

Automatic Detection of Irrigation Failures in Rice Crops Using Satellite Imagery and Artificial Intelligence

Delfina Valdés-Castro¹, Maite Azcue², Arturo Alcala², Martin Andreotti², Walter Cardozo², Diego Emilio Moulia², Alfredo Paine², Juan Zenon Gonzalez², Federico Pousa^{1,3}, Agustín Mosteiro¹, Daniela Villani¹, Roni Barylko¹, Maximiliano Suppes¹, Carlo Giambiagi Ferrari¹ , Lucas Rodriguez¹, and Matías Lopez-Rosenfeld^{1,4,5} 

¹ Eryx, Cooperativa de trabajo limitado, Buenos Aires, Argentina. info@eryx.co
<http://www.eryx.co>

² Adecoagro, Mercedes, Corrientes, Argentina
<https://adecoagro.com/arroz/>

³ Universidad Torcuato Di Tella

⁴ Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales.
Departamento de Computación. Buenos Aires, Argentina.
<http://www.dc.uba.ar>

⁵ CONICET-Universidad de Buenos Aires.
Instituto de Ciencias de la Computación (ICC). Buenos Aires, Argentina.
<https://icc.fcen.uba.ar/>

Resumen Irrigation monitoring in rice cultivation is a critical task for productivity, whose manual execution presents significant operational limitations at large scale. This paper presents an R&D project aimed at the automatic detection of areas with water deficit ("secones") using satellite imagery and machine learning models, developed jointly between Adecoagro and Eryx over two consecutive growing seasons (2024/25 and 2025/26).

We describe the construction of a field-validated proprietary dataset of 1,566 labeled images, the design of specialized models for different phenological stages, and the results obtained across both seasons. The proposed system achieved an F1-score of 70 % over 265 images from the 2025/26 season. The work also includes the formalization of evaluation metrics incorporating spatial tolerance, a multi-stage data validation procedure involving field operators and production managers, and the development of multimodal models that integrate spectral and contextual information. Finally, we discuss current limitations and outline directions for future work.

Keywords: irrigation , satellite imagery , artificial intelligence , deep learning , rice

Detección automática de *secones* en cultivo de arroz mediante imágenes satelitales usando Inteligencia Artificial

Resumen El monitoreo del riego en cultivos de arroz constituye una tarea crítica para la productividad, cuya ejecución manual presenta limitaciones operativas a gran escala. En este trabajo se presenta un proyecto de I+D orientado a la detección automática de zonas con déficit hídrico ("secones") mediante imágenes satelitales y modelos de aprendizaje automático, desarrollado conjuntamente entre Adecoagro y Eryx a lo largo de dos campañas consecutivas (24/25 y 25/26).

Se describe la construcción de un dataset propio de 1.566 imágenes validadas en campo, el diseño de modelos especializados para distintos estadios fenológicos y los resultados obtenidos. El sistema propuesto alcanzó un F1-score del 70 % sobre 265 imágenes de la campaña 25/26. El trabajo incluye además la formalización de métricas de evaluación con tolerancia espacial, un procedimiento de validación de datos en múltiples etapas con participación de operadores de campo y gerentes de producción, y el desarrollo de modelos multimodales que integran información espectral y contextual.

Finalmente, se discuten las limitaciones actuales y se proponen líneas de trabajo futuro.

Keywords: secones, riego, imágenes satelitales, inteligencia artificial , arroz

1. Introducción

El cultivo de arroz bajo riego requiere mantener condiciones controladas de inundación durante gran parte de su ciclo productivo. Desvíos en estas condiciones pueden derivar en zonas con déficit hídrico, comúnmente denominadas “secones”, que impactan negativamente en el rendimiento (Zhang et al., 2019).

La identificación de estas zonas se realiza tradicionalmente mediante inspección manual en campo. Este procedimiento resulta costoso en términos de tiempo y recursos humanos, y presenta dificultades de escalabilidad en explotaciones de gran superficie. Además, en la práctica, este proceso es inviable a gran escala: en campañas previas no era posible analizar la totalidad de las 65.000 hectáreas en un mismo día, lo que obligaba a priorizar subconjuntos de lotes y generaba demoras en la detección de problemas de riego.

En este contexto, las imágenes satelitales constituyen una fuente de información sistemática (González-Dugo et al., 2014) y de amplia cobertura espacial. Su utilización para el monitoreo agrícola ha sido ampliamente estudiada, particularmente mediante el uso de índices espectrales para caracterizar el estado del cultivo (Jackson et al., 1981; Tucker, 1979; Xue & Su, 2017; Zhang et al., 2019), así como mediante enfoques basados en modelos físicos para la estimación de variables hidrológicas relevantes (Allen et al., 2007). La aplicación de técnicas de inteligencia artificial sobre estas imágenes permite avanzar hacia la automatización del proceso de detección de fallas de riego.

No obstante, la complejidad del problema varía según el estadio del cultivo (Dong & Xiao, 2016; Xiao et al., 2005). En etapas tempranas (hasta aproximadamente 25 días desde el inicio del riego), las zonas secas presentan características visuales diferenciables en imágenes RGB: la densidad del follaje permite ver el terreno. En etapas más avanzadas, el desarrollo vegetativo del cultivo dificulta la discriminación directa: el follaje es demasiado denso y es lo único que captura la imagen satelital, requiriendo el uso de información espectral adicional y modelos más complejos (Dong & Xiao, 2016). En la Figura 1 se puede observar esta diferencia entre etapas tempranas y avanzadas del cultivo.

Este trabajo presenta el desarrollo y evaluación de un sistema de detección automática de secones a lo largo de dos campañas consecutivas (24/25 y 25/26), describiendo la evolución metodológica del sistema, los resultados obtenidos y las lecciones aprendidas. La campaña 24/25 permitió desarrollar e implementar una primera solución operativa; la campaña 25/26 tuvo como foco la formalización metodológica, la mejora de la calidad del dataset y el desarrollo de modelos más precisos y robustos. Con la incorporación de la herramienta propuesta, el análisis diario de imágenes puede completarse en aproximadamente tres horas, incluso en momentos de alta demanda, representando una mejora sustancial respecto al proceso manual previo.

2. Metodología

El proyecto involucra el esfuerzo combinado de tres equipos: Monitoreo y Producción, ambos de Adecoagro, y el equipo de IA de Eryx. Esta colaboración



Figura 1. Distintos estadios del cultivo de arroz. Izquierda: antes de los 25 días desde el inicio del riego, que aún se observa el suelo y se distingue fácilmente qué parte no tiene agua (4 días). Derecha: después de los 25 días desde el inicio del riego con el follaje que oculta el suelo y el agua (52 días).

multidisciplinaria fue determinante tanto para la construcción del dataset como para la validación de los modelos en condiciones reales de producción.

2.1. Construcción del dataset y validación

Al momento de iniciar el proyecto no fue posible encontrar un dataset anotado (o modelo entrenado) para el problema de detección de secones, existen grandes dataset como BigEarthNet (Sumbul et al., 2019) y SatlasPretrain (Bastani et al., 2023), pero no tienen información etiquetada del problema específico. Por esto fue necesario construir un dataset propio a partir de imágenes satelitales provenientes de distintas fuentes (incluyendo Planet y Sentinel), combinadas con un proceso de etiquetado supervisado.

Una contribución central de este trabajo es el procedimiento de validación en múltiples etapas diseñado para garantizar que las etiquetas reflejen la realidad agronómica del cultivo. A diferencia de esquemas donde el etiquetado queda exclusivamente a cargo del equipo técnico de análisis, en este proyecto se incorporó de manera formal la participación de los encargados de campo y gerentes de producción en el proceso de validación. El procedimiento implementado se estructuró en cinco etapas:

1. Generación inicial de marcado por parte de un modelo o índice.

2. Revisión técnica y ajuste preliminar por parte de los analistas del equipo de Monitoreo.
3. Feedback operativo de los encargados de campo, con validación in-situ a menos de 48 horas de obtenida la imagen satelital.
4. Validación final por parte de los gerentes de producción.
5. Consolidación y almacenamiento de las etiquetas definitivas.

Se puede observar un esquema del flujo de información en la Figura 2.




Figura 2. Esquema de trabajo para la construcción del dataset.

Este esquema de doble validación —técnica y operativa— permite reducir ambigüedades en el marcado y alinear el dataset con los criterios agronómicos que efectivamente se utilizan en la toma de decisiones. En particular, la confirmación desde campo, idealmente dentro de las 48 horas de obtenida la imagen, garantiza que las etiquetas correspondan al estado real del lote en el momento de la captura, buscando minimizar errores temporales.

El dataset final consolidado durante las dos campañas cuenta con 1.566 imágenes etiquetadas y validadas, constituyendo un activo estratégico para el entrenamiento y evaluación de futuros modelos.

Métricas de evaluación El desempeño de los modelos fue evaluado mediante métricas estándar de clasificación binaria calculadas píxel a píxel sobre la superficie sembrada de cada lote: *Accuracy*, *Precision*, *Recall* y *F1-score*.

Dado que el marcado manual sobre imágenes satelitales introduce imprecisiones inherentes —bordes difusos, variaciones subjetivas entre marcadores y errores de georreferenciación entre capas—, se incorporó un criterio de tolerancia espacial en la evaluación. Bajo este esquema, una predicción se considera correcta si existe correspondencia dentro de un radio máximo de 10 metros respecto de la verdad anotada, equivalente a 3 píxeles en imágenes Planet y 1 píxel en imágenes Sentinel. Esta tolerancia evita penalizar detecciones que, a pesar de pequeñas diferencias geométricas, resultan igualmente informativas para la intervención en campo.

2.2. Modelos y entrenamiento

El problema se abordó mediante modelos de segmentación supervisada aplicados sobre imágenes satelitales.

En particular, se utilizaron arquitecturas de redes neuronales convolucionales para segmentación semántica, inspiradas en modelos tipo U-Net (Ronneberger et al., 2015), ampliamente utilizados en tareas de segmentación en dominios con disponibilidad limitada de datos etiquetados.

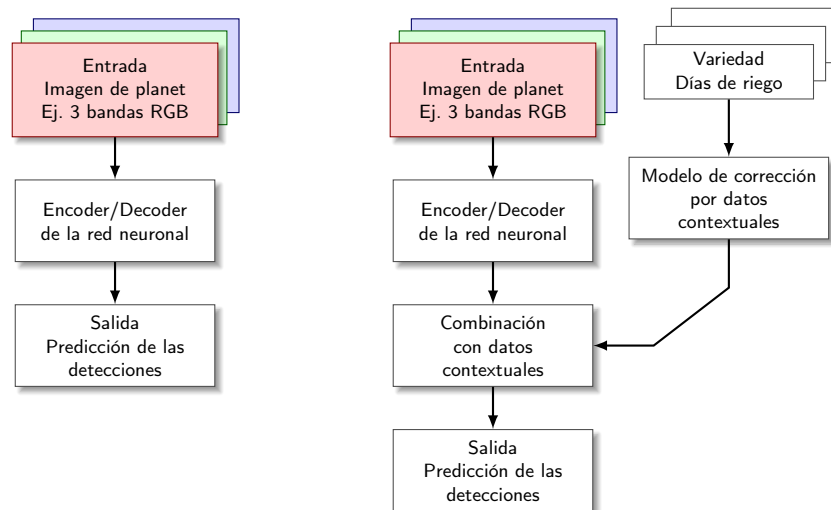


Figura 3. A la izquierda arquitectura de la red que utiliza únicamente las bandas de color RGB, a la derecha arquitectura de la red que incorpora además información contextual del cultivo.

Un aspecto central del enfoque fue la segmentación del ciclo del cultivo en dos etapas con características espectrales diferenciadas: hasta 25 días desde el

inicio del riego (DDR), cuando las zonas secas presentan características visuales identificables en imágenes RGB (usando una red como la esquematizada en la Figura 3 izquierda); y a partir de los 25 DDR, cuando el desarrollo vegetativo del cultivo dificulta la discriminación directa y requiere el uso de información espectral adicional.

El desarrollo de los modelos siguió un proceso iterativo a lo largo de las dos campañas. En una primera etapa se entrenaron modelos basados exclusivamente en etiquetas validadas por el equipo de Monitoreo, utilizando imágenes RGB para etapas tempranas e imágenes multiespectrales para etapas avanzadas. A medida que el dataset creció y se formalizó el proceso de validación, cada nueva iteración de entrenamiento incorporó etiquetas adicionales y más representativas de la realidad agronómica, produciendo mejoras progresivas y medibles en *precision* y *F1-score*. Este proceso evidenció que la calidad del dataset tiene un impacto directo y dominante sobre el desempeño de los modelos, por encima de los cambios arquitectónicos.

A partir de este punto, el foco se trasladó hacia la exploración de enfoques multimodales. Los modelos multimodales integran simultáneamente dos tipos de información: datos espectrales de las imágenes satelitales y variables contextuales del cultivo (usando una red como la esquematizada en la Figura 3 derecha). En el caso de imágenes Planet se utilizan ocho bandas espectrales originales más dos índices derivados, junto con cuatro variables tabulares: tipo de riego, días desde el inicio del riego, días desde emergencia y variedad del cultivo. Para imágenes Sentinel se incorporan diez bandas espectrales originales más diez índices derivados –incluyendo NDVI, NDMI, NDWI, NIR/SWIR e índice de clorofila, entre otros– además de las mismas variables contextuales. Esta combinación permite que el modelo no dependa únicamente de la señal espectral instantánea, sino que incorpore el estado fenológico del cultivo como variable predictiva, mejorando la capacidad de generalización en escenarios donde la señal espectral por sí sola resulta ambigua.

El pipeline de entrenamiento incluye:

1. Preprocesamiento de imágenes: recorte del área de interés, normalización de valores por banda, etc.
2. División en parches para el entrenamiento (32x32 píxeles)
3. Entrenamiento de modelos con etiquetas validadas.
4. Evaluación sobre conjuntos independientes.

Todos los modelos desarrollados durante el proyecto toman como entrada una imagen satelital, información contextual del lote a revisar y generan como solución una predicción en formato de capa visual incluida en las herramientas utilizadas por Adecoagro, tanto en el equipo de Monitoreo como en el de Producción (ver Figura 4).

2.3. Fuente de imágenes satelitales

Para el desarrollo de este proyecto se contó con acceso a imágenes satelitales de distintas fuentes, incluyendo PlanetScope y Sentinel-2. La estrategia de inte-




Figura 4. Esquema de funcionamiento de la generación de predicciones y el uso de dicha información.

gración de estas fuentes se diseñó para resolver una tensión central del problema: frecuencia temporal versus riqueza espectral.

Por un lado PlanetScope aporta cobertura de alta frecuencia, operativamente cercana a diaria, con una disponibilidad típica de aproximadamente 7-8 imágenes cada 10 días según lote y condiciones de nubosidad. PlanetScope ofrece ocho bandas espectrales (Coastal Blue, Blue, Green I, Green, Yellow, Red, Red Edge y NIR), lo que permite un monitoreo frecuente con información espectral suficiente para etapas tempranas del cultivo.

Por otro lado, Sentinel-2 aporta 13 bandas multiespectrales con resoluciones de 10, 20 y 60 metros, y una revisita nominal de 5 días en constelación (Drusch et al., 2012). La riqueza espectral de Sentinel-2 es especialmente valiosa para variables de contenido hídrico y estado de cultivo mediante bandas NIR/SWIR e índices derivados como NDVI, NDMI/NDWI. Sin embargo, su frecuencia semanal limita su uso para monitoreo diario. En etapas avanzadas del cultivo, donde la señal RGB pierde poder explicativo, la información espectral adicional de Sentinel-2 resulta crucial para mejorar la capacidad discriminativa del modelo.

2.4. Framework y lenguaje

La herramienta fue implementada en Python 3, y se apoya en varias bibliotecas para su funcionamiento. Para la construcción de los modelos de segmentación se utilizó `segmentation-models-pytorch`, que provee implementaciones preentrenadas de arquitecturas tipo U-Net y FPN, facilitando la experimentación con distintas configuraciones. Para estructurar el proceso de entrenamiento se empleó `lightning`, que permite organizar el código de manera modular y reproducible,

facilitando la gestión de ciclos de entrenamiento, validación y trazabilidad experimental.

Por otro lado, el procesamiento de imágenes satelitales y la georreferenciación se apoyó en bibliotecas como `numpy`, `rasterio` y `shapely`, que permiten manipular datos geoespaciales y convertir las imágenes multibanda en formatos adecuados para el entrenamiento e inferencia de los modelos.

Para su *deploy* se utilizó la estrategia de generar un paquete de inferencia en un repositorio privado de github que podía ser fácilmente instalable mediante pip. Este paquete proveía toda la funcionalidad para integrarse con las herramientas preexistentes de Adecoagro, permitiendo que el equipo de Monitoreo y Producción pudieran acceder a las predicciones generadas por los modelos sin necesidad de modificar su flujo de trabajo habitual, alcanzó con, una vez recibida la imagen satelital, ejecutar un comando que generaba la predicción y la incorporaba automáticamente a las herramientas de visualización utilizadas por ambos equipos.

Luego de las distintas iteraciones, se llegó a la versión final de la herramienta cuyos resultados se describen en la siguiente sección.

3. Resultados

3.1. Evaluación de la herramienta

La herramienta fue evaluada sobre un conjunto de 265 imágenes, combinando distintas etapas del cultivo. Los resultados globales muestran un *F1-score* de 70 %, con una *precision* del 75 %, un *recall* del 65 % y una *accuracy* del 99 %. Estos resultados reflejan una alta capacidad del modelo para identificar correctamente la mayoría de las instancias, aunque con margen de mejora en la detección exhaustiva (*recall*).

Antes de la incorporación del sistema, el monitoreo se realizaba mediante inspección manual y el uso de índices espectrales de umbral fijo. Este proceso no permitía analizar la totalidad de las 65.000 hectáreas en un mismo día, lo que obligaba a priorizar subconjuntos de lotes y generaba demoras en la detección de problemas de riego. Con el sistema propuesto, el análisis diario de imágenes puede completarse en aproximadamente tres horas, habilitando la cobertura completa de la superficie productiva.

3.2. Resultados por etapa fenológica

El sistema integra modelos especializados según el momento del ciclo productivo. Los resultados por etapa, evaluados con tolerancia espacial de 10 metros, muestran perfiles de desempeño diferenciados:

Etapas tempranas (hasta 25 días de riego) Evaluado sobre 50 imágenes Planet: En esta etapa el modelo alcanza su mejor desempeño. La señal visual en imágenes RGB es suficientemente discriminativa para identificar zonas con déficit hídrico, lo que se refleja en la solidez de los resultados.

Cuadro 1. Evaluación de modelos hasta los 25 días de riego.

<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
98 %	91 %	77 %	83 %

Etapla avanzada (post 25 días de riego) A partir de los 25 DDR, el desarrollo vegetativo del cultivo reduce la discriminabilidad espectral y hace necesario recurrir a información multispectral y contextual. En el Cuadro 2 se detalla la performance de las soluciones construidas.

Cuadro 2. Evaluación de modelos a partir de los 25 días de riego.

Modelo	Imágenes	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Riego PS2 v1.2 (Planet)	49	76 %	63 %	69 %
Planet Multimodal	74	78 %	59 %	67 %
Sentinel Multimodal	68	76 %	74 %	75 %

El modelo Sentinel Multimodal muestra el mejor equilibrio entre *precision* y *recall*, con un *F1-score* de 75 %. Su ventaja respecto a los modelos basados en Planet reside en la mayor riqueza espectral de las imágenes Sentinel. Su principal limitación es la disponibilidad: a diferencia de Planet, que provee cobertura diaria, Sentinel opera con frecuencia semanal, lo que restringe su uso en el monitoreo cotidiano.

3.3. Análisis cualitativo

El análisis visual de las predicciones permite observar que el modelo captura adecuadamente patrones espaciales asociados a zonas secas en etapas tempranas. Sin embargo, en etapas avanzadas se identifican confusiones con otras condiciones del cultivo (por ejemplo, bajo stand de plantas o presencia de malezas), lo cual afecta la performance del sistema.

4. Discusión y conclusiones

Los resultados obtenidos indican que la detección automática de secones mediante imágenes satelitales e inteligencia artificial es viable como herramienta de apoyo al monitoreo de riego en cultivos de arroz a gran escala.

Desde el punto de vista operativo, el sistema permite completar el análisis diario de imágenes en aproximadamente tres horas, habilitando la cobertura completa de las 65.000 hectáreas bajo monitoreo en un único ciclo de análisis. Esto representa un cambio cualitativo respecto al proceso manual previo, donde la escala obligaba a priorizar subconjuntos de lotes.




Figura 5. Izquierda: visualización de la imagen satelital de las bandas RGB. Derecha: capa de predicción generada por la herramienta que indica el estado del lote (marrón: sección, azul: bien regado).

Un aspecto central de este trabajo es que la mejora en el desempeño no respondió únicamente a cambios en la arquitectura de los modelos, sino fundamentalmente a la formalización del proceso de construcción del dataset. La incorporación de un esquema de doble validación —técnica y operativa— con participación activa de encargados de campo y gerentes de producción permitió construir un conjunto de datos más representativo de la realidad agronómica, con impacto directo y medible en los resultados.

No obstante, el análisis por etapa fenológica revela una asimetría relevante. En etapas tempranas (hasta 25 DDR), donde la señal visual en imágenes RGB es suficientemente discriminativa, el modelo alcanza un *F1-score* de 83 % con tolerancia espacial. En etapas avanzadas (post 25 DDR), el desarrollo vegetativo reduce la discriminabilidad espectral y el desempeño cae, aun con el uso de información multiespectral y contextual. El mejor resultado en esta etapa corresponde al modelo Sentinel Multimodal (*F1-score* 75 %), cuya principal limitación es la frecuencia semanal de las imágenes, que restringe su uso en el monitoreo cotidiano. Esta dependencia estructural del estadio fenológico debe considerarse en el diseño de cualquier solución de monitoreo automatizado para este cultivo.

Una contribución adicional de este trabajo es la formalización de un esquema de métricas con tolerancia espacial adaptado a las particularidades del problema: imprecisión inherente del marcado manual, errores de alineación entre capturas satelitales y naturaleza continua del fenómeno. Este esquema permite comparar versiones de modelos bajo criterios objetivos y compartidos, y constituye una base metodológica reutilizable para trabajos futuros en dominios similares.

5. Trabajo futuro

Las líneas de investigación futuras se orientan a superar las limitaciones identificadas en el sistema actual.

En primer lugar, el proceso de etiquetado presenta oportunidades de mejora en términos de precisión espacial. El marcado manual sobre imágenes satelitales introduce imprecisiones inherentes en los bordes de las zonas detectadas. El desarrollo de metodologías más rigurosas, como el uso de lotes testigo con condiciones controladas o técnicas de clustering para detectar patrones sistemáticos en los errores de marcado, permitiría construir datasets de mayor calidad y reducir el ruido en el entrenamiento.

En segundo lugar, la incorporación de nuevas fuentes de imágenes satelitales representa una línea de trabajo prometedora. La dependencia actual de Planet para cobertura diaria y Sentinel para información multiespectral introduce limitaciones complementarias: Planet carece de las bandas espectrales necesarias para etapas avanzadas, mientras que Sentinel no provee cobertura diaria. La evaluación de plataformas con mayor resolución espectral y temporal podría reducir esta restricción estructural (Noman et al., 2024; Reed et al., 2023).

En tercer lugar, los resultados obtenidos con los modelos multimodales sugieren que la integración de múltiples fuentes de información es una dirección de potencial mejora. Queda por explorar la combinación simultánea de imágenes Planet y Sentinel dentro de un mismo modelo, así como la incorporación de series temporales que capturen la evolución del cultivo a lo largo del ciclo productivo (Follath et al., 2024; Tarasiou et al., 2023).

Finalmente, la integración de sensores adicionales en campo —como mediciones de nivel de agua o datos de telemetría— podría aportar información complementaria a la señal satelital, especialmente en situaciones donde las condiciones atmosféricas limitan la disponibilidad de imágenes o donde la señal espectral resulta ambigua.

Agradecimientos

Agradecemos a los equipos técnicos y de campo que participaron en la generación y validación de los datos, así como a las instituciones involucradas en el desarrollo del proyecto.

Nota sobre el uso de inteligencia artificial

Durante la preparación de este trabajo, los autores utilizaron Claude con el fin de mejorar, revisar y corregir el manuscrito. Tras utilizar esta herramienta, se revisó y editó el contenido según fuera necesario, asumiendo plena responsabilidad por el contenido de la publicación.

Referencias

- Allen, R. G., Tasumi, M., & Trezza, R. (2007). Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC). *Journal of Irrigation and Drainage Engineering*, 133(4), 380-394. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380))

- Bastani, F., Wolters, P., Gupta, R., Ferdinando, J., & Kembhavi, A. (2023). SatlasPretrain: A Large-Scale Dataset for Remote Sensing Image Understanding. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 16772-16782.
- Dong, J., & Xiao, X. (2016). A review of remote sensing for rice mapping and monitoring. *Remote Sensing*, 8(9), 712. <https://doi.org/10.3390/rs8090712>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25-36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Follath, T., Mickisch, D., Hemmerling, J., Erasmi, S., Schwieder, M., & Demir, B. (2024). Multi-Modal Vision Transformers for Crop Mapping from Satellite Image Time Series. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*.
- González-Dugo, M. P., Neale, C. M. U., Mateos, L., Kustas, W. P., Prueger, J. H., Anderson, M. C., & Li, F. (2014). Using remote sensing to monitor irrigation performance in agriculture. *Agricultural Water Management*, 144, 1-14. <https://doi.org/10.1016/j.agwat.2014.05.005>
- Jackson, R. D., Idso, S. B., Reginato, R. J., & Pinter Jr, P. J. (1981). Canopy temperature as a crop water stress indicator. *Water Resources Research*, 17(4), 1133-1138. <https://doi.org/10.1029/WR017i004p01133>
- Noman, M., Naseer, M., Cholakal, H., Anwar, R. M., Khan, S., & Khan, F. S. (2024). Rethinking Transformers Pre-training for Multi-Spectral Satellite Imagery. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Reed, C. J., Gupta, R., Li, S., Brockman, S., Funk, C., Clipp, B., Keutzer, K., Candido, S., Uyttendaele, M., & Darrell, T. (2023). Scale-MAE: A Scale-Aware Masked Autoencoder for Multiscale Geospatial Representation Learning. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 4088-4099.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Sumbul, G., Charfuelan, M., Demir, B., & Markl, V. (2019). BigEarthNet: A Large-Scale Benchmark Archive for Remote Sensing Image Understanding. *IGARSS 2019 – 2019 IEEE International Geoscience and Remote Sensing Symposium*, 5901-5904. <https://doi.org/10.1109/IGARSS.2019.8900532>
- Tarasiou, M., Chavez, E., & Zafeiriou, S. (2023). ViTs for SITS: Vision Transformers for Satellite Image Time Series. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 10418-10428.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.

- Xiao, X., et al. (2005). Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. *Remote Sensing of Environment*, 95(4), 480-492. <https://doi.org/10.1016/j.rse.2004.12.009>
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017.
- Zhang, C., et al. (2019). Monitoring crop water stress using remote sensing: A review. *Agricultural Water Management*, 223, 105707. <https://doi.org/10.1016/j.agwat.2019.105707>