

## PRINCIPAIS APLICAÇÕES E CONTRIBUIÇÕES DOS DADOS HARMONIZED LANDSAT SENTINEL-2 NA AGRICULTURA

Taya Cristo Parreiras<sup>1</sup>, Édson Luis Bolfe<sup>2</sup>, Édson Eyji Sano<sup>3</sup>

<sup>1</sup> Programa de Pós-Graduação em Geografia, Universidade Estadual de Campinas (UNICAMP), CEP 13083-855, Campinas – SP, tayacristo1@gmail.com; <sup>2</sup> Embrapa Agricultura Digital, CEP 13083-886, Campinas – SP, edson.bolfe@embrapa.br; <sup>3</sup> Embrapa Cerrados, CEP 73310-970, Planaltina – DF, edson.sano@embrapa.br

### RESUMO

O Harmonized Landsat Sentinel-2 (HLS) é uma iniciativa da NASA que, em 2016, passou a disponibilizar conjuntos de dados multiespectrais harmonizados do Landsat 8 e do Sentinel-2, possibilitando observações da Terra com resolução espacial de 30 m e resolução temporal de 2-3 dias. Assim, o HLS possui elevado potencial para aumentar o volume de dados em períodos-chave na agricultura brasileira e tropical, melhorando mapeamentos, estimativas de rendimento e demais aplicações do sensoriamento remoto na agricultura. Dessa forma, como se trata de uma iniciativa recente, este estudo tem como objetivo analisar o cenário mundial do emprego do HLS na agricultura a partir de consulta estruturada na plataforma *Web of Science*, identificando as principais aplicações, contribuições e desafios relacionados ao uso desses dados.

**Palavras-chave** — multisensor, HLS, revisão

### ABSTRACT

*Harmonized Landsat Sentinel-2 (HLS) is a NASA initiative that, in 2016, made available harmonized multispectral datasets from Landsat 8 and Sentinel-2, enabling Earth observations with a spatial resolution of 30m and temporal resolution between 2-3 days. Thus, the HLS has a high potential to increase the volume of data in critical periods of Brazilian tropical agriculture, improving mapping, yield estimates, and other applications of remote sensing in agriculture. Thus, as it is a recent initiative, this study aims to analyze the world scenario of HLS applications in agriculture from a structured review on the Web of Science platform, identifying the leading applications, contributions, and challenges related to the use of this data*

**Key words** — multisensor, HLS, review

### 1. INTRODUÇÃO

O sensoriamento remoto (SR) e as geotecnologias fazem parte do pacote de inserção da ciência, da tecnologia e da informação em diversas escalas da atividade agrícola, produzindo e fornecendo informações fundamentais de localização, extensão e estado dos recursos naturais e das lavouras agrícolas, visando uso sustentável da terra e dos recursos [1-2]. Entretanto, para que

o SR seja útil em reproduzir a dinâmica da superfície, auxiliar em modelagens precisas e, assim, fornecer informações úteis e de qualidade, é preciso que os sistemas sensores consigam adquirir dados com equilíbrio entre resolução espacial, espectral e temporal [3].

Tendo em vista as similaridades dos sensores do programa Landsat, como *Enhanced Thematic Mapper Plus* (ETM+), a bordo do Landsat 7 (L7) e o *Operational Land Imager* (OLI), a bordo do Landsat 8 (L8), com o instrumento *Multispectral Scanner* (MSI), a bordo dos satélites gêmeos Sentinel-2 (S2) A e B, em 2016, a *National Aeronautics and Space Administration* (NASA) passou a harmonizar e disponibilizar as séries temporais do L8 e S2 A e B de forma unificada em um conjunto de dados único, com resolução temporal de até 2 dias, por meio do projeto *Harmonized Landsat Sentinel-2* (HLS) [4]. Para isso, a agência aplica algoritmos de correção atmosférica, co-registro espacial, normalização da Função de Distribuição de Reflectância Bidirecional (BRDF) e ajuste de passagem bandas para normalizar os ângulos de visada e iluminação e promover o ajuste linear entre bandas equivalentes [5]. Inicialmente, os dados eram disponibilizados nos EUA e em algumas áreas experimentais, inclusive no Brasil. Atualmente, o projeto tem cobertura quase-global. Além da NASA, outros grupos de pesquisa têm desenvolvido metodologias de harmonização adaptadas às variabilidades regionais.

O HLS possui grande potencial para superar alguns desafios do sensoriamento remoto presentes na agricultura tropical e global, como a limitação relacionada à baixa disponibilidade de dados nos principais períodos de desenvolvimento das lavouras, ou seja, o período chuvoso, bem como a possibilidade de aplicações em nível regional, apresentando uma resolução espacial de 30 m. Dessa forma, este estudo tem como objetivo identificar, com uma revisão da literatura na plataforma *Web of Science*, as principais aplicações, contribuições e desafios que envolvem o uso do HLS na agricultura mundial.

### 2. MATERIAL E MÉTODOS

Para obter uma visão geral do volume e distribuição das publicações relacionadas ao HLS, inicialmente foi realizada uma busca na plataforma *Web of Science* que envolveu o uso do termo *Harmonized Landsat Sentinel*. Em seguida, uma nova busca foi feita com a adição do termo *Agriculture*. Dentre os documentos resultantes, foram considerados apenas os artigos, único filtro aplicado. Algumas métricas bibliométricas foram exploradas para verificar a tendência relacionada ao número e à

origem das publicações, em relação às principais palavras-chave e às principais aplicações no contexto agrícola (segunda busca). Ademais, também foi considerada a origem dos dados utilizados nos estudos, se originados pela NASA ou por harmonização regionalizada, e identificadas as principais contribuições e desafios relacionados ao uso dos dados HLS em estudos voltados à agricultura em escala mundial.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1 Evolução das publicações com dados HLS

No que diz respeito ao número de publicações, considerando a utilização dos dados HLS de maneira geral, foram identificados 74 estudos, distribuídos por 24 países, embora cerca de 66% deles tenham sido desenvolvidos nos EUA. Na segunda busca, foram encontrados 27 estudos, distribuídos por 14 países, sendo que 50% foram conduzidos nos EUA, e apenas três na América do Sul, dois no Brasil. De maneira geral, entre 2017 e 2022 a média de publicações anuais relacionadas ao HLS cresceu 720%. As aplicações na agricultura cresceram, em média, 233% entre 2018 e 2022 (Figura 2).

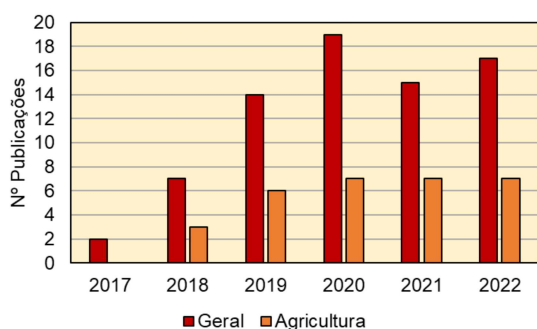


Figura 1. Evolução do número de publicações relacionadas aos dados *Harmonized Landsat Sentinel-2*, no contexto geral e na agricultura, entre 2017 e 2022.

#### 3.2 Principais aplicações e contribuições dos dados HLS em estudos na agricultura

A Figura 2, gerada com o *software* VOSviewer, ilustra uma rede com as principais palavras-chave dos trabalhos com aplicações de dados HLS na agricultura, na qual destacam-se algumas como *classification*, *vegetation indices*, *evapotranspiration*, *phenology*, *yield*, *machine learning*, entre outras. Essa rede foi capaz de ilustrar e sintetizar como os dados HLS têm sido explorados na literatura. Mapeamentos agrícolas, estimativas de rendimento, modelagem da evapotranspiração em alta resolução e a extração de métricas de fenologia foram as principais aplicações, presentes em praticamente todos os estudos analisados. Os índices de vegetação (IVs), principalmente o NDVI, foram elementos-chave em todas as aplicações, presentes em 85% dos estudos.

De maneira geral, no contexto agrícola, um em cada quatro estudos aplica os dados HLS no mapeamento de culturas. Em

2018, o conjunto multiespectral de bandas HLS, em uma série temporal de oito meses, foi usado com o algoritmo *Random Forest* para mapear nove cultivos agrícolas em quatro regiões diferentes nos EUA. Os resultados mostraram que o HLS gera modelos com maior poder preditivo do que o Sentinel-1 (S1) no início e no final da estação, e que a integração S1+HLS não produz resultados significativamente superiores [6]. Com uma média de 25 observações ‘limpas’ por *pixel* em uma série temporal de 15 meses, Griffiths et al. [7] mapearam oito culturas agrícolas e outras classes de cobertura com 81% de acurácia global e, em geral, acurácia do produtor do usuário > 80% em toda a Alemanha. No Brasil, foi possível melhorar significativamente o mapeamento da soja em até 15% com HLS em relação ao uso individual de dados OLI e MSI, com acurácia global de até 91% em pleno período chuvoso (outubro a março) [8]. Em duas províncias chinesas, a resolução temporal aprimorada do HLS permitiu a captura de detalhes fenológicos em todos os estágios de crescimento da colza, possibilitando o mapeamento da cultura com acurácia superior a 95%, apenas com abordagens de limiar para IVs [9]. A chave para os bons resultados com mapeamentos de diferentes culturas, em condições ambientais diversas está principalmente na capacidade que os dados HLS possuem de descrever fenologia da superfície, inclusive em períodos chuvosos, o que é possibilitado pela elevada frequência de observações. Além disso, a resolução média de 30 m facilita sua aplicação em escala local [10].

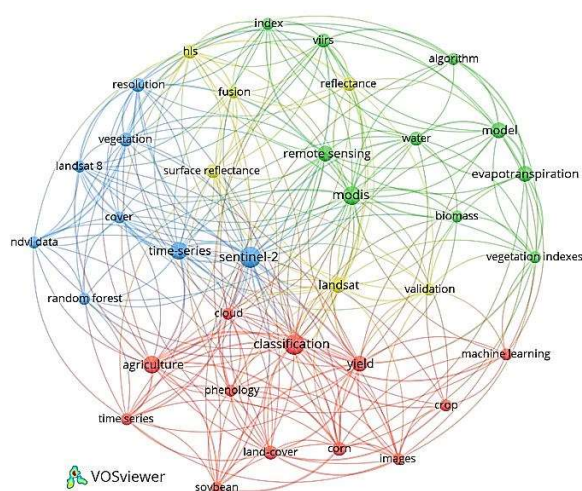


Figura 2. Mapa de redes com as mais importantes palavras-chave dos estudos analisados, gerado a partir dos resultados da busca na plataforma *Web of Science*.

Analisando especificamente o potencial das séries temporais de índices de vegetação de dados HLS em descrever as fases fenológicas das culturas, Gao et al. [11] estimaram, entre 2018 e 2020, as datas de emergência de soja e milho com diferença média de sete dias em escala de campo, e dois dias em escala estadual, em cinco cinturões de produção dos EUA. No delta do

Rio Nilo, no Egito, uma série temporal de quatro anos do índice de área foliar (IAF), com média de 98 imagens com cobertura de nuvens < 50% por ano, gerada com dados HLS, possibilitou que Amim et al. [12] estimassem o início e o fim da estação com 75% de precisão e desempenho superior em relação ao MSI e OLI individualmente.

A capacidade da série temporal de HLS NDVI em captar as fases fenológicas dos cultivos contribuiu para que Nguyen et al. [13] mapeassem a extensão de áreas agrícolas em regiões suscetíveis à seca no Vietnã e no Líbano, e para que Hao et al. [14] mapeassem a intensidade de cultivo (em um e dois ciclos), com precisão > 95% em quatro regiões agrícolas na China, EUA, África do Sul e Índia. A preservação dos padrões fenológicos também foi determinante para que Bolognesi et al. [15] conseguissem distinguir áreas sob regime de irrigação na Itália, inclusive com distinção entre espécies irrigadas herbáceas e arbustivas, com uma série temporal de NDVI e dados de precipitação.

Outra importante aplicação dos dados HLS é a estimativa de rendimento de lavouras, para a qual a fenologia da superfície é uma informação determinante. Na Ucrânia, Skakun et al. [16] mostraram que a evolução dos dados HLS, entre 2016 (com apenas o S2 A e L8) e 2018 (S2 A + B e L8), aumentou o número de observações limpas por *pixel* de até 2,6 para até 6,2 nos cinco meses de desenvolvimento do trigo. Essa melhora aprimorou as estimativas em escala regional em até 18% quando comparado com o uso individual do S2. Por outro lado, em escala de parcela, as bandas multiespectrais do HLS e do Planet falharam em explicar a variabilidade no rendimento do milho e da soja [17]. Resultados obtidos por Mourad et al. [18] sugerem que o IAF extraído de séries temporais do *Enhanced Vegetation Index* (EVI) de dados HLS se correlacionam bem com a altura de dosséis de trigo e batatas.

As estimativas de evapotranspiração (ET) para simular o balanço hídrico e avaliar a eficiência do uso da água representam um campo de vanguarda para o sensoriamento remoto e o HLS está presente também em estudos dessa natureza. Séries temporais do visível e do infravermelho termal são inseridas em modelos de balanço de energia para estimar, com elevada precisão, a ET em nível de cultura, como foi feito por Gavilán et al. [19], no Chile, utilizando apenas o NDVI. Jafaar et al. [20] foram ainda mais longe com a abordagem multisensor, desenvolvendo um modelo híbrido de balanço de energia com uso sinérgico dos dados HLS, MODIS e VIIRS, para estimar a ET diária com 30 m de resolução e em escala global.

Uma importante questão da abordagem multisensor é o papel do L8 (até o momento o L9 não estava presente nos dados dos estudos analisados). Apesar de possuir menos de 1/3 da frequência temporal do S2, datas de passagem do L8 representaram 17% da série temporal em Parreiras et al. [8], onde algumas dessas datas estavam entre as mais importantes no mapeamento da soja, 28% dos dados de Bolognesi [15], 39% das imagens em Skakun et al. [16], e 44% das imagens em Amime et al. [12]. Isso evidencia o potencial da abordagem multisensor, revelando que os dados Landsat contribuem positivamente com a resolução temporal do Sentinel-2, principalmente em áreas de

sobreposição de quadrantes. Também é válido lembrar que, em 2021, a NASA lançou o Landsat 9, com o mesmo sensor OLI, dobrando a frequência de observações do programa, que poderá chegar a quatro dias nas áreas de sobreposição, aumentando ainda mais a contribuição desses dados no conjunto HLS.

### 3.3 Principais desafios do uso de dados HLS em estudos na agricultura

No contexto agrícola, em 80% dos estudos analisados foram utilizados dados HLS gerados pela NASA. Embora haja boa compatibilidade entre os sensores MSI e OLI, os valores de reflectância podem diferir entre 1-9%, dependendo da banda, devido principalmente a efeitos de geometria da visada e iluminação [21]. Para produzir valores de reflectância de superfície padronizados, a NASA usa coeficientes globais nas equações de ajuste [5]. Entretanto, estudos sugerem que, com equações regionalmente ajustadas, essas diferenças podem ser reduzidas para aproximadamente 1% em todas as bandas [22, 13], melhorando a qualidade da harmonização e dos produtos derivados. Dessa forma, novos estudos são necessários para averiguar o impacto da harmonização com coeficientes regionais nos dados originais (reflectâncias de bandas), nos IVs, e nos produtos derivados, como mapeamentos e estimativas em geral.

Outra importante questão relacionada aos dados HLS está relacionada à banda para remoção de *pixels* contaminados, a *Fmask*. Perdas de dados entre 35% e 59% foram relatadas por Torbick et al. [6], enquanto Parreiras et al. [8] relataram uma perda média de 74%, índice 15% superior à média de cobertura de nuvens no período estudado. Embora as condições atmosféricas dos períodos de estudo selecionados sejam determinantes, já foram identificados na *Fmask*, erros de comissão e omissão, níveis superestimados de aerossol, bem como problemas na interpretação de objetos de maior brilho [22], além de menor acurácia na detecção de nuvens quando confrontada com outras metodologias, como uso sinérgico da *Fmask* e limiares do *Normalized Difference Water Index* [10]. É possível que a harmonização com coeficientes regionalizados também possa contribuir para aumentar o volume de dados válidos [6].

Este estudo não pretende encerrar o assunto, o objetivo principal foi analisar a evolução da harmonização de dados Landsat e Sentinel-2 a partir de uma amostra da literatura na plataforma Web of Science. Dessa forma, como um estudo em andamento, prosseguimento será dado com a adição de novas bases de busca e monitoramento constante de novas publicações para aprofundamento da literatura e melhor compreensão das potencialidades e desafios que envolvem a aplicação do HLS no contexto agrícola, em especial, para a agricultura tropical.

## 4. CONCLUSÕES

Considerando a análise da literatura disponível na plataforma *Web of Science*, observou-se que séries temporais de índices de vegetação geradas com dados HLS são eficientes em captar a fenologia de cultivos agrícolas em ambientes diversos.

A combinação dos dados Landsat 8 e Sentinel-2 melhora os resultados de mapeamentos e estimativas de rendimento, quando comparada com desempenhos individuais dos sensores OLI e MSI.

O HLS representa uma grande oportunidade de superação de limitações relativas à cobertura de nuvens e mistura espectral, produzindo dados com balanço entre resolução espacial e temporal.

## 5. AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento do projeto 2019/26222-6 e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código Financeiro - 001.

## 6. REFERÊNCIAS

- [1] E. L. Bolfe, J. G. A. Barbedo, S. M. F. S. Massruhá, K. X. S. Souza, E. D. Assad. *Desafios, tendências e oportunidades em agricultura digital no Brasil*. In: S. M. F. S. Massruhá, M. A. Leite, S. R. M. Oliveira, C. A. A. Meira, A. Luchiani Júnior, E. L. Bolfe. *Agricultura Digital: Pesquisa, desenvolvimento e inovação nas cadeias produtivas*. Brasília: Embrapa, 2020. 406 p.
- [2] A. R. Formaggio, I. D. Sanches. *Sensoriamento Remoto em Agricultura*. São José dos Campos: Oficina de Textos, 2017. 284 p.
- [3] J. L. Hatfield, J. H. Prueger, T. J. Sauer, C. Dold, P. O'Brien, K. Wacha. Applications of Vegetative Indices from Remote Sensing to Agriculture: Past and Future, *Inventions*, v. 4, 71, 2019.
- [4] NASA - National Aeronautics and Space Administration. Harmonized Landsat Sentinel-2. Disponível em: <https://hls.gsfc.nasa.gov/>. Acesso em 29 out. 2022.
- [5] M. Claverie, J. Ju, J. Masek, J. L. Dungan, E. F. Vermote, J. C. Roger, S. V. Skakun, Justice, C. The Harmonized Landsat and Sentinel-2 Surface Reflectance Data Set, *Remote Sensing of Environment*, v. 219, pp. 145-161, 2018.
- [6] N. Torbick, X. Huang, B. Ziniti, D. Johnson, J. Masek, M. Reba. Fusion of Moderate Resolution Earth Observations for Operational Crop Type Mapping, *Remote Sensing*, v. 10, 1058, 2018.
- [7] P. Griffiths, C. Nendel, P. Hostert. Intra-Annual Reflectance Composites from Sentinel-2 and Landsat for National-Scale Crop Land Cover Mapping, *Remote Sensing of Environment*, v. 220, pp. 135-151, 2019.
- [8] T. C. Parreiras, E. L. Bolfe, M. E. D. Chaves, I. D. Sanches, E. E. Sano, D. C. Victória, G. M. Bettiol, L. E. Vicente. Hierarchical Classification of Soybean in the Brazilian Savanna Based on Harmonized Landsat Sentinel Data, *Remote Sensing*, v. 14, 3736, 2022.
- [9] S. Chen, Z. Li, T. Ji, H. Zhao, X. Jiang, X. Gao, J. Pan, W. Zhang. Two-Stepwise Hierarchical Adaptive Threshold Method for Automatic Rapeseed Mapping over Jiangsu Using Harmonized Landsat/Sentinel-2. *Remote Sensing*, v. 14, 2715, 2022.
- [10] N. J. Pastick, D. Dahal, B. K. Wylie, S. Parajuli, S. P. Boyte, Z. Wu. Characterizing Land Surface Phenology and Exotic Annual Grasses in Dryland Ecosystems Using Landsat and Sentinel-2 Data in Harmony, *Remote Sensing*, v. 12, 725, 2020.
- [11] F. Gao, M. C. Anderson, D. M. Johnson, R. Sefferin, B. Wardlow, A. Suyker, Diao, C., D. M. Browning. Towards Routine Mapping of Crop Emergence within the Season Using the Harmonized Landsat and Sentinel-2 Dataset, *Remote Sensing*, v. 13, 5074, 2021.
- [12] E. Amim, S. Belda, L. Pipia, Z. Szantoi, A. El Baroudy, J. Moreno, J. Verrelst. Multi-Season Phenology Mapping of Nile Delta Croplands Using Time Series of Sentinel-2 and Landsat 8 Green LAI, *Remote Sensing*, v. 14, 1812, 2022.
- [13] M. D. Nguyen, O. M. Baez-Villanueva, D. D. Bui, P. T. Nguyen, L. Ribbe. Harmonization of Landsat and Sentinel 2 for Crop Monitoring in Drought Prone Areas: Case Studies of Ninh Thuan (Vietnam) and Bekaa (Lebanon), *Remote Sensing*, v. 12, 281, 2020.
- [14] P. Hao, H. Tao, Z. Chen, L. Yu, M. Wu. High Resolution Crop Intensity Mapping Using Harmonized Landsat-8 and Sentinel-2 Data, *Journal of Integrative Agriculture*, v. 18, pp. 2883-2897, 2019.
- [15] S. F. Bolognesi, E. Pasolli, O. R. Belfiore, C. De Michele, G. D'Urso. Harmonized Landsat 8 and Sentinel-2 Time Series Data to Detect Irrigated Areas: An Application in Southern Italy, *Remote Sensing*, v. 12, 1275, 2020.
- [16] S. Skakun, E. Vermote, B. Franch, J. C. Roger, N. Kussul, J. Ju, J. Masek. Winter Wheat Yield Assessment from Landsat 8 and Sentinel-2 Data: Incorporating Surface Reflectance, Through Phenological Fitting, into Regression Yield Models, *Remote Sensing*, v. 11, 1768, 2019.
- [17] S. Skakun, N. I. Kalecinski, M. G. L. Brown, D. M. Johnson, E. F. Vermote, J. C. Roger, B. Franch. Assessing within-Field Corn and Soybean Yield Variability from WorldView-3, Planet, Sentinel-2, and Landsat 8 Satellite Imagery, *Remote Sensing*, v. 13, 872, 2021.
- [18] R. Mourad, H. Jaafar, M. Anderson, F. Gao. Assessment of Leaf Area Index Models Using Harmonized Landsat and Sentinel-2 Surface Reflectance Data over a Semi-Arid Irrigated Landscape, *Remote Sensing*, v. 12, 3121, 2020.
- [19] V. Gavilán, M. L. Saavedra, E. Holzapfel, D. Rivera, A. G. Pedrero. Seasonal Crop Water Balance Using Harmonized Landsat-8 and Sentinel-2 Time Series Data. *Water*, v. 11, 2236, 2019.
- [20] H. Jafaar, R. Mourad, M. Schull. A Global 30-m ET Model (HSEB) Using Harmonized Landsat and Sentinel-2, MODIS and VIIRS: Comparison to ECOSTRESS ET and LST, *Remote Sensing of Environment*, v. 274, 112995, 2022.
- [21] N. Flood. Comparing Sentinel-2A and Landsat 7 and 8 Using Surface Reflectance over Australia. *Remote Sensing*, v. 9, 659, 2017.
- [22] J. G. Masek, J. Ju, M. Claverie, S. Skakun, J. C. Roger, E. Vermote, B. Franch, Z. Yin, J. L. Dungan. Harmonized Landsat Sentinel-2 (HLS) Product User Guide - Product Version 2.0. Disponível em: [https://lpdaac.usgs.gov/documents/1326/HLS\\_User\\_Guide\\_V2.pdf](https://lpdaac.usgs.gov/documents/1326/HLS_User_Guide_V2.pdf). Acesso em 29 out. 2022.