

MONITOREO DEL RENDIMIENTO DE SOJA A PARTIR DE SENSORES REMOTOS

Calabrese, L.^{1*}; Oesterheld, M. ¹; Piñeiro, G.¹

¹ Instituto de Investigaciones Fisiológicas y Ecológicas Vinculadas a la Agricultura (IFEVA).

EPG Escuela para Graduados – Fac. de Agronomía, UBA (Universidad de Buenos Aires)

*E-mail: matiasllebaria@hotmail.com

INTRODUCCIÓN

Con la lógica de la absorción y transformación de la radiación solar se puede explicar y predecir el rendimiento de los cultivos (Lobell, 2013; Monteith, 1972). Para estimar el rendimiento se estima la radiación incidente (PAR), la fracción de la radiación fotosintéticamente activa absorbida (fAPAR), la eficiencia con la que la radiación absorbida (APAR) se transforma en biomasa aérea (EUR) y, finalmente, la fracción de la biomasa aérea cosechada (IC). Además de explicar y predecir el rendimiento, esta lógica puede informar sobre aspectos agronómicos centrales. Por ejemplo, puede informar sobre la medida en que el rendimiento fue limitado por el despliegue de área foliar, por la conversión a biomasa o por la conversión a grano cosechado.

Hay otros modelos similares que, en vez de estimar el rendimiento a partir de la EUR y el IC, usan la Eficiencia de Conversión (EC)(Rattalino Edreira et al., 2020a, 2020b). Esta eficiencia refleja la habilidad del cultivo para convertir la radiación absorbida en rendimiento. La adopción de este enfoque se ha vinculado a la abundancia de datos disponibles sobre rendimiento a nivel de lote o nivel canopeo, a diferencia de la limitada disponibilidad de datos relacionados con la biomasa. Esta variante proporciona una perspectiva alternativa y complementaria, permitiendo, quizás, una comprensión más robusta de los factores que influyen en el rendimiento agrícola.

En el ámbito del monitoreo de cultivos, diversos actores, como productores, cooperativas, aseguradoras y autoridades, demandan información específica según sus necesidades y escalas temporales. Existen diversos enfoques de monitoreo de cultivos, desde sistemas reconocidos a nivel subnacional y nacional, como el MARS Crop Yield Forecasting System (MCYFS) y el USDA, que utilizan datos del cultivar, meteorológicos y sensores remotos (Van Der Velde et al., 2019; Van Der Velde and Nisini, 2019; Zhuo et al., 2018), hasta iniciativas globales como GEOGLAM, que emplea índices espectrales para evaluar el estado de los cultivos. A pesar de estos avances, la disponibilidad limitada de información a escala global destaca la necesidad de desarrollar modelos

que utilicen exclusivamente sensores remotos para prever el rendimiento de cultivos en extensiones amplias a nivel de lotes (Fritz et al., 2019). Este enfoque centrado en sistemas de monitoreo en tiempo real y en el pronóstico de rendimiento podría proporcionar información valiosa a los distintos actores de la cadena, asegurando una toma de decisiones más informada.

Existen tres tipos de modelos para estimar el rendimiento de cultivos a partir de sensores remotos: empíricos, semiempíricos y de simulación complementados con datos de sensores remotos. Los modelos empíricos se basan en correlaciones entre índices espectrales y medidas in situ, pero su limitación radica en la necesidad de ajustes frente a variaciones ambientales, dificultando su extrapolación precisa (Liao et al., 2019). Los modelos semiempíricos combinan procesos biofísicos con enfoques empíricos, como la fAPAR y la EC, permitiendo estimar distintos componentes del rendimiento (Monteith, 1972; Rattalino Edreira et al., 2020a). Los modelos de simulación, como CERES (Jones et al., 1986) y DSSAT (Jones et al., 2003), utilizan datos de manejo, suelo y atmósfera para simular procesos fisiológicos y estimar biomasa. En este trabajo, se propone un enfoque semiempírico basado en la radiación absorbida para la estimación del rendimiento de la soja, buscando superar las limitaciones de los modelos empíricos y la complejidad de los de simulación.

En los modelos basados en radiación, la Radiación Fotosintéticamente Activa Absorbida (APAR) se calcula multiplicando la Radiación Fotosintéticamente Activa Incidente (PAR) por la fracción de esta absorbida por el dosel vegetal (fAPAR). La PAR depende de factores atmosféricos, la latitud y la hora del día y del año, y se obtiene de fuentes como estaciones meteorológicas o datasets como NASA POWER (Sparks, 2018) o ERA5. La fAPAR, influida por factores ambientales y características del cultivo (Ruimy et al., 1994), engloba aspectos como el ángulo de radiación incidente, la proporción de radiación difusa, el contenido de clorofila y la estructura del dosel vegetal.

La fAPAR se puede estimar mediante índices derivados de sensores remotos. El NDVI, *Normalized Difference Vegetation Index*, (Tucker, 1979) es el más común,

aunque tiene menor sensibilidad cuando la fAPAR supera un umbral de aproximadamente 0.7. Otros índices como el WDRVI, *Wide Dynamic Range Vegetation Index* (Gitelson, 2004), y el EVI, *Enhanced Vegetation Index* (Huete et al., 2002), muestran mayor adaptabilidad a variaciones en la fAPAR. Estas relaciones empíricas varían según los factores ambientales y del cultivo, y al compararlas entre etapas vegetativas y reproductivas, se observan correlaciones diferentes asociadas a cambios en la estructura y contenido de clorofila del cultivo (Gitelson et al., 2014).

Otro componente en el modelo de radiación abordado en este estudio es la Eficiencia de Conversión (EC). La EC aumenta con la radiación difusa y la disponibilidad de agua en el suelo, y disminuye con la APAR y la temperatura media (Rattalino Edreira et al., 2020a). Sin embargo, existe una falta de correlación sólida entre la EC y factores meteorológicos, atribuible a la complejidad de las interacciones entre variables biológicas y de gestión. Este desafío destaca la importancia de examinar dichas interacciones para alcanzar una comprensión más precisa de la relación entre la conversión de radiación solar y el rendimiento de las semillas.

Considerando lo expuesto, este trabajo busca generar modelos que permitan pronosticar el rendimiento del cultivo de soja previo a la cosecha. Se explorará el impacto de factores meteorológicos en la variabilidad de la Eficiencia de Conversión (EC). Se analizará el aporte de la Radiación Fotosintéticamente Activa Absorbida (APAR) y la EC en la predicción de estos modelos, y cómo influye la fenología en dicho proceso. Además, se evaluará la capacidad y alcance de pronóstico de estos modelos antes de la cosecha.

MATERIALES Y MÉTODOS

Se desarrollaron modelos de pronóstico de rendimiento de soja basados en la radiación absorbida por el cultivo (APAR) y la eficiencia de conversión de esta radiación en rendimiento (EC). Los datos de rendimiento se obtuvieron de la base de datos DAT-CREA de la asociación CREA, que incluyó información de 2254 lotes distribuidos en toda Argentina durante las campañas 2017-18, 2018-19 y 2019-20. Cada lote proporcionó información sobre rendimiento, Región CREA, cultivar, campaña y fecha de siembra (**Figura 1**). Al comparar las campañas, se observan diferencias significativas en las precipitaciones. La campaña 2017-18 tuvo precipitaciones escasas en la mayoría de las regiones, mientras que la 2018-19 experimentó las más altas en la mayoría de ellas. La temporada 2019-20 mostró precipitaciones normales en la mayoría de las regiones.

La radiación absorbida por el cultivo (APAR) se estimó sumando diariamente el producto entre la fAPAR y la PAR, donde la fAPAR se calculó a partir del satélite Sentinel 2. Este satélite, con una resolución espacial de diez metros y una resolución temporal de seis días aproximadamente, generó el índice EVI a partir de sus bandas roja, roja lejana y azul. Un modelo propio (aún no publicado) convirtió este índice a fAPAR. Se calculó un promedio de fAPAR por lote, y se interpoló la serie de datos a una resolución diaria entre fechas sucesivas de paso del satélite. La PAR diaria se obtuvo de la base de datos de NASA POWER.

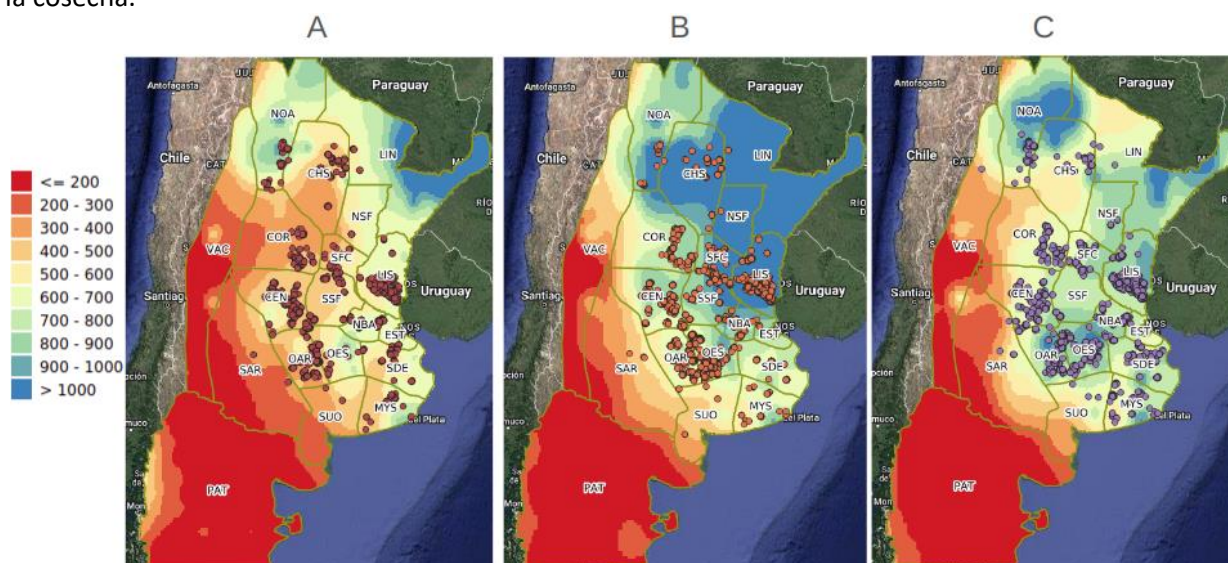


Figura 1. Precipitaciones acumuladas (fuente: Ciag y Nasa Power) entre octubre y abril del próximo año para las campañas A: 2017-18, B: 2018-19 y C: 2019-20. Los puntos en los mapas representan los lotes CREA de cada campaña. Los polígonos dentro de los mapas representan las abreviaturas de las regiones CREA. **Abreviaturas y nombre de las regiones CREA:** CEN: Centro, COR: Córdoba Norte, OAR: Oeste Arenoso, MYS: Mar y Sierras, OES: Oeste, SDE: Sudeste, NOA: NOA, SAR: Semiárida, SUO: Sudoeste, PAT: Patagonia, SSF: Sur de Santa Fe, EST: Este, SFC: Santa Fe Centro, NSF: Norte de Santa Fe, CHS: Chaco Santiagueño, LIS: Litoral Sur, NBA: Norte de Buenos Aires, LIN: Litoral Norte, VAC: Valles Cordilleranos.

Para estimar la EC, que se define como la relación entre el rendimiento y la APAR se empleó un enfoque específico. Dado que el rendimiento es un dato observado y directo, no es posible utilizarlo directamente en el cálculo de los modelos de pronóstico de rendimiento. Por lo tanto, fue necesario estimar la EC de manera indirecta. Inicialmente, se utilizó un modelo de bosques aleatorios que consideró una variedad de factores e índices meteorológicos como variables predictoras (**Figura 2**). Esta estimación de la EC se realizó empleando el 80% de los datos disponibles para calibrar el modelo. Durante este proceso, se ajustaron los parámetros del modelo utilizando tanto información observada de rendimiento, como los factores e índices meteorológicos.

Los factores meteorológicos se basaron en los valores medios de temperaturas máximas, mínimas y medias, humedad atmosférica, presión, velocidad del viento y los valores acumulados de precipitación proporcionados por NASA Power. Otros factores fueron los proporcionados por el balance operativo para el agro (BHOA), como el

almacenaje de agua en el suelo, la evapotranspiración potencial y real. Los índices meteorológicos utilizados fueron el VCI, que en este caso compara el valor actual de la fAPAR con el rango de valores de la fAPAR de años anteriores para la misma región y el mismo subperíodo. El otro índice fue el WRSI, que representa la relación entre la evapotranspiración real acumulada durante un subperíodo específico y la evapotranspiración potencial acumulada del mismo subperíodo. Para este estudio, este índice se calculó utilizando productos del instrumento satelital MODIS y el BHOA.

Posteriormente, el modelo calibrado se evaluó con el 20% restante de los datos, que se reservaron exclusivamente para pruebas. Esta evaluación permitió verificar la precisión del modelo en datos no utilizados previamente. Una vez validado el modelo de EC con estos datos de prueba, el valor predicho por este modelo se integró a los modelos de pronóstico de rendimiento. Este valor de EC predicho, junto con la APAR, contribuye a la estimación final del rendimiento del cultivo.

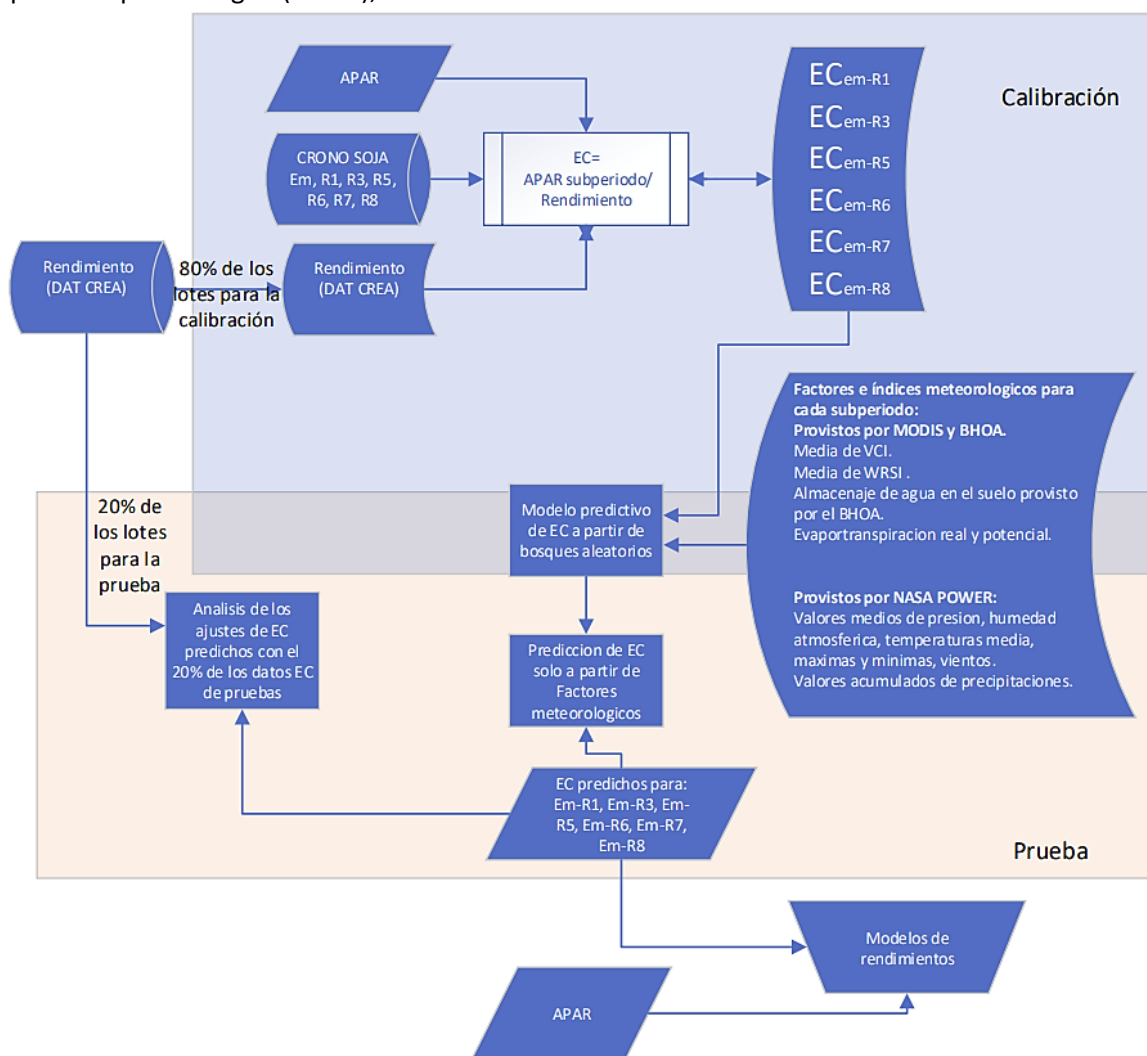


Figura 2. Calibración y prueba de los modelos de predicción de la eficiencia de conversión (EC).

Nota: VCI: índices de condición vegetal (Kogan, 1995), WRSI: índice de satisfacción de agua (FAO, 1986; Senay and Verdin, 2003), BHOA: Balance hidrológico operativo para el agro (Fernández-Long et al., 2012; Spennemann et al., 2020).

En este trabajo se consideró la fenología por su influencia en el rendimiento. Utilizamos el modelo CronoSoja® (Severini et al., 2023) para estimar la fenología, que, basándose en la fecha de siembra, cultivar y ubicación del lote, predice los estados fenológicos de emergencia, R1, R3, R5, R6 y R7. Esta información fenológica se empleó para calcular tanto la APAR como la EC en los subperiodos Em-R1, EM-R3, EM-R5, EM-R6, EM-R7 y EM-R8. En relación con la APAR, se acumuló para cada subperiodo, mientras que para la EC se estableció la relación entre la APAR de cada subperiodo y el rendimiento. La EC predicha para cada subperiodo se obtuvo a partir de los factores meteorológicos medios o acumulados específicos para cada subperiodo (Diagrama 1). El resultado final fue una matriz de datos que incluye un identificador de lote, rendimiento, APAR acumulado para cada subperiodo, EC predicha para cada subperiodo, región del lote, campaña y cultivar.

Para el pronóstico del rendimiento se generaron seis modelos, incorporando la APAR, la EC predicha y la región como variables predictoras. Se debe remarcar que los lotes empleados para la calibración y las pruebas de los modelos de pronóstico de rendimiento para cada subperiodo fueron los mismos que se utilizaron en la estimación de la EC predicha respectivamente.

La distinción entre los modelos de estimación de rendimiento radicó en que las predicciones de APAR y EC se realizaron para cada subperiodo (Figura 3). Esta metodología permitió analizar el ajuste de los pronósticos de rendimiento en cada subperiodo. Se emplearon modelos bayesianos en el estudio. La evaluación del ajuste entre las predicciones y las observaciones de rendimiento del conjunto de prueba se llevó a cabo para cada región y cada modelo.

Para comprender cómo los factores meteorológicos impactan en la variabilidad de la Eficiencia de Conversión

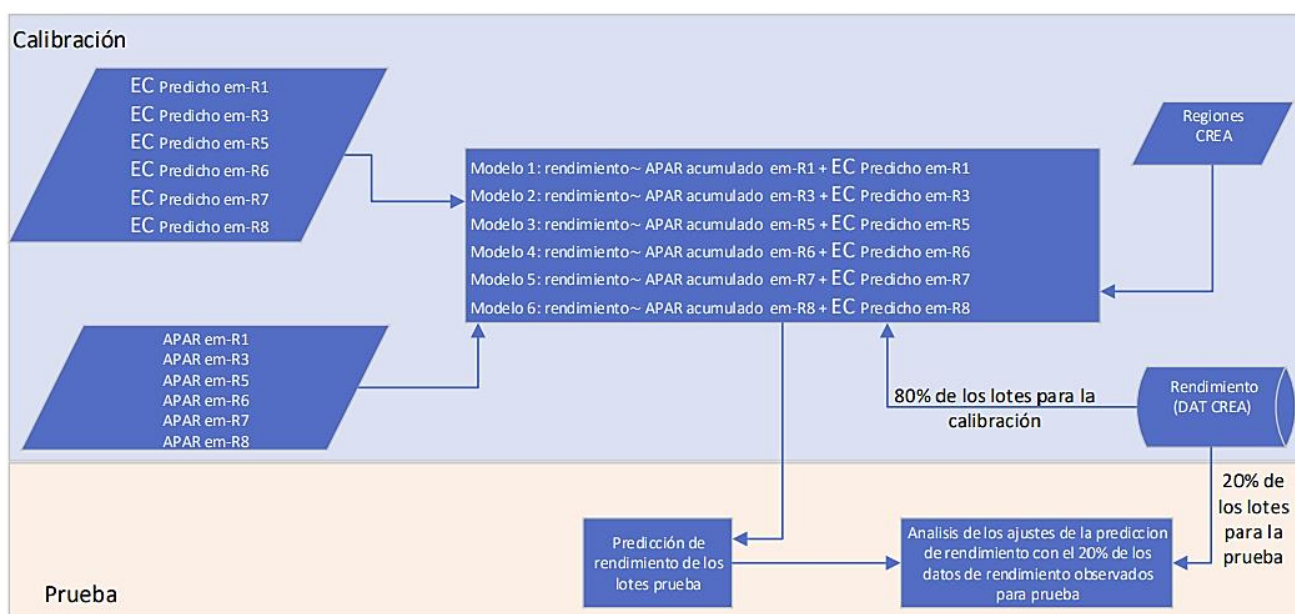


Figura 3. Calibración y prueba de los modelos de pronóstico de rendimiento.

(EC), se utilizó un modelo Random Forest y se evaluó la importancia de las variables mediante el criterio IncNodePurity, identificando las variables más influyentes en la predicción de la EC para cada subperiodo. El término IncNodePurity cuantifica cómo una variable mejora la pureza de los nodos del árbol de decisión, destacando aquellas que tienen un impacto significativo en la separación de las observaciones.

Para evaluar la capacidad y el alcance de pronóstico de estos modelos antes de la cosecha, se empleó el coeficiente de determinación (R^2) y el error absoluto medio (MAE), de la predicción de cada modelo de pronóstico de rendimiento en comparación con las

observaciones. Este análisis se realizó para todos los subperiodos, desde la emergencia hasta la cosecha,

permitiendo una comprensión completa de la capacidad pronóstica a lo largo de todo el ciclo del cultivo. Para analizar el aporte de APAR y EC en la Predicción del Rendimiento se compararon los coeficientes de las variables de APAR y EC, ambas estandarizadas para una comparación efectiva, en los modelos de pronóstico de rendimiento para cada subperiodo.

Además, se exploró cómo las variaciones en los rendimientos observados afectan la capacidad predictiva de los modelos para las tres campañas (2017-2018, 2018-2019 y 2019-2020). Este análisis se realizó comparando las desviaciones entre las predicciones del modelo que

considera la APAR y la EC del subperíodo Em-R8, y las observaciones con respecto al rendimiento observado. Cabe destacar que, adicionalmente, se generaron dos predicciones adicionales: un modelo que consideraba únicamente la variable APAR de Em-R8 y otro que incorporaba exclusivamente la variable EC predicha de Em-R8. Estos enfoques permitieron evaluar la contribución individual de APAR y EC en la capacidad predictiva de los modelos en diferentes contextos de rendimiento.

RESULTADOS

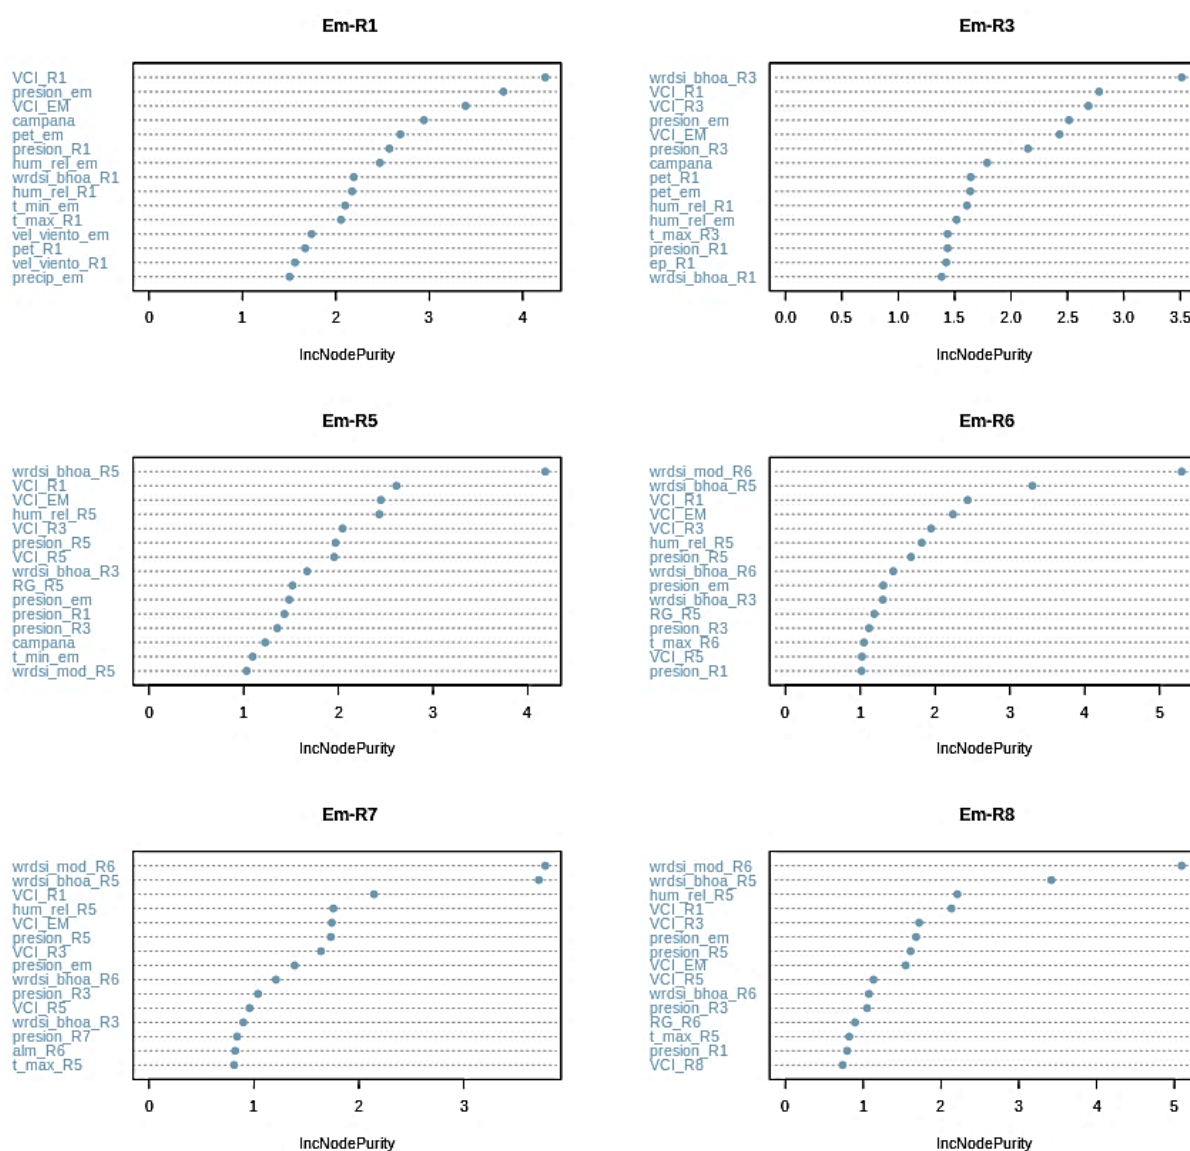


Figura 4: Análisis de Importancia de factores e índices Meteorológicos en la Predicción de la Eficiencia de Conversión en diferentes subperíodos fenológicos del cultivo de Soja. La importancia se determina mediante IncNodePurity, donde un valor más alto indica una contribución más significativa de la variable a la precisión del modelo

Los resultados referentes al análisis de pronóstico de los modelos de rendimiento previos a la cosecha (**Tabla 1**) son exclusivamente el producto de la fase de prueba (es

En relación con cómo los factores meteorológicos afectan la variabilidad de la eficiencia de conversión (EC) (**Figura 4**), se observa que ciertos índices meteorológicos, como el WRSI y el VCI, se mantienen influyentes en todos los subperíodos, destacándose el WRSI de MODIS durante el estado R6. Al final del ciclo, aunque las etapas R5 y R6 aparecen como las más importantes en la predicción de la EC del subperíodo Em-R8, se destaca que todos los estados fenológicos influyen en la predicción de esta EC predicha. Por último, se debe remarcar que el VCI en el subperíodo Em-R1 es importante en todas las predicciones de la EC de cada subperíodo.

decir, corresponden a estimaciones de puntos que no participaron de la creación del modelo). En este contexto, se observaron los ajustes más altos entre las predicciones

y las observaciones, al final del ciclo. Sin embargo, la magnitud de estos ajustes varió tanto entre regiones como dentro de los subperiodos anteriores. Por ejemplo, el Norte de Buenos Aires demostró ajustes destacados a partir de R5, en contraste con la región Sudeste. Aunque los mayores ajustes se realizaron al final del ciclo, también se observaron altos ajustes con R² que rondaron los 0.6 y

0.8, y MAE de 300 kg/ha y 600 kg/ha, cerca del estadio R6, dependiendo la región. Por último, en algunas regiones como Centro, Córdoba, Chaco Santiagueño y Litoral Sur, los modelos lograron pronosticar aproximadamente el 0.4 de la variabilidad del rendimiento en subperiodos iniciales, con MAE inferiores a 1000 kg/ha.

Tabla 1. Ajuste entre lo predicho por los modelos basados en la APAR y la EC, y lo observado en diferentes subperiodos fenológicos para cada región CREA". El ajuste se midió con los valores de R² (coeficiente de determinación), MAE (error absoluto medio) y el promedio (mean) para cada subperíodo fenológico (Em-R1, Em-R3, Em-R5, Em-R6, Em-R7, Em-R8) de cada región.

Regiones CREA	Em-R1	Em-R3	Em-R5	Em-R6	Em-R7	Em-R8
Centro	R2=0,42 MAE=899 mean=3250 n=43	R2=0,423 MAE=932 mean=3003 n=52	R2=0,603 MAE=681 mean=2864 n=55	R2=0,587 MAE=629 mean=3259 n=48	R2=0,747 MAE=587 mean=3178 n=57	R2=0,92 MAE=331 mean=3300 n=53
Chaco Santiagueño	R2=0,599 MAE=555 mean=3403 n=48	R2=0,697 MAE=646 mean=3172 n=39	R2=0,76 MAE=528 mean=3228 n=43	R2=0,623 MAE=435 mean=3492 n=47	R2=0,764 MAE=429 mean=3101 n=43	R2=0,899 MAE=250 mean=3235 n=44
Cordoba Norte	R2=0,614 MAE=573 mean=3249 n=36	R2=0,693 MAE=690 mean=3299 n=31	R2=0,868 MAE=436 mean=2932 n=16	R2=0,835 MAE=363 mean=3397 n=34	R2=0,807 MAE=436 mean=3240 n=30	R2=0,9 MAE=272 mean=3212 n=27
Litoral Sur	R2=0,403 MAE=524 mean=2244 n=121	R2=0,437 MAE=497 mean=2210 n=115	R2=0,65 MAE=481 mean=2172 n=119	R2=0,572 MAE=523 mean=2285 n=103	R2=0,66 MAE=501 mean=2296 n=104	R2=0,805 MAE=326 mean=2279 n=123
NOA	R2=0,145 MAE=641 mean=3277 n=18	-	-	R2=0,666 MAE=305 mean=3350 n=17	-	-
Norte de Buenos Aires	R2=0,253 MAE=802 mean=3018 n=27	R2=0,311 MAE=764 mean=2735 n=20	R2=0,835 MAE=373 mean=2763 n=22	R2=0,76 MAE=489 mean=3204 n=29	R2=0,788 MAE=362 mean=2792 n=25	R2=0,702 MAE=327 mean=2921 n=22
Oeste	R2=0,124 MAE=887 mean=3666 n=47	R2=0,55 MAE=613 mean=3500 n=55	R2=0,685 MAE=540 mean=3549 n=64	R2=0,744 MAE=516 mean=3421 n=41	R2=0,776 MAE=496 mean=3310 n=57	R2=0,939 MAE=313 mean=3583 n=53
Oeste Arenoso	R2=0,044 MAE=988 mean=3490 n=61	R2=0,378 MAE=771 mean=3490 n=53	R2=0,618 MAE=512 mean=3434 n=46	R2=0,631 MAE=553 mean=3283 n=51	R2=0,651 MAE=489 mean=3204 n=39	R2=0,924 MAE=305 mean=3198 n=47
Sudeste	-	R2=0,596 MAE=421 mean=2461 n=23	R2=0,345 MAE=572 mean=2580 n=17	R2=0,784 MAE=353 mean=2657 n=25	R2=0,735 MAE=387 mean=2612 n=28	R2=0,852 MAE=266 mean=2768 n=17
Sur de Santa Fe	R2=0,048 MAE=1157 mean=4121 n=17	R2=0,634 MAE=765 mean=3905 n=21	R2=0,657 MAE=523 mean=3769 n=25	R2=0,779 MAE=499 mean=3518 n=23	R2=0,68 MAE=598 mean=3978 n=27	R2=0,944 MAE=257 mean=3909 n=22

Nota: En casos en que la cantidad de lotes por región fue menor a 15, no se consideraron valores de R² y MAE, específicamente en algunos subperiodos de NOA y Sudeste. Es importante aclarar que las fluctuaciones en el valor de 'n' están sujetas a las variaciones en los datos empleados durante las fases de calibración y prueba, las cuales difirieron para cada subperíodo y región.

Al comparar los coeficientes estandarizados de APAR y EC para cada subperíodo, y analizar su contribución en los modelos (**Tabla 2**), se observa que, tanto APAR como EC muestran una influencia significativa a lo largo de todo el ciclo fenológico. La influencia de la APAR en la predicción

del rendimiento en etapas tempranas fue limitada, lo cual es comprensible. La EC, que se basa en factores e índices meteorológicos, logró capturar parte de la variabilidad no explicada por la APAR.

Tabla 2. Coeficientes estandarizados de APAR y EC en Diferentes subperiodos y su contribución en los modelos.

Modelo	APAR	EC
APAR acumulado em-R1 + EC Predicho em-R1	495	781
APAR acumulado em-R3 + EC Predicho em-R3	702	851
APAR acumulado em-R5 + EC Predicho em-R5	833	884
APAR acumulado em-R6 + EC Predicho em-R6	860	843
APAR acumulado em-R7 + EC Predicho em-R7	856	852
APAR acumulado em-R8 + EC Predicho em-R8	856	830

Nota: Cada coeficiente presentó un valor de p menor a 0.01, indicando diferencias significativas con respecto a cero.

Al analizar cómo las variaciones en los rendimientos observados afectan la capacidad predictiva de los modelos, se utilizó un gráfico que relaciona la desviación (diferencia entre lo predicho y lo observado) y el rendimiento para las tres campañas utilizando el modelo que consideraba la APAR y la EC desde emergencia hasta R8 (**Figura 5. A**). Se observó que, para valores medios, la desviación era mínima, indicando una buena capacidad del modelo para predecir rendimientos cercanos a la media. Sin embargo, para valores altos, se notó un aumento en la desviación y un sesgo ya que el modelo tendió a subestimar el rendimiento en las tres campañas. En contraste, para valores bajos, la campaña 2018-2019 mostró una tendencia a sobrestimar el rendimiento,

aunque este último hallazgo no resultó tan significativo en comparación con las otras observaciones.

Es importante destacar que cuando solo se consideró la APAR o la EC (**Figura 5. B y C**), los modelos generaron mayores desviaciones, principalmente en bajos rendimientos. En el modelo de APAR, se observaron mayores desvíos para bajos rendimientos en la campaña 2017-2018, mientras que, para EC, estas mayores desviaciones para bajos rendimientos se observaron en la campaña 2018-2019. Este análisis resalta la importancia de la inclusión conjunta de ambas variables para lograr predicciones más precisas, especialmente en situaciones de bajos rendimientos.

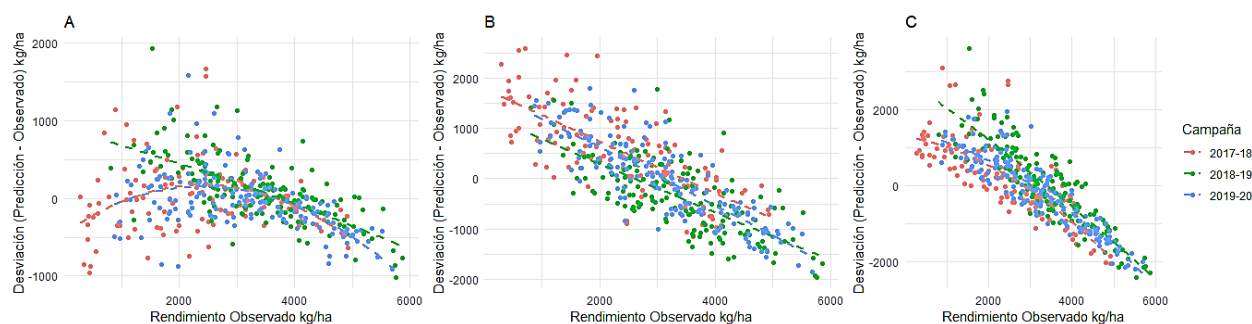


Figura 5: Gráficos entre la Desviación, obtenida de la diferencia de las predicciones de los modelos y las observaciones, y el rendimiento observado para las Campañas 2017-2018, 2018-2019 y 2019-2020: Modelos del subperiodo Em-R8: A) APAR + EC predicha, B) solo APAR, y C) solo EC predicha.

DISCUSIÓN

El estudio destaca el impacto del WRSI en la predicción de la EC, enfatizando la importancia de considerar la oferta y demanda de agua a lo largo del ciclo del cultivo. Se

necesita avanzar en la predicción y monitoreo del agua en el suelo, así como en la estimación precisa de la evapotranspiración utilizando tecnologías de sensores remotos (Amani and Shafizadeh-Moghadam, 2023). Además, todos los estados fenológicos, especialmente R5 y R6, influyen en la predicción de la EC final. Esto destaca

la necesidad de considerar múltiples aspectos del ciclo del cultivo al desarrollar modelos de predicción de rendimiento, ya que cada etapa fenológica puede tener un impacto significativo en la EC final.

Los modelos de pronóstico de rendimientos muestran un alto ajuste previo a la cosecha, incluso para el subperíodo Em-R5. En un contexto donde varios actores de la cadena productiva necesitan predicciones precisas del rendimiento, este producto ofrece una valiosa contribución. Ayudará a agricultores e industria agrícola a gestionar eficientemente recursos, tomar decisiones informadas y planificar operaciones de cosecha, almacenamiento, procesamiento y logística (Darra et al., 2023). La capacidad de estos modelos para proporcionar pronósticos precisos y oportunos del rendimiento del cultivo de soja es fundamental para toda la cadena de suministro agrícola.

Con relación a los coeficientes de los modelos de pronóstico de rendimiento, se observa una influencia significativa tanto de la EC como de la APAR. Esta dualidad de influencias sugiere una interacción complementaria entre estas dos variables en la predicción del rendimiento. Por otro lado, al analizar la desviación entre las predicciones y los rendimientos observados para distintos niveles de rendimiento, se evidencia que la Eficiencia de Conversión (EC) desempeña un papel significativo en campañas más secas, como la de 2017, al parecer, mitigando la variabilidad originada por la escasez de agua. Por otro lado, la APAR parece tener más dificultades para estimar por sí sola el rendimiento en estas situaciones. Esta observación podría estar relacionada con el hecho de que APAR está más vinculada a rendimientos potenciales (Van Ittersum et al., 2013), como se aprecia en los resultados, donde APAR muestra menos variabilidad para altos rendimientos en las tres campañas analizadas.

Por otro lado, en una campaña climáticamente normal, como la de 2018-2019, en la mayoría de las regiones el modelo que solo considera EC exhibe mayores desviaciones para niveles bajos de rendimientos. Si bien, el EC podría reducir las desviaciones en situaciones de alto estrés y bajos rendimientos, su capacidad para hacerlo no es tan efectiva en situaciones normales. En tales campañas, los bajos rendimientos podrían estar asociados a causas adicionales, como prácticas de manejo agrícola, que el modelo no logra capturar por completo. Por último, al comparar nuestro enfoque con otros estudios, notamos una amplia variedad de escalas de trabajo (Schwalbert et al., 2020; Stepanov et al., 2020; Von Bloh et al., 2023). La escala de medición puede influir significativamente en la precisión de los modelos. Al pasar de escalas amplias, como nacional o municipal, a escalas finas, como campo o lote, se pueden capturar variaciones

más específicas en el rendimiento de los cultivos, aunque esto puede aumentar la complejidad del modelado. Nuestro enfoque se destaca por lograr una mayor precisión en las predicciones, con errores relativos del error absolutos medios (rMAE) alrededor del 10%, en contraste con otros estudios similares que muestran errores relativos del error cuadrático medio (rRMSE) entre el 28% y el 35% (Gasó et al., 2021). Esto indica una precisión considerablemente mayor en la estimación del rendimiento de los cultivos a escala de lote en comparación con trabajos parecidos (Skakun et al., 2021).

CONCLUSIONES

Los modelos generados basados en la radiación absorbida y la eficiencia conversión obtienen ajustes precisos en la predicción del rendimiento usando sensores remotos, ofreciendo una alternativa accesible para pronosticar los rendimientos de los cultivos de soja. Los resultados resaltan la importancia integral de los factores meteorológicos y fenológicos en el desarrollo de modelos predictivos precisos.

La disponibilidad de agua en el suelo, la demanda de agua atmosférica y la absorción de radiación solar juegan un papel significativo a lo largo de los diferentes estados fenológicos del ciclo del cultivo, lo que subraya la necesidad de integrar estos aspectos en los modelos para obtener predicciones precisas. Además, se observó una interacción complementaria entre la radiación absorbida por el cultivo y la eficiencia de conversión, especialmente en condiciones adversas como la escasez de agua, así como en situaciones de altos rendimientos.

AGRADECIMIENTO

Agradecemos a la Facultad de Agronomía y AACREA por facilitar el acceso a los datos, así como al proyecto PICT-2020-SERIEA-I-A por financiar parte del trabajo.

BIBLIOGRAFÍA

- Amani, S., Shafizadeh-Moghadam, H. 2023. A review of machine learning models and influential factors for estimating evapotranspiration using remote sensing and ground-based data. *Agric. Water Manag.* 284, 108324. <https://doi.org/10.1016/j.agwat.2023.108324>
- Darra, N., Anastasiou, E., Kriezi, O., Lazarou, E., Kalivas, D., Fountas, S. 2023. Can Yield Prediction Be Fully Digitized? A Systematic Review. *Agronomy* 13, 2441. <https://doi.org/10.3390/agronomy13092441>
- FAO. 1986. Early agrometeorological crop yield assessment, FAO plant production and protection paper. Food and Agriculture Organization of the

- United Nations, Rome.
- Fernández-Long, M.E., Murphy, G., Spescha, L. 2012. Modelo de Balance Hidrológico Operativo para el Agro (BHOA). *Rev Agron. Ambiente* 32 1–2.
- Fritz, S., See, L., Bayas, J.C.L., Waldner, F., Jacques, D., Becker-Reshef, I., Whitcraft, A., Baruth, B., Bonifacio, R., Crutchfield, J., Rembold, F., Rojas, O., Schucknecht, A., Van Der Velde, M., Verdin, J., Wu, B., Yan, N., You, L., Gilliams, S., Múcher, S., Tetrault, R., Moorthy, I., McCallum, I. 2019. A comparison of global agricultural monitoring systems and current gaps. *Agric. Syst.* 168, 258–272. <https://doi.org/10.1016/j.agsy.2018.05.010>
- Gaso, D.V., De Wit, A., Berger, A.G., Kooistra, L. 2021. Predicting within-field soybean yield variability by coupling Sentinel-2 leaf area index with a crop growth model. *Agric. For. Meteorol.* 308–309, 108553. <https://doi.org/10.1016/j.agrformet.2021.108553>
- Gitelson, A.A. 2004. Wide Dynamic Range Vegetation Index for Remote Quantification of Biophysical Characteristics of Vegetation. *J. Plant Physiol.* 161, 165–173. <https://doi.org/10.1078/0176-1617-01176>
- Gitelson, A.A., Peng, Y., Huemmrich, K.F. 2014. Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250m resolution data. *Remote Sens. Environ.* 147, 108–120. <https://doi.org/10.1016/j.rse.2014.02.014>
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens. Environ.* 83, 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Jones, C.A., Kiniry, J.R., Dyke, P.T. (Eds.) 1986. CERES-Maize: a simulation model of maize growth and development, 1st ed. ed. Texas A&M University Press, College Station.
- Jones, J.W., Hoogenboom, G., Porter, C.H., Boote, K.J., Batchelor, W.D., Hunt, L.A., Wilkens, P.W., Singh, U., Gijssman, A.J., Ritchie, J.T. 2003. The DSSAT cropping system model. *Eur. J. Agron.* 18, 235–265. [https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/10.1016/S1161-0301(02)00107-7)
- Kogan, F.N. 1995. Application of vegetation index and brightness temperature for drought detection. *Adv. Space Res.* 15, 91–100. [https://doi.org/10.1016/0273-1177\(95\)00079-T](https://doi.org/10.1016/0273-1177(95)00079-T)
- Liao, C., Wang, J., Dong, T., Shang, J., Liu, J., Song, Y. 2019. Using spatio-temporal fusion of Landsat-8 and MODIS data to derive phenology, biomass and yield estimates for corn and soybean. *Sci. Total Environ.* 650, 1707–1721. <https://doi.org/10.1016/j.scitotenv.2018.09.308>
- Lobell, D.B. 2013. The use of satellite data for crop yield gap analysis. *Field Crops Res.* 143, 56–64. <https://doi.org/10.1016/j.fcr.2012.08.008>
- Monteith, J.L. 1972. Solar Radiation and Productivity in Tropical Ecosystems. *J. Appl. Ecol.* 9, 747. <https://doi.org/10.2307/2401901>
- Rattalino Edreira, J.I., Mourtzinis, S., Azzari, G., Andrade, J.F., Conley, S.P., Lobell, D., Specht, J.E., Grassini, P. 2020a. From sunlight to seed: Assessing limits to solar radiation capture and conversion in agro-ecosystems. *Agric. For. Meteorol.* 280, 107775. <https://doi.org/10.1016/j.agrformet.2019.107775>
- Rattalino Edreira, J.I., Mourtzinis, S., Azzari, G., Andrade, J.F., Conley, S.P., Specht, J.E., Grassini, P. 2020b. Combining field-level data and remote sensing to understand impact of management practices on producer yields. *Field Crops Res.* 257, 107932. <https://doi.org/10.1016/j.fcr.2020.107932>
- Ruimy, A., Saugier, B., Dedieu, G. 1994. Methodology for the estimation of terrestrial net primary production from remotely sensed data. *J. Geophys. Res. Atmospheres* 99, 5263–5283. <https://doi.org/10.1029/93JD03221>
- Schwalbert, R.A., Amado, T., Corassa, G., Pott, L.P., Prasad, P.V.V., Ciampitti, I.A. 2020. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agric. For. Meteorol.* 284, 107886. <https://doi.org/10.1016/j.agrformet.2019.107886>
- Senay, G.B., Verdin, J. 2003. Characterization of yield reduction in Ethiopia using a GIS-based crop water balance model. *Can. J. Remote Sens.* 29, 687–692. <https://doi.org/10.5589/m03-039>
- Severini, A.D., Álvarez-Prado, S., Otegui, M.E., Kavanová, M., Vega, C.R.C., Zuil, S., Ceretta, S., Acreche, M., Amarilla, F., Cicchino, M., Fernández-Long, M.E., Crespo, A., Serrago, R., Miralles, D.J. 2023. CRONOSOJA: a daily time-step hierarchical model predicting soybean development across maturity groups in the Southern Cone (preprint). *Plant Biology*. <https://doi.org/10.1101/2023.09.18.558336>
- Skakun, S., Kalecinski, N.I., Brown, M.G.L., Johnson, D.M., Vermote, E.F., Roger, J.-C., Franch, B. 2021. Assessing within-Field Corn and Soybean Yield Variability from WorldView-3, Planet, Sentinel-2, and Landsat 8 Satellite Imagery. *Remote Sens.* 13, 872. <https://doi.org/10.3390/rs13050872>
- Sparks, A. 2018. nasapower: A NASA POWER Global Meteorology, Surface Solar Energy and Climatology Data Client for R. *J. Open Source Softw.* 3, 1035. <https://doi.org/10.21105/joss.01035>
- Spennemann, P.C., Fernández-Long, M.E., Gattinoni, N.N., Cammalleri, C., Naumann, G. 2020. Soil moisture evaluation over the Argentine Pampas using models,

- satellite estimations and in-situ measurements. *J. Hydrol. Reg. Stud.* 31, 100723. <https://doi.org/10.1016/j.ejrh.2020.100723>
- Stepanov, A., Dubrovin, K., Sorokin, A., Aseeva, T. 2020. Predicting Soybean Yield at the Regional Scale Using Remote Sensing and Climatic Data. *Remote Sens.* 12, 1936. <https://doi.org/10.3390/rs12121936>
- Tucker, C.J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8, 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Van Der Velde, M., Nisini, L. 2019. Performance of the MARS-crop yield forecasting system for the European Union: Assessing accuracy, in-season, and year-to-year improvements from 1993 to 2015. *Agric. Syst.* 168, 203–212. <https://doi.org/10.1016/j.agry.2018.06.009>
- Van Der Velde, M., Van Diepen, C.A., Baruth, B. 2019. The European crop monitoring and yield forecasting system: Celebrating 25 years of JRC MARS Bulletins. *Agric. Syst.* 168, 56–57. <https://doi.org/10.1016/j.agry.2018.10.003>
- Van Ittersum, M.K., Cassman, K.G., Grassini, P., Wolf, J., Tittone, P., Hochman, Z. 2013. Yield gap analysis with local to global relevance—A review. *Field Crops Res.* 143, 4–17. <https://doi.org/10.1016/j.fcr.2012.09.009>
- Von Bloh, M., Nória Júnior, R.D.S., Wangerpohl, X., Saltik, A.O., Haller, V., Kaiser, L., Asseng, S. 2023. Machine learning for soybean yield forecasting in Brazil. *Agric. For. Meteorol.* 341, 109670. <https://doi.org/10.1016/j.agrformet.2023.109670>
- Zhuo, W., Huang, J., Li, L., Huang, R., Gao, X., Zhang, X., Zhu, D. 2018. Assimilating SAR and Optical Remote Sensing Data into WOFOST Model for Improving Winter Wheat Yield Estimation, in: 2018 7th International Conference on Agro-Geoinformatics (Agro-Geoinformatics). Presented at the 2018 7th International Conference on Agro-geoinformatics (Agro-geoinformatics), IEEE, Hangzhou, pp. 1–5. <https://doi.org/10.1109/Agro-Geoinformatics.2018.8476074>