

TRABAJO DE INTENSIFICACIÓN DE INGENIERÍA AGRONÓMICA

***ESTIMACIÓN DEL RENDIMIENTO DE CEBADA A PARTIR DE LA
INTEGRACIÓN DE DATOS ESPECTRALES Y EDÁFICOS***



IÑAKI ANTÍA

**DOCENTE TUTORA:
Dra. Cecilia Pellegrini**

**DOCENTES CONSEJEROS:
Dr. Mariano Oyarzabal
Dr. Alejandro Presotto**



DEPARTAMENTO DE AGRONOMÍA I UNIVERSIDAD NACIONAL DEL SUR

Febrero 2026

Agradecimientos

En cuanto al cumplimiento de este trabajo quiero agradecer a Cecilia, Mariano y Alejandro por su gran predisposición y por todo lo aprendido en el transcurso del mismo. Conceptos, enseñanzas y consejos que me van a acompañar en toda mi carrera profesional.

A mi familia por ser el eje que me sostiene en cada etapa y desafío de mi vida. A mi padre por acompañarme, enseñarme de su profesión y de sus experiencias siendo mi gran ejemplo a seguir y a mi madre por sus cualidades humanas y mentalidad abierta que me ayudan a ser mejor persona. A mis hermanos Bernardo, Facundo y Clarita por ser los pares de mi día a día, acompañando en cada momento necesario y cómplices de mi crecimiento. Por otro lado, a mis abuelos tanto a Ana que se encuentra presente como también a Omar, Héctor y “Maride” que no lo están y esta última se fue en el transcurso de este trabajo siendo una persona muy importante en mi vida, acompañándome durante toda la carrera con sus consejos sabios que guiaron muchas de mis decisiones. También a mis tíos que fueron mis consejeros por excelencia brindando siempre apoyo y mucho cariño.

Por otro lado, quiero agradecer a mis amigos del pueblo con los que transcurrí gran parte de mi vida, desde el jardín hasta el día de hoy con mutuos aprendizajes y grandes anécdotas. También a mis amigos de la carrera, que hicieron que esta etapa sea mucho más fácil, feliz y llevadera. De ellos aprendí sobre sus cualidades particulares, así como la importancia de entender de donde provienen y la aplicación de la agronomía y cultura de cada pueblo.

A la Universidad Nacional del Sur por brindarme la oportunidad de realizar una carrera y de poder tener enseñanza de calidad. Además, por tener la posibilidad de realizar un intercambio académico a Brasil, una experiencia gratificante que me marcó mucho en lo personal y académico. Dentro de ella, me gustaría hacer hincapié en el departamento de Agronomía que permite acompañar a los alumnos durante el trayecto de una forma muy cálida, y por último al centro de estudiantes de agronomía por su hermoso ambiente de trabajo en equipo, momentos inolvidables y saber que cualquier cosa que se proponga con predisposición y apoyo se puede lograr en conjunto.

Índice

Resumen	3
Introducción	4
Metodología / Materiales y Métodos	10
Área de estudio	10
Información técnica del lote	11
Variables estudiadas	11
Rendimiento	11
Índice de vegetación normalizado - IVN.....	13
Profundidad de la tosca	15
Unión de datos por resolución	16
Generación de modelos explicativos del rendimiento de la cebada.....	18
Evaluación de modelos explicativos del rendimiento de la cebada.....	19
Resultados.....	21
Generación de modelos explicativos de rendimiento de la cebada.....	21
Evaluación de los modelos explicativos del rendimiento de la cebada	22
Consideraciones finales.....	26
Bibliografía.....	30

Resumen

En la producción de granos, la disponibilidad de herramientas capaces de cuantificar la variabilidad espacial de un cultivo ha crecido de manera sostenida durante las últimas décadas. Para ello, entre las tecnologías más difundidas, se encuentran los sensores remotos multiespectrales, los mapas de rendimiento, los modelos de topografía digital, los sensores de conductividad eléctrica, y los relevamientos edáficos dirigidos, los cuales permiten caracterizar tanto la condición del suelo como la dinámica del cultivo a lo largo del ciclo.

El presente trabajo tuvo como objetivo desarrollar y evaluar modelos de estimación del rendimiento de cebada mediante la integración de información espectral y edáfica, analizando el efecto de distintas resoluciones espaciales sobre su desempeño predictivo. El estudio se realizó en un lote agrícola de 105 ha ubicado en el partido de General La Madrid, provincia de Buenos Aires. Se utilizaron datos de rendimiento provenientes de un monitor de cosecha, imágenes multiespectrales Sentinel-2 para el cálculo del Índice de Vegetación Normalizado (IVN) y mediciones de profundidad de tosca obtenidas mediante muestreo directo. A partir de estos datos se generaron tres variables predictoras: IVN Máximo en antesis, IVN promedio del ciclo (IVN Ciclo) y profundidad de la tosca.

Los datos se homogeneizaron mediante cuadrículas de hexágonos regulares a tres resoluciones espaciales diferentes (10 m, 50 m y 100 m). Se construyeron modelos de regresión lineal múltiple para cada resolución y su desempeño fue evaluado mediante el coeficiente de determinación (R^2), la eficiencia de Nash–Sutcliffe (NSE), el error cuadrático medio (MSE) y su raíz (RMSE).

Los resultados mostraron que el IVN Máximo fue la variable con mayor frecuencia de significancia estadística en todas las resoluciones. Las resoluciones más agregadas (50 m y 100 m) exhibieron mayor estabilidad y robustez en los modelos, en contraste con la resolución de 10 m que mostró menor consistencia estadística. El modelo con mejor desempeño se obtuvo de la resolución de 50 m con un RMSE de aproximadamente $0,28 \text{ t ha}^{-1}$. En conclusión, la integración de información espectral y edáfica permitió explicar de manera confiable el rendimiento de cebada a escala de lote en el partido de General La Madrid.

Introducción

En las últimas décadas, la agricultura mundial enfrenta el desafío de satisfacer una creciente demanda de alimentos impulsada por el aumento demográfico. Desde mediados del siglo XX, los avances en salud, nutrición y condiciones socioeconómicas han acelerado el crecimiento poblacional, generando una presión creciente sobre los recursos naturales (UN, 2022).

Por otro lado, el aumento productivo por unidad agrícola conlleva avances tecnológicos que buscan optimizar procesos, aumentar la eficiencia del uso de insumos y comprender la variabilidad espacial y temporal de los cultivos con un nivel de detalle anteriormente inalcanzable. Entre los principales avances se destacan la mejora genética, el desarrollo de insumos más eficientes y el uso de agroquímicos de menor impacto ambiental. Estas innovaciones, junto con nuevas prácticas de manejo, han contribuido a un notable incremento en la producción de alimentos a escala mundial (Tilman et al., 2002; Foley et al., 2011).

Frente a esta necesidad de producir más y mejor, con menos recursos y menor impacto ambiental, a fines de la década de 1980 y principios de 1990, surgió la Agricultura de Precisión como un enfoque de manejo sitio-específico orientado a ajustar las prácticas de manejo a la variabilidad intra-lote (Pierce & Nowak, 1999). A la vez, la liberación del sistema de posicionamiento global (GPS) para uso civil permitió conocer con exactitud la ubicación de la maquinaria y de cada punto dentro del lote. Este avance, junto con el desarrollo de sensores y mapas de rendimiento integrados a las cosechadoras, posibilitó registrar información georreferenciada y elaborar mapas de variabilidad espacial de distintos parámetros del cultivo y suelo (Mulla, 2013; Sishodia et al., 2020).

La heterogeneidad espacial dentro de los lotes agrícolas ha sido ampliamente reconocida, aunque durante mucho tiempo no se dispuso de herramientas adecuadas para cuantificarla. A partir del aumento de los costos de los insumos en la década de 1990, los productores comenzaron a adoptar tecnologías de manejo sitio-específico que permiten ajustar las dosis y optimizar el uso de insumos según el potencial productivo de cada zona (Peralta et al., 2013; Sishodia et al., 2020).

Paralelamente, creció la preocupación por el impacto ambiental al evidenciarse que el modelo productivo tradicional estaba generando efectos negativos tanto en el medio ambiente como en el ámbito social. Como consecuencia, el concepto de sustentabilidad cobró significativa relevancia, entendida como la capacidad de satisfacer las necesidades del presente sin comprometer la capacidad de las futuras

generaciones para satisfacer las suyas (WCED, 1987). El sector agrícola comenzó a tomar conciencia de la degradación potencial de los recursos naturales y de la necesidad de desarrollar sistemas productivos más resilientes y eficientes frente a la variabilidad climática (Tilman et al., 2002; Foley et al., 2011).

La demanda actual de los mercados también constituye un nuevo desafío para la producción agrícola que exige mayor eficiencia, sustentabilidad y trazabilidad. En este contexto, la agricultura de precisión adquiere un rol central como herramienta que permite ajustar el manejo a los requerimientos específicos del cultivo y generar información confiable para los sistemas de certificación. De este modo, la comercialización, la sustentabilidad y la agricultura de precisión se articulan bajo un objetivo común: el de producir más y mejor, utilizando menos recursos, preservando el medio ambiente y respondiendo a las nuevas exigencias del mercado (Talukder et al., 2020).

Considerando estos factores, las técnicas *in situ* y vía remota adquieren relevancia ya que permiten obtener información precisa y a escala de lote para la caracterización del crecimiento y la detección temprana de factores limitantes de los cultivos (Peralta et al., 2013; Sishodia et al., 2020). Por ejemplo, el uso de índices espectrales como el Índice de Vegetación Normalizado (IVN) ha demostrado ser una herramienta eficaz para estimar biomasa, vigor vegetal y rendimiento potencial de los cultivos, a partir de combinar bandas espectrales de la región visible e infrarrojo cercano del espectro electromagnético (Reynolds et al. 2000; Oberthur et al. 2007).

En la producción de granos, la disponibilidad de herramientas capaces de cuantificar la variabilidad espacial del cultivo ha crecido de manera sostenida durante las últimas décadas (Mulla, 2013; Sishodia et al., 2020). Para ello, entre las tecnologías más difundidas, se encuentran los sensores remotos multiespectrales, los mapas de rendimiento, los modelos de topografía digital, los sensores de conductividad eléctrica, y los relevamientos edáficos dirigidos, los cuales permiten caracterizar tanto la condición del suelo como la dinámica del cultivo a lo largo del ciclo (Peralta et al., 2013; Sishodia et al., 2020).

En este marco, los índices espectrales derivados de imágenes satelitales o de plataformas aéreas, y particularmente el IVN, se han consolidado como indicadores robustos del estado de la vegetación. Diversos estudios han demostrado que el IVN se relaciona con la biomasa aérea, la interceptación de radiación fotosintéticamente activa y el vigor del cultivo, variables fuertemente asociadas al rendimiento final (Cabrera-Bosquet et al., 2011; Panek et al., 2020; Zsebő et al., 2024). Sin embargo, la

capacidad predictiva del IVN depende del momento fenológico en el que se realiza la medición, dado que las relaciones entre vigor y rendimiento varían a lo largo del ciclo del cultivo (Li et al., 2024; Zsebő et al., 2024).

En cultivos de invierno como la cebada cervecera, la literatura coincide en que las etapas cercanas a antesis representan un período crítico para estimar el rendimiento, ya que coinciden con el máximo desarrollo y con la fijación del número de granos por unidad de superficie (Figuigui et al., 2020; Li et al., 2024). Por otra parte, factores edáficos como la profundidad de tosca condicionan la disponibilidad hídrica para el cultivo y, por ende, influyen directamente en el rendimiento (Pazos & Mestelan, 2002; Krüger et al., 2020; Peralta et al., 2022). Es por eso que la integración de información espectral con información edáfica permitiría desarrollar modelos más robustos que consideren simultáneamente la oferta de recursos y la respuesta del cultivo.

Un aspecto relevante en la modelización espacial es la resolución o tamaño de unidad de análisis. La literatura señala que la elección de la resolución puede modificar la estabilidad de las relaciones estadísticas, ya que resoluciones muy finas pueden estar afectadas por variabilidad intra-lote, mientras que resoluciones más agregadas pueden suavizar variaciones de interés (Wu, 2004; Nouri et al., 2017).

La provincia de Buenos Aires tiene un papel fundamental en la producción agropecuaria nacional dado que, en sus 37 Mha, se ubica casi el 50 % de la superficie sembrada del país y se concentra aproximadamente el 56 % del total de exportaciones bovinas, el 44 % de las de cereales y el 32 % de las oleaginosas del país (Bona, 2021). Con más de un tercio de la superficie agrícola y el liderazgo en cuatro de las cinco principales producciones nacionales (soja, trigo, girasol, cebada), siendo segunda en la restante (maíz), es la principal productora agropecuaria del país. La mayor participación de la provincia en el total nacional se observa en la cebada y el girasol, con el 85% y 56% de la producción nacional, respectivamente; le siguen en orden de magnitud el trigo (28% de la producción nacional), la soja (31%) y el maíz (28%). En conjunto, estos cultivos alcanzaron una siembra de 12,9 Mha en la campaña 20/21, el máximo registro que ha tenido la provincia en su historia (MDA, 2023).

Más allá de su relevancia, su geografía es muy diversa y cuenta con regiones de muy distinta especialización, donde históricamente han prevalecido actividades agrícolas, ganaderas o de rotación (Bona, 2021). Por ello, su extenso territorio ha sido dividido en regiones productivas (Figura 1) las que no sólo identifican las zonas agronómicas por excelencia de la provincia, sino que, además, integran otros criterios, como los

poblacionales (no más de 1,4 M habitantes), geográficos (distritos colindantes), de cantidad de municipios (entre diez y veinticinco) y productivos (por composición sectorial y de cadenas de valor afines (Ministerio de Economía de Pcia. Bs. As., 2011).




Figura 1: Regiones productivas de la provincia de Buenos Aires según Bona (2021).

La Región Sudoeste se constituye en una de las más extensas del territorio bonaerense y presenta condiciones climáticas relativamente diversas, con una zona de características patagónicas en el sur y mayor fertilidad del suelo hacia el norte de la misma. La actividad agrícola-ganadera es preponderante a partir del desarrollo de la ganadería de invernada, sumada a la cosecha de trigo, girasol y cebada cervecera (Figura 2; Bona 2021). El crecimiento de la agricultura extensiva se basa en diversas cuestiones, entre las que se destacan factores coyunturales, como el importante aumento de los precios de los *commodities* por la pandemia, y otros factores estructurales como las mejoras en los paquetes tecnológicos, que permitieron la adopción de estos cultivos en zonas menos adaptadas de la provincia (MDA, 2023).

En cuanto a la producción de cultivos de fina, la cebada merece especial atención por su rápida expansión lo que se explica por la conducta defensiva de los productores (mayor tolerancia de este cultivo al estrés hídrico y los buenos precios actuales del cereal). Dos demandas complementarias explican gran parte de este crecimiento: la demanda de “cebada cervecera”, con calidad apta para el uso de la industria maltera, donde la provincia tiene una gran parte de la capacidad nacional, y la “cebada forrajera”, de fuerte demanda externa por su uso como alimentación animal (MDA, 2023).




Figura 2: Evolución de la superficie (ha) sembrada de girasol, maíz, soja y trigo de los cultivos en la Región Sudoeste de la Pcia. de Buenos Aires. Campañas 1978/79, 1998/99, 2008/09, 2014/15 y 2018/19 (tomado de Bona, 2021).

General La Madrid es uno de los partidos que integran la Región Sudoeste de la provincia de Buenos Aires (Figura 1). El principal rubro económico del mismo es el agropecuario (Figura 3), aportando el 72% del valor agregado bruto. La actividad agrícola ocupa aproximadamente un 32 % del territorio y está destinada a gran diversidad de cultivos como avena, trigo, maíz, soja, girasol y cebada, siendo este último un componente importante para la ganadería como verdeo y para la agricultura como grano (Soc. Rural de Gral. Lamadrid, datos no publicados).




Figura 3. Uso/Cobertura del partido de General Lamadrid, Buenos Aires. *Uso Agrícola-ganadero*: áreas con producción agrícola predominante donde se identifican intercalados algunos lotes de producción ganadera. *Uso Mixto*: áreas con una proporción equitativa de las categorías agrícola y ganadera (tomado de Otero, 2016).

El cultivo de cebada destinada a la cosecha ocupa el 14% de la superficie del partido (Soc. Rural de Gral. La Madrid, datos no publicados), por lo que desarrollar una herramienta que pueda predecir su rendimiento a la escala de lote sería de gran utilidad para los productores en términos de logística productiva, frente a los cambios de la economía actual del país.

A pesar del avance de tecnologías aplicadas a la producción agropecuaria, en la región del sudoeste bonaerense, y específicamente en el partido de General La Madrid, existe escasa información sobre la combinación de IVN, profundidad de tosca y diferentes resoluciones espaciales para la estimación del rendimiento de cebada. Esta falta de antecedentes justifica la necesidad de desarrollar modelos locales que permitan comprender la variabilidad del cultivo y aportar herramientas útiles para el manejo sitio-específico.

En este contexto, el presente trabajo tiene como propósito desarrollar un modelo de estimación del rendimiento de cebada a partir de información espectral y de profundidad de tosca, analizando su desempeño bajo distintas resoluciones espaciales.

Materiales y Métodos

Área de estudio

El trabajo se llevó a cabo en un lote del establecimiento “Atalaya”, ubicado en el partido de General La Madrid, provincia de Buenos Aires, Argentina, próximo a la localidad de Líbano (Figura 4A). Las coordenadas del centro del polígono son 37°39'07"S 61°26'13"W. El mismo abarca una superficie de 105 ha (Figura 4B).




Figura 4. A- Ubicación del establecimiento “La Atalaya”, en un sector de la región sudoeste de la provincia de Buenos Aires. B- Perímetro del área estudiada delimitada con un polígono rojo (el mayor).

Información técnica del lote

El lote tenía como antecesor un cultivo de girasol con un rendimiento promedio de aproximadamente 1500 kg ha⁻¹. La Tabla 1 resume la información técnica sobre las labores realizadas para el cultivo de cebada estudiado.

Tabla 1. Manejos productivos realizados durante el ciclo del cultivo

Fecha	Labor	Producto	Dosis
6/05/24	Pulverización	Glifosato	2,5 L ha ⁻¹
		2,4-D	0,8 L ha ⁻¹
		Heat	0,035 L ha ⁻¹
10/06/24	Rolo picador		
16/06/24	Siembra	Cebada Overture	120 kg ha ⁻¹
		DAP	70 kg ha ⁻¹
25/06/24	Pulverización	Glifosato	1,5 L ha ⁻¹
		Flurocloridona	1 L ha ⁻¹
15/08/24	Fertilización	Urea	100 kg ha ⁻¹

Variables estudiadas

Para poder realizar el estudio propuesto se decidió utilizar el mapa de rendimiento, el IVN y el mapa de profundidad de tosca del lote en cuestión.

Rendimiento

La cosecha del lote se comenzó el 14/12/24 y finalizó el 16/12/24. Los datos de rendimiento se obtuvieron a partir del monitor de cosecha de marca *Plantium* modelo S.BOX, instalado en la cosechadora. Este monitoreo de cosecha permitió registrar un conjunto de datos puntuales y continuos del cultivo, controlar el rendimiento general del lote en tiempo real y obtener mapas de rinde. La información original incluyó registros georreferenciados de producción (en t ha⁻¹), con una frecuencia de muestreo de 5 segundos abarcando un ancho de labor de 10,5 m.

Finalizada la cosecha, se cerró el mapa y dentro de la memoria se generaron los mapas en formato SBOX. Luego, se utilizó el programa *Map Easy Convert* para convertirlos a mapas en formato “.shp” (formato universal de los Sistemas de Información Geográfica) resultando un multiarchivo compuesto por tres archivos de igual nombre con las extensiones .shp, .shx, .dbf.) (Figura 5).

Previo al análisis, la base de datos fue depurada para eliminar valores atípicos, lecturas erróneas, superposiciones de pasadas o variaciones abruptas no atribuibles al cultivo. Para ello se aplicaron filtros basados en la posición del cabezal, distancia entre

puntos consecutivos, valores atípicos que por sí solos estaban fuera de la media de sus vecinos y puntos correspondientes a cabeceras (Figura 6).




Figura 5. Mapa de puntos de rendimiento ($t\ ha^{-1}$) de la cebada (en formato “.shp”).




Figura 6. Mapa de puntos de rendimiento ($t\ ha^{-1}$) de la cebada (en formato “.shp”) obtenido luego de filtrar los datos según los criterios mencionados.

Índice de vegetación normalizado - IVN

Para el procesamiento de las imágenes en relación de este parámetro se utilizó la colección Sentinel-2, constelación diseñada para brindar datos e imágenes al programa de Copernicus, perteneciente a la Comisión Europea (*Visualización de productos Sentinel-2 L2A en Copernicus Data Space*). La colección cuenta con una cámara multispectral con resoluciones de 10 m, 20 m y 60 m, y para este trabajo se seleccionó la resolución de 10 m para tener mayor nivel de detalle. Dicha resolución cuenta con 4 bandas de diferentes porciones del espectro electromagnético (longitud de onda), pero las que fueron de interés para el trabajo para los fines de calcular el IVN fueron la banda roja (B4), que abarca longitudes de onda de 0,65-0,68 μm , y la infrarroja cercana (B8), con longitudes de 0,78-0,90 μm , que fueron parte de la siguiente ecuación:

$$IVN = \frac{B8 - B4}{B8 + B4}$$

Otras de las características de la constelación Sentinel-2 importante para este trabajo fue la frecuencia en la que es posible obtener imágenes terrestres. Al contar con dos satélites idénticos en la misma órbita, que trabajan en conjunto de manera sincrónica y separados entre sí por 180°, permite obtener imágenes cada 5 días, por lo tanto, tiene la ventaja de evitar la pérdida de información por condiciones climáticas adversas (por ejemplo, nubosidad).

Para la obtención de las de las variables predictoras se generó una serie temporal de IVN. Se utilizaron datos desde la fecha de siembra a la cosecha aplicando una máscara de nubes por escena y calculando, para cada fecha, el valor medio del IVN dentro del lote, la que fue exportada en formato CSV. Con estos datos se generó un gráfico (Figura 7) a partir del cual se determinó la fecha en la que se registró el pico de IVN y que representó el momento de la antesis del cultivo.

Una vez evaluada la dinámica del IVN durante el ciclo del cultivo, se seleccionaron las escenas comprendidas entre el 1 de julio y el 18 de octubre de 2024, coincidentes con el período desde emergencia a antesis del cultivo. La información se filtró por intersección con el polígono del lote estudiado y por un porcentaje global de nubosidad menor al 40 %. Posteriormente, se calculó el IVN de todo el lote para cada fecha filtrada desde la emergencia a la antesis.

Luego de cargados todos los mapas de IVN del periodo, se hizo un promedio de los valores de cada fecha por cada pixel, resultando un nuevo mapa (Figura 8) que explicó

el desempeño productivo de la cebada. A esta variable independiente se la denominó “IVN Ciclo”.




Figura 7. Dinámica temporal del IVN promedio del lote obtenido a partir de imágenes multiespectrales para la campaña 2024 de fina.




Figura 8. Imagen ráster que representa el IVN ciclo desde la emergencia a la antesis del cultivo, Los colores muestran una graduación, desde la intensidad de verde que representa a altos valores de IVN hasta el rojo que representa valores menores de IVN.

Para la determinación del IVN en antesis, se repitió el mismo proceso que con IVN Ciclo, pero solo en la fecha del 18 de octubre del 2024. A esta otra variable independiente se la nombró “*IVN máximo*” (Figura 9).



Figura 9. Imagen ráster que representa el *IVN máximo* para la fecha de 18/10/24 (antesis). Los colores muestran una graduación, desde la intensidad del rojo que representa valores menores de IVN hasta el verde que representa a altos valores de IVN.

Profundidad de la tosca

La tosca corresponde a un horizonte petrocálcico cuya cementación limita la profundidad efectiva del suelo y la exploración radicular (Jenny, 1994; Lal & Shukla, 2004). En este establecimiento, se presenta una capa subsuperficial de carbonato de calcio, de dureza y espesor suficientes para impedir el paso de las raíces y limitar el volumen de suelo explorado por las mismas.

Una característica importante es la variabilidad que puede existir en la profundidad de esta capa y, dado que dicha profundidad no es evidente, resulta de sumo interés cuantificarla en forma experimental ya que es de suma utilidad para contribuir con las variables que determinen el rendimiento.

Para ello, se realizaron mediciones de la profundidad de la tosca para distintos pares de coordenadas de lote. La obtención de datos consistió en la medición directa de la profundidad de la tosca utilizando un barreno hasta un valor máximo de 150 cm, con una incerteza de 1 cm. Cada medición fue georreferenciada empleando un GPS GARMIN Etrex Legend®, que registra las coordenadas del punto con una incerteza máxima de 5 m. De esta manera se establecieron las tres coordenadas que identifican a cada uno de los puntos de muestreo.

El mapa se realizó previamente al presente trabajo, utilizando una densidad de muestreo de 4 puntos por hectárea. Se tomó una muestra cada 50 m y luego se formó una grilla de muestras equidistantes.

Una vez obtenida una muestra estadística de puntos, estos datos fueron procesados con el software QGIS, el cual realiza triangulaciones que modelan una superficie consistente con los datos aportados. Así se obtuvo otra de las variables predictoras del rendimiento y llamada “Profundidad de la tosca” (Figura 10).




Figura 10. Mapa de profundidad de la tosca (m) interceptada con el área de estudio, elaborado mediante interpolación espacial en QGIS. Se representan las isolíneas y clases de profundidad (0–1,6 m).

Unión de datos por resolución

Para la combinación de datos georreferenciados y homogeneizados en una misma área, se confeccionó una cuadrícula de hexágonos. Dentro de cada unidad de estudio quedó representada la mediana de cada variable para que los valores extremos que no fueron filtrados no incidieran en el posterior análisis estadístico.

Dado que los datos de las variables tenían diferentes formatos (GEOTIFF para las variables de *IVN Ciclo* e *IVN Máximo*; SHP en forma de polígonos para la profundidad de la tosca y en símbolos de puntos para el mapa de rendimiento), se homogeneizaron los datos en tres resoluciones diferentes para evaluar la capacidad predictiva de cada una.

La grilla de hexágonos fue generada mediante la plataforma QGIS. En dicha herramienta, la construcción de grillas hexagonales requiere la definición de los parámetros operativos denominados “espaciado horizontal” y “espaciado vertical”. Con el objetivo de obtener hexágonos regulares, a ambos parámetros se les asignó el mismo valor, el cual corresponde a la distancia entre caras opuestas del hexágono. De este modo, la geometría de cada celda queda representada por una única dimensión característica. Se emplearon tres resoluciones espaciales, correspondientes a distancias entre caras opuestas de 10 m, 50 m y 100 m.




Figura 11. Unidad hexagonal de las cuadrículas. La flecha naranja representa el espaciado vertical y la flecha verde el espaciado horizontal.

La confección de las cuadrículas fue mediada por la plataforma de QGIS, mediante herramientas vectoriales de investigación permitiendo corregirlo al área de estudio por herramientas de geoproceto de corte e intersección. Una vez que se obtuvo la capa base del área para cada resolución de polígonos, se procedió a incorporarle los datos de rendimiento, IVN Máximo, IVN Ciclo y profundidad de la tosca a cada unidad de la cuadrícula (hexágono).

Para las combinaciones de datos por hexágono, se utilizaron diversas herramientas. En el caso de rendimiento y profundidad de la tosca, la herramienta de “Unir atributos por localización (Resumen)” fue la más adecuada para el formato vectorial de puntos y polígonos. Se calculó la mediana por localización y se añadió dentro de cada uno de los hexágonos. Para las imágenes ráster de IVN se utilizó la herramienta de “Estadísticas zonales” que permite unir la capa de formato TIFF dentro de la vectorial, calculando la mediana por unidad hexagonal. Como resultado se obtuvo una

cuadrícula de Hexágonos con la mediana de todas las variables. Este procedimiento se repitió para las tres resoluciones (Figura 12).




Figura 12. Cuadrículas de hexágonos de diferentes resoluciones. A- 10 m; B- 50 m; C- 100 m. Los colores muestran una graduación, desde la intensidad del rojo que representa valores menores de rendimiento hasta el verde que representa a altos valores de rendimiento.

Generación de modelos explicativos del rendimiento de la cebada

Para poder realizar los modelos de predicción de rendimiento, primero se realizó una selección de datos al azar. En esta etapa se utilizó una herramienta de QGIS, que se basa en la selección aleatoria de subconjuntos. El criterio para cada resolución fue tomar diez conjuntos de datos elegidos al azar ($n=30$), c/u dividido en dos grupos: un conjunto de *entrenamiento* ($n=20$) y el otro de *validación* ($n=10$). Cada subconjunto de entrenamiento fue utilizado para construir los modelos, mientras que el subconjunto de validación se utilizó para evaluar su capacidad predictiva. Este paso garantizó que la validación del modelo se realice con datos independientes, y no con los mismos que fueron utilizados para entrenarlo.

Una vez estructurados los conjuntos de datos para cada resolución en un Excel, se procedió a la construcción de los modelos mediante Google Colab, una plataforma de

computación en la nube que permite ejecutar código de lenguaje *Python*. Su entorno orientado al trabajo con bibliotecas científicas que facilitan el análisis estadístico, manejo de grandes volúmenes de datos y desarrollo de modelos de aprendizaje automático fue de gran utilidad porque sus virtudes se adaptaban a las características del trabajo.

Se incorporaron a la nube de la plataforma los archivos XLSX correspondientes a la base de datos de cada resolución. Se generaron una serie de regresiones lineales múltiples, tomando como variable dependiente al rendimiento y como variables independientes a IVN Máximo, IVN Ciclo y a la profundidad de la tosca. De este proceso se obtuvo como resultado para cada modelo, los coeficientes de las tres variables regresoras y los valores de significancia tanto del modelo (valor F) como de cada variable (valor p). En base a la significancia de cada modelo (valor F) se preparó la etapa de validación, descartando aquellos que no fueron significativos (Valor F > 0.05).

Evaluación de modelos explicativos del rendimiento de la cebada

Una vez identificados los modelos significativos, se tomó el conjunto de datos de validación seleccionados previamente para utilizarlos en los modelos de entrenamiento y así obtener las predicciones. Por su parte, también se calcularon indicadores estadísticos de robustez de cada modelo. Las métricas utilizadas fueron: Coeficiente de determinación (R^2), Eficiencia de Nash E (NSE), Error cuadrático medio (MSE), Raíz del error cuadrático medio (RMSE), además del valor p de la estadística F de validación.

Se filtraron nuevamente los modelos, seleccionando solo aquellos cuya significancia estadística (medida por el valor F de validación) fue menor al 0,05 para generar una serie de gráficos de puntos agrupados, y así visualizar las métricas de validación por resolución de hexágono en un panel de cuatro gráficos correspondiente a cada indicador.

Por otro lado, se estudiaron los comportamientos de las variables independientes. Se realizaron matrices de correlación para ver el grado de ajuste que tuvo cada variable respecto de la otra. El objetivo fue analizar si mostraban el mismo comportamiento y, en caso de ser así, explicar de igual forma al rendimiento. Este análisis fue acompañado con su valor p correspondiente a cada correlación. Por su parte, se

estudió la frecuencia por la cual cada variable era significativa (valor p) en los 30 modelos de entrenamiento, 10 por cada resolución espacial.

Resultados

Generación de modelos explicativos de rendimiento de la cebada

De las tres variables analizadas, el *IVN Máximo* fue la que más frecuentemente (>60%) explicó el rendimiento de la cebada, independientemente de la resolución espacial. En cambio, el *IVN Ciclo* tuvo una frecuencia inferior al 10% en la resolución de 10 m, y aumentó con la disminución de la resolución espacial (Figura 12). Por su parte, la variable *Profundidad de tosca* alcanzó una frecuencia del 30% en 50 m y 100 m, mientras que no presentó significancia en la resolución de 10 m (Figura 12).




Figura 13. Frecuencia (%) con que las variables independientes fueron significativas en los modelos explicativos del rendimiento de cebada para cada resolución espacial (10 m, 50 m y 100 m).

En cuanto a las matrices de correlación, en la resolución de 10 m, la correlación entre *IVN Máximo* y *Profundidad de tosca* fue significativa ($r = 0.59$), así como entre *IVN Máximo* e *IVN Ciclo* ($r = 0.54$). La correlación entre *IVN Ciclo* y *Profundidad de tosca* fue menor ($r = 0.16$), manteniendo no obstante significancia estadística (ment $p = 0.026$) (Figura 13A). En la resolución 50 m, la relación entre *IVN Ciclo* y *Profundidad de tosca* fue la más baja entre las variables de esta resolución ($r = 0.22$), mientras que en las demás relaciones se mantuvieron similares a las observadas en 10 m (Figura 13B). Por último, en la resolución 100 m, se registraron las correlaciones más altas de todo el análisis, destacándose la asociación entre *IVN Máximo* y *Profundidad de tosca* ($r = 0.68$), seguida de la relación entre *IVN Máximo* e *IVN Ciclo* ($r = 0.64$) y también una correlación entre *Profundidad de tosca* e *IVN Ciclo* ($r = 0.33$) (Figura 13C).




Figura 14. Matrices de correlación entre las variables independientes (NDVI Máximo, NDVI Ciclo y Profundidad de tosca) para cada una de las resoluciones espaciales analizadas. A- 10 m; B- 50 m; C- 100 m. Los valores expresados en la parte superior derecha de cada matriz corresponden a coeficiente de Pearson (tonalidades de azul según la intensidad). En la parte inferior izquierda de cada matriz se encuentran los valores p de las correlaciones, donde se puede ver con tonalidades graduales de verde según la intensidad.

Evaluación de los modelos explicativos del rendimiento de la cebada

El comportamiento del NSE (Figura 14A) mostró una similitud en el comportamiento de los valores en todas las resoluciones, salvo un caso en la de 10 m, que tiene mayoría de valores positivos, aunque destaca un caso extremo con $NSE = -1.62$. En las resoluciones de 50 m y 100 m, los modelos se agruparon también en torno a valores cercanos a cero o moderadamente positivos, (equivalentes a predecir tan bien como la media).

Por su parte, el R^2 presentó una tendencia más heterogénea entre resoluciones. En 10 m, los valores oscilaron entre 0,47 y 0,79 mostrando una mayor distribución de los valores. En 50 m, al igual que en la anterior resolución, mostraron una mayor

dispersión de los R^2 , que rondaron entre 0,45 y 0,81, mientras que en 100 m se vio una mayor agrupación de puntos entre 0,55 y 0,68 (Figura 14B).




Figura 15. Distribución de los indicadores estadísticos para los modelos de predicción en cada resolución espacial. A- Eficiencia de Nash-Sutcliffe (NSE); B- Coeficiente de correlación (R^2); C- Raíz del error cuadrático medio (RMSE) y D- Error cuadrático medio (MSE). Los colores distinguen a cada resolución espacial (naranja 10 m; azul: 50 m y verde: 100 m).

En cuanto a los valores de RMSE, mostraron una disminución general del error a medida que aumenta la resolución espacial. En 10 m variaron ampliamente (0,7-1,5), al igual que en 50 m que también mostraron gran distribución de valores (0,3-1,2). En cambio, en 100 m se observaron datos agrupados y de menor magnitud de RMS (0,4-0,9) (Figura 14C).

Finalmente, el MSE reprodujo el mismo patrón observado en RMSE, dado que ambos indicadores están directamente relacionados. En 10 m apareció el modelo con mayor error del conjunto ($MSE > 2,0$), asociado al valor extremo de NSE negativo y con un grupo de valores altos y variables. En 50 m tuvo el valor más bajo pero un promedio general más alto que en 100 m, donde los MSE se distribuyeron en valores bajos, coherentes con el comportamiento de RMSE (Figura 14D).

Luego de todos los análisis hechos y el descarte de modelos que no cumplieran con la significancia estadística, quedaron 17 modelos de regresiones múltiples capaces de predecir el rendimiento (Tabla 2).

Tabla 2. Modelos de predicción de rendimiento con sus respectivos índices estadísticos. La columna de “Tamaño” representa a las diferentes resoluciones de estudio. A cada fila de resolución le corresponde un conjunto de filas de la columna de “modelos”, haciendo referencia a los modelos de entrenamiento llamados “T”.

IVN (Índice de Vegetación Normalizado); NSE (Eficiencia de Nash–Sutcliffe); R² (Coeficiente de correlación); RMSE (Raíz del error cuadrático medio); MSE (Error cuadrático medio). Para cada modelo hay una “Constante” como coeficiente de intersección y los coeficientes que acompañan a cada variable independiente.

Tamaño	Modelo	NSE	R ²	MSE (t ha ⁻¹) ²	RMSE (t ha ⁻¹)	Constante (Tn ha ⁻¹)	Coeficiente IVN Máximo (t ha ⁻¹)	Coeficiente IVN Ciclo (t ha ⁻¹)	Coeficiente Profundidad de la tosca (t ha ⁻¹ ·m ⁻¹)
10 m	T1	0.44	0.47	0.53	0.73	-19.01	29.40	-6.21	0.85
	T3	0.76	0.79	0.84	0.92	-30.15	35.64	4.13	1.49
	T5	0.59	0.60	0.61	0.78	-12.48	20.64	-6.13	2.07
	T9	-1.62	0.73	2.41	1.55	-26.75	38.62	-7.13	0.58
	T10	0.51	0.53	1.14	1.07	-31.28	44.78	-9.57	1.20
50 m	T1	0.56	0.70	0.11	0.32	-16.94	31.44	-13.46	0.50
	T2	0.39	0.62	1.46	1.21	-14.61	22.24	-2.26	0.96
	T4	0.39	0.58	0.33	0.57	-23.44	37.38	-11.37	0.73
	T7	0.41	0.46	1.26	1.12	-16.50	23.64	-2.39	1.91
	T8	0.76	0.81	0.08	0.28	-11.84	20.24	-3.24	0.31
	T9	0.34	0.46	0.40	0.63	-24.58	35.69	-5.80	0.21
	T10	0.29	0.66	0.24	0.49	-19.29	21.91	7.96	0.91
100 m	T1	0.46	0.65	0.21	0.45	-9.66	22.73	-13.17	1.06
	T4	0.28	0.66	0.94	0.97	-11.55	27.10	-16.99	0.64
	T6	0.44	0.61	0.86	0.93	-15.15	25.39	-5.92	0.42
	T7	0.49	0.66	0.21	0.46	-30.37	51.10	-20.98	-0.51
	T9	0.65	0.67	0.17	0.41	1.78	5.12	-6.08	1.88
	T10	0.39	0.56	0.89	0.94	-6.18	11.71	-1.94	2.08

Los modelos observados en la Tabla 2 son aquellos que no fueron descartados por la significancia estadística. Además de los indicadores estadísticos evaluados, cada modelo tiene un coeficiente de intersección que indica al valor de 'Y' cuando todas las variables independientes son cero y a los coeficientes de cada variable independiente que representan el cambio promedio en el rendimiento por cada unidad de aumento de

valor de cada predictor, pero manteniendo todas las demás variables independientes constantes.

Entre éstos se puede observar que, en la resolución de 10 m, hubo una menor significancia de los modelos y por ello quedaron 4 modelos significativos. Por su parte, la resolución media (50 m) obtuvo el 70% de los modelos con significancia estadística siendo el de mayor aporte mientras que la resolución de 100 m arrojó el 60% de los modelos de manera significativa.

Individualizando los análisis de la Figura 14, pueden identificarse en la Tabla 2 aquellos modelos que tomaron relevancia para cada resolución. El llamativo valor anómalo de NSE, corresponde al modelo T9 de la resolución de 10 m. En la resolución de 50 m, el modelo T8 fue el que tuvo los valores más apropiados de cada indicador comparado con todos los modelos obtenidos. En cuanto a la resolución de mayor tamaño, no hubo modelos de relevancia ya que los valores de los indicadores mantuvieron estabilidad dentro de un rango más acotado, y solo el T9 fue el modelo de valores estadísticos de mejor desempeño dentro de la resolución.

Consideraciones finales

A partir de los resultados obtenidos se puede concluir que, en cuanto a la frecuencia la variable IVN Máximo tuvo un desempeño relevante frente a las demás variables en todas las resoluciones (Figura 13). Por lo que dicha variable demuestra significancia en la predicción del rendimiento. Complementariamente al estudio de las variables, comprobamos la correlación entre los predictores para saber el grado de asociación y redundancia. Los valores más altos de r siempre fueron entre la correlación de profundidad de tosca e IVN Máximo para cada resolución, indicando una relación moderada desde el punto de vista estadístico, pero no alta para determinar un sobreajuste o multicolinealidad que amerite la exclusión de alguna de ellas (Figura 14).

Al analizar los modelos en función de la resolución espacial, partimos desde la base que en la resolución de 10 m hubo muy pocos que lograron significancia estadística. Esto pudo explicarse por qué la cuadrícula de hexágonos más detallada contenía una mayor cantidad de unidades de datos. Al recopilar solo un conjunto de 20 para realizar los modelos, se utilizaba un porcentaje pequeño del total de los datos. En términos generales, la resolución detallada obtuvo mayor variabilidad de datos por lo que no pudo explicar el rendimiento en la mayoría de los casos (Tabla 2).

En contraste, las resoluciones de 50 m y 100 m tuvieron un mejor desempeño en la significancia teniendo 7 y 6 modelos significativos de 10, respectivamente. Disminuir el detalle de la resolución demostró menor variabilidad y mayor robustez comprobada en las validaciones. Este comportamiento se debe a que, al calcular la mediana en un área mayor, se elimina el ruido de los valores extremos dando datos que puedan explicar de mejor forma al rendimiento (Tabla 2).

En relación a las métricas evaluadas para cada modelo podemos observar que el peor desempeño fue el modelo T9 de la resolución de 10 m, teniendo los valores menos apropiados de todos los modelos en 3 de los 4 indicadores, en cuanto al indicador que falta fue R^2 , siendo el tercer valor más alto de todos los modelos. Este resultado pone en evidencia la necesidad de complementar los indicadores y no inclinarse por un solo uno de ellos. En cuanto al mejor modelo nos indica una coherencia estadística, en la resolución 50 m el T8 fue el que mejor desempeño tuvo, obteniendo los mejores resultados estadísticos de todos los modelos realizados. Por su parte en la resolución de 100 m hubo una estabilidad de valores intermedios, sin valores abruptos propio de regular los valores extremos dentro de áreas mayores, que si bien no fue el de mayor repertorio fue el que nos otorga mayor equilibrio en los indicadores (Tabla 2)

Desde una perspectiva aplicada, no hace falta tanto detalle en la construcción de estos modelos. Ni tanto esfuerzo si los mismos están destinados a manejos variables por ambiente. Tampoco necesitamos múltiples variables para poder predecir el rendimiento con anticipación, a partir de 2 meses antes de la cosecha ya es posible encontrar un estimativo de rendimiento que pueda ayudarte en la logística comercial y de la propia cosecha mediante el IVN Máximo.

Desde un enfoque práctico, para conseguir la predicción con este trabajo hace falta un código en lenguaje de programación *Python* que indique el cálculo de IVN en fecha de ané debate y el promedio de la siembra hasta ese mismo momento. También es importante mejorar el conocimiento en el manejo de QGIS para extrapolar esos rásters resultantes a un valor numérico en la ecuación, y también contar con un barreno que permita medir profundidad. Con esto se puede tener una estimación del rendimiento con un error aproximado de $0,28 \text{ t ha}^{-1}$.

Es necesario enfatizar que este modelo (T8 de la resolución 50 m) está diseñado para el partido de General La Madrid, y para su utilización en otra zona se recomiendan nuevos análisis e inclusión de variables edafoclimáticas al modelo que puedan caracterizar de una mejor forma a la zona.

Respecto de la calidad de los mapas de rendimiento se debe tener precaución con los datos obtenidos. Estos fueron los únicos datos obtenidos por un tercero, que por cuestiones de logística otorgaron la irregular forma del área de estudio al retirarse del establecimiento sin brindar la totalidad del mapa. Utilizar criterios adecuados para la filtración de datos erróneos tomados por el maquinista y lo importante prestar suma atención en la calibración de la máquina que te puede llevar al descarte de gran cantidad de datos y superficie del mapa resultante. Por ello es importante involucrarse para obtener datos que se conviertan en información consolidada y útil para cada análisis.

Como líneas futuras del trabajo se busca la inclusión de nuevas variables como otros indicadores espectrales, variables climáticas (precipitación, temperatura, heladas), otras variables edáficas como por ejemplo modelar para una clasificación de suelo determinada, la evapotranspiración y con ello la repetición de los modelos para ver cómo se consolida el modelo a través del tiempo. Este modelo es de una sola campaña, en una zona determinada para un cultivo específico que pretende generar una herramienta útil al productor.

Desde lo personal este trabajo me permitió adquirir múltiples capacidades como procesamiento y conformación de mapas, a partir de imágenes obtenidas de datos de fuente satelital, muestreos manuales y sensores de máquinas (Figura 16), logrando comprender para todas, su metodología de trabajo particular y formato de los resultados. Fue un gran desafío aprender a encontrar la forma de unificarlos y hacer de esos datos una información útil.

Por otro lado, hice el seguimiento del cultivo en el lote, evaluando y haciendo análisis personales en cada visita, sobre el comportamiento del IVN actual frente a la profundidad de la tosca que me permitía entender cómo se expresa el índice frente al parámetro edáfico en las distintas etapas fenológicas con distintas condiciones climáticas (Figura 16A).



Figura 16. Imágenes tomadas en el transcurso del trabajo. A- Visita al lote durante la floración de la cebada. B- Participación y seguimiento de la máquina cosechadora. C- Monitor de la cosechadora que brindó el mapa de rendimiento con falla en el sensor de humedad. D- Inconvenientes en el sinfín de la descarga. E- Visita al lote durante la madurez del cultivo pronto a la cosecha. F- Planilla y GPS utilizados en la conformación del mapa de profundidad.

Por último, estuve presente durante la cosecha para comprender el funcionamiento y respuesta del monitor frente a los demás parámetros (Figura 16B y 16E). Aprendí tanto de lo técnico como en lo social al estar en contacto con los operarios y entender de los problemas propios de una campaña típica (humedad del grano, desperfectos mecánicos, tiempos de trabajo y logística) (Figura 16C y 16D).

Bibliografía

- Bona, L. 2021. Tendencias recientes en los cultivos y la producción ganadera en la provincia de Buenos Aires. Una mirada desde sus regiones productivas. *Ciencia, Docencia y Tecnología* 32(62), 1-39. DOI: <https://10.33255/3262/775>
- Cabrera-Bosquet, L., Araus, J.L., Bort, J. & Nogués, M. 2011. NDVI as a potential tool for predicting biomass, plant height and grain yield in wheat. *Cereal Research Communications* 39, 147–159. <https://doi.org/10.1556/CRC.39.2011.1.15>
- Figuigui, Y., Cossani, F.M. & Savin, R. 2020. *Relationship of NDVI at heading and anthesis with grain number and yield in barley*. Universitat Politècnica de Catalunya. <https://upcommons.upc.edu/bitstreams/9a407a33-edbd-4828-a767-ffd9be9a1d94/download>
- Foley, J.A., Ramankutty, N., Brauman, K.A., Cassidy, E.S., Gerber, J.S., Johnston, M., Mueller, N.D., O'Connell, C., Ray, D.K., West, P.C. & Balzer, C. 2011. Solutions for a cultivated planet. *Nature* 478, 337–342. <https://doi.org/10.1038/nature10452>
- Jenny, H. 1994. *Factors of soil formation: A system of quantitative pedology*. Dover Publications, New York. <https://soilandhealth.org/wp-content/uploads/01aglibrary/010159.Jenny.pdf>
- Krüger, H., Puricelli, C. & Puricelli, M. 2020. Profundidad de suelo, disponibilidad de agua y rendimiento en sistemas agrícolas de secano. *Revista de la Facultad de Agronomía* 119(2), 274–286. https://www.scielo.org.ar/scielo.php?pid=S1850-20672020000200274&script=sci_arttext
- Lal, R. & Shukla, M.K. 2004. *Principles of soil physics*. Marcel Dekker, New York. <https://doi.org/10.4324/9780203021231>
- Li, X., Jin, H., Eklundh, L., Bouras, E.H., Olsson, P.-O., Cai, Z., Ardö, J. & Duan, Z. (2024). Estimation of district-level spring barley yield in southern Sweden using multi-source satellite data and random forest approach. *International Journal of Applied Earth Observation and Geoinformation* 134, 104183. <https://doi.org/10.1016/j.jag.2024.104183>
- Ministerio de Desarrollo Agrario de la Pcia. de Buenos Aires (MDA), 2023. Estrategia Provincial para el Sector Agroindustrial (EPSA). 78pp. <https://www.argentina.gob.ar/sites/default/files/2023/05/agroxxi-epsa-buenosaires.pdf>

- Ministerio de Economía de la Provincia de Buenos Aires. 2011. Plan de Regionalización. La estrategia de desarrollo para la provincia. La Plata: Ministerio de Economía de la PBA.
- Mulla, D.J. 2013. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358–371. <https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Nouri, H., Anderson, S., Sutton, P., Beecham, S., Nagler, P., Jarchow, C.J. & Roberts, D.A. 2017. NDVI, scale invariance and the modifiable areal unit problem: An assessment of vegetation in the Adelaide Parklands. *Science of the Total Environment* 584–585, 11–18. <https://doi.org/10.1016/j.scitotenv.2017.01.130>
- Oberthür, T., Ries, J.B., Poorter, H. & Bol, J. 2007. Using optical remote sensing to estimate grain yield in small-grain cereals. *Agricultural and Forest Meteorology* 144(1–2), 9–17. <https://doi.org/10.1016/j.agrformet.2007.01.008>
- Otero, J. 2017. *Actualización de mapas uso/cobertura de partidos de la Provincia de Buenos Aires*. CONAE; Ministerio de Agroindustria de la Provincia de Buenos Aires.
http://www.gba.gob.ar/static/agroindustria/docs/direccion_de_fiscalizacion_vegetal/PROGRAMA%20PROVINCIAL/Actualizacion_Mapas_Uso-Cobertura_Partidos_Buenos_Aires-CONAE.pdf biblioteca.cfi.org.ar
- Panek, E., Stępień, K.J. & Gozdowski, D. 2020. Analysis of relationship between cereal yield and NDVI for selected regions of Central Europe based on MODIS satellite data. *Remote Sensing Applications: Society and Environment* 17, 100286. <https://doi.org/10.1016/j.rsase.2019.100286>
- Pazos, M.S. & Mestelan, S.A. 2002. Variability of depth to tosca in Udolls and soil classification, Buenos Aires Province, Argentina. *Soil Science Society of America Journal* 66(4), 1256–1264. <https://doi.org/10.2136/sssaj2002.1256>
- Peralta, N.R., Alesso, C.A., Costa, J.L. & Martin, N.F. 2022. Mapping soil depth in southern pampas Argentina using ancillary data and statistical learning. *Soil Science Society of America Journal* 86(1), 65–78. <https://doi.org/10.1002/saj2.20350>
- Peralta, N.R., Costa, G.A., Balzarini, M.A. & Pazos, M.S. 2013. Delineation of management zones using soil apparent electrical conductivity in the southeastern Pampas of Argentina. *Computers and Electronics in Agriculture* 99, 218–226. <https://doi.org/10.1016/j.compag.2013.10.014>

- Pierce, F.J. & Nowak, P. 1999. Aspects of precision agriculture. *Advances in Agronomy* 67, 1–85. [https://doi.org/10.1016/S0065-2113\(08\)60513-1](https://doi.org/10.1016/S0065-2113(08)60513-1)
- Reynolds, M.P., Rajaram, S. & McNab, A. (Eds.). (2000). Application of physiology in wheat breeding. CIMMYT. <https://repository.cimmyt.org/handle/10883/1333>
- Sishodia, R.P., Ray, R.L. & Singh, S.K. 2020. Applications of remote sensing in precision agriculture: A review. *Remote Sensing* 12(19), 3136. <https://doi.org/10.3390/rs12193136>
- Sridhar, V.N., Stow, D.A. & Hope, A.S. 1994. Relationship between vegetation indices and crop characteristics in barley and wheat fields. *Remote Sensing of Environment* 47(3), 299–306. [https://doi.org/10.1016/0034-4257\(94\)90102-3](https://doi.org/10.1016/0034-4257(94)90102-3)
- Stanhill, G., Scholte Ubing, D.W. & Kalma, J.D. 1972. Radiation balance of vegetation. *Quarterly Journal of the Royal Meteorological Society* 98(417), 467–478. <https://doi.org/10.1002/qj.49709841710>
- Talukder, B., Blay-Palmer, A., vanLoon, G.W. & Hipel, K.W. 2020. Towards complexity of agricultural sustainability assessment: Main issues and concerns. *Environmental and Sustainability Indicators* 6(3), 100038. <https://doi.org/10.1016/j.indic.2020.100038>
- Taylor, J.C., Wood, G.A., Earl, R. & Bradley, R.I. 1998. Monitoring crop variability using vegetation indices derived from aerial photography. *Precision Agriculture* 1, 95–110. <https://doi.org/10.1023/A:1009972517230>
- Tilman, D., Cassman, K.G., Matson, P.A., Naylor, R. & Polasky, S. 2002. Agricultural sustainability and intensive production practices. *Nature* 418, 671–677. <https://doi.org/10.1038/nature01014>
- United Nations, Department of Economic and Social Affairs, Population Division. 2022. *World Population Prospects 2022: Summary of results*. United Nations. https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/wpp2022_summary_of_results.pdf
- World Commission on Environment and Development. 1987. *Our common future*. Oxford University Press. <https://www.are.admin.ch/en/1987-brundtland-report>
- Wu, J. 2004. Effects of changing scale on landscape pattern analysis: Scaling relations. *Landscape Ecology* 19, 125–138. <https://doi.org/10.1023/B:LAND.0000021711.40074.ae>

Zsebő, S., Anda, A., Varga, I. & Mátyás, Z. 2024. Yield prediction using NDVI values from GreenSeeker and UAV platforms. *Drones* 8(3), 88.
<https://doi.org/10.3390/drones8030088>