



GABRIELLY CARVALHO DE SOUZA

**ANÁLISE DE DISCREPÂNCIAS ENTRE VIGOR
VEGETATIVO E PRODUTIVIDADE DE GRÃOS DE MILHO
COM ABORDAGEM MULTISENSOR**

**LAVRAS – MG
2023**

GABRIELLY CARVALHO DE SOUZA

**ANÁLISE DE DISCREPÂNCIAS ENTRE VIGOR VEGETATIVO E
PRODUTIVIDADE DE GRÃOS DE MILHO COM ABORDAGEM MULTISENSOR**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para a obtenção do título de Mestre.

Prof. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS – MG
2023**

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

Souza, Gabrielly Carvalho.

Análise de discrepâncias entre vigor vegetativo e produtividade de grãos de milho com abordagem multisensor / Gabrielly Carvalho Souza. - 2023.

24 p. : il.

Orientador(a): Marcelo Carvalho Alves.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2023.

Bibliografia.

1. Sensoriamento remoto. 2. Agricultura de precisão. 3. Índices de vegetação. I. Alves, Marcelo Carvalho. II. Título.

GABRIELLY CARVALHO DE SOUZA


**ANÁLISE DE DISCREPÂNCIAS ENTRE VIGOR VEGETATIVO E
PRODUTIVIDADE DE GRÃOS DE MILHO COM ABORDAGEM MULTISENSOR**

**ANALYSIS OF DISCREPANCIES BETWEEN VEGETATIVE VIGOR AND CORN
GRAIN YIELD WITH A MULTISENSOR APPROACH**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para a obtenção do título de Mestre.

APROVADA em 28 de Fevereiro de 2023.

Prof. Dr. Rafael Noetzold UNEMAT
Prof. Dr. José Sérgio de Araújo IFSM

Documento assinado digitalmente
 MARCELO DE CARVALHO ALVES
Data: 10/01/2024 14:43:30-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS – MG
2023**

Aos meus pais Rozimeire e Cezaro (In memoriam)
DEDICO.

AGRADECIMENTOS

Agradeço a Deus por sempre me amparar e me proteger.

Agradeço a minha família, por confiarem em mim e me incentivarem a não desistir diante das minhas falhas. Em especial à minha mãe, Rozimeire, por todos os dias me colocar em suas orações e pela motivação perante as dificuldades deste trabalho.

Ao meu orientador, Prof^o. Dr. Marcelo de Carvalho Alves e seu mestrando Flávio Vannoni de Carvalho Júnior, por tudo que me ensinou, pelas oportunidades que me proporcionou, pela amizade e por ter acompanhado minha trajetória, sempre com muita paciência, simplicidade, humildade e humor.

À Universidade Federal de Lavras e ao Departamento de Engenharia Agrícola pela concretização desse sonho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

*Aquele que tentou e não conseguiu é superior àquele que nada tentou.
(Arquimedes de Siracusa)*

RESUMO

Imagens provenientes de sensores acoplados em satélites permitem análises de lavouras a baixo custo e têm sido alvo de estudos de correlação entre índices de vegetação e a produtividade. Os índices de vegetação obtidos a partir de plataforma orbital e mapas de colheita tem sido importantes ferramentas no contexto da popularização da agricultura de precisão. No entanto, são muitos os fatores que interferem na produtividade do milho e nos consequentes mapas de colheita obtidos. Com isso, nem sempre é obtida correlação entre índices de vegetação e produtividade. Tal fato abre espaço para metodologias de se identificar áreas de não correlação e investigar direcionadamente as possíveis causas. Diante o exposto, teve-se por objetivo utilizar imagens de satélite disponíveis gratuitamente, atrelada a dados de produtividade de colhedora de milho com intuito de se identificar áreas onde houve e não houve correlação da produtividade em função dos índices de vegetação. Nas áreas com correlação, foi obtido o modelo linear da produtividade em função do NDVI. Calculou-se um mapa de discrepâncias, em que na maior parte da lavoura houve correlação, com produtividade variando em torno de 2 ton ha^{-1} em relação ao modelo. Foram identificadas áreas com produtividades discrepantes, negativamente e positivamente em relação ao modelo, permitindo uma investigação localizada das possíveis causas do fenômeno.

Palavras-chave: Sensoriamento remoto. Agricultura de precisão. Sentinel-2. Landsat-8. Índices de vegetação.

ABSTRACT

Imagery from sensors embedded in satellites enables low-cost crop analysis and has been the subject of correlation studies between vegetation indices and productivity. Vegetation indices obtained from orbital platforms and crop maps have been important tools in the context of popularizing precision agriculture. However, there are many factors that affect maize yields and the resulting harvest maps. As a result, correlations between vegetation indices and yields are not always obtained. This leaves a gap for methodologies to identify areas of non-correlation and investigate the possible causes in a targeted manner. The aim of this study was to use freely available satellite images, together with yield data from a maize harvester, to identify regions with and without a correlation between yields and vegetation indices. In areas with correlation, a linear model of yield as a function of NDVI was obtained. A map of discrepancies was calculated, in which most of the crop was correlated, with yields varying by around 2 ton ha^{-1} in relation to the model. Areas with discrepant yields were identified, both negatively and positively in relation to the model, enabling a localized investigation into the possible causes of the phenomenon and crop management.

Keywords: Remote sensing. Precision agriculture. Sentinel-2. Landsat-8. Vegetation index.

LISTA DE FIGURAS

Figura 3.1 – Localização da área de estudo: composição natural RGB 10 m (Sentinel-2).	14
Figura 4.1 – Índices de vegetação e mapa de produtividade ($ton\ ha^{-1}$).	17
Figura 4.2 – Polígonos de correlação sobre mapa de produtividade.	18
Figura 4.3 – Análise de regressão do NDVI em função da produtividade nos polígonos de correlação.	18
Figura 4.4 – Variação entre a produtividade mensurada e o modelo ($ton\ ha^{-1}$).	19

LISTA DE TABELAS

Tabela 3.1 – Variáveis operacionais da colhedora.....	15
Tabela 4.1 – Estatísticas descritivas para variações entre produtividade e modelo.....	19

SUMÁRIO

1	INTRODUÇÃO	10
2	REFERENCIAL TEÓRICO	12
3	MATERIAL E MÉTODOS	14
3.1	Caracterização da área de estudo	14
3.2	Dados de colheita e mapa de produtividade	14
3.3	Índices de vegetação	15
3.4	Análises de correlação e discrepâncias	16
4	RESULTADOS	17
4.1	Índices de vegetação e mapa de colheita	17
4.2	Delimitação de polígonos de correlação	17
4.3	Aplicação do modelo e mapa de discrepâncias	18
5	DISCUSSÃO	20
5.1	Análise de correlação	20
5.2	Mapa de divergências	20
6	CONSIDERAÇÕES FINAIS	22
	REFERÊNCIAS	23

1 INTRODUÇÃO

É inegável a importância do milho (*Zea mays* L.) para a agricultura brasileira e mundial. É uma das plantas mais cultivadas globalmente, utilizada principalmente para consumo humano e animal. O Brasil figura entre os três maiores produtores e exportadores de milho, evidenciando não apenas a importância econômica da cultura no país mas a contribuição para a segurança alimentar mundial.

Diante do aumento da demanda global por alimentos e ao mesmo tempo o necessário avanço da agricultura sustentável, há a necessidade de aumento na produtividade e redução do uso de insumos. Nesse contexto a agricultura de precisão (AP) surge como ferramenta para o manejo da variabilidade presente nas lavouras, permitindo ganhos em produtividade, uso racional dos insumos e conseqüentemente melhores retornos financeiros ao produtor.

Os mapas de produtividade são uma das fontes mais completas de informações sobre a variabilidade em uma lavoura. Para elaboração dos mesmos é necessário que a colhedora possua a tecnologia necessária, como sensor de produtividade, sensor de umidade, sistema de posicionamento por satélite e registro de dados pelo monitor de produtividade. Com isso, esses dados podem ser utilizados na elaboração de superfícies contínuas que permitem a visualização da variabilidade, além de diversas operações e análises que podem ser conduzidas.

Os índices de vegetação têm sido amplamente utilizados como forma de avaliar o vigor vegetativo no contexto do sensoriamento remoto. Esses índices têm sido correlacionados com a produtividade de lavouras, apresentando potencial para captar efeitos de variabilidade na área que afetem a produção. Imagens de satélite gratuitas e ambiente de programação livre em linha de comando como o R, contribuem com a popularização da agricultura de precisão, garantindo a reprodutibilidade dos trabalhos.

No entanto, nem sempre é obtida correlação satisfatória entre o vigor vegetativo reportado pelos índices de vegetação e a produtividade. Diversas são as causas possíveis de tal fato, como erros nos dados provenientes da colhedora e fatores não relacionados com o vigor vegetativo. O ataque tardio por pragas e doenças, em época posterior à obtenção das imagens, consumo da produção por agentes externos são alguns exemplos que podem causar perda de produtividade não identificada através de índices de vegetação.

Diante o exposto, tem-se por objetivo avaliar a correlação entre índices de vegetação calculados a partir de imagens de satélite e a distribuição espacial da produtividade de milho, definido as áreas onde há ou não correlação e com isso elaborar um mapa de discrepâncias,

de modo a permitir identificar zonas na lavoura que apresentam produtividades diferentes do esperado. Com isso espera-se fornecer subsídios para que o produtor possa atuar de maneira localizada na investigação das causas das discrepâncias.

2 REFERENCIAL TEÓRICO

Um dos maiores desafios na agricultura é a produção sustentável, seja no âmbito ambiental, social ou econômico (BASSO; ANTLE, 2020; NEVES; IMPERADOR, 2022). Com o crescente aumento da demanda por alimentos, entende-se que o avanço tecnológico nas áreas de produção eleva os ganhos em produtividade, reduzindo impactos ambientais da expansão agrícola (TILMAN et al., 2011). Para que isso seja possível é necessário o desenvolvimento de tecnologias que auxiliem na tomada de decisões de modo preciso e ágil, demandando um conjunto de informações claras que retratem a realidade do ambiente agrícola, desde a semeadura até a colheita. Neste contexto, a Agricultura de Precisão (AP) constitui um conjunto de tecnologias que permitem o manejo de cultura em pontos estratégicos, uma vez que a produtividade pode variar no âmbito espacial e temporal, reduzindo gastos com insumos e aumentando a sustentabilidade (GEBBERS; ADAMCHUK, 2010; KENDALL et al., 2022; WHELAN; MCBRATNEY, 2000).

O milho (*Zea Mays L.*) é uma importante cultura distribuída em vários países do mundo, sendo utilizado tanto como fonte de alimento quanto de matéria-prima para a indústria, como na produção de etanol de milho que vem apresentando crescimento no Brasil (YANG et al., 2021; COLUSSI et al., 2023). Atualmente o país é o terceiro maior produtor mundial e o cenário se encontra otimista para o produtor (COÊLHO, 2023). A produtividade de grãos de milho é influenciada por diversos fatores, como as condições climáticas, condições biológicas e de fertilidade do solo, além da qualidade e adaptabilidade genética das plantas (ARAÚJO et al., 2016; SHARMA et al., 2022; WADE et al., 2020). Além disso, o ataque por pragas pode levar a perda total da produção (TIMBÓ; MENEZES; LIMA, 2023). O vigor vegetativo, ou seja, a capacidade das plantas de crescer e se desenvolver, também é um importante indicador para a produtividade. A avaliação do vigor vegetativo é um desafio, pois as plantas podem apresentar diferenças visíveis apenas em estádios avançados de desenvolvimento. As técnicas tradicionais de avaliação, como a contagem de folhas ou a medição da altura da planta, exigem investigação de campo, sendo trabalhosas e subjetivas (BERTOLIN et al., 2017). A abordagem multisensor em plataforma orbital tem sido muito utilizada em estudos com intuito de quantificar índices biofísicos e o monitoramento da vegetação (SANTOS et al., 2020), permitindo o estudo de correlação entre esses índices e a produtividade de grãos (HENRIQUES et al., 2021).

Tendo em vista as inúmeras vantagens oferecidas pelos avanços da Agricultura de Precisão na operação de colheita de grãos, muitos produtores têm optado por adquirir máquinas que

já venham com um pacote completo de recursos informatizados para monitorar os mecanismos que compõem a máquina. Nas colhedoras de grãos, sensores de fluxo ou células de carga aferem a massa de grãos que passa pelo elevador condutor de grãos, que leva das trilhas ao tanque graneleiro, esses equipamentos atrelados a sistemas de posicionamento, geram o mapa de produtividade (ALBARENQUE; VÉLEZ, 2011). Este mapeamento é uma das principais fontes de informações para agricultura de precisão (MICHELAN; SOUZA; URIBE-OPAZO, 2007). Em relação aos fatores de produção, é a informação mais completa para visualizar a variabilidade espacial das lavouras (MOLIN, 2002).


Em muitos casos, a relação entre índices de vegetação e produtividade apresenta baixa correlação devido a fatores que vão além da resposta espectral captada por índices de sensoriamento remoto. Além disso, dados de produtividade provenientes de colhedoras estão sujeitos a ocorrência de erros causados pelo próprio sistema automatizado de aferição de produtividade da máquina (MENEGATTI; MOLIN, 2004; MICHELAN; SOUZA; URIBE-OPAZO, 2007). Portanto, determinar zonas onde os índices de vegetação e a produtividade são discrepantes, permite uma investigação localizada de variabilidades e ocorrência de fenômenos na área ou no equipamento que afetam a produção.

3 MATERIAL E MÉTODOS

3.1 Caracterização da área de estudo

O presente estudo foi realizado no município de Cruzília, localizado na região Sul do Estado de Minas Gerais, em lavoura situada a 21.675 graus de latitude sul e 44.765 graus de longitude oeste, representada na Figura 3.1 em projeção UTM Zona 23S. A área em estudo denominada talhão “Mata da Fazenda Cachoeira” tem aproximadamente 52.2 ha e a variedade de milho utilizada foi a 30F53 VYHR da Pioneer. A elevação na área variou aproximadamente entre 1012 m e 1097 m. A data de colheita teve início 05 de abril 2021 e foi finalizada 29 de abril 2021. Os dados de produtividade foram coletados pela colhedora de grãos modelo S760 da marca John Deere, com 325 cv de potência nominal e 10600 L de capacidade do graneleiro. Informações de trabalho e desempenho estão dispostas na Tabela 1.

Figura 3.1 – Localização da área de estudo: composição natural RGB 10 m (Sentinel-2).



Fonte: Do autor (2023).

3.2 Dados de colheita e mapa de produtividade

Para obter os dados reais de produtividade foi necessário que a colhedora John Deere estivesse acoplada com o pacote de tecnologia para agricultura de precisão e que ao iniciar a colheita o operador preenchesse os dados da operação, ou seja, a cultura, a variedade da semente, o nome do proprietário, da fazenda e do talhão. A colhedora possui vários sensores que precisam ser calibrados. O sensor da balança que registra a massa de grãos que adentra a máquina é muito sensível, e alguns fatores podem alterar o resultado gerado nos mapas de

Tabela 3.1 – Variáveis operacionais da colhedora.

Variável	Valores
Área Colhida	52.2 ha
Rendimento Líquido	11.3 ton ha ⁻¹
Peso líquido	590 ton
Umidade	19%
Rendimento Bruto	11.9 ton ha ⁻¹
Peso Bruto	619 ton
Velocidade	3.3 km h ⁻¹
Produtividade	1.7 ha h ⁻¹
Tempo de Trabalho	30 h36 min
Combustível Total	1289 L
Rendimento (Seco)	19.3 ton h ⁻¹
Rendimento (Molhado)	20237.2 kg h ⁻¹
Eficiência do Combustível	0.5 ton L ⁻¹
Combustível	24.6 L ha ⁻¹
Combustível	42 L h ⁻¹

produtividade, como a trepidação do terreno, a vibração gerada pelas peneiras, dentre outros. Calibrar a balança da colhedora é um trabalho difícil e que demanda bastante tempo, sendo assim, existe um software da John Deere que possibilita realizar a calibração após a colheita. Após finalizada a colheita, foram coletada as informações com um pendrive e inseridos no software para calibração e exportação em arquivo shapefile.

Os dados obtidos são do tipo nuvem de pontos. Os atributos utilizados foram a produtividade em $ton\ ha^{-1}$ e a umidade em base úmida dada em porcentagem. A produtividade (P) de cada ponto foi corrigida para 13% de umidade base úmida conforme Equação 3.1. Para realização das análises, a nuvem foi transformada em rasters de 10 m e de 30 m de resolução espacial com uso do pacote terra no R (HIJMANS et al., 2023) pela função rasterize de modo a permitir as comparações com os índices de vegetação. Os pixels foram compostos utilizando-se a média dos pontos de produtividade situados dentro de sua área.

$$P(13\%) = P \frac{100 - \text{Umidade}(\%)}{100 - 13} \quad (3.1)$$

3.3 Índices de vegetação

Foram obtidas imagens de reflectância de superfície da área de estudo do dia 31/01/2021 do satélite Sentinel-2 (ESA, 2023) e 04/02/2021 do satélite Landsat-8 (USGS, 2023) adquiridas no portal Copernicus Open Access Hub e Earth Explorer, respectivamente. As imagens foram

selecionadas com data de aquisição próximas e antes da colheita que teve início em 05/04/2021. As imagens do satélite Sentinel-2 possuem 10 m de resolução espacial para as bandas Red e NIR, e 20 m para a banda Red Edge 2. Já as imagens do satélite Landsat-8, possuem 30 m de resolução espacial. Todo o processamento de imagem foi executado no ambiente R.

Foram utilizados o índice de vegetação NDVI (Índice de vegetação por diferença normalizada) (Equação 3.2) (ROUSE et al., 1973) e o índice NDRE (Índice de vegetação borda do vermelho por diferença normalizada) (GITELSON; MERZLYAK, 1994). Ambos os índices foram calculados para os dados do satélite Sentinel-2 e apenas o NDVI para os dados do satélite Landsat. O satélite Sentinel-2 fornece quatro bandas de borda do vermelho em comprimentos de onda diferentes. O NDRE foi obtido pela mesma equação do NDVI, substituindo a banda Red (B04 – 665 nm) pela Red Edge 2 (B06 – 740 nm), reamostrada para 10 m de resolução por interpolação bilinear para realização do cálculo (Equação 3.3).

$$\text{NDVI} = \frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}} \quad (3.2)$$

$$\text{NDRE} = \frac{\rho_{\text{nir}} - \rho_{\text{rededge}}}{\rho_{\text{nir}} + \rho_{\text{rededge}}} \quad (3.3)$$

3.4 Análises de correlação e discrepâncias

Obteve-se a representação visual dos índices de vegetação e do raster de colheita para realização de análise visual de correlação por meio do pacote stars (PEBESMA, 2022) no R. Adotou-se a mesma paleta de cores e técnicas de geovisualização científica, identificando-se visualmente áreas que possuíam correlação entre os índices de vegetação e a produtividade.

Foram delimitados cinco polígonos em áreas que apresentaram maior correlação visual entre o NDVI e a produtividade. Realizou-se a máscara do raster de produtividade e de NDVI pelos cinco polígonos. Com isso, obteve-se o ajuste de regressão linear da produtividade em função do NDVI nas áreas delimitadas pelos cinco polígonos.

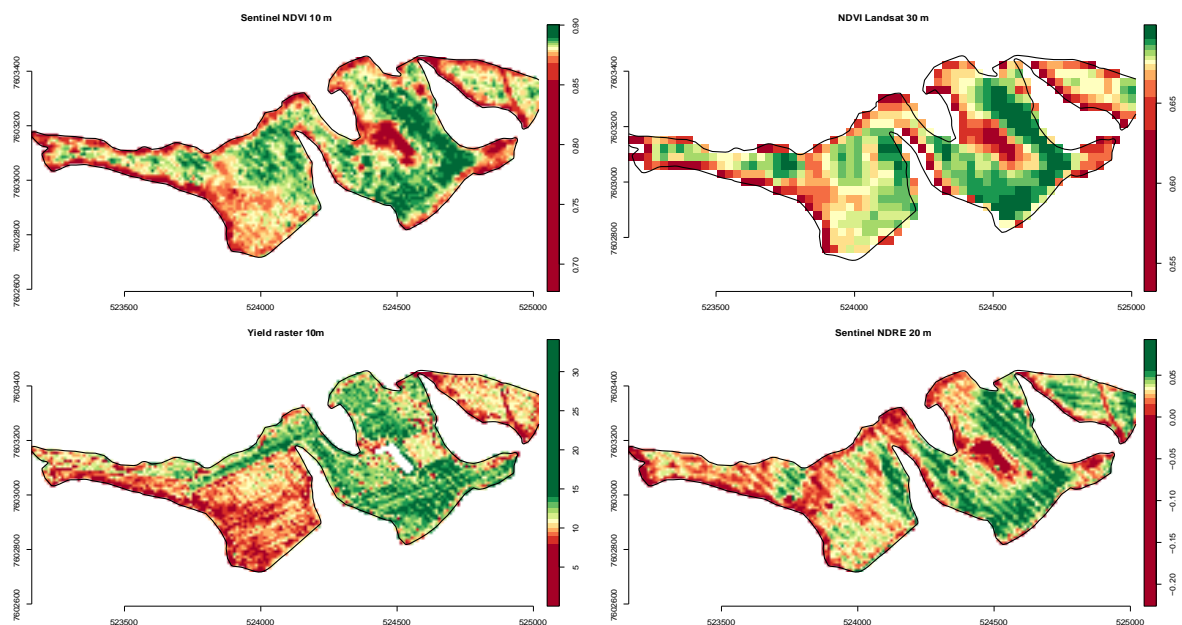
A equação obtida do modelo linear foi usada para gerar um mapa de estimativa de produtividade em função do NDVI. Através de álgebra de mapas, calculou-se a diferença entre a produtividade e o mapa de estimativa. O raster resultante foi representado de modo a permitir a visualização das zonas com discrepâncias positivas e negativas de produtividade.

4 RESULTADOS

4.1 Índices de vegetação e mapa de colheita

Os índices NDVI dos satélites Sentinel-2 e Landsat-8 estão representados na Figura 2. Ambos apresentaram distribuição espacial bastante similar na área, excetuando-se apenas pelo maior detalhamento devido a resolução espacial de 10 metros do Sentinel-2. No caso do NDRE (Figura 4.1), apesar de ser representado com 10 metros de resolução espacial, o resultado é proveniente de banda com 20 metros de resolução.

Figura 4.1 – Índices de vegetação e mapa de produtividade (ton ha^{-1}).

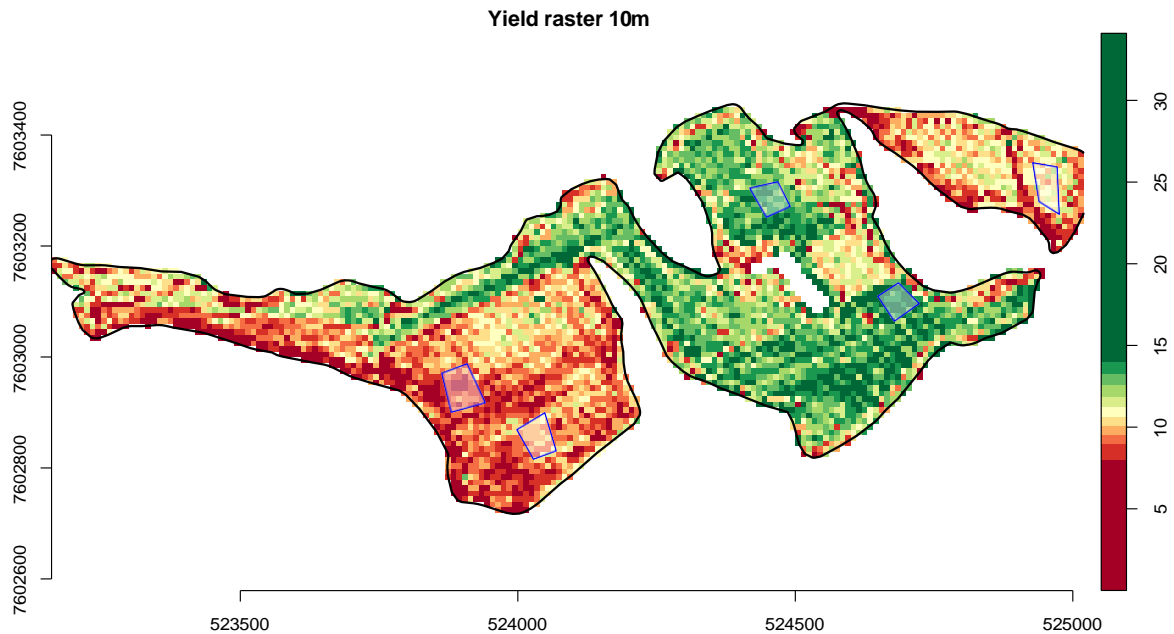


Fonte: Do autor (2023).

4.2 Delimitação de polígonos de correlação


Na Figura 4.2 estão representados os polígonos delimitados sobre o mapa de colheita, em áreas onde foi possível observar correlação visual entre a produtividade e os índices de vegetação. Cada polígono tem aproximadamente meio hectare e foram dispostos de modo a abranger todos os talhões. Os ajustes de regressão linear da produtividade em função do NDVI para os dois satélites estão dispostos na Figura 4.3. A correlação foi forte para o Sentinel-2 e moderada para o Landsat-8, com coeficiente R^2 de 0.706 e 0.588, respectivamente.

Figura 4.2 – Polígonos de correlação sobre mapa de produtividade.



Fonte: Do autor (2023).

Figura 4.3 – Análise de regressão do NDVI em função da produtividade nos polígonos de correlação.



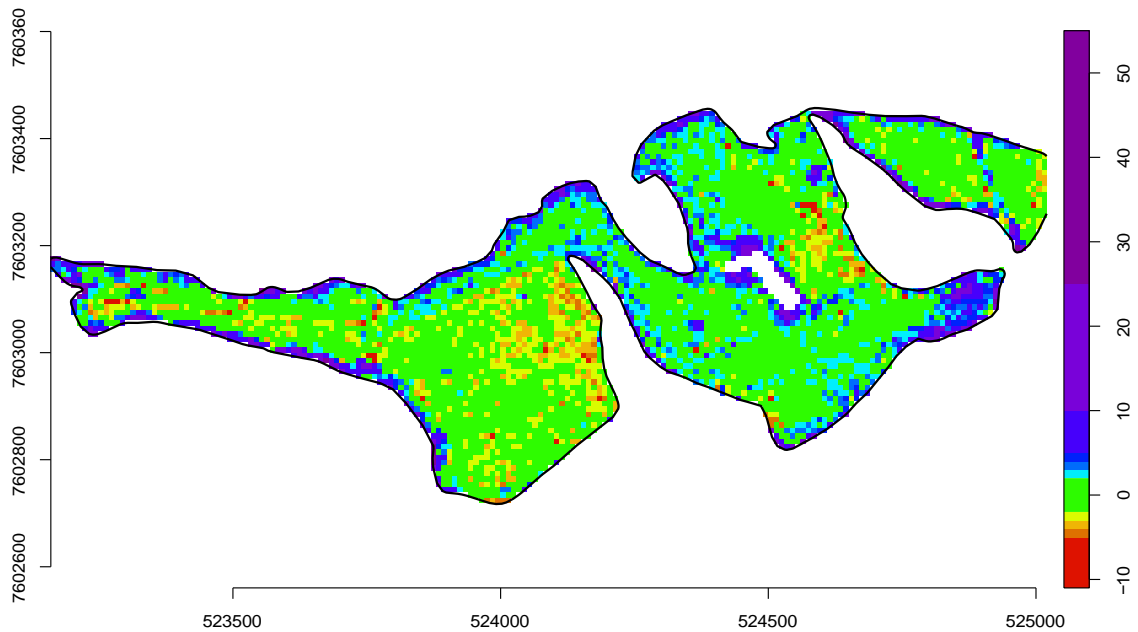
Fonte: Do autor (2023).

4.3 Aplicação do modelo e mapa de discrepâncias

As áreas em verde da Figura 4.4 representam aquelas em que a diferença entre a produtividade e o modelo baseado em NDVI estiveram entre -2 e 2 ton ha^{-1} . Em azul claro a roxo estão as áreas em que a produtividade foi consideravelmente maior do que o modelo. Já de amarelo a vermelho são as áreas onde a produtividade contabilizada foi consideravelmente menor

do que o modelo. Algumas áreas apresentaram discrepâncias visíveis, enquanto a maior parte da área acompanhou o modelo. A média de discrepância na área foi 1.31 ton ha^{-1} positiva,

Figura 4.4 – Variação entre a produtividade mensurada e o modelo (ton ha^{-1}).



Fonte: Do autor (2023).

enquanto que 75% dos valores se situaram entre -1.13 e 2.27 ton ha^{-1} (Tabela 4.1). O desvio padrão foi de 4.13 ton ha^{-1} .

Tabela 4.1 – Estatísticas descritivas para variações entre produtividade e modelo.

Estatísticas descritivas	Valores ton ha^{-1}
Min.	-10.763
1st Qu.	-1.130
Median	0.456
Mean	1.193
3rd Qu.	2.270
Max.	50.922
NA's	8358

5 DISCUSSÃO

5.1 Análise de correlação

Algumas zonas apresentaram clara relação entre aumentos e quedas de produtividade em função do NDVI enquanto em outras não houve nenhuma relação. Os estudos envolvendo correlação entre índices de vegetação e produtividade de milho apresentam resultados bastante variados. Isso se deve ao fato de que muitos fatores podem interferir na produtividade além da biomassa verde, como condições de nutrição vegetal, ataque de pragas e o consumo da produção pela fauna local. Em se tratando de milho safrinha, há maior suscetibilidade ao ataque por pragas em relação à primeira safra, principalmente por conta das condições climáticas. Há de se pontuar que o milho sofre ataques de pragas e doenças durante todo o período de desenvolvimento, da semeadura a colheita (WORDELL FILHO et al., 2016). O ataque aos grãos é uma importante causa de perdas na produção (PICANÇO et al., 2003). Portanto, deve-se considerar a possibilidade de perdas por ataques de pragas na fase reprodutiva da cultura, em épocas posteriores à aquisição das imagens. Outra fonte de divergências são os erros inerentes aos dados coletados pelos sistemas automatizados das colhedoras (MENEGATTI; MOLIN, 2004).

A forte correlação obtida dentro dos polígonos delimitados mostra que de fato os índices de vegetação exercem influência na produtividade. Os melhores resultados para os dados provenientes do satélite Sentinel-2 se devem em grande parte a resolução espacial de 10 metros, promovendo um detalhamento maior da área em relação ao Landsat-8. Principalmente quando se considera o fato da área ser relativamente pequena e situada em região de relevo mais acidentado, onde as variações espaciais de atributos climáticos e de solo tendem a ser maiores. Sabe-se que em geral a temperatura varia linearmente em -0.6°C com o aumento de 100 metros na altitude (HIRASUGA; LEUNG, 2019) e que atributos do solo variam tanto na horizontal quanto na vertical (RICHTER et al., 2011).

5.2 Mapa de divergências

No mapa de discrepâncias (Figura 4.4) a maior parte da área acompanhou o modelo, porém certas zonas e pontos discrepantes espalhados pela lavoura faz com que o nível de correlação seja fortemente reduzido. A análise do mapa obtido permite investigar as áreas de divergências positivas e negativas, fornecendo subsídios para determinar possíveis causas da variabilidade e eventuais ações de correção.

Foram verificadas produtividades acima do modelo nas bordas de boa parte do perímetro da área. Uma das possíveis causas do efeito de borda pode estar relacionada com a resolução espacial das imagens de satélite que por cobrir uma área maior, acaba por captar efeitos de zonas que estão fora da área efetivamente cultivada. A presença de carreadores no meio da lavoura pode causar o mesmo efeito. Regiões que apresentaram produtividade menor que o modelo, devem ser investigadas por parte do produtor para se determinar as causas da baixa produtividade que nem sempre estão relacionadas com vigor vegetativo reportado pelos índices de vegetação.

6 CONSIDERAÇÕES FINAIS

Foi possível visualizar a variabilidade espacial do NDVI e da produtividade com os dados adotados. Foram identificadas zonas na lavoura que apresentaram forte correlação entre a produtividade de milho e o NDVI e locais específicos onde não houve correlação.

O índice NDVI a partir do Sentinel-2, com 10 metros de resolução espacial apresentou melhor desempenho para captar a variabilidade em relação ao NDVI de 30 metros do Sentinel-2 e ao NDRE calculado a partir de dados de 20 metros de resolução espacial do Sentinel-2.

O uso do modelo aplicado na elaboração do mapa de discrepâncias permitiu identificar zonas com valores divergentes em que outros fatores além vigor vegetativo captado pelo NDVI atuaram na área, bem como a incidência de erros nos dados de colheita, fornecendo subsídios para o produtor atuar de maneira localizada.

São necessários novos estudos com aplicação do método em diferentes áreas produtivas e estádios fenológicos da cultura, combinados com investigação de campo e dados climáticos de modo a identificar as causas das discrepâncias.

REFERÊNCIAS

- ALBARENQUE, S. M.; VÉLEZ, J. P. **Técnicas para el procesamiento de mapas de rendimiento**. 1st. ed. [S.l.]: Ediciones INTA, 2011.
- ARAÚJO, L. da S. et al. Desempenho agrônômico de híbridos de milho na região sudeste de goiás. **Agro@mbiente On-line**, v. 10, p. 334–341, 2016.
- BASSO, B.; ANTLE, J. Digital agriculture to design sustainable agricultural systems. **Nature Sustainability**, v. 3, p. 254–256, 2020.
- BERTOLIN, N. et al. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Revista Brasileira de Agricultura Irrigada**, v. 11, p. 1627–1638, 2017.
- COÊLHO, J. D. Agricultura: Milho. **Caderno Setorial**, v. 8, p. 1–9, 2023.
- COLUSSI, J. et al. Brazil emerges as corn-ethanol producer with expansion of second crop corn. **farmdoc daily**, v. 13, p. 1–5, 2023. Disponível em: <<https://farmdocdaily.illinois.edu/2023/06/brazil-emerges-as-corn-ethanol-producer-with-expansion-of-second-crop-corn.html>>.
- ESA, E. S. A. **Sentinel-2 Level-2**. 2023. Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/processing-levels/level-2>>. Acesso em: 2023-11-17.
- GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. **Science**, v. 327, p. 828–831, 2010.
- GITELSON, A. A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology B: Biology**, v. 22, p. 247–252, 1994.
- HENRIQUES, H. J. R. et al. Vegetation indices and their correlation with second-crop corn grain yield in mato grosso do sul, brazil. **Brazilian Journal of Maize and Sorghum**, v. 20, p. 1–13, 2021.
- HIJMANS, R. J. et al. **Package ‘terra’**. 2023. Disponível em: <<https://cran.r-project.org/web/packages/terra/terra.pdf>>.
- HIRASUGA, N.; LEUNG, L. Using computer climate generator versus conventional lapse rate to model skyscrapers. **Earth and Environmental Science**, v. 294, p. 1–10, 2019.
- KENDALL, H. et al. Precision agriculture technology adoption: a qualitative study of small-scale commercial “family farms” located in the north china plain. **Precision Agriculture**, v. 23, p. 319–351, 2022.
- MENEGATTI, L. A. A.; MOLIN, J. P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 8, p. 126–134, 2004.
- MICHELAN, R.; SOUZA, E. G. de; URIBE-OPAZO, M. A. Determinação e remoção do tempo de atraso em mapas de colheita de milho. **Acta Scientiarum. Agronomy**, v. 29, p. 147–155, 2007.
- MOLIN, J. P. Definição de unidades de manejo a partir de mapas de produtividade. **Engenharia Agrícola**, v. 22, p. 83–92, 2002.

NEVES, J. A.; IMPERADOR, A. M. The agroecological transition: challenges for sustainable agriculture. **Revista GEAMA, Scientific Journal of Environmental Sciences and Biotechnology**, v. 8, p. 5–14, 2022.

PEBESMA, E. **stars: Spatiotemporal Arrays, Raster and Vector Data Cubes**. 2022. Disponível em: <<https://r-spatial.github.io/stars/>>.

PICANÇO, M. C. et al. Intensities of losses and of insect pests attack to cultivars on the late maize cultivation. **Ciênc. agrotec.**, v. 27, p. 339–347, 2003.

RICHTER, R. L. et al. Variabilidade espacial de atributos da fertilidade de um latossolo sob plantio direto influenciados pelo relevo e profundidade de amostragem. **Enciclopédia Biosfera**, v. 7, p. 1043–1059, 2011.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with erts. In: **PROCEEDINGS OF THE 3RD. ERTS-1 SYMPOSIUM**. [S.l.]: NASA SP-351, 1973. p. 309–316.

SANTOS, R. A. dos et al. Remote sensing as a tool to determine biophysical parameters of irrigated seed corn crop. **Semina: Ciências Agrárias**, v. 41, p. 435–446, 2020.

SHARMA, R. K. et al. Impact of recent climate change on corn, rice, and wheat in southeastern usa. **Scientific Reports**, v. 12, p. 1–14, 2022.

TILMAN, D. et al. Global food demand and the sustainable intensification of agriculture. **PNAS**, v. 108, p. 20260–20264, 2011.

TIMBÓ, F. V. A. M.; MENEZES, T. A.; LIMA, R. P. Main pests that affect corn crops. **Revista Foco**, v. 16, p. 1–17, 2023.

USGS. **Landsat Collection 2 Level-2 Science Products**. 2023. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-collection-2-level-2-science-products>>. Acesso em: 2023-11-17.

WADE, J. et al. Improved soil biological health increases corn grain yield in n fertilized systems across the corn belt. **Scientific Reports**, v. 10, p. 1–9, 2020.

WHELAN, B. M.; MCBRATNEY, A. B. The “null hypothesis” of precision agriculture management. **Precision Agriculture**, v. 2, p. 265–279, 2000.

WORDELL FILHO, J. A. et al. **Pragas e doenças do milho: Diagnose, danos e estratégias de manejo**. **Boletim técnico N° 170**. [S.l.]: Epagri, 2016. 88 p.

YANG, W. et al. Estimation of corn yield based on hyperspectral imagery and convolutional neural network. **Computers and Electronics in Agriculture**, v. 184, p. 1–10, 2021.