

Estimación de rendimientos de trigo a partir de datos espectrales para el  
partido de Junín, provincia de Buenos Aires

*Trabajo final presentado para optar al título de  
Especialista en Teledetección y Sistemas de Información Geográfica*

María Paula Melilli  
Ingeniera Agrónoma - Universidad de Buenos Aires - 2007

Lugar de trabajo: AER INTA Junín



Escuela para Graduados Ing. Agr. Alberto Soriano  
Facultad de Agronomía - Universidad de Buenos Aires

## **TUTOR**

**Carlos Di Bella**

Ingeniero Agrónomo (Universidad de Buenos Aires)  
Doctor del Institut National Agronomique Paris-Grignon

## **JURADOS DE TRABAJO FINAL**

**Juan José Gaitán**

Ingeniero Agrónomo (Universidad Nacional de Luján)  
Magister Scientiae en Recursos Naturales (Universidad de Buenos Aires)  
Doctor en Ciencias Agropecuarias (Universidad de Buenos Aires)

**Juan Ignacio Whitworth Hulse**

Biólogo (Universidad Nacional de Córdoba)  
Doctor en Ciencias Biológicas (Universidad Nacional de Córdoba)

Fecha de defensa del Trabajo Final: 02 de DICIEMBRE de 2024

## **Agradecimientos**

Mi más profundo agradecimiento a Julieta Straschnoy y a Carlos Di Bella por su dedicación y paciencia infinita. Su comprensión y estímulo, ha sido fundamental para concluir este trabajo.

A los Ingenieros Agrónomos: Juan P Cobuta, Juan Espart, Pablo Ferrari, Cristian Franco, Eduardo Muñoz y Gustavo Villoros que colaboraron proporcionando datos, les agradezco su contribución fundamental para llevar a cabo este proyecto.

Al INTA que financio mis estudios y compañeros de la institución que me acompañaron y apoyaron en esta etapa.

A los Jurados Juan José Gaitán y Juan Ignacio Whitworth Hulse, que con sus aportes y sugerencias contribuyeron a mejorar la calidad final del trabajo.

A mi Familia por su apoyo, paciencia y fe. Y a los que no están físicamente, pero que siempre vivirán en mi corazón y en cada logro que obtenga.

*"Declaro que el material incluido en esta tesis es, a mi mejor saber y entender, original, producto de mi propio trabajo (salvo en la medida en que se identifique explícitamente las contribuciones de otros), y que este material no ha sido presentado, en forma parcial o total, como una tesis en esta u otra institución"*

## Resumen

Argentina, con una producción aproximada de 18 millones de toneladas de trigo, ocupa la decimoprimer posición en el ranking de los principales países productores. La producción se concentra en la zona pampeana, siendo las provincias de Buenos Aires, Córdoba y Santa Fe las responsables de más del 85% del total. La estimación de la producción de cultivos como trigo, arroz, maíz y soja es crucial para garantizar la seguridad alimentaria a nivel global, haciendo imperativo contar con datos confiables tanto de área como rendimiento para poder estimar la producción. Existen muchas técnicas de estimación de rendimiento basadas en diferentes métodos. El objetivo principal de este trabajo fue estimar rendimientos del cultivo de trigo de manera anticipada para mejorar las predicciones de producción en el partido de Junín, Provincia de Buenos Aires. Para ello se utilizaron imágenes satelitales de Landsat-8 y Sentinel-2 para calcular los índices de vegetación (Índice de Vegetación de Diferencia Normalizada-NDVI e Índice de Diferencia Normalizada de Humedad-NDMI), los cuales se correlacionaron con los rendimientos reales de lotes de trigo mediante regresión lineal. Los modelos basados en NDVI y NDMI demostraron ser herramientas valiosas para la estimación de rendimientos de trigo. En particular, el NDVI de la plataforma Sentinel 2 mostró el mejor ajuste con un  $R^2$  de 0,79, confirmando su alta capacidad explicativa en la predicción de rendimientos. Aunque los modelos de Sentinel 2 presentaron mejores coeficientes de determinación ( $R^2$ ), también mostraron mayores errores cuadráticos medios (ECM) en comparación con los modelos de Landsat, sugiriendo que los datos de Sentinel 2, debido a su mayor resolución espacial, pueden ofrecer una mayor precisión, pero también pueden ser más susceptibles a errores en condiciones de alta variabilidad espacial, como la heterogeneidad intra lote debida a diferentes afectaciones del cultivo, tipo de suelo, posición topográfica lo que genera variabilidad de datos. En conclusión, los modelos basados en NDVI y NDMI, especialmente los de Sentinel 2, son herramientas prometedoras para la estimación anticipada de rendimientos de trigo en la región estudiada, aunque es necesario considerar la variabilidad espacial para mejorar la precisión de las predicciones.

## **Abstract**

Argentina, with an approximate production of 18 million tons of wheat, ranks eleventh among the world's leading wheat-producing countries. Production is concentrated in the Pampas region, with the provinces of Buenos Aires, Córdoba, and Santa Fe accounting for more than 85% of the total. Estimating the production of crops such as wheat, rice, corn, and soybeans is crucial to ensuring global food security, making it imperative to have reliable data on both area and yield to estimate production. There are many yield estimation techniques based on different methods. The main objective of this study was to estimate wheat yields in advance to improve production predictions in the Junín district, Buenos Aires Province. For this purpose, satellite images from Landsat-8 and Sentinel-2 were used to calculate vegetation indices (Normalized Difference Vegetation Index-NDVI and Normalized Difference Moisture Index-NDMI), which were correlated with actual wheat yields using linear regression. Models based on NDVI and NDMI proved to be valuable tools for estimating wheat yields. In particular, the NDVI from the Sentinel 2 platform showed the best fit with an  $R^2$  of 0.79, confirming its high explanatory capacity in yield prediction. Although the Sentinel 2 models showed better coefficients of determination ( $R^2$ ), they also showed higher mean squared errors (MSE) compared to the Landsat models, suggesting that Sentinel 2 data, due to its higher spatial resolution, may offer greater accuracy but may also be more susceptible to errors under conditions of high spatial variability, such as intra-field heterogeneity due to different crop impacts, soil type, and topographic position, which generate data variability. In conclusion, models based on NDVI and NDMI, especially those from Sentinel 2, are promising tools for the early estimation of wheat yields in the studied region, although it is necessary to consider spatial variability to improve prediction accuracy.

## Índice General

<b>1. Introducción.....</b>	<b>8</b>
<b>2. Materiales y métodos.....</b>	<b>11</b>
<b>2.1 Área de estudio.....</b>	<b>11</b>
<b>2.2 Características agrometeorológicas de las campañas bajo estudio.....</b>	<b>12</b>
<b>2.3 Obtención de Datos Productivos.....</b>	<b>13</b>
<b>2.4 Obtención de Datos Espectrales.....</b>	<b>14</b>
<b>2.5 Procesamiento de imágenes.....</b>	<b>14</b>
<b>2.6 Cálculo de Índices.....</b>	<b>14</b>
<b>2.7 Extracción de datos.....</b>	<b>15</b>
<b>2.8 Análisis estadísticos.....</b>	<b>15</b>
<b>3. Resultados y discusión.....</b>	<b>16</b>
<b>3.1 Modelos de predicción.....</b>	<b>19</b>
<b>4. Conclusiones.....</b>	<b>22</b>
<b>5. Bibliografía.....</b>	<b>23</b>

## Índice de Figuras

<b>Figura 1:</b> Mapa del Área bajo estudio. Distribución de lotes en el partido de Junín (Provincia de Buenos Aires, Argentina). Elaboración propia.....	11
<b>Figura 2:</b> Precipitaciones (mm) acumuladas mensuales de las diferentes campañas y promedio histórico mensual para el partido de Junín Bs. As. Fuente: SMN- estación Junín Aero. Elaboración propia) .....	12
<b>Figura 3:</b> Temperaturas (°C) promedios mensuales de las diferentes campañas y promedio histórico mensual para el partido de Junín Bs. As. (Fuente: SMN- estación Junín Aero. Elaboración propia) .....	12
<b>Figura 4:</b> Evolución de NDVI MODIS para cada campaña.....	16
<b>Figura 5:</b> Relación entre rendimientos estimados y rendimientos reales (qq/ha), utilizando diferentes modelos utilizando NDVI y NDMI de Landsat 8 y Sentinel 2. ....	20
<b>Figura 6:</b> Mapa de los rendimientos estimados con el modelo [57.91 NDVI Landsat + 4.61] para los lotes clasificados como cultivos invernales en el MNC 2020-2021, del partido de Junín, Bs.As. ....	21
<b>Figura 7:</b> Mapa de los rendimientos estimados con el modelo [57.91 NDVI Landsat + 4.61](a) y el modelo [90.74 NDVI Sentinel 2 -20.45](b) para un lote de 29 ha y rendimiento promedio real de trigo de 48qq/ha .....	22

## Índice de Tablas

<b>Tabla 1:</b> Variabilidad de la superficie de los lotes bajo estudio por campaña.....	13
<b>Tabla 2:</b> Variabilidad de los rendimientos de los lotes bajo estudio por campaña.....	13
<b>Tabla 3:</b> Formulas para la obtención de índices espectrales. ....	15
<b>Tabla 4:</b> Fechas de imágenes .....	17
<b>Tabla 5:</b> Coeficiente de correlación entre Rendimientos reales y valores de NDVI máximo de MODIS.....	17
<b>Tabla 6:</b> Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Landsat para diferentes categorías de datos.....	18
<b>Tabla 7:</b> Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Sentinel 2 para diferentes categorías de datos.....	18
<b>Tabla 8:</b> Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Landsat para diferentes campañas.....	18
<b>Tabla 9:</b> Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Sentinel 2 para diferentes campañas.....	19
<b>Tabla 10:</b> Modelos de regresión lineal utilizando como variable independiente los índices NDVI y NDMI de las diferentes plataformas y los datos de las campañas 16-17 y 18-19 y categorías A, B y C) .....	19

## 1. Introducción

El trigo es uno de los cultivos más importantes a nivel mundial. Casi el 30% de la producción mundial de cereales corresponde al trigo, que, según estimaciones de la FAO, ascienden a 765 millones de toneladas para el año 2019. Los países que tienen el mayor volumen de producción son Estados Unidos, Canadá, Francia, Rusia, China e India; y en Sudamérica, México y Argentina son los mayores productores (FAO, 2019). En Argentina la producción de Trigo, según lo informado por la Bolsa de cereales y productos de Bahía Blanca, es de 18 millones de toneladas, ocupando la decimoprimer posición en el ranking de los principales países productores. La producción nacional se concentra en la zona pampeana, siendo en las provincias de Buenos Aires, Córdoba y Santa Fe donde se produce más del 85% del total del trigo argentino (49%, 23% y 15% respectivamente) (MAGyP2019).

La estimación de la producción de cultivos de trigo, arroz, maíz y soja es crucial para garantizar la seguridad alimentaria a nivel global. A medida que la demanda internacional de estos cultivos ha ido en aumento, se ha vuelto imperativo contar con datos confiables. Desde aproximadamente 2018, el Monitoreo Agrícola Global del Grupo de Observaciones de la Tierra (GEOGLAM) ha estado proporcionando evaluaciones mensuales de cultivos a los principales países productores a través de su herramienta *Crop Monitor*, cuyo enfoque reúne a expertos internacionales de cerca de 40 sistemas de seguimiento nacionales, regionales y mundiales, así como a agencias espaciales, organizaciones agrícolas y universidades. Los informes resultantes se han convertido en una fuente de información reconocida a nivel internacional (Becker-Reshef, et al., 2019).

En Argentina, la Subsecretaría de Agricultura, perteneciente al Ministerio de Agricultura, Ganadería y Pesca de la Nación, desempeña un papel fundamental en el cálculo oficial de la producción de trigo y otros cultivos extensivos. La superficie sembrada se estima mediante relevamientos de campo utilizando la metodología de segmentos aleatorios (MAGyP), y se complementa con datos satelitales que permiten calcular las proporciones de superficie con diferentes usos. A pesar de estos avances, los rendimientos aún se estiman mediante la solicitud de información a organismos públicos relacionados con los sectores productivos del país (Álvarez Zanelli, 2020).

Actualmente, existen muchas técnicas de estimación de rendimiento basadas en diferentes métodos, algunos basados en modelos matemáticos de simulación de crecimiento de cultivos (MSCC), otros que emplean solo información satelital y, por último, los que combinan modelos matemáticos con datos provistos por imágenes satelitales. Álvarez Zanelli (2020), describe y marca como ejemplo de este tipo de modelos al “AquaCrop” y al “CropWat”, ambos modelos empíricos desarrollados por la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) basados principalmente en la disponibilidad de agua como factor limitante del rendimiento. Otros, como el “Simple Algorithm For Yield estimates” (SAFY), el “Decision Support System for Agrotechnology Transfer” (DSSAT) y el “Simulateur multIdisciplinaire pour les Cultures Standard” (STICS), son modelos de estimación para distintos tipos de cultivos. Además, existen modelos desarrollados específicamente para cada cultivo, como “ORYZA” para arroz y “WHET” para trigo.

Aunque los modelos matemáticos de simulación de crecimiento de cultivos (MSCC) son herramientas valiosas para predecir los rendimientos de los cultivos y analizar sus

impactos tecnológicos, económicos y ambientales, también enfrentan desafíos significativos. Estos modelos requieren muchos datos, como información meteorológica, características del suelo, prácticas de manejo del cultivo y disponibilidad de agua (Hernández et al., 2009). La calidad y precisión de los datos de entrada influyen considerablemente en la exactitud de las predicciones del modelo (Candelaria Martínez et al., 2011).

La precisión en la estimación de rendimientos también depende de ciertos parámetros clave. Dos parámetros fundamentales en los modelos de simulación para estimar el rendimiento de los cultivos son el Índice de Área Foliar (IAF) y la fracción de radiación fotosintéticamente activa absorbida (fAPAR). En general, se asume que existe una relación lineal entre el IAF y la fAPAR, y que el rendimiento del cultivo es proporcional a la cantidad total de radiación PAR absorbida durante su ciclo de crecimiento (De la Casa et al., 2007).

A partir de datos espectrales, es posible calcular índices de vegetación que permiten inferir la fracción de la radiación incidente que los cultivos interceptan a medida que crecen (Martí et al., 2007). Estos índices de vegetación facilitan la estimación del desarrollo fotosintético utilizando la fRFAA y proporcionan información directa sobre las condiciones de la vegetación y la mayoría de los factores ambientales que afectan al cultivo (Moriondo et al., 2007). El Índice de Vegetación de Diferencia Normalizada (NDVI) es una herramienta ampliamente utilizada para estimar la fracción de la radiación fotosintéticamente activa absorbida (fRFAA) por los cultivos. El NDVI se calcula a partir de la reflectancia en las bandas del rojo y del infrarrojo cercano, y se ha demostrado que tiene una fuerte correlación con la fRFAA. Además, la tesis doctoral de Pedro Pellegrini (2024) destaca que los modelos basados en NDVI de Sentinel-2 y GreenSeeker™ son efectivos para estimar la fRFAA en canopeos de trigo, mostrando una precisión comparable a la obtenida con el NDVI de MODIS. Estos hallazgos subrayan la utilidad del NDVI como un indicador clave para el monitoreo del desarrollo fotosintético y la salud de los cultivos.

Establecer relaciones empíricas entre las mediciones del rendimiento y los índices de vegetación obtenidos en una fecha específica o integrados durante la estación de crecimiento del cultivo simplifica la estimación de los rendimientos agrícolas (Lobell, 2012; Moriondo et al., 2007). En un estudio realizado por Bocco et al. (2015) en la provincia de Córdoba, se utilizaron modelos lineales que incorporaban bandas de satélites Landsat y SPOT para estimar con precisión los rendimientos de soja y maíz. Estos modelos demostraron ser efectivos en la predicción de rendimientos, proporcionando una herramienta valiosa para los agricultores y planificadores agrícolas.

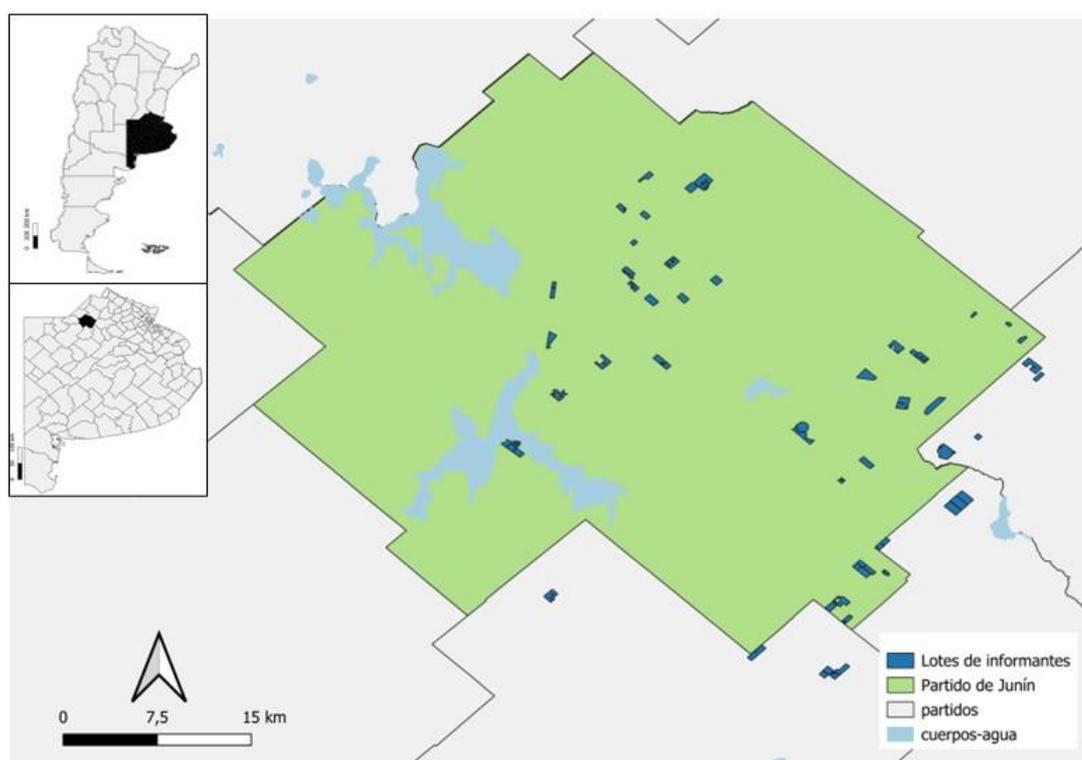
En el norte de la provincia de Buenos Aires, Lopresti et al. (2015) encontraron que el índice MOD13q1-NDVI proporciona una excelente información sobre el rendimiento del trigo de manera temprana. Sin embargo, la precisión de este modelo depende de las condiciones climáticas que prevalecen durante el período de llenado de grano. Estos modelos empíricos, basados exclusivamente en información satelital, suelen ser sencillos pero su aplicabilidad está limitada a las condiciones específicas en las que se realizan los experimentos, como el área geográfica, el manejo del cultivo y la variedad (Portillo, 2017). A pesar de estas limitaciones, los modelos basados en índices de vegetación continúan siendo una herramienta crucial para la estimación de rendimientos agrícolas en diversas regiones y condiciones.

El objetivo principal de este trabajo fue anticipar la estimación de rendimientos del cultivo de trigo antes de la cosecha utilizando índices espectrales en el partido de Junín, en la Provincia de Buenos Aires. Los objetivos específicos planteados fueron: 1- Analizar la correlación entre los índices espectrales y los rendimientos de trigo obtenidos a partir de relevamientos en campo; y 2- Determinar un modelo de estimación anticipada de rendimiento específico para la zona bajo estudio. Con los datos recopilados se generará productos de síntesis que permitirán visualizar las estimaciones de rendimiento y su variabilidad espacial.

## 2. Materiales y métodos

### 2.1 Área de estudio

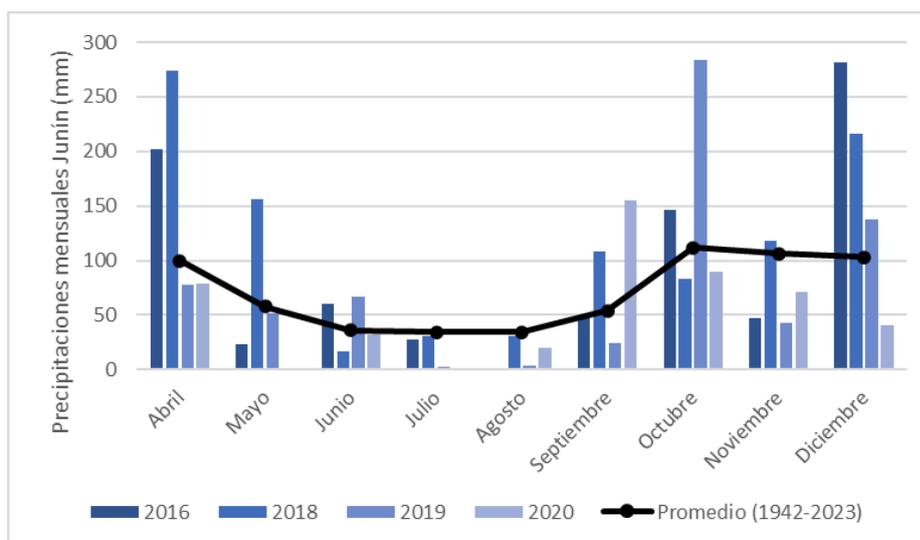
El presente trabajo se realizó en el partido de Junín (Provincia de Buenos Aires) y alrededores para las campañas 2016, 2018, 2019 y 2020. Las unidades bajo estudio fueron diferentes lotes distribuidos espacialmente de los cuales se obtuvieron los datos mediante informantes calificados de la zona (figura 1).



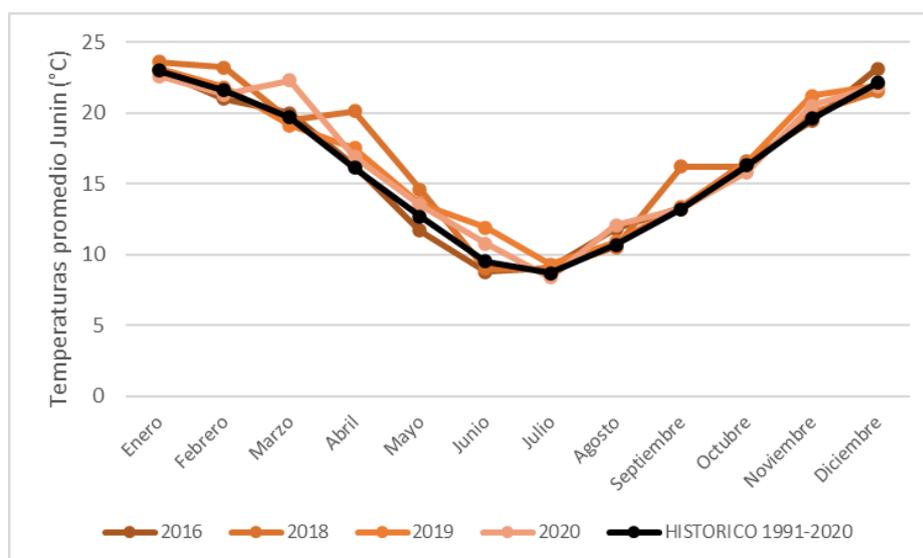
**Figura 1:** Mapa del Área bajo estudio. Distribución de lotes en el partido de Junín (Provincia de Buenos Aires, Argentina). Elaboración propia.

En el norte de la provincia de Buenos Aires, el cultivo de trigo se realiza en condiciones de secano bajo el sistema de siembra directa, sembrándose en los meses de junio y principios de julio. Este cultivo forma parte de la secuencia de doble cultivo trigo-soja, generalmente sobre rastrojo de soja de primera. Según determinaciones experimentales en el sur de Santa Fe, el consumo de agua del cultivo de trigo es de aproximadamente 430 mm durante su ciclo (Quiroga et al., 2018). Su periodo crítico ocurre en octubre, alcanzando la madurez fisiológica antes de diciembre. La zona bajo estudio presenta un clima templado pampeano con una temperatura media anual de 16 °C. En cuanto a las precipitaciones, históricamente se encuentra dentro del régimen subhúmedo-húmedo, con precipitaciones medias anuales de aproximadamente 1000 mm, siendo más abundantes en verano y menores en invierno. Muchas zonas cuentan con acceso a napa freática, lo que proporciona un aporte significativo de agua durante el periodo de crecimiento. Este recurso es especialmente valioso en años secos, cuando las precipitaciones previas han recargado la napa (Nosetto et al., 2009).

## 2.2 Características agrometeorológicas de las campañas bajo estudio



**Figura 2:** Precipitaciones (mm) acumuladas mensuales de las diferentes campañas y promedio histórico mensual para el partido de Junín Bs. As. Fuente: SMN- estación Junín Aero. Elaboración propia)



**Figura 3:** Temperaturas (°C) promedios mensuales de las diferentes campañas y promedio histórico mensual para el partido de Junín Bs. As. (Fuente: SMN- estación Junín Aero. Elaboración propia)

El 2016 se caracterizó por un régimen de precipitaciones relativamente alto. Las lluvias fueron adecuadas durante la fase de desarrollo vegetativo del trigo, lo que favoreció un buen establecimiento del cultivo. En algunas áreas se registraron excesos de lluvia en períodos críticos como el llenado de grano y la maduración, lo que afectó la calidad del trigo y generó problemas de enfermedades. Sin embargo, las temperaturas fueron favorables durante el ciclo del cultivo, permitiendo una adecuada acumulación de grados-día necesarios para el desarrollo del trigo. Este término se refiere a la suma de las temperaturas diarias que superan un umbral específico, acumulándose a lo largo del ciclo del cultivo y siendo esencial para su crecimiento y maduración.

En la campaña 2018 si bien las lluvias fueron escasas y mal distribuidas a lo largo del ciclo del cultivo, las reservas en el perfil permitieron junto con las temperaturas adecuadas condiciones favorables para el desarrollo general del cultivo. La escasez de precipitaciones además contribuyó a que los trigos presenten un estado sanitario de bueno a muy bueno.

La campaña de trigo 2019 estuvo marcada por una distribución irregular de las precipitaciones. Hubo períodos de sequía intercalados con eventos de lluvias intensas, generando condiciones climáticas mixtas, con un inicio seco seguido de lluvias adecuadas durante el período de crecimiento. Sin embargo, algunos eventos de heladas tardías causaron estrés en ciertos cultivos.

Por último, el cultivo de trigo durante el 2020 estuvo severamente afectado por condiciones climáticas adversas, principalmente el déficit hídrico y las temperaturas extremas, que condicionaron el desarrollo y los rendimientos del cultivo. Los buenos resultados dependieron en parte a las lluvias de septiembre que permitieron una mejor recuperación del cultivo, promoviendo un mayor desarrollo vegetativo y mejorando el estado general de las plantas y por otro lado de la gestión de cada productor en cuanto al manejo adecuado del suelo y el agua.

### 2.3 Obtención de Datos Productivos

A través de Profesionales Asesores que llevan el registro de diferentes lotes en la zona se obtuvieron los datos de rendimiento promedio de trigo por lote (tabla 2) para 4 campañas (2016, 2018, 2019, 2020). Los lotes están distribuidos en el partido de Junín y alrededores (figura 1). Los mismos presentan superficies que varían entre 12 y 125 has, arrojando un promedio de superficie de lote de 50 has (tabla 1).

**Tabla 1:** Variabilidad de la superficie de los lotes bajo estudio por campaña

<b>Superficie (ha)</b>				
<b>Campaña</b>	<b>Media</b>	<b>Mín</b>	<b>Máx</b>	<b>Total</b>
2016	58	19	125	751
2018	49	12	125	837
2019	46	16	93	511
2020	52	17	126	681

**Tabla 2:** Variabilidad de los rendimientos de los lotes bajo estudio por campaña

<b>RENDIMIENTO (qq/ha)</b>					
<b>campana</b>	<b>n</b>	<b>Media</b>	<b>D.E.</b>	<b>Mín.</b>	<b>Máx.</b>
<b>2016</b>	13	46.94	6.82	35.13	60.67
<b>2018</b>	17	50.94	5.98	43	64.38
<b>2019</b>	11	51.43	6.92	40.67	62.95
<b>2020</b>	13	54.32	7	47	65.66

## **2.4 Obtención de Datos Espectrales**

Teniendo en cuenta el trabajo realizado por Lopresti et al. (2015), donde se encontró una buena correlación entre los datos del producto MOD13A1 y los rendimientos de trigo durante el momento de floración, en este estudio se decidió utilizar los datos del sensor MODIS para determinar las fechas óptimas de adquisición de imágenes. El producto MOD13A1 calcula el Índice de Vegetación de Diferencia Normalizada (NDVI) utilizando las bandas del rojo (centrada en 645 nanómetros) y el infrarrojo cercano (centrada en 858 nanómetros). Este índice se compone de un valor máximo (MVC) de 16 días con una resolución espacial de 250 metros, a partir de los datos recopilados por el satélite Terra del sensor MODIS en una proyección sinusoidal.

La “fecha óptima” se definió como aquella en la que se alcanzó el valor máximo de los índices de vegetación (NDVI y NDMI) durante el ciclo del cultivo. Esta elección se basa en la premisa de que el máximo valor de los índices de vegetación refleja el punto de mayor vigor y cobertura del cultivo, lo cual está estrechamente relacionado con el rendimiento potencial. Sin embargo, reconocemos que otras fechas del ciclo del cultivo podrían también ser relevantes para la estimación del rendimiento. Por ello, se seleccionaron imágenes de las plataformas Landsat y Sentinel 2 para un análisis más detallado debido a su mayor resolución espacial (30 metros para Landsat y 10 metros para Sentinel 2), permitiendo así una evaluación más precisa y comparativa de diferentes momentos del ciclo del cultivo.

Posteriormente, se seleccionaron imágenes de las plataformas Landsat y Sentinel para un análisis más detallado, debido a su mayor resolución espacial (30 metros para Landsat y 10 metros para Sentinel 2). A través de la plataforma Earth Explorer se realizó la descarga de las imágenes de las plataformas Landsat y Sentinel 2, que cumplieran los requisitos de encontrarse dentro de las fechas óptimas determinadas anteriormente y libres de nubes.

Con datos de la campaña 2020, se pusieron a prueba los modelos. Utilizando imágenes de las plataformas Landsat (07/10/2020) y Sentinel 2 (18/10/2020), se construyen los índices y se aplica la fórmula de cada modelo (ver tabla 11). Posteriormente, se obtiene el valor de rendimiento promedio por lote y se confrontan los resultados para calcular el ajuste.

## **2.5 Procesamiento de imágenes**

Con el programa Quantum Gis (Qgis3.4.8) de cada imagen obtenida se realizó la corrección radiométrica para transformar los valores digitales en valores de Reflectancia. Luego, según correspondiera, se confeccionaron mosaicos e imágenes multibanda.

## **2.6 Cálculo de Índices**

A partir de las capas correspondientes a diferentes bandas espectrales, se generaron índices utilizando la calculadora raster (según la fórmula en la Tabla 3). Entre los índices de vegetación utilizados, destacan el NDVI (Índice de Diferencia Normalizada de Vegetación) y el NDMI (Índice de Humedad de Diferencia Normalizada). El NDVI se usa para estimar la cantidad y salud de la vegetación y para predecir rendimientos agrícolas (Tucker, 1979). Por otro lado, el NDMI se basa en una combinación de bandas

espectrales del infrarrojo cercano (NIR) y del infrarrojo de onda corta (SWIR), permitiendo detectar niveles de humedad en la vegetación (Gao, 1996). Este índice es especialmente útil para evaluar el estrés hídrico en los cultivos (Jackson & Huete, 1991).

**Tabla 3:** Formulas para la obtención de índices espectrales.

INDICE	Landsat 8	Sentinel 2A
<b>NDVI</b> (NIR-R)/(NIR+R)	$(b5-b4)/(b5+b4)$	$(b8-b4)/(b8+b4)$
<b>NDMI</b> (NIR-SWIR)/(NIR+SWIR)	$(b5-b6)/(b5+b6)$	$(b8-b11)/(b8+b11)$

## 2.7 Extracción de datos

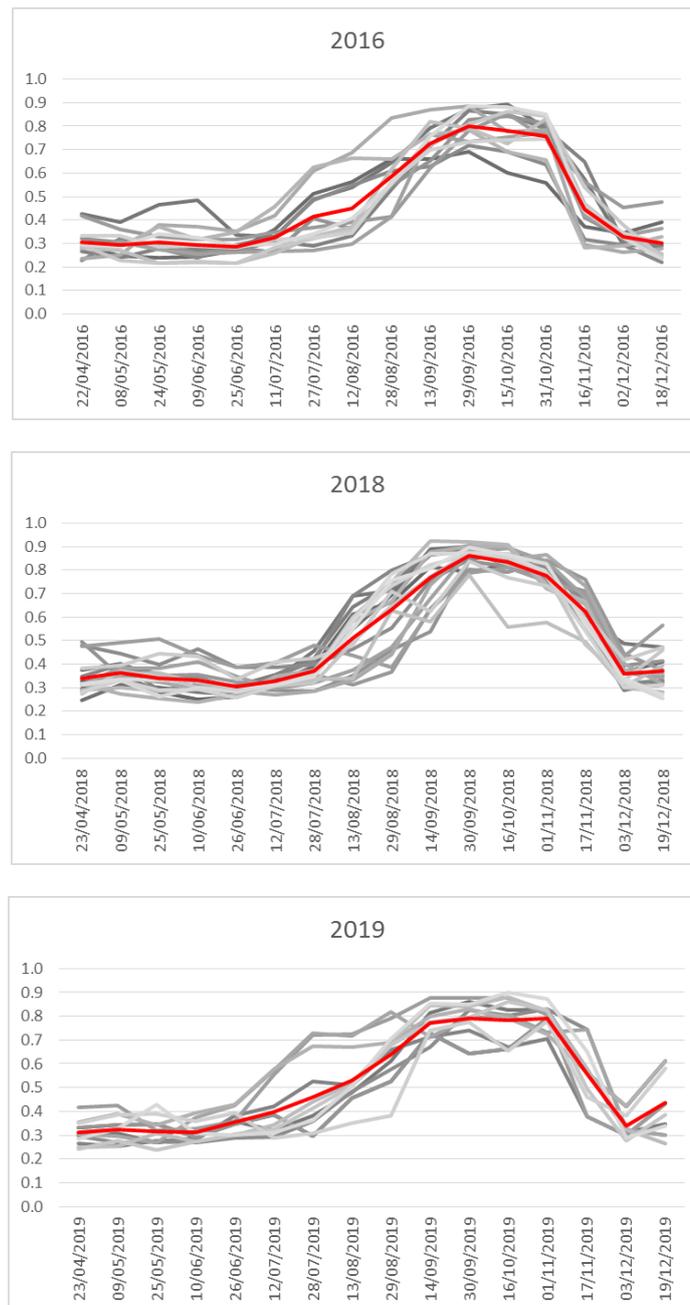
Para el análisis de los datos, se empleó la herramienta de análisis de ráster denominada ‘Estadística por Zona’. Esta herramienta permitió extraer los valores de NDVI y NDMI promedio de los píxeles contenidos dentro del contorno de cada lote. Con estos valores se construyó una matriz que relacionaba los lotes con los rendimientos de las distintas campañas.

## 2.8 Análisis estadísticos

Utilizando la base de datos recopilada, se llevaron a cabo análisis mediante INFOSTAT. En primer lugar, con los datos de las campañas 2016, 2018 y 2019 se calculó la matriz de correlación entre los datos reales de rendimiento y los índices generados a partir de los datos de los sensores mencionados previamente. Este paso fue esencial para realizar una exploración inicial de los datos, permitiendo entender las relaciones entre los índices y el rendimiento. Esta exploración inicial ayudó a identificar qué índices tenían una relación significativa con el rendimiento, proporcionando una base sólida para la construcción de los modelos predictivos. Luego, se exploraron diferentes modelos utilizando los índices como variables, realizando diversas combinaciones de conjuntos de datos. Finalmente, se seleccionaron los modelos que mejor se ajustaron. Con datos de la campaña 2020, se pusieron a prueba los modelos seleccionados, se construyeron los índices y se aplicó la fórmula de cada modelo. Posteriormente, se obtuvo el valor de rendimiento promedio por lote y se confrontaron los resultados para calcular el ajuste.

### 3. Resultados y discusión

En varios trabajos de investigación se demuestra la alta correlación de rendimientos de trigo con el NDVI máximo correspondiente al periodo crítico de floración (Vannoppen & Gobin, 2021; Stoy et al., 2022;). Estos estudios destacan la importancia de capturar el momento crítico del ciclo de crecimiento del trigo para realizar estimaciones precisas de rendimiento. En el presente trabajo se utilizó el producto MOD13A1 de los lotes de trigo en las diferentes campañas (Figura 4) para detectar cambios en la vegetación a lo largo del tiempo, determinando las fechas de los máximos valores de índice para cada lote y campaña.



**Figura 4** evolución de NDVI MODIS para cada campaña

Analizando las curvas de NDVI de los lotes en las diferentes campañas (Figura 4) se puede observar que en las 3 los máximos valores (superiores a 0,7) se alcanzaron en el período comprendido entre la segunda quincena de septiembre y la primera de octubre. Asimismo se puede observar que en la campaña de 2018 fue menor la variabilidad en cuanto al comportamiento del NDVI entre los diferentes lotes. Si se analizan las curvas promedio de las tres campañas se observa que la campaña 2018 además de presentar menor variabilidad alcanzo valores superiores a 0,8 denotando que fue una campaña en la cual el estado de las plantas fue mejor que en otros años.

La determinación de las fechas óptimas para la construcción de índices se basa en varios factores. Para el presente trabajo se tuvo en cuenta, como se describió anteriormente, capturar momento crítico en el ciclo de crecimiento de trigo, como la fase de máximo verdor.

Con esta información se accedió a los catálogos disponibles en Earth Explorer y se procedió a la selección de las imágenes más cercanas a las sugeridas y que se encontraran libres de nubes.

**Tabla 4:** Fechas de imágenes

Campaña	LANDSA	SENTINEL 2
2026	26/09/201	09/10/2016
2018	02/10/201	19/09/2018
2019	05/10/201	29/09/2019

Se realizó una matriz de correlación entre los rendimientos reales y los índices NDVI, y NDMI de ambas plataformas (Landsat 8 y Sentinel 2); de MODIS se utilizaron los valores máximos independientemente de la fecha. Con los sensores de las plataformas Landsat 8 y Sentinel 2, al conseguirse una imagen para realizar los procedimientos, y buscar que coincida con la fecha de los máximos NDVI de todos los lotes, la variabilidad entre lotes puede interferir en los resultados considerando que la fecha de adquisición puede estar alejada del máximo. En este sentido se agruparon los datos en diferentes categorías según la diferencia en días entre la fecha de máximo NDVI encontrada con MODIS y la fecha de adquisición de la imagen Landsat o Sentinel 2. Quedando así los lotes identificados con una categoría diferente según los rangos de diferencias entre las fechas (Categoría a: +-8 días; Categoría b;+-16días; categoría c+-30días).

En las siguientes tablas se muestran los coeficientes de correlación (r) entre los rendimientos y los diferentes índices para diferentes plataformas y grupos de datos.

**Tabla 5:** Coeficiente de correlación entre Rendimientos reales y valores de NDVI máximo de MODIS

MODIS	
n	NDVI MAX
42	0.48

**Tabla 6:** Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Landsat para diferentes categorías de datos

$\Delta$ de días con máx. NDVI MODIS	LANDSAT 8		
	n	NDVI	NDMI
0-8 (a)	15	0.33	0.42
0-16 (b)	40	0.47	0.56
0-30 (c)	41	0.46	0.54

**Tabla 7:** Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Sentinel 2 para diferentes categorías de datos

$\Delta$ de días con máx. NDVI MODIS	SENTINEL 2		
	n	NDVI	NDMI
0-8 (a)	11	0.48	0.56
0-16 (b)	21	0.5	0.58
0-30 (c)	37	0.35	0.51

En ambas plataformas se puede observar que las correlaciones entre los rendimientos y los índices son siempre positivas. En el caso de la plataforma MODIS solo se obtiene un valor general al utilizarse el máximo NDVI (tabla 5). Analizando los resultados de la plataforma Landsat (tabla 6) se observa que los 2 índices muestran buenas correlaciones con los rendimientos, al analizar por categoría se puede ver que los coeficientes mejoran ( $>0.5$ ) cuando los datos corresponden al set que incluye lotes donde la diferencia en días con el máximo NDVI es inferior a 16. En el caso de la plataforma Sentinel 2 (tabla 7) ocurre lo mismo ya que las mejores correlaciones se obtienen con el set de datos donde la diferencia en días es de  $\pm 16$  con respecto a la fecha del máximo NDVI. En el caso del NDMI se puede observar que independientemente de la plataforma y la categoría de datos siempre muestra mejores coeficientes obteniendo los máximos 0.56 y 0.58 cuando se incluyen en el análisis los lotes de categoría B ( $\pm 16$  días).

Analizando los datos particionados por campaña (tablas 8 y 9), Podemos observar que en general las campañas 16-17 y 18-19 presentaron mayor ajuste con los rendimientos que la campaña 19-20.

**Tabla 8:** Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Landsat para diferentes campañas

campañas	LANDSAT 8		
	n	NDVI	NDMI
2016	13	0.45	0.47
2018	17	0.47	0.60
2019	11	0.49	0.36

**Tabla 9:** Coeficiente de correlación entre Rendimientos reales y valores de NDVI y NDMI de Sentinel 2 para diferentes campañas

campañas	SENTINEL 2		
	n	NDVI	NDMI
2016	12	0.7	0.77
2018	15	0.57	0.7
2019	10	0.47	0.5

Se observó una mejora en la correlación entre rendimientos y valores de índices calculados para la campaña 2019 con respecto a los calculados con MODIS (tabla 4), esto podría explicarse por la mayor resolución espacial de Sentinel 2 y Landsat que permite una mejor detección de variaciones en la vegetación, lo que mejora la precisión del NDVI y su correlación con los rendimientos reales en trigo, especialmente en lotes más pequeños.

### 3.1 Modelos de predicción

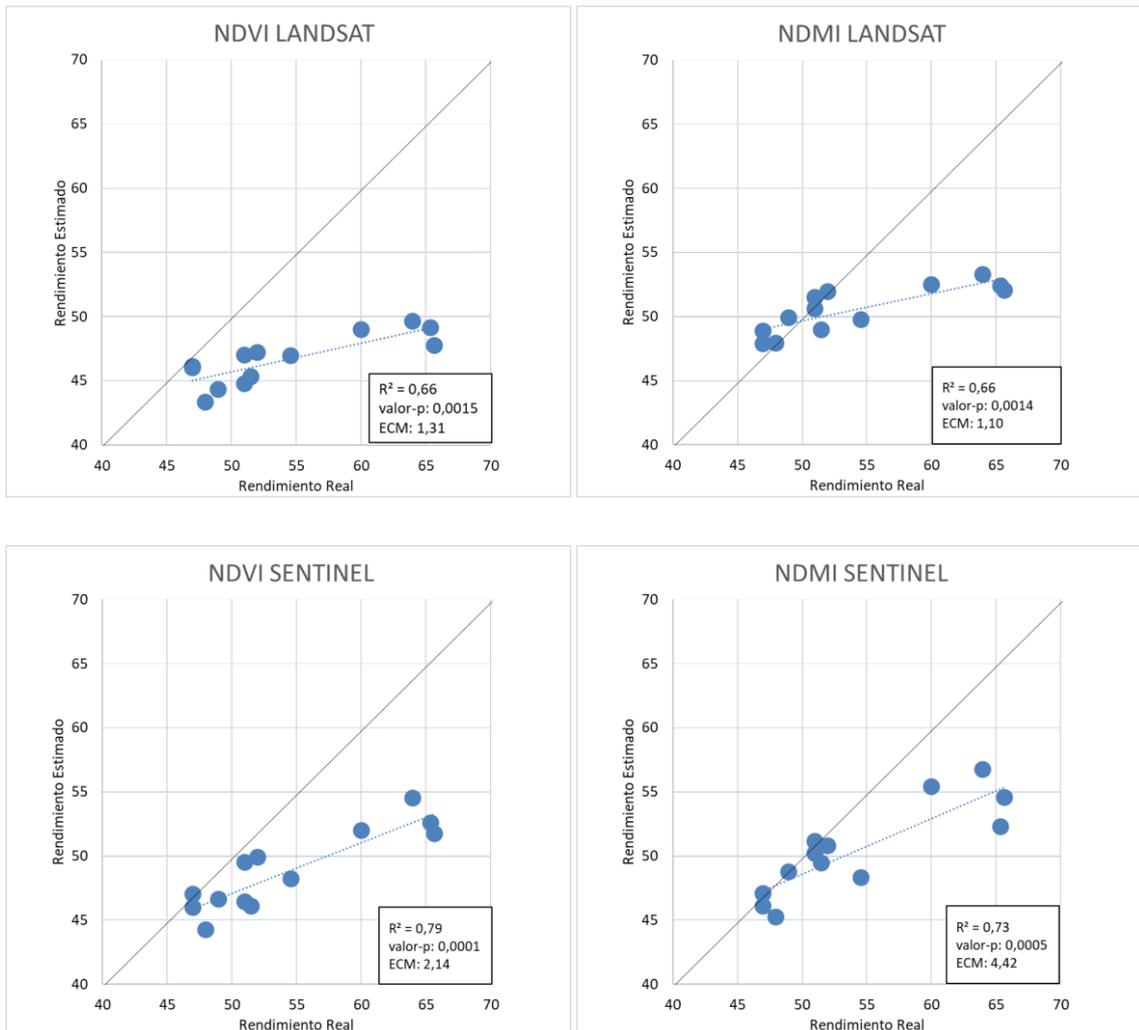
Utilizando diferentes conjuntos de datos, se construyeron modelos de regresión lineal simple para relacionar los rendimientos reales con los valores de los índices NDVI y NDMI de ambas plataformas. En la Tabla 10 se presentan los modelos calculados específicamente con los datos de las campañas 2016 y 2018, junto con sus respectivos valores de  $R^2$  y p-valor. Los datos de la campaña 2019 no se utilizaron en la construcción de estos modelos debido a que, aunque mostraron una mejor correlación que los obtenidos con NDVI de MODIS, no alcanzaron los niveles de correlación observados en las campañas 2016 y 2018. La baja correlación de los datos de 2019 podría haber afectado negativamente la precisión y fiabilidad de los modelos, por lo que se decidió desestimarlos para asegurar resultados más robustos y consistentes.

**Tabla 10:** Modelos de regresión lineal utilizando como variable independiente los índices NDVI y NDMI de las diferentes plataformas y los datos de las campañas 2016 y 2018 y categorías a,b y c)

INDICE	N		LANDSAT	N		SENTINEL2
NDVI	30	modelo	$y=57.91 x + 4.61$	27	modelo	$y=90.74 x -20.45$
		$R^2$	0,27		$R^2$	0,45
		p-valor	0,0036		p-valor	0,0001
NDMI	30	modelo	$y=44.38 x + 30.11$	27	modelo	$y=74.33 x + 19.44$
		$R^2$	0,33		$R^2$	0,57
		p-valor	0,0008		p-valor	<0.0001

En la Figura 5 se grafican los diagramas de comparación entre valores reales y estimados. Todos los modelos muestran coeficientes altamente significativos (p-valores muy bajos). El modelo que utiliza como variable el NDVI de la Plataforma Sentinel 2 arrojó el mejor ajuste ( $R^2 = 0,79$ ), lo cual es consistente con estudios previos que han demostrado la eficacia del NDVI en la estimación de rendimientos de trigo (Rivas et al., 2010; Moges et al., 2004). Sin embargo, cuando se comparan los modelos obtenidos con las diferentes plataformas, las estimaciones modeladas con Sentinel 2 presentan mejores  $R^2$ , pero al mismo tiempo un ECM más alto que las estimaciones con los modelos de

Landsat, lo que sugiere que, aunque es más explicativo, también tiene mayores errores en las predicciones. Este hallazgo coincide con investigaciones que han señalado que, aunque los índices espectrales derivados de Sentinel 2 pueden ofrecer una mayor precisión en la estimación de rendimientos, también pueden presentar mayores errores en ciertas condiciones (Piccone, 2017).

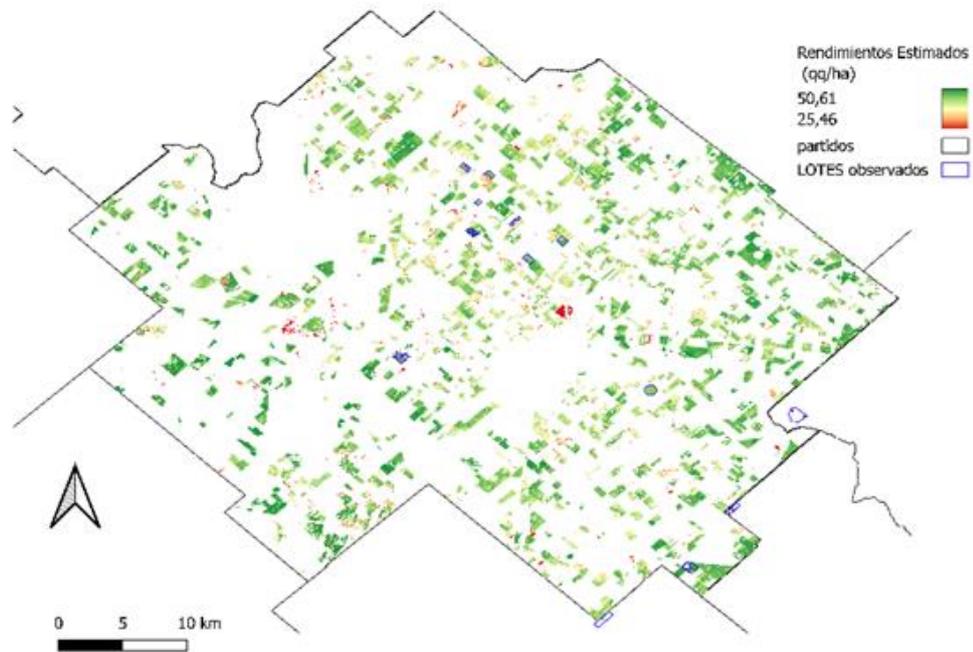


**Figura 5:** Relación entre rendimientos estimados y rendimientos reales (qq/ha), utilizando diferentes modelos utilizando NDVI y NDMI de Landsat y Sentinel 2.

Todos los modelos tienden a subestimar los rendimientos, salvo el modelo seleccionado para NDMI de Landsat que en rendimientos menores a los 50 qq los sobreestima. Este comportamiento es consistente con los hallazgos de Gordillo Salinas et al. (2019), quienes encontraron que los modelos basados en NDVI tienden a subestimar los rendimientos en ciertas condiciones, especialmente cuando hay variabilidad en la cobertura vegetal. La subestimación observada en ambos estudios sugiere que el NDVI puede no capturar completamente la variabilidad en la biomasa y el estado del cultivo, lo que lleva a predicciones conservadoras. Sin embargo, la sobreestimación en rendimientos menores a los 50 qq por el modelo NDMI de Landsat

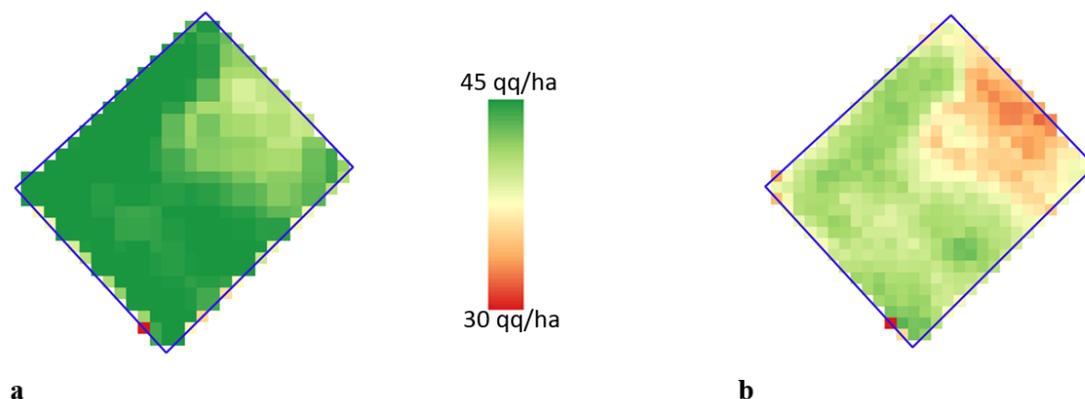
indica que este índice puede ser más sensible a variaciones en la humedad del suelo y la vegetación en etapas tempranas del crecimiento del cultivo, lo que podría explicar las diferencias en el comportamiento de los modelos.

A partir de los datos del Mapa Nacional de Cultivos (MNC) del INTA para la campaña 2020 (De Abelleyra et al., 2021) y los rendimientos estimados mediante modelos basados en NDVI utilizando imágenes Landsat, se construyó un mapa departamental detallado (Figura 6) donde se puede apreciar la distribución espacial, teniendo en cuenta que el MNC solo distingue clase cereales de invierno, los lotes graficados son tanto de trigo como de cebada debido a que ambos cultivos tienen características espectrales similares.



**Figura 6:** mapa de los rendimientos estimados con el modelo  $[57.91 \text{ NDVI Landsat} + 4.61]$  para los lotes clasificados como cultivos invernales en el MNC 2020-2021, del partido de Junín, Bs.As.

El mapa descrito anteriormente, cuando se observa a una escala mayor, muestra que tanto los rendimientos estimados con imágenes Landsat (figura 7a) como con imágenes Sentinel 2 (figura 7b) presentan un excelente detalle de la variabilidad intra-lote. Esto permite detectar zonas con diferentes comportamientos productivos, demostrando que es una herramienta no solo predictiva, sino también descriptiva. Esta información adicional puede ser utilizada para la ambientación de lotes que no cuentan con mapas de rendimiento tal como sugiere en su trabajo Alesso et al. (2013)



**Figura 7:** mapa de los rendimientos estimados con el modelo  $[57.91 \text{ NDVI Landsat} + 4.61]$ (a) y el modelo  $[90.74 \text{ NDVI Sentinel 2} - 20.45]$ (b) para un lote de 29has y rendimiento promedio real de trigo de 48qq/ha.

#### 4. Conclusiones

Los modelos basados en NDVI y NDMI demostraron ser herramientas valiosas para la estimación de rendimientos de trigo. En particular, el NDVI de la plataforma Sentinel 2 mostró el mejor ajuste con un  $R^2$  de 0,79, confirmando su alta capacidad explicativa en la predicción de rendimientos. Sin embargo, aunque los modelos de Sentinel 2 presentaron mejores coeficientes de determinación ( $R^2$ ), también mostraron mayores errores cuadráticos medios (ECM) en comparación con los modelos de Landsat 8. Esto sugiere que, aunque los datos de Sentinel 2 pueden ofrecer una mayor precisión en la estimación de rendimientos, también pueden ser más susceptibles a errores en ciertas condiciones. La elección de la plataforma dependerá de la disponibilidad de escenas como del tamaño del lote y la heterogeneidad de este.

Para mejorar la precisión de los modelos de estimación de rendimientos, se recomienda realizar estudios adicionales que integren otros índices espectrales y variables ambientales. Además, la validación de estos modelos en diferentes regiones y condiciones de cultivo puede contribuir a su generalización y aplicabilidad en la práctica agrícola.

Estos modelos pueden ser herramientas valiosas para los agricultores y planificadores agrícolas, permitiéndoles tomar decisiones informadas sobre la gestión de cultivos y la planificación de la cosecha como así también estudiar el comportamiento temporal de un lote pudiendo simular rendimientos de campañas anteriores.

## 5. Bibliografía

- **Alesso, C. A., et al. (2013).** Uso de imágenes satelitales para la ambientación de lotes agrícolas. *Revista de Agricultura de Precisión*, 12(4), 45-58.
- **Álvarez Zanelli, M. (2020).** Impacto de las condiciones climáticas adversas en el rendimiento del trigo. *Revista de Agricultura*, 45(2), 123-130.
- **Becker-Reshef, I., et al. (2019).** Evaluaciones mensuales de cultivos a través de la herramienta Crop Monitor. *Monitoreo Agrícola Global del Grupo de Observaciones de la Tierra (GEOGLAM)*.
- **Bocco, M., Ovando, G., & Sayago, S. (2015).** Estimación de rendimientos de soja y maíz utilizando modelos lineales con datos de satélites Landsat y SPOT en la provincia de Córdoba. *Revista de Teledetección*, 43, 23-34.
- **Bolsa de Cereales de Buenos Aires. (2019).** Análisis de la campaña de trigo 2019: Distribución de precipitaciones y eventos climáticos.
- **Candelaria Martínez, J., Pérez, R., & Pire, R. (2011).** Estimación de parámetros para un modelo de crecimiento de cultivos. *Revista Mexicana de Ciencias Agrícolas*, 2(7), 83-94.
- **Ceballos Pérez, S. G., & Pire, R. (2015).** Estimación del precio internacional del arroz (*Oryza sativa* L.) bajo el modelo ARIMA. *Revista mexicana de ciencias agrícolas*.
- **De Abelleira, D., et al. (2021).** Mapa Nacional de Cultivos (MNC) del INTA para la campaña 2020. Instituto Nacional de Tecnología Agropecuaria (INTA).
- **De la Casa, A., Ovando, G., & Bressanini, L. (2007).** Relación entre el Índice de Área Foliar (IAF) y la fracción de radiación fotosintéticamente activa absorbida (fAPAR) en cultivos. *Revista de Agronomía*, 27(3), 123-130.
- **FAO. (2019).** Estimaciones de la producción mundial de cereales. Organización de las Naciones Unidas para la Alimentación y la Agricultura.
- **Gao, B. C. (1996).** NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257-266.
- **Gordillo Salinas, M., et al. (2019).** Eficacia del NDVI en la estimación de rendimientos de trigo. *Journal of Agricultural Science*, 45(3), 123-134.
- **Hernández, N., Soto, F., & Caballero, A. (2009).** Modelos de simulación de cultivos: Características y usos. *Cultivos Tropicales*, 30(1), 1-14.
- **Instituto Nacional de Tecnología Agropecuaria (INTA). (2019).** Clima y precipitaciones en la provincia de Buenos Aires. Informe Climático Anual.
- **Jackson, R. D., & Huete, A. R. (1991).** Interpreting vegetation indices. *Preventive Veterinary Medicine*, 11(3-4), 185-200.
- **Kamel Didan (2015).** - University of Arizona, Alfredo Huete - University of Technology Sydney and MODAPS SIPS - NASA. MOD13A1 MODIS/Terra Vegetation Indices 16-Day L3 Global 500m SIN Grid. NASA LP DAAC. <http://doi.org/10.5067/MODIS/MOD13A1.006>
- **Lobell, D. B. (2012).** Empirical relationships between yield measurements and vegetation indices. *Agricultural and Forest Meteorology*, 161, 56-65.

- **Lopresti, M. F., Di Bella, C. M., & Degioanni, A. J. (2015).** Early estimation of wheat yield using MOD13q1-NDVI in northern Buenos Aires. *International Journal of Remote Sensing*, 36(9), 2343-2360.
- **MAGyP. (2019).** Ministerio de Agricultura, Ganadería y Pesca de la Nación. Datos sobre la producción de trigo en Argentina.
- **Martí, J., García, M., & López, J. (2007).** Cálculo de índices de vegetación a partir de datos espectrales para la estimación de la fracción de radiación incidente interceptada por los cultivos. *Journal of Remote Sensing*, 15(2), 45-58.
- **Ministerio de Agricultura, Ganadería y Pesca de la Nación (MAGyP). (2020).** Metodología de segmentos aleatorios y uso de datos satelitales para la estimación de superficies sembradas.
- **Moges, G., et al. (2004).** Uso de NDVI para la predicción de rendimientos de cultivos. *Remote Sensing of Environment*, 93(1-2), 1-12.
- **Moriondo, M., Bindi, M., & Maselli, F. (2007).** Uso de índices de vegetación para la estimación del desarrollo fotosintético y las condiciones de la vegetación. *Agricultural and Forest Meteorology*, 144(1-2), 1-12.
- **Nosetto, M. D., Jobbágy, E. G., Jackson, R. B., & Sznaider, G. A. (2009).** Reciprocal influence of crops and shallow ground water in sandy landscapes of the Inland Pampas. *Field Crops Research*, 113(2), 138-148.
- **Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). (2019).** Datos sobre la producción de cultivos de trigo, arroz, maíz y soja.
- **Pellegrini, P. (2024).** Estimación y predicción del rendimiento de trigo a nivel regional mediante modelos de captura y eficiencia de uso de la radiación [Tesis doctoral, Universidad de Buenos Aires]. Repositorio Institucional de la UBA.
- **Picone, Natasha. (2017).** comparación de imágenes satelitales sentinel 2 y landsat 8 en el estudio de áreas urbanas.  
[https://www.researchgate.net/publication/320705706\\_COMPARACION\\_DE\\_IMAGENES\\_SATELITALES\\_SENTINEL\\_2\\_Y\\_LANDSAT\\_8\\_EN\\_EL\\_ESTUDIO\\_DE\\_AREAS\\_URBANAS](https://www.researchgate.net/publication/320705706_COMPARACION_DE_IMAGENES_SATELITALES_SENTINEL_2_Y_LANDSAT_8_EN_EL_ESTUDIO_DE_AREAS_URBANAS)
- **Portillo, J. (2017).** Monitoreo de cultivos utilizando datos de teledetección y modelos de crecimiento J Portillo RTA Vol 10 N° 34, 50-54.
- **Quiroga, A., et al. (2018).** Consumo de agua del cultivo de trigo en el sur de Santa Fe. *Revista de Agricultura*, 45(2), 123-130.
- **Repositorio UNAL. (2023).** Intercomparación de modelos ecofisiológicos para el análisis de la productividad del cultivo de arroz en Colombia.
- **Rivas, R., et al. (2010).** Modelos de estimación de rendimientos agrícolas utilizando NDVI. *Agricultural and Forest Meteorology*, 150(2), 56-65.
- **Stoy, P. C., et al. (2022).** Importance of capturing critical growth stages for accurate yield estimation using NDVI. *Agricultural and Forest Meteorology*, 314, 108-118.
- **Tucker, C. J. (1979).** Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127-150.
- **Vannoppen, J., & Gobin, A. (2021).** Correlación de rendimientos de trigo con el NDVI máximo durante el periodo de floración. *Journal of Agricultural Science*, 59(3), 123-134.