

COMPARAÇÃO ESTATÍSTICA DE VALORES DE NDVI OBTIDOS POR DIFERENTES PLATAFORMAS: QGIS E GOOGLE EARTH ENGINE

Tássia Parada Sampaio¹; Luciano Martins Tavares²; Tainara Goulart Corrêa³; Marília Lazarotto⁴; Diuliana Leandro⁵

¹*Universidade Federal de Pelotas – tssiap.sampaio@gmail.com* 1

²*Universidade Federal de Pelotas – rstchemartins@gmail.com* 2

³*Universidade Federal de Pelotas – tainaragoulart15@gmail.com* 3

⁴*Universidade Federal de Pelotas – marilia.lazarotto@ufpel.edu.br* 4

⁵*Universidade Federal de Pelotas – diuliana.leandro@gmail.com* 5

1. INTRODUÇÃO

O Índice de Vegetação por Diferença Normalizada (NDVI) é amplamente utilizado no sensoriamento remoto para monitorar a cobertura vegetal (RAHMAN; MEHNAZ, 2024), sendo especialmente relevante em áreas sensíveis como zonas úmidas e agrícolas (PETTORELLI, 2013). Em Pelotas, RS, o uso do NDVI permite análises espaciais e temporais da vegetação, apoiando a gestão ambiental e a conservação (MIRANDA, 2017; OL莫斯-TRUJILLO *et al.*, 2020; TRAN *et al.*, 2021).

Com o avanço das plataformas de sensoriamento remoto, tornaram-se viáveis desde métodos manuais via Earth Explorer e QGIS até abordagens automatizadas no Google Earth Engine (GEE) (CAPOLUPO *et al.*, 2020; RENBAO *et al.*, 2020; YANG *et al.*, 2022).

Diante disso, é fundamental avaliar se os valores de NDVI obtidos por essas metodologias são estatisticamente equivalentes, assegurando interpretações consistentes em estudos ambientais (AGBANGBA *et al.*, 2024; KANG *et al.*, 2022; LIU; ZHU; WANG, 2021).

Este estudo visa comparar estatisticamente os valores de NDVI extraídos pelo QGIS e pelo GEE, a partir de imagens Sentinel-2 (sensor MSI), referentes aos meses de abril e maio de 2025, com até 20% de cobertura de nuvem, na região de Pelotas-RS.

2. METODOLOGIA

As imagens do satélite Sentinel-2, obtidas por meio da plataforma Copernicus Browser, foram processadas no software QGIS (versão 3.40 LTR). O NDVI foi calculado com a Calculadora Raster, utilizando a equação (1), e as médias dos valores foram obtidas por meio do caminho: Menu → Raster → Miscellaneous → Informações Raster.

$$NDVI = \frac{(B8 - B4)}{(B8 + B4)} \quad \text{eq.(1)}$$

Os dados comparativos de NDVI para os meses de abril e maio de 2025, com filtro de cobertura de nuvens entre 20% e 27%, foram extraídos diretamente da plataforma Google Earth Engine (GEE) utilizando JavaScript.

Os resultados foram submetidos a análises estatísticas descritivas (média, desvio padrão) e inferenciais, realizadas na linguagem de programação Python por meio do ambiente de desenvolvimento PyCharm.

2.1 ANÁLISE ESTATÍSTICA

A comparação dos valores de NDVI entre plataformas (QGIS vs. Google Earth Engine) e períodos (Abril vs. Maio de 2025) foi realizada mediante testes

não-paramétricos, considerando a natureza não-normal dos dados e o reduzido tamanho amostral ($n \leq 6$ por grupo).

A normalidade das distribuições foi verificada pelo teste de Shapiro-Wilk ($\alpha = 0.05$), que indicou ausência de normalidade na maioria dos grupos ($p < 0.05$), justificando a adoção de métodos robustos.

Para as comparações entre grupos independentes, aplicou-se o teste U de Mann-Whitney, conforme recomendado por MOYA (2021) para dados contínuos não-normais. Complementarmente, calculou-se o tamanho do efeito através do Cliff's Delta (δ), classificado como: $|\delta| < 0.147$ (desprezível), $0.147 \leq |\delta| < 0.33$ (pequeno), $0.33 \leq |\delta| < 0.474$ (médio) ou $|\delta| \geq 0.474$ (grande), conforme proposto por ROMANO *et al.* (2006). Foram realizadas quatro análises comparativas: Plataformas no mês de Abril; Plataformas no mês de Maio; Meses na plataforma QGIS; Meses na plataforma Google Earth Engine.

O nível de significância foi estabelecido em $\alpha = 0.05$. Cada análise foi acompanhada por estatísticas descritivas (mediana, média e diferenças entre grupos), medidas de efeito (Cliff's Delta) e representações gráficas específicas: boxplots com valores individuais e indicações de diferenças de medianas, gráficos de barras com direcionalidade das diferenças e gráficos de magnitude do efeito.

As análises foram implementadas em Python 3.12 com as bibliotecas SciPy (VIRTANEN *et al.*, 2020), NumPy (HARRIS *et al.*, 2020), Matplotlib e Seaborn (HUNTER, 2007; WASKOM, 2021), utilizando o ambiente de desenvolvimento PyCharm.

3. RESULTADOS E DISCUSSÃO

A comparação entre QGIS e Google Earth Engine (GEE) não revelou diferenças estatisticamente significativas nos valores de NDVI ($p > 0,05$). Ainda assim, foram observadas variações sistemáticas nos valores médios, com o QGIS apresentando NDVI ligeiramente mais alto em abril ($\Delta = +0,084$) e o GEE em maio ($\Delta = -0,119$). Essas diferenças, embora não significativas, podem ser explicadas por variações nos algoritmos de correção atmosférica e nos métodos de composição de imagens utilizados pelas plataformas (NASIRI *et al.*, 2022; PANIDI *et al.*, 2020).

O NDVI é altamente sensível às dinâmicas sazonais da vegetação (LASAPONARA *et al.*, 2022), o que implica que o processamento temporal das imagens pode influenciar a detecção dessas mudanças. Por exemplo, ao processar datas de imagens individualmente, como frequentemente ocorre no QGIS de forma manual, as oscilações sazonais são mais evidentes em comparação com métodos de composição temporal automática, como medianas ou médias calculadas no GEE.

No aspecto temporal, o QGIS mostrou maior sensibilidade às variações sazonais, com uma redução de 11,4% nos valores de NDVI entre abril e maio, enquanto o GEE apresentou maior estabilidade, com uma queda de apenas 3,5% no mesmo período. Essa diferença pode estar associada às estratégias de processamento de imagens durante a transição para o outono em regiões de alta nebulosidade, como Pelotas (RS). No QGIS, o uso de imagens individuais ou em menor quantidade torna o resultado mais suscetível aos efeitos da cobertura de nuvens e da variabilidade sazonal (MORAIS *et al.*, 2021). Apesar de pequenas, diferenças relativas de até 35% no NDVI médio podem afetar aplicações sensíveis.

O estudo aponta para uma equivalência estatística entre as duas plataformas, mas sugere a existência de possíveis vieses sistemáticos. A limitação do tamanho amostral ($n \leq 6$) destaca a necessidade de séries temporais mais extensas e testes adicionais em pesquisas futuras.

4. CONCLUSÕES

A comparação entre QGIS e Google Earth Engine (GEE) para estimativas de NDVI não revelou diferenças estatisticamente significativas ($p > 0,05$), indicando equivalência entre as plataformas. No entanto, o QGIS demonstrou maior sensibilidade às variações sazonais, enquanto o GEE apresentou maior estabilidade temporal. Isso sugere que o QGIS é mais indicado para estudos focados em mudanças sazonais, e o GEE, para análises que exigem consistência nos dados. Apesar da ausência de significância estatística, os efeitos práticos observados podem ser relevantes em contextos ambientais específicos, portanto as plataformas são intercambiáveis para NDVI, mas a escolha depende do objetivo: QGIS para variação sazonal, GEE para estabilidade temporal. O pequeno tamanho amostral representa uma limitação do estudo, reforçando a necessidade de investigações futuras com dados mais amplos.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- AGBANGBA, Codjo Emile *et al.* On the use of post-hoc tests in environmental and biological sciences: A critical review. **Heliyon**, [s. l.], v. 10, n. 3, p. e25131, 2024.
- CAPOLUPO, Alessandra *et al.* Extracting Land Cover Data Using GEE: A Review of the Classification Indices. In: , 2020, Cham. (Osvaldo Gervasi *et al.*, Org.)**Computational Science and Its Applications – ICCSA 2020**. Cham: Springer International Publishing, 2020. p. 782–796.
- COPERNICUS. Copernicus Data Space Ecosystem. Disponível em: <https://browser.dataspace.copernicus.eu>. Acesso em: 29 jul. 2025.
- GOOGLE. Google Earth Engine – plataforma de análise geoespacial. Disponível em: <https://code.earthengine.google.com>. Acesso em: 29 jul. 2025.
- HARRIS, Charles R. *et al.* Array programming with NumPy. **Nature**, [s. l.], v. 585, n. 7825, p. 357–362, 2020.
- HUNTER, John. Matplotlib: A 2D Graphics Environment. **Computing in Science & Engineering**, [s. l.], v. 9, p. 90–95, 2007.
- KANG, Ye *et al.* Performance evaluation of low-cost air quality sensors: A review. **Science of The Total Environment**, [s. l.], v. 818, p. 151769, 2022.
- LASAPONARA, Rosa *et al.* On the Use of Sentinel-2 NDVI Time Series and Google Earth Engine to Detect Land-Use/Land-Cover Changes in Fire-Affected Areas. **Remote Sensing**, [s. l.], v. 14, n. 19, p. 4723, 2022.
- LIU, Peide; ZHU, Baoying; WANG, Peng. A weighting model based on best-worst method and its application for environmental performance evaluation. **Applied Soft Computing**, [s. l.], v. 103, p. 107168, 2021.
- MIRANDA, Ciomara de Souza. Geotechnology as support for the management of conservation units in Brazil's Pantanal Geotecnologias como suporte ao manejo de unidades de conservação do Pantanal, Brasil. [s. l.], v. 12, n. 2, 2017.

MORAIS, Leonardo Fiusa De *et al.* Spectral responses in rangelands and land cover change by livestock in regions of the Caatinga biome, Brazil. **Scientific Reports**, [s. l.], v. 11, n. 1, p. 18261, 2021.

MOYA, Claudia Regina. **Como escolher o teste estatístico: Um guia para o pesquisador iniciante**. São Paulo, SP: Claudia Moya, 2021.

NASIRI, Vahid *et al.* Land Use and Land Cover Mapping Using Sentinel-2, Landsat-8 Satellite Images, and Google Earth Engine: A Comparison of Two Composition Methods. **Remote Sensing**, [s. l.], v. 14, n. 9, p. 1977, 2022.

OLMOS-TRUJILLO, Edith *et al.* Spatio-Temporal Response of Vegetation Indices to Rainfall and Temperature in A Semiarid Region. **Sustainability**, [s. l.], v. 12, n. 5, p. 1939, 2020.

PANIDI, E. *et al.* CLOUD-DESKTOP REMOTE SENSING DATA MANAGEMENT TO ENSURE TIME SERIES ANALYSIS, INTEGRATION OF QGIS AND GOOGLE EARTH ENGINE. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [s. l.], v. XLIII-B4-2020, p. 553–557, 2020.

PETTORELLI, Nathalie. **The Normalized Difference Vegetation Index**. [S. l.]: Oxford University Press, 2013. Disponível em: <https://doi.org/10.1093/acprof:osobl/9780199693160.001.0001>. Acesso em: 29 jul. 2025.

RAHMAN, Parvejur; MEHNAZ, Sagufta. International Journal for Multidisciplinary Research (IJFMR). **SSRN Electronic Journal**, [s. l.], 2024. Disponível em: <https://www.ssrn.com/abstract=5054029>. Acesso em: 29 jul. 2025.

RENBAO, LIAN *et al.* Road Extraction Methods in High-Resolution Remote Sensing Images: A Comprehensive Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s. l.], v. 13, p. 5489–5507, 2020.

ROMANO, Jeanine; KROMREY, Jeffrey. Appropriate Statistics for Ordinal Level Data: Should We Really Be Using t-test and Cohen's d for Evaluating Group Differences on the NSSE and other Surveys? [s. l.], 2006.

TRAN, Thuong V. *et al.* Characterising spatiotemporal vegetation variations using LANDSAT time-series and Hurst exponent index in the Mekong River Delta. **Land Degradation & Development**, [s. l.], v. 32, n. 13, p. 3507–3523, 2021.

VIRTANEN, Pauli *et al.* SciPy 1.0: fundamental algorithms for scientific computing in Python. **Nature Methods**, [s. l.], v. 17, n. 3, p. 261–272, 2020.

YANG, Liping *et al.* Google Earth Engine and Artificial Intelligence (AI): A Comprehensive Review. **Remote Sensing**, [s. l.], v. 14, n. 14, p. 3253, 2022.

WASKOM, Michael. seaborn: statistical data visualization. **Journal of Open Source Software**, [s. l.], v. 6, n. 60, p. 3021, 2021.