


INFORME

ÁREA SEMBRADA, RINDES Y PRODUCCIÓN DE SOJA Y MAÍZ CAMPAÑA 2024/2025 PROVINCIA DE CÓRDOBA

NOVIEMBRE 2025

IDECOR - INFRAESTRUCTURA DE DATOS ESPACIALES
GOBIERNO DE LA PROVINCIA DE CÓRDOBA



RÍO
SEGUNDO

SAN
JUSTO

TERCERO
ARRIBA

GRAL.
SAN
MARTÍN

UNIÓN

MARCOS
JUAREZ

JUÁREZ
CELMAN

MAPA DE ÁREA SEMBRADA,
RINDES Y PRODUCCIÓN DE SOJA
Y MAÍZ, CAMPAÑA 2024/2025,
PROVINCIA DE CÓRDOBA

Organismos participantes

Desarrollo


Ministerio de Bioagroindustria de la Provincia de Córdoba. Secretaria de Agricultura y Recursos Naturales.

INTA Centro Regional Córdoba.

Infraestructura de Datos Espaciales de la Provincia de Córdoba (IDECOR), Ministerio de Economía y Gestión Pública de la Provincia de Córdoba.

Versión y Licencia

MAPA DE ÁREA SEMBRADA, RINDES Y PRODUCCIÓN DE SOJA Y MAÍZ, CAMPAÑA 2024/2025, PROVINCIA DE CÓRDOBA. Está distribuido bajo una Licencia Creative Commons Atribución 4.0 Internacional. Libre para compartir, distribuir, copiar y adaptar.



Citar como: Monzani F., Ferreiro, A.M., Córdoba M., Morales H., Fuentes, L. Mapa de Área Sembrada, Rindes y Producción de Soja y Maíz, Campaña 2024/2025, Provincia de Córdoba. Ministerio de Bioagroindustria de la Provincia de Córdoba. INTA Centro Regional e IDECOR. Noviembre de 2025.

Aviso de uso

Los datos del presente trabajo fueron desarrollados por el Ministerio de Bioagroindustria de la Provincia de Córdoba, INTA Centro Regional Córdoba e IDECOR para dar soporte a la gestión de políticas públicas del sector agropecuario. En su utilización deben tomarse las consideraciones técnicas que se derivan del presente informe.

El equipo de trabajo se desliga de cualquier uso indebido que pueda realizarse de los mapas y datos desarrollados fuera del ámbito para el cual fueron diseñados y/o sus características técnicas posibilitan, quedando estas otras aplicaciones bajo responsabilidad de los usuarios.

Contenido

Resumen Ejecutivo	3
1. Introducción	6
2. Relevamiento de datos a campo	7
3. Mapeo de cultivos estivales	8
3.1. Identificación de unidades de cultivo agrícola	8
3.1.1. Procesamiento del parcelario rural y generación de puntos semillas	8
3.1.2. Obtención de datos espectrales	9
3.1.3. Aplicación de algoritmo de segmentación	10
3.2. Construcción de mosaicos para la clasificación	10
3.3. Obtención y procesamiento de la muestra	11
3.4. Modelo de clasificación	14
3.5. Resultados obtenidos	15
4. Estimación de rendimientos por cultivo	17
4.1. Muestra utilizada	17
4.2. Variables utilizadas en los modelo de predicción de rendimientos	19
4.3. Modelos de aprendizaje computacional	19
4.4. Comparación de rendimientos de las últimas campañas	23
5. Estimación de la producción de soja y maíz	24
6. Pronósticos	31
7. Conclusiones	34
8. Referencias Bibliográficas	35
Anexo I. Variables utilizadas en el modelo de predicción de rendimientos	37
Anexo II - Modelos de Aprendizaje Computacional utilizados	41
Créditos. Equipo de trabajo	42

Resumen Ejecutivo

Este estudio forma parte de un programa sostenido desde 2020 que combina innovación tecnológica, trabajo en equipo y datos abiertos. La colaboración entre el Ministerio de Bioagroindustria, IDECOR e INTA Regional Córdoba ha permitido convertir a Córdoba en referente nacional en estimaciones agrícolas con base geoespacial, promoviendo una producción más eficiente y decisiones mejor informadas.

El presente informe expone los resultados y la metodología aplicada en el mapeo del área sembrada, la estimación de rendimientos y el cálculo de la producción agrícola de la provincia de Córdoba durante la campaña 2024/25.

De las 7,97 millones de hectáreas cultivables de la provincia (50% de la superficie total), el **59,8% se destinó a soja**, el **28,2% a maíz**, el **4,2% a maní** y el **7,8% a otros cultivos**. En conjunto, **soja y maíz concentran el 88% del área cultivada** total de la provincia.

El **rendimiento promedio de soja** fue de **32,5 qq/ha**, un **16% por encima del promedio de los últimos cinco años (27,4 qq/ha)**. En el caso del **maíz**, el rendimiento alcanzó **76 qq/ha**, lo que representa un **23% superior al promedio de los últimos cinco años (68 qq/ha)**.

La estimación se basó en **1.021 observaciones georreferenciadas** para esta campaña, que, sumadas a las registradas desde 2020, conforman una base de **8.334 observaciones**. Con base en un conjunto de **142 variables geográficas, topográficas, edafológicas, índice verde y datos climáticos**, se ajustaron modelos de aprendizaje computacional para predecir rendimientos sobre una grilla continua de 25 hectáreas.

Los **departamentos del sureste provincial** (Marcos Juárez, Unión y Tercero Arriba) mostraron los rendimientos más altos: más de 33 qq/ha en soja y más de 80 qq/ha en maíz. En contraste, en el **norte de Córdoba** los rindes de maíz fueron menores, entre 55 y 70 qq/ha.

En términos de producción, se estimaron **15,4 millones de toneladas de soja**, un **15% más** que en la campaña previa. En **maíz**, la producción alcanzó **16,9 millones de toneladas**, un **20% menos** que el año anterior. Este descenso puede atribuirse a la **reducción del 25% en el área sembrada**, factor que a su vez podría estar asociado al impacto de la chicharrita (*Dalbulus maidis*).

ÁREA SEMBRADA, RINDES Y PRODUCCIÓN DE SOJA Y MAÍZ

CAMPAÑA 2024/25. Provincia de Córdoba

TOTAL DE SUPERFICIE SEMBRADA

7.927.704 ha

OTROS CULTIVOS

12,06 %

MAÍZ

28,14 %

SOJA

59,80 %

76,01 QQ/ha

Rendimiento promedio
de MAÍZ

32,50 QQ/ha

Rendimiento promedio
de SOJA

1. Introducción

El **Ministerio de Bioagroindustria de la Provincia de Córdoba**, con el acompañamiento de **IDECOR** y la participación del **INTA Regional Córdoba**, puso en marcha a partir de la campaña **2020/21** un programa de **estimaciones agrícolas** que integra herramientas **geomáticas** y enfoques metodológicos innovadores. Con el paso de los años, esta iniciativa se consolidó como una pieza central para el **monitoreo de la producción**, brindando información a escala de **25 hectáreas** que resulta de gran utilidad para la toma de decisiones, tanto en organismos públicos como en el sector privado.

De acuerdo con los registros del Ministerio en las últimas **cinco campañas**, incluida la actual, la **soja** alcanzó un promedio de **27,42 qq/ha** y una producción de **13,9 millones de toneladas**, mientras que el **maíz** registró **68 qq/ha** con un total de **18,0 millones de toneladas**.

En la campaña **2024/25**, los resultados muestran una mejora: la soja promedió **32,5 qq/ha** sobre **4,7 millones de hectáreas** sembradas, generando una producción estimada de **15,4 millones de toneladas**, y el maíz obtuvo **76 qq/ha** en **2,23 millones de hectáreas**, con una producción de **16,9 millones de toneladas**.

El proceso de modelado puede sintetizarse en tres grandes etapas:

1- Mapeo del área sembrada y tipos de cultivo:

A través de un **modelo de segmentación**, se identifican de manera automática las **unidades espaciales mínimas de manejo agrícola**, cada una asignada a un único cultivo por campaña. Con el apoyo de **imágenes satelitales** y más de **25.000 datos de campo relevados**, se clasifica el tipo de cultivo presente en cada unidad.

2- Predicción y mapeo de rendimientos de soja y maíz:

Mediante **algoritmos de aprendizaje computacional**, se entrenan modelos con una muestra de **8.334 observaciones georreferenciadas** de las campañas **2020/21 a 2024/25**, combinadas con **148 variables territoriales**. Las predicciones se proyectan sobre una **grilla regular de 25 ha**, compuesta por **431.835 celdas**. Como innovación, en esta campaña se exploró la generación de **pronósticos** basados en información acumulada de años previos.

3- Estimación y mapeo de la producción:


La **producción agrícola** se determina multiplicando el **rendimiento estimado de cada celda** por la **superficie cultivada dentro de la misma**, permitiendo obtener valores agregados a diferentes escalas espaciales.

La continuidad de este programa, ya en su quinta edición, consolida la generación de información pública de alta calidad y detalle espacial, basada en técnicas geomáticas y de aprendizaje computacional que representan un salto cualitativo respecto de las estimaciones tradicionales. Sustentado en principios de transparencia y datos abiertos, constituye una herramienta clave para el diseño de políticas sectoriales y la toma de decisiones tanto públicas como privadas, fortaleciendo una gestión territorial basada en evidencia y orientada al bienestar de la sociedad.

2. Relevamiento de datos a campo

Las observaciones fueron recolectadas utilizando **Rindes Collect** (Figura N°1), una herramienta desarrollada por IDECOR para relevar y registrar datos georreferenciados de área cultivada y rendimientos agrícolas a nivel de campo.

Figura N°1. Pantallas de la App Rindes.



Fuente: IDECOR, 2025.

La plataforma permite geoposicionar información relevante para el estudio, incluyendo: Cultivo relevado, Cultivo antecesor, Fecha de siembra, Superficie sembrada, Rendimiento y Eventos climáticos que afectaron el rendimiento

La coordinación del relevamiento estuvo a cargo del equipo técnico de IDECOR, en conjunto con el Ministerio de Bioagroindustria, logrando recopilar 1.156 observaciones durante la campaña 2024/25. La participación incluyó al INTA Regional Córdoba, sus Agencias de Extensión, las Agencias Zonales del Ministerio —que aportaron el 83% de los datos— y colaboradores del sector privado. Estos registros se emplearon como datos muestrales en el mapeo de cultivos y la estimación de rendimientos (ver apartados 3.3 y 4.1). El relevamiento incorporó información sobre fechas de siembra y contingencias, registrándose un 8% de casos con eventos adversos (granizo, heladas o sequías). En cuanto a la distribución temporal, el 64% de las siembras fueron tempranas (septiembre a noviembre) y el 36% tardías (diciembre a enero) (**Figura N°2**).

Figura N°2. Distribución espacial de fechas de siembra (derecha).



Fuente: IDECOR, 2025.

3. Mapeo de cultivos estivales

El proceso de mapeo de cultivos estivales en la provincia de Córdoba se organizó en una serie de etapas sucesivas, diseñadas para asegurar precisión y consistencia en los resultados. En primer lugar, se llevó a cabo la **segmentación de unidades parcelarias** con el objetivo de delimitar unidades espaciales homogéneas que representen a los lotes agrícolas, adoptando un enfoque de clasificación orientada a objetos.

Esta elección metodológica respondió a la necesidad de trabajar con unidades de análisis compatibles con la escala y dinámica de los sistemas de producción extensiva de la provincia, donde los lotes constituyen la base de decisión productiva y de gestión. Posteriormente, se **construyeron mosaicos multitemporales** y se derivaron variables a partir de información espectral y de radar, con el fin de capturar la variabilidad fenológica y estructural de los cultivos.

En una tercera instancia, se procedió a la **obtención y procesamiento de las muestras de entrenamiento**, asegurando la representatividad de las principales coberturas agrícolas y minimizando posibles sesgos. A continuación, se aplicó el **modelo de clasificación** supervisada, que permitió identificar y cartografiar los distintos cultivos estivales presentes en la región de estudio.

Finalmente, se presentan los resultados obtenidos, que sintetizan la distribución espacial de los cultivos durante la campaña analizada y constituyen un insumo clave para la planificación territorial y la evaluación de la producción agropecuaria en Córdoba.

3.1. Identificación de unidades de cultivo agrícola

La unidad de análisis utilizada para la clasificación de cultivos en la provincia de Córdoba fue el lote agrícola, definido como una unidad espacial con comportamiento espectral homogéneo que aproxima a los límites reales de los lotes de producción extensiva. Dado que no existe un registro oficial georreferenciado de los lotes y estos no necesariamente coinciden con los límites catastrales, fue necesario implementar un proceso de segmentación sobre imágenes satelitales para delimitar dichas unidades.

Este proceso se desarrolló en tres etapas principales: primero, el procesamiento del parcelario y la generación de puntos semilla; segundo, la construcción de mosaicos multibanda; y finalmente, la aplicación del algoritmo “SNIC”: Simple Non-Iterative Clustering (R. Achanta & S. Susstrunk, 2017), permite subdividir las parcelas en unidades internas homogéneas y definir los lotes agrícolas a clasificar.

3.1.1. Procesamiento del parcelario rural y generación de puntos semillas

En primera instancia, se procesó la base parcelaria rural actualizada para toda la provincia de Córdoba (Figura 3.A), provista por la Dirección General de Catastro. Sobre este insumo se excluyeron aquellas parcelas con superficie menor a 5 ha, por no ser representativas para los cultivos extensivos analizados.

Luego se seleccionaron exclusivamente las parcelas con al menos 30 ha de superficie cultivada, correspondiente a las categorías 16 (cultivo extensivo anual) y 17 (cultivo anual irrigado) del [Mapa de Cobertura y Uso del Suelo 2022-2023](#) elaborado por IDECOR (2023). Las parcelas con superficies entre 5 y 30 ha se consideraron directamente como unidades indivisas, mientras que aquellas mayores a 30 ha fueron destinadas al proceso de segmentación interna.

Para la segmentación se generaron puntos semilla a razón de uno cada 30 ha de superficie cultivada, organizados en una malla regular de aproximadamente 546 m de lado (Figura 3.B), longitud equivalente al cuadrado de 30 ha. Estas semillas constituyen los puntos iniciales a partir de los cuales el algoritmo de segmentación agrupa píxeles vecinos, delimitando objetos con homogeneidad espectral y espacial.

La estrategia de distribución en malla regular permitió evitar la formación de superpíxeles excesivamente grandes o contiguos, asegurando a su vez una representación más adecuada de la heterogeneidad interna de las parcelas.

El procesamiento vectorial y la generación de las semillas se realizaron en R (R Core Team, 2023), utilizando el paquete *sf* (Pebesma, 2018; Pebesma & Bivand, 2023) para la lectura, manipulación y limpieza de datos espaciales.

3.1.2. Obtención de datos espectrales

Para la segmentación de los lotes agrícolas se construyeron mosaicos multibanda a partir de imágenes Sentinel-2 (Reflectancia de superficie) correspondientes a los meses de febrero y marzo de la campaña 2024–2025. Las imágenes se filtraron utilizando la capa Cloud Score+ S2_HARMONIZED V1 (Pasquarella et al., 2023), donde se seleccionó la banda *cs_cdf*, que representa la probabilidad de que un píxel esté libre de nubes, y se aplicó un umbral de 0,75, de modo que sólo se conservaron los píxeles con alta probabilidad de estar despejados. Esta elección de umbral permite eliminar nubes finas, bruma y sombras de cirros, asegurando que las mediciones espectrales utilizadas en la segmentación y generación de mosaicos sean confiables.

Una vez filtradas las imágenes de calidad, se calcularon medianas mensuales de las variables espectrales empleadas en la segmentación: el índice NDVI (Rouse et al., 1973) y las bandas B6, B7, B8 y B8A (740 nm, 783 nm, 842 nm y 865 nm de longitud de onda central respectivamente), seleccionadas por su capacidad de maximizar la diferenciación espectral entre lotes y minimizar la variabilidad intra-lote.

Para este paso de segmentación, se seleccionó un menor número de variables respecto al usado posteriormente en la clasificación, con el objetivo de evitar incorporar un gran número de variables que demanden mayor capacidad de cómputo y/o introduzcan fuentes de error.


3.1.3. Aplicación de algoritmo de segmentación

Con los mosaicos multibanda recortados a cada parcela, se aplicó el algoritmo Superpixel Non-Iterative Clustering (SNIC) (Achanta & Susstrunk, 2017). SNIC agrupa píxeles vecinos en regiones espectralmente homogéneas a partir de los puntos semilla, considerando tanto la proximidad espacial como la similitud espectral. Este enfoque preserva la estructura interna de la parcela y asegura que cada superpíxel representa un área con comportamiento espectral uniforme, evitando la mezcla de unidades heterogéneas.

Las imágenes de superpíxeles generadas para cada parcela se incorporaron a una colección global, formando un mosaico único que cubre la totalidad de la superficie cultivada de la provincia. Se aplicó un enmascaramiento de coberturas no agrícolas, quedando unidades homogéneas de aproximadamente 30 ha, coherentes con la escala de análisis de los cultivos extensivos. Las parcelas menores a 30 ha se incorporaron directamente como unidades indivisas.

Finalmente, se realizaron ajustes vectoriales y filtrado de outliers, fusionando polígonos contiguos con la misma clase de cultivo. El resultado final consistió en 220.000 unidades espaciales homogéneas, que constituyen la base para la clasificación supervisada, permitiendo representar de manera realista la heterogeneidad interna de los lotes y optimizar la precisión de los mapas de cultivo resultantes (Figura N°3.C).

Figura N°3. Esquema del proceso de segmentación. (A) Parcelas agrícolas a segmentar. (B) Distribución de los puntos semilla dentro de cada parcela. (C) Resultado de la segmentación en superpíxeles generados a partir de los puntos semilla.



Fuente: IDECOR, 2025.

3.2. Construcción de mosaicos para la clasificación

Para la clasificación de cultivos estivales se integró información óptica y de radar proveniente de los satélites Sentinel-2 y Sentinel-1, abarcando el período comprendido entre el 20 de septiembre de 2024 y el 30 de abril de 2025. Este intervalo incluye la totalidad del ciclo de los principales cultivos estivales de la región (maíz, soja y maní), desde la siembra y emergencia temprana hasta la madurez y cosecha. Con el fin de capturar la dinámica fenológica diferencial de cada especie, la serie temporal fue subdividida en seis intervalos clave: (1) 20/09 – 15/11, (2) 15/12 – 10/01, (3) 10/01 – 10/02, (4) 05/02 – 05/03, (5) 05/03 – 31/03 y (6) 31/03 – 30/04.

Para cada intervalo se calcularon valores de mediana, reduciendo la influencia de nubes, bruma y valores atípicos, y obteniendo una representación robusta de la respuesta espectral y radar de cada cultivo en cada etapa fenológica.

En el caso de Sentinel-2, se utilizaron imágenes nivel 2A corregidas a reflectancia de superficie. De cada mosaico temporal se seleccionaron las bandas B2 (490 nm), B3 (560 nm), B6 (740 nm), B11 (1610 nm) y B12 (2190 nm), junto con los índices espectrales NDVI, NDVIre2 (Gitelson & Merzlyak, 1997), MTCI (Dash & Curran, 2007) y EVI (Huete et al., 1994). La selección de estas bandas e índices responde a su reconocida capacidad para discriminar estadios de desarrollo y diferencias estructurales y fisiológicas entre los principales cultivos estivales.

En paralelo, se incorporó información de Sentinel-1 en órbita descendente. Se optó por este modo de adquisición debido a que ofrece una geometría de observación más estable para la región de estudio y mayor consistencia temporal, minimizando artefactos relacionados con diferencias en la trayectoria ascendente. Estas variables radar complementan la información óptica, aportando sensibilidad a la estructura de la vegetación, la rugosidad del suelo y el contenido de humedad, lo que resulta particularmente útil en presencia de nubosidad persistente durante etapas críticas del ciclo agrícola.

Para cada unidad espacial, se calcularon las medianas de todas las variables, tanto ópticas como de radar, a lo largo de los seis intervalos fenológicos. Este proceso permitió resumir la información original a nivel de píxel a una escala correspondiente a lotes agrícolas, lo que garantizó que la clasificación se definiera en unidades espaciales homogéneas. La integración de datos multiespectrales y multitemporal generó así un conjunto de variables predictoras robusto y representativo de la dinámica fenológica de los cultivos estivales, lo que optimizó la capacidad de discriminación del modelo de clasificación supervisada.

3.3. Obtención y procesamiento de la muestra

El entrenamiento y validación del modelo de clasificación requirió un conjunto de datos georreferenciados que identificaran el cultivo presente en cada lote. Para ello se integraron dos fuentes principales de información: datos recolectados en campo mediante la aplicación **Rinde Collect** (consultar apartado 2, Relevamiento de Campo) y **Recetas Fitosanitarias** provistas por la Secretaría de Agricultura y Recursos Naturales, del Ministerio de Bioagroindustria de la Provincia.

El banco de datos de Rinde Collect incluyó un total de 5.862 registros georreferenciados de las cinco campañas, comprendiendo desde 2019 a 2025 (Tabla N°1 y Figura N°4.A). En conjunto, abarcaron los principales cultivos de la región: maíz temprano (686), maíz tardío (1.754), soja (3.106), maní (201) y otros cultivos como girasol, sorgo y alfalfa (115). Para la campaña más reciente (2024–2025), se recolectaron 965 muestras, a las cuales se sumaron 39 muestras adicionales de maní aportadas por INTA-IPAVE (Figura N°4.B).


Tabla N°1. Tabla con cantidad de muestras recolectadas mediante la aplicación Rinde Collect, entre las campañas 2019–2020 y 2024–2025, discriminadas por cultivo (maíz, soja, maní y otros).

Campaña	Maíz	Soja	Maní	Otros	Total por campaña
2019-2020	691	771	49	17	1.528
2021-2022	593	811	44	27	1.475
2022-2023	461	646	40	18	1.165
2023-2024	374	344	7	4	729
2024-2025	321	534	22 (+ 39*)	49	1.004
Total por cultivo	2.440	3.106	201	115	5.862

*En la campaña 2024-2025 se incluyeron 39 muestras adicionales de maní aportadas por INTA-IPAVE.

Fuente: IDECOR, 2025.

Figura N°4. Distribución de muestras georreferenciadas recolectadas mediante la aplicación Rinde Collect entre las campañas 2019–2020 y 2024–2025, coloreadas por cultivo (maíz, soja, maní y otros). La imagen (A) presenta la distribución de las muestras desde 2019, mientras que la (B) únicamente muestra la campaña 2024-2025



Fuente: IDECOR, 2025.

En paralelo, se procesaron las recetas fitosanitarias correspondientes a las campañas 2023–2024 y 2024–2025. Estas recetas constituyen registros oficiales donde los productores declaran la aplicación de agroquímicos sobre parcelas específicas, generando así polígonos georreferenciados que representan el área tratada. Al tratarse de información declarativa, se aplicó un proceso de filtrado para garantizar la

consistencia de los datos: se eliminaron recetas que se superponían pero correspondían a cultivos distintos y aquellas con discrepancias superiores al 20% entre la superficie declarada y la estimada a partir de la geometría de los polígonos.


Luego del filtrado, se obtuvieron 14.100 polígonos para la campaña 2023–2024 y 9.728 para la campaña 2024–2025, sumando un total de **23.828 polígonos georreferenciados**, los cuales se utilizaron como muestra para determinar el cultivo presente en cada unidad espacial (Tabla N°2 y Figura N°5).

Tabla N°2. Tabla con cantidad de lotes con recetas fitosanitarias utilizados, diferenciados por campaña 2023–2024 y 2024–2025, y por cultivo (maíz, soja, maní y otros).

Campaña	Maíz	Soja	Maní	Otros	Total por campaña
2023-2024	4.490	8.894	71	645	14.100
2024-2025	1.749	5.576	1.579	824	9.728
Total por cultivo	6.239	14.470	1.650	1.469	23.828

Fuente: IDECOR, 2025.

Figura N°5. Distribución de muestras de lotes con recetas fitosanitarias de las campañas 2023-2024, y 2024-2025, coloreadas por cultivo (maíz, soja, maní y otros).



Fuente: IDECOR, en base a datos provenientes a Recetas Fitosanitarias, 2025.

Estos conjuntos representan una fuente confiable de información para el entrenamiento y validación del modelo de clasificación, garantizando que la identificación de los cultivos se base en áreas efectivamente trabajadas y con coherencia fenológica.

Finalmente, el repositorio de observaciones se conformó de la integración de las fuentes mencionadas, RindeCollect y Recetas Fitosanitarias, que se utilizaron para caracterizar espectralmente los principales cultivos extensivos de la provincia, usándose como verdad de campo, tanto en el entrenamiento como en la validación de los modelos de clasificación que se describen en el siguiente apartado.

3.4. Modelo de clasificación

Para la identificación de cultivos se aplicó un modelo de clasificación multiclase basado en el algoritmo Random Forest (Breiman, L. y Cutler, A., 2001). Este enfoque, ampliamente utilizado en teledetección, combina múltiples árboles de decisión contruidos sobre subconjuntos aleatorios de datos y variables, lo que permite reducir el sobreajuste y aumentar la capacidad predictiva.

La clasificación se implementó en un esquema orientado a objetos, donde la unidad de análisis fueron los lotes agrícolas previamente segmentados en lugar de píxeles individuales. Este enfoque permite integrar de manera más robusta la información espectral y fenológica sintetizada en cada unidad espacial, disminuyendo la variabilidad intra-lote y mejorando la consistencia de la clasificación.

El modelo se configuró con 500 árboles de decisión, un número que asegura estabilidad en las predicciones sin incrementar de manera significativa el costo computacional. Para cada división en los nodos, el número de variables consideradas se estableció en la raíz cuadrada del total de predictores, siguiendo la práctica estándar para problemas de clasificación multiclase.

El conjunto de datos se dividió de manera aleatoria en un 80% para entrenamiento y un 20% para validación, utilizando exclusivamente observaciones correspondientes a la campaña actual en esta última etapa. En total, el **modelo fue entrenado con 27.058 muestras** representativas de los principales cultivos de la región, mientras que la **validación se realizó con 1.960 muestras** independientes.

La capacidad de ajuste del modelo se evaluó mediante la elaboración de la matriz de confusión y el cálculo de indicadores de desempeño estándar: precisión global, precisión del productor y precisión del usuario.

Adicionalmente, se calculó el índice kappa como métrica complementaria para evaluar el grado de acuerdo entre la clasificación y los datos de referencia, más allá del azar.

3.5. Resultados obtenidos

El modelo desarrollado permitió estimar la distribución espacial de los principales cultivos estivales de la provincia durante la campaña 2024–2025, alcanzando un **89,72% de precisión global y un índice kappa de 0,83**, lo que refleja una alta capacidad de discriminación de las clases y una baja probabilidad de que los aciertos se deban al azar. La matriz de confusión mostró valores consistentes de precisión del productor y del usuario entre las distintas clases (Tabla N°3). El desempeño fue particularmente alto en soja (Precisión del productor: 96%; del usuario: 92%) y maní (96% y 88% respectivamente), mientras que maíz y el grupo “otros cultivos” presentaron precisiones levemente menores, aunque superiores al 83%.


Tabla N°3: Matriz de confusión para la clasificación de cultivos, campaña 2024-2025.

Especies cultivadas		Predicciones					Precisión del usuario
		Maíz	Soja	Maní	Otros	Total general	
Observ.	Maíz	342	61	4	3	410	83%
	Soja	33	1.074	6	9	1.122	92%
	Maní	6	26	255	3	290	96%
	Otros	6	13	0	119	138	87%
	Total general	387	1174	265	134	1.960	
Precisión del productor		88%	96%	88%	86%	Precisión global	90%

Fuente: IDECOR, 2025.

En términos de superficie cultivada (Figura N° 6), los resultados indican que la **soja** fue el cultivo predominante, con **4.740.704 ha (59,8%)**, seguida por **maíz con 2.232.500 ha (28,2%)**, de las cuales se diferenciaron las categorías de siembra temprana y tardía. Por su parte, el **maní alcanzó 334.648 ha (4,2%)**, mientras que los otros cultivos (girasol, sorgo, alfalfa, entre otros) abarcaron 619.992 ha (7,8%).

Figura N°6. Distribución del tipo de cultivo, campaña 2024-2025, provincia de Córdoba.



Fuente: elaboración propia.

4. Estimación de rendimientos por cultivo


La estimación de rendimientos agrícolas se llevó a cabo sobre una grilla regular de 25 hectáreas (celdas de 500 metros de lado), compuesta por 431.835 unidades espaciales. En cada celda se integraron 148 variables territoriales, organizadas en grandes categorías que incluyen topografía, clima, propiedades del suelo, cobertura vegetal y otros factores relevantes.

A partir de una muestra de rendimientos de campo, que incluyó los datos productivos en quintales por hectárea (qq/ha) para soja y maíz junto con las 148 variables mencionadas, se entrenó un modelo de regresión cuantílica aleatoria (QRF). El algoritmo demostró un ajuste satisfactorio y permitió predecir los rendimientos de ambos cultivos en toda la grilla del área sembrada.

4.1. Muestra utilizada

Luego de un proceso de depuración y considerando únicamente los cultivos de soja y maíz, se conformó un conjunto final de 1.021 registros. Estos datos, junto con las 7.313 observaciones recopiladas en campañas anteriores, sirvieron como base para estimar los rendimientos de la presente campaña. La Figura N°7 ilustra la distribución espacial de los datos utilizados.

Figura N°7 - Distribución espacial de las observaciones de campo utilizadas en el estudio.



Fuente: IDECOR, 2025.

Para predecir los rendimientos de soja y maíz para la campaña 2024/25 se utilizó una muestra compuesta por **8.348 observaciones a campo**, que abarcan las campañas 2020/21, 2021/22, 2022/23, 2023/24, 2024/25. La distribución temporal de las mismas está detallada en Tabla N°4.

Tabla N°4: Estadística descriptiva de *rendimientos* en qq/ha campañas 2020/21 a 2023/24.

Cultivo	Campaña	Media	Mín.	Máx.	Desv. Est.	P5	P95	Obs.
Maíz	2020/21	85	15	150	22	48	122	945
	2021/22	77	10	155	25	37	120	901
	2022/23	48	5	120	25	10	90	869
	2023/24	72	10	156	28	20	115	559
	2024/25	78	12	140	21	39	115	401
Soja	2020/21	34	4	58	9	18	48	1055
	2021/22	33	5	60	11	16	52	1255
	2022/23	17	2	50	8	5	33	1187
	2023/24	33	3	58	10	15	49	542
	2024/25	34	5	70	9	21	50	634

Fuente: IDECOR, 2025.

En la campaña 2024/25, los datos muestrales muestran un incremento en los rendimientos de ambos cultivos respecto a campañas anteriores. El maíz alcanzó un promedio de 78 qq/ha, con una variabilidad moderada (CV del 27%), superando los 72 qq/ha registrados en la campaña previa. Los resultados evidencian cierta estabilidad en comparación con años anteriores, aunque persisten contrastes relevantes entre lotes: mientras que el 5% más bajo de las observaciones no superó los 39 qq/ha, el 5% superior se ubicó por encima de los 115 qq/ha.

La soja, por su parte, registró un rendimiento promedio de 34 qq/ha, similares al de la campaña 2023/24, pero con una leve mejora en la homogeneidad productiva (CV del 26%). En este caso, el 5% de los lotes con menores rendimientos produjo menos de 21 qq/ha, mientras que el 5% superior superó los 50 qq/ha. En conjunto, los resultados de la muestra reflejan un año en el que ambos cultivos consolidaron su recuperación tras los fuertes impactos de las campañas 2022/23 y 2023/24, mostrando un regreso a situaciones más estables.

4.2. Variables utilizadas en los modelo de predicción de rendimientos

Para la generación de las predicciones, el modelo QRF se apoyó en un conjunto de 148 variables independientes, diseñadas para explicar el comportamiento de los rendimientos de soja y maíz, considerados como variables dependientes. El detalle y la definición de cada una de estas variables se incluyen en el Anexo I. Los valores fueron estimados y asignados a todas las celdas de la grilla de predicción mediante procedimientos consistentes con los aplicados en campañas previas, lo que asegura comparabilidad en el tiempo.

Las fuentes de información utilizadas para la construcción de estas variables fueron diversas e integraron tanto sensores remotos como bases de datos oficiales. Entre ellas se destacan imágenes satelitales de Landsat 8 y Sentinel-2, productos generados por INTA, información climática de MODIS y ECMWF ERA5, además de un amplio repertorio de datos temáticos y oficiales disponibles en la Infraestructura de Datos Espaciales (IDE) de la provincia.

4.3. Modelos de aprendizaje computacional

Para la estimación de rendimientos se entrenó un modelo de aprendizaje computacional del tipo Quantile Regression Forest (QRF) (Meinshausen, 2006). Este enfoque pertenece a la familia de los modelos de bosques aleatorios y se caracteriza por su capacidad para estimar no solo un valor promedio de la variable dependiente, sino también su distribución condicional completa, lo que permite obtener cuantiles específicos. En el contexto agrícola, esta característica resulta especialmente útil, ya que brinda información no solo sobre el rendimiento esperado, sino también sobre la variabilidad y el rango de valores posibles para cada unidad espacial. De esta manera, es posible evaluar no solo el nivel medio de los rendimientos, sino también la incertidumbre y el riesgo asociado a los mismos, aspecto clave para la toma de decisiones en la gestión agrícola.

La capacidad predictiva del modelo fue evaluada a través de un proceso de validación cruzada. En este procedimiento, la muestra de observaciones se divide aleatoriamente en 10 grupos de tamaño similar. Posteriormente, se selecciona uno de estos grupos como conjunto de prueba, mientras que los otros nueve se utilizan para entrenar el modelo. Una vez entrenado, se evalúa el desempeño del modelo prediciendo los valores del grupo reservado. Este proceso se repite iterativamente hasta que todos los grupos hayan sido utilizados como conjunto de prueba. Con este enfoque, cada observación es validada de manera independiente, lo que permite obtener una estimación robusta del error de predicción y de la capacidad del modelo para generalizar más allá de la muestra de entrenamiento.

En conjunto, la aplicación del modelo QRF y la validación cruzada aportan una metodología sólida para estimar rendimientos agrícolas, al integrar la riqueza de múltiples variables explicativas con un marco estadístico que captura tanto el valor esperado como la incertidumbre y dispersión inherentes a los sistemas productivos.

En la Tabla N°5 se muestra el ajuste del modelo para los distintos años que existe en la muestra.

Tabla N°5: Resumen estadísticos de los rendimientos observados y predichos de maíz y soja para las campañas 2020/21 a 2024/25, junto con indicadores de error como MAPE (Error Porcentual Absoluto Medio) y RMSE (Raíz del Error Cuadrático Medio).

Cultivo	Campaña	Rend. Observado (qq/ha)	Rend. Predicho (qq/ha)	Observaciones	MAPE	RMSE
Maíz	2020/21	84,5	83,7	945	16%	15,20
	2021/22	76,5	76,4	901	22%	16,70
	2022/23	47,7	48,0	869	56%	17,70
	2023/24	72,2	72,6	559	23%	14,30
	2024/25	78,6	78,6	387	21%	16,60
Soja	2020/21	33,5	33,5	1.055	19%	6,59
	2021/22	32,8	32,9	1.255	20%	6,82
	2022/23	16,7	17,0	1.187	45%	6,31
	2023/24	32,9	32,9	542	22%	6,70
	2024/25	34,1	34,2	634	18%	6,70

Fuente: IDECOR, 2025.

De lo informado en Tabla 4 sobre la última campaña (2024/25), se observa lo siguiente:


- Para **maíz**, el rendimiento observado fue de **78,6 qq/ha**, exactamente igual al rendimiento predicho por el modelo, mostrando una muy buena precisión. El MAPE es del **21%**, levemente inferior a la campaña anterior, lo que indica que el modelo sigue siendo confiable incluso con menor número de observaciones (**387 puntos**, menos que en años previos). Esto es notable, ya que en comparación con la campaña **2022/23**, donde hubo una **sequía importante** y el MAPE subió al **56%**, en la actual campaña el modelo logra un mejor desempeño que se relaciona con condiciones normales de producción.
- Para **soja**, el rendimiento observado fue de **34,1 qq/ha**, también muy cercano al predicho (**34,2 qq/ha**), con un MAPE del **18%**, el más bajo desde 2020/21. Esto refleja una predicción confiable. La campaña 2022/23, afectada por sequía, tuvo un rendimiento mucho menor (**16,7 qq/ha**) y un MAPE alto (**45%**), lo que muestra cómo eventos climáticos extremos aumentan la incertidumbre y el error del modelo.

En otras palabras, la campaña 2024/25 se puede considerar “normal” o “de referencia”: los rendimientos recuperan niveles más altos y estables, y los modelos de predicción logran ajustarse de manera más precisa. Comparando con 2022/23, donde las contingencias climáticas provocaron rendimientos bajos y errores de predicción mayores, en la última campaña se evidencia que, cuando las condiciones son favorables, los modelos predictivos reflejan de manera más precisa la realidad a campo.

4.4. Resultados obtenidos

El modelo desarrollado permitió estimar los rendimientos de soja y maíz en toda el área sembrada de la provincia. En el caso de la **soja**, alcanzó un rendimiento promedio de **32,50 qq/ha**, con un CV del **13%**, siendo que los valores extremos de la distribución mostraron rendimientos mínimos cercanos a **8,00 qq/ha** y máximos de **57,32 qq/ha**, que refleja la diversidad de escenarios productivos que conviven dentro del territorio provincial (Figuras N°8).


Figura N°8. Mapa de rendimiento de soja a nivel de 25 ha, campaña 2023-24.



Fuente: IDECOR, 2025.

En **maíz**, el rendimiento promedio estimado fue de **76,01 qq/ha**, con un coeficiente de variación (CV) relativamente bajo del **12,80%**, lo que indica una variabilidad comparable a la de soja. Los valores predichos oscilaron entre un mínimo de **26,92 qq/ha** y un máximo de **121,59 qq/ha**, mostrando una amplitud de situaciones productivas (Figura N° 9).

Figura N°9. Mapa de rendimiento de maíz a nivel de 25 ha, campaña 2023-24.



Fuente: IDECOR, 2025.

La siguiente Tabla N°5 presenta un resumen estadístico de la predicción para ambos cultivos.

Tabla N°5. Estadística descriptiva de la predicción de los rendimientos por cultivo.

Cultivo	Media (qq/ha)	CV (%)	Min	Max
Maíz	76,01	12,80	26,92	121,59
Soja	32,50	13,00	8,00	57,32

Fuente: IDECOR, 2025.


4.4. Comparación de rendimientos de las últimas campañas¹

La Figura 10 muestra la comparación de los rendimientos estimados para la campaña 2025 de maíz (izquierda) y soja (derecha) respecto del promedio de las cuatro campañas anteriores (2021–2024). Los valores se expresan como un cociente entre el rendimiento actual y el promedio histórico reciente, de manera que:

- valores menores a 0,90 indican una disminución del rendimiento,
- valores entre 0,90 y 1,10 reflejan una estabilidad sin cambios relevantes, y
- valores superiores a 1,10 señalan un aumento del rendimiento.

La resolución espacial de 25 ha permitido apreciar con mayor detalle la distribución territorial de estas variaciones, revelando contrastes dentro de cada zona agrícola y aportando una visión más detallada de la dinámica productiva en la provincia en los últimos años.

Figura N°10. variación de los rendimientos estimados para la campaña 2025 de maíz (izquierda) y soja (derecha) respecto del promedio de las cuatro campañas anteriores (2021–2024).



Fuente: IDECOR, 2025.

¹ En el promedio no se incluye la presente campaña.

5. Estimación de la producción de soja y maíz

A partir del modelo de clasificación de cultivos, se identifican los píxeles de 10 m de resolución provenientes de imágenes Sentinel. Estos píxeles se intersectan con la grilla de 25 ha, lo que permite estimar la proporción de superficie sembrada con soja y maíz en cada celda.

Posteriormente, la superficie sembrada en cada unidad de 25 ha se multiplica por el rendimiento estimado (expresado en qq/ha) de esa misma unidad, obteniendo así la producción por celda en toneladas.

La suma de la producción de todas las celdas brinda la producción total de soja y maíz, mientras que la agregación de las superficies permite determinar la superficie total sembrada por cultivo, tal como especifica la siguiente expresión:

$$Prod_{25ha} = \sum_{i=1} R_i S_i P_i$$

Donde:

- Prod: producción de la cuadrícula de 25 ha,
- R: rendimiento en qq/ha de la cuadrícula de 25 ha,
- S: superficie sembrada de soja o maíz en la cuadrícula de 25 ha.

Los resultados obtenidos para la campaña agrícola 2024/25 en la provincia de Córdoba evidencian el desempeño sobresaliente de los dos principales cultivos extensivos: maíz y soja.

El **maíz** alcanzó una superficie implantada de **2.232.283 hectáreas**, con un **rendimiento medio de 76,01 qq/ha** y una **producción total estimada en 16.967.583 toneladas**. Este desempeño confirma la alta productividad del cereal en los departamentos del centro y sureste provincial.

Por su parte, la **soja** consolidó su liderazgo en superficie sembrada, con **4.740.586 hectáreas**, y alcanzó un **rendimiento promedio de 32,50 qq/ha**, lo que equivale a una **producción estimada de 15.406.905 toneladas**.

Este resultado representa una mejora significativa respecto a campañas anteriores, atribuible a condiciones climáticas más favorables

La Tabla N°6 presenta la superficie sembrada, el rendimiento promedio en quintales por hectárea (qq/ha), la producción total en toneladas (Tn) y la relación entre el rendimiento de la campaña 2025 y el promedio de las últimas cuatro campañas (2021-2024), a nivel departamental, para el cultivo de Soja.

La Tabla N°6. Soja. Superficie sembrada, producción y rendimiento a nivel departamental, variación del rendimiento en relación al rendimiento promedio de las últimas 4 campañas a nivel departamental (campaña 2025/21-24).


Departamento	Superficie en ha	Rendimiento qq/ha	Producción (tn)	Rendimiento 2025 / Rendimiento promedio (21-24)
Calamuchita	46.851	32,16	150.696	1,30
Capital	231	30,25	698	1,36
Colón	76.474	32,38	247.602	1,25
Cruz Del Eje	981	29,41	2.883	1,65
General Roca	403.757	32,61	1.316.825	1,15
Gral. San Martín	162.068	28,44	460.888	1,26
Ischilín	7.822	30,91	24.173	1,35
Juárez Celman	288.881	33,84	977.644	1,15
Marcos Juarez	472.235	41,69	1.968.766	1,23
Pocho	6.623	32,51	21.530	1,88
Pte. Roque Saenz Peña	253.624	34,37	871.685	1,11
Punilla	87	32,64	283	1,55
Rio Seco	75.655	30,21	228.562	1,19
Río Cuarto	732.557	32,19	2.358.356	1,13
Río Primero	343.206	31,64	1.085.738	1,34
Río Segundo	260.013	32,09	834.313	1,29
Sobremonte	331	28,92	958	1,31
San Alberto	8.311	30,46	25.318	1,78
San Javier	3.540	29,68	10.508	1,57
San Justo	529.086	33,02	1.747.120	1,25
Santa María	113.943	33,11	377.220	1,38
Tulumba	96.854	30,66	296.967	1,24
Tercero Arriba	272.506	33,81	921.400	1,33
Totoral	119.742	31,95	382.631	1,30
Unión	421.361	36,07	1.520.051	1,18

Fuente: IDECOR, 2025.

En conjunto, los resultados reflejan un aumento generalizado del rendimiento, lo que permitió alcanzar volúmenes de producción muy superiores al promedio histórico reciente.

La Figura N°11 muestra la producción de soja en la provincia de Córdoba para la campaña 2025, distribuida por pedanías. Los colores representan rangos de producción, desde áreas con menos de 1.000 toneladas hasta aquellas con más de 1 millón de toneladas.

Figura N°11. Producción de soja 2025 por pedanías en la provincia de Córdoba (en toneladas).



Fuente: IDECOR, 2025.


Las pedanías en el noreste, sureste y sur de la provincia presentan las producciones más altas, superando 1 millón de toneladas, reflejando áreas de alta densidad agrícola y favorable disponibilidad de recursos hídricos y suelo.

En el centro-norte y oeste se observan pedanías con producciones intermedias, entre 50.000 y 500.000 toneladas, zonas donde la superficie cultivada es menor o los

rendimientos son moderados. Las zonas coloreadas en gris corresponden a áreas no productivas

La Figura N°12 presenta la variación en la producción y en la superficie sembrada de soja durante la campaña 2024/25 en comparación con el promedio de las cuatro campañas previas (2020/21 a 2023/24). Estos mapas permiten identificar las diferencias territoriales en el comportamiento del cultivo a nivel de pedanía.

Figura N°12. Refleja los cambios en la producción (izquierda) y superficie (derecha) de soja en la provincia por departamento durante la campaña 2024-25.



Fuente: IDECOR, 2025.

El mapa de la izquierda muestra la variación en la producción de soja, mientras que el de la derecha refleja la superficie cultivada. Se observa un aumento en la superficie de soja en muchas zonas, particularmente en el noreste de la provincia, asociado a la disminución de la superficie de maíz afectada por la chicharrita del maíz.

Esta tendencia es más marcada en áreas donde la siembra de maíz se realiza tardíamente, lo que coincide con el período de mayor actividad de la plaga, generando una reducción del rendimiento y motivando el reemplazo por soja. Las zonas en rojo indican disminuciones, en gris donde no hubo cambios significativos y en gris claro aquellas áreas no productivas.

La Tabla N°7 presenta la superficie sembrada, el rendimiento promedio en quintales por hectárea (qq/ha), la producción total en toneladas (Tn) y la relación entre el rendimiento de la campaña 2025 y el promedio de las últimas cuatro campañas (2021-2024), a nivel departamental, para el cultivo de maíz.

Tabla N°7. Maíz. Superficie sembrada, producción y rendimiento a nivel departamental, variación del rendimiento en relación al rendimiento promedio de las últimas 4 campañas a nivel departamental (campaña 2025/21-24).

Dpto.	Superficie en ha	Rendimiento qq/ha	Producción (tn)	Rendimiento 2025 / Rend. prom. (21-24)
Calamuchita	19.777	78,52	155.284	1,20
Capital	99	76,99	761	1,17
Colón	32.512	75,23	244.603	1,09
Cruz Del Eje	212	55,60	1.181	1,15
General Roca	261.144	72,61	1.896.049	1,12
Gral. San Martín	76.989	74,05	570.116	1,26
Ischilín	4.272	68,80	29.393	1,15
Juárez Celman	173.395	78,15	1.355.123	1,09
Marcos Juárez	182.488	94,63	1.726.960	1,08
Pocho	4.355	57,98	25.248	1,26
Pte. Roque Saenz Peña	128.044	80,26	1.027.641	1,03
Punilla	155	64,82	1.003	1,20
Río Seco	32.450	60,10	195.010	1,19
Río Cuarto	478.357	74,25	3.551.925	1,08
Río Primero	97.833	74,14	725.299	1,21
Río Segundo	98.233	78,16	767.797	1,15
Sobremonte	44	52,16	232	1,09
San Alberto	4.925	59,20	29.156	1,20
San Javier	2.692	59,49	16.012	1,09
San Justo	144.499	74,56	1.077.321	1,30
Santa María	41.713	79,03	329.649	1,12
Tulumba	35.707	66,78	238.447	1,30
Tercero Arriba	121.793	82,39	1.003.493	1,14
Totoral	59.101	71,42	422.091	1,15
Unión	186.408	87,49	1.630.876	1,13

Fuente: IDECOR, 2025.


Durante esta campaña, los departamentos con mayores superficies sembradas fueron **Río Cuarto** (478.357 ha), **Marcos Juárez** (182.488 ha) y **Juárez Celman** (173.395 ha), concentrando una proporción significativa de la producción provincial. En términos de rendimiento, los departamentos con los valores más altos fueron **Marcos Juárez** (94,63 qq/ha) y **Unión** (87,49 qq/ha), mientras que los rendimientos más bajos se registraron en **Sobremonte** (52,16 qq/ha) y **Pocho** (57,98 qq/ha).

La producción total refleja tanto la superficie sembrada como los rendimientos, se destacan Río **Cuarto** con 3.551.925 toneladas y **Marcos Juárez** con 1.726.960 toneladas.

Al analizar la relación entre el rendimiento 2025 y el promedio de los últimos cuatro años, se observa que la mayoría de los departamentos registraron rendimientos superiores al promedio histórico.

La Figura N°13 muestra la distribución espacial de la producción de maíz a nivel de pedanía.

Figura N°13. Producción de maíz por pedanía.




Fuente: IDECOR, 2025.

El mapa evidencia una marcada concentración de la producción de maíz en el centro y sudeste de Córdoba, donde las condiciones de suelo, clima e infraestructura favorecen rendimientos superiores al millón de toneladas por pedanía. En contraste, las zonas del centro-norte y este presentan valores intermedios, mientras que el noroeste y oeste registran los niveles más bajos (menos de 50 mil toneladas), reflejando la heterogeneidad territorial y las diferencias de aptitud agrícola en la provincia.

La Figura N°14 presenta la variación en la producción y en la superficie sembrada de maíz durante la campaña 2024/25 en comparación con el promedio de las cuatro campañas previas (2020/21 a 2023/24). Estos mapas permiten identificar las diferencias territoriales en el comportamiento del cultivo a nivel de pedanía.

Figura N°14. Variación relativa de la producción (izquierda) y de la superficie sembrada (derecha) de maíz en la campaña 2024/25 respecto al promedio de las campañas 2020/21 a 2023/24, a nivel de pedanía.



Fuente: IDECOR, 2025.

Los mapas muestran una disminución generalizada en la producción y la superficie sembrada de maíz en la provincia, con predominio de valores negativos en la mayor parte del territorio. Aunque los rendimientos fueron superiores al promedio histórico (76 qq/ha frente a 68 qq/ha), la caída en la producción se explica principalmente por la **reducción del área sembrada**, especialmente en el centro y norte provincial, decisión tomada por muchos productores ante el impacto de la chicharrita registrado en la campaña anterior.

6. Pronósticos


Durante la campaña 2024/25 se desarrollaron pruebas de pronóstico de rendimientos de soja y maíz capitalizando la información recolectada en las **cuatro campañas previas (2020/21 a 2023/24)**. Esta base histórica de datos permitió entrenar modelos predictivos más robustos, integrando series temporales de variables climáticas y de vegetación obtenidas del Google Earth Engine (GEE). Entre ellas se incluyeron precipitaciones, temperatura, humedad del suelo y evapotranspiración (provenientes de ERA5), junto con índices de vegetación MODIS como NDVI, EVI y MSAVI, que capturan la evolución del estado de los cultivos durante los meses críticos del ciclo agrícola.

Asimismo, se incorporaron variables edáficas y topográficas –capacidad de uso del suelo (INTA), relieve (IGN) y mapas elaborados por IDECOR sobre cobertura, textura, materia orgánica y pH– que aportan contexto territorial a las estimaciones. La combinación de estas fuentes, junto con la experiencia acumulada de campañas anteriores, permitió **proyectar tempranamente la distribución espacial de los rendimientos** sobre una grilla de 25 hectáreas, fortaleciendo el análisis regional y la capacidad de anticipación frente a variaciones productivas.

La Figura N°15 presenta la evolución de los rendimientos estimados de **maíz** durante la campaña 2024/25, a partir de los pronósticos mensuales correspondientes a **febrero, marzo y abril de 2025**.

Cada mapa muestra la distribución espacial del rendimiento proyectado, expresado en quintales por hectárea (qq/ha), sobre una resolución de 25 ha.

Figura N°15. Rendimientos estimados de maíz (qq/ha) para febrero, marzo y abril de 2025 en la provincia de Córdoba. Pronósticos generados a partir de modelos entrenados con información climática, de vegetación y de suelo.



Fuente: IDECOR, 2025.


En cuanto a la evolución temporal los rendimientos se observa lo siguiente:

- **Febrero 2025:** los valores estimados se concentran mayormente en rangos bajos a intermedios (<60 qq/ha), con áreas de menor productividad en el norte y oeste de la provincia.
- **Marzo 2025:** se mantiene una distribución heterogénea, pero comienzan a diferenciarse con mayor claridad las zonas de mejor desempeño en el sudeste y sur provincial, con rendimientos superiores a 80 qq/ha.
- **Abril 2025:** las proyecciones consolidan una tendencia hacia mayores rendimientos en el centro-sur y sudeste, mientras que las áreas del norte y noroeste se mantienen en los rangos bajos, reflejando el efecto de condiciones ambientales menos favorables.

En conjunto, estos mapas permiten visualizar cómo las predicciones mensuales capturan la evolución espacial del maíz durante el ciclo del cultivo, proporcionando una herramienta temprana para anticipar la distribución de la producción y analizar diferencias regionales dentro de la provincia.

La Figura N°16 muestra la evolución de los **rendimientos estimados de soja** durante la campaña 2024/25, a partir de los pronósticos mensuales correspondientes a **febrero, marzo y abril de 2025**. Los valores están expresados en quintales por hectárea (qq/ha), con una resolución espacial de 25 ha.

Figura N°16. Rendimientos estimados de soja (qq/ha) para febrero, marzo y abril de 2025 en la provincia de Córdoba. Pronósticos generados a partir de modelos que integran información climática, de vegetación y de suelo.



Fuente: IDECOR, 2025.

En cuanto a la evolución temporal los rendimientos se observa lo siguiente:

- **Febrero 2025:** predominan valores intermedios (20–30 qq/ha), con menores rendimientos en el norte provincial.
- **Marzo 2025:** se intensifican las áreas con mejores rendimientos, especialmente en el centro y sudeste, donde se registran zonas mayores a 35 qq/ha.
- **Abril 2025:** se consolidan los rendimientos altos en el sudeste y sur de la provincia (>40 qq/ha), mientras que el norte y noroeste mantienen niveles más bajos, por debajo de 25 qq/ha.

En conjunto, los mapas evidencian cómo las proyecciones mensuales permiten seguir la dinámica temporal del cultivo de soja, mostrando un aumento gradual de los rendimientos hacia el final de la campaña y resaltando diferencias regionales claras entre el norte y el sudeste provincial.

Para evaluar la robustez de los pronósticos, se consideró un doble enfoque metodológico. En primer lugar, se aplicó un modelo **sin incluir los datos de la campaña 2024/25**, lo que permitió utilizarlos como una muestra independiente para validar externamente el desempeño del modelo. Bajo este esquema, los valores de error alcanzaron un **MAPE del 26% y un RMSE de 20,2 en maíz**, mientras que en soja se registró un **MAPE del 22% y un RMSE de 7,57**.

Posteriormente, al **incorporar los datos de la campaña 2024/25** en el entrenamiento del modelo y aplicar la técnica de **validación cruzada**, se observaron mejoras significativas en los indicadores de precisión. En este caso, el **MAPE se redujo al 21% en maíz y al 18% en soja**, mientras que el **RMSE descendió a 16,6 y 6,7**, respectivamente.

En la comparación de ambos enfoques se observa que los valores de error obtenidos **sin considerar las observaciones de la campaña 2024/25** resultan muy similares a los calculados cuando la campaña es incluida en el entrenamiento mediante validación cruzada. Esto indica que los modelos mantienen un desempeño estable y confiable aun cuando se evalúan con datos completamente externos, lo que refuerza la validez de los pronósticos de rendimiento generados para la campaña analizada.

En conjunto, los resultados muestran que los modelos permiten proyectar la evolución mensual de los rendimientos de soja y maíz, identificando con antelación las diferencias regionales más relevantes. Al mismo tiempo, los indicadores de ajuste evidencian que el desempeño del modelo se mantiene estable aun cuando se lo evalúa con datos externos, lo que respalda la confiabilidad de los pronósticos.

Estos resultados reflejan la utilidad de los pronósticos mensuales para anticipar la evolución del cultivo y detectar zonas con contrastes productivos significativos. De esta manera, se facilita la planificación y el análisis regional del desempeño agrícola en la campaña 2024/25.

7. Conclusiones

El presente informe constituye la quinta edición consecutiva del programa provincial de estimaciones agrícolas, desarrollado de manera conjunta entre el **Ministerio de Bioagroindustria de la Provincia de Córdoba, IDECOR e INTA Regional Córdoba**. La continuidad de esta iniciativa ha permitido construir una base sólida de información agroproductiva, fortaleciendo la capacidad institucional para monitorear la evolución de los cultivos estratégicos y orientar políticas públicas basadas en evidencia.

Los resultados de la campaña 2024/25 muestran un escenario productivo favorable y consolidan la madurez metodológica alcanzada por el programa. Con rendimientos promedios de **32,50 qq/ha en soja y 76,01 qq/ha en maíz**, la provincia reafirma su liderazgo agrícola y la capacidad de sostener altos niveles de productividad. Estas estimaciones, elaboradas a partir de una extensa base de más de **8.000 observaciones georreferenciadas**, ofrecen una visión integral de la campaña y un insumo de alto valor para la planificación sectorial.

Un aspecto destacado del informe es la **posibilidad de comparar los resultados actuales con los de las cuatro campañas anteriores**, lo que permite evaluar tendencias, variaciones espaciales y efectos de factores climáticos y de manejo. Este análisis comparativo aporta una lectura más profunda sobre la dinámica productiva provincial, revelando patrones de estabilidad, recuperación o ajuste en distintas regiones y sistemas productivos. La capacidad de realizar estas comparaciones constituye uno de los principales activos del programa, al posibilitar el seguimiento continuo y la evaluación de políticas en el tiempo.

Asimismo, la **incorporación de pronósticos de rendimiento** representa un avance significativo hacia la anticipación de escenarios productivos. El aprovechamiento de la información histórica, combinada con nuevos insumos climáticos y de vegetación, permitió generar predicciones tempranas que refuerzan la utilidad práctica del sistema. Estos pronósticos abren el camino hacia un esquema de monitoreo preventivo, capaz de orientar la toma de decisiones en etapas críticas del ciclo agrícola.

Desde una perspectiva institucional, este trabajo reafirma el valor de la cooperación entre organismos provinciales, nacionales y del sistema científico-técnico. La sostenibilidad del programa y su orientación a la apertura de datos fortalecen la transparencia y promueven la construcción colectiva de conocimiento, en beneficio del sector agroindustrial y de la sociedad cordobesa en su conjunto. Dado que no sólo se reflejan los resultados productivos de la campaña, sino también el fortalecimiento de un modelo de gestión pública sustentado en información confiable, comparaciones continuas y capacidades predictivas que mejoran la planificación y la toma de decisiones en el ámbito agropecuario.

8. Referencias Bibliográficas

- Achanta, R., & Susstrunk, S. (2017). Superpixels and polygons using simple non-iterative clustering. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4651-4660).
- Bishop, Y.M.; Fienberg S.E.; Holland P.W. (1975). Discrete Multivariate Analysis Theory and Practice, MIT Press, Carnbridge, Massachusetts, 557 p.
- Breiman, L. (2001). Random forests. Machine learning, 45(1), 5–32.
- Canny, J. (1986). A computational approach to edge detection. IEEE Transactions on pattern analysis and machine intelligence, (6), 679-698.
- Cortes, C.; Vapnik, V. (1995). Support-vector networks. Machine Learning, 20(3), 273–297.
- Dash J., Curran P. (2007) Evaluation of the MERIS terrestrial chlorophyll index (MTCI). Adv. Space Res., 39: 100–104.
- Friedman, JH (2001). Aproximación de funciones codiciosas: una máquina de aumento de gradiente. Anales de estadística, 1189-1232.
- Gelder, B. K.; Kaleita, A. L.; Cruse, R. M. (2009). Estimating mean field residue cover on midwestern soils using satellite imagery. Agronomy journal, 101(3), 635-643.
- Gitelson A A, Merzlyak M. (1997) Remote estimation of chlorophyll content in higher plant leaves. Int. J. Remote Sens., 18: 2691–2697.
- Guyot, G.; Baret, F.; Major, D. J. (1988). High spectral resolution: determination of spectral shifts between the red and near infrared. In ISPRS Congress.
- Haralick, R. M.; Shanmugam, K.; Dinstein, I. H. (1973). Textural features for image classification. IEEE Transactions on systems, man, and cybernetics, (6), 610-621.
- Huete, A.; Justice, C.; Liu, H. (1994). Development of vegetation and soil indices for MODIS-EOS. Remote Sensing of Environment, 49, 224–234.
- IDECOR. (2023). Mapa de Cobertura y Uso de Suelo de la Provincia de Córdoba 2022-2023. Infraestructura de Datos Espaciales de Córdoba.
- Jamalabad, M. S.; Abkar, A.A. (2004). Forest Canopy Density Monitoring, Using Satellite Images. XXth ISPRS Congress, Istanbul 12-23 July.
- Meinshausen, N. (2006). Quantile regression forests. Journal of Machine Learning Research, 7(Jun), 983–999.
- Monzani, F., Pozzi Tay, E., Mariño, F., Córdoba, M., & Morales, H. (2024). Mapa de Área Sembrada, Rindes y Producción de Soja y Maíz, Campaña 2023/2024, Provincia de Córdoba. Ministerio de Bioagroindustria de la Provincia de Córdoba. INTA Centro Regional e IDECOR. <https://mapascordoba.gob.ar/viewer/mapa/535>
- Pasquarella, V. J., Brown, C. F., Czerwinski, W., & Rucklidge, W. J. (2023). Comprehensive quality assessment of optical satellite imagery using weakly

supervised video learning. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, 2023, pp. 2125-2135.

Pebesma, E. (2018). Simple Features for R: Standardized support for spatial vector data. The R Journal, 10(1), 439-446.

Pebesma, E., & Bivand, R. (2023). Spatial Data Science: With applications in R. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429459016>

QGIS Development Team. (2021). QGIS Geographic Information System. Open Source Geospatial Foundation (Version 3.16). En <http://qgis.osgeo.org>

R Core Team. (2023). R: A language and environment for statistical computing. R Foundation for Statistical Computing. <https://www.R-project.org>

Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. (1973): Monitoring vegetation systems in the great plains with ERTS. Third 80 ERTS Symposium, NASA SP-351, pp. 309-317.

Xu, H. (2005): A Study on Information Extraction of Water Body with the Modified Normalized Difference Water Index (MNDWI). Journal of Remote Sensing. 9: 589-595.

Anexo I. Variables utilizadas en el modelo de predicción de rendimientos

Variable	Descripción
altura_median	Mediana de la altura (msnm)
altura_stdev	Desvío estándar de la altura (msnm)
pend_median	Mediana de la pendiente (%)
pend_stdev	Desvío estándar de la pendiente (%)
t_med_anual	Temperatura media anual (1970-2000) World Clim
rad_solar	Radiación solar media acumulada (1970-2000)
ndvi_mediana	Mediana de NDVI (promedio histórico 2000-2020)
ndvi_stdev	Desvío estándar de NDVI (promedio histórico 2000-2020)
evapo_medi_an	Evapotransp. media mensual acumulada de la serie (2001-2020)
pp_med_an	Precipitación media acumulada anual histórica (1958-2019)
t_min_med	Temperatura máxima anual media (1958-2019)
t_max_med	Temperatura mínima anual media (1958-2019)
def_hidric	Déficit hídrico medio histórico (1958-2019))
pdsi	Índice de Severidad de Sequía media histórica (1958-2019)
rec_1median	mediana dentro de la celda
rec_1stdev	desvío estándar dentro de la celda
rec_2median	mediana dentro de la celda
rec_2stdev	desvío estándar dentro de la celda
rec_3median	mediana dentro de la celda
rec_3stdev	desvío estándar dentro de la celda
perc_agua_perm	% agua en la celda (Año hidrológico 2020/06/01 al - 2021/04/20)
perc_agua_aneg	% agua en la celda (Año hidrológico 2020/06/01 al - 2021/04/20)
n2_cob16	% sup. Cultivos anuales de secano
n2_cob17	% sup. Cultivos Irrigados
cu_moda	Moda de CU de la celda
ip_median	Mediana del Índice de Productividad
ip_stdev	Desvío estándar del Índice de Productividad
cu_clase0	% Capacidad de Uso sin clasificar
cu_clase1	% Capacidad de Uso clase I
cu_clase2	% Capacidad de Uso clase II
cu_clase3	% Capacidad de Uso clase III
cu_clase4	% Capacidad de Uso clase VI
cu_clase5	% Capacidad de Uso clase V
cu_clase6	% Capacidad de Uso clase VI
cu_clase7	% Capacidad de Uso clase VII
cu_clase8	% Capacidad de Uso clase VIII
cu_clase9	% Capacidad de Uso clase áreas misceláneas
perc_pivot	Porcentaje de superficie con pivotes en la grilla
e_fvt_11	Evapotranspiración de la vegetación acumulada (m). Noviembre
e_fvt_12	Evapotranspiración de la vegetación acumulada (m). Diciembre
e_fvt_01	Evapotranspiración de la vegetación acumulada (m). Enero
e_fvt_02	Evapotranspiración de la vegetación acumulada (m). Febrero
e_fvt_03	Evapotranspiración de la vegetación acumulada (m). Marzo
e_fvt_04	Evapotranspiración de la vegetación acumulada (m). Abril
lail_11	Superficie total de hojas verdes por m2 de suelo horizontal para vegetación baja (m2/m2). Noviembre
lail_12	Superficie total de hojas verdes por m2 de suelo horizontal para vegetación baja (m2/m2). Diciembre

Variable	Descripción
lail_01	Superficie total de hojas verdes por m2 de suelo horizontal para vegetación baja (m2/m2). Enero
lail_02	Superficie total de hojas verdes por m2 de suelo horizontal para vegetación baja (m2/m2). Febrero
lail_03	Superficie total de hojas verdes por m2 de suelo horizontal para vegetación baja (m2/m2). Marzo
lail_04	Superficie total de hojas verdes por m2 de suelo horizontal para vegetación baja (m2/m2). Abril
skin_t_11	Temperatura de la superficie de la Tierra (media mensual en °K). Noviembre
skin_t_12	Temperatura de la superficie de la Tierra (media mensual en °K). Diciembre
skin_t_01	Temperatura de la superficie de la Tierra (media mensual en °K). Enero
skin_t_02	Temperatura de la superficie de la Tierra (media mensual en °K). Febrero
skin_t_03	Temperatura de la superficie de la Tierra (media mensual en °K). Marzo
skin_t_04	Temperatura de la superficie de la Tierra (media mensual en °K). Abril
rad_ss_11	Cantidad de radiación solar que alcanza la superficie de la Tierra por m2 (J/m2). Noviembre
rad_ss_12	Cantidad de radiación solar que alcanza la superficie de la Tierra por m2 (J/m2). Diciembre
rad_ss_01	Cantidad de radiación solar que alcanza la superficie de la Tierra por m2 (J/m2). Enero
rad_ss_02	Cantidad de radiación solar que alcanza la superficie de la Tierra por m2 (J/m2). Febrero
rad_ss_03	Cantidad de radiación solar que alcanza la superficie de la Tierra por m2 (J/m2). Marzo
rad_ss_04	Cantidad de radiación solar que alcanza la superficie de la Tierra por m2 (J/m2). Abril
evap_t_11	Evaporación total acumulada en el mes de análisis (m). Noviembre
evap_t_12	Evaporación total acumulada en el mes de análisis (m). Diciembre
evap_t_01	Evaporación total acumulada en el mes de análisis (m). Enero
evap_t_02	Evaporación total acumulada en el mes de análisis (m). Febrero
evap_t_03	Evaporación total acumulada en el mes de análisis (m). Marzo
evap_t_04	Evaporación total acumulada en el mes de análisis (m). Abril
prec_t_11	Precipitación total acumulada en el mes de análisis (m). Noviembre
prec_t_12	Precipitación total acumulada en el mes de análisis (m). Diciembre
prec_t_01	Precipitación total acumulada en el mes de análisis (m). Enero
prec_t_02	Precipitación total acumulada en el mes de análisis (m). Febrero
prec_t_03	Precipitación total acumulada en el mes de análisis (m). Marzo
prec_t_04	Precipitación total acumulada en el mes de análisis (m). Abril
evi_11	Índice de vegetación mejorado (EVI). Noviembre
ndwi_11	Índice de agua de diferencia normalizada modificado (MNDWI). Noviembre
msavi_11	Índice de vegetación ajustado al suelo modificado (MSAVI). Noviembre
ndvi_11	Índice de vegetación de diferencia normalizada (NDVI). Noviembre
evi_12	Índice de vegetación mejorado (EVI). Diciembre
ndwi_12	Índice de agua de diferencia normalizada modificado (MNDWI). Diciembre
msavi_12	Índice de vegetación ajustado al suelo modificado (MSAVI). Diciembre
ndvi_12	Índice de vegetación de diferencia normalizada (NDVI). Diciembre
evi_01	Índice de vegetación mejorado (EVI). Enero
ndwi_01	Índice de agua de diferencia normalizada modificado (MNDWI). Enero
msavi_01	Índice de vegetación ajustado al suelo modificado (MSAVI). Enero
ndvi_01	Índice de vegetación de diferencia normalizada (NDVI). Enero
evi_02	Índice de vegetación mejorado (EVI). Febrero
ndwi_02	Índice de agua de diferencia normalizada modificado (MNDWI). Febrero
msavi_02	Índice de vegetación ajustado al suelo modificado (MSAVI). Febrero
ndvi_02	Índice de vegetación de diferencia normalizada (NDVI). Febrero
evi_03	Índice de vegetación mejorado (EVI). Marzo
ndwi_03	Índice de agua de diferencia normalizada modificado (MNDWI). Marzo
msavi_03	Índice de vegetación ajustado al suelo modificado (MSAVI). Marzo
ndvi_03	Índice de vegetación de diferencia normalizada (NDVI). Marzo
evi_04	Índice de vegetación mejorado (EVI). Abril

Variable	Descripción
ndwi_04	Índice de agua de diferencia normalizada modificado (MNDWI). Abril
msavi_04	Índice de vegetación ajustado al suelo modificado (MSAVI). Abril
ndvi_04	Índice de vegetación de diferencia normalizada (NDVI). Abril
vswl_1_09	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Septiembre
vswl_1_10	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Octubre
vswl_1_11	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Noviembre
vswl_1_12	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Diciembre
vswl_1_01	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Enero
vswl_1_02	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Febrero
vswl_1_03	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Marzo
vswl_1_04	Volumen de agua en profundidades de 0 a 7 cm (m3/m3). Abril
vswl_2_09	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Septiembre
vswl_2_10	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Octubre
vswl_2_11	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Noviembre
vswl_2_12	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Diciembre
vswl_2_01	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Enero
vswl_2_02	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Febrero
vswl_2_03	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Marzo
vswl_2_04	Volumen de agua en profundidades de 7 a 28 cm (m3/m3). Abril
vswl_3_09	Volumen de agua en profundidades de 28 a 100 cm (m3/m3). Septiembre
vswl_3_10	Volumen de agua en profundidades de 28 a 100 cm (m3/m3). Octubre
vswl_3_11	Volumen de agua en profundidades de 28 a 100 m (m3/m3). Noviembre
vswl_3_12	Volumen de agua en profundidades de 28 a 100 cm (m3/m3). Diciembre
vswl_3_01	Volumen de agua en profundidades de 28 a 100 cm (m3/m3). Enero
vswl_3_02	Volumen de agua en profundidades de 28 a 100 cm (m3/m3). Febrero
vswl_3_03	Volumen de agua en profundidades de 28 a 100 cm (m3/m3). Marzo
vswl_3_04	Volumen de agua en profundidades de 28 a 100 m (m3/m3). Abril
vswl_4_09	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Septiembre
vswl_4_10	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Octubre
vswl_4_11	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Noviembre
vswl_4_12	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Diciembre
vswl_4_01	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Enero
vswl_4_02	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Febrero
vswl_4_03	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Marzo
vswl_4_04	Volumen de agua en profundidades de 100 a 289 cm (m3/m3). Abril
hs_09	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Septiembre
hs_10	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Octubre
hs_11	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Noviembre
hs_12	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Diciembre
hs_01	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Enero
hs_02	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Febrero
hs_03	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Marzo
hs_04	Volumen de agua del suelo de 0 a 50 cm de profundidad (%). Abril
vrmm_02	Variación interanual de las medianas de los escenarios de rinde de maíz (adimensional). Febrero
vrmm_03	Variación interanual de las medianas de los escenarios de rinde de maíz (adimensional). Marzo
vrs_02	Variación interanual de las medianas de los escenarios de rinde de soja (adimensional). Febrero
vrs_03	Variación interanual de las medianas de los escenarios de rinde de soja (adimensional). Marzo
qq_maiz_21	Rinde maíz en Quintales
qq_soja_21	Rinde soja en Quintales

Variable	Descripción
qq_maiz_22	Rinde maíz en Quintales
qq_soja_22	Rinde soja en Quintales
media_mo	Media de Contenido de materia orgánica en suelo utilizando una grilla de 3x3
std_mo	Desvío estándar de Contenido de materia orgánica en suelo utilizando una grilla de 3x3
media_p	Media de Contenido de fósforo en suelo utilizando una grilla de 3x3
std_p	Desvío estándar de Contenido de fósforo en suelo utilizando una grilla de 3x3
media_ph	Media de pH del suelo utilizando una grilla de 3x3
std_ph	Desvío estándar de pH del suelo utilizando una grilla de 3x3
media_arcilla	Media de valores de contenido de arcilla- SH utilizando una grilla de 3x3
std_arcilla	Desvío estándar de valores de contenido de arcilla- SH utilizando una grilla de 3x3
media_limo	Media de valores de contenido de limo utilizando una grilla de 3x3
std_limo	Desvío estándar de valores de contenido de limo utilizando una grilla de 3x3
media_arena	Media de valores de contenido de arena utilizando una grilla de 3x3
std_arena	Desvío estándar de valores de contenido de arena utilizando una grilla de 3x3
depto	Nombre de departamento
maskara	Máscara para realizar la estimación de rinde
_anom_de_22_23_mean	Precipit. % sobre promedio 2003/2019 - dic 22 → ene 23 GPMIMERG
_anom_def_22_23_mean	Precipit. % sobre promedio 2003/2019 - dic 22 → feb 23 GPMIMERG
_anom_son_22_23_mean	Precipit. % sobre promedio 2003/2019 - sep 22 → nov 22 GPMIMERG
_spei_de_22_23_mean	Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) - dic 22 → ene 23
_spei_ma_22_23_mean	Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) - mar 23 → abr 23
_spei_son_22_23_mean	Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) - sep 22 → nov 22
_spei_def_22_23_mean	Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) - dic 22 → feb 23
_spei_fma_22_23_mean	Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) - feb 23 → abr 23
_spei_asondefma_22_23_mean	Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) - ago 22 → abr 23
_spi_de_22_23_mean	Índice de Precipitación Estandarizado (SPI) - dic 22 → ene 23
_spi_ma_22_23_mean	Índice de Precipitación Estandarizado (SPI) - mar 23 → abr 23
_spi_son_22_23_mean	Índice de Precipitación Estandarizado (SPI) - sep 22 → nov 22
_spi_def_22_23_mean	Índice de Precipitación Estandarizado (SPI) - dic 22 → feb 23
_spi_asondefma_22_23_mean	Índice de Precipitación Estandarizado (SPI) - ago 22 → abr 23
_smant_de_22_23_mean	Soil Moisture Anomaly (SMA) - dic 22 → ene 23
_smant_def_22_23_mean	Soil Moisture Anomaly (SMA) - dic 22 → feb 23
_smant_fma_22_23_mean	Soil Moisture Anomaly (SMA) - feb 23 → abr 23
_smant_ma_22_23_mean	Soil Moisture Anomaly (SMA)- mar 23 → abr 23
_smant_son_22_23_mean	Soil Moisture Anomaly (SMA)- sep 22 → nov 22
_smant_asondefma_22_23_mean	Soil Moisture Anomaly (SMA)- sep 22 → abr 23
_anom_ma_22_23_mean	Precipit. % sobre promedio 2003/2019 - mar 23 → abr 23 GPMIMERG
_anom_fma_22_23_mean	Precipit. % sobre promedio 2003/2019 - feb 23 → abr 23 GPMIMERG
_anom_asondefma_22_23_mean	Precipit. % sobre promedio 2003/2019 - sep 22 → abr 23 GPMIMERG
stand_sum_seas	Suma estandarizada (ANOM + SPI + SPEI + SMA) para [sep 22 → abr 23]
stand_sum_meses	Suma estandarizada (ANOM + SPI + SPEI + SMA) para [(sep 22 → nov 22) + (dic 22 → ene 23) + (feb 23 → abr 23)]
stand_sum_todo	Suma estandarizada (ANOM + SPI + SPEI + SMA) para [(sep 22 → nov 22) + (dic 22 → ene 23) + (feb 23 → abr 23) + [sep 22 → abr 23]]

Anexo II - Modelos de Aprendizaje Computacional utilizados

Random Forest (RF) (Breiman, 2001)

Es un algoritmo que se caracteriza por ser de comportamiento anidado (en contraposición a los modelos lineales clásicos, que no permiten la interacción entre variables) y de estar compuesto por un conjunto de reglas de partición binaria recursivas, donde un conjunto de datos muestrales es sucesivamente particionado en función de diversas covariables.

Consiste en generar una serie de árboles de regresión a partir de la misma muestra mediante *bootstrapping*. RF combina las predicciones de estos árboles mediante el promedio condicional de las predicciones de cada modelo. Esta técnica se denomina *bagging* y permite reducir simultáneamente el sesgo y la varianza en la predicción. Además, RF permite realizar predicciones más precisas al disminuir la correlación entre los árboles; esto se consigue seleccionando aleatoriamente un subconjunto de variables independientes que se consideran en cada nodo de división.

Quantile Regression Forest (QRF) (Meinshausen, 2006)

El modelo QRF es una adaptación del algoritmo Random Forest (RF), que sigue la misma estrategia de ensamble, *bagging*, combinando árboles de decisión independientes, pero se distingue en el procedimiento de agregación de las predicciones de cada árbol. A diferencia de RF que agrega a través de la media, QRF permite realizar predicciones no sólo de la media condicionada de la variable objetivo, sino también del resto de los cuantiles. Es decir, se amplía la información brindada por Random Forest y, por lo tanto, se puede proveer de mayor información sobre la distribución total condicional de la variable objetivo y no únicamente de la media condicionada. Esta mayor información suele utilizarse para detectar *outliers* (o anomalías) en el set de datos por medio de la utilización de intervalos cuantílicos. Por lo tanto, con el algoritmo QRF se puede obtener la mediana de las predicciones del “bosque” en lugar de la media, brindando una mayor robustez en presencia de *outliers*. Adicionalmente, QRF puede utilizarse para identificar áreas donde la variable explicada tenga mayor varianza, logrando una estimación territorial del nivel de dispersión en los resultados. También surgen medidas como la desviación estándar (que se encuentra en la misma unidad de la variable objetivo) y el coeficiente de variación o dispersión, expresadas en porcentaje. De este modo se obtiene mayor información.

Créditos. Equipo de trabajo

Supervisión y relevamiento de datos (Min. de Bioagroindustria, INTA Córdoba)

Agencias Zonales del Ministerio de Bioagroindustria: General Deheza, Las Varillas, Bell Ville, Villa Huidobro, Marcos Juárez, San Francisco, El Tío, Laboulaye, Tancacha, Río Cuarto, Santa Rosa de Río Primero, San Agustín, Villa María, Villa de María de Río Seco, Villa del Rosario, Dean Funes, Jesús María, Morteros, Oliva, Villa Dolores y Cura Brochero.

Ministerio de Bioagroindustria: Marcos Blanda, Germán Font, Santiago Dellarossa.

Agencias de Extensión INTA en Córdoba: Horacio Videla, Sebastián Muñoz.

Modelado, cartografía y documentación (IDECOR)

Federico Monzani, Alejandro Manuel Ferreiro, Mariano Córdoba (en convenio con CONICET), Hernán Morales y María Luz Fuentes.

