

# **Modelado del rendimiento a partir de datos satelitales para el cultivo de maíz semilla**

*Tesis presentada para optar al título de Especialista en Cultivos de Granos.*

**Francisco Javier Boronat**

Ingeniero Agrónomo - Universidad de Buenos Aires - 2011

Lugar de trabajo: Bayer Crop Science



Escuela para Graduados Ing. Agr. Alberto Soriano  
Facultad de Agronomía - Universidad de Buenos Aires

**COMITÉ CONSEJERO**

Director de tesis

**Sebastián Gavilán**

Ingeniero Agrónomo – Universidad de Buenos Aires  
Doctor en Ciencias Agrarias y Forestales – Universidad Nacional de La Plata

**JURADO DE TRABAJO FINAL**

Jurado

**Ivana Sabljic**

Ingeniera Agrónoma (Universidad de Buenos Aires)  
Máster Internacional en Tecnología de los Alimentos (Universidad de Parma, Italia)

Jurado

**Diego Hernan Rotilli**

Ingeniero Agrónomo (Universidad de Buenos Aires)  
Magister en Agronegocios (Universidad de Buenos Aires)

Fecha de defensa del Trabajo Final: 10 de Julio de 2023

## Índice

<b>Índice</b> .....	<b>iii</b>
<b>Índice de figuras</b> .....	<b>iv</b>
<b>Índice de Tablas</b> .....	<b>vi</b>
<b>Índice de ecuaciones</b> .....	<b>vi</b>
<b>Agradecimientos</b> .....	<b>vii</b>
<b>Declaración</b> .....	<b>vii</b>
<b>Resumen</b> .....	<b>viii</b>
<b>Introducción</b> .....	<b>8</b>
<b>Objetivos</b> .....	<b>16</b>
<b>Hipótesis</b> .....	<b>17</b>
<b>Materiales y Métodos</b> .....	<b>17</b>
<b>Generalidades</b> .....	<b>17</b>
<b>Obtención de datos satelitales</b> .....	<b>20</b>
<b>Generación de datos de NDVI acumulado</b> .....	<b>21</b>
<b>Obtención de datos de rendimiento bruto</b> .....	<b>24</b>
<b>Muestreo convencional para estimación de rendimiento a campo</b> .....	<b>25</b>
<b>Análisis estadístico</b> .....	<b>26</b>
<b>Resultados</b> .....	<b>27</b>
<b>Discusión</b> .....	<b>33</b>
<b>Conclusión</b> .....	<b>38</b>
<b>Referencias</b> .....	<b>39</b>

## Índice de figuras

Figura 1. Porcentaje de la luz incidente reflejada (Reflectancia) en cada longitud de onda del espectro electromagnético para diferentes coberturas del suelo.....	11
Figura 2. Esquema de los componentes y subcomponentes del rendimiento en un cultivo de grano (Cárcova, Abeledo, y López Pereira 2003).....	14
Figura 3: Ubicación de las 22 unidades muestrales (lotes) utilizadas. 15 correspondieron al set de datos utilizado para generar los modelos (lotes de calibración) y 7 fueron utilizadas para evaluar las estimaciones del modelo (lotes de evaluación). .....	18
Figura 4. Representación esquemática del ciclo ontogénico del maíz indicando los rasgos morfológicos externos, visibles macroscópicamente y los internos. También se indican los momentos aproximados en que queda fijado el número y tamaño de algunas estructuras de la planta (Ritchie <i>et al.</i> 1993). .....	19
Figura 5. Imagen de una espiga de maíz con estigmas receptivos a la vista, indicador del momento de floración por individuo. ....	23
Figura 6. Esquema de días que abarcan las ventanas de tiempo en función de la fecha donde se detectó el 50% de los individuos en etapa de floración.....	24
Figura 7: Esquema del procedimiento de muestreo de los componentes del rendimiento a campo para líneas de maíz utilizadas para producir semilla en el Sudeste de Buenos Aires. ....	26
Figura 8: Modelos de regresión polinomial de Rendimiento real en función del NDVI acumulado para las ventanas de tiempo seleccionadas en función de la fecha donde se observó el 50 % de los individuos en floración. ....	29
Figura 9: Modelo bilineal para la estimación de rendimiento generado con datos de NDVI acumulados entre los 10 y 20 días desde el 50% de floración.....	30
Figura 10: Rendimiento bruto (gris intermedio), rendimiento estimado por el modelo satelital utilizando la ventana de tiempo de 10 a 20 días desde el 50% de floración (gris claro) y rendimiento estimado por muestreo convencional (gris oscuro) promedio para los 7 lotes de validación.....	31
Figura 11: Gráfico de regresión lineal entre el rendimiento real y el rendimiento estimado a través del modelo satelital, el método de estimación convencional a campo y un hipotético modelo ideal ( $y = X$ ).....	32



## Índice de Tablas

Tabla 1: Fechas de siembra, fechas de floración (50% de los estigmas receptivos) y días desde siembra hasta la fecha de floración para cada una de las 15 unidades muestrales que compusieron el set de datos para la evaluación del momento de mayor bondad de ajuste. ....	21
Tabla 2: Ejemplo de interpolación lineal de valores de NDVI para un vector cronológico en DDS. ....	22
Tabla 3: Resultados de los análisis estadísticos asociados a cada modelo polinomial por ventana de tiempo. ....	30
Tabla 4: Resumen de las diferencias entre los modelos a nivel regional.....	31
Tabla 5: Resumen de las diferencias entre los métodos de estimación lote a lote. ....	32

## Índice de ecuaciones

Ecuación 1: $NDVI = (Rojo - Infrarojo)/(Rojo + Infrarojo)$ .....	10
Ecuación 2: $DDS = Fecha\ de\ Imagen - Fecha\ de\ Siembra$ .....	21
Ecuación 3: $\Delta_{NDVI} = (NDVI\ fecha\ posterior - NDVI\ fecha\ anterior)/cantidad\ de\ días\ entre\ imágenes$ .....	22

## **Agradecimientos**

A Sebastián Gavilán por su aporte como tutor de esta tesis y el acompañamiento durante todo su desarrollo.

A Monsanto Argentina por apostar al crecimiento profesional de sus colaboradores y posibilitar el acceso a esta especialización.

A Carlos Putzeys por haberme seleccionado y alentado a realizar este curso de posgrado.

A mi Esposa y mi familia por estar siempre a mi lado.

## **Declaración**

Declaro que el material incluido en esta tesis es, a mi mejor saber y entender, original producto de mi propio trabajo (salvo en la medida en que se identifique explícitamente las contribuciones de otros), y que este material no lo he presentado, en forma parcial o total, como una tesis en esta u otra institución.

## Resumen

En la llamada cuarta revolución industrial se encuentra la necesidad de convivir en un mundo controlado por datos. Los sensores remotos nos ofrecen datos continuos sobre el estado de la vegetación. Es posible utilizar la información satelital para generar índices espectrales relacionados a la biomasa vegetativa, que sirvan para estudiar la evolución del cultivo. La gran cantidad de imágenes provenientes de la constelación Sentinel 2 nos permite obtener datos periódicamente y evaluar el momento donde la variable satelital tenga mayor bondad de ajuste con el rendimiento real. A partir de esta información es posible generar un modelo para la predicción del rendimiento. En el presente trabajo se propone evaluar el ajuste entre el índice de verdor de diferencia normalizada (NDVI) acumulado dentro de distintas ventanas de tiempo alrededor del momento de floración en lotes de producción de maíz semilla ubicados en el sudeste de la provincia de Buenos Aires. Luego, a partir de los datos de la ventana de tiempo de mayor ajuste, y con el objetivo de que tenga un sentido fisiológico, generar un modelo con el cual se realicen estimaciones de rendimiento. Por último, evaluar la precisión del modelo, compararlo con un hipotético modelo ideal y con estimaciones realizadas por el método convencional de conteo de los componentes del rendimiento a campo. La ventana de tiempo donde los datos mostraron mayor bondad de ajuste es entre los 10 y los 20 días después del momento de floración. El modelo desarrollado ofreció estimaciones de rendimiento más precisas que el muestreo convencional.

**Palabras clave:** sensores remotos, NDVI, estimaciones de rendimiento, maíz semilla, Sentinel 2



## Introducción

Entre los cambios de paradigma que está suponiendo la llamada cuarta revolución industrial, también llamada Industria 4.0, se encuentra la necesidad de convivir en un mundo controlado por datos, lo que ya se conoce como Big Data (Salvador Naya, 2018). Distintos tipos de sensores conectados en red aumentan las capacidades de monitoreo a lo largo de los procesos de producción. Esto permite la recopilación masiva de datos en tiempo real sobre los recursos utilizados (Huber *et al.* 2019). Sin embargo, los datos brutos raramente son beneficiosos directamente, su verdadero valor se basa en la habilidad para extraer información útil para la toma de decisiones y la comprensión del fenómeno analizado. El descubrimiento de conocimiento en bases de datos (KDD, iniciales de Knowledge Discovery in Databases) se define como el proceso de identificar patrones significativos en los datos que sean válidos, novedosos, potencialmente útiles y comprensibles para un usuario (Riquelme, Ruiz, y Gilbert 2006). A todas las tecnologías que se necesitan para la gestión y transformación de la información en conocimiento se las conoce como tecnologías de la información y la comunicación (TICs) (Sanchez Duarte, 2008). El proceso de digitalización puede afectar de forma diferente a los distintos sectores productivos estando el agrícola más rezagado, la digitalización facilita también la integración entre sectores y el salto tecnológico de los menos avanzados (Sotomayor, Ramirez, y Martinez 2021).

La agricultura de precisión es un enfoque que utiliza las TICs para mejorar la calidad de los cultivos, aumentar los rendimientos y mejorar la rentabilidad de los agricultores mientras se reducen los efectos negativos en el medio ambiente (Srbínovska *et al.* 2015). Los problemas que normalmente suceden en la agricultura y a los que la tecnología puede ayudar a mitigar son los

siguientes: deficiente localización de sitios de alto y bajo rendimiento productivo asociados a condiciones del suelo, incapacidad para realizar pronósticos acertados de rendimiento necesarios para una adecuada gestión comercial y el manejo deficiente de los fertilizantes, localización inadecuada, cantidades excesivas o insuficientes (Carpio Santos 2018). Existe un falso concepto de que las TICs son demasiado sofisticadas para ser aplicadas en labores que tienen que ver con la tierra, el clima, el trabajo físico o la naturaleza (Pérez *et al.* 2006). De acuerdo con el interés expresado por los agricultores, entre las tareas propias de la agricultura que pueden ser objetos de aplicaciones de la tecnología podemos encontrar: resolución de interrogantes sobre las prácticas de cultivos (preparación de suelos, sistema de riego, determinación de ataques de plagas y enfermedades), contabilidad y gestión de la empresa agropecuaria (cálculo de inversiones, inventario y movimiento, cálculo de insumos agrícolas, etc.), planificación y manejo de cultivos (selección de áreas de cultivos, proyección de fechas de siembra, cálculo de dosis de plaguicidas, etc.), meteorología local (registros de lluvias, humedad relativa, radiación y cálculos de evapotranspiración, etc.) (Pérez *et al.* 2006).

Por su parte, el maíz es un cultivo de importancia económica a nivel mundial, debido a su utilidad como alimento para humanos, ganado y derivados industriales, abarcando el 40% de la producción mundial de granos (Guamán Guamán *et al.* 2020). La expansión mundial del cultivo de maíz está ligada a la mejora genética y al desarrollo de híbridos adaptados a las necesidades de cada lugar (Esperbent *et al.* 2018). Debido a su importancia económica y al valor agregado que le aportan todas las biotecnologías al cultivo de maíz se hace necesario acompañar dichas mejoras con avances en el campo de la digitalización y las TIC. A la luz de este contexto desafiante para la agricultura, existe una fuerte necesidad de monitorear el crecimiento y estado de los cultivos en varios lugares y

contextos ambientales para diferentes propósitos (Yang *et al.* 2017). Se necesita monitoreo casi en tiempo real para reaccionar ante distintos eventos para minimizar el impacto en el rendimiento final (von Braun 2020). La teledetección aparece como una herramienta esencial para dar respuesta a los requisitos antes mencionados ya que ofrece un medio de información recurrente a escala local y regional de forma sistemática permitiendo la caracterización de la variabilidad espacio-temporal (Weiss, Jacob, y Duveiller 2020). Actualmente, la Agencia Espacial Europea (ESA) cuenta con 2 satélites llamados SENTINEL 2 diseñados para proporcionar imágenes multispectrales de media/alta resolución espacial (10 m) y una revisita temporal de 5 a 3 días (Frampston *et al.* 2013).

El Índice de Vegetación de Diferencia Normalizada (NDVI) es posiblemente el índice espectral de teledetección para monitorear la superficie terrestre más implementado. Matemáticamente, el NDVI se expresa de la siguiente manera:

$$\text{Ecuación 1:} \quad \text{NDVI} = \frac{(\text{Rojo} - \text{Infrarrojo})}{(\text{Rojo} + \text{Infrarrojo})}$$

donde “Rojo” e “Infrarrojo” son mediciones de radiación espectral (o reflectancia) grabado con sensores en la fracción del espectro electromagnético correspondiente al color visible rojo (650 - 680 nm) y regiones del infrarrojo cercano (780 – 900 nm) (Huang *et al.* 2021). Los pigmentos fotosintéticos absorben eficientemente la radiación en la fracción del espectro electromagnético correspondiente a la luz azul (~ 427 - 476 nm) y roja (~ 618 - 780 nm) y reflejan la luz verde (~ 497 - 570 nm) y, en mayor proporción la luz invisible de infrarrojo cercano (NIR, ~ 850 - 880 nm). Este equilibrio se ve modificado ante situaciones de estrés nutricional, hídrico, enfermedades o estado fenológico (Reol 2003). En cultivos estresados, la luz NIR reflejada será más bajo y la roja será más alta comparado con cultivos en buenas condiciones (Cozzolino *et al.* 2017) (Figura 1).

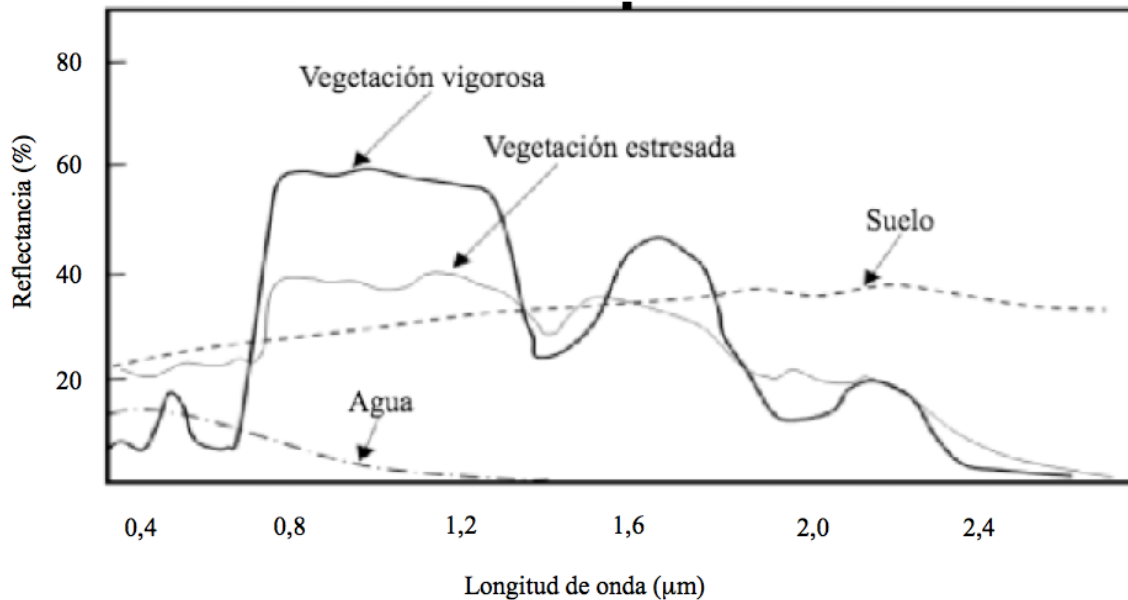


Figura 1. Porcentaje de la luz incidente reflejada (Reflectancia) en cada longitud de onda del espectro electromagnético para diferentes coberturas del suelo.

A través de sucesivas mediciones de NDVI es posible reflejar la evolución de la biomasa vegetal durante el ciclo del cultivo. En la literatura se ha reportado un incremento de los valores de NDVI desde los 50 a 60 Días desde siembra (DDS) llegando a un pico aproximadamente a los 95 DDS y comenzando a declinar a partir de los 120 a 130 DDS (Gitelson *et al.* 2003). En otro estudio se han encontrado valores de NDVI en V6 de 0,22 llegando a 0,77 en V8/V9 antes de comenzar a declinar en V10/V11 utilizando un sensor de mano “GreenSeeker” (Teal *et al.* 2006). El aumento en la lectura de NDVI desde la siembra podría deberse a aumentos en las actividades fisiológicas de los cultivos (consumo de agua, la absorción de nutrientes y luz solar) requeridas para el crecimiento vegetativo activo. Este aumento de vigor es síntoma de una buena provisión de nutrientes y de agua que se expresan en una cobertura vegetal adecuada (Jermthaisong *et al.* 2019). Los picos coincidieron con la etapa reproductiva temprana cuando los cultivos adquieren la máxima

concentración de clorofila para procesos de mazorca y llenado de granos que demandan altos niveles de fotosíntesis. La disminución de NDVI observada después de alcanzar el pico podría deberse a la degeneración de las células, las cuales pierden pigmentos de clorofila reduciendo la capacidad para absorber PAR (Verhulst y Govaerts 2010). La clorofila en la hoja está estrechamente relacionada con la concentración de N y, por lo tanto, refleja el estado nutricional con respecto a este nutriente. Cantidades adecuadas de N en la planta, producen hojas de color verde oscuro debido a que estas tienen alta concentración de clorofila. El pigmento verde de la clorofila absorbe la energía de la luz necesaria para iniciar la fotosíntesis (Castillo y Ligarreto 2010).

Desde el punto de vista de los componentes numéricos del rendimiento, el número de granos es el principal componente asociado al rendimiento, quedando establecido en un período de aproximadamente 30 días centrado en el momento de floración, etapa definida como período crítico (PC) (Goldsworthy y Fisher 2008; Cerrudo *et al.* 2013). Durante esta etapa, la incidencia de un estrés hídrico o lumínico provoca mermas en el número de granos ya que coincide con el crecimiento activo de la espiga, la emergencia de estigmas y el inicio del llenado de granos (Cárcova, Borrás, y Otegui 2003). Por lo tanto, se espera que, al finalizar esta etapa, los valores de NDVI expresen las condiciones que exploró el cultivo durante el PC (Venancio *et al.* 2020).

Para la producción de semillas, es necesario sincronizar la emisión de polen por parte de surcos sembrados con líneas macho y la aparición de estigmas receptivos de las líneas hembra. Para ampliar la ventana de tiempo de emisión de polen, se siembran surcos con un primer macho y surcos con un segundo macho sembrado a pocos días del primero dependiendo del material genético. Es importante, para lograr una buena fecundación de los óvulos que las panojas de las plantas machos comiencen a emitir polen en época cercana a la aparición de los estigmas en los surcos sembrados

con plantas hembra (Torres Flores *et al.* 2004), en esta etapa quedan definidos el número potencial de granos cuajados . A partir de este momento los óvulos fecundados (futuros granos) pueden ser abortados o llenarse completamente determinándose aquí gran parte del rendimiento (Golik *et al.* 2018). Luego de la polinización y fecundación de las flores comienza el llenado de los granos que comprende diferentes fases. La primera fase, llamada período de cuaje, se caracteriza por tener una baja tasa de acumulación de materia seca en los granos, pero tiene lugar una activa división celular que da lugar a la formación de las células endospermáticas (sitios donde se depositará el almidón). La segunda fase, llamada período efectivo de llenado o fase de crecimiento lineal, presenta la máxima tasa de llenado y constituye más de la mitad de este período (Maddonni, Otegui, y Bonhomme 1998).

El procedimiento general de estimaciones de rendimiento de maíz semilla a campo, denominado de aquí en adelante “muestreo convencional”, se basa en la cuantificación de los componentes del rendimiento (Figura 2). En primer lugar, se realiza un conteo de la población con espigas fértiles, luego se contabilizan los granos por espiga y finalmente se afectan los resultados por la densidad lograda para escalar la estimación a una unidad de área determinada. En la actualidad, se utilizan sistemas digitales que estiman la cantidad de granos a través de algoritmos de visión artificial (Khaki *et al.* 2020). Para el peso de los granos se utilizan promedios históricos para cada material sembrado.

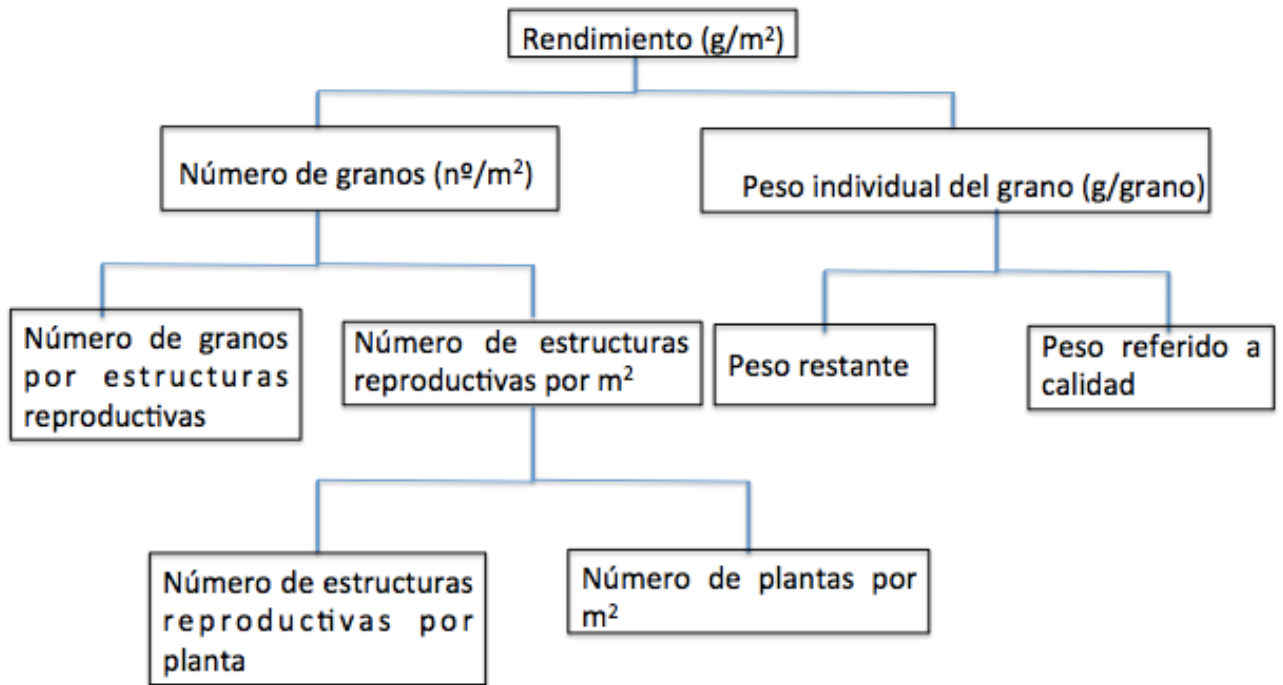


Figura 2. Esquema de los componentes y subcomponentes del rendimiento en un cultivo de grano (Cárcova, Abeledo, y López Pereira 2003).

Como ejemplos de modelos utilizados actualmente puede mencionarse el caso del Departamento de Agricultura de Estados Unidos (USDA) que pronostica los rendimientos esperados de los todos cultivos durante el transcurso de la temporada utilizando un modelo funcional, basado en algoritmos que reflejan mecánicamente proceso fisiológicos, llamado CERES-Maize. El modelo CERES-Maize puede simular con precisión el índice de área foliar (LAI), el rendimiento y la biomasa del maíz y el contenido de humedad del suelo en condiciones de suministro de agua suficiente (Song y Jin 2020). Este modelo ha sido validado robustamente en diferentes regiones productoras de maíz en el mundo (Quiring y Legates, 2008) y ha mostrado solidez en la región pampeana (Ferreyra *et al.* 2001). Los modelos de pronóstico del rendimiento de maíz desarrollados a partir de información espectral explican una mayor proporción de la variabilidad del rendimiento,

por lo general, cuando consideran varias fechas de muestreo durante el ciclo del cultivo (Chang *et al.* 2003).

Un modelo calibrado para estimar rendimientos en el Departamento de Marcos Juárez (Córdoba) integró el NDVI para distintas etapas del ciclo ontogénico del cultivo de maíz con imágenes de baja resolución espacial (100 ha por pixel) de la misión NOAA-AVHRR. Con este modelo se pudo explicar alrededor del 80% de la variabilidad del rendimiento de maíz a escala departamental (De La Casa y Ovando 2007). La constelación NOAA-AVHRR introduce la ventaja de tener una alta resolución temporal (1 pasada por día) permitiendo una cobertura completa del ciclo del cultivo (Smith *et al.* 1995). Otro estudio realizado con índices de vegetación en Shelton (U.S.A.), con una resolución espacial de 0,5 m, recopiló datos desde aeronaves en varias fechas durante dos temporadas (1997 y 1998) utilizando un sistema de cámara digital multiespectral de cuatro bandas (reflectancia azul, verde, roja y del infrarrojo cercano). Los resultados mostraron que los valores del índice de vegetación de diferencia normalizada verde (GNDVI) derivados de imágenes adquiridas durante el llenado de grano medio fueron los más altamente correlacionados con el rendimiento de grano con coeficientes de correlación ( $r$ ) de 0,7 y 0,92 en las dos campañas que analizadas, y los valores más altos se obtuvieron durante la etapa de llenado de granos (Shanahan *et al.* 2001).

Lo anteriormente mencionado demuestra la importancia de tener una alta revisita y resolución espacial. Con el objetivo de desarrollar una metodología robusta y genérica basada en el uso de datos de teledetección de alta resolución para proporcionar estimaciones de biomasa y rendimiento de maíz, Battude *et al.* (2016) desarrollaron un modelo que no requiere mediciones *in situ*. En el trabajo de Battude se puede ver el gran potencial de la tecnología satelital de alta



resolución espacial y temporal usando datos de muchos sensores (Formosat 2, SPOT 4, Landsat 8 y Deimos 1). La metodología propuesta consiste en generar series temporales de NDVI con datos de muchos sensores simulando la revisita que se obtiene con los satélites Sentinel 2, lanzados con posterioridad a la publicación de Battude. La metodología desarrollada pretende ser un modelo genérico para ser aplicado a imágenes Sentinel-2, aunque no se llegó a probar con dicha misión satelital (Battude *et al.* 2016).

En el presente trabajo, se propuso evaluar el nivel de ajuste entre el NDVI acumulado dentro de ventanas de tiempo de 10 días abarcando el período crítico de todos los lotes analizados (desde el día 70 hasta el día 130 a partir de la siembra) con datos satelitales de la misión espacial Sentinel-2 y el rendimiento real obtenido en lotes cultivados para maíz semilla en la región Sudeste de la provincia de Buenos Aires. El objetivo de este estudio es analizar en que ventana de tiempo se encuentra la mayor bondad de ajuste entre las variables para comprender mejor la dinámica del NDVI en cultivos de maíz. El segundo objetivo es obtener un modelo que tenga sentido fisiológico que permita estimar los rendimientos en cultivos de maíz semilla y evaluar su poder predictivo comparándolo con el método de estimación convencional, destructivo, de conteo de los componentes de rendimiento in situ.

## **Objetivos**

1. Evaluar el ajuste entre el NDVI acumulado en ventanas de tiempo de 10 días cercanas al momento de floración y el rendimiento real de maíz semilla en el Sudeste de Buenos Aires.
2. Generar un modelo que tenga sentido fisiológico para la ventana de tiempo de mayor ajuste y evaluar la precisión de las estimaciones.

## **Hipótesis**

Hipótesis de trabajo 1:

Existe una estrecha relación entre los valores acumulados de NDVI y el rendimiento real que aumenta hacia el final del período crítico (entre 10 y 20 días después del 50% de floración)

Hipótesis de trabajo 2:

El modelo de predicción satelital permite realizar estimaciones de rendimiento más precisas que el método de estimación convencional a campo.

## **Materiales y Métodos**

### **Generalidades**

Se analizó información proveniente de un total de 22 lotes de producción de semillas de maíz en el sudeste de la provincia de Buenos Aires. El 70% de los lotes se analizaron para evaluar la bondad de ajuste y generar un modelo de predicción y el 30% restante para evaluar la precisión de este (Figura 3).

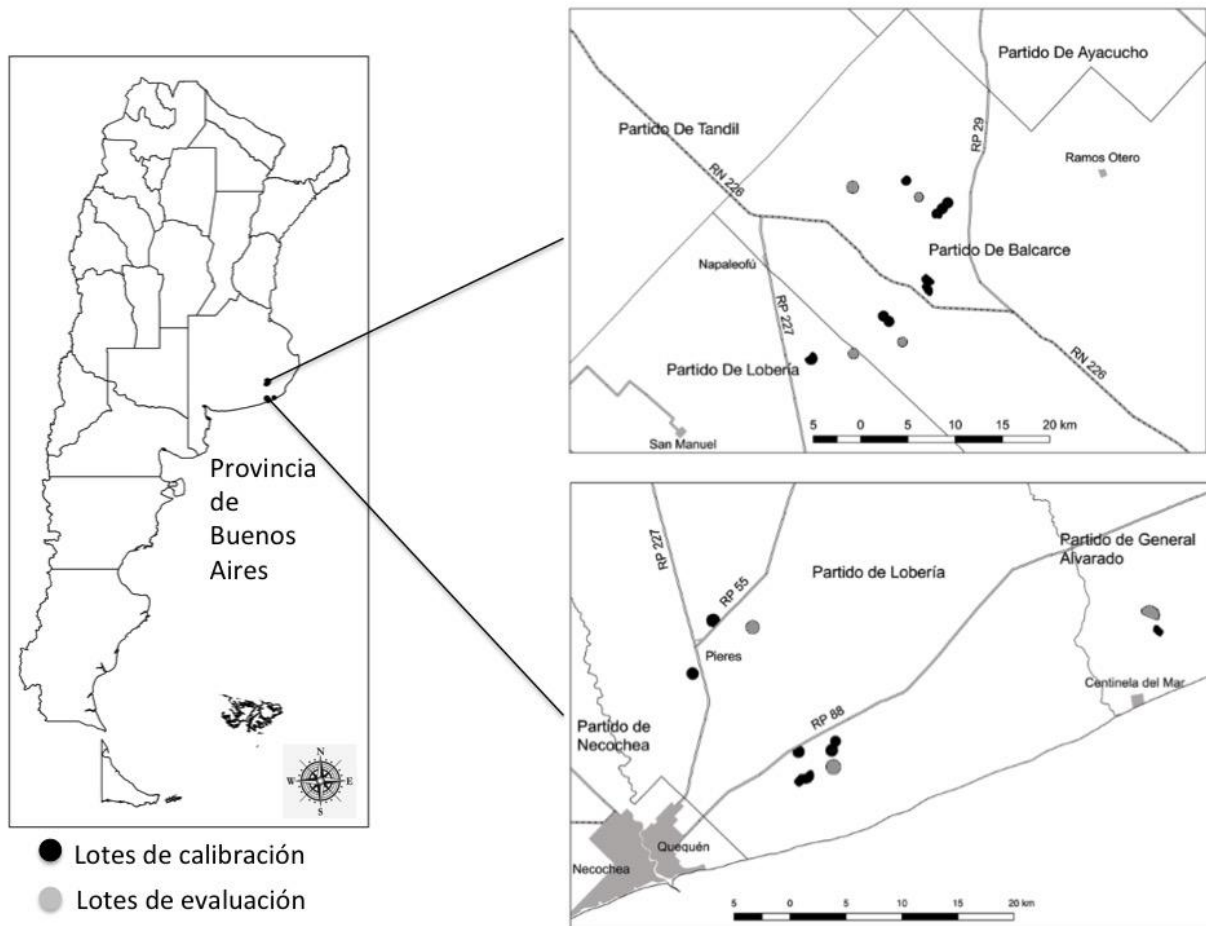


Figura 3: Ubicación de las 22 unidades muestrales (lotes) utilizadas. 15 correspondieron al set de datos utilizado para generar los modelos (lotes de calibración) y 7 fueron utilizadas para evaluar las estimaciones del modelo (lotes de evaluación).

Para la producción comercial de maíz se siembran líneas endocriadas de manera extensiva. Esto radica en el elevado vigor híbrido del cultivo de maíz, pero sobre todo en la posibilidad de cruzar líneas que actúen como padre y madre al presentar sus flores masculinas (proveedoras de polen) y femeninas (proveedoras de ovarios) en diferentes partes de las plantas (especie diclinomonoica). Así, la producción de maíz semilla se realiza a partir del cruce de dos líneas con

proporciones poblacionales diferentes según cada situación, dependiendo de la capacidad de polinización de la línea parental macho. Para este trabajo se utilizó una relación de siembra de 6 surcos de línea parental hembra y 2 surcos de línea parental macho.

Los lotes fueron regados con pivotes centrales (recibieron entre 150 y 200 mm durante todo el ciclo). La fertilización se dividió, con una primera aplicación a la siembra (promedio de 100 kg/ha de Fosfato Monoamónico) y una segunda aplicación entre V4 y V6 (Figura 4) (Ritchie *et al.* 1993), promedio 300 kg/ha de urea granulada.




Figura 4. Representación esquemática del ciclo ontogénico del maíz indicando los rasgos morfológicos externos, visibles macroscópicamente y los internos. También se indican los momentos aproximados en que queda fijado el número y tamaño de algunas estructuras de la planta (Ritchie *et al.* 1993).

En la totalidad de los lotes se manejaron las prácticas recomendadas para la producción de semillas de maíz, por lo que en todos los casos se controlaron las malezas, hubo una muy baja incidencia de daños de insectos (isoca de la espiga) y baja incidencia de enfermedades (roya). La sincronía floral entre hileras de líneas que actuaron como machos (proveyeron el polen) y hembras (proveyeron los ovarios y portaron las flores fecundadas que formaron granos) fue muy buena y no se observaron problemas de granazón en ningún lote. Se utilizaron 4 genotipos, fechas de siembra tradicionales de la región para evitar daños por heladas (entre el 15/10/2019 y el 8/11/2019), distanciamiento entre hileras de 52 cm y densidades de entre 110.000 pl/ha y 130.000 pl/ha (las recomendadas según el genotipo).

### **Obtención de datos satelitales**

Los datos satelitales utilizados para llevar a cabo este trabajo provienen del satélite Séntinel-2 de la ESA. La descarga de los datos se realizó utilizando el visor de la plataforma Land Viewer (<https://eos.com/landviewer>) seleccionando las de 0% de nubosidad. La ventana de tiempo definida para descargar las imágenes fue desde 07/12/2019 al 21/03/2020 para abarcar la totalidad de los períodos críticos de todos los lotes, estimados en 15 días antes de la fecha de floración y 15 días después. Posteriormente se realizó el procesamiento utilizando el software libre Qgis (Congedo, 2016). Para alivianar la descarga, se seleccionaron solamente las bandas del color rojo (banda 4 o “Rojo”) e infrarrojo (banda 8 o “NIR”) ya que con estas se calcula el índice NDVI. Se descargaron los “tiles” 21HUT y 21HUU en diferentes fechas para formar las series temporales de NDVI para las 22 unidades muestrales (lotes) que se mencionaron arriba y fueron el objeto de estudio.

## Generación de series temporales de NDVI

Para analizar el ajuste entre el NDVI y el rendimiento se decidió, en primer lugar, confeccionar series temporales del índice promedio por lote. Para ello, a partir de las imágenes descargadas se calculó el NDVI a partir de las bandas 4 y 8 utilizando la ecuación 1. Posteriormente, de cada imagen de NDVI generada se extraen los datos correspondientes a cada lote a partir de un “clip” utilizando como límite un archivo “*Shape*” (.SHP) que contiene la geometría del lote. Todos estos pasos fueron realizados con el software Qgis.

Para evitar desfases entre las curvas de NDVI generadas satelitalmente debido a las diferentes fechas de siembra de los lotes se utilizó la expresión “Días desde Siembra” (DDS). Para calcular los DDS correspondientes a cada recorte de imagen, se utilizó la siguiente ecuación:

Ecuación 2: 
$$\text{DDS} = \text{Fecha de Imagen} - \text{Fecha de Siembra} \text{ (Tabla 1)}$$

Tabla 1: Fechas de siembra, fechas de floración (50% de los estigmas receptivos) y días desde siembra hasta la fecha de floración para cada una de las 15 unidades muestrales que compusieron el set de datos para la evaluación del momento de mayor bondad de ajuste.

Lote	SIEMBRA	50% FLORACION	DDS
UN3983G	19/10/19	28/1/20	101
UN3988	31/10/19	3/2/20	95
UN3981A	1/11/19	26/1/20	86
UN3985	2/11/19	25/1/20	84
UN50343	3/11/19	25/1/20	83
UN09414	30/10/19	2/2/20	95
UN096LN4	6/11/19	4/2/20	90
UN3972	5/11/19	29/1/20	85
UN2004	6/11/19	31/1/20	86
UN3975	19/10/19	30/1/20	103
UN20023	16/10/19	1/2/20	108
UN4008	22/10/19	29/1/20	99
UN20017A	21/10/19	7/2/20	109

UN2008	4/11/19	29/1/20	86
UN20017B	15/10/19	5/2/20	113

Luego, se ubicó el dato de NDVI promedio de cada lote y fecha de la imagen en un vector cronológico que comprende el rango de tiempo estudiado en DDS. Una vez ubicados los datos de NDVI en el vector cronológico de DDS, se interpolaron linealmente los valores faltantes entre cada uno de los valores obtenidos (Tabla 2).

Tabla 2: Ejemplo de interpolación lineal de valores de NDVI para un vector cronológico en DDS.

NDVI Promedio	0,69				0,78				0,85
NDVI Interpolado	0,69	0,71	0,75	0,77	0,78	0,80	0,82	0,84	0,85
DDS	70	71	72	73	74	75	76	77	78

Para calcular el NDVI de los días donde no hay imágenes se utiliza la siguiente expresión:

Ecuación 3: 
$$\Delta_{\text{NDVI}} = \frac{(\text{NDVI fecha posterior} - \text{NDVI fecha anterior})}{\text{cantidad de días entre imágenes}}$$

### **Generación de datos de NDVI acumulados por ventana de tiempo**

Una vez completada la serie temporal con datos diarios, se dividió en ventanas de tiempo de 10 días a partir de la fecha del 50% de floración en el lote y se calculó la suma de los valores de NDVI diarios dentro de cada ventana. La fecha de floración de cada lote se determina cuando el 50% de los individuos muestreados presentan estigmas receptivos a la vista (Figura 5, Tabla 1).



Figura 5. Imagen de una espiga de maíz con estigmas receptivos a la vista, indicador del momento de floración por individuo.

A partir de la fecha donde el 50% de los individuos muestreados presenten estigmas receptivos se contabilizan los DDS para generar las ventanas de tiempo de 10 días. Las ventanas de tiempo quedan definidas de la siguiente manera (Figura 6):

**10-0 da50F:** desde 10 días antes de la fecha donde se determinó el 50% de los individuos en etapa de floración (estigmas receptivos).

**0-10 dd50F:** desde la fecha donde se determinó el 50% de los individuos en etapa de floración hasta 10 días después de dicha fecha.

**10-20 dd50F:** desde 10 días después de la fecha de floración hasta 20 días después de dicha fecha.

**20-30 dd50F:** desde 20 días después de la fecha de floración hasta 30 días después de dicha fecha.



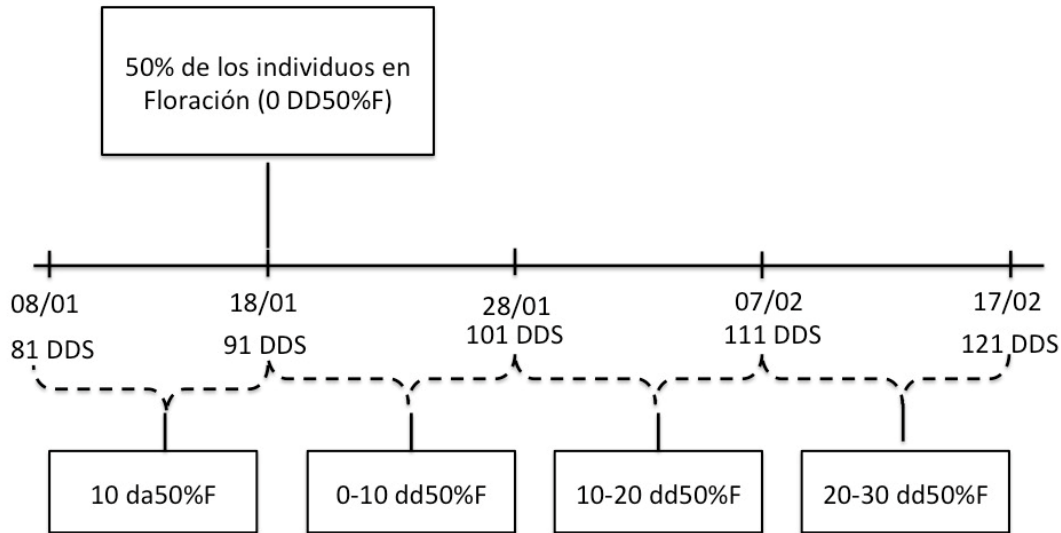


Figura 6. Esquema de días que abarcan las ventanas de tiempo en función de la fecha donde se detectó el 50% de los individuos en etapa de floración.

Dentro de cada ventana de tiempo se decidió utilizar la suma de los valores de NDVI para poder tener una medida de las condiciones que exploró el cultivo durante ese período siendo el NDVI acumulado mejor que el promedio.

### Obtención de datos de rendimiento bruto

Cuando un lote de producción de semillas alcanzó una humedad establecida según las especificaciones, se inició la cosecha. Las espigas se transportaron en camiones a la planta de procesamiento. En dicha planta, se extrajo una muestra por cada camión tal cual llegó del campo. Las muestras obtenidas de todos los camiones que salieron del lote se consolidaron para formar una

muestra compuesta. La muestra compuesta se pesó, deschaló y se le midió la humedad. Los granos obtenidos se secaron y se llevaron a una humedad del 14%, a este nivel de humedad se hizo el pesaje para obtener el peso seco. A partir del peso húmedo y el peso seco se calculó un factor de conversión que se utilizó para calcular el peso seco en grano de todo lo ingresado a planta. Por último, el peso seco total obtenido se dividió por la cantidad de hectáreas del lote, siendo el resultado el rendimiento bruto del correspondiente lote.

### **Muestreo convencional para estimación de rendimiento a campo**

Para realizar la estimación de rendimiento por lote en kg de semilla por hectárea se contabilizaron los componentes del rendimiento entre los 30 y 35 días luego de finalizado el período de floración (estadíos R3-R4). Para ello, se determinaron 6 estaciones de muestreo por lote. En cada estación, se realizó un recuento de población identificando el número de plantas con espigas granadas en una distancia lineal de 19,2 m de la línea hembra en 6 surcos consecutivos. Luego se recolectaron muestras para realizar el conteo de granos, se extrajeron 5 espigas principales consecutivas de cada uno de los 6 surcos de la línea hembra en forma escalonada (total 30) (Figura 7). El conteo de granos se realizó de forma digital utilizando un equipo “seed counter” que determina, a partir de algoritmos de visión artificial, la cantidad de granos junto con el largo y ancho de la espiga («Machvision – Inspección por imagen» s. f.). Se promedió la cantidad de granos por espiga de cada sitio de muestreo y luego se lo multiplicó por la cantidad de individuos contados. Posteriormente, se multiplicó el número de granos por el peso de las semillas para el genotipo sembrado a partir del promedio histórico registrado. Por último, la magnitud obtenida debe ser afectada por un factor de corrección para determinar los kg por hectárea del sitio. El factor de

corrección (0,75) se debe a la proporción de la superficie sembrada con parental hembra (75%) y parental macho (25%).

### **Método de muestreo para estimación de rendimiento**




Figura 7: Esquema del procedimiento de muestreo de los componentes del rendimiento a campo para líneas de maíz utilizadas para producir semilla en el Sudeste de Buenos Aires.

### **Análisis estadístico**

Referente a la hipótesis de trabajo 1 que postula:

Existe una estrecha relación entre los valores acumulados de NDVI y el rendimiento real que aumenta hacia el final del período crítico (entre 10 y 20 días desde el 50% de floración).

Para contrastar la hipótesis 1, se evaluó la bondad de ajuste ( $R^2$ ) de los datos acumulados de NDVI por ventana de tiempo con el rendimiento real.


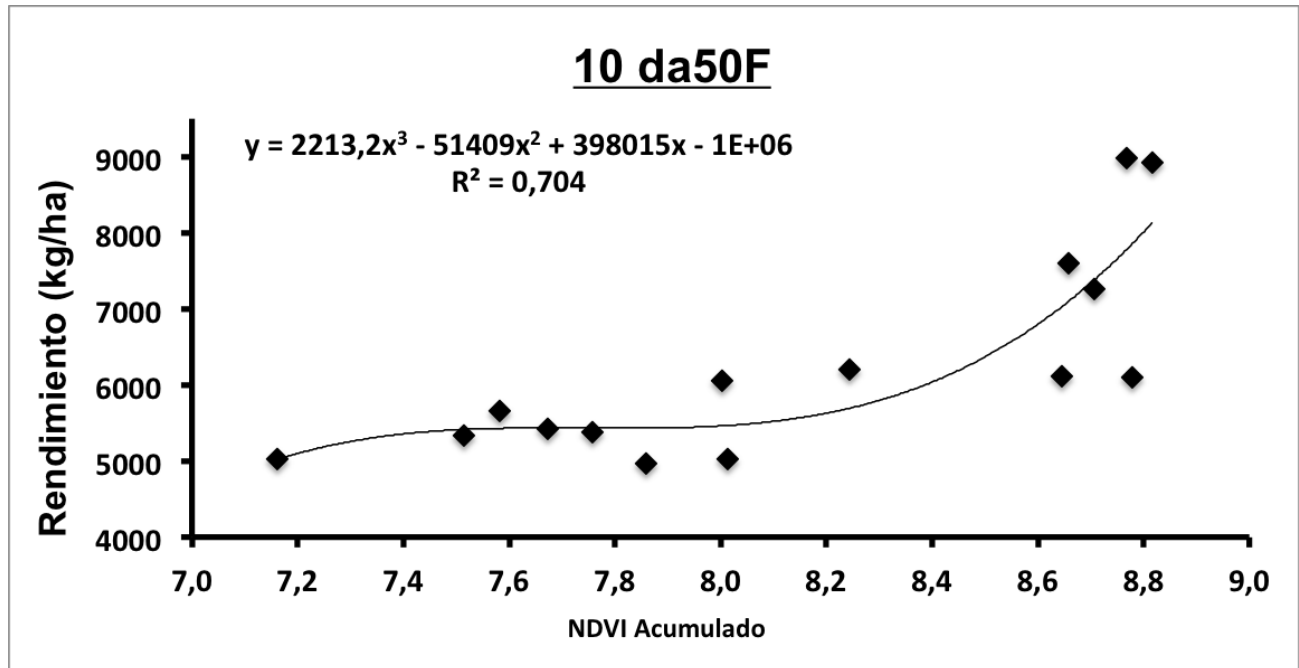
Referente a la hipótesis de trabajo 2 que postula:

El modelo funcional (bilineal) derivado de la ventana de mayor bondad de ajuste permite realizar estimaciones de rendimiento más precisas que el método de estimación convencional a campo a nivel regional y de lote.

Para contrastar la hipótesis 2 se seleccionó la ventana de tiempo de mayor bondad de ajuste para generar un modelo bilineal que tenga sentido fisiológico. Para el conjunto completo de datos de validación, rendimiento a nivel regional, fue analizada la magnitud de las diferencias entre el rendimiento promedio real y rendimiento promedio estimado. Luego, las diferencias por lote se analizaron con la raíz del error cuadrático medio (RMSE) y la diferencia máxima absoluta. Finalmente, se evaluó la relación entre el rendimiento real y las estimaciones realizadas por cada método en comparación con un modelo ideal hipotético donde la pendiente de la curva de regresión lineal es 1 y el intercepto es cero. En la siguiente sección se presentan los resultados teniendo en cuenta lo anterior.

## **Resultados**

Se observó una tendencia positiva entre el NDVI acumulado y el rendimiento real en todas las ventanas de tiempo analizadas. La bondad de ajuste ( $R^2$ ) de los modelos polinomiales generados va en aumento hacia el final del período crítico, en la ventana de tiempo de 10 a 20 días desde el momento donde se observó el 50 % de floración en los individuos muestreados (Figura 8, Tabla 3).







Figura 8: Modelos de regresión polinomial de Rendimiento real en función del NDVI acumulado para las ventanas de tiempo seleccionadas en función de la fecha donde se observó el 50 % de los individuos en floración.

Tabla 3: Resultados de los análisis estadísticos asociados a cada modelo polinomial por ventana de tiempo.

Modelo	R <sup>2</sup>
10 da50F	0,704
0-10 dd50F	0,836
10-20 dd50F	0,906
20-30 dd50F	0,376

A partir de la ventana de tiempo que va desde los 10 a los 20 días desde el 50% de floración se generó el modelo funcional compuesto por dos ecuaciones de primer grado (Modelo Bilineal) con un umbral de corte de 8,4 de NDVI acumulado (Figura 9).

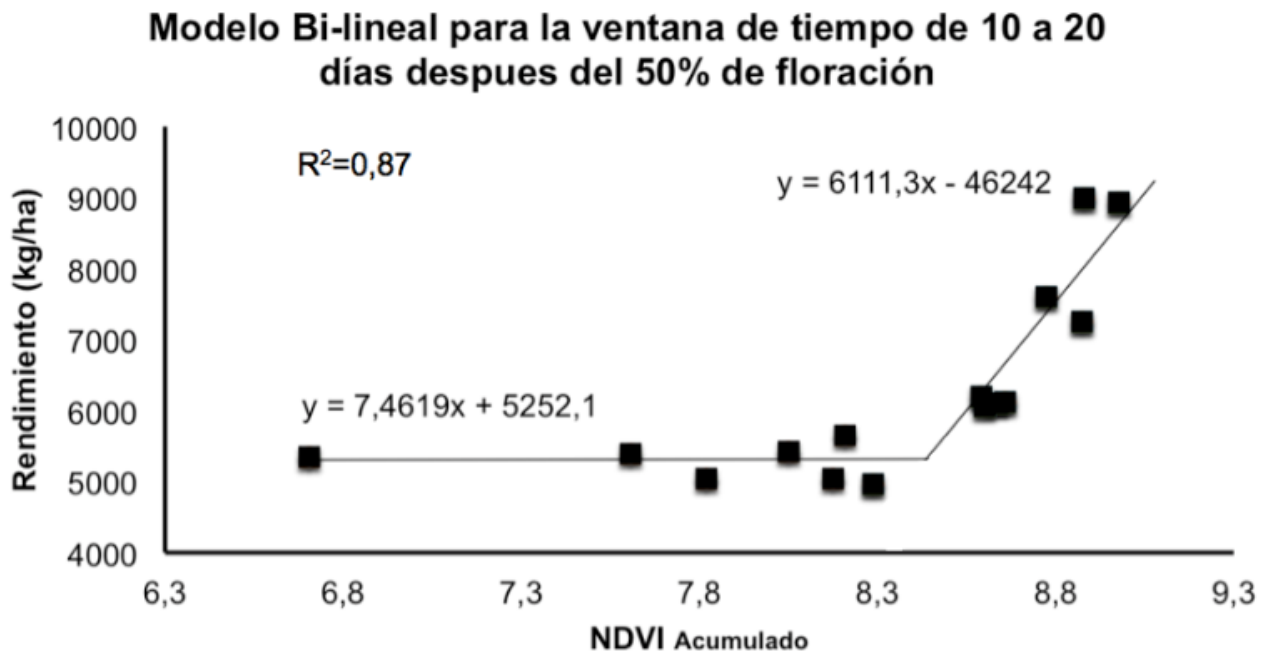


Figura 9: Modelo bilineal para la estimación de rendimiento generado con datos de NDVI acumulados entre los 10 y 20 días desde el 50% de floración.

Al analizar la precisión de las estimaciones, con los 7 lotes de set de datos de validación, se observa una mayor aproximación al rendimiento real otorgada por el modelo satelital para el rendimiento promedio conjunto de todos los lotes, rendimiento a nivel regional (Figura 10, tabla 4).

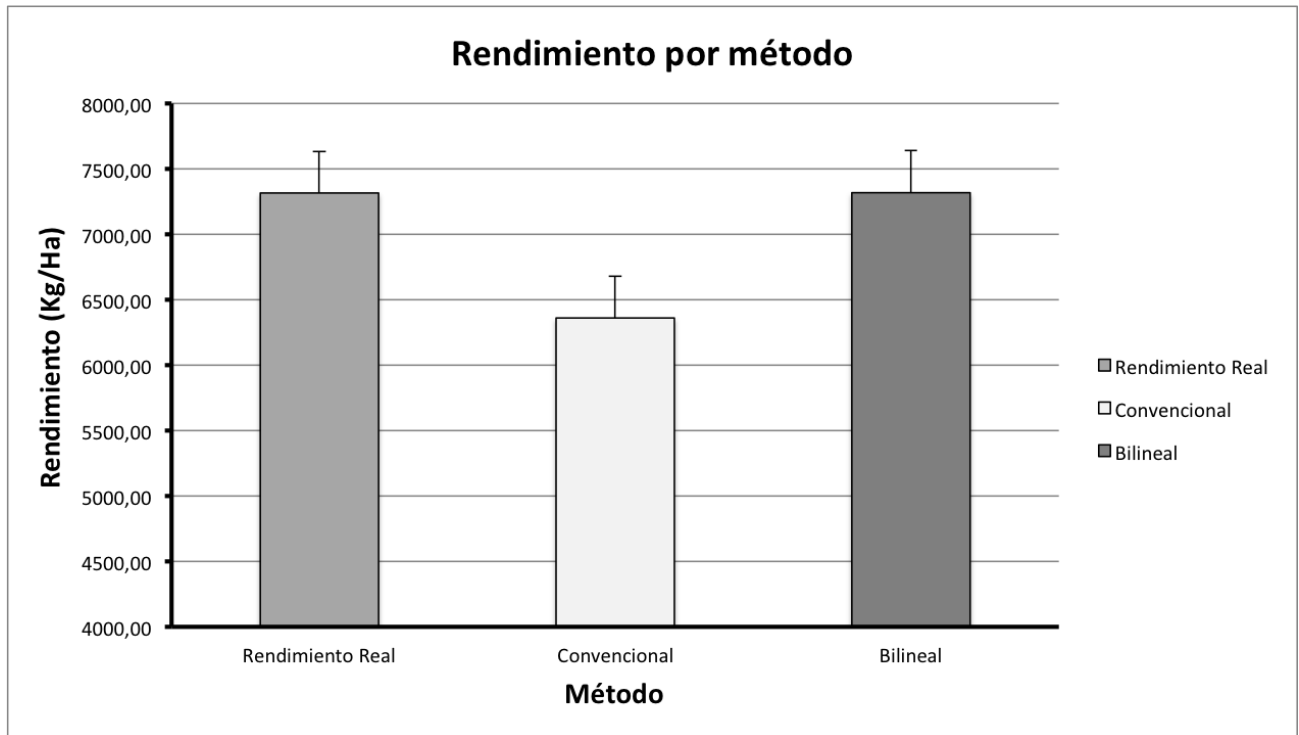


Figura 10: Rendimiento bruto (gris intermedio), rendimiento estimado por el modelo satelital utilizando la ventana de tiempo de 10 a 20 días desde el 50% de floración (gris claro) y rendimiento estimado por muestreo convencional (gris oscuro) promedio para los 7 lotes de validación.

Tabla 4: Resumen de las diferencias entre los modelos a nivel regional.

RENDIMIENTO POR MÉTODO			DIFERENCIAS (Metodo-Real)	
Rend. Real	SAT. Bilineal	Convencional	SAT. Bilineal	Convencional
7316	7318	6361	-2,3	-955

Analizando las diferencias lote por lote entre los métodos de estimación y el rendimiento real obtenido, se obtuvo un RMSE (raíz del error cuadrático medio) de 1029 kg/ha (14% de error



relativo) para el método bilineal generado por satélite y 1499 kg/ha (20% de error relativo) para el método convencional (tabla 5).

Tabla 5: Resumen de las diferencias entre los métodos de estimación lote a lote.

	Dif. Abs. Prom.	Min. Dif. Abs.	Max. Dif. Abs.	RMSE	Error relativo (%)
Est. Convencional	1115,01	82,65	2549,01	1499,01	20
Mod. Bilineal	957,09	447,65	1450,22	1029,52	14

Además, se analizó el rendimiento real versus el predicho por ambos métodos de estimación (“Satelital” y “Convencional”) comparado con el modelo hipotético ideal observándose que la línea de tendencia que se genera con los datos del modelo satelital se asemeja más a la que se obtendría con un modelo de estimación ideal (donde  $y = x$ ) (Figura 11).

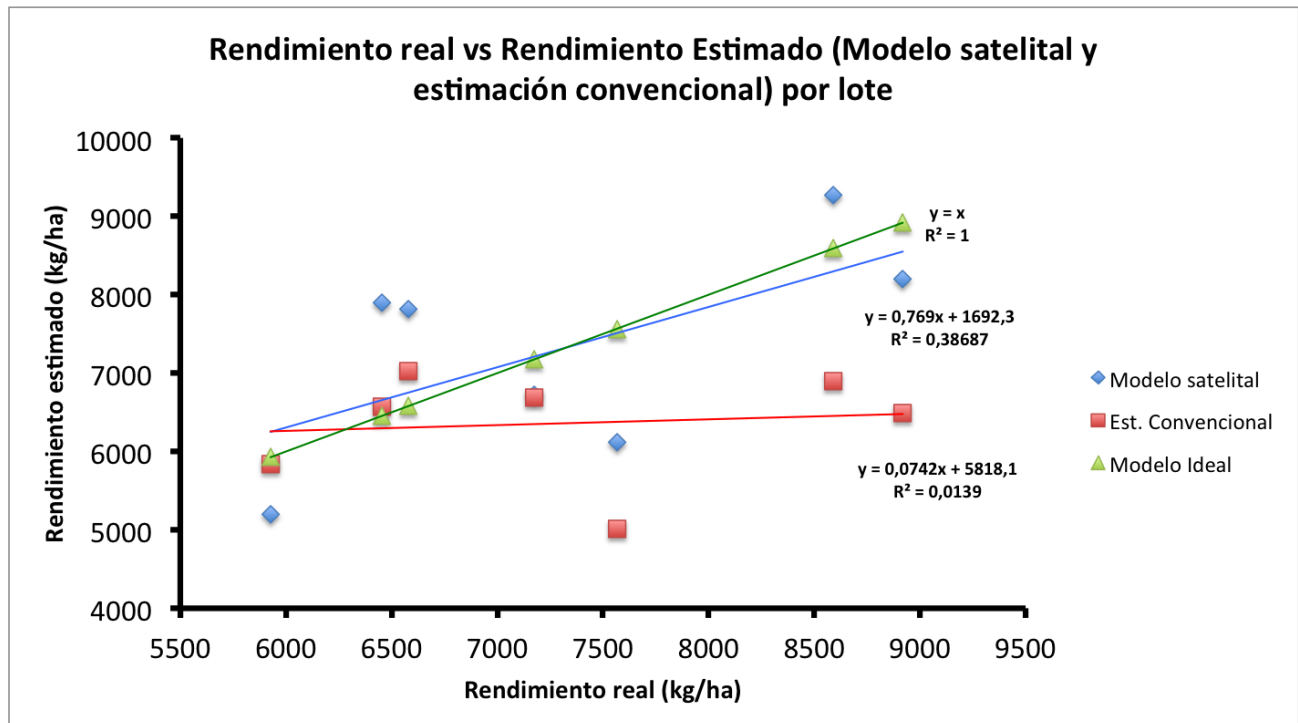


Figura 11: Gráfico de regresión lineal entre el rendimiento real y el rendimiento estimado a través del modelo satelital, el método de estimación convencional a campo y un hipotético modelo ideal ( $y = X$ ).

## Discusión

La agricultura de precisión emplea diversas herramientas y tecnologías para identificar la variabilidad de los cultivos y del suelo para optimizar insumos y mejorar prácticas de manejo. La teledetección, constituye en la actualidad un componente más de la agricultura de precisión para realizar el monitoreo del suelo y los cultivos (Bottega *et al.* 2017). Los datos radiométricos con alta resolución espacial y temporal provenientes de la teledetección presentan un potencial para describir la variación espaciotemporal de los parámetros biofísicos de los cultivos. En tal sentido, la reciente disponibilidad de datos de imágenes satelitales de Sentinel-2, con mejor resolución espacial que Landsat 8 y bandas más específicas para identificar distintas propiedades de la vegetación, ofrece nuevas perspectivas para el monitoreo de cultivos y oportunidades para mejorar la precisión en estimaciones de rendimiento de lotes de maíz semilla.

El período crítico para la determinación del rendimiento abarca desde los 15 días antes del momento de floración hasta 15 días después. La incidencia de un estrés hídrico o lumínico provoca mayores mermas en el número de granos cuando tiene lugar en este período, que coincide con el de crecimiento activo de la espiga, la emergencia de estigmas y el inicio de llenado de granos. Sobre el final del período crítico de los lotes cultivados los valores de NDVI acumulados incrementaron su asociación con los rendimientos reales obtenidos, medido por su bondad de ajuste ( $R^2$ ). El momento de mayor ajuste entre las variables coincide con la ventana de tiempo final de dicho período (10-20 dd50F). Al comenzar esta ventana temporal ya todos los individuos han presentado estigmas receptivos y, si hubo una buena polinización de la línea macho, se estaría dando el llenado efectivo de los granos. Esta etapa se caracteriza por una acumulación de almidón en los granos definiéndose el peso de estos. La cantidad de biomasa vegetativa que muestra el cultivo en esta etapa es

condicionante para determinar el rendimiento final. Los lotes que han llegado con una mayor cantidad de biomasa vegetal tuvieron mayor capacidad de llenar los granos. Por el contrario, en lotes con baja biomasa vegetal, o sea bajo NDVI acumulado en dicha ventana temporal, se pudo observar fallas de granazón por aborto de granos que van desde la punta de la espiga hacia la base. A esto hay que sumarle el factor ambiental ya que un cultivo con buena biomasa vegetal tiene la capacidad de aprovechar mejor la radiación solar incidente y generar una mayor tasa de crecimiento permitiendo un mejor flujo de asimilados hacia el grano. Los resultados encontrados en esta ventana de tiempo concuerdan con lo encontrado por Shanahan *et al.* (2001) en un trabajo realizado en parcelas experimentales de 7.3 por 15.2m en Shelton (Nebraska) donde se observó un mayor ajuste entre índices satelitales de vegetación (en este caso GNDVI) y el rendimiento durante la etapa de llenado de granos.

A partir de los datos de esta ventana de tiempo puede observarse un punto de inflexión alrededor del valor 8,4 de NDVI acumulado que divide a los datos en dos patrones distintos. Por debajo de dicho umbral los incrementos en los valores de NDVI no muestran incrementos significativos en el rendimiento. Por el contrario, por encima del umbral se observan incrementos pronunciados del rendimiento a medida que aumentan los valores de NDVI acumulados. Esto permitió generar un modelo bilineal para la estimación del rendimiento con un mayor sentido fisiológico que la ecuación polinomial de grado 3.

Durante los primeros días de la primera ventana de tiempo analizada (10da50F), se observa baja cantidad de individuos con estigmas receptivos y hacia el final de dicha ventana se llega al 50% de individuos en estado de floración. Esto quiere decir que a los lotes analizados aún les quedan hojas por expandir y no han llegado a su biomasa vegetativa final. A su vez, la poca cantidad de estigmas receptivos hacen que pueda haber efectos negativos de la polinización sobre el

rendimiento. En esta etapa, el componente del rendimiento que mayormente se ve afectado es el número de granos.

En la segunda ventana de tiempo analizada (0-10dd50F) podemos ver desde el 50% de los individuos con estigmas receptivos pasando por un 100% sobre la mitad de la ventana y llegando con un 50% de los individuos con estigmas secos hacia el final de esta. En este momento podemos pensar que se está definiendo el número potencial de granos, y un estrés (hídrico, lumínico, térmico etc.) podría ocasionar mermas en la tasa de crecimiento del cultivo que afectarían al rendimiento final. Este motivo podría explicar que la bondad de ajuste entre las variables aumenta con respecto a la ventana de tiempo anterior, pero existe variabilidad en los rendimientos reales no explicada por la variación en el NDVI acumulado.

En la última ventana de tiempo analizada (20-30dd50F) el ajuste entre las variables disminuye por lo que variaciones del NDVI acumulado no estaría explicando el rendimiento final. En esta etapa los lotes muestran una coloración más amarillenta debido a que disminuyen los pigmentos fotosintéticos como la clorofila. Esto es más notorio en lotes de altos niveles de NDVI acumulados donde aumenta la dispersión comparada con lotes de menores NDVI acumulados. Esto podría deberse a diferencias del largo de ciclo de cultivos entre genotipos en cada lote. Lotes con genotipos de ciclo corto tendrían menor cantidad de NDVI acumulados, pero podrían tener una excelente granazón que luego se expresaría en rendimiento.

A partir de las estimaciones realizadas con el modelo satelital bilineal se obtienen datos de rendimiento a nivel regional (7318 kg/ha) más cercanos a los rendimientos reales obtenidos (7316 kg/ha), comparado con el método de estimación convencional (6361 kg/ha). Analizando los resultados lote por lote podemos observar que el método convencional es más preciso que el modelo satelital para lotes con rendimientos bajos (menores a 7200 kg/ha). Por el contrario, para lotes con

altos rendimiento (mayores a 7200 kg/ha) con el modelo satelital se obtienen mejores resultados. A su vez, se puede observar que la línea de tendencia generada con los datos obtenidos con el modelo satelital tiene mayor similitud con la línea de tendencia de un hipotético modelo ideal donde los rendimientos estimados son exactamente iguales a los rendimientos reales. Con el modelo satelital se obtuvo un RSME de 1029 kg/ha (14% de error relativo) mientras que con el método convencional se obtuvo un RMSE de 1499 kg/ha (20% de error relativo). Los valores de RMSE encontrados en este estudio son comparables a valores encontrados en la literatura. Por ejemplo, Vaiman (2018) obtuvo un RMSE de 820 kg/ha (error relativo del 22%) con un modelo basado en estimaciones satelitales de precipitaciones de la misión TRMM (*Tropical Rain Measured Mision*) y 363 kg/ha (error relativo de 8 %) con un modelo basado en índices de vegetación satelital para distintos departamentos de la provincia de Entre Ríos.

La metodología propuesta en este trabajo resultó adecuada para generar series temporales de índices de vegetación satelital para determinar el momento de mejor ajuste con el rendimiento real al igual que lo observado por Battude *et al.* (2016) donde utilizaron una fusión de sensores. En dicho estudio se demuestra el gran potencial de los datos de teledetección de alta resolución espacial y temporal simulando la misión Sentinel-2. El trabajo mencionado destaca la importancia del muestreo temporal utilizando datos de sensores múltiples. Sin embargo, el impacto del muestreo espectral de Sentinel-2 no pudo ser evaluado por Battude por lo que resultó de gran interés para desarrollarlo en el presente trabajo.

La metodología de interpolación lineal permitió tener una cobertura diaria de NDVI con lo cual se pudieron generar los datos acumulados dentro de cada ventana de tiempo. En este sentido, cabe destacar que el valor de NDVI acumulado es mejor que el promedio de la ventana de tiempo ya que representa mejor las condiciones que exploró el cultivo en ese período de tiempo. Sin embargo,

esta metodología planteada demostró algunas limitaciones que podrían ser mejoradas a futuro. Una podría ser incorporando coeficientes que nos permitan valorar más cuando el NDVI va en aumento que cuando va en descenso. Otra podría ser aumentar el alcance de este trabajo a otras regiones de producción en las que, debido a factores edáficos y climáticos, las líneas de maíz podrían presentar una evolución diferente de NDVI a lo largo del ciclo. También, sería conveniente realizar nuevos estudios en la zona para evaluar posibles diferencias interanuales para que el modelo de estimación sea más robusto y disminuyan los errores. Además, se podrían separar los modelos por material genético para disminuir el efecto del genotipo sobre la curva de NDVI. Otro punto interesante sería evaluar ventanas de tiempo de mayor duración para considerar períodos que coincidan con bases funcionales (ej. cuaje 15 días o período crítico 30 días) o bien el NDVI acumulado desde emergencia hasta cierto punto del ciclo ya que podría ser interesante conocer con qué antelación se puede predecir el rendimiento.

Por último, una de las grandes ventajas de este trabajo consistió en la posibilidad de obtener estimaciones de rendimiento anticipadas (alrededor de un mes) con respecto al método convencional de conteo de los componentes del rendimiento. Esto es importante para la planificación anticipada dentro de la cadena de producción, posibilitando proyectar volumen y momento de ingreso de los materiales a la planta de procesamiento, cantidad de camiones para destinar a cada lote, pagos a los productores, etc. También es de suma importancia para la cadena de comercialización del producto posibilitando proyectar y desarrollar campañas de venta tempranas.

## Conclusión

En el primer objetivo de este trabajo se propuso evaluar el ajuste entre el NDVI acumulado en ventanas de tiempo de 10 días cercanas al momento de floración y el rendimiento real de maíz semilla en el Sudeste de Buenos Aires. Este objetivo ha sido cumplido y hemos observado que la ventana de 10-20 dd50F es la que mayor bondad de ajuste muestra con respecto a los datos de rendimiento real tal como postula la primera hipótesis de trabajo.

En el segundo objetivo se propuso generar un modelo que tenga sentido fisiológico para la ventana de tiempo de mayor ajuste y evaluar la precisión de las estimaciones. Este objetivo también ha sido cumplido ajustándose los datos a un modelo bilineal con el cuál se realizaron las estimaciones de rendimiento. Las estimaciones hechas por el método satelital son más precisas que las realizadas por el método convencional para datos regionales. Al analizar lote por lote se observó que la ecuación obtenida es mejor que el método convencional para estimar rendimientos altos y no pasa lo mismo con rendimientos bajos obteniéndose un menor error relativo para las estimaciones con el modelo satelital. Obtener estimaciones tempranas de rendimiento utilizando esta metodología permitiría mejorar las eficiencias productivas y comerciales en la industria de semillas de maíz.

## Referencias

- Battude, M., Al Bitar, A., Morin, D., Cros, J., Huc, M., Sicre, C. M., ... & Demarez, V. (2016). Estimating maize biomass and yield over large areas using high spatial and temporal resolution Sentinel-2 like remote sensing data. *Remote Sensing of Environment*, 184, 668-681.
- Bottega, E. L., de Queiroz, D. M., de Assis de Carvalho Pinto, F., Valente, D. S. M. y de Souza, C. M. A. (2017). Precision agriculture applied to soybean: Part III-Spatial and temporal variability of yield. *Australian Journal of Crop Science*, 11(7), 799-805. <https://doi.org/10.21475/ajcs.17.11.07.pne383>
- Cárcova, Jorgelina, Gabriela Abeledo, y Mónica López Pereira. 2003. «Análisis de la generación del rendimiento: crecimiento, partición y componentes.» En *Producción de Granos. Bases Funcionales para su Manejo*, editado por Antonio J. Pascale, 1º, 75-94. Ciudad Autónoma de Buenos Aires: Editorial Facultad de Agronomía, Universidad de Buenos Aires.
- Cárcova, Jorgelina, Lucas Borrás, y María Elena Otegui. 2003. «Ciclo ontogénico, dinámica del desarrollo y generación del rendimiento y la calidad en maíz.» En *Producción de Granos. Bases Funcionales para su Manejo*, 132-57. Facultad de Agronomía, Universidad de Buenos Aires. Buenos Aires, Argentina.
- Carpio Santos, Lisi Katherine. 2018. «El uso de la tecnología en la agricultura». *Pro Sciences: Revista de Producción, Ciencias e Investigación* 2 (14): 25-32. <https://doi.org/10.29018/issn.2588-1000vol2iss14.2018pp25-32>.
- Castillo, Álvaro Rincón, y Gustavo Adolfo Ligarreto. 2010. «Relación entre nitrógeno foliar y el contenido de clorofila, en maíz asociado con pastos en el Piedemonte Llanero colombiano». *Ciencia & Tecnología Agropecuaria* 11 (2): 122-28. [https://doi.org/10.21930/rcta.vol11\\_num2\\_art:202](https://doi.org/10.21930/rcta.vol11_num2_art:202).
- Cerrudo, A, J. Di Matteo, E. Fernandez, M. Robles, L. Olmedo Pico, y F. H. Andrade. 2013. «Yield components of maize as affected by short shading periods and thinning». *Crop and Pasture Science* 64 (6): 580-87. <https://doi.org/10.1071/CP13201>.
- Chang, Jiyul, David E. Clay, Kevin Dalsted, Sharon Clay, y Mary O'Neill. 2003. «Corn (Zea mays L.) Yield Prediction Using Multispectral and Multidate Reflectance». En *Agronomy Journal*, 95:1447-53. John Wiley & Sons, Ltd. <https://doi.org/10.2134/agronj2003.1447>.
- Congedo, L. 2016. Semi-automatic classification plugin documentation. *Release*, 4(0.1), 29.
- Cozzolino, D. 2017. The role of near-infrared sensors to measure water relationships in crops and plants. *Applied Spectroscopy Reviews*, 52(10), 837-849.
- De la Casa, Antonio, y Gustavo Ovando. 2007. «Integración del Índice de Vegetación de la Diferencia Normalizada (NDVI) y del ciclo fenológico de maíz para estimar el rendimiento a escala departamental en Córdoba, Argentina». *Agricultura Tecnica* 67 (4): 362-71. <https://doi.org/10.4067/s0365-28072007000400004>.
- Esperbernt, Cecilie, Gerardo Cervigni, Marcelo Ferrer, Jorge Parrado, y Juliana Iglesias. 2018. «Estudian cómo diseñar semillas multirresistentes». *Revista de Investigaciones Agropecuarias* 44 (2): 9-13.



<https://repositorio.inta.gob.ar/handle/20.500.12123/3349>.

- Ferreira, R. A., Podestá, G. P., Messina, C. D., Letson, D., Dardanelli, J., Guevara, E., y Meira, S. 2001. A linked-modeling framework to estimate maize production risk associated with ENSO-related climate variability in Argentina. *Agricultural and Forest Meteorology*, 107(3), 177-192.
- Frampton, W. J., Dash, J., Watmough, G., y Milton, E. J. (2013). Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS journal of photogrammetry and remote sensing*, 82, 83-92.
- Gitelson, Anatoly A., Andrés Vina, Timothy J. Arkebauer, Donald C. Rundquist, Galina Keydan, y Bryan Leavitt. 2003. «Remote estimation of leaf area index and green leaf biomass in maize canopies». *Geophysical Research Letters* 30 (5). <https://doi.org/10.1029/2002gl016450>.
- Goldsworthy, P.R., y N.M. Fisher. 2008. «The Physiology of Tropical Field Crops.» *Experimental Agriculture* 21 (04): 409. <https://worldveg.tind.io/record/1195>.
- Golik, Silvina, Matías Schierenbeck, Juan Dietz, y María Fleitas. 2018. «Maíz: Crecimiento y desarrollo del cultivo de maíz». En *Cereales de verano*, 26-40. Universidad Nacional de La Plata. <https://ri.conicet.gov.ar/handle/11336/162703>.
- Guamán Guamán, Rocío Noemí, Teodoro Xavier Desiderio Vera, Ángel Fabián Villavicencio Abril, Santiago Miguel Ulloa Cortázar, y Edison Javier Romero Salguero. 2020. «Evaluación del desarrollo y rendimiento del cultivo de maíz (*Zea mays* L.) utilizando cuatro híbridos.» *Siembra* 7 (2): 047-056. <https://doi.org/10.29166/siembra.v7i2.2196>.
- Huang, Sha, Lina Tang, Joseph P. Hupy, Yang Wang, y Guofan Shao. 2021. «A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing». *Journal of Forestry Research*. <https://doi.org/10.1007/s11676-020-01155-1>.
- Huber, Steffen, Hajo Wiemer, Dorothea Schneider, y Steffen Ihlenfeldt. 2019. DMME: Data mining methodology for engineering applications - A holistic extension to the CRISP-DM model. En *Procedia CIRP*, 79:403-8. Elsevier. <https://doi.org/10.1016/j.procir.2019.02.106>.
- Jermthaisong, P., Kingpaiboon, S., Chawakitchareon, P., y Kiyoki, Y. 2019. Relationship between vegetation indices and SPAD values of waxy corn using an unmanned aerial vehicle. *Inf. Model. Knowl. Bases*, 30, 312.
- Khaki, S., Pham, H., Han, Y., Kuhl, A., Kent, W., y Wang, L. 2020. Convolutional neural networks for image-based corn kernel detection and counting. *Sensors*, 20(9), 2721.
- «Machvision – Inspección por imagen». s. f. Accedido 3 de noviembre de 2022. <https://machvision.com.ar/>.
- Maddoni, G. A., M. E. Otegui, y R. Bonhomme. 1998. «Grain yield components in maize II. Postsilking growth and kernel weight». *Field Crops Research* 56 (3): 257-64. [https://doi.org/10.1016/S0378-4290\(97\)00094-4](https://doi.org/10.1016/S0378-4290(97)00094-4).
- Pérez, Adriana, M Milla, M Mesa, Ms C Adriana Pérez, Investigador Agregado, y C M Milla. 2006. «Revisión bibliográfica IMPACTO DE LAS TECNOLOGÍAS DE LA INFORMACIÓN Y LA COMUNICACIÓN EN LA

- AGRICULTURA». *Cultivos Tropicales* 27 (1): 11-17.  
<https://www.redalyc.org/pdf/1932/193215885002.pdf>.
- Quiring, S. M., y Legates, D. R. 2008. Application of CERES-Maize for within-season prediction of rainfed corn yields in Delaware, USA. *Agricultural and forest meteorology*, 148(6-7), 964-975.
- Reol, E. M. 2003. Los pigmentos fotosintéticos, algo más que la captación de luz para la fotosíntesis. *Ecosistemas*, 12(1).
- Riquelme, José C., Roberto Ruiz, y Karina Gilbert. 2006. «Minería de datos: Conceptos y tendencias». *Inteligencia Artificial* 10 (29): 11-18. <https://idus.us.es/handle/11441/43290>.
- Ritchie, S. W., Hanway, J. J., y Benson, G. O. 1993. How a corn plant develops. Iowa State Univ. *Coop. Ext. Serv. Spec. Rep*, 48, 21.
- Salvador Naya, Autor. 2018. «Nuevo paradigma de big data en la era de la industria 4.0.» *Revista electrónica de terapia ocupacional Galicia, TOG, ISSN-e 1885-527X, N.º. 27 (V.15,mayo), 2018*. Vol. 15. <https://dialnet.unirioja.es/servlet/articulo?codigo=6489657>.
- Sanchez Duarte, Esmeralda. 2008. «Las tecnologías de información y comunicación (TIC) desde una perspectiva social». *Revista Electrónica Educare* XII: 155-62.  
<https://www.redalyc.org/pdf/1941/194114584020.pdf>.
- Shanahan, J. F., J. S. Schepers, D. D. Francis, G. E. Varvel, W. W. Wilhelm, J. M. Tringe, M. R. Schlemmer, y D. J. Major. 2001. «Use of remote-sensing imagery to estimate corn grain yield». *Agronomy Journal* 93 (3): 583-89. <https://doi.org/10.2134/agronj2001.933583x>.
- Smith, R. C.G., J. Adams, D. J. Stephens, y P. T. Hick. 1995. «Forecasting wheat yield in a Mediterranean-type environment from the NOAA satellite». *Australian Journal of Agricultural Research* 46 (1): 113-25.  
<https://doi.org/10.1071/AR9950113>.
- Song, Libing, y Jiming Jin. 2020. Improving CERES-Maize for simulating maize growth and yield under water stress conditions. *European Journal of Agronomy* 117 (julio): 126072.  
<https://doi.org/10.1016/j.eja.2020.126072>.
- Sotomayor, Octavio, Eduardo Ramirez, y Hugo Martinez. 2021. «Digitalización y cambio tecnológico en las mipymes agrícolas y agroindustriales en América Latina». *Naciones Unidas & FAO L*: 111-21.  
<https://repositorio.cepal.org/handle/11362/46965>.
- Srbínovska, Mare, Cvetan Gavrovski, Vladimir Dimcev, Aleksandra Krkoleva, y Vesna Borozan. 2015. Environmental parameters monitoring in precision agriculture using wireless sensor networks. *Journal of Cleaner Production* 88 (febrero): 297-307. <https://doi.org/10.1016/j.jclepro.2014.04.036>.
- Teal, RK, B Tubana, K Girma, ... KW Freeman - Agronomy, y undefined 2006. 2006. «In-season prediction of corn grain yield potential using normalized difference vegetation index». *Wiley Online Library* 98 (6): 1488-94. <https://doi.org/10.2134/agronj2006.0103>.
- Torres Flores, Jose Luis, David Lewis Beck, Aquiles Carballo Carballo, y J. Arturo Estrada Gómez. 2004. «Técnicas para sincronizar floración en la producción de semilla híbrida de maíz». *redalyc.org* 30 (1):

89-100. <https://www.redalyc.org/pdf/608/60830108.pdf>.

- Vaiman, N. 2018. *Comparación de índices climáticos y espectrales en la estimación de rendimiento de maíz y soja a nivel departamental en Entre Ríos* (Doctoral dissertation, Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales).
- Venancio, L. P., Filgueiras, R., da Cunha, F. F., dos Santos Silva, F. C., dos Santos, R. A., y Mantovani, E. C. (2020). Mapping of corn phenological stages using NDVI from OLI and MODIS sensors Mapeamento dos estádios fenológicos da cultura do milho utilizando o NDVI derivado dos sensores OLI e MODIS. *Semina: Ciências Agrárias, Londrina*, 41(5), 1517-1534.
- Verhulst, N, y B Govaerts. 2010. *The normalized difference vegetation index (NDVI) Greenseeker(TM) handheld sensor: toward the integrated evaluation of crop management part A: concepts and case studies.* México D.F.: CIMMYT. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=57f116fa910cb542caed278f5ab804cdcf97078>.
- Von Braun, Joachim von. 2020. Climate Change Risks for Agriculture, Health, and Nutrition. En *Health of People, Health of Planet and Our Responsibility*, 135-48. [https://doi.org/10.1007/978-3-030-31125-4\\_11](https://doi.org/10.1007/978-3-030-31125-4_11).
- Weiss, M., F. Jacob, y G. Duveiller. 2020. «Remote sensing for agricultural applications: A meta-review». *Remote Sensing of Environment* 236 (enero): 111402. <https://doi.org/10.1016/J.RSE.2019.111402>.
- Yang, Zhengwei, Wen bin WU, Liping Di, y Berk Üstündağ. 2017. «Remote sensing for agricultural applications». *Journal of Integrative Agriculture*. [https://doi.org/10.1016/S2095-3119\(16\)61549-6](https://doi.org/10.1016/S2095-3119(16)61549-6).