

Universidad Nacional de Rosario  
Facultad de Ciencias Exactas, Ingeniería y Agrimensura



Tesis Doctoral

**Modelación numérica del sistema suelo-agua-planta  
con una metodología de optimización multi-objetivo  
para la calibración de la dinámica de crecimiento y  
desarrollo de soja HaHB4**

Montero Bulacio Enrique

Director: Dra. Portapila Margarita Isabel  
Co-Director: Dra. Otegui María Elena

Miembros del Jurado: Dra. Rodríguez Leticia  
Dr. Salvagiotti Fernando  
Dr. Stenta Hernán Roberto

*Tesis presentada en la Facultad de Ciencias Exactas, Ingeniería y  
Agrimensura, en cumplimiento parcial de los requisitos para optar al título de*

**Doctor en Ingeniería**

31 de Julio de 2023

Certifico que el trabajo incluido en esta tesis es el resultado de tareas de investigación originales y que no ha sido presentado para optar a un título de posgrado en ninguna otra Universidad o Institución.

A handwritten signature in black ink, consisting of a stylized 'E' followed by the word 'Montero' in a cursive script.

Montero Bulacio, Enrique

## **AGRADECIMIENTOS**

En primer lugar, considerando que este trabajo comenzó con el otorgamiento de la beca doctoral en 2017, es mucho el tiempo dedicado y da cierta sensación de cierre de una etapa de vida, por eso me parece oportuno agradecer en general a todos mis afectos los que ya no están, los que veo con frecuencia y a los que conozco hace poco.

A la Selección Argentina de Fútbol que nos trajo la copa. A mis amigos que me bancaron durante el Aislamiento Social Preventivo y Obligatorio. A mi hermano que me enseñó y me ayudó a construir mi casa.

Al estado argentino que en sus diferentes niveles me brindó acceso a la educación desde 1995. En particular quiero agradecer al personal de la FCA-UNR, la FCEIA-UNR y del CIFASIS que me acompañaron en mi formación de grado y posgrado; y al CONICET que financió mi beca.

Al grupo de trabajo de INTA Pergamino y del IAL-CONICET con quienes compartimos muchas salidas de campo. A la empresa Bioceres que otorgó algunos datos para esta tesis. A Raquel que siempre tuvo muy buena predisposición para resolver las dudas que nos surgieron sobre cuestiones administrativas y sobre procesos biotecnológicos. A María, mi codirectora, que también acompañó y ayudó siempre con muy buen ánimo.

Al grupo de trabajo del CIFASIS. Mis compañeros de oficina con los que nos divertimos en los descansos de laburo. A Martín que desde el primer día me trató como un par. A Margarita que me enseñó una gran variedad de enfoques sobre cómo tratar un problema y me dirigió en esta tesis, siempre con respeto, valorando mis conocimientos y ayudándome a afrontar nuevos desafíos y problemas en el campo de la investigación.

A mi papá que siempre estuvo dispuesto a ayudar en lo que yo necesite. A mi mamá que fue un ejemplo de perseverancia y lucha y que desde que nació fue creando su mayor legado que es la hermosa familia que tengo. A Nacho, Toti y Marito que siempre que los veo me sacan muchas sonrisas.

A Leticia, Fernando y Hernán por sus aportes y por dedicarle su tiempo a la lectura y corrección de la tesis.

## RESUMEN

El impacto de cambio climático podría traer significativas pérdidas en los rendimientos de los cultivos por el efecto que generará el aumento de la temperatura y las sequías, sumado a esto la demanda mundial de alimento se incrementa con una tasa mayor a la de incremento de la producción de alimento. La soja HaHB4 es un transgénico de segunda generación que podría mitigar estas adversidades porque la introgresión del gen proveniente del girasol, HaHB4, le otorga mayor resistencia a condiciones de temperaturas altas y estrés hídrico. La soja HaHB4 se ha aprobado en Argentina, EEUU, Brasil, Paraguay, Canadá y China. Con un análisis de sensibilidad de parámetros se caracteriza el efecto en las variables de estudio. Luego, en esta tesis se presenta una metodología robusta para la calibración del modelo CROPGRO-*soybean* para el crecimiento y desarrollo de soja HaHB4, se realiza un tratamiento holístico de parámetros, funciones objetivo, respuestas del modelo y datos medidos. Basado en las diferencias obtenidas en experimentos a campo entre HaHB4 y control se incluyen parámetros relacionados a las diferencias fisiológicas entre los cultivares. Una vez calibrado el modelo en fenología, balance hídrico, biomasa y rendimiento es validado con datos independientes. En rendimiento presentó valores de RMSE de 636 kg/ha para calibración y 542 kg/ha para validación. Luego, se evaluó su performance con múltiples experimentos de diferentes regiones productivas de Argentina. En la cuenca baja del Río Carcarañá se realiza un análisis del efecto de cambio climático sobre este cultivar y se generan series sintéticas para la calibración del modelo agrohidrológico SWAT en el periodo 1993-2015 que da un  $NS=0,76$ . La importancia de modelar el crecimiento y desarrollo de un cultivo con respuesta diferencial a las condiciones climáticas en el sistema suelo-planta-atmósfera es un paso para asegurar el manejo sustentable del suelo y la seguridad alimentaria.

## ABSTRACT

The impact of climate change could bring significant losses in crop yields due to the effect generated by the increase in temperature and droughts, added to this the world demand for food increases with a higher rate than the increase in production of food. HaHB4 soybean is a second generation transgenic crop that could mitigate these adversities, the introgression of the gene from sunflower, HaHB4, greater tolerance to conditions of high temperatures and water stress. HaHB4 soybean has been approved in Argentina, USA, Brazil, Paraguay, Canada and China. With a parameter sensitivity analysis, the effect on the study variables is characterized. Then, in this thesis a robust methodology for the calibration of the CROPGRO-*soybean* model for the growth and development of HaHB4 soybean is presented, a holistic treatment of parameters, objective functions, model responses and measured data is performed. Based on the differences obtained in field experiments between HaHB4 and control, parameters related to physiological differences between cultivars are included. Once the model has been calibrated in phenology, water balance, biomass and yield, it is validated with independent data. In yield, it presented RMSE values of 636 kg/ha for calibration and 542 kg/ha for validation. Then, its performance was evaluated with multiple experiments from different productive regions of Argentina. In the lower basin of the Carcarañá river, an analysis of the effect of climate change on this cultivar is carried out and synthetic series are generated for the calibration of the SWAT agrohydrological model in the period 1993-2015, which gives a NS=0.76. The importance of modeling the growth and development of a crop with differential response to climatic conditions in the soil-plant-atmosphere system is a step to ensure sustainable soil management and food security.

## **PALABRAS CLAVE**

CROPGRO-*soybean*

Calibración multiobjetivo

Acople OSTRICH-CROPGRO

Modelación agrohidrológica

Soja HaHB4

<b>ÍNDICE</b>	
<b>RESUMEN</b>	<b>3</b>
<b>ABSTRACT</b>	<b>4</b>
<b>PALABRAS CLAVE</b>	<b>5</b>
<b>ÍNDICE</b>	<b>6</b>
<b>ABREVIATURAS</b>	<b>9</b>
<b>CAPÍTULO I – INTRODUCCIÓN</b>	<b>11</b>
1.1 El cultivo de soja HaHB4, un cultivo transgénico de segunda generación	11
1.2 Calibración del modelo de crecimiento de cultivos, CROPGRO- <i>soybean</i>	12
1.3 SWAT, un modelo agrohidrológico a nivel de cuenca que permite simular escenarios de usos del suelo con soja HaHB4	13
1.4 Efectos del cambio climático en Argentina	14
1.5 Conceptos agronómicos básicos	15
<b>CAPÍTULO II – ANTECEDENTES</b>	<b>18</b>
2.1 La importancia del cultivo de soja en Argentina	18
2.2 La exportación de tecnología genética HaHB4	19
2.3 Modelos de crecimiento y desarrollo de cultivos	20
2.4 Modelo CROPGRO- <i>soybean</i>	21
2.5 Simulaciones a nivel de lote en la región pampeana Argentina con CROPGRO- <i>soybean</i>	22
2.6 Simulaciones a nivel regional en la cuenca baja del Rio Carcarañá	23
2.7 Objetivos	24
2.8 Hipótesis basadas en los objetivos específicos	25
<b>CAPÍTULO III – ANÁLISIS DE SENSIBILIDAD DEL MODELO CROPGRO-SOYBEAN</b>	<b>26</b>
3.1 Introducción	26
3.2 Materiales y métodos	27
3.3 Resultados	32

<b>CAPÍTULO IV – AJUSTES PRELIMINARES: CRECIMIENTO DE RAICES Y CONTENIDO DE AGUA INICIAL EN EL SUELO</b>	<b>38</b>
<b>4.1 Introducción</b>	<b>38</b>
<b>4.2 Materiales y métodos</b>	<b>39</b>
4.2.1 Descripción de los experimentos de campo	39
4.2.2 Datos meteorológicos	40
4.2.3 Datos de suelo y manejo agronómico	41
4.2.4 Contenido de agua en el perfil del suelo al momento de la siembra	41
4.2.5 Factor de crecimiento de la raíz	43
4.2.6 Progresión de la profundidad de la raíz	44
<b>4.3 Resultados</b>	<b>46</b>
4.3.1 Contenido inicial de agua en el perfil del suelo	46
4.3.2 Factor de crecimiento de la raíz	48
4.3.3 Progresión de la profundidad de la raíz	50
<b>CAPÍTULO V – CALIBRACIÓN Y VALIDACIÓN DEL MODELO CROPGRO-SOYBEAN</b>	<b>52</b>
<b>5.1 Introducción</b>	<b>52</b>
<b>5.2 Materiales y métodos</b>	<b>53</b>
5.2.1 Vinculación de CROPGRO y OSTRICH	53
5.2.2 Calibración multiobjetivo semiautomática OSTRICH-CROPGRO	54
5.2.3 Funciones objetivo y estadísticas para evaluar las simulaciones	56
5.2.4 Validación del modelo CROPGRO	57
<b>5.3 Resultados</b>	<b>58</b>
5.3.1 Calibración de fenología	58
5.3.2 Calibración de balance hídrico del suelo	60
5.3.3 Calibración de biomasa aérea	64
5.3.4 Calibración de rendimiento	66
5.3.5 Validación del modelo	71
<b>5.4 Discusión</b>	<b>73</b>
<b>CAPÍTULO VI – APLICACIÓN DEL MODELO CROPGRO-SOYBEAN</b>	<b>75</b>
<b>6.1 Introducción</b>	<b>75</b>
<b>6.2 Materiales y métodos</b>	<b>75</b>
6.2.1 Evaluación en distintas regiones agrícolas de Argentina	76
6.2.2 Generación de la línea de base de producción de soja HaHB4 para el periodo 1993-2015	78
6.2.3 Predicción de escenarios de cambio climático con CROPGRO en CBRC	78
6.2.4 Calibración de un modelo agrohidrológico con series sintéticas generadas por CROPGRO-soybean	80
<b>6.3 Resultados y discusión</b>	<b>83</b>
6.3.1 Resultados de la evaluación en distintas regiones de Argentina	83
6.3.2 Simulaciones con CROPGRO en la cuenca baja del Río Carcarañá	85

<i>6.3.3 Resultados de la calibración de SWAT en CBRC con series sintéticas de datos de rendimiento</i>	88
<b>CAPÍTULO VII – CONCLUSIONES Y TRABAJO FUTURO</b>	<b>90</b>
<b>7.1 Conclusiones</b>	<b>90</b>
<i>7.1.1 Contraste de hipótesis asociadas a los objetivos específicos</i>	92
<b>7.2 Trabajo futuro</b>	<b>93</b>
<i>7.2.1 Asimilación de datos remotos en modelos de crecimiento de cultivos</i>	93
<i>7.2.2 Simulación de escenarios de usos del suelo en la CBRC en situaciones de cambio climático</i>	94
<i>7.2.3 Calibración y validación de modelos de cultivos para trigo y maíz</i>	94
<b>PUBLICACIONES REALIZADAS DURANTE EL TRANSCURSO DE LA TESIS</b>	<b>96</b>
<b>ANEXO CAPÍTULO III</b>	<b>97</b>
<b>ANEXO CAPÍTULO IV</b>	<b>113</b>
<b>ANEXO CAPÍTULO V</b>	<b>114</b>
<b>ANEXO CAPÍTULO VI</b>	<b>115</b>
<b>ANEXO SALIDAS A CAMPO</b>	<b>120</b>
<b>Registro fotográfico de salidas a campo donde se recolectaron datos de cultivos transgénicos y sus parentales</b>	<b>122</b>
<b>BIBLIOGRAFÍA</b>	<b>128</b>

## ABREVIATURAS

B0 – Intercepción de regresión linear simétrica

B1 – Pendiente de regresión linear simétrica

BAME – Brazo Automático para Mediciones Espectrales

CBRC – Cuenca baja del Río Carcarañá

CFSR – *Climate Forecast System Reanalysis*

CS – Contenido de agua del suelo

CTSG – Cultivo transgénico de segunda generación

CSM-DSSAT – Modelo de sistema de cultivos de *Decision Support System for Agrotechnology Transfer*

DA – Diferencias absolutas

DAA – Diferencias absolutas acumuladas

DDS – Días después de la siembra

DTR – Desviación típica relativa

ENOS – El Niño Oscilación del Sur

ETAc – Evapotranspiración acumulada

FO – Función objetivo

FOA – Función objetivo absoluta

FOR – Función objetivo relativa

GEI – Gases de efecto invernadero

HRU – Unidad de respuesta hidrológica

MBE – Error de sesgo medio

OAT – *One at time* (de a uno a la vez)

RCP – Trayectorias de concentración representativas (por sus siglas en inglés)

RL#D – Densidad de raíces simulada diaria, donde # indica la capa del suelo

RL8D – Densidad de raíces simulada diaria entre 120-150 cm

RL9D – Densidad de raíces simulada diaria entre 150-180 cm

RMSE – Raíz del error cuadrático medio por sus siglas en inglés *Root Mean Square Error*

SDUL – Capacidad de campo, definido en DSSAT por las siglas en inglés *Soil Drained Upper Limit* ( $\text{cm}^3/\text{cm}^3$ )

SLLL – Punto de marchitez permanente, definido en DSSAT por las siglas en inglés *Soil Lower Limit* ( $\text{cm}^3/\text{cm}^3$ )

SRGF – Factor del suelo de crecimiento de la raíz, definido en DSSAT por las siglas en inglés: *Soil Root Growing Factor*

SWAT – *Soil and Water Assessment Tool*

URH – Unidad de respuesta hidrológica

W82 – Cultivar *Williams 82*

## CAPÍTULO I – INTRODUCCIÓN

### 1.1 El cultivo de soja HaHB4, un cultivo transgénico de segunda generación

Estudios recientes predicen que la demanda mundial de alimentos para los principales cultivos no estará acompañada por los aumentos de rendimiento necesarios. Las estimaciones actuales calculan que el impacto del cambio climático en la agricultura resultará en pérdidas de rendimiento entre 8-43%, principalmente debido a una combinación de sequía y calor. Se espera que los cultivos transgénicos de segunda generación (CTSG) mitiguen estas limitaciones (Hall y Richards, 2013; Chan *et al.*, 2020). Hasta el momento, la mayoría de los eventos de modificación genética que han sido adoptados por los agricultores a nivel mundial siguen un camino de innovación que impacta principalmente en la productividad agrícola a través del desarrollo de semillas tolerantes a herbicidas y resistentes a diferentes tipos de insectos. Además, estos desarrollos se han concentrado en gran medida en un puñado de países y cultivos (Sztulwark y Girard, 2016b). Para 2020, el único cultivo con resistencia mejorada al estrés abiótico que llegó al mercado fue un maíz resistente a la sequía (Castiglioni *et al.*, 2008). El grupo de investigación de la Dra. Raquel Chan del Instituto de Agrobiotecnología del Litoral (IAL-CONICET) con técnicas de mejoramiento genético utilizando *Agrobacterium* logró aislar e identificar una construcción genética portadora del gen de girasol HaHB4 asociado a la respuesta de la planta a estrés térmico e hídrico. Estos genes fueron introducidos con resultados favorables en primer lugar a *Arabidopsis* (Dezar *et al.*, 2005; Cabello *et al.*, 2007) y luego, a trigo (González *et al.*, 2019) y soja (González *et al.*, 2020; Ribichich *et al.*, 2020).

En Ribichich *et al.* (2020) se publicaron resultados de veintisiete ensayos de soja a campo en diferentes ambientes en Argentina, mostrando que la soja-HaHB4 fue capaz de conferir a las plantas resistencia al estrés hídrico, mejorar el rendimiento del uso del agua y la producción de biomasa, y aumentar el rendimiento de los cultivos. Inicialmente el gen se ha introducido en el cultivar de soja Williams 82 (W82), un cultivar de grupo de madurez (GM) tres, que se encuentra entre los más difundidos a nivel mundial especialmente en el ámbito científico porque se ha realizado la secuenciación del genoma (Haun *et al.*, 2011). En cuanto a la fenología, los autores establecieron que la presencia de HaHB4 no afectó el número de días hasta el inicio de la floración, en comparación con el cultivar sin modificar, W82. Por el contrario, los eventos que expresan HaHB4 mostraron un ligero retraso en la senescencia en comparación con W82. Otros rasgos observados en las plantas de soja HaHB4 cultivadas en el campo fueron una mayor resistencia a altas temperaturas, mayor interceptación de luz y mayor tasa fotosintética. Los avances en la

comprensión de los procesos de las plantas a nivel molecular aumentan las oportunidades para representarlos en modelos de cultivos. Con la creciente disponibilidad de datos sobre HaHB4 de soja (González *et al.*, 2020; Ribichich *et al.*, 2020), estamos en condiciones de mejorar la calibración de un modelo de crecimiento del cultivo con información empírica de experimentos de campo.

## **1.2 Calibración del modelo de crecimiento de cultivos, CROPGRO-soybean**

Cuando se habla de calibración de modelos, esto plantea varios problemas, incluidos qué parámetros considerar para la calibración, cuántos parámetros estimar y, debido a que los modelos de sistemas suelen tener múltiples salidas, la forma de tener en cuenta múltiples variables de salida (Wallach *et al.*, 2019). Una dificultad importante en el modelado de cultivos es que los modelos contienen varios parámetros dependientes del genotipo, que deben estimarse para cada genotipo (Casadebaig *et al.*, 2020).

En esta tesis se va a presentar una metodología robusta que garantice las simulaciones correctas para diferentes manejos y ubicaciones de soja HaHB4. El modelo de cultivo seleccionado para ser calibrado para esta soja de segunda generación es CROPGRO (Boote *et al.*, 1998) ya que es uno de los modelos de cultivo más robustos y ampliamente difundidos en el mundo y es parte del Modelo de sistema de cultivos de *Decision Support System for Agrotechnology Transfer (CSM-DSSAT)* (Jones *et al.*, 2003; Hoogenboom *et al.*, 2019), un conjunto de programas informáticos con interfaz propia que combina una serie de modelos y aplicaciones para llevar a cabo simulaciones del sistema suelo-agua-planta a nivel de lote productivo.

El enfoque planteado consiste en un tratamiento holístico de los parámetros de calibración, las funciones objetivo, las respuestas del modelo y los datos medidos, ya que potencialmente todas las decisiones involucradas en el proceso de calibración tienen un impacto en los resultados. Se definieron múltiples funciones objetivas como una forma de manejar múltiples respuestas simuladas en el procedimiento de calibración. Es decir, en lugar de usar todos los datos juntos para la calibración, se realiza la calibración en pasos. En cada paso, solo se usa una variable de salida y solo se estiman algunos parámetros. Una ventaja del procedimiento secuencial es que se ajusta una única variable de respuesta a los datos experimentales con pocos parámetros en cada paso, lo que evita problemas numéricos. Una desventaja es que los parámetros que se ajustan a una respuesta a menudo afectan a otras respuestas, con la posibilidad de degradar el ajuste a las respuestas tratadas en pasos anteriores.

Para la cantidad de parámetros que se incluirán en el proceso de calibración, la elección de los parámetros debe tener en cuenta que la cantidad de coeficientes del cultivar en los modelos de cultivo es relativamente pequeña (de 5 a 15, Boote *et al.*, 2016), y la selección de parámetros específicos del genotipo para su uso en los modelos fue un tanto arbitrario, basado en la evidencia empírica de las diferencias entre los cultivares y su respuesta a las condiciones ambientales. Sin embargo, esta forma de parametrizar diferencias entre genotipos no incluía explícitamente genes o marcadores genéticos como variables del sistema, lo que implica un problema con la estimación de parámetros para nuevos cultivares cuando se liberan (Wallach *et al.*, 2019).

Con base en las diferencias entre los transgénicos y los controles obtenidos en los ensayos de campo de fenotipado de HaHB4 en soja, la metodología propuesta para la calibración del modelo incluye parámetros de especie relacionados con aquellos rasgos fisiológicos que presentan las diferencias más significativas (resistencia al calor y la sequía sin penalizaciones en el rendimiento, mayor interceptación de luz y tasa fotosintética, aumento de la biomasa y el rendimiento de los cultivos, y mejora de la eficiencia en el uso del agua). Por lo tanto, los parámetros de las especies vinculados a estos rasgos se seleccionaron como posibles candidatos para la calibración, se incluyeron para el análisis de sensibilidad y se usaron cuando fuera necesario. Dado que la soja HaHB4 superó el rendimiento de W82 en condiciones de déficit hídrico, sin penalización de rendimiento en condiciones de riego abundante, se decidió realizar la calibración de CROPGRO para funciones objetivo considerando los dos regímenes hídricos en conjunto.

### **1.3 SWAT, un modelo agrohidrológico a nivel de cuenca que permite simular escenarios de usos del suelo con soja HaHB4**

El modelo agrohidrológico *Soil and Water Assessment Tool* (SWAT) es una herramienta desarrollada por el Servicio de Investigación Agrícola del Departamento de Agricultura de EE.UU. (USDA-ARS) (Arnold *et al.*, 1998; Neitsch *et al.*, 2011). SWAT es un modelo de simulación continua, semidistribuido que está diseñado para simular el efecto de las prácticas culturales de manejo del suelo en el balance hídrico del suelo y de la cuenca, la erosión hídrica y los rendimientos agrícolas en grandes cuencas complejas con diferentes suelos, condiciones de uso y manejo durante largos períodos de tiempo (desde años a décadas) (Neitsch *et al.*, 2011). En SWAT se utiliza un modelo de crecimiento de cultivo para simular diferentes tipos de cobertura terrestre, que incluye una gran base de datos de diferentes cultivos. El modelo de crecimiento de la planta se utiliza para evaluar la eliminación de agua y nutrientes de la zona de raíces, la transpiración y la producción de

biomasa/rendimiento. La siembra, la cosecha, los pases de labranza y las aplicaciones de nutrientes y pesticidas se pueden simular para cada sistema de cultivo con fechas específicas.

En esta tesis se va a proponer: calibrar por primera vez, una herramienta tecnológica confiable para simular la respuesta del rendimiento de una soja transgénica de segunda generación en la cuenca baja del Río Carcarañá (CBRC). Con SWAT-HaHB4 calibrado y validado se estará en condiciones de plantear distintos escenarios de usos de suelo, con manejos que permitan cumplir con objetivos ambientales definidos para apoyar la toma de decisiones en la planificación de políticas públicas y actividades privadas en el sur de la Provincia de Santa Fe.

#### **1.4 Efectos del cambio climático en Argentina**

Las proyecciones climáticas pronostican para la mayor parte del territorio argentino aumentos de la temperatura de 0,5 °C para las próximas décadas (2021-2040) y 1,5 °C para fines de siglo (2081-2100) en un escenario favorable (RCP 4.5), siendo un poco mayores en el noroeste argentino; en cuanto a las precipitaciones se estiman leves aumentos para la región Pampeana y el efecto contrario para las regiones de la Patagonia, Cuyo y Noroeste argentino (Camilloni, 2018). Además, el cambio climático tiene efectos en la distribución del régimen de precipitaciones y en el incremento de la ocurrencia de eventos climáticos extremos como sequías, olas de calor o inundaciones (CIMA, 2015). Frente a estos escenarios de cambio climático, las características de los cultivos modificados HaHB4 pueden presentar una ventaja fundamental, por su adaptabilidad a altas temperaturas y resistencia a estrés hídrico.

A partir de esta tesis se cuenta con un modelo de crecimiento y desarrollo de soja HaHB4 que se puede aplicar tanto en pequeñas parcelas experimentales, como en lotes productivos, que permitirá la simulación del rendimiento de soja frente a escenarios de cambio climático.

Así mismo, a partir de haber calibrado y validado un modelo de simulación agrohidrológico a nivel de cuenca, se podrán simular usos y manejos de suelo frente a escenarios de cambio climático.

## 1.5 Conceptos agronómicos básicos

**Cultivar:** Un cultivar (del inglés *cultivated variety*, variedad cultivada), es un término empleado en botánica y agronomía para designar poblaciones de plantas cultivadas que son genéticamente homogéneas, tienen características de relevancia agrícola que permiten distinguir claramente a dicha población de las demás de la especie y transfieren estas características de generación en generación, sea de forma sexual o asexual.

**Grupo de madurez de soja:** El grupo de madurez es la forma de definir el tipo, velocidad de crecimiento y la sensibilidad al fotoperiodo que va a tener un cultivar de soja. Se definen en forma numérica desde el número 2 al número 8. A medida que aumenta el número de grupo de madurez, aumenta la sensibilidad al fotoperiodo y también aumentan el tiempo necesario para que dicho cultivar de soja desarrolle ramas, flores, llene los granos y esté listo para cosechar. Entonces, por ejemplo, un cultivar de GM 3 sembrado en la misma fecha y la misma zona que un cultivar de GM 5 va a terminar su ciclo antes.

**El complejo sojero:** Hace referencia a todos los integrantes de los tres sectores que se encargan de la producción, la industrialización y la comercialización de soja y commodities derivados de la soja (Sorrentino y Thomasz, 2014).

**Desarrollo de un cultivo:** Hace referencia a cambios cualitativos del cultivo. En el cultivo de soja las etapas de desarrollo o estadios fenológicos son descritos por Fehr y Caviness (1977), los factores que afectan al desarrollo de este cultivo son la temperatura y el fotoperíodo.

Estadios fenológicos de soja según Fehr y Caviness (1977) (Figura 1.1), los siguientes son solo los estadios reproductivos más relevantes:

- R1 – comienzo de floración
- R3 – inicio de formación de vainas
- R5 – inicio de formación de granos
- R7 – madurez fisiológica
- R8 – madurez comercial




Figura 1.1. Estadios fenológicos de soja según Fehr y Caviness (1977) a medida que aumenta el tiempo en días después de la siembra (DDS).

Crecimiento de un cultivo: Hace referencia al incremento de biomasa. Según el ambiente donde se produzca un cultivo, los principales factores que podrían actuar como la mayor limitante al crecimiento son la radiación solar, el agua disponible o la fertilidad del suelo, además de estos tres factores, el crecimiento del cultivo es un proceso complejo que se puede ver afectado por factores bióticos, abióticos, antrópicos e interacciones entre estos factores.

Capacidad de campo - *Soil Drained Upper Limit* (SDUL): Es una característica del suelo que indica el contenido de humedad del suelo que es capaz de retener luego de saturación o de haber sido provisto de agua abundantemente y después dejado drenar libremente, evitando pérdida por evapotranspiración hasta que el potencial hídrico del suelo se estabilice (alrededor de 24 a 48 horas después de la lluvia o riego). Se corresponde aproximadamente al contenido de agua que retiene una muestra de suelo saturada y luego sometida a una tensión de -0,33 bares (Richards y Weaver, 1944).

Punto de marchitez permanente - *Soil Lower Limit* (SLLL): Es una característica del suelo que indica el contenido de humedad del suelo a partir del cual una planta no puede seguir extrayendo agua del suelo y no puede recuperarse de la pérdida hídrica, aunque la humedad ambiental sea saturada. Se estima como el contenido de agua retenido en el suelo tras ser sometido a una tensión de -15 bares.

Agua útil, agua disponible o agua extraíble del suelo: Es el agua que pueden tomar la mayoría de los cultivos y plantas en general, está delimitada por el punto de marchitez permanente y la capacidad de campo. De manera que el agua útil máxima es la diferencia

entre SDUL y SLLL, asimismo, el agua útil en un momento particular es el contenido de agua en el suelo menos SLLL (siempre y cuando no superé al agua útil máxima).

Horizonte argílico (también llamado árgico o Bt): Horizonte del suelo formado por acumulación de arcilla eluvial, normalmente se caracteriza por altos contenidos de arcilla, por ende, tiene alta densidad aparente y son altas las constantes de retención de agua tanto SDUL como SLLL.

## CAPÍTULO II – ANTECEDENTES

### 2.1 La importancia del cultivo de soja en Argentina

El cultivo de soja se comienza a desarrollar en Argentina en la década de 1970. Las políticas neoliberales de apertura de mercado de comienzos de la década de 1990 permitieron una posterior aprobación en 1996 de la comercialización de un paquete tecnológico que incluye tres pilares: soja transgénica resistente a glifosato; glifosato, un herbicida selectivo que afecta a todas las malezas y un sistema de siembra directa que resultaba muy beneficioso para la conservación de suelos en comparación con las labores culturales de remoción de suelo ampliamente difundidas para el manejo de malezas. Los precios favorables del mercado permitieron una expansión sin precedentes del cultivo, a tal punto que se generó una dependencia comercial de la economía argentina a la producción del cultivo de soja (Oña Mean, 2022).

La expansión desmedida del cultivo destacó durante la primera década de este siglo con sistemas productivos basados en monocultivo de soja (Bacigaluppo *et al.*, 2009; Montico y Di Leo, 2011; Satorre y Andrade, 2021). En diagnóstico en la provincia de Santa Fe sobre el cultivo de soja de primera y la relación con las rotaciones, Martínez (2022) identifica que el área sembrada de soja de primera fue muy superior a la de una rotación agrícola sustentable (soja - trigo/soja - maíz) en 2009 y esa relación disminuyó considerablemente en 2019. La misma tendencia fue observada a nivel nacional, donde en los últimos años en materia de participación de cultivos se muestra una notoria reducción del monocultivo de soja y un avance de la aplicación de rotaciones de cultivos (BCR, 2021).

En las últimas décadas es el cultivo con mayor producción nacional anual siendo de 53 millones de toneladas en promedio entre 2015 y 2019, solo superado por maíz en algunos años en particular por condiciones ambientales, comerciales o políticas. Buenos Aires concentra el 32,9% de la producción del país, seguida por Córdoba (29,2%), Santa Fe (17,5%) y Santiago del Estero (4,8%) (Ministerio de Hacienda, 2019). A nivel mundial Argentina es el tercer mayor productor de soja. El destino principal del cultivo es la industrialización primaria para la producción de aceite de soja en bruto, harinas, pellets y expellers extraídos del aceite de soja, biodiesel, entre otros. De estos subproductos se destaca que Argentina es el país con mayor exportación de aceite de soja y harina de soja del mundo. A nivel local también se destaca el nodo portuario de Gran Rosario, el cual, es el principal punto de exportación del mundo del complejo oleaginoso (Paolilli *et al.*, 2019). En 2022 las exportaciones del complejo soja sumaron 24868 millones de dólares (28,1% de las exportaciones totales de la nación). El complejo sojero opera con un nivel de

importaciones de 2365 millones de dólares en 2022 (3,0 % de las importaciones totales de la nación) (INDEC, 2022). Por este motivo este complejo es el sector de mayor aporte de moneda extranjera y genera una gran dependencia de la economía nacional hacia el sector. En cuanto al empleo del sector del complejo sojero, la Bolsa de Comercio de Rosario estimó que, en 2021, la cadena soja genera 1 de cada 9 empleos agroindustriales y el 2,5% del empleo en Argentina (BCR, 2021).

## **2.2 La exportación de tecnología genética HaHB4**

Desde dos instituciones públicas argentinas, la Universidad Nacional del Litoral y el Instituto de Agrobiotecnología del Litoral (IAL-CONICET) se identificaron los genes HaHB4 diferenciados de girasol y se introdujeron a soja para conferirle mejor adaptabilidad a ambientes de sequía y estrés hídrico, sin alterar su composición (Chiozza *et al.*, 2020). Estas instituciones junto a la empresa INDEAR de Bioceres gestionaron los permisos de exportación de esta tecnología (Girard, 2020). El avance de esta tecnología representa un hecho clave para el MERCOSUR, ya que, es una de las regiones con mayor difusión de cultivos transgénicos del mundo. En esta región, Argentina es el único país con aprobación de eventos transgénicos locales (Sztulwark y Girard, 2016a).

Inicialmente se han presentado dificultades para su difusión a nivel mundial, en Chan *et al.* (2020) se destacan como principales inconvenientes las diferencias del cultivo HaHB4 con resistencia a un factor climático y las diferencias con los transgénicos convencionales asociados a resistencia a insectos o agroquímicos. La resistencia a factores climáticos no se expresa en todos los ambientes de la misma manera y no presenta una visibilidad cualitativa, sino que varía según la duración, el momento y la intensidad del estrés ambiental. Por ende, no permite a las empresas de semillas cuantificar de manera precisa los beneficios esperados para el rendimiento. Además, esta tecnología no está dirigida a la totalidad de los ambientes productivos de soja, por el contrario, va a representar un beneficio solo en regiones con condiciones hídricas más desfavorables, ya sea por la localización o por las condiciones climáticas particulares de la campaña (Chan *et al.*, 2020). Por ejemplo, en el sur de Brasil se obtuvieron resultados que indican que las plantas transgénicas se desempeñaron mejor durante el estrés hídrico, pero en ambientes sin restricciones hídricas no se observaron diferencias en los rendimientos frente a los genotipos de control (Queiroz, 2014).

La soja HaHB4 fue la primera venta de un desarrollo argentino en biotecnología agrícola al exterior, se concretó en 2009 por Bioceres en acuerdo con la semillera Advanta de India. Las semillas comenzaron a comercializarse en 2019 (Papini y Morinigo, 2020). El evento transgénico en 2022 ya había sido aprobado por Argentina, Estados Unidos, Brasil,

Paraguay, Canadá e India (Businesswire, 2021). En abril de 2022, el Ministerio de Agricultura de China aprobó el evento de soja HaHB4 (Bloomberg, 2022). China es el mayor consumidor mundial de soja y el mayor importador de soja argentina. La decisión de China allana el camino para la entrada de la soja HaHB4 en un mercado clave para nuestro país. Estas naciones son responsables de más del 85% de la producción y exportación mundial de soja.

### **2.3 Modelos de crecimiento y desarrollo de cultivos**

A raíz de la importancia del cultivo de soja a nivel mundial se han desarrollado numerosos modelos de cultivos con niveles de complejidad variable, capaces de simular su crecimiento y/o desarrollo y que además varían considerablemente según los objetivos específicos para los cuales fueron desarrollados.

Uno de los modelos más sencillos se ocupa únicamente del desarrollo del cultivo, el modelo CRONOSOJA desarrollado en la Facultad de Agronomía de la Universidad de Buenos Aires se basa en un algoritmo de dinámica fototérmica (Severini *et al.*, 2019); a partir de la localidad, la fecha de siembra y el cultivar de soja sembrado estima la fenología del cultivo indicando el periodo crítico y las probabilidades de heladas en cada etapa fenológica. Otros modelos están enfocados en el crecimiento del cultivo con énfasis en la producción de biomasa y el rendimiento, son bastante generalistas, usan las mismas variables para describir a una gran variedad de cultivos o coberturas vegetales, por ejemplo, el modelo de zona agroecológica de la FAO (Doorendos y Kassam, 1979) es un modelo de cultivo simple que se utiliza para evaluar la relación entre el rendimiento del cultivo y las condiciones climáticas.

Los modelos de cultivo complejos consideran más detalles en la descripción de todos los procesos de cultivo, lo que aumenta sus posibles usos para evaluar el desarrollo y el rendimiento de los cultivos (Battisti *et al.*, 2017). AquaCrop - FAO simula la respuesta del rendimiento de los cultivos al agua y es particularmente adecuado para las condiciones en las que el agua es un factor limitante en la producción de cultivos (Steduto *et al.*, 2009). El modelo CROPGRO integra los balances de Carbono, Nitrógeno y agua en los procesos de crecimiento para estimar el rendimiento de la soja (Boote *et al.*, 2003). APSIM (Keating *et al.*, 2003) y MONICA (Nendel, 2014) también contemplan los tres procesos mencionados. El modelo SWAT (*Soil and Water Assessment Tool*), modelo continuo desarrollado para asistir en la toma de decisiones durante la gestión de los recursos hídricos a nivel de cuenca hídrica (Arnold *et al.*, 1998), cuenta con un módulo de crecimiento de plantas basado en el modelo EPIC (*Erosion Productivity Impact Calculator*). Este modelo fue desarrollado para determinar la relación entre la erosión del suelo y su productividad en

EE.UU. (Williams *et al.*, 1989). EPIC consta de componentes físicamente basados capaces de simular la erosión del suelo, el crecimiento de las plantas y procesos relacionados. También incluye componentes económicos para evaluar el costo de la erosión y determinar estrategias óptimas de gestión. Los procesos físicos implicados se simulan de forma simultánea y realista utilizando *inputs* fácilmente disponibles.

En SWAT el componente de crecimiento de plantas es una versión simplificada del EPIC que incluye el desarrollo fenológico de la planta basado en las unidades de calor acumuladas diariamente, la biomasa potencial se basa en un método desarrollado por Monteith, se utiliza un índice de cosecha para calcular el rendimiento y el crecimiento de la planta puede inhibirse por estrés de temperatura, agua, Nitrógeno o Fósforo. Las partes del modelo de crecimiento de plantas EPIC que no se incorporaron a SWAT incluyen el crecimiento detallado de las raíces, el ciclo de micronutrientes y las respuestas a la toxicidad, así como el crecimiento simultáneo de varias especies de plantas en la misma unidad de respuesta hidrológica (HRU). La base de datos de cultivos de EPIC contiene valores de parámetros para soja, alfalfa, maíz, sorgo, trigo, cebada, avena, girasol, algodón, distintas pasturas, maní, papa, habas, colza, caña de azúcar, sorgo, arroz, mandioca, lentejas y diversas pináceas y productos hortícolas. Versiones anteriores de SWAT sólo permitían simular el crecimiento de una especie vegetal por vez. Actualmente se han añadido algoritmos del modelo ALMANAC (Kiniry *et al.*, 1992; Johnson *et al.*, 2009) para simular el crecimiento de múltiples especies de plantas y su competencia dentro de una comunidad vegetal. Las comunidades vegetales que se han simulado incluyen: cultivos y malezas, árboles y pasturas, diferentes especies de árboles en un bosque, y hierbas y arbustos en comunidades de pastizales. Antes de la simulación se elabora un archivo de datos que describe las distintas plantas de cada comunidad.

La información requerida en la operación de la planta (operaciones de manejo de cultivo) incluye el momento de cada operación, el número total de unidades de calor necesarias para que la planta a simular alcance la madurez y el uso de suelo específico que se va a simular en cada HRU.

#### **2.4 Modelo CROPGRO-soybean**

El CSM-DSSAT es un programa de aplicación de software que simula el crecimiento, el desarrollo y el rendimiento de un cultivo que crece en un área uniforme de tierra bajo un manejo específico (Hoogenboom *et al.*, 2019; Jones *et al.*, 2003). El modelo CROPGRO es un modelo genérico orientado a procesos integrado en el CSM-DSSAT que utiliza un código común para simular diferentes leguminosas de grano, así como varias no

leguminosas. No hay subrutinas específicas de cultivos en CROPGRO; más bien, todas las diferencias de especies o cultivares se manejan externamente a través de parámetros de entrada y relaciones descritas en tres archivos de entrada: especie, ecotipo y cultivar (Boote *et al.*, 1998). El modelo integra los balances de agua, Carbono y Nitrógeno de los procesos de crecimiento a lo largo del ciclo del cultivo. Una parte clave es la simulación del balance hídrico del suelo, que incluye la lluvia y el riego, la infiltración y la escorrentía superficial, el drenaje, la evaporación del suelo y la transpiración de los cultivos. La infiltración y la escorrentía de la lluvia dependen del número de la curva de escorrentía del Servicio de Conservación de Suelos (US *Soil Conservation Service*, 1972). El drenaje del agua del suelo sigue el enfoque unidimensional de cubeta basculante descrito por Ritchie (1998). La evapotranspiración potencial se calcula mediante el método de Priestley-Taylor modificado por Ritchie (1998). Este enfoque no requiere datos de punto de rocío y velocidad del viento, que son escasos en la región pampeana (Mercau *et al.*, 2007). Después de eso, la evapotranspiración potencial se divide en transpiración potencial del cultivo y evaporación potencial del suelo en función del índice de área foliar y el coeficiente de extinción de energía. La evaporación real del suelo se estima utilizando el método de Suleiman-Ritchie (Ritchie *et al.*, 2009) y la transpiración real del cultivo es el mínimo de la absorción potencial de agua por las raíces o la transpiración potencial del cultivo. La absorción potencial de agua por las raíces es una función de la densidad de la longitud de la raíz y el contenido de agua del suelo, y la relación entre la absorción potencial de agua por las raíces y la transpiración potencial del cultivo se utiliza para calcular los efectos del déficit de agua (Boote *et al.*, 2008).

La distribución de la densidad de raíces en cada capa del suelo depende de la tasa de aumento de la profundidad de las raíces, una función de preferencia de enraizamiento del suelo según el grado de impedancia para la proliferación de raíces y el contenido de agua del suelo. En las simulaciones se activó la fijación biológica de Nitrógeno y se seleccionó la opción de fotosíntesis a nivel horario (Boote y Pickering, 1994). Además, se simuló la dinámica de la materia orgánica del suelo utilizando el módulo adaptado por Gijsman *et al.* (2002). Se puede encontrar más información sobre el modelo CROPGRO en Hoogenboom *et al.* (2019).

## **2.5 Simulaciones a nivel de lote en la región pampeana Argentina con CROPGRO-soybean**

El modelo CROPGRO-soybean es uno de los modelos más difundidos de este cultivo a nivel mundial. En la región pampeana Argentina desde la década del 2000 se viene usando

para extensión e investigación relacionado a estimación de rendimiento, selección de cultivares apropiados, estudio de efectos de cambio climático, prueba de diversas prácticas de manejo como fecha de siembra, densidad de siembra, distancia entre surcos, fertilizaciones (nitrogenadas), riego (Dardanelli *et al.*, 2003; Mercau *et al.*, 2007; Kantolic *et al.*, 2007; Vettorello *et al.*, 2008; Llovet, 2014; Confalone *et al.*, 2016; Ovando *et al.*, 2017 y 2018; Giménez *et al.*, 2018; Teixeira *et al.*, 2019). Además, el simulador está al alcance de asesores, miembros de la academia, extensionistas o productores que también hacen uso directo del modelo a través del programa DSSAT. Los proyectos de simulación se desarrollan en toda la zona productiva de soja a nivel nacional siendo las provincias de Buenos Aires, Córdoba y Santa Fe las que concentran mayor investigación con CROPGRO. Los proyectos pueden incluir diferentes fuentes de información climática como mediciones propias, estimaciones en base a imágenes satelitales, datos medidos por estaciones meteorológicas y agrometeorológicas y estimaciones de modelos climáticos. En cuanto al suelo generalmente se usa como base algún perfil de suelo de los determinados en el territorio por el INTA para luego según la disponibilidad de análisis propios complementar con información específica medida o estimada.

## **2.6 Simulaciones a nivel regional en la cuenca baja del Río Carcarañá**

La Cuenca Baja del Río Carcarañá (CBRC), una zona representativa del uso del suelo en el sur de la provincia de Santa Fe, donde se practica agricultura intensiva, se encuentra en un área con pocas estaciones de aforo de cursos de agua superficiales y subterráneas y muy pocos datos de calidad del agua. Por lo tanto, los datos hidrológicos disponibles son limitados.

En Romagnoli *et al.* 2017, la aplicación del modelo SWAT a la CBRC en la provincia de Santa Fe se concretó a través del análisis de datos de campo y de teledetección que caracterizan la hidrología, la calidad del agua, los tipos de suelo, el uso de la tierra/cobertura del suelo, las prácticas de manejo y el rendimiento de los cultivos, de la zona en estudio. Se realizó un proceso combinado de calibración y validación manual y automatizado que incorporó el análisis de sensibilidad e incertidumbre utilizando información relativa a los procesos intrínsecos de la cuenca hidrográfica.

Una vez calibrado y validado el modelo, se seleccionaron once dosis de fertilizante Nitrógeno (N) / Fósforo (P) para simular el impacto del N en el rendimiento de los cultivos, la absorción del mismo por el cultivo, así como las pérdidas de N por escorrentía y lixiviación y diferentes índices del cultivo (factor de productividad parcial, eficiencia agronómica, eficiencia aparente de recuperación del cultivo frente al nutriente aplicado,

eficiencia de utilización interna del cultivo y eficiencia fisiológica). La calidad global del ajuste resultó satisfactoria, teniendo en cuenta las limitaciones de los datos de entrada. Este trabajo proporcionó, por primera vez en Argentina, una herramienta fiable para simular la respuesta del rendimiento de cultivos frente a la calidad del suelo y a la disponibilidad de agua.

En Maydana *et al.* (2020) se analizó el escenario actual de uso de suelos en CBRC en comparación con un escenario de agricultura de conservación y un escenario de buenos rendimientos a corto plazo con una perspectiva de valoración integrada. Los autores realizaron un análisis desde distintos puntos de vista de diferentes actores del sistema productivo, generando indicadores a partir de una metodología sociotécnica enfocada a contribuir al proceso necesario para lograr un amplio consenso entre los actores del agronegocio en Argentina. El escenario de agricultura de conservación que promueve la cobertura permanente del suelo mediante la rotación de cultivos y la implementación de zonas de amortiguamiento no tratadas alrededor de las ciudades, fue identificado como la mejor opción por los actores agrupados con perspectivas de *estado regulador, sociedad civil y consenso social*. Pero desde el punto de vista del *sector privado* fue el escenario actual el que tiene mejor valoración que los otros.

## 2.7 Objetivos

El objetivo general es:

Desarrollar y poner a punto de una herramienta informática que facilite la toma de decisiones en el marco de la gestión sustentable de los recursos naturales agua y suelo.

Los objetivos específicos son:

- OBJETIVO ESPECIFICO 1: Calibrar y validar un modelo numérico del sistema suelo-agua-planta a nivel de lote productivo que considere las particularidades de la soja HaHB4.
- OBJETIVO ESPECIFICO 2: Evaluar el modelo para distintas condiciones hídricas en distintas regiones productivas de la Republica Argentina.
- OBJETIVO ESPECIFICO 3: Simular en distintas localizaciones del sur de la provincia planteando escenarios de cambio climático a nivel de lote.
- OBJETIVO ESPECIFICO 4: Calibrar Soil and Water Assessment Tool (SWAT) en la región de la Cuenca Baja del Río Carcarañá para soja HaHB4.

## **2.8 Hipótesis asociadas a los objetivos específicos**

- HIPÓTESIS 1: La metodología de calibración es robusta, por lo que, luego de la calibración de un genotipo de soja HaHB4, el modelo a nivel de lote será exitosamente validado y evaluado en diferentes regiones de Argentina.
- HIPÓTESIS 2: En los escenarios de cambio climático, teniendo en cuenta que el cultivar HaHB4 presenta ciertas ventajas adaptativas a las altas temperaturas, el efecto de las altas temperaturas que presentan los escenarios de la RCP 8.5 no afectará al cultivo permitiendo que mantenga su rendimiento en comparación con los escenarios de la RCP 4.5.
- HIPÓTESIS 3: Los datos sintéticos generados por el modelo a nivel de lote permitirán una correcta calibración y validación del modulo de cultivo de SWAT.

## **CAPÍTULO III – ANÁLISIS DE SENSIBILIDAD DEL MODELO CROPGRO-SOYBEAN**

### **3.1 Introducción**

Una de las estrategias más comunes para evaluar un modelo es el análisis de sensibilidad, el cual consiste en determinar la magnitud del cambio en la respuesta, al cambio de valores en los componentes del modelo (Vélez-Pareja 2003). El modelo CROPGRO-*soybean* fue diseñado para ser utilizado en un extenso rango de regiones de producción, realizar el análisis de sensibilidad con un experimento en la localización puntual de estudio permitirá identificar cuáles son los parámetros de entrada al modelo que afecten en mayor grado a las variables de salida. Sumado a esto, evaluar la sensibilidad en condiciones hídricas óptimas como también en situaciones de déficit hídrico permitirá identificar correctamente los parámetros del modelo para una adecuada selección en el proceso de calibración.

El método de pruebas de un parámetro a la vez (OAT: *one at a time*, según el acrónimo en inglés), es una manera de realizar un análisis de sensibilidad para identificar un conjunto de parámetros sensibles y su rango de sensibilidad. Consiste en modificar un solo parámetro de entrada a la vez, manteniendo los demás en sus valores base, para ver qué efecto produce en las variables de salida. El objetivo de este capítulo es obtener una detallada caracterización de los parámetros de entrada al modelo que incluya el nivel de sensibilidad y los rangos de sensibilidad a las variables de desarrollo, crecimiento y dinámica hídrica que serán utilizados en la calibración. Además de destacar los parámetros sensibles, se busca tener en cuenta en qué medida pueden afectar a las variables según si la condición hídrica ambiental es favorable o no para el desarrollo del cultivo.

### 3.2 Materiales y métodos

La base del modelo en esta etapa fueron simulaciones de un experimento situado en la localidad de Pergamino en la temporada 2017-2018, la misma ubicación y temporada que en el Capítulo V se usará para el proceso de calibración. El análisis de sensibilidad se realizó en condiciones tanto de secano como potenciales (sin estrés hídrico ni nutricional). Debido a la severa sequía ocurrida durante la temporada 2017-18 causada por la fase La Niña de El Niño - Oscilación del Sur (ENOS), los resultados de sensibilidad en condiciones de secano son representativos de una condición de déficit hídrico. Dado que el cultivar HaHB4 de soja se obtuvo mediante la transformación del genotipo Williams 82 (W82), los parámetros de ecotipo y cultivar de este genotipo parental se consideraron como valores base para las corridas del modelo CROPGRO.

Treinta y cinco coeficientes genéticos del cultivo que funcionan en el modelo como parámetros de entrada relacionados con el desarrollo de la soja y los procesos de crecimiento fueron seleccionados en base a la revisión de la literatura de implementaciones previas del modelo CROPGRO-soybean (Grimm *et al.*, 1993; Boote *et al.*, 1998; Ritchie, 1998; Sau *et al.*, 1999; Ruíz-Nogueira *et al.*, 2001; Mercau *et al.*, 2007; Jones *et al.*, 2011; Ma *et al.*, 2020; Wang *et al.*, 2003; Pedersen *et al.*, 2004; Nath *et al.*, 2017; Lamsal *et al.*, 2017; Salmerón *et al.*, 2017; Battisti *et al.*, 2017; Fensterseifer *et al.*, 2017; Richetti *et al.*, 2019; Teixeira *et al.*, 2019; Sciarresi *et al.*, 2020). Trece de estos parámetros pertenecen al archivo de entrada de cultivar, tres al archivo de ecotipo y diecinueve al archivo de entrada de especie. Como se mencionó anteriormente, los parámetros de especie se seleccionaron en función de los rasgos fisiológicos distintivos del HaHB4 de soja obtenidos en ensayos de campo (resistencia a la sequía y al calor, mayor intercepción de luz y tasa fotosintética, mayor eficiencia en el uso del agua y retraso en la senescencia).

El rango de los intervalos en el cual se evaluaron los parámetros de ecotipo y cultivar se definió en base a una síntesis de rangos de estudios previos sumado a información de rasgos específicos del cultivar (grupo de madurez III) disponibles en la base de datos de CSM-DSSAT para cultivares de soja, que fue creada por los desarrolladores del modelo. En cuanto al intervalo de rango para los parámetros del archivo de especie, se definió en base a una combinación de valores de estudios de calibración seminales dentro de un rango físicamente significativo (Ruíz-Nogueira *et al.*, 2001; Sau *et al.*, 1999; Ritchie, 1998; Pedersen *et al.*, 2004; Saseendran *et al.*, 2010; Präger *et al.*, 2019). La Tabla 3.1 enumera los parámetros seleccionados agrupados según el archivo de entrada, junto con su descripción, valor base y rango de variación del intervalo.

Para cuantificar la sensibilidad de los parámetros, se evaluaron doce variables de salida relacionadas con fenología, evapotranspiración, biomasa y rendimiento de semillas. Diez

de estas variables son valores escalares: los tiempos fenológicos EM-R1, R1-R3, R3-R5, R5-R7 y R7-R8; la evapotranspiración acumulada a final de ciclo ( $ETAc_{R8}$ ); la biomasa máxima (bio max); y el rendimiento, peso de granos y número de granos a final del ciclo. Las otras dos variables son vectores de cinco componentes que se forman con los valores de ETAc y biomasa aérea en los momentos fenológicos R1, R3, R5, R7 y R8 ( $[ETAc_{R1}, ETAc_{R3}, ETAc_{R5}, ETAc_{R7}, ETAc_{R8}]$  y  $[B_{R1}, B_{R3}, B_{R5}, B_{R7}, B_{R8}]$ ). El análisis OAT se realizó subdividiendo en 30 partes iguales los rangos de variación de parámetros enumerados en la Tabla 3.1, de este modo se obtienen 31 valores de cada parámetro a los que se les realizará el estudio de sensibilidad. Ejecutando el modelo para cada parámetro (es decir, un total de 2170 simulaciones, 1085 en condiciones de seco y 1085 en condiciones potenciales). Por lo tanto, se obtuvieron treinta y un valores diferentes de doce variables de salida seleccionadas. La Tabla 3.2 describe las variables de salida elegidas junto a los nombres de los archivos de salida correspondientes de CROPGRO.

Tabla 3.1. Parámetros de entrada seleccionados para el análisis de sensibilidad, valores de base e intervalos de rango de prueba.

Parámetro	Descripción	Valor base	Rango de prueba
cul- CSDL	Duración crítica del día corto por debajo de la cual el desarrollo reproductivo progresa sin efecto sobre la duración del día (para plantas de día corto) (hora)	13,4	11,7:14,7
cul- PPSEN	Pendiente de la respuesta relativa del desarrollo al fotoperíodo con el tiempo (positiva para plantas de día corto) (hora <sup>-1</sup> )	0,285	0,12:0,36
cul- EM-FL	Tiempo entre la emergencia de la planta y la aparición de la primera flor (R1) (días fototérmicos)	19,0	14,7:23,7
cul- FL-SH	Tiempo entre la primera flor y la primera vaina (R3) (días fototérmicos)	8,3	4,5:10,5
cul- FL-SD	Tiempo entre la primera flor y la primera semilla (R5) (días fototérmicos)	14,2	10,7:19,7
cul- SD-PM	Tiempo entre la primera semilla (R5) y madurez fisiológica (R7) (días fototérmicos)	32,2	25,0:37,4
cul- FL-LF	Tiempo entre la primera flor (R1) y el final de la expansión de la hoja (días fototérmicos)	28,0	18,0:35,0
cul- LFMAX	Tasa máxima de fotosíntesis de la hoja a 30 C, 350 vpm CO <sub>2</sub> y mucha luz (mg CO <sub>2</sub> /m <sup>2</sup> s)	0,99	0,85:1,40
cul- SLAVR	Área foliar específica del cultivar en condiciones de crecimiento estándar (cm <sup>2</sup> /g)	385	300:490
cul- SIZLF	Tamaño máximo de hoja completa (tres foliolos) (cm <sup>2</sup> )	180	137:240
cul- WTPSD	Peso máximo por semilla (g)	0,18	0,14:0,20
cul- SFDUR	Duración del llenado de semillas para la cohorte de vainas en condiciones de crecimiento estándar (días fototérmicos)	26,0	19,0:30,0
cul- PODUR	Tiempo requerido para que el cultivar alcance la carga final de vainas en condiciones óptimas (días fototérmicos)	12,0	6,0:16,0
eco- R1PPO	Aumento de la sensibilidad al fotoperíodo después de R1 (CSDVAR y CLDVAR disminuyen en la misma cantidad) (h)	0,324	0,100:0,549
eco- OPTBI	Temperatura mínima diaria por encima de la cual no hay ningún efecto sobre la ralentización del desarrollo normal hacia la floración (°C)	18,0	17,5:20,5
eco- SLOBI	Pendiente de la relación que reduce el progreso hacia la floración si TMIN para el día es menor que OPTBI	0,028	0,017:0,047
spe- TB veg	Temperatura base en etapas vegetativas	7,0	5,8:14,8
spe- TO1 veg	Temperatura óptima menor en etapas vegetativas	28,0	27,0:33,0
spe- TO2 veg	Temperatura óptima mayor en etapas vegetativas	35,0	31,5:43,5
spe- TM veg	Temperatura máxima en estados vegetativos	45,0	43,2:46,2
spe- TB r1	Temperatura base en etapas reproductivas tempranas	6,0	5,0:11,0
spe- TO1 r1	Temperatura óptima más baja en etapas reproductivas tempranas	26,0	20,0:29,0
spe- TO2 r1	Temperatura óptima más alta en etapas reproductivas tempranas	34,0	26,0:35,0
spe- TM r1	Temperatura máxima en etapas reproductivas tempranas	45,0	40,0:49,0

Tabla 3.1. Parámetros de entrada seleccionados para el análisis de sensibilidad, valores de base e intervalos de rango de prueba. (Continuación)

Parámetro	Descripción	Valor base	Rango de prueba
spe- TB r2	Temperatura base en etapas reproductivas tardías	6,0	-15,0:9,0
spe- TO1 r2	Temperatura óptima más baja en etapas reproductivas tardías	26,0	20,0:29,0
spe- TO2 r2	Temperatura óptima más alta en etapas reproductivas tardías	34,0	26,0:35,0
spe- TM r2	Temperatura máxima en etapas reproductivas tardías	45,0	40,0:49,0
spe- STG9-STG11	Sensibilidad de la fenología al estrés hídrico desde las fases R5 (STG 9) a R7 (STG 11)	0,7	0,1:0,7
spe- RWUMX	Absorción máxima de agua por unidad de longitud de raíz, limitada por el agua del suelo (cm <sup>3</sup> [agua] / cm [raíz])	0,04	0,01:0,18
spe- FNPGL1	Temperatura base que afecta la tasa de saturación de la fotosíntesis al día siguiente	0,0	-5,0:7,0
spe- FNPGL2	Temperatura óptima más baja que afecta la tasa de saturación de la fotosíntesis al día siguiente	19,0	12,0:24,0
spe- FNGT2	Temperatura óptima más baja para el crecimiento de nódulos (N)	22,0	16,0:28,0
spe- FNFXT2	2 <sup>do</sup> punto de la curva de temperatura que describe el efecto sobre la fijación de N	20,0	16,0:28,0
spe- KEP	Coeficiente total de extinción de energía solar	0,68	0,50:0,83

Tabla 3.2. Variables de salida seleccionadas para el análisis de sensibilidad. DAP: días después de la siembra. GSTD: estadio de desarrollo. ETAC: evapotranspiración acumulada (mm). CWAD: peso de la biomasa aérea (kg/ha). GWAD: peso de granos (kg/ha). GWGD: peso unitario de granos (g). G#AD: Número de granos.

Variables observadas	Variables de salida de CROPGRO
Fenología	DAP asociado con cambios en GSTD (PlantGro.OUT)
1. EM-R1	
2. R1-R3	
3. R3-R5	
4. R5-R7	
5. R7-R8	
Evapotranspiración	ETAC (ET.OUT)
6. Vector ET [ETAC <sub>R1</sub> ,ETAC <sub>R3</sub> ,ETAC <sub>R5</sub> ,ETAC <sub>R7</sub> ,ETAC <sub>R8</sub> ]	
7. ETAC <sub>R8</sub>	
Biomasa	CWAD (PlantGro.OUT)
8. Vector Biomasa [B <sub>R1</sub> ,B <sub>R3</sub> ,B <sub>R5</sub> ,B <sub>R7</sub> ,B <sub>R8</sub> ]	
9. Bio max	
10. Rendimiento	GWAD (PlantGro.OUT)
11. Peso unitario de granos secos	GWGD (PlantGro.OUT)
12. Número de granos	G#AD (PlantGro.OUT)

Las diferencias absolutas (DA) entre los valores de variables de salida subsiguientes se calculan de la siguiente manera dependiendo de la dimensión de la variable de salida, escalar o vector respectivamente:

$$DA(n) = Y_n - Y_{n+1} \quad o \quad \sqrt{\sum_{i=1,3,5,7,8}^5 (Y_n - Y_{n+1})_{Ri}^2}, \quad n = [1: 30] \quad (3.1)$$

donde Y representa la variable de salida, n es el número de la subdivisión del rango del parámetro al que se le estudia sensibilidad y Ri representa la etapa fenológica en la que se extraen los valores de salida del vector evapotranspiración y vector biomasa. Los resultados de la Ecuación 3.1 para cada parámetro se grafican de manera secuencial en un diagrama bidimensional donde en abscisas se muestran los valores que toma el parámetro y en ordenadas los valores de las DA. A partir del análisis visual de estos gráficos se definen los rangos iniciales de variación de parámetros que se utilizarán en el proceso de calibración. Los parámetros sensibles para cada variable de salida se clasifican de mayor a menor en función de la Ecuación 3.2 y la Ecuación 3.3, dependiendo de si la dimensión de la variable de salida es escalar (izquierda) o vectorial (derecha):

$$DAA = \sum_{n=1}^{n=30} \sqrt{(Y_n - Y_{n+1})^2} \quad o \quad \sum_{n=1}^{n=30} \sqrt{\sum_{i=1,3,5,7,8}^5 (Y_n - Y_{n+1})_{Ri}^2} \quad (3.2)$$

$$DTR = \frac{\sqrt{\frac{\sum_{n=1}^{n=31} (Y_n - \bar{Y})^2}{31}}}{\bar{Y}} \quad o \quad \frac{\sum_{i=1,3,5,7,8}^5 \sqrt{\frac{\sum_{n=1}^{n=31} (Y_{ni} - \bar{Y}_i)^2}{31}}}{\bar{Y}_i} \quad (3.3)$$

donde Y representa la variable de salida, n es el número de la subdivisión del rango de parámetros probados y Ri representa la etapa fenológica en la que se extraen los valores de salida de evapotranspiración acumulada y la biomasa para los vectores. Diferencias absolutas acumuladas (DAA) acumula la diferencia absoluta de valores de variables de salida posteriores y la desviación típica relativa (DTR) es una medida de cuán dispersa está la variable de salida en relación con su media. Debido a que DTR es una medida relativa, los valores de diferentes variables de salida se pueden comparar entre sí. En este trabajo se definieron como valores umbrales un valor de 10% de DAA máximo para la Ecuación 3.2 y 0,02 de DTR para la Ecuación 3.3, por encima de estos valores los parámetros se consideran "sensibles" para la variable de salida considerada. Los valores umbrales para los criterios de determinación de sensibilidad se definieron luego de revisar las relaciones entre los parámetros de entrada y las variables de salida con el objetivo de que la cantidad de parámetros sensibles se acerque al valor deseado de parámetros que se desea utilizar en el proceso posterior de calibración. Ya que, estos parámetros sensibles son los parámetros que se consideran para calibración en el Capítulo V.

Adicionalmente se observaron las diferencias máximas entre dos corridas consecutivas que podrían destacar la sensibilidad de parámetros que actúan en el modelo con un efecto exponencial o logarítmico, no obstante, observando los máximos en dos corridas consecutivas no se identificó ningún parámetro que no hubiera sido incluido por las dos métricas definidas para la totalidad de las variables de salida observadas (Anexo Capítulo III).

### 3.3 Resultados

Los resultados del análisis de sensibilidad se resumen en la Tabla 3.3 y la Figura 3.1 para el rendimiento de grano como variable de salida. La Tabla 3.3 muestra los valores de los índices de sensibilidad (DTR y DAA) seleccionados para evaluar los parámetros más influyentes sobre una sola variable de salida (rendimiento de grano en riego). El método de

corte elegido es el valor umbral que se definió en Materiales y Métodos. Los números en negrita en la Tabla 3.3 indican valores de índices superiores al umbral correspondiente, es decir, superiores a 0,02 para DTR y superiores a 149 (10 % de 1487) para DAA. Los parámetros de entrada en la Tabla 3.3 están ordenados según los valores DTR en orden descendente. Considerando los valores de umbral establecidos para los dos índices de sensibilidad, veintidós parámetros de entrada influyen en el comportamiento del rendimiento de grano simulado. Para facilitar la lectura los parámetros que arrojaron valores de DTR y DAA iguales a cero no se incluyeron en la Tabla 3.3.

Tabla 3.3. Ranking y rango de sensibilidad de los parámetros sensibles a la variable de salida rendimiento en condiciones potenciales de crecimiento.

Parámetro	DTR	DAA	Rango de sensibilidad
spe-FNPGL1	<b>0,106</b>	<b>1132</b>	-5,0:7,0
spe-FNPGL2	<b>0,099</b>	<b>694</b>	12,0:24,0
cul-CSDL	<b>0,092</b>	<b>1487</b>	11,7:14,0
spe-TBr2	<b>0,070</b>	<b>923</b>	-15,0:8,2
cul-LFMAX	<b>0,067</b>	<b>832</b>	0,981:1,311
cul-SD-PM	<b>0,059</b>	<b>623</b>	25,0:37,0
cul-FL-SH	<b>0,056</b>	<b>590</b>	4,5:10,3
cul-SIZLF	<b>0,049</b>	<b>565</b>	137:228
cul-EM-FL	<b>0,048</b>	<b>639</b>	14,7:23,7
cul-PPSEN	<b>0,045</b>	<b>649</b>	0,12:0,36
spe-TO1veg	<b>0,042</b>	<b>432</b>	27,0:33,0
spe-TBveg	<b>0,039</b>	<b>410</b>	7,0:14,8
spe-TO1r1	<b>0,035</b>	<b>428</b>	20,0:29,0
cul-FL-SD	<b>0,030</b>	<b>616</b>	10,7:19,7
spe-TO1r2	<b>0,027</b>	<b>265</b>	21,4:25,4
spe-RWUMX	<b>0,025</b>	<b>483</b>	0,01:0,03
cul-SFDUR	<b>0,024</b>	<b>273</b>	19,0:30,0
spe-KEP	<b>0,021</b>	<b>330</b>	0,5:0,83
spe-TO2r1	0,018	<b>298</b>	27,2:32,2
eco-R1PPO	0,014	<b>257</b>	0,100:0,535
cul-SLAVR	0,013	<b>149</b>	300:490
spe-TBr1	0,009	<b>309</b>	6,8:9,8
spe-TO2r2	0,008	69	-
cul-FL-LF	0,007	94	-
cul-PODUR	0,006	134	-
spe-TMr1	0,004	132	-
spe-TO2veg	0,003	29	-
cul-WTPSD	0,003	36	-

En la Figura 3.1 se representan los cuatro parámetros más sensibles de la Tabla 3.3 (FNPGL1, FNPGL2, CSDL y TBr2) para mostrar cómo se define el rango de variación de cada parámetro sensible. El eje x de cada sub-figura muestra el rango de variación del parámetro de entrada, y el eje y muestra las DA para los valores subsiguientes del parámetro de entrada, evaluados de acuerdo con la Ecuación 3.1. Si las DA son distintas de cero, entonces se dice que la salida es sensible a este parámetro. Los rangos identificados, que se indican también en la Tabla 3.3, son:  $-5 < \text{FNPGL1} < 6,6$  (Figura 3.1a),  $12 < \text{FNPGL2} < 23,6$  (Figura 3.1b),  $11,7 < \text{CSDL} < 14$  (Figura 3.1c) y  $-15 < \text{TBr2} < 8,2$  (Figura 3.1d). Los parámetros FNPGL1 y FNPGL2 son sensibles al rendimiento y forman líneas continuas porque no son sensibles a la fenología, en cambio en los parámetros CSDL y TB r2 se observa alta discontinuidad en los valores debido a su sensibilidad a la fenología que en la TB r2 presenta cierto patrón por ser solo sensible en una etapa fenológica en particular y en CSDL hay mucha dispersión porque es sensible a todas las etapas fenológicas (esto se puede observar en el Anexo Capítulo III: Figuras A3.2 a A3.9).

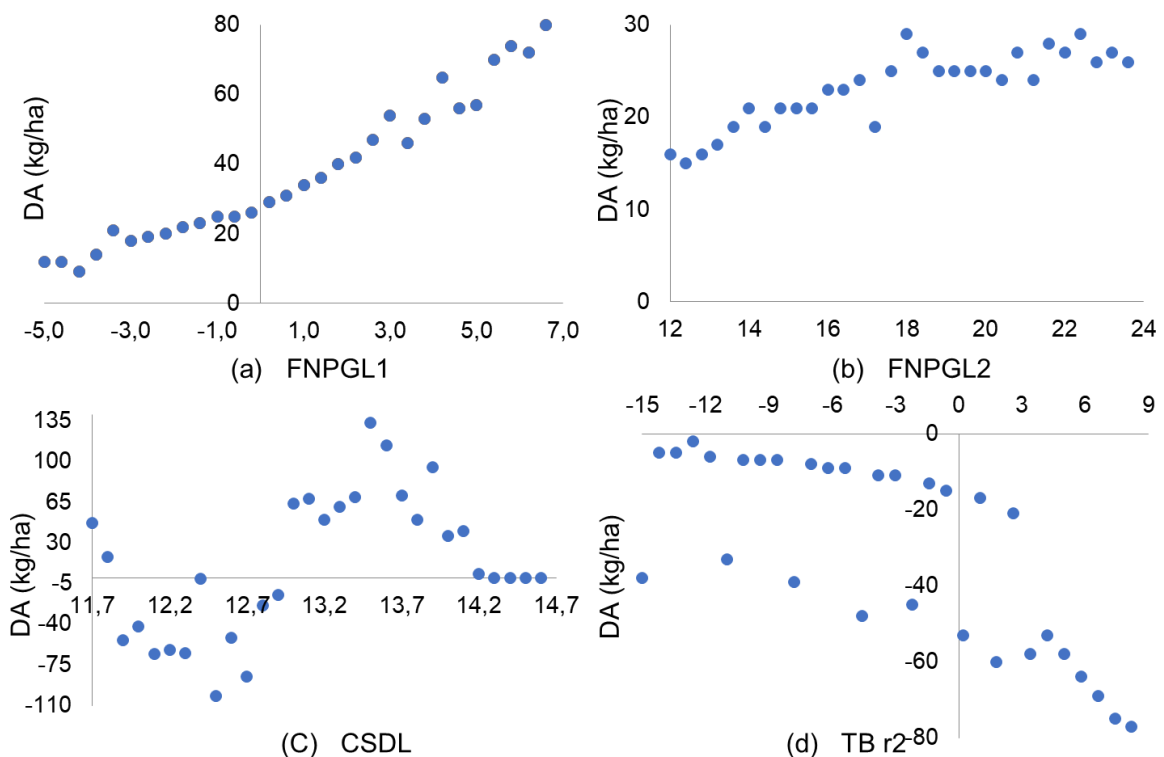


Figura 3.1. Valores de DA que muestran la sensibilidad del rendimiento en condiciones potenciales a los cuatro parámetros más sensibles: FNPGL1, FNPGL2, CSDL y TBr2.

El mismo procedimiento para determinar los rangos de sensibilidad se lleva a cabo tanto en condiciones de secano como potenciales para cada una de las variables de salida mencionadas en la Tabla 3.2, salvo para la variable R7-R8 que no presentó sensibilidad a

ninguno de los parámetros evaluados. En el Anexo Capítulo III se encuentran las Figuras A3.2 a A3.23 que se usaron para visualizar la sensibilidad de cada parámetro a cada variable de salida a partir de las cuales se obtuvieron los rangos de sensibilidad.

Los resultados finales del análisis de sensibilidad se resumen en la Tabla 3.4 para condiciones potenciales y la Tabla 3.5 para condiciones de secano. Estas tablas muestran los parámetros sensibles para cada variable de salida junto con sus rangos “sensibles”. Las celdas verdes indican que el parámetro correspondiente es sensible a la variable de salida tanto en condiciones de secano como potenciales; las celdas rosadas indican que el parámetro es sensible en condiciones de secano y las celdas celestes indican que el parámetro es sensible en condiciones potenciales. Los rangos finales resultan de la unión de los rangos de cada variable de salida en condiciones de secano y potencial. Los valores en la Tabla 3.4 corresponden a DTR en condiciones potenciales y la Tabla 3.5 presenta los valores de DTR en condiciones de secano. Los parámetros más sensibles a la fenología son CSDL, PPSEN, EM-FL, FL-SH, FL-SD, SD-PM. En la sensibilidad a la variable evapotranspiración se destaca SIZLF y KEP, los únicos parámetros sensibles que no son sensibles a fenología. En la sensibilidad a la biomasa se destacan LFMAX, SLAVR, PODUR, FNPGL1 y FNPGL2 que son los únicos parámetros sensibles a biomasa que no son sensibles a fenología y balance hídrico. Para rendimiento se destaca el parámetro SFDUR porque solo dio sensible al rendimiento y las componentes del rendimiento.

Tabla 3.4. Resultados finales del análisis de sensibilidad riego. Las celdas verdes indican que los parámetros son sensibles en condiciones de secano y potenciales, las celdas rosadas que son sensibles solo en condiciones de secano y las celdas celestes que son sensibles solo en condiciones potenciales. Los valores corresponden a DTR en condiciones potenciales.

Archivo-Parámetro	EM-R1	R1-R3	R3-R5	R5-R7	R7-R8	Vector ET	ETAc	Vector biomasa	Bio max	Rendimiento	Nº de granos	Peso granos	Rango de sensibilidad
cul- CSDL	0,262	0,212	0,209	0,027	0	0,197	0,075	0,483	0,216	0,092	0,086	0,026	11,7 a 14,0
cul- PPSEN	0,048	0,051	0,085	0,013	0	0,040	0,019	0,118	0,059	0,045	0,046	0,009	0,129 a 0,212
cul- EM-FL	0,105	0,038	0,074	0,014	0	0,066	0,024	0,191	0,067	0,048	0,031	0,019	17,2 a 21,6
cul- FL-SH	0	0,216	0,234	0	0	0	0,001	0,018	0,039	0,056	0,027	0,080	7,4 a 10,3
cul- FL-SD	0	0	0,354	0,012	0	0,024	0,023	0,043	0,027	0,030	0,108	0,131	0,16 a 0,35
cul- SD-PM	0	0	0	0,102	0	0,013	0,028	0,010	0,022	0,059	0,002	0,060	28,7 a 36,1
cul- FL-LF	0	0	0	0	0	0	0,001	0,003	0,008	0,007	0,007	0,001	
cul- LFMAX	0	0	0	0	0	0,001	0,001	0,061	0,061	0,067	0,056	0,011	0,850 a 1,400
cul- SLAVR	0	0	0	0	0	0,004	0,003	0,028	0,018	0,013	0,013	0,001	300 a 425
cul- SIZLF	0	0	0	0	0	0,037	0,023	0,105	0,059	0,049	0,037	0,012	140 a 235
cul- WTPSD	0	0	0	0	0	0	0	0,007	0,004	0,003	0,104	0,106	0,14 a 0,20
cul- SFDUR	0	0	0	0	0	0	0	0,004	0,009	0,024	0,073	0,097	19,0 a 27,7
cul- PODUR	0	0	0	0	0	0	0,001	0,011	0,029	0,006	0,008	0,012	6,0 a 19,0
eco-R1PPO	0	0,051	0,052	0,013	0	0,010	0,006	0,027	0,026	0,014	0,019	0,009	0,161 a 0,348
eco-OPTBI	0,019	0,040	0,051	0,012	0	0,011	0,003	0,033	0,009	0,007	0,002	0,005	17,5 a 20,5
eco-SLOBI	0,017	0,064	0,032	0,012	0	0,009	0,001	0,028	0,007	0,005	0,003	0,003	0,017 a 0,047
spe- TB veg	0,018	0,029	0,034	0,009	0	0,043	0,023	0,078	0,041	0,039	0,025	0,014	7,0 a 10,0
spe- TO1 veg	0,025	0,040	0,052	0,013	0	0,043	0,022	0,079	0,045	0,042	0,028	0,014	27,0 a 32,8
spe- TO2 veg	0	0	0	0	0	0	0	0,010	0	0,003	0,002	0,001	
spe- TM veg	0	0	0	0	0	0	0	0	0	0	0	0	
spe- TB r1	0,024	0,029	0,050	0,009	0	0,018	0,008	0,054	0,026	0,009	0,010	0,017	5,0 a 11,0
spe- TO1 r1	0,050	0,065	0,106	0,014	0	0,046	0,022	0,132	0,062	0,035	0,024	0,022	20,0 a 29,0
spe- TO2 r1	0,032	0,040	0,053	0,013	0	0,025	0,009	0,074	0,032	0,018	0,014	0,010	23,0 a 27,0
spe- TM r1	0,013	0,036	0,051	0,013	0	0,008	0,002	0,025	0,010	0,004	0,006	0,006	43,2 a 46,2
spe- TB r2	0	0	0	0,089	0	0,009	0,022	0,013	0,028	0,070	0,004	0,066	-15,0 a 8,5
spe- TO1 r2	0	0	0	0,037	0	0,003	0,006	0,005	0,008	0,027	0,002	0,025	21,4 a 25,4
spe- TO2 r2	0	0	0	0,014	0	0,001	0,002	0,001	0,003	0,008	0,002	0,010	
spe- TM r2	0	0	0	0	0	0	0	0	0	0	0	0	
spe- STG9-STG11	0	0	0	0	0	0	0	0	0	0	0	0	0,2 a 0,7
spe- RWUMX	0,005	0	0,018	0,005	0	0,017	0,009	0,057	0,034	0,025	0,021	0,005	0,01 a 0,03
spe- FNPGL1	0	0	0	0	0	0	0	0,043	0,064	0,106	0,029	0,079	-5,0 a 7,0
spe- FNPGL2	0	0	0	0	0	0	0,001	0,039	0,048	0,063	0,039	0,024	12,0 a 24,0
spe- FNNGT2	0	0	0	0	0	0	0	0,001	0	0,004	0,003	0,001	
spe- FNFXT2	0	0	0	0	0	0	0	0,001	0	0,004	0,003	0,001	
spe- KEP	0	0	0	0,005	0	0,034	0,015	0,005	0,012	0,021	0	0,020	0,50 a 0,83

Tabla 3.5. Resultados finales del análisis de sensibilidad seco. Las celdas verdes indican que los parámetros son sensibles en condiciones de seco y potenciales, las celdas rosadas que son sensibles solo en condiciones de seco y las celdas celestes que son sensibles solo en condiciones potenciales. Los valores corresponden a DTR en condiciones de seco.

Archivo-Parámetro	EM-R1	R1-R3	R3-R5	R5-R7	R7-R8	Vector ET	Vector ETAc	Vector biomasa	Bio max	Rendimiento	Nº de granos	Peso granos	Rango de sensibilidad
cul- CSDL	0,262	0,214	0,216	0,090	0	0,227	0,154	0,507	0,256	0,241	0,066	0,241	11,7 a 14,0
cul- PPSEN	0,048	0,051	0,085	0,015	0	0,043	0,026	0,120	0,046	0,058	0,020	0,046	0,129 a 0,212
cul- EM-FL	0,105	0,038	0,074	0,018	0	0,069	0,026	0,188	0,049	0,040	0,058	0,070	17,2 a 21,6
cul- FL-SH	0	0,216	0,234	0,017	0	0,019	0,011	0,056	0,033	0,109	0,073	0,184	7,4 a 10,3
cul- FL-SD	0	0	0,354	0,018	0	0,022	0,017	0,036	0,020	0,103	0,069	0,172	0,16 a 0,35
cul- SD-PM	0	0	0	0,127	0	0,007	0,014	0,004	0,000	0,037	0,001	0,038	28,7 a 36,1
cul- FL-LF	0	0	0	0	0	0,002	0,004	0,004	0,006	0,013	0,018	0,008	
cul- LFMAX	0	0	0	0	0	0,001	0,001	0,062	0,059	0,076	0,041	0,036	0,850 a 1,400
cul- SLAVR	0	0	0	0	0	0,004	0,002	0,035	0,024	0,036	0,017	0,025	300 a 425
cul- SIZLF	0	0	0	0,013	0	0,026	0,011	0,115	0,076	0,082	0,055	0,029	140 a 235
cul- WTPSD	0	0	0	0	0	0,001	0,000	0,006	0,003	0,003	0,104	0,105	0,14 a 0,20
cul- SFDUR	0	0	0	0	0	0,001	0,003	0,005	0,009	0,035	0,069	0,107	19,0 a 27,7
cul- PODUR	0	0	0	0,016	0	0,005	0,012	0,015	0,031	0,040	0,066	0,105	6,0 a 19,0
eco-R1PPO	0	0,051	0,051	0,019	0	0,012	0,009	0,026	0,018	0,015	0,014	0,026	0,161 a 0,348
eco-OPTBI	0,019	0,040	0,051	0,011	0	0,012	0,002	0,032	0,006	0,003	0,003	0,005	17,5 a 20,5
eco-SLOBI	0,017	0,039	0,053	0,016	0	0,009	0,002	0,027	0,006	0,002	0,003	0,004	0,017 a 0,047
spe- TB veg	0,018	0,029	0,034	0,017	0	0,031	0,010	0,099	0,079	0,127	0,112	0,020	7,0 a 10,0
spe- TO1 veg	0,025	0,040	0,052	0,016	0	0,032	0,011	0,099	0,081	0,126	0,111	0,021	27,0 a 32,8
spe- TO2 veg	0	0	0	0	0	0,001	0,001	0,012	0,007	0,010	0,005	0,005	
spe- TM veg	0	0	0	0	0	0	0,000	0	0,000	0,001	0,000	0,000	
spe- TB r1	0,024	0,034	0,050	0,016	0	0,019	0,007	0,051	0,016	0,008	0,030	0,032	5,0 a 11,0
spe- TO1 r1	0,050	0,065	0,106	0,019	0	0,047	0,024	0,127	0,045	0,035	0,023	0,034	20,0 a 29,0
spe- TO2 r1	0,032	0,040	0,053	0,015	0	0,026	0,011	0,072	0,022	0,012	0,018	0,022	23,0 a 27,0
spe- TM r1	0,013	0,036	0,051	0,015	0	0,009	0,003	0,024	0,007	0,005	0,009	0,013	43,2 a 46,2
spe- TB r2	0	0	0	0,101	0	0,006	0,014	0,002	0,001	0,025	0,007	0,033	-15,0 a 8,5
spe- TO1 r2	0	0	0	0,033	0	0,002	0,003	0,002	0,001	0,014	0,004	0,018	21,4 a 25,4
spe- TO2 r2	0	0	0	0,012	0	0,001	0,001	0,001	0,000	0,003	0	0,004	
spe- TM r2	0	0	0	0	0	0	0	0	0	0	0	0	
spe- STG9-STG11	0	0	0	0,062	0	0,004	0,008	0,001	0	0,007	0	0,007	0,2 a 0,7
spe- RWUMX	0,005	0	0	0,021	0	0,012	0,012	0,081	0,067	0,091	0,056	0,056	0,01 a 0,03
spe- FNPGL1	0	0	0	0	0	0,007	0,001	0,043	0,023	0,053	0,010	0,043	-5,0 a 7,0
spe- FNPGL2	0	0	0	0	0	0	0	0	0	0	0	0	12,0 a 24,0
spe- FNNGT2	0	0	0	0	0	0,007	0,001	0,018	0,000	0,003	0,011	0,008	
spe- FNFXT2	0	0	0	0	0	0,007	0,001	0,019	0,000	0,003	0,011	0,008	
spe- KEP	0	0	0	0,010	0	0,028	0,013	0,025	0,010	0,019	0,023	0,017	0,50 a 0,83

## **CAPÍTULO IV – AJUSTES PRELIMINARES: CRECIMIENTO DE RAICES Y CONTENIDO DE AGUA INICIAL EN EL SUELO**

### **4.1 Introducción**

Los modelos de cultivos basados en procesos son herramientas útiles para simular el crecimiento, el desarrollo y el rendimiento de las plantas, así como el balance hídrico del suelo (Moura da Silva *et al.*, 2021). Los modelos tienen un requerimiento básico de información que el usuario debe suministrar para su funcionamiento. Para mayor especificidad en la simulación, el modelo tiene una amplia serie de opciones que el usuario puede indicar. Si no se dispone de la información necesaria para especificar esos valores, se puede usar el modelo con los valores predeterminados que el desarrollador haya especificado. No obstante, estos valores surgen de experimentos particulares que no fueron llevados a cabo en el mismo ambiente que el usuario desea aplicar el modelo o podrían haber surgido de promedios de diversos experimentos. En ambos casos, si el usuario desea una simulación que refleje en mayor medida los procesos del ambiente a analizar es conveniente revisar estos parámetros y corregir o adaptar sus valores para la zona de estudio.

Se describirá en este capítulo los experimentos utilizados para calibración y validación del modelo CROPGRO. En el sistema suelo-planta-atmósfera, el flujo del agua es un factor clave y son las raíces de las plantas las principales movilizadoras del agua del suelo (Clothier *et al.*, 2008a y 2008b). Por esta razón se prestó especial atención al ajuste del contenido de agua inicial en el perfil del suelo y la dinámica de crecimiento de las raíces. El objetivo de este capítulo es, a partir de un análisis de las relaciones del modelo entre la dinámica hídrica del suelo y el crecimiento de las raíces del cultivo, mejorar la simulación de los experimentos que se va a usar para la calibración para que refleje correctamente el contenido de agua inicial del modelo, la profundización de raíces y el crecimiento de las mismas. De esta manera, se ajustarán parámetros para que luego en la calibración del cultivar se representen fielmente las condiciones de la localización del estudio que están reflejadas en diferentes parámetros que se encuentran en los archivos de especie, suelo y experimento del modelo numérico.

## 4.2 Materiales y métodos

En esta sección se describe en primer lugar el experimento agronómico junto con los datos y las condiciones para la realización de las pruebas de simulación en los apartados 4.2.1, 4.2.2 y 4.2.3. En segunda instancia, dado que no es fácil conseguir mediciones de campo para el contenido inicial de agua del suelo y la progresión del crecimiento de las raíces, se decidió evaluar el contenido de agua del suelo al momento de la siembra, el factor del suelo de crecimiento de la raíz (SRGF) y la progresión de la profundidad de la raíz utilizando procedimientos de datos blandos (*soft data*) en las secciones 4.2.4, 4.2.5 y 4.2.6, respectivamente.

Los datos blandos se definen como información sobre procesos individuales dentro de un balance que puede no medirse directamente en el área de estudio. Los ejemplos de datos blandos incluyen estimaciones regionales de índices de relaciones de flujo base o evapotranspiración, profundidades promedio de las capas freáticas, coeficientes de escorrentía anual promedio para varios usos de la tierra, tasas anuales de desnitrificación de parcelas de investigación encontradas en la literatura, concentraciones medias de eventos, coeficientes de exportación de nutrientes/sedimentos, acumulación de sedimentos en estudios de sedimentación de embalses, índice de área foliar promedio de cultivos/vegetación, rendimientos de cultivos departamentales/regionales y otros. Seibert y McDonnell (2002) argumentaron que los datos blandos representan una nueva dimensión para el proceso de calibración del modelo que podría:

(i) permitir el diálogo entre experimentadores y modeladores, (ii) ser una verificación formal de la razonabilidad y consistencia de las estructuras y simulaciones del modelo, y (iii) especificar rangos de parámetros realistas que generalmente se ignoran en las rutinas de calibración automática actuales. Se destaca que la performance de los modelos aumenta considerablemente al utilizar datos blandos. En Romagnoli *et al.* (2017), la incertidumbre de los parámetros se reduce en un 60 % en promedio, con la introducción de la calibración multicriterio de datos blandos; el desarrollo de datos blandos incluyó el flujo de entrada, la identificación del uso de la tierra, la carga de Nitrógeno y Fósforo y los valores para la eficiencia del uso de Nitrógeno.

### 4.2.1 Descripción de los experimentos de campo

Los datos para realizar la calibración y validación se recolectaron de ensayos de campo realizados en EEA Pergamino (Estación Experimental Agropecuaria del Instituto Nacional de Tecnología Agropecuaria, 33°57'46"S 60°34'25"W) por el grupo Cultivos extensivos a cargo de María Otegui en dos temporadas de cultivo sucesivas (2017-18 y 2018-19). La

soja transgénica HaHB4 de segunda generación se cultivó bajo dos regímenes hídricos contrastantes: déficit hídrico en 2017-18 y riego abundante en 2017-18 y 2018-19. El diseño experimental fue de bloques completos al azar con tres repeticiones y parcelas de 2.08 m de ancho por 5 m de largo. Las etapas de crecimiento del cultivo se determinaron siguiendo la escala fenológica de soja desarrollada por Fehr *et al.* (1971). Las mediciones de la biomasa aérea y el contenido de agua del suelo se realizaron en diferentes etapas de crecimiento. El rendimiento de grano se obtuvo en madurez fisiológica mediante la cosecha manual de todas las plantas presentes en al menos un m<sup>2</sup> de una hilera central de cada parcela. El contenido de agua del suelo se cuantificó mediante mediciones volumétricas (0–30 cm de profundidad) y mediciones con sonda de neutrones (Troxler 3400, Troxler Electronic Laboratories, NC, EE. UU.) (30–185 cm de profundidad). En el tratamiento del déficit hídrico, se excluyó la lluvia de las parcelas a través de refugios removibles instalados 23 DDS (días después de la siembra) (es decir, antes de iniciar R1) y removidos 91 DDS (en R6). Los tratamientos bien regados recibieron agua por aspersion programada para mantener las capas de suelo cerca de la capacidad de campo. Se pueden encontrar más detalles sobre los experimentos de campo en Ribichich *et al.* (2020).

#### 4.2.2 Datos meteorológicos

Los datos meteorológicos de los ensayos experimentales se obtuvieron del sistema de información agrometeorológica del INTA (<http://siga2.inta.gov.ar/>). Esta base de datos centralizada proporciona información pública basada en una red nacional de estaciones meteorológicas. La distancia entre el sitio experimental y la estación meteorológica es menor a 100 m, la cual está dentro de la distancia máxima de 1 km sugerida por Kersebaum *et al.* (2015). Todos los datos meteorológicos se procesaron con WeatherMan, que convierte los datos al formato CSM-DSSAT (Pickering *et al.*, 1994). Los datos meteorológicos de entrada necesarios para el modelo incluían la radiación solar diaria, la temperatura máxima y mínima del aire y las precipitaciones. Para la temporada de cultivo 2017-18, la cantidad total de lluvia caída durante el ciclo de cultivo (diciembre a abril) fue de 198 mm, y los valores promedio de radiación solar diaria, temperatura máxima y mínima del aire fueron 21,3 MJ m<sup>2</sup>/día, 29,7 °C y 14,3 °C, respectivamente. Para la temporada de cultivo 2018-19, la cantidad total de lluvia caída durante el ciclo de cultivo fue de 776 mm, y los valores promedio de radiación solar diaria, temperatura máxima y mínima del aire fueron 19,4 MJ m<sup>2</sup>/día, 27,0 °C y 14,7 °C, respectivamente.

#### 4.2.3 Datos de suelo y manejo agronómico

Los datos sobre el manejo de cultivos y las características del suelo son insumos esenciales para la simulación de cultivos. El suelo representativo para el sitio experimental es un argiudol típico térmico fino, ilítico (Taxonomía de suelos de EE. UU.) de la serie Pergamino sin fase de erosión hídrica (pendiente < 0,3%). El perfil del suelo tiene una profundidad de 2 m con una capacidad de almacenamiento de agua de 348,6 mm (Llovet, 2014). La conductividad hidráulica saturada y el contenido de agua del suelo saturado se estimaron utilizando funciones de pedo-transferencia disponibles en CSM-DSSAT (Saxton y Rawls, 2006). En este estudio se usó un factor de fertilidad del suelo de 1,0 porque los suelos en esta región son generalmente fértiles sin mayores problemas. La Tabla A4.8 del Anexo Capítulo IV muestra las propiedades del perfil del suelo experimental tales como fueron ingresadas al modelo. Las fechas de siembra son fechas tardías, el 18 de diciembre de 2017 para calibración y el 4 de diciembre de 2018 para validación, la densidad de plantas fue de 30 plantas/m<sup>2</sup> y el espacio entre hileras fue de 0,35 m. Los cultivos antecesores del experimento de calibración fueron trigo y maíz de segunda en la campaña 2016-2017. El agua total recibida (riego + precipitación) en los tratamientos bien regados fue de 326,5 mm (128,5 + 198) para 2017-18 y 806 mm (30 + 776) para la temporada de crecimiento 2018-19. La condición de déficit hídrico recibió un total de 132 mm de los cuales 74mm fueron antes R1 y 40mm fueron después de R6; algunas precipitaciones, en total 18mm, no fueron cubiertas por el *shelter* o se cubrió cuando ya había empezado a llover.

#### 2.2.4 Contenido de agua en el perfil del suelo al momento de la siembra

El contenido de agua es crucial para estimar el balance hídrico del suelo, que está fuertemente asociado con el crecimiento y desarrollo de los cultivos. En este experimento se midió el contenido de agua en el suelo con una sonda de neutrones, se necesitan permisos especiales para el uso de la sonda, dificultades operativas llevaron a que la primera medición volumétrica del contenido de agua del suelo se realizó el 10 de enero de 2018, es decir, 23 DDS, y se necesitaba estimar el contenido de agua del suelo al momento de la siembra, es decir, ajustar el contenido de agua inicial del experimento.

Se llevó a cabo un proceso iterativo para las dos prácticas de manejo consideradas en el experimento, déficit hídrico y riego. Para este proceso se ejecutó CROPGRO con los parámetros en sus valores base correspondiente al cultivar W82 (*Williams 82*). Un aspecto a tener en cuenta es que el experimento numérico consiste en representar un suelo formado por los horizontes que provee la Carta de Suelos del INTA para la Serie Pergamino (6 horizontes hasta una profundidad de 1,80m) y los datos experimentales con los que se

cuenta, que fueron medidos cada 30cm de suelo (6 capas de suelo definidas por la metodología de medición de humedad *in-situ* hasta una profundidad de 1,80m). De este modo, debido a que las profundidades de las capas de INTA y las medidas son diferentes, se consideran 11 capas de suelo como *input* de CROPGRO, según se muestra en la Figura 4.1 (valores del perfil de suelo observables en la Tabla A4.8 del Anexo Capítulo IV).




Figura 4.1. Profundidades de los datos de suelo disponibles y del perfil de suelo utilizado en la simulación. CS-INTA es la Carta de Suelo de INTA, CC es capacidad de campo, PMP es punto de marchitez permanente y CA es el contenido de agua. La sonda de medición de CA mide cada 30 cm, la CC y el PMP también se midieron cada 30 cm porque son calculados para la utilización de la sonda.

En una primera iteración se modificó de manera aleatoria el contenido inicial de agua del suelo para cada una de las 11 capas simuladas, en un rango delimitado por un límite inferior de agua del suelo extraíble por las plantas (punto de marchitez permanente, *SLLL*: son las siglas en el modelo CROPGRO) y un límite superior de retención de agua (capacidad de campo, *SDUL*: son las siglas en el modelo CROPGRO). Se realizaron 3000 corridas de CROPGRO.

La segunda iteración se realizó teniendo en cuenta que el perfil de suelo para el experimento numérico está formado por once capas de suelo de diferentes espesores con una profundidad máxima de 180 cm y los contenidos iniciales de esas once capas se debían ajustar con las mediciones de agua del suelo realizadas con una sonda que midió 23 DDS el contenido de agua cada 30 cm de suelo, es decir, en seis capas de suelo definidas por la metodología de medición de humedad *in-situ*. Entonces, con las once capas de suelo de la simulación y seis capas de suelo medidas 23 DDS, se decidió hacer variar los rangos de contenido inicial para la segunda iteración por capa de suelo simulada, aunque varias de estas capas se correspondan con una única capa de suelo en la que se midió contenido de agua (ver Figura 4.1). Los rangos de variación para cada una de las once capas se definieron en función de los mejores 30 resultados que arrojó la primera iteración respecto a los datos observados a los 23 DDS.

Para la evaluación del desempeño en ambas iteraciones se calculó la raíz del error cuadrático medio (RMSE) de todo el perfil de suelo para las dos condiciones hídricas por separado.

#### 4.2.5 Factor de crecimiento de la raíz

CROPGRO tiene la capacidad de simular diferentes densidades de la longitud de la raíz a lo largo del perfil de suelo, a través de un parámetro que determina el potencial de crecimiento de raíz en cada capa de suelo considerada. Este parámetro se denomina SRGF (*Soil Root Growing Factor*) y determina la capacidad de las raíces para crecer y proliferar en una capa de suelo, lo que a su vez modifica la cantidad de agua del suelo que pueden absorber las mismas.

SRGF fue el parámetro ajustado en el modelo para representar la absorción de agua de las raíces a través de la distribución del contenido de agua observada en el perfil del suelo hacia el final del ciclo de cultivo. Los valores de SRGF pueden variar de 0,0 a 1,0. Un valor de 1,0 para una capa dada indica que no hay restricciones de impedancia del suelo donde el crecimiento profundo de la raíz progresa a tasas máximas. Un valor inferior a 1,0

restringe el crecimiento de raíces y un valor de 0,0 significa que no hay penetración de raíces en la capa.

Se implementó un procedimiento de *prueba y error*, comenzando con los valores iniciales generados por la herramienta SBuild que forma parte del paquete de DSSAT, al que se le entrega información básica de la textura y materia orgánica estable del suelo por capa y el programa calcula datos faltantes a través de funciones de pedo-transferencia. Se llamó a estos valores SRGF iniciales. Luego se calculó la diferencia en porcentaje entre el agua útil máxima y el agua útil a final de ciclo y se los llamó SRGF basados en medición (ver Tabla 4.1). Luego basado en el trabajo de Dardanelli *et al.* (2003), se propusieron valores más bajos para los horizontes argílicos, que corresponden a los horizontes del suelo con mayor contenido de arcilla y se los llamó SRGF con reducción en Bt. Por último, en base a las mediciones de contenido de agua en el suelo al final del ciclo que indicaban que a partir de una profundidad de 120 cm se había consumido casi la totalidad del agua disponible se dispuso aumentar los valores de SRGF en los horizontes por debajo del horizonte argílico y se los llamó SRGF ajustados.

Tabla 4.1. Principales valores de SRGF probados.

Profundidad	SRGF			
	Iniciales	Basados en medición	Con reducción en Bt	Ajustados
0-15	1	1	1	1
15-25	1	1	1	1
25-30	0,577	1	1	1
30-45	0,472	0,661	0,041	0,041
45-60	0,350	0,661	0,041	0,041
60-75	0,259	0,275	0,017	0,017
75-90	0,192	0,275	0,017	0,017
90-120	0,122	0,794	0,122	1
120-135	0,078	0,962	0,078	1
135-150	0,058	0,962	0,058	1
150-180	0,037	0,968	0,037	1

Todos los valores fueron evaluados a través de la comparación del contenido de agua al final del ciclo medido y simulado en las diferentes capas del suelo. Además, para tener una estadística general se calculó RMSE de todo el perfil para ambos tratamientos.

#### 4.2.6 Progresión de la profundidad de la raíz

Las mediciones de campo de progresión de la profundidad de raíces en el tiempo son extremadamente difíciles de realizar de manera directa, pueden requerir ensayos de grandes superficies porque serían muestras destructivas. Además, si se considera como menciona Andriani (2000) que la profundidad alcanzada por las raíces de soja es de 200

cm en suelos argiúdoles sin impedimentos físicos, las muestras serían muy complicadas de tomar por la dificultad de perforar el suelo hasta esa profundidad. Por lo tanto, y teniendo en cuenta la disponibilidad de mediciones con las que se contaba, la progresión de raíces fue estimada de manera indirecta en base a la humedad del suelo. El contenido de agua en el suelo fue medido cada 30 cm de profundidad hasta 180 cm en cinco momentos del ciclo, en esta sección resultó de interés fundamentalmente las mediciones a las profundidades 120-150 cm y 150-180 cm, ya que se buscó representar la profundización total de la raíz. Además, se tuvo en cuenta que en las capas a mayor profundidad que 90 cm no tuvieron saturación del suelo en la campaña, ya que, su contenido de agua útil es marcadamente inferior a capacidad de campo en todas las mediciones realizadas, y por esto, se puede inferir que no hay movimiento vertical de agua. Entonces, se consideró que si entre dos mediciones a la misma profundidad realizadas en momentos consecutivos había una reducción significativa del contenido hídrico (los intervalos formados por la media de las tres muestras de la medición más/menos un desvío estándar no se superponen), las raíces habían llegado hasta esa zona en el intervalo de tiempo entre las dos mediciones. A esta profundidad se la llamará de ahora en más “valor observado de profundidad de la raíz”.

Se evaluaron los ocho parámetros de la raíz que identifican a la soja en CROPGRO, y sus rangos de variación se obtuvieron de los trabajos de Boote *et al.* (2002, 2003). A través de un análisis de sensibilidad se seleccionaron los parámetros que más afectaron la progresión de la raíz: YRTFAC, RWUEP1, RTDEPI, RFAC1 y RTSEN. Una vez seleccionados estos parámetros, se configuraron sus valores en función de los que mejor se ajustaban a la profundidad de raíz estimada. En la Tabla 4.2 se indican los parámetros con su significado, el valor por defecto del modelo y el rango de evaluación definido.

Tabla 4.2. Parámetros de raíz del modelo CROPGRO-soybean.

Parámetros	Definición	Valor base	Rango de prueba
RTDEPI	Profundidad de las raíces el día de la emergencia de la planta. (cm)	20,0	15,0:25,0
RFAC1	Longitud de raíz por unidad de peso de raíz. (cm/g)	7500	6750:8250
RTSEN	Fracción de la longitud de la raíz existente que puede senescer por día fisiológico.	0,020	0,008:0,025
RLDSM	Densidad mínima de longitud de raíz en una capa determinada, por debajo de la cual no se permite la senescencia inducida por la sequía.	0,10	0,01:0,50
RTSDF	Fracción máxima de la longitud de la raíz que senesce en una capa dada por día fisiológico cuando el contenido de agua esa capa cae por debajo del 25% del agua útil.	0,015	0,010:0,050
RWUEP1	Umbral para reducir la expansión de la hoja según la comparación con la proporción de absorción de agua de la raíz diaria potencial total en relación a la transpiración real.	1,50	1,00:2,00
RWUMX *	Absorción máxima de agua por unidad de longitud de raíz, limitada por el agua del suelo (cm <sup>3</sup> [agua] / cm [raíz])	0,04	0,010:0,180
YRTFAC (4) **	Tasa de aumento en la profundidad de la raíz por grado día según el número de nudos primarios de la hoja del tallo XRTFAC (cm/día fisiológico)	2,5-2,5- 2,6-2,6	2,00:4,40

\* Es sensible a varias variables de crecimiento y desarrollo fue usado para la calibración en el Capítulo V.

\*\* Es un vector de cuatro componentes, se utilizó modificándolas a la par con el mismo valor.

### 4.3. Resultados

#### 4.3.1 Contenido inicial de agua en el perfil del suelo

En una primera iteración, se realizaron 3000 simulaciones para cada práctica de manejo. En este paso, el valor inicial del contenido de agua del suelo de cada capa se varió aleatoriamente dentro del rango delimitado por SLLL y SDUL. La mejor estimación del contenido de agua del suelo (0-30, 30-60, 60-90, 90-120, 120-150 y 150-180 cm) el 10 de enero de 2018 alcanzó un valor RMSE de 0,025 cm<sup>3</sup>/cm<sup>3</sup> para la condición de déficit hídrico y para la condición de riego un valor RMSE de 0,040 cm<sup>3</sup>/cm<sup>3</sup>.

Se redujeron los rangos de la iteración inicial de manera considerable, en base al rango delimitado por los mejores resultados de la primera iteración en cada una de las capas del suelo y se realizó una segunda iteración. Este proceso resultó necesario porque los rangos iniciales probados eran demasiado amplios y 3000 simulaciones aleatorias del modelo no eran suficientes para calibrar los contenidos de agua de 11 capas del suelo. Los rangos de intervalo por capa utilizados en el proceso de iteración se muestran en la Tabla 4.3. Esta segunda iteración mejoró la calidad de los resultados alcanzando un valor de RMSE de

0,010  $\text{cm}^3/\text{cm}^3$  para condiciones de déficit hídrico y un valor de RMSE de 0,034  $\text{cm}^3/\text{cm}^3$  para condiciones con riego (Figura 4.2b). Los valores iniciales del contenido de agua del suelo después de la segunda iteración se muestran en la Figura 4.2a, estos valores son los que se utilizarán en el Capítulo V para el proceso de calibración. El contenido de agua del suelo simulado para estos valores iniciales y los observados el 10 de enero de 2018 se muestran en la Figura 4.2b, además se presentan las condiciones de punto de marchitez permanente y capacidad de campo (SLLL y SDUL respectivamente) con líneas grises escalonadas cada 30 cm, para tenerlas como referencia.

Tabla 4.3. Intervalo de valores usados para la calibración del contenido de agua inicial en cada iteración.

Profundidad (cm)	Riego		Déficit hídrico	
	1er iteración	2da iteración	1er iteración	2da iteración
0-15	0,191:0,371	0,191:0,210	0,191:0,371	0,195:0,205
15-25	0,191:0,371	0,191:0,220	0,191:0,371	0,200:0,210
25-30	0,191:0,371	0,191:0,220	0,191:0,371	0,200:0,220
30-45	0,230:0,406	0,340:0,380	0,230:0,406	0,334:0,404
45-60	0,230:0,406	0,346:0,386	0,230:0,406	0,360:0,406
60-75	0,231:0,401	0,385:0,401	0,231:0,401	0,356:0,401
75-90	0,231:0,401	0,388:0,400	0,231:0,401	0,376:0,401
90-120	0,200:0,349	0,309:0,314	0,200:0,349	0,325:0,333
120-135	0,158:0,329	0,213:0,243	0,158:0,329	0,250:0,290
135-150	0,158:0,329	0,220:0,250	0,158:0,329	0,258:0,298
150-180	0,156:0,326	0,215:0,245	0,156:0,326	0,253:0,257

(a) Humedad de suelo en la siembra

Profundidad (cm)	Riego	Deficit hídrico
0-15	0.196	0.207
15-25	0.201	0.202
25-30	0.208	0.197
30-45	0.386	0.351
45-60	0.400	0.385
60-75	0.401	0.395
75-90	0.401	0.400
90-120	0.325	0.311
120-135	0.283	0.223
135-150	0.263	0.246
150-180	0.257	0.216

(b) Humedad de suelo el 10 de enero (23 DDS)

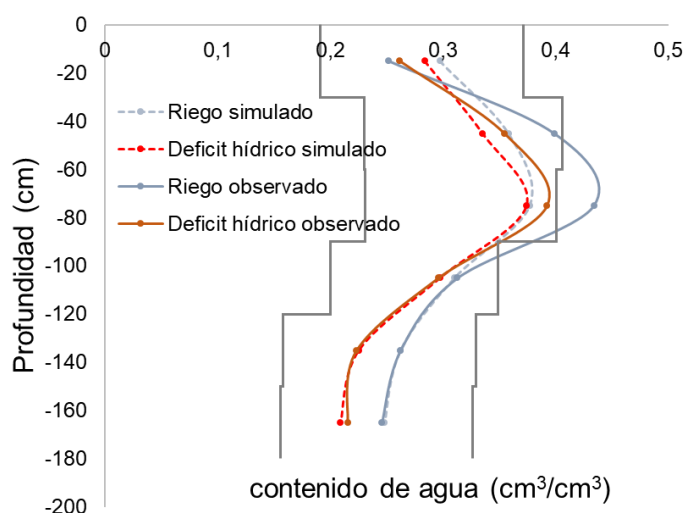


Figura 4.2. (a) Contenido de agua del suelo inicial estimado después de las dos iteraciones. (b) Contenido de agua del suelo observado y simulado después de la segunda iteración el 10 de enero de 2018.

#### 4.3.2 Factor de crecimiento de la raíz

Los suelos argílicos se caracterizan por un comportamiento de expansión y agrietamiento, lo que puede resultar en la formación de impedancias que afecten el crecimiento de raíces y, por lo tanto, la capacidad del sistema radical para extraer agua puede verse restringida debido a la proliferación limitada en el suelo circundante (Dardanelli *et al.*, 2003). La modificación de los valores iniciales de SRGF nos permitió simular la restricción de la proliferación de raíces en los horizontes argílicos, y por lo tanto considerar la disminución de la extracción de agua del suelo por parte de las raíces (Boote *et al.*, 2008).

Los valores SRGF ajustados fueron los que mejor representaron las distribuciones de contenido de agua del suelo simuladas al final del ciclo del cultivo (29 de marzo de 2018) en comparación con los valores medidos para ambas condiciones, déficit hídrico y riego (Tabla 4.4).

Tabla 4.4. Contenido de agua el 29 de marzo para los diferentes SRGF probados.

Profundidades del suelo		0-30	30-60	60-90	90-120	120-150	150-180	RMSE
Medido	Déficit Hídrico	0,191	0,290	0,357	0,234	0,164	0,161	-
	Riego	0,239	0,293	0,354	0,231	0,188	0,176	
Inicial	Déficit Hídrico	0,215	0,234	0,247	0,231	0,218	0,207	0,056
	Riego	0,209	0,251	0,266	0,249	0,240	0,235	
Basado en medición	Déficit Hídrico	0,257	0,233	0,253	0,217	0,220	0,206	0,055
	Riego	0,256	0,259	0,279	0,238	0,230	0,236	
Reducción en Bt	Déficit Hídrico	0,248	0,256	0,278	0,214	0,197	0,206	0,044
	Riego	0,243	0,295	0,311	0,242	0,240	0,238	
Ajustado	Déficit Hídrico	0,224	0,271	0,312	0,202	0,182	0,206	0,032
	Riego	0,212	0,322	0,353	0,213	0,202	0,234	

El contenido de agua del suelo simulado para los valores de SRGF iniciales y ajustados, así como los valores observados el 29 de marzo de 2018 se muestran en la Figura 4.3; como referencia también se incluyen en líneas escalonadas grises el SLLL y SDUL para las distintas capas de suelo de 30cm de espesor.

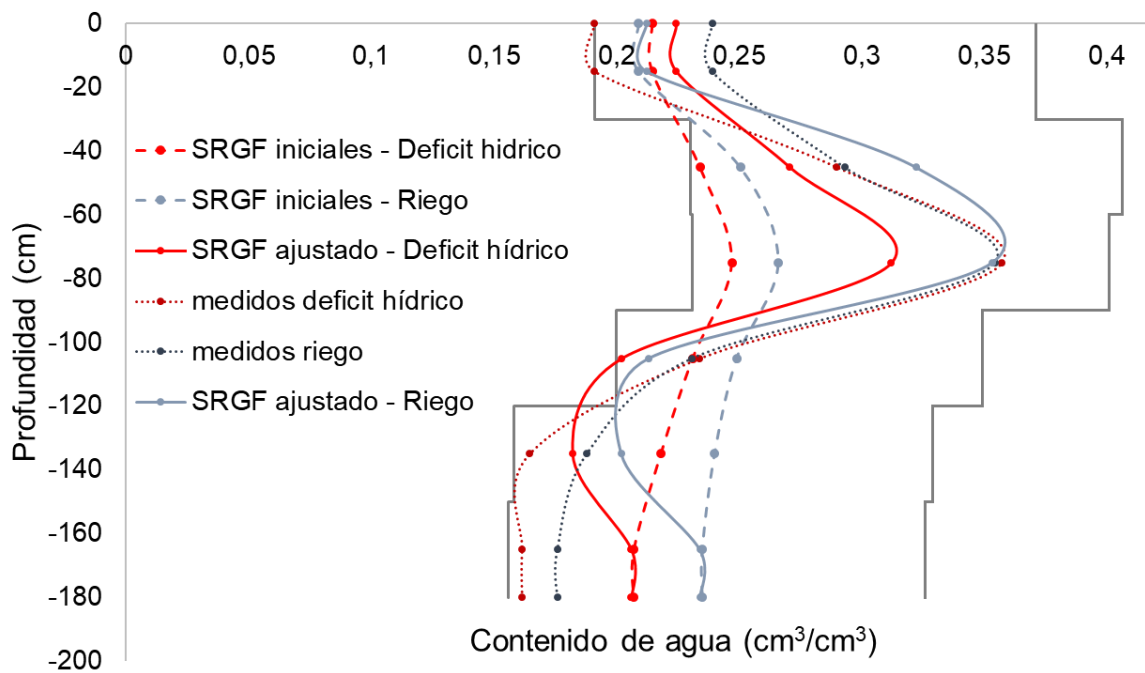


Figura 4.3. Contenido de agua del suelo observado y simulado el 29 de marzo de 2018 (101 DDS) usando valores de SRGF iniciales y ajustados.

Los valores iniciales de SRGF afectaban la simulación entre los 30-90 cm, permitiendo que el cultivo absorbiera mucha más agua en el horizonte argílico (líneas de trazo, Figura 4.3) en comparación con las mediciones que se realizaron (líneas de puntos, Figura 4.3). Además, esos valores iniciales de SRGF arrojaban resultados simulados con un consumo mucho menor de agua entre los 90-180 cm. Los valores SRGF de 0,041 y 0,017 ajustados a 30-60 y 60-90 cm de profundidad corresponden a los horizontes argílicos (Bt) de un Argiudol Típico. Estos valores simulan mejor las distribuciones de agua del suelo al final del ciclo de cultivo que los valores iniciales de SRGF debido a que restringen la proliferación de raíces y la extracción de agua del suelo a 30-90 cm de profundidad (Figura 4.3). Los valores de RMSE se reducen de 0,056 (SRGF iniciales) a 0,032  $\text{cm}^3/\text{cm}^3$  (SRGF ajustado). Para la capa a 150-180 cm de profundidad, ambos valores de SRGF (valor inicial de 0,037 y valor ajustado de 1) simulan el mismo contenido de agua del suelo (0,207  $\text{cm}^3/\text{cm}^3$  para déficit de agua y 0,234  $\text{cm}^3/\text{cm}^3$  para condiciones de riego). Esto se explica porque la proliferación de raíces por debajo de los 120-150 cm de profundidad es limitada y la profundidad máxima de enraizamiento no podría alcanzar la capa más profunda observada (150-180 cm). En la siguiente sección se presenta un análisis de la progresión de la profundidad de la raíz. Los valores ajustados de SRGF se utilizaron en los resultados de calibración y validación en el Capítulo V.

### 4.3.3 Progresión de la profundidad de la raíz

En ausencia de mediciones de progresión de la profundidad de las raíces y debido a la fuerte relación positiva entre la profundidad de las raíces y la humedad del suelo, se relacionó la humedad del suelo monitoreada con el crecimiento de las raíces según se mencionó en el apartado 4.2.6: cuando el contenido de humedad observado a 120-150 cm o a 150-180 cm de profundidad disminuye de manera significativa frente a una medición anterior, se consideró que existe absorción de agua por parte de las plantas y la profundidad de enraizamiento ha llegado a esta capa de suelo. La progresión de la profundidad de enraizamiento observada basada en la extracción de agua del suelo se muestra en la Tabla 4.5.

Tabla 4.5. Periodos de tiempo estimados en los que las raíces alcanzan profundidades de 120-150 cm y 150-180 cm y fechas simuladas usando los valores base y ajustados de los parámetros de raíz. Con tipografía **negrita** se indican las fechas en las que se alcanzó la profundidad que se encuentran incluidas dentro del intervalo estimado según las mediciones.

Profundidad de raíces (cm)	Estimado según agua en el suelo		Simulado Corrida base		Simulado Corrida ajustada	
	Déficit hídrico	Riego	Déficit hídrico	Riego	Déficit hídrico	Riego
120-150	24-ene a 7-feb	7-feb a 20-feb	15-feb	<b>16-feb</b>	<b>5-feb</b>	<b>9-feb</b>
150-180	7-feb a 20-feb	20-feb a 29-mar	Sin raíces	Sin raíces	<b>18-feb</b>	17-feb

Una vez ajustados los valores de SRGF, se verificó la progresión de la profundidad de la raíz simulada para una ejecución base del modelo (es decir, una corrida del modelo con el experimento planteado y los parámetros del cultivar Williams 82 con sus valores por defecto). Para esta *corrida base*, se observó la profundidad máxima de enraizamiento simulada y las fechas en que se alcanzaron estas profundidades para los diferentes tratamientos. Las fechas corresponden al primer día donde la densidad de raíz simulada (RL#D, variable de salida del modelo CROPGRO donde # indica la capa del suelo) tiene valores mayores a cero y se evaluó para profundidades en las que hay datos de campo disponibles (se utilizó RL8D para 120-150 cm de profundidad y RL9D para 150-180 cm de profundidad). La profundidad máxima de enraizamiento para la corrida base alcanzó los 120-150 cm de profundidad del suelo el 15 y 16 de febrero de 2018 para condiciones de déficit hídrico y riego, respectivamente. Estos resultados mostraron que la proliferación de raíces simulada por debajo de 150 cm fue limitada y, por lo tanto, la planta no pudo extraer agua de la capa más profunda observada a 150-180 cm de profundidad (Tabla 4.5).

Para mejorar la progresión de la profundidad de la raíz simulada, se realiza un ajuste sobre los cinco parámetros que afectan a la profundidad de enraizamiento YRTFAC, RWUEP1, RTDEPI, RFAC1 y RTSEN. Las variables de salida evaluadas fueron las fechas en que las raíces alcanzaron 120-150 y 150-180 cm de profundidad para condiciones de déficit hídrico y bien regado. Los valores ajustados de estos cinco parámetros, alcanzados después de dos iteraciones de 3000 simulaciones cada una, fueron los que proporcionaron el mejor ajuste de la progresión de la profundidad de enraizamiento simulada frente a la observada a 120-150 cm y 150-180 cm de profundidad. Como ya se mencionó, los rangos de los parámetros en la primera iteración se obtuvieron de la literatura. En la segunda iteración, los rangos fueron la mitad de los iniciales y se centraron en el valor que correspondía a la mejor simulación de la primera iteración. En la Tabla 4.6 se muestran los parámetros sensibles y sus rangos de variación, junto con los valores base y ajustados obtenidos tras el procedimiento de ajuste. Los resultados de la progresión de la profundidad de la raíz obtenidos usando los valores base y los valores ajustados de los parámetros de la raíz se muestran en la Tabla 4.5.

La profundidad de enraizamiento máxima simulada mejoró después del procedimiento de ajuste y alcanzó la capa más profunda observada (150-180 cm de profundidad) bajo ambos tratamientos. Para la condición de déficit hídrico, el crecimiento de la raíz muestra que las raíces alcanzan 120-150 y 150-180 cm de profundidad en fechas (5 y 18 de febrero, respectivamente) concordantes con las observadas. Para la condición de riego se logró que las raíces alcancen la profundidad de 150-180 cm, aunque no dentro del periodo observado 20/02-29/03, sino adelantándose tres días. De todas maneras, se considera aceptable el ajuste dado que se consiguió simular la profundización de las raíces.

Tabla 4.6. Parámetros sensibles a profundidad de raíz, valores base, rangos de iteración y valores ajustados.

Parámetro	Valor base	1er iteración	2da iteración	Valor ajustado
spe-YRTFAC*	2.50	2.00:4.40	2.96:4.16	3.33
spe-RWUEP1	1.50	1.00:2.00	1.34:1.83	1.52
spe-RTDEPI	20.00	15.00:25.00	15.97:20.96	20.24
spe-RFAC1	7500	6750:8250	7801:8250	7832
spe-RTSEN	0.020	0.010:0.030	0.010:0.016	0.010

\*YRTFAC es un vector que se calibró con el mismo valor en sus cuatro componentes.

## **CAPÍTULO V – CALIBRACIÓN Y VALIDACIÓN DEL MODELO CROPGRO-SOYBEAN**

### **5.1 Introducción**

El proceso de calibración es central para la correcta utilización de modelos de simulación. Este proceso consiste en realizar simulaciones de un entorno conocido y según una evaluación de las salidas del modelo cambiar los parámetros de entrada para que el modelo represente de mejor manera la situación observada. A partir de esto surgen varios interrogantes incluidos: qué parámetros considerar para la calibración, cuántos parámetros estimar y, debido a que los modelos de sistemas suelen tener múltiples salidas, la forma de tener en cuenta múltiples variables de salida (Wallach *et al.*, 2019).

Además, un factor importante en el modelado de cultivos es que los modelos contienen parámetros dependientes del genotipo, que deben estimarse para cada genotipo que se simule (Casadebaig *et al.*, 2020).

La capacidad relativa de los modelos existentes y la credibilidad de sus resultados está asociada primeramente a la disponibilidad de datos apropiados para la calibración del modelo y, por otro, a la posibilidad de adecuación de las representaciones de los procesos e interacciones del sistema agua-suelo-planta-atmósfera. Por tanto, toma considerable importancia, antes de adoptar cualquier modelo para aplicaciones agrícolas y medioambientales realizar un trabajo de validación exhaustivo de los modelos (Hernández *et al.*, 2009). Otra consideración preponderante a tener en cuenta es utilizar conjuntos de datos diferentes a los usados para el proceso de calibración a la hora de validar un modelo (Martinez Ruiz *et al.*, 2012).

La información obtenida sobre la sensibilidad de los parámetros en el Capítulo III actúa como un paso preliminar para la toma de decisiones al momento de elegir qué parámetros del modelo deben ser incluidos en cada proceso calibrado. Los ajustes realizados en el Capítulo IV permiten minimizar errores de los factores que se relacionan con el ambiente y, de esta manera, poder afrontar la calibración de los parámetros que identifican al cultivo propiamente dicho con menor incertidumbre respecto a cómo afectan directamente estos parámetros a las salidas del modelo. Los parámetros que identifican directamente al cultivo son los que forman los archivos de cultivar, ecotipo y especie. El primer objetivo de este capítulo es calibrar los parámetros de especie, ecotipo y cultivar que identifican al crecimiento y desarrollo de soja HaHB4 para que simule con el menor error posible fenología, balance hídrico, biomasa y rendimiento tanto en condiciones de déficit hídrico

como en condiciones de riego con datos de la campaña 2017-2018. El segundo objetivo es validar el desempeño del modelo con datos de la campaña 2018-2019.

## 5.2 Materiales y métodos

El enfoque planteado consiste en un tratamiento holístico de los parámetros de calibración, las funciones objetivo, las respuestas del modelo y los datos medidos, ya que potencialmente todas las decisiones involucradas en el proceso de calibración tienen un impacto en los resultados. Se definieron múltiples funciones objetivo como una forma de manejar múltiples respuestas simuladas en el procedimiento de calibración.

Es decir, en lugar de usar todos los datos juntos para la calibración, se realizó la calibración semiautomática en etapas (Romagnoli *et al.*, 2017). En cada etapa, solo se usó una variable de salida y solo se estimaron algunos parámetros. Una ventaja del procedimiento secuencial es que se ajusta una única variable de respuesta a los datos experimentales con pocos parámetros en cada paso, lo que evita problemas numéricos.

Una desventaja es que los parámetros que se ajustan a una respuesta a menudo afectan a otras respuestas, con la posibilidad de degradar el ajuste a las respuestas tratadas en pasos anteriores.

### 5.2.1 Vinculación de CROPGRO y OSTRICH

En este trabajo, se conecta CROPGRO con el software OSTRICH según las siglas de su nombre en inglés “*Optimization Software Toolkit for Research Involving Computational Heuristics*”. OSTRICH es un programa independiente que automatiza los procesos de calibración de un modelo numérico sin que el usuario tenga que escribir ningún software adicional. Se puede configurar para operar con CROPGRO completando las partes requeridas del archivo de entrada de OSTRICH y creando plantillas de los archivos de entrada del modelo de crecimiento de planta (Mattot, 2017). La vinculación de OSTRICH y CROPGRO está dirigida por un archivo de configuración (OSTRICH.config) que conecta con un archivo de ejecución (DSSAT.bat) y un conjunto de archivos con los formatos correspondientes al modelo de simulación de cultivos (CROPGRO.tpl). El archivo de configuración establece los algoritmos físicamente basados, las funciones objetivo, los parámetros de calibración y las restricciones que se quieran imponer. Los archivos de plantilla (*template files*) son copias de las entradas del modelo requeridas (representan a los archivos de entrada SBGRO047.CUL, SBGRO047.ECO y SBGRO047.SPE de CROPGRO) en los que los valores numéricos de los parámetros se reemplazan con nombres de parámetros únicos, definidos en la sección de parámetros de OSTRICH.config.

OSTRICH utiliza estos nombres de parámetros para realizar operaciones de "búsqueda y reemplazo" y convertir los archivos de plantilla en los archivos de entrada del modelo CROPGRO sintácticamente correctos que contienen la configuración de parámetros deseada para un paso determinado del proceso de calibración. Cada vez que finaliza una ejecución del modelo CROPGRO, OSTRICH analiza los archivos de salida de CROPGRO (evaluate.out, plantgro.out, et.out) para extraer información de la función objetivo. Este proceso itera hasta que el algoritmo de optimización alcanza el número máximo de evaluaciones del modelo o su criterio de parada. OSTRICH almacena una cantidad de resultados de optimización especificados por el usuario (es decir, el conjunto de parámetros, su valor de función objetivo correspondiente por iteración y las variables de salida simuladas para las iteraciones especificadas) en archivos de salida. El marco conceptual para el acople OSTRICH-CROPGRO se describe en la Figura 5.1.

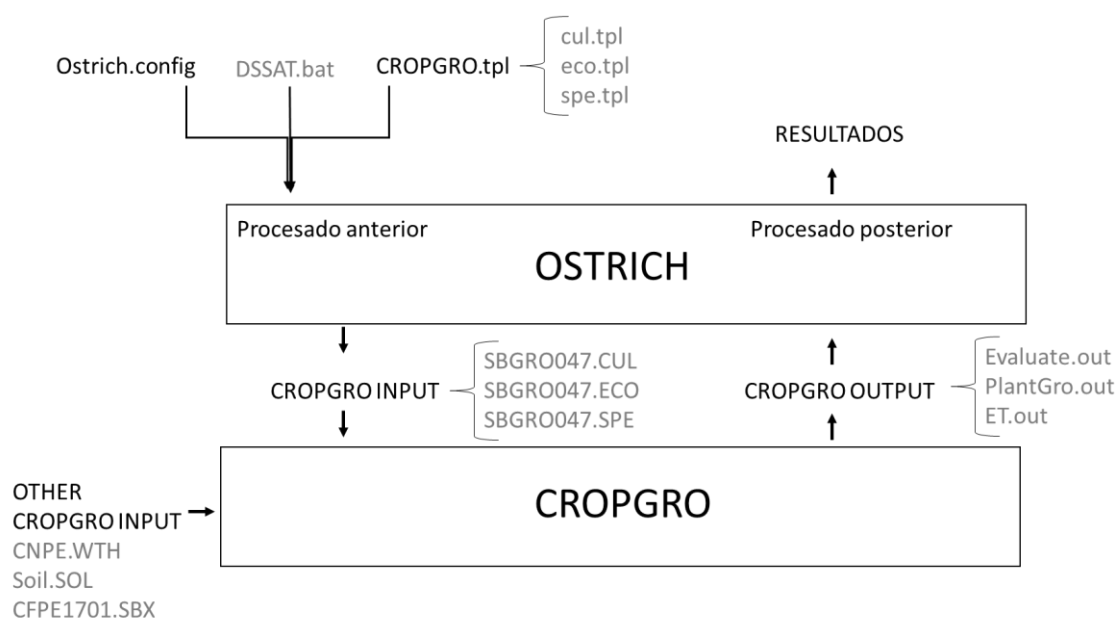


Figura 5.1. Acople de los modelos OSTRICH-CROPGRO.

### 5.2.2 Calibración multiobjetivo semiautomática OSTRICH-CROPGRO

La calibración del modelo es el proceso de estimar los valores de los parámetros para obtener una coincidencia entre el comportamiento del sistema observado y simulado. Eso requiere mediciones reales realizadas en el sistema, predicciones del modelo y un método para determinar los mejores parámetros. En esta tesis se definieron diferentes funciones objetivo como una forma de manejar múltiples respuestas simuladas en el procedimiento de calibración.

El análisis de sensibilidad proporcionó información importante que indica la relación que tienen los parámetros del modelo con las variables a simular de fenología, balance hídrico

del suelo, biomasa aérea y rendimiento en granos. Esto permitió definir rankings de parámetros sensibles y rangos iniciales de variación de parámetros por variable de salida, siendo éste el punto de partida de la etapa de calibración. En esta tesis se modifican los procedimientos básicos para la calibración automática considerando un proceso de calibración semiautomático, donde pasos sucesivos incorporan información sobre la dinámica suelo-planta-atmósfera en la estimación de parámetros. Como se mencionó anteriormente, el análisis basado en mediciones fisiológicas realizadas a campo mostró que la soja HaHB4 superó el rendimiento del genotipo W82 en condiciones de déficit hídrico, sin penalización de rendimiento en condiciones de buena disponibilidad de agua. Dado el rendimiento de campo de este genotipo transgénico de segunda generación, no se restringió el proceso de calibración a condiciones óptimas (Jones *et al.*, 2011; Jha *et al.*, 2021), sino que se recurrió a la calibración simultánea de dos ambientes diferentes, déficit hídrico y tratamientos con riego abundante durante la temporada de cultivo 2017-18. Los coeficientes genéticos de W82 en la base de datos de genotipos CSM-DSSAT se eligieron como valores base.

La implementación siguió un enfoque sistemático basado en una secuencia de calibración de cuatro pasos. Cada paso se llevó a cabo para calibrar variables de salida diferentes. A partir del segundo paso se verificaron las variables calibradas en los pasos anteriores. La secuencia de calibración de las variables de salida fue la siguiente: el desarrollo fenológico en CROPGRO es independiente del crecimiento de la planta (Jones *et al.*, 2011), por lo que el primer paso fue la estimación de los parámetros de desarrollo fenológico. Dado que el contenido de agua del suelo simulado o la evapotranspiración influyen directamente en el crecimiento y la producción de la biomasa previstos (Boote *et al.*, 2008), los parámetros relacionados con el balance de agua del suelo se calibraron en un segundo paso. El tercer paso de la calibración involucró la estimación de parámetros que afectan a la biomasa aérea, y finalmente fueron ajustados los parámetros relacionados con el rendimiento en granos.

Para incorporar parámetros sensibles en el procedimiento de calibración para cada variable de salida, se propuso un esquema de iteración. De esta manera, cada paso de la calibración consta de tres a cinco iteraciones según el siguiente orden:

- (a-)** incluir los parámetros de cultivar y ecotipo sensibles a la variable de salida considerada, siempre que no se hayan utilizado en un paso anterior;
- (b-)** incluir parámetros de cultivar y ecotipo sensibles a la variable de salida considerada, y ya utilizados en pasos anteriores;
- (c-)** agregar parámetros de especie sensibles a la variable de salida considerada que no sean sensibles a las variables ya calibradas;

**(d-)** agregar parámetros de especie sensibles a variables de salida previamente calibradas pero no utilizados;

**(e-)** agregar parámetros de especie sensibles a la variable de salida considerada, y ya utilizados en pasos anteriores.

Los parámetros de especie en las iteraciones (c-), (d-) y (e-) se evalúan uno a la vez y se incluyen solo si mejoran el ajuste del modelo.

Una iteración consistió en 3000 simulaciones de modelos con conjuntos de parámetros muestreados aleatoriamente dentro del intervalo especificado según lo recomendado por los creadores del modelo en Jones *et al.* (2011). En cada iteración, los rangos de los intervalos de los parámetros se pueden reducir evaluando la función objetivo y el espacio de soluciones. Este procedimiento, que se nombra como subiteración, se realiza una sola vez para cada parámetro, y los nuevos rangos más estrechos se mantienen durante todo el proceso. En cada iteración subsiguiente, el intervalo se centra en el valor del parámetro que minimiza la función objetivo en la iteración anterior. Las diferentes combinaciones de los valores de los parámetros se muestrearon utilizando un esquema Monte Carlo implementado como preprocesamiento en el modelo acoplado OSTRICH-CROPGRO (Figura 5.1). Se supuso que las distribuciones de los parámetros eran independientes y uniformemente distribuidas.

### 5.2.3 Funciones objetivo y estadísticas para evaluar las simulaciones

El criterio para determinar el mejor conjunto de parámetros en cada iteración fue minimizar la función objetivo definida como posprocesamiento en el modelo acoplado OSTRICH-CROPGRO. La función objetivo (FO) evalúa las diferencias entre las variables simuladas y observadas para cada conjunto de parámetros. Se definieron funciones objetivo dependiendo de la variable de salida considerada (es decir, correspondientes al paso considerado del procedimiento de calibración):

$$FOA = \sum_{i=1}^n (P_i |S_i - O_i|) \quad (5.1)$$

La función objetivo de diferencias absolutas (FOA) se utilizó para fenología.

$$FOR = \sum_{i=1}^n (P_i |S_i - O_i|/O_i) \quad (5.2)$$

La función objetivo de diferencias relativas (FOR) se usó para el balance de agua del suelo, la biomasa y el rendimiento en granos. Donde  $i$  es cada una de las  $n$  mediciones,  $S$  y  $O$  son las variables simuladas y observadas y  $P$  es un factor de ponderación.

La representación de los procesos de calibración se midió utilizando la raíz del error cuadrático medio (RMSE por sus siglas en ingles) que es la estadística más utilizada para evaluar los modelos de este tipo y el error de sesgo medio (MBE por sus siglas en ingles) que permite ver si el modelo está subestimando o sobreestimando las variables evaluadas.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n}} \quad (5.3)$$

$$MBE = \frac{\sum_{i=1}^n (S_i - O_i)}{n} \quad (5.4)$$

Donde  $i$  es cada una de las  $n$  mediciones,  $S$  y  $O$  son los valores simulados y observados.

#### 5.2.4 Validación del modelo CROPGRO

El proceso de validación se realizó utilizando el conjunto de datos del experimento de campo realizado durante la campaña de cultivo 2018-2019. Por un lado, el fenómeno ENOS (El Niño – Oscilación del Sur) tuvo un fuerte efecto en las precipitaciones de la campaña 2017-2018 usada para calibración que se caracterizó por condiciones de la fase La Niña débil lo cual afecta reduciendo las precipitaciones casi en la totalidad del territorio argentino, por el lado contrario, el efecto del fenómeno ENOS en la campaña 2018-2019 fue muy cercano a llegar a la fase El niño, lo cual provocó un efecto opuesto con aumento de precipitaciones en el territorio nacional (Servicio Meteorológico Nacional, 2018 y 2019). En particular en la zona de Pergamino desde diciembre de 2018 a abril de 2019, se observaron episodios de precipitaciones superiores a lo normal, la precipitación total durante este ciclo de cultivo fue casi cuatro veces la cantidad de precipitación durante la temporada de cultivo 2017-2018 para los mismos meses. Por esta razón, el contenido inicial de agua del suelo y, por lo tanto, la condición de humedad del suelo antecedente para calcular la escorrentía superficial en la etapa de validación se fijó en capacidad de campo, como así también el contenido inicial de agua en la simulación.

Teniendo en cuenta la equifinalidad, es decir, cuando varias combinaciones diferentes de valores de parámetros pueden dar resultados similares, la calibración no conduce necesariamente a valores de parámetros únicos (Beven y Freer, 2001). Por esta razón, se realizó la validación con los diez mejores conjuntos de parámetros obtenidos de la

calibración. Los resultados de la validación se evaluaron mediante los valores estadísticos: RMSE y MBE.

### 5.3 Resultados

Como se mencionó en el apartado 5.2.2, el proceso de calibración involucra cuatro pasos. Cada paso se llevó a cabo para calibrar una variable de salida diferente. A partir del segundo paso se verificaron las variables calibradas en los pasos anteriores. Debido a que el desempeño del modelo depende en gran medida del desarrollo del cultivo, primero se estimaron los parámetros relacionados con la fenología. El segundo paso se centró en calibrar los parámetros que afectan el balance hídrico del suelo. Las dos últimas variables utilizadas para calibrar el modelo fueron biomasa aérea y rendimiento de grano, en ese orden.

#### 5.3.1 Calibración de fenología

La predicción correcta de la fenología de la planta es esencial para el buen funcionamiento de los modelos de cultivo. Se aplicó la siguiente función objetivo para calibrar el tiempo de las principales etapas de desarrollo:

$$FOA_{fen} = \sum_{i=1,3,5,7}^4 |Ri_S - Ri_O|_{d\acute{e}ficit\ h\acute{d}rico} + \sum_{i=1,3,5,7}^4 |Ri_S - Ri_O|_{riego} \quad (5.5)$$

donde R1, R3, R5 y R7 representan los días de inicio de floración, inicio de formación de vainas, inicio de llenado de semillas y madurez fisiológica, respectivamente; los subíndices s y o indican variables simuladas y observadas; y como está indicado con los subíndices se consideraron los ambientes con déficit hídrico y con riego.

En este paso en total se consideraron nueve parámetros de entrada de los archivos de cultivar, ecotipo y especie. Los cuales habían sido identificados como sensibles en el Capítulo III de la presente tesis.

Se consideraron siete parámetros de entrada de los archivos de cultivar y ecotipo en una primera iteración, y dos parámetros de entrada del archivo de especie se consideraron en una segunda iteración. La primera iteración (i) se compuso de dos subiteraciones (i.1 e i.2). Los nombres de los parámetros, los intervalos de rango para cada iteración y los valores ajustados se enumeran en la Tabla 5.1. Los intervalos utilizados para la subiteración i.1, que están enumerados en la segunda columna de la Tabla 5.1, se determinaron en función de los resultados del análisis de sensibilidad y la información relacionada con el grupo de madurez del cultivar W82.

La subiteración i.1, que consistió en 3000 simulaciones, resultó en un valor de FOA<sub>fen</sub> de 6 días (RMSE=1,23 días y MBE=0 días). Para la subiteración i.2, los rangos se estrecharon y se centraron en el mejor conjunto de parámetros obtenidos en la subiteración i.1 (tercera columna de la Tabla 5.1). Después de 3000 simulaciones, se obtuvo un valor de función objetivo menor (FOA<sub>fen</sub>=3 días, RMSE=1,06 días y MBE=-0,38 días). Este error de 3 días se acumuló en la etapa R7 del tratamiento de déficit hídrico (véanse los resultados de la subiteración i.2, bajo déficit hídrico, en la Tabla 5.2).

Tabla 5.1. Paso de calibración de fenología. Las letras entre paréntesis hacen referencia al esquema de iteraciones mencionado en la sección 5.2.2.

Parámetros	Intervalos utilizados			Valores ajustados
	Subiteración i.1(a-)	Subiteración i.2(a-)	Iteración ii (c-)	
cul-CSDL	12,00:13,20	12,17:12,77	12,17:12,77	12,53
cul-PPSEN	0,129:0,213	0,142:0,184	0,142:0,184	0,163
cul-EM-FL	17,20:21,56	18,37:20,55	18,37:20,55	19,51
cul-FL-SH	7,43:10,30	7,43:8,23	7,43:8,23	7,51
cul-FL-SD	11,74:16,10	11,74:13,37	11,74:13,37	12,59
cul-SD-PM	28,74:34,29	32,25:34,29	32,25:34,29	32,47
eco-R1PPO	0,160:0,350	0,271:0,350	0,271:0,350	0,283
spe-TB r2	-	-	-15,00:9,00	-1,65
spe-TO1r2	-	-	21,40:25,40	25,20

Para mejorar la simulación de fenología para R7, se incorporaron dos parámetros de especie relacionados con la temperatura en las últimas etapas reproductivas (TB r2 y TO1 r2) en la iteración ii (sus rangos se enumeran en la cuarta columna de la Tabla 5.1). Los valores de los parámetros ajustados se obtuvieron después de 3000 simulaciones y dieron como resultado una FOA<sub>fen</sub> de 3 días (RMSE=0,79 días y MBE=0,12 días). Nuevamente se obtuvo un error de 3 días para la etapa R7, aunque más equilibrada, -1 día para déficit hídrico y +2 días para tratamiento regado. En cuanto a RMSE y MBE, ambos disminuyeron de 1,06 a 0,79 días y de -0,38 a 0,12 días, respectivamente. Se obtuvo una coincidencia perfecta entre los resultados simulados y observados para las etapas R1, R3 y R5 en condiciones de déficit hídrico y riego. La Tabla 5.2 muestra los resultados de la calibración de fenología para la subiteración i.2 y la iteración ii.

Tabla 5.2. Resultados de la calibración fenológica expresado en DDS. FOA<sub>fen</sub>=3 días, RMSE=1,061 días y MBE=-0,375 días para la subiteración i.2; FOA<sub>fen</sub>=3 días, RMSE=0,79 días y MBE=0,12 días para la iteración ii.

Estado fenológico	Déficit hídrico			Riego		
	Obs.	Subiteración i.2	Iteración ii	Obs.	Subiteración i.2	Iteración ii
R1	42	42	42	41	41	41
R3	56	56	56	54	54	54
R5	66	66	66	63	63	63
R7	103	100	102	103	103	105

### 5.3.2 Calibración de balance hídrico del suelo

La simulación precisa del balance hídrico del suelo en el marco del sistema suelo-planta-atmósfera es clave para predecir el crecimiento y el rendimiento de la biomasa. El balance de agua del suelo en la zona radicular se expresa como

$$P + R - \Delta CS = E + D + ET \quad (5.6)$$

donde P es la precipitación, R es el agua de riego,  $\Delta CS$  es el cambio en el contenido de agua del suelo (medido en el experimento como la diferencia de contenido de agua en el perfil de suelo entre dos mediciones consecutivas), E es la escorrentía superficial, D es el drenaje profundo por debajo del perfil del suelo y ET es la evapotranspiración.

La escorrentía superficial (E) se calculó utilizando el método del número de curva del Servicio de Conservación de Suelos. Los cultivos de verano estuvieron expuestos a una severa sequía en 2017-18 causada por la fase La Niña del fenómeno ENSO, que trajo lluvias por debajo de lo normal junto con episodios de temperaturas por encima del óptimo. Por esa razón, se adoptó un valor de número de curva de condición de humedad del suelo (CN1) antecedente seco para calcular la escorrentía directa en el proceso de calibración. Con base en el valor promedio del número de curva de la condición de humedad del suelo antecedente para las tierras agrícolas cultivadas de la serie de suelos Pergamino con pendiente inferior a 0,2% (CN2 = 78, Darder *et al.*, 2018), el valor del número de curva estimado fue CN1 = 60 (Ward *et al.*, 2015).

La evapotranspiración (ET) y el drenaje en la parte inferior del perfil del suelo (D) son los principales términos sumideros del sistema suelo-planta-atmósfera que afectan el estado del agua del suelo. La falta de lluvias significativas durante la temporada de calibración 2017-18, minimizó el drenaje profundo. Esto nos permitió calibrar el balance hídrico del suelo sin tener en cuenta la percolación y, por lo tanto, considerando parámetros que solo son sensibles al proceso de evapotranspiración.

Se consideró la siguiente función objetivo para la calibración del balance hídrico del suelo:

$$FOR_{bh} = \frac{1}{8} \left[ \left( \frac{|S-O|}{0} \right)_{23 \text{ a } 37 | dh} + \left( \frac{|S-O|}{0} \right)_{38 \text{ a } 51 | dh} + \left( \frac{|S-O|}{0} \right)_{52 \text{ a } 64 | dh} + \left( \frac{|S-O|}{0} \right)_{65 \text{ a } 83 | dh} \right. \\ \left. + \left( \frac{|S-O|}{0} \right)_{23 \text{ a } 37 | r} + \left( \frac{|S-O|}{0} \right)_{38 \text{ a } 51 | r} + \left( \frac{|S-O|}{0} \right)_{52 \text{ a } 64 | r} + \left( \frac{|S-O|}{0} \right)_{65 \text{ a } 83 | r} \right] \quad (5.7)$$

donde S representa la suma de las variables simuladas ( $S = E+D+ET$ ) y O la suma de las variables observadas ( $O = P + R - \Delta CS$ ); los números de subíndice indican el período de tiempo expresado en DDS; y los subíndices *dh* y *r* refieren los tratamientos déficit hídrico y regado.

Se consideraron siete parámetros de entrada de los archivos de cultivar y ecotipo para calibrar el balance hídrico del suelo. De estos siete parámetros, uno es sensible exclusivamente al balance hídrico (SIZLF), y los seis parámetros restantes son sensibles tanto al balance hídrico como a la fenología (CSDL, PPSEN, EM-FL, FL-SD, SD-PM y R1PPO). Como la calibración del balance hídrico del suelo es el segundo paso del proceso de calibración, a partir de este paso se verifican las variables calibradas en el paso anterior. Por lo tanto, la calibración de este paso consistió en una primera iteración para ajustar solo el parámetro SIZLF (i), una segunda iteración para ajustar el SIZLF más seis parámetros adicionales que son sensibles al balance hídrico y la fenología del suelo (ii), y un proceso de verificación de fenología. Los intervalos de rango para cada iteración y los valores de los parámetros ajustados y verificados se enumeran en la Tabla 5.3. Los valores ajustados corresponden al conjunto de parámetros que minimiza la función objetivo del balance hídrico del suelo. Los valores verificados corresponden al conjunto de parámetros que proporciona resultados fenológicos aceptables.

La primera iteración (i) se compuso de dos subiteraciones (i.1 e i.2). La subiteración i.1, que consistió en 3000 simulaciones con un parámetro de entrada (SIZLF) del archivo de cultivar, resultando en un valor de  $FOR_{bh}$  de 0,173 (RMSE=23,64 mm y MBE=-15,12 mm). Como los valores más bajos de la función objetivo para la subiteración i.1 se agruparon en la mitad superior del rango de variación del parámetro SIZLF, se eligió este intervalo reducido para la subiteración i.2. Después de 3000 simulaciones, se obtuvo un valor de  $FOR_{bh}$  mínimo de 0,173 con una ligera mejora de las otras métricas: RMSE=23,63 mm días y MBE=-15,11 mm.

La segunda iteración (ii) permitió que los siete parámetros sensibles al balance hídrico del suelo variaran durante otras 3000 simulaciones. Esta iteración dio como resultado mejores valores del balance hídrico del suelo, minimizando la función objetivo, es decir,  $FOR_{bh}=0,167$ , con RMSE=23,63 mm y MBE=-14,57 mm. Cuando se revisaron las etapas

fenológicas para los parámetros ajustados por el balance hídrico del suelo, la función objetivo de la fenología no arrojó resultados satisfactorios ( $FOA_{fen} = 39$  días).

La estrategia para verificar la fenología fue realizar una búsqueda entre aquellos conjuntos de parámetros de la iteración ii con valores bajos de  $FOR_{bh}$  para el balance hídrico del suelo que, además, cumplan con dos restricciones para la fenología: un valor de  $FOA_{fen}$  menor a 10 días y no más de un día de diferencia entre los simulados y los observados para cada etapa R1, R3 y R5. El conjunto de parámetros enumerados en la sexta columna de la Tabla 5.3 verificó estas condiciones con  $FOR_{bh}=0,173$  ( $RMSE=23,63$  mm y  $MBE=-15,10$  mm) para el balance hídrico del suelo y  $FOA_{fen}=4$  días ( $RMSE=1,12$  días y  $MBE=0,25$  días) para fenología. Estos resultados se presentan en la Tabla 5.4.

Tabla 5.3. Paso de calibración de balance hídrico del suelo. Las letras entre paréntesis hacen referencia al esquema de iteraciones mencionado en la sección 5.2.2.

Parámetros	Intervalos utilizados			Valores ajustados	Valores verificados
	Subiteración i.1(a-)	Subiteración i.2(a-)	Iteración ii(b-)		
cul-CSDL	-	-	12,23:12,83	12,31	12,51
cul-PPSEN	-	-	0,142:0,184	0,153	0,150
cul-EM-FL	-	-	18,41:20,59	20,35	19,97
cul-FL-SD	-	-	11,81:13,44	13,18	12,73
cul-SD-PM	-	-	31,45:33,49	32,66	32,66
cul-SIZLF	137,0:240,0	182,5:240,0	182,5:240,0	237,5	239,9
eco-R1PPO	-	-	0,244:0,323	0,272	0,296

Tabla 5.4. Resultados de la calibración de balance hídrico y su verificación. Se presentan en mm los datos de balance hídrico y en DDS los datos de fenología. Se obtuvo  $FOR_{bh}=0,173$ ,  $RMSE=23,63$  mm y  $MBE=-15,10$  mm para el balance hídrico; y  $FOA_{fen}=4$  días,  $RMSE=1,12$  días y  $MBE=0,25$  días para la fenología.

DDS	Balance hídrico del suelo*				Estado Fenológico	Fenología			
	Déficit hídrico		Regado			Déficit hídrico		Regado	
	Obs.	Sim.	Obs.	Sim.		Obs.	Sim.	Obs.	Sim.
23 a 37	68,9	44,7	67,7	56,6	R1	42	42	41	41
38 a 51	63,4	55,7	110,0	87,5	R3	56	56	54	54
52 a 64	37,6	37,1	123,3	67,1	R5	66	66	63	63
65 a 83	67,1	64,3	140,9	145,2	R7	103	102	103	106

\*Las variables observadas de balance hídrico son ( $P + R - \Delta CS$ ) y las simuladas ( $E+D+ET$ )

El contenido de agua del suelo (CS) es uno de los factores edáficos más importantes, especialmente en zonas agrícolas, y es una variable hidrológica clave. Para corroborar la veracidad de la calibración del balance de agua del suelo; el CS simulado comparado con el observado presentado en capas de 30 cm hasta 1,80 m de profundidad, para ambas condiciones, déficit hídrico y riego, se muestra en la Figura 5.2. Como se muestra en la Figura, los valores de CS simulados coinciden con buena precisión con los valores observados.

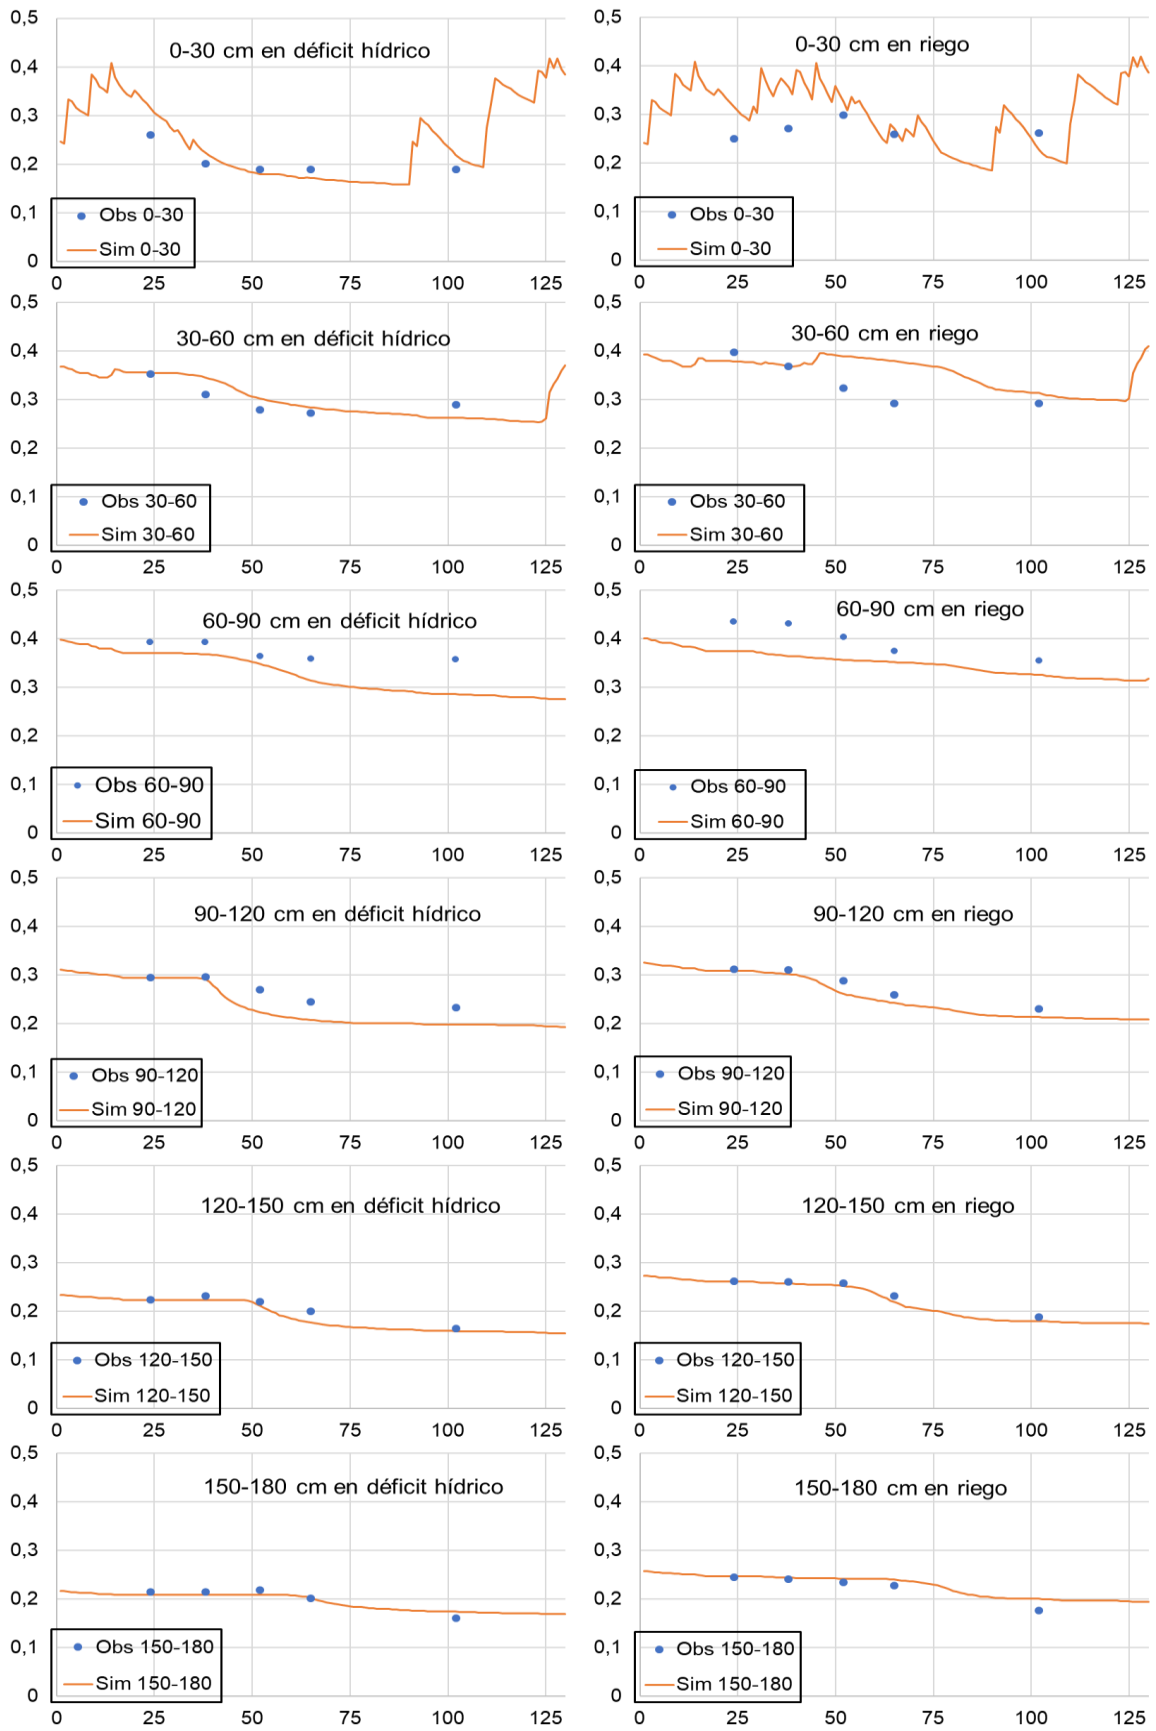


Figura 5.2. Contenido de agua en el suelo ( $\text{cm}^3$  agua /  $\text{cm}^3$  suelo) en función del tiempo (en DDS). Los valores están representados por separado cada 30 cm y según el tratamiento, los puntos indican los valores observados y las líneas los simulados.

### 5.3.3 Calibración de biomasa aérea

La biomasa es un parámetro agronómico importante que se usa con frecuencia para indicar el estado de crecimiento de los cultivos y los efectos de las prácticas de manejo. Para la calibración de biomasa se consideró la siguiente función objetivo:

$$FOR_{bio} = \frac{1}{12} \left[ \left( \frac{|S-O|}{O} \right)_{39|dh} + \left( \frac{|S-O|}{O} \right)_{56|dh} + \left( \frac{|S-O|}{O} \right)_{66|dh} + \left( \frac{|S-O|}{O} \right)_{39|r} + \left( \frac{|S-O|}{O} \right)_{56|r} + \left( \frac{|S-O|}{O} \right)_{66|r} \right] + \frac{1}{4} \left[ \left( \frac{|S-O|}{O} \right)_{108|dh} + \left( \frac{|S-O|}{O} \right)_{108|r} \right] \quad (5.8)$$

donde S representa la biomasa simulada y O la biomasa observada; los números de subíndice indican la fecha expresada en DDS; y los subíndices *dh* y *r* denotan los tratamientos de déficit hídrico y riego. La ecuación 5.8 se propone como un polinomio ponderado, donde cada término se ve afectado por un coeficiente de peso. Dado que la biomasa en madurez es el factor que tiene una relación más directa con el rendimiento en granos y con la materia orgánica remanente poscosecha, se asignó un coeficiente de peso más alto para los estos valores, de manera que el 50% del peso de la función objetivo se deba a la biomasa en madurez (coeficiente de peso vale 1/4 para DDS = 108), para todos los demás momentos medidos el coeficiente de peso fue menor de manera que las otras mediciones juntas sumen el otro 50% del factor de peso (1/12 para DDS = 39, 56, 66).

Se consideraron catorce parámetros de entrada de archivos de cultivar, ecotipo y especie para calibrar biomasa. Once parámetros pertenecen a los archivos de cultivar y ecotipo y tres al archivo de especie. De los once parámetros pertenecientes a los archivos de cultivar y ecotipo, tres parámetros (LFMAX, SLAVR y PODUR) son sensibles exclusivamente a biomasa, mientras que los ocho restantes son sensibles a biomasa y, además, a fenología y/o balance hídrico del suelo (CSDL, PPSN, EM-FL, FL-SH, FL-SD, SD-PM, SIZLF y R1PPO). De los tres parámetros de especie, dos de ellos son sensibles solo a biomasa (FNPGL1 y FNPGL2), y el tercero además es sensible a la fenología y al balance hídrico del suelo (RWUMX). La parte de la calibración de biomasa que involucró parámetros de cultivar y ecotipo comprendió dos iteraciones (iteraciones i y ii). La inclusión de parámetros de especie incluyó dos iteraciones adicionales (iteraciones iii y iv).

La primera iteración (i), que consistió en 3000 simulaciones, resultó en un valor de  $FOR_{bio}=0,409$  (RMSE=3897 kg/ha y MBE=-2950 kg/ha). La iteración ii resultó en un mejor desempeño del modelo, alcanzando un  $FOR_{bio}=0,372$  (RMSE=3703 kg/ha y MBE=-2303 kg/ha). La iteración iii, que incluyó dos parámetros de especie, resultó en una función objetivo igual a la de la iteración anterior ( $FOR_{bio}=0,372$ ; RMSE=3990 kg/ha y MBE=-2693

kg/ha), no obstante, muchos resultados llegaban a esos valores de  $FOR_{bio}$ . Con la inclusión de tres parámetros de especie, la iteración iv, arrojó el mejor resultado para la función objetivo de biomasa, alcanzando un  $FOR_{bio}=0,362$  (RMSE=3818 kg/ha y MBE=-2637 kg/ha). Los intervalos de rango para cada iteración y los valores de los parámetros ajustados se muestran en la Tabla 5.5. Una vez que se calibró biomasa, se verificaron las variables de salida previamente calibradas para los parámetros ajustados. El balance hídrico del suelo alcanzó buenos resultados para los parámetros ajustados en la Tabla 5.5, pero el ajuste de etapas fenológicas no fue aceptable ( $FOA_{fen}=23$  días).

La fenología se verificó siguiendo la misma estrategia que para el balance hídrico del suelo (imponiendo dos restricciones, un valor de  $FOA_{fen}$  inferior a 10 días y no más de un día de diferencia entre los valores simulados y observados para cada etapa R1, R3 y R5). El conjunto de parámetros de la cuarta iteración que verificó estas condiciones se lista en la séptima columna de la Tabla 5.5. Su desempeño fue  $FOR_{bio}=0,372$ , RMSE=3861 kg/ha y MBE=-2659 kg/ha para biomasa;  $FOR_{bh}=0,200$ , RMSE=25,03 mm y MBE=-16,71 mm para balance hídrico del suelo; y  $FOA_{fen}=9$  días, RMSE=1,45 días y MBE=0,875 días para fenología. Estos resultados se presentan en la Tabla 5.6.

Tabla 5.5. Paso de calibración de biomasa. Las letras entre paréntesis hacen referencia al esquema de iteraciones mencionado en la sección 5.2.2.

Parámetros	Iteración i (a)	Intervalos utilizados			Valor ajustado	Valor verificado
		Iteración ii (b)	Iteración iii (c)	Iteración iv (d)		
cul-CSDL	-	12,24:12,84	12,24:12,84	12,24:12,84	12,34	12,52
cul-PPSEN	-	0,150:0,193	0,150:0,193	0,150:0,193	0,174	0,188
cul-EM-FL	-	18,11:20,29	18,11:20,29	18,11:20,29	19,04	18,28
cul-FL-SH	-	7,11:7,91	7,11:7,91	7,11:7,91	7,58	7,71
cul-FL-SD	-	11,86:13,49	11,86:13,49	11,86:13,49	11,90	13,13
cul-SD-PM	-	32,15:34,18	32,15:34,18	32,15:34,18	34,06	33,09
cul-LFMAX	0,850:1,400	0,850:1,400	0,850:1,400	0,850:1,400	1,353	1,299
cul-SLAVR	282,5:425,0	282,5:425,0	282,5:425,0	282,5:425,0	381,5	313,7
cul-SIZLF	-	182,5:240,0	182,5:240,0	182,5:240,0	195,7	187,4
cul-PODUR	7,00:15,70	7,00:15,70	7,00:15,70	7,00:15,70	11,59	11,13
eco-R1PPO	-	0,220:0,299	0,220:0,299	0,220:0,299	0,265	0,262
spe-RWUMX	-	-	-	0,244:0,323	0,272	0,296
spe-FNPGL1	-	-	-5,00:7,00	-5,00:7,00	-4,57	0,94
spe-FNPGL2	-	-	11,20:24,00	11,20:24,00	15,06	14,23

Tabla 5.6. Resultados de calibración de biomasa expresados en kg/ha.  $FOR_{bio}=0,372$ ,  $RMSE=3861$  kg/ha y  $MBE=-2659$  kg/ha para la biomasa;  $FOR_{bh}=0,200$ ,  $RMSE=25,03$  mm y  $MBE=-16,71$  mm para el balance hídrico del suelo; y  $FOA_{fen}=9$  días,  $RMSE=1,45$  días y  $MBE=0,875$  días para fenología.

Biomasa					Balance hídrico*					Fenología				
Déficit hídrico		Riego			Déficit hídrico		Riego			Déficit hídrico		Riego		
DDS	Obs.	Sim.	Obs.	Sim.	DDS	Obs.	Sim.	Obs.	Sim.	Estado	Obs.	Sim.	Obs.	Sim.
39	868	1072	1686	734	23 a 37	68,9	36,2	67,7	54,0	R1	42	41	41	41
56	3162	1801	8918	3503	38 a 51	63,4	52,1	110,0	88,6	R3	56	57	54	54
66	4468	2227	13959	5380	52 a 64	37,6	38,6	123	67,2	R5	66	67	63	64
108	5794	2878	8904	8896	65 a 83	67,1	70,6	141	138,0	R7	103	105	103	106

\* Las variables observadas son  $(P + R - \Delta CS)$  y las simuladas  $(E + D + ET)$ .

### 5.3.4 Calibración de rendimiento

El rendimiento en el cultivo de soja, normalmente se expresa en kg de granos producidos por ha de cultivo. El rendimiento es un rasgo muy complejo determinado por múltiples factores, relacionados al genotipo, el medio ambiente, las prácticas de manejo que se apliquen y todas las interacciones posibles entre estos factores. Una predicción precisa del rendimiento de los cultivos contribuye a los procesos de toma de decisiones tanto a nivel de parcela como regional. Los formuladores de políticas públicas y privadas, confían en predicciones precisas para tomar decisiones oportunas de importación y exportación para fortalecer la seguridad alimentaria. Para denotar la interacción genotipo por ambiente, se propuso una función objetivo (Ecuación 5.9), donde cada término que representa un ambiente diferente, es decir, tratamientos con riego y déficit hídrico, se ve afectado por el mismo coeficiente de peso = 0,5.

$$FOR_{rend} = \frac{1}{2} \left[ \left( \frac{|S - O|}{O} \right)_{\text{déficit hídrico}} + \left( \frac{|S - O|}{O} \right)_{\text{riego}} \right] \quad (5.9)$$

donde S representa el rendimiento simulado, O el rendimiento observado, y los subíndices indican los dos tratamientos.

Se consideraron dieciocho parámetros de entrada de archivos de cultivar, ecotipo y especie para calibrar el rendimiento en granos. Trece parámetros pertenecen a los archivos de cultivar y ecotipo y cinco al archivo de especie. De los trece parámetros pertenecientes a los archivos de cultivar y ecotipo, dos parámetros (WTPSD y SFDUR) son sensibles exclusivamente al rendimiento de grano, y los once parámetros restantes (CSDL, PPSN, EM-FL, FL-SH, FL-SD, SD-PM, LFMAX, SLAVR, SIZLF, PODUR y R1PPO) son sensibles al rendimiento de grano más biomasa, balance hídrico del suelo y/o fenología. De los cinco parámetros de especie, solo TO1veg no se utilizó en los pasos anteriores y los otros cuatro

se consideraron para variables previamente calibradas (TB r2, RWUMX, FNPGL1 y FNPGL2).

El paso de calibración del rendimiento de grano que involucra parámetros de cultivar y ecotipo consistió en dos iteraciones (i y ii). La inclusión de parámetros de especie incluyó dos iteraciones adicionales (iii y iv). Cuando entre los sets de parámetros que dan los mejores resultados de la función objetivo surge que para un parámetro en particular, todos los valores de ese parámetro forman parte de un subintervalo marcadamente menor al intervalo que dio origen a esa iteración, se propone una segunda subiteración reduciendo el intervalo de variación de dicho parámetro. Este escenario ocurrió durante este paso para la segunda y cuarta iteración. Por lo tanto, la iteración ii se compone de las subiteraciones ii.1 y ii.2; y la iteración iv está compuesta por las subiteraciones iv.1 y iv.2; presentando las subiteraciones ii.2 y iv.2 solo una reducción de los intervalos en esos parámetros correspondientes en comparación con ii.1 y iv.1.

La Tabla 5.7 muestra los parámetros considerados para la calibración del rendimiento de grano, sus rangos de variación por iteración, los valores de los parámetros ajustados y los valores resultantes de la verificación de las variables de salida previamente calibradas. La iteración i resultó en un valor  $FOR_{rend}$  de 0,329 (RMSE=899 kg/ha y MBE=-105 kg/ha). La subiteración ii.1 mejoró el ajuste del modelo alcanzando un valor  $FOR_{rend}$  de 0,247 (RMSE=725,6 kg/ha y MBE=-372 kg/ha). Como se explica anteriormente, los intervalos de rango de los parámetros LFMAX, SLAVR y PODUR se estrecharon, dando resultados de la iteración ii.2. Esta estrategia mejoró la precisión del modelo (es decir, una desviación estándar más baja de los 3000 valores de la función objetivo) y resultó en un  $FOR_{rend}=0,250$  (RMSE=725 kg/ha y MBE=-343 kg/ha). La iteración iii, que incluía un parámetro de especie (TO1veg), mejoró el valor de la función objetivo de rendimiento después de 3000 simulaciones alcanzando un  $FOR_{rend}=0,217$  (RMSE=633 kg/ha y MBE=-311 kg/ha). Cuatro parámetros del archivo de especie (TB r2, RWUMX, FNPGL1 y FNPGL2) que se utilizaron en los pasos anteriores también se permitieron cambiar en la iteración iv. La subiteración iv.1, con dieciocho parámetros de entrada sensibles, dio como resultado un valor de  $FOR_{rend}$  de 0,157 (RMSE=468 kg/ha y MBE=-262 kg/ha). Para la subiteración iv.2, se mejoró la precisión del modelo al reducir los intervalos de rango de estos cuatro parámetros de entrada. Los valores ajustados (octava columna de la Tabla 5.7) dieron como resultado un valor de  $FOR_{rend}=0,158$  (RMSE=462 kg/ha y MBE=-401 kg/ha). Este conjunto de parámetros de valores ajustados proporcionó  $FOR_{bio}=0,699$  para biomasa;  $FOR_{bh}=0,406$  para el balance hídrico del suelo; y  $FOA_{fen}=46$  días para fenología (Ecuación 5.5), reduciendo la precisión del modelo para valores previamente calibrados. Por tal motivo, se realizó un proceso de verificación. La estrategia consistió en imponer restricciones entre

los conjuntos de parámetros de la iteración iv.2, con valores aceptables de  $FOR_{rend}$ , sobre la fenología y biomasa (un valor  $FOA_{fen}$  inferior a 10 días y no más de un día de diferencia entre los valores simulados y observados para cada etapa R1, R3 y R5 y un valor  $FOR_{bio}$ , inferior a 0,5). El conjunto de parámetros que verificó estas restricciones (novena columna de la Tabla 5.7), mejoró el desempeño general del modelo alcanzando  $FOR_{rend}=0,207$  (RMSE=636 kg/ha y MBE=-376 kg/ha) para el rendimiento de grano;  $FOR_{bio}=0,488$  (RMSE=4536 kg/ha y MBE=-3408 kg/ha) para biomasa;  $FOR_{bh}=0,247$  (RMSE=27,4 mm y MBE=-20,7 mm) para balance hídrico del suelo; y  $FOA_{fen}=9$  días (RMSE=1,62 días y MBE=0,63 días) para fenología. Los resultados de todo el proceso de calibración se presentan en la Tabla 5.8.

En la Tabla A5.12 del Anexo Capítulo V se encuentra la comparación entre los parámetros del cultivar Williams y los parámetros calibrados del cultivar Williams HaHB4.

Tabla 5.7. Paso de calibración de rendimiento. Las letras entre paréntesis hacen referencia al esquema de iteraciones mencionado en la sección 5.2.2.

Parámetros	Intervalos utilizados						Valores ajustados	Valores verificados
	Iteración i -(a)	Subiteración ii 1-(b)	Subiteración ii 2-(b)	Iteración iii -(d)	Subiteración iv 1-(e)	Subiteración iv 2-(e)		
cul-CSDL	-	12,22:12,82	12,22:12,82	12,22:12,82	12,22:12,82	12,22:12,82	12,68	12,41
cul-PPSEN	-	0,167:0,209	0,167:0,209	0,167:0,209	0,167:0,209	0,167:0,209	0,205	0,170
cul-EM-FL	-	17,19:19,37	17,19:19,37	17,19:19,37	17,19:19,37	17,19:19,37	19,29	18,05
cul-FL-SH	-	7,31:8,11	7,31:8,11	7,31:8,11	7,31:8,11	7,31:8,11	7,60	7,84
cul-FL-SD	-	12,32:13,95	12,32:13,95	12,32:13,95	12,32:13,95	12,32:13,95	12,70	12,67
cul-SD-PM	-	32,07:34,11	32,07:34,11	32,07:34,11	32,07:34,11	32,07:34,11	33,12	32,95
cul-LFMAX	-	0,850:1,400	1,162:1,400	1,162:1,400	1,162:1,400	1,162:1,400	1,374	1,282
cul-SLAVR	-	282,5:425,0	282,5:345,0	282,5:345,0	282,5:345,0	282,5:345,0	315,4	287,1
cul-SIZLF	-	161,2:213,7	161,2:213,7	161,2:213,7	161,2:213,7	161,2:213,7	188,8	191,5
cul-WTPSD	0,14:0,20	0,14:0,20	0,14:0,20	0,14:0,20	0,14:0,20	0,14:0,20	0,142	0,191
cul-SFDUR	19,0:28,0	19,0:28,0	19,0:28,0	19,0:28,0	19,0:28,0	19,0:28,0	19,91	22,17
cul-PODUR	-	7,00:15,70	8,95:13,30	8,95:13,30	8,95:13,30	8,95:13,30	10,28	12,37
eco-R1PPO	-	0,224:0,303	0,224:0,303	0,224:0,303	0,224:0,303	0,224:0,303	0,267	0,261
spe-TO1veg	-	-	-	27,0:33,0	27,0:33,0	27,0:33,0	29,57	32,36
spe-TBrep2	-	-	-	-	-15,0:9,0	-7,6:4,4	3,19	0,77
spe-RWUMX	-	-	-	-	0,003:0,040	0,003:0,022	0,004	0,011
spe-FNPGL1	-	-	-	-	-5,0:7,0	-5,0:2,5	-4,88	1,73
spe-FNPGL2	-	-	-	-	11,2:24,0	11,2:17,2	14,58	16,35

Tabla 5.8. Resultados de calibración de rendimiento de grano expresados en kg/ha.  $FOR_{rend}=0,207$ ,  $RMSE=636$  kg/ha y  $MBE=-376$  kg/ha para rendimiento de grano;  $FOR_{bio}=0,488$ ,  $RMSE=4536$  kg/ha y  $MBE=-3408$  kg/ha para biomasa;  $FOR_{bh}=0,247$ ,  $RMSE=27,4$  mm y  $MBE=-20,7$  mm para el balance hídrico del suelo; y  $FOA_{ren}=9$  días,  $RMSE=1,62$  días y  $MBE=0,63$  días para fenología.

Rendimiento				Biomasa					Balance hídrico*					Fenología				
Déficit hídrico		Riego		Déficit hídrico		Riego			Déficit hídrico		Riego			Déficit hídrico		Riego		
Obs.	Sim.	Obs.	Sim.	DDS	Obs.	Sim.	Obs.	Sim.	DDS	Obs.	Sim.	Obs.	Sim.	Estadio	Obs.	Sim.	Obs.	Sim.
2385	1496	3289	3427	39	868	589	1686	400	23 a 37	68,9	27,2	67,7	52,6	R1	42	41	41	41
				56	3162	1366	8918	2393	38 a 51	63,4	44,9	110,0	87,5	R3	56	56	54	55
				66	4468	1823	13959	4081	52 a 64	37,6	34,2	123,3	68,1	R5	66	65	63	63
				108	5794	2767	8904	7073	65 a 83	67,1	69,5	140,9	129,5	R7	103	106	103	106

\* Las variables observadas son  $(P + R - \Delta CS)$  y las simuladas  $(E+D+ET)$ .

La Tabla 5.9 resume los valores de la función objetivo obtenidos a partir de conjuntos de valores de parámetros ajustados y verificados para cada paso de calibración: fenología, balance de agua del suelo, biomasa y rendimiento.

Como ya se mencionó, el conjunto de valores de parámetros ajustados minimizó la función objetivo, y el conjunto de valores de parámetros verificados corroboró el ajuste de las variables de salida previamente calibradas.

Tabla 5.9. Valores obtenidos de las funciones objetivo de los sets de parámetros ajustados y verificados para cada paso de la calibración.

	Fenología	Balance hídrico	Biomasa	Rendimiento
	FOA <sub>ren</sub>	FOR <sub>bh</sub>	FOR <sub>bio</sub>	FOR <sub>rend</sub>
Valores ajustados en cada uno de los cuatro pasos	3 días	0,167	0,362	0,158
Valores verificados en el paso balance hídrico del suelo	4 días	0,173	-	-
Valores verificados en el paso de biomasa	9 días	0,200	0,372	-
Valores verificados en el paso de rendimiento	9 días	0,247	0,488	0,207

### 5.3.5 Validación del modelo

De los resultados de calibración se tomaron los diez mejores sets ajustados al final del proceso, si bien hay ciertas diferencias en los parámetros que conforman el set y en las variables de salida, los valores de RMSE y MBE en la calibración de estos diez sets no presentó grandes diferencias. Por este motivo a modo de comparación, para tener un punto de referencia entre la calibración y la validación, se incluyen entre paréntesis los valores de RMSE y MBE obtenidos en la etapa de calibración del primer set (línea 1 de la Tabla 5.10). Los resultados de la validación para el mejor set de la calibración se muestran en la Tabla 5.11, donde se muestran los valores simulados y observados para las diferentes etapas fenológicas, balance hídrico del suelo, biomasa y rendimiento de granos.

Tabla 5.10. Desempeño de la validación, para los 10 set de parámetros calibrados, expresado en RMSE y MBE para cada variable de salida: fenología, balance hídrico del suelo, biomasa y rendimiento. Los valores entre paréntesis corresponden a los resultados de calibración.

Nº de set	Fenología		Balance hídrico		Biomasa		Rendimiento	
	RMSE (días)	MBE (días)	RMSE (mm)	MBE (mm)	RMSE (kg/ha)	MBE (kg/ha)	RMSE (kg/ha)	MBE (kg/ha)
1	3,6 (1,6)	-3,3 (0,6)	29,5 (27,4)	20,1 (-20,7)	5116 (4536)	-4664 (-3408)	542 (636)	542 (-376)
2	3,6	-3,3	32,6	23,2	3456	-3018	888	888
3	4,6	-4,3	33,3	23,5	2800	-2313	1520	1520
4	4,9	-4,8	27,7	18,0	3575	-3116	666	666
5	3,7	-3,5	28,7	19,2	4867	-4389	965	965
6	3,7	-3,5	27,9	18,2	4105	-3679	107	107
7	4,2	-4,0	29,6	19,8	4901	-4435	928	928
8	3,9	-3,8	28,5	18,7	4832	-4373	941	941
9	4,8	-4,5	28,8	19,1	3886	-3438	362	362
10	4,8	-4,5	28,0	18,2	5175	-4719	626	626

Tabla 5.11. Resultados de la validación. RMSE=542 kg/ha y MBE=542 kg/ha para rendimiento de grano; RMSE=5116 kg/ha y MBE=-4664 kg/ha para biomasa; RMSE=29,5 mm y MBE=20,1 mm para balance hídrico; y RMSE=3,60 días y MBE=-3,30 días por fenología.

Fenología (DDS)			Balance hídrico (mm) *			Biomasa (kg/ha)			Rendimiento (kg/ha)	
Estado	Obs.	Sim.	DDS	Obs.	Sim.	DDS	Obs.	Sim.	Obs.	Sim.
R1	44	42	24 a 39	107,1	142,7	45	2270	1050	3455	3977
R3	59	56	40 a 49	88,6	71,7	63	9430	3741		
R5	70	64	50 a 71	308,3	330,7	72	6593	5214		
R7	111	109	72 a 93	118,2	164,2	99	12457	8009		
			94 a 118	42,2	55,6	111	11085	7561		

\* Las variables observadas son  $(P + R - \Delta CS)$  y las simuladas  $(E + D + ET)$

## 5.4 Discusión

Se realizó una calibración del cultivar HaHB4 simultánea de dos tratamientos hídricos diferentes con una metodología multiobjetivo, desarrollada en pasos para el ajuste de las variables de fenología, el balance hídrico, la biomasa y el rendimiento.

Se observó una buena precisión en la simulación del desarrollo de soja HaHB4 en todas las etapas fenológicas; los valores de RMSE fueron 1,62 días para la calibración y 3,60 días para la validación. El modelo de cultivo simuló un ciclo ligeramente más largo para la calibración que el observado en el experimento de campo, lo que se refleja en el valor positivo de MBE de 0,63 días. Por el contrario, el ciclo simulado para la validación fue más corto en comparación con los datos observados, con un valor de MBE negativo de 3,30 días. La diferencia entre los datos simulados y observados osciló entre 1 y 6 días, lo que concuerda bien con los resultados mostrados por Moura da Silva *et al.* (2021) (entre 1 y 5 días). Además, los resultados de esta tesis sugieren un mejor desempeño del modelo en comparación con otros estudios utilizando CROPGRO en la Región Pampeana Argentina, que reportaron valores de RMSE de 5,8 días (Casali *et al.*, 2021), 12,6 días (Caviglia *et al.*, 2013), 10 días (Mercau *et al.*, 2007), y 7,3 días (Monzon *et al.*, 2007).

El balance hídrico del suelo se simuló con éxito, alcanzando valores RMSE de 27,4 mm y 29,5 mm, para calibración y validación, respectivamente. El modelo de cultivo subestimó los componentes del balance de agua del suelo para la calibración, con un valor de MBE negativo de 20,7 mm. En contraste, los componentes del balance hídrico del suelo simulado para la validación fueron más altos que los observados en el experimento de campo, expresado por el valor MBE positivo de 20,1 mm.

Mercau *et al.* (2007), utilizando un modelo CROPGRO-*soybean* revisado (con una relación no lineal entre la transpiración real y potencial y la fotosíntesis bruta real y potencial, donde una constante empírica es considerada) bajo condiciones de oferta limitada en suelo con horizonte argílico obtuvo un valor RMSE de 26 mm. Shelia *et al.* (2018) simuló la dinámica del agua del suelo en un experimento de soja utilizando el modelo CROPGRO original y un modelo CROPGRO-HYDRUS acoplado. Los resultados obtenidos con el modelo acoplado fueron en general superiores a los simulados con el modelo original, reportando valores RMSE de 41,3 mm y 26,5 mm, respectivamente.

Mercau *et al.* (2007) evaluaron el desempeño de CROPGRO en cinco parcelas de la Región Pampeana Argentina, realizadas bajo prácticas agrícolas estándar y en condiciones de estrés hídrico. Con el modelo CROPGRO original, simuló biomasa con un RMSE del 39 % del valor medio medido. En un trabajo reciente (Moura da Silva *et al.*, 2021), se evaluó el desempeño de CROPGRO en un ambiente tropical, donde las lluvias se caracterizan por su irregularidad y alta intensidad, con altas temperaturas y fuerte radiación solar. Los

experimentos considerados se regaron con el máximo de agua requerida por el cultivo y, bajo esta única condición óptima de agua, alcanzaron un valor RMSE para biomasa del 20 %. En esta tesis, los valores de RMSE que se obtuvieron en la madurez fueron el 34 % de la biomasa media medida para la calibración y el 31 % para la validación. Estos resultados indicaron una simulación de biomasa aceptable, ya que, la metodología de calibración considera déficit hídrico y condiciones de riego adecuado. El rendimiento del grano de soja HaHB4 fue bien predicho por el modelo; los valores RMSE fueron 636 kg/ha (22 % de los valores promedio observados) para la calibración y 542 kg/ha (16 % de los valores promedio observados) para la validación. La precisión de las estimaciones de rendimiento de esta tesis concordó con trabajos anteriores. Monzón *et al.* (2007), modelando estrategias de manejo para soja en el sureste pampeano, reportaron un valor de RMSE de 475 kg/ha (25% de los valores promedio observados). Mercáu *et al.* (2007) obtuvieron RMSE de simulación de rendimiento de soja entre 531 kg/ha (16% de los valores promedio observados) y 1007 kg/ha (32% de los valores promedio observados). Caviglia *et al.* (2013), modelando los efectos a largo plazo de la intensificación de cultivos usando CROPGRO-soybean, reportaron un valor RMSE de 573 kg/ha. Casali *et al.* (2021) simularon diferentes escenarios climáticos y concentraciones de CO<sub>2</sub> en la región semiárida del Chaco con un valor de RMSE de 494 kg/ha (18% de los valores promedio observados). Moura da Silva *et al.* (2021) obtuvieron valores de RMSE entre el rendimiento de soja observado y previsto que oscilaron entre 94 y 625 kg/ha. En un trabajo más reciente, Perondi *et al.* (2022) optimizaron los parámetros del genotipo para evaluar la variabilidad del rendimiento de la soja en el sureste de los EE. UU. y obtuvieron valores de RMSE que oscilaron entre 423 y 589 kg/ha.

## **CAPÍTULO VI – APLICACIÓN DEL MODELO CROPGRO-SOYBEAN**

### **6.1 Introducción**

Una vez que un modelo ha sido calibrado y validado se puede utilizar con mayor certeza en la veracidad de los resultados de las simulaciones para una amplia variedad de aplicaciones, algunos ejemplos podrían ser plantear el desempeño del cultivo bajo distintas estrategias de manejo (Figarola *et al.*, 2020; Rodríguez *et al.*, 2021), estimar rendimientos potenciales según fecha de siembra y manejo de fertilización (Reinoso *et al.*, 2018), calcular los efectos de la aplicación de agricultura de precisión (Kemerer *et al.*, 2020), evaluar efectos de diferentes planteos de fertilización y estrategias de riego en el impacto ambiental (Malik *et al.*, 2019). En síntesis, las simulaciones, permiten en un instante estimar lo que sucedería en numerosas situaciones que llevarían mucho tiempo y costo operativo estudiar con experimentos realizados a campo.

En este capítulo se aplicó el modelo CROPGRO-soybean, en primer lugar, para evaluar cuál es el desempeño del modelo para representar al cultivar de soja HaHB04 en diversas regiones productivas de la República Argentina. En segundo lugar, se utilizó para comparar rendimientos regionales de producción de soja en la cuenca baja del Río Carcarañá (CBRC), en la provincia de Santa Fe, simulando la producción que se hubiera obtenido con soja HaHB4 para el periodo 1993-2015, en comparación con resultados simulados con el modelo SWAT (Romagnoli *et al.* 2017). En una tercera instancia se simuló escenarios de cambio climático en localizaciones de la CBRC. Por último, se generaron series de datos de rendimiento de soja HaHB4 para luego utilizarlos en la calibración del modelo agrohidrológico SWAT.

### **6.2 Materiales y métodos**

En este capítulo, por un lado, en la sección 6.2.1 se mencionan los lineamientos para la prueba del modelo en varios ambientes de la República Argentina, en esta instancia como hay significativos cambios en el ambiente las simulaciones se compararán con valores medidos realizados en experimentos a campo.

En la sección 6.2.2 se plantea una simulación con características similares a las realizadas por Romagnoli *et al.* (2017) con el modelo SWAT en la cuenca baja del Río Carcarañá (CBRC), esto actúa como punto de partida para luego simular en la misma región las situaciones de cambio climático que se detallan en la sección 6.2.3. Por último, en la sección 6.2.4 se calibra el modelo SWAT a partir de datos generados del cultivar HaHB4 con CROPGRO.

### 6.2.1 Evaluación en distintas regiones agrícolas de Argentina

Predecir el rendimiento de un cultivo es una tarea compleja, ya que, depende de múltiples factores como el genotipo, el ambiente y sus interacciones. Esta etapa de evaluación integra los resultados de calibración y validación mediante la ejecución de múltiples simulaciones en regiones geográficas con diferentes condiciones agronómicas, climáticas y de suelo. El modelo calibrado se utilizó para evaluar el rendimiento de grano de soja HaHB4 de catorce ensayos de campo que incluyeron diferentes condiciones de agua, temporadas de crecimiento y ubicaciones (Tabla 6.1).

Las características del perfil del suelo se asignaron a cada experimento de acuerdo con las series de suelo definidas en las Cartas de Suelo de INTA. Las características de retención de agua se calcularon mediante la herramienta SBuild de DSSAT. Los contenidos iniciales de agua del suelo se fijaron entre el 80% y el 100% de la capacidad de campo. Los números de curva se estimaron de acuerdo con la permeabilidad y textura del suelo. Siguiendo el concepto de equifinalidad, se evalúan las diez mejores combinaciones de parámetros obtenidos de la calibración para predecir el rendimiento de grano de los catorce ensayos de campo descritos en la Tabla 6.1.

Sumado a las estadísticas, RMSE y MBE, que se utilizaron en el Capítulo V para la calibración y validación; los resultados se cuantificaron mediante el coeficiente de determinación ( $R^2$ ), un índice de concordancia llamado índice D (Willmott, 1981) y los valores estadísticos de una regresión lineal simétrica, la intercepción ( $B_0$ ) y la pendiente ( $B_1$ ) (Correndo *et al.*, 2022). La regresión lineal simétrica demuestra que hay relación entre dos variables medidas en las mismas unidades (hipótesis nula) cuando  $B_0=0$  y  $B_1=1$  (Warton *et al.*, 2006).

$$R^2 = \frac{[\sum_{i=1}^n (S_i - \bar{S})(O_i - \bar{O})]^2}{\sum_{i=1}^n (S_i - \bar{S})^2 \sum_{i=1}^n (O_i - \bar{O})^2} \quad (6.1)$$

$$\text{índice D} = 1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n [|(S_i - \bar{O})| + |(O_i - \bar{O})|]^2} \quad (6.2)$$

Donde O y S son los valores observados y simulados en cada una de los i experimentos;  $\bar{O}$  y  $\bar{S}$  son los valores promedio de las observaciones y las simulaciones, respectivamente.

Tabla 6.1. Descripción de experimentos usados para la evaluación en distintas regiones de Argentina. Los experimentos se nombraron según la localidad y el año de inicio de la campaña.

Nombre del experimento y localidad	Localización geográfica		Serie de suelo	Fecha de siembra	Fecha de cosecha	Radiación solar (MJ/m <sup>2</sup> day)	Tmáx (°C)	Tmín (°C)	Precipitación (+Irrig.) (mm)
QL2009-Quimili	27°65'16"S	62°10'40"W	Santa Rita	15/01/2010	25/04/2010	19,7	32,0	19,3	320,2
LL2009a-Liborio Luna	33°35'15"S	65°38'09"W	San Luis	29/12/2009	20/04/2010	26,0	29,0	13,8	267,8 (+135)
LL2009b-Liborio Luna	33°35'15"S	65°38'09"W	San Luis	29/12/2009	20/04/2010	26,0	29,0	13,8	267,8 (+377)
HG2011-Hughes	33°48'60"S	61°18'06"W	Hugues	13/01/2012	03/05/2012	18,5	28,5	14,3	469,4
CH2012-Chilibroste	32°15'24"S	62°31'15"W	Monte Buey	21/11/2012	09/04/2013	21,8	29,0	15,8	517,0
CB2012-Corral de Bustos	33°16'47"S	62°07'48"W	Hansen	10/12/2012	18/04/2013	21,2	28,6	14,6	385,9
CA2012-Carmen de Areco	34°19'47"S	59°49'52"W	Capitán Sarmiento	20/11/2012	15/04/2013	19,3	30,1	14,7	455,2
AR2012-Aranguren	32°14'36"S	60°09'11"W	General Ramírez	16/11/2012	04/04/2013	21,6	29,1	17,3	493,6
AR2013-Aranguren	32°14'36"S	60°09'11"W	General Ramírez	08/01/2014	25/04/2014	17,4	27,5	17,1	481,0
VS2012-Villa Saboya	34°29'39"S	62°42'27"W	Saboya	27/12/2012	22/04/2013	18,8	28,9	13,5	163,4
VS2013-Villa Saboya	34°29'39"S	62°42'27"W	Saboya	23/12/2013	28/04/2014	15,8	27,2	13,1	484,2
MB2013-Monte Buey	33°00'13"S	62°26'17"W	Monte Buey	30/12/2013	23/04/2014	17,7	28,8	15,8	631,0
R02013a-Roldan	32°55'11"S	60°57'44"W	Peyrano	19/12/2013	16/04/2014	18,8	29,9	17,4	582,0
RO2013b-Roldan	32°55'11"S	60°57'44"W	Peyrano	07/01/2014	09/05/2014	17,1	28,2	16,0	571,0

### 6.2.2 Generación de la línea de base de producción de soja HaHB4 para el periodo 1993-2015

Para el inicio del trabajo en la cuenca baja del Río Carcarañá (CBRC), se planteó como periodo de referencia un periodo que incluye 23 campañas, desde 1993 hasta 2015 porque se tienen certeza de simulaciones publicadas anteriormente con el modelo SWAT, Maydana *et al.* (2020). Es difícil obtener datos a largo plazo de rendimientos de cultivos regionales detallados y completos y registros de manejo de cultivos en una cuenca no aforada como es el caso de la CBRC. En el trabajo mencionado SWAT se calibró para rendimientos anuales promedio de soja a nivel provincial.

La base de datos de suelos utilizada como entrada para CROPGRO, que contiene información detallada sobre propiedades físicas y parámetros hidrológicos para diferentes horizontes de suelos, se completó utilizando los datos de suelos disponibles y las funciones de pedotransferencia de Romagnoli *et al.*, 2017. La información climática requerida por SWAT, que incluye valores diarios de precipitación, temperatura máxima y mínima del aire, radiación solar, humedad relativa y velocidad del viento, se obtuvo del conjunto de datos meteorológicos globales *Climate Forecast System Reanalysis* (CFSR) (Dile y Srinivasan, 2014; Fuka *et al.*, 2014). Los datos climáticos de CFSR de seis estaciones en CBRC sirvieron como variables meteorológicas de entrada para el período 1993-2010. El simulador de datos meteorológicos integrado del modelo SWAT, WXGEN, se utilizó para completar los datos climáticos para el período 2011-2015. CROPGRO utilizó los mismos datos climáticos utilizados por SWAT para el período de referencia.

Se identificó que el modelo CFSR presenta precipitaciones menores a las normales en la región, 586 mm anuales. No obstante, para poder comparar los valores de rendimiento del cultivar de soja HaHB4 con el rendimiento de un cultivar genérico de soja calibrado en Maydana *et al.* 2020, se utilizaron los mismos datos climáticos que en ese trabajo.

### 6.2.3 Predicción de escenarios de cambio climático con CROPGRO en CBRC

Los efectos del fenómeno de cambio climático ya están presentes en la actualidad. No obstante, se estima que se incrementará significativamente con el paso de los años. Las trayectorias de concentración representativa (RCP) son escenarios que se plantearon para entender el fenómeno, estimar los efectos y realizar simulaciones a partir de diferentes interpretaciones posibles sobre cómo actuará la sociedad en la emisión de gases de efecto invernadero (GEI). En la Figura 6.1 se muestran cuatro de las RCP más difundidas. En este trabajo se utilizará la RCP 4.5 (nivel de forzamiento radiativo de  $4,5 \text{ W m}^{-2}$ ) que es un escenario de estabilización que estima que las emisiones de GEI sigan aumentando hasta

2040 y la RCP 8.5 (nivel de forzamiento radiativo de  $8,5 \text{ W m}^{-2}$ ) que es un escenario de referencia con altas emisiones (Van Vuuren *et al.*, 2011).




Figura 6.1. Trayectorias de concentración representativas (RCP) desde el año 2000 hasta 2100, gráfica creada por el sitio web Wikipedia a partir del reporte del IPCC 2019 (Shukla *et al.*, 2019).

Para la obtención de los datos climáticos de escenarios futuros se utilizó el generador meteorológico MarkSim DSSAT (Jones *et al.*, 2002) y se plantearon tres periodos de 23 años. Siguiendo la metodología sugerida por los autores del generador meteorológico y utilizada en varias publicaciones (Jones & Thornton, 2013; Quansah *et al.*, 2020; Pequeno *et al.*, 2022) los periodos son representados por 23 réplicas realizadas con diferentes semillas aleatorias de un año que se encuentra en el centro de los periodos. A partir de esto se llamó a los tres periodos: 2033, 2055 y 2077 que representan lapsos de tiempo que van desde 2022 hasta 2044, desde 2044 hasta 2066 y desde 2066 hasta 2088, respectivamente. Se tomaron datos de dos modelos, IPSL-CM5A-MR (Dufresne *et al.*, 2013) y MIROC5 (Watanabe *et al.*, 2010) para seis subcuencas de CBRC que en esta tesis son llamadas por las localidades más cercanas: Villa Elvira, Bustinza, Cañada de Gómez, Lucio V. López, Villa Eloísa y Cruz Alta. En primer lugar, se analizarán los promedios regionales en conjunto sumando las seis subcuencas para los dos modelos, en busca de efectos generales; para luego en una segunda instancia analizar por separado las diferencias entre estos dos modelos y los efectos en las seis localizaciones.

Las simulaciones se configuraron con fecha de siembra el primero de noviembre y cosecha al finalizar el ciclo, al comienzo de marzo. Se utilizó el genotipo HaHB4 calibrado y validado en capítulos anteriores. Las series de suelo representativas fueron Maciel (Villa Elvira), Bustinza (Bustinza y Lucio V. López), Correa (Cañada de Gómez), Casilda (Villa Eloísa) y Hansen (Cruz Alta), se definieron según Romagnoli *et al.* (2017).

Para incluir el efecto de la concentración de dióxido de carbono, se cambió en el módulo de modificaciones ambientales de CROPGRO en cada uno de los escenarios climáticos

futuros de acuerdo con la concentración que corresponde a los años 2033, 2055 y 2077 para ambas RCP utilizadas (ver Figura 6.1).

#### *6.2.4 Calibración de un modelo agrohidrológico con series sintéticas generadas por CROPGRO-soybean*

El modelo SWAT es un modelo hidrológico continuo, físicamente basado, utilizado ampliamente que operan con un paso de tiempo diario y está diseñado para simular el efecto de las prácticas culturales de uso y manejo del suelo en el balance hídrico del suelo y de la cuenca, es capaz de evaluar la erosión hídrica (producción de sedimentos) y los rendimientos agrícolas en grandes cuencas complejas con diferentes suelos, condiciones de uso y manejo durante prolongados períodos de tiempo (desde años a décadas). Su base de funcionamiento se organiza de una manera semi-distribuida. En el modelo SWAT, una cuenca se divide en varias subcuencas, que luego se subdividen en unidades de respuesta hidrológica (URH) que consisten en una combinación única de tipo de suelo, pendiente, uso y manejo de suelo. El balance hídrico es la fuerza impulsora detrás de todos los procesos y la URH es el componente más pequeño utilizado para calcular los procesos hidrológicos (Neitsch *et al.*, 2011).

En primer lugar, se generaron con CROPGRO series anuales de datos de rendimiento sintéticas para seis subcuencas que caracterizan la CBRC (Figura 6.2), a partir de los cuales, se calculó el rendimiento promedio de la cuenca que se utilizó para la calibración y validación del modelo SWAT. Las simulaciones se realizaron desde 1993 hasta 2015, con las mismas características planteadas anteriormente salvo por las series climáticas de datos. Para este proceso se decidió utilizar un modelo global diferente al que se utilizó en la sección 6.2.2 porque las precipitaciones del modelo CFSR son bajas respecto a lo normal en la región; se eligió utilizar el modelo de la NASA *Power* (2023) que en la región tiene precipitaciones más acordes a las esperadas. El modelo de la NASA *Power* (2023) tienen el nivel de detalle necesario para todas las subcuencas que forman la CBRC para su uso posterior en el modelo SWAT. Los datos meteorológicos y los nombres de las series de suelo que caracterizan a las subcuencas se encuentran en la Tabla 6.2.




Figura 6.2. Subcuencas que caracterizan la CBRC. Las localidades más cercanas al centro de cada subcuenca son: subcuenca 5, Villa Elvira; subcuenca 7, Bustinza; subcuenca 10, Cañada de Gómez; subcuenca 12, Lucio V. López; subcuenca 16, Villa Eloisa; y subcuenca 24 - Cruz Alta.

Tabla 6.2. Características de las subcuencas utilizados en las simulaciones para la generación de series sintéticas con CROPGRO-soybean. Precipitación acumulada anual, temperatura máxima promedio anual, temperatura mínima promedio anual, radiación anual promedio y serie de suelo predominante en la subcuenca.

Subcuenca	Precipitación (mm)	Tmáx (°C)	Tmín (°C)	Radiación (MJ/m <sup>2</sup> )	Serie de suelo
n° 5	721,4	26,0	13,1	18,7	Maciel
n° 7	689,5	26,0	13,0	18,8	Bustinza
n° 10	679,8	25,8	12,9	18,8	Correa
n° 12	721,4	26,0	13,1	18,7	Bustinza
n° 16	634,7	25,9	12,9	18,9	Casilda
n° 24	586,7	26,0	12,9	19,0	Hansen

El modelo SWAT en su módulo de crecimiento de cultivos identifica al cultivo de soja con treinta y siete parámetros entre los cuales se identificaron, según las características estudiadas de la soja HaHB4, los que tienen relación con el modo de crecimiento y marcan distinción por la presencia del gen HaHB4 (Tabla 6.3). Estos parámetros se utilizaron para calibrar el nuevo genotipo, partiendo de los valores correspondientes a los catorce

parámetros con los que anteriormente se había calibrado en la CBRC un cultivar genérico de soja (Romagnoli *et al.*, 2017). La calibración de SWAT se realizó por iteraciones, corriendo 500 simulaciones en cada iteración y ajustando de una manera semiautomática los intervalos de variación de los parámetros según el mejor resultado obtenido en la iteración anterior. El mejor resultado en cada iteración se definió por el valor de la función objetivo de Nash-Sutcliffe (NS) (Nash y Sutcliffe, 1970), además, se calculó el RMSE para visualizar la performance de los resultados.

El modelo SWAT requiere la utilización de los primeros años de datos para realizar un autoajuste de parámetros internos, este periodo de inicio del modelo es de 5 años desde 1993 hasta 1998. Las doce campañas siguientes desde 1998 hasta 2010 se utilizaron para calibrar el modelo y las últimas cinco campañas desde 2010 hasta 2015 se utilizaron para validar el modelo. El proceso de validación consistió en correr una iteración de 500 simulaciones sin modificar los intervalos de variación de los parámetros definidos en el proceso de calibración.

Tabla 6.3. Parámetros del módulo de cultivo en el modelo SWAT utilizados por Romagnoli *et al.* (2017). Los seis primeros parámetros que se resaltan en letra negrita son los seleccionados para la calibración.

Parámetro de cultivo	Significado
<b>T_BASE</b>	Temperatura base de crecimiento
<b>T_OPT</b>	Temperatura óptima de crecimiento
<b>EXT_COEF</b>	Coeficiente de extinción de la luz
<b>GSI</b>	Máxima conductancia estomática en condiciones de alta radiación y bajo déficit de presión de vapor
<b>VPDFR</b>	Déficit de presión de vapor correspondiente al segundo punto en la curva de conductancia estomática
<b>RDMX</b>	Profundidad máxima de raíces
BIO_E	Eficiencia del uso de la radiación
HVST1	Índice de cosecha
LAIMX1	Fracción del máximo índice de área foliar correspondiente al primer punto en la curva de desarrollo potencia de hojas
LAIMX2	Fracción del máximo índice de área foliar correspondiente al segundo punto en la curva de desarrollo potencia de hojas
DLAI	Fracción del periodo de crecimiento en que comienza a disminuir el área foliar
BMDIEOFF	Fracción de senescencia de biomasa
BLAI	Índice de área foliar máximo
CHTMX	Altura máxima del canopeo

## 6.3 Resultados y discusión

### 6.3.1 Resultados de la evaluación en distintas regiones de Argentina

Para evaluar más a fondo la metodología propuesta para calibrar el crecimiento y desarrollo de un genotipo de soja transgénica de segunda generación, se procedió a evaluar el rendimiento de soja HaHB4 en una amplia gama de ubicaciones.

La Tabla 6.4 muestra los resultados y el desempeño del proceso de evaluación, expresados por RMSE, MBE,  $R^2$ , índice D, B0 y B1, para los diez mejores conjuntos de parámetros de la calibración. Los resultados de la evaluación demostraron una buena predicción del rendimiento de grano, con valores de RMSE que varían entre 402 y 563 kg/ha. En el MBE no se presenta una tendencia a subestimar o sobreestimar que se pueda generalizar a la mayoría de los sets de parámetros evaluados. Los coeficientes de determinación,  $R^2$ , entre el rendimiento de grano previsto y el observado fueron superiores a 0,7 ( $0,74 < R^2 < 0,81$ ), y el índice D varió de 0,90 a 0,94 para todos los conjuntos de parámetros. Los resultados de la Tabla 6.4 muestran el buen desempeño del modelo calibrado.

En la Figura 6.3 se muestran los resultados de la evaluación del primer set de calibración presentados con una regresión lineal simétrica realizada con Métrica (Correndo *et al.*, 2022), el valor de B0 es de -131,03 kg/ha, es cercano a cero considerando los valores de los rendimientos y el valor de B1 de 1,04 se encuentra muy cercano al valor ideal de 1.

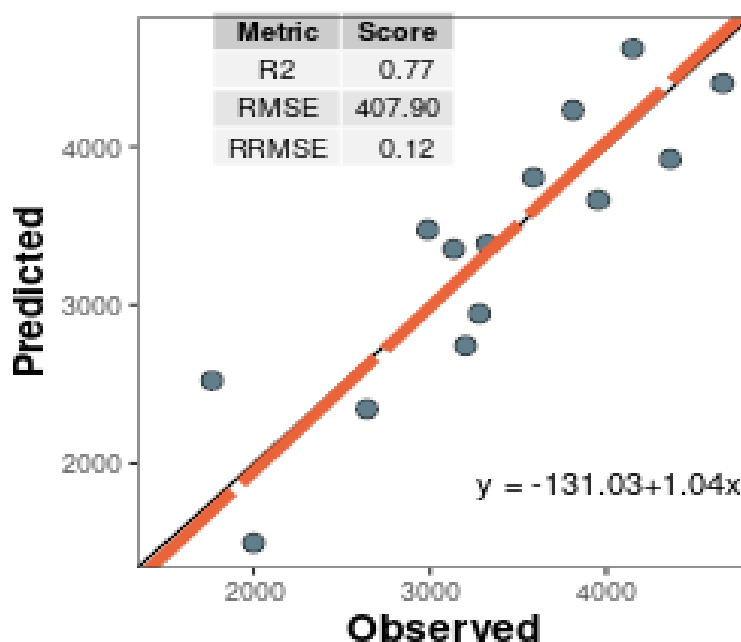


Figura 6.3. Regresión lineal simétrica para el proceso de evaluación con el set n°1 de calibración. Métricas:  $R^2$ , RMSE, valor relativo de RMSE (RRMSE).

Tabla 6.4. Resultados de la evaluación en los catorce sitios experimentales para los diez mejores sets de calibración. En las primeras columnas se muestran las estadísticas y en las últimas los rendimientos en los catorce sitios, los sitios están nombrados según los nombres de la Tabla 6.1. Los valores de rendimientos de los experimentos están en la última fila.

N° de	Rendimientos (kg/ha)																			
set	RMSE	MBE	R <sup>2</sup>	Ind D	B0	B1	QL09	LL09a	LL09b	HG11	CH12	CB12	CA12	AR12	AR13	VS12	VS13	MB13	RO13a	RO13b
1	408	3	0,77	0,93	-131	1,04	2743	1499	3476	3384	3921	4400	4621	2523	2344	3805	2946	3664	4230	3354
2	428	-131	0,78	0,93	-426	1,09	2785	1314	3229	3383	4233	4258	4308	2461	2048	3508	2647	3519	4271	3062
3	447	-77	0,74	0,92	-323	1,07	2578	1397	3402	3371	4081	4453	4454	2614	2263	3456	2501	3766	4064	3384
4	428	122	0,78	0,93	-200	1,10	3163	1561	3636	3721	3836	4417	4887	2200	2333	3951	3400	3679	4376	3414
5	563	315	0,76	0,90	-297	1,18	2926	1656	4016	3816	4140	4691	5248	2360	2502	4292	3603	3904	4470	3653
6	442	-139	0,76	0,92	-345	1,06	2689	1400	3380	3455	3824	4126	4494	2263	1881	3725	3117	3406	4054	3098
7	459	99	0,75	0,92	-309	1,12	2828	1485	3623	3751	3922	4465	4878	2430	2182	3853	3363	3700	4373	3399
8	446	101	0,76	0,93	-255	1,10	2707	1617	3613	3555	3950	4394	4975	2386	2222	3969	3570	3751	4136	3425
9	402	-164	0,81	0,94	-226	1,02	2823	1320	3074	3305	3855	4157	4355	2340	2179	3442	2824	3525	4160	3204
10	426	-18	0,77	0,93	-329	1,09	2656	1566	3579	3471	3997	4386	4737	2358	2106	3788	2907	3584	4184	3294
Rendimientos medidos a campo							<b>3203</b>	<b>2001</b>	<b>2986</b>	<b>3327</b>	<b>4363</b>	<b>4659</b>	<b>4148</b>	<b>1763</b>	<b>2644</b>	<b>3585</b>	<b>3282</b>	<b>3955</b>	<b>3812</b>	<b>3135</b>

### 6.3.2 Simulaciones con CROPGRO en la cuenca baja del Río Carcarañá

En primera instancia se obtuvieron los rendimientos de soja HaHB4 para el periodo de referencia 1993-2015, estos resultados son considerados como la "línea de base" de producción de este genotipo. En la Tabla 6.5 se comparan los rendimientos de soja HaHB4 con los simulados para el mismo periodo por SWAT. Se observó que frente a las mismas condiciones ambientales el rendimiento de soja HaHB4 aumenta alrededor de un 34% en comparación con los rendimientos promedio de soja en la CBRC para el escenario de referencia simulado con SWAT.

Tabla 6.5. Condiciones climáticas como promedios anuales de las 22 campañas y rendimientos promedio de las simulaciones en la CBRC. En los escenarios base se presenta SWAT con soja y CROPGRO con soja HaHB4. Los periodos 2022-2044, 2044-2066 y 2066-2088 se nombran como escenarios 2033, 2055 y 2077 respectivamente.

	Escenarios de base		Escenarios de cambio climático HaHB4					
	1993–2015		2022-2044		2044-2066		2066-2088	
	SWAT	CROPGRO	RCP4.5	RCP8.5	RCP4.5	RCP8.5	RCP4.5	RCP8.5
Concentración de CO <sub>2</sub> (ppm)	380	380	440	480	520	660	560	925
Precipitación anual acumulada (mm)	586,7	586,7	1006,5	1004,7	1015,7	971,9	1023,3	962,8
Temperatura máxima promedio (°C)	26,0	26,0	24,4	24,6	25,1	25,8	25,7	27,2
Temperatura mínima promedio (°C)	12,9	12,9	11,7	11,9	12,2	13,1	12,7	14,3
Radiación solar promedio (MJ/m <sup>2</sup> )	19,0	19,0	16,8	16,5	16,8	16,9	16,6	17,2
Rendimiento promedio (kg/ha)	1016,3	1363,3	3984,1	3968,8	4070,6	4095,3	3825,1	3850,3

En segunda instancia se simularon escenarios de cambio climático, se presentan promedios entre las seis localizaciones de la CBRC para los dos modelos climáticos utilizados, IPSL-CM5A-MR y MIROC5. Estos modelos estiman temperaturas promedio más bajas con precipitaciones acumuladas bastante superiores a las del modelo de CFSR del escenario de referencia, lo que da como resultado mayores rendimientos de soja HaHB4 en todos los escenarios futuros (Tabla 6.5). En el modelo CROPGRO excesos de agua no afectan directamente el rendimiento del cultivo, por otro lado, el modelo SWAT por ser un modelo agrohidrológico continuo a nivel de cuenca contempla que los excesos de precipitaciones y escurrimiento superficial pueden provocar inundaciones en zonas productivas, afectando de manera significativa los rendimientos de cultivos. Por ser la CBRC una cuenca de llanura, en años excesivamente húmedos se presentan con frecuencia problemas de anegamiento e inundaciones. Por lo tanto, se requiere un análisis

a nivel de cuenca de los escenarios de cambio climático en la CBRC que queda planteado como trabajo futuro de esta tesis.

Para los escenarios de 2033 la mayor diferencia entre las RCP 4.5 y 8.5 es la concentración de CO<sub>2</sub>, esto no afectó de manera significativa el rendimiento que en ambos casos tiene valores cercanos a 4000 kg/ha. En los escenarios 2055 los rendimientos aumentan con ambas RCP (aproximadamente a 4100 kg/ha) y en el periodo 2077 disminuyen de similar manera ambas RCP por debajo de los valores que se observan en el periodo 2033 (aproximadamente 3800 kg/ha). En comparación entre la RCP 4.5 y la RCP 8.5, si bien en los promedios de rendimientos de las seis localidades para los dos modelos climáticos no se observan marcadas diferencias, si hay diferencias en las condiciones ambientales: en la RCP 8.5 aumenta la concentración de CO<sub>2</sub> y las temperaturas con una tasa mayor al aumento que se presenta en la RCP 4.5; Y también en la RCP 4.5 se mantienen las precipitaciones y la radiación en los periodos 2055 y 2077, mientras en la RCP 8.5 disminuyen las precipitaciones y aumenta la radiación solar (Tabla 6.6).

De los factores climáticos simulados durante el periodo cultivado las precipitaciones acumuladas y la radiación solar promedio fueron las que presentaron correlación con el rendimiento (R<sup>2</sup> de 0,37 y 0,25 respectivamente), además estas dos variables climáticas están correlacionadas entre sí. Por otro lado, las variables climáticas: concentración de CO<sub>2</sub>, temperatura máxima y temperatura mínima también se encuentran correlacionadas entre sí. (Figuras A6.5 a A6.13 del Anexo Capítulo VI).

Tabla 6.6. Condiciones climáticas durante los meses con cultivo de los modelos MIROC5 y IPSL-CM5A-MR y rendimiento promedio de las seis localizaciones. Los meses con cultivo son noviembre, diciembre, enero, febrero y marzo. Las columnas indican el promedio por campaña de la precipitación acumulada en mm, la radiación solar promedio en MJ/m<sup>2</sup>, las temperaturas máxima y mínima promedios en grados centígrados y el rendimiento en kg/ha.

Modelo	RCP	Periodo	Precipitación	Radiación	T. máxima	T. mínima	Rendimiento
MIROC5	4.5	2033	674,0	22,6	30,2	16,5	3928
		2055	706,4	22,6	30,9	17,1	4018
		2077	726,9	22,3	31,3	17,6	4135
	8.5	2033	664,6	22,5	30,4	16,5	4037
		2055	668,8	22,9	31,4	17,6	4261
		2077	703,1	23,0	32,2	18,7	4307
IPSL	4.5	2033	693,3	22,7	29,8	16,4	4041
		2055	686,0	22,7	30,9	17,2	4124
		2077	676,2	22,9	32,2	18,0	3515
	8.5	2033	689,3	22,5	30,3	17,1	3901
		2055	638,9	22,7	32,0	18,7	3929
		2077	598,7	23,2	34,2	20,5	3394

En general los dos modelos presentan aumento de rendimiento en ambas RCP del 2033 al 2055, siendo muy marcado en el modelo MIROC5 RCP 8.5 y muy bajo en el modelo del IPSL RCP 8.5. En el modelo MIROC5 el aumento de rendimiento del 2055 al 2077 se mantiene para la RCP 4.5 y también sigue aumentando pero muy poco para la RCP 8.5. Por otro lado, entre estos mismos periodos, en los modelos del IPSL se nota una alta disminución del rendimiento tanto con RCP 4.5 como para la RCP 8.5. Esta diferencia marcada en el efecto sobre el rendimiento del cultivo que tienen estos dos modelos se da principalmente por las diferencias que tienen en la predicción de precipitaciones durante los meses estivales. Con el paso del tiempo el modelo MIROC5 predice un aumento de las precipitaciones, por el lado contrario, el modelo de IPSL predice una reducción de las precipitaciones (Tabla 6.6).

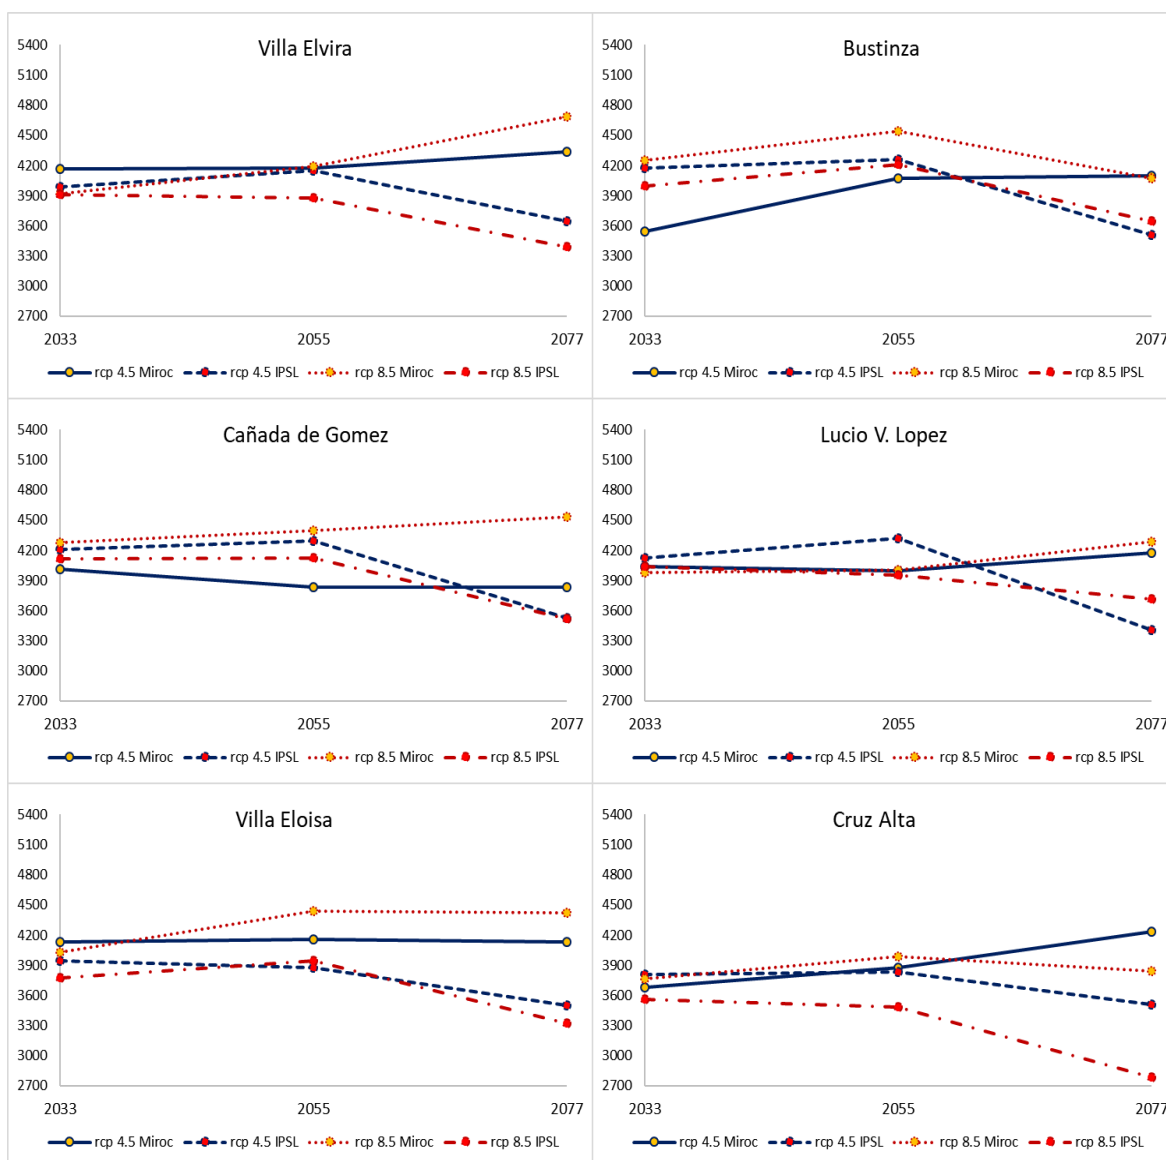


Figura 6.4. Rendimientos del cultivar HaHB4 en escenarios de cambio climático para seis localizaciones de la CBRC.

El efecto en las subcuencas analizadas presenta cierta variabilidad de acuerdo al modelo considerado siguiendo los lineamientos mencionados en el párrafo anterior. No obstante se destaca que en Cruz Alta que es el sitio que presenta los menores rendimientos en el periodo más próximo 2033-RCP 4.5 (entre 200 y 400 kg/ha menos que las otras locaciones), es también el único sitio que presenta una consistente reducción de rendimiento para los dos modelos en los escenarios de 2077-RCP 8.5 frente a 2077-RCP 4.5 (una diferencia de 400 kg/ha para MIROC5 y 700 kg/ha para IPSL) (Figura 6.4).

### 6.3.3 Resultados de la calibración de SWAT en CBRC con series sintéticas de datos de rendimiento

Se requirieron tres iteraciones para la calibración del modelo SWAT con los rangos que se indican en la Tabla 6.7. La calibración a partir de los promedios de rendimiento en la CBRC generados con CROPGRO presentó un buen ajuste con un valor RMSE de 557 kg/ha en el mejor resultado de la tercera iteración. En la Tabla 6.8 se presentan los resultados de calibración de rendimiento. El índice NS alcanzó un valor de 0,76, lo cual es considerado muy bueno (Moriassi *et al.*, 2007; Lin *et al.*, 2017).

Tabla 6.7. Intervalos de los parámetros para la calibración de SWAT en las tres iteraciones.

Parámetro	Intervalo 1 <sup>er</sup> iteración		Intervalos 2 <sup>da</sup> iteración		Intervalos 3 <sup>ra</sup> iteración	
T_BASE	7,00	9,33	7,96	9,88	8,00	9,00
T_OPT	23,39	30,00	23,39	27,03	24,00	26,00
EXT_COEF	0,426	0,800	0,426	0,650	0,530	0,630
GSI	0,0003	0,0090	0,0045	0,0128	0,0065	0,0095
RDMX	1,20	1,80	1,44	1,93	1,50	1,90
VPDFR	2,09	4,00	2,24	3,41	2,70	3,20

Tabla 6.8. Calibración del rendimiento de soja con SWAT. Valores de rendimiento con CROPGRO y en las tres iteraciones de calibración con SWAT para los años de calibración en kg/ha.

Año de cosecha	Observado CROPGRO	Mejores resultados		
		Primera iteración	Segunda iteración	Tercera iteración
1998	5758	5265	5532	5591
1999	4805	4010	4219	4799
2000	3273	3450	3014	3414
2001	5691	5273	4860	5462
2002	2349	3989	3921	4168
2003	5062	4862	4809	5035
2004	3286	3665	4100	3440
2005	4572	4379	4646	4960
2006	3255	2970	3048	3684
2007	5442	4560	4915	5048
2008	3244	2995	3446	2969
2009	2603	1990	2642	2406
2010	4631	4861	4689	4673
RMSE (kg/ha)		641	603	557
NS		0,69	0,72	0,76

En la validación con los últimos cinco años del periodo estudiado el valor de NS fue de 0,84 (RMSE=493 kg/ha), mejorando el valor obtenido durante el proceso de calibración. La Figura 6.5 presenta los valores de rendimiento de calibración y validación de soja HaHB4 para las seis subcuencas características que fueron seleccionadas para el análisis.

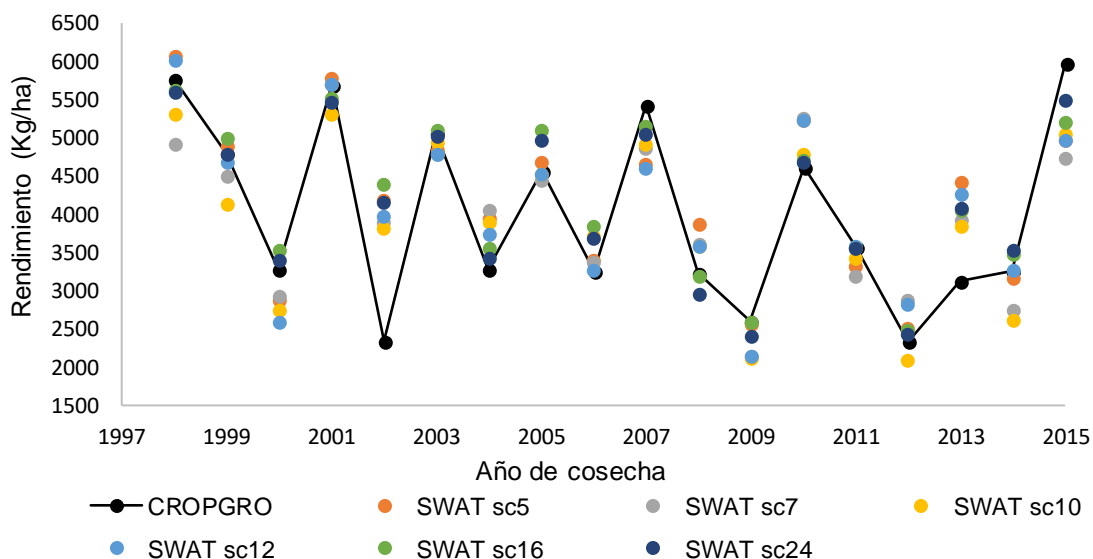


Figura 6.5. Rendimientos anuales de soja (Kg/ha) en los años de calibración y validación para las seis subcuencas (sc) representativas y el valor promedio de CROPGRO.

## CAPÍTULO VII – CONCLUSIONES Y TRABAJO FUTURO

### 7.1 Conclusiones

En esta tesis se desarrolló una metodología robusta para ampliar y facilitar la calibración y validación de un modelo de crecimiento y desarrollo de soja (CROPGRO) para un cultivar genéticamente modificado de segunda generación, resistente a altas temperaturas y a condiciones de déficit hídrico. Se comenzó con un detallado análisis de sensibilidad que permitió caracterizar el efecto de los parámetros del modelo en las variables estudiadas (Capítulo III). Luego en el proceso de calibración los resultados mostraron que se desarrolló una metodología de calibración confiable para parametrizar CROPGRO combinando sus tres niveles de variabilidad (es decir, parámetros de cultivar, ecotipo y especie). En cada paso del proceso de calibración se determinó si era mejor estimar  $k$  parámetros de cultivar y ecotipo para ajustarse a los datos existentes o  $k + n$  parámetros, donde  $n$  eran parámetros de especies. En los casos en que se consideraron parámetros de especie para el proceso de calibración, estos parámetros fueron cuidadosamente seleccionados en función de características fisiológicas singulares del genotipo HaHB4 identificadas en ensayos de laboratorio y refrendadas en ensayos de campo. Después de la calibración multiobjetivo semiautomática, que incluyó cuatro pasos (cada paso se llevó a cabo para calibrar una variable de salida diferente) y ajustes preliminares (relacionados con el contenido de agua del suelo y la dinámica de las raíces), el modelo mostró una predicción correcta de las etapas de desarrollo (R1, R3, R5 y R7), balance hídrico del suelo, biomasa y rendimiento del cultivo.

El balance de agua del suelo se calibró y validó con un conjunto sólido de datos experimentales y características de retención de agua del suelo bien establecidas (punto de marchitez permanente y capacidad de campo) estimadas a partir de mediciones en los ensayos. Se hizo un esfuerzo especial para ajustar el contenido inicial de agua del suelo, el SRGF y la progresión de la profundidad de la raíz, utilizando procedimientos de datos blandos (Capítulo IV). Además, al momento de analizar el balance hídrico del suelo en la zona radicular, se consideraron los aspectos que afectan directamente el contenido de agua del suelo como la escorrentía y la infiltración. Al respecto, Caviglia *et al.* (2013) mencionan que, en ambientes subhúmedos a húmedos, como el que se considera para la calibración, los componentes del balance hídrico del suelo, distintos a la evapotranspiración, pueden representar del 30% al 70% de la precipitación anual. Además, es importante considerar la variabilidad de la precipitación ENSO, que resultó en una cantidad total de precipitación durante la temporada de validación casi cuatro veces mayor que durante la temporada de calibración. En este sentido, los resultados obtenidos

concuerdan con los de Moura da Silva *et al.* (2021), quienes señalan que CROPGRO subestima el contenido de agua del suelo en condiciones de sequía y sobreestima el contenido de agua del suelo en condiciones de riego completo. En general, los resultados del Capítulo V mostraron que el modelo calibrado fue capaz de simular el balance hídrico del suelo con buena verosimilitud.

La simulación de biomasa tiende a subestimar la biomasa producida durante el desarrollo del cultivo y mejora con los valores de biomasa a final de ciclo, dado que, la metodología de calibración considera déficit hídrico y condiciones de riego, se consideraron adecuados los errores en comparación con otros estudios. La simulación de rendimiento fue buena en la validación y también se comprobó que tuvo un buen desempeño en diferentes regiones productivas de Argentina.

El cultivar HaHB4 calibrado en CROPGRO presentó rendimientos 34% mayores a los calibrados con SWAT de un cultivar convencional en el periodo 1998-2015 (Maydana *et al.*,2020), usando el modelo climático CFSR que presentaba una precipitación anual promedio de 586mm. Teniendo en cuenta que la precipitación es baja, es esperable que los rendimientos del cultivar HaHB4 sean mayores por su adaptabilidad a situaciones de estrés hídrico. Además, se probó el modelo calibrado para escenarios futuros de cambio climático con dos modelos globales de datos, IPSL-CM5A-MR y MIROC5. Las diferencias entre los modelos mostraron que el factor de precipitaciones es el que afecta en mayor medida al rendimiento. No se destaca un efecto negativo del aumento de las temperaturas, puede ser debido a que el cultivar calibrado presenta mayor resistencia al estrés térmico que los cultivares convencionales.

Por último, el modelo CROPGRO se utilizó para generar series sintéticas de rendimiento que permitieron calibrar y validar el módulo de cultivo del modelo agrohidrológico SWAT con un índice NS de 0,76 y 0,84 para calibración y validación respectivamente. Moriasi *et al.* (2007) clasificaron valores de NS entre 0,75 y 1,00 como muy buenos, mientras que, en el mismo sentido, Lin *et al.* (2017) concluyeron que valores de NS mayores a 0,75 sugieren que las simulaciones son satisfactorias. Por eso se concluye que el modelo CROPGRO calibrado es una buena herramienta para la calibración del modelo SWAT.

Los resultados mostraron que se presentó una metodología de calibración confiable para un genotipo de soja transgénica de segunda generación recientemente desarrollado. Contar con una metodología de calibración robusta para ampliar y facilitar el modelado de cultivos brinda una herramienta tecnológica para la gestión y planificación del uso del suelo (estrategias y políticas) bajo escenarios de cambio climático. La importancia de modelar el crecimiento y desarrollo de un cultivo resistente al clima en el marco del sistema suelo-planta-atmósfera es un paso hacia la seguridad alimentaria.

### *7.1.1 Contraste de las hipótesis asociadas a los objetivos específicos*

*HIPÓTESIS 1: La metodología de calibración es robusta, por lo que, luego de la calibración de un genotipo de soja HaHB4, el modelo a nivel de lote será exitosamente validado y evaluado en diferentes regiones de Argentina.*

En los capítulos III y IV se prepara el proceso de calibración que se lleva a cabo en el Capítulo V con una metodología de calibración multiobjetivo robusta. El proceso de calibración consideró parámetros de especie en función de características ecofisiológicas del cultivar de soja HaHB4 que presenta resistencia a condiciones de estrés hídrico y térmico. Se hizo énfasis en la fenología, el balance hídrico, la biomasa y el rendimiento. En el Capítulo V se realizó la validación las variables de fenología, balance hídrico, biomasa y rendimiento. En el Capítulo VI se evalúa en diferentes regiones de Argentina el rendimiento simulado por el modelo. En ambos casos el modelo simuló con precisión las variables evaluadas. Por lo tanto, las evidencias encontradas en los capítulos V y VI permitieron aceptar la hipótesis propuesta.

*HIPÓTESIS 2: En los escenarios de cambio climático, teniendo en cuenta que el cultivar HaHB4 presenta ciertas ventajas adaptativas a las altas temperaturas, el efecto de las altas temperaturas que presentan los escenarios de la RCP 8.5 no afectará al cultivo permitiendo que mantenga su rendimiento en comparación con los escenarios de la RCP 4.5.*

En el Capítulo VI se plantearon escenarios de cambios climático a nivel de lote a partir de los modelos climáticos IPSL-CM5A-MR y MIROC5. Los modelos tenían la distribución esperada de temperatura con mayores temperaturas en los escenarios de RCP 8.5, sin embargo, la distribución y cantidad de precipitaciones en ambos modelos fue muy diferente, incluso la tendencia fue opuesta, mientras en un modelo aumentaban las precipitaciones en el otro disminuían. El rendimiento simulado estuvo fuertemente influenciado por la variable de precipitaciones, no se pudo corroborar como fue el efecto del factor temperatura en la comparación de los escenarios de cambio climático con RCP 4.5 y RCP 8.5. Por lo tanto, se decidió rechazar la hipótesis propuesta.

*HIPÓTESIS 3: Los datos sintéticos generados por el modelo a nivel de lote permitirán una correcta calibración y validación del modulo de cultivo de SWAT.*

En el Capítulo VI se calibró el modulo de cultivo de soja de SWAT a partir de series de rendimiento generadas con CROPGRO a partir de un cultivar de soja HaHB4. La validación del modelo SWAT presentó valores de RMSE e índice NS que corroboraron una buena performance de las simulaciones, Por lo tanto, se aceptó la hipótesis propuesta.

## 7.2 Trabajo futuro

### 7.2.1 Asimilación de datos remotos en modelos de crecimiento de cultivos

Para mejorar la predicción de rendimiento de cultivos a una escala regional es necesario incorporar información de humedad de suelo, y datos fenológicos de cultivos, entre otros, que suelen ser inexistentes en cuencas no aforadas como es el caso de la CBRC.

Como sucede con otro tipo de modelos, los modelos de crecimiento de cultivos están sujetos a errores que provienen de datos de campo. La asimilación de datos provenientes de sensoramiento remoto puede ser utilizada en estos modelos sin alterar su estructura, a través de la actualización de parámetros o variables de estado con datos observados durante la campaña que quiere simularse.

Los datos de sensoramiento remoto tienen el potencial de proveer información frecuente y en extensas superficies de variables vinculadas a la cobertura vegetal y al suelo. En particular, estas observaciones remotas son capaces de monitorear humedad de suelo, biomasa, fracciones de radiación fotosintética, índice de área foliar y estadios fenológicos de cultivos.

A su vez, los modelos de crecimiento de cultivos son difíciles de parametrizar para aplicaciones a gran escala (regional), debido a la variabilidad de tipos de cultivos, variaciones en suelos y diferentes prácticas de manejo. Es deseable, entonces, combinar modelos de crecimiento de cultivos como CROPGRO o agrohidrológicos como SWAT con observaciones remotas.

La incorporación de información obtenida a través de sensoramiento remoto, en un modelo de crecimiento de cultivo, es una manera robusta de combinar resultados numéricos y datos observados, de modo de minimizar la incertidumbre tanto de parámetros de entrada como de variables de salida del modelo. Para ello existen técnicas de asimilación de datos (*Data Assimilation*) que proveen una manera formal de combinar las predicciones de los modelos numéricos con observaciones remotas (Amor *et al.*, 2013; Huang *et al.*, 2019).

La implementación de algunas de estas técnicas se plantea como trabajo futuro a realizar durante mis actividades posdoctorales.

Durante el transcurso de esta Tesis Doctoral participé de actividades de campo y gabinete en la recolección y análisis de datos remotos. Como parte de estas tareas de investigación se publicaron varios trabajos que se mencionan en la sección PUBLICACIONES REALIZADAS DURANTE EL TRANSCURSO DE LA TESIS.

### 7.2.2 Simulación de escenarios de usos del suelo en la CBRC en situaciones de cambio climático

La complejidad del sistema suelo-agua-planta analizada desde un modelo que incluya una gran extensión de terreno, considerando escorrentía, erosión de suelo (producción de sedimentos) y los principales cauces hidrológicos, entre otras variables, será modelada en situaciones de cambio climático utilizando el modelo agrohidrológico SWAT. Se utilizará el modelo climático de la NASA *power* con las RCP 4.5 y 8.5 con sistemas de rotaciones que incluirán, en una primera instancia, dos cultivares de soja de primera diferentes, uno convencional y otro HaHB4. Este trabajo se encuentra en proceso de escritura.

En una segunda instancia se planteará un ajuste de otros cultivos.

### 7.2.3 Calibración y validación de modelos de cultivos para trigo y maíz.

Una vez establecida una metodología para la calibración de CROPGRO para soja HaHB4, es de interés extender la misma lógica de calibración a cultivares de trigo HaHB4 y maíz HaHB11.

La recolección de datos de experimentos de trigo HaHB4 y maíz HaHB11 se ha realizado durante el transcurso de esta tesis y por dificultades técnicas originadas durante la pandemia de COVID19 se retrasó la disponibilidad de estos datos, demorando el procesamiento de éstos. Los experimentos de maíz incluyen pruebas de variedades de maíz con genes de resistencia a anegamiento (HaHB11), sus parentales e híbridos convencionales, además de distintas condiciones de riego (con tratamientos de inundación) y fertilización. Los experimentos de trigo incluyen cultivares con los genes HaHB4 y su parental (cultivar de trigo Algarrobo), en situaciones de condiciones controladas en invernadero, crecimiento a campo en seco, con restricción hídrica y con riego, en algunos experimentos hay hasta cinco fechas de siembra diferentes. DSSAT utiliza los modelos de cultivo CERES-*maize* y CERES-*wheat*. Como se realizó con soja, la calibración de estos modelos también puede utilizarse para ajustar mejor el modelo agrohidrológico SWAT.

Las recolecciones de datos propios incluyen mediciones fenológicas, biomasa (subdivida en granos, tallo y hojas), área foliar, humedad de suelo de manera gravimétrica, utilización del medidor portátil de fotosíntesis LI-6400XT (tasa de fotosíntesis, conductancia estomática, fluorescencia), muestreo de suelos (para fertilidad y para densidad aparente), mediciones espectrométricas, utilización de un dron propio del grupo de trabajo con sensores espectrales y cámaras RGB y RG-NIR (*Near InfraRed*).

En el Anexo Salidas A Campo se detallan los experimentos y los momentos en que se realizaron tomas de datos propias (además cada experimento tiene otros grupos que toman

datos para hacer un registro continuo del cultivo). También se muestran imágenes de las salidas donde se puede observar los momentos de tomas de datos espectrométricos de manera directa manual y de manera semiautomática con un dispositivo desarrollado por el grupo de trabajo (Brazo Automático de Mediciones Espectrales – BAME), las tomas de datos fotosintéticos con un analizador de gases infrarrojos no dispersivos (IRGA) LI-6400XT, la recolección en bolsas de muestras de biomasa y el drone que también fue diseñado por el equipo de trabajo en que me desempeño.

## PUBLICACIONES REALIZADAS DURANTE EL TRANCURSO DE LA TESIS

**Montero Bulacio, E.**, Romagnoli, M., Otegui, M. E., Chan, R. L., & Portapila, M. (2023). OSTRICH-CROPGRO multi-objective optimization methodology for calibration of the growing dynamics of a second-generation transgenic soybean tolerant to high temperatures and dry growing conditions. *Agricultural Systems*, 205, 103583.

**Montero Bulacio, E.**, Romagnoli, M., & Portapila, M. Analysis of production and sustainability in situations of climate change in the lower basin of the Carcarañá river with an agrohydrological model. (En proceso de escritura)

Rigalli N., **Montero Bulacio E.**, Romagnoli M., Terissi L., Portapila M. "Identification and characterization of crops through the analysis of spectral data with machine learning algorithms" CAI - 10° Congreso de Agroinformática (JAIIO). Septiembre 2018. <http://47jaiio.sadio.org.ar/sites/default/files/CAI-50.pdf>

Rigalli N. F., **Montero Bulacio E.**, Romagnoli M., Otegui M.E., Portapila M. "Identificación de genotipos de soja a partir de datos espectrales". 7° Congreso de Soja del Mercosur, MERCOSOJA 2019. Septiembre 2019.

Arias C., **Montero Bulacio E.**, Rigalli N., Romagnoli M., Curin F., González F.G., Otegui M.E., Portapila M. "Ability of in situ canopy spectroscopy to differentiate genotype by environment interaction in wheat". *International Journal of Remote Sensing*, <https://doi.org/10.1080/01431161.2021.1875148> (Pages 3660-3680 | Received 18 Jun 2020, Accepted 16 Dec 2020, Published online: 02 Mar 2021).

Rigalli, N.; **Montero Bulacio, E.**; Romagnoli, M.; Enrico, J. M.; Bacigaluppo, S.; Pozzi, R.; Chan, R. L.; Otegui, M. E.; & Portapila, M. "Soybean phenology estimation using proximally-sensed hyperspectral canopy reflectance data" (En revisión en *International Journal of Remote Sensing*)

Di Leo, N., Jozami, E., **Montero Bulacio, E.**, Rigalli, N., Romagnoli, M., Barbona, I., Portapila, M. & Feldman, S. (2022, September). Biomass Estimation of *Sporobolus spartinus* with Multispectral Images from a Fixed-Wing Unmanned Aerial Vehicle and a Spectrometer. In 2022 IEEE Biennial Congress of Argentina (ARGENCON) (pp. 1-5). IEEE.

### ANEXO CAPÍTULO III




Figura A3.2. Diferencias absolutas (DA) en días de la variable simulada EM-R1 para los parámetros que dieron sensibles en el análisis en seco.

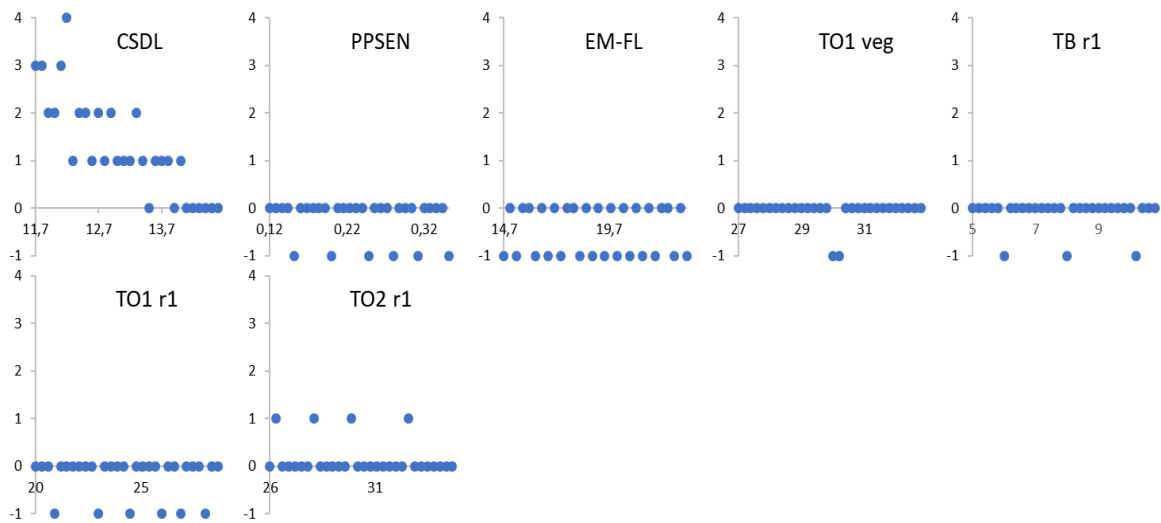


Figura A3.3. DA en días de la variable simulada EM-R1 para los parámetros que dieron sensibles en el análisis en condiciones potenciales.




Figura A3.4. DA en días de la variable simulada R1-R3 para los parámetros que dieron sensibles en el análisis en seco.

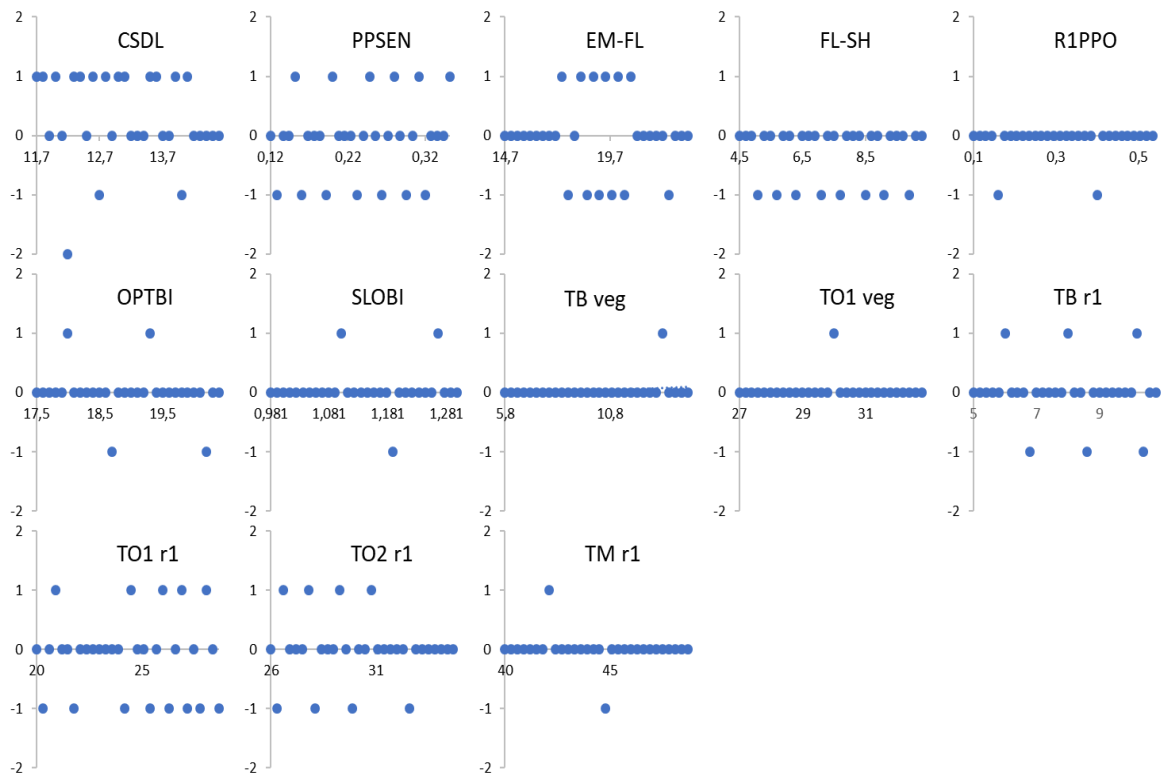


Figura A3.5. DA en días de la variable simulada R1-R3 para los parámetros que dieron sensibles en el análisis en condiciones potenciales.




Figura A3.6. DA en días de la variable simulada R3-R5 para los parámetros que dieron sensibles en el análisis en seco.

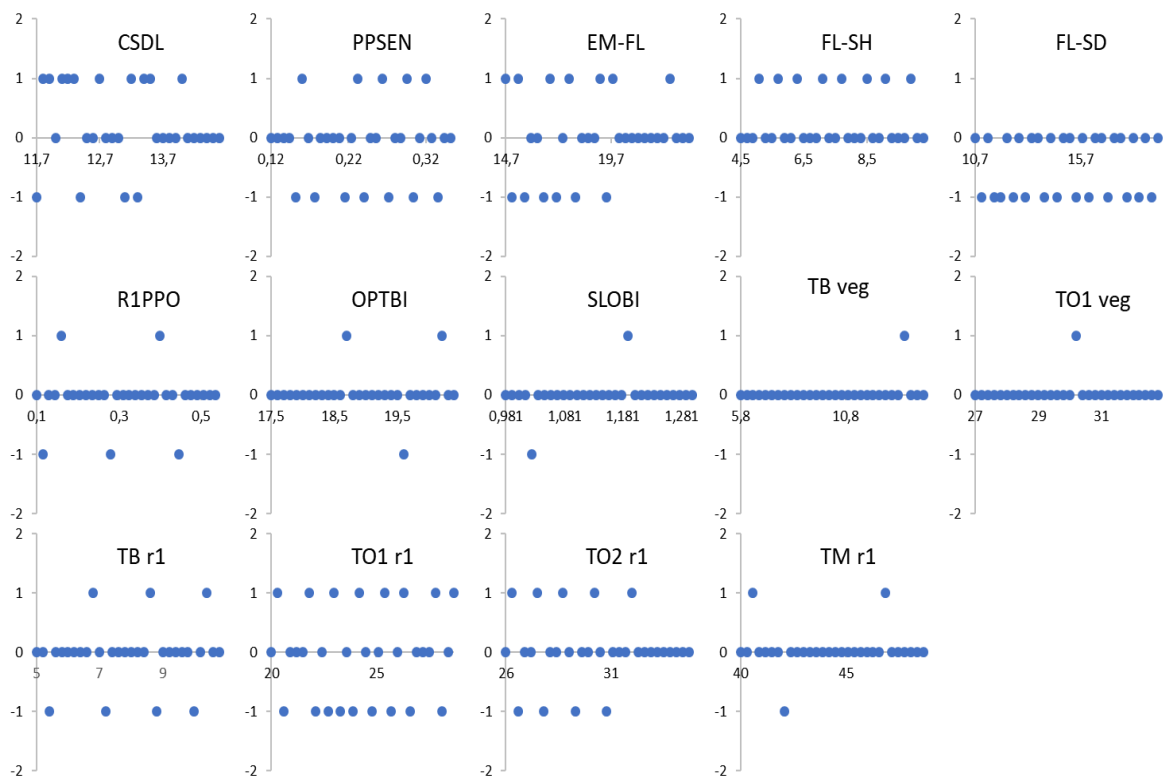


Figura A3.7. DA en días de la variable simulada R3-R5 para los parámetros que dieron sensibles en el análisis en condiciones potenciales.




Figura A3.8. DA en días de la variable simulada R5-R7 para los parámetros que dieron sensibles en el análisis en seco.




Figura A3.9. DA en días de la variable simulada R5-R7 para los parámetros que dieron sensibles en el análisis en condiciones potenciales.

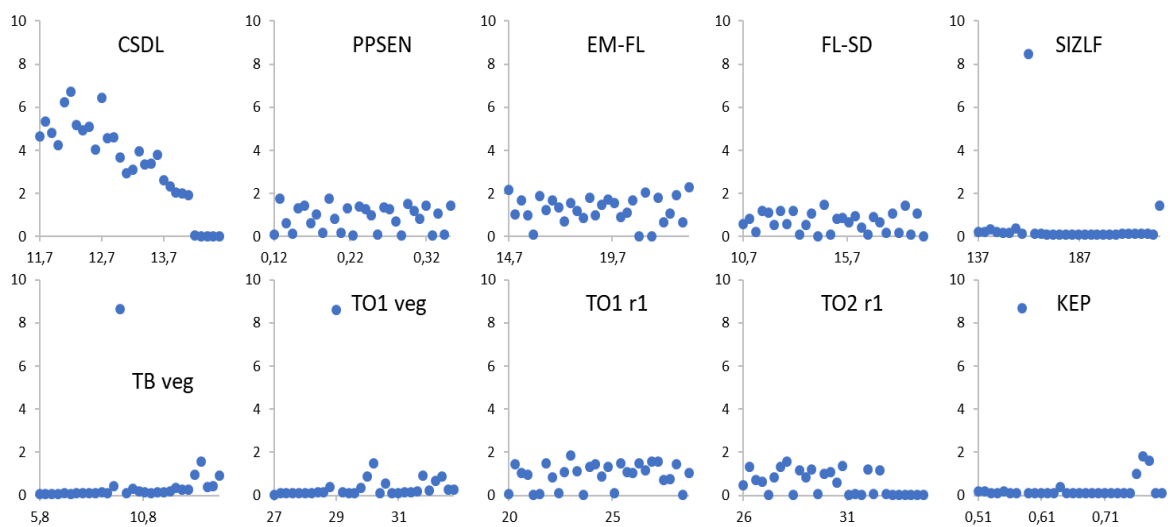


Figura A3.10. DA en mm del vector ET para los parámetros que dieron sensibles en el análisis en seco.

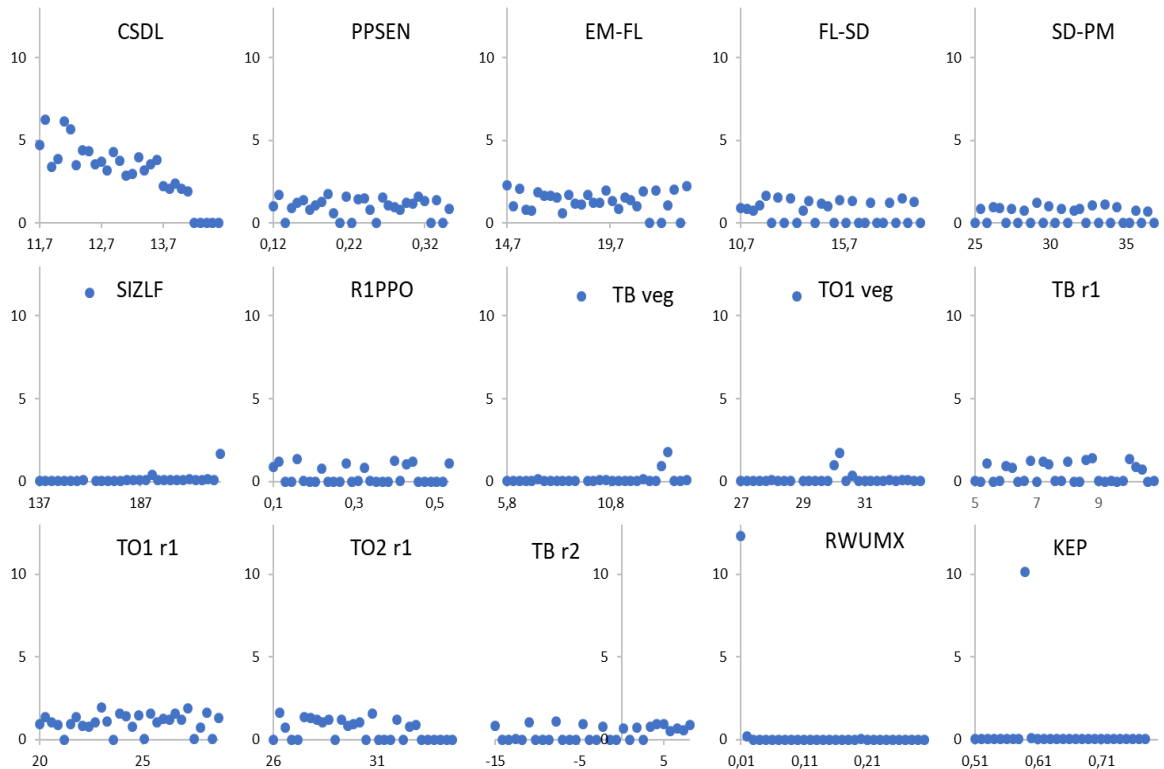


Figura A3.11. DA en mm del vector ET para los parámetros que dieron sensibles en el análisis en condiciones potenciales.




Figura A3.12. DA en mm de la variable simulada ETac a final de ciclo para los parámetros que dieron sensibles en el análisis en seco.




Figura A3.13. DA en mm de la variable simulada ETac a final de ciclo para los parámetros que dieron sensibles en el análisis en condiciones potenciales.

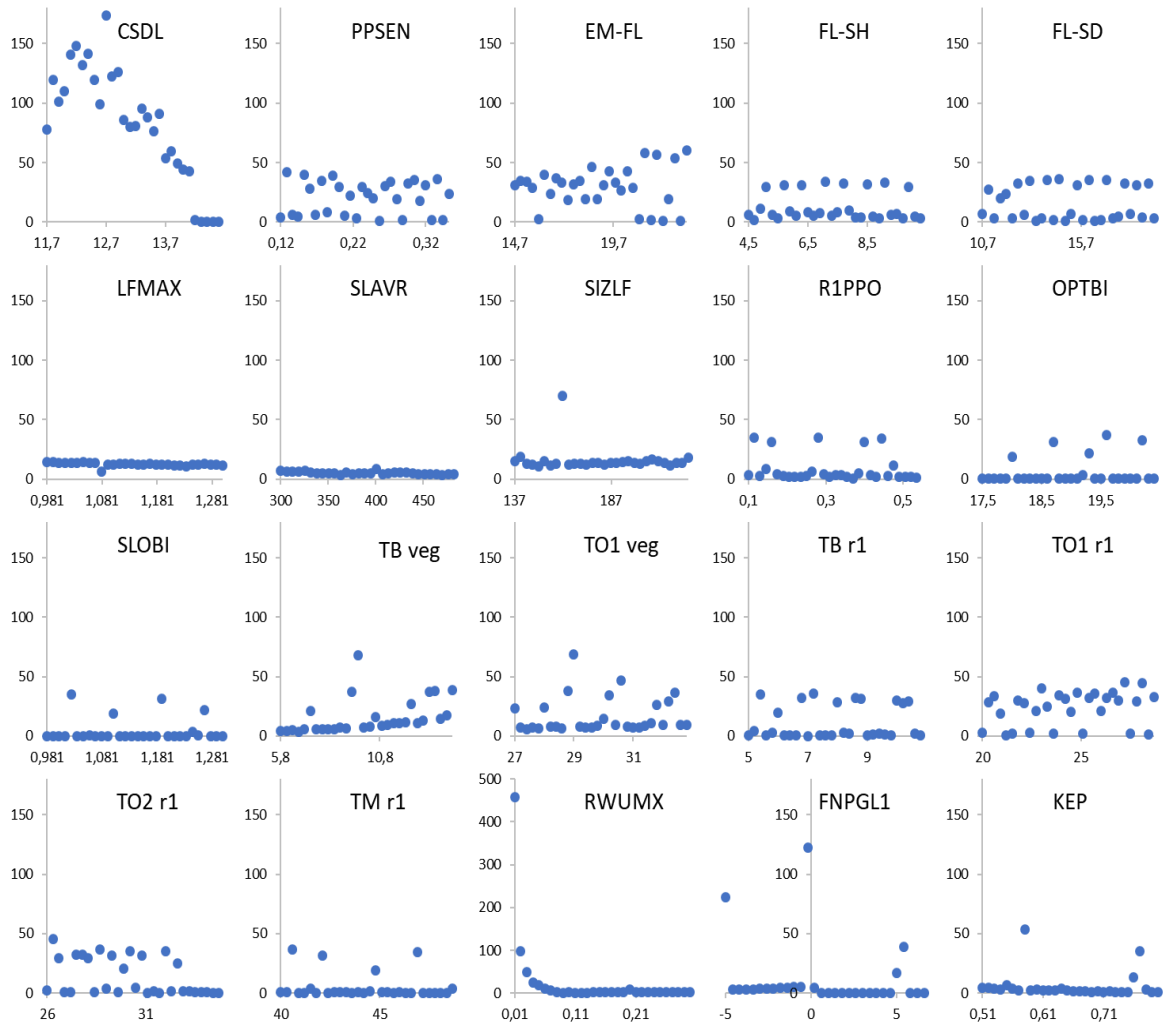


Figura A3.14. DA en kg/ha del vector biomasa para los parámetros que dieron sensibles en el análisis en seco.

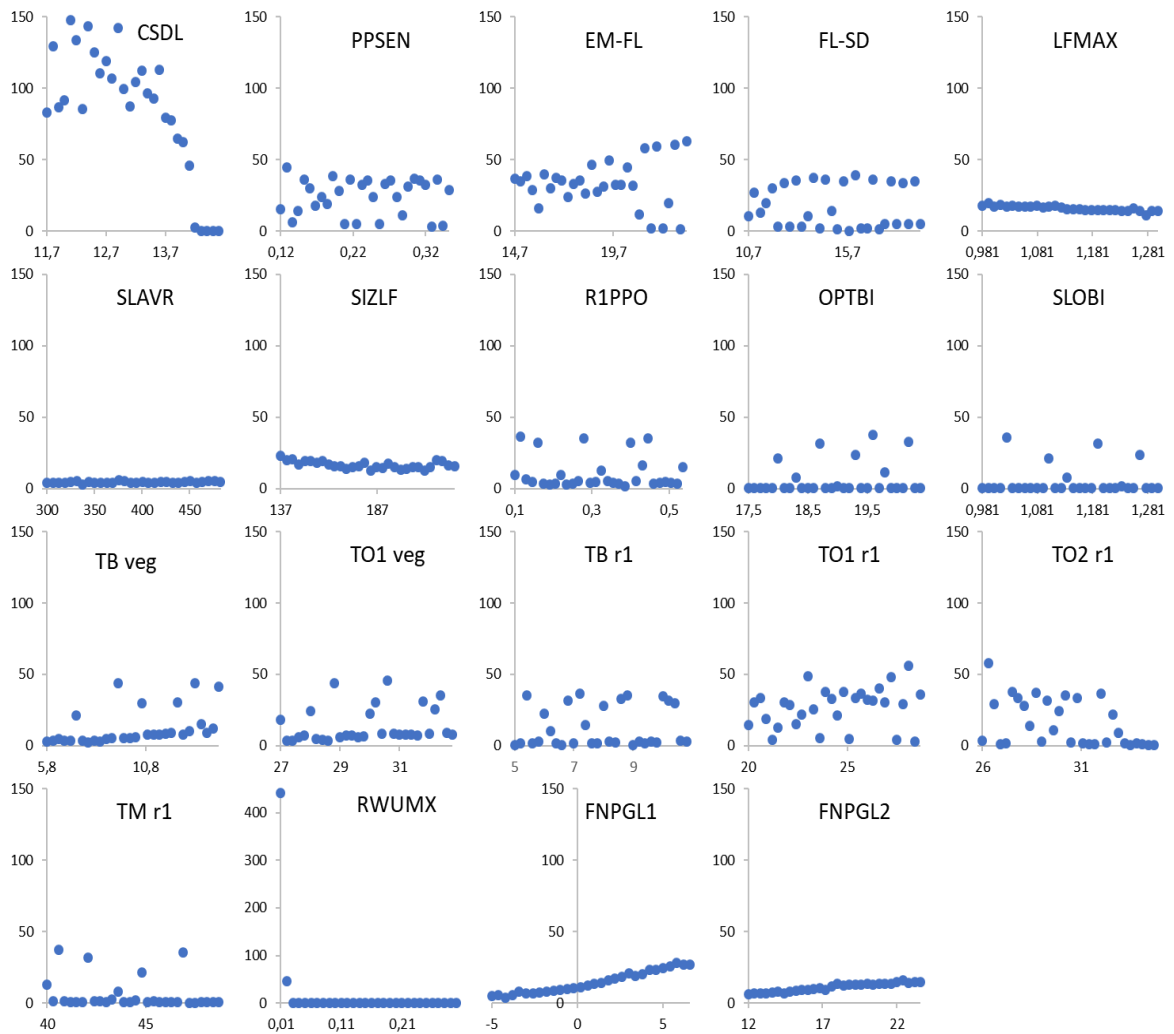


Figura A3.15. DA en kg/ha del vector biomasa para los parámetros que dieron sensibles en el análisis en condiciones potenciales.

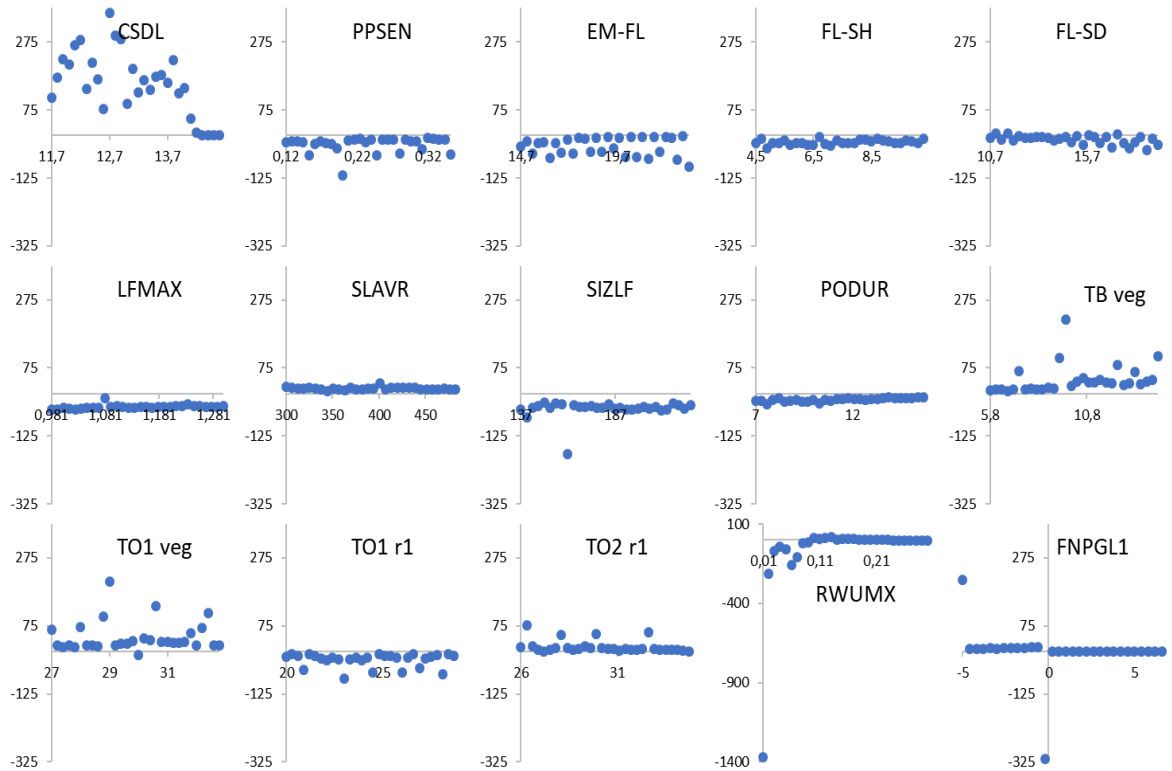


Figura A3.16. DA en kg/ha de la variable simulada biomasa máxima para los parámetros que dieron sensibles en el análisis en seco.

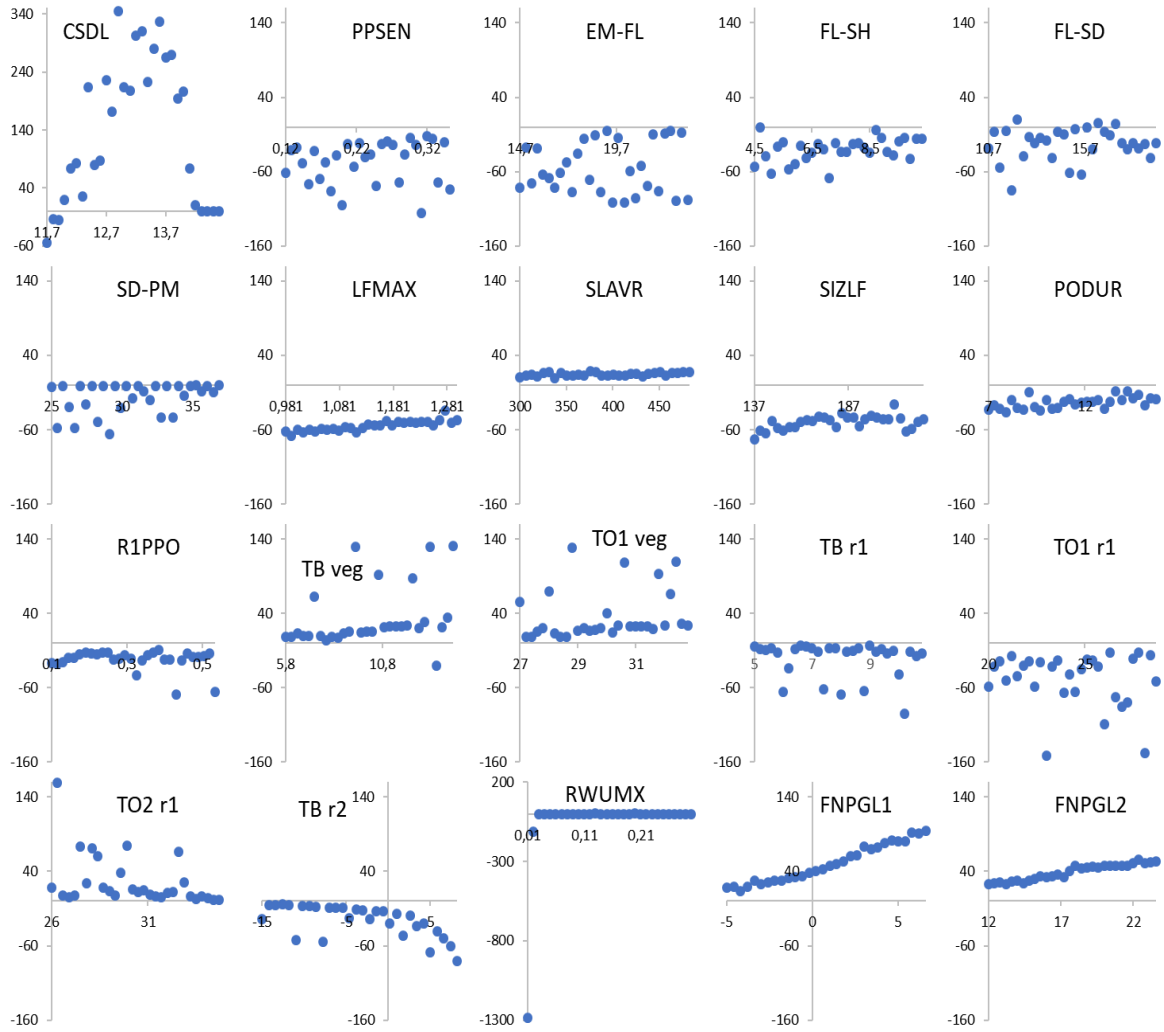


Figura A3.17. DA en kg/ha de la variable simulada biomasa máxima para los parámetros que dieron sensibles en el análisis en condiciones potenciales.




Figura A3.18. DA en kg/ha de la variable simulada rendimiento para los parámetros que dieron sensibles en el análisis en seco.

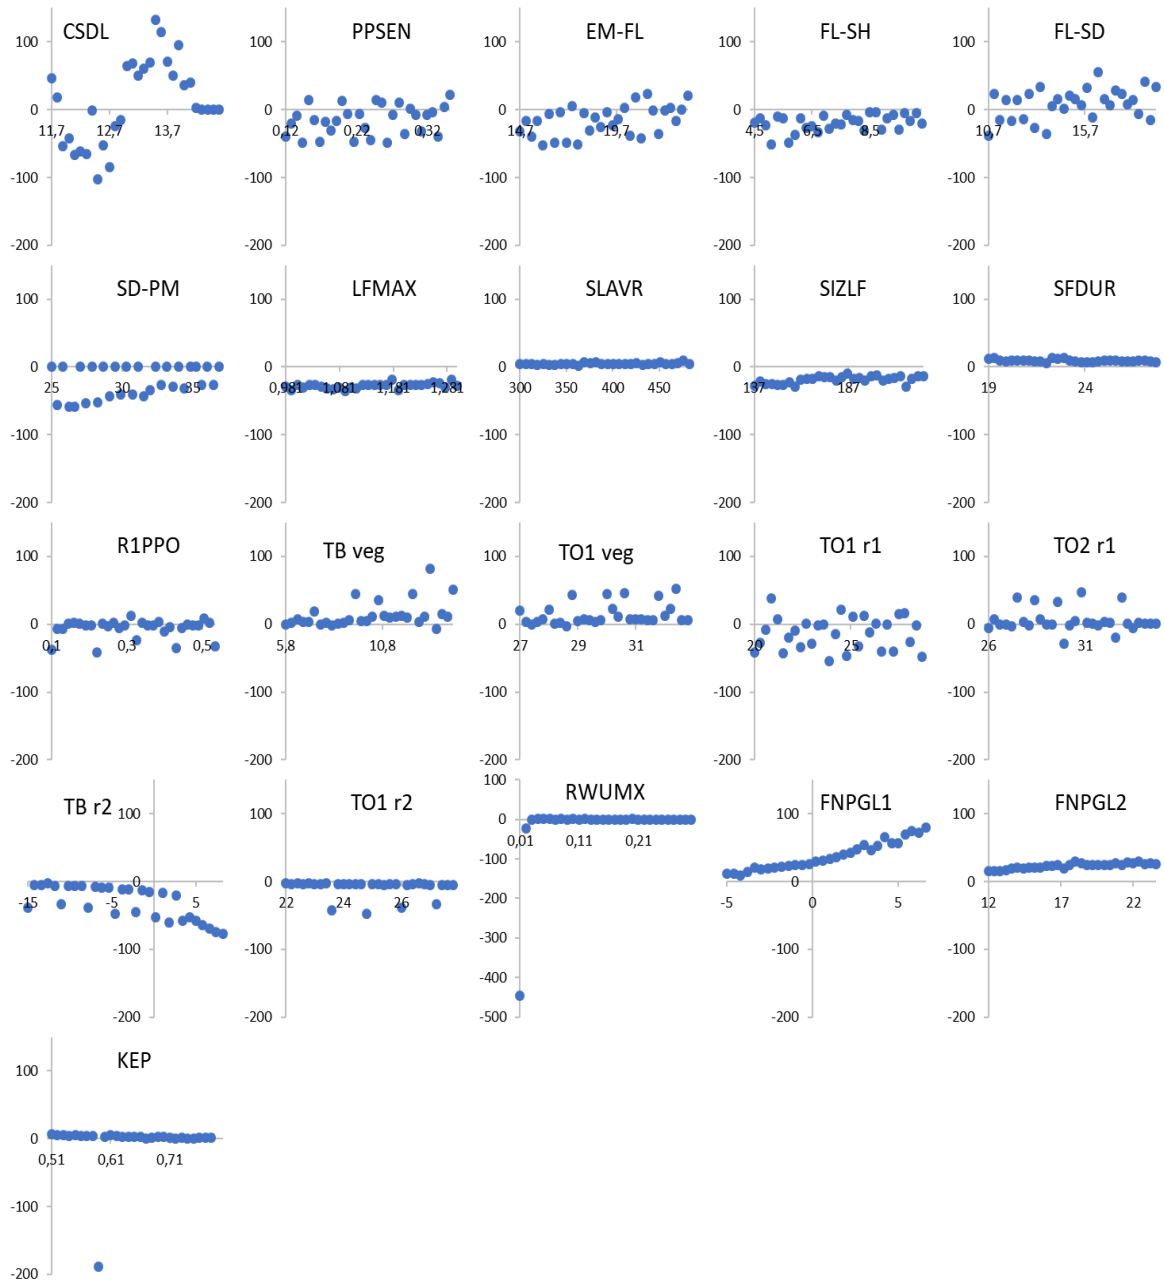


Figura A3.19. DA en kg/ha de la variable simulada rendimiento para los parámetros que dieron sensibles en el análisis en condiciones potenciales.

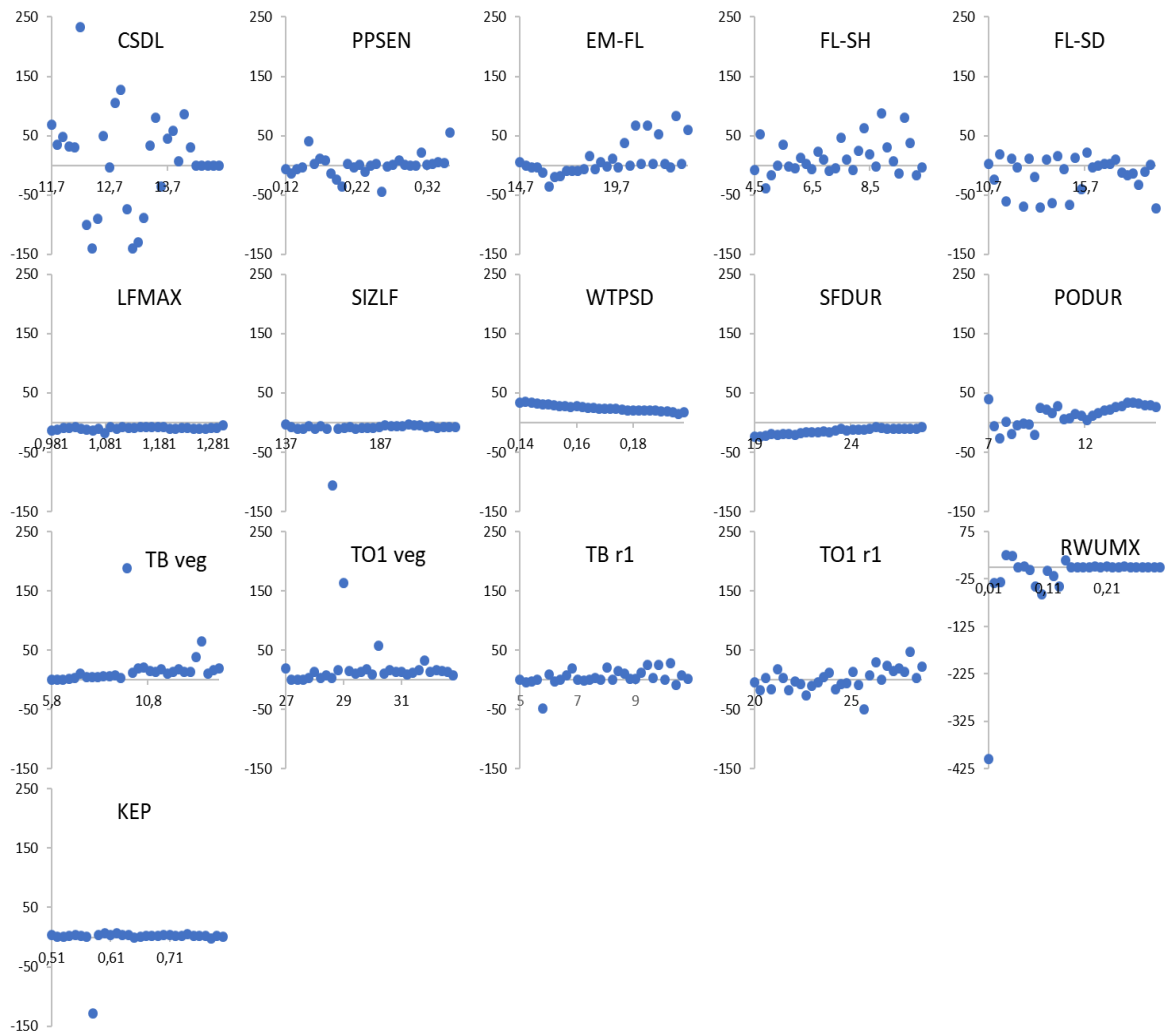


Figura A3.20. DA de la variable simulada número de granos para los parámetros que dieron sensibles en el análisis en seco.

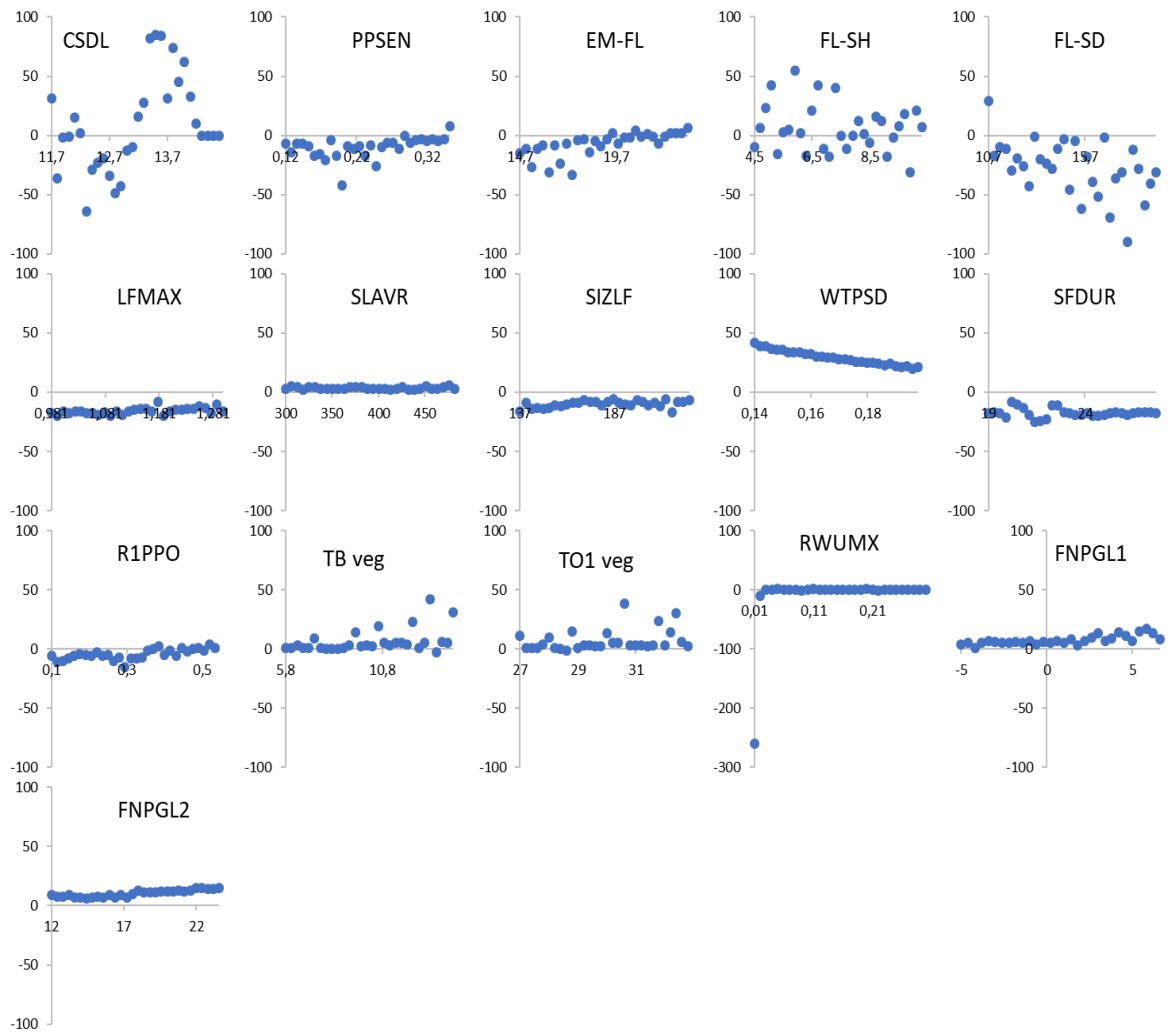


Figura A3.21. DA de la variable simulada número de granos para los parámetros que dieron sensibles en el análisis en condiciones potenciales.

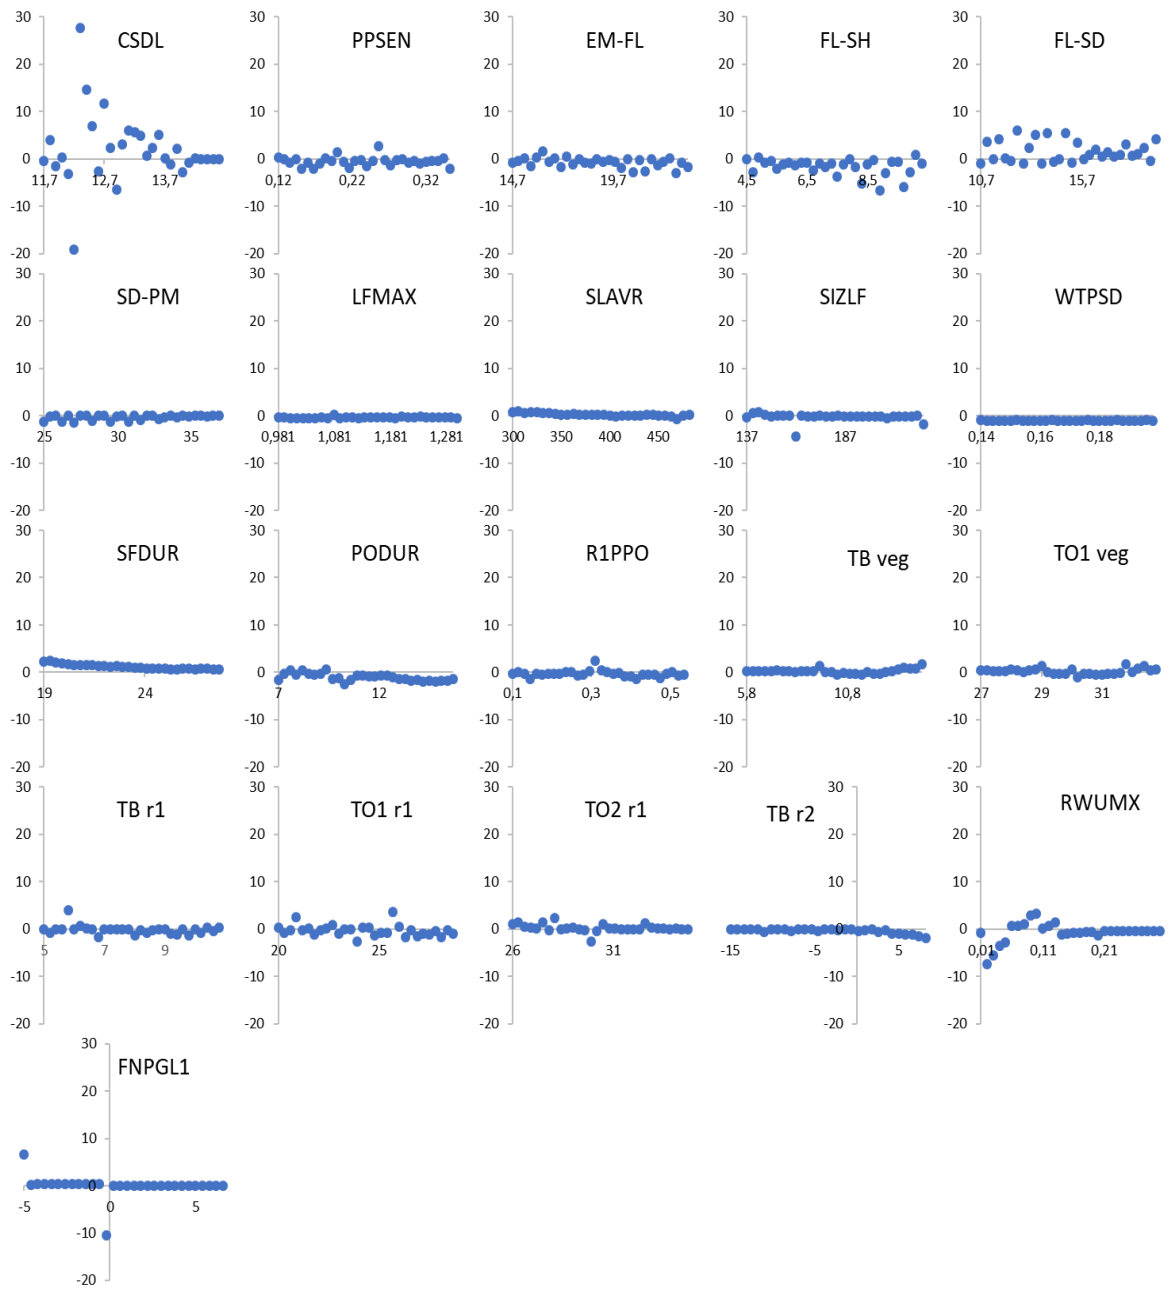


Figura A3.22. DA en gramos por grano de la variable simulada peso de granos para los parámetros que dieron sensibles en el análisis en seco.

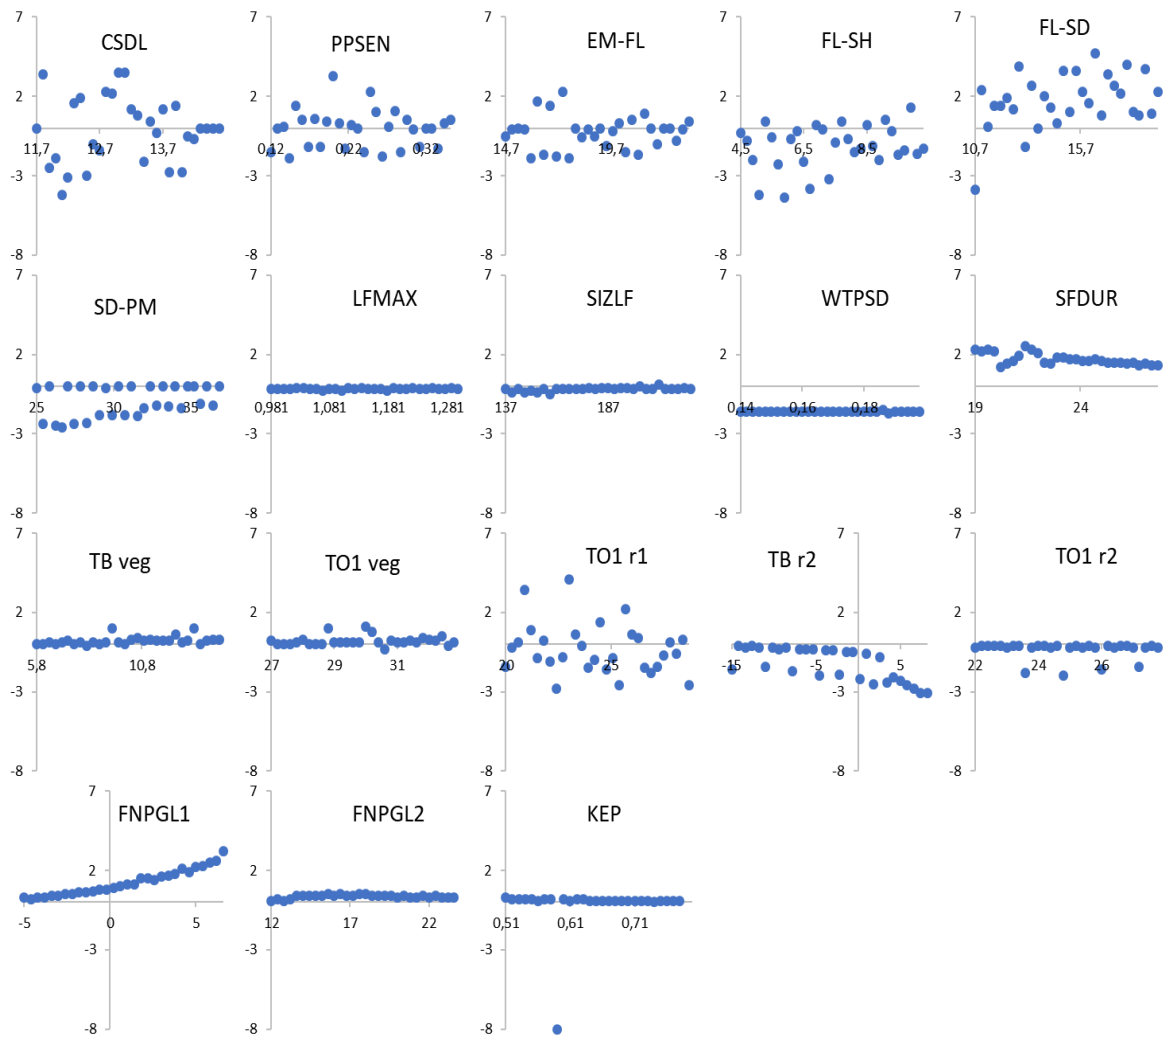


Figura A3.23. DA en gramos por grano de la variable simulada peso de granos para los parámetros que dieron sensibles en el análisis en condiciones potenciales.

## ANEXO CAPÍTULO IV

Tabla A4.8. Perfil de suelo ingresado al modelo CROPGRO. Donde SLB es la profundidad máxima del horizonte, SLMH es el nombre del horizonte, SLLL es el punto de marchitez permanente, SDUL es la capacidad de campo, SSAT es el punto de saturación hídrico, SRGF es el factor de crecimiento de raíces, SSKS es la conductividad hidráulica saturado, SBDM es la densidad aparente, SLOC es el contenido de materia orgánica estable, SLCL es el contenido de arcilla, SLSI es el contenido de limo, SLCF es el contenido de arena que lo calcula por diferencia (100-SLCL-SLSI) y SLHW es el pH en agua.

@	SLB	SLMH	SLLL	SDUL	SSAT	SRGF	SSKS	SBDM	SLOC	SLCL	SLSI	SLHW
15	Ap1	.191	.371	.474	1	.68	1.27	2.91	22.7	64.8	5.9	
25	Ap2	.191	.371	.432	1	.68	1.27	2.55	22.8	65.1	6.1	
30	BAt	.191	.371	.44	1	.15	1.27	1.5	30.2	56.8	6.2	
45	BAt	.23	.406	.44	.041	.15	1.39	1.5	30.2	56.8	6.2	
60	Bt1	.23	.406	.461	.041	.09	1.39	1.1	43.5	47.5	6.3	
75	Bt1	.231	.401	.498	.017	.15	1.34	1.1	43.5	47.5	6.3	
90	Bt2	.231	.401	.498	.017	.15	1.34	.6	30.2	56.4	6.5	
120	Bt2	.2	.349	.509	1	.15	1.25	.6	30.2	56.4	6.5	
135	Bt2	.158	.329	.51	1	.68	1.22	.6	30.2	56.4	6.5	
150	BC	.158	.329	.506	1	.68	1.22	.41	17	65.5	6.5	
180	BC	.156	.326	.506	1	.68	1.22	.41	17	65.5	6.5	

## ANEXO CAPÍTULO V

Tabla A5.12. Parámetros del cultivar Williams y parámetros calibrados del cultivar HaHB4.

Parámetro	Cultivar Williams	Cultivar HaHB4
cul- CSDL	13,40	12,41
cul- PPSEN	0,285	0,170
cul- EM-FL	19,00	18,05
cul- FL-SH	8,30	7,84
cul- FL-SD	14,20	12,67
cul- SD-PM	32,20	32,95
cul- LFMAX	0,990	1,282
cul- SLAVR	385,0	287,1
cul- SIZLF	180	191,5
cul- WTPSD	0,180	0,191
cul- SFDUR	26,00	22,17
cul- PODUR	12,00	12,37
eco- R1PPO	0,324	0,261
spe- TO1 veg	28,00	32,36
spe- TB r2	6,0	-15,0:9,0
spe- RWUMX	0,040	0,011
spe- FNPGL1	0,00	1,73
spe- FNPGL2	19,00	16,35

## ANEXO CAPÍTULO VI




Figura A6.5. Rendimiento en función de las precipitaciones acumuladas en el ciclo del cultivo para las 22 campañas en seis localidades, dos modelos, dos RCP.

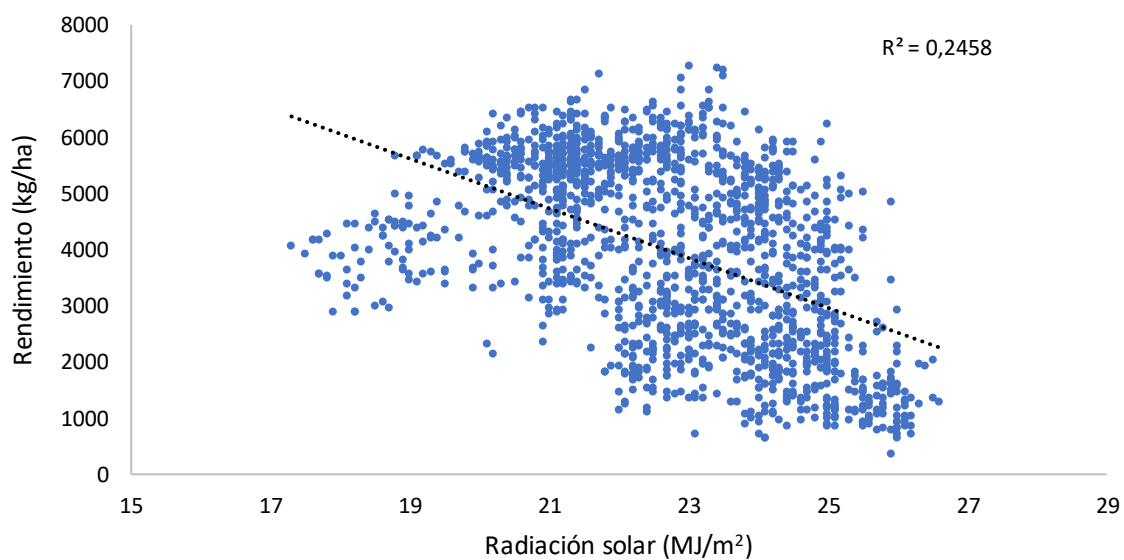


Figura A6.6. Rendimiento en función de la radiación solar promedio en el ciclo del cultivo para las 22 campañas en seis localidades, dos modelos, dos RCP.




Figura A6.7. Rendimiento en función de la temperatura máxima promedio en el ciclo del cultivo para las 22 campañas en seis localidades, dos modelos, dos RCP.




Figura A6.8. Rendimiento en función de la temperatura mínima promedio en el ciclo del cultivo para las 22 campañas en seis localidades, dos modelos, dos RCP.




Figura A6.9. Rendimiento en función de la concentración de CO<sub>2</sub> para las 22 campañas en seis localidades, dos modelos, dos RCP.




Figura A6.10. Temperatura máxima promedio en el ciclo del cultivo según la concentración de CO<sub>2</sub> para las 22 campañas en seis localidades, dos modelos, dos RCP.




Figura A6.11. Temperatura mínima promedio en el ciclo del cultivo según la concentración de CO<sub>2</sub> para las 22 campañas en seis localidades, dos modelos, dos RCP.

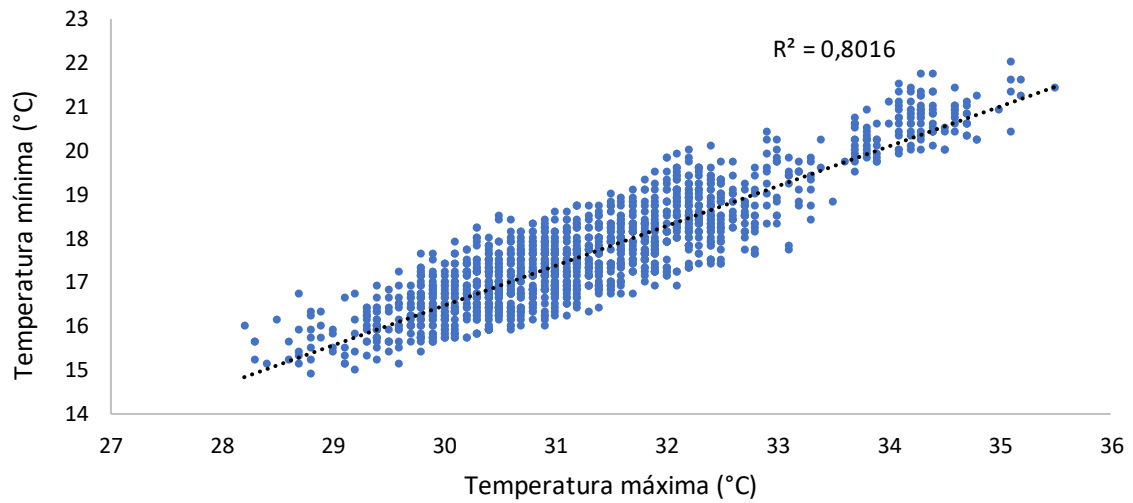


Figura A6.12. Relación entre las temperaturas mínimas y máximas promedio en el ciclo del cultivo para las 22 campañas en seis localidades, dos modelos, dos RCP.




Figura A6.13. Relación entre la radiación solar promedio y las precipitaciones acumuladas en el ciclo del cultivo para las 22 campañas en seis localidades, dos modelos, dos RCP.

## ANEXO SALIDAS A CAMPO

Tabla A8.1. Fechas de salidas a campo a los diversos experimentos, lotes experimentales o productivos.

Cultivo/Planta	Localidad	Institución	Año	Fechas de mediciones
Soja	Gilbert	Monsanto	16-17	13/1/2017 6/3/2017
Soja	Conesa	Monsanto	16-17	25/1/2017 1/3/2017
Maíz	Santa Fe	IAL	16-17	16/2/2017
Trigo	Pergamino	Bioceres	17	15/9/2017 3/11/2017 9/11/2017
Trigo	Oliveros	INTA	17	11/8/2017
Soja	Pergamino	INTA	17-18	24/1/2018 1/2/2018 22/2/2018 15/3/2018 28/3/2018
Soja	Oliveros	INTA	17-18	11/1/2018 30/1/2018 23/2/2018 16/3/2018
Soja	Santa Fe	IAL	17-18	8/2/2018 1/3/2018 26/3/2018
Arroz	Santa Fe	IAL	17-18	1/3/2018 26/3/2018
Soja	Roldán	Bioceres	17-18	1/3/2018
Trigo	Oliveros	INTA	18	29/8/2018 5/10/2018 17/10/2018 2/11/2018
Trigo	Roldán	Bioceres	18	28/9/2018 16/10/2018
Soja	Santa Fe	IAL	18-19	16/1/2019 29/1/2019 19/2/2019 21/3/2019
Soja	Pergamino	INTA	18-19	18/1/2019 5/2/2019 26/2/2019 25/3/2019
Soja	Oliveros	INTA	18-19	20/12/2018

Tabla A8.1. Fechas de salidas a campo a los diversos experimentos, lotes experimentales o productivos. (Continuación)

Cultivo/Planta	Localidad	Institución	Año	Fechas de mediciones
Soja	Oliveros	INTA	18-19	8/1/2019
				7/2/2019
				13/3/2019
Maíz	Santa Fe	IAL	18-19	16/1/2019
				29/1/2019
Trigo	Pergamino	Bioceres	19	20/9/2019
				8/10/2019
				25/10/2019
				7/11/2019
Trigo invernadero	Pergamino	Bioceres	19	5/12/2019
				20/9/2019
				8/10/2019
				25/10/2019
Trigo	Santa Fe	IAL	19	7/11/2019
				27/9/2019
				31/10/2019
Soja	Santa Fe	IAL	19-20	12/12/2019
				16/1/2020
				28/1/2020
				13/2/2020
				18/2/2020
Maíz	Santa Fe	IAL	19-20	2/3/2020
				17/1/2020
				28/1/2020
				13/2/2020
				18/2/2020
Cardo	Zavalla	FCA	19-20	18/9/2019
				18/12/2019
				22/1/2020
Espartillar	Gálvez		19-20	10/10/2019
				12/3/2020
Trigo	Pergamino	Bioceres	20	28/9/2020
				12/10/2020
				27/10/2020
				10/11/2020

**Registro fotográfico de salidas a campo donde se recolectaron datos de cultivos transgénicos y sus parentales**



Fotografía 1. Preparación para la toma de datos con mi codirectora, María.



Fotografía 2. En ensayo de soja, verificando la correcta toma de datos espectrales con la computadora.



Fotografía 3. Ordenamiento y etiquetado de muestras de biomasa de soja.




Fotografía 4. Muestreo de suelo con barreno.



Fotografía 5. Vista aérea de ensayo con tratamientos de riego y restricción hídrica.



Fotografía 6. En ensayo de riego y restricción hídrica en INTA Pergamino, realización de toma de datos fotosintéticos con IRGA.



Fotografía 7. En ensayo de trigo en Bioceres Pergamino, toma de datos espectrométricos con BAME.



Fotografía 8. Drone del grupo de trabajo.



Fotografía 9. En ensayo de maíz en IAL, Santa Fe, tomando datos espectrométricos de manera semiautomática.



Fotografía 10. En ensayo de maíz en IAL, Santa Fe, tomando datos espectrométricos de manera semiautomática.



Fotografía 11. En ensayo de soja en IAL, Santa Fe, tomando datos espectrométricos de manera semiautomática.

## BIBLIOGRAFÍA

Amor, I. V., Das, N. N., Hansen, J. W., & Njoku, E. G. (2013). Assimilation of remotely sensed soil moisture and vegetation with a crop simulation model for maize yield prediction. *Remote Sensing of Environment*, 138, 149-164.

Andriani, J. (2000). Crecimiento de las raíces de los principales cultivos extensivos en suelos Argiudoles de la provincia de Santa Fe. *Para mejorar la producción* N°13, EEA INTA Oliveros, pp 40-44.

Arnold, J.G., Srinivasan, R., Muttiah, R.S., & Williams, J.R. (1998). Large area hydrologic modeling and assessment part i: model development. *J. Am. Water Resour. Assoc.* 34, 73–89. <http://dx.doi.org/10.1111/j.1752-1688.1998.tb05961.x>

Bacigaluppo, S., Bodrero, M., & Salvagiotti, F. (2009). Producción de soja en rotación vs monocultivo en suelos con historia agrícola prolongada. *Para mejorar la producción*, 42, 53-55.

Battisti, R., Sentelhas, P. C., & Boote, K. J. (2017). Inter-comparison of performance of soybean crop simulation models and their ensemble in southern Brazil. *Field Crops Research*, 200, 28-37.

BCR, (2021). Empleo, exportaciones y actividad: ¿qué aporta la cadena soja a la Argentina? *AÑO XXXIX - N° Edición 2045 - Especial campaña de Soja 2021/22 - 01 de Abril de 2022*.

Beven, K., & Freer, J. (2001). Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the glue methodology. *J. Hydrol.* 249, 11–29. [https://doi.org/10.1016/S0022-1694\(01\) 00421-8](https://doi.org/10.1016/S0022-1694(01) 00421-8).

Bloomberg, (2022). <https://www.bloomberg.com/news/articles/2022-04-29/bioceres-soars-after-china-approves-drought-resistant-soy-strain>.

Boote, K., & Pickering, N. (1994). Modeling photosynthesis of row crop canopies. *HortScience* 29, 1423–1434.

Boote, K., Jones, J., Hoogenboom, G., & Pickering, N. (1998). The CROPGRO model for grain legumes. En: Gordon, Y., Hoogenboom, G., Thornton, P. (Eds.), *Understanding options for agricultural production*, vol. 7. *Springer, Dordrecht*, pp. 99–128.

Boote, K. J., Mínguez, M. I., & Sau, F. (2002). Adapting the CROPGRO legume model to simulate growth of faba bean. *Agronomy Journal*, 94(4), 743-756.

Boote, K. J., Jones, J. W., Batchelor, W. D., Nafziger, E. D., & Myers, O. (2003). Genetic coefficients in the CROPGRO–Soybean model: Links to field performance and genomics. *Agronomy Journal*, 95(1), 32-51.

Boote, K., Sau, F., Hoogenboom, G., & Jones, J. (2008). Experience with water balance, evapotranspiration, and predictions of water stress effects in the CROPGRO model. En: Ahuja, L., Reddy, V., Saseendran, S., Yu, Q. (Eds.), *Response of Crops to Limited Water*:

Understanding and Modeling Water Stress Effects on Plant Growth Processes, vol. 1, pp. 59–103.

Boote, K.J., Vallejos, C.E., Jones, J.W., & Correll, M.J. (2016). Crop Modeling Approaches for Predicting Phenotype of Grain Legumes with Linkage to Genetic Information. *Springer International Publishing, Cham*, pp. 163–192. [https://doi.org/10.1007/978-3-319-20562-5\\_8](https://doi.org/10.1007/978-3-319-20562-5_8).

Businesswire, 2021. Bioceres Crop Solutions Receives Approval of HB4 Drought Tolerant Soybean in Canada. *Businesswire Online*. Disponible en: <https://www.businesswire.com/news/home/20210601005303en/Bioceres-Crop-Solutions-Receives-Approval-of-HB4C2AE-Drought-Tolerant>

Cabello, J. V., Dezar, C. A., Manavella, P. A., & Chan, R. L. (2007). The intron of the *Arabidopsis thaliana* COX5 c gene is able to improve the drought tolerance conferred by the sunflower Hahb-4 transcription factor. *Planta*, 226, 1143-1154.

Camilloni, I. A. (2018). Argentina y el cambio climático. *Revista CEL, Ciencia e Investigación*, Tomo 68, N°5, 2018. Edición: Asociación Argentina para el Progreso de las Ciencias (AAPC), [www.aargentinapciencias.org](http://www.aargentinapciencias.org)

Casadebaig, P., Debaeke, P., & Wallach, D. (2020). A new approach to crop model calibration: phenotyping plus post-processing. *Crop Sci.* 60, 709–720. <https://doi.org/10.1002/csc2.20016>.

Casali, L., Herrera, J.M., & Rubio, G. (2021). Modeling maize and soybean responses to climatic change and soil degradation in a region of South America. *Agron. J.* 113, 1381–1393. <https://doi.org/10.1002/agj2.20585>.

Castiglioni, P., Warner, D., Bensen, R.J., Anstrom, D.C., Harrison, J., Stoecker, M., Abad, M., Kumar, G., Salvador, S., D'Ordine, R., Navarro, S., Back, S., Fernandes, M., Targolli, J., Dasgupta, S., Bonin, C., Luethy, M.H., & Heard, J.E. (2008). Bacterial rna chaperones confer abiotic stress tolerance in plants and improved grain yield in maize under water-limited conditions. *Plant Physiol.* 147, 446–455. <https://doi.org/10.1104/pp.108.118828>.

Caviglia, O., Sadras, V., & Andrade, F. (2013). Modelling long-term effects of cropping intensification reveals increased water and radiation productivity in the South-Eastern Pampas. *Field Crops Res.* 149, 300–311. <https://doi.org/10.1016/j.fcr.2013.05.003>.

Chan, R.L., Trucco, F., & Otegui, M.E. (2020). Why are second-generation transgenic crops not yet available in the market? *J. Exp. Bot.* 71, 6876–6880. <https://doi.org/10.1093/jxb/eraa412>.

Chiozza, M. V., Burachik, M., & Miranda, P. V. (2020). Compositional analysis of soybean event IND-ØØ41Ø-5. *GM crops & food*, 11(3), 154-163.

CIMA (2015). 3ra Comunicación Nacional de Cambio Climático. Disponible en: <http://3cn.cima.fcen.uba.ar/>

Clothier, B. E., Green, S. R., Robinson, B. H., Thayalakumaran, T., Scotter, D. R., Vogeler, I., ... & Granel, T. (2008a). Contaminants in the rootzone: bioavailability, uptake and

transport, and their implications for remediation. *Developments in Soil Science*, 32, 633-655.

Clothier, B. E., Green, S. R., & Deurer, M. (2008b). Preferential flow and transport in soil: progress and prognosis. *European Journal of Soil Science*, 59(1), 2-13.

Confalone, A., Vilatte, C., Lázaro, L., Roca, N., Mestelan, S., Aguas, L., Navarro, M. & Sau, F. (2016). Parametrización del modelo CROPGRO-soybean y su uso como herramienta para evaluar el impacto del cambio climático sobre el cultivo de soja. *Revista de la Facultad de Ciencias Agrarias. Universidad Nacional de Cuyo*, 48(1), 49-64.

Correndo, A., Moro Rosso, L., Schwalbert, R., Hernandez, C., Bastos, L., Nieto, L., Holzworth, D., Ciampitti, I. (2022). *metrica: Prediction Performance Metrics*. R package version 2.0.0, <https://adriancorrendo.github.io/metrica/>  
<https://doi.org/10.5281/zenodo.6474101>

Dardanelli, J., Calmon, M., Jones, J., Andriani, J., Diaz, M., & Collino, D. (2003). Use of a crop model to evaluate soil impedance and root clumping effects on soil water extraction in three argentine soils. *Trans. ASABE* 46, 1265–1275. <https://doi.org/10.13031/2013.13946>.

Darder, M., Castiglioni, M., Andriulo, A., & Sasal, M. (2018). Análisis de la relación entre la conductividad hidráulica efectiva y la curva número bajo dos intensidades de lluvia. *Cuad. CURIHAM* 24, 1–10.

Dezar, C. A., Gago, G. M., González, D. H., & Chan, R. L. (2005). HaHB-4, a sunflower homeobox-leucine zipper gene, is a developmental regulator and confers drought tolerance to *Arabidopsis thaliana* plants. *Transgenic research*, 14, 429-440.

Dile, Y.T., & Srinivasan, R. (2014). Evaluation of cfsr climate data for hydrologic prediction in data-scarce watersheds: an application in the Blue Nile River Basin. *JAWRA J. Am. Water Resour. Assoc.* 50, 1226–1241. <https://doi.org/10.1111/jawr.12182>.

Doorenbos, J. & Kassam, A. M. (1979). Yield response to water. Irrigation and Drainage Paper 33, FAO, Rome, Italy.

Dufresne, J. L., Foujols, M. A., Denvil, S., Caubel, A., Marti, O., Aumont, O., ... & Vuichard, N. (2013). Climate change projections using the IPSL-CM5 Earth System Model: from CMIP3 to CMIP5. *Climate dynamics*, 40(9), 2123-2165.

Fehr, W.R., Caviness, C.E., Burmood, D.T., & Pennington, J.S. (1971). Stage of development descriptions for soybeans, glycine max (l.) merrill1. *Crop Sci.* 11, [cropsci1971.0011183X001100060051x](https://doi.org/10.1007/BF02611183).

Fehr, W. R., & Caviness, C. E. (1977). Stages of soybean development. Spec. Rep. 80. Iowa Agric. Home Econ. Exp. Stn., Iowa State Univ., Ames.

Fensterseifer, C.A., Streck, N.A., Baigorria, G.A., Timilsina, A.P., Zanon, A.J., Cera, J.C., & Rocha, T.S. (2017). On the number of experiments required to calibrate a cultivar in a crop model: the case of cropgro-soybean. *Field Crops Res.* 204, 146–152. <https://doi.org/10.1016/j.fcr.2017.01.007>.

Figarola, L. A., Ghera, F., Castro, R., & Ferraro, D. O. (2020). Automatización del modelo de simulación de cultivos DSSAT para evaluar el desempeño productivo bajo distintas

estrategias de manejo y escenarios ambientales. En *XII Congreso de AgroInformática (CAI 2020)-JAIIO 49 (Modalidad virtual)*.

Fuka, D.R., Walter, M.T., MacAlister, C., Degaetano, A.T., Steenhuis, T.S., & Easton, Z.M. (2014). Using the climate forecast system reanalysis as weather input data for watershed models. *Hydrol. Process.* 28, 5613–5623. <https://doi.org/10.1002/hyp.10073>.

Gijsman, A., Hoogenboom, G., Parton, W., & Kerridge, P. (2002). Modifying DSSAT crop models for low-input agricultural systems using a soil organic matter-residue module from CENTURY. *Agron. J.* 94, 462–474.

Giménez, V. D., Micheloud, J. R., & Maddonni, G. Á. (2018). Climatic constraints for the maize-soybean system in the humid subtropical region of Argentina. *Theoretical and Applied Climatology*, 134, 753-767.

Girard, M. A. (2020). Desarrollo de biotecnología agrícola en Argentina. El caso de la papa resistente a PVY y la soja tolerante a la sequía (HB4).

González, F. G., Capella, M., Ribichich, K. F., Curín, F., Giacomelli, J. I., Ayala, F., ... & Chan, R. L. (2019). Field-grown transgenic wheat expressing the sunflower gene HaHB4 significantly outyields the wild type. *Journal of Experimental Botany*, 70(5), 1669-1681.

González, F.G., Rigalli, N., Miranda, P.V., Romagnoli, M., Ribichich, K.F., Trucco, F., Portapila, M., Otegui, M.E., & Chan, R.L. (2020). An interdisciplinary approach to study the performance of second-generation genetically modified crops in field trials: a case study with soybean and wheat carrying the sunflower hahb4 transcription factor. *Front. Plant Sci.* 11, 178. <https://doi.org/10.3389/fpls.2020.00178>.

Grimm, S. S., Jones, J. W., Boote, K. J., & Hesketh, J. D. (1993). Parameter estimation for predicting flowering date of soybean cultivars. *Crop Science*, 33(1), 137-144.

Hall, A.J., & Richards, R.A. (2013). Prognosis for genetic improvement of yield potential and water-limited yield of major grain crops. *Field Crops Res.* 143, 18–33. <https://doi.org/10.1016/j.fcr.2012.05.014>.

Haun, W. J., Hyten, D. L., Xu, W. W., Gerhardt, D. J., Albert, T. J., Richmond, T., ... & Stupar, R. M. (2011). The composition and origins of genomic variation among individuals of the soybean reference cultivar Williams 82. *Plant physiology*, 155(2), 645-655.

Hernández, N., Soto, F., & Caballero, A. (2009). Modelos de simulación de cultivos: Características y usos. *Cultivos Tropicales*, 30(1), 00-00.

Hoogenboom, G., Porter, C., Boote, K., Shelia, V., Wilkens, P., Singh, U., White, J., Asseng, S., Lizaso, J., Moreno, L., Pavan, W., Ogoshi, R., Hunt, L., Tsuji, G., & Jones, J. (2019). The DSSAT crop modeling ecosystem. In: Boote, K. (Ed.), *Advances in Crop Modeling for a Sustainable Agriculture*. Burleigh Dodds Science Publishing, Cambridge, United Kingdom, pp. 173–216.

Huang, J., Gómez-Dans, J. L., Huang, H., Ma, H., Wu, Q., Lewis, P. E., ... & Xie, X. (2019). Assimilation of remote sensing into crop growth models: Current status and perspectives. *Agricultural and forest meteorology*, 276, 107609.

INDEC, 2022. Informes técnicos / Vol. 7, n° 39. Comercio exterior / Vol. 7, n° 4. ISSN 2545-6636.

J.,ha, P.K., Ines, A.V., & Singh, M.P. (2021). A multiple and ensembling approach for calibration and evaluation of genetic coefficients of cereals-maize to simulate maize phenology and yield in Michigan. *Environ. Modell. Softw.* 135, 104901 <https://doi.org/10.1016/j.envsoft.2020.104901>.

Johnson, M. V. V., MacDonald, J. D., Kiniry, J. R., Arnold, J., & Gassman, P. (2009). ALMANAC: A potential tool for simulating agroforestry yields and improving SWAT simulations of agroforestry watersheds. *International Agricultural Engineering Journal*, 18(1), 51.

Jones, P., Thornton, P., Díaz, W., & Wilkens, P. (2002). Marksim: a computer based tool that generates simulated weather data for crop modelling and risk assessment. CD-ROM Series, Cali: CIAT, doi:10.3109/9780203427583-32. Acceso al programa en <http://gisweb.ciat.cgiar.org/MarkSimGCM/>

Jones, J., Hoogenboom, G., Porter, C., Boote, K., Batchelor, W., Hunt, L., Wilkens, P., Singh, U., Gijsman, A., & Ritchie, J. (2003). DSSAT cropping system model. *Eur. J. Agron.* 235–265.

Jones, J.W., He, J., Boote, K.J., Wilkens, P., Porter, C., & Hu, Z. (2011). Estimating dssat cropping system cultivar-specific parameters using bayesian techniques, 365–393.

Jones, P. G., & Thornton, P. K. (2013). Generating downscaled weather data from a suite of climate models for agricultural modelling applications. *Agricultural Systems*, 114, 1-5.

Kantolic, A. G., Mercau, J. L., Slafer, G. A., & Sadras, V. O. (2007). Simulated yield advantages of extending post-flowering development at the expense of a shorter pre-flowering development in soybean. *Field Crops Research*, 101(3), 321-330.

Keating, B. A., Carberry, P. S., Hammer, G. L., Probert, M. E., Robertson, M. J., Holzworth, D., ... & Smith, C. J. (2003). An overview of APSIM, a model designed for farming systems simulation. *European journal of agronomy*, 18(3-4), 267-288.

Kemerer, A., Melchiori, R., & Albarenque, S. (2020). Información Agronómica para la Agricultura de Precisión generada en la EEA Paraná del INTA. *Electronic Journal of SADIO (EJS)*, 19(1), 33-48.

Kersebaum, K., Boote, K., Jorgenson, J., Nendel, C., Bindi, M., Frühauf, C., Gaiser, T., Hoogenboom, G., Kollas, C., Olesen, J., Rötter, R., Ruget, F., Thorburn, P., Trnka, M., & Wegehenkel, M. (2015). Analysis and classification of data sets for calibration and validation of agro-ecosystem models. *Environ. Modell. Softw.* 72, 402–417. <https://doi.org/10.1016/j.envsoft.2015.05.009>.

Kiniry, J. R., Williams, J. R., Gassman, P. W., & Debaeke, P. (1992). A general, process-oriented model for two competing plant species. *Transactions of the ASAE*, 35(3), 801-810.

Lamsal, A., Welch, S., Jones, J., Boote, K., Asebedo, A., Crain, J., Wang, X., Boyer, W., Giri, A., Frink, E., Xu, X., Gundy, G., Ou, J., & Arachchige, P.G. (2017). Efficient crop model

parameter estimation and site characterization using large breeding trial data sets. *Agric. Syst.* 157, 170–184. <https://doi.org/10.1016/j.agry.2017.07.016>.

Lin, F., Chen, X., & Yao, H. (2017). Evaluating the use of Nash-Sutcliffe efficiency coefficient in goodness-of-fit measures for daily runoff simulation with SWAT. *Journal of Hydrologic Engineering*, 22(11), 05017023.

Llovet, J. A. (2014). Balance hídrico del cultivo de soja *Glycine max* (L.) Merr. en suelos de diferente textura del norte bonaerense: ajuste de herramientas modelizadoras (Tesis de doctorado, Facultad de Ciencias Agrarias, Universidad Nacional de Rosario).

Ma, H., Malone, R.W., Jiang, T., Yao, N., Chen, S., Song, L., Feng, H., Yu, Q., & He, J. (2020). Estimating crop genetic parameters for dssat with modified pest software. *Eur. J. Agron.* 115, 126017 <https://doi.org/10.1016/j.eja.2020.126017>.

Malik, W., Isla, R., & Dechmi, F. (2019). *Gestión agronómica y medioambiental del regadío del Valle Medio del Ebro: evaluación de las buenas prácticas en el maíz* (No. ART-2019-115403).

Martínez, F. (2022). Impuesto inmobiliario rural segmentado y diferenciado: una respuesta justa para el agro santafesino. *El grito del Siglo XXI*, pp. 75-88, ISBN 978-987-48900-0-9. Economía Regional, Editorial Lux, Santa Fe, 2022.

Martínez Ruiz, A., López-Cruz, I. L., Ruiz-García, A., & Ramírez-Arias, A. (2012). Calibración y validación de un modelo de transpiración para gestión de riegos de jitomate (*Solanum lycopersicum* L.) en invernadero. *Revista mexicana de ciencias agrícolas*, 3(SPE4), 757-766.

Mattot, L. (2017). OSTRICH: an Optimization Software Tool, Documentation and User's Guide, Version 17.12.19.

Maydana, G., Romagnoli, M., Cunha, M., & Portapila, M. (2020). Integrated valuation of alternative land use scenarios in the agricultural ecosystem of a watershed with limited available data, in the pampas region of Argentina. *Sci. Total Environ.* 714, 136430 <https://doi.org/10.1016/j.scitotenv.2019.136430>.

Mercau, J., Dardanelli, J., Collino, D., Andriani, J., Irigoyen, A., & Satorre, E. (2007). Predicting on-farm soybean yields in the Pampas using CROPGRO-soybean. *Field Crops Res.* 100, 200–209.

Ministerio de Hacienda (2019). Presidencia de la Nación. Informes de cadenas de valor – Oleaginosas: Soja Septiembre 2019. ISSN 2525-0221.

Montico, S., & Di Leo, N. (2011). Sustentabilidad de diferentes modelos de uso de la tierra en unidades de paisaje de una cuenca del Sur de Santa Fe, Argentina. *Natura neotropicalis*, 1(42), 21-33.

Monzon, J., Sadras, V., Abbate, P., & Caviglia, O. (2007). Modelling management strategies for wheat–soybean double crops in the South-Eastern Pampas. *Field Crops Res.* 101, 44–52. <https://doi.org/10.1016/j.fcr.2006.09.007>.

- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Binger, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Trans. ASABE*, 50(3), 885–900.
- Moura da Silva, E.H.F., Boote, K.J., Hoogenboom, G., Gonçalves, A.O., Junior, A.S.A., & Marin, F.R., (2021). Performance of the csm-cropgro-soybean in simulating soybean growth and development and the soil water balance for a tropical environment. *Agric. Water Manag.* 252, 106929 <https://doi.org/10.1016/j.agwat.2021.106929>.
- NASA (2023). NASA Official: Paul Stackhouse, Jr., Ph.D. Version: 1.0 | Last Modified: 2020/02/19. <https://power.larc.nasa.gov/data-access-viewer/>
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting trough.1: A conceptual model discussion of principles. *J. Hydrol.*, 10(3), 282–290.
- Nath, A., Karunakar, A. P., Kumar, A., Yadav, A., Chaudhary, S., & Singh, S. P. (2017). Evaluation of the CROPGRO-soybean model (DSSAT v 4.5) in the Akola region of Vidarbha, India. *Ecology, Environment and Conservation*, 23, 153-159.
- Neitsch, S.L., Arnold, J.G., Kiniry, J.R., & Williams, J.R. (2011). Soil and water assessment tool — theoretical documentation — version 2009. Technical Report 406. Texas Water Resources Institute.,
- Nendel, C. (2014). MONICA: a simulation model for nitrogen and carbon dynamics in agro-ecosystems. *Novel Measurement and Assessment Tools for Monitoring and Management of Land and Water Resources in Agricultural Landscapes of Central Asia*, 389-405.
- Oña Meán, F. A. (2022). Evaluación de los impactos socioambientales en la producción de soja transgénica en Argentina (1990-2019) (Bachelor's thesis, PUCE-Quito).
- Ovando, G., Sayago, S., Salvaggiotti, F., & Bocco, M. (2017). Estimación del rendimiento de soja con datos de radiación solar de CERES. En IX Congreso Argentino de AgroInformática (CAI 2017)-JAIIO 46-CLEI 43 (Córdoba, octubre de 2017).
- Ovando, G., Sayago, S., & Bocco, M. (2018). Evaluating accuracy of DSSAT model for soybean yield estimation using satellite weather data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 138, 208-217.
- Papini, V., & Morinigo, R. (2020). Inserción internacional con valor agregado: experiencias exitosas de empresas biotecnológicas argentinas en los mercados asiáticos.
- Pedersen, P., Boote, K., Jones, J., & Lauer, J. (2004). Modifying the cropgro soybean model to improve predictions for the upper midwest. *Agron. J.* 96 <https://doi.org/10.2134/agronj2004.0556>.
- Pequeno, D. N. L., Ferreira, T. B., Fernandes, J. M. C., Singh, P. K., Pavan, W., Sonder, K., ... & Asseng, S. (2022). Wheat blast disease impact on global grain yield under climate change.
- Perondi, D., Boote, K., de Souza Nória Júnior, R., Mulvaney, M., Iboyi, J., & Fraise, C. (2022). Assessment of soybean yield variability in the southeastern u.s. with the calibration of genetic coefficients from variety trials using cropgro-soybean. *Agron. J.* 114, 1100–1114. <https://doi.org/10.1002/agj2.20995>.

- Pickering, N.B., Hansen, J.W., Jones, J.W., Wells, C.M., Chan, V.K., & Godwin, D.C. (1994). Weatherman: a utility for managing and generating daily weather data. *Agron. J.* 86, 332–337. <https://doi.org/10.2134/agronj1994.00021962008600020023x>.
- Präger, A., Boote, K.J., Munz, S., & Graeff-Honninger, S. (2019). Simulating growth and development processes of quinoa (*Chenopodium quinoa* Willd.): adaptation and evaluation of the CSM-CropGro model. *Agronomy* 9. <https://doi.org/10.3390/agronomy9120832>.
- Quansah, J. E., Welikhe, P., El Afandi, G., Fall, S., Mortley, D., & Ankumah, R. (2020). CROPGRO-soybean model calibration and assessment of soybean yield responses to climate change. *American Journal of Climate Change*, 9(03), 297.
- Queiroz, L. N. (2014). Transformação genética de soja [*Glycine max* (L.) Merrill] para expressão do gene HaHB11 relacionado à tolerância a estresses abióticos.
- Reinoso, L. G., Martinez, R. S., Otegui, M. E., Mercu, J., & Gutierrez, M. (2018). Rendimiento potencial de maíz en los valles de Norpatagonia: una aproximación desde los modelos de simulación.
- Ribichich, K.F., Chiozza, M., Avalos-Britez, S., Cabello, J.V., Arce, A.L., Watson, G., Arias, C., Portapila, M., Trucco, F., Otegui, M.E., & Chan, R.L. (2020). Successful field performance in warm and dry environments of soybean expressing the sunflower transcription factor hb4. *J. Exp. Bot.* 71, 3142–3156. <https://doi.org/10.1093/jxb/eraa064>.
- Richards, L. A., & Weaver, L. R. (1944). MOISTURE RETENTION BY SOME IRRIGATED SOILS AS. *Journal of Agricultural Research*, 69, 215.
- Richetti, J., Boote, K. J., Hoogenboom, G., Judge, J., Johann, J. A., & Uribe-Opazo, M. A. (2019). Remotely sensed vegetation index and LAI for parameter determination of the CSM-CROPGRO-Soybean model when in situ data are not available. *International Journal of Applied Earth Observation and Geoinformation*, 79, 110-115.
- Ritchie, J. (1998). Soil water balance and plant water stress. In: Gordon, Y., Hoogenboom, G., Thornton, P. (Eds.), *Understanding options for agricultural production*, vol. 7. Springer, Dordrecht, pp. 41–54.
- Ritchie, J., Porter, C., Judge, J., Jones, J.W., & Suleiman, A. (2009). Extension of an existing model for soil water evaporation and redistribution under high water content conditions. *Soil Sci. Soc. Am. J.* 73, 792–801.
- Rodríguez, O., Florido, R., Hernández, N., Soto, F., Jeréz, E. I., González, D., & Vázquez, J. R. (2021). Simulation of management strategies from the DSSAT model to increase the yields of a corn cultivar. *Cuban Journal of Agricultural Science*, 55(2).
- Romagnoli, M., Portapila, M., Rigalli, A., Maydana, G., Burgués, M., & García, C.M. (2017). Assessment of the SWAT model to simulate a watershed with limited available data in the Pampas region, Argentina. *Sci. Total Environ.* 596–597, 437–450. <https://doi.org/10.1016/j.scitotenv.2017.01.041>.
- Ruiz-Nogueira, B., Boote, K., & Sau, F. (2001). Calibration and use of cropgro-soybean model for improving soybean management under rainfed conditions. *Agric. Syst.* 68, 151–173. [https://doi.org/10.1016/S0308-521X\(01\)00008-7](https://doi.org/10.1016/S0308-521X(01)00008-7).

- Salmerón, M., Purcell, L.C., Vories, E.D., & Shannon, G. (2017). Simulation of genotype-by-environment interactions on irrigated soybean yields in the U.S. Midsouth. *Agric. Syst* 150, 120–129. <https://doi.org/10.1016/j.agsy.2016.10.008>.
- Saseendran, S.A., Nielsen, D.C., Ma, L., & Ahuja, L.R. (2010). Adapting cropgro for simulating spring canola growth with both rzwqm2 and dssat 4.0. *Agron. J.* 102, 1606–1621. <https://doi.org/10.2134/agronj2010.0277>.
- Satorre, E. H., & Andrade, F. H. (2021). Cambios productivos y tecnológicos de la agricultura extensiva argentina en los últimos quince años. *Cienc. Hoy*, 29(173), 19-27.
- Sau, F., Boote, K.J., & Ruíz-Nogueira, B. (1999). Evaluation and improvement of cropgrosoybean model for a cool environment in Galicia, Northwest Spain. *Field Crops Res.* 61, 273–291. [https://doi.org/10.1016/S0378-4290\(98\)00168-3](https://doi.org/10.1016/S0378-4290(98)00168-3).
- Saxton, K.E., & Rawls, W.J. (2006). Soil water characteristic estimates by texture and organic matter for hydrologic solutions. *Soil Sci. Soc. Am. J.* 70, 1569–1578.
- Sciarresi, C., Proctor, C., Haramoto, E. R., Lindsey, L. E., Carmona, G. I., Elmore, R., Everhart, S., Looker W., Marroquin Guzman, M., McMechan, J., Wehrbein J., Werle R. & Salmerón, M. (2020). Evaluating short-season soybean management adaptations for cover crop rotations with a crop simulation model. *Field Crops Research*, 250, 107734.
- Seibert, J., & McDonnell, J. J. (2002). On the dialog between experimentalist and modeler in catchment hydrology: Use of soft data for multicriteria model calibration. *Water Resources Research*, 38(11), 23-1.
- Servicio Meteorológico Nacional (2018). Aldeco, L. S., Domínguez, D. A., Garay, N., Herrera, N., Skansi, M. M., Stella, J. L., & Veiga, H. Informes *Breves del Clima - Febrero 2018* <http://hdl.handle.net/20.500.12160/679>
- Servicio Meteorológico Nacional (2019). Aldeco, L. S., Domínguez, D. A., Garay, N., Herrera, N., Skansi, M. M., Stella, J. L., & Veiga, H. Informes *El fenómeno El Niño – Oscilación del Sur (ENOS) - Enero 2019* <http://hdl.handle.net/20.500.12160/916>
- Severini, A. D., Álvarez Prado, S., Otegui, M. E., Vega, C. R. C., Zuil, S., Kavanová, M., ... & Miralles, D. J. (2019). Predicting soybean development with a simple photothermal dynamic algorithm.
- Shelia, V., Simunek, J., Boote, K., & Hoogenboom, G. (2018). Coupling dssat and hydrus-1d for simulations of soil water dynamics in the soil-plant-atmosphere system. *Journal of Hydrology and Hydromechanics* 66, 232–245. doi:10.1515/johh-2017-0055.
- Shukla, P. R., Skeg, J., Buendia, E. C., Masson-Delmotte, V., Pörtner, H. O., Roberts, D. C., ... & Malley, J. (2019). *Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems*.
- Sorrentino, A., & Thomasz, E. O. (2014). Incidencia del complejo sojero: implicancias en el riesgo macroeconómico.

- Steduto, P., Hsiao, T. C., Raes, D., & Fereres, E. (2009). AquaCrop - The FAO crop model to simulate yield response to water: I. Concepts and underlying principles. *Agronomy Journal*, 101(3), 426-437.
- Sztulwark, S., & Girard, M. (2016a). Estrategias nacionales de innovación en biotecnología agrícola. Implicancias para el MERCOSUR. *Gestión y Gerencia*, 10(3), 46-79.
- Sztulwark, S., & Girard, M. (2016b). Genetically modified seeds and the de-commodification of primary goods. *International Journal of Biotechnology*, 14(2), 132-150.
- Teixeira, W. W. R., Battisti, R., Sentelhas, P. C., de Moraes, M. F., & de Oliveira Junior, A. (2019). Uncertainty assessment of soya bean yield gaps using DSSAT-CM5-CROPGRO-Soybean calibrated by cultivar maturity groups. *Journal of Agronomy and Crop Science*, 205(5), 533-544.
- US Soil Conservation Service (1972). National Engineering Handbook. Section 4. Hidrology. US Government Printing Office, Washington, DC, p. 544.
- Van Vuuren, D. P., Edmonds, J., Kainuma, M., Riahi, K., Thomson, A., Hibbard, K., Hurtt, G. C., Kram, T., Krey, V., Lamarque, J.F., Masui, T., Meinshausen, M., Nakicenovic, Smith S. J., & Rose, S. K. (2011). The representative concentration pathways: an overview. *Climatic change*, 109(1), 5-31.
- Vélez-Pareja, I. (2003). *Decisiones empresariales bajo riesgo e incertidumbre*. Editorial Norma.
- Vettorello, C. I., Dardanelli, J. L., & Sereno, R. (2008). Modelo Cropgro en soja. Parte I: simulación del agua edáfica y producción del cultivo en la zona semiárida central de Córdoba. Reunión Argentina de Agrometeorología. 12. 2008 10 08-10, 8 al 10 de octubre de 2008. San Salvador de Jujuy. AR.
- Wallach, D., Makowski, D., Jones, J.W., & Brun, F. (2019). Chapter 13 - gene-based crop models. En: Wallach, D., Makowski, D., Jones, J.W., Brun, F. (Eds.), *Working with Dynamic Crop Models*, third ed. Academic Press, pp. 445–486. <https://doi.org/10.1016/B978-0-12-811756-9.00013-7>.
- Wang, F. E. N. G. X. I. A. N., Fraisse, C. W., Kitchen, N. R., & Sudduth, K. A. (2003). Site-specific evaluation of the CROPGRO-soybean model on Missouri claypan soils. *Agricultural Systems*, 76(3), 985-1005.
- Ward, A.D., Trimble, S.W., Burckhard, S.R., & Lyon, J.G. (2015). *Environmental Hydrology*, third ed. CRC Press.
- Warton, D. I., Wright, I. J., Falster, D. S., & Westoby, M. (2006). Bivariate line-fitting methods for allometry. *Biological reviews*, 81(2), 259-291.
- Watanabe, M., Suzuki, T., O'ishi, R., Komuro, Y., Watanabe, S., Emori, S., ... & Kimoto, M. (2010). Improved climate simulation by MIROC5: mean states, variability, and climate sensitivity. *Journal of Climate*, 23(23), 6312-6335.
- Williams, J. R., Jones, C. A., Kiniry, J. R., & Spanel, D. A. (1989). The EPIC crop growth model. *Transactions of the ASAE*, 32(2), 497-0511.

Willmott, C. J. (1981). On the validation of models. *Physical geography*, 2(2), 184-194.