E. C.; FILGUEIRAS, R.; AMARAL, C. H. **Biomassa e produtividade de grãos na cultura do milho irrigado por meio do NDVI acumulado**. 2019. DOI: 10.13140/RG.2.2.29771.64802

VIAN, A. L.; SANTI, A. L.; AMADO, T. J. C.; CHERUBIN, M. R.; SIMON, D. H.; DAMIAN, J. M.; BREDEMEIER, C. Variabilidade espacial da produtividade de milho irrigado e sua correlação com variáveis explicativas de planta. **Ciência Rural, Santa Maria**, v.46, n.3, p.464-471, mar, 2016. DOI: <http://dx.doi.org/10.1590/0103-8478cr20150539>

YANG, Y.; ANDERSON, M. C.; GAO, F.; JOHNSON, D. M.; YANG, Yun.; SUN, L.; DULANEY, W.; HAIN, C. R.; OTKIN, J. A., PRUEGER, J.; MEYERS, T. P.; BERNACCHI, C. J.; MOORE, C. E. Phenological corrections to a field-scale, ET-based crop stress indicator: An application to yield forecasting across the U.S. Corn Belt. **Remote Sensing of Environment**, v. 257, p. 112337, 1 mai. 2021.