

Detección automática del riego por pivote central a partir de imágenes satelitales de alta resolución en el norte de Buenos Aires (2016-2023)

Barrionuevo, Néstor¹, Havrylenko, Sofía¹, Sepulcri, Gabriela², Casella, Alejandra¹ y Espíndola, Aimé¹

¹ Instituto de Clima y Agua. INTA, Los Reseros s/n, Hurlingham, Buenos Aires

² Agencia de Extensión Rural Luján.

barrionuevo.nestor@inta.gob.ar

Resúmen. El riego por pivote central permite aumentar la productividad agrícola y adaptarse a la variabilidad climática ante la creciente demanda alimentaria y la escasez de agua. Este estudio analiza su expansión en el norte de la provincia de Buenos Aires, Argentina entre 2016 y 2023 mediante el uso de imágenes satelitales Sentinel-2 del programa Copernicus y algoritmos de detección automática. Se calcularon índices espectrales como el NDVI, EVI y WRI, que sirvieron como insumos para el modelo Grounding DINO. Este modelo combina la visión por computadora e inteligencia artificial (IA) basada en lenguaje natural y se adaptó para identificar los patrones circulares típicos del riego por pivote en una región caracterizada por vegetación continua que dificulta la detección automatizada. La metodología desarrollada permitió detectar un aumento del 159% en la cantidad de sistemas de riego durante el período de estudio, asociado a eventos de sequía agrícola que impulsaron su adopción. El modelo alcanzó una métrica F1-Score del 73,2%, que mostró su efectividad en la Pampa Húmeda. Los resultados demuestran que la integración de teledetección e IA permiten monitorear de forma eficiente la expansión de esta tecnología agrícola. Asimismo, se destaca la necesidad de continuar con los modelos de IA para mejorar la detección y caracterización de objetos geográficos, que contribuyan a una gestión sostenible de los recursos hídricos.

Palabras clave: Riego por aspersión, imágenes satelitales, inteligencia artificial.

Automatic detection of centre-pivot irrigation from high-resolution satellite imagery in northern Buenos Aires (2016-2023)

Abstract. Center-pivot irrigation enhances agricultural productivity and adapts to climate variability amid growing food demand and water scarcity. This study analyzes its expansion in northern Buenos Aires Province, Argentina, between 2016 and 2023 using Sentinel-2 satellite imagery from the Copernicus program and automated detection algorithms. Spectral indices such as NDVI, EVI, and WRI were calculated and served as inputs for the Grounding DINO model. This

model combines computer vision and natural language-based artificial intelligence (AI) and was adapted to identify the circular patterns typical of center-pivot irrigation in a region characterized by continuous vegetation, which complicates automated detection. The developed methodology detected a 159% increase in irrigation systems during the study period, linked to agricultural drought events that drove their adoption. The model achieved an F1-Score of 73.2%, demonstrating its effectiveness in the Pampa Húmeda region. The results show that integrating remote sensing and AI enables efficient monitoring of this agricultural technology's expansion. Furthermore, the study highlights the need to continue developing AI models to improve the detection and characterization of geographic features, supporting sustainable water resource management.

Keywords: Sprinkler irrigation, satellite imagery, artificial intelligence.

1 Introducción

El riego agrícola constituye una herramienta clave para garantizar la estabilidad en la producción de alimentos frente a la variabilidad climática. Actualmente, más de 340 millones de hectáreas están bajo riego a nivel mundial, con un incremento del 53 % desde el año 2000 (FAO, 2021). En regiones como la Pampa Húmeda argentina, donde la disponibilidad hídrica presenta una marcada variabilidad interanual, el riego por pivote central tuvo un crecimiento exponencial, no solo como medida de adaptación, sino también como estrategia para maximizar rendimientos (Riera et al., 2017). Esta expansión, impulsada por factores económicos y condiciones agroclimáticas favorables, conlleva riesgos significativos para la sustentabilidad de los recursos hídricos, como la modificación de los niveles freáticos, la disminución de reservas subterráneas y el deterioro de la calidad del agua. En consecuencia, resulta indispensable implementar estrategias de monitoreo rápidas y de bajo costo que permitan identificar y cuantificar la distribución espacial y temporal de las áreas irrigadas.

La falta de datos actualizados sobre la superficie irrigada en Argentina representa una limitación significativa en la gestión sostenible del agua (Barrionuevo et al., 2022). Tradicionalmente, el relevamiento de pivotes se realizaba mediante la interpretación visual de imágenes satelitales (Bauder et al., 2004), un proceso lento y propenso a errores. En los últimos 15 años, la inteligencia artificial (IA) experimentó avances significativos, lo que impulsó el desarrollo de nuevas herramientas para el análisis de datos y la automatización de tareas complejas. Dentro de este campo, destacan el aprendizaje automático (*machine learning*) y en particular, el aprendizaje profundo (*deep learning*) cuya evolución ha sido posible gracias al aumento del poder computacional y la disponibilidad de grandes volúmenes de datos. Entre las técnicas más relevantes del aprendizaje profundo se encuentran las redes neuronales convolucionales (*convolutional neural networks*, CNN), las cuales han demostrado una alta eficacia en el reconocimiento de patrones y objetos en imágenes satelitales como los círculos de riego (Zhang et al., 2018). Aunque estos avances han abierto nuevas posibilidades para automatizar este proceso, persiste un vacío debido a que la mayoría de los algoritmos automatizados se desarrollaron para ambientes áridos (Johansen et al., 2021), donde los círculos de riego son más distintivos.

Modelos recientes como *U-Net* (Saraiva *et al.*, 2020) y *Pivot-Net* (Fuyou *et al.*, 2023) han alcanzado precisiones superiores al 95 % en la detección de pivotes en regiones de Estados Unidos y Brasil. Sin embargo, su rendimiento disminuye en entornos como la Pampa Húmeda, donde la vegetación continua y la alta intensidad de cultivos dificultan la identificación automática de patrones circulares (Graf *et al.*, 2020). Existen aún pocos estudios orientados a adaptar estas tecnologías a contextos de agricultura intensiva con alta cobertura vegetal. Este escenario plantea la necesidad de desarrollar algoritmos innovadores capaces de fusionar visión por computadora y contexto geoespacial para mejorar la precisión del análisis.

En este trabajo se presenta una metodología basada en *Grounding DINO* (Liu *et al.*, 2023), un modelo de IA que combina imágenes Sentinel-2 y descriptores textuales para detectar pivotes centrales de forma automática. A diferencia de las CNN tradicionales, este enfoque aprovecha modelos pre-entrenados en lenguaje natural, lo cual reduce la necesidad de contar con grandes volúmenes de datos etiquetados. Además, se incorporan índices espectrales para identificar patrones de vegetación asociados al riego, incluso en paisajes heterogéneos. El objetivo de este estudio fue cuantificar la expansión del riego por pivote central entre 2016 y 2023 mediante algoritmos de IA, validar la precisión de los resultados obtenidos en un ambiente húmedo y evaluar la influencia de la variabilidad climática en dicha expansión.

2 Materiales y método

El presente estudio se desarrolló en los partidos de Pergamino, Rojas, Salto y Bartolomé Mitre, al norte de la provincia de Buenos Aires, Argentina ($33^{\circ}36' - 34^{\circ}35' S$; $59^{\circ}31' - 61^{\circ}28' O$) (Fig.1).

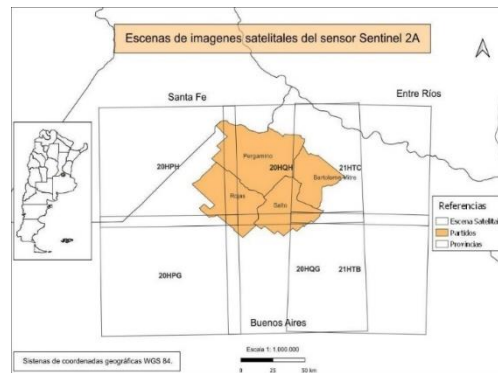


Fig. 1. Área de estudio. Escenas del sensor Sentinel-2.
Fuente: Elaboración propia.

Esta región presenta un clima templado y una elevada productividad agrícola, con predominancia de cultivos extensivos como trigo, maíz y soja, sobre suelos *Argiudoles* típicos (Havrylenko, 2013). El relieve corresponde a la unidad geomorfológica de la Pampa Ondulada, caracterizada por pendientes suaves (<2 %) y una alta capacidad de

recarga hídrica (Auge, 2004). El principal recurso hídrico para el riego proviene del acuífero Pampeano, con aporte secundario del acuífero Puelches (Etcheverry, 2014).

El análisis de entrenamiento y validación de la metodología se centró en octubre 2022-marzo 2023 correspondiente al ciclo de cultivos estivales, para ajustar un modelo de detección automática de sistemas de riego por pivote central en vegetación densa. Para el análisis retrospectivo, se consideraron los mismos meses del período 2016-2022.

La primera etapa consistió en la selección y procesamiento de las imágenes que sirvieran como entrada al modelo *Grounding DINO* (Liu *et al.*, 2023). El mismo es un modelo de detección de objetos en imágenes que esta pre-entrenado con un set de datos basados en el modelo Segment Anything Model (SAM) (Kirillov *et al.*, 2023) de la empresa Meta, de modo que no se entrenó al modelo. Se utilizaron imágenes multiespectrales de los satélites Sentinel-2A y Sentinel-2B del programa Copernicus (ESA), que cuentan con 13 bandas espectrales y resoluciones espaciales de 10, 20 y 60 metros, dependiendo de la banda (Sentinels, 2023). La selección de escenas libres de nubes se realizó mediante el complemento qgis-earth-engine (Donchyts *et al.*, 2023), utilizando imágenes correspondientes a los mosaicos 20HPPH, 20HQH, 20HPG, 20HQG, 21HTC y 21HTB (Fig. 1), los cuales cubren completamente el área de estudio.

A partir de estas imágenes se calcularon tres índices espectrales: el índice de vegetación de diferencia normalizada (NDVI) (Rouse *et al.*, 1973), el índice de vegetación mejorado versión 2 (EVI2) (Jiang *et al.*, 2008) y el índice de proporción de agua (WRI) (Shen y Li, 2010). Estos índices, derivados de combinaciones entre las bandas del espectro visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR), se generaron mediante scripts en Python dentro del entorno QGIS. Fueron seleccionados por su capacidad para resaltar características biofísicas y contenido de humedad de la vegetación, permitiendo discriminar con mayor precisión las áreas irrigadas (Casella *et al.*, 2022). Se calcularon promedios mensuales de cada índice (Fig. 2), se generaron composiciones multibanda en las que las bandas B1, B2 y B3 representaron tres meses consecutivos (octubre-noviembre-diciembre y enero-febrero-marzo), lo que mejoró el contraste visual de los círculos de riego.

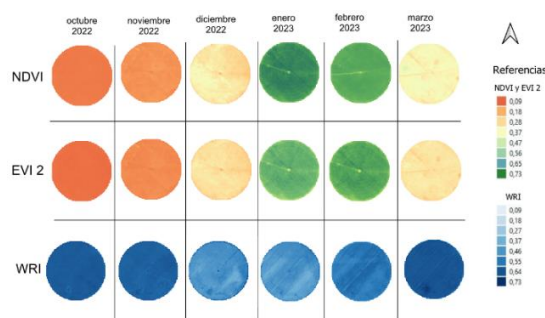


Fig. 2. Índices espectrales de vegetación (NDVI, EVI 2 y WRI) de un círculo de riego.

Fuente: Elaboración propia.

La segunda etapa correspondió a la detección automática de círculos de riego. Para ello se empleó el modelo *Grounding DINO* (Liu *et al.*, 2023), una red neuronal preentrenada para tareas de detección de objetos mediante descripciones textuales. A diferencia de las redes neuronales convolucionales tradicionales, este modelo puede ser aplicado a imágenes multiespectrales sin requerir grandes volúmenes de datos etiquetados. La implementación se llevó a cabo en la plataforma *Google Colaboratory*.

El modelo generó cajas delimitadoras (*bounding boxes*) alrededor de los objetos detectados (Fig. 3 a), las cuales funcionaron como máscaras para identificar ubicación y dimensiones de cada círculo. Se ajustaron manualmente los parámetros de detección: *Box_Threshold* = 0.40 y *Text_Threshold* = 0.90 y se definieron clases semánticas específicas en inglés como "*satellite view crop circle*". Los mismos fueron ajustados empíricamente debido a que este modelo pre-entrenado no lo estaba para imágenes satelitales. Este filtrado permitió descartar las detecciones con baja confianza. Luego, se procedió a la segmentación binaria de las imágenes (1 = presencia de círculo; 0 = ausencia) y los resultados fueron exportados en formato GeoTIFF (Fig.3 b).




Fig. 3. a. Cajas de detección generadas por el modelo *Grounding DINO*.

b. Segmentación de los círculos de riego.

Fuente: Elaboración propia.

Una vez obtenidas las imágenes segmentadas, se llevó a cabo un proceso de post-clasificación en QGIS, donde se analizaron las imágenes generadas por el modelo y se transformaron de formato raster a formato vectorial (*shapefiles*) y se eliminaron los errores de la detección (Fig. 4). Finalmente, las imágenes segmentadas fueron procesadas en QGIS para su vectorización, corrección de errores y asignación de atributos espaciales y administrativos (ID, partido, superficie, entre otros).

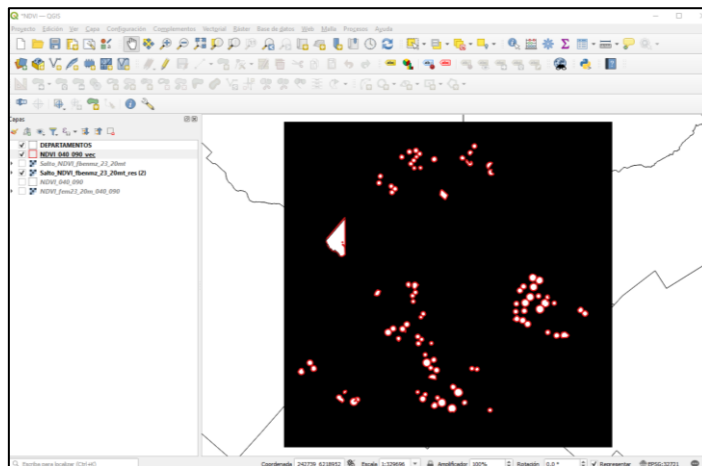


Fig. 4. Proceso de vectorización del raster de salida de los círculos de riego.

Fuente: Elaboración propia en Qgis.

Para facilitar análisis posteriores, se incorporaron cuatro atributos a la base de datos de salida en formato vectorial: ID único para cada polígono, el partido al que pertenece, la provincia y el cálculo de la superficie de cada polígono.

La tercera etapa consistió en la validación del modelo mediante una matriz de confusión, construida en Qgis a partir de una grilla de puntos de control con separación regular de 1 km (Fig. 5).

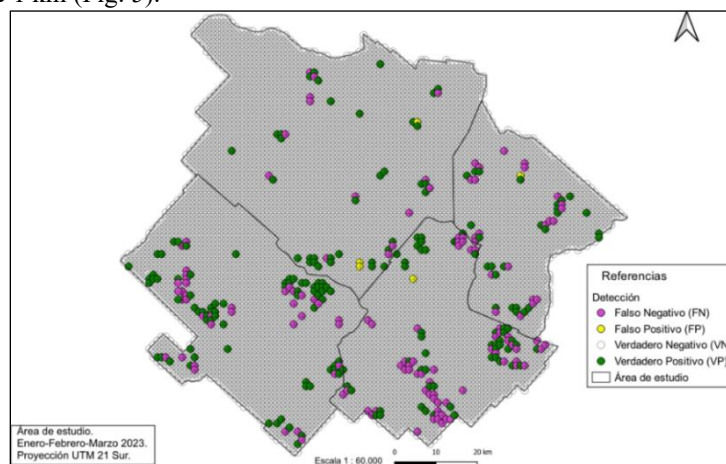


Fig. 5. Detección de los círculos en la grilla de puntos.

Fuente: Elaboración propia.

Sobre esta grilla se compararon las predicciones del modelo con una interpretación visual experta de las imágenes satelitales, considerada como referencia de verdad de campo. Cada punto fue clasificado según las siguientes categorías:

- Verdadero Positivo (VP): el modelo predice la presencia de un círculo de riego y este realmente está presente en la imagen.
- Falso Positivo (FP): el modelo predice un círculo de riego en una ubicación donde no existe.
- Falso Negativo (FN): el modelo no detecta un círculo que efectivamente está presente.
- Verdadero Negativo (VN): el modelo predice correctamente la ausencia de un círculo.

A partir del recuento de estas cuatro categorías, se calcularon las métricas estándar de desempeño en clasificación binaria (Müller y Guido, 2016) que se muestra en la Tabla 1.

Tabla 1. Definición de métricas de desempeño del modelo de clasificación binaria.

Métrica	Símbolo	Fórmula	Descripción
Exactitud	<i>Accuracy</i>	$(VP + VN)/(VP + FP + FN + VN)$	Proporción de predicciones correctas respecto al total de observaciones.
Precisión	<i>Precision</i>	$VP / (VP + FP)$	Proporción de verdaderos positivos entre todos los casos predichos como positivos.
Sensibilidad	<i>Recall</i>	$VP / (VP + FN)$	Capacidad del modelo para identificar correctamente todos los positivos reales.
Especificidad	<i>Specificity</i>	$VN / (VN + FP)$	Proporción de negativos correctamente identificados por el modelo.
Tasa de falsos positivos	TFP	$FP / (FP + VN)$	Proporción de negativos incorrectamente clasificados como positivos.
Tasa de falsos negativos	TFN	$FN / (FN + VP)$	Proporción de positivos no detectados por el modelo.
Puntaje F1	<i>F1-Score</i>	$2 \times (Precision \times Recall) / (Precision + Recall)$	Media armónica entre precisión y sensibilidad, útil cuando hay desbalance entre clases.

El conteo de cada clase permitió calcular estas métricas en una hoja de cálculo, lo que proporcionó una evaluación cuantitativa robusta de la precisión y eficacia del modelo de detección.

3 Resultados

3.1 Resultados de la detección automática de círculos de riego

La aplicación del modelo *Grounding DINO* (Liu *et al.*, 2023) permitió la detección automática de círculos de riego a partir de imágenes Sentinel-2 procesadas mediante los índices espectrales NDVI, EVI2 y WRI. El análisis se realizó considerando dos períodos temporales: octubre - diciembre de 2022 y enero - marzo de 2023. Los resultados obtenidos evidencian diferencias en el desempeño del modelo según el índice empleado, el partido analizado y el año considerado (Tabla 2).

Tabla 2. Cantidad de círculos detectados.

	Salto		Rojas		Btomé. Mitre		Pergamino	
	2022	2023	2022	2023	2022	2023	2022	2023
NDVI	76	74	88	102	38	46	52	53
EVI2	73	80	89	100	44	44	54	53
WRI	79	76	85	86	40	47	55	56

Durante el período enero - marzo de 2023 la cartografía resultante del modelo presentó su mayor eficiencia en la detección de círculos de riego (Fig. 6). En el partido de Salto, el índice EVI2 fue el más efectivo, con 80 círculos detectados. En Rojas, tanto NDVI como EVI2 evidenciaron un desempeño alto y consistente, con 102 y 100 detecciones, respectivamente. Por su parte, en los partidos de Bartolomé Mitre y Pergamino, el índice WRI fue el que alcanzó el mejor rendimiento, con 47 y 56 círculos detectados en cada caso. En 2022, las diferencias en la cantidad de círculos detectados entre los índices fueron menores, mostrando un desempeño más homogéneo.

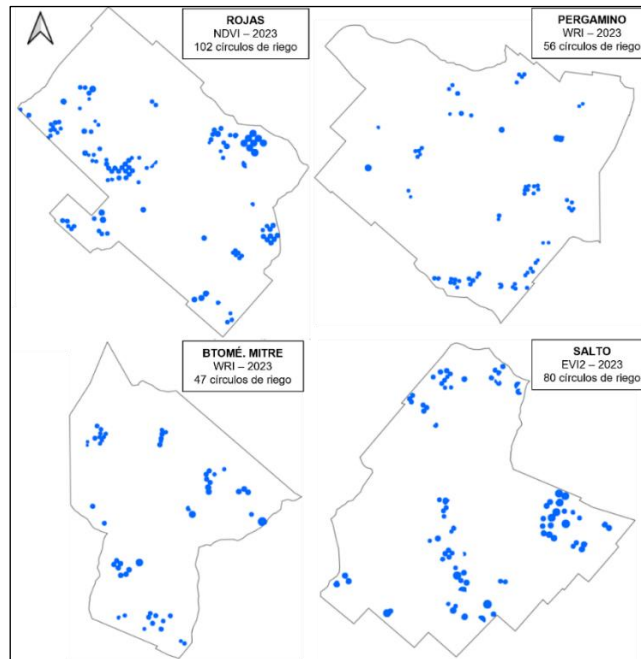


Fig. 6. Cartografía de los círculos de riego detectados por el modelo.

Fuente: Elaboración propia

El análisis temporal entre 2016 y 2023, restringido al período enero-marzo, reveló un incremento sostenido en la detección de círculos en todos los partidos (Tabla 3). En Rojas, la cantidad de círculos detectados aumentó de 25 en 2016 a 102 en 2023. En Salto, se registró un incremento entre 2016 y 2017 de 24 círculos, manteniéndose luego una tendencia estable. En Pergamino, se observó un aumento de 21 círculos entre 2021 y 2022, mientras que en Bartolomé Mitre el salto más significativo se dio entre 2022 y 2023, con 26 nuevos círculos detectados. Estos aumentos podrían asociarse a la disminución de precipitaciones en la región, lo cual habría incentivado la incorporación de sistemas de riego por pivote central.

Tabla 3. Cantidad de círculos detectados en el área de estudio.

Partidos	Años							
	2016	2017	2018	2019	2020	2021	2022	2023
Salto	39	63	76	69	60	65	72	80
Rojas	25	58	58	64	63	72	88	102
Btomé. Mitre	16	22	22	19	15	31	21	47
Pergamino	30	21	33	34	28	36	57	56
Total	110	164	189	186	166	204	238	285

3.2 Resultados de las métricas de la detección automática

La validación del modelo se llevó a cabo empleando una grilla de 1 km por 1 km, que permitió una comparación precisa entre las clases reales y las predicciones generadas por el algoritmo.

En el campo Detección donde quedaron los ceros (0), luego se clasificaron con unos (1) donde había círculos de riego y ceros (0) donde no. Visualmente se cargaron los datos al campo Imagen (considerada realidad de campo), donde uno (1), coincidía con un círculo de riego en la imagen. También se agregó el campo Resultado donde se analizaron los campos Imagen y Detección para clasificar las muestras (Tabla 4).

Tabla 4. Variables para generar la matriz de confusión.

Fuente: Elaboración propia a partir de Müller y Guido (2016).

Valor	Imagen	Detección
Verdadero Positivo (VP)	1	1
Falso Positivo (FP)	0	1
Falso Negativo (FN)	1	0
Verdadero Negativo (VN)	0	0

Posteriormente se realizó el conteo de las muestras para la determinar las variables verdadero positivo (VP), verdadero negativo (VN), falso negativo (FN) y falso positivo (FP) (Fig. 7).

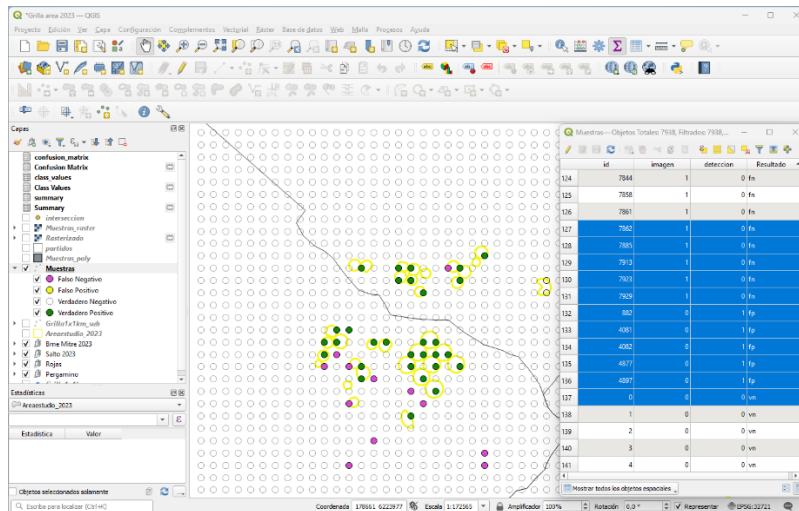


Fig. 7. Visualización de las variables verdadero positivo (VP), verdadero negativo (VN), falso negativo (FN) y falso positivo (FP).

Fuente: Elaboración propia en Qgis.

A partir de esta comparación se construyó una matriz de confusión y se calcularon las métricas de rendimiento (Tabla 5). El modelo presentó una exactitud de 98,31 % y una precisión de 98,39 %, lo cual indica una gran capacidad para clasificar correctamente los casos positivos identificados. Sin embargo, la sensibilidad fue significativamente menor (58,28 %), lo que sugiere que el modelo tiende a no identificar algunos casos positivos, a pesar de ser confiable en los que detecta. El puntaje F1-Score, que integra precisión y sensibilidad en una sola métrica, alcanzó un 73,2 %. Esto evidencia un desempeño general aceptable, aunque con espacio para mejorar la capacidad de detección de la clase positiva (círculos de riego).

Tabla 5. Métricas del modelo. Unidad de medida (%).

Métricas	Porcentajes
Exactitud	98.31
Precisión	98.39
Sensibilidad	58.28
Especificidad	99.96
Tasa falsos positivos	0.04
Tasa falsos negativos	41.72
Puntaje F1	73.20

Con relación a la influencia de la variabilidad climática sobre la evolución del riego por pivote central, se realizó un análisis de los datos históricos de precipitaciones y de las ventas de equipos de riego. Los registros mensuales y anuales de precipitaciones entre diciembre y febrero fueron comparados con los datos de ventas de equipos de aspersión relevados por Valmont Industries Argentina para los años 1996 a 2023. Se observó que los picos en las ventas (más de 500 equipos en 1996 y más de 350 en 1997 y 2008) coinciden con años de precipitaciones por debajo del promedio. De forma similar, en 2023, otro año marcado por bajos valores de precipitación, se detectaron 285 círculos de riego mediante el modelo, el valor más alto del período 2016-2023. Estos resultados sugieren una fuerte vinculación entre las condiciones de sequía y la incorporación de sistemas de riego presurizados. En particular, las severas sequías ocurridas entre 2018 y 2022 habrían sido un factor determinante en la decisión de los productores de adoptar tecnologías de riego como estrategia de adaptación frente a la creciente variabilidad climática.

4 Discusión

Los resultados obtenidos validan la hipótesis inicial que sostiene que es posible estimar la evolución de la superficie regada por pivote central mediante un algoritmo de detección automática aplicado a imágenes satelitales de alta resolución. La metodología presentó desafíos particulares al aplicarse en un área templada, donde la presencia de lotes cultivados no irrigados dificultó la clasificación precisa. El modelo *Grounding*

DINO mostró limitaciones puntuales al agrupar varios círculos en una única caja de detección, afectando la precisión del conteo. Se propone ajustar el parámetro *img_size* de 512 a 256 píxeles para mejorar la segmentación y evitar que el algoritmo confunda sectores sin riego con estructuras circulares.

El trabajo debió adaptarse a limitaciones técnicas vinculadas al procesamiento computacional, por lo que los análisis se realizaron en *Google Colaboratory*, con suscripción paga. La disponibilidad de recursos adecuados impacta directamente en la eficiencia y en los tiempos de ejecución de los modelos de inteligencia artificial. En este estudio, el procesamiento de imágenes satelitales Sentinel-2 y la ejecución del modelo se completaron en menos de una hora por índice espectral y por partido, frente a las nueve horas reportadas por de Albuquerque *et al.* (2020) y las diez horas estimadas para detección visual según Barrionuevo *et al.* (2022), lo que evidencia una mejora significativa respecto a otros enfoques.

El modelo alcanzó un 73 % de precisión según la métrica F1-Score. Si bien este valor es inferior al reportado por Zhang *et al.* (2018) (99,79 %) o por de Albuquerque *et al.* (2020) (96 %), es importante señalar que *Grounding DINO* no fue entrenado específicamente para detectar círculos de riego, lo cual diferencia su enfoque de los modelos basados en aprendizaje profundo supervisado. Esta característica, junto con su bajo costo computacional, justifica su elección y permite proyectar mejoras a partir del uso de nuevas versiones como SAM 2, *Grounding DINO* 1.5, *SAMGEO* (Wu y Prado Osco, 2023) o el plugin *GeoAI* (Pérez, 2024).

Este trabajo aporta una metodología original y escalable para la detección automática de riego por pivote central en áreas templadas mediante imágenes satelitales. Los algoritmos utilizados son adaptables a diversas investigaciones y sus productos vectoriales, livianos, resultan aptos para estudios hidrogeológicos a gran escala y para la gestión de aguas subterráneas. Un aspecto para considerar para el futuro de esta línea de trabajo sería la inclusión de otros índices espectrales para analizar su comportamiento en la detección automática del círculo de riego por el modelo, como así también, profundizar en herramientas de análisis masivo de imágenes y visión por computadora, con especial énfasis en desarrollos vinculados a la inteligencia artificial geoespacial (GeoAI).

5 Conclusión

Los resultados obtenidos en este estudio demuestran que la detección automática de agricultura irrigada por pivote central mediante inteligencia artificial es una metodología efectiva para monitorear la evolución del riego en entornos agrícolas complejos y de alta cobertura vegetal. La implementación del modelo *Grounding DINO*, adaptado para procesar imágenes satelitales multiespectrales, permitió automatizar con precisión el reconocimiento de círculos de riego, superando las limitaciones de los enfoques visuales tradicionales y sin crear un *dataset* específico para una red neuronal convolucional específica como U-Net o Yolo. Entre 2016 y 2023, el número de círculos de riego detectados se incrementó de 110 a 285, lo que evidenció una expansión vinculada a períodos de baja precipitación y a factores socioeconómicos.

6 Bibliografía

- Auge, M. (2004). Regiones Hidrogeológicas, República Argentina y provincias de Buenos Aires, Mendoza, y Santa Fe. Asociación Latinoamericana de Hidrología Subterránea. Editado por La Asociación Latinoamericana de Hidrología Subterránea para el Desarrollo (ALHSUD). Recuperado de: <http://sedici.unlp.edu.ar/handle/10915/15909>
- Barrionuevo, N.; Waldman, C. y Martínez R. (2022). Análisis espacio temporal del riego por pivote central en la República Argentina en el período 1995-2015. VI Congreso Internacional de Ordenamiento Territorial y Tecnologías de la Información Geográfica. 26 al 28 de octubre de 2022. Ciudad Autónoma de Buenos Aires-Argentina. Universidad Nacional de Luján. Del 7 al 11 de noviembre de 2016.
- Bauder, T.; Cipra, J.; Waskom, R. y Gossenauer, M. (2004). Center pivot irrigation in Colorado as mapped by Landsat imagery. Colorado Agricultural Experiment Station. Department of Soil and Crop Science. Colorado State University.
- Casella, A.; Orden, L.; Pezzola, N.A.; Bellacomo, C.; Winschel, C.I.; Caballero, G.R.; Delegido, J.; Gracia, L.M.N.; Verrelst, J. (2022). Analysis of Biophysical Variables in an Onion Crop (*Allium cepa* L.) with Nitrogen Fertilization by Sentinel-2 Observations. *Agronomy* 2022, 12, 1884. Recuperado de: <https://doi.org/10.3390/agronomy1208188>
- de Albuquerque, A.; de Carvalho Júnior, O.; Carvalho, O. L. F. de; de Bem, P.; Ferreira, P.; de Moura, R. dos S. y Silva, C. (2020). Deep Semantic Segmentation of Center Pivot Irrigation Systems from Remotely Sensed Data. *Remote Sensing*, 12(13), 2159. MDPI AG. Recuperado de <http://dx.doi.org/10.3390/rs12132159>
- Donchyts, G.; Corredor Llano, X. y Baart, F. (2023). Complemento qgis-earth-engine. Recuperado de: https://plugins.qgis.org/plugins/ee_plugin/#plugin-details
- Etcheverry, M. (2014). Aprovechamiento sustentable de los recursos hídricos para riego complementario de cultivos extensivos en la Cuenca del Río Arrecifes, Provincia de Buenos Aires. Tesis de Maestría en Manejo Integral de Cuencas Hidrográficas. Universidad Nacional de La Plata. Repositorio institucional. Recuperado de: <http://sedici.unlp.edu.ar/handle/10915/34474>
- Food Agriculture Organization (FAO) (2021). El estado de los recursos de tierras y aguas del mundo para la alimentación y la agricultura - Sistemas al límite. Informe de síntesis 2021. Rome. Recuperado de: <https://doi.org/10.4060/cb7654es>
- Fuyou T., Bingfang W., Hongwei Z., Miao Z., Yueran H., Yan X., Congcong W., Zhengdong W., Xingli Q., Wei H. y Honghai Y. (2023). A shape-attention Pivot-Net for identifying central pivot irrigation systems from satellite images using a cloud computing platform: an application in the contiguous US. *GIScience & Remote Sensing*, 60:1. Recuperado de: <https://doi.org/10.1080/15481603.2023.2165256>
- Graf, L., Bach, H., y Tiede, D. (2020). Semantic Segmentation of Sentinel-2 Imagery for Mapping Irrigation Center Pivots. *Remote Sensing*, 12(23), 3937. MDPI AG. Recuperado de: <http://dx.doi.org/10.3390/rs12233937>
- Havrylenko, S. (2013). Caracterización de sequías en la cuenca agrícola de la región pampeana mediante la aplicación del modelo hidrológico SWAT. Tesis de Maestría en Ingeniería de los recursos hídricos. Facultad de ingeniería y Ciencias hídricas. Universidad Nacional del Litoral. Recuperado de: <https://bibliotecavirtual.unl.edu.ar:8443/handle/11185/527?show=full>
- Jiang, Z.; Huete A.; Didan K. y Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, Volume 112, Issue 10, 2008, Pages 3833-3845, ISSN 0034-4257. Recuperado de: <https://www.sciencedirect.com/science/article/pii/S0034425708001971>

- Johansen, K.; Lopez, O.; Tu, Y.; Li, T y McCab, M. (2021). Center pivot field delineation and mapping: A satellite-driven object-based image analysis approach for national scale accounting. *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 175, Pages 1-19, ISSN 0924-2716. <https://doi.org/10.1016/j.isprsjprs.2021.02.019>.
- Kirillov, A.; Mintun, E.; Ravi, N; Mao, H.; Rolland, C.; Gustafson, L.; Xiao, T.; Whitehead, S.; Berg A.; Lo, W.; Dollár, P. y Girshick, R. (2023). Segment Anything. Recuperado de: <https://doi.org/10.48550/arXiv.2304.02643>
- Liu, S.; Zeng, Z.; Ren, T, Li, F.; Zhang, H.; Yang, J.; Li, Ch.; Yang, J. Su, H.; Zhu J y Zhang, L. (2023). Grounding DINO: Marrying DINO with Grounded Pre-Training for Open-Set Object Detection. Recuperado de: <https://arxiv.org/abs/2303.05499>
- Müller, A. y Guido S. (2016). *Introduction to Machine Learning with Python*. Editorial O'Reilly Media, Inc. ISBN: 9781449369897.
- Pérez, L. (2024). Desarrollo de plugin GeoAI para Qgis. Recuperado de (<https://www.linkedin.com/in/luisedpg/>).
- Riera, C.; Barrionuevo, N. y Gattinoni, N. (2017). Riego mecanizado con agua subterránea en Buenos Aires norte: elementos para un análisis de la lógica productiva detrás del cambio territorial. XXVI Congreso Nacional del Agua. 201 al 23 septiembre 2017. Córdoba. Argentina.
- Rouse, J.; Haas, R.; Schell, J. y Deering, D. (1973). Monitoring Vegetation Systems in the Great Plains with ERTS. 3rd ERTS Symposium, NASA SP-351, Washington DC, 10-14 December 1973, 309-317.
- Saraiva, M.; Protas, É.; Salgado, M. y Souza Jr., C. (2020). Automatic Mapping of Center Pivot Irrigation Systems from Satellite Images Using Deep Learning. *Remote Sensing*, 12(3), 558. MDPI AG. Recuperado de: <http://dx.doi.org/10.3390/rs12030558>
- Sentinels (2023). Misión Sentinel 2. Recuperado a partir de: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/>
- Shen, L. y Li, C. (2010, June). Water body extraction from Landsat ETM+ imagery using ada-boost algorithm. In 2010 18th International Conference on Geoinformatics (pp. 1-4). IEEE.
- Wu, Q. y Prado Osco, L. (2023). Samgeo: A python package for segmentation geospatial data with the Segment Anything Model (SAM). *Journal of Open Source Software*, 8 (89), 5663. Recuperado de: <https://doi.org/10.21105/joss.05663>.
- Zhang, C.; Yue, P.; Di, L. y Wu, Z. (2018). Automatic identification of center pivot irrigation systems from Landsat images using convolutional neural networks. *Agriculture*, 8(10), 147. Recuperado de: <https://www.mdpi.com/2077-0472/8/10/147>