

● ● ●  
**COMPILACIÓN DE  
TRABAJOS TÉCNICOS**



**20° CONGRESO INTERNACIONAL  
AGRICULTURA DE PRECISIÓN**

21 y 22 DE AGOSTO de 2024 - EEA INTA MANFREDI

## **AUTORIDADES Y COMISIONES**

---

### **AUTORIDADES DE INTA**

---

**PRESIDENTE**

MOLINA HAFFORD Juan Cruz

**VICEPRESIDENTE**

GIRAUDO Maria Beatriz

**DIRECTOR NACIONAL**

PEREDA Ariel

**DIRECTOR REGIONAL CÓRDOBA**

SALINAS Aquiles

**DIRECTOR EEA INTA MANFREDI**

GILETTA Martín

### **COMISIÓN ORGANIZADORA**

---

SCARAMUZZA Fernando

VILLARROEL Diego

MENDEZ Andrés

MATHIER Diego

PUECHAGUT Maria Soledad

USTARROZ Fernando

SOSA Nicolás

BRAGACHINI Marcos

BIANCO GAIDO Mauro

EUGENI Maria Elena

OSCAR Victor

### **REVISION Y COMPILACION DE TRABAJOS TECNICOS**

---

MELCHIORI Ricardo

## PROLOGO

La Agricultura de Precisión en Argentina ha tenido un camino de desarrollo estrechamente asociado con la intervención del INTA y con la continuidad de un evento central para estas temáticas, que alcanza el hito de su **20 Congreso Internacional de Agricultura de Precisión**.

Este proceso de generación, difusión y transferencia se originó a mediados de los 90, se potenció innovando en la vinculación con empresas y profesionales como estrategia impulsora. Primero se impulsó la AP desde la tecnificación de la mecanización agrícola y esto demandó más capacitación y creación de conocimientos agronómicos específicos. También demandó herramientas y técnicas para producir y gestionar los recursos desde un concepto diferente, basado en el reconocimiento de la variabilidad para optimizar el manejo de las decisiones agronómicas. Hoy día, cobra fuerza el surgimiento de técnicas analíticas, la instrumentación y automatización, como elementos complementarios para crear oportunidad para que las técnicas sean base de una producción agrícola sustentable.

Este compendio de trabajos presentados en el 20 Congreso Internacional de Agricultura de precisión, es una representación del estado del arte de la AP en Argentina. Con foco en la relación directa con los sistemas de producción, se presenta desde la creación y evaluación de técnicas y herramientas analíticas para la gestión de datos a distintas escalas, propuesta de utilización de vehículos aéreos no tripulados (VANT), utilización de técnicas estadísticas avanzadas e IA para la gestión de datos de interés agronómico, evaluaciones de componentes de la mecanización agrícola y también reportes sobre demandas complementarias de capacitación. Los aportes presentados reflejan hoy también la multiplicidad de actores involucrados.

Finalmente, cabe señalar que esta 20 edición del Congreso Internacional de Agricultura de Precisión alcanzada en 2024, da muestra del compromiso de INTA y la relevancia del rol del Estado como agente promotor del desarrollo de un sistema agroalimentario Argentino referente en la región basado en la aplicación racional de tecnología.

Ricardo Melchiori,  
(INTA EEA Paraná)

 <b>21 DE AGOSTO DE 2024</b> 			
HORARIO	TEMÁTICA	NOMBRE	INSTITUCIÓN
8:00 a 9:00 <b>ACREDITACIÓN</b>			
<b>20° Congreso Internacional de Agricultura de Precisión - INTA Manfredi</b>			
9:00 a 10:20	Brechas en adopción de tecnologías en Argentina ¿hacia una agricultura 5.0?	Fernando Scaramuzza	INTA Manfredi
	Avances, perspectivas y políticas públicas para el desarrollo de la Agricultura de Precisión en Paraguay	Enrique Hahn (Paraguay)	Municipios Colonias Unidas Dpto Itapúa
	Oportunidades y desafíos de la revolución digital en la Agricultura de Precisión	Carlos Vidal	INTA Centro de Investigación en Economía y Prospectiva
<b>Bloque Drones: Moderador Ricardo Melchiori</b>			
10:20 a 11:20	Innovaciones tecnológicas para el control preciso de malezas	José Dorado (España)	Instituto de Ciencias Agrarias
	Calidad en aplicaciones. Oportunidades y experiencias	Eugenio Lobo	Efficatia
	Estado de las normativas que rigen para la aplicación de fitosanitarios a nivel nacional e internacional. ¿Qué debemos hacer?	Marcos Blanda	Secretario de Agricultura y Recursos Naturales. Ministerio de Bioagroindustria Gobierno de Córdoba
11:20 a 12:00 <b>BREAK</b>			
<b>Bloque Fertilización: Moderador Fernando Salvaggiotti (INTA Oliveros)</b>			
12:00 a 13:00	Criterios y herramientas para la gestión de la agricultura por ambientes	Gabriel Tinghitella	CREA - Área de Innovación
	Cropwise: La solución integral para un manejo de precisión	Leandro Romoli	Syngenta Agro
	¿Puede la agricultura de precisión mejorar el negocio agrícola?	Agustín Pagani	Laboratorio de suelo y planta CLARION
13:00 a 15:45 <b>ALMUERZO E INAUGURACIÓN</b>			
13:00 a 15:45 <b>Bloque Dinámica Diego Villarroel (INTA Manfredi) Pedro Ibañez - (INTA CR Buenos Aires Sur)</b>			
15:45 a 16:00	Estudio de Prospectiva Tecnológica-Ocupacional del sector de la maquinaria agrícola de la provincia de Córdoba al 2035	Javier Vitale	INTA CR Mendoza - San Juan
<b>Bloque Siembra Moderador Fernando Scaramuzza (INTA Manfredi)</b>			
16:00 a 17:00	Sembradoras y tecnologías, aliadas para lograr calidad de siembra	Fernando Scaramuzza	INTA Manfredi
	Marcando el camino de la precisión	Bianca Petrolati	Crucianelli - Leaf
	Innovaciones , experiencias y resultados en siembras de alta velocidad	Mario Ghelfi	Plantium
	Innovación en la dosificación de sembradoras Air Drill	José Luis Morena	INDECAR



22 DE AGOSTO DE 2024



HORARIO	TEMÁTICA	NOMBRE	INSTITUCIÓN
<b>Panel Tecnologías para el manejo de malezas: Moderador Andrés Méndez (INTA Manfredi)</b>			
9:00 a 10:15	El desafío en el proceso de aplicación	Lucas Dellamaggiore	ACRONEX
	Mapeo digital de malezas. Tecnología y ahorro	Nicolas Battiston	Xarvio by BASF
	Weedit Quadro: ¿Aplicación dirigida en convencional? Experiencias e innovación	Agustín Dominguez	Geosistemas
	Impacto inteligente: inteligencia artificial en pulverización	Artur Stein Fiegenbaum (Brasil)	Savefarm - Abelardo Cuffia
	Sistema de trazabilidad digital para las buenas prácticas fitosanitarias	Gustavo Balbi	Ministerio de Bioagroindustria
10:15 a 10:40	<b>BREAK</b>		
<b>Bloque Cosecha y Postcosecha Moderador Diego Villarroel (INTA Manfredi)</b>			
10:40 a 12:00	Estrategias y oportunidades en las nuevas generaciones de cosechadoras	Diego Villarroel	INTA Manfredi
	Desafíos en la digitalización del agro	Diego Gutierrez	NEW HOLLAND
	Class - Silajes inteligentes	Leonardo Gatti & Jimena Paradela	CLAAS ARGENTINA
	Conectividad e inteligencia artificial al servicio de la eficiencia productiva	Pablo Petit	CASE IH
	Inteligencia artificial en Cosechadoras... ¿Cuánto es utilizado en nuestro país?	Federico Sánchez	JOHN DEERE
	Tecnologías para almacenamiento	Diego De La Torre	INTA Balcarce
12:00 a 13:30	<b>ALMUERZO</b>		
<b>Plataformas AgTech Moderador Adriana Godoy (INTA Salta)</b>			
13:30 a 14:30	Soluciones AgTech tranqueras afuera	Adriana Godoy	INTA - Programa AgTech
<b>Experiencias en ensayos con Agricultura de Precisión</b>			
14:30 a 15:30	La red colaborativa: clave para el éxito de la agricultura digital	Juan Pablo Vélez	Comunidad AGDI
<b>CIERRE CONGRESO</b>			



PLATINO



ORO



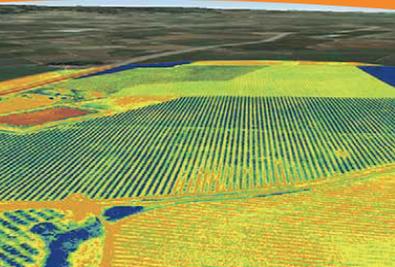
PLATA



BRONCE



COBRE



✉ congreso@nickel.com.ar

● ● Coordina y Comercializa:

**NICKEL**  
Comunicación | Marketing | Producción

## INDICE

■ ... Scaramuzza F, Villarroel D. Estimación de la evolución en la adopción de componentes de Agricultura de Precisión 2020/24. ....	1
■ ... Lo Celso I. Respuesta productiva y económica del maíz a distintas dosis de fertilizante nitrogenado, en ambientes diferenciados en Villa del Totoral (Cba., campaña 23-24). ....	7
■ ... Carrillo WG. Variabilidad espacio-temporal como criterio de ambientación en campos de Entre Ríos. ....	15
■ ... Flesia M, Ferace E, Chiaraviglio D, Bodenbender G, Alberione L, Romano G, Panero S. Impacto del Cambio Climático en la Productividad Agrícola de la región centro de Argentina. ....	29
■ ... Flesia M, Ferace E, Chiaraviglio D, Alberione L, Romano G, Panero S. Simulación de productividad agrícola en la localidad de Chañaritos, Córdoba, Argentina bajo escenarios de variación climática utilizando modelos de machine learning avanzados. ....	37
■ ... Flesia M, Ferace E, Chiaraviglio D, Alberione L, Romano G, Panero S. Predicción de Productividad Agrícola en la Región Centro de Córdoba Utilizando Modelos de Machine Learning. ....	45
■ ... Domínguez M, Menes JF, Portillo JE, Lavandera J. Fenotipado con drones en girasol: implementación en resistencia a imidazolinonas. ....	53
■ ... Córdoba M, Paccioretti P, Balzarini M. Comparación de tratamientos en ensayos sin repeticiones cosechados con monitores de rendimiento. ....	61
■ ... Jimenez YA, Melhen R, Lobo Vallejo E. Mapas de compactación de suelo: herramientas para la optimización de recursos en agricultura sostenible. ....	69
■ ... Olivanti M, Gullino I, Bessone N. Evaluación de tecnologías en la calidad de siembra del cultivo de Maíz. ....	75
■ ... Guilino FD, Mur M, Merani VH, Larrieu L, Ferro DA, Vázquez JM, Cinquetti T, Donadelli MC, Pereira EI. CIR 1.5 vs ojo humano: evaluación de la capacidad de procesamiento. ....	85
■ ... Orona MC, Figueroa PA. Emergencia agropecuaria de precisión. ....	93
■ ... Ponieman KD, Bongiovanni R, Hilbert J, Battaglia M, Cipriotti PA, Espósito G. Evaluación del impacto del manejo sitio-específico del nitrógeno sobre la huella de carbono del bioetanol de maíz. ....	107
■ ... Platz P, Tourn S, Merani VH, Mur M, Larrieu L, Ferro, Vázquez JM, Guilino F, Cinquetti T. Drones pulverizadores: Calidad de aplicación con diferentes calibraciones y coadyuvantes. ....	117
■ ... Peirone, LS, Ovando G, Ogando FA, Pari E, Villafañe J, Raspa FA, Vega CRC. Empleo de índices de vegetación y térmico obtenidos mediante VANT para caracterizar la condición hídrica en maíz. ....	125

... Peirone L, Mazzalay A, Heinz N, Vega CR. Uso de índices de vegetación multiespectrales para el fenotipado de alto caudal en híbridos de girasol cultivado a campo. ....	135
... Pari E, Ogando FA, Villafañe MJ, Peirone LS, Raspa FA, Vega CRC. Uso de NDRE para evaluar efectos de fertilización nitrogenada durante la post-floración en maíz (Zea mays L.). ....	145
... Villafañe MJ, Ogando FA, Pari E, Peirone LS, Raspa FA, Alemanno S, Vega CRC. Estimación del contenido de clorofila “a”, carotenoides y peso de grano en maíz mediante NDRE. ....	151
... Figueroa PA. Formación superior en agricultura de precisión Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro ....	157
... Scaramuzza FM; Villarroel DD; Olivo SM. Calidad de siembra de maíz (Zea maíz L) y su efecto en el rendimiento, con y sin órgano afirmador de semillas. ....	165
... Rompani JM, Mercau JL y Pagani A. Modelo de fertilización nitrogenada en trigo diseñado para apoyar el manejo sitio-específico del cultivo en el centro oeste bonaerense ....	173
... Scaramuzza FM; Villarroel DD; Olivo SM; Lopez Seco E. Encuesta sobre siembra e implantación del cultivo de Alfalfa (Medicago Sativa, L) en Argentina. ....	183
... Grosso JA; Bongiorno C; Rodríguez M; Lázaro L; Ressia JM. Análisis de la calidad de zonificación realizada en un cultivo de maíz. ....	185

## Estimación de la evolución en la adopción de componentes de Agricultura de Precisión 2020/24.

**Fernando M Scaramuzza; Diego D Villarroel**

INTA EEA Manfredi, Ruta 9 Km 636, Manfredi, Córdoba, Argentina.

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** *El salto tecnológico ha sido significativo desde la última vez que se realizó el relevamiento de adopción de equipamientos de agricultura de precisión. Cada rubro ha mostrado un quiebre en la incorporación de nuevos desarrollos, siempre direccionados a facilitar la incorporación al paquete tecnológico que ya tiene la maquinaria apuntada a la eficiencia, el automatismo de procesos y a facilitar la interpretación de la información para lograr datos más certeros. El INTA viene abordando la temática de agricultura de precisión desde hace 29 años y a través de una encuesta dirigida a las principales empresas del sector realiza un análisis de la evolución en la adopción de la tecnología, la cual demuestra una alta correlación con la realidad del sector, ajustándose en gran medida a la tendencia observada. No obstante, es importante aclarar que los números son estimativos y los totales pueden tener una diferencia. De acuerdo a lo contabilizado en el análisis de los datos proporcionados por las diferentes empresas que colaboraron se pudo estimar el crecimiento sostenido. Definitivamente las tecnologías mayormente adoptadas tienen que ver con la guía automática de la maquinaria apuntando a una mayor eficiencia en las diferentes labores, también la incorporación de mayor cantidad de equipos de aplicación selectiva para el control de malezas, consolidándose no solo en el norte del país, sino también en la región pampeana. Pero también se observa un crecimiento sostenido en la incorporación de sistemas de dosificación variable, principalmente en sembradoras donde se vio un incremento en la implementación de motores eléctricos. Por último, destacar la tecnología transversal a todas las labores y equipos, como lo es la telemetría, la cual se ve reflejada en la cantidad de hectáreas relevadas a través de las diferentes plataformas.*

**Palabras clave.** *Tecnología, monitor de rendimiento, piloto automático, control selectivo, dosis variable.*

## Introducción

A pesar de haber transitado dos años complejos desde el punto de vista económico y financiero, pero también climático y productivo, afectando directamente en los potenciales de rendimiento de los principales cultivos, la incorporación de tecnologías de agricultura de precisión se mantuvo en crecimiento. Una de las características que destaca al empresario agropecuario argentino, productor, asesor, contratista, es su capacidad de resiliencia para afrontar las adversidades que le presenta el sistema y revertir en muchos casos la complejidad a través de la incorporación de nuevas tecnologías. Al menos, esa es una primera interpretación que se puede hacer respecto al contexto transitado en estos últimos años de análisis de datos y el crecimiento marcado en la adopción de equipos.

El salto tecnológico ha sido significativo desde la última vez que se realizó el relevamiento de adopción de equipamientos de agricultura de precisión. Cada rubro ha mostrado un quiebre en la incorporación de nuevos desarrollos, siempre direccionados a facilitar la incorporación del paquete tecnológico que ya tiene la maquinaria, apuntado a aumentar la eficiencia, automatizar procesos y facilitar la interpretación de la información para lograr datos y manejos más certeros.

Claramente se está atravesando un momento en el cual se observan alianzas estratégicas entre empresas, no solo internacionales, sino también nacionales e internacionales bajo un esquema expresado recurrentemente como Ecosistema Colaborativo. Vemos empresas multinacionales y nacionales trabajando en conjunto con el fin de simplificar la adopción de las nuevas tecnologías que vinculan a la maquinaria, las agtech y el manejo agronómico incorporando el concepto de agricultura digital.

El INTA, viene abordando la temática de agricultura de precisión desde hace 29 años y a través de una encuesta dirigida a las principales empresas del sector realiza un análisis de la evolución en la incorporación de tecnologías, la cual demuestra una alta correlación con la realidad del sector, ajustándose en gran medida a la tendencia observada. No obstante, es importante aclarar que los números totales pueden tener una diferencia.

## Materiales y Métodos

La metodología utilizada es a través de encuesta dirigida a cada empresa que esté vinculada a las tecnologías de agricultura de precisión. Toda la información proporcionada es confidencial de cada una y es conservada con total discreción. Los análisis realizados son por rubro y no por empresa, es decir que no se analiza quien se ha destacado o ha crecido en ventas en los últimos años, sino que se analiza la evolución de cada tecnología.

A su vez se incorporan al análisis, los datos de ventas de la maquinaria agrícola con el fin de ajustar e interpretar los resultados observados.

Los principales rubros analizados están relacionados a la tecnología que actualmente equipan a la maquinaria agrícola. Tanto Banderilleros Satelitales como Monitores de Siembra son herramientas que ya forman parte de la maquinaria, es decir que no son opcionales, incluso han ido mejorando en sus prestaciones y hoy se observan como monitores con múltiples funcionalidades, observándose equipos que se prestan como computadoras de aplicación, configuración de la

maquinaria y guía virtual.

Otros rubros evaluados son los  Sistemas de mapeo de rendimiento ,  Sistemas de dosificación variable ,  Guías o Pilotos Automáticos  y los  Sistemas de aplicación selectiva  para el control de malezas, temática que ha crecido significativamente en los últimos años.

## Resultados y Discusión

En el Gráfico 1 se puede ver la evolución de los principales rubros en número de unidades acumuladas, desde el año 1997 hasta 2023.

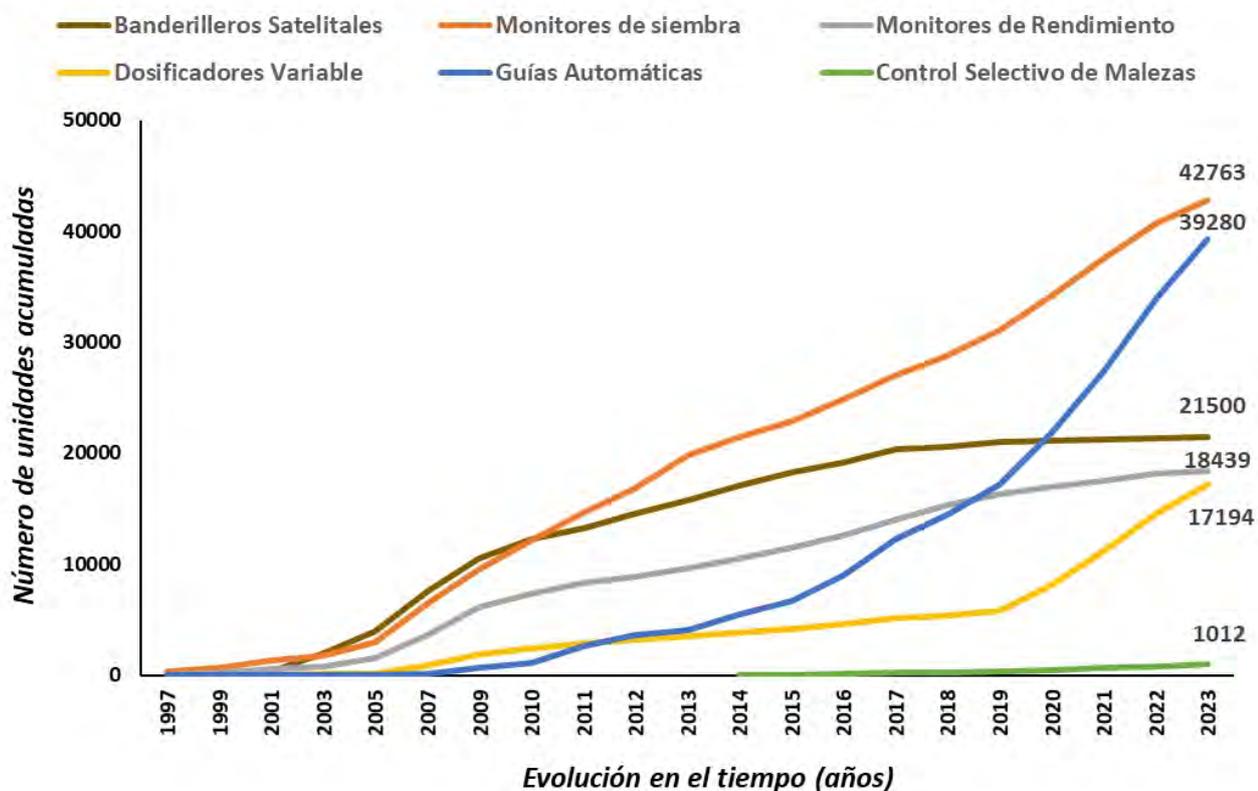


Gráfico 1: Estimación de la evolución de número de equipos, en unidades acumuladas en los diferentes rubros tecnológicos, para Argentina. Fuente: INTA Manfredi, 2024.

### Banderilleros satelitales y monitores de siembra.

Actualmente debemos mencionar que esta tecnología ya viene incorporada en la maquinaria que la utiliza, principalmente pulverizadoras y fertilizadoras autopropulsadas y de arrastre. A su vez, también es importante destacar que estos equipos ya se observan como parte de una computadora de aplicación, formando parte de un monitor con guía virtual y muchas veces también acompañando la función de la calidad de la dirección visualizada en pantalla de un piloto automático. Por lo tanto, hoy si mencionamos a un banderillero satelital, ya estamos haciendo referencia a un monitor multifunción para configurar y monitorear una pulverizadora o fertilizadora. Respecto al último dato contabilizado, se observa una estabilización en el crecimiento de esta tecnología, se observa solo un 2,3% de incremento respecto a lo observado en 2019.

Respecto a la interpretación de los datos de crecimiento en monitores de siembra, es similar a los

banderilleros satelitales, es una tecnología que se ofrece como parte de las configuraciones de sembradoras del mercado. Y de igual manera, actualmente un monitor de siembra, además de visualizar datos de la actividad que está realizando la sembradora, también puede formar parte de múltiples funciones, entre ellas, la posibilidad de brindar información sobre la dirección del piloto automático. Respecto a lo observado en 2019, se ve un crecimiento de un 39%. Incremento que está asociado a la incorporación de nuevas sembradoras o la restauración de las mismas con nuevos equipos de precisión para su monitoreo, estos valores contemplan más de 95% del parque total de sembradoras en nuestro país.

### Monitores de rendimiento.

En el rubro relacionado a sistema de mapeo de rendimiento, no solo se observa un crecimiento de la incorporación de nuevos monitores de generaciones o versiones más actualizadas, sino que también se aprecia la evolución respecto al sistema en su conjunto. Varias empresas ya incorporan sistemas de inteligencia artificial a través de cámaras de alta velocidad para regular la calidad y eficiencia de la trilla, sistemas de predicción del rendimiento por medio de imágenes satelitales y cámaras que hacen lectura de la biomasa por delante de la plataforma de cosecha. Pero también un set de balanzas incorporadas en la tolva de la cosechadora para mantener la calibración de los pesos de rendimiento a lo largo de la jornada de trabajo bajo el mínimo error ajustado. El crecimiento en este rubro de dio en un 14% respecto a lo observado en 2019.

### Sistemas de dosis variable.

Respecto a los sistemas de dosis variable, se pueden mencionar equipos de aplicación variable en pulverizadoras, fertilizadoras de sólidos, pero principalmente asociar el crecimiento a la incorporación de tecnologías en sembradoras. Los sistemas de accionamiento electromecánicos y electrohidráulicos son una tecnología probada y aceptada por el productor y/o contratista agropecuario, pero la posibilidad de incorporar motores eléctricos en la sembradora ha crecido significativamente en los últimos 5 años, comandando diferentes tipos de acciones sobre el implemento, la velocidad de la placa dosificadora, la variación de insumos o el corte cuerpo por cuerpo en sembradoras. Se observa una mayor implementación en el manejo variable de insumos, debido a la posibilidad simplificada que permite definir ambientes y/o prescripciones a través de diferentes plataformas web con imágenes gratuitas y de buena resolución como lo son las Sentinel. Los sistemas de dosis variable de insumos crecieron en un 273% respecto a lo contabilizado en 2019.

### Guía o Piloto automático

Sin duda este rubro se ha afianzado en su adopción e implementación en los últimos años respecto al resto de las herramientas de agricultura de precisión que equipan a la maquinaria agrícola, cerca de 128% más respecto a lo observado en 2019. Es una tecnología que ha crecido en pulverización, en siembra y también en cosecha. La posibilidad de tener una señal satelital con corrección diferencial más accesible que en sus comienzos hace que hoy sea fundamental para incorporar pilotos automáticos y otras tecnologías como cortes por sección o pico a pico en pulverización o también cortes cuerpo por cuerpo de siembra, logrando más eficiencia en las labores y mejoras en los tiempos operativos a campo. Por lo tanto, ahorro de insumos, eficiencia en el uso de combustible y extensión en horas de trabajo por jornada, sosteniendo la calidad de la labor a lo largo del día.

### Sistemas de aplicación selectiva

Con un 208% de incremento de incorporación de equipos en pulverizadoras, es una de las tecnologías que también ha crecido significativamente desde el 2020. En los primeros años fue una

herramienta que brindó una alternativa de manejo ante la presencia exponencial de malezas resistentes, pero también para trabajar en barbechos extensos y largos en regiones como en NOA y NEA, donde un cultivo de invierno o de servicio no son posibles debido a su restricción hídrica. Actualmente la ecuación de adopción ha cambiado y ya se observan muchos equipos en la región pampeana y también como una alternativa de implementación en zonas de restricción como son los periurbanos, debido a la eficiencia de las aplicaciones respecto al ahorro de fitosanitarios y el bajo impacto ambiental logrado.

## Telemetría

En este rubro es preciso destacar que es una tecnología que también ha crecido significativamente, hoy se cuenta con más de 12250 máquinas conectadas que relevan más de 18 millones de hectáreas, esto permite el seguimiento en tiempo real de todas las labores a campo, desde el momento de la siembra, la pulverización y la cosecha, logrando almacenar los datos en la nube de diferentes plataformas web que proponen espacios de trabajos colaborativos entre las diferentes empresas. Hoy se puede relevar y certificar una siembra, enviar una prescripción a distancia, como así también lograr la trazabilidad de un control fitosanitario realizado por una pulverizadora, pero el mayor valor lo encuentran las empresas, ya que permiten también lograr una asistencia en tiempo y forma a través del seguimiento de la maquinaria por parte de los diferentes centros de monitoreo en los concesionarios.

## Conclusión

De acuerdo a lo contabilizado en el análisis de los datos proporcionados por las diferentes empresas que colaboraron, se pudo estimar el crecimiento sostenido que siguen manifestando los diferentes rubros, logrando consolidarse las herramientas más tradicionales, mostrando también algunas mejoras en sus prestaciones. Definitivamente las tecnologías mayormente adoptadas tienen que ver con la guía automática de la maquinaria apuntando a una mayor eficiencia en las diferentes labores, también a la incorporación de mayor cantidad de equipos de aplicación selectiva para el control de malezas, consolidándose no solo en el norte del país, sino también en la región pampeana. Pero también se observa un crecimiento sostenido en la incorporación de sistemas de dosificación variable, principalmente en sembradoras donde se vio un incremento en la implementación de motores eléctricos. Por último, destacar la tecnología transversal a todas las labores y equipos, como lo es la telemetría, la cual se ve reflejada en la cantidad de hectáreas relevadas a través de las diferentes plataformas.

## Referencias

- Asociación de Fabricantes de Maquinaria Agrícola y Agrocomponentes de Córdoba. AFAMAC 2024. <https://afamac.com.ar/catalogo/> . Consultado 13/07/2024
- Cámara Argentina Fabricantes de Maquinaria Agrícola. CAFMA 2024. <https://cafma.org.ar/> . Consultado 13/07/2024
- Instituto Nacional de Estadísticas y Censos de la República Argentina. 2024. Censo Nacional Agropecuario 2018. <https://www.indec.gob.ar/indec/web/Nivel3-Tema-3-8> . Consultado 13/07/2024
- Villarroel, D.; Scaramuzza, F.; Melchiori, R. 2022. Estimación de la evolución en la adopción de componentes de Agricultura de Precisión de cara al inicio de una década de Agricultura digitalizada. Repositorio INTA Digital. [https://repositorio.inta.gob.ar/bitstream/handle/20.500.12123/9513/INTA\\_CRCordoba\\_EEAManfredi\\_Villarroel\\_D\\_estimacion\\_evolucion\\_adopcion\\_componentes\\_agricultura\\_precision.pdf?sequence=1&isAllowed=y](https://repositorio.inta.gob.ar/bitstream/handle/20.500.12123/9513/INTA_CRCordoba_EEAManfredi_Villarroel_D_estimacion_evolucion_adopcion_componentes_agricultura_precision.pdf?sequence=1&isAllowed=y) . Consultado 13/07/2024.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Respuesta productiva y económica del maíz a distintas dosis de fertilizante nitrogenado, en ambientes diferenciados en Villa del Totoral (Cba., campaña 23-24)

**Ing. Agr. (MBA) Ignacio Lo Celso**

Gerente de Producción. San Juan de Totoral SA y Nuevo Centenario SA, Villa del Totoral, Córdoba.  
Docente de Postgrado. Universidad Católica de Córdoba. Córdoba. Argentina.  
ignacio.locelso@gmail.com.ar

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

### **Resumen.**

La agricultura de precisión presenta nuevos desafíos e interrogantes. Para procurar responder a algunos de esos interrogantes, en nuestra zona de influencia, realizamos un ensayo de dosis fijas (0, 100, 200, 300 y 400 l ha<sup>-1</sup>), de fertilizante nitrogenado (Solmix 28%), en ambientes diferenciados como alta y baja productividad. Los ambientes fueron diferenciados por calidad de suelo: el ambiente de bajo potencial de rendimiento es atravesado por un paleocauce, con presencia de CaCO<sub>3</sub> y, además, es un suelo más pobre en materia orgánica y fósforo. El fertilizante fue chorreado en V11-12 y se incorporó a la solución de suelo 25 días después de la labor (R1). Para aislar el efecto suelo, se calculó un índice ambiental para cada franja que fue utilizado para ajustar la respuesta de las mismas a las distintas dosis de fertilizante. A partir de ello, se calcularon la rentabilidad de las distintas dosis, para cada ambiente. El resultado fue que el ambiente de alto potencial respondió productiva y rentablemente a las primeras dos dosis (100 y 200) pero luego encontró otro "techo" para seguir respondiendo: el agua. El ambiente de bajo potencial, si bien obtuvo respuestas productivas positivas a la fertilización, las mismas no fueron rentables en ningún caso. También pudo verificarse la importancia de contar con más de una capa de información (particularmente precipitaciones promedio, según fase ENSO) y discernir si los ambientes de menor potencial son corregibles con manejo o no, porque de eso depende el nivel de respuesta potencial a la fertilización.

### **Palabras clave.**

Gestión de la variabilidad; manejo variable; rentabilidad de la fertilización

## Introducción

La adopción cada vez mayor de sensores remotos, plataformas digitales, softwares específicos y de equipamientos con posibilidad de realizar dosis variable, nos ha permitido pasar de considerar a la agricultura de precisión como un enunciado teórico a ser una realidad cada vez más movilizadora entre asesores, productores e investigadores (Villarroel et al. 2020, Lachman et al. 2022).

A su vez, la agricultura de precisión presenta nuevos desafíos e interrogantes concretos: ¿cómo gestionamos la variabilidad de nuestros lotes en, por ejemplo, el cultivo de maíz? ¿cómo asignamos los recursos limitados de manera eficiente? ¿todos los años tenemos respuestas productivas en todos los ambientes? ¿esas respuestas son rentables? Para procurar responder a algunos de esos interrogantes en nuestra zona de influencia, se planteó como objetivo cuantificar la respuesta productiva y económica del maíz a distintas dosis de un fertilizante nitrogenado, en ambientes con distintos potenciales de rendimiento en Villa del Totoral, provincia de Córdoba.

## Material y método

### Caracterización de los sitios de ensayo

Los ensayos se realizaron en la Estancia San Juan ubicada a unos 7 km hacia el NE de Villa del Totoral. El promedio anual de precipitaciones histórico de dicho establecimiento es de 750 mm. Sin embargo, si consideramos sólo los años agrícolas (alrededor del año 2000, se intensifica el pasaje de ganadería a siembra directa), ese promedio se reduce hasta los 636 mm. En dichos años, el registro promedio entre los meses de noviembre a marzo (período en el cual se desarrollan gran parte del ciclo de cultivos estivales) es de 498 mm (Tabla 1). La presente campaña agrícola, según el fenómeno ENSO, fue el primer evento □El Niño□, después de tres □La Niña□ consecutivas. Por esta razón, nos resultó imposible medir (con barreno hidráulico) el nivel de recarga de humedad en el perfil, por lo que lo asumimos en cero.

**Tabla 1. Registro de precipitaciones en años agrícolas y según fase ENSO (El Niño, Oscilación del Sur).**

ENSO	Anual (mm)	DE	CV	Noviembre □ Marzo (mm)	DE	CV
Niño	730	200,0	27%	572	152,1	27%
Neutro	688	156,8	23%	506	129,2	26%
Niña	522	91,3	17%	434	89,6	21%

Los suelos de los sitios de ensayo son Argiustoles típicos de textura franco limosa (Series Barranca Yaco y Las Mercedes) y poseen una capacidad de uso IIIc (IDECOR, 2024). En ellos, se seleccionaron dos ambientes: a) Ambiente de Bajo Potencial de rendimiento (ABP): definido por un paleo cauce, con mayor incidencia de  $\text{CaCO}_3$  y b) Ambiente de Alto Potencial de rendimiento (AAP) sin limitaciones más que las descriptas en la clasificación de suelo (climática).

Históricamente, el ABP de rendimiento tiene una respuesta productiva entre 20 al 40% menor respecto al AAP de rendimiento (según análisis interanual de mapas de rendimiento). En relación a esto, es necesario destacar que es de suma importancia determinar cuál es la razón que define al ambiente de Bajo Potencial, ya que si tiene un origen genético de difícil o imposible corrección (por ejemplo, paleo cauce arenoso, limitado desarrollo del perfil, presencia de carbonatos de calcio, etc.), su respuesta siempre estará limitada por esa dificultad de origen y siempre será inferior a la del Alto Potencial (Lo Celso, 2020). Ahora bien, si el origen de la limitante es exógena o no genética (por ejemplo, que se haya quemado la cobertura y la materia orgánica (MO) del suelo por un incendio, o presencia de

distintas recargas de perfiles por distinto manejo de la rotación, insuficiencia de fósforo, etc.), el ambiente de Bajo Potencial es circunstancial y puede y debe ser corregido con manejo (Lo Celso, 2023).

En relación a la caracterización nutricional natural de cada ambiente, podemos decir que el AAP, no tenía limitante en cuanto a disponibilidad de fósforo (P) y una muy buena provisión natural de nitrógeno (N), si consideramos una mineralización del 3% (262 kg de N) (Tabla 2). En el caso del ABP, la oferta inicial de P era muy pobre (5 ppm) y una provisión natural más limitada de N, si tomamos en cuenta los NO<sub>3</sub> y la mineralización potencial (120 kg de N). Ante estos resultados, en el ABP, se decidió volcar 160 kg de superfosfato triple (SPT) el 22/08/23, lo que equivaldría a un agregado de 73,6 kg de P<sub>2</sub>O<sub>5</sub>. Si la eficiencia fuera perfecta, esa dosis nos habría permitido elevar en 11,1 ppm los niveles de P en la solución del suelo. Las precipitaciones importantes, ocurrieron a partir de mediados de octubre, unos 45 días antes de la siembra, lo que debió facilitar la incorporación y disponibilidad del nutriente para el cultivo. García et al. (2009) refieren que esta técnica tiene resultados similares a la fertilización en la línea si se hace, entre otras razones, en dosis mayores a 100-125 kg de SPT y con suficiente tiempo de antelación a la siembra, lo que resulta en una ventaja operativa importante en una zona donde la ventana de siembra es acotada y las lluvias son erráticas.

**Tabla 2. Datos analíticos de 0-20 cm de profundidad de los sitios de ensayos.**

Propiedades	Sitios de ensayo	
	Alto Potencial	Bajo Potencial
Profundidad (cm)	0-20	0-20
Materia orgánica (%)	5	2,6
Carbono (%)	2,9	1,55
Nitrógeno Orgánico (%)	0,29	0,11
Fósforo (ppm)	55	5
Nitratos (ppm)	15,24	14,35
Nitratos (kg Ha <sup>-1</sup> )	9,0	8,4
N Min (3%) (kg Ha <sup>-1</sup> )	226,2	85,8
N Tot (kg Ha <sup>-1</sup> )	235,2	94,2

## Prescripción de siembra

La siembra se realizó el 02/12/2023, con tecnología Precision Planting. Se utilizaron dos densidades de siembra: 55.000 semillas ha<sup>-1</sup> en el sitio de Bajo Potencial de rendimiento y 70.000 semillas ha<sup>-1</sup> en el sitio de Alto Potencial de rendimiento (Figura 1). El material utilizado fue Pioneer 2021 PWUE.



Figura 1. Prescripción de siembra variable para los dos sitios de ensayo: 1, ABP de rendimiento y 2, AAP de rendimiento.

## Supuestos económicos

En la Tabla 3 se detallan los supuestos sobre los que se ancló el análisis económico para un rendimiento real de 7.602 Kg ha<sup>-1</sup> y un rendimiento del monitor de 7.293 Kg ha<sup>-1</sup> con un ajuste de 1.04.

Tabla 3. Supuestos para el análisis económico

Supuestos	Campañas	
	23-24	22-23
Precio Maíz (USD Tn <sup>-1</sup> )	181	199
Gastos Comerciales (USD Tn <sup>-1</sup> )	39.81	
Precio Neto (USD Tn <sup>-1</sup> )	141,19	
Precio Fertilizante (USD/kg)	0,75	0,69
% N	0,28	
Costo Labor (USD ha <sup>-1</sup> )	13	
Precipitaciones (noviembre-marzo)	539	

## Aplicación del fertilizante nitrogenado

Se diseñaron 5 franjas de 32 m (ancho del botalón del pulverizador), a lo largo de todo el lote, que atravesaran ambos ambientes. Los tratamientos fueron: testigo (0 l ha<sup>-1</sup>), 100, 200, 300 y 400 l ha<sup>-1</sup> de Solmix (28% N). El método de fertilización fue chorreado, con pulverizador autopropulsado y se realizó el 13/01/24 (V11-V12). No pudo chorrearse antes por falta de piso para realizar la labor. El fertilizante se incorporó a la solución del suelo recién el 08/02/24, con una lluvia (25 días después de la aplicación) estando el cultivo en R1, es decir, con toda la arquitectura foliar desplegada (Andrade, 2023). Además, entre la aplicación y la incorporación, hubo 15 días con temperaturas superiores a los 32 °C (Figura 2)

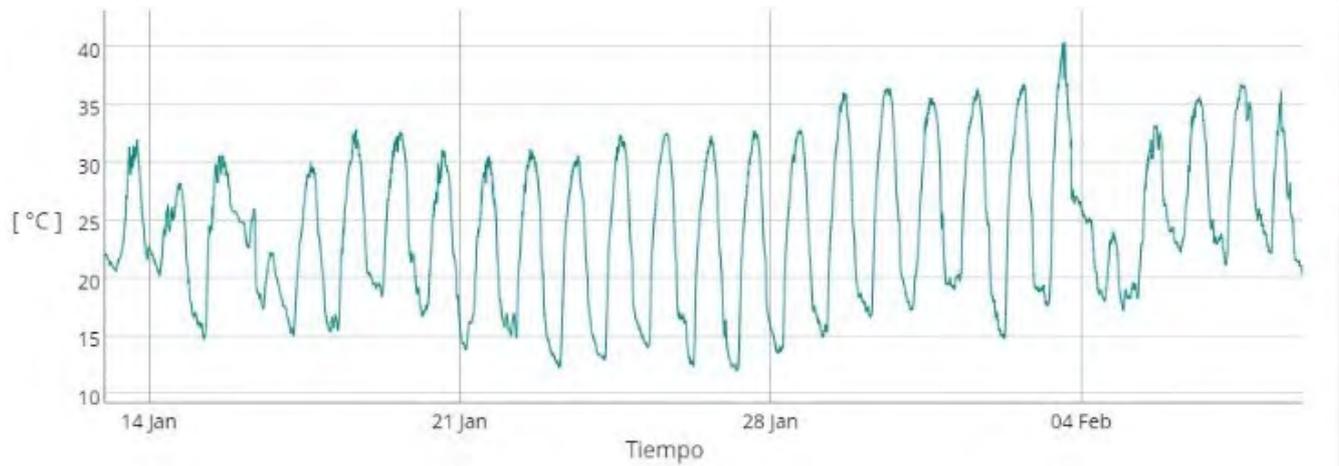


Figura 2. Temperaturas entre 13/01/24 al 08/02/24 en Villa del Totoral (Bolsa y Cámara de Cereales de Córdoba, 2024)

### Ajuste de los rendimientos. Índice Ambiental

Con los datos registrados en el monitor de rendimiento AFS 700 Pro (CNH), se obtuvieron los resultados de cada franja, en cada ambiente. Dentro de cada franja, se seleccionaron áreas (de alrededor de 1 ha de superficie) de lote que se ubicaran exactamente dentro de cada franja y de cada ambiente, para su posterior análisis. Los mapas fueron procesados con la plataforma Agrian de TELUS Agriculture (Nutrien Ag Solutions) (Figura 3). Esos datos, posteriormente fueron ajustados por el rendimiento final real del lote.

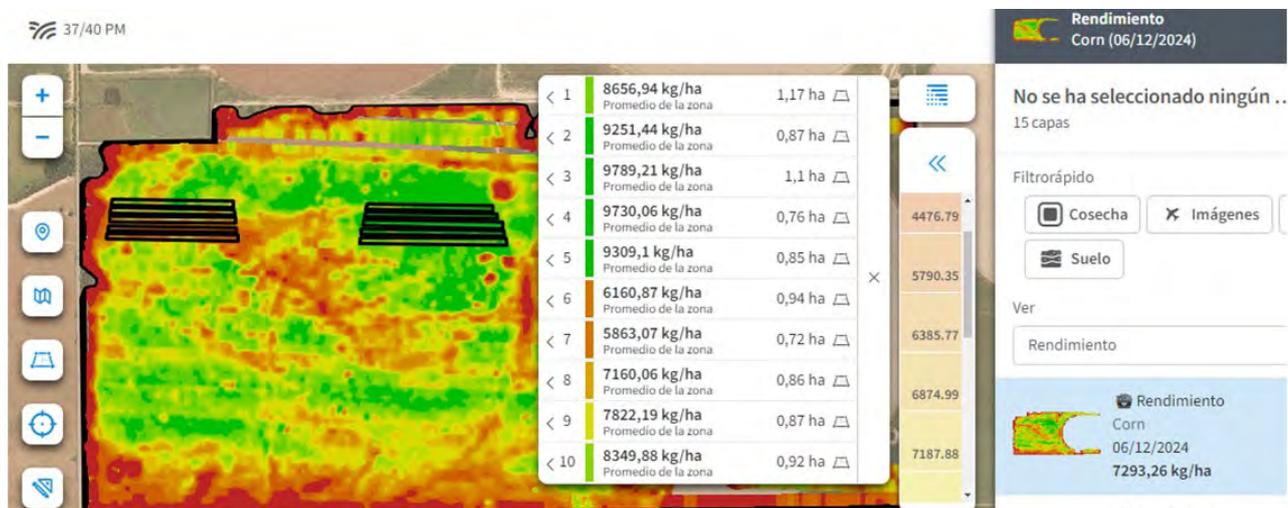


Figura 3. Rendimientos obtenidos para cada tratamiento, en cada ambiente.

A su vez, para aislar el efecto de la variabilidad de suelo entre cada tratamiento, según ambiente, se calculó un Índice Ambiental. Para ello, se tomaron los rendimientos de cada franja tratamiento y se lo comparó con el promedio del rendimiento de las cinco franjas, para cada campaña. Al relacionar el rendimiento de una franja, en una determinada campaña, con el promedio de las cinco franjas, para la misma campaña, se obtuvo el Índice Ambiental de la franja en dicha campaña. Luego, se promedió los índices ambientales, de todas las campañas, para cada franja (seis campañas en total) y se obtuvo el Índice Ambiental Promedio de cada franja tratamiento.

Con el que Índice Ambiental Promedio, se corrigieron los datos del rendimiento real. A partir de allí,

se calcularon los siguientes parámetros: Eficiencia de Uso de Agua (EUA, relacionando los rendimientos con las precipitaciones obtenidas en el período noviembre-marzo); Requerimientos Agronómicos de Fertilización (RAF) (relacionando kg de N fertilizados por tn de grano de maíz obtenida); Costo del Tratamiento (CT) (labor de fertilización + costo de dosis de fertilizante); Resultado Económico Bruto (REB) (USD netos obtenidos por cada dosis de fertilización); Resultado Económico Neto (REN) (REB - CT); y Rentabilidad (R) (REN / CT).

## Resultados y discusión

Con los datos provistos por los análisis de suelo y los rendimientos de los testigos, se calculó la mineralización real de la materia orgánica para cada sitio de ensayo (Tabla 4).

**Tabla 4. Cálculo de mineralización real de la materia orgánica por sitio de ensayo. AAP: Ambiente de alto potencial de rendimiento., ABP: Ambiente de bajo potencial de rendimiento, N: nitrógeno**

Propiedades	AAP	ABP
Rendimiento Testigo (kg Ha <sup>-1</sup> )	8520	7034
Requerimiento N (kg Ha <sup>-1</sup> ) (García, 2016)	187,4	154,8
Nitrógeno de NO <sub>3</sub> (kg Ha <sup>-1</sup> ) (Bono, 2021)	21,1	19,8
Nitrógeno Mineralizado (kg Ha <sup>-1</sup> )	166,4	134,9
Nitrógeno Orgánico (%)	0,3	0,1
Mineralización (%)	2,2	4,2

Como se observa en la Tabla 4, se produjeron distintos niveles de mineralización de la materia orgánica para cada sitio de ensayo (4.2%, en el ABP y 2.2% en el AAP). A su vez, estos fueron diferentes al presupuestado (3%).

En el sitio de ensayo del AAP, en general, hubo respuesta productiva al agregado de fertilizante. En relación a la respuesta económica, los primeros dos tratamientos (100 y 200) fueron rentables, pero las dosis mayores (300 y 400), ya no (Tabla 5). Si lo relacionamos con la EUA para los meses de noviembre-marzo, podemos inferir que estas últimas ya no obtuvieron respuestas porque se encontró con otra limitante que ya no era el nitrógeno sino posiblemente el agua.

**Tabla 5. Respuestas productivas y económicas a la fertilización en el ambiente de alto potencial de rendimiento (AAP).**

Variables	Tratamientos				
	0	100	200	300	400
Rend. Monitor (kg ha <sup>-1</sup> )	8557	9251	9789	9730	9309
Rendimiento Real (kg ha <sup>-1</sup> )	9024	9643	10204	10142	9703
Índice Ambiental Promedio (IAP)	1,06	0,99	1	1,01	0,94
Rendimiento ajustado por IAP	8520	9698	10242	10040	10322
EUA (kg mm <sup>-1</sup> )	15,81	17,99	19	18,63	19,15
Dosis N (kg Ha <sup>-1</sup> )	0	37	74	111	148
Req. Agron. Fert. (kg N Kg Mz <sup>-1</sup> )	0	31,4	42,9	72,9	82
Costo Tratamiento (USD ha <sup>-1</sup> )	0	112	211	310	409
Resultado Económico Neto (USD ha <sup>-1</sup> )	0	166,3	243,2	214,6	254,5
Resultado Económico Bruto (USD ha <sup>-1</sup> )	0	54,3	32,2	-95,4	-154,5
Rentabilidad (%)	0%	48%	15%	-31%	-38%

En el sitio de ensayo de Bajo Potencial, hay respuestas productivas positivas a la fertilización, pero no rentables (Tabla 6). Es decir, en un ambiente limitado por □genética y/o calidad nutricional de suelo, cuesta mucho más mejorar el rendimiento con fertilizante nitrogenado. Estos mismos resultados se obtuvieron en un ensayo, en el mismo lote, en la campaña 19-20 (Lo Celso, 2020). A esto, hay que sumarle que el cultivo, cuando recibió el □alimento□ (en R1), tenía una □maquinaria□ muy limitada para transformarla en grano: esto se observó en las recorridas a campo (plantas más chicas, hojas más pequeñas, etc.) y eso, teniendo en cuenta que cada planta gozó de mayores recursos ambientales

(radiación y precipitaciones) respecto al AAP, por una menor densidad de siembra en la prescripción (55.000 vs 70.000) (Figura 1). El sitio de ensayo del ABP, aún a las mayores dosis de fertilizante, no alcanza el rendimiento del tratamiento testigo del AAP. Por otra parte, la mejor EUA del ABP, es inferior al tratamiento testigo del AAP (Figura 4).

**Tabla 6. Respuestas productivas y económicas a la fertilización en el ambiente de bajo potencial de rendimiento (ABP).**

Variables	Tratamientos				
	0	100	200	300	400
Rend. Monitor (kg ha <sup>-1</sup> )	6161	5863	7170	7822	8350
Rend. Real (kg ha <sup>-1</sup> )	6422	6111	7474	8153	8704
Ind. Amb. Prom. (IAP)	0,91	0,9	1	1.1	1.09
Rendimiento ajustado por IAP (kg ha <sup>-1</sup> )	7034	6783	7486	7445	7967
EUA (kg mm <sup>-1</sup> )	13,05	12,58	13,89	13,83	14,78
Dosis N (kg ha <sup>-1</sup> )	0	37	74	111	148
Req. Agron. Fert. (kg N Kg Mz <sup>-1</sup> )	0	-147,2	163,3	269,5	158,4
Costo Tratam. (USD ha <sup>-1</sup> )	0	112	211	310	409
Resultado. Económico Neto (USD ha <sup>-1</sup> )	0	-35,3	63,9	58,1	131,8
Resultado. Económico Bruto (USD ha <sup>-1</sup> )	0	-147,5	-147,1	-251,9	-277,2
Rentabilidad (%)	0%	-132%	-70%	-81%	-68%

Es interesante destacar que hubo respuesta de los tratamientos teniendo en cuenta las demoras en la realización de la labor, las condiciones ambientales que sufrió el fertilizante antes de incorporarse a la solución del suelo y el momento en que esto último sucedió. Sin embargo, en contraposición con lo que menciona García et al. (2016), estos hechos indeseados generaron requerimientos demasiados altos e ineficientes de N, con su correlato de rentabilidades bajas y/o negativas.

Por último, cabe agregar el ruido no menor del efecto "chicharrita" (*Dalbulus maidis*), que ocasionó una menor expresión general del cultivo respecto a la oferta ambiental de la campaña, pero especialmente en las zonas o ambientes más restringidos.

## Conclusiones

En el AAP obtuvimos respuestas productivas y rentables a las primeras dos dosis de fertilizante (100 y 200 l Ha<sup>-1</sup>), pero luego este ambiente se encontró con la falta de agua para seguir respondiendo al N. No fue así en el ABP: allí, en general, obtuvimos respuestas productivas, pero no rentables. Esto pudo deberse a distintas causas propias de ese ambiente, por ejemplo, proximidad de CaCO<sub>3</sub> a las raíces, una inadecuada incorporación del P en la solución del suelo (con la consiguiente limitante de crecimiento del cultivo para expresar una mejor respuesta al agregado de N). A su vez, tanto la fertilización, como la incorporación del N a la solución del suelo, fueron de manera tardía, lo que afectó la producción del cultivo con su correlato de rentabilidades bajas y/o negativas. Por último, hubo un empeoramiento de la relación insumo / producto, respecto de la campaña anterior.

Por otro lado, creemos importante remarcar que es necesario discernir si la diferenciación de ambientes es circunstancial o definitiva porque, como hemos visto, eso puede anticiparnos potenciales respuestas. También consideramos valioso, en nuestra zona, tener en cuenta con qué niveles de recarga de perfil vamos a enfrentar la próxima campaña y que fase ENSO tendremos. Ambas fuentes de información nos van a facilitar ajustar mejor la fertilización nitrogenada.

El presente ensayo nos ha permitido reconocer que las decisiones de manejo que tomamos en materia de fertilización pueden no ser productivas y/o rentables, en cada ambiente y/o en las diferentes

campañas agrícolas. Contar con la mayor cantidad de capas de información (mapas de rendimientos, análisis de suelo georreferenciados, registros de precipitaciones históricos, imágenes satelitales, etc.) nos permite tomar decisiones más inteligentes y eficientes, ajustadas a la oferta ambiental que puede ofrecernos cada ambiente del lote y en cada año.

En un escenario de alta presión impositiva y de márgenes ajustados, la agricultura de precisión deja de ser un tópico del marketing a ser una necesidad concreta e imperiosa. Pero esta nos abre un abanico casi infinito de posibilidades de manejo y de decisiones a tomar, lo que hace necesario que los técnicos nos tomemos el trabajo de probar y medir para aprender y ajustar y volver a probar, porque como dice la frase (que se le suele atribuir a Peter Drucker, parafraseando a William Thomson) □ lo que no se puede medir, no se puede controlar. Lo que no se puede controlar, no se puede gestionar. Lo que no se puede gestionar, no se puede mejorar □

## Agradecimientos

A los socios (familia Bottaro) de las empresas para las que trabajo, por apoyar siempre la innovación y la adopción de tecnología. Al Ing. Agr. Diego Picos, Ing. Agr. Joaquín Benedetti, Luis y Hugo Heredia, por la colaboración en la confección del ensayo y en la cosecha de los datos. Un agradecimiento muy especial al Dr. Antonio Aoki por su revisión, valiosos aportes y sugerencias al presente trabajo.

## Referencias

- Andrade, F. H. et al. Ecofisiología y manejo del cultivo de maíz (Capítulo 3, página 77). Balcarce. MAIZAR.
- Bolsa de Cereales de Córdoba (2024) Redes de estaciones meteorológicas. Omixom. <https://clima.bccba.org.ar/accounts/login/?next=>
- Bono, A., Alvarez, R. (2021). Estimación de nitratos en profundidad en suelos de la región semiárida y subhúmeda pampeana. <https://fertilizar.org.ar/wp-content/uploads/2021/10/Bono.pdf>
- Cartas de suelo (2024). <https://mapascordoba.gob.ar/viewer/mapa/334%20>. IDECOR.
- García, F. O., Ciampitti, I. A. y otros (2009). La Fertilización Fosfatada en la Argentina: Actualidad, Manejo y Perspectivas. <http://www.creaoeste.org.ar/wp-content/uploads/2015/02/Garcia-Ciampitti-Rubio-Picone-Fosforo-2009.pdf>
- García, F. y Correndo, A. (2016). Cálculo de requerimientos nutricionales. International Plant Nutrition Institute. <http://lacs.ipni.net/article/LACS-1024>
- Lachman, J., Gómez-Roca, S. y López, A. (2022). Adopción de tecnologías de agricultura de precisión en los grupos CREA. Serie Documentos de Trabajo del IIEP, 79, 1-43. <https://ojs.econ.uba.ar/index.php/DT-IIEP/issue/view/427>
- Lo Celso, I. (2020). Apuntes sobre zonas de manejo variable y gestión de la variabilidad. [https://www.linkedin.com/posts/ignacio-lo-celso-6b01867b\\_zonas-de-manejo-diferenciado-y-gesti%C3%B3n-de-activity-6839552285601783808-6AXM?utm\\_source=share&utm\\_medium=member\\_desktop](https://www.linkedin.com/posts/ignacio-lo-celso-6b01867b_zonas-de-manejo-diferenciado-y-gesti%C3%B3n-de-activity-6839552285601783808-6AXM?utm_source=share&utm_medium=member_desktop)
- Lo Celso, I. (2023). [https://www.linkedin.com/posts/ignacio-lo-celso-6b01867b\\_precisionfarming-agriculturadeprecision-activity-7092951562368483328-sxyt?utm\\_source=share&utm\\_medium=member\\_desktop](https://www.linkedin.com/posts/ignacio-lo-celso-6b01867b_precisionfarming-agriculturadeprecision-activity-7092951562368483328-sxyt?utm_source=share&utm_medium=member_desktop)
- Villarroel, D., Scaramuzza, F., Melchiori, R. (2020) Estimación de la evolución en la adopción de componentes de Agricultura de Precisión de cara al inicio de una década de Agricultura digitalizada. INTA. [https://repositorio.inta.gob.ar/xmlui/bitstream/handle/20.500.12123/9513/INTA\\_CRCordoba\\_EEAManfredi\\_Villarroel\\_D\\_estimacion\\_evolucion\\_adopcion\\_componentes\\_agricultura\\_precision.pdf?sequence=1&isAllowed=y](https://repositorio.inta.gob.ar/xmlui/bitstream/handle/20.500.12123/9513/INTA_CRCordoba_EEAManfredi_Villarroel_D_estimacion_evolucion_adopcion_componentes_agricultura_precision.pdf?sequence=1&isAllowed=y)

## Variabilidad espacio-temporal como criterio de ambientación en campos de Entre Ríos.

**"Ing. Agr. Carrillo Wilson G."**

"Crespo, Entre Ríos, Argentina"

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

### Resumen.

*En el presente trabajo se analiza un gran número de mapas de rendimiento de 9 cultivos, en campos de Entre Ríos. En los cuales se observa que cada cultivo tiene una distribución de frecuencias distintas y por lo cual cada rotación de cultivos va tener magnitudes de variación distintas.*

*La obtención de mapas de rendimiento siempre fue un inconveniente y actualmente se están utilizando imágenes satelitales obtenidas de diferentes plataformas. Por lo cual, se comparan 3 metodologías de zonificación de campos de acuerdo a su productividad, una de estas utiliza como input mapas de rendimiento y otras dos con índices vegetales (IV). Para probar la asociación entre rendimiento e IV, se realizaron regresiones básicas y espaciales, en la cual, esta última fue elevada y no hubo diferencias entre los distintos IV. Las zonas definidas son bajo potencial estable, alto potencial estable y los ambientes inestables; donde la ambientación con GCI ordeno de manera correcta los rendimientos en cada ambiente con un índice de Kappa de Fleiss de 0,28.*

### Palabras clave.

*Agricultura de precisión, mapas de rendimiento, imágenes satelitales, índices de vegetación, ambientes, Entre Ríos.*

## Introducción

Las zonas de manejo (ZM) se definen como subregiones dentro de los campos donde se expresa una combinación homogénea de factores determinantes del rendimiento y para las cuales es apropiada una determinada combinación de insumos (Doerge, 1999). En Argentina generalmente la subdivisión de los lotes en ZM, se realiza teniendo en cuenta la variabilidad espacial pero no la temporal, la cual suele ser muy importante. Realizando una ambientación espacio-temporal, se obtienen tres ZM, bajo potencial estable, alto potencial estable y la zona inestable. Dicha forma de zonificar disminuye la incertidumbre a la hora de la toma de decisiones de aplicación variable de insumos a la superficie del campo ocupada por la zona inestable, ya que las zonas estables dependen menos de las condiciones climáticas del año. Este abordaje de la agricultura de precisión (AP) tiene sus primeros comienzos con el cambio de milenio, en diferentes puntos del mundo como Australia (Whelan, McBratney, 2000) y Reino Unido (Blackmore, 2000), mientras que en Estados Unidos en la última década numerosos trabajos están siendo publicados. Basso B. (2018) zonifica 30 millones de hectáreas de maíz de acuerdo a su estabilidad espacio-temporal utilizando imágenes de índice de vegetación diferencial normalizada (NDVI), donde determina eficiencias de uso de nitrógeno y las pérdidas de dicho nutriente para cada ambiente. Maestrini B y Basso B., (2021) utilizan mapas de rendimiento sobre 768 campos (23,400 has) para la ambientación a través de dos algoritmos, donde indican que el rendimiento de los cultivos tiene una distribución asimétrica negativa y además que en los rendimientos bajos se tienen los mayores desvíos estándar. Guan S. y Basso B. (2022) proponen un método para pronosticar el rendimiento de cultivos combinando índices de vegetación de clorofila verde (GCVI) y un índice de sequía del modelo SALUS de cultivo. En Argentina, Melchiori R. y Albarenque S. (2016) evaluaron los márgenes brutos de los cultivos de soja y maíz en cada ambiente de los lotes, donde el criterio utilizado fue el cuartil (percentil 75) superior de frecuencias del coeficiente de variación (CV).

A pesar de que la mayoría de las cosechadoras tienen mapeador de rendimiento y su implementación en el país es de más de 20 años, por distintos motivos, es muy difícil contar con estos. Este tipo de tecnología actualmente está compitiendo con las imágenes satelitales, que son de fácil obtención, en plataformas muy ágiles, ya procesadas y con buena resolución espacio-temporal. En Argentina una gran proporción del área agrícola es arrendada, con alta rotación de arrendadores, lo cual hace difícil que el productor cuente con largo historial de información de mapas de rendimiento.

## Objetivos

### Objetivo General

Delimitar ambientes según la variabilidad espacio-temporal de los campos utilizando índices vegetación derivados de imágenes satelitales, con la finalidad de disminuir la incertidumbre a la hora de aplicar insumos.

### Objetivos específicos

- Calcular estadísticos descriptivos del rendimiento de cultivos en lotes de producción de la provincia de Entre Ríos.
- Analizar la correlación espacial entre Índices de vegetación y el rendimiento de los cultivos obtenidos mediante mapas de rendimiento.

Comparar metodologías para la ambientación espacio-temporal realizadas a partir de mapas de rendimientos con aquellas que utilizan índices vegetales.

## Materiales y métodos

En este estudio se colectaron 201 mapas de rendimiento de 50 campos de Entre Ríos, ubicados en los departamentos de Tala, Victoria, Nogoya y Diamante (Figura 1). La superficie total es de 6585 has, con una media de 131,7 has, una superficie mínima de 22 has y una máxima de 458 has. Se tomó como condición necesaria que tenga 3 o más mapas de rendimiento, sin problemas evidentes en el cultivo (helada, granizo o resiembra). Cada mapa de rendimiento fue sometido a una depuración de datos siguiendo la metodología recomendada por la Universidad de Córdoba (Mariano A. Cordoba et. al. 2015), en este protocolo se re proyecta a coordenadas planares (EPSG 32721) cada mapa de rendimiento generado por la maquina cosechadora y luego se remueven los datos erróneos que se generan en el proceso de colecta de dicha información. Los outliers (3 desvíos estándar) son los primeros datos en excluirse y luego los inliers (distancia = 35 m). Finalmente se realizó una interpolación por kriging, ajustando la mejor función a los datos (se prueban 6 funciones: gausseana, esférica, exponencial, lineal, Matern y parametrización de Matern Stein), con una distancia de 40 m, dando como resultado un raster de 5 m x 5 m.

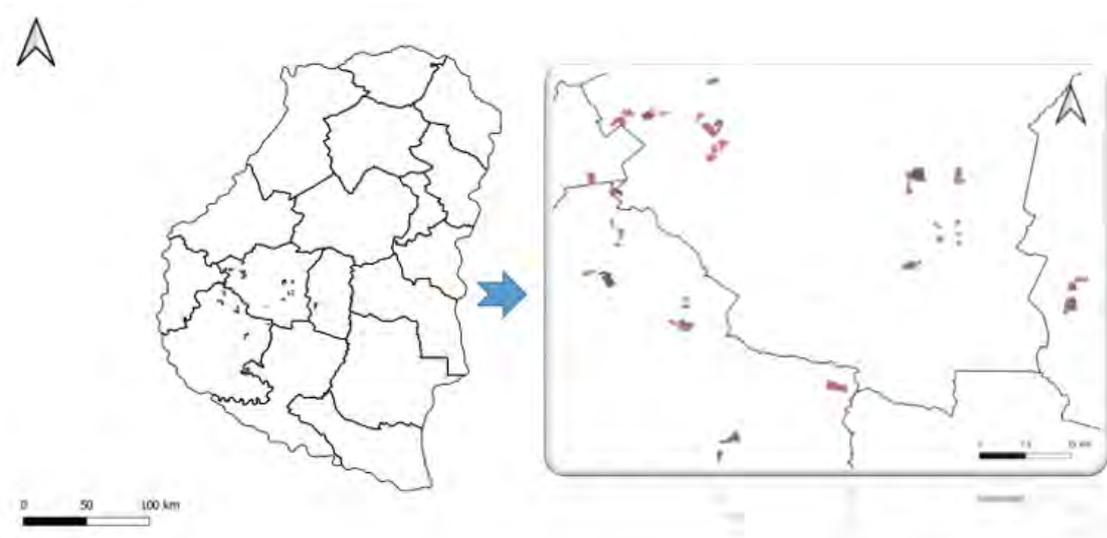


Figura 1: Ubicación de los campos en los departamentos de Entre Ríos, Argentina.

Se trabajó con mapas de rendimientos de 9 cultivos, 4 cultivos de verano (soja, maíz, girasol y sorgo) y 5 cultivos de invierno (trigo, cebada, colza, arveja y lino). En la tabla 1 está el número de mapas de rendimiento y la superficie de cada cultivo utilizados en este trabajo.

Tabla 1: Numero de mapas de rendimiento, superficie total por cultivo y porcentaje del área incluidos en el trabajo.

CULTIVO	NUMERO DE MAPAS DE REND.	SUPERFICIE	%
MAIZ	54	7573	29.9
SOJA	79	9640	38.1
GIRASOL	1	191	0.8
SORGO	1	36	0.1
ARVEJA	7	907	3.6
COLZA	4	666	2.6
TRIGO	43	4926	19.4
CEBADA	11	1395	5.5
LINO	1	221	0.9
TOTAL	201	25334	100

En la tabla 2 se especifica los rendimientos promedios de cada cultivo, desvío estándar y CV.

Tabla 2: media de rendimiento, desvío estándar y coeficiente de variación por cultivo.

Cultivos	Media	Desvio_estandar	CV
Arveja	3.2092372	1.0979705	34.21282
Cebada	3.3081871	1.3816466	41.76446
Colza	1.8767941	0.4875728	25.97903
Girasol	1.9830605	0.4586702	23.12941
LINO	0.8453942	0.5062733	59.88606
Maiz	5.7853393	2.5980822	44.90803
Soja	2.4096262	0.9566774	39.70232
Sorgo	3.6393914	1.0620295	29.18151
Trigo	3.7883915	1.1825001	31.21378

Una vez limpios los mapas de rendimiento, se obtuvo el desvío estándar del rendimiento para cada cultivo de manera espacial y temporal, para poder observar su magnitud.

Se normalizaron los rendimientos ( $\mu=0$  y  $\sigma=1$ ), campo por campo, año a año y se aplicó un remuestreo para llevar la resolución espacial a 20 m. Para luego ambientar los campos con el algoritmo de desviación estándar (Maestrini B. y Basso B. 2021):

Para cada píxel de los mapas de rendimiento, calcule la media y la desviación estándar del rendimiento normalizado en los años disponibles.

Defina como inestables los píxeles con una desviación estándar superior a 0,8 y luego divida los píxeles restantes entre bajo y estable (media <0,2) y alto y estable (media >=0,2).

Se seleccionaron y descargaron imágenes de 3 índices de vegetación (IV) entre los más comúnmente utilizados en la actualidad, NDVI (Basso B. et. al. 2019), GNDVI (Melchiori R. et. al. 2009) y GCI (Shuai G. Basso B. 2022) de imágenes satelitales de Sentinel 2, con el objetivo de poder tener buena resolución espacial. Utilizando la página web de Landviewer (<https://eos.com>), en cada caso, se utilizaron los límites de los lotes delimitados en formato KMZ y se determinaron los picos de mayor IV en cada ciclo de crecimiento de cada cultivo, para una serie de datos de 10 años imágenes Sentinel 2. En el caso de imágenes con nubes se eligió la siguiente imagen o en el caso de haber resiembra, granizo, helada u otro factor que afectara el IV en ese ciclo, se eliminó dicha figura.

Se determinó la correlación de los datos de rendimiento e IV mediante regresiones básicas y espaciales con el software Geoda (Bongiovanni R. 2009). Se seleccionaron datos de rendimiento de 10 campos seleccionados al azar para los cultivos de soja, trigo y maíz. La regresión básica no tuvo en cuenta una matriz de vecinos, mientras que la regresión espacial se realizó con una matriz de vecinos con estilo W. Como las regresiones tanto básica como espacial, fueron similares para los 3 IV, se determinó ambientar con NDVI y GCI. Ambos IV se llevaron a una resolución espacial de 20 m para que coincida con la de los mapas de rendimiento.

Con los NDVI se ambientó siguiendo la metodología propuesta por Basso B. et. al. (2019) donde se clasifica a los ambientes en inestables, estables de bajo o alto potencial productivo. Los píxeles son clasificados como bajo o alto potencial dependiendo si el valor promedio del píxel, para los años disponibles, es menor o mayor/igual al valor promedio del lote respectivamente y luego se los clasifica como estables o inestables si tienen un desvío estándar menor o mayor igual a 0,15 respectivamente.

Con el GCI se propuso en este trabajo una nueva metodología, en la cual se siguieron los siguientes pasos para cada lote individualmente:

Calcular la media y CV de cada píxel, para los años disponibles.

Calcular la media de los valores de todos los píxeles del lote.

Clasificar como alto o bajo potencial productivo a un píxel de acuerdo si es mayor/igual a la media del lote o menor, respectivamente.

Calcular el cuartil superior (percentil 75) de la frecuencia de los CV calculados en el paso 1.

Para caracterizar la estabilidad del píxel, se utilizó el valor calculado en el paso 4, siendo estable o inestable si es menor o mayor a dicho valor.

Finalmente se compararon las 3 metodologías para la ambientación, en cuanto a la organización de los datos de rendimientos en cada ambiente utilizando estadísticos básicos descriptivos y además se utilizó el índice de Kappa (Landis J. R. & Koch G. G. 1977) para evaluar la coincidencia.

## Resultados y Discusión

Se calculó el desvío estándar del rendimiento (sin normalizar) de cada cultivo para cada pixel, en el tiempo, es decir a través de distintos años disponibles y por otro lado se calculó el desvío estándar por cultivo, lote y año. El resultado se observa en la figura 2, donde se aprecia que algunos cultivos varían más en el espacio (colza y cebada) y otros varían más en el tiempo (maíz y soja). Los demás cultivos que no están incluidos en este gráfico, es porque no se repitieron en el mismo lote, lo cual no nos permite determinar el desvío estándar temporalmente. Esto es muy importante, ya que cada rotación de cultivos en un campo tiene una variabilidad implícita que no solo varía con los cultivos que esta incluya, sino que también con las veces que este se repita y de las condiciones climáticas que afecten al rendimiento.

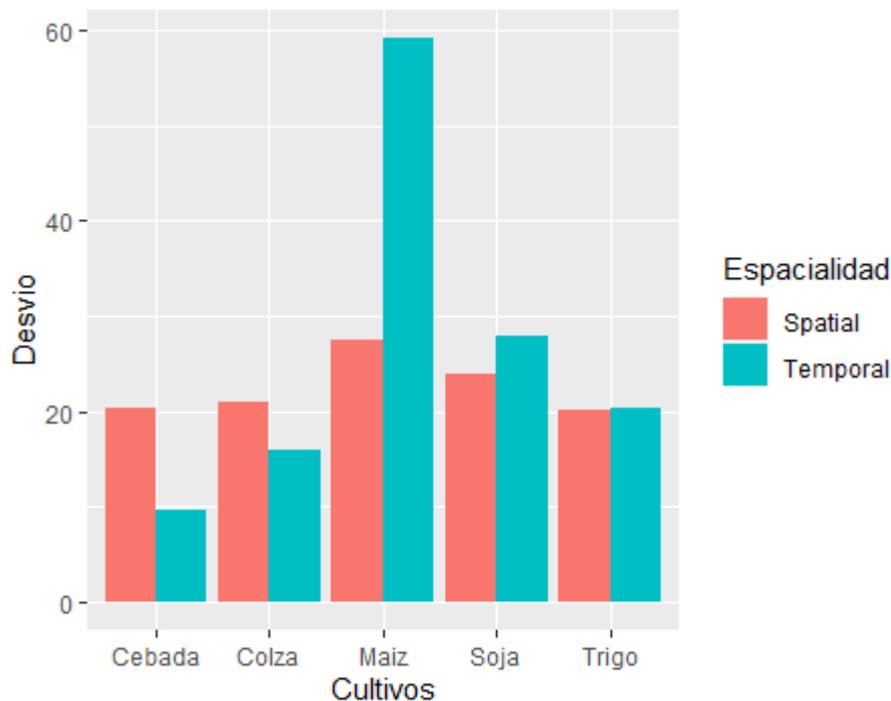


Figura 2: Desvío estándar espacial y temporal de cada cultivo.

Al estudiar la distribución de frecuencias del rendimiento de los cultivos abordados en este trabajo pudimos ver que cada cultivo tiene una forma distinta. Maestrini B. & Basso B. (2021) encontraron que a medida que el rendimiento aumenta, el desvío estándar disminuye. Todo esto, sumado a que cada campo tiene una combinación única de tipos de suelos, nos lleva a plantear que cada campo tiene un parámetro distinto para la clasificación en cuanto a la estabilidad temporal.

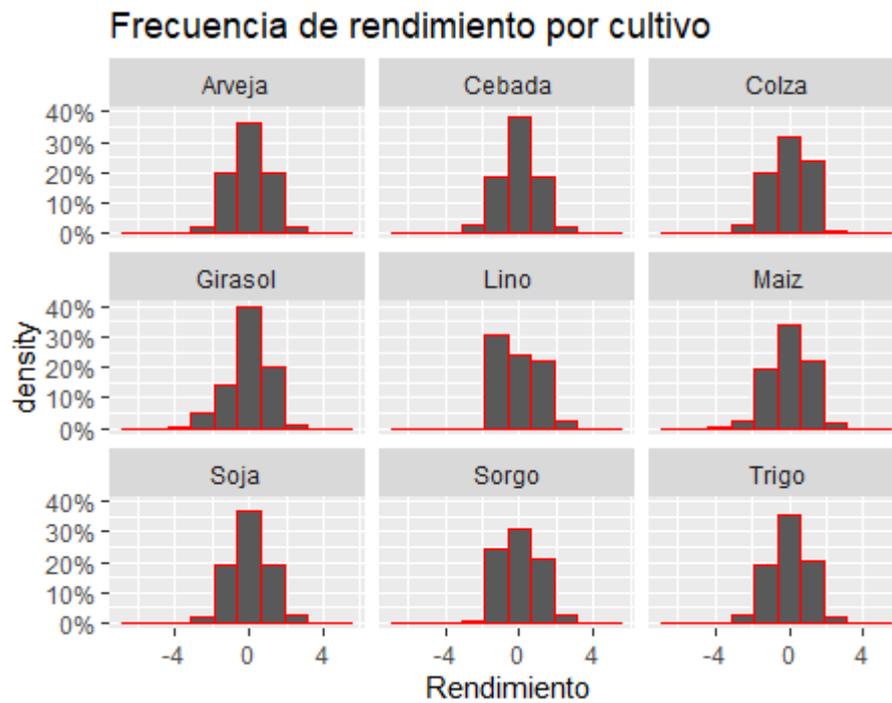


Figura 3: Distribución de frecuencias de rendimiento para cada cultivo.

Las regresiones básicas entre rendimiento y los distintos IV fueron muy bajas para todos los cultivos, mientras que cuando en las regresiones se tuvo en cuenta la espacialidad, fueron muy altas. Entre IV, prácticamente no hubo diferencias, lo cual no limita la utilización de cualquiera de los 3 probados.

Tabla 3: Regresión básica de rendimiento versus IV.

CULTIVO	NDVI	GNDVI	GCI	CULTIVO	NDVI	GNDVI	GCI	CULTIVO	NDVI	GNDVI	GCI
MAIZ 21-22	0.37	0.38	0.35	SOJA 20-21	0.40	0.37	0.24	TRIGO 19	0.37	0.41	0.45
MAIZ 21-22	0.01	0.00	0.00	SOJA 20-21	0.08	0.05	0.01	TRIGO 21	0.04	0.04	0.08
MAIZ 21-22	0.18	0.24	0.44	SOJA 20-21	0.02	0.00	0.00	TRIGO 19	0.11	0.11	0.10
MAIZ 21-22	0.17	0.12	0.14	SOJA 20-21	0.30	0.32	0.32	TRIGO 21	0.04	0.04	0.02
MAIZ 19-20	0.03	0.04	0.05	SOJA 21-22	0.18	0.16	0.09	TRIGO 19	0.20	0.19	0.18
MAIZ 19-20	0.16	0.20	0.11	SOJA 21-22	0.29	0.28	0.15	TRIGO 21	0.06	0.09	0.08
MAIZ 19-20	0.08	0.14	0.10	SOJA 20-21	0.40	0.45	0.57	TRIGO 21	0.20	0.17	0.19
MAIZ 19-20	0.35	0.40	0.45	SOJA 20-21	0.16	0.16	0.17	TRIGO 19	0.01	0.04	0.10
MAIZ 19-20	0.29	0.35	0.36	SOJA 19-20	0.34	0.34	0.49	TRIGO 21	0.23	0.20	0.11
MAIZ 19-20	0.07	0.08	0.15	SOJA 19-20	0.19	0.19	0.20	TRIGO 19	0.27	0.29	0.30
PROMEDIO	0.17	0.19	0.21	PROMEDIO	0.24	0.23	0.22	PROMEDIO	0.15	0.16	0.16

Tabla 3: Regresión espacial de rendimiento versus IV.

CULTIVO	NDVI	GNDVI	GCI	CULTIVO	NDVI	GNDVI	GCI	CULTIVO	NDVI	GNDVI	GCI
MAIZ 21-22	0.86	0.86	0.86	SOJA 20-21	0.93	0.93	0.93	TRIGO 19	0.93	0.93	0.93
MAIZ 21-22	0.91	0.91	0.91	SOJA 20-21	0.95	0.95	0.95	TRIGO 21	0.97	0.97	0.97
MAIZ 21-22	0.95	0.95	0.95	SOJA 20-21	0.93	0.93	0.93	TRIGO 19	0.93	0.93	0.94
MAIZ 21-22	0.94	0.94	0.94	SOJA 20-21	0.96	0.96	0.96	TRIGO 21	0.92	0.92	0.92
MAIZ 19-20	0.94	0.94	0.94	SOJA 21-22	0.67	0.67	0.66	TRIGO 19	0.98	0.98	0.98
MAIZ 19-20	0.93	0.94	0.92	SOJA 21-22	0.98	0.98	0.98	TRIGO 21	0.85	0.85	0.84
MAIZ 19-20	0.94	0.94	0.94	SOJA 20-21	0.93	0.93	0.93	TRIGO 21	0.86	0.86	0.85
MAIZ 19-20	0.91	0.91	0.92	SOJA 20-21	0.87	0.87	0.87	TRIGO 19	0.94	0.94	0.94
MAIZ 19-20	0.95	0.95	0.95	SOJA 19-20	0.96	0.96	0.96	TRIGO 21	0.80	0.80	0.80
MAIZ 21-22	0.93	0.93	0.93	SOJA 19-20	0.91	0.91	0.91	TRIGO 19	0.83	0.83	0.83
PROMEDIO	0.93	0.93	0.93	PROMEDIO	0.91	0.91	0.91	PROMEDIO	0.90	0.90	0.90

Tabla 5: Regresiones promedio, básica y espacial de los 3 cultivos estudiados.

	BASICA	ESPACIAL
NDVI	0.19	0.91
GNDV	0.19	0.91
GCI	0.20	0.91

En la tabla 6 se observa el porcentaje que ocupa cada ambiente generado por los distintos métodos. Donde podemos describir que con NDVI tenemos un porcentaje muy bajo de la superficie como inestable y alto porcentaje de alto potencial estable. Esto puede deberse a diferentes motivos, entre los cuales, utilizar un único valor de desviación estándar (0,15) para todos los lotes para clasificar como inestable y una saturación del índice en coberturas muy densas.

Tabla 6: Porcentaje de superficies ocupadas por cada ambiente generado por los 3 métodos de zonificación.

AMBIENTE	MAPAS DE RENDIMIENTO	NDVI	GCI
	SUPERFICIE (%)	SUPERFICIE (%)	SUPERFICIE (%)
INESTABLE	38	15	25
ESTABLE BAJO POTENCIAL	37	30	33
ESTABLE ALTO POTENCIAL	26	55	42

En las figuras 3, 4 y 5 se ven los tres métodos de ambientación sobre el campo El Durazno 1. Este campo tiene 6 mapas de rendimiento (cebada, soja, trigo, soja, arveja y maíz). La ambientación con NDVI es la metodología con menor área inestable y mayor área de alto potencial estable, lo cual puede sugerir algún problema de saturación de dicho índice en el cual no reflejaría 100% la realidad del lote. La metodología con GCI realiza una ambientación que coincide mucho con la realizada con la metodología de desviación estándar.

Ambientación con metodología de la desviación estandar

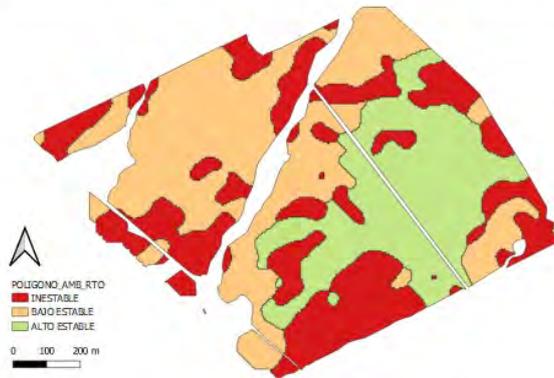


Figura 3: Campo El Durazno 1, ambientado con algoritmo de desviación estándar.

Ambientado con metodología de NDVI



Figura 4: Campo El Durazno 1, ambientado con NDVI.

Ambientado con metodología de GCI

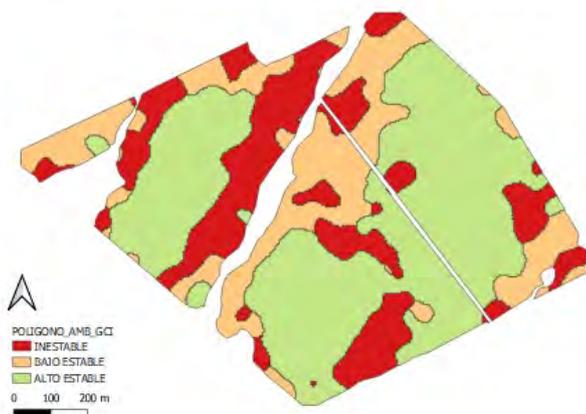


Figura 5: Campo El Durazno 1, ambientado con GCI.

Tabla 7: Porcentaje de la superficie del campo El Durazno 1, abarcado por cada ambiente según cada

metodología de ambientación.

AMBIENTE	RENDIMIENTO	NDVI	GCI
	%	%	%
INESTABLE	32	1	24
BAJO ESTABLE	40	31	23
ALTO ESTABLE	28	68	53

En la tabla N°8 se aprecia la media, desvío estándar y CV de los mapas de rendimiento normalizados, para cada ambiente y cada metodología de ambientación. En el podemos apreciar que la ambientación con NDVI no se termina de ajustar perfectamente y tenemos un coeficiente de variación (CV) bajo en el ambiente inestable, mientras que el CV más alto es el de alto potencial estable. La metodología de ambientación con GCI se ajusta mejor, ya que el CV mayor está en el área inestable y menor en el alto potencial estable. Distintos trabajos demuestran que la frecuencia de rendimiento tiene sesgo negativo y además los rendimientos bajos tienen alto CV y a medida que los rendimientos son más elevados el CV es menor (Maestrini B. Basso B. 2021).

Tabla 8: Estadísticos descriptivos básicos de los mapas de rendimiento normalizados, para cada ambiente en el total de los campos con las tres metodologías de ambientación.

AMBIENTES	ALGORITMO DE DESVIACIÓN ESTANDAR			AMBIENTACIÓN CON NDVI			AMBIENTACIÓN CON GCI		
	MEDIA	DESVÍO ESTANDAR	CV	MEDIA	DESVÍO ESTANDAR	CV	MEDIA	DESVÍO ESTANDAR	CV
INESTABLE	0.07	1.13	1579	-0.29	0.84	-291	-0.13	0.97	-723
BAJO ESTABLE	-0.45	0.72	-159	-0.43	0.92	-214	-0.37	0.91	-243
ALTO ESTABLE	0.62	0.65	104	0.30	0.90	296	0.38	0.86	227

El test de Kappa de Fleiss mostró que hay una confiabilidad mínima entre los tres observadores ( $k= 0,279$  [IC 95%: 0,276-0,28];  $Z= 262$ ;  $p< 0,001$ ). La ambientación creada con el algoritmo de desviación estándar respecto a la realizada con NDVI es más baja ( $k= 0,217$  y coincidencia del 33,2%), respecto a la de GCI ( $k= 0,255$  y coincidencia del 33,2%).



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Conclusión

Este trabajo permite dar inicio a un estudio más amplio del comportamiento del rendimiento en la provincia de Entre Ríos. Podemos concluir que cada cultivo tiene un comportamiento distinto en su frecuencia de distribución y cada uno tiene un comportamiento diferente en el tiempo y espacio. También se obtuvo regresiones elevadas entre rendimiento e IV, para trigo, soja y maíz; siempre y cuando se tuvo en cuenta la espacialidad de los datos. Por último podemos concluir que la metodología de ambientación con GCI se ajustó mejor que la de NDVI, logrando disminuir el CV del rendimiento en los ambientes estables.

## Agradecimientos

Agradezco a Pablo Pacciorretti de la Universidad de Córdoba por brindarme solvencia en los métodos estadísticos; y a Ricardo Melchiori por darme soporte en el trabajo.

## Referencias

### Artículo

Mariano A. Cordoba, Cecilia I. Bruno, Jose L. Costa, Nahuel R. Peralta, Monica G. Balzarini (2015). Protocol for multivariate homogeneous zone delineation in precision agriculture.

### Artículo

Landis, J. R., & Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159.

Whelan, B. M., & McBratney, A. B. (2000). *Precision Agriculture*, 2(3), 265-279.

Melchiori, R.J.M. y Albarenque, S. M. Variabilidad espacio temporal de rendimiento y margen bruto para la delimitación de zonas de manejo (2016).

### Artículo

Laner M., Albarenque S. Kemerer A. Melchiori R (2018), Métodos de delimitación de zonas de manejo usando variabilidad espacio-temporal de rendimiento y margen bruto.

### Artículo

Susana M. Albarenque, Bruno Basso,\* Octavio P. Caviglia, and Ricardo J.M. Melchiori (2016), Spatio-Temporal Nitrogen Fertilizer Response in Maize: Field Study and Modeling Approach.

### Artículo

Blackmore S. (1999), The interpretation of trends from multiple yield maps.

### Artículo

Bruno B., Shuai G., Zhang J., Robertson P. (2019), Yield stability analysis reveals sources of large-scale nitrogen loss from the US Midwest.

### Artículo

Maestrini B., Bruno B. (2021), Subfield crop yields and temporal stability in thousands of US Midwest fields.

### Artículo

Maestrini B., Basso, B., (2018), Drivers of within-field spatial and temporal variability of crop yield across the US Midwest.

### Artículo

Shuai G., Basso B. (2022), Subfield maize yield prediction improves when in-season crop water deficit is included in remote sensing imagery-based models.

### Artículo

Bongiovanni R. (2009), Economía espacial aplicada a la agricultura de precisión.

Melchiori R., Albarenque S., Schulz G., Kemerer A., Bedendo D. (2009), Determinación de zonas de manejo mediante relevamiento de suelos y herramientas informáticas.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## **Impacto del Cambio Climático en la Productividad Agrícola de la región centro de Argentina**

### **Trabajo presentado al 20° Congreso de Agricultura de Precisión 20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Marcos Flesia 1, Emiliano Ferace 2, Diego Chiaraviglio 3, Gretel Bodenbender 4,  
Leandro Alberione 5, Gisela Romano 6, Santiago Panero 7**

<sup>1</sup> Tesista de Maestría en Ciencias de Datos y Gestión del Conocimiento, Especialista en Geoestadística y Suelos, Especialista en Estadística y Biometría, Empresa Rinde Plus, Córdoba, Argentina.

<sup>2</sup> Ingeniero Agrónomo, Especialista en Ingeniería Ambiental, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>3</sup> Ingeniero Agrónomo, Especialista en Fertilidad de suelos y Fertilizantes, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>4</sup> Licenciada en RRHH, Auditora trinorma, Certificadora empresas B, Empresa Rinde Plus, Córdoba, Argentina.

<sup>5</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>6</sup> Ingeniera Agrónoma, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>7</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

### **Resumen**

El cambio climático representa una de las mayores amenazas para la agricultura global, y Argentina no es la excepción. Este estudio examina cómo el aumento de las temperaturas y las variables de suelo impactarán la productividad agrícola en Argentina para el año 2050. Utilizando datos climáticos históricos, características del suelo y proyecciones de aumento de temperatura, se aplicaron modelos de machine learning, específicamente Random Forest y XGBoost, para predecir el impacto en los rendimientos de cultivos clave. Los resultados indican un aumento significativo en las temperaturas promedio anuales, combinado con variaciones en las propiedades del suelo, que podrían afectar de manera desigual la producción agrícola. Este trabajo destaca la necesidad de implementar estrategias de adaptación y mitigación para salvaguardar la seguridad alimentaria y la sostenibilidad agrícola en el país.

### **Introducción**

#### **Contexto Global del Cambio Climático**

El cambio climático se refiere a las alteraciones a largo plazo en los patrones de temperatura y clima, atribuibles en gran medida a las actividades humanas que han aumentado la concentración de gases de efecto invernadero en la atmósfera. Estos cambios climáticos han provocado una serie de impactos a nivel global, incluyendo eventos climáticos extremos, aumento del nivel del mar y alteraciones en los patrones de precipitación, lo que afecta gravemente los ecosistemas y las actividades humanas, especialmente la agricultura.

### **Cambio Climático en Argentina**

Argentina, con su vasta extensión territorial y diversidad climática, enfrenta desafíos significativos debido al cambio climático. Las observaciones recientes muestran un aumento en las temperaturas promedio y cambios en los patrones de precipitación, lo que ha comenzado a afectar la producción agrícola. Dado que la agricultura es un pilar fundamental de la economía argentina, cualquier cambio en las condiciones climáticas puede tener repercusiones significativas en la seguridad alimentaria y económica del país.

### **Importancia de las Variables de Suelo**

Además del clima, las propiedades del suelo, como la textura, la capacidad de retención de agua y la fertilidad, juegan un papel crucial en la productividad agrícola. El cambio climático puede exacerbar las limitaciones del suelo, alterando su capacidad para soportar cultivos. Este estudio incluye variables de suelo para proporcionar un análisis más completo y preciso de cómo las condiciones cambiantes afectarán la producción agrícola.

### **Objetivo del Estudio**

El objetivo principal de este estudio es analizar cómo el cambio climático, en particular el aumento de la temperatura y las condiciones del suelo afectará la productividad agrícola en Argentina hasta el año 2050. A través de modelos de machine learning, este estudio busca proporcionar una comprensión detallada de las futuras condiciones climáticas y su impacto en los rendimientos agrícolas, destacando las regiones más vulnerables y proponiendo estrategias de adaptación.

### **Metodología**

#### **Recolección de Datos**

Los datos utilizados en este estudio fueron recolectados de 136 productores y 1847 lotes. Estos datos consisten en parámetros climáticos y edáficos. Los datos climáticos incluyen temperatura, precipitación, humedad y evapotranspiración, registrados diariamente a través de la plataforma de OpenWeather. Para calcular el aumento interanual de temperatura, se realizó un aprendizaje sobre los últimos 30 años y sus variaciones de temperatura interanual.

Los datos edáficos comprenden parámetros como pH, capacidad de intercambio catiónico (CIC), materia orgánica (MO), calcio, magnesio, potasio, fósforo, sodio, PSI, y relaciones de cambio como calcio/magnesio y calcio/potasio, entre otros. Los datos de suelos fueron tomados utilizando de base ambientaciones realizadas a partir de imágenes NDVI históricas con las cuáles se construyen mapas de ambientes identificando zonas de alta, media y baja productividad usando la plataforma Campo 360 de Geoagro. Luego se procede a tomar muestras de suelo con un calador hidráulico CH200 de la empresa Tornomar tomando muestras de suelo georreferenciadas en dos estratos, 0 a 20 cm y 20 a 40 cm de profundidad; en el mismo lugar donde se toma la muestra de suelo se realiza una medición de compactación con un penetrómetro digital montado sobre el mismo calador anteriormente mencionado. Una vez recolectadas las muestras de suelo son refrigeradas y enviadas a laboratorio para realizar las determinaciones antes mencionadas.

## Modelos de Machine Learning

Se emplearon los modelos de Random Forest y XGBoost debido a su capacidad para manejar grandes conjuntos de datos y capturar interacciones complejas entre variables. Estos modelos se entrenaron utilizando datos históricos para proyectar el rendimiento de los cultivos bajo escenarios de variación de temperatura y evapotranspiración según las variaciones interanuales sufridas en los últimos 30 años.

## Proyecciones Climáticas

Las proyecciones de temperatura se basaron en un incremento anual del 0.89% y un incremento mensual del 0.074%. Se aplicaron estos porcentajes a los datos históricos para modelar el escenario climático futuro hasta 2050.

## Análisis de Datos

Se realizaron análisis exploratorios para identificar tendencias y correlaciones entre las variables climáticas, las propiedades del suelo y los rendimientos de los cultivos. Los modelos de machine learning se evaluaron utilizando métricas de precisión y se validaron mediante métodos de validación cruzada.

## Resultados

### Análisis de Temperaturas

Los resultados muestran un incremento consistente en las temperaturas promedio anuales desde el año 2000 al 2024, utilizamos dichos aumentos para poder simular un posible escenario de crecimiento de temperaturas como viene siendo hasta el día de la fecha del 2024.

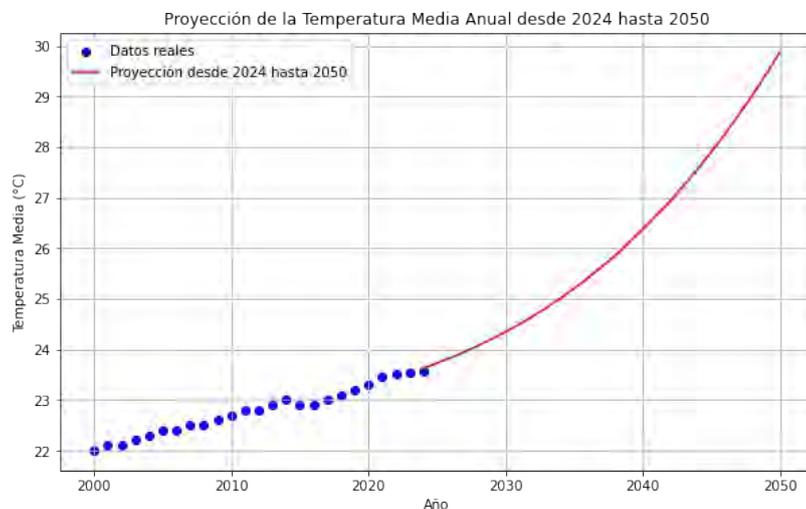


Fig. 1 simulación del posible crecimiento de temperaturas medias, analizadas en función del crecimiento de temperatura anual de los últimos 20 años.

Diferencia 2025 - 2024:	0.10 °C
Diferencia 2026 - 2025:	0.11 °C
Diferencia 2027 - 2026:	0.11 °C
Diferencia 2028 - 2027:	0.12 °C
Diferencia 2029 - 2028:	0.13 °C
Diferencia 2030 - 2029:	0.14 °C
Diferencia 2031 - 2030:	0.15 °C
Diferencia 2032 - 2031:	0.16 °C
Diferencia 2033 - 2032:	0.17 °C
Diferencia 2034 - 2033:	0.18 °C
Diferencia 2035 - 2034:	0.19 °C
Diferencia 2036 - 2035:	0.21 °C
Diferencia 2037 - 2036:	0.22 °C
Diferencia 2038 - 2037:	0.23 °C
Diferencia 2039 - 2038:	0.25 °C
Diferencia 2040 - 2039:	0.26 °C
Diferencia 2041 - 2040:	0.28 °C
Diferencia 2042 - 2041:	0.29 °C
Diferencia 2043 - 2042:	0.31 °C
Diferencia 2044 - 2043:	0.32 °C
Diferencia 2045 - 2044:	0.34 °C
Diferencia 2046 - 2045:	0.36 °C
Diferencia 2047 - 2046:	0.38 °C
Diferencia 2048 - 2047:	0.39 °C
Diferencia 2049 - 2048:	0.41 °C
Diferencia 2050 - 2049:	0.43 °C

Fig. 2 Diferencia interanual del crecimiento de temperatura en la simulación.

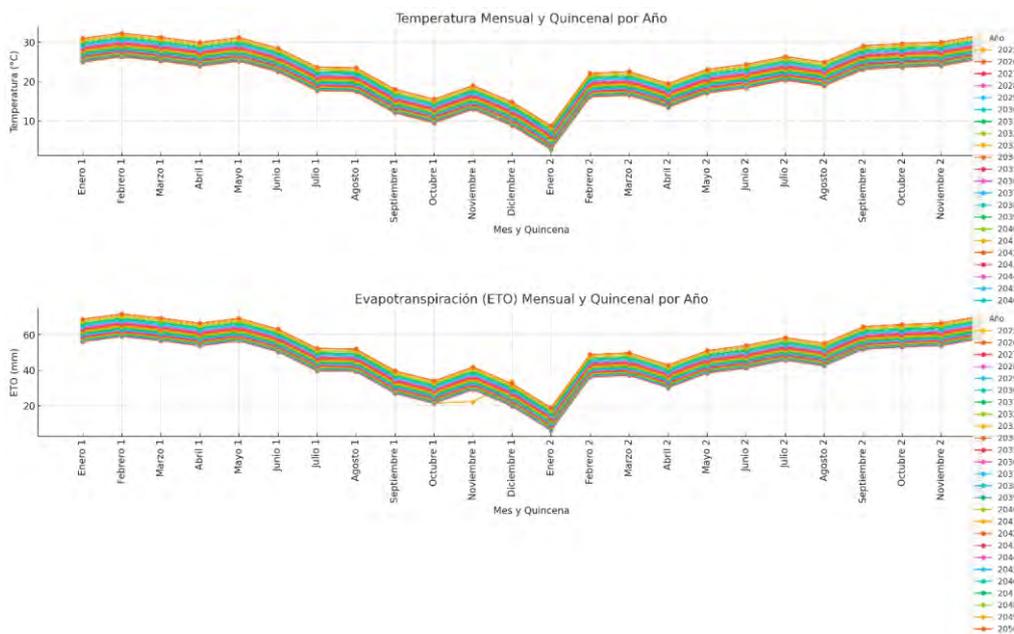


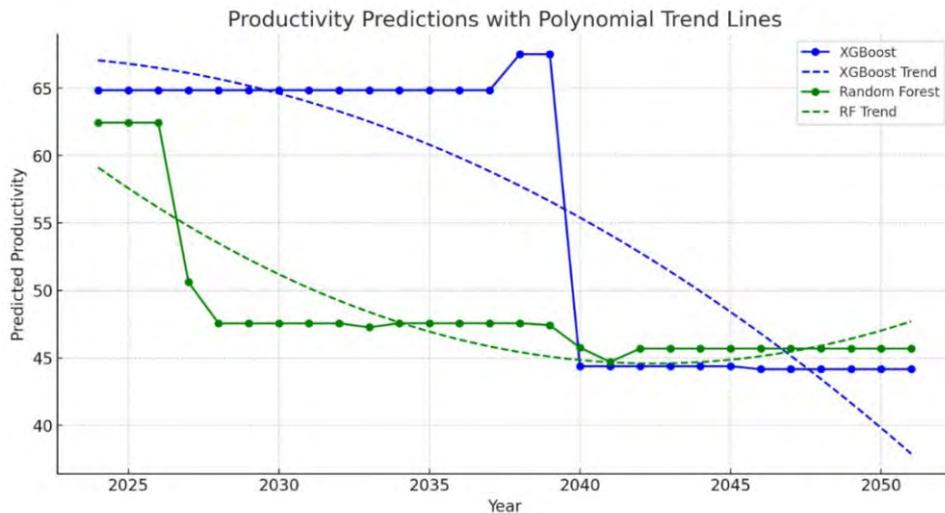
Fig. 3 Gráfica de los incrementos interanuales en cada mes del año para temperatura y evapotranspiración.

### Impacto en la Productividad Agrícola

Los modelos muestran que la productividad de los cultivos clave, como el maíz, la soja y el trigo, podría disminuir significativamente en la región del centro de Córdoba con base de análisis en la localidad de Río Primero, debido al estrés térmico y la falta de agua que compense a la alta demanda atmosférica.

Como resultado una fuerte caída de rendimientos llegando al 16.75% de merma de productividad en

26 años. Para ponerle de referencia si el productor de la zona de Río Primero espera 6.2 toneladas de Maíz, en el 2050, con los aumentos de temperatura va a lograr 4.59 toneladas de Maíz.



## Rendimiento de algoritmo

Random Forest -  $R^2$ : 0.79, RMSE: 10.85

XGBoost -  $R^2$ : 0.83, RMSE: 9.80

Columnas en el archivo de prueba: Index(['Latitud\_y', 'Longitud\_y', 'Año', 'pH', 'CIC meq/100 gr', 'SatK [%]', 'SatCa [%]', 'SatMg [%]', 'MO [%]', 'Carbono (%)', 'ETO agosto 1', 'ETO agosto 2', 'ETO septiembre 1', 'ETO septiembre 2', 'ETO octubre 1', 'ETO octubre 2', 'ETO noviembre 1', 'ETO noviembre 2', 'ETO diciembre 1', 'ETO diciembre 2'], dtype='object', length=120)

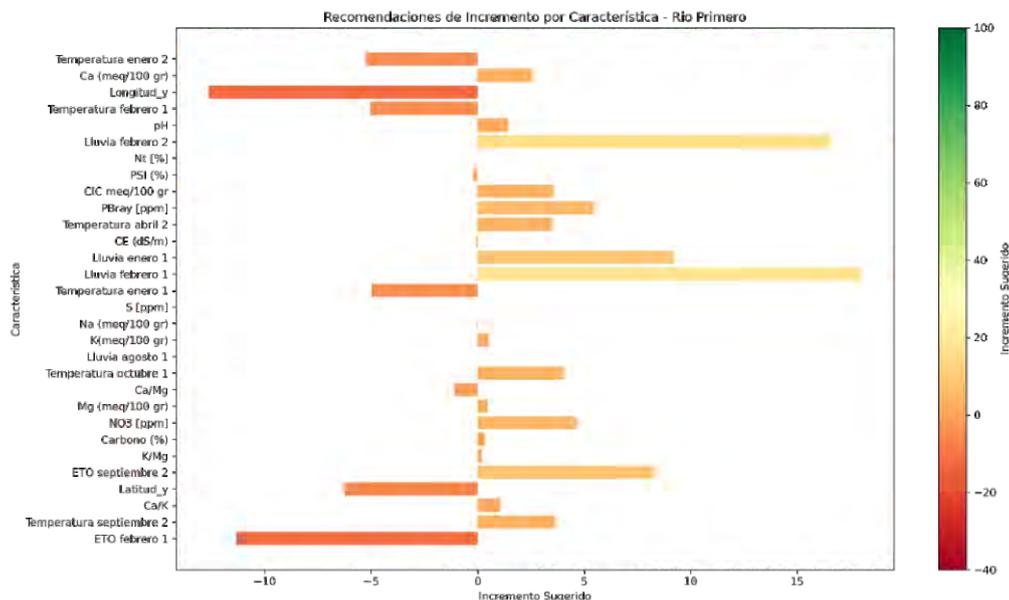
## Variabilidad Regional

Motivamos este estudio a que se realice en el norte de Argentina con ambientes de mayor vulnerabilidad al cambio climático debido a su clima ya cálido y a las limitaciones del suelo. En contraste, las regiones del sur podrían experimentar aumentos de productividad debido a condiciones climáticas más moderadas.

## Efecto de las Variables de Suelo

Las variables de suelo, especialmente la capacidad de retención de agua y el contenido de materia orgánica, muestran un fuerte impacto en la mitigación del estrés climático, subrayando la importancia de la gestión del suelo en las estrategias de adaptación.

Para que el productor compense estas pérdidas ocasionadas por el cambio climático tiene que poner foco en mejorar las siguientes condiciones:



Por ejemplo, mejorar el calcio y el Carbono orgánico del suelo como fuentes de mejora estructural y retención de agua.

## Discusión

### Implicaciones para la Política Agrícola

Los resultados de este estudio tienen importantes implicaciones para la política agrícola en Argentina. La implementación de prácticas de manejo sostenible del suelo, como fomentar el uso de cultivos de cobertura y la mejora de la materia orgánica del suelo, podría ayudar a mitigar algunos de los efectos negativos del cambio climático en la productividad agrícola. Además, se debe considerar la promoción de cultivos con mayor tolerancia al calor y al estrés hídrico.

### Limitaciones del Estudio

Este estudio se basa en proyecciones de datos históricos y modelos de machine learning, lo que implica ciertas limitaciones. Los modelos pueden no capturar completamente todas las complejidades del cambio climático y su impacto en la agricultura.

### Futuras Direcciones de Investigación

Futuras investigaciones podrían centrarse en la integración de modelos climáticos más avanzados y en el análisis de políticas de adaptación específicas para diferentes regiones. Además, la colaboración con agricultores y comunidades locales será crucial para desarrollar estrategias efectivas y prácticas adaptadas a las necesidades locales.

## Conclusiones

El cambio climático presenta desafíos significativos para la agricultura en Argentina, pero también oportunidades para innovar y adaptar prácticas agrícolas. Este estudio destaca la importancia de considerar tanto las variables climáticas como las del suelo al planificar para el futuro. A medida que las condiciones climáticas continúan cambiando, será esencial implementar estrategias de manejo sostenible para asegurar la seguridad alimentaria y la resiliencia agrícola. Dentro de las prácticas de manejo que recomendamos son todas aquellas que están relacionadas con la preservación de la materia orgánica del suelo y el almacenamiento de agua. Para lo cual promovemos mantener niveles

de calcio adecuado, controlar sodio y ph, realizar coberturas verdes con el fin de mejorar la estructura de los suelos agrícolas.

### Referencias

1. IPCC. (2021). Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change.
2. Ministerio de Agricultura, Ganadería y Pesca. (2020). Estrategias para la adaptación al cambio climático en la agricultura.
3. Rosenzweig, C., & Hillel, D. (2015). Handbook of Climate Change and Agroecosystems: Global and Regional Aspects and Implications.
4. Lobell, D. B., Schlenker, W., & Costa-Roberts, J. (2011). Climate Trends and Global Crop Production Since 1980. *Science*, 333(6042), 616-620.
5. FAO. (2017). Climate-Smart Agriculture: A Call for Action.
6. Smith, P., et al. (2014). Agriculture, Forestry and Other Land Use (AFOLU). In: *Climate Change 2014: Mitigation of Climate Change*.
7. Sánchez, B., et al. (2014). Climate Change Impacts on Agriculture in Argentina: A Review. *Agronomy Journal*, 106(5), 1659-1673.
8. World Bank. (2020). Climate Change Knowledge Portal.
9. García, J., & Martínez, L. (2019). Impactos del cambio climático en la agricultura de América Latina y el Caribe. CEPAL.
10. Olesen, J. E., & Bindi, M. (2002). Consequences of Climate Change for European Agricultural Productivity, Land Use and Policy. *European Journal of Agronomy*, 16(4), 239-262.
11. Altieri, M. A., & Nicholls, C. I. (2017). Agroecology: A Pathway to Resilient Agriculture. In: *Climate Change and Food Systems Resilience in Sub-Saharan Africa*.
12. Rockström, J., et al. (2017). Sustainable Intensification of Agriculture for Human Prosperity and Global Sustainability. *Ambio*, 46(1), 4-17.
13. Campbell, B. M., et al. (2016). Reducing Risks to Food Security from Climate Change. *Global Food Security*, 11, 34-43.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Simulación de productividad agrícola en la localidad de Chañaritos, Córdoba, Argentina bajo escenarios de variación climática utilizando modelos de machine learning avanzados

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

Marcos Flesia <sup>1</sup>, Emiliano Ferace <sup>2</sup>, Diego Chiaraviglio <sup>3</sup>, Leandro Alberione <sup>4</sup>, Gisela Romano <sup>5</sup>, Santiago Panero <sup>6</sup>

<sup>1</sup> Ingeniero Agrónomo, Tesista de Maestría en Ciencias de Datos y Gestión del Conocimiento, Especialista en Geoestadística y Suelos, Especialista en Estadística y Biometría, Empresa Rinde Plus, Córdoba, Argentina.

<sup>2</sup> Ingeniero Agrónomo, Especialista en Ingeniería Ambiental, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos., Calchín, Córdoba, Argentina.

<sup>3</sup> Ingeniero Agrónomo, Especialista en Fertilidad de suelos y Fertilizantes, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos., Calchín, Córdoba, Argentina.

<sup>4</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos., Calchín, Córdoba, Argentina.

<sup>5</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos., Calchín, Córdoba, Argentina.

<sup>6</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos., Calchín, Córdoba, Argentina.

### Resumen

Este trabajo presenta un enfoque para la predicción de la productividad agrícola en la localidad de Chañaritos, ubicada en la región centro de Córdoba mediante el uso de modelos de machine learning, considerando escenarios de variación climática. Se emplearon modelos de Random Forest y XGBoost para analizar datos climáticos y edáficos recolectados a lo largo del tiempo. Además, se simularon dos escenarios climáticos: uno con un aumento del 15% en las precipitaciones (año Niño) con un 10% menos de demanda atmosférica y otro con una disminución del 15% en las precipitaciones (año Niña) con aumento del 10% de demanda atmosférica. Los resultados indican que ambos modelos ofrecen predicciones precisas, con un rendimiento superior al del modelo XGBoost. Este enfoque permite una planificación agrícola más eficiente y basada en datos, mejorando la toma de decisiones en el manejo técnico de cultivos.

**Palabras clave:** Predicción agrícola, machine learning, Random Forest, XGBoost, datos climáticos, productividad agrícola, variación climática, simulación.

### Introducción

La agricultura de precisión ha revolucionado la manera en que los agricultores gestionan sus cultivos, proporcionando herramientas avanzadas para maximizar la productividad y minimizar el impacto ambiental. En la región centro de Córdoba, la variabilidad climática y edáfica representa un desafío significativo para los agricultores. Este trabajo propone un modelo de predicción de la productividad agrícola utilizando técnicas de machine learning, específicamente Random Forest y XGBoost, para mejorar la planificación y gestión de los cultivos bajo escenarios de variación climática, simulando años Niño y Niña.

### **Objetivo del Trabajo**

El objetivo principal de este trabajo es desarrollar y evaluar modelos de machine learning, específicamente Random Forest y XGBoost, para predecir la productividad agrícola en la región centro de Córdoba bajo escenarios de variación climática. A través de la integración de datos climáticos y edáficos recolectados de múltiples productores y lotes, y la simulación de variaciones en las precipitaciones, se busca proporcionar una herramienta precisa y eficiente que permita a los agricultores optimizar la planificación y gestión de sus cultivos.

### **Materiales y Métodos**

#### **Datos**

Los datos utilizados en este estudio fueron recolectados de 136 productores y 1847 lotes. Estos datos consisten en parámetros climáticos y edáficos. Los datos climáticos incluyen temperatura, precipitación, humedad y evapotranspiración, registrados diariamente a través de la plataforma de OpenWeather. Los datos edáficos comprenden parámetros como pH, capacidad de intercambio catiónico (CIC), materia orgánica (MO), calcio, magnesio, potasio, fósforo, sodio, PSI, y relaciones de cambio como calcio/magnesio y calcio/potasio, entre otros. Los datos de suelos fueron tomados utilizando de base ambientaciones realizadas a partir de imágenes NDVI históricas con las cuáles se construyen mapas de ambientes identificando zonas de alta, media y baja productividad usando la plataforma Campo 360 de Geoagro. Luego se procede a tomar muestras de suelo con un calador hidráulico CH200 de la empresa Tornomar tomando muestras de suelo georreferenciadas en dos estratos, 0 a 20 cm y 20 a 40 cm de profundidad; en el mismo lugar donde se toma la muestra de suelo se realiza una medición de compactación con un penetrómetro digital montado sobre el mismo calador anteriormente mencionado. Una vez recolectadas las muestras de suelo son refrigeradas y enviadas a laboratorio para realizar las determinaciones antes mencionadas.

Los datos fueron almacenados en archivos Excel para conformar el conjunto de entrenamiento y se procesaron para eliminar valores faltantes. Este estudio se realizó para la localidad de Chañaritos, Córdoba, Argentina. Para esta localidad se creó un conjunto de testing específico con las mismas variables del conjunto de entrenamiento, actualizadas a la campaña en curso 2024. Una vez generados ambos archivos (entrenamiento y testing), se procedió a efectuar el análisis dentro del entorno de programación Python.

La distribución de Lluvias promedio de Chañaritos Años (202 - 2021 - 2022 - 2023):

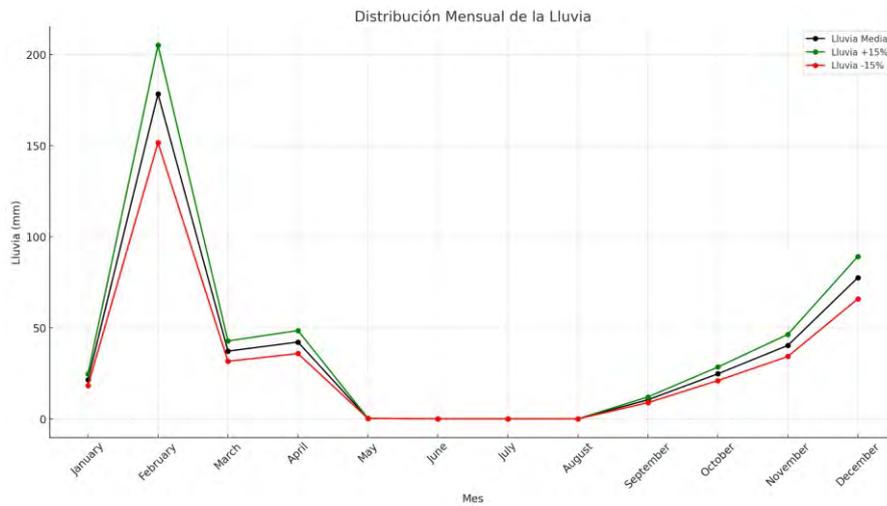


Fig. 1 Distribución de lluvias promedio de Chañaritos, Córdoba (línea negra). Simulación de lluvia + 15%(línea verde). Simulación de lluvia -15% (línea roja).

La distribución de temperatura promedio de Chañaritos (2020 - 2021 - 2022 - 2023):

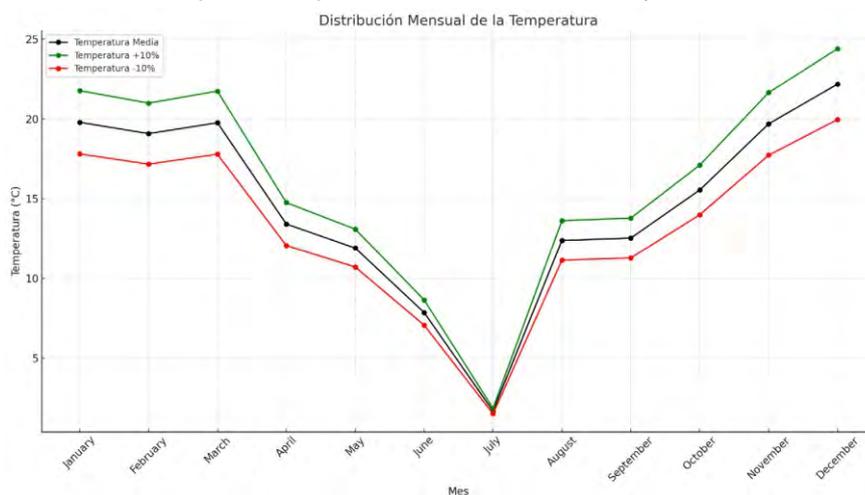


Fig. 2 Distribución de temperatura promedio de Chañaritos, Córdoba (línea negra). Simulación de temperatura + 10%(línea verde). Simulación de temperatura -10% (línea roja).

## Preparación de Datos

La limpieza de los datos implicó la eliminación de filas con valores faltantes en las columnas más relevantes. Las variables independientes incluyeron parámetros climáticos y edáficos, mientras que la variable dependiente fue la productividad agrícola.

## Simulación de Escenarios Climáticos

Para simular los escenarios de años Niño y Niña, se ajustaron las precipitaciones en los datos de testing:

**Año Niño:** se aumentaron las precipitaciones en un 15% y se disminuyó la demanda atmosférica en un 10%.

**Año Niña:** se disminuyeron las precipitaciones en un 15% y se aumentó la demanda atmosférica en un 10%.

## Modelos de Machine Learning

Para este estudio, se implementaron dos modelos de machine learning: Random Forest y XGBoost. A continuación, se detallan los pasos seguidos para la implementación de estos modelos:

### Cargar Datos de Entrenamiento y Testing:

Se utilizaron archivos Excel para cargar los datos de entrenamiento y testing. Los datos de entrenamiento se utilizaron para ajustar los modelos, mientras que los datos de testing se emplearon para evaluar el rendimiento de los modelos.

#### 1. Limpieza y Preparación de Datos:

Se eliminaron las filas con valores faltantes en las columnas clave.

Se seleccionaron las variables independientes (parámetros climáticos y edáficos) y la variable dependiente (productividad agrícola).

#### 2. División de Datos:

Los datos se dividieron en conjuntos de entrenamiento y prueba utilizando la función `train_test_split` de la biblioteca `sklearn`.

#### 3. Implementación del Modelo Random Forest:

Se creó un pipeline que incluyó la normalización de los datos con `Standard Scaler` y el modelo `Random Forest Regressor`.

Se entrenó el modelo utilizando el conjunto de entrenamiento y se realizaron predicciones sobre el conjunto de prueba de la localidad de Chañaritos.

Se evaluó el rendimiento del modelo utilizando métricas como el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE) y el coeficiente de determinación ( $R^2$ ).

#### 4. Implementación del Modelo XGBoost:

Similarmente, se creó un pipeline para el modelo `XGBoost` utilizando `Standard Scaler` y `XGB Regressor`. Se entrenó el modelo y se realizaron predicciones sobre el conjunto de prueba de la localidad de Chañaritos. Se evaluó el rendimiento del modelo utilizando las mismas métricas (MSE, RMSE y  $R^2$ ).

#### 5. Predicciones Futuras:

Se utilizaron los modelos entrenados para realizar predicciones de productividad futura para el año 2025, bajo los escenarios simulados de variación climática.

## Resultados

El modelo `Random Forest` mostró un error cuadrático medio (MSE) de 115.10, una raíz del error cuadrático medio (RMSE) de 10.73 y un coeficiente de determinación ( $R^2$ ) de 0.8033. Por otro lado, el modelo `XGBoost` presentó un MSE de 95.81, un RMSE de 9.78 y un  $R^2$  de 0.829351. Los resultados indican que ambos modelos proporcionan predicciones precisas, con un rendimiento superior al del modelo `XGBoost`.

### Productividad en Escenario Niño

Modelo	Predicción 2025
Random Forest	58.4
XGBoost	70,309.44

Fig. 3 Resultados de posible porcentaje de productividad en el escenario año niño.

En el escenario Niño, con un aumento del 15% en las precipitaciones, se observó un incremento en la productividad agrícola promedio. Los valores de productividad fueron:

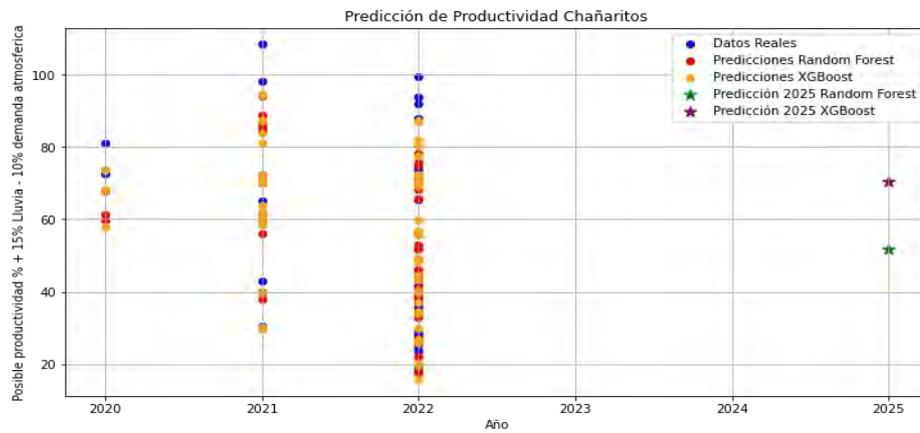


Fig. 4 Gráfica de entrenamiento y testeo de los resultados.

### Productividad en Escenario Niña

En el escenario Niña, con una disminución del 15% en las precipitaciones, se observó una reducción en la productividad agrícola promedio. Los valores de productividad fueron:

Modelo	Predicción 2025
Random Forest	50,476
XGBoost	50,283.09

Fig. 5 Resultados de posible porcentaje de productividad en el escenario año niña.

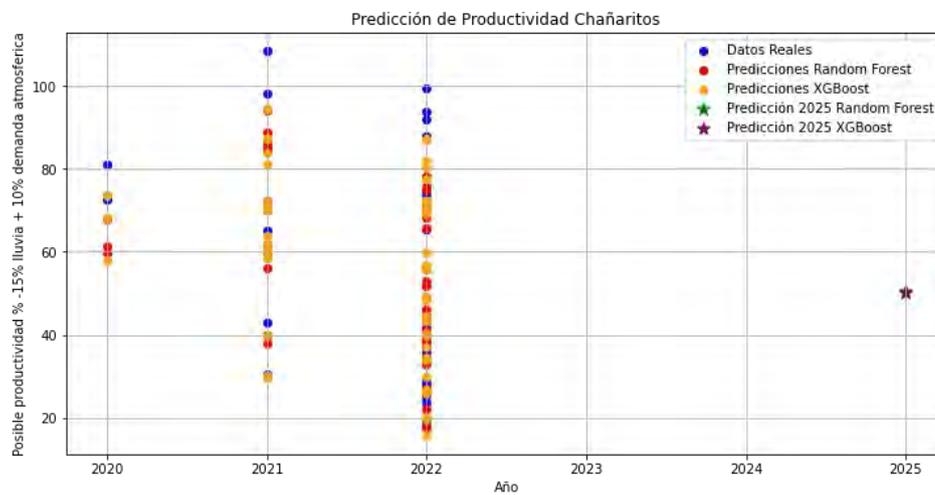


Fig. 6 Gráfica de entrenamiento y testeo de los resultados.

Ambos modelos identificaron las variables más importantes para la predicción de la productividad agrícola. Las características más influyentes incluyeron la precipitación y la temperatura en determinados meses, así como algunos parámetros edáficos específicos.

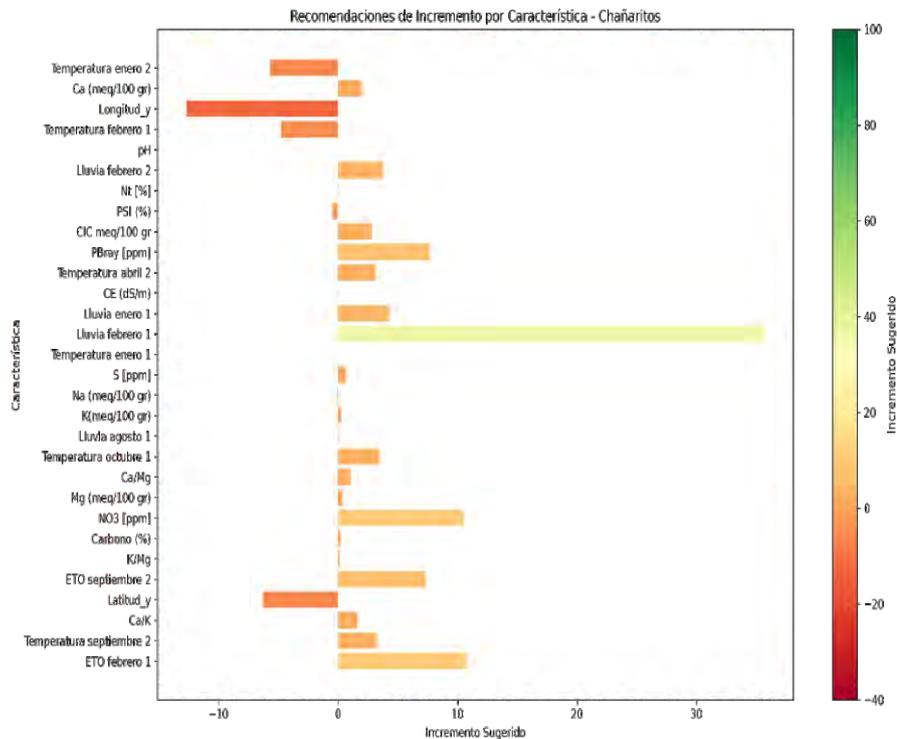


Fig. 7 Gráfica feature importance identificadas por los modelos y establecidas directamente en el set de testeo para luego ser graficadas como se muestra en la gráfica.

## Discusión

Los resultados obtenidos demuestran la viabilidad de utilizar modelos de machine learning para predecir la productividad agrícola en la región centro de Córdoba bajo escenarios de variación climática. La capacidad de identificar las variables más influyentes permite a los agricultores centrar sus esfuerzos en los factores que más afectan el rendimiento de los cultivos. Además, el uso de predicciones a futuro facilita la planificación y toma de decisiones, optimizando los recursos y mejorando la eficiencia.

El beneficio para los productores es significativo, ya que pueden planificar sus campañas agrícolas de manera más eficiente. Con los escenarios de aumento y disminución de precipitaciones, los agricultores pueden ajustar sus estrategias de riego, fertilización y manejo de cultivos para maximizar la productividad y minimizar riesgos. En términos económicos, puede elegir con más previsibilidad el riesgo a tomar frente a la planificación de campañas.

## Conclusiones

Este estudio confirma que los modelos de Random Forest y XGBoost son herramientas efectivas para la predicción de la productividad agrícola. La integración de datos climáticos y edáficos en estos modelos proporciona predicciones precisas, ayudando a los agricultores a tomar decisiones informadas. La simulación de escenarios climáticos permite evaluar el impacto de variaciones en las precipitaciones, proporcionando información valiosa para la planificación agrícola en años Niño y Niña.

## Referencias

1. Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. doi:10.1023/A:1010933404324.
2. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). doi:10.1145/2939672.2939785.
3. Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. New York: Springer.
4. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: with Applications in R*. New York: Springer.
5. Zhang, Z. (2016). Introduction to machine learning: K-nearest neighbors. *Annals of Translational Medicine*, 4(11), 218. doi:10.21037/atm.2016.03.37.
6. Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 2(3), 18-22.
7. Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
8. Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792. doi:10.1890/07-0539.1
9. Caruana, R., & Niculescu-Mizil, A. (2006). An empirical comparison of supervised learning algorithms. *Proceedings of the 23rd International Conference on Machine Learning*, 161-168.
10. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Second Edition. New York: Springer.
11. Polikar, R. (2006). Ensemble based systems in decision making. *IEEE Circuits and Systems Magazine*, 6(3), 21-45.
12. Elith, J., Leathwick, J. R., & Hastie, T. (2008). A working guide to boosted regression trees. *Journal of Animal Ecology*, 77(4), 802-813. doi:10.1111/j.1365-2656.2008.01390.x
13. Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300. doi:10.1016/j.patrec.2005.08.011



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Predicción de Productividad Agrícola en la Región Centro de Córdoba Utilizando Modelos de Machine Learning

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

**Marcos Flesia<sup>1</sup>, Emiliano Ferace<sup>2</sup>, Diego Chiaraviglio<sup>3</sup>, Leandro Alberione<sup>4</sup>,  
Gisela Romano<sup>5</sup>, Santiago Panero<sup>6</sup>**

<sup>1</sup> Ingeniero Agrónomo, Tesista de Maestría en Ciencias de Datos y Gestión del Conocimiento, Especialista en Geoestadística y Suelos, Especialista en Estadística y Biometría, Empresa Rinde Plus, Córdoba, Argentina.

<sup>2</sup> Ingeniero Agrónomo, Especialista en Ingeniería Ambiental, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>3</sup> Ingeniero Agrónomo, Especialista en Fertilidad de suelos y Fertilizantes, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>4</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>5</sup> Licenciada en Geografía, Especialista en Agricultura de Precisión, Especialista en Gis, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

<sup>6</sup> Ingeniero Agrónomo, Especialista en Agricultura de Precisión, Empresa Chiaraviglio Hnos, Calchín, Córdoba, Argentina.

### Resumen

Este trabajo presenta un enfoque para la predicción de la productividad agrícola en la región centro de Córdoba mediante el uso de modelos de machine learning. Se emplearon modelos de Random Forest y XGBoost para analizar datos climáticos y edáficos recolectados a lo largo del tiempo. Los datos se obtuvieron de archivos Excel y se procesaron para eliminar valores faltantes y seleccionar las variables más relevantes. Los resultados indican que ambos modelos ofrecen predicciones precisas, con un rendimiento superior al del modelo XGBoost. Este enfoque permite una planificación agrícola más eficiente y basada en datos, mejorando la toma de decisiones en el manejo técnico de cultivos.

**Palabras clave:** Predicción agrícola, machine learning, Random Forest, XGBoost, datos climáticos, productividad agrícola.

### Introducción

La agricultura de precisión ha revolucionado la manera en que los agricultores gestionan sus cultivos, proporcionando herramientas avanzadas para maximizar la productividad y minimizar el impacto ambiental. En la región centro de Córdoba, la variabilidad climática y edáfica representa un desafío significativo para los agricultores. Este trabajo propone un modelo de predicción de la productividad agrícola utilizando técnicas de machine learning, específicamente Random Forest y XGBoost, para mejorar la planificación y gestión de los cultivos.

### Objetivo del Trabajo

El objetivo principal de este trabajo es desarrollar y evaluar modelos de machine learning, específicamente Random Forest y XGBoost, para predecir la productividad agrícola en la región centro de Córdoba. A través de la integración de datos climáticos y edáficos recolectados de múltiples productores y lotes, se busca proporcionar una herramienta precisa y eficiente que permita a los agricultores optimizar la planificación y gestión de sus cultivos.

## **Materiales y Métodos**

Los datos utilizados en este estudio fueron recolectados de 136 productores y 1847 lotes durante 4 campañas de productividad. Estos datos consisten en parámetros climáticos y edáficos. Los datos climáticos incluyen temperatura, precipitación, humedad y evapotranspiración, registrados diariamente a través de la plataforma de OpenWeather. Los datos edáficos comprenden parámetros como pH, capacidad de intercambio catiónico (CIC), materia orgánica (MO), calcio, magnesio, potasio, fósforo, sodio, PSI, Ce, micronutrientes y relaciones de cambio como calcio/magnesio y calcio/potasio, entre otros, fueron tomados utilizando de base ambientaciones realizadas a partir de imágenes NDVI históricas con las cuáles se construyen mapas de ambientes identificando zonas de alta, media y baja productividad usando la *plataforma Campo 360 de Geoagro*. Luego se procede a tomar muestras de suelo con un calador hidráulico CH200 de la empresa *Tornomar* tomando muestras de suelo georreferenciadas en dos estratos, 0 a 20 cm y 20 a 40 cm de profundidad; en el mismo lugar donde se toma la muestra de suelo se realiza una medición de compactación con un penetrómetro digital montado sobre el mismo calador anteriormente mencionado. Una vez recolectadas las muestras de suelo son refrigeradas y enviadas a laboratorio para realizar las determinaciones antes mencionadas.

En el caso de lotes que tienen muestreos en varias campañas se utilizan siempre los mismos puntos georreferenciados para poder realizar comparaciones campaña tras campaña.

Los datos fueron almacenados en archivos Excel para conformar el conjunto de entrenamiento y se procesaron para eliminar valores faltantes. Para cada localidad, se creó un conjunto de testing específico con las mismas variables del conjunto de entrenamiento, actualizadas a la campaña en curso 2024. Una vez generados ambos archivos (entrenamiento y testing), se procedió a efectuar el análisis dentro del entorno de programación Python.

## **Preparación de Datos**

La limpieza de los datos implicó la eliminación de filas con valores faltantes en las columnas más relevantes. Las variables independientes incluyeron parámetros climáticos y edáficos, mientras que la variable dependiente fue la productividad agrícola.

## **Modelos de Machine Learning**

Para este estudio, se implementaron dos modelos de machine learning: Random Forest y XGBoost. A continuación, se detallan los pasos seguidos para la implementación de estos modelos:

Primero, se cargaron los datos de entrenamiento y testing desde archivos Excel. Los datos de entrenamiento se utilizaron para ajustar los modelos, mientras que los datos de testing se emplearon para evaluar el rendimiento de los modelos. La limpieza y preparación de los datos involucró la eliminación de filas con valores faltantes en las columnas clave y la selección de las variables independientes (parámetros climáticos y edáficos) y la variable dependiente (productividad agrícola).

Los datos se dividieron en conjuntos de entrenamiento y prueba utilizando la función `train_test_split` de la biblioteca `sklearn`. Para el modelo Random Forest, se creó un pipeline que incluyó la normalización de los datos con `StandardScaler` y el modelo `RandomForestRegressor`. Este modelo se entrenó utilizando el conjunto de entrenamiento y se realizaron predicciones sobre el conjunto de prueba. El rendimiento del modelo se evaluó utilizando métricas como el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE) y el coeficiente de determinación ( $R^2$ ).

De manera similar, se implementó el modelo XGBoost utilizando un pipeline con `StandardScaler` y `XGBRegressor`. Este modelo también se entrenó y se realizaron predicciones sobre el conjunto de prueba, evaluándose el rendimiento con las mismas métricas (MSE, RMSE y  $R^2$ ). Finalmente, se utilizaron los modelos entrenados para realizar predicciones de productividad futura para el año 2025, utilizando los datos actualizados de las distintas localidades.

## Resultados

El modelo Random Forest mostró un error cuadrático medio (MSE) de 115.10, a raíz del error cuadrático medio (RMSE) de 10.73 y un coeficiente de determinación ( $R^2$ ) de 0.8033. Por otro lado, el modelo XGBoost presentó un MSE de 95.81, un RMSE de 9.78 y un R 2 de 0.829. Los resultados indican que ambos modelos proporcionan predicciones precisas, con un rendimiento superior al del modelo XGBoost.

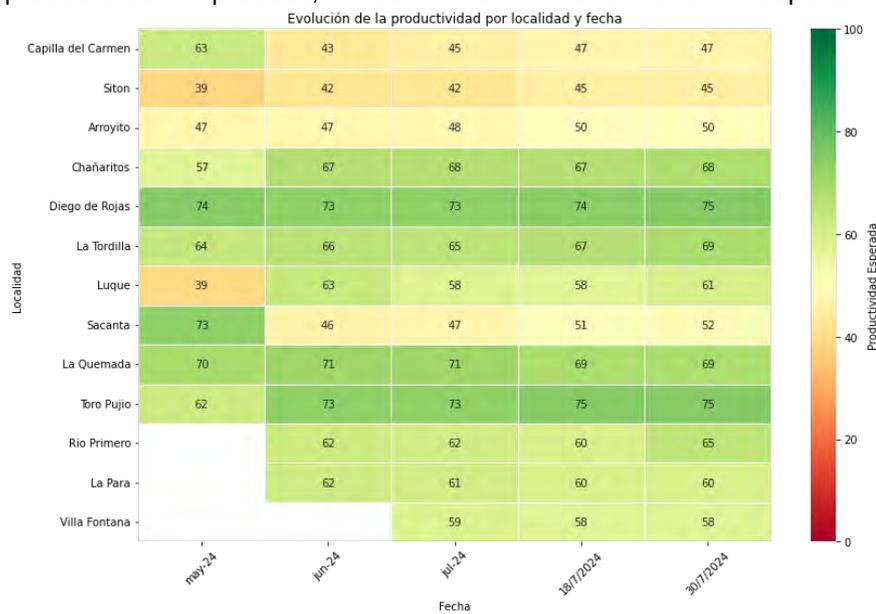


Fig. 1 Evolución de la posible productividad a lograr en la campaña 2024/2025 - con corrección mensual.

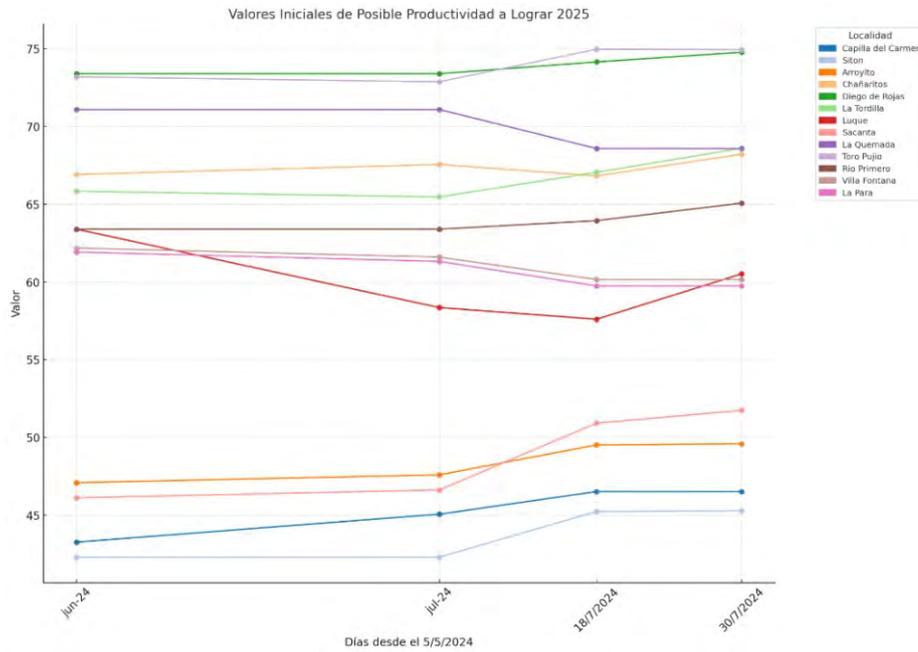


Fig. 2 Evolución de la posible productividad a lograr en la campaña 2024/2025 - con corrección mensual.

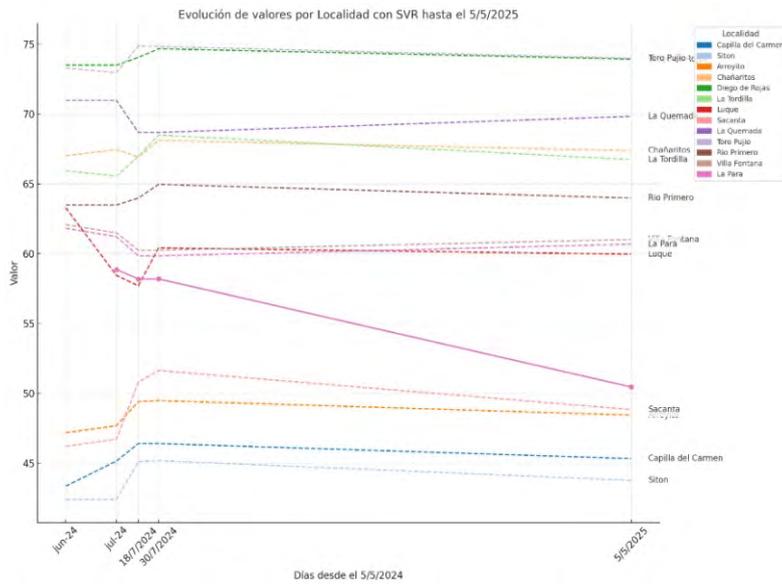


Fig. 3 Evolución de la posible productividad en la campaña 2024/2025 con línea de tendencia al 5/5/2025 utilizando Support Vector Regression (SVR) con un kernel RBF.

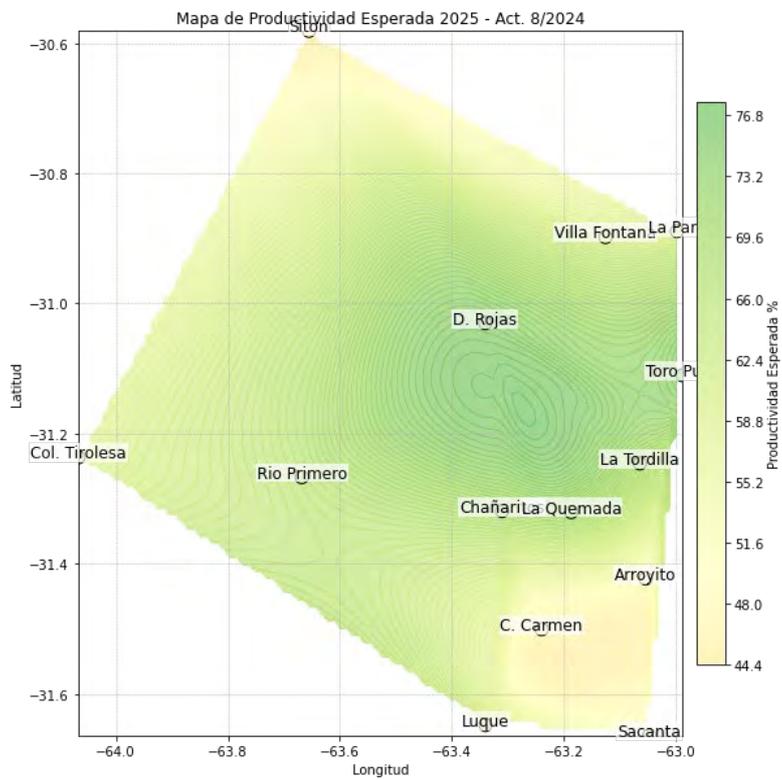


Fig. 4 Mapa de la posible productividad esperada para la campaña 2024/205 por localidad.

Ambos modelos identificaron las variables más importantes para la predicción de la productividad agrícola. Las características más influyentes incluyeron la precipitación y la temperatura en determinados meses, así como algunos parámetros edáficos específicos.

### Top 30 Feature Importance - Random Forest

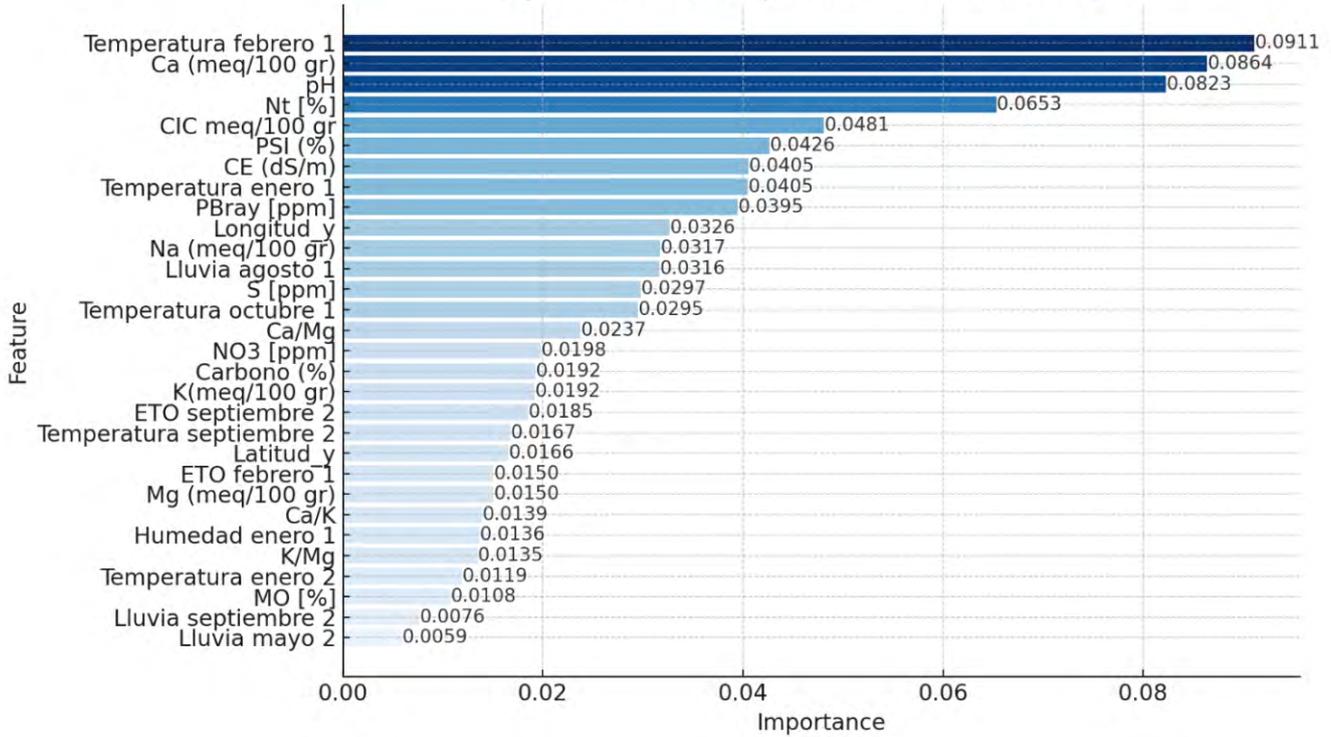


Fig. 5 Se muestra el impacto de las 30 variables mas importantes para el modelo Random Forest de un total de 144 variables.

### Top 30 Feature Importance - XGBoost

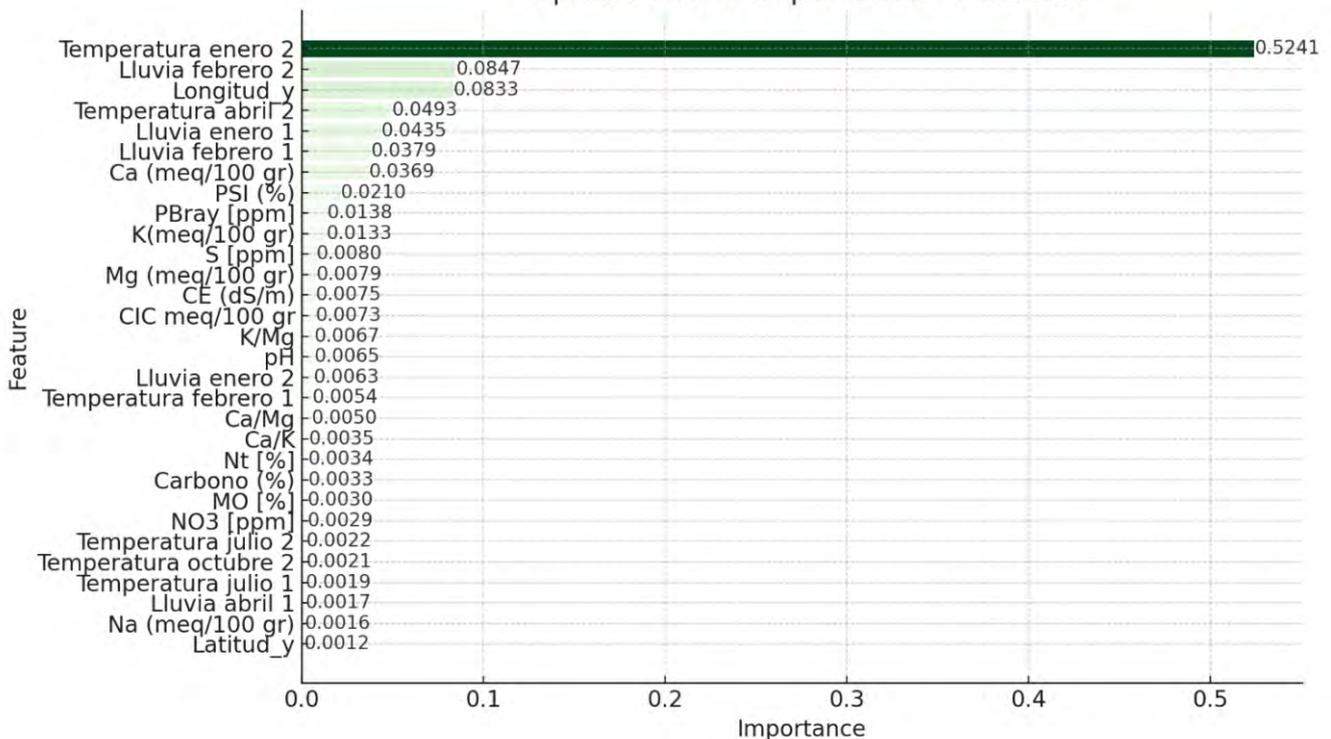


Fig. 6 Se muestra el impacto de las 30 variables mas importantes para el modelo XGBoost de un total de 144 variables.

## Discusión

Los resultados obtenidos demuestran la viabilidad de utilizar modelos de machine learning para predecir la productividad agrícola en la región centro de Córdoba. La capacidad de identificar las variables más influyentes permite a los agricultores centrar sus esfuerzos en los factores que más afectan el rendimiento de los cultivos. Además, el uso de predicciones a futuro facilita la planificación y toma de decisiones, optimizando los recursos y mejorando la eficiencia.

## Conclusiones

Este estudio confirma que los modelos de Random Forest y XGBoost son herramientas efectivas para la predicción de la productividad agrícola. La integración de datos climáticos y edáficos en estos modelos proporciona predicciones precisas, ayudando a los agricultores a tomar decisiones informadas. Futuras investigaciones podrían explorar la inclusión de otros factores, como las fechas de siembra y variedades de los cultivos, para mejorar aún más la precisión de las predicciones.

## Referencias

1. Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. doi:10.1023/A:1010933404324.
2. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). doi:10.1145/2939672.2939785.
3. Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. New York: Springer.
4. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: with Applications in R*. New York: Springer.
5. Zhang, Z. (2016). Introduction to machine learning: K-nearest neighbors. *Annals of Translational Medicine*, 4(11), 218. doi:10.21037/atm.2016.03.37.
6. Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5), 1-26. doi:10.18637/jss.v028.i05.
7. Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 2(3), 18-22.
8. Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
9. Cutler, D. R., Edwards, T. C., Jr., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792.
10. Shaphiro, S. S., & Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4), 591-611.
11. van der Laan, M. J., Polley, E. C., & Hubbard, A. E. (2007). Super Learner. *Statistical Applications in Genetics and Molecular Biology*, 6(1), 25.
12. Caruana, R., & Niculescu-Mizil, A. (2006). An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd International Conference on Machine Learning* (pp. 161-168). ACM.
13. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York: Springer.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Fenotipado con drones en girasol: implementación en resistencia a imidazolinonas

**Domínguez, M.<sup>1\*</sup>; Menes, J.F.<sup>1,2</sup>; Portillo, J.E.<sup>1,3</sup>; Lavandera, J.<sup>1</sup>**

<sup>1</sup>Estación Experimental Agropecuaria Pergamino, Instituto Nacional de Tecnología Agropecuaria. Pergamino, Buenos Aires, Argentina

<sup>2</sup>Cátedra de Genética, Facultad de Agronomía, Universidad de Buenos Aires. Av. San Martín 4453, C1417DSE, Ciudad Autónoma de Buenos Aires, Argentina.

<sup>3</sup>Universidad Nacional del Noroeste de la Provincia de Buenos Aires. Av. Libertad 555, B6000 Junín, Buenos Aires, Argentina

\*dominguez.matias@inta.gob.ar

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** El fenotipado de alto caudal implementando drones con cámaras multiespectrales y sensores térmicos es una herramienta de gran potencial para eficientizar las actividades rutinarias de los programas de mejoramiento. El objetivo de este trabajo fue evaluar la factibilidad del uso de imágenes obtenidas a partir de un dron para el fenotipado de la resistencia a imidazolinonas en girasol. Fueron evaluados 742 genotipos del programa de mejoramiento de girasol de INTA y se incluyeron 182 parcelas testigo. El tamaño de las parcelas fue de un surco de 5 m de longitud. Se realizaron 3 vuelos con un dron DJI Matrice 300, equipado con sensores multiespectral y térmico MicaSense Altum, a una altura de 40 m. El primer vuelo fue realizado 9 días después de aplicado el herbicida y los dos vuelos posteriores fueron realizados 43 y 57 días de la aplicación. De las imágenes obtenidas se extrajeron los valores de reflectancia de las bandas: azul (475 nm), verde (560 nm), rojo (668 nm), borde rojo (717 nm), NIR (840 nm) y la emisividad de la banda térmica (8-14 nm). Fueron evaluados diferentes modelos de Machine Learning para poder predecir el valor fenotípico de cada parcela utilizando 2 escalas de evaluación, con dos y tres categorías fenotípicas. Los resultados presentaron valores de precisión de 0,87 y de 0,68 para las escalas de 2 y 3 clases fenotípicas. Los resultados revelan la capacidad y el potencial que tiene el fenotipado con drones para la resistencia a imidazolinonas en girasol.

**Palabras clave.** Imágenes multiespectrales, machine learning, girasol, índices de vegetación.

## Introducción

La capacidad de fenotipar un gran número de líneas rápidamente e identificar con precisión la mejor progenie es clave para el mejoramiento genético. Sin embargo, el fenotipado sigue siendo en gran medida una actividad artesanal, específica para cada especie, que requiere grandes esfuerzos, tiempo y recursos para poder ser llevado a cabo. Esto hace que el fenotipado sea uno de los principales cuellos de botella para el mejoramiento genético, limitando operativamente y financieramente los estudios genéticos.

Actualmente, las nuevas metodologías de fenotipado de alto caudal, *High Throughput Phenotyping* (HTP) complementan cada vez en mayor medida a las técnicas clásicas de fenotipado y permiten evaluar el comportamiento de las plantas de forma más objetiva y eficiente contribuyendo enormemente a aumentar la ganancia genética de los programas de mejoramiento (Reynolds et al., 2020; Serrano, 2020). En los últimos años, el advenimiento de los drones con sensores RGB, multiespectrales y térmicos ha permitido que programas de mejoramiento de diferentes cultivos y con diversas escalas de trabajo comiencen a incluir e implementar en sus estudios de fenotipado los drones con distintos tipos de sensores.

El análisis de las imágenes es uno de los temas clave para el HTP, en la bibliografía pueden encontrarse una gran variedad de enfoques. Entre estos, las técnicas de *machine learning* es una de las más adoptadas para el análisis de grandes cantidades de datos. Estas técnicas se refieren a un grupo de algoritmos que permiten reconocer patrones presentes en los datos a partir de los cuales se generan modelos que los representan. Estos modelos, permiten predecir información sobre eventos o escenarios que aún no se han observado. El uso de estos enfoques en investigaciones en el área vegetal, ofrece la oportunidad de analizar grandes conjuntos de datos para descubrir patrones de comportamiento observando simultáneamente una combinación de factores en lugar de analizar cada característica de manera individual. Inclusive poder incorporar al modelo, en el caso de análisis de estreses, los efectos integrados de los factores genéticos, agronómicos, económicos, meteorológicos y humanos (Singh et al., 2016).

Actualmente, los híbridos de girasol con resistencia a imidazolinonas cubren la mayor parte de la superficie sembrada con el cultivo en la Argentina. Para los programas de mejoramiento de girasol en Argentina es muy importante la incorporación de la resistencia a esta familia de herbicidas, por lo que el fenotipado de este carácter es una actividad fundamental en el proceso de desarrollo de nuevas líneas *elite* para la formación de híbridos. Este proceso consiste en la aplicación del herbicida en el estado vegetativo de 6 hojas y la posterior evaluación visual del germoplasma para su selección, lo cual conlleva grandes esfuerzos y recursos dependiendo de la cantidad de surcos a evaluar (Breccia et al., 2011).

El objetivo de este trabajo fue evaluar la factibilidad del uso de imágenes obtenidas a partir de un dron para el fenotipado de la resistencia a imidazolinonas en girasol a los fines de considerar la utilidad de esta técnica para su implementación en los programas de mejoramiento genético de girasol.

## Materiales y métodos

El experimento fue realizado en la EEA Pergamino (33° 57' 02" S, 60° 34' 08" O) en la campaña 2023/24, en un diseño aumentado en donde los testigos resistentes y susceptibles al herbicida Imazapir fueron distribuidos sistemáticamente. Fueron evaluados 742 genotipos del programa de mejoramiento de girasol de INTA y se incluyeron 182 parcelas testigo, incluyendo un 50 % de parcelas resistentes y un 50 % de parcelas susceptibles. El tamaño de las parcelas fue de un surco de 5 m de longitud. Se realizaron 3 vuelos con un dron DJI Matrice 300, equipado con sensores multiespectral y térmico MicaSense Altum, a una altura de 40 m. El tamaño del píxel fue de 1,84 cm/píxel para las bandas que van desde el azul hasta el infrarrojo cercano, mientras que para la banda térmica fue de 6,41 cm/píxel.

El primer vuelo fue realizado 9 días después de aplicado el herbicida y los dos vuelos posteriores fueron realizados 43 y 57 días de la aplicación.

El procesamiento de las imágenes fue realizado con el software Agisoft Metashape para obtener los ortomosaicos de cada uno de los vuelos. Para el análisis de las imágenes se utilizó el software QGIS (Team QGIS, 2021) junto con el complemento FieldImageR (Matias et al., 2020). Antes de la extracción de los datos, se eliminaron los píxeles correspondientes al suelo y vegetación espontánea mediante enmascaramiento utilizando el índice *Overall Hue Index* (HUE) y un método de clasificación supervisada con *Random Forest* (RF). Esto permitió aislar únicamente la reflectancia y emitancia de las plantas de girasol. Para la extracción de datos a nivel de parcela, se generaron polígonos de 0,27 x 5 m, con un total de 6670 píxeles por parcela. Se calculó la media de los valores de reflectancia para las bandas: azul (475 nm), verde (560 nm), rojo (668 nm), borde rojo (717 nm), NIR (840 nm), y la emisividad de la banda térmica (8-14  $\mu\text{m}$ ). A partir de estos datos se generaron los índices de vegetación: *Normalized Difference Vegetation Index* (NDVI), *Normalized Difference Red Edge index* (NDRE) y *Green Normalized Difference Vegetation Index* (GNDVI) para cada uno de los vuelos realizados utilizando la extensión del paquete FieldImageR (Matias et al., 2020) para QGIS.

La evaluación fenotípica visual a campo fue realizada en fechas coincidentes con los vuelos realizados. Se utilizó una escala de 4 valores, siendo el valor 0 plantas sin síntomas, el valor 1 con leves síntomas de clorosis, el valor 2 con síntomas de clorosis y necrosis y el valor 3 plantas totalmente muertas por la exposición al herbicida. A los fines de evaluar la capacidad de los modelos predictivos, se transformaron las categorías fenotípicas a escalas de dos o tres valores, para poder evaluar la capacidad de predicción de las categorías de resistencia intermedia.

Fueron implementados modelos predictivos basados en técnicas de *machine learning* que utilizan los valores de los índices de vegetación y las bandas espectrales originales para poder predecir las clases fenotípicas de resistencia a imidazolinonas a nivel de parcela. Para comenzar el análisis, se dividió la matriz de datos total en una denominada matriz de entrenamiento que incluyó el 80 % de la totalidad de los datos y en una matriz de prueba que incluyó al 20 % de la matriz original. La primera matriz fue empleada para el entrenamiento de los modelos y la segunda para evaluar la precisión en la predicción de las clases fenotípicas mediante la validación cruzada de las clases fenotípicas predichas y las definidas por la evaluación a campo. Los modelos implementados para realizar las predicciones fueron: *Classification and Regression Trees* (CART), *Support Vector Machine* (SVM), *Linear Discriminant Analysis* (LDA), RF, *eXtreme Gradient Boosting* (XGB), *Averaged Neural Network* (avNNET) y *K-Nearest Neighbor* (KNN) utilizando el paquete de R CARET (Kuhn, 2020).

Para entrenar y comparar los modelos utilizados se empleó la técnica *K-Fold Cross Validation*. Ésta consiste en dividir al conjunto de entrenamiento en  $k$  subconjuntos y, al momento de realizar el entrenamiento, se toma cada  $k$  subconjunto como conjunto de prueba del modelo, mientras que el resto de los datos se utiliza como conjunto de entrenamiento. Este proceso se repite  $k$  veces, y en cada iteración se selecciona un conjunto de prueba diferente, mientras los datos restantes se emplean como conjunto de entrenamiento (Tong & Nikoloski, 2021). El número de subconjuntos utilizados fue de 10. Una vez finalizadas las iteraciones, se calculó la precisión media utilizando la fórmula:

$$\text{Precisión} = \frac{\text{Clases predichas correctamente}}{\text{Clases predichas correctamente} + \text{Clases predichas incorrectamente}} \times 100 \quad (1)$$

Los dos modelos con mayores valores de precisión fueron utilizados para predecir el 20 % restante del conjunto de prueba con el propósito de evaluar la incidencia de posibles sobreajustes en los modelos y la correspondiente precisión de los mismos en un conjunto de datos que no fue utilizado para el entrenamiento.

## Resultados

A partir de la información obtenida de las imágenes de cada uno de los tres vuelos, el proceso de procesamiento de estas y el fenotipado tradicional a campo de la respuesta de los genotipos de girasol a la aplicación del herbicida fueron desarrollados los modelos predictivos citados en la sección de materiales y métodos. La Figura 1 muestra las diferencias entre un surco de girasol resistente y uno de girasol susceptible al herbicida aplicado. Las Figuras 2 y 3 muestran los valores obtenidos de precisión después del proceso de validación cruzada con el conjunto de entrenamiento para cada uno de los modelos implementados utilizando dos y tres categorías fenotípicas.



Figura 1. Plantas de girasol resistente (izquierda) y susceptible (derecha) a imidazolinonas.

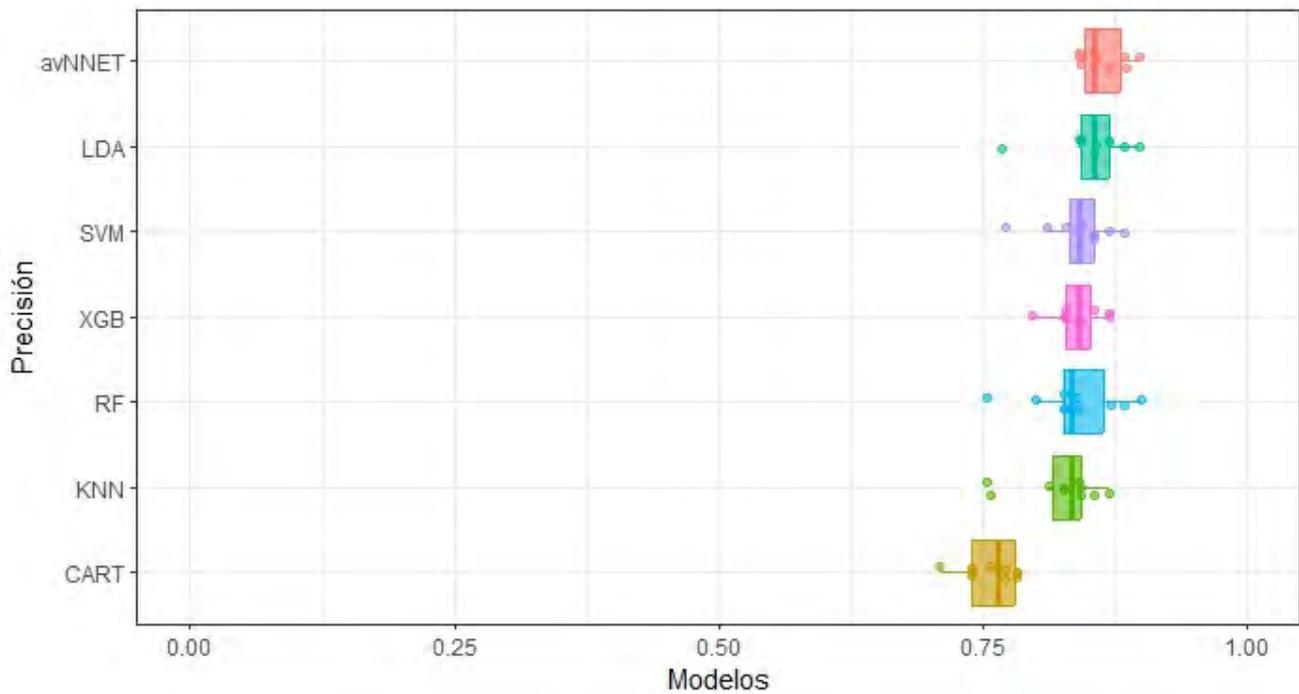


Figura 2. Precisión de los modelos de *machine learning* implementados con dos clases fenotípicas.

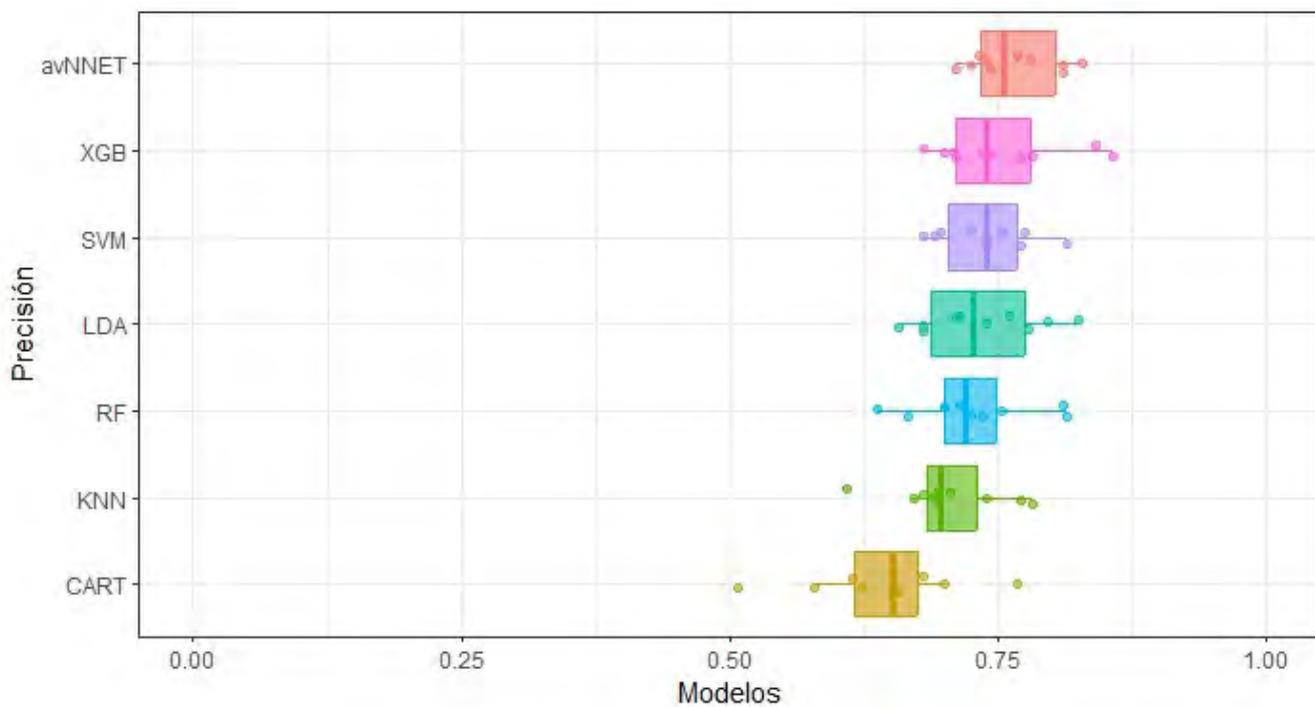


Figura 3. Precisión de los modelos de *machine learning* implementados con tres clases fenotípicas.

Las Figuras 2 y 3 muestran que los modelos con mayor precisión fueron para el caso de la escala fenotípica de dos clases los modelos avNNET y LDA, y para el caso de la escala de tres clases los

modelos avNNET y XGB. Asimismo, de estas Figuras se desprende que los modelos funcionaron mejor para predecir dos clases fenotípicas en lugar de tres clases con valores de precisión de 0.84 y de 0.75 respectivamente.

Con el objetivo de realizar una segunda validación para evaluar posibles sobreajustes, los dos mejores modelos fueron seleccionados para predecir el 20 % de los datos originales que no fueron utilizados en el proceso de entrenamiento y evaluación de los modelos. Las Tablas 1 y 2 muestran las matrices de confusión obtenidas para ambos modelos utilizando las clases fenotípicas de tres y dos clases.

Tabla 1. Matrices de confusión para los modelos avNNET y XGB para tres clases fenotípicas.

avNNET				XGB			
Referencia				Referencia			
Predicción	Resistencia	Intermedia	Susceptible	Predicción	Resistencia	Intermedia	Susceptible
Resistencia	64	27	1	Resistencia	59	31	1
Intermedia	11	23	2	Intermedia	20	14	3
Susceptible	2	0	3	Susceptible	2	0	5

Tabla 2. Matrices de confusión para los modelos avNNET y LDA para dos clases fenotípicas.

avNNET			LDA		
Referencia			Referencia		
Predicción	Resistente	Susceptible	Predicción	Resistente	Susceptible
Resistente	119	8	Resistente	117	8
Susceptible	8	8	Susceptible	10	8

Las matrices de confusión permiten diferenciar como los modelos predicen cada una de las clases, pudiéndose ver como en el caso de las tres clases fenotípicas la clase intermedia es la que tiene mayor error y es la más difícil de predecir por los modelos. La precisión obtenida para los modelos avNNET y XGB para las tres clases fenotípicas fueron de 0.68 y 0.58 respectivamente. Para las dos clases fenotípicas la precisión fue de 0.89 y 0.87 para los modelos avNNET y LDA. Los valores de precisión alcanzados en esta segunda validación permiten ver que la precisión se mantuvo utilizando nuevos datos que no habían sido utilizados para el entrenamiento de los modelos.

Asimismo, fueron evaluados modelos implementando una menor cantidad de información, utilizando solamente la información perteneciente al primer vuelo. Los valores de precisión obtenidos fueron de 0.87 para ambos modelos avNNET y LDA para las dos clases fenotípicas. Estos resultados muestran que la inclusión de vuelos posteriores a la primer semana post aplicación del herbicida no aportó mejoras en la precisión de los modelos.

## Conclusiones

Los resultados de este trabajo muestran que los modelos de *machine learning* empleados utilizando la información obtenida de las imágenes multiespectrales y del sensor térmico a partir de los tres vuelos realizados con el dron permitieron predecir la resistencia de genotipos de girasol a imidazolinonas dispuestos en parcelas de un sólo surco de 5 m de largo. Los modelos presentaron mayor precisión en la predicción de dos clases fenotípicas (resistente y susceptible) en lugar de tres clases fenotípicas (resistente, intermedia y susceptible). La limitada cantidad de parcelas con comportamiento intermedio frente al herbicida pudo haber influido en la menor precisión de dicha clase. Asimismo, a los fines de



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



ajustar la técnica, resultado muy importante la identificación de que vuelos posteriores a los 7 días de aplicado el herbicida no generaron un incremento en la precisión de la predicción de los modelos.

Los resultados obtenidos en este trabajo sirven como prueba de concepto para el uso e implementación de esta técnica y muestran el potencial y las ventajas que aportarían en capacidad y velocidad de fenotipado para la resistencia a imidazolinonas en girasol. Futuros estudios se planean a los fines de ajustar la técnica y evaluar la misma para la caracterización de híbridos de girasol en parcelas de mayor superficie, lo cual se espera incluso una mayor precisión en la predicción y una mejor discriminación de las clases intermedias de resistencia.

#### Agradecimientos

Los autores agradecen al equipo de ecofisiología de la EEA Pergamino por la posibilidad de poder usar el dron para la realización de estos estudios, al proyecto estructural I111 de la cartera de proyectos 2023 de INTA por el financiamiento. Asimismo, a los colaboradores del sector girasol Gabriel Colacilli, Carlos Baroni y Renzo Piazza por la preparación y mantenimiento del campo experimental.

## Referencias

- Breccia, G., Vega, T., Nestares, G., Mayor, M. L., Zorzoli, R., & Picardi, L. (2011). Rapid test for detection of imidazolinone resistance in sunflower (*Helianthus annuus* L.). *Plant Breeding*, *130*(1), 109–113. <https://doi.org/10.1111/J.1439-0523.2009.01756.X>
- Kuhn, M. (2020). *caret: Classification and Regression Training* (R package version 6.0-86). <https://cran.r-project.org/package=caret>
- Matias, F. I., Caraza-Harter, M. V., & Endelman, J. B. (2020). FIELDimageR: An R package to analyze orthomosaic images from agricultural field trials. *The Plant Phenome Journal*, *3*(1), e20005. <https://doi.org/10.1002/ppj2.20005>
- Reynolds, M., Chapman, S., Crespo-Herrera, L., Molero, G., Mondal, S., Pequeno, D. N. L., Pinto, F., Pinera-Chavez, F. J., Poland, J., Rivera-Amado, C., Saint Pierre, C., & Sukumaran, S. (2020). Breeder friendly phenotyping. *Plant Science*, *295*(December 2019), 110396. <https://doi.org/10.1016/j.plantsci.2019.110396>
- Serrano, I. B. (2020). *High-throughput field phenotyping using a drone with RGB imagery Exploiting the spectral , spatial* (Issue October). Universidad de KU Leuven.
- Singh, A., Ganapathysubramanian, B., Singh, A. K., & Sarkar, S. (2016). Feature Review Machine Learning for High-Throughput Stress Phenotyping in Plants. *Trends in Plant Science*, *21*(2). <https://doi.org/10.1016/j.tplants.2015.10.015>
- Team QGIS. (2021). *QGIS geographic information system. Open Source Geospatial Found Proj.* <https://www.qgis.org/en/site/index.html>
- Tong, H., & Nikoloski, Z. (2021). Machine learning approaches for crop improvement: Leveraging phenotypic and genotypic big data. *Journal of Plant Physiology*, *257*, 153354. <https://doi.org/10.1016/J.JPLPH.2020.153354>

## Comparación de tratamientos en ensayos sin repeticiones cosechados con monitores de rendimiento

Córdoba M.<sup>1,2</sup>, Paccioretti P.<sup>1,3</sup>, Balzarini M.<sup>1,2</sup>

<sup>1</sup>Universidad Nacional de Córdoba, Facultad de Ciencias Agropecuarias, Estadística y Biometría.

<sup>2</sup>Unidad de Fitopatología y Modelización Agrícola (UFyMA), INTA □ CONICET. Córdoba, Argentina.

<sup>3</sup>Departamento de Agronomía y Horticultura, Universidad de Nebraska □ Lincoln, USA.

Trabajo presentado al  
**20° Congreso de Agricultura de Precisión**  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

**Resumen.** Los monitores de rendimiento permiten coleccionar numerosos datos georreferenciados en la experimentación en campo de productores (OFE), incluso en ensayos con una única parcela por tratamiento. En algunas ocasiones los tratamientos no están repetidos (existe una única parcela o franja por tratamiento) y los datos espaciales dentro de cada parcela no se consideran repeticiones porque están correlacionados espacialmente, y sobreestiman el tamaño de muestra por tratamiento. Aquí implementamos un nuevo método (OFE-mean test) que provee significancia estadística para la diferencia de medias de rendimiento entre tratamientos no repetidos. OFE-mean test incluye: 1) cálculo del tamaño de muestra efectivo (ESS) según la estructura espacial subyacente en los datos de rendimientos, 2) ANOVA permutacional utilizando muestras aleatorias según ESS y 3) Obtención de significancia estadística (valores p) mediante la repetición del ANOVA con distintas muestras. El método se aplicó en ensayos de maíz con dos tratamientos bajo dos escenarios, con y sin diferencias entre tratamiento. OFE-mean test reporto diferencias estadísticamente significativas con diferencias de media del 6% o más entre tratamientos. Tras eliminar los efectos del tratamiento, como era esperado OFE-mean test no reporto diferencias estadísticas. El método fue programado y se encuentra disponible como paquete de R ([https://github.com/PPaccioretti/OFE-mean test](https://github.com/PPaccioretti/OFE-mean-test)).

**Palabras clave.** Datos georreferenciados, Diseño en franjas sin repeticiones, Parcelas demostrativas, Análisis de Varianza por permutación, Software.

### Introducción

Tradicionalmente, los experimentos agronómicos se han llevado a cabo en campos experimentales controlados, donde los diseños experimentales incluían parcelas pequeñas, un número limitado de repeticiones y un dato y pocos datos por parcela. Los resultados de estos ensayos a nivel de parcela no siempre son fácilmente extrapolables a la escala del lote (Kravchenko et al., 2017). Con la adopción generalizada de las tecnologías de agricultura de precisión (AP), como los monitores de rendimiento y los aplicadores de tasa variable, se ha abierto la posibilidad de realizar experimentos a gran escala en campos comerciales con la participación activa de los agricultores (Bullock et al., 2020). La experimentación en campo de productores (OFE, por sus siglas en inglés) permite evaluar la respuesta de los cultivos a diferentes tratamientos, proporcionando información específica para cada lote. Se han utilizado numerosos diseños experimentales para OFE (Alesso et al., 2019). Aunque los principios fundamentales de replicación, aleatorización y bloqueo (Federer, 1955) siguen siendo esenciales en la investigación en AP (Piepho et al., 2011), cuando no se dispone de maquinaria para manejar tasas variables, suelen realizarse ensayos en franjas no repetidas. El uso de monitores de rendimiento ha permitido la recolección de datos en numerosos puntos dentro de cada lote, ofreciendo información detallada de la respuesta sitio-específica de los cultivos y de la variabilidad espacial del rendimiento. La

multiplicidad de datos espaciales generados por el sensoramiento hace que los ensayos con diseños en franjas únicas a lo largo del lote, conocidos comúnmente como parcelas demostrativas, aun cuando no tienen repeticiones de cada tratamiento, puedan ser analizados estadísticamente. En estos ensayos, el lote se divide en grandes áreas o parcelas (tratamiento(s) y control) que no se repiten, pero de las cuales se recopilan muchos datos georreferenciados. Este gran volumen de datos dentro de las parcelas puede utilizarse para obtener medias y errores estándares de tratamiento ajustados por variación espacial y comparar las medias de los tratamientos.

Bajo limitada disponibilidad de maquinaria de AP, los ensayos de tratamiento en franjas únicas atravesando la variabilidad del lote representan una opción de experimentación más sencilla de implementar que un ensayo con múltiples repeticiones (Lawes y Bramley, 2012). En otros escenarios, los agricultores pueden querer comprender cómo responden ciertas zonas del lote a un tratamiento específico, lo que puede llevarlos a realizar ensayos que consideren los efectos de las zonas dentro del diseño experimental. Estos ensayos experimentales implican agrupar la variabilidad dentro del lote en zonas con características similares, que se presume tendrán respuestas comparables a los tratamientos y, por lo tanto, requieren estrategias de manejo similares. Aunque muchos ensayos en AP están basados en la zonificación del lote para controlar la variabilidad causada por factores distintos a los tratamientos, en este estudio utilizamos como ejemplo la situación de parcelas demostrativas, donde el lote no se ha zonificado y se ha dividido en dos áreas: una que recibió un nuevo manejo (tratamiento) y la otra adherida a las prácticas agrícolas estándar (control). Se supone que el principal objetivo del análisis estadístico es comparar las medias de rendimiento entre ambas áreas del lote con el fin de decidir el tratamiento más adecuado para el lote.

Es importante destacar que, si bien la comparación de medias también es la motivación para realizar experimentos comparativos con parcelas pequeñas, la metodología utilizada en los ensayos con repeticiones y un dato por parcela no puede aplicarse directamente a ensayos en grandes parcelas sin repeticiones. En ensayos con parcelas pequeñas, los efectos del tratamiento suelen asumirse como espacialmente invariantes, lo que es una suposición poco realista para ensayos en grandes parcelas (Gotway Crawford et al., 1997). Con grandes parcelas o franjas, se espera que haya autocorrelación entre las observaciones dentro de la parcela, lo que significa que el número total de puntos de datos registrados sobreestima el número de observaciones independientes adecuadas para el análisis de la respuesta (Whelan et al., 2012). Por lo tanto, es necesario utilizar modelos estadísticos que puedan tener en cuenta la variación espacial en los datos usados para estimar los efectos del tratamiento (Stefanova et al., 2023). Analizar datos de grandes parcelas sin repeticiones plantea varios desafíos debido a la variabilidad espacial de la variable de respuesta influenciada por la autocorrelación espacial. Esta variación a menudo no está relacionada con el tratamiento bajo investigación y con frecuencia supera la variación atribuible a los efectos del tratamiento (Evans et al., 2020). En este estudio, utilizamos un método estadístico basado en ANOVA por permutaciones para apoyar inferencias específicas del lote a partir de datos georreferenciados dentro del contexto de ensayos sin repeticiones (Córdoba et al., 2024). El método, denominado *OFE-mean test*, permite evaluar la significancia estadística de las diferencias de medias entre tratamientos y puede extenderse para comparar más de dos medias ajustando los valores p por multiplicidad (Benjamini & Hochberg, 1995).

## Materiales y Métodos

### Datos

Se utilizaron datos de tres ensayos de maíz sin repeticiones, ubicados en Córdoba, Argentina. En cada ensayo se emplearon diseños de franjas que atraviesan el lote para capturar la variabilidad potencial de la respuesta dentro del lote, donde se delimitaron dos grandes áreas: tratamiento y control (sin tratamiento). Uno de los ensayos (F1) se realizó bajo riego, mientras que los demás (F2 y F3) fueron en seco (Tabla 1). En la Figura 1 se presentan los datos promedio de rendimiento en una grilla de 10

x 10 m para cada ensayo. En F1, se evaluó el efecto de un fertilizante arrancador, utilizando dos franjas: Tratado, con una aplicación de 100 kg ha<sup>-1</sup> [21-17-3 + 1% MgO + 5% S + 0.1% Zn], y Control, sin fertilizante (0 kg ha<sup>-1</sup>). Cada franja ocupó 1.1 ha en un lote de 34 ha. En F2, se evaluó el impacto de la fertilización con fósforo (P) aplicado al voleo. La franja tratada recibió superfosfato a tasas de 250 a 500 kg ha<sup>-1</sup> [0-21-0], mientras que la franja de control no recibió P (0 kg ha<sup>-1</sup>). Cada franja ocupó 2.2 ha en un lote de 100 ha. En F3, el ensayo se centró en el efecto de la aplicación foliar de zinc en la etapa de crecimiento V4. La franja tratada recibió 2 L ha<sup>-1</sup> (700 g L<sup>-1</sup>) de zinc, mientras que la franja de control no recibió zinc (0 L ha<sup>-1</sup>). Cada franja ocupó 2 ha (500 m de largo x 40 m de ancho) en un lote de 68 ha.

Table 1. Características principales de tres ensayos sin repeticiones realizados para evaluar los efectos de tratamientos bajo un diseño de franja única.

Ensayo	Superficie Lote (ha)	Franja	Superficie Franja (ha)	# datos	Rendimiento Promedio (t ha <sup>-1</sup> )	Variabilidad Rendimiento (%)
F1	34	Control	1.1	728	11.16	11
		Tratamiento	1.1	697	11.81	10
F2	100	Control	2.6	1499	4.81	22
		Tratamiento	2.6	1571	5.31	18
F3	68	Control	2.0	1008	9.88	15
		Tratamiento	2.0	989	9.80	18

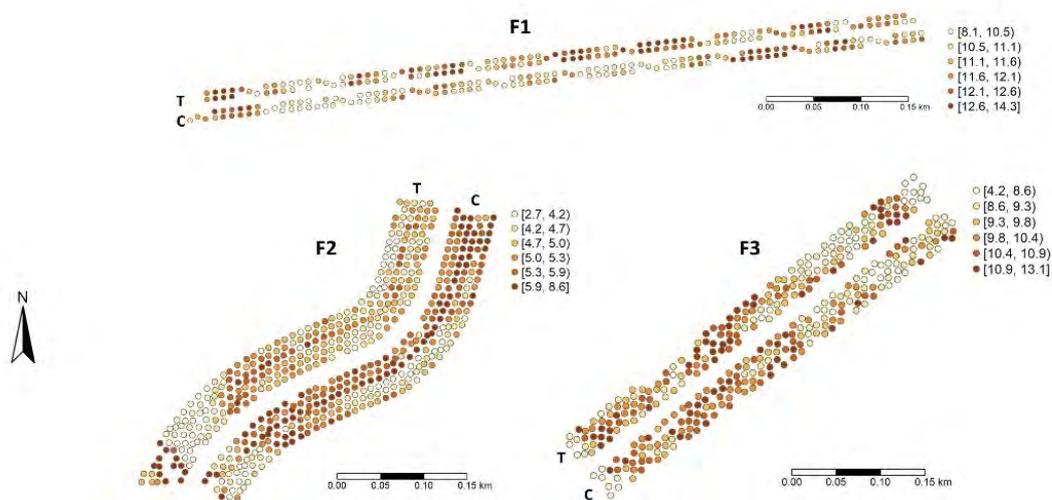


Figura 1. Datos de rendimiento de maíz (t ha<sup>-1</sup>, promedio de cada celda de la cuadrícula de 10 x 10 m) para dos franjas (C: control, T: tratamiento) en tres lotes (F1, F2 y F3).

## Metodología de Análisis

### Depuración de datos

Los datos de monitor de rendimiento para cada ensayo y franja fueron depurados siguiendo el protocolo propuesto por Vega et al. (2019). Primero, los datos fueron sometidos a verificaciones de restricciones dentro de umbrales de sensibilidad predefinidos para eliminar observaciones que cayeran fuera del patrón o distribución esperados del conjunto de datos. Luego, se eliminaron los valores de rendimiento que excedían la media  $\pm$  3 desviaciones estándar (*outliers* globales). Posteriormente, se identificaron y

eliminaron *outliers* espaciales utilizando el Índice de Autocorrelación Espacial Local de Moran (Anselin 1995) y el Diagrama de Dispersión de Moran (Anselin 1996).

#### Creación de Grilla

Se generó una grilla regular de 10 m × 10 m sobre las franjas bajo análisis. Esta grilla se superpuso a los datos puntuales del mapa de rendimiento, asociando cada punto georreferenciado con su celda correspondiente en la grilla. Se calculó la mediana del rendimiento, descartando las celdas vacías o aquellas con menos de cinco puntos de datos.

#### Cálculo del Tamaño de Muestra Efectivo (ESS)

Se calculó el ESS utilizando la Ecuación 1 propuesta por Griffith (2005). El ESS representa el número de observaciones independientes ( $n^*$ ). En ausencia de autocorrelación espacial,  $n^*$  es igual al tamaño de muestra original ( $n$ ). Para cuantificar la magnitud de autocorrelación espacial se estimó el parámetro  $\rho$  (Li et al., 2007) a partir de los residuos de un ANOVA a una vía de clasificación, ajustado a las medianas de las celdas, con el fin de eliminar el efecto del tratamiento.

#### ANOVA Permutacional en Muestras Aleatorias

Se realizó un muestreo aleatorio de celdas de la grilla sin reemplazo según el ESS. Los datos de rendimiento de ambas franjas (tratamiento y control) se utilizaron para realizar un ANOVA permutacional (Frossard y Renaud 2021), que incluyó 2000 iteraciones. Este procedimiento generó un valor-p para la comparación de medias de las franjas.

#### Distribución Empírica del Valor p

El ANOVA permutacional se repitió en 200 muestras aleatorias de celdas de la grilla, siguiendo el mismo procedimiento de muestreo. Los valores-p resultantes se recopilaron para generar una distribución empírica. Finalmente, se calculó la mediana de estos valores-p, la cual se asocia a la hipótesis que prueba el efecto del tratamiento.

#### Implementación en R

La metodología propuesta se encuentra disponible en el paquete de R que denominamos *ofemeanest* el cual puede descargarse desde: <https://github.com/PPaccioretti/OFE-mean test>

#### Validación del Protocolo

Se evaluó el desempeño del método para cada ensayo bajo dos escenarios: uno que representa el caso con diferencias en las medias de rendimiento entre tratamientos (escenario  $H_1$ ) y otro sin diferencias en las medias de rendimiento entre las franjas del ensayo (escenario  $H_0$ ). El método se aplicó utilizando los rendimientos originales y los residuos de rendimiento ( $Rinde^*$ ), que es el rendimiento original menos el efecto del tratamiento estimado.

## Resultados

La distribución empírica de los rendimientos en cada ensayo se muestra en la Figura 2. Las diferencias en rendimiento entre las franjas tratadas y sus controles variaron entre los lotes. Se observaron cambios en el nivel de la media de la distribución en dos de los tres ensayos. En F1 y F2, el tratamiento tuvo rendimientos superiores a los de la franja de control. La significancia estadística de las medias de rendimiento obtenidas utilizando *OFE-mean test* se muestra en la Tabla 2. Para F1 las diferencias entre tratamiento y control fueron estadísticamente significativas ( $p=0.02975$ ). La aplicación del fertilizante arrancador en maíz resultó en un aumento de rendimiento de  $0.70 \text{ t ha}^{-1}$ , representando una diferencia del 6.2% en comparación con el control. En F2, las diferencias también fueron significativas ( $p=0.0045$ ), la fertilización con P mostró una diferencia del 11% en comparación con el control. En el campo F3, el método evaluado no detectó diferencias entre la aplicación foliar de zinc y el control (diferencias

menores al 1.5%). Cuando se realizaron comparaciones dentro de los mismos lotes utilizando el rendimiento ajustado (Rinde\*), que representa el rendimiento observado después de eliminar el efecto del tratamiento, *OFE-mean test* no mostró diferencias estadísticamente significativas ( $p > 0.05$ ). La relación entre la magnitud de la estructura espacial y el ESS se observa también en la Tabla 2. A medida que aumentó la estructura espacial, el ESS disminuyó. Por ejemplo, con un Rho de 0.65, el ESS representó el 18% del tamaño total de la muestra, pero con un Rho menor (0.55), el ESS fue el 25% del tamaño original de la muestra.

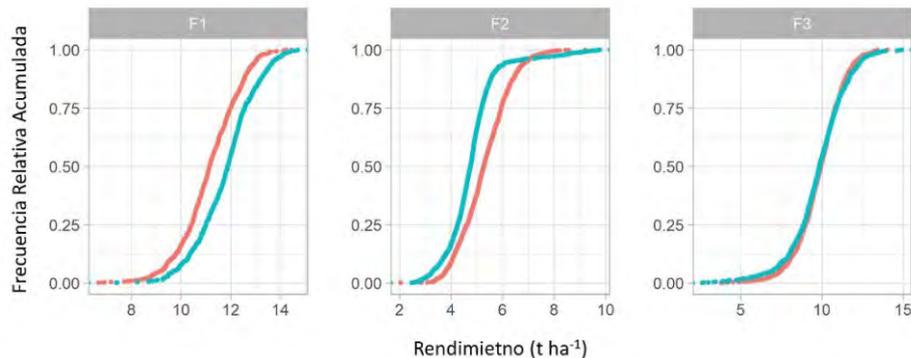


Figura 2. Función de distribución empírica de los rendimientos en tres ensayos de maíz (F1, F2 y F3).

Tabla 2. Comparación de medias de rendimiento utilizando *OFE-mean test* en tres ensayos de maíz.

Ensayo	Hiperparámetros <i>OFE-mean test</i>			Rendimiento Promedio ( $t\ ha^{-1}$ )		p-valor <sup>2</sup>
	Celdas (#)	Estructura Espacial (Rho <sup>1</sup> )	Tamaño Efectivo Muestra (n*)	Tratamiento	Control	
F1	289	0.55	73	11.91	11.21	0.02975
F2	554	0.65	99	5.28	4.76	0.00450
F3	375	0.62	75	9.77	9.91	0.49125

<sup>1</sup>Rho=magnitud de la autocorrelación espacial (Li et al., 2007).

<sup>2</sup>Valor-p permutacional.  $p < 0.05$  indica diferencias estadísticamente significativas entre el tratamiento y el control.

## Discusión

Los ensayos agronómicos realizados en entornos agrícolas que incluyen AP son fundamentales ya que proporcionan a los agricultores conocimientos específicos de los lotes para optimizar las estrategias de manejo de los cultivos y maximizar los beneficios del manejo sitio específico. Entre los diseños experimentales comúnmente utilizados en AP, una de las características más recomendadas es incluir un número adecuado de repeticiones para los tratamientos evaluados, lo cual es factible cuando los productores disponen de tecnología avanzada, como la aplicación variable de insumos. Sin embargo, en muchos casos, los productores solo cuentan con monitores de rendimiento. En estas circunstancias, la evaluación de los tratamientos con franjas únicas que atraviesan el lote se presenta como un diseño potencial para comparar los efectos de los tratamientos y determinar prácticas de manejo aplicables al lote en el que se realiza el ensayo.

En este trabajo, se emplea una estrategia alternativa para analizar datos de rendimiento en ensayos sin repeticiones. Se requiere que el dato sea medido con monitores de rendimiento para obtener múltiples puntos georreferenciados dentro de cada parcela del ensayo. A través del método propuesto, que se basa en el muestreo aleatorio de datos de rendimiento con un ESS combinado con un ANOVA permutacional, se pudo evaluar la diferencia estadística entre tratamientos. Se asume que las franjas

del ensayo atraviesan el lote capturando la variabilidad del mismo, dado que el alcance de la inferencia es el lote en el que se lleva a cabo el ensayo.

El método *OFE-mean test* se aparta de los enfoques convencionales basados en modelos ANOVA donde se necesita la presencia de repeticiones. Este método es particularmente relevante para ensayos de franjas largas, donde la ausencia de repeticiones y las suposiciones de independencia espacial en los efectos del tratamiento resultan poco realistas. Al considerar la autocorrelación espacial y la variabilidad inherente en los rendimientos, *OFE-mean test* proporciona un análisis más preciso y robusto que el ANOVA clásico para datos independientes. El desafío en la AP radica en realizar ensayos a campo y proporcionar a los agricultores datos transparentes y robustos que puedan interpretarse fácilmente y que contribuyan a optimizar el manejo del mismo (Lawes and Bramley, 2012). El método *OFE-mean test* brinda información valiosa sobre la probabilidad de encontrar diferencias entre tratamientos que no son debidas al azar.

Aunque el enfoque metodológico ofrece una solución prometedora para la comparación de medias de rendimiento en ensayos sin repeticiones, existen varias áreas para investigaciones futuras y mejoras metodológicas. Por ejemplo, la inclusión de conjuntos de datos más diversos y extensos de diferentes contextos agrícolas podría mejorar la robustez y generalización del método. *OFE-mean test*, aunque inicialmente fue diseñado para analizar datos de rendimiento, también puede aplicarse a otros datos georreferenciados como por ejemplo datos de conductividad eléctrica aparente para inferir cambios de manejo específicos dentro del lote. El método se puede ampliar para comparar más de dos tratamientos o combinar el factor evaluado con ZM previamente delineadas. En experimentos de respuesta a nutrientes, el método puede facilitar medias ajustadas para derivar funciones de respuesta específicas.

## Conclusiones

Este trabajo se utiliza un método estadístico alternativo (*OFE mean-test*) para evaluar la significancia estadística de las diferencias de medias entre parcelas no repetidas dentro de un lote que han sido medidas intensivamente en sitios georreferenciados. El alcance de las inferencias sobre los efectos del tratamiento se limita al lote donde se realizó el ensayo como es habitual en AP.

## Agradecimientos

A la Agencia Nacional de Promoción Científica y Tecnológica de Argentina (ANPCyT-PICT 2021-0682, PICT 2022-0682), al Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET) y a la Secretaría de Ciencia y Tecnología de la Universidad Nacional de Córdoba (UNC) por apoyar esta investigación. También agradecemos al personal técnico de Experta AGD por su ayuda en la recolección de los datos experimentales.

## Referencias

- Alesso, C. A., Cipriotti, P. A., Bollero, G. A., & Martin, N. F. (2019). Experimental Designs and Estimation Methods for On-Farm Research: A Simulation Study of Corn Yields at Field Scale. *Agronomy Journal*, 111(6), 2724–2735. <https://doi.org/10.2134/agronj2019.03.0142>
- Anselin, L. (1995). Local Indicators of Spatial Association-LISA. *Geographical Analysis*, 27(2), 93–115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L. (1996). The Moran Scatterplot as an ESDA Tool to Assess Local Instability in Spatial Association. In M. Fischer, H. Scholten, & D. Unwin (Eds.), *Spatial Analytical Perspectives on GIS* (pp. 111–125). London: Taylor and Francis.
- Benjamini, Y., & Hochberg, Y. (1995). Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing. *Journal of the Royal Statistical Society: Series B (Methodological)*, 57(1), 289–300.
- Bullock, D. S., Mieno, T., & Hwang, J. (2020). The value of conducting on-farm field trials using precision agriculture technology: a theory and simulations. *Precision Agriculture*, 21(5), 1027–1044. <https://doi.org/10.1007/s11119-019-09706-1>
- Córdoba, M., Paccioletti, P., Balzarini, M. (2024). A new method to compare treatments in unreplicated on-farm experimentation *Precision Agriculture* (en prensa).
- Evans, F. H., Recalde Salas, A., Rakshit, S., Scanlan, C. A., & Cook, S. E. (2020). Assessment of the Use of Geographically Weighted Regression for Analysis of Large On-Farm Experiments and Implications for Practical Application. *Agronomy*, 10(11), 1720. <https://doi.org/10.3390/agronomy10111720>
- Federer, W. T. (1955). *Experimental design*. New York: The MacMillan Company.
- Frossard, J., & Renaud, O. (2021). Permutation Tests for Regression, ANOVA, and Comparison of Signals: The permuco Package. *Journal of Statistical Software*, 99(15). <https://doi.org/10.18637/jss.v099.i15>
- Gotway Crawford, C. A., Bullock, D. G., Pierce, F. J., Stroup, W. W., Hergert, G. W., & Eskridge, K. M. (1997). Experimental Design Issues and Statistical Evaluation Techniques for Site-Specific Management. In F. J. Pierce & E. J. Sadler (Eds.), *The State of Site-Specific Management for Agriculture* (pp. 301–335). Madison, WI, USA: ASA/CSSA/SSSA.
- Griffith, D. A. (2005). Effective Geographic Sample Size in the Presence of Spatial Autocorrelation. *Annals of the Association of American Geographers*, 95(4), 740–760. <https://doi.org/10.1111/j.1467-8306.2005.00484.x>
- Kravchenko, A. N., Snapp, S. S., & Robertson, G. P. (2017). Field-scale experiments reveal persistent yield gaps in low-input and organic cropping systems. *Proceedings of the National Academy of Sciences*, 114(5), 926–931. <https://doi.org/10.1073/pnas.1612311114>
- Lawes, R. A., & Bramley, R. G. v. (2012). A simple method for the analysis of on-farm strip trials. *Agronomy Journal*, 104(2), 371–377. <https://doi.org/10.2134/agronj2011.0155>
- Li, H., Calder, C. A., & Cressie, N. (2007). Beyond Moran's I: Testing for Spatial Dependence Based on the Spatial Autoregressive Model. *Geographical Analysis*, 39(4), 357–375. <https://doi.org/10.1111/j.1538-4632.2007.00708.x>
- Piepho, H.-P., Richter, C., Spilke, J., Hartung, K., Kunick, A., & Thöle, H. (2011). Statistical aspects of on-farm experimentation. *Crop and Pasture Science*, 62(9), 721. <https://doi.org/10.1071/CP11175>
- R Core Team. (2023). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. Vienna, Austria: R Foundation for Statistical Computing. <https://www.R-project.org/>. Accessed 16 November 2023
- Stefanova, K. T., Brown, J., Grose, A., Cao, Z., Chen, K., Gibberd, M., & Rakshit, S. (2023). Statistical analysis of comparative experiments based on large strip on-farm trials. *Field Crops Research*, 297. <https://doi.org/10.1016/j.fcr.2023.108945>
- Vega, A., Córdoba, M., Castro-Franco, M., & Balzarini, M. (2019). Protocol for automating error removal from yield maps. *Precision Agriculture*, 20(5), 1030–1044. <https://doi.org/10.1007/s11119-018-09632-8>
- Whelan, B. M., Taylor, J. A., & McBratney, A. B. (2012). A small strip approach to empirically determining management class yield response functions and calculating the potential financial net wastage associated with whole field uniform-rate fertiliser application. *Field Crops Research*, 139, 47–56. <https://doi.org/10.1016/j.fcr.2012.10.012>



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Mapas de compactación de suelo: herramientas para la optimización de recursos en agricultura sostenible

**Yessica Analia Jimenez<sup>1</sup>, Ricardo Melhen<sup>2</sup>, Eugenio Lobo Vallejo<sup>3</sup>**

<sup>1</sup>Área de Imágenes, Efficatia, Yerba Buena, Tucumán, Argentina.

<sup>2</sup>Área Nutrición Vegetal, Efficatia, Yerba Buena, Tucumán, Argentina.

<sup>3</sup>Área de Desarrollo, Efficatia, Yerba Buena, Tucumán, Argentina.

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

### **Resumen.**

*La compactación del suelo representa un desafío crítico en la agricultura, afectando tanto la productividad de los cultivos como la eficiencia operativa. Este estudio se centró en la evaluación de la compactación en dos lotes agrícolas en Salta, Argentina. Se utilizó el Índice de Vegetación de Diferencia Normalizada (NDVI) para zonificar los lotes y se midió la resistencia a la penetración del suelo con un calador hidráulico Tornomar CH200. Los datos permitieron la elaboración de mapas de profundidad máxima de compactación. En el lote A1, se encontró que el 78,6% del área está clasificada en la Clase A (0-20 cm), indicando una compactación más severa en las capas superficiales. En contraste, el lote A2 mostró una mayor proporción en la Clase C (31-60 cm), con un 55,3% del área, lo que refleja compactación más profunda. También se evaluaron las Clases B (21-30 cm) en ambos lotes, destacando variaciones en la compactación a distintas profundidades. Estos mapas proporcionan una visión detallada de la variabilidad espacial de la compactación, permitiendo a los agricultores ajustar el manejo del suelo y optimizar el uso de maquinaria. La aplicación de estas técnicas mejora la eficiencia, reduce el consumo de combustible y promueve prácticas agrícolas sostenibles. Este estudio demuestra la efectividad de las herramientas de agricultura de precisión en la gestión de la compactación del suelo y en la mejora de la eficiencia agrícola.*

**Palabras clave.** Compactación del suelo, resistencia a la penetración, manejo del suelo, agricultura de precisión, Sistema de Información geográfica (SIG).

## Introducción

La compactación de suelo es un problema crítico en la agricultura moderna, ya que afecta la estructura del suelo y limita la productividad de los cultivos. Con el aumento de la mecanización y el tráfico de maquinaria pesada en los campos agrícolas, la compactación se ha convertido en un desafío importante que debe abordarse para garantizar la sostenibilidad y productividad de los sistemas agrícolas.

En respuesta a estos desafíos, la agricultura de precisión ofrece soluciones innovadoras para monitorear y manejar la compactación de manera eficiente. Herramientas como el Índice de Vegetación de Diferencia Normalizada, (NDVI), permite zonificar los lotes y dirigir el muestreo en áreas específicas. Mediante el análisis de los datos obtenidos de resistencia a la penetración se pueden elaborar mapas de máxima profundidad de compactación, proporcionando una visión más clara de la variabilidad espacial de los lotes. Este estudio tiene como objetivo evaluar la compactación del suelo en dos lotes de producción agrícola en Salta, Argentina, utilizando estas técnicas avanzadas para identificar áreas críticas y proponer estrategias de manejo adecuadas.

## Materiales y métodos

El estudio se realizó en dos lotes ubicados en la provincia de Salta, Argentina. El lote A1 se encuentra en (Latitud 25°43'32.05"S, Longitud 64°42'11.70"O), mientras que el lote A2 está en (Latitud 25°44'41.50"S, Longitud 64°42'25.19"O). El lote A1 tiene una superficie de 59 ha y el lote A2 cuenta con 90,42 ha, ambos destinados a la agricultura bajo la modalidad de siembra directa con rotación de maíz y soja. Los lotes fueron subdivididos en tres sectores, identificados en función del Índice de Vegetación de Diferencia Normalizada (NDVI) promedio de los últimos tres años, obtenido a partir de imágenes del satélite Sentinel-2. Este enfoque permitió realizar un muestreo dirigido según las zonas de productividad. Figuras 1 y 2.

El índice NDVI se calcula utilizando a siguiente fórmula:

$$NDVI = \frac{IR-R}{IR+R} \quad (1)$$

Donde: IR=reflectancia en la banda infrarroja y R=reflectancia en la banda roja.

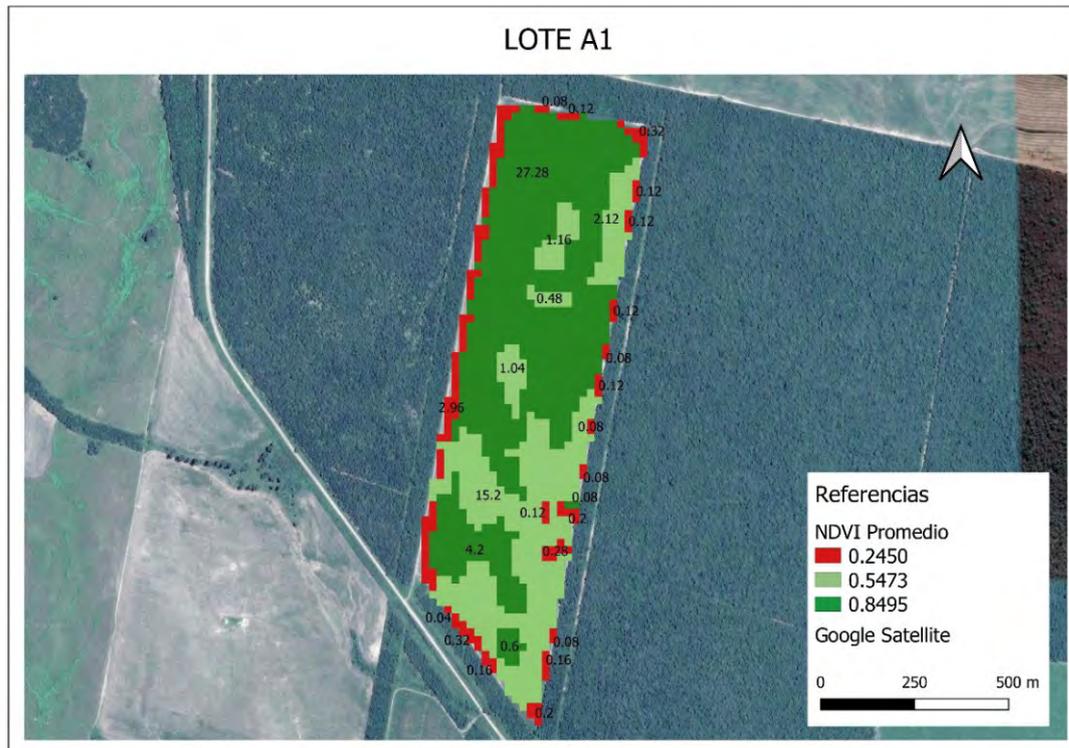


Figura 1. Zonificación del lote A1 según NDVI promedio (2021-2023).

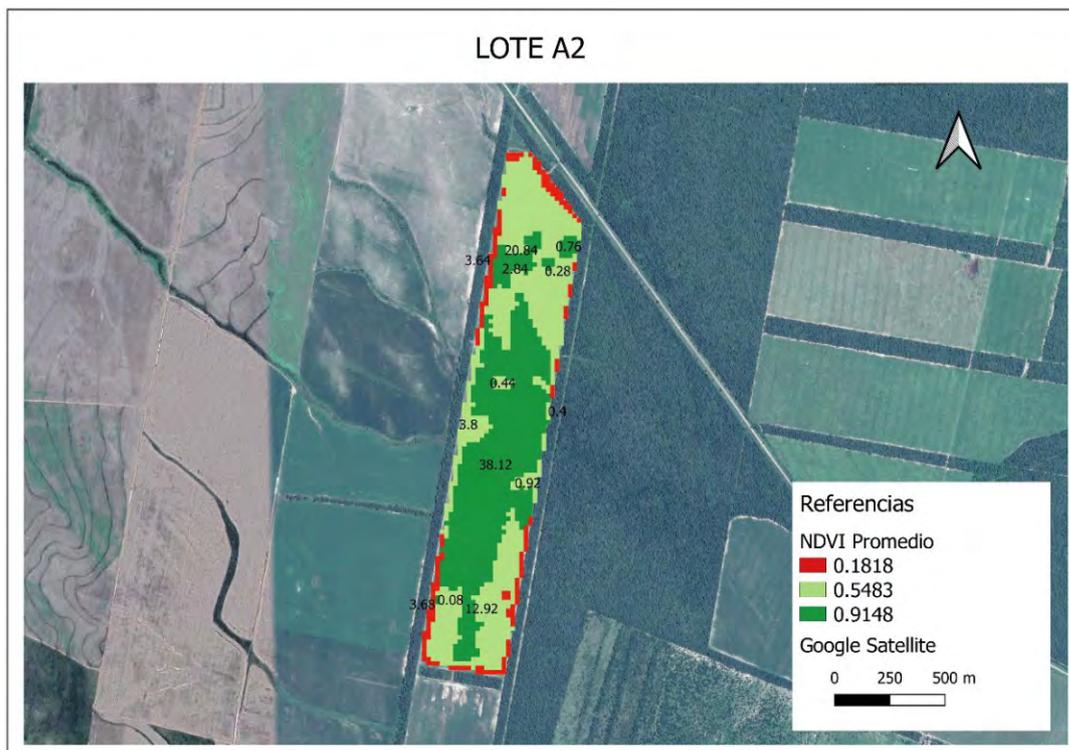


Figura 2. Zonificación del lote A2 según NDVI promedio (2021-2023).

## Determinación de la Compactación del Suelo

Para el análisis de compactación del suelo, se tomaron un total de 27 muestras en el lote A1 y 25 en el lote A2. Los datos de resistencia de penetración fueron obtenidos a partir del calador hidráulico Tornomar CH200. En cada punto georreferenciado las mediciones se realizaron a intervalos de 1 cm abarcando una profundidad total de 60 cm.

Con el fin de identificar las zonas de suelo compactado, se estableció un umbral de resistencia de penetración mayor a 4 MPa. Un suelo se consideró compactado si la resistencia de penetración superaba este umbral en cualquier profundidad del perfil de 60 cm. Se registró la última profundidad que excedió el umbral como la máxima profundidad de compactación para cada punto de muestreo. Posteriormente, se clasificaron los puntos en función de esta profundidad máxima utilizando las siguientes categorías: Clase A (0-20 cm), Clase B (21-30 cm) y Clase C (31-60 cm).

## Resultados

### Profundidad Máxima de Compactación

Se realizó un análisis de compactación de suelo en los lotes A1 y A2. A continuación, se presentan los resultados de la compactación, clasificados por profundidad y lote, junto con la desviación estándar para cada clase de profundidad.

#### Lote A1:

- ☐ Clase A (0-20 cm): 46,38 ha (78,6% del lote A1). Desviación estándar: 0,09 MPa.
- ☐ Clase B (21-30 cm): 4,09 ha (6,9% del lote A1). Desviación estándar: 0,10 MPa.
- ☐ Clase C (31-60 cm): 8,53 ha (14,5% del lote A1). Desviación estándar: 2,43 MPa.

#### Lote A2:

- ☐ Clase A (0-20 cm): 14,55 ha (16,1% del lote A2). Desviación estándar: 0.24 MPa.
- ☐ Clase B (21-30 cm): 25,85 ha (28,6% del lote A2). Desviación estándar: 0.82 MPa.
- ☐ Clase C (31-60 cm): 50,02 ha (55,3% del lote A2). Desviación estándar: 0.43 MPa.

La Tabla 1 proporciona un resumen de las superficies (ha) de los lotes correspondientes a cada clase según la profundidad de compactación.

Tabla 1. Distribución de superficie compactada por lote según las clases.

Lotes/Clases	A	B	C	Superficie (ha)
A1	46,38	4,09	8,53	<b>59</b>
A2	14,55	25,85	50,02	<b>90,42</b>
<b>Total</b>	<b>60,93</b>	<b>29,94</b>	<b>58,55</b>	

Los gráficos de barras en la Figura 3 ilustran la superficie total clasificada en cada categoría de compactación (Clase A, B, C) para los lotes A1 y A2. Se observa que en el lote A1, la Clase A tiene una mayor proporción de superficie, mientras que en el lote A2, la Clase C predomina.

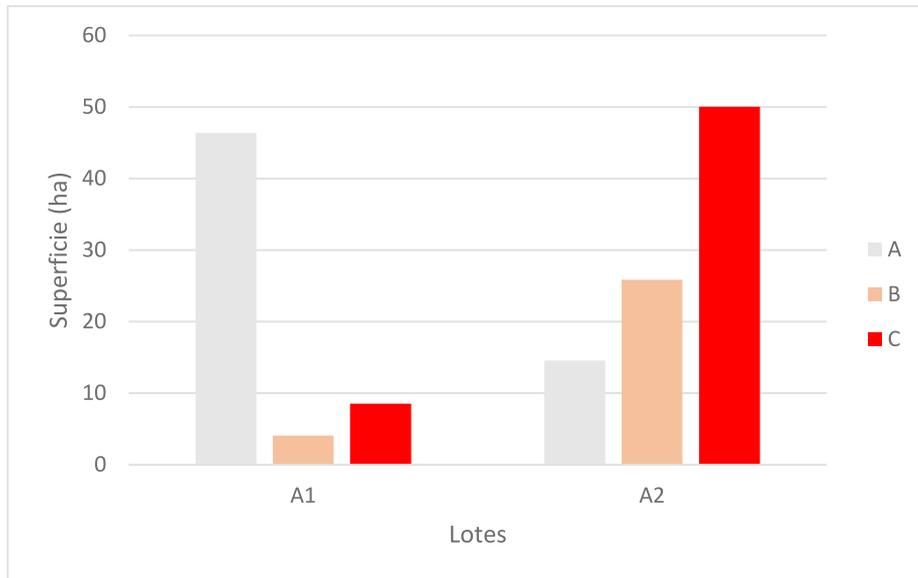


Figura 3. Gráfico de la distribución de la superficie (ha) por clase según el lote.

La Figura 4 muestra el mapa de máxima profundidad de compactación de los lotes A1 y A2, generado mediante polígonos de Voronoi en QGIS, que visualiza la variabilidad espacial de la compactación en cada lote.



Figura 4. Mapa de máxima compactación de suelo (cm)



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Conclusión

La elaboración de mapas de máxima profundidad de compactación ha demostrado ser una herramienta efectiva para identificar áreas críticas que puedan estar limitando la producción. Conocer la dinámica de compactación permite una elección precisa tanto de los implementos a utilizar como de la profundidad de labor, logrando con esta planificación una disminución de costos. La integración de estos mapas con otras variables de suelo, como la humedad y la composición química, ofrecería una visión más completa de las condiciones de suelo para una gestión agrícola más eficiente y sostenible, optimizando recursos, reduciendo costos operativos y mejorando la productividad a largo plazo.

## “Evaluación de tecnologías en la calidad de siembra del cultivo de Maíz”

Ing. Agr. Martin Olivanti – Grupo Orígenes SRL (Las Parejas, Sta. Fe)

Ing. Agr. Ivan Gullino – Grupo Orígenes SRL (Las Parejas, Sta. Fe)

Nestor Bessone – (Las Parejas, Sta. Fe)

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

**Resumen.** Este estudio evalúa diferentes tecnologías de siembra para determinar su efecto en la calidad de implantación y, por ende, en la productividad del maíz. Los objetivos principales fueron identificar la tecnología que optimiza la emergencia y desarrollo de las plantas, así como analizar su impacto en el rendimiento final del cultivo.

Se llevó a cabo un ensayo a campo, donde se compararon variables cualitativas y cuantitativas en dos configuraciones de siembra, una convencional, mecánica, con sistema a placa y otra equipada con tecnología de Precision Planting, vDrive, vApply, DeltaForce y SmartFirmer, incluyendo en el ensayo la aplicación de nitrógeno variable por ambiente y el uso de diferentes carros tapadores. Los resultados mostraron que el uso de la tecnología produjo una menor pérdida de stand de plantas, una emergencia más uniforme, mayor desarrollo vegetativo y un mayor rendimiento en comparación con la siembra convencional.

Los resultados cuantitativos muestran una diferencia de 597 kg/ha en el rendimiento a favor de la siembra con tecnología con respecto a la tecnología convencional, lo que subraya la importancia de adoptar nuevas tecnologías para mejorar la calidad de la siembra. Este estudio no solo proporciona evidencia sobre la efectividad de diferentes enfoques tecnológicos, sino que también ofrece recomendaciones prácticas para agricultores que buscan optimizar su producción de maíz.

**Palabras clave.** *Calidad de siembra, uniformidad de siembra, eficiencia de siembra, productividad agrícola, densidad de plantas, emergencia de plantas.*

## Diseño del ensayo

El ensayo se realizó en un campo cercano a la localidad de Las Parejas, Santa Fe, tipo de suelo Serie Los Cardos, clase 1, con una superficie total de 48 hectáreas.

La rotación de los últimos años fue: Maíz 1º / Soja 1º / Trigo-Soja 2º

Se evaluaron dos configuraciones de siembra: una convencional y otra equipada con tecnología. Se implementaron dos estrategias de fertilización nitrogenada: una de distribución homogénea y otra de distribución variable y además se evaluaron dos sistemas de carros tapadores: Furrow Force de Precision Planting versus tapadora convencional.

## Disposición de los ensayos

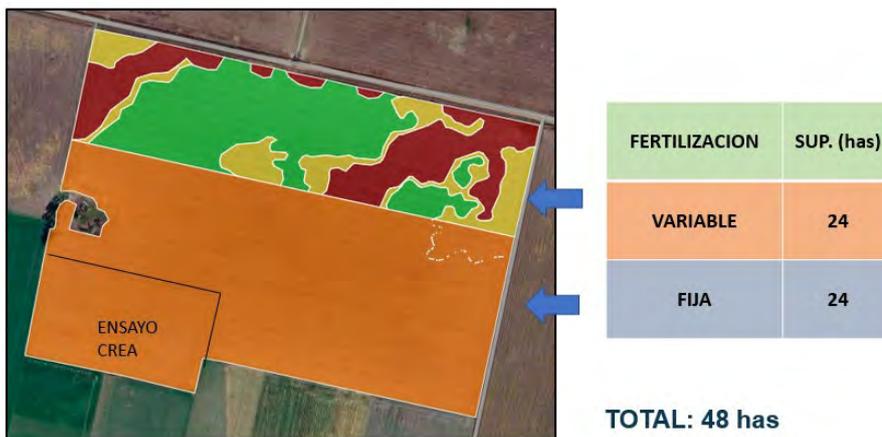


Figura 1. Fertilización nitrogenada vs fija

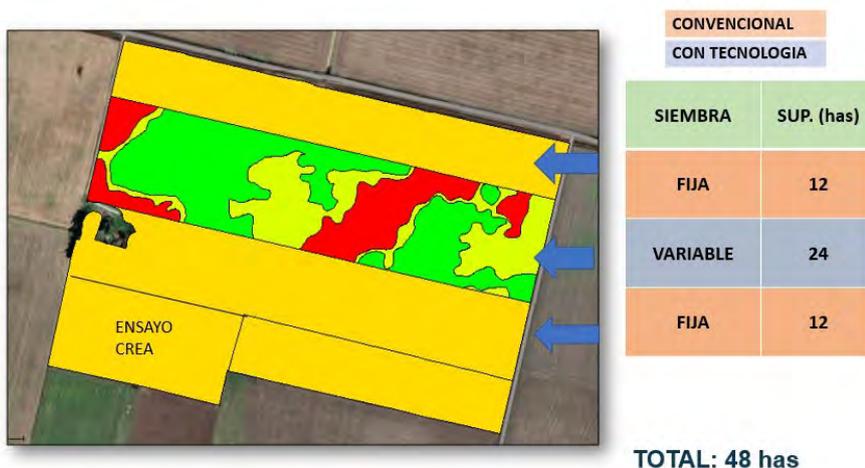


Figura 2. Siembra con tecnología con densidad variable vs Siembra convencional fija

Se utilizaron imágenes satelitales (NDVI) y mapas de rendimiento de las últimas campañas para analizar y definir los ambientes para realizar densidad y fertilización variable.

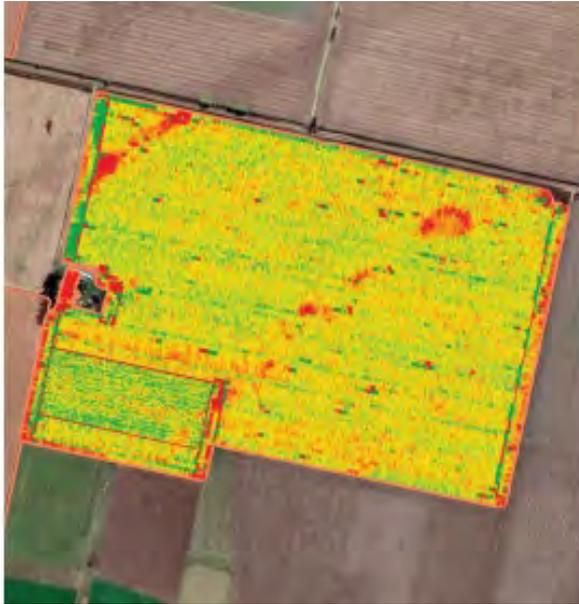


Figura 3. Mapa de rendimiento cultivo de Maíz campaña 20-21

Se realizó análisis de suelo en cada uno de los ambientes para ajustar la fertilización y densidad de siembra según potencial de rendimiento.

	RINDE ESPERADO (QQ/HA)	KG/HA UREA	KG N /HA UREA	DENSIDAD DE SIEMBRA (Semillas/ha)
AMBIENTE Alto	140	330	152	86.000
AMBIENTE Medio	110	305	140	80.000
AMBIENTE Baja	80	228	105	75.000
FIJO	110	279	128	82.000

Figura 4. Ajuste de fertilización y densidad por ambiente

El día 8 de agosto se realizó la incorporación del fertilizante nitrogenado a una profundidad de 10 cm, con una sembradora incorporadora con vApply (motor hidráulico) que permite realizar la dosificación variable por ambiente. Se realizó la siembra 30 grados respecto a la posterior siembra de Maíz.

La siembra del cultivo de Maíz se realizó el 9 de Setiembre, la sembradora con configuración con tecnología es de 8,4 metros de labor a una velocidad de siembra de 7,9 km/h y la configuración convencional de 10,5 metros de ancho de labor y una velocidad de siembra de 6 km/h.

Ambas aplicaron fertilizante fosforado en la línea (100 kg/ha), con iguales regulaciones de siembra.

La sembradora con tecnología nos permitió obtener datos de siembra en tiempo real a través de sensores, brindándonos información tales como:

- Velocidad de siembra: 7,9 km/h
- Singularidad %: 99,9
- CV %: 13,2
- Contacto con el suelo %: 98,8

- Estabilidad del cuerpo %: 98,8

## Relevamiento de datos

### Medición de calidad de siembra

Con el cultivo en estadio V3 se realizó la medición de calidad de siembra utilizando el PogoStick donde se evaluó coeficiente de variación y densidad de plantas, siendo el primer valor dentro de los parámetros aceptables para ambas siembras (14,3% con tecnología y 18,9% siembra convencional), en cuanto al stand de plantas hay una diferencia del **5,7%** más de semillas no nacidas en siembra convencional (por efecto de mal ambiente otorgado para la germinación de la semilla).

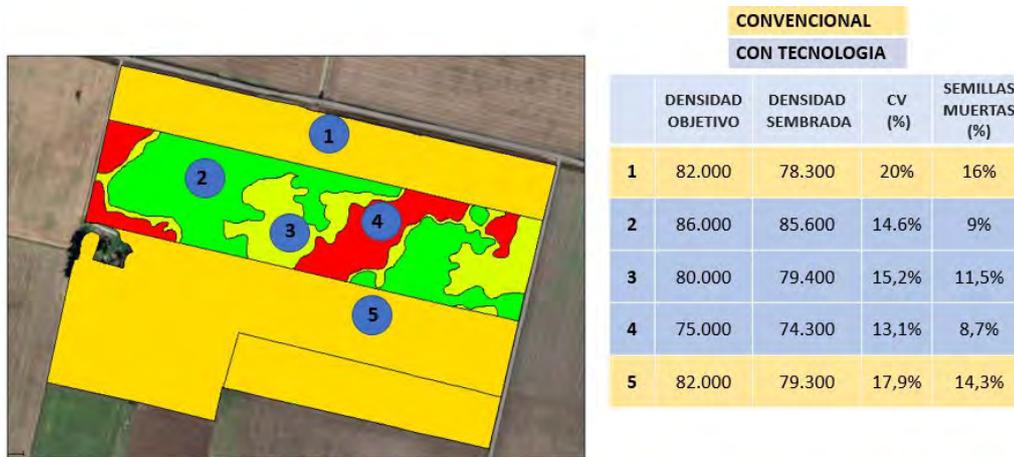


Figura 4. Datos de mediciones de coeficiente de variación y semillas no germinadas

### Medición de emergencia temporal.

Se tomaron dos surcos (uno con carro tapador convencional y otro con Furrowforce) y dos surcos de siembra convencional. Cada uno con 150 plantas lineales, y se colocó una bandera de color verde aquellas plantas que emergían el día 1, color azul las que emergían día 2, amarillo día 3 y rojo día 4.

El resultado fue un 14,4% más de plantas emergidas el día 1 a favor de siembra con tecnología, y una desuniformidad mayor en la convencional para el reto de los días siguientes.

No se observó diferencias significativas en la comparación entre carros tapadores

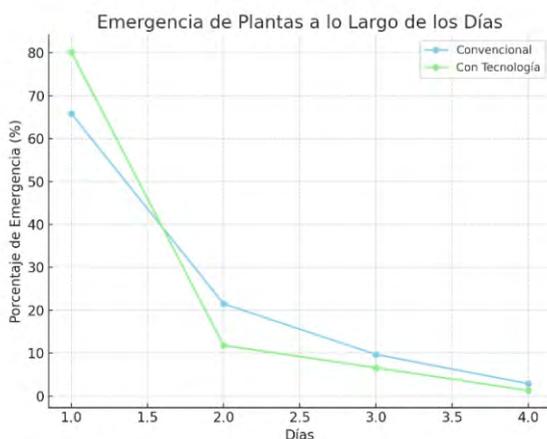


Figura 6. Emergencia temporal entre sistemas de siembra.

### Resultado por emergencia temporal. ¿Cuántos kg/ha perdemos por retraso de emergencia respecto al día 1?

Unos días antes de la cosecha, las espigas de cada bandera se cosechan manualmente y se obtienen los siguientes datos. Independientes del sistema de siembra utilizado, por cada día de retraso en la emergencia, la pérdida de rendimiento se duplica, a su vez, aquellas plantas que emergen el día 5 en adelante, son plantas que no generan espigas o con muy pocos granos.

	CONVENCIONAL				CON TECNOLOGIA				TOTAL
	REPETICION 1		REPETICION 2		CON FURROWFORCE		CONVENCIONAL		Perdida de rinde vs DIA 1
	ESPIGA (gramos)	%	%						
<b>DIA 1</b>	161,3		154,5		156,2		149,3		
<b>DIA 2</b>	152,7	-5,3	140,8	-8,8	148,7	-4,8	138,5	-7,2	<b>-6,5 %</b>
<b>DIA 3</b>	140,6	-12,8	134,2	-13,1	127,7	-18,2	127,2	-14,8	<b>-14,7 %</b>
<b>DIA 4</b>	94,8	-41,2	99,8	-35,4	112,9	-27,7	95,9	-35,7	<b>-35 %</b>

Figura 9. Pérdida de rendimiento por emergencia temporal

### Fotos aéreas

El 6 de noviembre con el cultivo en V3 se observaba una diferencia en desarrollo del cultivo a favor de la siembra con tecnología. (Imagen 5), luego en R1 la siembra convencional comienza a tener un color más oscuro hasta la cosecha, eso es debido que al quedar con una menor densidad de plantas los recursos para la planta fueron mayores alargándose unos días más el ciclo del cultivo (Imagen 6 y 7)



Imagen 5 y 6. Foto aérea del cultivo en estadio V3 y R1



Imagen 7. Foto aérea del cultivo próximo a cosecha

## Resultados

El día 12 de marzo se realizó la cosecha de la franja de siembra convencional / nitrógeno variable y de siembra con tecnología / nitrógeno variable y nitrógeno fijo. Debido a las lluvias la franja siembra convencional / nitrógeno fijo se realizó el día 21 de marzo.



Se descargo el mapa de rendimiento de la cosechadora y utilizando un software de edicion procedemos a realizar las evaluaciones ambiente por ambiente.

### Resultado por calidad de siembra

Al evaluar rendimiento entre ambas configuraciones de siembra, por calidad de siembra (temporalidad, espaciamento, densidad de plantas logradas), la diferencia de rendimiento es de 457 kg/ha a favor de la siembra con tecnología.

	CONVENCIONAL			CON TECNOLOGIA			457 kg/ha
	PESO (kg)	DENSIDAD (pl/ha)	RENDIMIENTO	PESO (kg)	DENSIDAD (pl/ha)	RENDIMIENTO	
DIA 1	10,389	65.772	9.956 kg/ha	12,160	70.269	10.413 kg/ha	
DIA 2	3,139			1,687			
DIA 3	1,328			0,838			
DIA 4	0,282			0,135			

Figura 8. Resultado por calidad de siembra entre ambas configuraciones

### Resultado por fertilización nitrogenada variable

Se utilizó la configuración de siembra con tecnología para realizar la evaluación de margen bruto para fertilización fija vs variable, y se realizó el cálculo económico de cada uno de los ambientes.

La distribución de los recursos nitrogenados permitió mejorar el margen bruto en **36,1 uss/ha**, que al precio del maíz del día son 212 kg/ha de ganancia por realizar esa práctica.

En los tres ambientes el resultado del margen bruto fue positivo. Mayor en el ambiente de baja productividad por ahorro de costos y aumento de rendimiento.

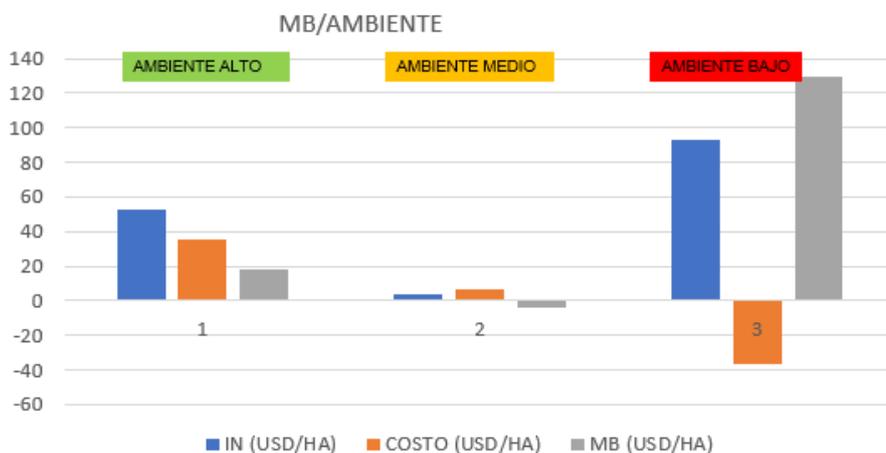


Figura 9. Grafico de ingreso, costos y margen bruto por ambientes

### Resultado por sistema productivo

Al evaluar el rendimiento obtenido entre ambas configuraciones de siembra incluyendo las dos formas de fertilización, se obtuvieron **597 kg/ha** de rendimiento a favor de la siembra con tecnología, debido a una mejor emergencia temporal y espacial y una mejor distribución de los recursos de densidad de plantas.

CONVENCIONAL  
CON TECNOLOGIA

HAS	KG (Total)	RENDIMIENTO (kg/ha)	DIFERENCIA (KG/HA)
19,6	218.280	11.136	<b>597</b>
20,2	237.020	11.733	

Figura 10. Resultados por configuraciones de siembra

### Mapa de humedad de cosecha

Se evidencio a la cosecha, la diferencia de humedad entre configuraciones de siembra, debido a la menor cantidad de plantas a cosecha, que genero una espiga más grande, pero que no llevo a compensar en rendimiento.

Se observa en la imagen 11, la diferencia de medio punto de humedad entre ambas siembras (recordar que una franja del ensayo se cosecho días posteriores)

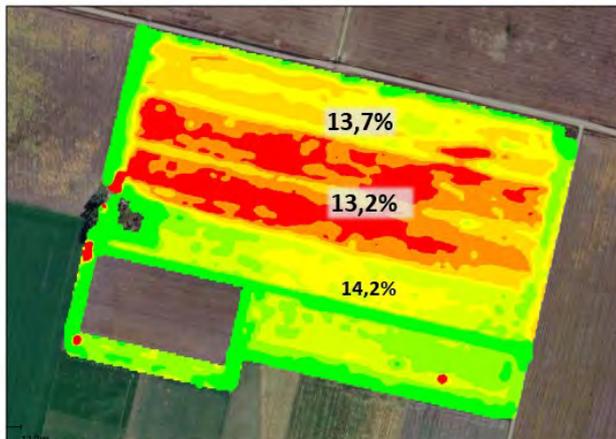


Figura 11. Mapa de humedad de cosecha

### Evaluación de malezas

A los 11 días posteriores de la cosecha se tomó la imagen aérea, donde se observa una mayor cantidad de malezas a cosecha en la configuración de siembra convencional, por perdidas en el stand de plantas y consecuentemente un mayor ingreso de luz.



Figura 12. Imagen de malezas, izquierda siembra convencional, derecha siembra con tecnología

### Evaluación de carros tapadores

Con el cultivo de maíz en estadio V11, se sacaron muestras de plantas aleatorias de surcos con carro tapador convencional y carros tapadores Furrowforce, para evaluar peso de raíz y parte aérea.

La diferencia fue de un **8,8%** de mayor peso de raíz y un **16%** mayor de peso de parte aérea a favor del carro tapador Furrowforce. Esa diferencia se debe a que se le brinda mejores condiciones de nacimiento a la semilla.

### Conclusiones

- 597 kg/ha** a favor del sistema productivo con tecnología
- 457 kg/ha** de diferencia por realizar una buena calidad de siembra
- 212 kg/ha o 36,1 uss/ha** por realizar fertilización variable nitrogenada
- 5%** más de **productividad** en capacidad de siembra con un menor ancho de labor (mayor velocidad).
- El **coeficiente de variación** entre ambas siembras resulto dentro de los parámetros normales.
- Hay **5,7%** más de **semillas no germinadas** en siembra convencional.
- Hay un **14,4 %** de plantas que tuvieron mayor velocidad de emergencia respecto a la convencional (**DIA 1**)
- El **17,2%** de las plantas de la siembra convencional nacieron entre el **DIA 2, 3 o 4**.
- Con **Furrowforce** se observó un **8,8%** de mayor peso de raíz y un **16%** de mayor peso de parte aérea versus las tapadoras tradicionales.
- Con **Deltaforce** hay una mayor altura de espiga y una menor variabilidad entre ellas.
- 0,5 %** de diferencia de humedad a cosecha
- Menor presión de malezas a la cosecha
- No hay solapamiento:** Ahorro de semillas y no hay pérdida de rendimiento



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



*Los resultados indican que la adopción de tecnologías avanzadas en la siembra y fertilización de maíz puede mejorar significativamente tanto la uniformidad del cultivo como el rendimiento. La siembra con tecnología no solo aumentó la productividad, sino que también mejoró la eficiencia en el uso de insumos, reduciendo las pérdidas y optimizando el retorno económico para los productores.*

### Agradecimientos

*Agradecimiento especial a Néstor Bessone y equipo por la predisposición, entusiasmo y acompañamiento para llevar adelante este ensayo.*

## CIR 1.5 vs ojo humano: evaluación de la capacidad de procesamiento.

Guilino F.D.<sup>1</sup>, Mur M.<sup>1</sup>, Merani V.H.<sup>1</sup>, Larrieu L.<sup>1</sup>, Ferro D.A.<sup>1</sup>, Vázquez J.M.<sup>1</sup>, Cinquetti T.<sup>1</sup>, Donadelli M C.<sup>1</sup>, Pereira E.I.<sup>1</sup>

[fquilino@agro.unlp.edu.ar](mailto:fquilino@agro.unlp.edu.ar), [matilde.mur@agro.unlp.edu.ar](mailto:matilde.mur@agro.unlp.edu.ar), [victor.merani@agro.unlp.edu.ar](mailto:victor.merani@agro.unlp.edu.ar),  
[larrieuluciano@gmail.com](mailto:larrieuluciano@gmail.com), [daniel.ferro@agro.unlp.edu.ar](mailto:daniel.ferro@agro.unlp.edu.ar), [juanmvaz@hotmail.com](mailto:juanmvaz@hotmail.com),  
[tatianacinquetti@gmail.com](mailto:tatianacinquetti@gmail.com), [m.claradonadelli@gmail.com](mailto:m.claradonadelli@gmail.com), [pereiraestebanivan@gmail.com](mailto:pereiraestebanivan@gmail.com),

<sup>1</sup>CISSAF FCAyF UNLP, La Plata, Buenos aires, Argentina.

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

**Resumen.** Hoy en día existe necesidad de perfeccionar las técnicas de evaluación de la aplicación de fitosanitarios, buscando lograr una correcta colocación del producto en el blanco, en cantidad necesaria, de forma económica, con el mínimo de contaminación de otras áreas. Una utilización errónea, pueden disminuir no solamente la eficacia de la operación, sino también, aumentar la presión de selección sobre los organismos y contaminación del medio ambiente. De manera tal, contar con metodologías que permitan cuantificar y calificar las variables involucradas en la pulverización, con rapidez (acelerar el proceso de cálculo), precisión, es cada vez más necesario. El objetivo del trabajo fue evaluar la precisión y confiabilidad de un software, en relación a la metodología manual. El ensayo evaluado la calidad de aplicación de una boquilla abanico plano XR 11002 (AP). Como objetivos de aplicación se empleó tarjetas hidrosensibles situadas a 0,75 m respecto al botalón y colocadas horizontalmente sobre dos prismas rectangulares simulando la existencia del blanco. Las condiciones ambientales fueron semicontroladas, sin viento y sin desuniformidad de la superficie de terreno. Se evaluó la capacidad de procesamiento del CIR 1.5 respecto a la metodología manual para los parámetros cantidad de impactos  $\text{cm}^2$  y diámetro volumétrico mediano ( $DV_{0,5}$ ). Para las variables analizadas, el CIR proporciono valores más altos respecto a la manual, sin embargo, no presentaron diferencias significativas para el parámetro cantidad de impactos  $\text{cm}^2$ , a diferencia del ( $DV_{0,5}$ ).

**Palabras clave.** Programa, calidad de aplicación, pulverización hidráulica, pastillas.

## Introducción y antecedentes

En el control químico, la pulverización hidráulica es la forma de aplicación más difundida de fitoterápicos (Márquez, 2007). Su uso es complejo, no sólo desde el punto de vista agronómico, sino también, por todos los aspectos que involucran la preservación del medio ambiente y la salud humana (Mur et al., 2018a; Mur et al., 2018b; Merani et al., 2018). Una problemática asociada a las aplicaciones de fitosanitarios mediante máquinas pulverizadoras es la ineficiencia del proceso, es decir, la cantidad de producto químico que alcanza el objetivo es significativamente menor al erogado por el pulverizador. Merani et al. (2023) evaluó la eficiencia de aplicación (EA) de pulverizaciones terrestres con sistema hidráulico de formación de gota en condiciones controladas (sin viento) sobre un suelo de asfalto, y reportó valores del 50 %. Estos resultados evidencian que la mitad del volumen de aplicación pulverizado no llega al objetivo, incluso en condiciones ideales de aplicación.

La aparición de colectores artificiales como son las tarjetas hidrosensibles, han permitido cuantificar los depósitos de gotas, siendo en la actualidad los objetivos artificiales más empleados como instrumento de monitoreo para la evaluación de los parámetros de pulverización agrícola (Ramos, 2000). Para la utilización de esta herramienta y en post de mejorar la calidad de la evaluación, se han desarrollado factores de expansión de la gota al impactar en la tarjeta que han permitido convertir el tamaño de las improntas al tamaño real de la gota que dio su origen (Giles y Downey, 2003; Hoffmann y Hewitt, 2005; Syngenta, 2002).

Los avances en la tecnología de procesamiento de imágenes sumado a la informática han permitido obtener rapidez, dinamismo y precisión en el análisis de los parámetros que definan la calidad de aplicación. En la actualidad existen diferentes softwares gratuitos o pagos que permiten cuantificar y tipificar una aspersion a partir de lecturas realizadas directamente sobre la tarjeta hidrosensible, o a través de un escaneo previo de las improntas generadas sobre las mismas.

Para que estas herramientas puedan ser utilizadas de manera precisa y confiable, es necesario comparar sus resultados de análisis con aquellas técnicas tradicionales de determinación, normalmente más laboriosas y demandantes.

En relación a lo expuesto, el objetivo del trabajo fue evaluar la precisión y confiabilidad del software CIR 1,5 en relación a la metodología manual (testigo).

## Materiales y métodos

El ensayo se llevó a cabo en la Estación Experimental Julio Hirschhorn perteneciente a la Facultad de Ciencias Agrarias y Forestales (FCAyF) de la Universidad Nacional de La Plata 34°35 S, 57°57 W. La evaluación se realizó en el interior de un galpón cerrado y asfaltado de 40 m de longitud y 24 m de ancho, bajo condiciones semicontroladas, sin viento y sin desuniformidad de la superficie de terreno.

Se utilizó una boquilla, abanico plano XR11002 (AP), con un caudal unitario normalizado de 0,79 L min<sup>-1</sup> a 3 bar de presión (Standard I.S.O, 2018). La presión de trabajo seleccionada fue de 250 kPa, a una velocidad de desplazamiento del equipo de pulverización de 4,72 m seg<sup>-1</sup> (17 km h<sup>-1</sup>). La distancia entre el botalón y los objetivos de aplicación fue de 0,75 m de altura. La tasa de aplicación lograda bajo estas condiciones fue de 50 L ha<sup>-1</sup>. Las condiciones ambientales al momento del ensayo fueron, HR% 89 % al 99 %, velocidad del viento de 0 a 0,5 m seg<sup>-1</sup> y T° entre 15,2 °C y 18,4 °C.

Se evaluaron 36 tarjetas, sobre las que se evaluaron Densidad de Impactos (Impactos cm<sup>2</sup>) y Diámetro Volumétrico Mediano (DV0,5-µm). Para las determinaciones testigo (T) de Densidad de Impactos y DV0.5, se realizaron lecturas con un microscopio óptico de 40x (Figura 1) y se utilizó el software Image Tool (versión 3.0, UTHSCSA), respectivamente. Estos valores fueron contrastados con el programa CIR1,5 (CIR). Los resultados fueron cargados en planillas Excel y analizados

estadísticamente por el programa INFOSTAT (DiRienzo et al).

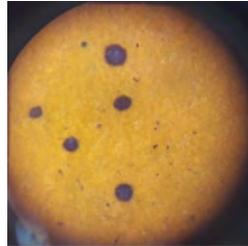


Figura 1. Vista de gotas sobre una tarjeta hidrosensible a través del microscopio óptico de 40X.

Para el análisis de la variable DV0.5 a través del software Image Tool (versión 3.0, UTHSCSA), se utilizaron imágenes escaneadas con una resolución de 1200 dpi. Para su procesamiento, el programa requiere de una calibración previa y posterior conversión de la imagen color de 24 bits a escala de grises (Figura 2).

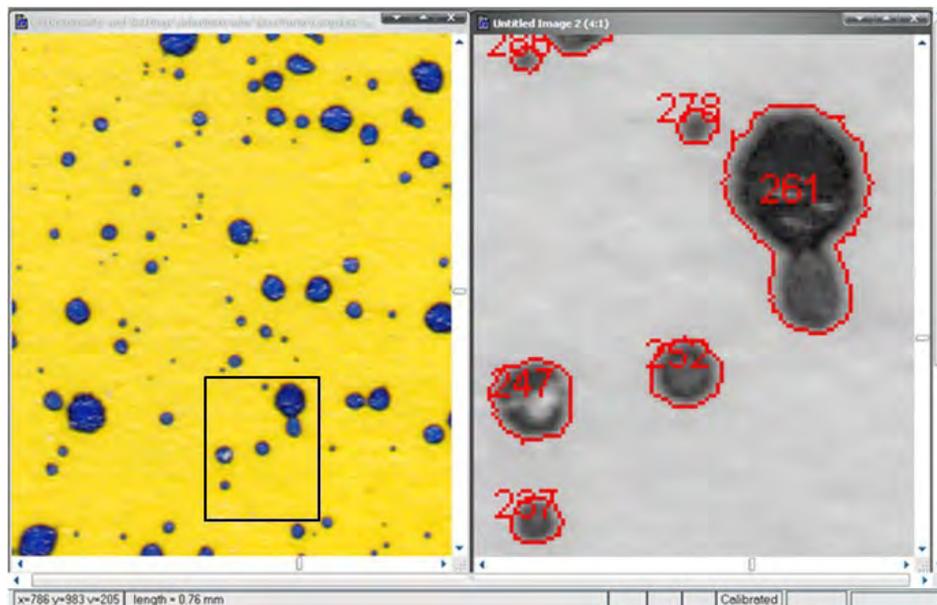
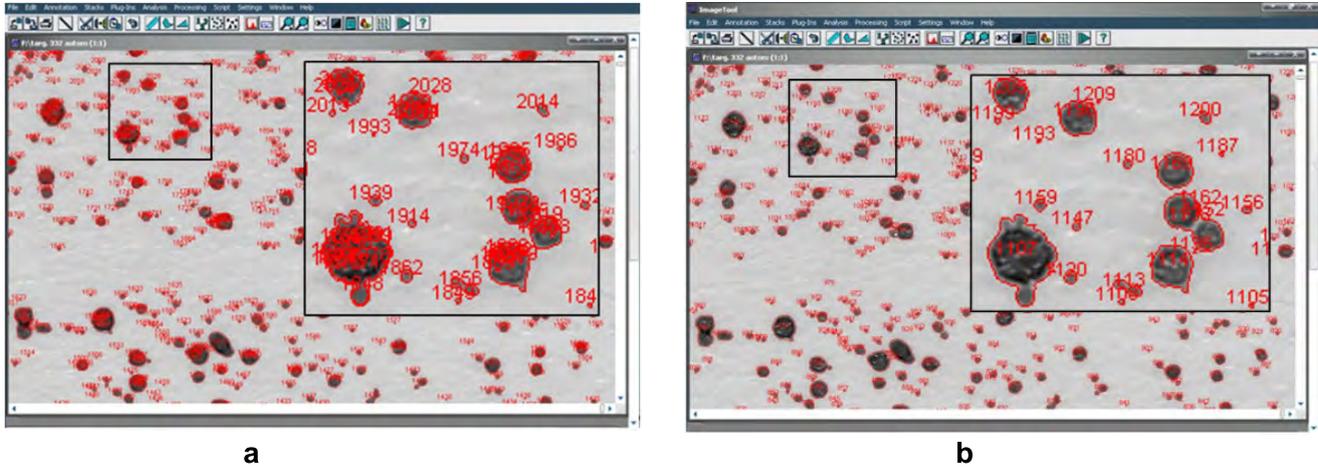


Figura 2. Tarjeta hidrosensible en color a escala normal (1:1), y en escala de grises aumentada 4 veces (4:1). ImageTool (versión 3.0, UTHSCSA).

Para el reconocimiento de las improntas, sobre la tarjeta, se seleccionó el modo manual y posterior umbralización. Al realizar el análisis, el programa reconoce posibles impactos y asigna automáticamente un número identificador a cada uno. En determinadas situaciones esos impactos identificados por el software deben ser corregidos manualmente con la finalidad de minimizar errores y aumentar la precisión de las lecturas. El nivel de umbralización se define cuando se identifica cada impronta de manera individual (Figura 2 a y b).



**Figura 2. a:** Puntos identificados por el programa ImageTool (versión 3.0, UTHSCSA) sobre una tarjeta hidrosensible sin umbralización. **b:** Puntos identificados por el programa ImageTool (versión 3.0, UTHSCSA) sobre la misma tarjeta hidrosensible, posterior a la umbralización manual

Previo a ejecutar las mediciones de las improntas, en la misma pantalla se deben visualizar ambas imágenes, en color de 24 bits y en escala de grises. La primera, en tamaño normal (1:1), se utiliza de referencia respecto a la segunda imagen aumentada 4 veces (4:1), como se observa en la figura 2.

Para el proceso de medición, cada impronta se selecciona, define y mide, individualmente, el parámetro longitud mayor (mm) y longitud menor (mm). Estos valores conjuntamente a los registrados por el programa son transferidos a una planilla de cálculo, sobre la misma se efectúan las correcciones correspondientes de aquellas improntas que no serían consecuencia del impacto de una gota de agua sobre la tarjeta, sino producto de deposición de impurezas preexistentes en el ambiente donde se realiza el ensayo, o manchas inherentes a la tarjeta. A partir de las longitudes medidas, que surgen de promediar la dimensión más grande (eje mayor) y perpendicular a la misma (eje menor), se determinan los diámetros de las manchas presentes en el objeto de aplicación. Los diámetros de improntas calculados, se basan en la suposición de que el área medida es circular. Posteriormente, se afectan por un factor de expansión propuesto por Chaim et al (1999), determinando el diámetro real de la gota que origina esa impronta y a partir del cual se calcula el DV0,5 (Diámetro Volumétrico Mediano).

## Resultados y discusión

Parámetro relacionado con la cobertura

Cantidad de impactos por  $\text{cm}^2$ .

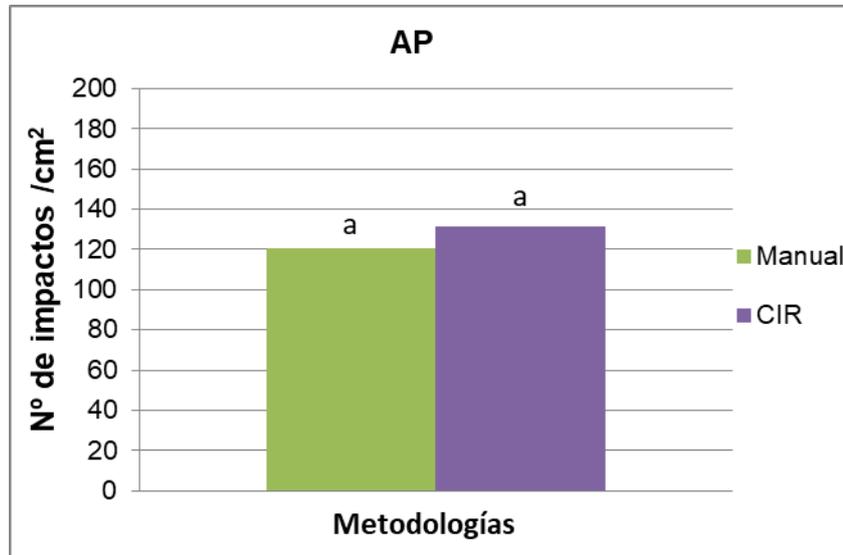


Figura 6 Cantidad de impactos  $\text{cm}^{-2}$  (IC) según metodología. Testigo (manual), programas CIR (automático, para la pastilla analizada, AP: abanico plano convencional. Letras diferentes sobre las columnas indican diferencias significativas ( $p \leq 0,05$ ) según el test de LSD Fisher entre metodologías.1

En la figura 4 se puede observar la capacidad de procesamiento del software CIR respecto al testigo (manual) en la variable cantidad de impactos (IC) para la pastilla abanico plano convencional (AP 11002). El programa proporcionó mayor valor respecto a la metodología manual (132 vs 121). Este comportamiento coincide con lo mencionado por Cunha et al. (2013), al comparar diferentes programas de metodología automática (Conta Gotas, e-Sprinkle, DepositScan, CIR 1.5) con el procesamiento manual, cuyos resultados demostraron, en todos los casos, que el CIR 1,5 reconoció significativamente el mayor número de impactos respecto al manual. Según Leiva & Araujo (2007), una de las fuentes de variación en los valores registrados se lo atribuyen a la mayor sensibilidad del software en reconocer superposición de gotas. Esta característica de individualizar gotas sobre improntas constituidas por más de una, es un factor importante en tratamientos terrestres, donde la cobertura es mayor, y no tanto en los aéreos, donde la cantidad de gotas difícilmente supere las 40 a 45 impactos por  $\text{cm}^2$ . En este trabajo, y a diferencia de lo encontrado por Cunha et al. (2013), los resultados no presentaron diferencias significativas. Esto reafirma lo dicho por Leiva & Araujo (2007) donde mencionan la capacidad del programa en identificar gotas superpuestas, claramente visible cuando sobre las mismas tarjetas se analizaron manualmente, a pesar que el análisis visual puede estar sujeto a errores en el conteo y medición, principalmente debido a la dificultad del proceso.

Parámetro relacionado con los espectros de tamaño de gota

Diámetro volumétrico mediano (DVM, también conocido como  $DV_{0.5}$ ).

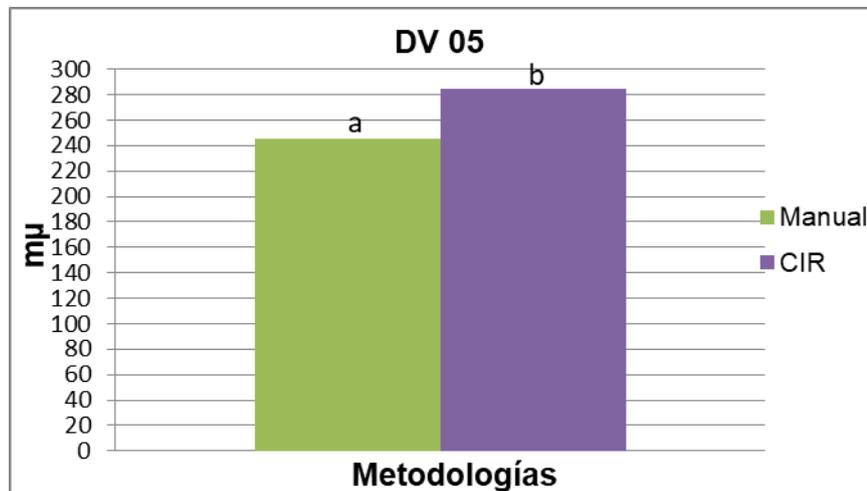


Figura 7. Resultados del diámetro volumétrico mediano  $DV_{05}$  según metodologías. Testigo (manual), programas CIR (automáticos) para la pastilla AP: abanico plano convencional. Letras diferentes sobre las columnas indican diferencias significativas ( $p \leq 0,05$ ) según el test de LSD Fisher.

En Figura 5 se visualiza el comportamiento del programa automático respecto a la metodología manual para el parámetro diámetro volumétrico mediano ( $DV_{0,5}$ ). Los valores cuantificados por CIR resultaron mayores a T (285 vs 245), presentando diferencias significativas entre métodos de análisis. Cunha et al. (2013) también encontraron diferencias significativas entre los tratamientos. Sin embargo, a diferencia de este ensayo, los valores mayores fueron encontrados en la lectura manual. Este resultado podría explicarse a través de los coeficientes de expansión utilizados por el programa, si bien los valores utilizados no son especificados, los coeficientes deberían ser diferentes en función del tamaño de gota evaluado. En este sentido, si las gotas halladas por Cunha et al. (2013) fueron diferentes en tamaño a las encontradas en este ensayo, es posible visualizar diferencias en los datos arrojados. Otra fuente de variación puede estar dada por la velocidad de desplazamiento del equipo de pulverización  $4,72 \text{ m seg}^{-1}$  ( $17 \text{ km h}^{-1}$ ) y la relación posición tarjeta-objetivo/botalón, generando que las gotas al impactar sobre el blanco presentes formas alargadas, lo que podría ocasionar errores en el resultado global arrojado por el programa. Otra posible causa de error se halla relacionada a los filtros utilizados para separar el color de fondo del papel (amarillo) del color de las improntas (azul). La coloración azul generada sobre la tarjeta al impactar una gota posee una variabilidad de tonos azulados producto de la expansión de la misma gota. Smith et al. (2000) han identificado alrededor de 90 tonos de colores entre amarillo y azul. Este comportamiento junto con que se trabajan con tamaños muy pequeños en el orden de micras, la dificultad de procesamiento aumenta.

## Conclusiones

Para el parámetro Número de Impactos por cm<sup>2</sup> el programa CIR 1.5 se comporta de igual forma que la evaluación manual a ojo con lupa.

Para el parámetro DV0,5 el programa CIR 1.5 presenta valores mayores que la evaluación manual a ojo con imágenes digitalizadas.

Como sugerencia, se debería determinar su comportamiento en otros tipos de pastillas y con otros programas presentes en el mercado.

## Agradecimientos

Quiero agradecer en primera instancia a Dios y segundo, al grupo de trabajo (amigos) del curso de Mecanización Agraria que han motivado la publicación del presente trabajo.

## Referencias

- Chaim, A.; Maia, A. H. N.; Pessoa, M. C. P. Y. 1999. Estimativa de deposição de agrotóxicos por análise de gotas. *Pesq. Agropec. Bras.*, v. 34, n. 6, p. 963-969.
- Harris, M., Karper, E., Stacks, G., Hoffman, D., DeNiro, R., Cruz, P., et al. (2001). Writing labs and the Hollywood connection. *Journal of Film Writing*, 44(3), 213-245.
- Cunha, J.P.A.R., Farnese, A.C., Olivet, J.J., 2013. Computer programs for analysis of droplets sprayed on water sensitive papers. *Planta Daninha* 31, n.3, p. 715-720.
- Slifka, M. K., & Whitton, J. L. (2000) Clinical implications of dysregulated cytokine production. *Journal of Molecular Medicine*, doi:10.1007/s001090000086.
- Di Rienzo J.A., Casanoves F., Balzarini M.G., Gonzalez L., Tablada M., Robledo C.W. InfoStat versión 2020. Centro de Transferencia InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. URL <http://www.infostat.com.ar>
- Giles, D., & Downey, D. 2003. Quality control verification and mapping for chemical application. *Precision Agriculture*, 4, 103-124.
- Hoffmann, W. C. & Hewitt, A. J. 2005. Comparison of three imaging systems for water sensitive papers □ technical note. *American Society of Agricultural and Biological Engineers*, 21(6), 961-964.
- Leiva, P.D. y Cordeiro Araujo, E. 2007. Comparación de programas de computación para recuento y tipificación de impactos de aspersión sobre tarjetas sensibles. INTA, EEA Pergamino - Agrotec Tecnología Agrícola e Industrial Ltda (Pelotas, RS, Brasil).
- Márquez, L. 2007. Pulverización y pulverizadores neumáticos. *Agrotécnica*. Año X. N°2. Febrero 2007. pp. 37-41.
- Merani, V. H., Guilino, F. D., Vazquez, J. M., Larrieu, L., Ferro, D. A., Platz, P., □ Mur, M. (2023). Pulverizaciones agrícolas. Distribución y pérdidas de producto con diferentes boquillas. *Ciencias Agronómicas*, (41), e030. <https://doi.org/10.35305/agro41.e030>.
- Mur, M., Ponce, M. J., Vázquez, J. M., Guilino, F., Merani, V., Palancar, T., & Balbuena, R. H. (2018a). Aplicación de agroquímicos en cultivos de soja (*Glycine max* L Merr); evaluación del efecto de diferentes técnicas sobre la eficiencia de distribución. *Revista de la Facultad de Agronomía, La Plata* (2018). 117(1): 77-88.
- Mur, M., Ponce, M. J., Guilino, F., Merani, V. H., & Balbuena, R. H. (2018b). Pulverización con alto y bajo volumen en rastrojo de sorgo. Eficiencia y riesgos ambientales de la aplicación. *UNR. Ciencias Agronómicas*. 32: 34-42.
- Ramos, H. H. Tecnología de aplicação de agrotóxicos. *Fitopatologia brasileira*. Fortaleza, 2000, vol. 25 (suplemento), n. 217-474, p. 275.
- Smith, D. B., Askew, S. D., Morris, W. H., Shaw, D. R., & Boyette, M. (2000). Droplet size and leaf morphology effects on pesticide spray deposition. *Transactions of the ASAE*, 43(2): 255-259.
- Standard, I.S.O. (2018). 10625: Equipment for crop protection--sprayer nozzles-colour coding for identification. International Organization for Standardization. Switzerland. Disponible en: <https://www.iso.org/standard/70624.html>.
- Syngenta 2002. Water sensitive paper for monitoring spray distributions. Syngenta Crop Protection, CH - 4002, Basel.
- Calfee, R. C., & Valencia, R. R. (1991). *APA guide to preparing manuscripts for journal publication*. Washington, DC: American Psychological Association.

## Emergencia agropecuaria de precisión

María Cecilia ORONA – Pablo Andrés FIGUEROA

[ma.cecilia.orona@gmail.com](mailto:ma.cecilia.orona@gmail.com) – [pfigueroacba@gmail.com](mailto:pfigueroacba@gmail.com) (Córdoba, Córdoba Argentina).

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

### Resumen.

#### Problema/Oportunidad:

La Ley 7121 de Emergencia Agropecuaria de la Provincia de Córdoba, vigente desde 1984, no contempla las nuevas tecnologías aplicadas al agro, lo que limita su capacidad para enfrentar emergencias climáticas modernas y optimizar la producción. La creciente frecuencia de eventos climáticos extremos y la evolución de tecnologías como la agricultura de precisión destacan la necesidad de una normativa adaptada a estas herramientas.

#### Objetivos:

El objetivo principal es integrar nuevas tecnologías en la gestión de emergencias agropecuarias para mejorar la eficiencia, resiliencia y productividad del sector agrícola y ganadero. Se busca optimizar la respuesta a eventos adversos mediante herramientas tecnológicas avanzadas como sensores remotos, drones, y sistemas de información geográfica (SIG).

#### Métodos:

Se realizará un análisis de la normativa existente y su relación con las nuevas tecnologías. Se propondrán modificaciones para fomentar el uso de estas herramientas y se diseñará un plan para su implementación.

#### Resultados Cuantitativos:

La propuesta incluirá métricas para medir la mejora en la eficiencia de monitoreo y respuesta, la reducción de pérdidas productivas y la optimización de la gestión de datos agrícolas. Se espera una mejora en la capacidad de respuesta y una reducción de los impactos negativos de eventos climáticos.

#### Importancia:

Actualizar la Ley 7121 para incorporar nuevas tecnologías fortalecerá la capacidad de la provincia para manejar emergencias agropecuarias, mejorará la resiliencia del sector y contribuirá a la sostenibilidad de la producción agropecuaria en Córdoba. La integración de tecnologías avanzadas promoverá una agricultura más eficiente y adaptativa, esencial para enfrentar los desafíos climáticos actuales.

## **Palabras clave.**

Ley 7121, Emergencia Agropecuaria, nuevas tecnologías, agricultura de precisión, sensores remotos, drones, sistemas de información geográfica, SIG, eficiencia, resiliencia, productividad, monitoreo, respuesta, impacto socioeconómico, adaptación normativa, sostenibilidad.

## **Introducción**

El entorno legal en el que operan las actividades agropecuarias es complejo y está en constante evolución. Desde regulaciones sobre la producción y comercialización de alimentos hasta normativas ambientales y de seguridad laboral, las leyes juegan un papel crucial en todos los aspectos de la gestión agrícola.

Por lo tanto, es esencial que los profesionales del sector comprendan en detalle estas regulaciones para operar de manera efectiva, legal y sostenible. Los participantes explorarán detalladamente leyes y regulaciones pertinentes al sector, normativas ambientales y responsabilidades legales.

En el contexto actual, el sector agropecuario enfrenta diversos desafíos que requieren de una regulación eficiente y adaptada a las nuevas realidades y tecnologías. En este proyecto, se aborda la temática de la implementación de una normativa legal relacionada con la actividad agropecuaria, con el objetivo de promover la incorporación y el uso de nuevas tecnologías aplicadas al agro en la provincia de Córdoba, Argentina.

La norma seleccionada para este análisis es la Ley 7121 de Emergencia Agropecuaria de la provincia de Córdoba, la cual establece medidas para la gestión de emergencias en el sector agrícola y ganadero. Esta ley, vigente desde 1984, ha sido elegida por su relevancia en el ámbito agropecuario cordobés y su potencial para ser adaptada y modernizada para la promoción de nuevas tecnologías.

En primer lugar, se realiza un análisis detallado de la normativa existente, describiendo su alcance, objetivos y competencias orgánicas. Posteriormente, se examina la relación de esta ley con el cuidado del ambiente y los Objetivos de Desarrollo Sostenible (ODS), así como su impacto en los diferentes actores involucrados en el sector agropecuario.

Además, se investiga cómo la normativa propuesta se relaciona con las nuevas tecnologías aplicadas al agro, y se proponen modificaciones para fomentar su incorporación y uso en el sector. Se realiza un análisis de impacto socioeconómico para evaluar las posibles repercusiones de estas modificaciones en los diferentes actores de la cadena de producción agropecuaria.

A través de una comparativa nacional e internacional, se examinan otras regulaciones similares y se analizan sus enfoques regulatorios, efectividad y adaptación a contextos específicos, con el fin de obtener lecciones aprendidas y buenas prácticas para la implementación de la normativa propuesta en la provincia de Córdoba.

## **Elección y Análisis de una norma Legal**

Para el presente trabajo, he seleccionado una norma legal que en particular despierta mi interés por su vigencia, actualidad, importancia y relevancia.

La provincia de Córdoba, ha sido históricamente una región clave en la producción agropecuaria del país. Sin embargo, este sector vital se ve constantemente amenazado por una serie de fenómenos climáticos que ponen en riesgo su desarrollo y sostenibilidad.

Estos eventos, que pueden manifestarse en forma de sequías, inundaciones, heladas u otros eventos climáticos extremos, representan una seria preocupación para los agricultores y ganaderos cordobeses, así como para la economía provincial en su conjunto.

Una de las consecuencias más inmediatas de las emergencias agropecuarias es la pérdida de cultivos y la disminución en la producción de alimentos. Las sequías prolongadas pueden causar estragos en los cultivos, disminuyendo los rendimientos y provocando pérdidas económicas significativas para los agricultores. De manera similar, las inundaciones repentinas pueden destruir cultivos enteros y llevar a la pérdida de animales, lo que impacta negativamente en la cadena de suministro de alimentos y en la seguridad alimentaria tanto a nivel local como nacional.

Además de las pérdidas económicas directas, las emergencias agropecuarias también tienen un impacto en la infraestructura rural y en la capacidad de producción a largo plazo. Las inundaciones pueden dañar caminos rurales, puentes y sistemas de riego, dificultando el acceso a las áreas agrícolas y limitando la capacidad de los agricultores para cultivar sus tierras. Asimismo, las heladas tardías pueden arruinar las cosechas y afectar la calidad de los productos, lo que reduce la competitividad de los agricultores en el mercado.

Otra consecuencia importante de las emergencias agropecuarias es el impacto en la economía local y en el bienestar de las comunidades rurales. La agricultura y la ganadería son sectores fundamentales en la generación de empleo y en la dinamización de la economía en las zonas rurales de Córdoba. Cuando se producen emergencias agropecuarias, los agricultores y ganaderos pueden enfrentarse a dificultades financieras, endeudamiento y pérdida de ingresos, lo que afecta su calidad de vida y la viabilidad de sus negocios a largo plazo.

En la provincia de Córdoba, desde el año 1984, rige la Ley 7121 de Emergencia Agropecuaria de la Provincia de Córdoba. Esta norma tiene una estrecha relación con la actividad agropecuaria, ya que su objetivo principal es establecer mecanismos y medidas para hacer frente a situaciones de emergencia o desastre que afecten gravemente la producción agropecuaria en la provincia. Esta norma busca regular y proteger al sector agropecuario cordobés ante eventos imprevisibles o inevitables, como fenómenos climáticos adversos, desastres naturales, enfermedades o cualquier otro factor que pueda comprometer significativamente la capacidad productiva de la región.

La realidad agropecuaria que esta ley busca regular en la provincia de Córdoba es diversa y vital para su economía. Córdoba es una de las provincias argentinas con mayor desarrollo agropecuario, con una amplia variedad de cultivos y actividades ganaderas. La provincia cuenta con extensas áreas destinadas a la agricultura, donde se cultivan cereales como maíz, trigo y soja, así como también cultivos hortícolas y frutales. Además, la ganadería es otra actividad importante en la provincia, con la cría de ganado bovino, ovino y porcino.

El ámbito de aplicación de esta norma se circunscribe a la provincia de Córdoba y su autoridad de aplicación es el actual Ministerio de Bioagroindustria.

Las competencias se circunscriben en el contexto del Decreto N° 2206/2023 (ratificado por Ley N° 10.956) y la delegación de funciones y atribuciones dispuesta mediante el artículo 6° del Decreto 2449/2023 (Delegase en el señor Ministro de Bioagroindustria las funciones y atribuciones que le permitan conforme a derecho: a) Declarar el Estado de Emergencia y/o Desastre Agropecuario, previa

intervención de la Secretaría de Ingresos Públicos.).

La Comisión provincial de Emergencia Agropecuaria está integrada por representantes del Estado provincial, así como también por representantes de entidades civiles, empresariales y gremiales vinculadas al sector agropecuario. Su competencia orgánica incluye funciones como proponer al Poder Ejecutivo la declaración de emergencia agropecuaria o desastre, evaluar el daño causado, coordinar medidas de ayuda, gestionar créditos especiales, entre otras acciones dirigidas a mitigar los efectos de los eventos adversos sobre la actividad agropecuaria cordobesa.

### **Relación con el Cuidado del Ambiente y Objetivos de Desarrollo Sostenible**

La Ley 7121 de Emergencia Agropecuaria de la Provincia de Córdoba tiene una relación indirecta pero importante con el cuidado del ambiente y los Objetivos de Desarrollo Sostenible (ODS). Aunque su enfoque principal es gestionar situaciones de emergencia o desastre en el sector agropecuario, las medidas y acciones que promueve también pueden contribuir al cuidado del ambiente y al logro de varios ODS, especialmente aquellos relacionados con el agua (ODS 6), la producción agrícola sostenible (ODS 2), el trabajo decente y el crecimiento económico (ODS 8), y la acción por el clima (ODS 13).

Aunque la ley se enfoca principalmente en la gestión de emergencias agropecuarias, su implementación efectiva puede contribuir significativamente al cuidado del ambiente y al avance de varios Objetivos de Desarrollo Sostenible, fortaleciendo así la resiliencia de las comunidades rurales y promoviendo un desarrollo más sostenible en la provincia de Córdoba.

### **Relación con Nuevas Tecnologías**

La Ley 7121 de Emergencia Agropecuaria de la Provincia de Córdoba, aunque no menciona explícitamente las nuevas tecnologías aplicadas al agro, tiene una relación indirecta con este aspecto debido a su objetivo de proteger y promover la actividad agropecuaria en situaciones de emergencia o desastre.

Algunas formas en las que esta normativa se relaciona con las nuevas tecnologías aplicadas al agro:

- **Monitoreo y detección temprana de eventos climáticos:** Las nuevas tecnologías, como sensores remotos, drones y sistemas de monitoreo satelital, pueden ser utilizadas para detectar y prevenir eventos climáticos adversos que puedan afectar la producción agropecuaria. La Comisión Provincial de Emergencia Agropecuaria podría aprovechar estas herramientas para realizar un monitoreo más preciso y oportuno de las condiciones climáticas en la provincia de Córdoba, lo que permitiría una respuesta más rápida ante situaciones de emergencia.
- **Gestión de datos agrícolas:** Las tecnologías de la información y comunicación (TIC) pueden facilitar la recopilación, análisis y gestión de datos agrícolas relevantes para evaluar el impacto de eventos climáticos en la producción agropecuaria. La implementación de sistemas de información geográfica (SIG) y plataformas de gestión de datos agrícolas podría mejorar la capacidad de la Comisión Provincial de Emergencia Agropecuaria para realizar evaluaciones precisas del daño y determinar las áreas afectadas por emergencias agropecuarias.
- **Comunicación y difusión de información:** Las nuevas tecnologías, como aplicaciones móviles y plataformas en línea, pueden ser utilizadas para difundir información relevante sobre situaciones de emergencia agropecuaria, medidas de prevención y ayuda disponible para los productores afectados. La Comisión Provincial de Emergencia Agropecuaria podría aprovechar estas

herramientas para garantizar una comunicación efectiva y oportuna con los actores del sector agropecuario en la provincia de Córdoba.

- Innovación en prácticas agrícolas: Las nuevas tecnologías aplicadas al agro, como la agricultura de precisión, el uso de drones para pulverización de cultivos, la automatización de procesos agrícolas y el uso de sensores para la gestión del riego, pueden contribuir a mejorar la resiliencia de la producción agropecuaria ante eventos climáticos adversos. La Comisión Provincial de Emergencia Agropecuaria podría promover la adopción de estas tecnologías entre los productores afectados por emergencias agropecuarias, facilitando el acceso a capacitación y recursos para su implementación.

Aunque la Ley 7121 de Emergencia Agropecuaria de la Provincia de Córdoba no hace referencia directa a las nuevas tecnologías aplicadas al agro, su implementación efectiva podría beneficiarse de la utilización de estas herramientas para mejorar la detección, prevención, gestión y respuesta ante situaciones de emergencia agropecuaria en la provincia.

### **Propuestas de Modificación o Creación de Normativas**

Nuestro país, en la actualidad está atravesando por las consecuencias de una gran tragedia climática y sus repercusiones como lo ha sido la sequía. Hemos participado a poder ver las consecuencias del cambio climático y las innumerables emergencias agropecuarias que se han declarado en nuestro país en el último año.

En ese contexto, y ante el desarrollo de la agricultura de precisión, estimo necesario y útil, la creación de una normativa planificada que instaure el sistema de emergencia agropecuaria de precisión con la ayuda de las nuevas tecnologías con aplicación directa en el agro.

Esta es sin duda, una innovación que contribuye favorablemente a la producción y a la productividad agropecuaria, a la seguridad y bienestar del productor rural y a la preservación de la vida y del medio ambiente de la República Argentina.

Entiendo que con el uso de imágenes satelitales podremos actuar de algún modo anticipadamente y trabajar con el productor antes de la emergencia o del desastre. Soy del pensamiento que debemos actualizar la legislación respectiva y el paradigma en relación a las emergencias agropecuarias y no solo actuar a posteriori del evento climático adverso.

La agricultura en la Argentina ha incrementado notablemente su productividad en los últimos años gracias a la incorporación de diversas tecnologías y a la innovación científica en lo referido a técnicas modernas de manejo de cultivos. En este sentido, fueron fundamentales los aportes del manejo ecofisiológico de los cultivos, los avances en genética, la fertilización estratégica, como así también la agricultura de precisión, entre otros.

El dinamismo económico y social que impulsa la producción agrícola obedece en parte, a causas inherentes a la geografía y los recursos naturales y en parte a sus múltiples posibilidades de incorporación de nuevas tecnologías de aplicación directa.

El sector agrícola resulta de importancia estratégica para el desarrollo económico y social de nuestra provincia y del país. Su gran potencial de crecimiento fundamenta la incorporación de innovaciones tecnológicas. La digitalización e implementación de tecnologías con aplicación directa al agro se presenta como un instrumento esencial para su impulso y crecimiento, ofreciendo nuevas oportunidades de desarrollo a través de la denominada agricultura de precisión, los dispositivos IoT, la

inteligencia artificial, el manejo y procesamiento de datos, etc. La tecnología aporta nuevas, mejores y mayores herramientas que, empleadas de forma adecuada y precisa, potencian y coadyuvan los diferentes procesos de la producción agrícola.

Las agrotecnologías están vinculadas con la denominada agricultura inteligente o Agricultura 4.0. Este tipo de moderna agricultura recopila y analiza datos temporales y espaciales del cultivo, del suelo, del terreno o del clima, a través de sensores que facilitan información en tiempo real o a través de imágenes obtenidas mediante teledetección (satélites y drones) y los combina con otra información adicional para tomar decisiones y hacer un uso más eficiente y sostenible de los recursos disponibles, reduciendo así el uso de pesticidas y fertilizantes. Sus herramientas son la sensorización ambiental, el uso de drones y la teledetección, la utilización de sistemas predictivos y de la inteligencia artificial, la trazabilidad, y el manejo y procesamiento de grandes cantidades de datos.

El objetivo principal de este programa es utilizar las nuevas tecnologías aplicadas al sector agropecuario para mejorar la eficiencia, la productividad y la resiliencia en situaciones de emergencia. A través de la implementación de soluciones de precisión, buscamos optimizar la producción agrícola y ganadera, así como minimizar los impactos negativos causados por eventos climáticos adversos u otras emergencias.

Los Componentes del programa serían Monitoreo remoto y pronóstico del clima, Agricultura de precisión, Manejo del ganado, Comunicación y capacitación y respuesta rápida y apoyo financiero.

En base a la normativa elegida, se propone la creación de una norma para fomentar y propiciar la incorporación y uso de nuevas tecnologías aplicadas al agro.

### **Programa de Emergencia Agropecuaria de Precisión**

Objetivo:

El objetivo principal de este programa es utilizar las nuevas tecnologías aplicadas al sector agropecuario para mejorar la eficiencia, la productividad y la resiliencia en situaciones de emergencia. A través de la implementación de soluciones de precisión, buscamos optimizar la producción agrícola y ganadera, así como minimizar los impactos negativos causados por eventos climáticos adversos u otras emergencias.

Componentes del programa:

Monitoreo remoto y pronóstico del clima:

- Establecer una red de estaciones meteorológicas y sensores distribuidos en las zonas agrícolas y ganaderas clave.
- Recopilar datos climáticos en tiempo real y utilizar algoritmos de pronóstico para prevenir condiciones adversas con anticipación.
- Utilizar plataformas de análisis de datos para traducir la información climática en recomendaciones específicas para los agricultores y ganaderos.

Agricultura de precisión:

- Promover la adopción de tecnologías como la teledetección, drones y sistemas de información geográfica (SIG) para recopilar datos sobre los cultivos y los suelos.

- Utilizar imágenes satelitales y drones para obtener información detallada sobre la salud de las plantas, la calidad del suelo y el crecimiento de los cultivos.
- Implementar sistemas de riego y fertilización inteligentes que ajusten la cantidad y el momento de la aplicación de agua y nutrientes según las necesidades específicas de cada área.

#### Manejo del ganado:

- Utilizar sensores y dispositivos portátiles para monitorear la salud y el comportamiento del ganado.
- Implementar sistemas de identificación electrónica y seguimiento de los animales para mejorar la trazabilidad y facilitar la gestión del ganado en situaciones de emergencia.
- Establecer alertas tempranas basadas en datos para detectar enfermedades o comportamientos anormales en el ganado.

#### Comunicación y capacitación:

- Establecer plataformas de comunicación y colaboración en línea para compartir información entre los agricultores, ganaderos y expertos técnicos.
- Ofrecer capacitación y asistencia técnica para promover la adopción de tecnologías y buenas prácticas agrícolas y ganaderas.
- Desarrollar materiales educativos y guías de referencia para ayudar a los productores a tomar decisiones informadas durante situaciones de emergencia.

### **Proyecto de Ley de Emergencia Agropecuaria de Precisión con AgTech y Determinación de Área de Afectación Mediante Polígonos Georreferenciados mediante Imágenes Satelitales**

#### Artículo 1: Objetivo

El objetivo de esta ley es establecer un marco legal para la implementación de tecnologías agrícolas de precisión (AgTech) y la determinación de áreas de afectación en situaciones de emergencia en el sector agropecuario en la provincia de Córdoba.

Se busca utilizar imágenes satelitales y técnicas de georreferenciación para identificar y delimitar con precisión las áreas afectadas por eventos climáticos adversos u otras emergencias, y proporcionar apoyo oportuno a los agricultores y ganaderos afectados.

#### Artículo 2: Creación de una red de imágenes satelitales

Se establecerá una red provincial de imágenes satelitales de alta resolución, que abarcará todo el territorio nacional. Esta red estará bajo la supervisión y coordinación de la autoridad competente en materia agrícola.

#### Artículo 3: Monitoreo y análisis de imágenes satelitales

Se llevará a cabo un monitoreo regular utilizando imágenes satelitales para identificar cambios en los patrones de vegetación, la calidad del suelo y otras variables relevantes para el sector agropecuario.

Estos datos se analizarán utilizando técnicas de procesamiento de imágenes y georreferenciación.

#### Artículo 4: Determinación de áreas de afectación

Mediante el análisis de las imágenes satelitales y la aplicación de técnicas de georreferenciación, se establecerán polígonos georreferenciados que delimiten las áreas afectadas por eventos climáticos adversos u otras emergencias. Estos polígonos serán utilizados para determinar las zonas que serán consideradas en estado de emergencia agropecuaria.

#### Artículo 5: Declaración de emergencia agropecuaria

Una vez determinadas las áreas de afectación, se declarará el estado de emergencia agropecuaria en las zonas correspondientes. Esta declaración será realizada por la autoridad competente en materia agrícola, y se deberá comunicar de manera inmediata a los agricultores y ganaderos afectados.

La delimitación del área afectada será instrumentada mediante dispositivos o metodologías agtech que disponga la autoridad de aplicación respectiva.

#### Artículo 6: Implementación de AgTech

En las áreas declaradas en estado de emergencia agropecuaria, se promoverá la implementación de tecnologías agrícolas de precisión (AgTech). Se fomentará el uso de drones, sensores remotos, sistemas de riego inteligente y otras herramientas tecnológicas que ayuden a optimizar la producción agrícola y ganadera, y mitigar los impactos de la emergencia.

#### Artículo 7: Apoyo financiero y asistencia técnica

El Estado proporcionará apoyo financiero y asistencia técnica a los agricultores y ganaderos afectados por la emergencia agropecuaria. Se establecerán programas de financiamiento, seguros agrícolas y capacitaciones especializadas para ayudar en la recuperación y rehabilitación de las actividades agropecuarias.

#### Artículo 8: Coordinación interinstitucional

Se promoverá la coordinación entre las diferentes entidades gubernamentales, organizaciones no gubernamentales, empresas privadas y otras partes interesadas relevantes en la implementación de esta ley.

### **Detalles de la Propuesta**

#### Ámbito Territorial de Aplicación:

- La propuesta de ley de emergencia agropecuaria de precisión con AgTech y determinación de área de afectación mediante polígonos georreferenciados mediante imágenes satelitales se aplicará en la provincia de Córdoba

#### Vigencia y Actores Involucrados:

La vigencia de esta ley será establecida una vez aprobada por la legislatura provincial.

Los actores involucrados incluyen:

- Agricultores y ganaderos afectados por emergencias agropecuarias.
- Autoridad competente en materia agrícola (a definir en la ley).
- Entidades gubernamentales.
- Organizaciones no gubernamentales.
- Empresas privadas del sector agropecuario.
- Proveedores de tecnologías AgTech.
- Profesionales especializados en georreferenciación e interpretación de imágenes satelitales.

Objeto Principal de la Norma y Autoridad de Aplicación:

- La norma tiene como objetivo establecer un marco legal para:
- La implementación de tecnologías agrícolas de precisión (AgTech).
- La determinación de áreas de afectación en situaciones de emergencia en el sector agropecuario.
- La autoridad de aplicación de la propuesta será la entidad designada por la legislatura provincial con competencia en materia agrícola. Ministerio de Bioagroindustria

Fundamentación de la Necesidad de la Norma:

### **Evaluación de Impacto Socioeconómico**

La propuesta de una nueva ley de emergencia agropecuaria que incorpore nuevas tecnologías aplicadas al agro tendría un impacto significativo en el sector agropecuario de la provincia de Córdoba. A continuación, se realiza un análisis detallado del posible impacto de esta normativa en diferentes actores dentro de la cadena de producción:

Pequeños productores agrícolas y ganaderos:

**Beneficios:** Los pequeños productores se verían beneficiados por la promoción de nuevas tecnologías que mejorarían la eficiencia y la productividad de sus actividades. La incorporación de tecnologías como la agricultura de precisión, el uso de drones para la monitorización de cultivos y la gestión inteligente del agua les permitiría optimizar el uso de recursos y reducir costos.

**Desafíos:** Sin embargo, algunos pequeños productores podrían enfrentar desafíos para acceder a las nuevas tecnologías debido a limitaciones financieras o falta de capacitación. Por lo tanto, sería necesario implementar programas de financiamiento y capacitación específicos para este sector.

Medianos y grandes productores:

**Adopción de tecnologías avanzadas:** Los medianos y grandes productores tendrían la capacidad financiera y la infraestructura para adoptar rápidamente nuevas tecnologías avanzadas. Esto les permitiría mejorar la eficiencia, aumentar la producción y reducir los riesgos asociados a eventos

climáticos adversos.

**Competitividad:** La implementación de tecnologías innovadoras les otorgaría una ventaja competitiva en el mercado, tanto a nivel nacional como internacional. Además, les permitiría diversificar sus actividades y explorar nuevos mercados.

**Empresas agroindustriales:**

**Integración vertical:** Las empresas agroindustriales podrían aprovechar las nuevas tecnologías para integrar verticalmente su cadena de producción, desde la producción agrícola hasta el procesamiento y la comercialización. Esto les permitiría mejorar la trazabilidad, la calidad y la seguridad alimentaria de sus productos.

**Eficiencia operativa:** La automatización de procesos y el uso de tecnologías de la información les permitiría mejorar la eficiencia operativa y reducir costos en todas las etapas de la cadena de valor.

**Instituciones de investigación y desarrollo:**

**Colaboración:** Las instituciones de investigación y desarrollo tendrían un papel fundamental en la promoción e implementación de nuevas tecnologías en el sector agropecuario. La colaboración entre el sector público y privado, así como la transferencia de conocimientos y tecnología, serían clave para el éxito de la normativa propuesta.

**Innovación:** La normativa podría estimular la inversión en investigación e innovación en el desarrollo de nuevas tecnologías adaptadas a las necesidades específicas del sector agropecuario de la provincia de Córdoba.

La normativa propuesta tendría un impacto positivo en el sector agropecuario de la provincia de Córdoba al promover la adopción de nuevas tecnologías que mejorarían la eficiencia, la productividad y la competitividad de los productores y empresas agroindustriales. Sin embargo, sería importante implementar medidas adicionales para garantizar que los pequeños productores también puedan beneficiarse de estas tecnologías y que exista una distribución equitativa de los beneficios en toda la cadena de producción.

## **Comparativa nacional y/o Internacional**

Para comparar la normativa propuesta con regulaciones similares a nivel federal e internacional, podemos examinar algunas leyes y políticas relacionadas con la emergencia agropecuaria y la incorporación de nuevas tecnologías en el sector agrícola en diferentes países:

**Ley de Emergencia Agropecuaria de Argentina:**

A nivel federal, Argentina cuenta con la Ley Nacional de Emergencia Agropecuaria (Ley 26.509), que establece medidas de asistencia para productores afectados por desastres naturales. Esta ley proporciona beneficios fiscales y créditos blandos para la recuperación de las zonas afectadas.

**Comparación:** Si bien la ley nacional aborda la emergencia agropecuaria, la propuesta de adaptación de la Ley 7121 de la provincia de Córdoba busca ampliar el enfoque para incluir la promoción y el uso de nuevas tecnologías en el sector agrícola.

**Políticas de la Unión Europea:**

La Política Agrícola Común (PAC) de la Unión Europea incluye medidas de apoyo para los agricultores en caso de desastres naturales, como sequías o inundaciones. Además, la PAC ha promovido la adopción de tecnologías sostenibles en la agricultura, como la agricultura de precisión y la gestión inteligente del agua.

Comparación: Si bien la PAC aborda la emergencia agropecuaria y promueve la adopción de nuevas tecnologías, la propuesta de la Ley 7121 de Córdoba se enfoca específicamente en la integración de tecnologías modernas para la gestión de emergencias agropecuarias.

Políticas en Estados Unidos:

En Estados Unidos, la Farm Bill incluye disposiciones para ayudar a los agricultores afectados por desastres naturales. Además, el Departamento de Agricultura de Estados Unidos (USDA) ha implementado programas de subvenciones y préstamos para la adquisición de tecnologías agrícolas avanzadas.

Comparación: Aunque existen programas de asistencia para emergencias agropecuarias y para la adquisición de tecnología en Estados Unidos, la propuesta de la Ley 7121 de Córdoba se centra en la coordinación de esfuerzos y en la promoción activa de la adopción de nuevas tecnologías dentro de una jurisdicción provincial específica.

En términos de similitudes, todas estas regulaciones buscan proporcionar apoyo a los agricultores afectados por desastres naturales y promover prácticas agrícolas sostenibles. Sin embargo, la propuesta de adaptación de la Ley 7121 de Córdoba se distingue por su enfoque específico en la integración de nuevas tecnologías en la gestión de emergencias agropecuarias, lo cual puede ser una estrategia innovadora para abordar los desafíos en el sector agrícola.

## Conclusiones

La situación problemática que se trata de resolver con la propuesta de la Emergencia Agropecuaria de Precisión en la Provincia de Córdoba se centra en la ineficiencia y la falta de precisión en la gestión de emergencias agropecuarias. En la actualidad, la provincia enfrenta desafíos significativos relacionados con la detección temprana, evaluación precisa y respuesta efectiva ante eventos climáticos adversos y otras emergencias que afectan al sector agropecuario.

La falta de herramientas tecnológicas avanzadas y protocolos claros de actuación dificulta la identificación y delimitación precisas de las áreas afectadas, lo que puede provocar demoras en la respuesta y la asignación de recursos. Además, la ausencia de un marco legal específico para la gestión de emergencias agropecuarias limita la capacidad de las autoridades para coordinar acciones y brindar apoyo eficaz a los productores afectados.

Después de un exhaustivo análisis y desarrollo de la propuesta sobre la Emergencia Agropecuaria de Precisión en la Provincia de Córdoba, se llega a las siguientes conclusiones:

La implementación de tecnologías de precisión, como las imágenes satelitales y la georreferenciación, representa una oportunidad invaluable para mejorar la detección y respuesta ante emergencias agropecuarias en Córdoba. Estas herramientas permiten una identificación precisa de las áreas afectadas, lo que facilita la toma de decisiones y la asignación de recursos durante situaciones de crisis.

La ausencia de un marco legal específico para la gestión de emergencias agropecuarias en la provincia resalta la importancia de desarrollar una legislación que promueva el uso de tecnologías de precisión y establezca procedimientos claros para la declaración y manejo de estas situaciones.

La propuesta de legislación agropecuaria de precisión no solo contribuirá a mitigar los impactos

negativos de las emergencias en el sector agrícola y ganadero, sino que también promoverá la adopción de prácticas más eficientes y sostenibles, mejorando la resiliencia y competitividad del sector.

La coordinación entre entidades gubernamentales, organizaciones no gubernamentales y otros actores relevantes será fundamental para la implementación exitosa de la propuesta. La colaboración permitirá aprovechar al máximo los recursos disponibles y garantizar una respuesta efectiva ante emergencias agropecuarias.

La propuesta de legislación agropecuaria de precisión refleja el compromiso de la provincia de Córdoba con el desarrollo sostenible y la protección del medio ambiente. Al promover el uso de tecnologías avanzadas y prácticas agrícolas más sustentables, se busca garantizar la viabilidad a largo plazo del sector agropecuario.

Este trabajo de investigación sobre la Emergencia Agropecuaria de Precisión en la Provincia de Córdoba presenta varias proyecciones y posibilidades de ampliación.

Una vez desarrollada la propuesta legislativa, se podría avanzar en su implementación práctica, trabajando en conjunto con autoridades gubernamentales y actores del sector agropecuario para llevar a cabo pilotos o programas de prueba que demuestren la viabilidad y eficacia de las tecnologías de precisión en la gestión de emergencias.

Sería relevante realizar estudios para evaluar el impacto de la legislación propuesta en términos de reducción de pérdidas agrícolas, mejora de la resiliencia del sector y beneficios económicos para los productores. Esto permitiría ajustar y mejorar continuamente la implementación de la legislación.

Se podrían llevar a cabo investigaciones adicionales para profundizar en aspectos específicos relacionados con la gestión de emergencias agropecuarias, como la optimización de algoritmos de georreferenciación, el desarrollo de sistemas de alerta temprana basados en datos satelitales, o el análisis de la percepción y adaptación de los productores frente a estas tecnologías.

Una vez validada la propuesta en la provincia de Córdoba, se podría considerar su extensión a otras regiones del país o incluso a nivel nacional, adaptando la legislación y las tecnologías a las características y necesidades específicas de cada área.

Sería beneficioso establecer colaboraciones interdisciplinarias con investigadores, profesionales y organizaciones del ámbito tecnológico, agrícola, ambiental y legal para enriquecer la propuesta y asegurar su éxito a largo plazo



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Referencias

Comisión de Emergencia Agropecuaria. (1984). Ley 7.121. Boletín Oficial, 23 de octubre de 1984. Córdoba, 5 de octubre de 1984.

Ministerio de Bioagroindustria. (n.d.). Emergencia Agropecuaria. Recuperado de <https://bioagroindustria.cba.gov.ar/?p=2276>

Naciones Unidas. (n.d.). Objetivos de desarrollo sostenible. Recuperado de <https://www.un.org/sustainabledevelopment/es/>

Ley 26.509, Sistema Nacional para la Prevención y Mitigación de Emergencias y Desastres Agropecuarios. (2009). Sancionada el 20 de agosto de 2009 y promulgada el 27 de agosto de 2009.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Evaluación del impacto del manejo sitio-específico del nitrógeno sobre la huella de carbono del bioetanol de maíz

Ponieman, K.D.<sup>1,2</sup>, Bongiovanni, R.<sup>3</sup>, Hilbert, J.<sup>4</sup>, Battaglia, M.<sup>5</sup>, Cipriotti, P.A.<sup>6</sup>, Espósito, G.<sup>7</sup>

<sup>1</sup> Instituto de Ingeniería Rural, INTA, Buenos Aires, Argentina. [ponieman.karen@inta.gob.ar](mailto:ponieman.karen@inta.gob.ar)

<sup>2</sup> Facultad de Agronomía □ EPG, Universidad de Buenos Aires / CONICET, Argentina.

<sup>3</sup> INTA Manfredi, Córdoba, Argentina.

<sup>4</sup> Energy & Environment Consulting Services (EEC), Argentina.

<sup>5</sup> Renewable LLC, Freeville, NY, Estados Unidos.

<sup>6</sup> Facultad de Agronomía □ IFEVA, Universidad de Buenos Aires / CONICET, Argentina

<sup>7</sup> Universidad de Río Cuarto, Córdoba, Argentina.

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** *La huella de carbono (HC) es un indicador globalmente utilizado para cuantificar la presión humana sobre el ambiente natural, y en los últimos años, se ha incorporado a las regulaciones regionales e internacionales del comercio de granos y combustibles de biomasa. El objetivo de este trabajo fue caracterizar la respuesta de la HC del bioetanol de maíz en función de la fertilización nitrogenada (N), considerando la variabilidad espacial y temporal mediante técnicas de estadística espacial. Se analizó una base de datos sitio-específicos en campos de productores de maíz, con ensayos de hasta 6 niveles de fertilización con urea, a través de un gradiente de elevación, en 5 campañas distribuidas a lo largo de 12 años, en la región centro-sur de la provincia de Córdoba, Argentina. Se contó con datos anuales de una planta industrial para representar el transporte de la materia prima y el procesamiento industrial de bioetanol de maíz en Argentina. La HC se estimó mediante la metodología de Análisis de Ciclo de Vida (ACV) y se adaptó el modelo econométrico espacial MEME SAR (Espósito, 2013; Balboa, 2014) para explicar la HC en función de N. Se encontraron resultados significativos para ajustar funciones de HC específicas según las precipitaciones de la campaña y la topografía del lote. Estos hallazgos subrayan la importancia de considerar tanto las condiciones climáticas anuales como la variabilidad espacial del lote para optimizar la fertilización nitrogenada, maximizando los rendimientos agrícolas y económicos y minimizando la HC del bioetanol de maíz.*

**Palabras clave.** *Huella de carbono, Análisis de Ciclo de Vida, Estadística Espacial, Biocombustibles, Fertilización nitrogenada.*

## Introducción

El uso de instrumentos de política ambiental, como la huella de carbono (HC), que buscan valorizar en términos no monetarios las externalidades ambientales para su incorporación en la economía, ha ido en aumento (Georgescu-Roegen, 1971; Lopez Sardi & Cattaneo, 2013). Tal es el caso de la Directiva Europea 2018/2001 (Unión Europea, 2018) que establece un marco regulador en la Unión Europea basado en la reducción de la HC para los biocombustibles producidos en la Unión o importados. Este contribuye a los Objetivos de Desarrollo Sostenible de la Agenda de las Naciones Unidas (Naciones Unidas, 2015). Así, más empresas de todo el mundo están incorporando la HC como indicador ambiental en los reportes de sustentabilidad para la planificación, medición, evaluación y comunicación de los avances e impactos de la organización en aspectos ambientales, económicos y sociales.

Los biocombustibles surgen como una alternativa para reducir las emisiones de dióxido de carbono resultantes de la extracción y uso de combustibles fósiles. En Argentina, estudios recientes utilizando la metodología de ACV indicaron que el bioetanol de maíz podría generar una reducción de hasta 71-80% en las emisiones de gases de efecto invernadero (GEI) con respecto a los combustibles fósiles. En estos, la fase agrícola representa un 49% del total de GEI producidos durante toda la cadena de producción de bioetanol de maíz (Bongiovanni & Tuninetti, 2021; Hilbert et al., 2021). Asimismo, esta etapa está fuertemente influenciada por las condiciones locales y específicas de cada campaña. Incluir la variabilidad espacial y temporal en las evaluaciones de sostenibilidad desde una perspectiva integral del sistema agroindustrial es fundamental (Petrielli et al., 2023). En este sentido, las tecnologías digitales permiten monitorear el ambiente, generando grandes cantidades de datos, para contribuir en la comprensión de la complejidad del agroecosistema y toda su cadena de producción. Estas tecnologías proveen información detallada para la toma de decisiones de manejo con el fin de potenciar tanto la productividad (Kamilaris et al., 2017; Coble et al., 2018) como la sustentabilidad del sistema (Delgado et al., 2019).

La producción de maíz se ve afectada por múltiples factores interrelacionados, por lo que el análisis de regresión lineal simple no permite explicar adecuadamente la respuesta del rendimiento (Lambert et al., 2004). Diversos estudios han identificado a la fertilización nitrogenada como un punto crítico en la formación del rendimiento del maíz, así como también en las emisiones de GEI asociadas (Ma et al., 2012; Wang et al., 2015; Yan et al., 2015; Qi et al., 2018; Piñero et al., 2019; Bongiovanni & Tuninetti, 2021; Hilbert et al., 2021; Lee et al., 2021). A su vez, la eficiencia de uso del nitrógeno se ve afectada por la variabilidad de precipitaciones (Eyhéabide, 2012; Socchiuzzi et al., 2018) y por la zonificación del lote (Boone et al., 2016; Arrieta et al., 2018). En este sentido, los datos de rendimiento presentan heterogeneidad y autocorrelación espacial, características que deben ser consideradas en su procesamiento (Lambert et al., 2004). Además, cuando la variabilidad espacial y temporal entre y dentro de los campos es significativa, es relevante aplicar un manejo variable por ambiente, a través de las herramientas de agricultura de precisión (Tantalaki et al., 2019).

Las técnicas de estadística espacial permiten analizar grandes cantidades de datos considerando la heterogeneidad espacial. Estas técnicas contribuyen a la comprensión detallada del impacto de la fertilización nitrogenada sobre el rendimiento de maíz y su huella de carbono (HC) en diferentes contextos climáticos y zonas de manejo; siendo la HC ampliamente utilizada como indicador para cuantificar la presión humana sobre el ambiente (Hoelstra & Wiedmann, 2014). A diferencia de métodos tradicionales, estas tienen la capacidad de manejar y analizar datos espaciales complejos para identificar patrones y relaciones que no serían evidentes con los enfoques clásicos. Esto es particularmente importante en la agricultura de precisión, donde la optimización del uso de insumos, como el nitrógeno, puede tener significativos beneficios tanto económicos como ambientales (Schimmelpfennig, 2016; Finger et al. 2019).

Trabajos previos han utilizado dichas técnicas de estadística espacial para estudiar la variabilidad del rendimiento de maíz a escala tanto regional (Zouabi & Peridy, 2015; Schwalbert et al., 2018; Jiang et al., 2019; Emediegwu et al., 2022) como sitio-específica (Bongiovanni, 2002; Espósito, 2013; Balboa, 2014). También, en la bibliografía se han estudiado patrones espaciales y temporales de las HC del maíz (Xu & Lan, 2017; Fan et al., 2022) y del bioetanol (Mekonnen et al., 2018) a escala regional con el objetivo de analizar distintas prácticas de mitigación en cada caso. Sin embargo, no se han encontrado estudios en la bibliografía que analicen a nivel sitio-específico la HC del bioetanol de maíz. El objetivo de este trabajo fue caracterizar la respuesta de la HC del bioetanol de maíz en función de la fertilización nitrogenada, considerando la variabilidad espacial topográfica de cada lote y la variabilidad temporal de las precipitaciones en cada campaña por medio de técnicas de estadística espacial. Se espera obtener funciones que describan la HC a diferentes dosis de N, posiciones topográficas y condiciones climáticas, para incorporar como funciones objetivo en la toma de decisiones sobre la dosis de fertilización óptima sitio-específica.

## Materiales y métodos

Se dispuso de una base de datos georreferenciada de forma sitio-específica de 18 ensayos en campos de productores agrícolas reales, con hasta 6 niveles de fertilización uniforme en maíz con urea (46-0-0), a través de un gradiente de elevación (Lowenberg-Deboer et al., 2000), en 5 campañas distribuidas a lo largo de 12 años, en la región centro-sur de la provincia de Córdoba, Argentina (Bongiovanni, 2002; Espósito, 2013). Se realizaron ensayos de fertilización nitrogenada a campo en lotes de típicos productores agrícolas de la zona, de acuerdo a los principios para llevar a cabo ensayos a campo (Brouder & Nielsen, 2000). Los datos presentan una escala espacial regular ajustados a una grilla rectangular de polígonos cuadrados de lado igual al ancho de la máquina cosechadora (9m×9m). La escala temporal del estudio abarca cinco campañas agrícolas, es decir el período comprendido entre el 1 de julio al 30 de junio del año siguiente, distribuidas a lo largo de 12 años (1998/1999-2009/2010): 1998/1999, 2000/2001, 2004/2005, 2005/2006, 2009/2010.

Se contó con datos anuales de una planta industrial seleccionada como caso representativo para estudiar el transporte de la materia prima y del procesamiento industrial de bioetanol a partir de maíz en Argentina. Estos corresponden a la campaña 2020/2021. El 92% de los camiones realizaron menos de 250 km por viaje transportando la materia prima desde los campos directa o indirectamente hacia la planta. Los 18 ensayos de fertilización se realizaron en campos ubicados en dicho radio de distancia, por lo que permiten representar la variabilidad de los campos de maíz que abastecen la planta de bioetanol. El transporte del maíz y el proceso industrial para la obtención de bioetanol se consideraron como subsistemas fijos en este trabajo de investigación, independientes del manejo agrícola implementado en el campo. Esto se justifica ya que la planta industrial tiene una capacidad de procesamiento independiente del rendimiento del cultivo. Estas etapas se tuvieron en cuenta como un balance de masa para la transformación de cada tonelada de maíz producida en el campo hasta la obtención de una tonelada de etanol en la planta industrial y su huella de carbono asociada.

Se estimó la HC del bioetanol para cada polígono cuadrado de la grilla regular del mapa de rendimiento mediante la metodología de Análisis de Ciclo de Vida (ACV) evaluando la categoría de impacto cambio climático. La metodología de cálculo de la HC de producto descrita en Ponieman et al. (2023) sigue la Norma ISO 14067 (2018) y las directrices del Panel Intergubernamental de Cambio Climático (IPCC por sus siglas en inglés) 2006 y perfeccionadas en 2019 (IPCC, 2019). Luego, se adaptó el modelo econométrico espacial MEME SAR (Espósito, 2013; Balboa, 2014) para determinar el modelo que define a la HC del bioetanol de maíz [ $\text{gCO}_2\text{eq MJ}^{-1}$ ] en cada celda  $i$  del ensayo  $j$  en función de la dosis de nitrógeno (N). Este modelo considera errores autocorrelacionados espacialmente (Anselin, 2021), la dosis de N como variable regresora, el índice topográfico compuesto (CTI) y el índice de precipitaciones (IPP), y sus respectivas interacciones, como efectos espaciales y temporales fijos, y la localidad como efecto aleatorio. Se ha demostrado que el CTI es un buen indicador de la acumulación hídrica y carbono

orgánico en el suelo (Schmidt & Persson, 2003; Liu et al., 2006; Terra et al., 2006; Huang et al., 2008). En la región de estudio estas cualidades son características de las zonas bajas en el paisaje ondulado de Córdoba (Espósito, 2013). Se consideraron los dos terciles de CTI del conjunto de datos como valores umbrales en la definición de las tres zonas topográficas intra-lote. Por otro lado, el IPP se calculó para identificar años húmedos o secos de acuerdo a la precipitación acumulada en la campaña estudiada en cada ensayo con respecto a los valores históricos de cada campo [ $IPP_{SEP-FEB} = PP_{ACUMULADA} / PP_{ACUMULADA\ HISTÓRICA}$ ]. El IPP se consideró como una variable *dummy*, donde valores de IPP inferiores a 1 corresponden a años secos ( $IPP\ dummy = 1$ ) y valores de IPP mayores a 1 corresponden a años húmedos ( $IPP\ dummy = -1$ ). Los años húmedos se corresponden con mayores rendimientos promedio que los años secos, mediante una relación lineal con el IPP con un ajuste de  $R^2 = 79\%$  (Espósito, 2013). De esta forma, se incluye la cuestión espacial y temporal al modelar la HC del bioetanol.

Se utilizó el programa estadístico R y el editor RStudio, con el paquete `lme4` y `lmerTest`. Este modelo está determinado por la Ecuación 1.

$$HC_{ij} = \beta_0 + \beta_1 N_{ij} + \beta_2 CTI_{ij} + \beta_3 IPP_{ij} + \beta_4 N_{ij} CTI_{ij} + \beta_5 N_{ij} IPP_{ij} + \beta_6 CTI_{ij} IPP_{ij} + \beta_7 N_{ij} CTI_{ij} IPP_{ij} + \varepsilon \quad [1]$$

Donde  $HC_{ij}$  es la huella de carbono del bioetanol de maíz [ $g\ CO_2eq\ MJ^{-1}$ ] por cada celda  $i$  de  $9m \times 9m$  en cada ensayo  $j$ ,  $N_{ij}$  es la dosis de nitrógeno [ $kgN\ ha^{-1}$ ] aplicada en cada celda  $i$  del ensayo  $j$ ,  $CTI_{ij}$  es el índice topográfico compuesto en cada celda  $i$  del ensayo  $j$ ,  $IPP_{ij}$  como variable *dummy* (Húmedo = -1; Seco = 1) es el índice de precipitaciones en cada ensayo  $j$ ,  $\beta_0 - \beta_7$  son los parámetros de la ecuación de regresión,  $\varepsilon$  es el término de error del modelo con una especificación autorregresiva espacial (Anselin, 1999) [Ecuación 2].

$$y = X\beta + \varepsilon; \quad \varepsilon = \lambda W\varepsilon + \mu \quad [2]$$

Donde  $y$  es el vector ( $n \times 1$ ) de observaciones de la variable dependiente;  $X$  es una matriz ( $n \times k$ ) de observaciones de las variables predictoras fijas independientes;  $\beta$  es el vector de parámetros de efectos fijos del modelo;  $\varepsilon$  es el error de muestreo aleatorio con una especificación autorregresiva espacial (SAR) donde  $\lambda$  o *lambda* es el coeficiente de autorregresión espacial,  $W\varepsilon$  representa la estructura espacial  $W$  en el término de error  $\varepsilon$ , y  $\mu$  es el error independiente luego de tener en cuenta la relación espacial.

Se probó modelar la HC utilizando tres enfoques con diferente grado de complejidad: una relación lineal simple clásica donde solo intervino el N, un modelo clásico que incluye también como factores fijos a los índices CTI e IPP, y un modelo de estadística espacial considerando errores autocorrelacionados. Para las tres regresiones, se evaluaron los indicadores de regresión: R cuadrado, criterio de información de Akaike (AIC), criterio de Schwartz (BIC), indicador de máxima verosimilitud (MVR) y el índice de Moran.

## Resultados

En la Tabla 1 se presentan los coeficientes estimados en los modelos de HC del bioetanol, y los indicadores estadísticos de las regresiones. El modelo lineal clásico simple presenta un  $R^2$  de 0,14, explicando pobremente la relación entre las variables de HC y dosis de N. Además, este modelo presenta el menor valor de máxima verosimilitud y mayores valores de AIC y BIC. Cuando el modelo clásico incluye a los índices CTI e IPP como factores fijos, el  $R^2$  aumenta levemente a 0,22 y mejoran levemente los indicadores estadísticos. La inclusión de la variable IPP ha sido significativa para el corrimiento del parámetro lineal y la ordenada, mientras que la inclusión del CTI ha sido significativa únicamente para el corrimiento del parámetro lineal. No se observó una interacción significativa entre estas dos variables. El índice de Moran de 0,45 y 0,42, respectivamente, indica una moderada autocorrelación espacial, los valores de la variable respuesta tienden a ser similares en ubicaciones cercanas. El diagnóstico de la dependencia espacial indica que esta se presenta en los errores de la

estimación, ya que los valores de los estadísticos ML error y MLR error son mayores a ML lag y MLR lag. Los datos presentan heterocedasticidad de acuerdo a la prueba de Breusch-Pagan (1979). Por ello, es adecuado utilizar el modelo MEME SAR.

**Tabla 1. Coeficientes del modelo de huella de carbono (HC) del bioetanol de maíz estimados con un modelo clásico simple, un modelo clásico con la inclusión de IPP y CTI como factores fijos, y un modelo de error espacial MEME SAR adaptado de Espósito (2013). Se incluyen indicadores estadísticos y diagnóstico de la regresión.**

HC	Modelo Clásico Simple		Modelo Clásico + Efectos fijos		Modelo Espacial MEME SAR	
	Coefficientes	Valor p	Coefficientes	Valor p	Coefficientes	Valor p
$\beta_0$	21,78	<2e-16	21,60	<2e-16	22,39	1,02e-5
$\beta_1 N$	0,09	<2e-16	0,104	<2e-16	0,11	<2e-16
$\beta_2 CTI$			-0,029	0,514	-0,28	5,6e-6
$\beta_3 CTI N$			-0,001	0,026	0,00005	0,918
$\beta_4 IPP$			1,31	0,005	7,90	3,3e-14
$\beta_5 IPP N$			0,036	4,05e-12	0,04	<2e-16
$\beta_6 IPP CTI$			0,017	0,713	-0,28	5,84e-6
$\beta_7 IPP CTI N$			-0,0006	0,248	0,00031	0,487
$R^2$	0,14		0,22		0,51	
MVR	-83.357,5		-82.320,8		-77.518,2	
AIC	166.720,9		164.659,6		155.056,4	
BIC	166.744,8		164.731,1		155.135,8	
Índice de Moran	0,45		0,42		-	
Lambda	-		-		0,827	
Dependencia espacial	SC	Valor p	SC	Valor p		
ML lag	10.994,99	<0,0001	8.974,47	<0,0001		
MLR lag	293,26	<0,0001	291,67	<0,0001		
ML error	14.524,86	<0,0001	12.614,08	<0,0001		
MLR error	3.823,12	<0,0001	3.931,28	<0,0001		
SARMA	12.818,12	<0,0001	12.905,74	<0,0001		
Heterocedasticidad						
Test Breusch-Pagan	1.339,93**	<0,0001	6,64e+16	<0,0001		

- no corresponde

$\beta_{0-2}$ , representan los estimadores de los parámetros de las funciones al agregado de nitrógeno (N).

MVR, máxima verosimilitud restringida. AIC, criterio de información de Akaike. BIC, criterio de Schwartz.

SC, suma de cuadrados. ML, multiplicador de Lagrange tipo error o lag. MLR, multiplicador robusto de Lagrange tipo error o lag. SARMA, multiplicador de Lagrange (Anselin et al., 1996).

Según los indicadores estadísticos, el modelo espacial permite estimar mejor la HC del bioetanol de maíz en función de la cantidad de N aplicado, contemplando la variabilidad espacial y temporal mediante los efectos fijos y aleatorios incluidos en el modelo (Tabla 1). La inclusión de la variable *dummy* IPP ha sido significativa para el corrimiento de todos los parámetros: la ordenada y el parámetro lineal. En años húmedos (IPP *dummy* = -1), el coeficiente  $\beta_4 IPP$  afecta negativamente a la constante, mientras que el coeficiente  $\beta_5 IPP N$  disminuye la respuesta lineal al N aplicado.

Por otro lado, la inclusión del índice topográfico CTI ha sido significativa solo para el corrimiento del parámetro ordenada. A mayores valores de CTI (zonas bajas), el coeficiente  $\beta_2 CTI$  disminuye el valor de la constante. Asimismo, la interacción  $\beta_6 IPP CTI$  es significativa, indicando que las zonas responden distinto según el IPP de la campaña. Estos resultados sugieren la posibilidad de ajustar una función de HC de bioetanol de maíz dependiente de la dosis de N en distintas zonas topográficas del lote para años con distinta condición hídrica.

Dada la distribución de CTI en terciles y considerando el valor medio en cada tercil (Alta: 5,19; Media: 9,28; Baja: 19,44), las funciones lineales que caracterizan a cada zona topográfica en cada condición climática (húmedo/seco) quedan determinadas por los coeficientes del modelo lineal espacial graficados en la Figura 1. Se observa que la HC es significativamente menor en años húmedos que en secos (menor ordenada de la función); mientras que, en años secos, la respuesta a la fertilización nitrogenada es mayor que en húmedos (mayor pendiente de la función). Además, tanto en años secos como en húmedos, la zona baja muestra una menor HC. Esta diferencia entre zonas se atenúa cuando las precipitaciones superan los niveles históricos.

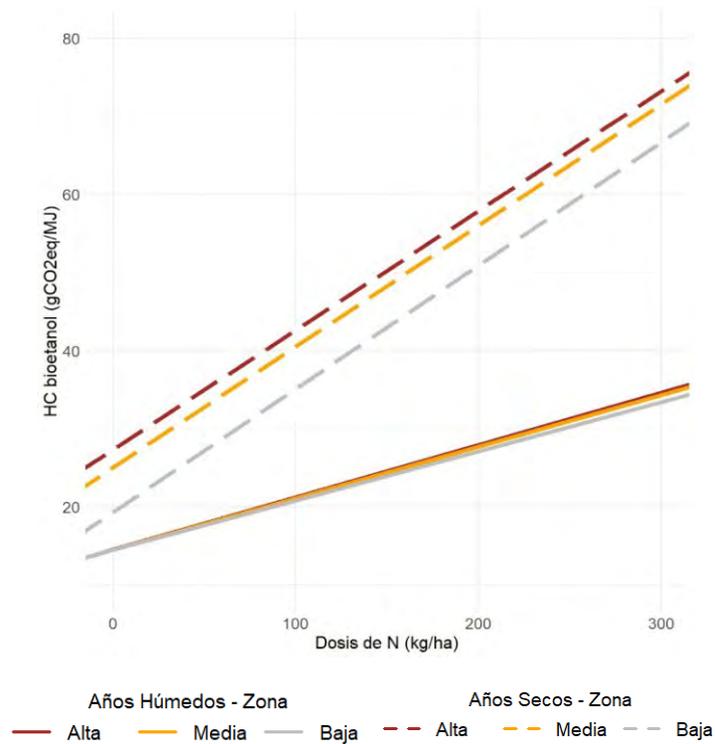


Figura 1. Función de respuesta estimada de la huella de carbono (HC) del bioetanol de maíz ( $\text{gCO}_2\text{eq MJ}^{-1}$ ) según la dosis de nitrógeno (N) aplicado ( $\text{kg ha}^{-1}$ ) con el modelo MEME SAR adaptado. Línea continua: años húmedos (IPP = -1). Línea punteada: años secos (IPP = 1). Marrón: zonas topográficas altas del lote (media CTI = 5,19). Naranja: zonas topográficas medias del lote (media CTI = 9,28). Gris: zonas topográficas bajas del lote (media CTI = 19,44).

## Discusión

El modelo desarrollado en este estudio permite explicar la relación entre la HC del bioetanol de maíz, la dosis de N aplicada, y factores climáticos y topográficos durante el período de estudio. Se encontraron evidencias significativas que justifican el ajuste de distintas funciones de HC para diferentes dosis de N, según las precipitaciones de la campaña y la topografía del lote resumida por el CTI. El factor climático influye tanto al parámetro de la ordenada como al de la pendiente de la función, mientras que el factor topográfico afecta significativamente a la ordenada.

Estos resultados indican que la variabilidad interanual de las precipitaciones tiene un impacto significativo en la HC del bioetanol de maíz, con una menor respuesta a la fertilización nitrogenada en años lluviosos en comparación con los años secos. La heterogeneidad espacial intra-lote caracterizada por las diferencias en la topografía, también desempeña un papel relevante en la regulación de la eficiencia de uso del nitrógeno, afectando en la respuesta de la HC de forma diferente en años húmedos o secos. Estos hallazgos son consistentes con estudios previos que han demostrado cómo la disponibilidad de agua y las posiciones del terreno pueden influir en la respuesta del maíz al nitrógeno aplicado (Bongiovanni, 2002; Espósito, 2013; Balboa, 2014; Lee et al., 2020).

La variabilidad temporal en las precipitaciones tiene un mayor impacto sobre la HC que la variabilidad espacial de la topografía intralote, sugiriendo que las estrategias de manejo de la fertilización deben adaptarse principalmente a las condiciones climáticas de cada año. Complementariamente, se podrían realizar ajustes específicos según la topografía del lote. Para validar los resultados encontrados se requiere otro set independiente de ensayos a campo realizados en condiciones similares. En trabajos futuros se podría repetir el análisis, agregando nuevas localidades, y evaluando el efecto de las nuevas variedades genéticas sobre la eficiencia del uso del N.

Los hallazgos aquí presentados subrayan la importancia de considerar tanto las condiciones climáticas anuales como la variabilidad espacial del lote para optimizar las prácticas de fertilización nitrogenada de forma tal que se maximicen los rendimientos agrícolas y económicos y se minimice la HC del bioetanol de maíz. La integración de datos espaciales y temporales en los modelos de manejo agrícola puede proporcionar una vía eficaz para mejorar la sostenibilidad de la producción de bioetanol y desarrollar estrategias de manejo específicas para diferentes escenarios agroclimáticos, con el objetivo de maximizar la eficiencia del uso del N y minimizar las emisiones de GEI.

## Conclusiones

Este estudio proporciona evidencia sólida de que tanto la dosis de fertilización nitrogenada como las condiciones climáticas y topográficas influyen significativamente en la HC del bioetanol de maíz, en el marco de los valores de referencia establecidos en las regulaciones regionales e internacionales del comercio de granos y combustibles de biomasa. La variabilidad en las precipitaciones anuales se destacó como un factor clave, afectando más la HC que la variabilidad topográfica intra-lote. Se destaca la importancia de adaptar las prácticas de fertilización nitrogenada a las condiciones climáticas específicas de cada año, además de considerar las características topográficas del lote para maximizar la eficiencia del uso del N y reducir las emisiones de GEI. La integración de datos espaciales y temporales en los modelos de manejo agrícola puede ser una herramienta eficaz para mejorar la sostenibilidad de la producción de bioetanol, así como también la eficiencia de la producción agrícola y los rendimientos económicos.

## Agradecimientos

Este trabajo de investigación fue financiado por una beca doctoral INTA-CONICET.

## Referencias

- Anselin, L. (1999). *Spatial Econometrics*. Bruton Center, School of Social Sciences, University of Texas at Dallas, Richardson, TX 75083-0688.
- Anselin, L. (2021). Spatial Models in Econometric Research. *Oxford Research Encyclopedia of Economics and Finance, March*.
- Arrieta, E. M., Cuchietti, A., Cabrol, D., & González, A. D. (2018). Greenhouse gas emissions and energy efficiencies for soybeans and maize cultivated in different agronomic zones: A case study of Argentina. *Science of the Total Environment, 625*, 199–208.
- Balboa, G. R. (2014). *Comparación agronómica de dos criterios de dosificación de nitrógeno en maíz en la llanura bien drenada del Centro y Sur de la Provincia de Córdoba*. Universidad Nacional de Río Cuarto, Facultad de Agronomía y Veterinaria, Maestría en Ciencias agropecuarias.
- Bongiovanni, R. G. (2002). *A Spatial Econometric Approach to the Economics of Site-Specific Nitrogen Management in Corn Production*. Purdue University, Graduate School.
- Bongiovanni, & Tuninetti. (2021). Huella de Carbono y Huella energética del etanol anhidro, producido en una mini destilería □Minidest□ en origen. *Revista de Investigaciones Agropecuarias* □15.
- Boone, L., Van linden, V., De Meester, S., Vandecasteele, B., Muylle, H., Roldán-Ruiz, I., Nemecek, T., & Dewulf, J. (2016). Environmental life cycle assessment of grain maize production: An analysis of factors causing variability. *Science of the Total Environment, 553*, 551–564.
- Breusch, T.S. & Pagan, A.R. (1979) A Simple Test for Heteroscedasticity and Random Coefficient Variation. *Econometrica, 47*, 1287-1294.
- Brouder, S., & Nielsen, R. 2000. On-Farm Research. In J. Lowenberg-Deboer, K. Erickson, & K. A. Vogel (Eds.), *Precision Farming Profitability* (pp. 103–112). Purdue University, West Lafayette, IN.
- Coble, K. H., Mishra, A. K., Ferrell, S., & Griffin, T. (2018). Big data in agriculture: A challenge for the future. *Applied Economic Perspectives and Policy, 40*(1), 79-96.
- Correndo, A. A., Gutierrez-Boem, F. H., García, F. O., Alvarez, C., Alvarez, C., Angeli, A., ... & Salvagiotti, F. (2021). Attainable yield and soil texture as drivers of maize response to nitrogen: A synthesis analysis for Argentina. *Field Crops Research, 273*, 108299.
- Delgado, J. A., Short Jr, N. M., Roberts, D. P., & Vandenberg, B. (2019). Big data analysis for sustainable agriculture on a geospatial cloud framework. *Frontiers in Sustainable Food Systems, 3*, 54.
- Emediegwu, L. E., Wossink, A., & Hall, A. (2022). The impacts of climate change on agriculture in sub-Saharan Africa: a spatial panel data approach. *World Development, 158*, 105967.
- Espósito, G. P. (2013). *Análisis de la Variabilidad Espacio-Temporal de la Respuesta al Nitrógeno en Maíz Mediante un Modelo Económico Mixto Espacial (MEME)*. Universidad Nacional de Córdoba, Facultad de Ciencias Agropecuarias, Escuela para Graduados.
- Eyhéabide, G. H. (2012). *Bases para el Manejo del Cultivo de Maíz*. Ediciones INTA. Instituto Nacional de Tecnología Agropecuaria.
- Fan, J., Guo, D., Han, L., Liu, C., Zhang, C., Xie, J., ... & Yin, L. (2022). Spatiotemporal dynamics of carbon footprint of main crop production in China. *International Journal of Environmental Research and Public Health, 19*(21), 13896.
- Finger, R., Swinton, S. M., El Benni, N., & Walter, A. (2019). Precision Farming at the Nexus of Agricultural Production and the Environment. *Annual Review of Resource Economics, 11*, 313–335.
- Georgescu-Roegen, N. (1971). *La Ley de la Entropía y el proceso económico* (Traducción al español 1996 (ed.)). Colección Economía y Naturaleza. Serie Textos básicos, vol. III. Fundación Argentaria - Visor Distribuciones.
- Hilbert, J. A., Manosalva, J. A., & Ponieman, K. (2021). Estudios sobre biorefinerías de maíz en la Argentina. *Proceeding of the 9th International Conference on Life Cycle Assessment*.
- Hoekstra, A. Y., & Wiedmann, T. O. 2014. Humanity's unsustainable environmental footprint. *Science, 344*(6188), 1114-1117.
- Huang, X., Wang, L., Yang, L., & Kravchenko, A. N. (2008). Management effects on relationships of crop yields with topography represented by wetness index and precipitation. *Agronomy Journal, 100*(5), 1463–1471.
- Jiang, H., Hu, H., Zhong, R., Xu, J., Xu, J., Huang, J., ... & Lin, T. (2020). A deep learning approach to conflating heterogeneous geospatial data for corn yield estimation: A case study of the US Corn Belt at the county level. *Global change biology, 26*(3), 1754-1766.
- Kamilaris, A., Kartakoullis, A. & Prenafeta-Boldú, F. X. (2017). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture, 143*, 23-37.
- Lambert, D. M., Lowenberg-Deboer, J., & Bongiovanni, R. (2004). A comparison of four spatial regression models for yield monitor data: A case study from Argentina. *Precision Agriculture, 5*(6), 579–600. doi:10.1007/s11119-004-6344-3
- Lee, U., Kwon, H., Wu, M., & Wang, M. (2021). Retrospective analysis of the U.S. corn ethanol industry for 2005–2019: implications for greenhouse gas emission reductions. *Biofuels, Bioproducts and Biorefining, 1*–14.

- Lee, E. K., Zhang, X., Adler, P. R., Kleppel, G. S., & Romeiko, X. X. (2020). Spatially and temporally explicit life cycle global warming, eutrophication, and acidification impacts from corn production in the U.S. Midwest. *Journal of Cleaner Production*, 242, 118465.
- Liu, Y., Swinton, S. M., & Miller, N. R. (2006). Is site-specific yield response consistent over time? Does it pay? *American Journal of Agricultural Economics*, 88(2), 471-483.
- Lopez Sardi, E. M., & Cattaneo, M. P. (2013). Los indicadores ambientales como herramientas de la economía. *Ciencia y Tecnología*, 1(13), 279-292.
- Lowenberg-Deboer, J., Erickson, K., & Vogel, K. A. (2000). *Precision Farming Profitability*. Purdue University, West Lafayette, IN.
- Ma, B. L., Liang, B. C., Biswas, D. K., Morrison, M. J., & McLaughlin, N. B. (2012). The carbon footprint of maize production as affected by nitrogen fertilizer and maize-legume rotations. *Nutrient Cycling in Agroecosystems*, 94(1), 15-31.
- MINEM. 2021. Datos Energía - Estadísticas de biodiesel y bioetanol. Ministerio de Energía y Minería de La Nación Argentina. <http://datos.minem.gob.ar/dataset/estadisticas-de-biodiesel-y-bioetanol>
- Naciones Unidas. (2015). *Objetivos y metas de Desarrollo Sostenible*. <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- Mekonnen, M. M., Romanelli, T. L., Ray, C., Hoekstra, A. Y., Liska, A. J., & Neale, C. M. (2018). Water, energy, and carbon footprints of bioethanol from the US and Brazil. *Environmental science & technology*, 52(24), 14508-14518.
- Petrielli, G. P., Nogueira, G. P., de Souza Henzler, D., De Souza, N. R. D., Bruno, K. M. B., dos Santos Luciano, A. C., le Maire, G. & Hernandez, T. A. D. (2023). Integrating carbon footprint to spatialized modeling: The mitigation potential of sugarcane ethanol production in the Brazilian Center-South. *Resources, Conservation and Recycling*, 189, 106725.
- Piñero, P., Sevenster, M., Lutter, S., Giljum, S., Gutschlhofer, J., & Schmelz, D. (2019). *Technical documentation of the Sustainable Consumption and Production Hotspots Analysis Tool (SCP-HAT)* (Issue September).
- Ponieman, K.D., Bongiovanni, R., Battaglia, M.L., Hilbert, J.A., Cipriotti, P.A. and Espósito, G. (2023). Site-specific calculation of corn bioethanol carbon footprint with Life Cycle Assessment. In: K. Behrendt, D. Paparas, A. Mumbi, N. Hill, and J. Lowenberg-DeBoer (eds.) Proceedings of the 6th Symposium on Agri-Tech Economics for Sustainable Futures. Global Institute for Agri-Tech Economics, Food, Land & Agribusiness Management Department, Harper Adams University. HAU Publications, Newport, United Kingdom, 18-19 September 2023, [80-89].
- Qi, J. Y., Yang, S. T., Xue, J. F., Liu, C. X., Du, T. Q., Hao, J. P., & Cui, F. Z. (2018). Response of carbon footprint of spring maize production to cultivation patterns in the Loess Plateau, China. *Journal of Cleaner Production*, 187, 525-536.
- Schimmelpfennig, D., & Ebel, R. (2016). Sequential adoption and cost savings from precision agriculture. *Journal of Agricultural and Resource Economics*, 97-115.
- Schmidt, F., & Persson, A. (2003). Comparison of DEM data capture and topographic wetness indices. *Precision Agriculture*, 4, 179-192.
- Schwalbert, R., Amado, T. J., Horbe, T. A., Stefanello, L. O., Assefa, Y., Prasad, P. V., Rice, C. W. & Ciampitti, I. A. (2018). Corn yield response to plant density and nitrogen: Spatial models and yield distribution. *Agronomy Journal*, 110(3), 970-982.
- Socchiuzzi, S., Basualdo, A., & Boragno, S. (2018). Mapas de áreas aptas para cultivos de secano en Argentina. In *RADA 2018 (Reunión Argentina de Agrometeorología. Merlo, San Luis, Argentina. 19 a 21 de septiembre de 2018)*. Oficina de Riesgo Agropecuario, Secretaría de Agroindustria, Ministerio de Producción y Trabajo.
- Tantalaki, N., Souravlas, S., & Roumeliotis, M. (2019). Data-driven decision making in precision agriculture: The rise of big data in agricultural systems. *Journal of agricultural & food information*, 20(4), 344-380.
- Terra, J. A., Shaw, J. N., Reeves, D. W., Raper, R. L., van Santen, E., Schwab, E. B., & Mask, P. L. (2006). Soil Management and Landscape Variability Affects Field-Scale Cotton Productivity. *Soil Science Society of America Journal*, 70(1), 98-107.
- Unión Europea. (2018). Directiva (UE) 2018/2001 del Parlamento Europeo y del Consejo de 11 de diciembre de 2018 relativa al fomento del uso de energía procedente de fuentes renovables (versión refundida). *Diario Oficial de La Unión Europea*, 328, 82-209.
- Wang, H., Yang, Y., Zhang, X., & Tian, G. (2015). Carbon footprint analysis for mechanization of maize production based on life cycle assessment: A case study in Jilin Province, China. *Sustainability (Switzerland)*, 7(11), 15772-15784.
- Xu, X., & Lan, Y. (2017). Spatial and temporal patterns of carbon footprints of grain crops in China. *Journal of Cleaner Production*, 146, 218-227.
- Yan, M., Cheng, K., Luo, T., Yan, Y., Pan, G., & Rees, R. M. (2015). Carbon footprint of grain crop production in China - Based on farm survey data. *Journal of Cleaner Production*, 104, 130-138.
- Zouabi, O., & Peridy, N. (2015). Direct and indirect effects of climate on agriculture: an application of a spatial panel data analysis to Tunisia. *Climatic change*, 133, 301-320.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Drones pulverizadores: Calidad de aplicación con diferentes calibraciones y coadyuvantes

Platz P., Tourn S., Merani V.H., Mur M., Larrieu L., Ferro., Vazquez J.M. Guilino F., Cinquetti T.

[victormerani@gmail.com](mailto:victormerani@gmail.com) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.  
[pedroplatz@gmail.com](mailto:pedroplatz@gmail.com) FCA UNMdP. Mar del Plata Buenos Aires Argentina  
[tourn.santiago@gmail.com](mailto:tourn.santiago@gmail.com) FCA UNMdP. Mar del Plata Buenos Aires Argentina  
[mecanizacionunlp@gmail.com](mailto:mecanizacionunlp@gmail.com) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.  
[daniel.ferro@agro.unlp.edu.ar](mailto:daniel.ferro@agro.unlp.edu.ar) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.  
[larrieuluciano@gmail.com](mailto:larrieuluciano@gmail.com) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.  
[juanmvaz@hotmail.com](mailto:juanmvaz@hotmail.com) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.  
[fguilino\\_33@hotmail.com](mailto:fguilino_33@hotmail.com) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.  
[tatianacinquetti@gmail.com](mailto:tatianacinquetti@gmail.com) Depto. Ing. Agrícola FCAyF UNLP. La Plata Buenos Aires Argentina.

Trabajo presentado al

**20° Congreso de Agricultura de Precisión**  
**20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** El avance de los Vehículos aéreos no tripulados (VANT) comienza a verse reflejando en los sistemas de aplicación de agroquímicos. Las aplicaciones con VANT o comúnmente llamados "dron", están logrando la atención de muchos productores y asesores. Independientemente de las ventajas operativas de estos equipos, es fundamental tener en cuenta que requieren, al igual que las metodologías clásicas de aplicación, una calibración que permitan obtener aplicaciones con óptimos controles y mínimas contaminaciones. El siguiente trabajo pretende evaluar el comportamiento de diferentes calibraciones de un VANT pulverizador en cultivo de papa. Se realizaron vuelos sobre un cultivo de papa con un VANT AGRAST30, con dos boquillas (Teejet abanico plano 110-01 y ASJ doble abanico 30-30 110-015), dos coadyuvantes (Speedwet Silicongel y antideriva Speedwet) y 2 tasas de aplicación (20 Lha-1 y 30 Lha-1). Se utilizaron Tarjetas Hidrosensibles en dos estratos del cultivo, sobre las que se evaluaron, Densidad de impactos (gotas cm-2), DV0,5 ( $\mu\text{m}$ ), DV0,1 ( $\mu\text{m}$ ) y DV0,9 ( $\mu\text{m}$ ). Se observaron corrimientos de las gotas en el sentido del viento ambiental hasta 3,4 m, con mayor efecto sobre gotas más grandes, No se observaron diferencias de tamaño entre gotas halladas en los dos estratos, pero sí existió mayor tamaño de gotas con las boquillas más grandes, no se verificaron diferencias en el número de impactos entre tratamientos en el estrato alto, pero se hallaron diferencias en el bajo con boquillas más grandes y mayor tasa. Estos resultados permiten avanzar en el estudio del comportamiento de los VANTs en pulverizaciones a campo.

**Palabras clave.** VANTs, Ala Rotatoria, UAV, UAS, AGRAST30.

## INTRODUCCIÓN

El avance de los Vehículos Aéreos No Tripulados (VANT) en la agricultura comienza a verse reflejando en los sistemas de aplicación de agroquímicos (fertilizantes y fitosanitarios), en distintas zonas del país. Las aplicaciones con VANT o comúnmente llamados "dron", están logrando la atención de muchos productores y asesores que encuentran ventajas comparativas respecto a los sistemas tradicionales de aplicación como pueden ser las pulverizaciones aéreas y terrestres en cobertura total (Bloise et al., 2021). Estos equipos son fáciles de transportar, livianos y prácticos para calibrar. Su altura de vuelo puede variar de 2 a 3 m evitando "pisar" el cultivo. Por su tamaño y maniobrabilidad pueden aplicar en espacios reducidos y utilizan bajos volúmenes de agua. Están equipados con boquillas hidráulicas de caudales que van entre  $0,4 \text{ L min}^{-1}$  (01 GPM) a  $0,6 \text{ L min}^{-1}$  (015 GPM).

Independientemente de las ventajas operativas de estos equipos, es fundamental tener en cuenta que requieren, al igual que las metodologías clásicas de aplicación, una calibración que permita obtener aplicaciones con óptimos controles y mínimas contaminaciones.

La variabilidad existente en la aplicación de agroquímicos, generada por distintos tipos de formulaciones y modos de acción, distintos objetivos de control, ya sea en barbechos o cultivos de diferente densidad, requieren de calibraciones específicas para lograr los mejores parámetros en calidad de aplicación. Las variables más frecuentes utilizadas para evaluar estas aplicaciones son cobertura (número de impactos  $\text{cm}^{-2}$ ) y los respectivos diámetros medianos, mínimos y máximos (DV05, DV01 y DV09), obtenidos a partir del análisis de Tarjetas Hidrosensibles (TH). Estos parámetros permiten cuantificar la calidad de la aplicación en cuanto a requerimientos mínimos de cobertura de gotas y caracterización de las familias de gotas en post de reducir las pérdidas de las mismas por deriva.

## MATERIALES Y MÉTODOS

Se utilizó un equipo de aplicación AGRAS T30 conformado por una estructura plegable y cuadrilateral, capacidad de carga de 40 kg o 30 l, sistema de radar esférico de percepción, radar omnidireccional y radar superior para detección constante de altura, detección de obstáculos y anticollisión, cámaras FPV delantera y trasera, bomba de pistones y 16 aspersores, 8 por cada frente de avance en la aplicación. Asimismo, cuenta con caudalímetro electromagnético de dos canales e indicador de nivel de líquido (Figura 1).

El equipo posee una autonomía de 2 a 4 ha en función del caudal que se deba aplicar, la velocidad y altura de vuelo. Se divide en dos partes, frontal y trasero en función del sentido de avance. Según el sentido de avance, se accionan las 8 boquillas traseras. Únicamente se accionan todas las boquillas cuando debe superar un determinado caudal.

Las condiciones meteorológicas al momento de la aplicación se registraron con una estación móvil DAVIS Vantage Pro2 que permite registrar en un datalogger dirección y velocidad del viento (promedio y ráfagas), temperatura y humedad por minuto.

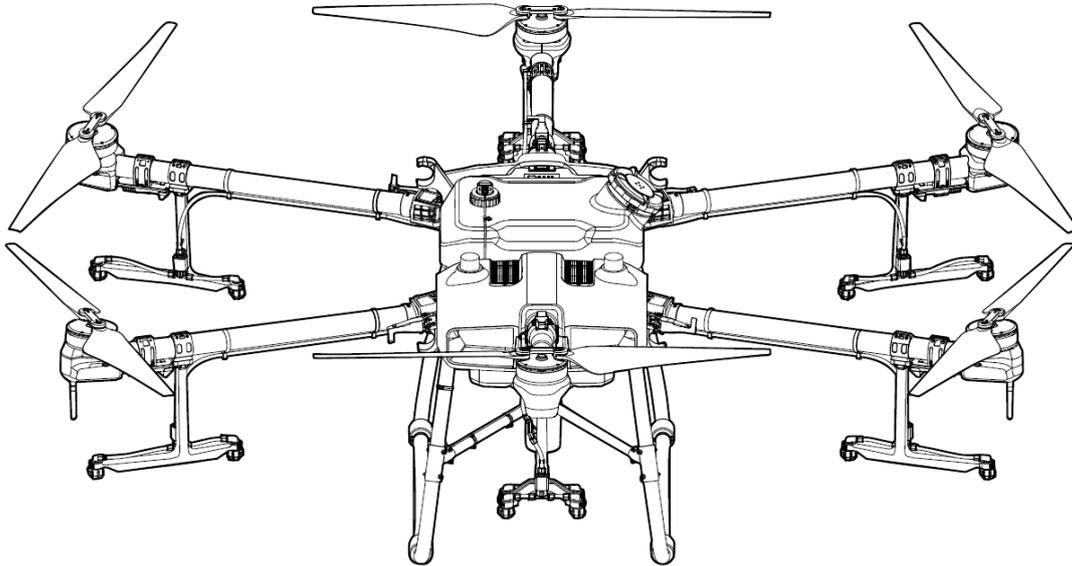


Figura 1. AGRAS T30.

## Ensayo

El día 21 de diciembre se estableció un plan de vuelo sobre un cultivo de papa en el campo □Las Elenas□ en la ciudad de Balcarce. El mismo consto de 3 pasadas paralelas a una distancia de 7 m entre ellas (Figura 2), este plan de vuelo se respetó para todos los tratamientos realizados.

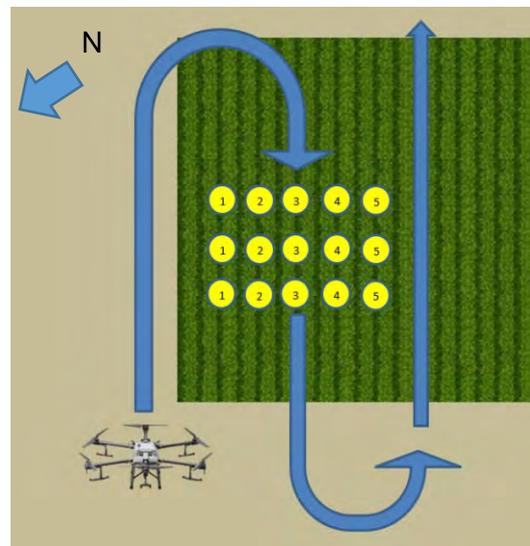


Figura 2. Esquema de plan de vuelo de la aeronave. Ubicación de los porta-tarjetas

Se instalaron 3 hileras (repeticiones) con 5 porta-tarjetas colocadas surco por medio (1,7 m) en el cultivo de papa. Cada porta-tarjeta tenía dos alturas de evaluación del canopeo: alto y bajo (Figura 3).



Figura 3. Imagen de foto mostrando la ubicación de las TH en distintas alturas del canopeo del cultivo de papa.

Se realizaron 4 tratamientos (T).

- T1: Boquillas Teejet abanico plano 110-01 (01 GPM) a una a altura de 2,5 m, velocidad 15 km h<sup>-1</sup>, caudal 2,5 L min<sup>-1</sup>, ancho 7 m y tasa de aplicación 20 L ha<sup>-1</sup>. Se aplicó agua en mezcla con un coadyuvante Speedwet Silicongel (SG) a una dosis de 50 cc c/100 L agua.
- T2: Boquillas Teejet abanico plano 110-01 a una a altura de 2,5 m, velocidad 15 km h<sup>-1</sup>, caudal 2,5 L min<sup>-1</sup>, ancho 7 m y tasa de aplicación 20 L ha<sup>-1</sup>. Se utilizó un adyuvante antideriva Speedwet (NG) en una dosis de 80 cc c/100 L agua.
- T3: Boquillas ASJ doble abanico 30-30 110-015 (015 GPM) aire inducido a una a altura de 2,5 m, velocidad 15 km h<sup>-1</sup>, caudal 2,5 L min<sup>-1</sup>, ancho 7 m y tasa de aplicación 20 L ha<sup>-1</sup>. Se utilizó un adyuvante antideriva Speedwet (NG) en una dosis de 80 cc c/100 L agua.
- T4: Boquilla ASJ doble abanico 30-30 110-015 aire inducido a una a altura de 2,5 m, velocidad 15 km h<sup>-1</sup>, caudal 2,5 L min<sup>-1</sup>, ancho 7 m y tasa de aplicación 30 L ha<sup>-1</sup>. Se utilizó un adyuvante antideriva Speedwet (NG) en una dosis de 80 cc c/100 L agua.

Las TH se digitalizaron con escáner HP Deskjet 2050 J510 a 1200 dpi de resolución sin necesidad de realizar ajustes de brillo o contraste y luego fueron analizadas con el programa StainMaster para la obtención de los siguientes parámetros:

- Cobertura (Número de impactos cm<sup>-2</sup>).
- DV0,5 (µm).
- DV0,1 (µm).
- DV0,9 (µm).

Los resultados fueron cargados en planillas Excel para su procesamiento y posterior evaluación estadística por medio del programa libre InfoStat. (Di Rienzo et al., 2014)

## RESULTADOS y DISCUSIÓN

Las condiciones ambientales durante el momento de aplicación fueron de 10,2 km h<sup>-1</sup>, ± 3,5 km h<sup>-1</sup> con dirección noreste, temperatura 24,5 °C ± 3,2 y humedad relativa 61,8% ± 12,0 (Figura 4).

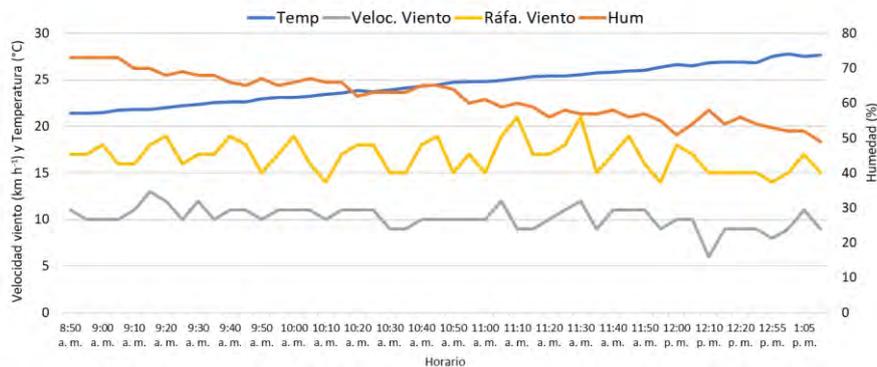


Figura 4. Condiciones meteorológicas durante la jornada de aplicaciones.

Se realizó un primer análisis de evaluación de la distribución de las gotas sobre el ancho de trabajo efectivo del equipo (Figura 5). Se puede observar que existe un efecto de desplazamiento de las gotas hacia el sector derecho de la pasada de aproximadamente 1,7 m y 3,4 m siendo el primero más marcado. Este efecto se visualiza más marcadamente en el estrato alto y no en el bajo permitiendo inferir que las gotas que se movilizan no llegan a penetrar en el canopeo. Este desplazamiento pudo estar influenciado por el viento atmosférico predominante ya que existen diversos trabajos que mencionan que las aplicaciones hidráulicas de fitosanitarios se ven fuertemente influenciadas por los vientos predominante en el momento de la labor (Mur et al., 2018a; Mur et al., 2018b; Merani et al., 2018). Por otro lado, Wang et al. (2020) mencionan que la aplicación con drones posee derivas cercanas al centro de pasada del dron.

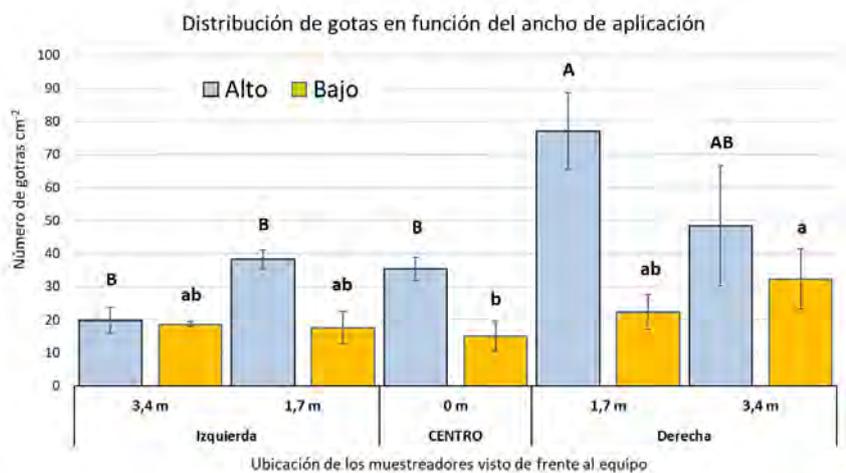


Figura 5. Distribución de gotas en cada porta-tarjeta ubicados a distintas alturas de evaluación. Promedios acompañados con al menos una letra mayúscula igual no difieren significativamente entre distancias de porta-tarjetas para una misma altura (LSD  $\alpha=0,05$ ). Barras verticales indican error estándar.

La Figura 6 muestra la distribución de las gotas para cada tratamiento. Se observa un desempeño similar en todos los tratamientos, sin embargo, el movimiento lateral de las gotas es más marcado en T4, alcanzando mayor cantidad de impactos a los 3,4 m del centro del vuelo del VANT. Este tratamiento es el que eleva la media de las mediciones a 3,4 m, observadas en la Figura 5. Este comportamiento es llamativo, debido a que T4 es el tratamiento que presenta el mayor tamaño de gotas (Figuras 7 y 8) y, en función de lo expresado por Merani et al., (2018), se esperaría que fuese el menos afectado por el viento.

Si se tiene en cuenta lo expresado por Wang et al. (2020) respecto al efecto de los vórtices generados por las hélices de los VANT sobre las gotas, se puede suponer que las gotas más livianas se ven más afectadas por estos vórtices que por el viento ambiental alcanzando los objetivos más cerca del centro de la pasada. Mientras que, las gotas pesadas se ven más influenciadas por el viento ambiental que por el vórtice de las hélices alcanzando los objetivo más lejos de su posición de salida.

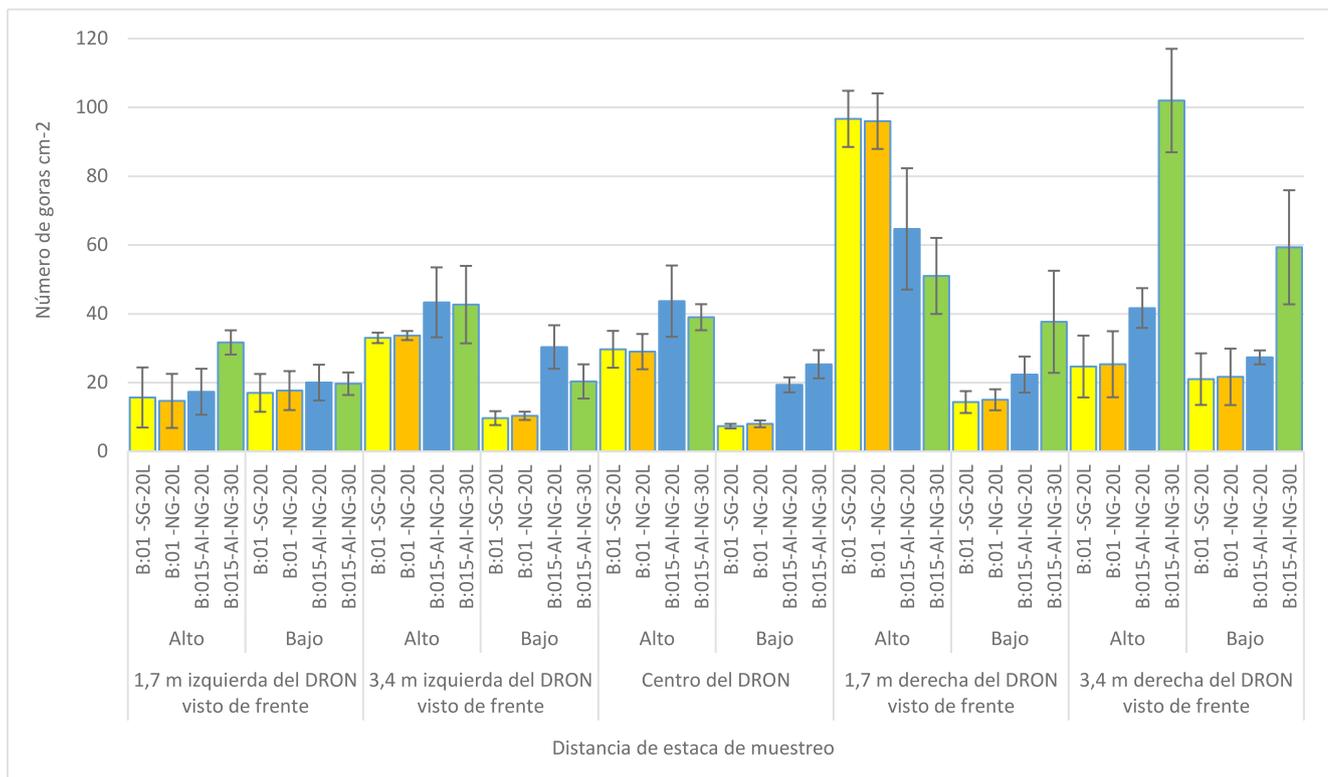


Figura 6. Distribución de gotas para cada posición y cada altura de porta-tarjeta y cada tratamiento. Barras verticales indican error estándar.

Se realizó una segunda evaluación, particionando los datos por tratamiento sin tener en cuenta las posiciones relativas de las TH, para el parámetro número de gotas (Figura 7). Esto permitió observar que la cobertura rondó entre 39,9 impactos cm<sup>-2</sup> y 53,3 impactos cm<sup>-2</sup> distribuidas en un ancho de 9 m. No se detectaron diferencias de gotas para ninguno de los tratamientos de la posición alto ( $p=0,7330$ ). En la posición bajo, los tratamientos con pastillas 015 GPM presentaron valores superiores, pero solo se diferenció estadísticamente T4 con una tasa de aplicación de 30 L ha<sup>-1</sup>.

Estos resultados permitirían inferir que, a diferencia de lo que ocurre en aplicaciones con equipos terrestres hidráulicos mencionado por Mur et al. (2018b), la aplicación con drones permitiría alcanzar el interior de los canopeos de forma más eficiente con gotas más grandes generadas con mayores tasas de aplicación.

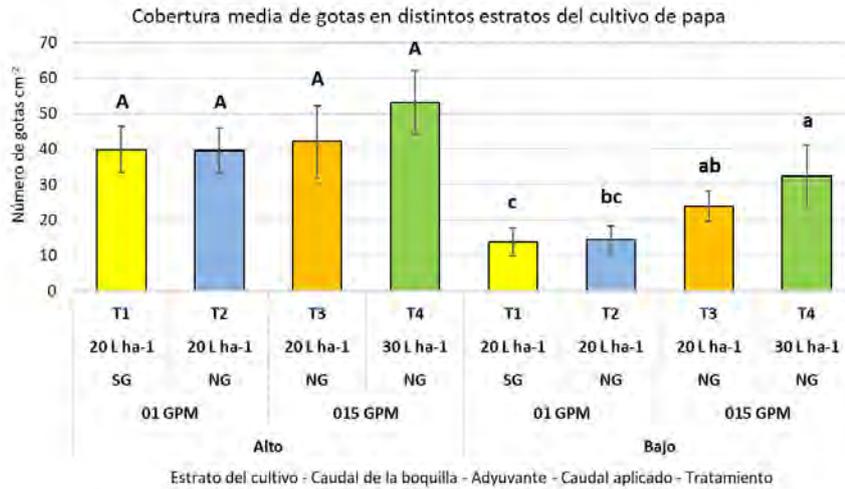


Figura 7. Número de gotas cm<sup>-2</sup> logrado en cada tratamiento. Promedios acompañados con al menos una letra mayúscula igual no difieren significativamente entre tratamientos (LSD  $\alpha=0,05$ ). Barras verticales indican error estándar.

El diámetro mediano de las gotas del 50% del volumen aplicado (DV05), no mostró diferencias entre adyuvantes (T1-T2) pero si hubo efecto del tipo de boquilla y la tasa de aplicación en los dos estratos evaluados ( $p=0,0001$ ; Figura 8).

Las boquillas 01 GPM generaron diámetros medianos de 174  $\mu\text{m}$  y 175  $\mu\text{m}$  con los adyuvantes Silicongen (SG) y Antideriva (NG) en el estrato superior, respectivamente.

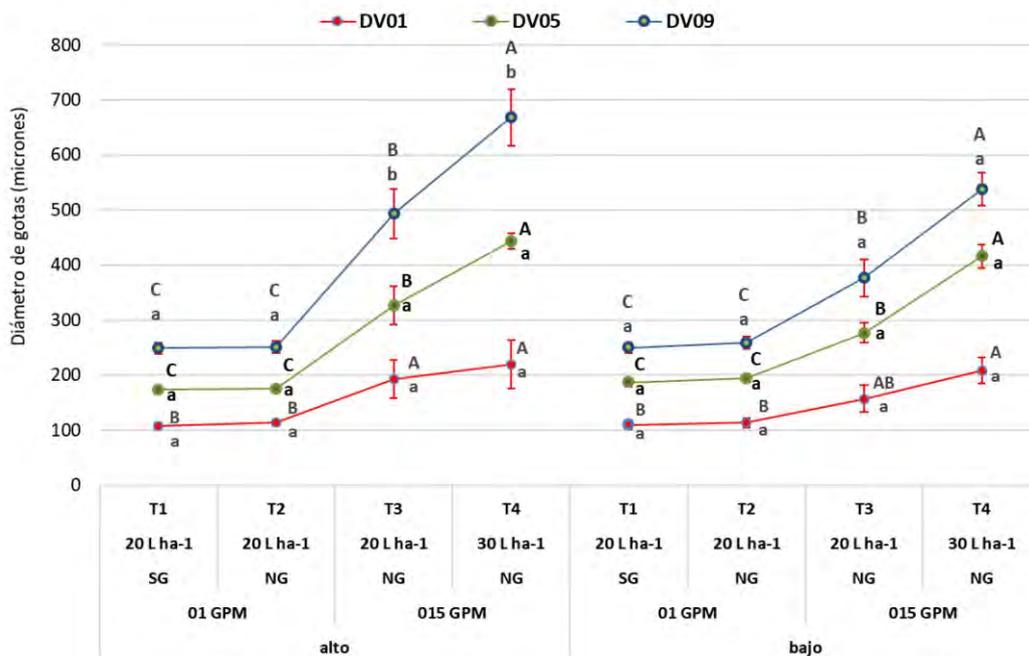


Figura 8. Diámetro volumétrico de las gotas del 10% (DV01), 50%(DV05) y 90%(DV09) del volumen aplicado en cada tratamiento. Promedios acompañados con al menos una letra mayúscula igual no difieren significativamente entre tratamientos (LSD  $\alpha=0,05$ ) para cada posición (alto y bajo). Promedios acompañados con al menos una letra minúscula igual no difieren significativamente entre posiciones (alto y bajo) (LSD  $\alpha=0,05$ ) para cada tratamiento. Barras verticales indican error estándar.

Un cambio significativo en el diámetro de las gotas se observó al utilizar la boquilla de doble abanico 30-30 110-015 de aire inducido, pasando de un promedio de 175  $\mu\text{m}$  a 327  $\mu\text{m}$  con la misma tasa de aplicación (20 L ha<sup>-1</sup>) y en la posición alto del canopeo. Al aumentar la tasa de aplicación, aumentó el diámetro a 443  $\mu\text{m}$  y también lo hizo el diámetro del 10% del volumen aplicado DV01 a 219  $\mu\text{m}$ . Este rango de tamaño de gotas reduce la potencialidad de perderse gotas por derivas ya sean físicas o por evaporación.

Por otro lado, no se observan diferencias significativas en los tamaños de gotas entre posiciones para cada tratamiento (DV0,1, DV0,5 y DV 0,9) permitiendo inferir que llegan gotas de todos los tamaños a todas las posiciones evaluadas. Solo se hallaron diferencias para T3 y T4 evaluando DV0,9, lo que permite suponer que cuando las gotas son demasiados grandes quedan retenidas en el estrato superior generando un efecto de reducción de la media en los estratos inferiores.

## Conclusiones

Las aplicaciones con VANT se comportan de manera diferentes frente al viento atmosférico que las aplicaciones con equipos terrestres hidráulicos.

Se observó una buena distribución de impactos en el ancho de trabajo efectivo del VANT, influenciadas por los vórtices generados por las hélices.

Se observó uniformidad en el tamaño de gotas obtenidas en los diferentes objetivos evaluados con los distintos tratamientos.

Una mayor tasa de aplicación y gotas más grandes mejorarían la calidad de aplicación en estratos bajos del canopeo.

Se recomienda avanzar en el estudio de derivas y pérdidas de producto en aplicaciones con VANTs

## Agradecimientos

Se agradece la ayuda y participación en este trabajo de Ing. Agr. MARCELO GIMÉNEZ ZAPIOLA ALENA AGRITECH.

## Referencias

- Blaise, N., Ruiz, M. C., D'Ambrosio, D., Guglieri, G. (2021, November). Wind Tunnel Testing of Remotely Piloted Aircraft Systems for Precision Crop-Spraying Applications. In 2021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor) (pp. 378-383). IEEE.
- Teske, M. E., Wachspress, D. A., Thistle, H. W. (2018). Prediction of aerial spray release from UAVs. Transactions of the ASABE, 61(3), 909-918.
- Wang, G., Han, Y., Li, X., Andaloro, J., Chen, P., Hoffmann, W. C., Lan, Y. (2020). Field evaluation of spray drift and environmental impact using an agricultural unmanned aerial vehicle (UAV) sprayer. Science of the Total Environment, 737, 139793.
- Wen, S., Han, J., Ning, Z., Lan, Y., Yin, X., Zhang, J., Ge, Y. (2019). Numerical analysis and validation of spray distributions disturbed by quad-rotor drone wake at different flight speeds. Computers and Electronics in Agriculture, 166, 105036.
- Merani V.H.; M. Mur; F. Ramirez; M.J. Ponce; F. Guilino; T. Palancar. 2018. Efecto de variables operativas sobre la calidad de aplicación y la deriva en la pulverización de agroquímicos. AGRISCIENTIA.: AGRISCIENTIA. 2018 vol. n°. p - . . eissn 1668-298X.
- Mur M.; M.J. Ponce; F.D. Guilino; V.H. Merani; R.H. Balbuena. 2018. Pulverización con alto y bajo volumen en rastrojo de sorgo. Eficiencia y riesgos ambientales de la aplicación. Ciencias Agronómicas.: UNR. 2018 vol.32 n°. p34 - 42. . eissn 2250-8872.
- Mur M.; M.J. Ponce; J.M. Vazquez; F. Guilino; V.H. Merani; T. Palancar; R.H. Balbuena. 2018. Aplicación de herbicidas en rastrojo de sorgo. Eficiencia de técnicas de alto y bajo volumen. Revista de la Facultad de Agronomía.: edulp. 2018 vol.117 n°. p261 - 273. issn 0041-8676.
- Di Rienzo J.A., Casanoves F., Balzarini M.G., Gonzalez L., Tablada M., Robledo C.W. InfoStat versión 2014. Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. URL <http://www.infostat.com.ar>.

## Empleo de índices de vegetación y térmico obtenidos mediante VANT para caracterizar la condición hídrica en maíz

Peirone, L.S.<sup>1-2\*</sup>, Ovando, G.<sup>3</sup>, Ogando, F.A.<sup>1</sup>, Pari, E.<sup>4</sup>, Villafañe, J.<sup>5</sup>, Raspa, F.A.<sup>1</sup>, Vega, C.R.C.<sup>1</sup>

<sup>1</sup> EEA INTA Manfredi, <sup>2</sup> IAPCByA UNVM, Villa María, <sup>3</sup> Universidad Nacional de Córdoba FCA, Córdoba, <sup>4</sup> AER INTA Río Primero, <sup>5</sup> Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

Trabajo presentado al  
**20° Congreso de Agricultura de Precisión**  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

### **Resumen.**

*En el contexto del cambio climático, con eventos climáticos extremos y cambios en las precipitaciones, la evaluación precisa del estrés hídrico en cultivos es crucial para mejorar la productividad agrícola, especialmente en ambientes semiáridos como la región pampeana oeste de Argentina. Este trabajo tuvo como objetivo evaluar la capacidad de los índices de vegetación de diferencia normalizada (NDVI), Temperatura de superficie (LST) e Índice espectral de sequía (TDVI) para discriminar condiciones hídricas en un cultivo de maíz. El maíz fue manejado bajo riego o con estrés hídrico alrededor de floración, y evaluado al final del período crítico de definición del número de granos mediante imágenes multiespectrales y térmicas adquiridas con un vehículo aéreo no tripulado (VANT). Todos los índices discriminaron la condición hídrica. Los mayores valores de NDVI y los menores de LST se concentraron en las parcelas bajo riego. En particular, TDVI demostró ser un indicador robusto para evaluar el estado hídrico del cultivo. Este estudio sugiere que el uso de datos multiespectrales y térmicos obtenidos mediante VANTs es prometedor en áreas como la agricultura de precisión y el fenotipado de alto caudal. Sin embargo, estudios adicionales se requieren para evaluar su capacidad discriminante en distintos genotipos de maíz y en condiciones generadas por otras prácticas de manejo.*

### **Palabras clave.**

*Espacio LST-NDVI, TDVI, Sequía, Teledetección proximal.*

## Introducción

En el contexto actual de cambio climático, con aumento de ocurrencia de eventos climáticos extremos, episodios de estrés térmico, y cambios en régimen de precipitaciones (IPCC 2014), la evaluación del impacto del estrés hídrico en los cultivos es esencial para mejorar la productividad agrícola y optimizar las prácticas de manejo. Estos aspectos, son especialmente relevantes en ambientes semi-áridos donde estreses combinados son frecuentes, y en los que se espera se acentúe aún más la frecuencia de episodios de estrés térmico y de primaveras secas. En la región pampeana oeste de Argentina, los cultivos se desarrollan mayoritariamente en secano, siendo el déficit hídrico y su variabilidad interanual los principales factores condicionantes del rendimiento del cultivo (De la Casa y Ovando, 2014). En dicha región, el maíz (*Zea mays L.*) es el cereal más cultivado y de mayor relevancia. Por otro lado, en maíz cultivado en fechas temprana, el periodo crítico alrededor de la floración tiene alta probabilidad de coincidir con estrés hídrico y/o térmico, aspectos que afectan significativamente el rendimiento del cultivo.

Existen distintos métodos para evaluar la condición hídrica de los cultivos, incluyendo índices relacionados con el déficit hídrico del suelo y el estrés hídrico de la vegetación (Sayago et al., 2017). Una combinación particularmente valiosa es la de la temperatura de la superficie terrestre (LST, por sus siglas en inglés, *land surface temperature*) y el índice de vegetación de diferencia normalizada (NDVI), la cual ha sido ampliamente estudiada (Sandholt et al., 2002; Sayago et al., 2017). El NDVI es comúnmente utilizado para monitorear la salud de la vegetación y evaluar las condiciones de estrés hídrico (Rouse et al., 1973), aunque su efectividad puede verse influenciada por diversos factores. Por otro lado, la LST es crucial en estudios ambientales, ya que juega un papel importante en la dinámica de la energía superficial y el ciclo hidrológico (Yang et al., 2024), aumentando rápidamente en presencia de estrés hídrico (Sandholt et al., 2002). La relación entre LST y NDVI ha sido estudiada extensamente, ya que proporciona información sobre las condiciones de la vegetación y la humedad superficial (Cheng et al., 2023; Sayago et al., 2017). Esta relación puede adoptar una forma trapezoidal o triangular, caracterizada por dos líneas que representan los límites seco y húmedo del área estudiada. A partir de estos límites, se calcula el índice de vegetación de temperatura-sequía (TDVI). Este índice ha mostrado constituir un método eficaz para monitorear cambios espacio-temporales en la humedad superficial del suelo a escala regional (Chen et al., 2023, Sayago et al., 2017, Sandholt et al., 2002). Sin embargo, estos estudios se basan mayoritariamente en información derivada de satélites que, por lo tanto, presentan ciertas limitaciones con relación a la resolución espacial y tiempo de revisita (Masina et al., 2020). Para superar estas limitaciones, el uso de sensores térmicos instalados en vehículos aéreos no tripulados (VANTs) se presenta como una herramienta prometedora en la agricultura de precisión.

El objetivo de este trabajo fue analizar la capacidad del índice de Diferencia Normalizada de Vegetación (NDVI), de la relación entre la temperatura superficial (LST) y del índice de vegetación de temperatura-sequía (TDVI) para discriminar condiciones hídricas contrastantes en un cultivo de maíz.

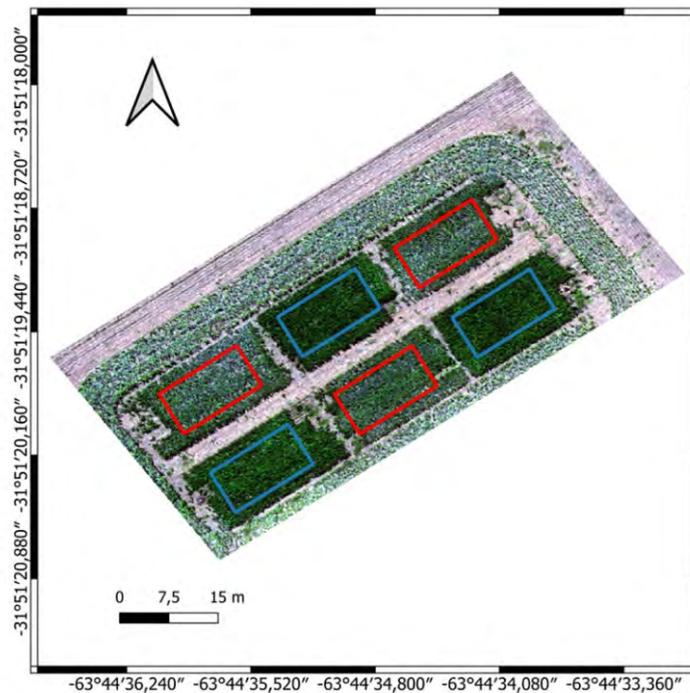
## Materiales y métodos

### Sitio de estudio

El estudio se llevó a cabo en un experimento a campo en Manfredi (31°49'S, 63°46'O), Córdoba (AR) durante la campaña agrícola 2023-2024. Las precipitaciones en la zona alcanzan un promedio anual de 760 mm, con el 75% concentrado en primavera-verano. El tipo de suelo es un Haplustol éntico, serie Oncativo, con capacidad de almacenaje de agua útil de 313 mm (2 m de profundidad).

Un híbrido de maíz (Next Power Core Ultra) fue sembrado el 31 de octubre de 2023 con una densidad de plantas de 7.5 pl. m<sup>-2</sup> bajo dos condiciones hídricas contrastantes durante el período crítico alrededor de floración. Los niveles hídricos fueron: i) riego durante todo el ciclo (AU > 70 %) y ii) estrés hídrico

durante el período crítico de floración  $\pm 15$  días ( $AU \cong 30\%$ ;  $EH_{PC}$ ). El manejo del agua se realizó mediante un sistema de riego por goteo. El diseño experimental fue de bloques completos aleatorizados con tres repeticiones (Figura 1). El área de estudio total consistió en una zona de 30 m de ancho y 74 m de largo. El cultivo se mantuvo libre de plagas, enfermedades y malezas.



**Figura 1. Mosaico RGB de cultivos de maíz sembrados bajo dos condiciones hídricas durante el período crítico. Parcelas con marco de color azul y rojo corresponden a tratamientos de Riego y Estrés hídrico, respectivamente. Las imágenes fueron capturadas mediante VANT a los 93 días de la siembra.**

### Adquisición de imágenes térmicas y multiespectrales con vehículo aéreo no tripulado (VANT)

Para la adquisición de imágenes, se utilizó un VANT Matrice 300 RTK (DJI Technology Co., Shenzhen, China), equipado con una cámara multiespectral y térmica (MicaSense Altum, Lepton Unmanned Aircraft Systems, Inc., Denver, Colorado, USA). Dicha cámara posee cinco bandas multiespectrales (verde, rojo, azul, borde rojo y NIR) y una banda termográfica. El plan de vuelo fue diseñado para una superposición frontal de 80 % (overlap) y superposición lateral de 80 % (sidelap). Antes del vuelo, se realizó una calibración de reflectancia utilizando el panel con valores de reflectancia proporcionados por Micasense. El vuelo se llevó a cabo a los 93 días desde la siembra (1/02/2024), en la etapa fenológica R3 (Ritchie y Hanway), entre las 13 y 15 h, a una altura de 15 m. Las condiciones del cielo fueron despejadas y con calma. Al momento de la medición, la temperatura fue de 38°C y la humedad relativa de 49%.

### Procesamiento de imágenes térmicas y multiespectrales

Las imágenes térmicas y multiespectrales fueron procesadas para generar dos ortomosaicos con la misma resolución espacial de 8.7 cm pixel<sup>-1</sup>.

A partir de la información de la reflectancia de las bandas infrarroja y roja se calculó el índice de

vegetación de diferencia normalizada (NDVI):

$$NDVI = \frac{IR-R}{IR+R} \quad (1)$$

Donde: IR=reflectancia en la banda infrarroja y R=reflectancia en la banda roja.

Para el cálculo de la temperatura de superficie (LST) se utilizaron los datos de la banda térmica de la imagen. Para convertir los valores de temperatura de centi-Kelvin a temperatura en °C, se empleó la siguiente fórmula provista por el fabricante de la cámara:

$$LST = \frac{B6}{100} - 273,15 \quad (2)$$

Donde: B6= valores en centi-Kelvin obtenidos de la banda térmica.

Para el mosaico termal, se asumió que la emisividad (cociente entre la radiación emitida por la superficie en estudio y un cuerpo negro a la misma temperatura) de la superficie fue igual a 1 (Messina y Modica, 2020).

### Índice espectral de sequía (TDVI)

A partir del par de imágenes de NDVI y LST, se determinó el TDVI. Se consideró el rango de NDVI entre 0.15 (rastrojo) y el valor máximo observado. Ese rango se dividió en 15 intervalos iguales y dentro de cada uno de ellos se calcularon los percentiles 0.1 y 99.9 de LST. Para obtener el borde seco, se emplearon funciones lineales por partes, calculando los coeficientes de una regresión lineal entre los percentiles 99.9 de LST y el NDVI central de cada intervalo hasta encontrar el punto de quiebre; luego se repitió el procedimiento para encontrar los coeficientes de la segunda función lineal. De manera similar, se utilizaron los percentiles de LST para obtener una única ecuación lineal del borde húmedo. Una vez obtenidas las ecuaciones de los bordes secos y húmedos, se generó una imagen de TDVI, calculando los valores TDVI (Ec. 3) de cada píxel a partir de los valores NDVI y LST:

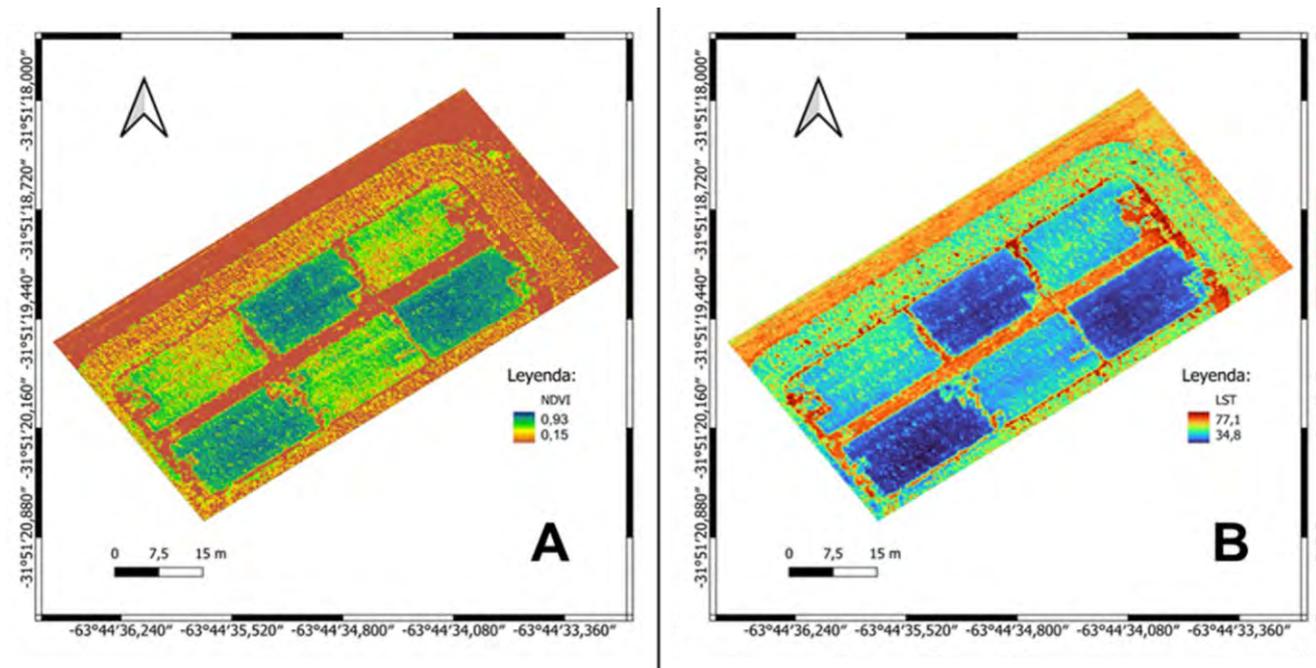
$$TDVI_i = \frac{LST_i - LST_w}{LST_d - LST_w} \quad (3)$$

Donde  $LST_i$  es el valor de LST en un píxel dado,  $LST_w$  y  $LST_d$  son los valores de LST obtenidos a partir del NDVI de ese píxel con la ecuación de las líneas húmeda y seca, respectivamente. Cuando TDVI fue mayor que 1, se estableció que el valor resultante de TDVI sea 1; cuando TDVI fue menor que 0, se estableció que el valor sea 0.

Los valores de TDVI, NDVI y LST de cada unidad experimental fueron comparados mediante ANOVA para comparar los efectos de los tratamientos hídricos. También, se calcularon los coeficientes de correlación de Pearson entre cada uno de los índices empleados en cada condición hídrica.

## Resultados y discusión

En la Figura 2, se presentan los ortomosaicos de los índices NDVI y LST. El rango del NDVI varió de 0.15 (rastraje) a 0.93. LST varió desde 34.8°C hasta 77°C. En términos generales, los mayores valores de NDVI y los menores de LST correspondieron al maíz regado; mientras que lo opuesto fue observado en los sitios con estrés hídrico alrededor de la floración.



**Figura 2.** Índices de vegetación de maíz cultivado bajo dos condiciones hídricas relevados mediante imagen multiespectral y térmica. A) índice de vegetación de diferencia normalizada (NDVI); B) Temperatura de superficie (LST; °C).

En la Figura 3, se presenta el espacio generado por la relación LST y NDVI y la determinación de las líneas seca y húmeda. El borde seco (línea roja) está compuesto por puntos que tienen las temperaturas de superficie del percentil 99.9 para cada intervalo de NDVI. El borde húmedo (línea azul) se determina a partir de los puntos que tienen las temperaturas de superficie del percentil 0.1 para cada intervalo de NDVI, y que corresponden a áreas con alta humedad del suelo. Como se observa en la Figura 3, el gráfico de dispersión de la relación entre NDVI y LST no presenta la típica forma triangular/trapezoidal descrita por muchos autores (Liu et al., 2022; Rostami et al., 2023). En este trabajo, la determinación del borde seco se realizó mediante funciones lineales por partes ( $LST_{\text{borde seco}} = NDVI * -9.94 + 78.28$  cuando  $NDVI < 0.727$  y  $LST_{\text{borde seco}} = NDVI * -115.61 + 150.22$  en caso contrario); para el borde húmedo, se utilizó una función lineal simple ( $LST_{\text{borde húmedo}} = NDVI * -2.69 + 37.24$ ). A diferencia de este trabajo, otros autores (i.e. Liu et al. 2015) emplearon funciones parabólicas para representar los bordes seco y húmedo en el espacio LST/NDVI.

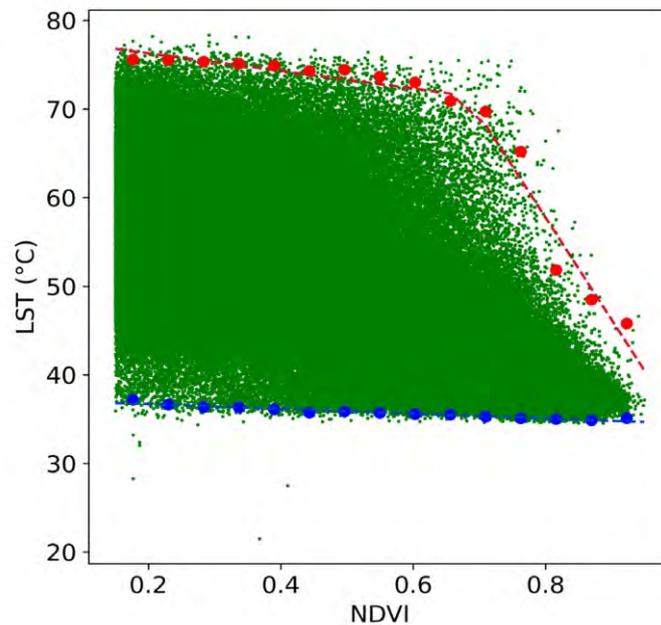


Figura 3. Espacio NDVI-LST y determinación de bordes secos (en rojo) y húmedos (en azul). Los datos fueron relevados en cultivos de maíz bajo dos condiciones hídricas a los 93 días después de la siembra.

A partir de las ecuaciones del borde húmedo y seco se calcularon los valores de TDVI para cada uno de los píxeles que componen la imagen. El resultado de este procedimiento se presenta en la Figura 4, donde pueden observarse los menores valores de TDVI asociados a los lotes con riego, en concordancia con lo expuesto por Chen et al., (2023), quienes observaron que el TDVI está inversamente correlacionado con la humedad del suelo.

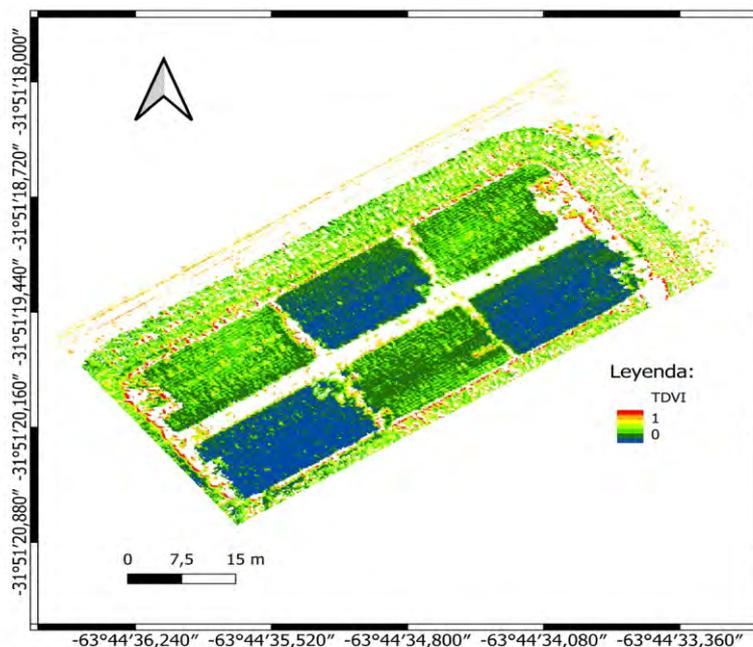


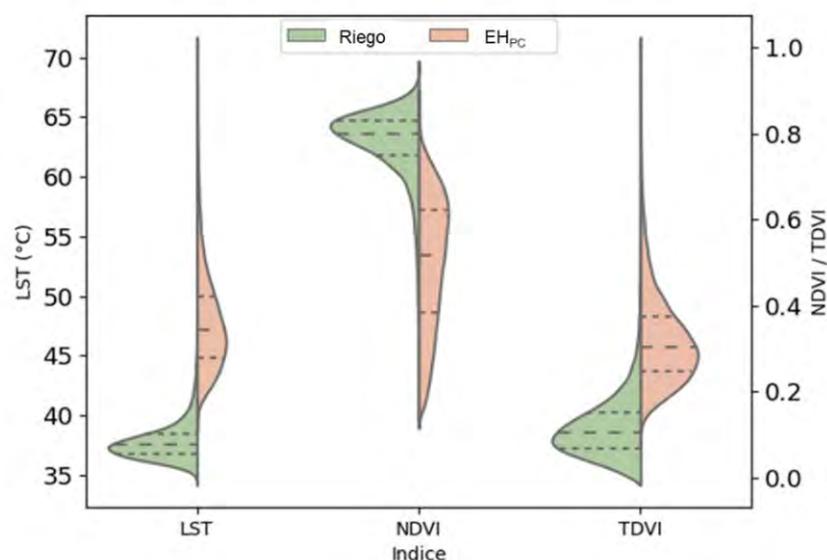
Figura 4: Índice espectral de sequía (TDVI) en maíz cultivado bajo dos condiciones hídricas. TDVI fue generado a partir del espacio NDVI-LST y de ecuaciones de borde húmedo y seco.

Todos los índices difirieron significativamente entre tratamientos (Tabla 1), siendo los valores promedio de LST y TDVI menores en riego que en secano, en tanto que el NDVI tuvo un comportamiento inverso (Tabla 1). En términos promedio, el NDVI en EH<sub>PC</sub> fue 36% menor que en la condición regada. A su vez, LST y TDVI en EH<sub>PC</sub> aumentaron 26 y 172 %, respectivamente en comparación con la situación control. En este estudio y a diferencia de otros, el NDVI determinado en R3 también permitió discriminar significativamente las distintas condiciones hídricas, probablemente debido al efecto negativo del estrés hídrico sobre procesos como la expansión y la duración del área foliar verde y la concentración de nitrógeno en hojas (Nguy-Robertson et al., 2012; Gitelson et al., 2014).

**Tabla 1. Valores promedio de índice de vegetación de diferencia normalizada (NDVI), temperatura de superficie (LST; °C) e índice espectral de sequía (TDVI) en maíz cultivado bajo dos condiciones hídricas (riego, R y estrés hídrico alrededor de floración, EH<sub>PC</sub>). Experimento conducido en Manfredi, Córdoba. Datos relevados a los 93 días desde la siembra**

Variable	Valores Promedio	
	Riego	EH <sub>PC</sub>
NDVI	0.777	0.498
LST (°C)	37.815	47.816
TDVI	0.118	0.321
P value	<0.05	<0.05

Un segundo aspecto a destacar, además de los efectos de la condición hídrica sobre los valores medios de los índices, fue la mayor variabilidad de las distribuciones de frecuencia de LST y NDVI en la condición de estrés hídrico (Figura 5).



**Figura 5: Diagrama de violín del Índice de vegetación de diferencia normalizada (NDVI), la Temperatura de superficie (LST) y el Índice espectral de sequía (TDVI) en maíz cultivado bajo dos condiciones hídricas. Para cada índice, las líneas de guiones indican los cuartiles Q1 y Q3 y la mediana.**

## Conclusiones

Mediante el espacio NDVI-LST generado a partir de imágenes multiespectrales y térmicas, se pudo estimar el TDVI, a pesar de que el gráfico de dispersión de la relación entre LST y NDVI no presentó la forma triangular o trapezoidal comúnmente descrita en la literatura. Todos los índices (LST, NDVI y TDVI) permitieron discriminar escenarios hídricos contrastantes. En particular, TDVI demostró ser un indicador robusto para evaluar los efectos del estado hídrico sobre variables asociadas con el funcionamiento fotosintético del maíz. La caracterización de cultivos mediante índices multiespectrales y térmicos obtenidos mediante VANT presenta potencial para estudios de fenotipado de alto caudal. Sin embargo, más estudios son necesarios para evaluar la capacidad discriminante de estos índices en distintos genotipos y estadíos fenológicos de los cultivos (i.e., su caracterización temporal).

## Agradecimientos

Este trabajo fue financiado mediante los siguientes proyectos: INTA 2023-PE-L01-I012 Intensificación Sostenible de la Agricultura Extensiva en la Región Pampeana; INTA 2023-PD-L01-I102 Bases ecofisiológicas para mejorar la adaptación de los cultivos a la variabilidad ambiental mediante el manejo agronómico y el mejoramiento genético.

## Referencias

- Cheng, M., Sun, C., Nie, C., Liu, S., Yu, X., Bai, Y., Liu, L., Meng, L., Jia, X., Liu, Y., Zhou, L., Nan, F., Cui, T., Jin, T. (2023) Evaluation of UAV-based drought indices for crop water conditions monitoring: A case study of summer maize. *Agricultural Water Management*, 287, Article 108442. <https://doi.org/10.1016/j.agwat.2023.108442>
- De la Casa, AC. y Ovando, GG. (2014). Climate change and its impact on agricultural potential in the central region of Argentina between 1941 and 2010. *Agricultural and Forest Meteorology*. 195-196: 1-11.
- Gitelson AA, Peng Y, Huemmrich KF (2014) Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250m resolution data. *Remote Sensing of Environment* 147, 108-120.
- IPCC, Shukla, P.R., Skea, J., Calvo Buendia, E., Masson-Delmotte, V., Pörtner, H.-O., Roberts, D.C., Zhai, P., Slade, R., Connors, S., van Diemen, R., Ferrat, M., Haughey, E., Luz, S., Neogi, S., Pathak, M., Petzold, J., Portugal Pereira, J., Vyas, P., Huntley, E., Kissick M, K. (2019). *Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems*. <https://doi.org/10.1002/9781118786352.wbieg0538>.
- Liu, Y., Wu, L., & Yue, H. (2015). Biparabolic NDVI-Ts space and soil moisture remote sensing in an arid and semi arid area. *Canadian Journal of Remote Sensing*, 41(3), 159-169.
- Liu, Y., Ni, Z., Zhao, Y., Zhou, G., Luo, Y., Li, S., ... & Zhang, S. (2022). Spatial-temporal evolution and driving forces of drying trends on the Qinghai-Tibet Plateau based on geomorphological division. *International Journal of Environmental Research and Public Health*, 19(13), 7909.
- Nguy-Robertson A, Gitelson A, Peng Y, Viña A, Arkebauer T, Rundquist D (2012) Green leaf area index estimation in maize and soybean: Combining vegetation indices to achieve maximal sensitivity. *Agronomy Journal* 104(5), 1336-1347. doi:10.2134/agronj2012.0065
- Ritchie, S.W., and J.J. Hanway. 1982. How a corn plant develops. Special Report 48. Coop. Extension S., Iowa State Univ. of Science and Technology, Ames, Iowa.
- Rostami, A., Raeini-Sarjaz, M., Chabokpour, J., & Chadee, A. A. (2023). Soil moisture monitoring by downscaling of remote sensing products using LST/VI space derived from MODIS products. *Water Supply*, 23(2), 688-705.
- Rouse, J. W. et al. (1974) Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ.* 351, 309
- Masina, M., Lambertini, A, Dapra, I, Mandanici, E, Lamberti, A. (2020). Remote Sensing Analysis of Surface Temperature from Heterogeneous Data in a Maize Field and Related Water Stress. *Remote Sens.* 12, 2506. doi:10.3390/rs12152506
- Messina, G., & Modica, G. (2020). Applications of UAV Thermal Imagery in Precision Agriculture: State of the Art and Future



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



Research Outlook. *Remote Sens.* 12, 1491.

Sandholt, I., Rasmussen, K., Andersen, J. (2002). A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sens. Environ.* 79 (2-3):213-224. [http://dx.doi.org/10.1016/S0034-4257\(01\)00274-7](http://dx.doi.org/10.1016/S0034-4257(01)00274-7).

Sayago, S., Ovando, G., Bocco, M. (2017). Landsat images and crop model for evaluating water stress of rainfed soybean. *Remote Sensing of Environment* 198, 30-39.

Yan W., Jiang, J., He, L., Zhao, W., Nair, R., Wang, X., Xiong, Y. (2024). Correcting land surface temperature from thermal imager by considering heterogeneous emissivity. *International Journal of Applied Earth Observation and Geoinformation* 129: 103824



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Uso de índices de vegetación multiespectrales para el fenotipado de alto caudal en híbridos de girasol cultivado a campo

Peirone, L.<sup>1-2</sup>, Mazzalay, A.<sup>1</sup>, Heinz, N.<sup>1</sup>, Vega, C.R.<sup>1</sup>

<sup>1</sup> EEA INTA Manfredi, Córdoba, <sup>2</sup> IAPCByA UNVM, Villa María, Córdoba.

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

**Resumen.** El girasol es el quinto cultivo en producción de semillas oleaginosas a nivel mundial, y Argentina tiene un rol destacado en su producción. El mejoramiento de girasol es crucial para la seguridad alimentaria. Entre los caracteres fenotípicos deseables, la uniformidad espacial y el establecimiento temprano del cultivo son esenciales. Tradicionalmente, estos caracteres se evalúan visualmente, metodología que puede ser muy subjetiva. Los índices de vegetación multiespectrales (IVs) capturados mediante vehículos aéreos no tripulados (VANTS) pueden contribuir para un fenotipado más preciso y rápido. En este trabajo se puso a prueba la fortaleza de distintos IVs para describir variables relacionadas con la cobertura, uniformidad espacial, estado general y rendimiento del cultivo de girasol. Se evaluaron 84 híbridos de girasol con resistencia a herbicidas imidazolinonas en condiciones de secano durante la campaña 2023/2024. Todos IVs y el porcentaje de cobertura (ArPrcnt), mostraron correlaciones significativas con la uniformidad espacial y, en menor medida, con el rendimiento, destacando su superioridad sobre las evaluaciones visuales tradicionales. NDVI, NGRDI, PSRI y ArPrcnt resultaron ser índices robustos, sugiriendo que su uso puede mejorar la precisión y velocidad del fenotipado en girasol. Estos hallazgos permitirían optimizar la selección genotípica y el mejoramiento de girasol, especialmente en escenarios con alta variabilidad ambiental. Estudios futuros deberían explorar la dinámica temporal de los IVs y su relación con la productividad en cultivos de girasol.

**Palabras clave.** Uniformidad espacial, VANTS, NDVI, Aspecto

## Introducción

El girasol, segundo cultivo híbrido más importante y quinto en producción de semillas oleaginosas alcanzó una producción mundial de 55.143 mil toneladas. Como cuarto productor, Argentina (USDA, 2024) tiene un histórico rol relevante en la producción de girasol. El mejoramiento y la selección genotípica de esta especie son aspectos fundamentales para el logro de materiales adaptados a nuevos escenarios de cambio climático y que contribuyan a la seguridad alimentaria a través de su rendimiento y calidad.

Entre diversos caracteres fenotípicos deseables, el establecimiento temprano y la uniformidad del cultivo son especialmente objetos de selección, además del rendimiento en semilla y aceite en girasol. Aunque la uniformidad espacial del cultivo es esencial para optimizar la captación y uso eficiente de recursos como el agua y la radiación solar (Araus et al., 2008), esta variable se evalúa tradicionalmente mediante escalas visuales. La valoración visual incluye aspectos relacionados con la uniformidad en la emergencia, la cobertura, el vigor híbrido, la presencia de plantas fuera de tipo, y la salud general del cultivo (*i.e.* grado de verdor y senescencia foliar). El fenotipado manual de estas variables necesita, asimismo, la experiencia del mejorador y está limitado por la capacidad operativa y su costo en términos de tiempo y oportunidad durante el ciclo del cultivo. Asimismo, una importante limitante en la eficiencia del fenotipado es la alta heterogeneidad de los ambientes a campo, particularmente cuando la selección se realiza en secano. La variación ambiental, aún en un mismo experimento a campo, puede enmascarar la correcta evaluación de la variabilidad genotípica (Rebetzke et al., 2012).

En este contexto, índices de vegetación multiespectrales (IVs) relevados mediante vehículos aéreos no tripulados (VANTs) pueden contribuir para un fenotipado más robusto que permita el equilibrio entre precisión, velocidad y rentabilidad (Gano et al., 2024). Los IVs capturan la reflectancia de los canopeos y pueden describir cuantitativamente múltiples variables asociadas con la captura y uso de recursos, y con la salud de cultivo en respuesta a factores genotípicos y ambientales (Al-Tamimi et al., 2022). En particular, su uso puede contribuir al desafío de superar la inherente variabilidad espacial del fenotipado a campo (Araus et al., 2015).

En este trabajo se puso a prueba la fortaleza de distintos IVs para describir variables relacionadas con la cobertura, uniformidad espacial, estado general y rendimiento del cultivo de girasol.

## Materiales y métodos

Se evaluaron 84 híbridos de girasol con resistencia a herbicidas imidazolinonas que incluyeron genotipos producidos a partir de líneas élite del programa de mejoramiento de la EEA INTA Manfredi, y testigos comerciales. El ensayo se llevó a cabo en Manfredi (31°49'S, 63°46'O), Córdoba, Argentina, durante la campaña 2023/2024, bajo condiciones de secano. El suelo fue un Haplustol éntico, serie Oncativo, con una capacidad de almacenamiento de agua útil de 313 mm (2 m). El experimento se sembró el 01/12/2024, siendo la unidad experimental una parcela de dos surcos de 5,10 metros de largo, distanciada a 0,70 metros. El diseño fue de bloques completos aleatorizados con tres repeticiones. El control de malezas se realizó mediante aplicaciones en pre-emergencia y en post emergencia (100 g de clearsol ha<sup>-1</sup>).

A los 69 días desde la siembra (DDS), se evaluó en cada unidad experimental el parámetro denominado Aspecto (ASP PROM), mediante una escala visual (0-5, donde 0 =muy mala condición y 5 =excelente) que valora la unidad experimental en forma completa en términos de la uniformidad espacial, genética y sanidad (Figura 1).



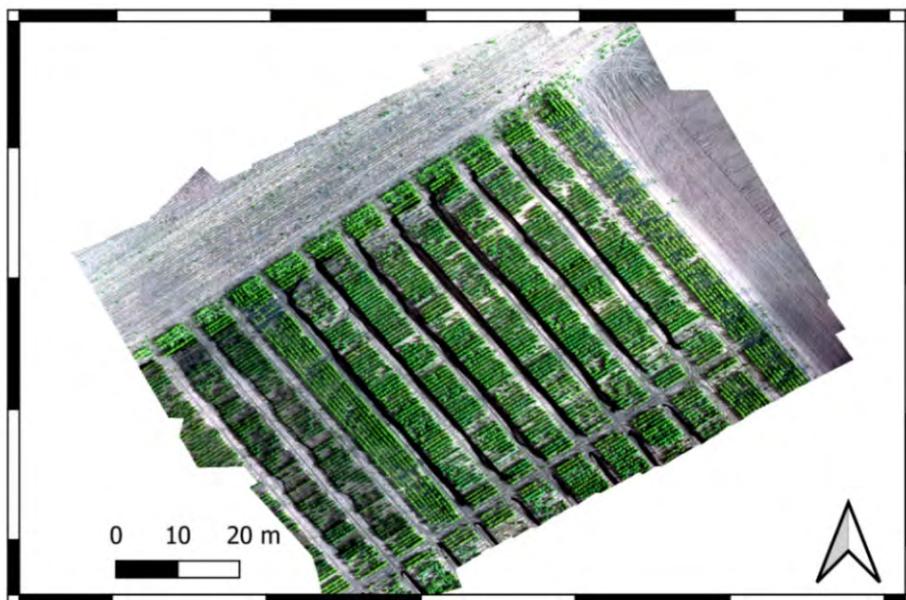
**Figura 1. Evaluación del parámetro Aspecto en cultivos de girasol a campo mediante escala visual. El parámetro valora variables como uniformidad espacial y salud general del cultivo.**

La adquisición de datos multiespectrales se realizó con un vehículo aéreo no tripulado (VANT) Matrice 300 RTK (DJI Technology Co., Shenzhen, China), equipado con una cámara multiespectral MicaSense, la cual posee 5 bandas (roja, azul, verde, borde rojo e infrarroja). Se llevaron a cabo dos vuelos, a los 53 y a los 69 DDS. Los vuelos se realizaron a una altitud de 30 m, con una superposición lateral de 80% y frontal de 80%. Antes del vuelo, se realizó una calibración de reflectancia utilizando el panel con valores de reflectancia proporcionados por Micasense. Las imágenes fueron procesadas para la generación de los ortomosaicos (Figura 2). Para la extracción de los resultados de cada ortomosaico a nivel de unidad experimental, se utilizó el paquete R FIELDimageR (Matias et al., 2020) Luego de la extracción de las bandas por unidad experimental se calcularon nueve índices de vegetación (IVs, Tabla 1). Se estimó, además, el porcentaje de cobertura de canopeo (ArPrcnt), estimador significativo del crecimiento de planta, a través del complemento FIELDimageR (Matias et al., 2020).

**Tabla 1. Fórmulas de cálculo matemático de índices de vegetación multispectrales a partir de lecturas de reflectancia de canopy en el rango de longitudes de onda de bandas rojo (R), azul (B), verde (G), borde rojo (RE) e infrarrojo cercano (NIR)**

Nombre del índice de vegetación	Abreviatura	Fórmula
Normalized Difference NIR/Red Normalized Difference Vegetation Index	NDVI	$(NIR-R)/(NIR+R)$
Green Normalized Difference Vegetation Index	GNDVI	$(NIR-G)/(NIR+G)$
Normalized Difference 790/720 Normalized difference red edge index	NDRE	$(NIR-RE)/(NIR+RE)$
Normalized green red difference index	NGRDI	$(G-R)/(G+R)$
Difference Vegetation Index	DVI	$(NIR-RE)$
Plant senescence reflectance index	PSRI	$(R-G)/(RE)$
Triangular vegetation index	TVI	$0.5*(120*(NIR-G)-200*(R-G))$
Enhanced vegetation index	EVI	$2.5*(NIR-R)/(NIR+6*R-7.5*B+1)$
Red edge chlorophyll index	RECI	$(NIR-RE)-1$

Luego de la madurez fisiológica del cultivo, los capítulos de plantas se trillaron y procesaron para valorar parámetros de rendimiento y calidad (Tabla 2). La humedad del grano se determinó con un humidímetro Dickey-John Corporation GAC 500 XT y se ajustó al 14% para calcular el Rendimiento por hectárea. El contenido de aceite en base seca se determinó por bulk de granos secos con un porcentaje de humedad igual o inferior al 5% mediante espectrómetro de resonancia magnética nuclear (NMR) SLK-100 de Spinlock SRL, calibrado según especificaciones de la American Oil Chemical Society. El contenido de aceite permitió estimar el Rendimiento ajustado por aceite por hectárea, el cual considera la bonificación otorgada al momento de comercialización en aquellos que superan el 42% de aceite.



**Figura 2. Ortomosaico multispectral a los 69 días desde la siembra. Ensayo de híbridos de girasol con resistencia a herbicidas**

imidazolinonas. EEA INTA Manfredi, Córdoba

**Tabla 2. Parámetros y abreviaturas relevados en 84 híbridos de girasol cultivados en secano durante 2023-2024**

Nombre del parámetro	Abreviatura
Aspecto promedio	ASP PROM
Densidad de planta por hectárea (plantas/ha)	DENSIDAD
Contenido de aceite (%)	ACEITE
Rendimiento de grano por hectárea (kg/ha)	RENSH
Rendimiento Ajustado por aceite por hectárea (kg/ha)	RENSA

## Análisis estadístico

Se evaluó la correlación entre parámetros relevados a campo (Tabla 2), distintos IVs (Tabla 1) y ArPrnt. La capacidad predictiva de los IVs se valoró mediante regresiones y análisis de componentes principales (ACP).

## Resultados y discusión

El alto número de unidades experimentales analizado permitió amplios rangos de variación de todas las variables evaluadas. Así, por ejemplo, la cobertura varió en un rango entre 60 y 98% en un momento inmediatamente anterior a la fecha media de floración del girasol (a los 69 DDS).

A los 53 DDS, todos los IVs y el porcentaje de cobertura (ArPrnt) mostraron correlaciones significativas con el índice ASP PROM ( $0.52 > r > 0.56$ ,  $<0,0001$ ), variable que fue determinada con posterioridad a los 69 DDS. Con menor fortaleza, pero significativamente, los IVs también se asociaron con el rendimiento de grano ( $r = 0.3$  a  $0.38$ ,  $<0,0001$ ; Tabla 3). El índice PSRI mostró correlación negativa y significativa con ASP PROM y rendimiento, respectivamente ( $r = -0.54$ ,  $<0,0001$ ;  $-0.29$ ,  $<0,0001$ ; Figura 3). Los índices que exhibieron una mayor correlación con ASP PROM fueron el NDVI, GNDVI y NDRE.

A los 69 DDS (Tabla 4), los IVs mostraron correlaciones más fuertes y significativas con ASP PROM ( $0.58 > r > 0.69$ ;  $p < 0.0001$ ) y RENSH ( $0.36 > r > 0.51$ ;  $< 0.0001$ ). En particular, ASP PROM mostró fuerte correlación con NDVI ( $r = 0.69$ ), PRSI ( $r = -0.67$ ) y ArPrnt ( $r = 0.67$ ). En términos promedios, el grupo de genotipos exhibió rangos de ASP PROM entre 0.83 y 4.17, y de NDVI entre 0.25 a 0.63.

Con variaciones particulares en cada IV, todos los índices utilizados describieron aspectos relacionados con el tamaño del área foliar, el porcentaje de cobertura y el contenido de clorofila del canopy. Se conoce que estas variables son críticas para la interceptación y uso de la radiación solar, la tasa de crecimiento del cultivo y la productividad final (Trapani et al., 2004). Estas relaciones subyacen a las fuertes asociaciones entre los IVs y los criterios utilizados en las observaciones visuales determinantes de ASP PROM.

Es de destacar también que los IVs fueron más robustos que las valoraciones visuales para describir la productividad medida como rendimiento en grano (Tablas 3 y 4).

**Tabla 3. Coeficientes de correlación a los 53 días después de siembra entre los índices multiespectrales y los parámetros relevados a campo. Color verde indican coeficientes significativos ( $p < 0.05$ )**

	NDVI	GNDVI	NGRDI	DVI	NDRE	PSRI	TVI	EVI	RECI	ArPrct	ASP PROM	RENSH	ACEITE	RENSA
ASP PROM	0,56	0,56	0,52	0,53	0,55	-0,54	0,54	0,54	0,53	0,53				
RENSH	0,34	0,36	0,3	0,34	0,37	-0,29	3,10E-01	0,31	0,34	0,38	0,14			
ACEITE	-0,05	-0,03	-0,08	0,02	-0,01	0,08	-0,02	-1,90E-03	0,02	0,09	-0,04	0,2		
RENSA	0,26	0,28	0,22	0,27	0,3	-0,22	0,24	0,24	0,27	0,35	0,09	0,95	0,4	
DENSIDAD	0,25	0,25	0,23	0,27	0,25	-0,23	0,27	0,27	0,27	0,23	0,17	0,25	0,32	0,29

**Tabla 4. Coeficientes de correlación a los 69 días después de siembra entre los índices multiespectrales y los parámetros relevados a campo. Color verde indican coeficientes significativos ( $p < 0.05$ )**

	NDVI	GNDVI	NGRDI	DVI	NDRE	PSRI	TVI	EVI	RECI	ArPrct	ASP PROM	RENSH	ACEITE	RENSA
ASP PROM	0,69	0,64	0,67	0,58	0,6	-0,67	0,64	0,63	0,58	0,67				
RENSH	0,41	0,47	0,36	0,51	0,45	-0,3	4,70E-01	0,46	0,51	0,19	0,14			
ACEITE	-0,09	-0,02	-0,16	0,01	-0,03	0,16	-0,04	-0,03	0,01	-0,11	-0,04	0,2		
RENSA	0,26	0,32	0,21	0,37	0,31	-0,16	0,33	0,33	0,37	0,09	0,06	0,91	0,39	
DENSIDAD	0,23	0,25	0,21	0,27	0,21	-0,18	0,28	0,29	0,27	0,15	0,17	0,25	0,32	0,26

Con el objetivo de integrar gráficamente las relaciones entre las variables analizadas y su capacidad para discriminar grupos de híbridos, se realizó un Análisis de Componentes Principales (ACP) a los 53 y 69 días con las variables más representativas de la investigación (Figura 3). Los dos componentes principales explicaron más del 80% de la variabilidad total de los datos en ambos momentos.

Los índices NDVI y NGRDI estuvieron fuertemente correlacionadas con ASP PROM y, en menor medida, con variables de importancia productiva como RENSH, ACEITE, y RENS (notar el ángulo menor a 90° entre vectores). Fueron destacables las asociaciones negativas entre ASP PROM y PSRI medidos a los 69 días.

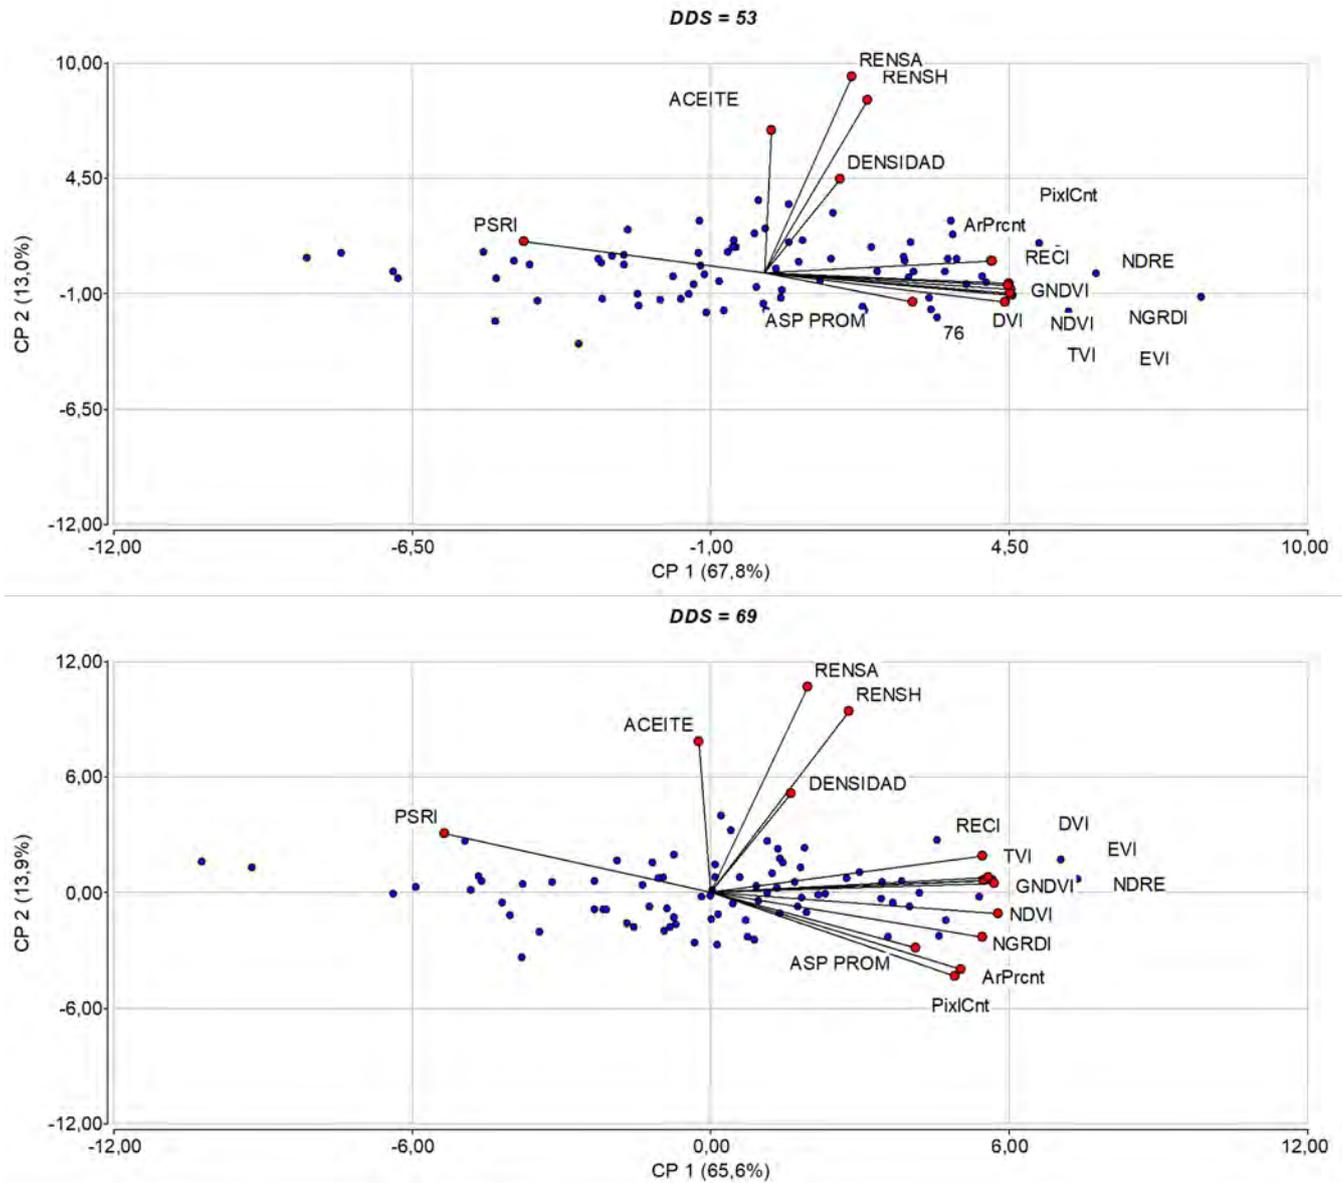


Figura 3. Análisis de componentes principales a los 53 (panel superior) y 69 (panel inferior) días después de siembra. Vectores: índices multiespectrales y parámetros relevados a campo. Casos: 84 híbridos de girasol evaluados a campo.

Los resultados de este trabajo, basados en una gran cantidad de genotipos que generaron amplios rangos de variables, destacan la contribución de los IVs relevados mediante VANT para el fenotipado de alto caudal en apoyo al mejoramiento genético vegetal. La fuerte asociación entre IVs y evaluaciones visuales que integran diversos aspectos de la salud del cultivo de girasol permitiría incrementar la velocidad y calidad de las evaluaciones a campo. Estudios complementarios para valorar la asociación entre los índices NDVI, GNDVI, NGRDI y PSRI y la acumulación de biomasa en floración o madurez fisiológica podrían mejorar la estimación del rendimiento en grano. Así como lo encontrado en este estudio, otros autores han destacado que mejores correlaciones entre IVs y rendimiento son alcanzadas cuando estos son medidos alrededor de floración (Amankulova et al., 2023). Asimismo, y como fuera

demostrado en cultivos de soja (Ogando et al., 2022), el uso de dinámicas temporales de los IVs en vez de mediciones puntuales podría contribuir a valorar el impacto de la duración del área foliar verde sobre el rendimiento en aceite.

## Conclusiones

El fenotipado de cultivos es uno de los mayores desafíos en la mejora genética no solo por su costo operativo sino por la ubicua variabilidad espacial a campo. En este estudio, se evaluó la fortaleza de la asociación entre los índices de vegetación NDVI, NGRDI y PSRI y la variable □Aspecto□, un proxy en escala visual de la uniformidad de plantas en términos de sincronía en la emergencia, el grado de cobertura, de crecimiento y salud en general. Las fuertes relaciones encontradas en momentos cercanos a la floración del cultivo explicaron también la variable rendimiento, aunque en menor medida. A futuro, es necesario indagar si dicha fortaleza de los IVs permite también discriminar genotipos donde son esperables menores rangos de variación, particularmente en aquellos ya adaptados y prontos a la liberación comercial.

## Agradecimientos

Este trabajo fue financiado mediante los siguientes proyectos: 2023-PE-L01-I012 Intensificación Agrícola Sustentable, 2019-REC-E1-I026-001 Red de Ecofisiología y PE. I111 Mejoramiento genético girasol, soja, colza y lino.

## Referencias

- Al-Tamimi, N., Langan, P., Bernád, V., Walsh, J., Mangina, E., Negrão, S., (2022). Capturing crop adaptation to abiotic stress using image-based technologies. *Open Biol.* 12(6), 210353. <https://doi.org/10.1098/rsob.210353>.
- Amankulova, K., Farmonov, N., Mukhtorov, U., Mucsi, L. (2023). Sunflower crop yield prediction by advanced statistical modeling using satellite-derived vegetation indices and crop phenology. *Geocarto International.* 38(1), 2197509. <https://doi.org/10.1080/10106049.2023.2197509>.
- Araus, J.L., Elazab, A., Vergara, O., Cabrera-Bosquet, L., Serret, M.D., Zaman-Allah, M., Cairns, J.E. (2015). New technologies for phenotyping, in: *Phenomics: How Next-Generation Phenotyping is Revolutionizing Plant Breeding*. pp. 1-14.
- Araus, J.L., Slafer, G.A., Royo, C., Serret, M.D. (2008). Breeding for Yield Potential and Stress Adaptation in Cereals. *Critical Reviews in Plant Sciences.* 27(6), 377-412.
- Gano, B., Bhadra, S., Vilbig, J.M., Ahmed, N., Sagan, V., Shakoore, N. (2024). Drone-based imaging sensors, techniques, and applications in plant phenotyping for crop breeding: A comprehensive review. *The Plant Phenome Journal.* 7(1), e20100. <https://doi.org/https://doi.org/10.1002/ppj2.20100>.
- Matias, F., Caraza-Harter, M., Endelman, J. (2020). *FIELDimageR*: An R package to analyze orthomosaic images from agricultural field trials. *The Plant Phenome Journal.* <https://doi.org/10.1002/ppj2.20005>
- Ogando, F., Peirone, L.S., Cicconi, E., Raspa, F.A., Ovando, G., Vega, C.R.C. (2022). Utilización de índices multiespectrales relevadas mediante un UAV para la predicción de rendimiento, número y peso de granos en Soja. *II Congreso Latinoamericano de Agricultura de Precisión*, 30-31/03 2022, Córdoba, Ar
- Rebetzke, G.J., Chenu, K., Biddulph, B., Moeller, C., Deery, D.M., Rattey, A.R., Bennett, D., Barrett-Lennard, E.G., Mayer, J.E. (2012). A multisite managed environment facility for targeted trait and germplasm phenotyping. *Functional Plant Biology.* 40(1), 1-13. <https://doi.org/https://doi.org/10.1071/FP12180>.
- Sala, C. A. (2010) Nuevas tecnologías en tolerancia a herbicidas. [asagir.org.ar](http://asagir.org.ar) Revisado 9 Agosto 2024
- Trapani, N., Lopez Pereyra, M., Sadras, V., Hall, A. (2004) Ciclo ontogénico, dinámica del desarrollo y generación del rendimiento y la calidad de girasol. En E. Satorre et al., (Ed.) *Producción de granos* (pp.204-237). FAUBA.
- USDA,(2024). *Sunflowerseed2024*. <https://ipad.fas.usda.gov/cropeplorer/cropview/commodityView.aspx?cropid=2224000> Accessed 9 August 2024



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Uso de NDRE para evaluar efectos de fertilización nitrogenada durante la post-floración en maíz (*Zea mays* L.)

Pari, E.<sup>1-2</sup>, Ogando, F.A.<sup>2</sup>, Villafañe, M.J.<sup>3</sup>, Peirone, L.S.<sup>2</sup>, Raspa, F.A.<sup>2</sup>, Vega, C.R.C.<sup>2</sup>.

<sup>1</sup> Agencia de extensión rural INTA Rio Primero, <sup>2</sup> Grupo de Ecofisiología de Cultivos EEA INTA Manfredi, <sup>3</sup> Instituto de Investigaciones Agrobiotecnológicas (INIAB-CONICET-UNRC).

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

### **Resumen.**

Este estudio evaluó el uso del índice NDRE (Normalized Difference Red Edge) para medir el efecto de una re-fertilización nitrogenada tardía en maíz (*Zea mays* L.) sobre el acumulado de NDRE, rendimiento, peso de granos y peso específico de tallos. El experimento se realizó durante la campaña agrícola 2023-2024 en INTA Manfredi (Córdoba, Argentina). Los tratamientos consistieron en dos condiciones hídricas contrastantes en la disponibilidad de agua durante el período crítico, y dos tratamientos de fertilización en R3. Las imágenes multispectrales se capturaron usando un vehículo aéreo no tripulado (VANT) con una cámara multispectral, se procesaron los datos para obtener valores de NDRE a lo largo del ciclo de cultivo. Los resultados mostraron que la variabilidad en el rendimiento de maíz fue explicada en un 67% por NDRE acumulado durante todo el ciclo y en un 74% por NDRE post fertilización (NDRE<sub>PF</sub>). Además, el peso de granos fue significativamente influenciado por la condición hídrica y la re-fertilización nitrogenada, con el NDRE<sub>PF</sub> explicando un 67% de la variabilidad observada. Sin embargo, se encontró una baja correlación entre NDRE<sub>PF</sub> y el peso específico de tallos, indicando que NDRE no captura completamente los factores complejos que afectan la removilización de reservas en el tallo. Estos hallazgos sugieren que NDRE<sub>PF</sub> es una herramienta valiosa para evaluar la respuesta del rendimiento de maíz a la fertilización tardía, aunque su capacidad para predecir aspectos estructurales como el peso de los tallos es limitada. Esto destaca la necesidad de explorar otros índices de vegetación o combinaciones de índices para capturar más completamente las dinámicas del cultivo.

### **Palabras clave.**

*Fertilización, Reflectancia, Condición hídrica.*

## Introducción

En Argentina, la aplicación de fertilizantes nitrogenados en maíz se realiza principalmente a la siembra o en dosis dividida entre siembra y estadios vegetativos tempranos (Correndo et al., 2021). Estudios de ganancia genética reportan que la absorción de nitrógeno en genotipos modernos de maíz cambió durante la pre-floración. Sin embargo, si observan que genotipos modernos absorben entre el 25% y 42% de nitrógeno total requerido durante la post-floración (Ciampitti & Vyn, 2012). Reducciones en la absorción de nitrógeno durante este período están asociadas a pérdida de la capacidad fotosintética (senescencia anticipada) penalizando al crecimiento del cultivo, la removilización de reservas en tallos y el peso de granos. Por lo tanto, sería de esperar que fertilizaciones tardías promuevan una mejora en la eficiencia en el uso del nitrógeno al acoplar la oferta y la demanda de nitrógeno por parte del cultivo y contribuir a sostener el crecimiento durante la post-floración y sostener o incrementar el peso de granos.

En los últimos años, el uso de tecnologías de sensado remoto basada en la utilización de sensores multiespectrales ayudan a proporcionar datos para la fenotipificación y el seguimiento de cultivos. En particular, el uso de VANT ha permitido avanzar a escala fina debido a su facilidad de uso y fácil acceso. El empleo de imágenes multiespectrales permite la construcción de distintos índices de vegetación (IV) para la cuantificación de variables en tierra. Entre ellos, los IV basados en la región visible e infrarrojo cercano (NIR), asociados con el contenido de clorofilas y absorción de nitrógeno, pueden ser utilizados para describir procesos asociados a la absorción de nitrógeno y procesos de senescencia por los cultivos. Entre ellos se destaca el uso del Normalized Difference Red Edge (NDRE) que a diferencia de otros IV comúnmente utilizados es menos susceptible a saturación en canopeos densos al emplear en su cálculo la banda del borde rojo y ha demostrado ser una potente herramienta para cuantificar la absorción de nitrógeno en diversos cultivos. Sin embargo, son escasos los estudios que utilizan estas herramientas para cuantificar el efecto de fertilización nitrogenada tardía en maíz. El objetivo de este trabajo fue evaluar mediante el uso de NDRE efectos de fertilización tardía en maíz sobre: I) Absorción de nitrógeno; II) Rendimiento y peso de granos; III) Peso específico de tallos.

## Materiales y métodos

### Sitio de estudio

Durante la campaña agrícola 2023-2024 se llevó a cabo un experimento a campo en la EEA INTA Manfredi (31°49'S, 63°46'O), Córdoba, Argentina. Las dimensiones del área de estudio consistieron en un ancho de 30 m y 74 m de largo. Se sembró un único genotipo de maíz (Next 22.6 PWU) con una densidad de 7,5 pl.m<sup>2</sup> el 31 de octubre. El manejo del agua se realizó mediante un sistema de riego por goteo. En el estadio fenológico de V6 (Ritchie et al., 1992) se re-fertilizó al cultivo para llegar a 105 kg N ha<sup>-1</sup> (suelo + fertilizante). El diseño experimental fue de parcelas sub-divididas con tres repeticiones. La parcela principal correspondió a dos tratamientos de condición hídrica contrastantes durante el período crítico del cultivo centrado en floración: i) Riego (R) y ii) estrés hídrico durante período crítico (EH<sub>PC</sub>). En R se regó para mantener el perfil a 70% de agua útil (AU) y en EH<sub>PC</sub> se cortó el suministro de agua para bajar el contenido hídrico a 30% del AU. El resto del ciclo del cultivo, y en ambos tratamientos hídricos, se mantuvo el perfil del suelo al 50% de agua útil. La sub-parcela correspondió a dos tratamientos de fertilización nitrogenada: i) Re-fertilizado en R3 con 85 kg N ha<sup>-1</sup> (F); ii) No re-fertilizado (NF). Durante el ciclo del cultivo, el mismo se mantuvo libre de plagas, enfermedades y malezas. En madurez fisiológica se midió rendimiento y componentes por unidad experimental, y se relevó peso específico de tallos.

### Toma de imágenes multiespectrales con vehículo aéreo no tripulado (VANT)

Para la toma de imágenes se utilizó un Matrice 300 RTK (DJI Technology Co. Shenzhen, China) con

una cámara multispectral montada (MicaSense Altum, Lepton Unmanned Aircraft Systems, Inc., Denver, Colorado, USA). Esta cámara multispectral presenta la capacidad de captar cinco bandas multispectrales (verde, rojo, azul, borde rojo y NIR) y una banda termográfica. Previo a realizar los vuelos, se utilizaron paneles de reflectancia para calibrar la cámara con el software de fotogrametría de Micasense. Los vuelos fueron autónomos ya que el VANT navega por waypoints, utilizando su GPS incorporado para posicionarse y recorrer líneas preestablecidas, asegurándose de sacar fotos en todos los puntos que necesite. El plan de vuelo fue diseñado con un solape frontal y lateral del 80 % en ambos casos. Se realizaron nueve vuelos con las correspondientes fechas: 7/12/2023, 22/12/2023, 04/01/2024, 17/01/2024, 1/02/2024, 8/02/2024, 16/02/2024, 22/02/2024, 14/03/2024.

### Procesamiento de imágenes multispectrales

Las imágenes multispectrales fueron procesadas con el fin de obtener nueve orto mosaicos con una misma resolución espacial de 8.7 cm pixel<sup>-1</sup>. Se georreferenciaron y mediante los valores de reflectancia de las bandas infrarroja cercana y borde rojo, se calculó el Índice de borde rojo de diferencia normalizada (NDRE):

$$NDRE = \frac{NIR - RED\ EDGE}{NIR + RED\ EDGE} \quad (1)$$

Donde: NIR=reflectancia en la banda infrarrojo cercano y RED EDGE =reflectancia en la banda del borde rojo.

A partir de las capas raster generadas con los valores de NDRE, se obtuvo la variación del índice a lo largo de las fechas de los vuelos del VANT durante todo el ciclo del cultivo (NDRE<sub>Ciclo</sub>) y desde el momento de re-fertilización tardía hasta madurez fisiológica (NDRE<sub>PF</sub>)

### Resultados y discusión

La amplia variabilidad observada en rendimiento (rango 3855 a 11013 kg ha<sup>-1</sup>) pudo ser explicada en un 67% por NDRE<sub>Ciclo</sub> (Figura 1 A). Sin embargo, la capacidad predictiva de NDRE<sub>PF</sub> fue superior en un 7% (Figura 1 B). Estas diferencias pueden ser explicadas en el efecto de los tratamientos sobre la dinámica del NDRE durante el ciclo en donde las diferencias se observan durante la post-floración (Figura 2).

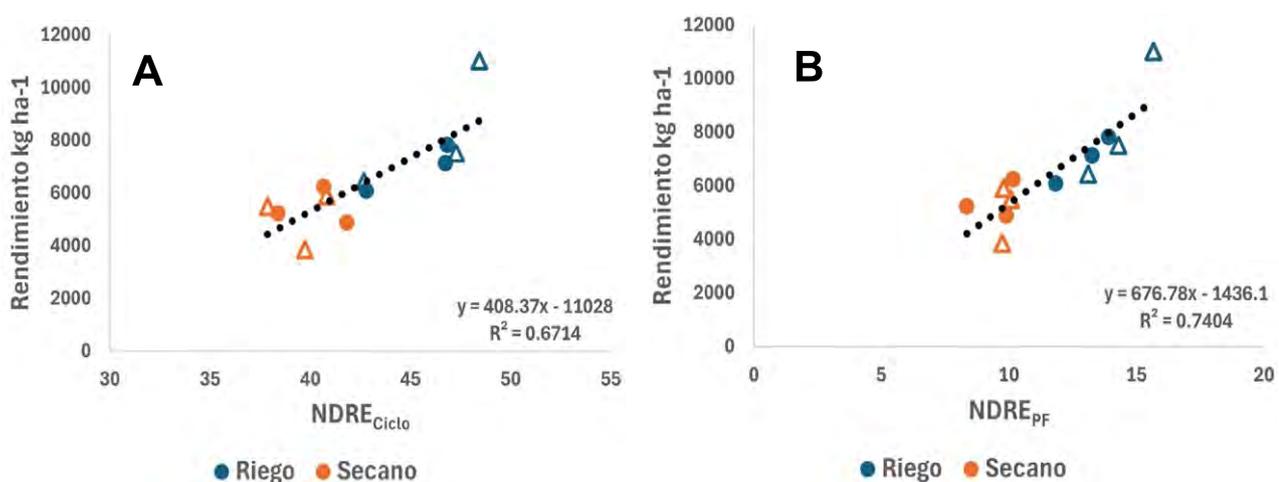


Figura 1. Relación entre NDRE<sub>Ciclo</sub> (A) y NDRE<sub>PF</sub> (B) con rendimiento para maíz sembrado bajo dos condiciones hídricas R

(naranja) y EHPC (azul). Símbolos vacíos y sólidos corresponden a los tratamientos F y NF respectivamente. En ambas figuras se indica la ecuación ajustada y el valor del ajuste.

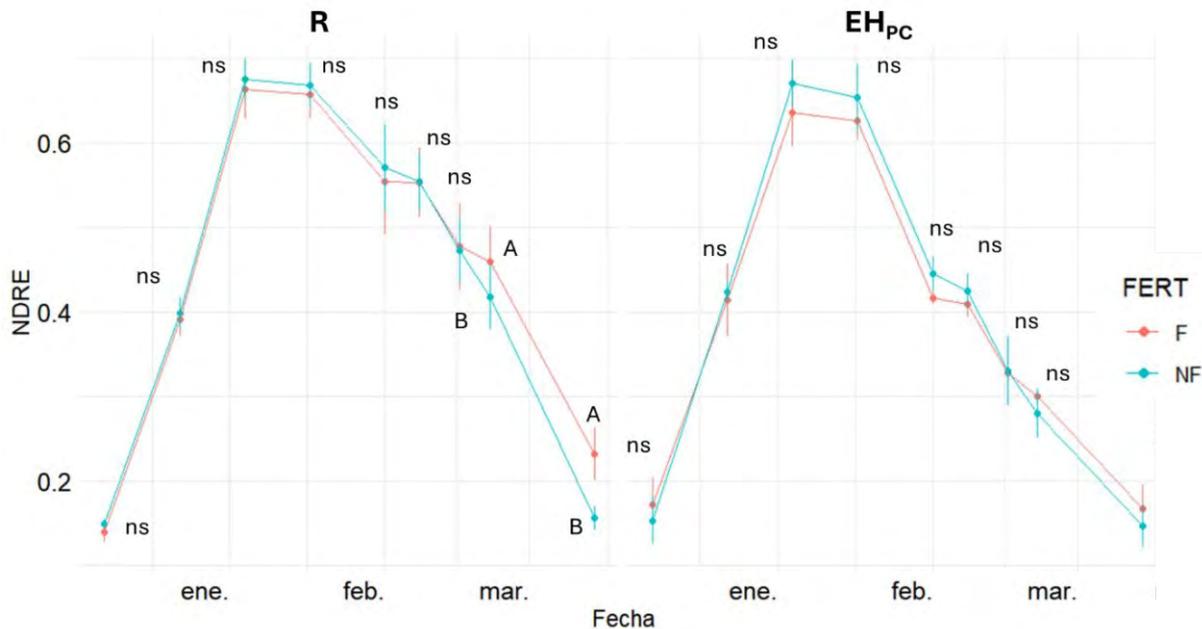


Figura 1. Evolución de NDRE para maíz sembrado bajo dos condiciones hídricas R (izquierda) y EHPC (derecha). Líneas rojas y azules corresponden a los tratamientos F y NF respectivamente. Para cada momento y condición hídrica se indica las diferencias estadísticas con un p-valor=0.05.

Por medio de todos los tratamientos, el PG varió entre 205 mg y 317 mg y fue explicado por la condición hídrica ( $R > EHPC$ ) y la re-fertilización nitrogenada ( $F > NF$ ;  $p < 0.05$ ; Tabla 1). El uso de NDREPF permitió explicar el 67% de las diferencias observadas en PG (Figura 3). Sin embargo, mostró una correlación baja con peso específico de tallos (Figura 4). Estos resultados destacan el uso de NDREPF para evaluar el efecto de fertilizaciones tardías sobre el peso de granos en maíz. Por otro lado, la baja correlación entre NDREPF y peso específico de tallos sugiere que el IV no es capaz de captar la complejidad de factores que determinan la removilización de reservas como por ejemplo la relación fuente destino. Este hallazgo abre puertas a futuras investigaciones que podrían explorar otros IV o combinaciones de IV y momentos del ciclo (i.e. período crítico).

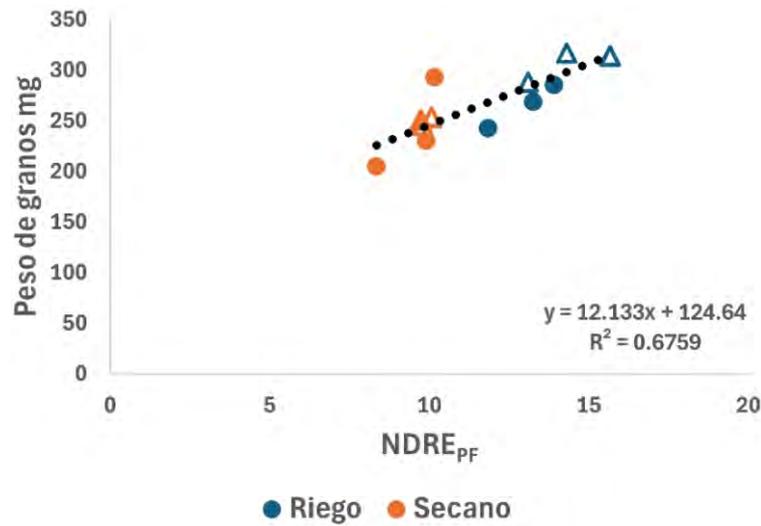


Figura 2. Relación entre NDREPF y peso de granos para maíz sembrado bajo dos condiciones hídricas R (naranja) y EHPC (azul). Símbolos vacíos y sólidos corresponden a los tratamientos F y NF respectivamente. En ambas figuras se indica la ecuación ajustada y el valor del ajuste.

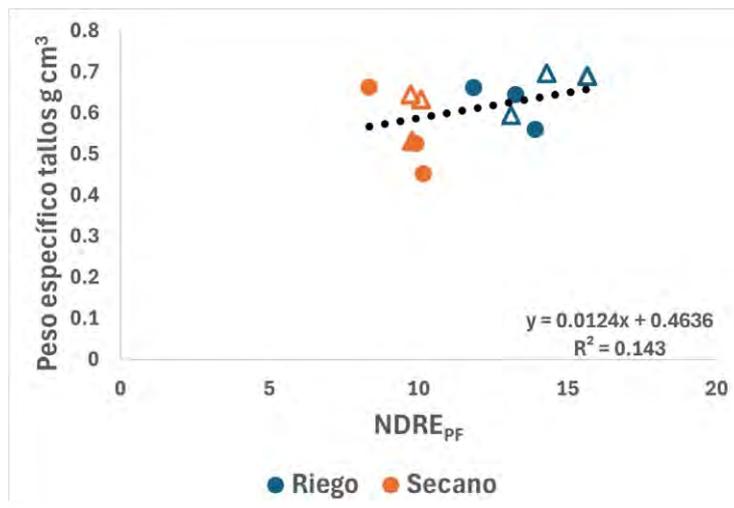


Figura 3. Relación entre NDREPF y peso específico para maíz sembrado bajo dos condiciones hídricas R (naranja) y EHPC (azul). Símbolos vacíos y sólidos corresponden a los tratamientos F y NF respectivamente. En ambas figuras se indica la ecuación ajustada y el valor del ajuste.

Tabla 1. Medias y resultados de ANOVA para peso de granos, letras diferentes indican diferencias significativas con un p-valor=0.05

	Peso de granos (mg)	
<b>Condición hídrica (CH)</b>		
R	283.8	A
EH <sub>PC</sub>	242.5	B
<b>Fertilización</b>		
F	278.4	A
NF	248.0	B
<b>Interacciones</b>		<b>P-valor</b>
CH	0.02	
F	0.01	
CH*F	ns	

## Conclusiones

El NDRE calculado a través de imágenes multiespectrales, mostro ser una herramienta muy útil para detectar variabilidad en el rendimiento de maíz frente a la re-fertilización en postfloración. Sin embargo, según lo expuesto, este índice no captura factores predominantes de la removilización de reservas en el tallo. Esto representa la necesidad de caracterizar al cultivo con nuevos índices que permitan interpretar covariables como en este caso, el peso del tallo. Emplear tecnologías basadas en el uso de sensores multiespectrales debiera ser una práctica común en los sistemas agrícolas modernos, ya que ayudan a proporcionar datos para el seguimiento e identificación de características específicas en los cultivos.

## Referencias

- Drian A. Correndo, Jose L. Rotundo, Nicolas Tremblay, Sotirios Archontoulis, Jeffrey A. Coulter, Dorivar Ruiz-Diaz, Dave Franzen, Alan J. Franzluebbbers, Emerson Nafziger, Rai Schwalbert, Kurt Steinke, Jared Williams, Charlie D. Messina, Ignacio A. Ciampitti, Assessing the uncertainty of maize yield without nitrogen fertilization, *Field Crops Research*, Volume 260, 2021. <https://doi.org/10.1016/j.fcr.2020.107985>.
- Ciampitti, IA y Vyn, TJ (2013), Cambios en la fuente de nitrógeno del grano a lo largo del tiempo en el maíz: una revisión. *Crop Science*, 53: 366-377. <https://doi.org/10.2135/cropsci2012.07.0439>
- Ritchie, S.W., and J.J. Hanway. 1982. How a corn plant develops. Special Report 48. Coop. Extension S., Iowa State Univ. of Science and Technology, Ames, Iowa.

## Estimación del contenido de clorofila “a”, carotenoides y peso de grano en maíz mediante NDRE

Villafañe, M.J.<sup>1</sup>, Ogando, F.A.<sup>2</sup>, Pari, E.<sup>2-3</sup>, Peirone, L.S.<sup>3</sup>, Raspa, F.A.<sup>3</sup>, Alemanno, S.G.<sup>1</sup>, Vega, C.R.C.<sup>3</sup>.

<sup>1</sup>Instituto de Investigaciones Agrobiotecnológicas (INIAB-CONICET-UNRC), <sup>2</sup>Grupo de Ecofisiología de Cultivos EEA INTA Manfredi; <sup>3</sup>Agencia de extensión rural INTA Rio Primero.

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

### Resumen.

La medición de clorofila se utiliza para evaluar la salud fotosintética y el impacto del estrés hídrico en los cultivos. Sin embargo, este indicador requiere mediciones costosas en tiempo y herramientas especializadas. Los índices de vegetación (IV) relevados mediante drone y sensores multiespectrales son una alternativa importante para determinar el estado fisiológico de cultivos a campo. Debido a su potencial y a que son pocos los estudios que correlacionan estas variables, este trabajo tuvo el objetivo de evaluar la fortaleza del índice NDRE (Normalized Difference Red Edge) para caracterizar el contenido de clorofila "a" y de carotenoides en maíz. Durante la campaña 2023-24, el NDRE de cultivos de maíz bajo distintas condiciones hídricas y nutricionales fue evaluado en los estadios V11 y R3 utilizando drones equipados con cámaras multiespectrales. Los resultados demostraron que NDRE explicó el 75 y 52% de la variación de clorofila y carotenoides en hoja, respectivamente. Un modelo único fue construido para evaluar la dinámica de estos pigmentos durante el período crítico del cultivo. A su vez,  $NDRE_{R1-R3}$  predijo el 60% de la variabilidad en el peso de los granos, destacando su utilidad para evaluar procesos de crecimiento durante el llenado. Si bien NDRE es promisorio como herramienta para el fenotipado de cultivos de maíz, nuevos estudios que valoren su potencia discriminante en distintos genotipos y ante combinaciones genotipo\*ambiente son necesarios.

### Palabras clave:

Maíz, NDRE, clorofila, carotenoides, condición hídrica

## Introducción

El maíz (*Zea Mays* L.) es uno de los principales cultivos sembrados a nivel mundial (FAO, 2022). En Argentina, su producción se realiza principalmente en secano. En regiones semiáridas, como la provincia de Córdoba, la producción de maíz se encuentra sujeta a la variabilidad y distribución de las precipitaciones durante el ciclo del cultivo (Otegui y Mercau, 2021). En estos ambientes, es común que los maíces sembrados en fechas tempranas enfrenten estreses hídricos, térmicos o combinados durante fases reproductivas con consecuentes efectos negativos sobre el funcionamiento y el rendimiento del cultivo.

En particular, estreses abióticos pueden acentuar la senescencia foliar (SF). La SF se caracteriza por la degradación de la clorofila en hojas. Por lo tanto, la cantidad de dicho pigmento es un indicador del estrés en las plantas, la senescencia y el contenido de nitrógeno foliar. En particular, la cuantificación del contenido de clorofila "a" ha sido ampliamente utilizada como un parámetro clave para monitorear el estado fotosintético de la planta debido a su alta concentración en hojas y su papel crucial en el transporte de electrones en el fotosistema II (Stirbet *et al.*, 2018). Durante estos periodos de estrés, la degradación de las clorofilas puede ser parcialmente compensada por la acción de pigmentos orgánicos, como los carotenoides, que la planta produce como respuesta antioxidante y que ayudan a transferir energía a las clorofilas (Rane *et al.*, 2022). Cuantificar el contenido de clorofila durante el período de llenado de granos es crucial para evaluar la eficiencia fotosintética y el impacto del estrés hídrico en el rendimiento del maíz. Sin embargo, este proceso puede ser costoso y requiere de herramientas especializadas y mediciones frecuentes en campo.

El uso de imágenes multiespectrales obtenidas mediante drones tiene un gran potencial para relevar el estado fisiológico de los cultivos de manera rápida y precisa. Entre los índices de vegetación derivados de estas imágenes, el Normalized Difference Red Edge (NDRE) se destaca por su potencial para cuantificar el contenido de clorofila, ya que detecta variaciones en la reflectancia del borde rojo cercano, un indicador crucial del vigor y la salud de las plantas. Asimismo, al poder identificar con mayor precisión los procesos de senescencia, podría ser utilizado para predecir el peso de granos en tratamientos contrastantes.

El objetivo de este trabajo es evaluar la capacidad predictiva de NDRE para discriminar cultivos de maíz bajo distinta condición hídrica y nitrogenada, y su relación con los pigmentos clorofila "a", carotenoides y el componente de rendimiento peso de granos.

## Materiales y métodos

### Experimento a campo

Durante la campaña 2023-24, se realizó un ensayo a campo en la estación experimental agropecuaria INTA Manfredi. Se sembró un único genotipo de maíz (Next 22.6 PWU) bajo un diseño experimental de parcelas sub-divididas con tres repeticiones. La parcela principal correspondió a dos tratamientos de condición hídrica; i) Riego (R) y ii) estrés hídrico durante período crítico ( $EH_{PC}$ ) y la subparcela a ocho tratamientos de fertilizantes basados en bioestimulantes (BE). Los tratamientos hídricos únicamente difirieron durante el período crítico del cultivo. En R, el perfil del suelo se mantuvo a 70% de agua útil (AU), mientras que en el tratamiento de  $EH_{PC}$ , el suministro de agua fue cercano al 30% del AU. A partir del fin del período crítico, ambos tratamientos se manejaron de modo de superar un umbral del 50% de agua útil. La combinación de diferentes condiciones hídricas y BE se utilizó para generar un amplio rango de concentración de clorofila y carotenoides durante el llenado de granos.

## Mediciones a campo

Los parámetros medidos en las plantas incluyeron la clorofila “a” y los carotenoides, determinados según el método de Wellburn (1994). En los estadios fenológicos V11 y R3, se recolectaron muestras de hoja en tres plantas consecutivas de los surcos centrales. Para la determinación, se extrajeron discos foliares de 1 cm de diámetro por planta, utilizando N-dimetilformamida como solvente de extracción. Las absorbancias de las soluciones se midieron a longitudes de onda de 646,8 nm, 663,8 nm y 480 nm. En el muestreo de V11, se utilizó la última hoja desplegada, mientras que en el muestreo de R3, se tomó la hoja situada justo debajo de la espiga.

## Mediciones de NDRE

Se realizaron siete vuelos desde inicio del período crítico hasta madurez fisiológica con un dron DJI Matrice 300 RTK (DJI Technology Co., Shenzhen, China) portador de una cámara multispectral MicaSense (con 5 bandas multispectrales y una banda térmica). A partir de las fotografías aéreas, se calculó el índice NDRE según la siguiente fórmula:

$$NDRE = \frac{NIR-RE}{NIR+RE} \quad (1)$$

Donde: NIR=reflectancia en la banda infrarrojo cercano y RE=reflectancia en la banda borde rojo.

## Análisis estadístico

Se estimó la integral del área bajo la curva del modelo entre el valor de NDRE y los días desde emergencia discriminando dos etapas: I) período crítico ( $NDRE_{V15-R3}$ ); II) llenado de granos ( $NDRE_{R1-R6}$ ). Los modelos fueron construidos para cada unidad experimental. Mediante correlaciones y regresiones, se evaluó la capacidad predictiva de  $NDRE_{V11-R3}$  para estimar la concentración de clorofila “a” y carotenoides, y la capacidad de  $NDRE_{R1-R6}$  para estimar el peso de granos.

## Resultados y discusión

A través del conjunto de tratamientos, se generó un amplio rango de valores de NDRE (0.31 a 0.68), de clorofila “a” (2.39 a 13.55  $\mu\text{g cm}^2$ ) y de carotenoides (0.68 a 2.19  $\mu\text{g cm}^2$ ). Esta variabilidad es importante para generar buenos modelos predictivos.

El contenido de clorofila y carotenoides en el estadio V11 fue idéntico en todos los tratamientos, destacando la similar condición hídrica en la etapa previa a la imposición del estrés. Con el avance del ciclo del cultivo, el contenido de clorofila y carotenoides disminuyó, siendo esta disminución mayor en los tratamientos  $EH_{PC}$  (Figura 1 a y b). Estudios previos demostraron que el estrés hídrico se asocia también a cambios en la absorción y el metabolismo del nitrógeno y, por ende, a variaciones en el patrón de senescencia foliar (Li *et al.*, 2018).

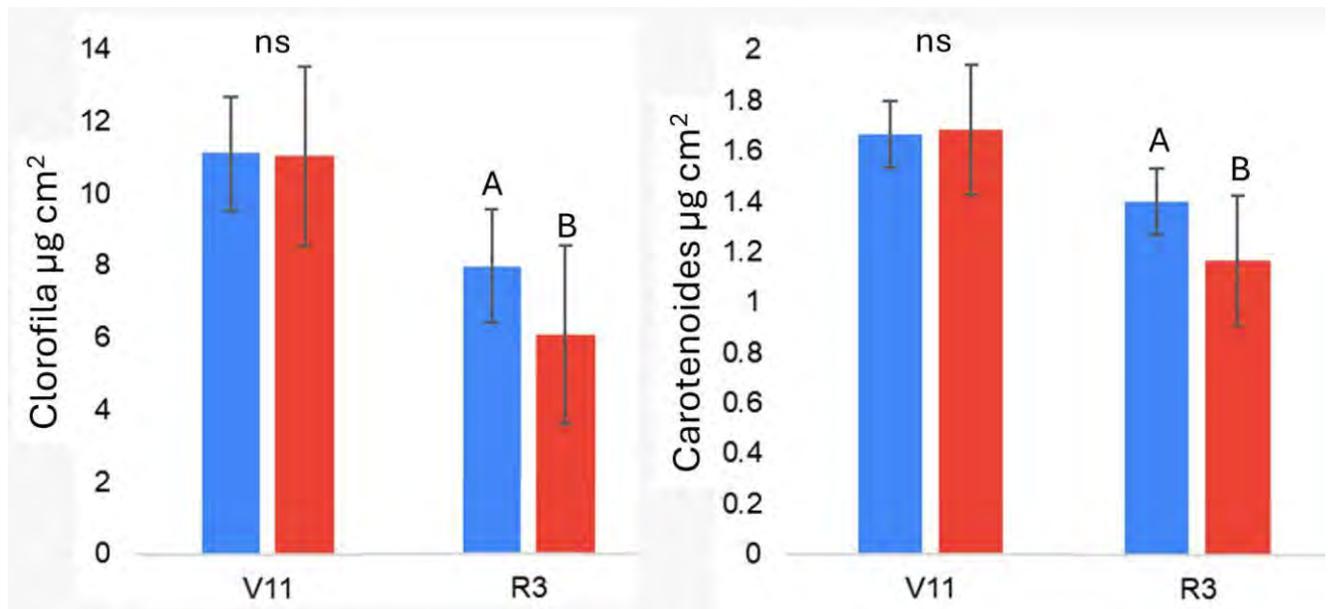


Figura 1. Contenido de clorofila (A) y carotenoides (B) para dos momentos fenológicos (V11 y R3) y dos tratamientos hídricos; I) R (azul); II) EH<sub>pc</sub> (rojo). Letras diferentes indican diferencias significativas para cada momento ( $p < 0.05$ ).

El índice de vegetación NDRE mostró buena correlación con el contenido de clorofila y carotenoides solo en el estadio R3 (Tabla 1). Sin embargo, NDRE fue un buen predictor de ambas variables cuando los dos momentos (V11 y R3) fueron considerados en conjunto (i.e. modelo único; Figura 2 A y B). NDRE explicó el 75% y 52% de la variabilidad observada en clorofila y carotenoides respectivamente, demostrando capacidad predictiva para estimar estas variables de manera remota. Al evaluar la capacidad predictiva de NDRE<sub>R1-R6</sub> para el peso de granos, se encontró que este índice pudo predecir el 60% de la variabilidad observada en dicho parámetro (rango 240 mg a 321 mg; Figura 3). Otros autores también han reportado resultados similares en maíz donde observaron que el llenado de grano es el momento óptimo para predecir el rendimiento del cultivo mediante el uso de índices multispectrales como NDRE (Yang *et al.*, 2022).

Tabla 1. Modelos y valor de R ajustado entre el índice de vegetación NDRE y el contenido de clorofila “a” o carotenoides en dos momentos fenológicos del ciclo de maíz.

Parámetro	Fenología	Modelo	R <sup>2</sup>
Clorofila	V11	$y = 19.075x - 1.0857$	R <sup>2</sup> = 0.1236
	R3	$y = 16.038x - 0.5023$	R <sup>2</sup> = 0.4857
Carotenoides	V11	$y = 2.3636x + 0.164$	R <sup>2</sup> = 0.0776
	R3	$y = 1.9648x + 0.3595$	R <sup>2</sup> = 0.2795

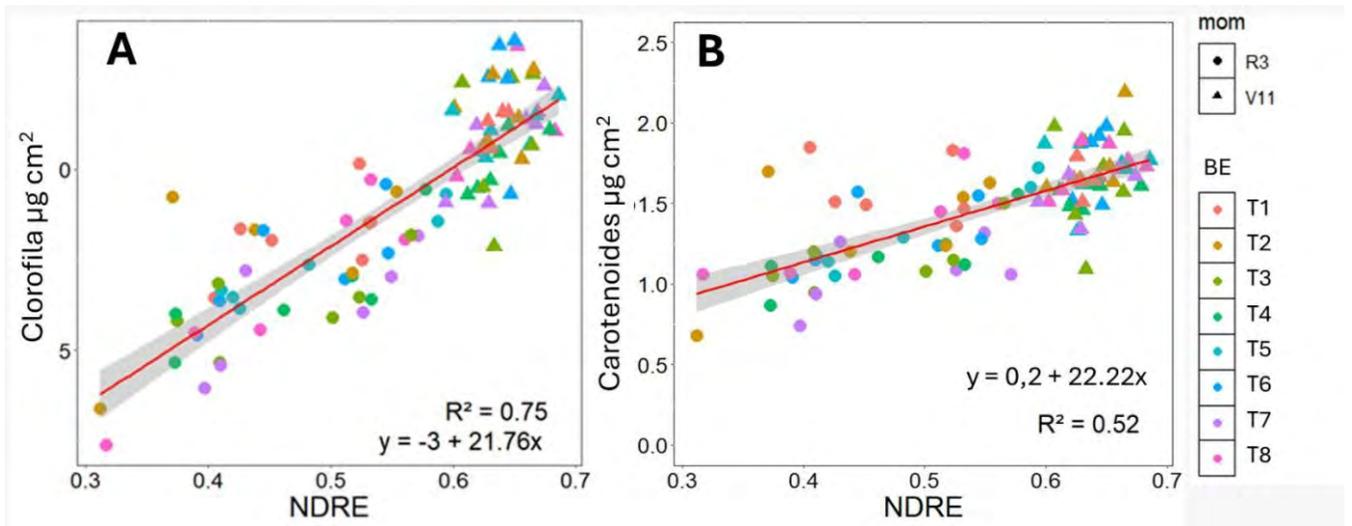


Figura 2. Modelo de respuesta de clorofila "a" (A) y carotenoides (B) en función del índice NDRE. La variación de NDRE fue obtenida a través de dos estados fenológicos (V11, triángulos y R3, círculos) y diferentes tratamientos de bioestimulantes (indicados en distinto color).

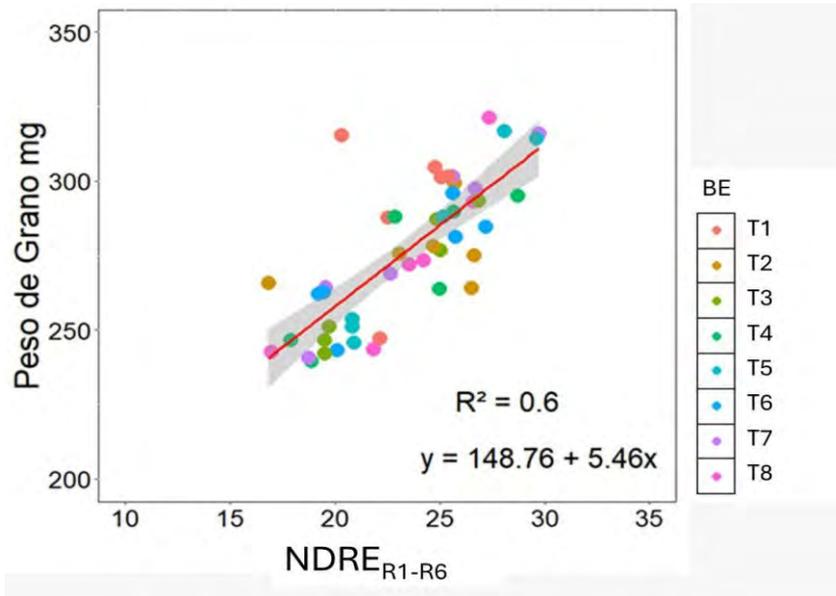


Figura 3. Modelo de respuesta de peso de grano (mg) y NDRE<sub>R1-R6</sub> para diferentes condiciones hídricas y tratamientos de bioestimulantes.

## Conclusiones

En este estudio, se evaluó la capacidad de NDRE para describir la concentración de clorofila "a" y carotenoides en hojas de un cultivo de maíz sometido a dos condiciones hídricas y diferentes tratamientos con bioestimulantes. NDRE mostró una gran capacidad predictiva para clorofila "a" y carotenoides con un  $R^2 = 0.75$  y  $0.52$  respectivamente. Además, fue posible la construcción de un único modelo para todo el período crítico demostrando su robustez en la predicción de la dinámica de dichas variables en el ciclo del cultivo. A su vez, NDRE<sub>V11-R3</sub> fue un robusto indicador para explicar la

variabilidad del peso de granos. Estos resultados son promisorios para futuros estudios de fenotipado de cultivos en su respuesta a estrés hídrico, nutricional o combinado utilizando sensoramiento remoto.

## Referencias

FAO. (2022). Food and agriculture organization of the United Nations. Statics Division. FAOSTAT

Li, M., R. Chu, Q. Yu, A.R.M.T. Islam, S. Chou, and S. Shen. (2018). Evaluating structural, chlorophyll-based and photochemical indices to detect summer maize responses to continuous water stress. *Water (Switzerland)* 10.

Mansour, E., El-Sobky, E. S. E., Abdul-Hamid, M. I., Abdallah, E., Zedan, A. M., Serag, A. M., Silvar, C., El-Hendawy, S., & Desoky, E. S. M. (2023). Enhancing drought tolerance and water productivity of diverse maize hybrids (*Zea mays*) using exogenously applied biostimulants under varying irrigation levels. *Agronomy*, 13(5):1320.

Monteiro, E., Gonçalves, B., Cortez, I., Castro, I. (2022). The role of biostimulants as alleviators of biotic and abiotic stresses in grapevine: A review. *Plants*, 11(3): 396.

Otegui, M. E., & Mercau, J. L. (2021). Fecha de siembra y rendimiento de maíz en ambientes con provisión hídrica contrastante de la región central de Argentina. *Anales de la ANAV*, 71.

Rane, J., Singh, A.K., Tiwari, M., Prasad, P.V.V. and Jagadish, S.V.K. (2022). Effective Use of Water in Crop Plants in Dryland Agriculture: Implications of Reactive Oxygen Species and Antioxidative System. *Front. Plant Sci.* 12:778270. doi: 10.3389/fpls.2021.778270.

Stirbet, A., Lazár, D., Kromdijk, J., & Govindjee. (2018). Chlorophyll a fluorescence induction: can just a one-second measurement be used to quantify abiotic stress responses?. *Photosynthetica*, 56(1), 86-104.

Wellburn, A.R. (1994). Spectral Determination of Chlorophylls a and B, as Well as Total Carotenoids, Using Various Solvents with Spectrophotometers of Different Resolution. *J. Plant Physiol.* 144: 307–313. doi:10.1016/S0176-1617(11)81192-2.

Wolfe, D.W., D.W. Henderson, T.C. Hsiao, and A. Alvino. 1988. Interactive Water and Nitrogen Effects on Senescence of Maize. II. Photosynthetic Decline and Longevity of Individual Leaves. *Agronomy Journal* 80:865-870.

Yang, B., Zhu, W., Rezaei, E. E., Li, J., Sun, Z., & Zhang, J. (2022). The optimal phenological phase of maize for yield prediction with high-frequency UAV remote sensing. *Remote Sensing*, 14(7), 1559.

## **Formación superior en agricultura de precisión Tecnatura Superior en Nuevas Tecnologías Aplicadas al Agro**

**Pablo Andrés FIGUEROA**

[pablo.figueroa@ispc.edu.ar](mailto:pablo.figueroa@ispc.edu.ar) - Instituto Superior Politecnico Cordoba (Córdoba, Córdoba Argentina).

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

### **Resumen.**

La Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro del Ministerio de Educación de Córdoba vino a solucionar la brecha existente entre el rápido avance de las tecnologías digitales y su adopción en el sector agroindustrial.

La formación responde a la necesidad de profesionalizar y modernizar el sector agropecuario mediante la incorporación de tecnologías avanzadas lo que permite optimizar la toma de decisiones, mejorar la eficiencia en la producción, y aumentar la competitividad en un mercado globalizado.

Además, ofrece una oportunidad de democratizar la educación técnica superior, facilitando el acceso a una formación innovadora y de alta demanda en el mercado laboral actual. Una formación única en el país, gratuita, libre, con título oficial de alcance nacional.

Esta carrera representa una oportunidad única para formar profesionales capacitados, perfiles que el sector precisa y exige para desarrollar soluciones tecnológicas que impulsen el crecimiento del sector agropecuario y liderar nuevos modelos de negocio basados en la gestión de grandes volúmenes de datos.

Los métodos de formación incluyen un enfoque práctico y colaborativo, con certificaciones parciales que permiten una rápida inserción laboral.

Los resultados incluyen la creación de un ecosistema educativo único e innovador que genera profesionales altamente capacitados, capaces de enfrentar los desafíos de la revolución industrial en el agro. Este programa responde a una demanda creciente de trabajadores especializados, mejorando las condiciones de producción y fomentando un avance sustancial en la industria agropecuaria.

### **Palabras clave.**

Educación superior. Transformación digital, nuevas tecnologías, sector agroindustrial, Big Data, Internet de las Cosas, IoT, Inteligencia Artificial, IA, Blockchain, competitividad agropecuaria, eficiencia en la producción, profesionalización del agro, formación técnica superior, innovación educativa, democratización de la educación, mercado laboral agropecuario, desarrollo económico en el agro.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## **Introducción**

La transformación digital, el desarrollo de nuevas tecnologías y la profesionalización del sector agroindustrial requieren hoy el manejo y la gestión de sistemas con niveles de inteligencia de datos avanzada y compleja. De la misma manera, el mercado requiere un mejor y mayor manejo de datos con la construcción y análisis de sistemas inteligentes para optimizar sus recursos, resultados y especialmente las decisiones a adoptar.

Así, las nuevas tecnologías aplicadas al agro constituyen un fenómeno de fuerte impacto relacionado con la denominada “Revolución Digital”, beneficiando tanto al sector público como privado en el aumento de la productividad, competitividad sectorial y calidad de vida de los ciudadanos. Estas nuevas tecnologías ocupan un lugar central en las organizaciones públicas y privadas promoviendo su empoderamiento y la facilitación en la toma de mejores y mayores decisiones.

Este nuevo campo profesional abarca herramientas, tecnologías, métodos y sistemas que posibilitan el manejo de grandes conjuntos de datos distribuidos, heterogéneos y complejos que no pueden analizarse con las herramientas y métodos tradicionales de procesamiento y administración de bases de datos.

La conectividad, la generación de grandes volúmenes de datos en tiempo real y su análisis configuran e influyen los nuevos modelos de producción agropecuaria que precisa el sector agropecuario en la actualidad en el marco de la evolución y profesionalización del sector.

El crecimiento económico es impulsado por la digitalización del mundo físico: la revolución tecnológica que estamos viviendo - conocida por muchos como la cuarta revolución industrial- está cambiando las organizaciones tanto o más que el internet de consumo ha cambiado los medios, las comunicaciones, el entretenimiento y la publicidad en la última década.

Las corrientes de bienes y servicios, activos financieros, personas, información y comunicación se han incrementado fuertemente en los últimos años como resultado de la difusión masiva de las tecnologías digitales e Internet. Estas tecnologías son plataformas de actividades como la comunicación, la información, el entretenimiento, el comercio, la prestación de servicios de educación, salud y gobierno, y más recientemente de sistemas complejos de producción. Este avance de la digitalización desencadena una economía mundial cada vez más conectada, convirtiendo a la economía global en una economía digital.

Se destacan dos elementos cruciales: la necesidad de progresar hacia un mercado digital regional que permita adquirir escala y la de desarrollar economías de red para competir en un mundo de plataformas globales.

Las implicancias sociales y económicas de la utilización de estos conocimientos y tecnologías en la Revolución Digital son enormes, y la demanda de trabajadores en esta área crece exponencialmente generando puestos de trabajo.

Las nuevas tecnologías fusionan la automatización con grandes volúmenes de datos que posibilitan la mejora cualitativa en la toma de decisiones por los diversos actores del sector agropecuario de la provincia y en la región.

Por lo tanto, se hace necesario acelerar de manera disruptiva la incorporación de las nuevas tecnologías en el segmento agroindustrial, acortando la distancia que existe entre estas y las empresas y organizaciones de todos los sectores mediante su incorporación eficiente generando un ecosistema que produzca y gestione la innovación.

El **Técnico Superior en Nuevas Tecnologías Aplicadas al Agro** estará capacitado para realizar desarrollos de soluciones tecnológicas que aceleren significativamente el avance de los diferentes sectores productivos de la industria del Agro. Además, estará calificado para liderar nuevos modelos de negocios que involucren el análisis de grandes volúmenes de datos y le permitan tomar las mejores decisiones.

A partir del uso de Big Data tendrá la capacidad de procesar, analizar y/o interpretar cualquier tipo de registros digitales proveniente de diferentes fuentes.

El Técnico Superior podrá participar activamente en el desarrollo colaborativo de proyectos de innovación digital, garantizando la fiabilidad de los datos registrados y los productos trazados con blockchain, aumentando los niveles de confianza de los productores que intervienen en esa cadena.

El Técnico Superior en Nuevas Tecnologías Aplicadas al Agro diseña y desarrolla propuestas de incorporación de herramientas digitales que le permitan el uso de modelos predictivos para la mejora en la toma de decisiones, mediante el manejo de aplicaciones de Inteligencia Artificial (IA) y contribuyendo a la obtención de información detallada en tiempo real a través de la incorporación de Internet de las Cosas (IoT) permitiendo almacenar grandes volúmenes de datos y, mediante la automatización, agilizar procesos productivos. Es un profesional capacitado para afrontar las necesidades generadas para la industria del agro.

La Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro propone una formación que brinde y proporcione las herramientas para realizar desarrollos de soluciones tecnológicas que aceleren significativamente el avance de los diferentes sectores productivos de la industria del Agro.

Esta formación posibilitará el liderazgo de nuevos modelos de negocios que involucren el análisis de grandes volúmenes de datos y le permitan tomar mejores decisiones. A partir del uso de Big Data, el egresado tendrá la capacidad de procesar cualquier tipo de registros digitales proveniente de diferentes fuentes.

El Técnico Superior podrá participar activamente en el desarrollo colaborativo de proyectos de innovación digital, garantizando la fiabilidad de los datos registrados y los productos trazados con blockchain, aumentando los niveles de confianza de los productores que intervienen en esa cadena.

El Técnico Superior en Nuevas Tecnologías Aplicadas al Agro diseña y desarrolla propuestas de incorporación de herramientas digitales que le permitan el uso de modelos predictivos para la mejora en la toma de decisiones, mediante el manejo de aplicaciones de Inteligencia Artificial (IA) y contribuyendo a la obtención de información detallada en tiempo real a través de la incorporación de Internet de las Cosas (IoT) permitiendo almacenar grandes volúmenes de datos y, mediante la automatización, agilizar procesos productivos. Es un profesional capacitado para afrontar las necesidades generadas para la industria del agro.

El Técnico Superior en Nuevas Tecnologías Aplicadas al Agro estará capacitado para trabajar activamente en el diseño y gestión de procesos innovadores en donde se apliquen métodos y tecnologías que aceleren el avance y desarrollo de los sectores productivos de la industria del Agro. Asimismo, también reunirá las capacidades para analizar mediante la utilización de datos la toma de decisiones en la gestión, entre otras habilidades que el sector agropecuario precisa y requiere en su profesionalización.

Régimen de cursada y caga horaria

- Duración de la carrera: 2 y ½ (dos años y medio)

- Modalidad de cursado: Virtual con prácticas presenciales
- Carga horaria total: 1622 horas reloj.
- Régimen de cursado: Anual Cuatrimestral

El desarrollo de la industria y las tecnologías vinculadas al Agro es uno de las más fuertes tanto de la provincia de Córdoba, como también en el país y de la región latinoamericana, ya que es la columna vertebral en todas las economías vigentes.

En el marco de las Leyes Nros. 26206 de Educación Nacional, 9870 de Educación Provincial, 24521 de Educación Superior y 26058 de Educación Técnico Profesional, como así también en los lineamientos referenciales acordados por las Resoluciones del Consejo Federal de Educación Nros. 229/14 y 295/16, el **Instituto Superior Politécnico Córdoba** es la primera institución de gestión estatal en Argentina en proponer un modelo innovador en materia pedagógica, metodológica, tecnológica y de vinculación con el objetivo de formar profesionales técnicos capaces de adaptarse a los cambios del mundo productivo, con perfiles y habilidades acordes al nuevo paradigma tecnológico.

En este contexto, **surgió la necesidad de creación de una carrera** que sea de específica vinculación entre lo tecnológico y el perfeccionamiento de una industria que nunca deja de crecer, mejorar, especializar y, sobre todo, adaptarse a las necesidades actuales que demanda el mercado en todo el mundo. Mediante la Resolución Ministerial N° 175/2022 del Ministerio de Educación de la provincia de Córdoba se aprobó para su aplicación en el Instituto Superior Politécnico Córdoba, el Plan de Estudios de la Carrera superior “Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro”.

El desarrollo de la industria y las tecnologías vinculadas al Agro es uno de las más fuertes tanto de la provincia de Córdoba, como también en el país y de la región latinoamericana, ya que es la columna vertebral en todas las economías vigentes.

Mediante la **Resolución Ministerial N° 175/2022** del Ministerio de Educación de la provincia de Córdoba se aprobó para su aplicación en el Instituto Superior Politécnico Córdoba, el Plan de Estudios de la Carrera superior “Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro”.

Mediante la Resolución Ministerial Resolución N° 397 - Letra D se aprobó la “Certificación de formación profesional Operador de agrotecnologías” del Ministerio de Educación del Gobierno de la Provincia de Córdoba, única formación en su tipo a nivel país, también oficial, de alcance nacional y gratuita.

Esta propuesta se enmarca en el ámbito del Instituto Superior Politécnico Córdoba del Ministerio de Educación del Gobierno de la Provincia de Córdoba. Su principal objetivo es formar profesionales técnicos capaces de adaptarse a los cambios del mundo productivo, con perfiles y habilidades pertinentes a lo que demande el sector productivo.

Esta institución es la primera institución de gestión estatal en Argentina en proponer un modelo innovador en materia pedagógica, metodológica y tecnológica

En este contexto, surgió la necesidad de creación de una certificación de nivel superior, específica e inédita en el país, que sea de contenidos y perfil con directa vinculación entre lo tecnológico y el agro para adaptarse a las necesidades actuales que demanda el mercado en todo el mundo.

Propone una formación que brinde y proporcione las herramientas para realizar desarrollos de soluciones tecnológicas que aceleren significativamente el avance de los diferentes sectores

productivos de la industria del Agro.

El desarrollo de la industria y las tecnologías vinculadas al Agro es uno de las más fuertes tanto de la provincia de Córdoba, como también en el país y de la región latinoamericana, ya que es la columna vertebral en todas las economías vigentes.

El cursado, combina clases sincrónicas y asincrónicas, que permite al estudiante realizar una trayectoria formativa flexible desde cualquier lugar de la Provincia. De esta manera, se interioriza al estudiante respecto a necesidades actuales a responder aplicando sus conocimientos adquiridos.

Es una formación profesional técnica, específica, pública, virtual, totalmente gratuita con certificación oficial de alcance nacional sin antecedentes ni precedentes en el país y en la región en la vinculación de la tecnología y el progreso del sector agropecuario.

Esta es sin duda, una innovación que contribuye favorablemente a la producción y a la productividad agropecuaria, a la seguridad y bienestar del productor rural y a la preservación de la vida y del medio ambiente de la República Argentina.

**Es una propuesta original ya que no existe una formación académica superior de estas particulares características, gratuita, de alcance nacional, virtual y con título oficial de estas específicas particularidades, estrechamente vinculada a la innovación en la producción y desarrollo del sector agropecuario que hacen que esta tecnicatura superior sea única en el país. Además de brindarse un título superior de estas características tan particulares convirtiéndose en una formación sin antecedentes en el país**

Cabe precisar que la construcción de este diseño curricular no se hizo en la soledad de un escritorio de un Ministerio sino, previo a su elaboración, se tomó contacto con distintas entidades y organizaciones públicas y privadas que aportaron sus conocimientos, opiniones y ayudaron a con crear esta propuesta de innovación, en este caso para la innovación agropecuario en lo que hace a la educación técnica y a la profesionalización de los recursos humanos.

Algunas de estas entidades que han dado el aval a esta formación son las siguientes:

- CONCI S.A.
- Centro Regional Córdoba del INTA
- Dirección de suelos del Ministerio de Agricultura y Ganadería de Córdoba
- Registro Nacional de trabajadores rurales y empleadores. RENATRE
- Estación Experimental INTA Marcos Juárez
- Carnes Validadas S.A.S.
- Cooperativa agrícola ganadera Freyre Ltda.

## Ver más



**Conocé el ISPC Instituto Superior Politécnico Córdoba**

<https://www.youtube.com/watch?v=i40akBlwFoM>



**Video institucional de la Tecnicatura Superior en nuevas tecnologías aplicadas al agro**

<https://www.youtube.com/watch?v=o6smZWO2Fm0>

## Conclusiones

La Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro surge como una solución integral a la necesidad de profesionalizar y modernizar el sector agropecuario en Argentina. A través de la incorporación de tecnologías avanzadas como Big Data, Internet de las Cosas (IoT), Inteligencia Artificial (IA) y Blockchain, esta carrera no solo optimiza la toma de decisiones y mejora la eficiencia en la producción, sino que también impulsa la competitividad en un mercado globalizado.

Además, la tecnicatura ofrece una oportunidad única para democratizar la educación técnica superior, al ser gratuita, de alcance nacional y con un enfoque innovador. Este programa permite la rápida inserción laboral de sus graduados, gracias a un enfoque práctico y colaborativo que incluye certificaciones parciales. Esto facilita el acceso a una formación de alta demanda en el mercado laboral actual, adaptándose a las necesidades del sector agropecuario.

Finalmente, esta formación no solo responde a la creciente demanda de trabajadores especializados en el sector, sino que también contribuye al desarrollo económico regional y nacional. Al formar profesionales capacitados para liderar nuevos modelos de negocio y gestionar grandes volúmenes de datos, la tecnicatura fortalece la competitividad y promueve un avance sustancial en la industria agropecuaria, convirtiéndose en un pilar fundamental para el progreso tecnológico del país.

La Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro surge como una respuesta integral y estratégica a las necesidades de modernización y profesionalización del sector agropecuario en Argentina. Este programa educativo se ha diseñado para abordar las brechas existentes entre el rápido avance de las tecnologías digitales y su adopción en el sector agroindustrial, contribuyendo significativamente a la optimización de la producción y la toma de decisiones en un contexto globalizado.

### **1. Incorporación de Tecnologías Avanzadas:**

El programa integra tecnologías avanzadas como Big Data, Internet de las Cosas (IoT), Inteligencia Artificial (IA) y Blockchain. Estas herramientas no solo permiten una gestión eficiente de grandes volúmenes de datos, sino que también facilitan la implementación de modelos predictivos y soluciones innovadoras en la producción agropecuaria. La capacidad de utilizar estas tecnologías proporciona una ventaja competitiva en un mercado globalizado, donde la eficiencia y la innovación son cruciales para el éxito.

## 2. Democratización de la Educación Técnica Superior:

La Tecnicatura ofrece una formación gratuita, de alcance nacional y con un enfoque innovador, permitiendo la democratización del acceso a la educación técnica superior. Su modalidad práctica y colaborativa, junto con certificaciones parciales, asegura una rápida inserción laboral de los graduados. Este enfoque facilita el acceso a una formación de alta demanda en el mercado laboral actual, adaptándose a las necesidades emergentes del sector agropecuario.

## 3. Respuesta a la Demanda de Especialización:

El programa se alinea con la creciente demanda de trabajadores especializados en tecnologías aplicadas al agro. Al formar profesionales capacitados para liderar nuevos modelos de negocio y gestionar grandes volúmenes de datos, la Tecnicatura contribuye al desarrollo económico regional y nacional. Esta formación no solo fortalece la competitividad del sector agropecuario, sino que también promueve un avance sustancial en la industria, alineándose con las tendencias globales de digitalización y automatización.

## 4. Relevancia para el Congreso Internacional de Agricultura de Precisión:

La Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro representa un pilar fundamental para el progreso tecnológico en el sector agropecuario. Su enfoque innovador y la integración de tecnologías avanzadas son temas centrales en el 20º Congreso Internacional de Agricultura de Precisión. La participación en este congreso permitirá destacar cómo el programa contribuye a la capacitación y actualización técnica de los actores del sector, promoviendo el intercambio de conocimientos y experiencias sobre las últimas tendencias en tecnologías de agricultura de precisión.

Por último, la Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro es una solución educativa integral que no solo moderniza el sector agropecuario, sino que también impulsa la competitividad y el desarrollo económico, alineándose perfectamente con los objetivos del 20º Congreso Internacional de Agricultura de Precisión.

## Referencias

- Instituto Superior Politécnico Córdoba. (n.d.). Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro. <https://www.ispc.edu.ar/tecnicatura-superior-en-nuevas-tecnologias-aplicadas-al-agro/>
- Ministerio de Educación de Córdoba. (2022, 15 de marzo). Resolución Ministerial 175/2022: Aprobación del diseño curricular de la Tecnicatura Superior en Nuevas Tecnologías Aplicadas al Agro. Boletín Oficial de la Provincia de Córdoba, Año CIX, Tomo DCLXXXVII, N° 55.
- Ministerio de Educación de la Nación. (2023, 4 de julio). Resolución 1385/2023: Validez nacional del título de Técnico/a Superior en Nuevas Tecnologías Aplicadas al Agro, Provincia de Córdoba. RM EX-2022-98099563-APN-DVNTYE#ME.
- Ministerio de Educación de Córdoba. (2023, 11 de agosto). Resolución N° 397 - Letra D: Aprobación del Diseño Curricular del Trayecto de Formación Profesional "Operador de Agrotecnologías" para implementación en 2023 en Institutos Superiores Técnicos dependientes de la Dirección General de Educación Técnica y Formación Profesional. Boletín Oficial de la Provincia de Córdoba, Año CX, Tomo DCCIV, N° 149.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Calidad de siembra de maíz (*Zea maíz L*) y su efecto en el rendimiento, con y sin órgano afirmador de semillas

**Fernando M Scaramuzza; Diego D Villarroel; Silvia M Olivo**

INTA EEA Manfredi, Ruta 9 Km 636, Manfredi, Córdoba, Argentina.

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** *El contacto entre la semilla y el suelo, favorecerá la capilaridad ayudando a la germinación de la semilla y enraizamiento de la plántula. Existen dos sistemas de contactadores de semillas, las ruedas y las colitas de castor o lengüetas. Sin embargo, en el medio productivo muchas veces estos son retirados. Por lo tanto, el objetivo del ensayo fue evaluar la calidad de siembra de maíz y su efecto en el rendimiento, con y sin órgano afirmador de semillas, para un maíz de siembra tardía. La siembra se realizó el 23 de diciembre de 2022 a una velocidad de labor de 7 km/h, 5 cm de profundidad y una densidad de siembra de 3,9 semillas/m. Se utilizó un DBCA con tres repeticiones; se evaluaron dos configuraciones del tren de siembra, Con Colita (CC) y Sin Colita (SC) pisa granos. Se determinó la distancia entre plantas y su coeficiente de variación. Según norma ISO 7256/1, cada individuo se clasificó de acuerdo a si está separado por distancias consideradas como Aceptable (A), Dobles (D) o Fallas (F) e Índice de Precisión (P). Se determinó el Rendimiento (t/ha). La calidad de siembra expresada como Aceptables (>90%), fue similar entre tratamientos, aunque con diferencia en rendimiento de 900kg/ha a favor de CC. En base a bibliografía la diferencia hallada en rendimiento podría ser explicada por la velocidad de emergencia que presentaron las plántulas cuando se utilizó la colita afirmadora de grano.*

**Palabras clave.** *Calidad de siembra, órgano contactador de semilla, maíz*

## Introducción

El éxito de una buena siembra será aquella donde la diferencia entre la cantidad de plantas posibles de obtener y las emergidas es mínima, la separación (plano horizontal) y profundidad (plano vertical) entre ellas es uniforme y el tiempo transcurrido para emerger, el mínimo (Maroni y Gargicevich 2006).

Sumado a lo anterior, la calidad de siembra también se verá influenciada con el contacto que se logre entre la semilla y el suelo, favoreciendo que la capilaridad por debajo de la semilla ayude a la germinación y al enraizamiento de la plántula. Sin embargo, no constituye un problema de fácil solución ya que excesos de compactación sobre la semilla pueden provocar el fracaso de la siembra sobre todo en suelos con problemas de estructura.

Los dos tipos de sistemas de contactado de semilla más conocidos, que existen en el mercado son: las ruedas y las colitas de castor o lengüetas (Ferrari y Ferrari, 2011). Estos autores sugieren que, frente a situaciones de baja humedad superficial de suelo, la rueda tiene el mejor desempeño, mientras que la colita de castor lo es en situaciones con mayor humedad.

En maíz, De Simone y Godoy, (2009) sostienen que el uso de órganos afirmadores mejora la distribución de las semillas y las plantas en la línea de siembra, favoreciendo la implantación a la profundidad deseada con todos los beneficios agronómicos que esto implica. Staggenborg et al., (2004), encontraron que, en maíz, el uso de lengüeta plástica presentó un menor desvío estándar entre semillas; un comportamiento similar fue hallado por De Simone y Godoy, (2009) en poroto. Estos autores muestran que cuando se usa lengüeta plástica o cola de castor y se aumenta la velocidad no se disminuye la calidad de la distribución, asegurando el nacimiento y sobrevivencia de las plántulas en condiciones de suelo muy húmedo. Sin embargo, cuando no se usa ningún órgano que contacte la semilla con el suelo y se incrementa la velocidad de avance, la calidad de siembra cae por un incremento en las duplicaciones.

De modo contrario Castagner et al., (2019), durante dos campañas, evaluando la calidad de siembra de maíz, con y sin órgano afirmador de semillas encontraron que, en un suelo de textura arenosa fina, cuando la siembra se llevó a cabo con afirmador de semilla tipo cola de castor, presentó un 10% más de coeficiente de variación respecto a la siembra sin órgano afirmador. Si bien estos resultados son diferentes a lo reportado por bibliografía, en el medio productivo se argumenta este mismo comportamiento.

Por lo tanto, el objetivo del ensayo fue evaluar la calidad de siembra de maíz y su efecto en el rendimiento, con y sin órgano afirmador de semillas, para un maíz de siembra tardía.

## Materiales y Métodos

La siembra del ensayo se realizó el 23 de diciembre de 2022. Se utilizó la sembradora de siembra directa Agrometal TX Mega IOM de 12 líneas, a 52,5 cm de distancia entre surcos, equipada con un dosificador neumático DX PRO de accionamiento hidráulico, con corte línea por línea Tekmatic y actuadores neumáticos Twin Force. Se utilizó un tractor NH T7 215 de 191 CV equipado con monitor Intelview IV, piloto automático y señal correctora Center Point. El híbrido de maíz utilizado fue P2089 VYHR y la operación de siembra se realizó a 7 km/h, con una profundidad de siembra propuesta de 5 cm y una densidad de siembra de 3,9 semillas/m (74.880 semillas/ha). El cultivo se mantuvo fertilizado.

## Diseño experimental y análisis de datos

Se utilizó un diseño en bloques completos aleatorizados; se evaluaron dos configuraciones del tren de siembra, Con Colita (CC) y Sin Colita (SC) pisa granos y con tres repeticiones, arrojando un total de seis tratamientos. Las variables evaluadas se analizaron estadísticamente con el software Infostat y las comparaciones múltiples post hoc fueron ajustadas, cuando fue necesario, mediante el método HSD de LSD Fisher. Fijándose un nivel de significancia de  $\alpha = 0,05$ .

### Distancia Entre Plantas

Se desarrolló siguiendo el protocolo establecido por Norma ISO 7256/1. En cada uno de los tratamientos evaluados, se procedió a cuantificar el número de semillas en 15 metros lineales de surco. Este procedimiento se realizó tres veces por tratamiento y repetición.

### Determinaciones

#### Variables Explicativas por individuo

Distancia Entre Plantas (DEP): En función de las distancias que la separan de sus dos vecinas en la línea de siembra y de los criterios de la norma ISO 7256/1, cada individuo se clasificó de acuerdo a si está separado por distancias consideradas como Aceptable (A), o Dobles (D) o Fallas (F).

#### Variables Explicativas por unidad de área

Coefficiente de Variación de la separación entre plantas (CV): es igual al desvío estándar de esa muestra dividido por la media y multiplicado por 100. En función a la norma ISO 7256/1 se calculó el Índice de semillas aceptablemente sembradas (A): esta medida de uniformidad en la distribución de semillas considera como A a toda aquella semilla ubicada en el surco a una distancia comprendida entre  $0,5 X_{ref}$  y  $1,5 X_{ref}$ , siendo la distancia de referencia ( $X_{ref}$ ) la DEP teórica entre semillas. Índice de Duplicaciones (D): es el porcentaje de semillas ubicadas a distancias menores a las  $0,5 X_{ref}$ . Índice de Fallas (F): corresponde al porcentaje de semillas ubicadas a distancias superiores a las  $1,5 X_{ref}$ . Índice de precisión (P): corresponde al CV de las semillas aceptablemente sembradas.

### Rendimiento

La cosecha fue realizada el 8 de agosto de 2023 (Humedad de grano: 14%). Para ello se utilizó una cosechadora Don Roque 125 equipada con monitor de rendimiento Ag Leader EDGE. Los datos del mapa de rendimiento se procesaron con el Software SMS y luego se exportaron para ser analizados a través de planillas de cálculos Excel. El filtrado de los datos del mapa de rendimiento se realizó a través de la metodología propuesta por INTA (Albarenque & Velez, 2011) para su posterior análisis estadístico a través de Software Infostat.

## Resultados y Discusión

### Variables explicativas por individuo. Distancia Entre Plantas

Según la densidad de siembra utilizada (74.880 mil semillas/ha), la DEP teórica es de 25,6 cm y como se observa en el Gráfico 1 los tratamientos presentaron una DEP superior a la teórica promedio de 27,65 cm sin diferencias significativas entre tratamientos ( $p > 0,05$ ).

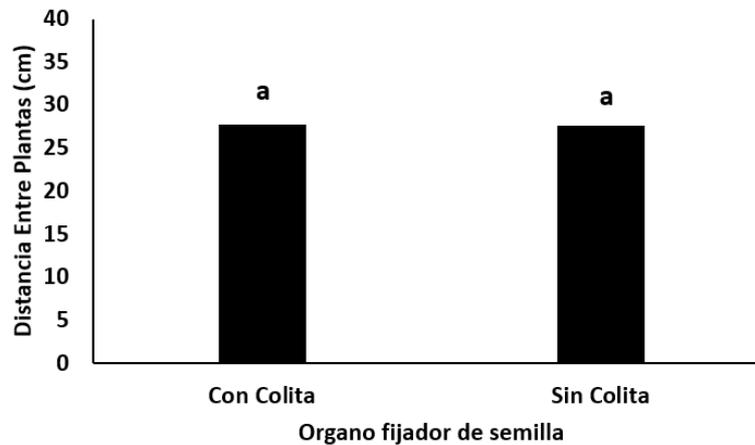


Grafico 1: Distancia entre plantas (DEP) en cm, para dos configuraciones de órgano fijador de semilla (Con Colita y Sin Colita); a una densidad de siembra de 74.880 semillas/ha y velocidad de siembra de 7 km/h. Letras distintas denotan diferencias significativas entre velocidades de siembra ( $p < 0,05$ ). Ensayo realizado en la EEA INTA Manfredi, campaña 22/23.

## Variables Explicativas por unidad de área.

### Coefficiente de Variación

En el Grafico 1, se observa el CV para dos configuraciones de órgano fijador de semilla, con valores promedios de 31 y 26,4 % para el tratamiento CC y SC respectivamente. Si bien, en términos absolutos el CV del tratamiento CC fue 17% superior al SC, cuando se analiza estadísticamente, no se detectan diferencias significativas entre tratamientos ( $p < 0,05$ ).

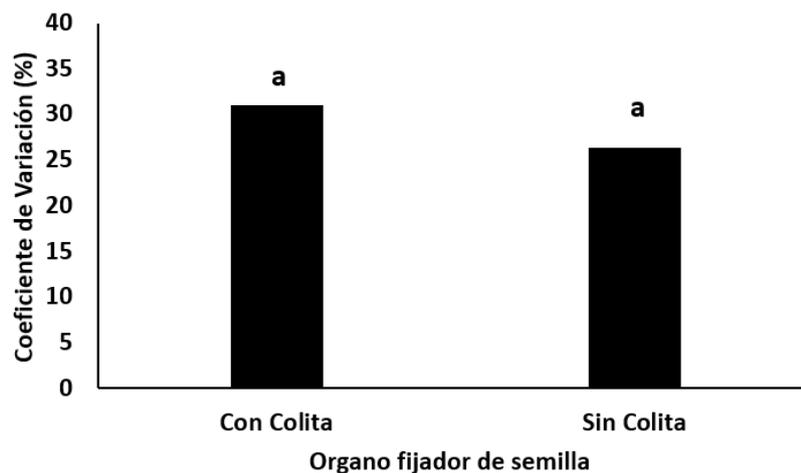


Grafico 2: Coeficiente de Variación (CV) en %, para dos configuraciones de órgano fijador de semilla (Con Colita y Sin Colita); a una densidad de siembra de 74.880 semillas/ha y velocidad de siembra de 7 km/h. Letras distintas denotan diferencias significativas entre velocidades de siembra ( $p < 0,05$ ). Ensayo realizado en la EEA INTA Manfredi, campaña 22/23.

## Índice de Semillas sembradas Aceptables, Fallas y Dobles

En las condiciones evaluadas, la calidad de siembra expresada como aceptables (Grafico 2a) presentó muy buen comportamiento y fue similar entre tratamientos, arrojando valores promedios de 93,18% cuando la siembra se realizó CC y 92,44% cuando no se utilizó el órgano fijador de semilla, es decir SC. De acuerdo al análisis realizado para calidad de siembra (en función del % de

aceptables). Se calculó para cada velocidad de avance la proporción de dobles y fallas (Grafico 2b). La calidad de siembra alcanzada, presentó en promedio para ambos tratamientos mayor proporción de fallas totales que de dobles

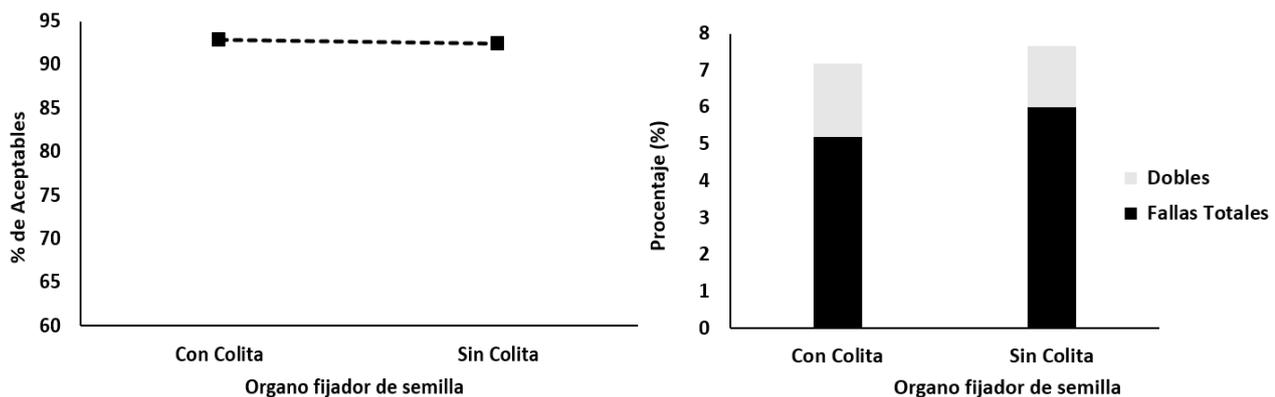


Grafico 2: (a) Calidad de siembra expresada en porcentaje de aceptables (%) y (b) porcentaje fallas totales y doble de la media de la distribución de plantas emergidas para dos configuraciones de órgano fijador. CC: Con Colita y SC: Sin Colita. a una densidad de siembra de 74.880 semillas/ha y velocidad de siembra de 7 km/h. Ensayo realizado en la EEA INTA Manfredi, campaña 22/23.

## Índice de precisión

En el Grafico 3 se observa índice de precisión que corresponde al CV de las semillas aceptablemente sembradas (A), el mismo fue similar entre tratamientos y presentó valores promedios de 16,6%.

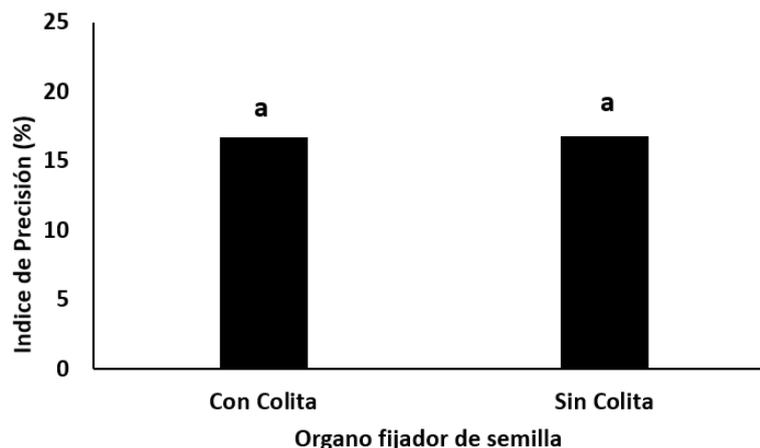


Gráfico 3: Índice de Precisión %, para dos configuraciones de órgano fijador de semilla (Con Colita y Sin Colita); a una densidad de siembra de 74.880 semillas/ha y velocidad de siembra de 7 km/h. Letras distintas denotan diferencias significativas entre velocidades de siembra ( $p < 0,05$ ). Ensayo realizado en la EEA INTA Manfredi, campaña 22/23

## Respuesta al rendimiento

El rendimiento presentó valores promedios de 10,5 y 9,6 t/ha para el tratamiento CC y SC respectivamente (Grafico 4), mostrando una diferencia significativa ( $p < 0,05$ ) de 900 kg/ha cuando se utilizó la colita como órgano para fijar la semilla en el fondo del surco.

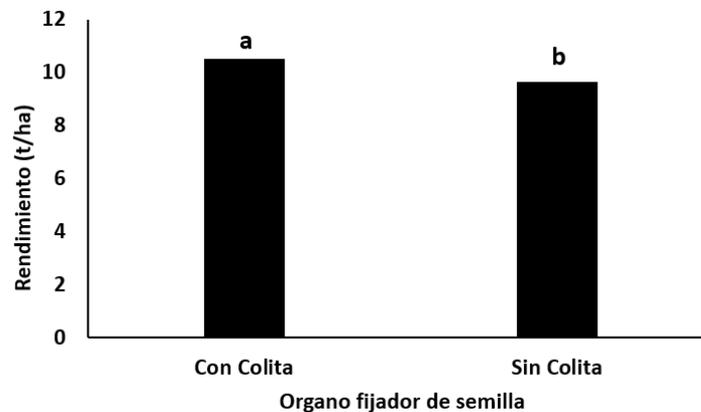


Grafico 4: Rendimiento del cultivo de maíz (t/ha), para dos configuraciones de órgano fijador de semilla (Con Colita y Sin Colita); a una densidad de siembra de 74.880 semillas/ha y velocidad de siembra de 7 km/h. Letras distintas denotan diferencias significativas entre velocidades de siembra ( $p < 0,05$ ). Ensayo realizado en la EEA INTA Manfredi, campaña 22/23.

## Conclusión

De acuerdo a la bibliografía consultada, la calidad de siembra también se verá influenciada por el contacto que se logre entre la semilla y el suelo, favoreciendo la capilaridad por debajo de la ubicación de la semilla, ayudando así a la germinación y al enraizamiento de la plántula. Es decir que la utilización del órgano fijador de semillas favorece la calidad de siembra y el tipo de afirmador a utilizar está condicionado a la textura y contenido de humedad que presente el suelo en el momento de la siembra. El presente ensayo se llevó a cabo en un suelo de textura franco limosa y con el contenido de humedad adecuado para efectuar la siembra.

La calidad de siembra expresada como porcentajes de Aceptables, fue similar entre tratamientos con valores superiores al 90% y la misma puede explicarse por una mayor proporción de fallas (6%) que de dobles (1,7%). Sin embargo, cuando se analizó el rendimiento se alcanzó una diferencia de 900 kg/ha cuando en la siembra se utilizó el órgano fijador de semillas.

Por último y conforme a lo citado por otros autores, el uso de órganos fijadores de semillas tendría un impacto positivo en la velocidad de emergencia de las plántulas, permitiendo poner en contacto estrecho a la semilla y el suelo. Por lo tanto, a pesar de no haberse cuantificado esto último, la diferencia hallada en rendimiento podría ser explicada por la velocidad de emergencia que presentaron las plántulas cuando se utilizó la colita afirmadora de grano.

## Agradecimientos

El presente trabajo pudo ser realizado gracias al aporte de la empresa Agrometal, New Holland, Precision Planting y la Cooperadora de la EEA INTA Manfredi. Se agradece la colaboración del apoyo técnico de Víctor Oscar y Claudio Ovando.

## Referencias

- Abbate, P.E.; Abbate, L.I. Abbate, N.F.; Scaramuzza, F.M.; Olivo, S; Villarroel, D. 2023. Evaluación de la calidad de siembra de sembradoras de granos individuales (sembradoras como las de maíz) Pagina virtual. Disponible en <https://cultivaresarg entinos.com/ maiz/semb radora/>
- Del Castagner, R. A. J.; Bonacci, A.; Cáceres, M., & Garetto, E. 2019. Calidad de siembra en el cultivo de maíz (zea mays. L) según velocidad de siembra y órgano afirmador de semillas. *Ab Intus*, (3), 77-80.
- De Simone, M.E.; Godoy, A.2008. Calidad de implantación de maíz y poroto en relación al diseño y regulación de la sembradora. INTA □ PRECOP.
- Ferrari, H.; Ferrari, C. 2011. Manual de equipos para siembra de granos. INTA-PRECOPII. Ediciones INTA.
- International standard for organization. ISO 7256/1. Sowing equipment - Test methods - Part 1: Single seed drills (precision drills). Suiza: International Standard for Organization. 1984.
- Maroni J.; Gargicevich A. 2006. Consideraciones para lograr una siembra de calidad: El caso Maíz. Programa de capacitación técnica y transferencia de Tecnología Argentina □ Venezuela Modulo de Capacitación Siembra y Sembradoras Pergamino.
- Staggenborg, S.; Taylor, R.; Maddux, L. 2004. Effect of planter speed and seed firmers on corn stand establishment. *Appl. Eng. Agric.* 20, 573.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Modelo de fertilización nitrogenada en trigo diseñado para apoyar el manejo sitio-específico del cultivo en el centro oeste bonaerense

Juan Martín Rompani<sup>a</sup>, Jorge Luis Mercou<sup>bc</sup> y Agustín Pagani<sup>a</sup>

<sup>a</sup>Clarion, 9 de Julio, Buenos Aires, Argentina; <sup>b</sup>INTA, AER San Luis, Argentina; <sup>c</sup>IMASL, Universidad Nacional de San Luis y CONICET, San Luis, Argentina

Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina

### Resumen.

*El objetivo de este trabajo fue i) caracterizar la variabilidad espacial y temporal del rendimiento, la respuesta óptima económica a nitrógeno (RespN), la dosis óptima económica de N (DOE) y la eficiencia agronómica del uso de N del fertilizante (EUNf) para el cultivo de trigo en el centro oeste bonaerense y ii) generar un modelo predictivo de la DOE para apoyar el manejo de la fertilización nitrogenada. Se realizaron 63 ensayos en microparcelas a campo, durante 7 campañas entre 2013 y 2022. Se relevaron 21 variables explicativas estáticas y dinámicas, se cuantificó la variabilidad espacio-temporal de las variables respuesta y se desarrollaron modelos para explicar la DOE. Las variables clásicas de diagnóstico de N, como el N-nitrato y el Nan, no fueron suficientes para explicar la DOE utilizadas de manera independiente. La predicción más robusta de la DOE al momento de la fertilización resultó de la combinación de variables estáticas y dinámicas mediante un modelo no paramétrico de árbol de decisión, que presentó un ajuste del 51% de la variabilidad, con un RMSE de 49 kg N ha<sup>-1</sup> y RRMSE de 0,49. La elevación relativa del terreno (Rel\_Elev) fue el factor individual de mayor relevancia para explicar DOE.*

### Palabras clave.

*Trigo, nitrógeno, manejo sitio-específico, dosis óptima económica, respuesta a nitrógeno, variabilidad, espacial, temporal, árboles de decisión.*

## Introducción

La brecha de rendimiento (van Ittersum et al., 2013) es mayor al 40% para el trigo argentino y se podría reducir a la mitad (Aramburu Merlos et al. 2015). La limitación nutricional es una de las principales causas de las brechas de rendimiento (Monzón y Grassini, en preparación) siendo el nitrógeno (N) el nutriente más importante para el manejo del cultivo (Havlin et al., 2005; Sinclair y Rufty, 2012). El exceso de N, representa una pérdida económica, porque no genera respuesta adicional en el rendimiento y es una fuente potencial de contaminación de los recursos agua y aire (Rockström et al. 2020), mientras que el déficit de N, limita el rendimiento por disminuir la fotosíntesis y la partición de biomasa hacia estructuras reproductivas (Abbate et al., 2017), pudiendo también reducir la rentabilidad (Scharf y Lory, 2000) y provocar minería del suelo (Angus y Grace, 2017). Además, los fertilizantes nitrogenados tienen alta importancia relativa dentro del costo productivo (Jaynes et al., 2011). Para elaborar recomendaciones de fertilización de N en trigo, existen métodos de diferente grado de complejidad, que consideran con distinto énfasis el requerimiento de N por parte del cultivo (demanda) y el aporte de N del suelo (oferta). Una metodología, estima la demanda de N en función de un rendimiento objetivo que sería factible lograr en el lote (Stanford, 1973) multiplicado por una variable empírica local que estima el N adicional requerido para optimizarlo (Álvarez, 1999). El método de balance (de Wit, 1953) agrega complejidad al descomponer la demanda, como la absorción de N por flujo masal (Bray, 1954) y la eficiencia fisiológica de utilización de N (EUN; Gastal et al., 2015); y la oferta, como la disponibilidad inicial en el suelo (Meisinger, 1984), el aporte desde la mineralización de la MO (Schepers y Meisinger, 1994), la descomposición de los residuos de cultivos anteriores y el agregado en los fertilizantes, a los que se restan las pérdidas por volatilización, desnitrificación y lixiviación (García y Berardo, 2005). Aunque los balances han tenido cierto grado de adopción, el enfoque habitual para el diagnóstico de N en trigo en Argentina es la simple combinación del análisis del contenido de N-nitrato 0-60 cm al momento de la siembra (Magdoff et al. 1984) y un umbral al que se debe alcanzar mediante la adición de fertilizantes para no limitar el rendimiento, en base a relaciones empíricas previas (Barbieri et al., 2012). A esta metodología de diagnóstico se le ha incorporado más recientemente la determinación del N incubado en anaerobiosis (Nan) como estimador de la variabilidad de oferta durante el ciclo del cultivo (Reussi Calvo et al., 2013). Por otra parte, se han propuesto métodos ópticos reactivos (Raun et al., 2002) o desarrollado modelos funcionales simples (González Montaner et al., 1997) y más complejos, de simulación a paso diario (Ritchie y Otter, 1985), como también, basados en simulaciones previas (Satorre et al., 2005). Sin embargo, la efectividad de estos enfoques se ve comprometida principalmente por la variabilidad temporal y espacial de la demanda y la oferta de N y su consecuente asincronía (Raun et al., 2011; Tremblay et al., 2012). El máximo retorno a la fertilización nitrogenada (Sawyer et al., 2006) se logra utilizando la dosis óptima económica de N (DOE), que proporciona un N crítico por encima del cual el incremento de rendimiento por unidad de N adicional no cubre el costo del insumo agregado (Correndo et al., 2021a). El uso de metodologías de aprendizaje automático, como los algoritmos no paramétricos de árboles de decisión (decision trees), son herramientas útiles para modelar respuestas que incluyen no linealidad, interacción entre variables explicativas y problemas de multicolinealidad (Kitchen et al., 2003; Ransom et al., 2019). En el centro oeste bonaerense no existe suficiente información para manejar el cultivo de trigo en un planteo de agricultura de precisión por lo que el objetivo de este trabajo fue i) caracterizar la variabilidad espacial y temporal del rendimiento, la respuesta óptima económica a nitrógeno (RespN), la DOE y la eficiencia agronómica del uso de N del fertilizante (EUNf) para el cultivo de trigo en el centro oeste bonaerense y ii) generar un modelo predictivo de la DOE para apoyar el manejo de la fertilización nitrogenada.

## Materiales y métodos

Se llevaron a cabo 63 ensayos en microparcels (3 m de largo y 2 m de ancho) a campo, con dosis creciente de N 0, 25, 50, 100, 150, 200 y 250 kg ha<sup>-1</sup>, en un diseño de bloques completos aleatorizados, con tres repeticiones para los tratamientos fertilizados y seis repeticiones para los testigos sin N. Los

sitios, en posiciones del paisaje y tipos de suelo contrastantes, se localizaron en 7 campos de los partidos de 9 de Julio, 25 de Mayo y General Viamonte, Buenos Aires, Argentina durante 7 campañas, 2013 - 2022. Los suelos presentaron textura franco-arenosa, siendo Hapludoles típicos en los sitios más productivos, Hapludoles énticos principalmente en lomas arenosas con menor productividad y Hapludoles thapto-árgicos en las posiciones más bajas. La fuente de N utilizada fue urea granulada aplicada al voleo en forma manual, entre la siembra y el inicio de macollaje del trigo (Z20-Z23). Se relevaron 21 variables explicativas, estáticas (no cambian entre campañas en un sitio, o lo hacen muy lentamente) y dinámicas (experimentan importantes cambios interanuales), mediante caracterización ambiental intensiva con rastra Veris 3100 y GPS RTK, muestreo y análisis de suelo y recolección de información meteorológica de cada campaña hasta el momento de fertilización (Tabla 1). La relación entre el rendimiento y la dosis de N se sintetizó a partir de modelos matemáticos de respuesta cuadráticos plateau y cuadráticos (significativos cuando  $P < 0,1$  y en caso contrario, sin respuesta a N), desde los cuales se calcularon las variables  $\square$ componentes de la respuesta $\square$  a la fertilización, estableciendo la derivada primera de la curva de respuesta ajustada a una relación de precios histórica de 6:1 (Barbieri et al., 2009). Se cuantificó la variabilidad espacio-temporal del rendimiento del trigo sin N (RendN0;  $\text{kg ha}^{-1}$ ), el rendimiento del trigo a la DOE (RendDOE;  $\text{kg ha}^{-1}$ ), la RespN ( $\text{kg de trigo ha}^{-1}$ ), la DOE ( $\text{kg N ha}^{-1}$ ) y la EUNf ( $\text{kg de trigo kg N}^{-1}$ ). El rendimiento en grano fue determinado mediante la cosecha manual de espigas y ajustado a 14% de humedad. Se desarrollaron modelos de regresión lineal simple y múltiple (MLM) con el paquete  $\square$ leaps $\square$  del software R y se construyó un árbol de decisión mediante la biblioteca  $\square$ rpart $\square$  (Breiman et al., 1984; James et al., 2021), para explicar la DOE. La evaluación se realizó mediante validación cruzada con 10 subgrupos, con  $R^2$ , RMSE y RRMSE (Archontoulis y Miguez, 2015).

Tabla 1. Descripción y valores observados de las variables estáticas y dinámicas relevadas en los ensayos de N en trigo para las campañas 2013-2022 en el centro oeste bonaerense.

Acrónimo	Explicación	Unidad	Rango observado	Promedio
<b>VARIABLES ESTÁTICAS (cambian lentamente a través del tiempo o no cambian)</b>				
MO	Materia orgánica del suelo (0-20 cm de profundidad)	%	1,5-5,7	3,1
Arena	Contenido de arena (0-20 cm de profundidad)	%	25-80	55
Arena_20_60	Contenido de arena (20-60 cm de profundidad)	%	25-82,5	60
Arcilla	Contenido de arcilla (0-20 cm de profundidad)	%	6,5-23	13,5
Arcilla_20_60	Contenido de arcilla (20-60 cm de profundidad)	%	7-30	15
CS	Contenido de arcilla y limo (0-20 cm de profundidad)	%	20-75	45
CS_20_60	Contenido de arcilla y limo (20-60 cm de profundidad)	%	18-75	40
MO_CS	Materia orgánica del suelo en relación a partículas finas (0-20 cm de profundidad)	-	0,045-0,113	0,069
CEa30	Conductividad eléctrica aparente del suelo (30 cm de profundidad)	$\text{mS m}^{-1}$	4-37	11
CEa90	Conductividad eléctrica aparente del suelo (90 cm de profundidad)	$\text{mS m}^{-1}$	4-52	15
Rel_Elev	Elevación relativa	m	-1,8-2,4	0,06
SCA	Área de cuenca específica	valor de pixel	0,1-331	30
TWI	Índice topográfico de humedad	valor de pixel	4-12	7
Pendiente	Pendiente del terreno	%	0,1-3,1	1
PEF	Profundidad efectiva del suelo	cm	55-sin limitantes	-
<b>VARIABLES DINÁMICAS (cambian rápidamente a través del tiempo)</b>				
SW	Agua inicial (0-100 cm de profundidad)	mm	142-417	252
N-nitrato	Contenido de $\text{N-NO}_3$ (0-60 cm de profundidad)	$\text{kg ha}^{-1}$	17-110	53
$\text{N}_{an}$	Nitrógeno incubado en anaerobiosis (0-20 cm de profundidad)	$\text{mg kg}^{-1}$	23-106	63
$\text{N}_{an\_CS}$	Nan en relación a la partículas finas (0-20 cm de profundidad)	-	0,6-3	1,4
$\text{N}_{an\_MO}$	Nan en relación a la materia orgánica del suelo (0-20 cm de profundidad)	-	7,5-34,7	21,3
Pp_mar_jul	Precipitaciones acumuladas en el período marzo-julio	mm	132-603	324

## Resultados y discusión

Se observó una amplia variabilidad de las variables respuesta en los 63 ensayos de N durante el periodo 2013-2022 (Figura 1). El RendN0 promedio fue  $3613 \text{ kg ha}^{-1}$  con un rango explorado desde 1484 hasta  $5880 \text{ kg ha}^{-1}$ , similar a lo informado por Barraco et al. (2009) en el noroeste bonaerense. La campaña 2019 fue la de mayor RendN0 promedio con  $4943 \text{ kg ha}^{-1}$  y 2022 la de menor, con  $2378 \text{ kg ha}^{-1}$ . El

RendDOE promedio fue 5068 kg ha<sup>-1</sup> (Figura 1), un 43% superior al promedio zonal de 3540 kg ha<sup>-1</sup> (Andrade y Satorre, 2015), posiblemente debido al material genético y rendimiento potencial inferior de las variedades implementadas en ese estudio. El RendDOE mostró una variación desde 1500 hasta 8350 kg de trigo ha<sup>-1</sup>, similar a lo reportado por Videla Mensegue et al. (2021) en condiciones edáficas y climáticas similares.

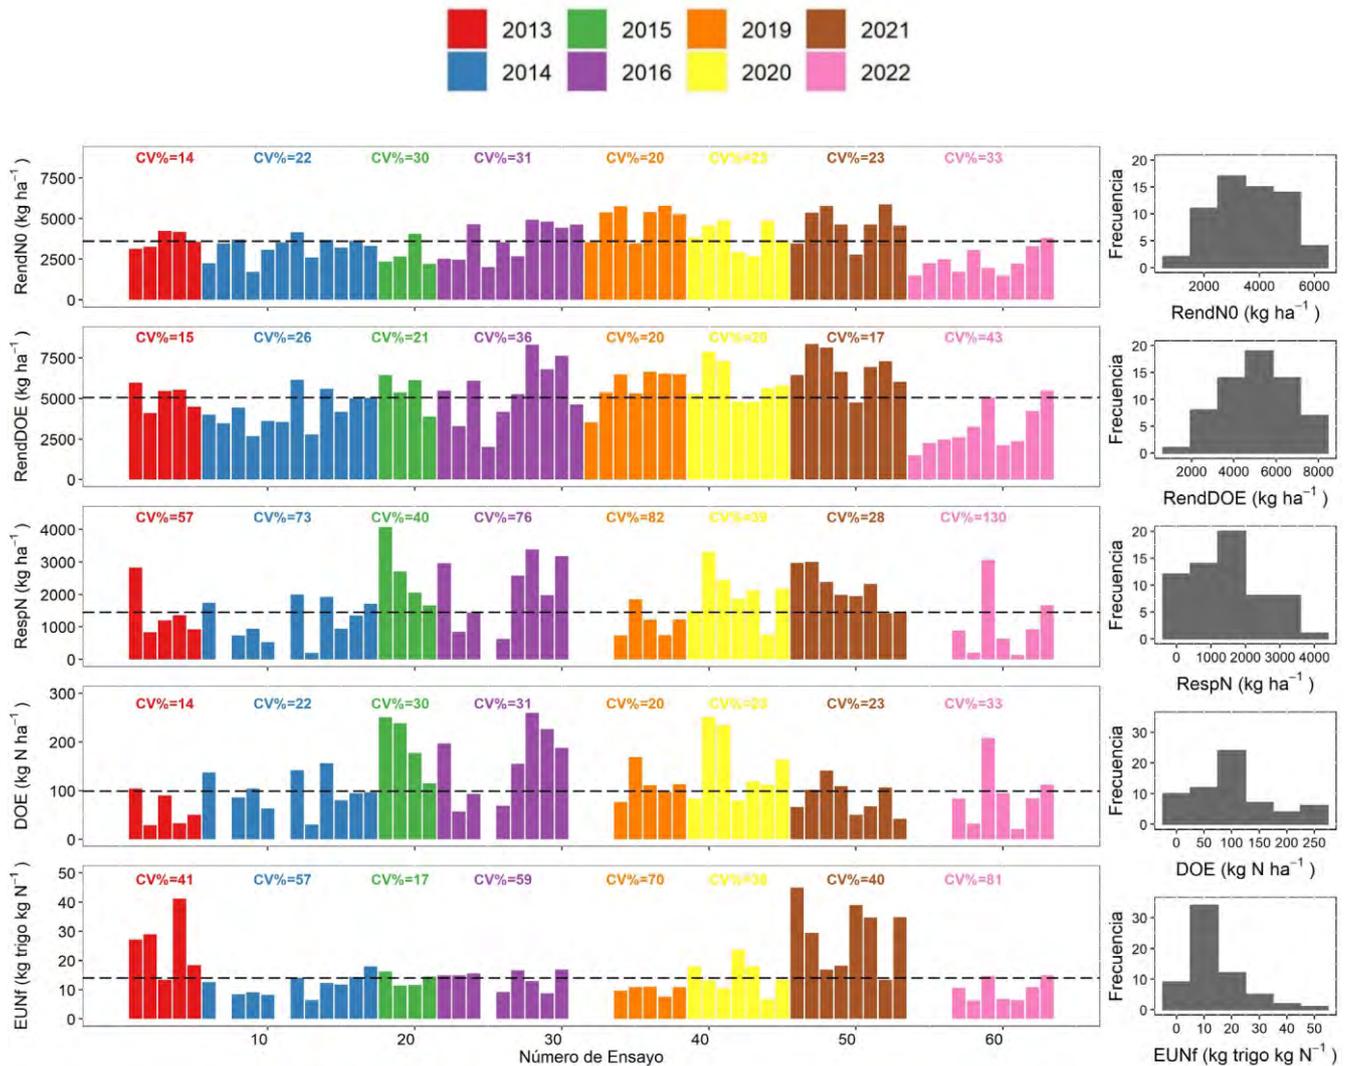


Figura 1. Variabilidad observada del rendimiento testigo sin N (RendN0), el rendimiento a la DOE (RendDOE), la respuesta a N (RespN), la dosis óptima económica (DOE) y la eficiencia de uso de N del fertilizante (EUNf) en cada ensayo de N en microparcelas de trigo para las campañas 2013-2022 (cada color es una campaña) en el centro oeste bonaerense. El histograma de frecuencias presenta la distribución de cada variable en el rango explorado. La línea punteada indica el valor promedio de cada variable.

La RespN varió desde 0 hasta 4076 kg de trigo ha<sup>-1</sup>, con un promedio de 1455 kg ha<sup>-1</sup>, que representa un 40% de incremento de rendimiento con respecto al tratamiento sin fertilizar con N, en línea con lo reportado por de Lara et al. (2023). La campaña de mayor RespN promedio fue la 2015 (muy húmeda) con 2628 kg de trigo ha<sup>-1</sup> (81% superior al promedio de los ensayos) y la de menor fue 2022 (muy seca) con un promedio de 752 kg de trigo ha<sup>-1</sup> de RespN (48% inferior al promedio de los ensayos; Figura 1). La DOE promedio de los 63 ensayos fue 99 kg N ha<sup>-1</sup>, un 39% superior a la dosis promedio nacional de

71 kg N ha<sup>-1</sup> (Bolsa de Cereales, 2020), con una variación espacio-temporal de 0 a 260 kg N ha<sup>-1</sup> (Figura 1). En el 65% de los casos (41 ensayos) la DOE estuvo por encima de la media utilizada a nivel de producción, respaldando la existencia de una importante brecha nutricional en el cultivo (Cassman y Dobermann, 2022). La campaña de mayor DOE promedio fue 2015 con 195 kg N ha<sup>-1</sup> (97% superior al promedio de todos los ensayos), que fue el año de mayores excesos hídricos y sitios con valores bajos de N-nitrato, MO y Nan (datos no mostrados). Contrariamente, 2013 fue la campaña de menor DOE, 61 kg N ha<sup>-1</sup> (68% inferior al promedio de los ensayos), con bajas precipitaciones y demanda de N (RendDOE bajo; Figura 1). El promedio de EUNf fue 14 kg de grano de trigo kg N<sup>-1</sup>, que varió desde 0 hasta 45 kg de trigo kg N<sup>-1</sup>, siendo 2021 la campaña de mayor EUNf promedio con 29 kg de trigo kg N<sup>-1</sup> (207% superior) y 2022 la de menor con 7 kg de trigo kg N<sup>-1</sup> (50% inferior; Figura 1).

La concentración de arena en el suelo presentó la mayor explicación de la DOE como variable simple ( $r^2 = 0,42$ ; RMSE = 62 kg N ha<sup>-1</sup> y RRMSE = 0,63) mediante una relación cuadrática. En cambio, variables clásicas utilizadas en modelos zonales de diagnóstico de N como el N-nitrato y el Nan, no fueron significativas para explicar la DOE utilizadas de manera independiente (datos no mostrados). La predicción más robusta de la DOE resultó de la combinación de variables estáticas y dinámicas mediante un modelo no paramétrico de árbol de decisión que presentó un ajuste del 51% de la variabilidad, con un RMSE de 49 kg N ha<sup>-1</sup> y RRMSE de 0,49 (Figura 2). Si bien la magnitud de este error supera lo aceptable para utilizar esta herramienta en forma estricta en una recomendación de dosis de fertilización nitrogenada, se considera como un marco de referencia sólido sobre el cual pueden ajustarse las decisiones contemplando otros factores. Otros trabajos han informado modelos de predicción de DOE de N en cereales con desempeños comparables a los aquí presentados (Sawyer et al., 2006; Ransom et al., 2023; Thornburn et al., 2024).

La variable de mayor importancia para explicar la DOE fue la Rel\_Elev, disminuyendo la DOE hacia posiciones topográficas más elevadas (Rel\_Elev >0,54 m) y sitios de menor Pp\_mar\_jul, que indicaría limitantes para el crecimiento asociadas al déficit hídrico con precipitaciones insuficientes. También, la DOE fue baja en sitios con elevado contenido de Arcilla\_20\_60 (>20%), que puede limitar la exploración radical y disponibilidad hídrica (Sadras y Calviño, 2001; Peralta et al., 2015). Los sitios de menor Rel\_Elev (<-0,87m) y contenido de Arcilla\_20\_60 inferior a 20%, fueron los de mayor DOE predicha, probablemente relacionados a una mayor demanda de N debido a una elevada capacidad de almacenaje de agua del perfil del suelo y a mayores pérdidas potenciales de N del sistema (Johnson II et al., 2022). La DOE predicha para las posiciones topográficas intermedias, dependieron del nivel de MO y Nan como indicadores de la oferta de N del suelo (Figura 2). Jaynes et al. (2011), trabajando en una región húmeda de EEUU, en campañas con niveles de precipitación promedio, observaron mayor DOE en zonas de mayor elevación respecto de las zonas más deprimidas dentro de un lote y atribuyeron este comportamiento al menor aporte de N edáfico. Sin embargo, estos autores reportaron también un comportamiento inverso en una campaña con precipitaciones por encima del promedio y sugirieron que las mayores DOE, en las zonas más deprimidas, podrían deberse a procesos de pérdidas de N. En un estudio realizado en Córdoba, en años con precipitaciones mayores al promedio histórico, la DOE en maíz fue superior en posiciones elevadas de la topografía y menor en sitios bajos (Bongiovanni, 2002). Por el contrario, en años secos, esta relación se invirtió drásticamente siendo conveniente fertilizar solamente en las zonas de menor elevación. Según Girón (2019), en ensayos de maíz de campañas húmedas del oeste bonaerense, la DOE fue mayor en las áreas con presencia de horizonte thapto que en las áreas de suelo profundo. En este sentido, Ruffo et al. (2006) también observaron mayor DOE en zonas de menor drenaje y por lo tanto más propensas a sufrir pérdidas de N por desnitrificación.

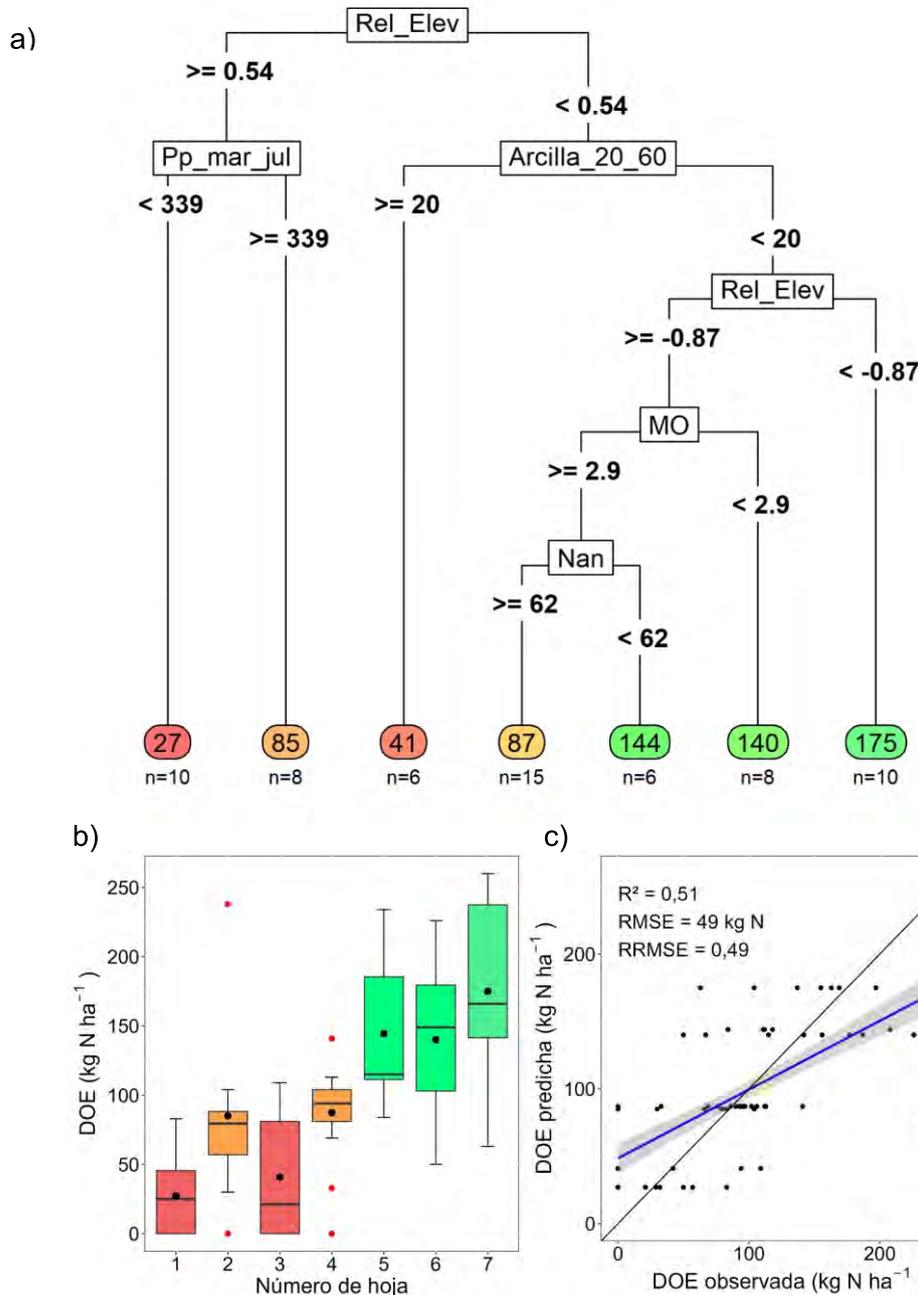


Figura 2. Árbol de decisión al momento de fertilización (AF) para la dosis óptima económica (DOE; a), gráfico de cajas para las hojas del árbol (b) y relación observados-predichos (c)

## Conclusiones

En este trabajo de investigación de siete años, sobre 63 ensayos de fertilización nitrogenada en el centro oeste bonaerense, en el cual se relevaron un total de 21 variables, se cuantificó simultáneamente la magnitud de la variabilidad espacio-temporal de la DOE, información hasta el momento inexistente en la región y se desarrolló un modelo para guiar en la toma de decisión de la fertilización nitrogenada, que considera tanto la variabilidad del suelo como la meteorológica. El modelo desarrollado es sitio-específico y cubre el espacio entre modelos simples (de una sola variable) y más complejos como los de simulación. Las variables clásicas de diagnóstico de N, como el N-nitrato y el Nan, no fueron

significativas para explicar la DOE utilizadas de manera independiente. El modelo no paramétrico de árbol de decisión, que contempla la no linealidad e interacción entre los factores, presentó la mayor capacidad explicativa de la DOE y la elevación relativa (Rel\_Elev) fue la variable explicativa más relevante. Este estudio amplía y complementa esfuerzos anteriores realizados en Argentina para el diagnóstico de la fertilización nitrogenada en trigo, sirviendo como herramienta de decisión sitio-específica en el centro-oeste bonaerense.

### Agradecimientos

A los productores agropecuarios y asesores que colaboraron con la experimentación: Lisandro Torrens (INTA 9 de Julio), Alejandro Mulcahy (Establecimiento □Las Chicas□, 9 de julio), Zacarías Nicola (Escuela Inchausti, 25 de Mayo), familia Lugano (Establecimiento □El Arapey□, 9 de Julio), Germán Molea (Zavalía, Gral. Viamonte), Norma Pedemonte (establecimiento □Don Atilio□, 9 de Julio), familia Pagani (establecimientos □San Lorenzo□ y □El Señuelo□, 9 de Julio).

A los investigadores Matías Ruffo, Fernando Miguez y Paula Girón quienes realizaron aportes valiosísimos.

### Referencias

- Abbate, P.E. 2017. Bases ecofisiológicas del manejo del cultivo de trigo en la región pampeana. Pp. 33-52 en Divito, G.A. y García, F. (eds.) Manual del Cultivo de Trigo. International Plant Nutrition Institute.
- Álvarez, R. 1999. Uso de modelos de balance para determinar los requerimientos de fertilizante nitrogenado de trigo y maíz. Pp 58. Editorial EUDEBA.
- Angus, J.F. y Grace, P.R. 2017. Nitrogen balance in Australia and nitrogen use efficiency on Australian farms. *Soil Research*, 55: 435. <https://doi.org/10.1071/SR16325>
- Andrade, J. y Satorre, E., 2015. Single and double crop systems in the Argentine Pampas: Environmental determinants of annual grain yield. *Field Crops Research*, 177: 137-147. <https://doi.org/10.1016/j.fcr.2015.03.008>
- Aramburu Merlos, F., Monzon, J. P., Mercau, J. L., Taboada, M., Andrade, F. H., Hall, A. J., Jobbagy, E., Cassman, K. G. y Grassini, P. 2015. Potential for crop production increase in Argentina through closure of existing yield gaps. *Field Crops Research*, 184: 145-154. <https://doi.org/10.1016/J.FCR.2015.10.001>
- Archontoulis, S. V. y Miguez, F. E. 2015. Nonlinear regression models and applications in agricultural research. *Agronomy Journal*, 107: 786-798. doi: 10.2134/agronj2012.0506
- Barbieri, P.A., Echeverría, H.E. y Sainz Rozas, H.R. 2009. Dosis óptima económica de nitrógeno en trigo según momento de fertilización en el Sudeste Bonaerense. *Ciencia del suelo*, 27: 115-125.
- Barbieri, P.A., Echeverría H.E. y Saínz Rozas, H.R. 2012. Alternatives for nitrogen diagnosis for wheat with different yield Potentials in the Humid Pampas of Argentina. *Communications in Soil Science and Plant Analysis*, 43(11): 1512-1522, DOI: 10.1080/00103624.2012.675388
- Barraco, M., Díaz-Zorita, M., Brambilla, C., Álvarez, C. y Sciancia, C. 2009. Respuesta del trigo a la fertilización nitrogenada y nitroazufrada en suelos arenosos. EEA INTA General Villegas. *Ciencia del suelo*, 27: 217-224.
- Basso, B., Ritchie, J.T., Cammarano y D., Sartori, L. 2011. A strategic and tactical management approach to select optimal N fertilizer rates for wheat in a spatially variable field. *European Journal of Agronomy* 35: 215-222. <https://doi.org/10.1016/j.eja.2011.06.004>
- Bongiovanni, R. 2002. A spatial econometrics approach to the economics of site-specific nitrogen management in corn production. Ph.D. Thesis, Department of Agricultural Economics, Purdue University, West Lafayette, IN (EUA), 280 p.
- Bray, R.H. 1954. A nutrient mobility concept of soil-plant relationships. *Soil Science*, 104:9-22.
- Breiman, L., Friedman, J., Stone, C.J. y Olshen, R.A., 1984. *Classification and Regression Trees*. Taylor & Francis. <https://doi.org/10.1201/9781315139470>
- Cassman, K.G. y Dobermann, A. 2022. Nitrogen and the future of agriculture: 20 years on. *Ambio*, 51: 17-24. <https://doi.org/10.1007/s13280-021-01526-w>
- Correndo, A.A., Gutiérrez-Boem, F.H., García, F.O., Alvarez, C., Álvarez, C., Angeli, A., Barbieri, P., et al. 2021a. □Attainable Yield and Soil Texture as Drivers of Maize Response to Nitrogen: A Synthesis Analysis for Argentina.□ *Field Crops Research*, 273: 108-299. <https://doi.org/10.1016/j.fcr.2021.108299>.

- de Lara, A., Mieno, T., Luck, J.D. y Puntel, L.A. 2023. Predicting site-specific economic optimal nitrogen rate using machine learning methods and on-farm precision experimentation. *Precision Agriculture*, 24: 1792-1812. <https://doi.org/10.1007/s11119-023-10018-8>
- de Wit, C. T. 1953. A physical theory on placement of fertilizers. [external PhD, WU]. Staatsdrukkerij. <https://edepot.wur.nl/345397>
- García, F. y Berardo, A. 2005. Trigo. Pag. 233-253. En H. Echeverría y F. García (eds.). *Fertilidad de Suelos y Fertilización de Cultivos*. Ediciones INTA. Buenos Aires, Argentina.
- Gastal, F., Lemaire, G., Durand, J.L. y Louarn, G. 2015. Chapter 8 - Quantifying crop responses to nitrogen and avenues to improve nitrogen-use efficiency. Pp. 161-206 en Sadras, V.O., Calderini, D.F. (Eds.), *Crop Physiology (Second Edition)*. Academic Press, San Diego. <https://doi.org/10.1016/B978-0-12-417104-6.00008-X>
- Girón, P. 2019. Manejo sitio - específico de nitrógeno para el cultivo de maíz en el noroeste bonaerense". Tesis de Maestría. Universidad de Buenos Aires. Facultad de Agronomía. Escuela para Graduados. <http://ri.agro.uba.ar/greenstone3/library/collection/tesis/document/2021gironpaula>
- González Montaner, J., Maddonni, G. y Dinapoli, M. 1997. Modeling grain yield and grain yield response to nitrogen in spring wheat crops in the Argentinean Southern Pampa. *Field Crops Research*, 51: 241-252. 10.1016/S0378-4290(96)03459-4.
- Havlin, J.L., Beaton, J.D., Tisdale, S.L y Nelson, W.L. 2005. *Soil fertility and fertilizers 7th ed.* Pp. 515. Prentice Hall, Englewood Cliffs, NJ.
- James, G., Witten, D., Hastie, T. y Tibshirani, R. 2021. *An Introduction to Statistical Learning, with Application in R, 2nd Ed.* Springer Series in Statistics.
- Jaynes, D.B., Kaspar T.C. y Colvin, T.S. 2011. Economically Optimal nitrogen Rates of Corn: Management Zones Delineated from Soil and Terrain Attributes. *Agronomy Journal*, 103: 1026-1035.
- Johnson II, F.E., Lerch, R.N., Motavalli, P.P., Veum, K.S. y Scharf, P.C. 2022. Spatial variability of denitrification enzyme activity and actual denitrification emissions on Missouri claypan soils. *Soil Science Society of America Journal* 86, 1582-1596. <https://doi.org/10.1002/saj2.20457>
- Kitchen, N.R., Drummond, S.T., Lund, E.D., Sudduth, K.A. y Buchleiter, G.W. 2003. Soil electrical conductivity and topography related to yield for three contrasting soil-crop systems. *Agronomy Journal*, 95: 483-495.
- Magdoff, F.R., Ross, D. y Amadon, J. 1984. A soil test for nitrogen availability to maize. *Soil Science Society of America Journal*, 48:1301-1304.
- Meisinger, J. 1984. Evaluating Plant-Available Nitrogen in Soil-Crop Systems. Pp. 389-416 in Hauck, R.D. (ed) *Nitrogen in Crop Production*. John Wiley & Sons, Ltd, <https://doi.org/10.2134/1990.nitrogenincropproduction.c26>
- Peralta, N.R., Costa, J.L., Balzarini, M., Castro Franco, M., Córdoba, M. y Bullock, D., 2015. Delineation of management zones to improve nitrogen management of wheat. *Computers and Electronics in Agriculture*, 110: 103-113. <https://doi.org/10.1016/j.compag.2014.10.017>
- Ransom, C., Kitchen, N., Camberato, J., Carter, P., Ferguson, R., Fernández, F., Franzen, D., Laboski, C., Myers, D., Nafziger, E., Sawyer, J. y Shanahan, J. 2019. Statistical and machine learning methods evaluated for incorporating soil and weather into corn nitrogen recommendations. *Computers and Electronics in Agriculture*, 164: 104872. <https://doi.org/10.1016/j.compag.2019.104872>
- Ransom, C., Kitchen, N., Camberato, J., Carter, P., Ferguson, R., Fernández, F., Franzen, D., Laboski, C., Myers, D., Nafziger, E. y Sawyer, J. 2023. Combining Corn N Recommendation Tools for an Improved Economical Optimal Nitrogen Rate Estimation. *Soil Science Society of America Journal*, 87: 902-917. <https://doi.org/10.1002/saj2.20539>
- Raun, W.R., Solie, J.B., Johnson, G.V., Stone, M.L., Mullen, R.W., Freeman, K.W., Thomason, W.E. y Lukina, E.V. 2002. Improving Nitrogen Use Efficiency in Cereal Grain Production with Optical Sensing and Variable Rate Application. *Agronomy Journal*, 94: 815-820. <https://doi.org/10.2134/agronj2002.8150>
- Raun, W.R., Solie, J.B. y Stone, M.L. 2011. Independence of yield potential and crop nitrogen response. *Precision Agriculture*, 12:508-518. doi:10.1007/s11119-010-9196-z
- Reussi Calvo, N.I., Sainz Rozas, H.R., Echeverría H.E. y Berardo, A. 2013. Contribution of anaerobically incubated nitrogen to the diagnosis of nitrogen status in spring wheat. *Agronomy Journal*, 105:321-328.
- Ritchie, J.T. y Otter, S. 1985. Description and performance of CERES-Wheat: A user-oriented wheat yield model. *ARS wheat yield project*, 38: 159-175.
- Rockström, J., Edenhofer, O., Gaertner, J. y DeClerck, F. 2020. Planet-proofing the global food system. *Nat Food*, 1: 3-5. <https://doi.org/10.1038/s43016-019-0010-4>
- Ruffo, M. L., Bollero, G. A., Bullock, D. S. y Bullock, D. G. 2006. Site-specific production functions for variable rate corn nitrogen fertilization. *Precision Agriculture*, 7(5): 327-342. <https://doi.org/10.1007/s11119-006-9016-7>
- Sadras, V.O. y Calviño, P.A., 2001. Quantification of Grain Yield Response to Soil Depth in Soybean, Maize, Sunflower, and Wheat. *Agronomy Journal*, 93: 577-583. <https://doi.org/10.2134/agronj2001.933577x>
- Scharf, P.C. y Lory, J.A. 2000. Calibration of remotely-sensed corn color to predict nitrogen needs. In *Proceedings of the 5th*

- International Conference on Precision Agriculture. ASA-CSSA-SSSA, Madison, WI, USA.
- Satorre, E.H., Menéndez, F., Tinghitella, G y Cavasassi, J.L. 2005. TRIGUERO: Un sistema de apoyo a la fertilización nitrogenada de Trigo. Convenio AACREA y PROFERTIL S.A., software de aplicación agronómico.
- Sawyer, J.E., Nafziger, E.D., Randall, G.W., Bundy, L.G., Rehm, G.W. y Joern, B.C. 2006. Concepts and Rationale for Regional Nitrogen Rate Guidelines for Corn.
- Schepers, J.S. y Meisinger, J.J., 1994. Field Indicators of Nitrogen Mineralization. Pp. 31-47 in: Soil Testing: Prospects for Improving Nutrient Recommendations. John Wiley & Sons, Ltd. <https://doi.org/10.2136/sssaspecpub40.c3>
- Sinclair, T.R. y Rufty, T.W., 2012. Nitrogen and water resources commonly limit crop yield increases, not necessarily plant genetics. *Global Food Security*, 1: 94-98. <https://doi.org/10.1016/j.gfs.2012.07.001>
- Stanford, G. 1973. Rationale for optimum nitrogen fertilization in corn production. *Journal of Environmental Quality*, 2:159-166.
- Thorburn, P.J., Biggs, J.S., Puntel, L.A., Sawyer, J.E., Everingham, Y.L. y Archontoulis, S.V. 2024. The nitrogen fertilizer conundrum: why is yield a poor determinant of crops' nitrogen fertilizer requirements? *Agronomy for Sustainable Development*, 44(2): 18. <https://doi.org/10.1007/s13593-024-00955-7>
- Tremblay, N., Bouroubi, Y.M., Belec, C., Mullen R.W., Kitchen N.R., Thomason, W.E., Ebelhar, S., Mengel, D.B., Raun, W.R., Francis, D.D., Vories, E.D. y Ortiz-Monasterio I. 2012. Corn response to nitrogen is influenced by soil texture and weather. *Agronomy Journal*, 104:1658-1671.
- Van Ittersum, M.K., Cassman, K.G., Grassini, P., Wolf, J., Tittonell, P., Hochman, Z., 2013. Yield gap analysis with local to global relevance - a review. *Field Crops Research*, 143: 4-17. <http://dx.doi.org/10.1016/j.fcr.2012.09.009>.
- Videla Mensague, H., Barraco, M., Álvarez, C., Miranda, W., Rampo, M., Pereyro, A., Macchiavello, A., Ferro, M. y Varillas, G. 2021. Estimación del rendimiento de trigo en función del agua disponible y la profundidad de napa. IX Congreso Nacional de Trigo. Calidad y sustentabilidad. Tres Arroyos, Argentina.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Encuesta sobre siembra e implantación del cultivo de Alfalfa (*Medicago Sativa, L*) en Argentina

**Fernando M Scaramuzza; Diego D Villarroel; Silvia M Olivo; Lopez Seco, Emilia**

INTA EEA Manfredi, Ruta 9 Km 636, Manfredi, Córdoba, Argentina.

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** Argentina, después de Estados Unidos y Canadá es el país con mayor superficie de siembra en el cultivo de alfalfa. El objetivo fue generar información sobre del proceso productivo de la alfalfa en Argentina. La mayor proporción de respuestas corresponden a provincias de Córdoba, Buenos Aires, Santa Fe, La Pampa. 51% son productores ganaderos/lecheros, 30% asesores y asesores/productor, 11% productores de alfalfa, 8% contratistas/productores agrícolas. El 75% de los encuestados tiene 300 hectáreas implantadas. El 33% utiliza el cultivo en pastoreo directo y/o confección de rollos y solo el 9% pastoreo directo. De 5 a 8% confeccionan exclusivamente de fardos/rollos/megafardos; mientras que el 37% lo hace mixta. Para estimar el rendimiento, solo el 20% realiza muestreo manual, aunque 50% lo hace de manera indirecta a través de la cantidad de fardos/rollos/megafardos producidos, el 21% lo realiza visualmente y 9% no estima. El 50% presenta rendimientos de 2000-3000 kgMS/ha. El 90% realiza entre 4 a 7 cortes/año. La fecha de siembra promedio es otoño, el 50% de los productores realiza siembra directa y el 60% utiliza maquinaria propia. El 80% de los encuestados realiza la siembra en líneas paralelas, de las cuales un 60% es a 15-17,5 cm. La densidad de siembra utilizada es de 18-20 kg de semilla/ha, 80% utiliza alfalfa sin reposo invernal. Una vez realizada la siembra, el 50% de los productores evalúa el coeficiente de logro con conteo manual, mientras que el resto lo hace visualmente, Sin embargo, el 60% de los encuestados considera importante poder cuantificar el coeficiente de logros a través del vuelo de drones, desarrollo tecnológico que está en proceso de validación

**Palabras clave.** *Calidad de siembra, tecnología, alfalfa*



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



## Análisis de la calidad de zonificación realizada en un cultivo de maíz

**Grosso, Javier Alejandro<sup>1\*</sup>, Bongiorno, Carlos<sup>1</sup>, Rodríguez, Mariana<sup>2</sup>, Lázaro, Laura<sup>1</sup>, Ressa, Juan Manuel<sup>1</sup>**

<sup>1</sup>CIISAS Facultad de Agronomía (UNCPBA), <sup>2</sup> alumna avanzada de Ingeniería Agronómica. República de Italia 780 (7300) Azul Buenos Aires. \*Autor de contacto: grossojavier52@gmail.com

**Trabajo presentado al  
20° Congreso de Agricultura de Precisión  
20-21 de agosto de 2024 Manfredi, Córdoba, Argentina**

**Resumen.** La adopción de plataformas digitales para la gestión agrícola ha aumentado, facilitando la consulta climática, el monitoreo de cultivos y la zonificación de lotes. Sin embargo, delimitar zonas de manejo homogéneas sigue siendo un desafío por la interacción de diversos factores que afectan la productividad. Este estudio evaluó una zonificación con la plataforma FieldView en un lote destinado a maíz en Azul, Buenos Aires, creando un mapa con cinco zonas según calidad de sitio: alta (A), media (B y C), baja (D) y una parcela que integró los distintos sitios (E). Se asignaron mayores densidades a zonas de mejor calidad y menores a las de calidad inferior, y se analizó la productividad del maíz en cada zona con QGIS e Infostat. Se obtuvieron diferencias significativas en el rendimiento, pero no la asociación esperada entre zonas de mayor calidad y mayores rendimientos. Las zonas E y B tuvieron los mayores rendimientos ( $11,27 \text{ t ha}^{-1}$  y  $11,58 \text{ t ha}^{-1}$ ), mientras que la zona A, tuvo uno de los rendimientos más bajos ( $10,93 \text{ t ha}^{-1}$ ). La zona D, de baja calidad, mostró un rendimiento medio ( $11,01 \text{ t ha}^{-1}$ ). La parcela con densidad uniforme presentó un coeficiente de variación menor (7,6%) en comparación con las zonas individuales ( $>8,5\%$ ) y el total del lote (11%), indicando falta de correspondencia entre las zonas y el rendimiento. Este estudio no permite concluir sobre la efectividad de la plataforma FieldView para delimitar zonas, pero destaca la necesidad de mejorar los criterios de zonificación y validar las prescripciones generadas.

**Palabras clave.** Agricultura de precisión, Plataformas web para la gestión agrícola, Validación de zonas de manejo en agricultura.

## Introducción

En las últimas décadas, el desarrollo y la utilización de tecnologías de la información han sido impulsados para mejorar la eficiencia productiva y optimizar el uso de insumos en términos agronómicos, económicos y ambientales, lo que ha contribuido al desarrollo de la Agricultura de Precisión (AP) (Landau et al., 2014). La incorporación de estas tecnologías en la agricultura genera una gran cantidad de información, cuya captura, interpretación, gestión, procesamiento o análisis se dificulta debido a su tamaño, complejidad y velocidad de generación.

Para resolver este problema, las plataformas web de gestión de Big Data se presentan como una solución al procesar y analizar grandes volúmenes de datos agrícolas. Estas plataformas permiten hacer un seguimiento del cultivo durante todo su ciclo mediante índices elaborados con imágenes satelitales y centralizan toda la información del proceso productivo, desde datos meteorológicos hasta la realización de márgenes brutos, pasando por inventarios de insumos, stock de productos y precios de mercado. También, elaboran diagnósticos y facilitan la toma de decisiones a través de modelos de simulación y Big Data mediante programas especiales, datos precargados y sensores. Por último, permiten la comunicación en tiempo real mediante telemetría y conectividad, (Vidosa et al., 2022). En este contexto, la adopción de estas plataformas ha sido notable. Según encuestas llevadas a cabo en la región pampeana por el equipo de INTA Manfredi e INTA Marcos Juárez, el uso de estas aplicaciones y plataformas web ha alcanzado un 92% entre productores y asesores, a pesar de su reciente incorporación (Scaramuzza et al., 2022). Entre las aplicaciones mencionadas por los encuestados se destacan FieldView, Auravant, One Soil y LandViewer, las cuales son utilizadas principalmente para consultar el estado de los cultivos, gestionar labores y realizar zonificaciones.

Existen diversos algoritmos para la delimitación de zonas de manejo homogéneas; sin embargo, lograr una zonificación eficiente, en el sentido de que las zonas delimitadas sean diferentes en cuanto al rendimiento y/o propiedades del suelo que lo determinan, representa una tarea compleja. Esto se debe al gran número de factores que interactúan en forma simultánea en la definición de la capacidad productiva diferencial dentro del lote (Arnaudo et al., 2017). En general, estos factores se correlacionan, y en muchos casos de forma no lineal. Una estrategia recomendada para comprobar un proceso de zonificación es determinar si existen diferencias significativas entre las zonas de manejo delimitadas en cuanto a las variables utilizadas en dicha zonificación (Taylor et al., 2007).

La no linealidad de los factores que definen la capacidad productiva dentro del lote, combinado con la ocurrencia de errores e inconsistencias espacio-temporales en los mapas de rendimiento y de suelos, indicarían que el uso de técnicas de inteligencia artificial presenta un alto potencial para ser empleadas en el contexto de Agricultura de Precisión (Arnaudo et al., 2017).

Diversos autores han destacado la falta de verificación y validación a nivel local de los resultados obtenidos mediante la utilización de Big Data, plataformas web y las metodologías que implementa esta tecnología para diferenciar zonas de manejo y gestionar labores (Landau et al., 2014; Melchiori et al., 2014; Villarroel et al., 2018). Por lo tanto, es crucial generar herramientas conceptualmente sólidas y fundamentalmente de resolución práctica y económica que permitan verificar los resultados obtenidos a partir de esta tecnología para una implementación efectiva de la AP.

El objetivo de este trabajo fue verificar la calidad de una zonificación realizada con una plataforma digital en un lote agrícola destinado al cultivo de maíz en Azul, Buenos Aires.

## Metodología

El presente trabajo se llevó a cabo en el establecimiento □La Tacuarita□ ubicado en el partido de Azul, provincia de Buenos Aires (Latitud Sur  $-36^{\circ} 55' 44,7''$ , Longitud Oeste  $59^{\circ} 51' 30,6''$ ) (Figura 1). El suelo corresponde a un Argiudol Petrocálcico (Soil Survey Staff, 2014), posee una capacidad de uso IIIs, presentando limitaciones de profundidad debido a la presencia de tosca.

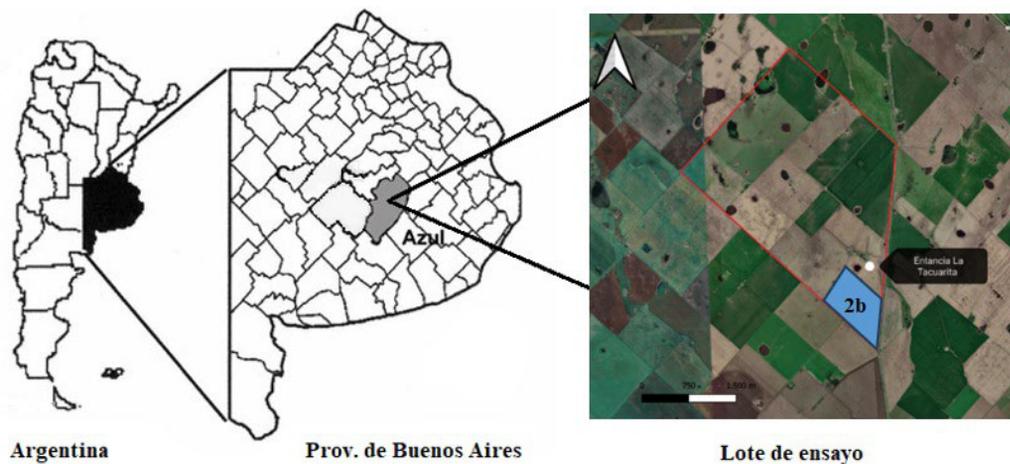


Figura 1: Establecimiento □La Tacuarita□ y lote de ensayo 2b

El clima predominante de la región es templado y húmedo, con una temperatura media anual del aire de  $15^{\circ}\text{C}$ . Las precipitaciones promedio anuales alcanzan los 960 mm, los cuales se distribuyen temporalmente de manera no uniforme registrándose, durante los meses de invierno, un exceso de precipitaciones sobre la evapotranspiración (CRAGM, 2022).

Dentro del establecimiento se trabajó en un lote de 62 hectáreas, cuya secuencia de cultivo es Maíz/Soja de primera/Trigo/Soja de segunda.

El híbrido de maíz Dekalb 7210 VT3PRO se sembró el 10 de noviembre de 2021 en densidad variable, con una sembradora equipada con dosificadores neumáticos Precision Planting. Se utilizó una prescripción de siembra realizada a partir de una zonificación generada con la plataforma digital FieldView mediante la opción □Prescripción de siembra FieldView□. Para generar dicha prescripción, la plataforma recopiló información a partir de imágenes satelitales de un período de 4 años (2018 a 2021) y el rendimiento del cultivo de maíz de una campaña, siendo esta la cantidad mínima de datos requerida por FieldView. Esta permitió crear un mapa con 5 zonas de manejo delimitadas por calidad de sitio alta (A), media alta (B), media baja C) y baja (D), a las que se le asignaron distintas densidades de siembra. Finalmente, se sembró una parcela compuesta, integrada por sitios de las distintas zonas y sembrada con densidad uniforme (E). A los sitios de mejor calidad se les asignó mayor densidad de siembra, mientras que, a los de inferior calidad se les asignó menor densidad (Tabla 1). Durante estadios vegetativos tempranos se realizaron visitas al sitio experimental y no se observaron diferencias entre la densidad prescripta y las plantas logradas en las distintas zonas.

Tabla 1: Densidad de siembra de maíz (semillas ha<sup>-1</sup>) para cada zona del lote, definida mediante la plataforma digital FieldView.

Zona	Densidad de siembra (semillas ha <sup>-1</sup> )
A	75000
B	70000
C	65000
D	60000
E	65000

El cultivo de maíz fue cosechado con una cosechadora Claas Lexion 760 con un monitor de rendimiento calibrado, lo que permitió realizar el mapa correspondiente. Dicho mapa fue analizado y depurado de forma manual, para reducir los errores y garantizar la veracidad de la información, utilizando el software QGIS 3.28.9.

En QGIS se interpolaron los datos de rendimiento usando el algoritmo de interpolación *Triangulated Irregular Network* (TIN) con un tamaño de ráster de salida de 4 x 4 m. A partir de la capa ráster de rendimiento se generaron archivos vectoriales de puntos en cada polígono correspondiente a cada zona de manejo. Para ello, se utilizó la herramienta generación de puntos en centroides de pixel dentro de polígonos. Los datos de rendimiento de los puntos mencionados anteriormente fueron analizados mediante el software estadístico Infostat (Di Rienzo, 2019). En primer lugar, se llevó a cabo un análisis estadístico descriptivo que incluyó cantidad de datos, medias, desvíos estándar, mínimos y máximos. Posteriormente, se realizó un análisis de varianza para determinar la existencia de diferencias significativas en el rendimiento entre las distintas zonas.

## Resultado y discusión

El mapa de prescripción de siembra fue realizado a partir de la zonificación generada por la plataforma digital FieldView para la siembra del cultivo de maíz en campaña 2022 (Figura 2).

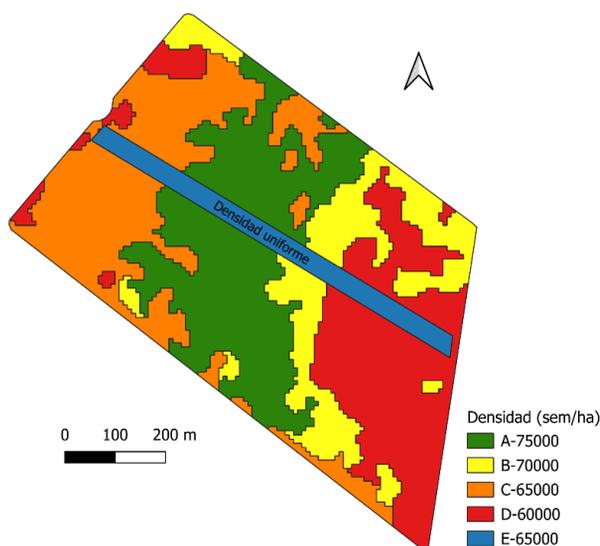


Figura 2. Mapa de prescripción de siembra para el cultivo de maíz campaña 2022

En el mismo, se pueden observar las cinco zonas definidas según el nivel de productividad. La zona A (75000 semillas  $ha^{-1}$ ) es la de mayor productividad, seguida de la zona B (70000 semillas  $ha^{-1}$ ), la zona C (65000 semillas  $ha^{-1}$ ) y la zona D (60000 semillas  $ha^{-1}$ ) como la de menor productividad. La parcela de control, con densidad uniforme, corresponde a la zona E (65000 semillas  $ha^{-1}$ ).

A partir del mapa de puntos generado por la cosechadora y posterior proceso de interpolación mediante el método TIN se obtuvo el mapa de rendimiento del cultivo (Figura 3). Se puede observar, a simple vista, que el mismo no presenta una clara correspondencia con el mapa de zonas definidas en la prescripción.

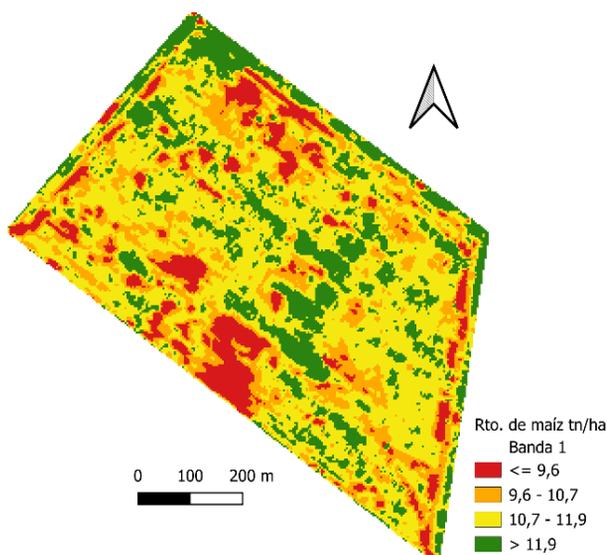


Figura 3. Mapa de rendimiento del cultivo de maíz campaña 2022 realizado con interpolación TIN

A continuación, se presentan los resultados del análisis estadístico descriptivo y el test de comparación

de medias realizado a los datos de rendimiento de maíz de cada zona definida por FieldView (Tabla 2).

**Tabla 2: Análisis estadístico descriptivo y comparación de medias del rendimiento de maíz de cada zona definida por la plataforma digital FieldView.**

Zonas	Densidad siembra (sem ha <sup>-1</sup> )	n	% Sup.	Rend. (t ha <sup>-1</sup> )	D.E.	CV (%)	Rend. Min (t ha <sup>-1</sup> )	Rend. Max (t ha <sup>-1</sup> )
A	75000	1736	28	10,93 <b>a</b>	1,23	11,28	5,25	14,09
B	70000	1035	17	11,58 <b>b</b>	1,24	10,74	6,49	15,76
C	65000	1551	25	10,66 <b>c</b>	1,36	12,74	4,63	13,72
D	60000	1497	24	11,01 <b>a</b>	0,96	8,74	4,41	15,57
E	65000	408	7	11,27 <b>d</b>	0,83	7,36	7,43	13,73
Total lote	67417	6227	100	11,01	1,22	11,11	4,41	15,76

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ )

La zonificación del lote agrícola reveló que la zona A, que supone mejor calidad de sitio, representa el 28% de la superficie total. La zona B cubrió el 17%, la C el 25%, la D el 24%, y la parcela de control el 7%. Sin embargo, al analizar la variabilidad del rendimiento en relación con las zonas, se observa que, a pesar de las diferencias significativas en el rendimiento del maíz, no se logró la asociación esperada entre las zonas de mejor calidad y los mayores rendimientos ( $n=4$ ,  $r^2=0,23$ ,  $p>= 0,7$ ). La zona E y B presentaron los rendimientos más altos (11,27 t ha<sup>-1</sup> y 11,58 t ha<sup>-1</sup> respectivamente), mientras que la zona A, supuestamente de mejor calidad, tuvo uno de los rendimientos más bajos (10,93 t ha<sup>-1</sup>). Por otro lado, la zona de menor calidad (D) se asoció con un rendimiento medio (11,01 t ha<sup>-1</sup>). Además, se observó que la parcela uniforme, que abarca todas las zonas definidas por la plataforma, mostró un coeficiente de variación inferior (7,63 %) en comparación con el de cada una de las zonas individuales (> 8,5 %) y con el del total del lote (11,11 %). Este hallazgo confirma la falta de correspondencia entre las zonas definidas y la variable rendimiento.

Según Arnaudo et al. (2017), la gran cantidad de factores que interactúan simultáneamente en la definición de zonas dificulta generar una diferenciación clara entre ellas, incluso al utilizar plataformas web que integran información sobre la productividad de los lotes para la gestión agrícola.

Estos resultados no son concluyentes para evaluar el correcto funcionamiento de la plataforma FieldView, ya que el estudio se realizó en un único lote y en un año específico. Sin embargo, evidencia la necesidad de revisar y mejorar los criterios de zonificación para aumentar la precisión en la identificación de áreas con diferentes niveles de calidad dentro del lote. Otro tema importante es conocer la respuesta a la densidad de cada híbrido en particular ya que en el mercado se encuentran múltiples opciones con genotipos más o menos plásticos que podrían distorsionar los resultados esperados en cada zona para condiciones locales. Además, subraya la importancia de desarrollar herramientas prácticas y económicas que validen los resultados de estas tecnologías y mejoren su implementación, con el fin de optimizar su aprovechamiento.

## Conclusiones

El rendimiento de maíz no presentó una asociación clara con las zonas definidas por la plataforma web de gestión agrícola FieldView.

Mediante la aplicación de conceptos básicos de estadística y un software libre, de código abierto, se logró verificar la calidad de una zonificación para el cultivo de maíz generada por dicha plataforma.

Este estudio no permite concluir sobre la efectividad de la plataforma para realizar zonificaciones, pero destaca la necesidad de mejorar los criterios de zonificación y de validar los resultados obtenidos. Para ello, es imprescindible además de conocer las virtudes y limitaciones de la plataforma, continuar desarrollando y perfeccionando herramientas prácticas y económicas para realizar esta validación.

## Agradecimientos

Se agradece a la empresa contratista Agustín Quattrocchio e Hijos SRL, encargados de realizar los servicios de siembra y cosecha del cultivo de maíz. También, y muy especialmente, a la empresa Schang por colaborar en la investigación.

## Referencias

Arnaudo, J. M., Marcili, M. J., & Passadore Venier, F. E. (2017). Zonificación y validación de zonas de manejo homogéneas (ZMH) en un lote del Sudeste Bonaerense (Bachelor's thesis).

CRAGM (2022). Centro Regional de Agrometeorología-FAA. Boletines. <https://cram.faa.unicen.edu.ar/>. Último acceso: Julio 2024.

Di Rienzo, J. A., Casanoves, F., Balzarini, M. G., Gonzalez, L., Tablada M., Robledo, C. W. (2019). InfoStat. Centro de Transferencia InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. <http://www.infostat.com.ar>

Landau, E. C., Brandão, Z. C., & Faria, C. M. (2014). Creación de mapas de manejo con datos espaciales (1 ed., Vol. 1). (E. C. Mantovani, & C. Magdalena, Edits.) Latinoamérica: Montevideo. [h/tps://repositorio.iica.int/handle/11324/2972](https://repositorio.iica.int/handle/11324/2972). Último acceso: agosto 2024.

Melchiori, R. J., Kemerer, A. C., & Albarenque, S. M. (2014). Interpretación de informaciones espacializadas y definición de unidades de manejo (1 ed., Vol. 1). (E. C. Mantovani, & C. Magdalena, Edits.) Latinoamérica: Montevideo. <https://repositorio.iica.int/handle/11324/2972>. Último acceso: julio 2024.

Scaramuzza, F. M., Villarroel, D. D., Olivo, S. M., Muñoz, S. A., Bianco Gaido, M. R., & Cuevas, L. E. (2022). Relevamiento de utilización de apps y/o plataformas digitales para la gestión de datos en el agro. Encuesta 2022. <https://repositorio.inta.gob.ar/handle/20.500.12123/12752>. Último acceso: agosto 2024.

Soil Survey Staff. (2014). Claves para la Taxonomía de Suelos (12 ed., Vol. 400). Departamento de agricultura de los Estados Unidos. <https://www.nrcs.usda.gov/sites/default/files/2022-10/Spanish-Keys-to-Soil-Taxonomy.pdf>. Último acceso: julio 2024.

Taylor, J. A., McBratney, A. B. & Whelan, B. M. (2007). Establishing Management Classes for Broadacre Agricultural Production. *Agronomy Journal*, 99(5), 1366-1376. <https://doi.org/10.2134/agronj2007.0070>

Vidosa, R., Iglesias, N. C., Jelinski, F. C., Tapia, M. E. & Lavarello, P. J. (2022). Reestructuración de la industria de maquinaria agrícola mundial: nuevos estándares frente a la agricultura 4.01. *SaberEs*, 14(1), 85-110.



21 y 22 DE AGOSTO de 2024  
EEA INTA MANFREDI



Villarroel, D., Scaramuzza, F., & Vélez, J. P. (2018). El progreso en la tecnificación del agro. (J. O. Maita, Ed.) Córdoba, Argentina. [https://www.academia.edu/39302358/Libro\\_Curso\\_AP](https://www.academia.edu/39302358/Libro_Curso_AP).



PLATINO



ORO



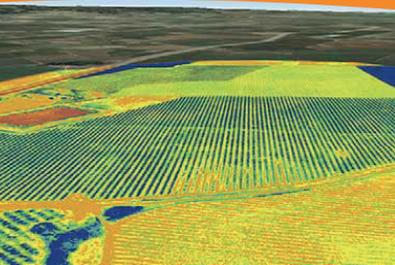
PLATA



BRONCE



COBRE



✉ congreso@nickel.com.ar

● ● Coordina y Comercializa:

**NICKEL**  
Comunicación | Marketing | Producción



**20° CONGRESO INTERNACIONAL  
AGRICULTURA DE PRECISIÓN**