

Ver el rendimiento desde el espacio: predicción de cosecha en trigo mediante imágenes satelitales diarias

Ariel Zajdband — Planet Labs | Diego Hugo Perez — AACREA

EL PROBLEMA QUE TODO PRODUCTOR ENFRENTA AL FINAL DEL CICLO

En noviembre de 2025, mientras un productor del norte santafesino esperaba que sus lotes terminaran de madurar, ya sabía —con seis semanas de anticipación— cuántos camiones necesitaría, cuánto espacio reservar en el acopio, y qué lotes priorizar en el orden de cosecha. Esa información no provino de un pronóstico climático ni de una estimación a ojo del canopeo: llegó de una serie de imágenes satelitales procesadas con un modelo biofísico que convierte el color de las hojas en kilogramos de grano.

Sin datos concretos, la logística de cosecha se planifica con márgenes amplios por necesidad: se reservan camiones de más, se sobreestima o subestima la capacidad de acopio, y se toman decisiones de comercialización sobre la base de intuiciones y promedios históricos alejados de la realidad de cada lote. Con un error de predicción de 500 kg/ha y lotes de entre 50 y 150 hectáreas, la incertidumbre del modelo equivale a uno o dos camiones por lote —un margen perfectamente dimensionable con anticipación, sabiendo que cada camión carga treinta toneladas.

La posibilidad de conocer con semanas de anticipación cuánto va a rendir cada polígono individual le permite al productor negociar posición en el acopio con datos propios, tomar decisiones de forward con margen de negociación, y dimensionar el transporte con precisión. Es, en definitiva, pasar de gestionar la cosecha por olfato a gestionarla con información.

POR QUÉ EL SATÉLITE ES HOY UNA HERRAMIENTA CONCRETA Y NO UNA PROMESA

Durante décadas, la teledetección aplicada a la agricultura fue una disciplina con enorme potencial pero con limitaciones prácticas: imágenes demasiado gruesas para distinguir lotes individuales, revisitas cada doce o dieciséis días que dejaban semanas sin datos en inviernos nublados, y algoritmos diseñados para vegetación genérica que no representaban bien el comportamiento del trigo.

PlanetScope, operado por Planet Labs, cambió este panorama. Ofrece cobertura diaria con píxeles de tres metros —aproximadamente el tamaño de un automóvil—, lo que permite medir con precisión la condición del canopeo de cada lote sin interferencia de bordes ni infraestructura predial. Incluso en los inviernos con mayor nubosidad del centro de Santa Fe, es posible obtener varias observaciones limpias por semana y reconstruir con fidelidad la trayectoria de desarrollo del cultivo desde la emergencia hasta la madurez fisiológica.

Lo que antes era un dato puntual y espacialmente grueso se convirtió en una serie temporal densa, lote por lote, campaña a campaña. La diferencia no es solo tecnológica: es la que existe entre saber que “el trigo de la zona viene bien” y saber que el Lote 7 va a rendir 6,2 t/ha mientras el Lote 12 va a quedar en 4,8 t/ha —y actuar en consecuencia.

LA FÍSICA DETRÁS DEL MODELO: POR QUÉ ESTO FUNCIONA

El modelo no es un algoritmo de machine learning entrenado para correlacionar imágenes con rendimientos históricos. Se basa en el principio más elemental de la agronomía: el rendimiento es, en última instancia, el resultado de cuánta radiación solar capturó el canopeo a lo largo del ciclo y con qué eficiencia la convirtió en biomasa. Este enfoque tiene un antecedente directo en el trabajo de Menendez-Coccoz et al. (2025), que demostró que modelos biofísicos de bajo insumo basados en radiación absorbida pueden predecir el rendimiento de maíz a múltiples escalas con alta interpretabilidad —y cuya lógica central adaptamos aquí para trigo. La conversión de NDVI satelital a fracción de radiación absorbida (fAPAR) sigue la

calibración exponencial de Pellegrini et al. (2020), desarrollada específicamente para trigo en la Pampa argentina.

El satélite mide el color de las hojas verdes —expresado como NDVI—, y ese color es un indicador directo de cuánta luz está absorbiendo el cultivo. A más verde y más densa la cobertura, más radiación interceptada, más fotosíntesis, y en última instancia más grano. La cadencia diaria de PlanetScope permite seguir esa curva de verdor con una fidelidad sin precedentes, desde la emergencia hasta la madurez.

Los estadios fenológicos se calculan mediante la acumulación de temperatura desde la siembra, con parámetros específicos para más de cincuenta variedades argentinas adaptados del modelo CRNOTRIGO de la FAUBA. La eficiencia con que el cultivo transforma la radiación en biomasa varía según el estadio, siendo máxima durante la encañazón cuando el canopeo está completo. El resultado es una estimación construida desde la física del cultivo, no desde una correlación estadística ciega.

DOS CAMPAÑAS, DOS REALIDADES: LA PRUEBA QUE LE IMPORTA AL AGRÓNOMO

Cualquier modelo puede mostrar buenos resultados en condiciones favorables. La prueba de fuego es la capacidad de funcionar en años difíciles, con variedades distintas, en lotes con historias diferentes. Durante las campañas 2024 y 2025 aplicamos este enfoque sobre el grupo CREA Las Petacas, en el norte de Santa Fe, con una muestra que creció de diecinueve lotes en 2024 a ochenta y tres en 2025.

La campaña 2024 fue una de las peores de los últimos años: la influencia de La Niña redujo las lluvias en momentos críticos y el rendimiento promedio fue de 3,5 t/ha. La primera versión del modelo —con una fórmula lineal para convertir el verdor del satélite en absorción de luz— reprodujo el promedio del grupo (sesgo de apenas 6 kg/ha) pero no pudo rankear los lotes con precisión, porque la fórmula comprimía las diferencias entre un lote vigoroso y uno estresado en un rango demasiado estrecho.

Para 2025 adoptamos la calibración exponencial de Pellegrini et al. (2020), desarrollada específicamente para trigo pampeano con mediciones de campo. Esa fórmula amplifica correctamente las diferencias de verdor en el rango medio del NDVI —precisamente

donde el trigo pasa la mayor parte de su ciclo. En 2025, con condiciones climáticas favorables y 61 lotes validados, el modelo no solo reprodujo el promedio (sesgo de -120 kg/ha) sino que explicó el 69% de la variabilidad entre lotes, con un error cuadrático medio de 600 kg/ha.

PREDECIR ANTES DE COSECHAR: LA CAPACIDAD QUE CAMBIA LAS DECISIONES

Saber cuánto rindió un lote después de cosecharlo es útil para el análisis; saber cuánto va a rendir antes de entrar con la cosechadora es lo que genera valor económico real.

El análisis de predicción anticipada sobre los 83 lotes de la campaña 2025 muestra en qué momento del ciclo la estimación se vuelve confiable. Desde los 60 días después de la siembra —encañazón, canopeo cubriendo la mayor parte del suelo—, el modelo ya explica más de la mitad de la variabilidad de rendimiento entre lotes ($R^2 = 0,52$), con un error típico de 680 kg/ha. A los 90 días, en espigazón, el R^2 sube a 0,67 y el error cae a 560 kg/ha.

El punto de inflexión más relevante ocurre a los 105 días desde la siembra, al inicio del llenado de grano: el modelo explicó el 74% de la variabilidad final de rendimiento, con un error típico de 500 kg/ha — el 9% del rendimiento promedio de la campaña. Eso ocurre entre 35 y 55 días antes de la cosecha de cada lote, exactamente la ventana en que las decisiones logísticas y comerciales más importantes deben tomarse.




Figura 1. Evolución de la capacidad predictiva del modelo (R^2 y error típico) en función de los días transcurridos desde la siembra, campaña 2025 (n = 83 lotes). El eje superior indica el estadio fenológico predominante en cada momento. La línea punteada verde marca los 105 días desde la siembra, punto óptimo de predicción anticipada ($R^2 = 0,74$, error típico = 500 kg/ha).

A los 105 días desde la siembra —inicio del llenado de grano, unas seis semanas antes de la cosecha— el modelo explicó el 74% de la variabilidad de rendimiento entre lotes, con un error típico de 500 kg/ha.

LOS RESULTADOS LOTE POR LOTE: QUÉ TAN BIEN FUNCIONA EN LA PRÁCTICA

La validación sobre los 61 lotes de la campaña 2025 muestra una correlación sólida entre los rendimientos estimados y los observados en campo ($r = 0,69$). El error cuadrático medio fue de 600 kg/ha y el error absoluto medio de 480 kg/ha. Dos de cada tres lotes tuvieron un error inferior a 500 kg/ha; ocho de cada diez quedaron dentro de una franja de ± 1 t/ha respecto al rendimiento real.

La nube de puntos de la Figura 2 se distribuye de manera simétrica alrededor de la línea 1:1, sin sesgos sistemáticos para segmentos específicos del rango de rendimiento. El modelo funciona de manera homogénea tanto en lotes de bajo como de alto potencial.

El sesgo promedio fue de -120 kg/ha : el modelo tendió a subestimar levemente el rendimiento real. Cuando se equivoca, tiende a quedarse levemente corto antes que a inflar las expectativas —exactamente el comportamiento preferido en un instrumento de apoyo a la toma de decisiones.

Dos de cada tres lotes de la campaña 2025 tuvieron un error de predicción inferior a 500 kg/ha —equivalente a menos de dos camiones sobre un lote de 100 hectáreas.




Figura 2. Rendimiento estimado por el modelo versus rendimiento observado en cosecha, campaña 2025 ($n = 61$ lotes, imágenes PlanetScope). La línea punteada indica la relación 1:1 perfecta; la banda gris corresponde al error típico de $\pm 600 \text{ kg/ha}$; la línea roja es la regresión de mínimos cuadrados ($r = 0,69$).

LA VARIEDAD IMPORTA: LO QUE EL MODELO CAPTURA Y LO QUE TODAVÍA AJUSTA

El modelo no trata a todos los lotes de la misma manera: la fenología se calcula con parámetros específicos para cada variedad, lo que le permite “saber” cuándo un DM Pehuen está en espigazón y cuándo un BG 620 todavía está en encañazón, aunque hayan sido sembrados el mismo día.

La tabla siguiente resume los resultados por grupo varietal en los 61 lotes validados de la campaña 2025:

Variedad	Lotes (n)	Rend. obs. (t/ha)	Sesgo modelo (kg/ha)
DM Pehuen	18	5,2	-10
BG 620	9	6,9	-320
ACA Fresno	7	6,2	-210
Otras variedades	27	5,0	-95

DM Pehuen, la variedad más sembrada en el grupo, mostró un sesgo prácticamente nulo (-10 kg/ha), lo que sugiere que los parámetros fenológicos del CRONOTRIGO están bien calibrados para este cultivar en el norte de Santa Fe. Las variedades tardías de alto potencial —BG 620 y ACA Fresno— fueron identificadas correctamente como los lotes de mayor rendimiento, aunque el modelo tendió a subestimarlas con mayor magnitud.

El origen del sesgo en variedades tardías es el índice de cosecha fijo de 0,45: en años favorables para el llenado, BG 620 puede alcanzar índices reales de 0,48 a 0,50. La solución es directa: con el historial de rendimientos reales que el CREA Las Petacas ya posee, es posible calibrar índices de cosecha específicos por grupo de madurez para las próximas campañas.

Más allá del índice de cosecha, la pregunta más relevante para calibrar y mejorar el modelo es: ¿qué variables agronómicas explican los errores que el modelo deja sin capturar? Para responderla de manera robusta —superando las limitaciones de las correlaciones lineales simples dentro de una sola campaña— realizamos un análisis de importancia de variables mediante Random Forest sobre los 66 lotes con datos climáticos completos de ambas campañas (2024 y 2025).

El método entrena un conjunto de árboles de decisión para predecir el residuo del modelo (rendimiento real - estimado) a partir de variables climáticas de temperatura y fotosíntesis acumulada, y cuantifica la contribución relativa de cada variable. A diferencia de la regresión lineal, captura relaciones no lineales e interacciones entre variables sin asumir ninguna forma funcional preestablecida.




Figura 3. Importancia relativa de variables climáticas en la predicción de los errores del modelo, estimada mediante Random Forest (campañas 2024 + 2025, n = 66 lotes). Las variables post-floración refieren al período días 100–175 desde la siembra; las variables ciclo_completo corresponden al ciclo completo desde siembra hasta madurez.

El cociente fotothermal acumulado post-floración (`post_floración_fotothermal_acum`) resultó la variable con mayor importancia relativa (17,3%), seguido por la varianza térmica post-floración (`post_floración_varianza_temp`, 15,9%) y la temperatura media post-floración (`post_floración_temp_media`, 14,6%). Las variables del ciclo completo —temperatura media, varianza y cociente fotothermal acumulado— aportaron importancias intermedias (8–13%). Los días con estrés calórico extremo (`ciclo_completo_días_estrés_calórico`, máximas > 35 °C) resultaron marginales en ambos períodos, lo que sugiere que en el rango de condiciones observado en las campañas analizadas no operaron umbrales de daño térmico severo.

La interpretación agronómica es coherente con el mecanismo biofísico del modelo. Los parámetros fijos de eficiencia en el uso de la radiación (RUE) e índice de cosecha (HI = 0,45) representan condiciones promedio; cuando el cociente fotothermal post-floración es excepcionalmente alto —más luz disponible por unidad de temperatura durante el llenado de grano—, el cultivo puede superar esos valores promedio y el modelo subestima. Lo opuesto ocurre en lotes con mayor variabilidad térmica, donde las oscilaciones de temperatura durante el llenado degradan la eficiencia real respecto a los coeficientes fijos del modelo.

Este resultado es consistente con Fischer (1985): el cociente fototermal durante los estadios peri-floración es el principal determinante del número de granos por espiga y, por extensión, del índice de cosecha efectivo. Incorporar un ajuste dinámico del HI en función del cociente fototermal post-floración observado lote a lote representa la extensión más prometedora del modelo para campañas futuras.

UNA HERRAMIENTA QUE CRECE CON EL USO

Lo que más nos entusiasma de esta experiencia no es el resultado de una campaña aislada, sino la lógica de mejora continua del enfoque. Cada campaña en que el grupo registra rendimientos reales lote por lote es una campaña en que el modelo puede calibrarse mejor: el índice de cosecha por variedad se ajusta, los casos atípicos se entienden, y la confianza en la predicción aumenta.

El salto de 2024 a 2025 —de una fórmula lineal a una calibración exponencial específica para trigo pampeano— no fue una corrección menor. Fue la diferencia entre un modelo que acierta el promedio pero no puede rankear lotes, y uno que explica el 69% de la variabilidad individual. A diferencia de los modelos de inteligencia artificial que requieren grandes volúmenes de datos históricos, este modelo biofísico arranca con una base teórica sólida y se afina de manera incremental con datos reales.

El código completo está disponible en acceso abierto en <https://github.com/agronomist/wheat-argentina>, y funciona con cualquier lote definido por un polígono GeoJSON. La posibilidad de extender esta metodología a otros grupos CREA de la región, cruzando datos entre grupos para enriquecer la calibración, representa una oportunidad concreta de construir una herramienta compartida que mejore campaña a campaña.

El satélite ya observa todos los lotes, todos los días. Aquel productor del norte santafesino que en noviembre de 2025 ya sabía cuántos camiones necesitaría no estaba viendo el futuro: estaba leyendo lo que el satélite había registrado durante seis meses de cultivo.

Contacto: ariel.zajdband@planet.com · diegohugoperez@gmail.com

El código del modelo y los datos de validación están disponibles en:
<https://github.com/agronomist/wheat-argentina>

Referencias

Menendez-Coccoz, M., Rotili, D. H., Otegui, M. E., Martini, G., Paolini, M., Di Bella, C., Piñeiro, G., & Oosterheld, M. (2025). Low-input, interpretable models to forecast maize yield at multiple scales based on absorbed radiation. *Agronomy Journal*, 117, e70089. <https://doi.org/10.1002/agj2.70089>

Fischer, R. A. (1985). Number of kernels in wheat crops and the influence of solar radiation and temperature. *Journal of Agricultural Science*, 105(2), 447–461. <https://doi.org/10.1017/S0021859600056495>

Pellegrini, P., Cossani, C. M., Di Bella, C. M., Piñeiro, G., Sadras, V. O., & Oosterheld, M. (2020). Remotely sensed biomass production of wheat: Relationships between NDVI and APAR across environments. *Crop Science*, 60, 1–10. <https://doi.org/10.1002/csc2.20129>