

# Imagens orbitais como ferramenta para correlacionar índices de vegetação e produtividade do trigo

Murilo Perondi Cominetti<sup>1\*</sup>; Helton Aparecido Rosa<sup>1</sup>

<sup>1</sup>Curso de Agronomia, Centro Universitário da Fundação Assis Gurgacz, Cascavel, Paraná.

\*murilocominetti@gmail.com

**Resumo:** O sensoriamento remoto tem se consolidado como uma importante ferramenta de apoio ao manejo agrícola, permitindo acompanhar o desenvolvimento das culturas com maior precisão. Este trabalho teve como objetivo correlacionar índices de vegetação derivados do satélite Sentinel-2 (NDVI, GNDVI, GCI e VARI) com a produtividade do trigo na safra 2025/2025. Para isso, foram adquiridas imagens multiespectrais do satélite Sentinel-2, processadas no software QGIS, e calculados quatro índices. Os valores extraídos foram relacionados com dados reais de produtividade por meio do coeficiente de correlação de Pearson, calculado no Microsoft Excel. Os resultados mostraram que os índices responderam de maneira distinta à variabilidade interna da lavoura. As correlações foram fracas para NDVI e VARI, e muito fracas para GCI e GNDVI, indicando que fatores externos, como chuvas excessivas durante o ciclo interferiram no comportamento espectral e no rendimento final da cultura. Apesar disso, os índices apresentaram potencial como ferramenta auxiliar no monitoramento do trigo, contribuindo para a identificação de áreas de maior e menor desempenho.

**Palavras-chave:** sensoriamento remoto; trigo; NDVI; GNDVI; GCI; VARI; Sentinel-2.

**Abstract:** Remote sensing has become an important tool for agricultural monitoring, allowing farmers and researchers to evaluate crop development with greater detail. This study aimed to correlate vegetation indices derived from Sentinel-2 imagery (NDVI, GNDVI, GCI and VARI) with wheat yield during the 2025/2025 growing season. Multispectral images were processed in QGIS, and four vegetation indices representing different physiological aspects of the crop were calculated. The extracted spectral values were compared with actual yield data using Pearson's correlation coefficient, computed in Microsoft Excel. Results showed that each index highlighted different patterns of spatial variability, reflecting variations in vigor, biomass and chlorophyll content. Correlations were moderate for NDVI and GNDVI, and weaker for GCI and VARI, possibly due to external factors such as excessive rainfall during key stages of the crop cycle, which affected both spectral response and final yield. Even with these limitations, the indices demonstrated potential as support tools for monitoring wheat performance and identifying areas with different productivity levels.

**Keywords:** remote sensing; wheat; NDVI; GNDVI; GCI; VARI; Sentinel-2.

## **Introdução**

Os avanços da tecnologia da agricultura de precisão tornaram possível para o produtor acompanhar com maior eficiência as informações de sua lavoura, e ferramentas de sensoriamento remoto (SR) também são utilizadas para esse auxílio. Segundo Shiratsuchi (2014), o SR é caracterizado pela obtenção de informações sobre um objeto sem a necessidade de contato físico direto, frequentemente a partir de grandes distâncias.

De acordo com Formaggio (1989), uma das principais metas da pesquisa em SR aplicado à agricultura consiste em estimar, por meio de informações espectrais, variáveis das culturas relacionadas às suas condições fisiológicas e estruturais. Tais variáveis, podem posteriormente servir como dados de entrada para modelos de crescimento e produtividade agrícola, contribuindo para o monitoramento e a previsão do desempenho das lavouras.

No cenário atual da agricultura de precisão e digital, o NDVI exerce um papel essencial ao possibilitar o monitoramento detalhado das lavouras durante todo o ciclo produtivo (Gatelli et al., 2025). Uma limitação intrínseca ao NDVI é a sua rápida saturação, o que reduz sua capacidade de detectar variações no aumento da biomassa vegetal a partir de determinadas fases de crescimento (Asrar et al., 1984).

Outro índice amplamente utilizado na agricultura é o Índice de Vegetação por Diferença Normalizada utilizando a banda verde (GNDVI), proposto por Shanahan et al. (2001). Ele é uma variação do NDVI tradicional, diferindo pelo uso da banda verde no lugar da banda do vermelho, o que o torna particularmente sensível ao conteúdo de clorofila e à condição fisiológica das plantas, sendo útil para o monitoramento do estado nutricional e da eficiência fotossintética das culturas.

Além dele, dois outros índices merecem destaque: o GCI e o VARI. O Green Chlorophyll Index (GCI) baseia-se na relação entre a reflectância do infravermelho próximo e a banda verde, permitindo estimar o conteúdo de clorofila das folhas com maior precisão. Pesquisas recentes, como as de Sheng et al. (2020), apontam que o GCI apresenta forte relação com indicadores fisiológicos e pode ser empregado em avaliações de saúde vegetal. Zhou et al. (2020) também reforçam o uso desse índice para estudos de clorofila em sensores como Landsat e Sentinel-2.

O Visible Atmospherically Resistant Index (VARI), por sua vez, foi desenvolvido para minimizar a interferência atmosférica e de variações de iluminação, utilizando exclusivamente bandas do espectro visível. Isso faz com que ele seja útil em situações

nas quais não há disponibilidade de bandas no infravermelho próximo, como imagens obtidas por sensores RGB embarcados em drones.

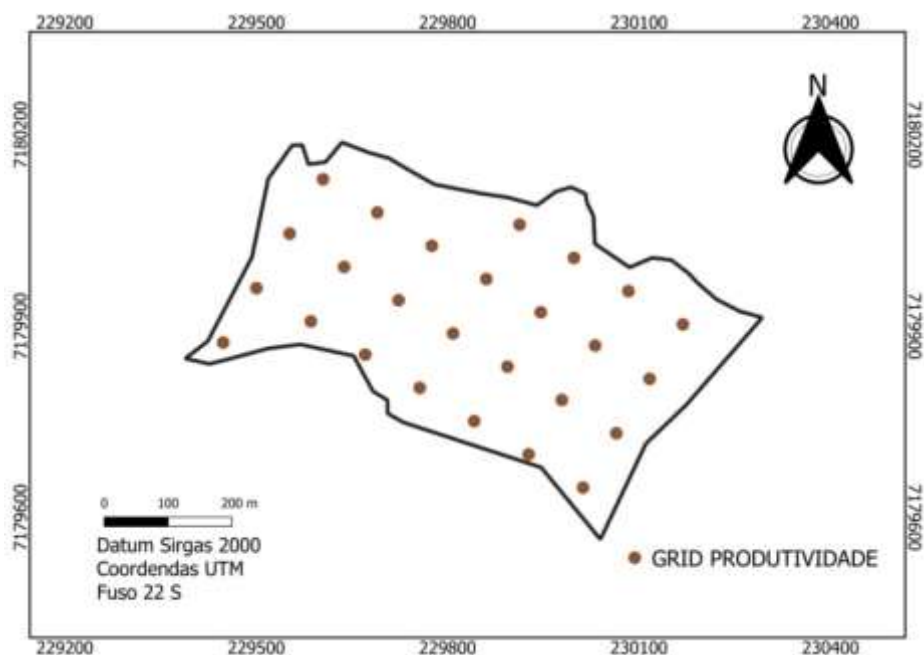
Diversos pesquisadores têm se dedicado à estimativa da produtividade do trigo por meio do uso do sensoriamento remoto na agricultura, como por exemplo, Paiva, Tsukahara e França (2013) desenvolveram uma metodologia que integra dados meteorológicos e espectrais com o objetivo de estimar a produtividade dessa cultura, demonstrando o potencial do sensoriamento remoto como ferramenta de apoio ao manejo agrícola e ao monitoramento de safras.

Desta forma, o objetivo desse trabalho foi correlacionar índices de vegetação e produtividade do trigo utilizando imagens do satélite Sentinel-2.

### Material e métodos

O experimento foi conduzido na safra 2025, em uma área localizada na Linha São Luiz, no município de Capitão Leonidas Marques, região oeste do Estado do Paraná. A cultivar de trigo utilizado foi TBIO Calibre, que possui característica de ciclo superprecoce, semeado no dia 10/06/2025. Para realizar a coleta do material na lavoura, foi feito primeiro o mapa da área pelo aplicativo Google Earth, onde posteriormente foi gerado um grid com os pontos onde seriam realizadas as coletas, com 100m de espaçamento, representando 1 ponto por hectare (Figura 1).

**Figura 1** – Grid de distribuição dos pontos de coleta de produtividade



*Fonte: Autor (2025).*

A coleta foi realizada no dia 10/10/2025, foram feitas 26 coletas de 1m<sup>2</sup> cada, em uma área de 26 ha, totalizando 1 ponto georreferenciado por hectare. As coletas foram realizadas de maneira manual, com a planta inteira, utilizando uma foice curta para cortar as plantas, e posteriormente foi realizada debulha de grãos, pesagem e quantificação da umidade, que foi corrigida para 13%. A debulha dos grãos foi realizada no dia 22/10/2025 na fazenda escola da FAG, e a pesagem e teste de umidade foram realizados no dia 27/10/2025.

Para o trabalho utilizou-se imagens do satélite Sentinel-2, disponibilizadas pela Agência Espacial Europeia (ESA), baixadas aos 63 dias após a semeadura (DAS). A escolha deste sensor se justifica pela sua alta resolução espectral e pela eficiência no monitoramento agrícola, sendo amplamente utilizado em estudos de vegetação (Rosa; Shimabukuro, 2021). O satélite Sentinel-2 conta com um sensor orbital capaz de captar imagens em alta resolução, distribuídas em 13 bandas espectrais, dentre as quais, quatro foram utilizadas na pesquisa (Tabela 1).

**Tabela 1** - Bandas espectrais do sensor MSI, presentes no satélite Sentinel-2 que foram utilizadas na geração dos IV.

Resolução	Nº da banda	Nome da banda	Comprimento de onda (nm)
10 m	B02	Azul (B)	490
	B03	Verde (G)	560
	B04	Vermelho (R)	665
	B08	Infravermelho Próximo (NIR)	842

Fonte: Adaptado de Engesat (2021).

O processamento das imagens, incluindo o recorte da área de estudo e o cálculo dos índices de vegetação, foi realizado no software QGIS. Para este estudo, foram calculados quatro índices espectrais amplamente utilizados na agricultura: NDVI (Equação 1), GCI (Equação 2), GNDVI (Equação 3) e VARI (Equação 4).

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (\text{Equação 1})$$

$$GCI = \frac{NIR}{GREEN} - 1 \quad (\text{Equação 2})$$

$$GNDVI = \frac{NIR - GREEN}{NIR + GREEN} \quad (\text{Equação 3})$$

$$VARI = \frac{GREEN - RED}{GREEN + RED - BLUE} \quad (\text{Equação 4})$$

Em que:

BLUE = Refletância na banda do azul (nm).

GREEN = Refletância na banda do verde (nm).

RED = Refletância na banda do vermelho (nm).

NIR = Refletância na banda do infravermelho próximo (nm).

Após o cálculo dos índices no QGIS, os valores foram exportados para planilhas no Microsoft Excel, onde foram organizados e preparados para a análise estatística. Para avaliar a relação entre os índices espectrais e a produtividade, foi aplicado o coeficiente de correlação de Pearson ( $r$ ), método amplamente adotado em estudos agrícolas por medir a intensidade e direção da relação linear entre variáveis contínuas (Carvalho; Assis, 2018). O coeficiente varia entre  $-1$  e  $1$ , onde valores próximos de  $1$  indicam correlação positiva forte, valores próximos de  $-1$  indicam correlação negativa forte e valores próximos de  $0$  indicam ausência de relação linear.

A interpretação dos coeficientes de variação (CV%) dos índices de vegetação e das épocas avaliadas seguiu os critérios descritos por Pimentel Gomes (2009), que classifica o CV como: baixo quando inferior a 10%; médio entre 10% e 20%; alto entre 20% e 30%; e muito alto quando acima de 30%.

Para fins de avaliação em relação a correlação, foi utilizado a classificação em que  $r$  tem possibilidade de ser avaliado qualitativamente, avaliação esta proposta por Callegari-Jacques (2003), onde é determinado a partir dos seguintes intervalos:  $0,9 \leq |r| \leq 1,0$ , representa uma correlação muito forte;  $0,7 \leq |r| < 0,9$ , representa uma correlação forte;  $0,4 \leq |r| < 0,7$ , representa em uma correlação moderada,  $0,2 \leq |r| < 0,4$ , representa uma correlação fraca e  $0,0 \leq |r| < 0,2$  representa uma correlação muito fraca.

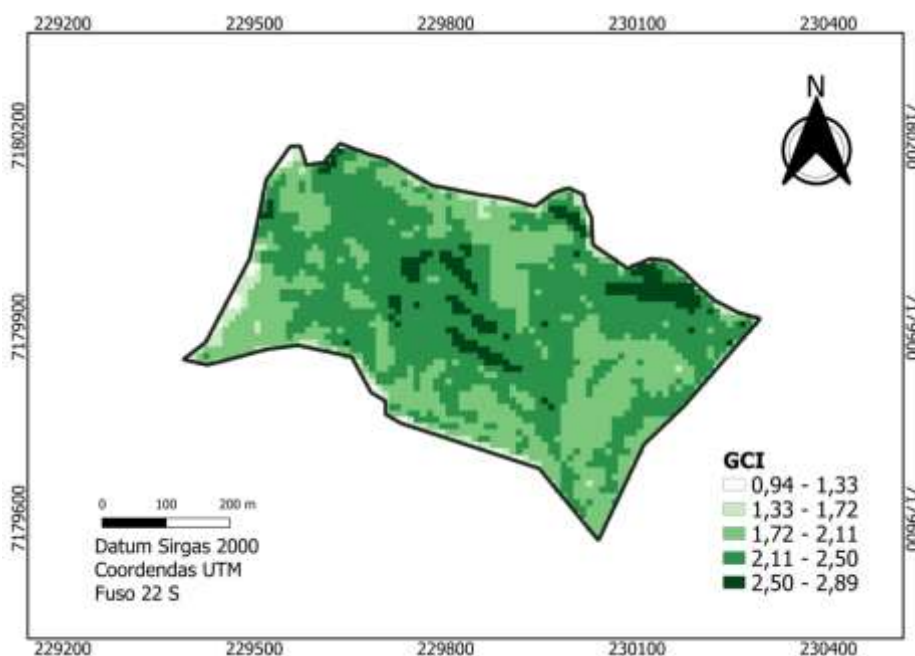
O Excel foi utilizado para realizar automaticamente o cálculo de  $r$ , possibilitando identificar de forma prática e objetiva a força da relação entre os quatro índices de vegetação e o índice de produtividade.

## Resultados e discussão

Ao analisar os mapas gerados a partir das imagens do Sentinel-2, foi possível observar de forma clara como os diferentes índices de vegetação responderam às variações internas da lavoura. Cada índice destacou determinados padrões, o que auxiliou na interpretação da variabilidade produtiva apresentada no mapa final.

O mapa do GCI (Figura 2) apresentou uma variação considerável dentro da área, com valores mais baixos no limite oeste e valores mais altos na região central e leste. Essa maior concentração indica plantas com maior teor de clorofila, o que normalmente representa melhor condição fisiológica naquele momento. Entretanto, algumas áreas com altos valores de GCI não se traduziram diretamente em maior produtividade, mostrando que fatores como solo e disponibilidade hídrica também influenciam o rendimento final, como cita Merladete (2024). O excesso de chuvas pode comprometer o desenvolvimento do trigo, pois favorece o encharcamento do solo, reduzindo a entrada de oxigênio na zona radicular. Nessa condição, as raízes passam a ter dificuldade para absorver nutrientes, o que acaba limitando o crescimento e o desempenho da cultura.

**Figura 2** – Mapa de variabilidade do índice GCI (Green Chlorophyll Index).

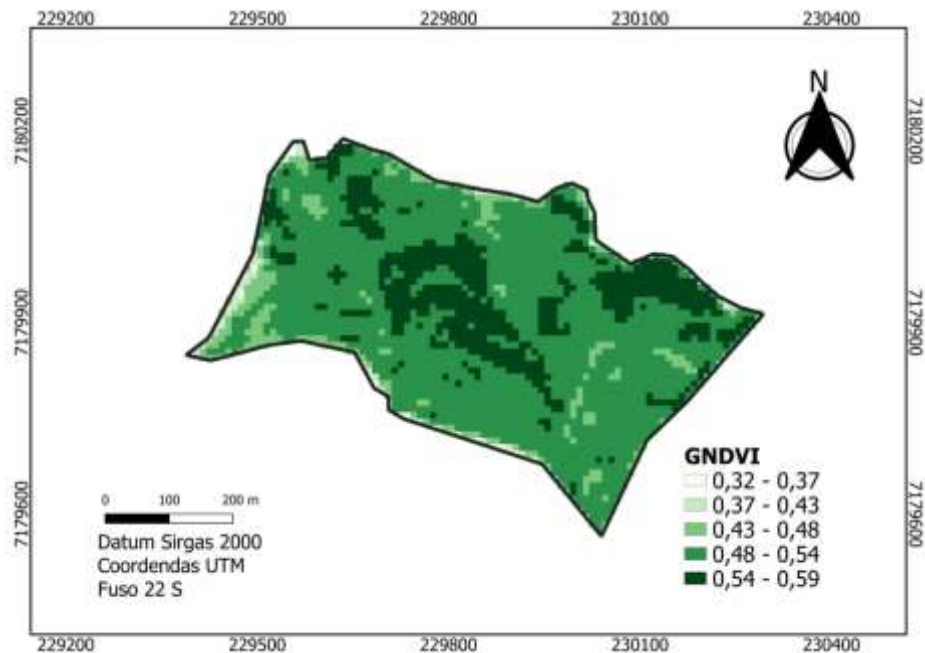


*Fonte: Autor (2025).*

O GNDVI (Figura 3) apresentou um comportamento semelhante ao GCI, mas com maior sensibilidade às condições nutricionais das plantas. Ele destacou de forma

mais evidente regiões centrais e nordeste da lavoura, que apresentaram melhor vigor vegetativo. Embora haja certa correspondência visual com a produtividade, essa relação não foi uniforme em toda a área.

**Figura 3** – Mapa de variabilidade do índice GNDVI (Green Normalized Difference Vegetation Index)

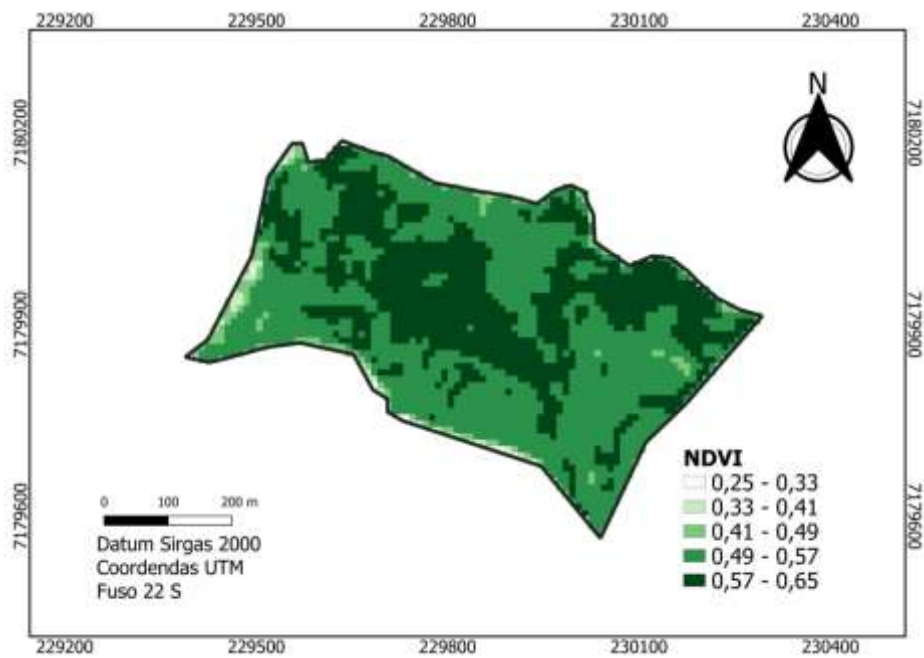


*Fonte: Autor (2025).*

O NDVI (Figura 4) mostrou maior homogeneidade, o que já era esperado, pois o índice tende a saturar em estádios mais avançados das culturas. De acordo com Garcia (2015), ao acompanhar o desenvolvimento fenológico de diferentes cultivares de trigo, verificou-se que, nos estádios em que a cobertura vegetal se torna mais densa, o NDVI apresenta tendência à estabilização, indicando um processo de saturação do índice.

Apesar da saturação, ainda foi possível observar faixas com maior biomassa principalmente no centro-leste da área, coincidindo parcialmente com zonas de maior produtividade posteriormente estimadas.

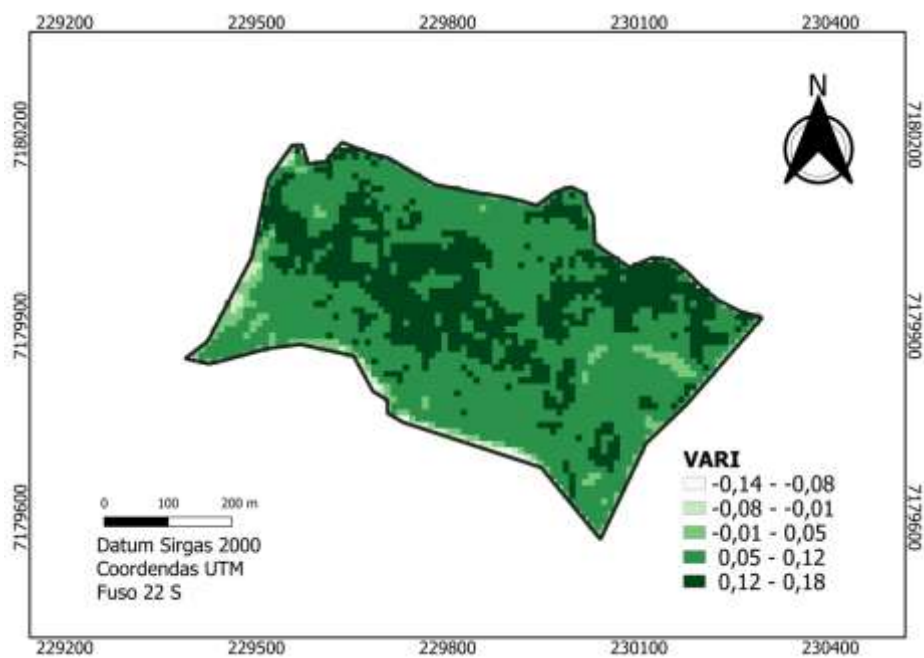
**Figura 4** – Mapa de variabilidade do índice NDVI (Normalized Difference Vegetation Index)



*Fonte: Autor (2025).*

O mapa de variabilidade do VARI (Figura 5) mostrou resultados semelhantes em relação ao NDVI, onde destacou as regiões central, nordeste e centro-oeste, com melhores índices de área foliar.

**Figura 5** – Mapa de variabilidade do índice VARI (Visible Atmospherically Resistant Index)



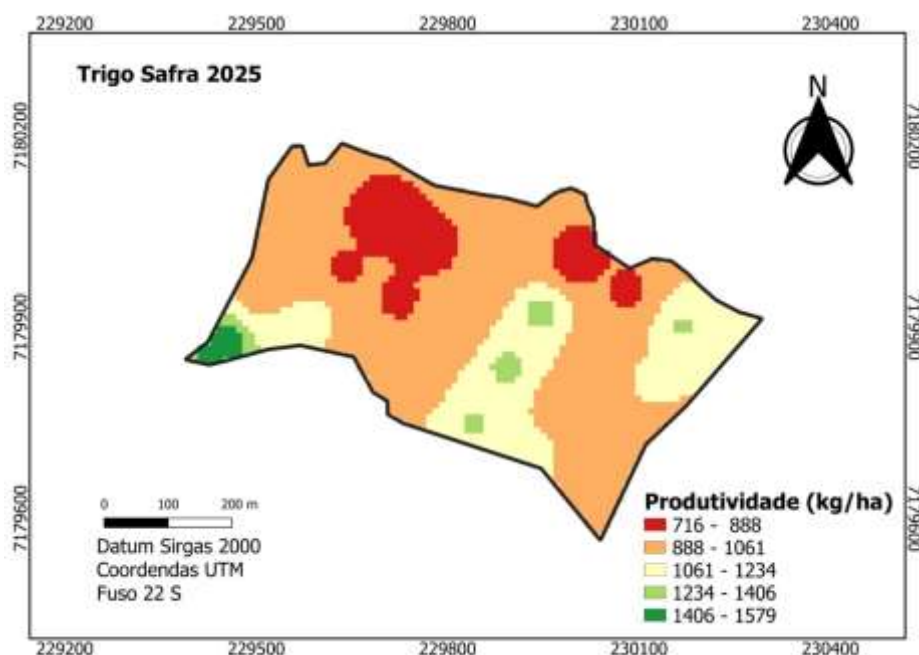


*Fonte: Autor (2025).*

O mapa interpolado de produtividade (Figura 6) revelou contrastes internos significativos na área, com regiões de baixo desempenho no setor central e nordeste, onde apresentou o menor valor de 716 kg ha<sup>-1</sup>, enquanto áreas ao sul e sudoeste apresentaram produtividade superior, onde encontramos o valor máximo de produção, de 1579 kg ha<sup>-1</sup>. Os valores encontrados são abaixo da média registrada no Paraná, onde segundo o boletim da Secretaria de Agricultura do Paraná, a produtividade média do trigo na safra 2025 ultrapassou 3.300 kg ha<sup>-1</sup>, um valor histórico.

A comparação visual entre esse mapa e os índices de vegetação mostra que embora existam semelhanças nas zonas de maior rendimento, os padrões não são idênticos.

**Figura 6** – Mapa interpolado de produtividade (kg ha<sup>-1</sup>)



*Fonte: Autor (2025).*

No caso deste trabalho com trigo, a ocorrência de chuvas excessivas durante etapas cruciais do ciclo pode ter atuado como um desses fatores limitantes. Boletins da Conab apontaram que precipitações superiores a 300 mm no período de 1º a 15 de novembro de 2022 comprometeram a colheita em regiões tricultoras do Paraná e de Santa Catarina (CONAB, 2022). Essas condições adversas reforçam que os sensores

utilizados podem não captar completamente os efeitos biológicos e agrônômicos desencadeados pela chuva, o que ajuda a explicar a variabilidade nos resultados.

Realizando a estatística descritiva (Tabela 2), obteve-se os dados referentes à produtividade do trigo em relação a diferentes IV's utilizados. É possível analisar que os IV's GCI e VARI apresentam um coeficiente de variação médio (11,76%) e muito alto (35,60%), enquanto de GNDVI (6,15%) e NDVI (7,80%) foram baixos segundo Pimentel Gomes. Tal variação pode ser explicada pela diferente ação de cada IV em relação a planta. Kurbanov e Zakharova (2020) demonstraram que o NDVI se mostrou pouco informativo para avaliar o trigo de inverno quando a cobertura vegetal era esparsa (solo exposto), enquanto o GCI apresentou maior sensibilidade às mudanças no estado da vegetação, especialmente em situações de baixa biomassa.

**Tabela 2** – Estatística descritiva dos índices de vegetação e produtividade do trigo.

	<i>Produtividade Trigo</i>	<i>GCI</i>	<i>VARI</i>	<i>GNDVI</i>	<i>NDVI</i>
Média	1005,60	2,14	0,10	0,52	0,55
Mediana	989,84	2,15	0,11	0,52	0,56
Desvio padrão	116,60	0,25	0,04	0,03	0,04
Mínimo	715,83	0,94	-0,14	0,32	0,25
Máximo	1578,88	2,89	0,18	0,59	0,65
CV	11,60	11,76	35,60	6,15	7,80

CV = Coeficiente de variação.

A análise estatística feita pelo método de correlação de Pearson, utilizando planilhas no Excel, permitiu quantificar essa relação entre os índices e a produtividade. Os resultados mostraram correlações fracas para NDVI e VARI, enquanto o GCI e GNDVI apresentaram correlação muito fraca (Tabela 3). Isso reforça que, apesar do sensoriamento remoto ser extremamente útil no monitoramento da lavoura, a produtividade final envolve múltiplos fatores que nem sempre são plenamente captados pela resposta espectral da vegetação.

**Tabela 3** – Correlação de Pearson entre os dados de produtividade do trigo os IV's (GCI, VARI, GNDVI, NDVI).

	<i>R de Pearson</i>
GCI	-0,19
VARI	-0,24
GNDVI	-0,19
NDVI	-0,21

IV's = Índices de vegetação.

Mesmo assim, os índices mostraram potencial para apoiar o manejo agrícola, especialmente quando utilizados em diferentes fases do ciclo da cultura. A identificação antecipada de áreas com tendência ao baixo desempenho pode permitir intervenções mais precisas, trazendo ganhos de eficiência para o produtor.

No conjunto, os resultados demonstram que o sensoriamento remoto, associado a índices espectrais como NDVI, GNDVI e GCI, oferece uma visão consistente da variabilidade espacial da lavoura e contribui para a compreensão dos padrões de produtividade observados.

Durante a análise dos resultados, também é importante considerar que a correlação entre os índices de vegetação e a produtividade nem sempre apresenta valores elevados, e esse comportamento já foi observado em outros estudos semelhantes. Rosa (2021), ao avaliar diferentes momentos de aquisição de imagens em diferentes fases da cultura, encontrou dias em que a correlação entre os índices espectrais e as condições reais da lavoura também se mostrou baixa. Segundo o autor, isso pode ocorrer em função do estado fenológico da cultura no momento da captura das imagens, da influência de fatores externos não detectados pelo sensor e, principalmente, de condições climáticas atípicas que interferem no desenvolvimento das plantas.

### **Conclusão**

A presente pesquisa demonstrou que não houve uma indicação alta de correlação entre o índice de produtividade da coleta realizada e os índices de sensoriamento remoto utilizados.

A variação entre os índices, porém, se demonstrou linear, indicando possível influência de fatores externos na produtividade, como condições climáticas atípicas que interferem nos valores finais. Assim, para garantir de forma concreta que o resultado do uso de sensoriamento remoto para pesquisa de produtividade seria eficiente, se faria necessário novas pesquisas.

### **Referencias**

ASRAR, G.; FUCHS, M.; KANEMASU, E. T.; HATFIELD, J. L. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. **Agronomy Journal**, v. 76, n. 2, p. 300–306, 1984.

CALLEGARI-JACQUES, S. M. **Bioestatística: princípios e aplicações**. Porto Alegre: Artmed, 2003.

CARVALHO, J. R. P.; ASSIS, F. N. Relação entre índices espectrais e variáveis agronômicas em culturas anuais. **Pesquisa Agropecuária Brasileira**, v. 53, n. 9, p. 1052–1061, 2018.

FORMAGGIO, A. R. **Características agronômicas e espectrais para sensoriamento remoto de trigo e de feijão**. 1989. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 1989.

GAO, X.; HUETE, A. R.; NI, W.; MIURA, T. Optical–biophysical relationships of vegetation spectra without background contamination. **Remote Sensing of Environment**, v. 74, n. 3, p. 609–620, 2000.

GARCIA, M. R. et al. **Caracterização espectro-temporal de cultivares de trigo por meio do índice de vegetação por diferença normalizada NDVI de sensores terrestres**. 2015.

GATELLI, A. E. P. et al. NDVI e suas aplicações. **Boletim Agrônomo**, Porto Alegre, v. 3, n. 5, p. 8–15, maio 2025.

HUETE, A., DIDAN, K., MIURA, T., RODRIGUEZ, E. P., GAO, X., & FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 2002.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: INPE, 2009.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KURBANOV, R. K.; ZAKHAROVA, N. I.; ZAKHAROVA, O. M.; GORSHKOV, D. M. Application of vegetation indexes to assess the condition of crops. **Agricultural Machinery and Technologies**, v. 14, n. 4, p. 4–11, 2020.

MERLADETE A. AGROLINK, **Chuvas em excesso podem prejudicar o trigo**. 2024. Disponível em: < [https://www.agrolink.com.br/noticias/chuvas-em-excesso-podem-prejudicar-o-trigo\\_496057.html](https://www.agrolink.com.br/noticias/chuvas-em-excesso-podem-prejudicar-o-trigo_496057.html)>. Acesso em 23 out. 2025.

PAIVA, R. C.; TSUKAHARA, R. Y.; FRANÇA, G. B. Estimativa de produtividade de trigo por meio de dados espectrais e meteorológicos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 2382–2389.

PIMENTEL-GOMES, F. **Curso de estatística experimental**. 15. ed. Piracicaba: FEALQ, 2009.

RAVEN, J. A. The transport and function of silicon in plants. **Biological Reviews**, v. 58, n. 2, p. 179–207, 1983.

ROSA, A. N.; SHIMABUKURO, Y. E. Processamento de índices de vegetação derivados do Sentinel-2 para aplicações agrícolas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, n. 3, p. 187–195, 2021.

ROSA, H. A. **Sensoriamento remoto orbital e não orbital no delineamento de zonas de manejo para agricultura de precisão**. 2021. 97 f. Tese (Doutorado em Engenharia Agrícola). Universidade Estadual do Oeste do Paraná, Cascavel, 2021.

SHANAHAN, J. F. et al. Use of remote-sensing imagery to estimate corn grain yield. **Agronomy Journal**, v. 93, n. 3, p. 583–589, 2001.

SHENG, H.; CHEN, X.; SU, J.; RAJAGOPAL, R.; NG, A. **Generalized vegetation index and chlorophyll estimation in agricultural monitoring**. 2020.

WARDLOW, B. D.; EGBERT, S. L.; KASTENS, J. H. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, v. 108, n. 3, p. 290–300, 2007.

ZHOU, X.; ZHANG, J.; CHEN, D.; HUANG, Y.; KONG, W.; YUAN, L. et al. Assessment of leaf chlorophyll content models for winter wheat using Landsat-8 multispectral remote sensing data. **Remote Sensing**, v. 12, n. 2574, 2020.