

**Limitantes actuales y futuras de la productividad de maíz y soja en el Chaco Semiárido-Subhúmedo: un análisis mediante el uso de modelos y el análisis de datos de campo**

*Tesis presentada para optar al título de Doctor de la Universidad de Buenos Aires, Área Ciencias Agropecuarias*

**Lucía Casali**

Lic. en Cs. Biológicas - UBA - 2012

INBA CONICET UBA



**FAUBA**

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



## COMITÉ CONSEJERO

Director de tesis  
**Gerardo Rubio**  
Ing. agrónomo (UBA)  
Dr. en Cs. Agropecuarias (UBA)

Co-director  
**Juan Manuel Herrera**  
Ing. agrónomo (UBA)  
PhD (Swiss Federal Institute of Technology)

## JURADO DE TESIS

JURADO  
**Fernando Salvagiotti**  
Ing. Agrónomo (Universidad Nacional de Córdoba)  
Doctor of Philosophy (University of Nebraska-Lincoln)

JURADO  
**Ignacio Lorite Torres**  
Ing. Agrónomo (Universidad de Córdoba - España)  
Doctor Ingeniero Agrónomo (Universidad de Córdoba - España)

JURADO  
**Claudia Rosa Cecilia Vega**  
Ing. Agrónomo (Universidad Nac. de Tucumán)  
Doctor en Ciencias Agropecuarias (Universidad Nac. de Mar del Plata)

Fecha de defensa de la tesis: 5 de julio de 2023

**Declaración**

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

**Publicaciones derivadas de la tesis**

- Casali, L., Rubio, G. and Herrera, J.M., 2018. Drought and temperature limit tropical and temperate maize hybrids differently in a subtropical region. *Agronomy for sustainable development*, 38(5), 49.
- 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. *Agronomy Journal*, 113(2), 1381-1393.
- Casali, L., Herrera, J.M., & Rubio, G. 2022. Resilient soybean and maize production under a varying climate in the semi-arid and sub-humid Chaco. *European Journal of Agronomy*, 135, 126463.

## ÍNDICE GENERAL

INDICE GENERAL	v
INDICE DE CUADROS	vii
INDICE DE FIGURAS	ix
ABREVIATURAS	xiii
RESUMEN	xvi
ABSTRACT	xviii
CAPÍTULO 1: Introducción general	1
1.1. La expansión agrícola en el Chaco Semiárido-Subhúmedo	2
1.2. Características climáticas del Chaco Semiárido-Subhúmedo	4
1.3. La agricultura en el Chaco Semiárido-Subhúmedo	5
1.4. El clima y la agricultura	8
1.5. Modelos de simulación agronómica	12
1.6. Objetivo general	15
1.7. Objetivos específicos	15
1.8. Hipótesis	16
CAPÍTULO 2: La sequía y la temperatura limitan diferencialmente a híbridos tropicales y templados de maíz en una región subtropical	18
2.1. Introducción	19
2.2. Materiales y métodos	21
2.2.1. Área de estudio	21
2.2.2. Datos de campo	22
2.2.3. Datos ambientales de entrada para los modelos	23
2.2.4. Modelo empírico: modelos lineales mixtos simples y múltiples	25
2.2.5. Modelo mecanístico: CERES- <i>Maize</i>	28
2.2.6. Análisis estadístico	31
2.3. Resultados y discusión	32
2.3.1. Resultados de la base de datos principal	32
2.3.2. Modelos simples	33
2.3.3. Modelos múltiples	37
2.3.4. Modelo mecanístico	44
2.4. Conclusión	47
2.5. Material suplementario	49
CAPÍTULO 3: Determinantes ambientales y de manejo del rendimiento de soja en una región subtropical	51
3.1. Introducción	52
3.2. Materiales y métodos	56
3.2.1. Área de estudio	56
3.2.2. Datos de campo	56
3.2.3. Variables predictoras del modelo	58
3.2.4. Análisis estadístico y selección de modelos	59
3.3. Resultados y discusión	61
3.3.1. Descripción general de la variabilidad de la base de datos	61

3.3.2. Modelos lineales simples de efectos mixtos	62
3.3.3. Modelos lineales múltiples de efectos mixtos	70
3.4. Conclusión	74
3.5. Material suplementario	75
<b>CAPÍTULO 4: Producción resiliente de soja y maíz bajo un clima variable en el Chaco Semiárido y Subhúmedo</b>	<b>76</b>
4.1. Introducción	77
4.2. Materiales y métodos	81
4.2.1. Área de estudio	81
4.2.2. Modelos de cultivos	81
4.2.3. Modelos mixtos	83
4.3. Resultados	87
4.3.1. Caracterización climática	87
4.3.2. Soja	90
4.3.3. Maíz	95
4.4. Discusión	99
4.4.1. Impacto en el rendimiento de soja y maíz	99
4.4.2. Implicancias futuras	104
4.5. Conclusión	108
<b>CAPÍTULO 5: Modelización de las respuestas del maíz y la soja al cambio climático y la degradación del suelo en una región de Sudamérica</b>	<b>110</b>
5.1. Introducción	111
5.2. Materiales y métodos	114
5.2.1. Área de estudio	114
5.2.2. Calibración y validación de los modelos de cultivo	114
5.2.3. Modelización de cultivos y escenarios climáticos	116
5.2.4. Suelos	118
5.2.5. Estrategias de manejo de los cultivos	119
5.2.6. Análisis estadísticos	120
5.3. Resultados	120
5.3.1. Escenarios de cambio climático	120
5.3.2. Maíz	122
5.3.3. Soja	126
5.3.3.1. Nivel base de CO <sub>2</sub>	129
5.3.3.2. Niveles elevados de CO <sub>2</sub>	131
5.4. Discusión	132
5.5. Conclusiones	139
5.6. Material suplementario	140
<b>CAPÍTULO 6: Conclusiones generales</b>	<b>141</b>
<b>BIBLIOGRAFÍA</b>	<b>151</b>

## ÍNDICE DE CUADROS

Cuadro 2.1. Estructura general de los modelos múltiples de efectos mixtos, para predecir el rendimiento del maíz en el Chaco Subhúmedo y Semiárido, con ejemplos seleccionados. Los modelos difieren en los predictores incluidos y en la relación aditiva o interactiva entre los predictores. Se llegó a un modelo final (# 2) mediante un proceso de selección por pasos según el criterio de información de Akaike (AIC).	38
Cuadro S2.1. Variables consideradas en el análisis con modelos mixtos dentro de cada uno de los cinco grupos de variables analizadas.	49
Cuadro S2.2. Variables más explicativas del rendimiento de maíz dentro de cada uno de los cinco grupos de variables analizadas con modelos simples. *Ninguna variable dentro del grupo “Suelo” fue un buen predictor del rendimiento de maíz.	50
Cuadro 3.1. Estructura general de los modelos múltiples de efectos mixtos, para predecir el rendimiento de la soja en el Chaco Semiárido y Subhúmedo, mostrada con algunos ejemplos. Los modelos difieren en los predictores incluidos y en las relaciones interactivas o aditivas entre ellos. Se arribó al modelo final (# 1) a través del proceso de selección de modelos por pasos de acuerdo al Criterio de Información de Akaike (AIC).	71
Cuadro 4.1. Datos analíticos de los dos perfiles de suelo utilizados en las simulaciones.	81
Cuadro 4.2. Estructura general de algunos de los modelos lineales mixtos planteados para predecir la anomalía del rendimiento de soja simulado por el modelo CROPGRO-Soybean en una localidad del Chaco Semiárido (Quimili) y una del Chaco Subhúmedo (Las Breñas), a partir de series climáticas históricas de los períodos 1994-2014 y 1967-2014 para cada localidad, respectivamente. Los modelos difieren en los predictores incluidos y en las relaciones (aditivas o interactivas) entre ellos. Los modelos se encuentran ordenados del mejor al peor ajuste según el criterio de información de Akaike (AIC). En negrita se resaltan los dos mejores modelos (diferencia de AIC < 2).	95
Cuadro 4.3. Estructura general de algunos de los modelos lineales mixtos planteados para predecir la anomalía del rendimiento de maíz simulado por el modelo CERES-Maize en una localidad del Chaco Semiárido (Quimili) y una del Chaco Subhúmedo (Las Breñas), a partir de series climáticas históricas de los períodos 1994-2014 y 1967-2014 para cada localidad, respectivamente. Los modelos difieren en los predictores incluidos y en las relaciones (aditivas o interactivas) entre ellos. Los modelos se encuentran ordenados del mejor al peor ajuste según el criterio de información de Akaike (AIC).	99
Cuadro 5.1. Datos analíticos de los tres perfiles de suelo utilizados en las simulaciones (se remarcan en negrita las características que se modificaron en los suelos degradados respecto al no degradado).	119
Cuadro 5.2. Valores de F y significancia del rendimiento simulado de maíz y soja en función de los escenarios climáticos (E), los suelos (S), los tratamientos de riego (R) y los niveles de CO <sub>2</sub> (C).	123
Cuadro 5.3. Valores de F y significancia del rendimiento simulado de maíz en función	124

de los escenarios climáticos, los suelos, y las fechas de siembra. Las simulaciones fueron realizadas en secano, y con el nivel base de CO<sub>2</sub> (360 ppm).

Cuadro 5.4. Valores de F y significancia del rendimiento simulado de soja en función de los escenarios climáticos, los suelos, y el riego. Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1961-2010, 2015-2039 RCP 4.5, 2075-2099 RCP 4.5, 2015-2039 RCP 8.5 y 2075-2099 RCP 8.5, respectivamente). 126

Cuadro 5.5. Valores de F y significancia del rendimiento simulado de soja en función de los escenarios climáticos, los suelos, y las fechas de siembra. Las simulaciones fueron realizadas en secano, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/ RCP 4.5, 2075-2099/ RCP 4.5, 2015-2039/ RCP 8.5 y 2075-2099/ RCP 8.5, respectivamente). 130

Cuadro S5.1. Valores de los coeficientes genéticos del cultivar A 8000 antes de ser calibrados, y luego de la calibración con datos de campo utilizando el modelo CROPGRO-Soybean. 140

Cuadro S5.2. Valores observados y simulados de días desde siembra a floración (R1), a madurez fisiológica (R7) y del rendimiento (kg ha<sup>-1</sup>, 0% humedad), por el modelo CROPGRO Soybean, utilizando el cultivar A 8000 calibrado. Se presenta la comparación estadística entre valores observados y simulados a través del RMSE (*Root Mean Square Error*) y de su expresión como porcentaje del promedio observado (RMSE normalizado o n-RMSE), del coeficiente de determinación R<sup>2</sup>, de la diferencia porcentual (diferencia en la media simulada vs la observada, expresada como porcentaje de la media observada) y del índice de ajuste d. Se indica además el número de datos utilizados en cada caso (N). 140



## ÍNDICE DE FIGURAS

Figura 1.1. El área de estudio (marcada con el recuadro de línea punteada) se extiende entre el Chaco Subhúmedo y el Chaco Semiárido, entre las provincias de Chaco y de Santiago del Estero. En línea punteada se muestran las isohietas.	2
Figura 1.2. Precipitación promedio anual entre 1901 y 2011, en el Chaco Argentino Semiárido y el Subhúmedo (Ricard et al., 2015)	4
Figura 2.1. a. Localización de la zona de estudio en el Chaco Subhúmedo y Semiárido y distribución espacial de los datos de las explotaciones agrícolas incluidos en el análisis. b. Campo de maíz en la etapa de tres hojas.	23
Figura 2.2. Relaciones entre el rendimiento de maíz (14,5% de contenido de humedad) y la precipitación durante todo el ciclo del cultivo (a), diciembre (b), febrero (c) y abril (d). Los datos se obtuvieron de 792 lotes de producción de maíz en el Chaco Subhúmedo y Semiárido. Las rectas corresponden a regresiones lineales entre el rendimiento y la precipitación.	36
Figura 2.3. a) Relación entre el rendimiento (14,5% de contenido de humedad) de los híbridos de maíz tropical y templado y la precipitación durante febrero. b) Relación entre el rendimiento de maíz y la temperatura máxima media de enero a abril (TEA), influenciada por un índice de estrés térmico (G35). Los datos se obtuvieron de 792 lotes de producción de maíz en el Chaco Subhúmedo y Semiárido. Las líneas corresponden a regresiones lineales entre las variables.	40
Figura 2.4. a) Relación entre el rendimiento (14,5% de contenido de humedad) del híbrido de maíz templado DK-747 simulado por CERES- <i>Maize</i> y el rendimiento observado en lotes ubicados en el Chaco Subhúmedo y Semiárido. La línea de puntos representa la relación 1:1. b) Relación entre los rendimientos simulados del híbrido de maíz templado DK-747 por CERES-Maíz y las precipitaciones durante febrero (mm). Las rectas azul y roja representan la regresión lineal y la regresión límite del cuantil del 95%, respectivamente.	46
Figura 3.1. Distribución de los 2840 lotes agrícolas que conformaron la base de datos de soja. El tamaño del círculo amarillo indica la cantidad de lotes en cada localidad del Chaco Semiárido y Subhúmedo, cuyo rango fue 5-443 lotes.	57
Figura 3.2. Relación entre el rendimiento en grano de la soja ( $\text{kg ha}^{-1}$ ) y los años con soja en los 5 años previos a la siembra. La línea es la regresión lineal ajustada a los datos.	63
Figura 3.3. Relación entre el rendimiento de grano de soja ( $\text{kg ha}^{-1}$ ) y la precipitación efectiva entre octubre y abril (mm) afectada por la cantidad de años con soja en los cinco años previos a la siembra. Las rectas representan las regresiones lineales de los datos.	66
Figura 3.4. Relación entre el rendimiento de grano de soja ( $\text{kg ha}^{-1}$ ) y los días con temperaturas máximas mayores a $35^{\circ}\text{C}$ entre el día 50 y 100 desde la siembra (días). La recta representa la regresión lineal de los datos.	68

- Figura 3.5. Relación entre el rendimiento de grano de soja ( $\text{kg ha}^{-1}$ ) y la temperatura máxima media entre diciembre y abril ( $^{\circ}\text{C}$ ) afectada por los días con temperaturas máximas mayores a  $35^{\circ}\text{C}$  entre el día 50 y 100 desde la siembra (D35). Las rectas representan las regresiones lineales de los datos. 70
- Figura S3.1. Frecuencia absoluta de los grupos de madurez de soja en la base de datos. 75
- Figura 4.1. De arriba a abajo: promedio de temperatura máxima, temperatura mínima, radiación solar y precipitación acumulada durante el ciclo del cultivo (enero-abril) en Quimilí entre 1995 y 2015 (derecha) y en Las Breñas entre 1968 y 2015 (izquierda). En línea punteada se indican los valores medios en cada caso. 89
- Figura 4.2. Rendimiento simulado por los modelos CROPGRO-Soybean y CERES-Maize para soja (arriba) y maíz (abajo) respectivamente, en Quimilí (izquierda) y Las Breñas (derecha). La media se indica en línea punteada. 90
- Figura 4.3. Anomalía del rendimiento de la soja simulada por CROPGRO-Soybean en función de a) la anomalía de la temperatura máxima entre enero y abril; b) la anomalía de los días con temperatura máxima superior a  $35^{\circ}\text{C}$  entre los días 50 y 100 después de la siembra; c) la anomalía de la precipitación acumulada entre diciembre y abril; y d) la anomalía del estrés hídrico entre la siembra y la cosecha. La anomalía se representa como una línea recta de la regresión lineal entre ambas variables y el valor  $R^2$  correspondiente. Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimilí. Los triángulos indican los ceros, que no fueron considerados en el análisis de regresión. La correlación fue altamente significativa ( $p < 0,001$ ). Las líneas punteadas indican la anomalía con valor 1. La anomalía se calculó en relación con los valores medios correspondientes a 21 y 48 años de datos en Quimilí y Las Breñas, respectivamente. Ejemplo: un valor de 1 en el eje x indica que en ese año la temperatura máxima coincidió con la media histórica y un valor de 1,1 indica que fue un 10% superior. 91
- Figura 4.4. Estrés hídrico entre siembra y cosecha simulado por CROPGRO-Soybean en función de las precipitaciones acumuladas entre diciembre y abril (izquierda), la temperatura máxima entre enero y abril (medio) y los días con temperatura máxima por encima de  $35^{\circ}\text{C}$  entre los días 50 y 100 desde la siembra (derecha). Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimilí. Se presentan las rectas de las regresiones lineales entre las variables y las correspondientes pendientes. Las tres correlaciones fueron altamente significativas ( $p < 0.001$ ). 93
- Figura 4.5. Anomalía del rendimiento del grano de maíz simulado por CERES-Maize en función de a) la anomalía de la temperatura máxima durante la fase de llenado del grano; b) la anomalía del cociente fototérmico (Q) entre la siembra y la cosecha; c) la anomalía del número de días con temperatura máxima superior a  $30^{\circ}\text{C}$  entre los días 50 y 100 desde la siembra; d) la anomalía de la relación entre la precipitación acumulada y la evapotranspiración acumulada según Hargreaves entre los días 0 y 50 desde la siembra. Se presenta la recta de la regresión lineal entre ambas variables y el valor de  $R^2$  correspondiente. Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimilí. La correlación fue altamente significativa ( $p <$  97

0,005). Las líneas punteadas indican la anomalía con valor 1. La anomalía se calculó en relación con los valores medios correspondientes a 21 y 48 años de datos en Quimilí y Las Breñas, respectivamente.

Figura 4.6. Anomalía\* de los días entre siembra y cosecha de maíz, simulado por el modelo CERES-Maize, en función de la anomalía de la temperatura máxima durante el llenado del grano (derecha); y anomalía del rendimiento de maíz simulado por CERES-Maize, en función de la anomalía de los días entre siembra y cosecha (izquierda). Se presentan las rectas de la regresión lineal entre las variables y los correspondientes valores de  $R^2$ . Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimilí. Ambas correlaciones fueron altamente significativas ( $p < 0.001$ ).

\*La anomalía fue calculada en relación a los valores medios correspondientes a los 21 y 48 años de datos en Quimilí y Las Breñas respectivamente.

Figura 5.1. Temperatura media mensual (a) y precipitación acumulada mensual (b) en Quimilí, bajo cinco escenarios climáticos generados por el ensamble multimodelo: pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5).

Figura 5.2. Rendimiento simulado de maíz en Quimilí por el modelo CERES-Maize en tres suelos (no degradado, moderadamente degradado y degradado), bajo dos tratamientos de riego (secano y riego) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, y con el nivel base de  $CO_2$  (360 ppm) y con los niveles aumentados (550, 425, 525, 450 and 800 ppm) en los escenarios 1986-2010, 2015-2039/RCP 4.5, 2075-2099/RCP 4.5, 2015-2039/RCP 8.5 y 2075-2099/RCP 8.5. Las barras representan el error estándar.

Figura 5.3. Largo del ciclo del cultivo simulado por el modelo CERES-Maize (a) y el modelo CROPGRO-Soybean (b), en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, en secano, con el nivel base de  $CO_2$  (360 ppm), y en el suelo no degradado. Las barras representan el error estándar. En el test de comparación de medias para cada cultivo,  $a < b < c$  y la misma letra indica que no hay diferencias significativas entre los escenarios climáticos a un nivel de 0,05 usando el test de Tukey.

Figura 5.4. Rendimiento simulado de maíz por el modelo CERES-Maize bajo tres fechas de siembra (10 y 31 de diciembre y 20 de enero) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas en secano, y con el nivel base de  $CO_2$  (360 ppm). Se muestra el rendimiento simulado en el suelo no degradado. Las barras representan el error estándar.

Figura 5.5. Rendimiento simulado de soja por el modelo CPROGRO-Soybean en tres suelos (no degradado, moderadamente degradado y degradado), bajo dos tratamientos de riego (secano y riego) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5

y 8.5)). Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/ RCP 4.5, 2075-2099/ RCP 4.5, 2015-2039/ RCP 8.5 y 2075-2099/ RCP 8.5, respectivamente). Las barras representan el error estándar.

Figura 5.6. Rendimiento simulado de soja por el modelo CPROGRO-*Soybean* en tres fechas de siembra (10 y 31 de diciembre y 20 de enero) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas en seco, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/ RCP 4.5, 2075-2099/ RCP 4.5, 2015-2039/ RCP 8.5 y 2075-2099/ RCP 8.5, respectivamente). Se muestra el rendimiento simulado en el suelo no degradado. Las barras representan el error estándar. 130

**Abreviaturas**

AACREA = Asociación Argentina de Consorcios Regionales de Experimentación Agrícola

*ACF* = Función de auto-correlación

AIC = Criterio de información de Akaike

AS = Cantidad de años con antecesor soja

C = Niveles de CO<sub>2</sub>

d. = (suelo) Degradado

D35<sub>50-100</sub> = Días con temperaturas máximas mayores a 35°C entre el día 50 y 100 desde la siembra

DDS = Días después de la siembra

*DSSAT* = *Decision Support System for Agrotechonology Transfer*

E = Escenarios climáticos

ENSO = El Niño Oscilación Sur

ETP<sub>0-50</sub> = Evapotranspiración potencial entre 0 y 50 días desde la siembra

F = Fecha de siembra

G35 = Gradosacumulados de temperatura máxima por encima de 35°C

*GCM* = Modelos de circulación general

GD = Grados Día

GM = Grupo de madurez

INTA = Instituto Nacional de Tecnología Agropecuaria

IPCC = Panel Intergubernamental del Cambio Climático

IUVM = Índice Único de Validación de Modelos

m.d. = (suelo) Moderadamente degradado

*ML* = Máxima verosimilitud

mod. degradado = (suelo) Moderadamente degradado

n.d. = (suelo) No degradado

$P_{0-50}$  = Precipitación acumulada entre 0 y 50 días desde la siembra

PF = Precipitaciones durante el mes de febrero

POA = Precipitaciones efectivas entre octubre y abril

Q = Cociente fototérmico

R = Tratamientos de riego

$R^2$  Cond. =  $R^2$  condicional

$R^2$  Marg. =  $R^2$  marginal

RCP = Trayectorias de Concentración Representativas

Rend. = rendimiento en grano

*RMSE = Root Mean Square Error*

S = Suelos

SigSE = Sistema de información geográfica de Santiago del Estero

*SRES = Special Report on Emissions Scenarios*

TDA = Temperatura máxima media entre diciembre y abril

TEA = Temperatura máxima media de enero a abril

TH = Tipo de híbrido de maíz

VIF = Factor de Inflación de la Varianza

$\Delta D_{30_{50-100}}$  = Anomalía del número de días con temperatura máxima por encima de 30°C entre los días 50 y 100 desde la siembra

$\Delta D_{35_{50-100}}$  = Anomalía del número de días con más de 35°C durante el periodo 50-100 días desde la siembra

$\Delta EH_{s-c}$  = Anomalía del estrés hídrico entre siembra y cosecha

$\Delta P_{12-4}$  = Anomalía de la precipitación de diciembre a abril

$\Delta p_p/etp_{0-50}$  = Anomalía de la relación entre las precipitaciones acumuladas y la evapotranspiración acumulada según Hargreaves, entre los días 0 y 50 desde la siembra

$\Delta Q_{s-c}$  = Anomalía del cociente fototermal entre siembra y cosecha

$\Delta \text{Rend Sim}_i$  = Anomalía del rendimiento simulado

$\Delta TM_{1-4}$  = Anomalía de la temperatura máxima promedio de enero a abril

$\Delta TM_{\text{llenado}}$  = Anomalía de la temperatura máxima durante el llenado del grano

$\epsilon$  = error

## Resumen

En el Chaco Semiárido-Subhúmedo, con el avance de la frontera agrícola a expensas de vegetación natural, se establecieron sistemas productivos bajo un elevado riesgo hídrico y térmico. El objetivo general fue evaluar el rol de variables ambientales y de manejo sobre el rendimiento de maíz y soja en secano, utilizando mediciones de campo y modelos de simulación. Del análisis de bases de datos con modelos mixtos, las precipitaciones durante febrero surgieron como un determinante principal del rendimiento del maíz y mostró que los híbridos tropicales tendieron a resistir mejor las altas temperaturas y el estrés térmico, y los templados el déficit hídrico. Para soja se identificó un umbral de temperatura máxima (35°C) y de tolerancia de eventos de estrés por calor (14 días) a partir de los cuales se afectó fuertemente el rendimiento. Hubo un marcado efecto negativo de la siembra continua de soja y una alta relación entre el rendimiento y las precipitaciones en pre-siembra y durante el cultivo. En ambos cultivos se encontró un efecto significativo de la interacción temperatura  $\times$  estrés por calor sobre los rendimientos. Al analizar la variabilidad climática histórica, los rendimientos simulados presentaron una elevada variabilidad interanual. Los resultados sugieren que las estrategias que conservan el agua del suelo son importantes, especialmente en soja, donde las anomalías en las precipitaciones durante los cuatro primeros meses tras la siembra fueron un importante predictor del rendimiento. En maíz, la anomalía de la temperatura máxima durante el llenado fue de suma relevancia en el rendimiento. Para mitigar el efecto de la temperatura, la principal práctica que surgió es retrasar las fechas de siembra en maíz. La degradación del suelo exacerbó los efectos negativos del cambio climático sobre el rendimiento de maíz, mientras que el aumento del CO<sub>2</sub> tuvo un marcado efecto positivo en el rendimiento simulado de soja.



**Palabras clave:** Cambio climático- Variabilidad climática- Modelos de simulación- Modelos Mixtos- Soja- Maíz- Regiones semiáridas y subhúmedas- Sequía- Estrés por calor- Conservación de suelos

**Abstract**

In the Semiarid-Subhumid Chaco, with the advance of the agricultural frontier at the expense of natural vegetation, production systems were established under high water and thermal risk. The general objective was to evaluate the role of environmental and management variables on rainfed maize and soybean yields, using field measurements and simulation models. From the analysis of mixed-model databases, rainfall during February emerged as a main determinant of maize yield and showed that tropical hybrids tended to resist better to high temperatures and heat stress, and temperate hybrids to resist water deficit. For soybean, a threshold of maximum temperature (35°C) and tolerance of heat stress events (14 days) was identified, above which yield was strongly affected. There was a marked negative effect of continuous sowing of soybean and a high relationship between yield and rainfall in pre-sowing and during cultivation. A significant effect of the temperature  $\times$  heat stress interaction on yields was found in both crops. When analyzing historical climate variability, simulated yields showed high interannual variability. The results suggest that strategies that conserve soil water are important, especially in soybean, where rainfall anomalies during the first four months after planting were an important predictor of yield. In maize, the maximum temperature anomaly during filling was highly relevant to yield. To mitigate the effect of temperature, the main practice that emerged was to delay planting dates in maize. Soil degradation exacerbated the negative effects of climate change on corn yield, while increased CO<sub>2</sub> had a marked positive effect on simulated soybean yield.

**Key words:** Climate change- Climate variability- Simulation models- Mixed models- Soybean- Maize- Semi-arid and sub-humid regions- Drought- Heat stress- Soil conservation

# CAPÍTULO 1

## Introducción general

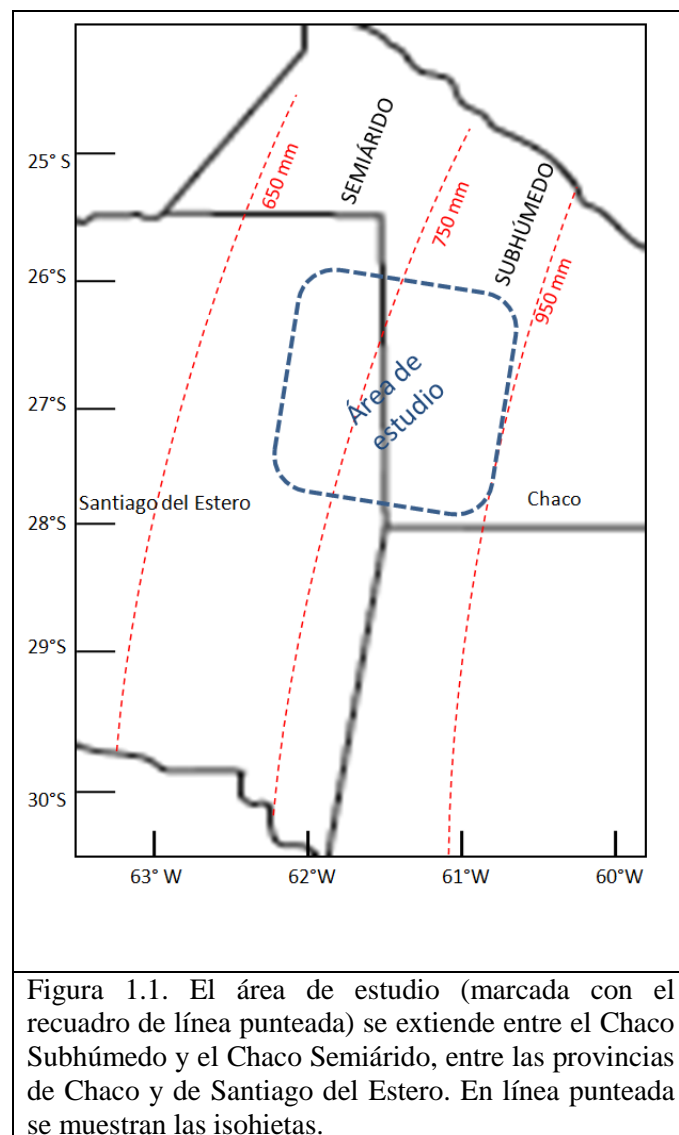
### 1.1. La expansión agrícola en el Chaco Semiárido-Subhúmedo

El Gran Chaco Americano es una zona biogeográfica de más de 1.000.000 km<sup>2</sup> compartida por Argentina, Bolivia y Paraguay. Junto con el Amazonas constituyen el área boscosa de mayor superficie de América del Sur y una de las de mayor diversidad ambiental y biológica del planeta (The

Nature Conservancy, 2005). Distintos autores han utilizado criterios variados para delimitar subregiones en el Gran Chaco. De acuerdo a criterios climáticos (principalmente el gradiente de aridez Este-Oeste) y geomorfológicos, algunos autores han subdividido al Gran Chaco en las subregiones: Chaco Húmedo, Chaco Subhúmedo, Chaco Semiárido, Chaco Árido y Chaco Serrano (Red Agroforestal Chaco Argentino, 1999; Naumann, 2006; Adámoli et al., 2011;

REGATTA-PNUMA, 2013). El Chaco Semiárido Argentino es la

subregión de mayor extensión territorial. Ocupa el Oeste de Chaco y Formosa, gran parte de Santiago del Estero, el Este de Salta y Tucumán y parte del Norte de Córdoba. Al Este de esta subregión, se extiende el Chaco Subhúmedo (Figura 1.1).



Los disturbios generados por las actividades antrópicas, han generado en el Gran Chaco una de las tasas más altas de pérdida de vegetación natural a escala global (CIAT, 2014; Vallejos et al., 2014). El Chaco Semiárido y el Chaco Subhúmedo, en particular, han experimentado en las últimas décadas una fuerte expansión agrícola (Boletta, 2001; Morello et al., 2005; Torella et al., 2005; Torella & Adámoli, 2005; Boletta et al., 2006), lo que implicó un incremento porcentual del área bajo cultivos, entre 1977 y 2010, de 922% en el Chaco Semiárido y 142% en el Subhúmedo (Adámoli et al., 2011). Extensas áreas de vegetación natural, principalmente bosques de quebracho (*Schinopsis* spp. y *Aspidosperma quebracho blanco*) y algarrobo (*Prosopis* spp.) y estepas gramíneas, han sido desmontadas para ser destinadas al cultivo de soja y, en menor medida, a algodón y otros cultivos. El proceso de expansión agrícola hacia el Chaco Semiárido - antes considerado marginal - se vio favorecido por la sucesión de años sin sequías extremas, el incremento en los precios internacionales de la soja, la adopción de la siembra directa que mejora el balance hídrico del suelo y la consolidación del arrendamiento como sistema de uso de la tierra (Torella et al., 2005; Manuel Navarrete et al., 2009; Adámoli et al., 2011; Goldfarb & Zoomers, 2013; Ricard et al., 2015).

El impacto de la expansión agrícola en el Chaco ha sido estudiado por varios autores (e.g. Adámoli et al., 1990; Coria & Lorenz, 2004; Paruelo et al., 2005; Paruelo et al., 2006; Goldfarb & Zoomers, 2013, Ricard et al., 2015). A través del análisis de imágenes satelitales, Paruelo et al. (2005) identificaron cientos de miles de hectáreas de bosque que fueron reemplazadas por agricultura en el Chaco Semiárido. La incorporación de actividades agrícolas en áreas naturales de esta región ha disminuido el tenor orgánico (Osinaga et al., 2017; Villarino et al., 2017) y de nitrógeno (Albanesi et al., 2001) de sus suelos y ha generado condiciones predisponentes para su erosión, así como, en algunos

casos ha alterado la regulación de los ciclos del agua (Giménez et al., 2020) y los nutrientes (Casas, 2007; Manuel Navarrete et al., 2009).

## 1.2. Características climáticas del Chaco Semiárido-Subhúmedo

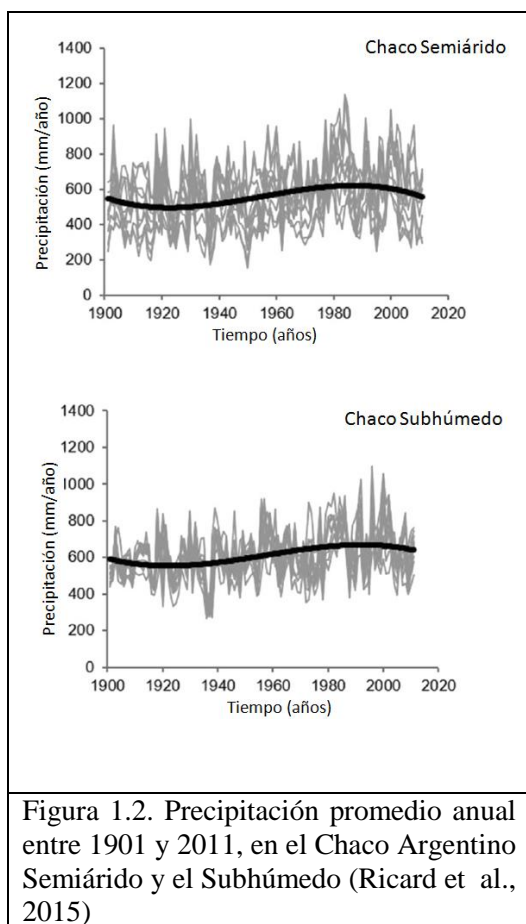


Figura 1.2. Precipitación promedio anual entre 1901 y 2011, en el Chaco Argentino Semiárido y el Subhúmedo (Ricard et al., 2015)

El clima del Chaco Subhúmedo es subtropical subhúmedo, con precipitaciones anuales de entre 750 y 950 mm (1901-2011). El del Chaco Semiárido es subtropical semiárido, con áreas que presentan las máximas temperaturas absolutas del continente (se han registrado temperaturas de hasta 47°C) y un promedio anual de lluvias de entre 500 y 750 mm (1901-2011) (Naumann, 2006). Si bien ambas regiones presentan precipitaciones con una alta variabilidad interanual, en el Chaco Semiárido la variabilidad es de mayor magnitud (Figura 1.2, Ricard et al., 2015). En ambas zonas, las lluvias presentan una

concentración de más del 75% en el período estival (Figura 1.2). La serie histórica indica que el período más húmedo abarcó desde 1960 hasta 2000, con valores promedios de precipitación de alrededor de 600 mm (Figura 1.2).

En el área bajo estudio, el régimen pluviométrico permite hacer agricultura de secano, aún con serios riesgos de sequías y estrés por altas temperaturas. Son frecuentes las limitaciones al crecimiento y productividad de los cultivos por déficit hídrico, a pesar que la estación lluviosa coincide con la de altas temperaturas (Giménez et al., 2015; Perez-

Carrera et al., 2008). El incremento de las precipitaciones en las últimas décadas (Figura 1.2) y el corrimiento de las isohietas hacia el Oeste impulsaron el avance agrícola (Hoffmann, 1989; Bonino, 2006; Serio & Zalazar, 2012; Ricard et al., 2015, Barros et al., 2015). Sin embargo, si este incremento se revirtiera, se podrían disparar procesos de desertificación de difícil reversibilidad y muchas áreas podrían presentar vulnerabilidad a la erosión (Paruelo et al., 2005; Oesterheld, 2008; Perez-Carrera et al., 2008). Por lo tanto, el desarrollo agrícola está condicionado por el régimen pluviométrico y térmico y demanda una adecuada planificación y una correcta gestión de los recursos hídricos (Gorleri, 2005).

### 1.3. La agricultura en el Chaco Semiárido-Subhúmedo

La soja es el cultivo más difundido en la zona, seguida por el maíz y el algodón (Giménez et al., 2015). Otros cultivos como girasol, sorgo y trigo (considerado de mayor riesgo en la zona), se cultivan en menor medida. Las prácticas agronómicas empleadas para producir soja y maíz son, en general, las utilizadas en la Región Pampeana. Cabe aclarar que por ejemplo la fertilización es una práctica habitual en la Región Pampeana, pero no en la Región Chaqueña. Esto no es llamativo, dado que la incorporación de la agricultura basada en soja es relativamente reciente y que los arrendatarios y nuevos propietarios provienen mayoritariamente de esa región. Sin embargo, las notorias diferencias ambientales entre las dos regiones, determinan la necesidad de comprobar localmente la efectividad de estas prácticas y, eventualmente, realizar las adaptaciones correspondientes. Comprobar localmente hace referencia a analizar, con bases de datos locales, la relación entre variables ambientales y de manejo sobre el rendimiento de los cultivos de maíz y soja en la región de estudio de esta tesis. Según Moscuza et al. (2003) la variabilidad climática y las actividades agropecuarias no sustentables, intensificaron los procesos de degradación



ambiental en la zona. Una evaluación para todo el país determinó que la Región Chaqueña presenta las mayores brechas de rendimiento de maíz y una de las dos mayores brechas de rendimiento de soja (Aramburu-Merlos et al., 2015). Es necesario, entonces, generar información local que permita diseñar prácticas agronómicas que compatibilicen una alta productividad de los cultivos con la preservación de los recursos naturales, principalmente el suelo. Como ocurre en otras áreas donde la disponibilidad de agua es limitada y variable, las estrategias de manejo deberían conducir a maximizar el aprovechamiento de cada unidad de lluvia caída y minimizar el riesgo utilizando esquemas productivos de bajo costo (Sadras et al., 2003). Distintos análisis a nivel de toda la región del Chaco mostraron que la productividad de los cultivos está asociada a la disponibilidad de agua (Calviño & Monzón, 2009; Adámoli et al., 2011; Madias et al., 2021). Sin embargo, estudios a campo muestran que esta relación es más débil cuando se la analiza a nivel de explotación individual (e.g. Baldi et al., 2015). Diferencias en prácticas de manejo podrían explicar esta discrepancia entre el nivel regional y local y su discernimiento podría permitir identificar estrategias de producción y manejo agronómico de utilidad ante escenarios climáticos futuros. En las agencias de extensión locales, se remarca la importancia de priorizar prácticas que contribuyan con la acumulación de agua en el suelo, como la siembra directa y las rotaciones que incorporen maíz o sorgo. La rotación de cultivos, además de aumentar el rendimiento, permite la producción sostenida debido a aumentos en la materia orgánica del suelo, mejoras en las propiedades físicas y la interrupción del ciclo de malezas y patógenos, los cuales pueden ser responsables de la depresión del rendimiento con monocultivo continuo (Karlen et al., 1994, 2006). El INTA Las Breñas (<http://intainforma.inta.gov.ar/>) también remarca la importancia que tiene el control de las malezas en los sistemas agrícolas del Chaco, al igual que la cobertura del suelo con

rastrajo, que contribuye a reducir el efecto de las altas temperaturas y la evaporación de agua del suelo. Una adaptación de las prácticas agrícolas en la zona, surgió con el atraso de las fechas de siembra (en relación a la región pampeana) hacia diciembre tanto en maíz como en soja. En el caso del maíz, Maddonni (2012) señala que este retraso en la fecha de siembra permitiría mejorar el balance de agua en el período crítico. Sin embargo en estos casos, se corre el riesgo de que el cultivo sufra estrés térmico en los períodos reproductivos (Maddonni, 2012). Una estrategia ante esto sería utilizar híbridos tropicales, ya que han mostrado un mejor comportamiento que los templados ante episodios de estrés por calor (Rattalino Edreira et al., 2011). También podrían extenderse las siembras hacia principios de enero, ya que disminuyen las temperaturas máximas (Maddonni, 2012). En el caso del cultivo de soja, el INTA Las Breñas también propone extender las fechas de siembra desde las primeras semanas de diciembre hasta los primeros días de enero, y combinar variedades de diferentes ciclos, para escapar de los estreses hídricos y térmicos. La Red de Ensayos de Evaluación de Cultivares de Soja del NEA (Aapresid; INTA-EEA Las Breñas), indicó que la variabilidad en el rendimiento en los ensayos, estuvo principalmente explicada por el ambiente, luego por la interacción genotipo x ambiente, y por último por los efectos de los genotipos. Esto resalta la importancia de la caracterización de los ambientes, además de la diversificación en la elección de cultivares, según su comportamiento en los diferentes ambientes. En diferentes viajes a la zona de estudio, se recogieron evidencias de los técnicos locales acerca de que los esquemas productivos basados en doble cultivo no se consideran apropiados en la zona por su alto consumo de agua (Eduardo Martínez Quiroga, com. pers.), aunque algunos reportes proponen la adopción de secuencias de cultivo flexibles que se puedan modificar en función de la disponibilidad inicial de agua (Giménez et al., 2015). El doble cultivo anual puede tener consecuencias en función del posible costo-beneficio

productivo pero también del ecosistema (Ricard et al., 2015). Al evitar esquemas productivos que utilizan más agua para reducir el riesgo climático, se pierde la oportunidad de obtener una mayor producción en años con mayores precipitaciones y el exceso de agua no utilizado representa un riesgo ambiental como consecuencia de procesos de erosión, inundación y salinización (Giménez et al., 2015). En conclusión, queda planteada aquí la hipótesis de que las condiciones ambientales de la zona bajo estudio indican que aquellas estrategias de manejo que contribuyan a la diversificación (e.g. flexibilidad en cuanto a fechas de siembra, rotaciones de cultivos y genotipos) serían beneficiosas para contrarrestar el riesgo climático.

#### 1.4. El clima y la agricultura

El estudio de la respuesta del crecimiento de los cultivos a la variabilidad climática histórica permite conocer su sensibilidad a los estreses hídricos y térmicos a los que se encuentran expuestos en la zona de estudio. De acuerdo a Dinse (2009), la variabilidad climática es el modo en que el clima fluctúa por encima o por debajo de un valor medio a largo plazo. La Organización Meteorológica Mundial sugiere un período de 30 años para calcular el valor medio (OMM, 2017). Para estudiar el impacto de la variabilidad climática sobre los cultivos, es importante tener en cuenta en qué momento de su ciclo ocurren los estreses ambientales. Cuando un estrés afecta la tasa de crecimiento del cultivo durante el período crítico para la generación del rendimiento, la productividad se verá afectada. En maíz, este período se ubica en pre y post floración, y en soja, desde el “inicio de formación de vainas” (R3) y “máximo tamaño de semilla” (R6) (Monzón et al., 2021). Hanft & Jones (1986) observaron que el llenado del grano en maíz puede verse seriamente afectado con temperaturas superiores a 35°C. Por otro lado, las altas temperaturas en antesis, provocan

disminución del número de granos (Schoper et al., 1987). Rattalino Edreira & Otegui (2012) en experimentos a campo en FAUBA encontraron que el efecto del golpe de calor en el rendimiento de maíz era mayor cuando ocurría alrededor de floración que durante el llenado del grano, y que era mayor en híbridos templados que tropicales. Molino (2011), en experimentos a campo en Córdoba, evaluó los efectos de breves episodios de estrés térmico y su interacción con déficit hídrico en soja, durante la etapa crítica de generación de vainas y encontró que la alta temperatura con secano redujo el rendimiento en un 45% respecto al control regado.

Diversos autores, utilizando bases de datos climáticos históricos y modelos de simulación, estudiaron la asociación entre la variabilidad climática histórica y la productividad agrícola en diferentes zonas del mundo (e.g. Bell & Fischer, 1994; Lal et al., 1999; Lobell et al., 2005; Lobell et al., 2013). Por ejemplo, Lal et al. (1999), utilizando el modelo CROPGRO, encontraron que la productividad de soja en India era menor en aquellos años donde el cultivo sufría estrés térmico. En los años con estrés hídrico en los estadios críticos del cultivo, se afectaba negativamente el crecimiento y el desarrollo, y en consecuencia el rendimiento. Lobell et al. (2013), utilizando APSIM y 46 años de datos climáticos en Estados Unidos, encontraron una respuesta negativa y marcada del rendimiento de maíz a la acumulación de temperaturas mayores a 30°C, y una respuesta relativamente débil a las precipitaciones. Existen diversos reportes de que la variabilidad climática interanual en la Región Chaqueña estaría asociada a la influencia del ENSO (Magrin et al., 2007; Patino & Vicentini, 2007; Tiedemann, 2011) cuya intensidad y frecuencia se vería aumentada por el cambio climático global (Clealand et al., 2007). Magrin et al. (2007) indican que en Sudamérica, los rendimientos varían de acuerdo a la variabilidad climática. Por ejemplo en Perú, durante El Niño, se han observado

acortamientos del ciclo de crecimiento en algodón (Torres et al., 2001), así como un aumento en la incidencia de enfermedades en maíz y trigo (Torres et al., 2001) y en trigo en Brasil y Argentina (Del Ponte et al., 2004), con consecuencias sobre la productividad. Si bien, como ya se mencionó, existen numerosos estudios sobre el efecto de la variabilidad climática histórica sobre la productividad de soja y maíz en diversas regiones del mundo, existen pocos estudios de este tipo en la zona de estudio de esta tesis.

Por otro lado, el cambio climático es el cambio continuo (aumento o disminución) a largo plazo (decenios o más) del promedio de las condiciones del tiempo (e.g. temperatura promedio) o de su rango (Dinse, 2009). Puede deberse a procesos internos naturales o a forzamientos externos (e.g. modulaciones de los ciclos solares) o a cambios antropogénicos persistentes de la composición de la atmósfera o del uso del suelo (IPCC, 2014). La disponibilidad total de agua y la distribución de las precipitaciones en el año son dos factores significativamente modificados por el cambio climático (Jury & Vaux, 2013). En este trabajo de tesis se tuvo en cuenta al Quinto Informe del IPCC (IPCC, 2014) (actualmente se encuentra disponible el Sexto), que indica que la temperatura media anual global aumentó  $0,6 \pm 0,2$  °C en el siglo XX, y se proyecta que aumente desde  $0,3$  hasta  $4,8$  °C para el año 2100, según el escenario SRES (por sus siglas en inglés, Special Report on Emissions Scenarios) considerado. Este informe indica que en las regiones secas actuales es probable que la frecuencia de las sequías aumente al final del siglo XXI. Estas predicciones muestran una tendencia al calentamiento y la desecación en las regiones semiáridas, lo cual generará una disminución en la disponibilidad de agua y requerirá una gestión integrada de los recursos hídricos. En relación con los principales cultivos (i.e. trigo, arroz y maíz), las proyecciones señalan que, de no mediar cambios drásticos en el manejo o la genética, el cambio climático tendrá un impacto negativo en los rendimientos

(Jones & Thornton, 2003; Malla, 2008; Schlenker & Roberts, 2009; Lobell et al., 2011), aunque podría haber ciertos cultivos en localidades de Argentina que resulten beneficiadas por el cambio climático, por ejemplo la soja (e.g. Asseng et al., 2013). Las proyecciones indican que el cambio climático hará que aumente progresivamente la variabilidad interanual de los rendimientos de los cultivos en muchas regiones del mundo. Esos impactos ocurrirán en un contexto de rápido crecimiento de la demanda de cultivos. Dentro de las estrategias de adaptación al cambio global, se mencionan frecuentemente la introducción de cultivares mejor adaptados a las nuevas condiciones climáticas (mayores temperaturas y sequías), el cambio de cultivos y/o modificaciones en el manejo de los sistemas agrícolas (Tilman et al., 2001; Smith & Skinner, 2002; Travasso et al., 2009).

Las perspectivas específicas para el Gran Chaco sugieren una alta vulnerabilidad al cambio climático, principalmente debido a su conformación geológica y localización geográfica (REGATTA -PNUMA, 2013). Se prevé, según el escenario climático A2 del IPCC (REGATTA -PNUMA, 2013) una ligera tendencia hacia el ascenso (pero no significativa) en la precipitación media anual hacia el año 2040, con un predominio de incremento en las lluvias invernales y una disminución en las estivales, en comparación con el período 1961-1990. Esta última tendencia es más marcada en las provincias de Argentina que forman parte del Gran Chaco. En cuanto a la temperatura media anual, el informe prevé un aumento significativo de 1,2°C para la década 2031-2040. Respecto a las temperaturas mínimas, se prevé un marcado aumento para el período 2011-2040. En estos casos, las provincias de Argentina que forman parte del Gran Chaco muestran una tendencia similar a toda la región.

Respecto al CO<sub>2</sub>, el IPCC predice que alcance valores, para el 2030, 2050 y 2080, de 429, 478 y 559 ppm CO<sub>2</sub> bajo el escenario B2 y de 451, 532 y 698 ppm CO<sub>2</sub> bajo el

escenario A2, respectivamente. El efecto del aumento del CO<sub>2</sub> sobre la productividad depende del cultivo y de las características climáticas de la región de estudio (Murgida et al., 2014). Algunos trabajos prevén que su efecto será positivo, ya que incrementa la eficiencia fotosintética y la eficiencia en el uso del agua de los cultivos. Este efecto es de mayor magnitud en cultivos C3 como la soja (e.g. Travasso et al., 2006; Magrin et al., 2007). Por otra parte, Long et al. (2005) indican que se estaría sobreestimando su efecto benéfico, especialmente en soja. Otros trabajos indican que la reducción del rendimiento de maíz por el aumento de la temperatura, no es compensada por el aumento de la concentración de CO<sub>2</sub> (Bassu et al., 2014). En las provincias de Chaco y Santiago del Estero, se esperaría que el rendimiento del cultivo de soja aumente con el incremento del CO<sub>2</sub>, mientras que la reducción del rendimiento en maíz por mayores temperaturas, no sería compensada por el aumento del CO<sub>2</sub> (Murgida et al., 2014).

Considerando la gran importancia que tiene en la actualidad la agricultura en la región y su sustentabilidad a largo plazo, es importante identificar el manejo más adecuado, teniendo en cuenta el impacto que las tendencias climáticas tuvieron sobre los sistemas agrícolas y las posibles adaptaciones frente a las tendencias futuras.

### 1.5. Modelos de simulación agronómica

Los modelos de simulación agronómica constituyen una herramienta valiosa para evaluar el efecto sobre los cultivos de la combinación de un número de situaciones o tratamientos que sería muy costoso abarcar a través de experimentos de campo (Jones et al., 2003; Alton, 2013). Permiten extender el alcance de resultados experimentales y formular nuevas hipótesis de trabajo. Además de generar escenarios específicos, estos modelos permiten medir la probabilidad y la incertidumbre asociada a esos escenarios y determinar

en forma cuantitativa el riesgo asumido al adoptar potenciales respuestas frente a dichos escenarios (Dzotsi et al., 2013).

DSSAT (por sus siglas en inglés: Decision Support System for Agrotechnology Transfer) es una plataforma que agrupa a un conjunto de submodelos que permiten simular el crecimiento y desarrollo de cultivos, integrando información de suelos, clima, cultivos y manejo. Permite simular la producción de cultivos, considerando el clima, factores genéticos, el carbono, nitrógeno y agua del suelo, y el manejo para un año o para una serie de años (Jones et al., 2003). DSSAT, permite simular la secuencia de cultivos en una serie de años, de modo tal que se pueden elaborar escenarios para predecir el efecto a largo plazo de una determinada variable sobre el crecimiento, desarrollo y rendimiento de un cultivo (Li et al., 2015). Este programa fue utilizado satisfactoriamente en muchos trabajos para evaluar distintas rotaciones de cultivos (e.g. Kumar et al., 2012; Araya et al., 2017). También permiten evaluar el impacto de tecnologías en distintos escenarios climáticos, históricos o pronosticados, y sobre diferentes suelos. Asimismo, ayudan a comprender por qué una tecnología es o no efectiva y a construir hipótesis para mejorar el manejo agronómico. El modelo CERES-Maize y el CROPGRO- Soybean fueron calibrados y evaluados para diferentes condiciones argentinas a nivel experimental y de lote, con errores de estimación relativamente bajos (e.g. Guevara & Meira, 1995; Meira & Guevara, 1995; Travasso & Magrin, 2001; Mercau et al., 2007; Monzon et al., 2007; Monzon et al., 2012; Caviglia et al., 2013; Aramburu-Merlos et al., 2015).

Los modelos incluidos en DSSAT fueron desarrollados en regiones templadas, en las cuales han sido evaluados y utilizados satisfactoriamente en un amplio rango de condiciones de suelo y de clima. Rosenzweig et al. (2014) sugieren que en regiones de latitudes medias los modelos pueden presentar ciertas incertezas debido a los efectos de



altas temperaturas, limitaciones para simular representativamente el ciclo del nitrógeno y el uso de protocolos de simulación inadecuados. Sin embargo, diversos trabajos también han evaluado y utilizado estos modelos en regiones tropicales y subtropicales, muchas de ellas con características climáticas similares a las de la zona de estudio de esta tesis. El resultado de la evaluación de la capacidad de los modelos en simular el crecimiento, desarrollo y rendimiento de maíz y de soja bajo estas condiciones, ha sido satisfactorio, al menos en la mayoría de los trabajos reportados. Por ejemplo, Maytin et al. (1995), Conde et al. (1997) y Jones & Thornton (2003), utilizaron el modelo CERES-Maize para evaluar el efecto del cambio climático en maíz en ambientes tropicales en Venezuela, en México y en ambientes tropicales y subtropicales de África y América Latina, respectivamente. Phillips et al. (1998) obtuvieron resultados satisfactorios al utilizar el modelo CERES-Maize en Zimbabwe (clima subtropical), para evaluar la asociación entre la variabilidad climática y el rendimiento simulado del cultivo de maíz. En otro trabajo en una región subtropical de Sudáfrica (Malawi), observaron una alta capacidad del modelo DSSAT en simular el rendimiento de maíz bajo diferentes manejos agrícolas y en respuesta al cambio climático (Ngwira et al., 2014). Tojo Soler et al. (2007) evaluaron el modelo CERES-Maize en una región subtropical de Brasil para simular el crecimiento, desarrollo y rendimiento de 4 híbridos de maíz y poder evaluar estrategias de manejo. El resultado de la evaluación fue satisfactorio, con valores de n-RMSE menores al 15%. Bathia et al. (2008) obtuvieron resultados satisfactorios al evaluar la capacidad de CROPGRO-Soybean para simular el crecimiento, desarrollo, rendimiento y balance de agua en India peninsular y central (región subtropical). Banterng et al. (2010) utilizaron el modelo CROPGRO-Soybean en Tailandia (ambiente tropical) para determinar estrategias óptimas de manejo. El resultado de la evaluación del modelo en general fue aceptable. Las desviaciones que encontraron

entre rendimientos observados y simulados las adjudicaron a que los cultivos pudieron haber estado afectados por enfermedades, plagas y malezas, que no son tenidas en cuenta en las simulaciones. Aramburu-Merlos et al. (2015) utilizaron los modelos CERES y CROPGRO, para estimar rendimientos potenciales en Argentina, incluyendo la localidad de Las Breñas (Chaco Subhúmedo). Araya et al. (2017) evaluaron la capacidad de los modelos de DSSAT en simular fenología, biomasa, rendimiento y evapotranspiración de 3 cultivos (maíz, trigo y sorgo) en un ambiente semiárido, obteniendo valores de n-RMSE menores al 20%.

La influencia de la variabilidad interanual y espacial en las simulaciones no fue cuantificada apropiadamente en estudios previos en regiones subtropicales, ya que estos trabajos fueron evaluaciones globales donde no se consideró la variación proveniente de distintos suelos, esquemas de manejo y campañas agrícolas. Por lo tanto, teniendo en cuenta esto, la extensa utilidad de los modelos y los antecedentes mencionados anteriormente, resulta importante continuar evaluándolos en regiones tropicales y subtropicales, como la zona de estudio de esta tesis.

#### 1.6. Objetivo general

Evaluar el rol de variables ambientales y de manejo sobre las producciones de maíz y soja en secano en el Chaco Semiárido-Subhúmedo, utilizando mediciones de campo, aproximaciones estadísticas y modelos de simulación.

#### 1.7. Objetivos específicos

- 1) Identificar variables ambientales y de manejo que determinan la productividad de maíz y soja en la Región Chaqueña mediante análisis de bases de datos recogidos en lotes de producción.
- 2) Calibrar, evaluar y utilizar el modelo de simulación agronómica DSSAT para maíz y soja en el área de estudio.
- 3) Estudiar el impacto de la variabilidad climática de las últimas décadas sobre la productividad de los cultivos de soja y de maíz en la zona de estudio.
- 4) Evaluar el impacto del cambio climático (utilizando proyecciones climáticas) sobre la productividad de maíz y soja en el área de estudio.
- 5) Identificar estrategias de producción que contribuyan a la sustentabilidad de la producción agrícola de la región.

#### 1.8. Hipótesis

- 1) La alta variabilidad interanual en los niveles de productividad agrícola en el Chaco Semiárido-Subhúmedo es principalmente una consecuencia de la variabilidad climática y puede ser reducida mediante la diversificación de los cultivos, los genotipos y en las prácticas de manejo, a saber:
  - a) Tanto en maíz como en soja, la extensión de las fechas de siembra desde principios de diciembre hasta los primeros días de enero es una estrategia favorable para evitar los estreses hídricos y térmicos.
  - b) En maíz, los híbridos tropicales presentan un mejor comportamiento ante altas temperaturas, mientras que híbridos templados presentan un mejor comportamiento ante la escasez de agua.

c) Los cultivos en rotación presentan mayores rendimientos que en monocultivo, además de resultar una práctica agrícola sostenible.

d) La fertilización nitrogenada en maíz, si bien no es una práctica habitual en la zona, tiene un efecto positivo en el rendimiento.

2) Los modelos CERES y CROPGRO pueden simular adecuadamente el rendimiento de los cultivos en la zona de estudio, con valores de n-RMSE (RMSE normalizado) de entre el 10% y el 20%, teniendo en cuenta las condiciones climáticas de la zona de estudio, y las limitaciones de los modelos.

3) a) El aumento de la temperatura consecuencia del cambio climático, provocará disminuciones en el rendimiento de maíz y de soja debido principalmente a una reducción en la duración del ciclo del cultivo.

b) La magnitud del efecto del aumento de la temperatura será mayor en maíz que en soja.

c) El aumento del CO<sub>2</sub> compensará la disminución del rendimiento en soja (por el aumento de la temperatura).

d) En maíz la disminución del rendimiento por mayores temperaturas, no será compensada por el aumento del CO<sub>2</sub>.

# CAPÍTULO 2

## El estrés hídrico y la temperatura limitan diferencialmente a híbridos tropicales y templados de maíz en una región subtropical <sup>1</sup>

<sup>1</sup>El contenido de este capítulo fue publicado en Casali, L., Rubio, G. and Herrera, J.M., 2018.

Drought and temperature limit tropical and temperate maize hybrids differently in a subtropical region. *Agronomy for sustainable development*, 38(5): 49.

## 2.1. Introducción

En Argentina, la producción de maíz (*Zea mays* L.) se concentraba principalmente en la Pampa Húmeda (Lavado y Taboada 2009). Sin embargo, en las últimas décadas se ha extendido a otras regiones, previamente consideradas marginales e inadecuadas para su cultivo. Entre ellas, el Chaco semiárido y subhúmedo fueron epicentros de una expansión agrícola que se vio favorecida por los cambios en la tenencia de la tierra (Goldfarb y van der Haar 2016). La expansión agrícola también fue promovida por el aumento en la precipitación anual (aproximadamente 18%) ocurrido en la última década (Ricard et al. 2015) y la mejora en la eficiencia de uso del agua por la adopción de la siembra directa (Piquer-Rodríguez et al. 2015). Actualmente, el maíz está siendo cada vez más adoptado por los agricultores locales, y se espera que continúe su expansión (Giménez et al. 2015). Evaluaciones recientes demostraron que estas regiones tienen las mayores brechas de rendimiento para maíz en Argentina (41% de rendimiento potencial limitado por agua) (Aramburu Aramburu-Merlos et al. 2015). La situación actual requiere identificar las principales limitaciones para la productividad del maíz, minimizar el riesgo climático, y mejorar las prácticas de manejo teniendo en cuenta el suelo, el clima, y los genotipos (Andrade et al. 2017). También resulta crítico maximizar la productividad de las tierras agrícolas existentes dada la alta tasa de deforestación en la región (Vallejos et al. 2015).

Los agricultores locales suelen adaptar las fechas de siembra de octubre a principios de diciembre para reducir el riesgo de sequía. Al atrasar las fechas de siembra, el maíz se encuentra con menores restricciones en el balance de agua durante el periodo reproductivo, el cual es crítico para la determinación del rendimiento. Sin embargo, este retraso incrementa el riesgo de que el cultivo se vea afectado por estrés térmico durante los periodos reproductivos (Edreira y Otegui 2012; Maddonni 2012). De acuerdo al trabajo de

Maddonni (2012) en la zona de Las Breñas la fecha óptima de siembra sería el 1ro diciembre, por lo que retrasar las fechas de siembra hacia diciembre permitiría reducir el riesgo de sequía. Al atrasar las fechas de siembra, el maíz se encuentra con menores restricciones en el balance de agua durante el periodo reproductivo, el cual es crítico para la determinación del rendimiento. Sin embargo, este retraso incrementa el riesgo de que el cultivo se vea afectado por estrés térmico durante los periodos reproductivos. De acuerdo a Maddonni (2012), el balance entre ambos fenómenos determina esa fecha óptima arriba mencionada. Además, las modificaciones en las prácticas de manejo como las fechas de siembra, sin duda tienen implicaciones en cuanto al genotipo más adecuado a utilizar. Optimizar las estrategias de manejo del maíz en esta región es un desafío debido a las pocas experiencias e investigaciones previas al respecto. Por lo tanto, es necesario generar información localmente válida para el diseño de prácticas agronómicas que compatibilicen la alta productividad de los cultivos, con un impacto ambiental mínimo o nulo.

Los modelos representan herramientas valiosas para el diseño de prácticas agronómicas, ya que permiten evaluar la combinación de un número elevado de variables o tratamientos que serían muy difíciles y llevarían mucho tiempo de abordar mediante experimentos de campo (Jones et al. 2003). CERES-*Maize* es un modelo mecanicista que integra información de suelos, climas, cultivos y manejos, para evaluar diferentes combinaciones de prácticas de producción (Jones et al. 2003). Este modelo fue evaluado y calibrado en regiones templadas de Argentina, mostrando errores de estimación bajos (e.g., Brisson et al. 2001). Por el contrario, en el momento de realizar este trabajo no se encontraban informes del desempeño de CERES-*Maize* en el área específica del interés de esta tesis, por lo que evaluación crítica previa a su utilización es necesaria, dado que las predicciones de estos modelos en áreas subtropicales pueden presentar ciertos sesgos (e.g.

Ray et al. 2015). Teniendo en cuenta que la calibración de modelos mecanicistas requiere una extensa colección de datos de campo (Lobell et al. 2003), el uso de modelos empíricos para analizar datos existentes representa una alternativa para obtener información en menos tiempo. Los modelos empíricos permiten a los investigadores conceptualizar hipótesis, generalizar relaciones, y brindar explicaciones válidas de los problemas de interés (Burnham et al. 2011). Se pueden derivar modelos con mayor poder explicativo a partir de modelos más simples y ser testeados para aceptar o rechazar explicaciones alternativas (Kirwan et al. 2009). Los modelos lineales de efectos mixtos son herramientas estadísticas apropiadas cuando las bases de datos están desbalanceadas y/o los datos tienen una estructura jerárquica, es decir cuando no cumplen con el supuesto de independencia (Smith et al. 2005).

Los objetivos de este trabajo fueron (i) determinar las principales restricciones climáticas y de manejo que explican la variabilidad en los rendimientos de maíz en el Chaco Semiarido y Subhúmedo, (ii) determinar si los modelos mecanicistas y empíricos pueden ser combinados para identificar restricciones en la productividad del maíz, y (iii) identificar características genotípicas con potencial de aliviar los efectos de las limitaciones climáticas identificadas.

## 2.2. Materiales y métodos

### 2.2.1. Área de estudio

La evaluación se realizó en dos regiones del Gran Chaco conocido como el Chaco subhúmedo y el semiárido (Adámoli et al. 2011). Estas dos regiones cubren una gran proporción de las provincias argentinas del norte de Santiago del Estero y Chaco (Fig. 2.1).



Además, estas regiones presentan una de las tasas más altas de deforestación de América del Sur, causada por la expansión de la agricultura, promovida por mayores precios agrícolas y cambios en la tenencia de la tierra (Vallejos et al. 2015). En 2016, el área sembrada con maíz fue de 661560 ha en Santiago del Estero y 166150 ha en Chaco.

El Chaco subhúmedo y semiárido presentan rangos de precipitación anual (1901-2011) de 750 a 950 mm y de 500 a 750 mm, respectivamente. La precipitación anual sigue un régimen monzónico, con mayores precipitaciones en verano (diciembre a marzo) que en invierno (junio a septiembre). En esta región se han registrado las temperaturas máximas absolutas más altas de Sudamérica (Naumann 2006), y cada año, los cultivos de verano como el maíz, se ven expuestos a temperaturas superiores a 30°C durante las etapas vegetativas tardías y las etapas reproductivas, sufriendo con frecuencia episodios de estrés por calor. Los suelos agrícolas son principalmente Haplustoles y Argiustoles.

#### 2.2.2. Datos de campo

Los datos de producción de maíz se obtuvieron un 85% de lotes de producción agrícola y un 15% de ensayos comparativos de rendimientos. Los datos de las fincas fueron recolectados por una asociación de agricultores (AACREA: Asociación Argentina de Consorcios Regionales de Experimentación Agrícola) mientras que los datos de evaluación de genotipos provienen de dos fuentes diferentes: (i) una red oficial de evaluación de genotipos de maíz del INTA y (ii) una evaluación realizada por una empresa de semillas (Don Mario S.A., Chacabuco, Argentina).

La base de datos consolidada incluyó datos de 792 lotes de producción y de ensayos de evaluación de genotipos durante cinco campañas agrícolas (2010/11, 2011/12, 2012/13, 2013/14 y 2014/15) en cinco localidades del Chaco Semiárido y 14 del Chaco Subhúmedo

(Fig. 2.1). El set de datos incluyó el rendimiento de grano de maíz (a humedad comercial, es decir 14,5%) en cada lote y diferentes variables sobre características de los campos, tales como manejo previo (e.g. años en que el lote estuvo cultivado, años bajo siembra directa y cultivos en rotación) y manejo del cultivo (e.g. híbrido de maíz, fecha de siembra y cosecha, densidad de siembra, aplicación de fertilizantes y medidas de protección del cultivo).

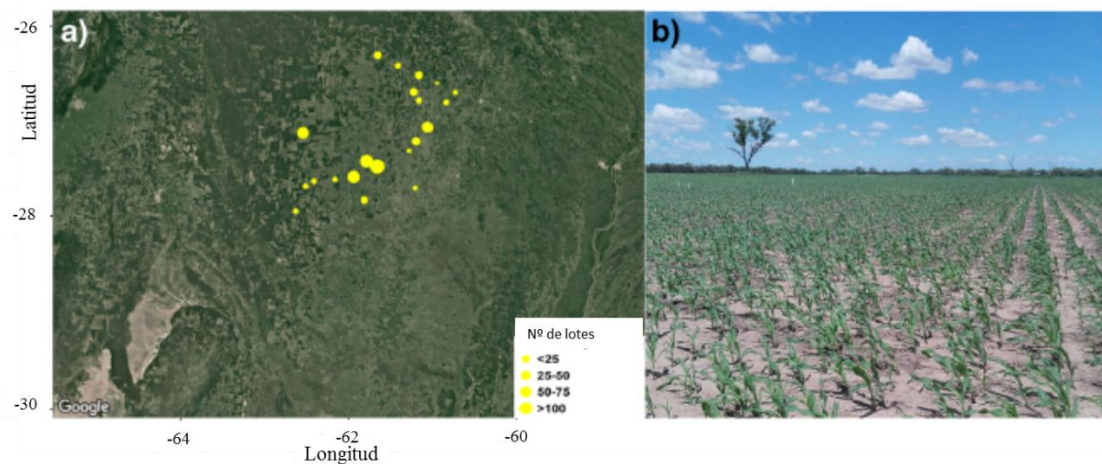


Figura 2.1. a. Localización de la zona de estudio en el Chaco Subhúmedo y Semiárido y distribución espacial de los datos de las explotaciones agrícolas incluidos en el análisis. b. Campo de maíz en estadio fenológico de tres hojas (V3).

### 2.2.3. Datos ambientales de entrada para los modelos

La radiación solar global (radiación total de onda corta sobre una superficie horizontal) y la temperatura del aire (obtenida a 1,5 m sobre la superficie del suelo) se obtuvieron de seis estaciones meteorológicas automáticas (la mayoría de la marca *Davis Instruments*, California, EE.UU.) de INTA (Instituto Nacional de Tecnología Agropecuaria; <http://siga2.inta.gov.ar/>) en Las Breñas, Añatuya, Gancedo, Los Frentones, Quimili, y Sacháyoj. La mayoría de los datos de precipitación se recolectaron en cada lote

semanalmente. Para los pocos casos donde no se disponía de datos de precipitación registrados en el lote, se utilizaron los datos de la estación meteorológica más cercana. Para algunas combinaciones de sitios y años, no se contaba con datos de radiación solar. En estos casos, se utilizaron datos de la NASA (<http://power.larc.nasa.gov/>) dado que evaluaciones recientes mostraron que en áreas planas como el Chaco, la correlación entre la radiación solar estimada por la NASA y la medida presentó un buen ajuste (Van Wart et al. 2013). La validez de esta relación para el área estudiada fue confirmada utilizando datos de las estaciones meteorológicas ubicadas en Las Breñas y en Añatuya ( $r = 0,97$ ). Para los pocos casos con datos de temperatura faltantes, se realizaron regresiones lineales entre los promedios mensuales de temperaturas mínimas y máximas de las estaciones meteorológicas y los datos de la NASA. Aunque las correlaciones fueron significativas y tuvieron altos coeficientes de determinación ( $R^2 > 0,8$ ), los datos de la NASA tendieron a sobreestimar ligeramente las temperaturas. Debido a la falta de otras alternativas, en los casos de datos de temperatura faltantes, se utilizaron los datos de la NASA pero corregidos con una función obtenida de las correlaciones descritas anteriormente.

A partir de la base de datos meteorológicos (es decir, precipitación, radiación solar, temperatura máxima y mínima), se calculó la precipitación efectiva, la evapotranspiración potencial según Hargreaves, la relación precipitación/ evapotranspiración, y cocientes fototermales. Además, se calcularon 12 índices de estrés por calor diferentes según el número de días y la sumatoria de grados en los que la temperatura máxima estuvo por encima de seis umbrales (es decir, 20, 25, 30, 35, 40 y 45°C). Se utilizó un umbral de 35°C a partir de trabajos previos (e.g., Lobell et al. 2013), y se consideraron los umbrales adicionales, por encima y por debajo de 35°C, para determinar (i) si hubo una influencia de los valores umbrales en las relaciones y (ii) si hubo un valor diferente de 35°C que debería

usarse como referencia del estrés por calor en las regiones estudiadas. Todas las variables calculadas se estimaron para todo el ciclo del cultivo, para períodos mensuales, y para 10 etapas durante el ciclo del cultivo definidas según el número de días desde la siembra. A partir de aquí se obtuvieron 304 variables que se consideraron como predictores potenciales en modelos empíricos para predecir el rendimiento de grano del maíz. Aunque se esperaba que esto generara variables redundantes, fueron igualmente calculadas de modo tal que se consideraran todos los predictores potenciales con un alto poder explicativo. Otra razón adicional para considerar un gran número de predictores fue abordar el hecho de que dos predictores redundantes pueden tener un poder explicativo similar pero pueden diferir en la forma en que se puede traducir la información de ese predictor en manejos agronómicos e intervenciones prácticas. También en la facilidad y costo para obtener la información.

La caracterización del suelo incluyó las series, la taxonomía y el uso del suelo. Todos estos datos fueron proporcionados por el INTA. Para el modelo mecanicista, los parámetros hídricos, definidos por el punto de marchitez y la capacidad de campo, se estimaron mediante funciones de pedotransferencia (Saxton et al. 1986), la saturación de agua del suelo se estimó como una función de la porosidad del suelo (Padarian et al. 2014) y se estimó la densidad aparente según Rawls y Brakensiek (1989). Además, se pidió a los agricultores que evaluaran la disponibilidad de agua en la siembra de acuerdo con una escala de tres categorías (i.e., mala, intermedia o buena). (Ver Cuadro S2.1 al final del capítulo).

#### 2.2.4. Modelo empírico: modelos lineales mixtos simples y múltiples

El objetivo de este capítulo fue identificar las variables ambientales y de manejo más relevantes que determinan la variabilidad del rendimiento de grano del maíz en el área

estudiada y cuantificar la magnitud de sus efectos. Para definir el modelo que mejor describe los datos observados, se consideró un modelo lineal de efectos mixtos ya que estos modelos pueden utilizarse con datos no balanceados y con observaciones faltantes, y son particularmente útiles cuando las mediciones constituyen unidades estadísticas relacionadas (Smith et al. 2005).

Si bien el objetivo final era contar con un modelo multivariado que explique la variabilidad en el rendimiento de grano del maíz, se comenzó por desarrollar modelos univariados para cada grupo de variables similares. Estos grupos fueron temperatura, estrés por calor, disponibilidad de agua, manejo (i.e., fecha de siembra, distancia entre hileras, densidad de plantas, fertilización, tipo de híbrido) y características del suelo (i.e., taxonomía del suelo, capacidad de uso). También se consideró si el lote se encontraba en el Chaco semiárido o en el subhúmedo. Los modelos univariados fueron del tipo:  $\text{Rendimiento} = \mu + \text{Predictor} + (\text{Sitio} \times \text{Año}) + \epsilon$ ; con Rendimiento: la predicción del rendimiento de grano asociado con los ambientes (Sitio  $\times$  Año),  $\mu$ : rendimiento promedio de grano, Predictor: variable evaluada como predictor,  $\epsilon$ : error. Se definió al ambiente como la combinación sitio-año para tener en cuenta el hecho de que algunas observaciones provenían de sitios cercanos y del mismo sitio en diferentes años. El predictor se estableció como un factor de efecto fijo mientras que la combinación Sitio  $\times$  Año se estableció como un factor aleatorio.

Una vez que se identificaron las variables individuales más explicativas dentro de cada grupo de variables similares, se consideró su uso potencial para el modelo multivariado. Se siguió un protocolo establecido (Zuur et al. 2010) para verificar (i) valores atípicos, (ii) homogeneidad de varianzas, (iii) distribución normal, e (iv) independencia y tipo de relación de la variable candidata con la variable respuesta. La multicolinealidad y

las relaciones entre variables cuantitativas fueron evaluadas con correlaciones de Pearson. También se exploraron las tendencias espaciales, utilizando coordenadas geográficas, como una fuente potencial de patrones que podían modificar la performance del modelo. Para verificar los supuestos de normalidad y de homocedasticidad, se inspeccionaron visualmente los gráficos de residuos estandarizados de los modelos. Tanto la estructura aleatoria de los modelos simples como de los múltiples, fue la combinación del sitio-año, que representa el ambiente. La heterogeneidad de varianzas a través de los ambientes se verificó específicamente ajustando un modelo por ambiente y comparando la varianza residual. Las observaciones de los predictores candidatos de efectos fijos se estandarizaron mediante *z-scores* para abordar el hecho de que los predictores presentaban escalas muy diferentes; los *z-scores* no modifican la relación funcional entre las variables predictoras y la variable respuesta. Para seleccionar los predictores para el modelo final, se siguió la estrategia *top-down* de selección de modelos y el enfoque de inferencia multimodelo basado en la teoría de la información (Burnham et al. 2011). El enfoque de inferencia multimodelo no se basa en el supuesto de que existe un único "modelo verdadero", sino que el proceso de selección del modelo identificará el mejor modelo aproximado capaz de resumir qué "efectos" (representados por predictores) pueden ser respaldados por los datos. La selección de los predictores del modelo se basó en el criterio AIC (criterio de información de Akaike) (Burnham et al. 2011). Los coeficientes del modelo final se estimaron utilizando REML (máxima verosimilitud restringida). La bondad de ajuste de los modelos mixtos se evaluó con el  $R^2$  de los modelos ajustados siguiendo a Nakagawa y Schielzeth (2013) donde el  $R^2$  marginal representa la varianza explicada por los factores fijos, mientras que el  $R^2$  condicional representa la varianza explicada por todo el modelo (efectos fijos y aleatorios).

### 2.2.5. Modelo mecanístico: CERES-*Maize*

Debido a la falta de reportes de validación o de uso de CERES-*Maize* (Jones et al. 2003) en el área de estudio, fue necesario evaluar la idoneidad del modelo en esta región. Se evaluó CERES-*Maize* v4.5 con datos de la base de datos consolidada, exceptuando aquellas observaciones que presentaban una o más de las siguientes características: (i) el manejo de cultivo había sido inusual para la región, (ii) la precipitación durante el ciclo del cultivo había sido inusualmente baja ( $<100$  mm) o inusualmente alta para la región ( $> 550$  mm), y (iii) los rendimientos de grano habían sido inusualmente bajos ( $<2000$  kg ha<sup>-1</sup>) o inusualmente altos ( $> 11500$  kg ha<sup>-1</sup>): Estos criterios de selección de datos se aplicaron para utilizar el modelo CERES-*Maize* en escenarios que representen las condiciones promedio a las que se ve sometido el cultivo en la región. Por ejemplo, se usó el umbral de precipitación de 550 mm dado que la precipitación fue superior a 550 mm en solo el 5% de los casos. Finalmente, el conjunto de datos utilizado en la evaluación de CERES-*Maize* quedó conformado por 69 lotes (10% de los lotes de la base de datos consolidada), que comprendieron cuatro temporadas de crecimiento (2010/11, 2011/12, 2012/13 y 2013/14); cuatro localidades en el Chaco Semiárido: Girardet, Otumpa, Quimili y Roversi; y nueve localidades en el Chaco subhúmedo: Campo del Cielo, Campo Largo, Charata, Gancedo, La Paloma, Las Breñas, Loro Blanco, Los Frentones y Pampa del Infierno.

Se realizaron simulaciones para el híbrido templado DK 747 porque fue el híbrido templado más cultivado en la región durante el período de estudio y se disponía de datos para la evaluación del modelo. Los coeficientes genéticos del híbrido DK 747 se obtuvieron a partir de trabajos previos (e.g., Aramburu-Merlos et al. 2015) y de datos no publicados de experimentos correctamente manejados.

Los datos de suelo utilizados en el modelo (i.e., porcentaje de arcilla y limo, carbono orgánico y nitrógeno total, color, drenaje y escorrentía potencial) se obtuvieron de los perfiles de suelo descritos por el Instituto de Suelos de INTA. Para la identificación de los perfiles de suelo en las localidades de Santiago del Estero, se utilizaron el sistema de información geográfica de Santiago del Estero (SigSE) (Angueira et al., 2007) y el visor GeoINTA (escala 1: 500000) (<http://geointa.inta.gov.ar/>). Para los suelos del Chaco, se utilizó la carta de suelos de la República Argentina, Provincia del Chaco (escala 1: 50000) y el visor GeoINTA. Para definir el suelo de cada lote, en cada localidad se identificó una serie dominante, y cuando existía una asociación de suelos, se utilizó la serie con el mayor porcentaje de representación y que era adecuada para uso agrícola.

Los horizontes argílicos restringen el crecimiento de las raíces y la captación de agua (Dardanelli et al. 1997). Por lo tanto, el valor del factor de crecimiento de la raíz en el suelo se definió según el porcentaje de arcilla: se utilizó un valor de 1.0 cuando el porcentaje de arcilla fue menor al 32%, 0,4 cuando estuvo entre 32% y 40%, y 0,2 cuando fue mayor al 40% (Dardanelli et al.1997). Se consideró una profundidad del suelo de 2 m en base a trabajos que reportan este valor como la profundidad promedio de enraizamiento del maíz en suelos similares (e.g., Dardanelli et al. 1997). Para aquellos sitios donde los datos de suelo no se encontraban disponibles para todo el perfil, se repitieron los valores disponibles del último horizonte hasta que se completaron los 2 m. La disponibilidad inicial de nitrato del suelo y de amonio del suelo se fijó en 70 y 15 kg ha<sup>-1</sup>, respectivamente, basado en análisis de suelos realizados por agrónomos locales. Estos contenidos de N se pueden considerar como los habituales en estos sitios y fechas de siembra. Se asumió una distribución de N exponencial decreciente con la profundidad en base a reportes previos (Rimski-Korsakov et al. 2012). La disponibilidad de agua a la siembra fue parametrizada en



base a la evaluación cualitativa que los agricultores habían hecho de este parámetro. Entre los lotes utilizados para la evaluación, solo cinco habían sido fertilizados con urea (46% N) a la siembra, con  $62 \text{ kg N ha}^{-1}$  en promedio.

Los datos meteorológicos para cada simulación se obtuvieron de la estación meteorológica (ver Sección 2.3) más cercana al campo (a menos de 60 km). Los datos ingresados al modelo sobre el manejo del cultivo fueron los reportados para cada lote, y se realizó una simulación para cada uno de ellos. Para algunos lotes, faltaba la información sobre distancia entre hileras y/o densidad de siembra; en dichos casos se utilizaron los valores más frecuentes, es decir  $52 \text{ cm}$  y  $6 \text{ plantas m}^{-2}$  para la distancia entre hileras y la densidad de siembra, respectivamente. En todos los casos, se utilizó una profundidad de siembra de  $5 \text{ cm}$ . Aunque hubo agricultores que sembraron maíz en otras fechas, las fechas de siembra utilizadas para las simulaciones con *CERES-Maize* fueron entre el 23 de diciembre y el 20 de enero, ya que estas fueron las más utilizadas en los lotes que fueron modelados. Cuando no se contaba con información sobre el cultivo precedente, se asumió que había sido soja, ya que es el cultivo más común en el área de estudio. Los rendimientos de grano de los cultivos previos se obtuvieron de un repositorio oficial de información agrícola (<http://www.sia.gov.ar>). Los residuos (biomasa aérea y de raíces) se estimaron según Álvarez et al. (1998), y no se asumió la incorporación de residuos ya que no se realizó esta práctica en los lotes. El rastrojo se estimó utilizando el rendimiento de grano (0% de contenido de humedad) y una relación paja/grano de 1,33, 1,9 y 1 para soja, trigo y maíz, respectivamente. La biomasa de la raíz se estimó como el 20% de la biomasa de rastrojo. Se asumió un contenido de N del 1% en los residuos. La fecha de inicio de la simulación se estableció como la fecha de cosecha del cultivo antecesor, que fue

generalmente seis meses antes de la siembra de maíz cuando los cultivos predecesores fueron soja, maíz, y algodón, y dos meses antes cuando fue trigo.

Las simulaciones se realizaron estableciendo limitaciones por agua y por nitrógeno y seleccionando el método de Priestley-Taylor para simular la evapotranspiración. La infiltración de agua se simuló siguiendo el enfoque del Servicio de Conservación de Suelos (USDA *Soil Conservation Service*, 1972).

Luego de evaluar el modelo CERES-*Maize*, se exploró la relación entre el rendimiento de grano simulado del híbrido DK 747 y la disponibilidad de agua a la siembra y durante el mes de febrero. El agua disponible (0–2 m) a la siembra se estimó corriendo el modelo durante todo el período de barbecho. La fecha de inicio de la simulación del barbecho se estableció de acuerdo con la fecha de cosecha del cultivo anterior.

#### 2.2.6. Análisis estadístico

Se utilizó el paquete lme4 (Bates et al. 2015) del software estadístico R (R Development Core Team, 2015) para realizar el análisis de efectos mixtos de la relación entre el rendimiento de grano de maíz y los diferentes predictores ambientales y de manejo. Usando el modelo mixto múltiple final, se realizó un análisis de componentes de la varianza para determinar si unos pocos factores explicaron la mayor parte de la varianza. La performance del modelo CERES-*Maize* se evaluó de acuerdo con dos estimadores: el RMSE (error cuadrático medio) y el NRMSE (RMSE normalizado) (Wallach et al. 2014). Se cuantificó la productividad de agua del híbrido de maíz DK 747 por medio de una regresión convencional y de una regresión del cuantil 95 con los datos simulados. Esta última se realizó utilizando la regresión por cuantiles del paquete *Quantreg* de R (Koenker 2016). Los valores de rendimiento de grano dentro del percentil 95 de cada clase de

precipitación fueron contrastados contra la precipitación y el modelo ajustado se tomó como el límite máximo para la productividad del agua.

### 2.3. Resultados y discusión

#### 2.3.1. Resultados de la base de datos de campo

La base de datos consolidada abarcó las condiciones típicas de crecimiento de los cultivos de verano en la región de estudio. La mayoría de los lotes habían sido cultivados por más de cinco años y la soja fue el cultivo antecesor mayoritario, encontrándose aproximadamente en dos tercios de las observaciones. El rendimiento del maíz promedió  $6156 \text{ kg ha}^{-1}$  pero presentó una gran variación; con valores mínimos y máximos de 297 y  $11015 \text{ kg ha}^{-1}$  (14,5% de contenido de humedad), respectivamente. La mayoría de los agricultores locales (87%) sembraron maíz en un período relativamente estrecho que se extendió desde el 15 de diciembre hasta el 31 de enero. En comparación con la Pampa Húmeda, en esta región hubo un retraso de las fechas de siembra de modo tal que el balance de agua fuera menos restrictivo durante los períodos críticos del cultivo, como una estrategia para reducir el riesgo climático (Giménez et al. 2015). Una ventaja adicional de atrasar la fecha de siembra es que el crecimiento del maíz ocurre durante los períodos de mayor radiación solar. Sin embargo, la siembra tardía no está libre de desventajas, ya que el cultivo también se encuentra expuesto a temperaturas más altas y a estrés por calor durante las etapas avanzadas de crecimiento.

Los agricultores sembraron maíz principalmente con una distancia entre hileras de 52 cm (81%), mientras que el 14 y el 5% lo hicieron con 76 y 70 cm, respectivamente. La densidad promedio varió de 3,8 a  $7,6 \text{ plantas m}^{-2}$  y el 63% de los lotes fueron tratados con

insecticidas. En la región de estudio, existe un proceso continuado de sustitución de híbridos tropicales por templados, el cual fue evidenciado en la base de datos: mientras que en 2010, el porcentaje de híbridos templados fue de 32%, en 2013 fue de 68%. Considerando todos los años de la base de datos, el híbrido de maíz más comúnmente cultivado fue el tropical DK 390 (madurez relativa 150 días) (22% de los casos), seguido del híbrido templado DK 747 (madurez relativa 125 días). El resto de los híbridos fueron cruza tropical × templado (18% de los casos). En promedio, la duración del ciclo de cultivo de maíz fue de 185 días.

### 2.3.2. Modelos simples

Los modelos simples permitieron identificar las variables más explicativas dentro de cada uno de los grupos de variables similares y en consecuencia reducir el número de predictores candidatos para el modelo múltiple (Kirwan et al. 2009). Las variables en la base de datos consolidada permitieron la evaluación de 40, 73, 59, 10 y 14 modelos simples dentro del grupo de variables de temperatura, estrés por calor, disponibilidad de agua, suelo y manejo, respectivamente. Entre las variables evaluadas dentro del grupo de temperatura, la temperatura máxima promedio de enero a abril (TEA) fue el predictor que explicó la mayor cantidad de la varianza en el rendimiento de grano de maíz. La variable que fue retenida entre las variables de temperatura fue la más asociada con el estrés por calor. En el caso del estrés por calor, el predictor que explicó la mayor cantidad de la varianza fue la suma de grados de temperatura máxima por encima de 35°C (G35). Sinsawat et al. (2004) indicaron que 35°C es un valor umbral de temperatura óptima para el desarrollo, el crecimiento, los procesos reproductivos, la viabilidad del polen y el rendimiento de grano de maíz.

En cuanto a las variables relacionadas con la disponibilidad de agua, la cantidad de lluvia durante febrero (Fig. 2.2) fue el mejor predictor del rendimiento de maíz, incluso por encima de los diferentes índices de evapotranspiración evaluados. Probablemente la evapotranspiración haya explicado una menor variación del rendimiento debido a que al retrasar las fechas de siembra, el balance de agua alrededor del período crítico resulta menos restrictivo. Solo el 1,8% de los agricultores sembró temprano (septiembre–octubre). Por otra parte, la variabilidad interanual de la lluvia fue mayor que la de la evapotranspiración (Maddonni, 2012). Además, los datos de precipitación fueron registrados en cada lote, lo que habría ayudado a detectar una mayor variabilidad local que los datos de evapotranspiración, que provenían de solo unas pocas estaciones meteorológicas. Al evaluar la relación entre la precipitación y el rendimiento de grano, la bondad del ajuste, indicada por el  $R^2$ , fue de 0,02 (precipitación durante todo el ciclo del cultivo, Fig. 2.2a), 0,005 (diciembre, Fig. 2.2b), 0,35 (febrero, Fig. 2.2c) y 0,09 (abril, Fig. 2.2d). Las variables ambientales en períodos mensuales explicaron una mayor parte de la varianza en el rendimiento de grano que los valores de las mismas variables durante todo el ciclo del cultivo, ya que existen períodos en los que la ocurrencia de un estrés abiótico tiene mayor influencia sobre el rendimiento que durante otras etapas del cultivo (Maddonni 2012). En el caso del maíz, este período se presenta alrededor de la floración (que en la zona ocurre generalmente durante febrero), cuando la incidencia de un estrés (e.g., hídrico) afectará negativamente el rendimiento de grano más que en cualquier otro período (Edreira y Otegui 2012).

Una práctica que podría reducir la limitación por agua es un control de malezas más eficiente. Sin embargo, en el esquema de recolección de datos no se consideró la cuantificación de la eficiencia del control de malezas. Ricard et al. (2015) sugieren que el

riego podría ser una herramienta efectiva para contrarrestar la variabilidad en la disponibilidad de agua de la zona de estudio. El doble cultivo, una práctica de manejo eficiente del agua y generalizada en otras partes del continente, se considera inadecuado en esta región debido al alto consumo de agua. También falta información para el Chaco sobre el efecto del control de malezas en el balance hídrico, por lo que sería importante generar esta información en futuros proyectos. Otra práctica importante es la cobertura del suelo con rastrojo, que contribuye a reducir el efecto de las altas temperaturas y la evaporación de agua del suelo.

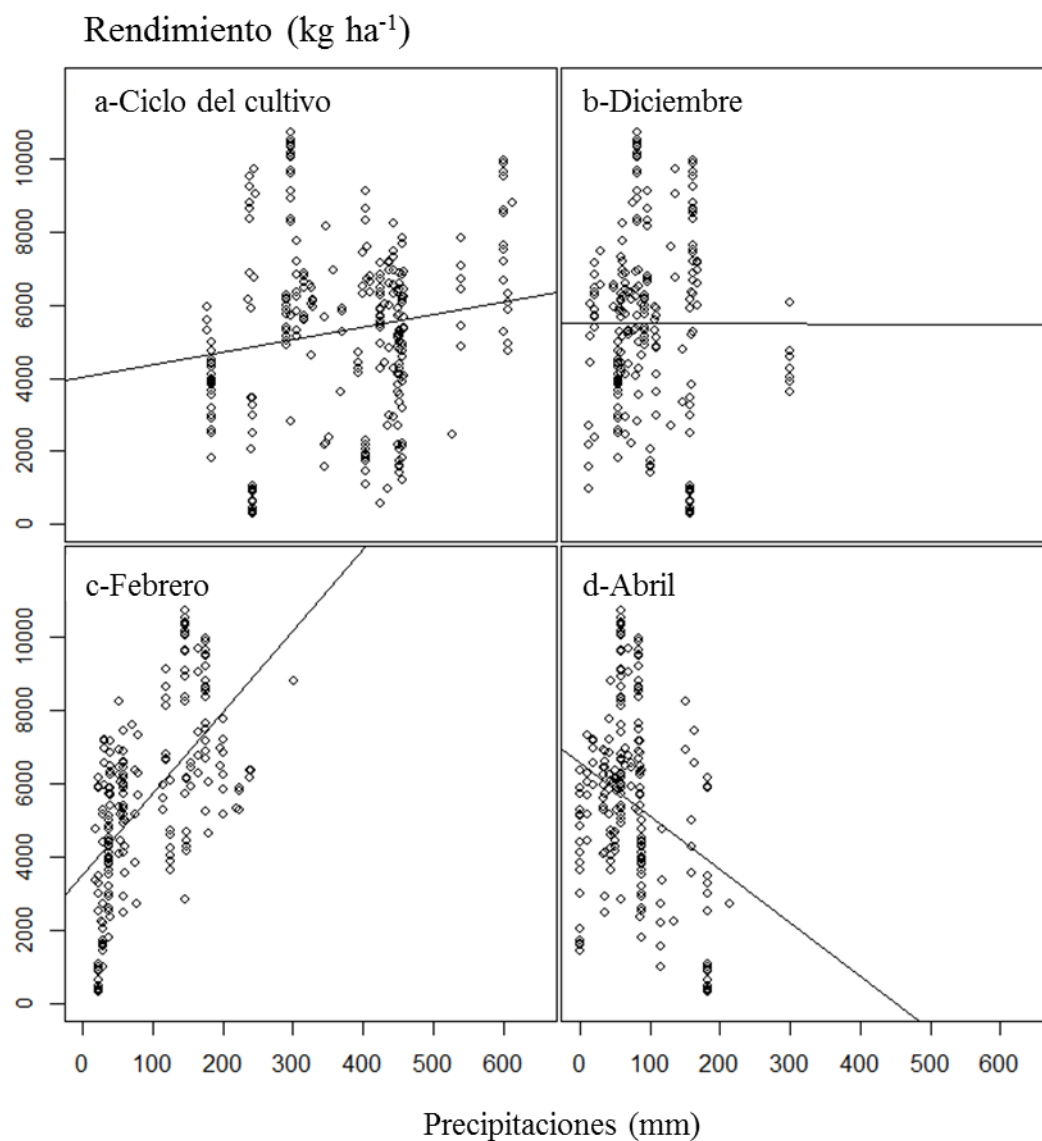


Figura 2.2. Relaciones entre el rendimiento de maíz (14,5% de contenido de humedad) y la precipitación durante todo el ciclo del cultivo (a), diciembre (b), febrero (c) y abril (d). Los datos se obtuvieron de 792 lotes de producción de maíz en el Chaco subhúmedo y semiárido. Las rectas corresponden a regresiones lineales entre el rendimiento y la precipitación. Las ecuaciones de las rectas, los valores de  $R^2$  y la significancia fueron: a)  $Y = 6,997 * X + 4033 - R^2 0,02 - p < 0,001$ ; b)  $Y = 1,500 * X + 5751 - R^2 0,005 - \text{no significativo}$ ; c)  $Y = 18,59 * X + 3757 - R^2 0,35 - p < 0,001$ ; d)  $Y = -16,91 * X + 7185 - R^2 0,09 - p < 0,001$ .

Entre las variables de manejo, el tipo de híbrido de maíz explicó una mayor parte de la varianza (Cuadro 2.1). Este resultado sugiere que los agricultores pueden influir en el rendimiento de maíz alcanzable no solo eligiendo un híbrido específico sino también

seleccionando entre híbridos tropicales o templados. De hecho, la elección del genotipo es una de las principales opciones para adaptar la producción de cultivos a las condiciones climáticas (Maddonni 2012). Aunque la cantidad de varianza explicada fue menor que para el tipo de híbrido de maíz, el cultivo antecesor y el número de años en que el lote estuvo cultivado, también explicaron cantidades significativas de la varianza en el rendimiento del maíz. Por el contrario, todas las variables evaluadas asociadas con el suelo fueron malos predictores del rendimiento de grano. Una variable cualitativa que clasificaba los lotes según si estaban ubicados en el Chaco semiárido o Subhúmedo, tampoco fue retenida por los modelos, lo que sugiere que esta clasificación tendría poca aplicación operacional a los fines de la modelización empírica de datos. Aunque otros estudios informaron asociaciones significativas entre la densidad de plantas y el rendimiento de grano de maíz (e.g., Andrade et al. 2017), en este trabajo la densidad de plantas no estuvo asociada con la variabilidad en el rendimiento de grano. Este resultado puede explicarse por el hecho de que los agricultores en el área utilizaron un rango muy estrecho de densidades de plantas, en la mayoría de los casos.

### 2.3.3. Modelos múltiples

Luego de identificar los predictores candidatos con los modelos simples, se evaluaron diferentes modelos múltiples, con el objetivo de resumir los principales factores ambientales y de manejo que limitan el rendimiento de grano de maíz en el área estudiada, y entender si las relaciones entre las variables son de tipo aditivo o interactivo. De una lista más larga de modelos candidatos, el Cuadro 2.1 muestra cinco ejemplos de ellos para documentar los criterios y procedimientos de selección de modelos. Entre los considerados, el modelo 2 mostró el mejor ajuste general. Este modelo presentó el AIC más bajo, que es



un criterio recomendado para la selección de modelos multivariados (Burnham et al. 2011). El  $R^2$  condicional más alto de otros modelos podría mostrar un sobreajuste u “overfitting” de estos modelos, mientras que el  $R^2$  marginal, que indica la varianza explicada por los factores fijos, fue mayor para el modelo 2 que para todos los demás modelos. En general, los modelos que no incluyeron el estrés por calor tuvieron menor consistencia que aquellos que lo incluyeron. Para ilustrar esto, el Cuadro 2.1 muestra los modelos donde se incluyó G35 como predictor (modelos 1 y 2) y donde no se incluyó (modelos 3 a 5). El modelo completo que incluyó interacciones entre todos los predictores individuales identificados (modelo 1 en el Cuadro 2.1), tuvo un mejor ajuste que otras combinaciones de predictores interactivas y aditivas, pero un peor ajuste que el modelo 2 seleccionado, que incluyó todos los parámetros como aditivos, excepto la interacción entre un índice de estrés térmico (i.e., G35) y TEA (temperatura máxima promedio de enero a abril).

Cuadro 2.1. Estructura general de los modelos de restricciones múltiples para predecir el rendimiento del maíz en el Chaco subhúmedo y semiárido, con ejemplos seleccionados. Los modelos difieren en los predictores incluidos y en la relación aditiva o interactiva entre los predictores. Se llegó a un modelo final (# 2) mediante un proceso de selección por pasos según el criterio de información de Akaike (AIC).

Modelo	Predictores	AIC	$R^2$	
			Marg.	Cond.
1. Completo	$\text{Rend}_{.i} = \text{G35} \times \text{TEA} \times \text{PF} \times \text{TH} \times (\text{Sitio} \times \text{Año})_i + \epsilon_i$	3816	0,55	0,66
2. Estrés por calor × Temperatura	$\text{Rend}_{.i} = \text{G35} + \text{TEA} + \text{PF} + \text{TH} + \text{G35} \times \text{TEA} \times (\text{Sitio} \times \text{Año})_i + \epsilon_i$	3722	0,40	0,60
3. Sin Estrés por calor y efectos interactivos	$\text{Rend}_{.i} = \text{TEA} \times \text{PF} \times \text{TH} + (\text{Sitio} \times \text{Año})_i + \epsilon_i$	8920	0,32	0,65
4. Sin Estrés por calor y efectos aditivos	$\text{Rend}_{.i} = \text{TEA} + \text{PF} + \text{TH} + (\text{Sitio} \times \text{Año})_i + \epsilon_i$	8990	0,32	0,65
5. Sin Estrés por calor ni Genotipo	$\text{Rend}_{.i} = \text{TEA} \times \text{PF} + (\text{Sitio} \times \text{Año})_i + \epsilon_i$	9247	0,31	0,56

$R^2$  Marg. ( $R^2$  marginal): representa la varianza explicada por los factores fijos,  $R^2$  Cond. ( $R^2$  condicional): representa la varianza explicada por todo el modelo. Rend.: rendimiento en grano de maíz, G35: grados acumulados de temperatura máxima por encima de 35°C, TEA: temperatura máxima media de enero a abril, PF: precipitaciones durante el mes de febrero, TH: tipo de híbrido de maíz,  $\epsilon$ : error.

La Figura 2.3a muestra la relación entre el rendimiento de grano y la precipitación durante febrero. Aunque la interacción entre el tipo de híbrido y la precipitación no tuvo un efecto significativo en el rendimiento de grano, hubo un efecto aditivo del tipo de híbrido en el rendimiento. Con escasas precipitaciones, los híbridos templados tendieron a rendir más que los tropicales, lo que explica la progresiva adopción por parte de los agricultores locales de los híbridos templados. La adopción de híbridos tropicales fue promovida en el pasado debido a la expectativa de que estarían mejor adaptados a las condiciones locales de temperatura y de fotoperíodo. La Figura 2.3b muestra la relación entre el rendimiento de grano y TEA y el efecto interactivo del índice de estrés térmico (G35) en esta relación. Como se esperaba, el rendimiento de grano del maíz disminuyó a medida que la TEA aumentaba por encima del promedio de 29°C registrado en el área estudiada. Como también podía esperarse, el índice de estrés térmico se correlacionó con TEA ( $r = 0,58$  según el coeficiente de correlación de Pearson). Sin embargo, la magnitud de la correlación entre estas dos variables no fue suficiente como para evitar diferentes intensidades de estrés por calor para una TEA similar. Esta combinación de temperaturas máximas y estrés por calor tiene implicancias para la productividad del maíz, y fueron capturadas por el modelo múltiple. La interacción significativa entre la temperatura y el estrés por calor se manifestó en el hecho de que en el extremo más bajo de la TEA (i.e., <30°C), no hubo observaciones con  $G35 > 150$  GD (grados día), mientras que en el extremo más alto de TEA (i.e., >34°C), no hubo observaciones con  $G35 < 150$  GD. A una TEA de aproximadamente 31°C, el rendimiento de grano tendió a ser mayor con  $G35 > 150$  GD, mientras que a aproximadamente 34°C, el rendimiento de grano tendió a ser mayor con  $G35 < 150$  GD. Por lo tanto, más eventos de estrés por calor resultaron en un rendimiento de grano más bajo con temperaturas más altas, pero no con temperaturas más bajas. Aunque este efecto puede

parecer sutil, demuestra cuán complejo es el dilema para los agricultores locales cuando deben elegir un tipo de híbrido, una fecha de siembra y otras decisiones de manejo, que median el efecto en la productividad de dos efectos climáticos, que en un rango estrecho pueden dar resultados muy diferentes. Este resultado a su vez, sugiere que, además de las mejoras en el mejoramiento o en el manejo de los cultivos, es importante implementar estrategias de diversificación (e.g. a través de rotaciones o genotipos) para minimizar el riesgo de los efectos climáticos que son difíciles de anticipar.

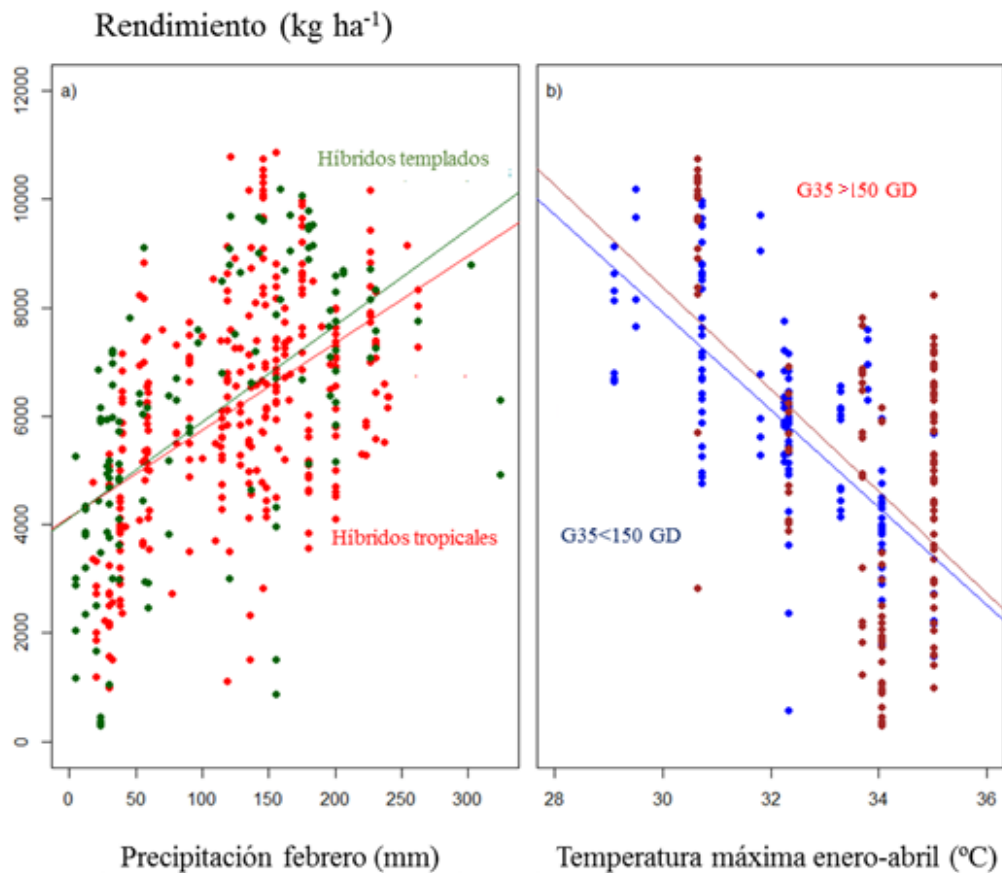


Figura 2.3. a) Relación entre el rendimiento (14,5% de contenido de humedad) de los híbridos de maíz tropical y templado y la precipitación durante febrero. b) Relación entre el rendimiento de maíz y la temperatura máxima media de enero a abril (TEA), influenciada por un índice de estrés térmico (G35). Los datos se obtuvieron de 792 lotes de producción de maíz en el Chaco subhúmedo y semiárido. Las líneas corresponden a regresiones lineales entre las variables.

Con el modelo multivariado seleccionado (modelo 2), se realizó un análisis de componentes de la varianza para identificar el impacto de estas fuentes de variabilidad en el rendimiento de grano. El 8% de la variación se atribuyó al tipo de híbrido, un factor que puede ser controlado por los agricultores. En contraste, la mayoría de los efectos en el rendimiento del grano se explicaron por las variables ambientales sobre las cuales los agricultores no tienen control o tienen un control indirecto (a partir del manejo de las fechas de siembra por ejemplo); G35 (11%), temperatura máxima promedio de enero a abril (26%), precipitaciones durante febrero (13%), la interacción G35 × TEA (13%) y la interacción Sitio × Año (11%). Sin embargo, la elección del híbrido tuvo implicancias en los efectos que las variables ambientales ejercen sobre el rendimiento. Cuando se circunscribió el análisis de componentes de la varianza a un subconjunto con solo genotipos tropicales, la precipitación en febrero explicó el 24% de la varianza en el rendimiento, el ambiente (i.e., Sitio × Año) el 17% y la TEA el 29%, mientras que el estrés por calor solo o interactuando con la temperatura no explicó prácticamente nada de la varianza. La partición de la varianza fue bastante diferente para los híbridos templados; i.e., 20, 22, 34 y 8% fueron explicados por la interacción estrés por calor × TEA, estrés por calor solo, TEA sola y precipitación, respectivamente. Los valores respectivos para los híbridos cruza tropical × templado fueron 6, 18, 36 y 10%. Del mismo modo, en experimentos a campo realizados en la Pampa húmeda Argentina, los efectos del estrés por calor en el rendimiento del grano fueron mayores para los híbridos templados que para los tropicales (Edreira y Otegui 2012). Un análisis que cubrió toda la región del Chaco destacó el papel de la disponibilidad de agua como otro factor que determina los rendimientos del maíz (Adamoli et al. 2011). Aunque estos resultados muestran que la disponibilidad de agua es una restricción importante en la productividad del maíz, dependiendo del tipo de híbrido, puede que no sea

la que explique la mayor cantidad de varianza, al menos en la forma que se pudo cuantificar (lluvias en febrero) que fue lo que el modelo 2 retuvo. Tal vez sea aconsejable hacer una mejor cuantificación de la disponibilidad hídrica, con otras mediciones que no pudieron ser incluidas con la base de datos analizada. Por lo tanto, los resultados aquí obtenidos respaldan las conclusiones de otros estudios (e.g., Baldi et al. 2015) respecto a que se deben tener en cuenta múltiples factores en el diseño de mejoras del manejo agronómico en áreas subtropicales semiáridas y subhúmedas.

Si bien el tipo de híbrido explica menos variabilidad que otros predictores, sería un factor estratégico para aumentar la productividad del maíz en la región, ya que a través de la elección de genotipos, los agricultores pueden influir en los efectos que las restricciones climáticas tienen sobre la productividad del maíz de manera más fácil o económica que con otro tipo de intervenciones. Los agricultores no tienen medios para influir directamente en la temperatura, mientras que influir en la humedad del suelo con el riego, requiere importantes inversiones que la mayoría de los agricultores locales no pueden afrontar. Otra estrategia de manejo importante es la cobertura del suelo con rastrojo, que contribuye a reducir el efecto de las altas temperaturas y la evaporación de agua del suelo. Los híbridos tropicales se vieron menos afectados por el estrés térmico y las altas temperaturas que los templados. Sin embargo, los híbridos tropicales se vieron más afectados por las menores precipitaciones que los templados, presumiblemente debido a su mayor biomasa y al mayor consumo de agua asociado (Edreira y Otegui 2012). La razón de combinar dos tipos de híbridos en un lote es hacer frente a las incertidumbres que surgen de la variabilidad del clima. Los cruces entre líneas puras tropicales y templadas representaron un grupo altamente heterogéneo que como categoría no mostró claras diferencias en comparación con los híbridos tropicales o templados. Aunque este escenario podría haber sido una

ventaja en términos de adaptación y tolerancia al estrés, esto no surgió en el análisis. Este resultado puede explicarse porque los cruces incluidos en este estudio fueron los primeros intentos de generar este tipo de genotipo en la región, y los rasgos fisiológicos de las líneas tropicales que confieren ventajas para la tolerancia al calor probablemente no fueron objetivos de selección por los fitomejoradores.

Otra estrategia de manejo que ya se viene realizando en la zona, es haber adaptado las fechas de siembra desde octubre a diciembre para reducir las restricciones en el balance de agua durante el periodo reproductivo, el cual es crítico para la determinación del rendimiento. Sin embargo, este retraso incrementa el riesgo de que el cultivo se vea afectado por estrés térmico durante los periodos reproductivos (Edreira y Otegui 2012; Maddonni 2012). Por eso resulta fundamental considerar también al tipo de híbrido.

Un resultado inesperado de la selección del modelo fue que la fertilización con N no se mantuvo en el modelo multivariado final y tampoco se identificó como un predictor con capacidad explicativa aceptable por los modelos univariados. Tres posibles explicaciones pueden explicar este resultado. Primero, la variabilidad observada en las tasas de fertilización con N fue baja para probar adecuadamente los efectos del N y el contenido real de N en el suelo fue incierto. En segundo lugar, la disponibilidad de N en el suelo podría ser lo suficientemente alta para los cultivos de verano y adecuada para su demanda, debido a que los suelos locales han comenzado a cultivarse recientemente, por lo que aún mantienen la fertilidad de los suelos vírgenes. Además, las altas temperaturas estivales exacerbaban la mineralización de N, generando pulsos de este nutriente durante los periodos de alta demanda. Tercero, las limitaciones impuestas por la disponibilidad de N pudieron haber sido ocultadas por otras restricciones, que también afectan al rendimiento, e.g., la sequía y el estrés por calor. En general, los agricultores locales consideran que la aplicación

de fertilizantes no asegura beneficios, los suelos locales todavía son lo suficientemente fértiles para lograr rendimientos satisfactorios de maíz, y/o la variabilidad climática genera que la respuesta a la fertilización con N sea altamente incierta.

#### 2.3.4. Modelo mecanístico

Los modelos mecanísticos se convirtieron en herramientas poderosas para evaluar los efectos del cambio climático y la variabilidad climática (Ray et al. 2015). En este estudio, el objetivo de utilizar *CERES-Maize* fue ampliar las conclusiones sugeridas por los datos de campo, aumentar el poder estadístico, resolver incertidumbres y aumentar el tamaño de las pruebas estadísticas. Una evaluación inicial de *CERES-Maize* para el híbrido templado más usado en el área (DK747) presentó valores de RMSE, NRMSE y  $R^2$  de la regresión entre los rendimientos de granos simulados y observados de  $1680 \text{ kg ha}^{-1}$ , 25% y 0,38, respectivamente. Una cuestión que se pretendió abordar en este trabajo, fue comprender mejor por qué el modelo *CERES-Maize* en ciertos casos se desempeña de manera deficiente en áreas subtropicales (e.g., Ray et al. 2015). La oportunidad de superar esta falta de precisión tiene implicancias para la comprensión de los efectos potenciales del cambio climático global y para planificar un desarrollo sostenible teniendo en cuenta estos efectos. Para ello, se buscaron fuentes de desviaciones entre los valores simulados y los observados entre las variables asociadas con el clima, con las características del cultivo, con el manejo y con el ambiente. No se identificó una fuente consistente que redujera la precisión de *CERES-Maize*, como el estrés por calor o la sequía intensa. En cambio, se identificaron tres fuentes de desviaciones: (i) sesgos en localidades específicas (Charata, Loro Blanco y Girardet, que fueron atribuidos a datos de suelo inexactos), (ii) sesgos en campos específicos (dos campos en los cuales el suelo probablemente estuviera degradado

en cierta medida), y (iii) sesgos en fechas de siembra específicas (tres observaciones del año 2014 donde se reportaron problemas en la emergencia del maíz). Cuando las observaciones que presentaron alguna de las características mencionadas anteriormente, no se incluyeron en el subconjunto de datos, los valores de RMSE, NRMSE y  $R^2$  de la regresión entre los valores simulados y observados fueron  $1246 \text{ kg ha}^{-1}$ , 16% y 0,61, respectivamente. Por lo tanto, la performance de *CERES-Maize* fue satisfactoria (Fig. 2.4a), e incluyó un amplio rango de combinaciones de factores para apoyar decisiones en relación a una región agrícola relativamente nueva, donde la información disponible localmente aún es escasa.



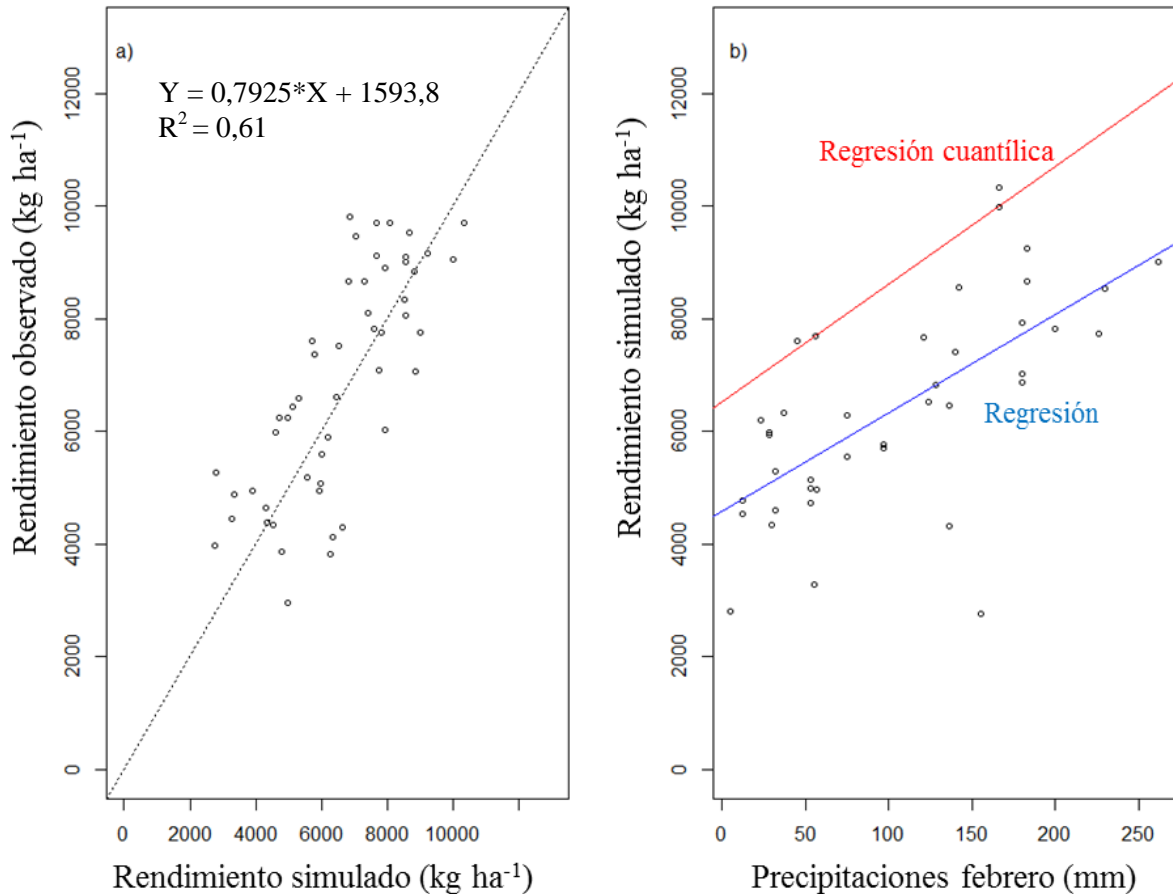


Figura 2.4. a) Relación entre el rendimiento (14,5% de contenido de humedad) del híbrido de maíz templado DK-747 simulado por CERES-*Maize* y el rendimiento observado en lotes ubicados en el Chaco subhúmedo y semiárido. La línea de puntos representa la relación 1:1. b) Relación entre los rendimientos simulados del híbrido de maíz templado DK-747 por CERES-Maíz y las precipitaciones durante febrero (mm). Las rectas azul y roja representan la regresión lineal y la regresión límite del cuantil del 95%, respectivamente.

Los modelos mecánicos permiten a los investigadores ampliar el alcance de los resultados observacionales (Jones et al. 2003). Esta es una oportunidad importante para superar un problema potencial asociado a los datos observacionales, que es que para ciertas variables de respuesta el rango de valores está cubierto de manera incompleta por los datos de campo (Rosenbaum 2002), y las observaciones pueden mostrar grupos dentro de los rangos observados. Este proceso puede ser una fuente de inexactitud ya que unos pocos grupos pueden tener efectos de apalancamiento sobre las regresiones. Luego de evaluar

CERES-*Maize* para el área estudiada, se realizaron simulaciones para cuantificar la productividad de agua del híbrido DK747. Cabe aclarar que dicha productividad se acotó a las precipitaciones durante el mes de febrero. La figura 2.4b muestra los análisis de regresión convencional y del cuantil 95, aplicados a los datos simulados. El análisis con regresión convencional indicó que el híbrido DK 747 tiene el potencial de aumentar el rendimiento de grano en  $18,5 \text{ kg ha}^{-1}$  (14,5% de contenido de humedad) por cada milímetro de lluvia durante febrero. Adicionalmente, se utilizó una regresión del cuantil 95 de los datos simulados para evaluar el potencial máximo de captura de agua del híbrido templado DK 747. Los resultados indicaron un aumento máximo posible en el rendimiento de grano de  $21,3 \text{ kg ha}^{-1}$  (14,5% de contenido de humedad) por cada milímetro de lluvia caído durante febrero. A pesar de que el modelo mecanicista dejó preguntas sin responder, redujo significativamente la cantidad de interrogantes que se plantearon al inicio de este proyecto y permitirá una inversión más eficiente de recursos en proyectos posteriores al centrarse solo en aquellas preguntas que permanecen abiertas.

#### 2.4. Conclusión

En relación al objetivo 1, la modelización empírica permitió identificar las principales restricciones climáticas y de manejo que explican la variabilidad en los rendimientos de maíz en el Chaco Semiarido y Subhúmedo: un índice de estrés por calor (grados acumulados de temperatura máxima por encima de  $35^{\circ}\text{C}$  durante el ciclo del cultivo), la temperatura máxima media de enero a abril, las precipitaciones durante el mes de febrero y el tipo de híbrido de maíz.

En cuanto al objetivo 2, se encontró que la combinación de la modelización empírica y mecanística de los datos del cultivo de maíz recolectados, permitió la

identificación de las principales restricciones a la producción de maíz en un área con escasa información disponible. El modelo empírico identificó la cantidad de lluvia durante febrero como un determinante principal de los rendimientos del maíz. En base a estas observaciones, las simulaciones realizadas con *CERES-Maize* indicaron que los híbridos templados tienen el potencial de aumentar el rendimiento de grano de 18 a 21 kg ha<sup>-1</sup> (14,5% de contenido de humedad) por cada milímetro de lluvia durante febrero.

En relación al objetivo 3, se puede afirmar que una contribución clave adicional del modelo mixto multivariado fue dilucidar el papel de los genotipos, ya que la mayoría de los modelos mecanísticos aún no se encuentran lo suficientemente desarrollados como para capturar las diferencias a nivel genotípico (Jeuffroy et al. 2014). El modelo empírico sugirió que los híbridos templados tendieron a desempeñarse mejor en condiciones de escasez de agua, mientras que los tropicales tendieron a tolerar mejor las condiciones de altas temperaturas y de estrés por calor (temperatura > 35°C). Esta situación sugiere que los agricultores se enfrentan a un difícil dilema cuanto tienen que seleccionar entre híbridos templados y tropicales, para reducir la vulnerabilidad a la sequía y al estrés por calor, que son dos estreses que tienden a ocurrir simultáneamente. Por lo tanto, en términos de la elección del genotipo, la mejor opción para los agricultores para minimizar los riesgos climáticos podría ser diversificarlos y combinarlos en diferentes lotes dentro del campo para minimizar la vulnerabilidad climática. Los hallazgos de este trabajo proporcionan a los fitomejoradores información (por ejemplo el potencial de aumento del rendimiento del híbrido templado ante cada milímetro de lluvia durante febrero) que se necesita con urgencia para generar genotipos de maíz mejor adaptados a esta región, que a su vez pueden aumentar las opciones de los agricultores locales.

## 2.5. Material suplementario

Cuadro S2.1: variables consideradas en el análisis con modelos mixtos dentro de cada uno de los cinco grupos de variables analizadas.

<b>Manejo e historia agrícola</b>	<b>Temperatura</b>	<b>Estrés por calor</b>	<b>Disponibilidad de agua</b>	<b>Suelo</b>
Tipo de híbrido	Temperatura máxima promedio de enero a abril	Número de días en los que la temperatura máxima estuvo por encima de seis umbrales (es decir, 20, 25, 30, 35, 40 y 45°C)*	Precipitación **	Serie
Fecha de siembra			Precipitación efectiva **	
Densidad de siembra	Temperatura media promedio de enero a abril			
Distancia entre hileras	Cociente fototermal promedio de enero a abril	Sumatoria de grados en los que la temperatura máxima estuvo por encima de seis umbrales ( 20, 25, 30, 35, 40 y 45°C)*	Precipitación/ ETP Hargreaves *	Taxonomía
Aplicación de fertilización nitrogenada				
Años en que el lote estuvo cultivado	Radiación global promedio de enero a abril		ETP acumulada Hargreaves *	Uso del suelo
Años bajo siembra directa				
Ubicación del lote				

\*La variable fue estimada para todo el ciclo del cultivo y para 10 etapas durante el ciclo del cultivo definidas según el número de días desde la siembra.

\*\*La variable fue estimada para todo el ciclo del cultivo y para diferentes períodos mensuales entre octubre y abril.

<b>Manejo e historia agrícola</b>	<b>Temperatura</b>	<b>Estrés por calor</b>	<b>Disponibilidad de agua</b>	<b>Suelo</b>
Tipo de híbrido (TH)	Temperatura máxima promedio de enero a abril (TEA)	Sumatoria de grados de temperatura máxima por encima de 35°C durante el ciclo del cultivo (G35)	Precipitación promedio durante febrero (PF)	Ninguna variable*

Cuadro S2.2: Variables más explicativas del rendimiento de maíz dentro de cada uno de los cinco grupos de variables analizadas con modelos simples. \*Ninguna variable dentro del grupo “Suelo” fue un buen predictor del rendimiento de maíz.

# CAPÍTULO 3

## Determinantes ambientales y de manejo del rendimiento de soja en una región subtropical

### 3.1. Introducción

La expansión de la producción de soja en los últimos 50 años en Argentina provocó un aumento del 50% de la superficie cultivada (Dominguez y Rubio 2019). Este avance de la frontera agropecuaria fue particularmente notorio en el Chaco Semiárido y el Subhúmedo, donde extensas áreas de monte natural fueron desmontadas para destinarlas principalmente a la producción de soja, situación impulsada por el aumento en su demanda mundial (Fehlenberg et al., 2017). En esta región las precipitaciones presentan un régimen monzónico y alta variabilidad interanual (Ricard *et al.*, 2015) con un rango de entre 500-950 mm (1901-2011) (Naumann, 2006) y áreas que presentan las máximas temperaturas absolutas del continente. Son frecuentes las limitaciones al crecimiento y productividad de los cultivos por déficit hídrico y estrés por altas temperaturas (Giménez *et al.*, 2015; Perez-Carrera *et al.*, 2008). La reciente agriculturización de la Región Chaqueña advierte la relevancia de investigar las particularidades de la zona. Es importante considerar las notorias diferencias ambientales entre la región pampeana, donde históricamente se ha desarrollado la producción agrícola extensiva del país, y la chaqueña, sobre todo teniendo en cuenta que en general, las prácticas agrícolas empleadas en la región pampeana se han extendido a la región de estudio. Además, considerando el intenso avance de la frontera agrícola en la Región Chaqueña, y todas las consecuencias que el proceso de desmonte conlleva, resulta urgente y fundamental desarrollar prácticas agrícolas sustentables.

En la zona de estudio la soja se cultiva bajo condiciones de secano. El principal factor determinante de la productividad de los cultivos en los sistemas de secano es la disponibilidad de agua (Boyer, 1982; Adámoli *et al.*, 2011). Además la región se caracteriza por presentar precipitaciones limitadas, concentradas y variables. La variabilidad en las lluvias se asocia con importantes variaciones en los rendimientos de soja

a través de los años (Aramburu Aramburu-Merlos et al., 2015). Por lo general la ocurrencia de déficit hídrico durante los estadios reproductivos de la soja impacta en mayor medida al rendimiento que durante los estadios vegetativos. Resulta fundamental implementar prácticas de manejo del cultivo adaptativas frente a las fluctuaciones en la disponibilidad de agua. Algunas de estas prácticas pueden estar asociadas con estrategias de tolerancia al estrés, buscando conservar el agua durante los estadios vegetativos, para poder ser luego aprovechada en los estadios reproductivos. Algunas prácticas de manejo tendientes a lograr este objetivo se asocian con la modificación de la distancia entre hileras y la densidad de plantas. En el primer caso, ampliar la distancia entre hileras (Reicosky et al., 1985), en el segundo caso, reducir la densidad de plantas (Holshouser & Whittaker, 2002), pueden favorecer la conservación del agua en los estadios tempranos del cultivo. Una estrategia contrastante puede estar dirigida a maximizar la captura de la radiación y el agua durante todo el ciclo del cultivo (Di Mauro et al., 2019), por ejemplo empleando cultivares de grupos de madurez largos, que pueden hacer frente a la intermitencia en la disponibilidad de agua al presentar períodos de crecimiento más largos (Wegerer et al., 2015). Otras prácticas que contribuyen a la conservación del agua en el suelo son la siembra directa y la cobertura del suelo con rastrojo, que reduce el efecto de las altas temperaturas y la evaporación de agua del suelo; las rotaciones que incorporan maíz o sorgo y el control de malezas (Díaz-Zorita et al., 2022; Studdert & Echeverria, 2000). Además, generalmente el maíz (y las gramíneas en general), al contribuir con una cantidad mayor de residuos de biomasa, protege al suelo de la erosión y promueve procesos de descomposición y humificación cerca de la superficie del suelo (Mazzilli et al., 2014). Por otra parte, la cantidad de rastrojo se asocia negativamente con las pérdidas de C orgánico del suelo (Villarino et al., 2017). Algunos trabajos sugieren la adopción de secuencias de cultivo



flexibles que se puedan modificar en función de la disponibilidad inicial de agua (Giménez *et al.*, 2015). En un análisis utilizando modelos de simulación de cultivos en una región del Chaco Subhúmedo (i.e. Las Breñas) la intensificación del uso de la tierra en un 40-70% implementando sistemas de doble cultivo maíz-soja (esto puede ser doble cultivo en la zona subtropical, ya que en regiones templadas son dos cultivos en dos años), surgió como una posibilidad a desarrollar en la zona (Giménez *et al.*, 2018). Sin embargo, el doble cultivo anual puede tener consecuencias en función del posible costo-beneficio productivo pero también del ecosistema (Ricard *et al.*, 2015). Al evitar esquemas productivos que utilizan más agua para reducir el riesgo climático, se pierde la oportunidad de obtener una mayor producción en años con mayores precipitaciones y el exceso de agua no utilizado representa un riesgo ambiental como consecuencia de procesos de erosión, inundación y salinización (Giménez *et al.*, 2015). Es importante destacar también que bajo condiciones limitantes de agua, además de estar limitada por la disponibilidad hídrica, la soja puede verse co-limitada por la disponibilidad de nitrógeno (Di Mauro *et al.*, 2019). Una adaptación notoria en las prácticas de manejo locales es el atraso en las fechas de siembra de octubre hacia diciembre (en relación a la región pampeana) y hasta los primeros días de enero, con la finalidad de evitar de los estreses hídricos y térmicos en los períodos críticos del cultivo.

En esta región resulta fundamental un análisis complejo y holístico para comprender los factores limitantes que determinan las variaciones en el rendimiento de soja. Para esto es necesario recolectar un extenso conjunto de datos de campo que abarque toda la heterogeneidad ambiental y de manejo de la zona. En este punto los modelos lineales de efectos mixtos surgen como una potente herramienta de análisis ya que permiten evaluar datos desbalanceados y/o con estructuras jerárquicas que por lo tanto no cumplen el supuesto de independencia. Un antecedente valioso en la zona de estudio es el reciente

trabajo de Madias et al. (2021). En el mismo se utiliza esta metodología para identificar los principales predictores del rendimiento de soja en una zona que incluye a la evaluada en el presente capítulo pero que se extiende hacia el Este, abarcando la mayor parte de la provincia del Chaco y el norte de Santa Fe. Estos autores encontraron que los principales predictores del rendimiento fueron: las lluvias desde un mes antes a la siembra y hasta la etapa de madurez fisiológica, los años de historia agrícola del lote, la evapotranspiración de referencia desde la siembra hasta R7, el nivel de fósforo del suelo y el número de períodos de 2 días con temperaturas máximas superiores a 35°C desde el inicio de la floración (R1) hasta R7 y la fecha de siembra. Estas variables predictoras no necesariamente son las que aplican en la zona bajo estudio en la presente tesis ya que aquel trabajo abarca una zona mucho más amplia y con factores ambientales muy diferentes. Al abarcar un área tan amplia, es entendible la gran variabilidad encontrada en las variables medidas (ej. años de agricultura, nivel de fósforo en el suelo, fechas de siembra). Por lo tanto, es esperable que en la zona de estudio de esta tesis, de menor superficie, se encuentre menor variabilidad en algunos parámetros y que las predicciones y las implicancias prácticas no coincidan con las de estos antecedentes. Por otro lado, al abarcar un área más reducida, los resultados a obtener se ajustarían más a la misma y serían de gran utilidad para conceptualizar el esquema de producción de soja en la zona y determinar estrategias de manejo acordes.

En este capítulo se reúne una extensa colección de datos de campo con el objetivo de evaluar la influencia de diferentes predictores ambientales, de manejo y genotípicos en el rendimiento de soja. Finalmente, utilizando modelos de efectos mixtos, se define el modelo que mejor describe la variabilidad en el rendimiento de soja en el Chaco Semiárido-Subhúmedo.

## 3.2. Materiales y métodos

### 3.2.1. Área de estudio

El Chaco Semiárido y el Subhúmedo son dos subregiones del Gran Chaco Americano (Adámoli *et al.*, 2011) que ocupan gran parte de las provincias de Santiago del Estero y Chaco, al norte de Argentina. En ambas regiones las precipitaciones presentan una alta variabilidad interanual y un régimen monzónico, con mayores precipitaciones en verano (diciembre a marzo), que en invierno (junio a septiembre). Los valores van desde 500 hasta 750, y desde 750 hasta 950 mm (1901-2011) en el Chaco Semiárido y en el Subhúmedo respectivamente (Naumann, 2006).

### 3.2.2. Datos de campo

Los datos de producción de soja provinieron de grupos de productores AACREA (Asociación Argentina de Consorcios Regionales de Experimentación Agrícola) Guayacán y Gancedo-La Paloma (63% de los datos) y ensayos de la Red de Evaluación de Cultivares de Soja del NEA (Aapresid; INTA-EEA Las Breñas) y de la Región Norte de Argentina (INTA-EEA Famaillá) (37% de los datos). Fueron reunidos 2840 datos de lotes de producción de soja de 168 materiales genéticos diferentes, durante 8 campañas agrícolas (2006 a 2013), en 21 localidades en el Chaco Subhúmedo y ocho en el Semiárido (Fig. 3.1). La superficie de los lotes fue de entre cinco y 590 ha. El set de datos incluyó el rendimiento medio de soja en cada lote, y variables sobre manejo agronómico (fecha de siembra, densidad a cosecha, distancia entre hileras, material genético y fertilización), historia agrícola (cultivos antecesores en los 5 años previos a la siembra, años de uso agrícola y años de siembra directa en el lote), disponibilidad hídrica (precipitaciones mensuales en el

campo entre octubre y abril y perfil hídrico del suelo) y características del suelo (materia orgánica, nitrógeno, fósforo, azufre y pH).

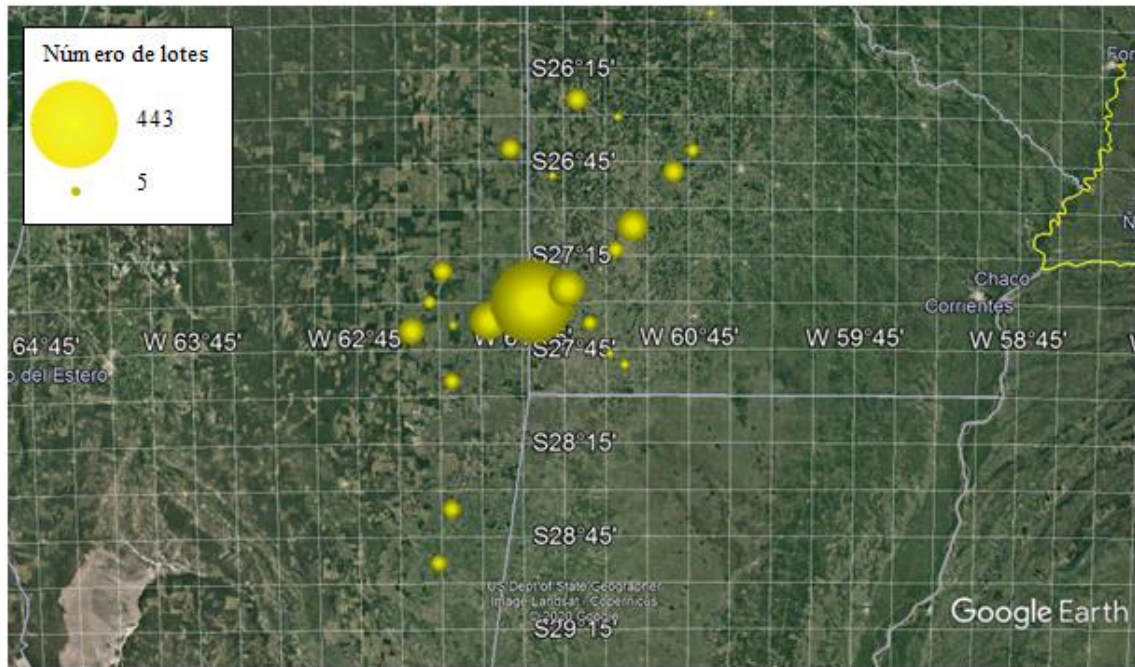


Figura 3.1. Distribución de los 2840 lotes agrícolas que conformaron la base de datos de soja. El tamaño del círculo amarillo indica la cantidad de lotes en cada localidad del Chaco Semiárido y Subhúmedo, cuyo rango fue 5-443 lotes.

Además se incorporaron a la base de datos una serie de variables ambientales calculadas a partir de la información climática diaria (temperatura máxima, mínima, radiación solar y precipitaciones) de seis estaciones del INTA ubicadas en Las Breñas, Bandera, Sachayoj, Añatuya, Castelli, y Los Frentones (<http://siga2.inta.gov.ar/>), y una de la Sociedad Rural del Noreste Santiagueño en Quimili. Estas variables fueron: temperaturas máximas medias, temperaturas medias, precipitaciones acumuladas, precipitaciones efectivas acumuladas, evapotranspiración potencial e índices de estrés por calor (ver sección 3.2.3).

### 3.2.3. Variables predictoras del modelo

Las variables predictoras fueron clasificadas en cinco grupos:

#### i. Manejo agronómico e historia agrícola

Variables cuantitativas: fecha de siembra (como días desde el 1 de diciembre), densidad a cosecha ( $\text{pl m}^{-2}$ ), distancia entre hileras (cm), grupo de madurez del material genético, años de uso agrícola, años de siembra directa y antecesores de los cinco años previos a la siembra. Ésta última variable se expresó como cantidad de años con cada cultivo o doble cultivo. (Las gramíneas fueron contabilizadas en un mismo grupo).

Variables categóricas: fertilización (si/no), hábito de crecimiento del material genético (determinado/indeterminado/semideterminado).

#### ii. Disponibilidad hídrica

Variables cuantitativas: precipitaciones (mm) y precipitaciones efectivas acumuladas (mm), evapotranspiración potencial (mm) según Hargreaves y relación precipitación/evapotranspiración (mm). Todas estas variables fueron calculadas mensualmente y en diferentes períodos entre octubre y abril.

Variables categóricas: perfil hídrico del suelo (malo, regular o bueno).

#### iii. Temperatura

Variables cuantitativas: temperaturas máximas y medias mensuales y en diferentes períodos entre diciembre y abril ( $^{\circ}\text{C}$ ).

#### iv. Estrés por calor

Variables cuantitativas: número de días (días) y sumatoria de grados( $^{\circ}\text{C}$ ) en los que la temperatura máxima estuvo por encima de seis umbrales (20, 25, 30, 35, 40, 45  $^{\circ}\text{C}$ ) en nueve períodos diferentes durante el ciclo del cultivo (0-50, 50-100, 50-150, 100-150, 150-200, 0-150, 0-250, 100-200, 150-300 días desde la siembra).

## v. Suelo

VARIABLES CUANTITATIVAS: materia orgánica (%), nitrógeno (%), fósforo Bray (ppm), azufre (ppm) y pH.

### 3.2.4. Análisis estadístico y selección de modelos

Para explorar la influencia de variables ambientales y de manejo en el rendimiento de soja en el área de estudio, se comenzó evaluando modelos lineales simples de efectos mixtos para cada uno de los cinco grupos de variables similares (manejo agronómica e historia agrícola, disponibilidad hídrica, temperatura, estrés por calor y suelo). Se utilizaron modelos de efectos mixtos ya que estos pueden utilizarse con datos no balanceados y con observaciones faltantes, y son particularmente útiles cuando las mediciones se realizan en unidades estadísticas relacionadas (Smith *et al.* 2005). La combinación Localidad×Año fue considerada como el ambiente porque algunas observaciones provenían de sitios cercanos, y del mismo sitio en distintos años. El factor ambiente fue considerado como aleatorio y la variable predictora como el factor fijo. Estos modelos fueron del tipo:

$$Y_i = \beta_{0j} + \beta_1 * X_i + \epsilon_i$$

donde  $Y_i$  es el rendimiento en grano en el lote  $i$ ,  $\beta_{0j}$  es el efecto aleatorio del ambiente  $j$ ,  $\beta_1 * X_i$  es el efecto fijo del predictor  $X$  y  $\epsilon_i$  es el residual del modelo.

Una vez seleccionado el mejor predictor dentro de cada uno de los cinco grupos de variables ambientales y de manejo similares, se plantearon modelos multivariados mixtos, incluyendo desde todos los predictores hasta sólo dos de ellos, y todas sus posibles interacciones (aditivas o interactivas). La estructura de estos modelos fue la misma que la de los modelos simples, con el mismo componente aleatorio, pero considerando más de un predictor. Las observaciones de los predictores candidatos de efectos fijos se estandarizaron

mediante *z-scores* para abordar el hecho de que los predictores presentaban escalas muy diferentes; los *z-scores* no modifican la relación funcional entre las variables predictoras y la variable respuesta.

Para realizar el análisis de efectos mixtos se utilizó el paquete lme4 (Bates *et al.* 2015) del software estadístico R (R *Development Core Team*, 2019). Tanto para los modelos mixtos univariados como para los multivariados, se siguió un protocolo establecido (Zuur *et al.* 2010) para evaluar i) *outliers*, ii) homogeneidad de varianzas, iii) distribución normal, e iv) independencia, y la existencia y tipo de relación de la variable predictora con el rendimiento, a través de diagramas de dispersión y el coeficiente de correlación de Pearson. Para verificar el supuesto de homocedasticidad se inspeccionaron visualmente los gráficos de residuos estandarizados en función de los predichos para el modelo general, y para cada una de las variables predictoras. Para verificar el supuesto de normalidad se realizaron gráficos del tipo *qq-plot*, para comparar la distribución de los residuales del modelo (que se asumió normal) con la distribución normal teórica. La correlación temporal entre los residuos se evaluó con la función de auto-correlación (ACF). Los coeficientes de los modelos se estimaron utilizando ML (máxima verosimilitud), ya que la componente aleatoria fue siempre la misma, y sólo se fueron modificando los predictores. La multicolinealidad entre predictores en los modelos multivariados fue evaluada a través de los valores de VIF (Factor de Inflación de la Varianza), utilizando el paquete car (Fox y Weisberg, 2011), y siguiendo el criterio de que valores de VIF menores a 10 indican que no hay problemas de multicolinealidad. Para la selección de los modelos se siguió el enfoque de inferencia multimodelo basado en la teoría de la información (Burnham *et al.* 2011). El enfoque de inferencia multimodelo no se basa en el supuesto de que existe un único "modelo verdadero", sino que se examinan diversas hipótesis que

compiten simultáneamente para identificar el mejor conjunto de modelos capaz de resumir qué "efectos" (representados por predictores) pueden ser respaldados por los datos. La selección de los predictores de los modelos se basó en el criterio de información de Akaike (AIC) (Burnham *et al.* 2011). Para la selección de los predictores para el modelo multivariado final, se siguió la estrategia *top-down* de selección de modelos. La bondad de ajuste de los modelos mixtos se evaluó, además de con su valor de AIC y su peso relativo, con el  $R^2$  de los modelos ajustados siguiendo a Nakagawa y Schielzeth (2013). El  $R^2$  marginal representa la varianza explicada por los factores fijos, mientras que el  $R^2$  condicional representa la varianza explicada por todo el modelo (efectos fijos y aleatorios).

### 3.3. Resultados y discusión

#### 3.3.1. Descripción general de la base de datos

La base de datos con información de 2840 lotes presentó una amplia variabilidad ambiental y de manejo. Las fechas de siembra abarcaron desde el 2 de diciembre hasta el 20 de febrero. La densidad a cosecha varió entre 11,8 y 42,7 pl m<sup>-2</sup> y la distancia entre hileras entre 35 y 70 cm. El rango de grupos de madurez de los 168 materiales genéticos fue 4,4 – 9, con una media de 7,63 y un desvío de 0,87 (ver Figura S3.1 en Material suplementario) y la historia agrícola de los lotes varió entre 3 y 18 años de uso. En los 5 años previos a la siembra el cultivo antecesor más habitual fue soja, seguido por maíz y en menor medida trigo, sorgo, girasol, algodón, avena, cultivo de cobertura, Gatton Panic y pasturas. Sólo en el 7% de los lotes hubo doble cultivo como girasol/soja, cultivo de cobertura/soja, maíz/soja, trigo/soja y girasol/maíz. Solamente se fertilizó el 8% de los lotes. La precipitación acumulada entre diciembre y marzo varió ampliamente entre los lotes, con valores desde 89 hasta 857 mm, mientras que la temperatura máxima media



estuvo entre 29,6 y 36,9°C para el mismo período. El rendimiento también presentó gran variabilidad entre los 2840 lotes, con un mínimo de 104 kg ha<sup>-1</sup>, un máximo de 6004 kg ha<sup>-1</sup> y una media de 2392 kg ha<sup>-1</sup>.

### 3.3.2. Modelos lineales simples de efectos mixtos

Dentro de cada uno de los cinco grupos de variables, las que explicaron la mayor proporción de la varianza del rendimiento fueron la cantidad de años con antecesor soja (AS) (Fig. 3.2), las precipitaciones efectivas entre octubre y abril (POA), los días con temperaturas máximas mayores a 35°C entre el día 50 y 100 desde la siembra (D35<sub>50-100</sub>) (Fig. 3.4) y la temperatura máxima media entre diciembre y abril (TDA), dentro del grupo manejo agronómico, disponibilidad hídrica, estrés por calor y temperatura, respectivamente. Ninguna de las variables del grupo suelo mostró asociación con el rendimiento de soja.




Figura 3.2. Relación entre el rendimiento en grano de la soja (kg ha<sup>-1</sup>) y los años con soja en los 5 años previos a la siembra. La línea es la regresión lineal ajustada a los datos.

En la Figura 3.2 se muestra la relación entre los años con soja como cultivo antecesor en los cinco años previos a la siembra y el rendimiento de soja. Cuantos mayores fueron los años con soja, menores fueron los rendimientos. Sin embargo, se observa en la figura que el caso con cero años de soja como antecesor, no sigue dicha tendencia, sino que el rendimiento medio es inferior al de los demás casos (exceptuando al caso de cinco años consecutivos de siembra de soja). Una posible explicación es que la cantidad de lotes de la base de datos con cero años de siembra de soja como antecesor, fue considerablemente pequeño, con tan solo 0,5% de los lotes que componían la base de datos. Además, estos rendimientos fueron notoriamente bajos (en solamente tres lotes el rendimiento estuvo por encima de los  $1500 \text{ kg ha}^{-1}$ ), con lo cual o bien puede tratarse de errores en el registro de los datos o bien de la incidencia de alguna plaga u otro factor similar que provocó disminuciones del rendimiento.

El rendimiento medio con un solo año de soja fue de  $2827 \text{ kg ha}^{-1}$ . Los cultivos antecesores fueron en general maíz y algodón, intercaladamente. Con cinco años consecutivos de siembra de soja el rendimiento se redujo a menos de la mitad (i.e.,  $1225 \text{ kg ha}^{-1}$ ). Además se observa en la figura que con cinco años de monocultivo de soja, la variabilidad de los rendimientos fue considerablemente menor, concentrándose en un 75% de los casos en valores por debajo de  $1326 \text{ kg ha}^{-1}$ , mientras que con un año de soja, dicho valor ascendió a  $3880 \text{ kg ha}^{-1}$ . Resulta importante destacar que la mayor variabilidad de los rendimientos ocurrió con un año de soja (i.e.,  $DE = 1207 \text{ kg ha}^{-1}$ ), mientras que con cinco años de soja, se redujo a  $870 \text{ kg ha}^{-1}$ . Por lo tanto, evitar el cultivar soja un año tras otro resultaría recomendable, no sólo por sus implicancias ambientales sino también productivas. Los datos recogidos muestran que la siembra consecutiva de soja sin alternancia con otros cultivos se asocia con bajos rendimientos. La relación entre los años

con soja y el rendimiento fue estudiada por diversos autores en ensayos a campo (e.g. Andrade et al., 2022; Bacigaluppo et al., 2009; Crookston et al., 1991; Yamoah et al., 1998; Wilhelm et al., 2004), donde observaron mayores rendimientos de soja en rotación, que en monocultivo. Los beneficios de las rotaciones en el rendimiento están asociados con sus diferentes efectos positivos en la conservación de la humedad del suelo, la disponibilidad de nutrientes y la estructura del suelo, así como en el control de malezas, insectos y enfermedades (e.g. Karlen et al., 1994, 2006). Villarino et al. (2017), en un trabajo realizado en el Chaco Semiárido, encontraron que la proporción de maíz en rotación estuvo negativamente asociada con la pérdida de C orgánico del suelo, a su vez estas pérdidas estuvieron asociadas positivamente con la proporción de soja en la rotación.

Dentro del grupo de variables de manejo e historia agrícola, la fecha de siembra no surgió como una variable relevante en la determinación del rendimiento. En cambio, Madias et al. (2021) en un trabajo que incluyó la zona de estudio de esta tesis, identificaron la fecha de siembra como la variable de manejo más relevante para determinar el rendimiento en grano de la soja. El resultado encontrado en esta tesis, probablemente se explique porque en la región, desde hace algunos años, las fechas de siembra son hacia diciembre/enero con el fin de evitar los estreses hídricos y térmicos en los períodos críticos del cultivo. Esta adaptación en el manejo estuvo reflejada en la base de datos, donde no hubo ninguna fecha de siembra anterior al 2 de diciembre. Por lo tanto en este análisis no se exploró el rango de fechas de siembra anteriores a diciembre. Otra variable dentro de este grupo que no surgió como relevante fueron los años con siembra directa. Esto muy probablemente haya sido porque en solamente 12 de los 2840 lotes los años con siembra directa fueron menores o iguales a 5. En cambio, en el resto de los lotes, los años con siembra directa fueron considerables (i.e. mayor o igual a 6 años). De Moraes et al. (2016)

en un trabajo en una región subtropical vecina de Brasil, concluyeron que la adopción de la siembra directa aumentó la calidad física del suelo y la disponibilidad de agua para los cultivos. También existen trabajos nacionales que pusieron en evidencia lo mismo (e.g. Basanta & Alvarez, 2015; Díaz-Zorita et al., 2022).

Dentro de las variables predictoras asociadas a la disponibilidad de agua, la que presentó mayor asociación con el rendimiento fue la precipitación efectiva entre octubre y abril, con un valor de AIC muy por debajo de los modelos simples con otras variables de este grupo. Por ejemplo, la precipitación efectiva durante el ciclo del cultivo (diciembre-abril) presentó un valor de AIC 314 veces mayor. Esto indica no sólo la importancia de las lluvias durante el ciclo del cultivo, sino también de la acumulación de agua previa a la siembra en el perfil del suelo. En este sentido, estrategias de manejo tendientes a favorecer la acumulación de agua en el perfil, serán beneficiosas para aumentar el rendimiento. Las estrategias a considerar incluyen la siembra directa – que ya se implementa en la zona – así como la rotación soja-maíz junto con un cultivo de cobertura invernal. El rastrojo aportado por el maíz es más eficiente que el de soja en la captación y conservación de agua en el suelo, debido a su mayor volumen y duración, y por lo tanto mejor cobertura. Por su parte, los cultivos de cobertura pueden ayudar a evitar la degradación del suelo (Villarino et al., 2017), reducir su erosión y mejorar su agregación en climas semiáridos (Blanco-Canqui et al., 2013). Existen diversos reportes sobre el uso de cultivos de cobertura en la zona (e.g. Prieto Angueira et al., 2018a, Prieto Angueira et al., 2018b, Prieto Angueira et al., 2019). Por ejemplo Prieto Angueira et al. (2022) encontraron que los cultivos de cobertura aportaban restos vegetales que mejoraron la infiltración y almacenaje de agua pero que además incrementaron la disponibilidad de nitrógeno por la fijación biológica y permitieron aumentar hasta un 19% la EUA. También resulta importante destacar que dentro del grupo

disponibilidad de agua, la precipitación efectiva resultó de mayor relevancia para el rendimiento que las precipitaciones. La precipitación efectiva se refiere a aquella que se infiltra en el suelo, sin llegar a perderse por escorrentía o por filtración profunda. Esto resalta el hecho de que en la región, una proporción del agua de lluvia relevante para la productividad se pierde, posiblemente por escorrentía. Esto remarca aún más la importancia de aquellas estrategias tendientes al aprovechamiento del agua de lluvia. Wright et al. (2012), en un trabajo de revisión sobre sistemas mixtos en regiones subtropicales, concluyeron que en los sistemas agrícola-ganaderos la productividad de agua era mayor que en sistemas de cultivos, además de reducir el riesgo. Sería interesante la implementación de este tipo de sistemas en la región de estudio.

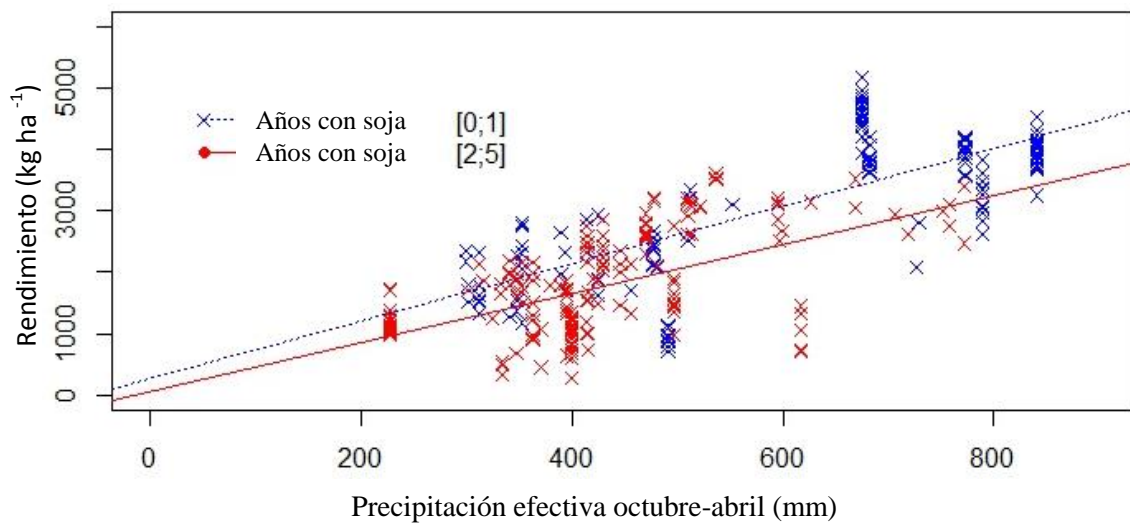


Figura 3.3. Relación entre el rendimiento de grano de soja ( $\text{kg ha}^{-1}$ ) y la precipitación efectiva entre octubre y abril (mm) afectada por la cantidad de años con soja en los cinco años previos a la siembra. Las rectas representan las regresiones lineales de los datos.

En cuanto a las variables asociadas al estrés por calor, el mejor predictor del rendimiento de soja fue la cantidad de días con temperaturas máximas superiores a  $35^{\circ}\text{C}$ , entre el día 50 y el 100 desde la siembra (coeficiente de correlación de Pearson,  $r= 0.47$ ). En la Figura 3.4 se muestra la relación entre  $D35_{50-100}$  y el rendimiento. A medida que

aumentó  $D35_{50-100}$ , el rendimiento disminuyó, y cuando el cultivo estuvo expuesto a más de 14 días con temperaturas máximas superiores a  $35^{\circ}\text{C}$ , el rendimiento nunca superó los  $4000 \text{ kg ha}^{-1}$ . Otros índices de estrés por calor evaluados, con el mismo umbral de temperatura, pero en otros períodos del ciclo del cultivo, tales como 0-50, 0-250, 100-150 y 150-200 días desde la siembra, presentaron nulas o menores asociaciones con el rendimiento ( $r=0, 0.43, 0.31$  y  $0$ , respectivamente). Cuando un estrés ocurre durante el período crítico para la generación del rendimiento, la productividad se verá irremediablemente afectada. En soja, este período se ubica entre “- inicio de formación de vainas” (R3) y “máximo tamaño de semilla” (R6) (Monzón et al., 2021), y en esta región ocurre generalmente entre el día 40 y el 110 desde la siembra. Fue un resultado esperable entonces, que el índice de estrés por calor identificado como el de mayor asociación con el rendimiento, haya sido el que se ubica entre el día 50 y el 100 desde la siembra, ya que coincide con el período crítico del cultivo. En cuanto al umbral de temperatura del índice, según el modelo de Jones et al. (1991), la respuesta de la tasa de desarrollo relativa de un cultivo a la temperatura está definida por una función lineal tri-segmentada definida por cuatro parámetros: la temperatura base, la óptima inferior, la óptima superior y la máxima, que se modifican en función de la ontogenia. En el caso de soja, la temperatura óptima superior en la etapa reproductiva tardía - que coincide en gran parte con el período crítico - es  $34^{\circ}\text{C}$ . A partir de este umbral, la tasa de desarrollo disminuye. Por lo tanto, tal como era esperable, el umbral de temperatura del índice identificado como el mejor por el modelo fue  $35^{\circ}\text{C}$ . Es importante conocer la tolerancia del cultivo al estrés por calor, no sólo por las características climáticas de la región de estudio - que como ya se mencionó presenta las máximas temperaturas absolutas del continente - sino también en el contexto del cambio climático global, que indica un aumento en la frecuencia de episodios de estrés térmico

(Tebaldi et al., 2006; IPCC, 2007), considerado por el Intergovernmental Panel on Climate Change (IPCC) como una importante amenaza para la provisión global de alimentos (IPCC, 2007).

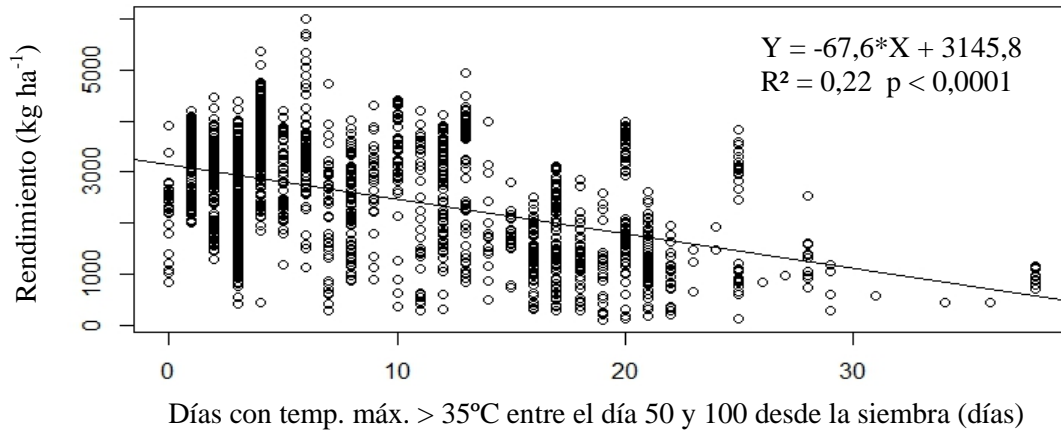


Figura 3.4. Relación entre el rendimiento de grano de soja (kg ha<sup>-1</sup>) y los días con temperaturas máximas mayores a 35°C entre el día 50 y 100 desde la siembra (días). La recta representa la regresión lineal de los datos.

Al evaluar como posibles predictores del rendimiento de soja a variables asociadas a la temperatura, se encontró que la variable con mayor poder explicativo de la variabilidad del rendimiento fue la temperatura máxima media entre diciembre y abril. Otras variables evaluadas, como temperaturas medias y temperaturas máximas en diferentes períodos del ciclo del cultivo, presentaron una relación de menor magnitud con el rendimiento. Esto indica la sensibilidad del cultivo a las temperaturas máximas durante todo su ciclo (de diciembre a abril), y no en alguna fase específica del cultivo, lo cual resulta sumamente relevante en un área como la de estudio, con temperaturas máximas extremas. La estrecha relación entre la temperatura y el rendimiento no se limita solamente a la Región Chaqueña, sino que también ha sido reportada en diferentes regiones. Por ejemplo, Andrade y Satorre (2015) encontraron que el promedio de temperatura diaria en los estadios reproductivos de la soja, fue uno de los más importantes determinantes del rendimiento de la soja en la Región Pampeana. Esta región, a diferencia de la Región Chaqueña, presenta un promedio

de temperaturas considerablemente menor, lo que podría explicar que el efecto de la temperatura sobre el rendimiento de soja se encuentre acotado a los estadios reproductivos, ya que el cultivo raramente se encuentre expuesto a temperaturas extremas y por consiguiente a eventos de estrés térmico. Lobell y Asner (2003) encontraron resultados similares analizando el efecto del cambio climático en los rendimientos de soja en zonas templadas de los Estados Unidos. En el norte de China, Zhang *et al.* (2010) reportaron que el aumento de la temperatura en estadios avanzados de la floración de la soja, acortaron el período de crecimiento, con una consecuente reducción del rendimiento en un 45%. Como una posible estrategia de manejo ante esto, Yang *et al.*, (2007) seleccionaron variedades de soja con un período de crecimiento más largo. Sin embargo, en el análisis de modelos mixtos aquí realizado, el grupo de madurez no surgió como una variable relevante en la determinación del rendimiento, por lo que no surge como una estrategia recomendable en la zona de estudio. Una posible explicación a este resultado es que si bien la base de datos presentó un amplio rango de grupos de madurez, la mayoría fueron GM mayores a 7, con escasa representatividad de GM menores. En la figura 3.5 se observa que con TDA inferiores a aproximadamente los 32°C, no existe una tendencia clara hacia la disminución del rendimiento ante mayores TDA. Sin embargo, a partir de aproximadamente los 32°C se observa una tendencia marcada hacia una disminución del rendimiento con el aumento de TDA. Con valores de TDA por encima de aproximadamente 33°C los rendimientos estuvieron siempre por debajo de los 4000 kg ha<sup>-1</sup>. Andrade y Satorre (2015), analizando una extensa base de datos de la región pampeana, encontraron que los rendimientos más altos de soja se obtenían a temperaturas moderadas.



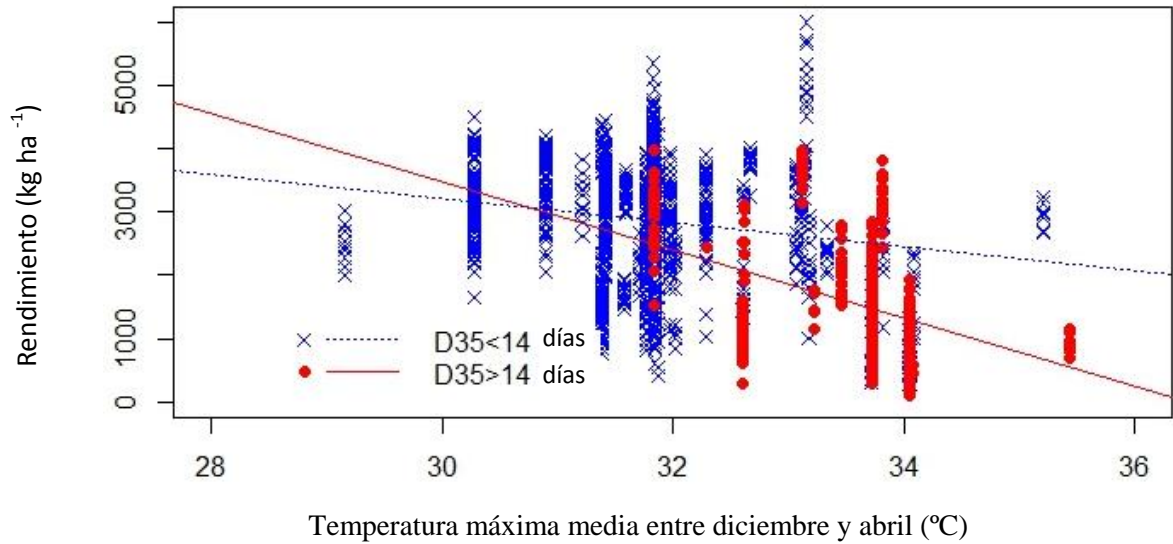


Figura 3.5. Relación entre el rendimiento de grano de soja (kg ha<sup>-1</sup>) y la temperatura máxima media entre diciembre y abril (°C) afectada por los días con temperaturas máximas mayores a 35°C entre el día 50 y 100 desde la siembra (D35<sub>50-100</sub>). Las rectas representan las regresiones lineales de los datos.

### 3.3.3. Modelos lineales múltiples de efectos mixtos

Luego de identificar las cuatro variables predictoras dentro de cada grupo que mayor asociación tuvieron con el rendimiento, se evaluaron diferentes posibles modelos múltiples de efectos mixtos, considerando relaciones aditivas e interactivas entre las diferentes variables, y considerando todas o sólo algunas de ellas. En el Cuadro 3.1, a modo de ejemplo figuran algunos de los modelos evaluados, con su respectivo valor de AIC, de R<sup>2</sup> marginal y de R<sup>2</sup> condicional, ordenados de menor a mayor AIC. El modelo que mejor explicó la variabilidad del rendimiento (modelo 1 en Cuadro 3.1) incluyó a las cuatro variables predictoras (D35<sub>50-100</sub>, TDA, POA y AS) e interacciones entre D35<sub>50-100</sub> y TDA, y entre POA y AS.

Cuadro 3.1. Estructura general de los modelos múltiples de efectos mixtos, para predecir el rendimiento de la soja en el Chaco Semiárido y Subhúmedo, mostrada con algunos ejemplos. Los modelos difieren en los predictores incluidos y en las relaciones interactivas o aditivas entre ellos. Se arribó al modelo final (# 1) a través del proceso de selección de modelos por pasos de acuerdo al Criterio de Información de Akaike (AIC).

Modelos	Predictores	AIC	R <sup>2</sup> Marg.	R <sup>2</sup> Cond.
1. Calor × Temperatura y Precipitaciones × Años Soja	$\text{Rend}_{.i} = \text{D35}_{50-100} + \text{TDA} + \text{POA} + \text{AS} + \text{D35}_{50-100} \times \text{TDA} + \text{POA} \times \text{AS} + (\text{Sitio} \times \text{Año})_j + \epsilon_i$	1724.2	0.89	0.95
2. Modelo completo	$\text{Rend}_{.i} = \text{D35}_{50-100} \times \text{TDA} \times \text{POA} \times \text{AS} \times (\text{Sitio} \times \text{Año})_j + \epsilon_i$	1727.9	0.93	0.95
3. Sin Temperatura y efectos aditivos	$\text{Rend}_{.i} = \text{D35}_{50-100} + \text{POA} + \text{AS} + (\text{Sitio} \times \text{Año})_j + \epsilon_i$	1728.1	0.83	0.95
4. Sin Calor y efectos aditivos	$\text{Rend}_{.i} = \text{TDA} + \text{POA} + \text{AS} + (\text{Sitio} \times \text{Año})_j + \epsilon_i$	1748.0	0.63	0.95
5. Sin Precipitaciones y efectos aditivos	$\text{Rend}_{.i} = \text{D35}_{50-100} + \text{TDA} + \text{AS} + (\text{Sitio} \times \text{Año})_j + \epsilon_i$	2384.0	0.46	0.90
6. Sin Temperatura y sin Calor y efectos aditivos	$\text{Rend}_{.i} = \text{POA} + \text{AS} + (\text{Sitio} \times \text{Año})_j + \epsilon_i$	4870.4	0.15	0.87
7. Sin Años Soja y efectos aditivos	$\text{Rend}_{.i} = \text{D35}_{50-100} + \text{TDA} + \text{POA} \times (\text{Sitio} \times \text{Año})_j + \epsilon_i$	7609.2	0.33	0.90
8. Sin Años Soja y efectos interactivos	$\text{Rend}_{.i} = \text{D35}_{50-100} \times \text{TDA} \times \text{POA} + (\text{Sitio} \times \text{Año})_j + \epsilon_i$	7616.3	0.33	0.90
9. Modelo nulo	$\text{Rend}_{.i} = (\text{Sitio} \times \text{Año})_j + \epsilon_i$	43526.5	----	----

R<sup>2</sup> Marg. (R<sup>2</sup> marginal): representa la varianza explicada por los factores fijos, R<sup>2</sup> Cond. (R<sup>2</sup> condicional): representa la varianza explicada por todo el modelo. Rend.: rendimiento de soja, D35<sub>50-100</sub>: días con temperaturas máximas mayores a 35°C entre el día 50 y 100 desde la siembra, TDA: temperatura máxima media entre diciembre y abril, POA: precipitaciones efectivas entre octubre y abril, AS: cantidad de años con antecesor soja,  $\epsilon$ : error.

En la figura 3.3 se muestra la relación entre el rendimiento y las precipitaciones efectivas entre octubre y abril, y el efecto interactivo de los años con soja en esa relación. Como era esperable, a medida que aumentaron las precipitaciones, aumentó el rendimiento. Cuando en el lote hubo entre dos y cinco años con soja como antecesor (en los últimos cinco años), la respuesta del rendimiento a las precipitaciones fue menor que cuando sólo hubo entre cero y un año con soja. La pendiente de la recta de ajuste en el primer caso fue 4,7 kg ha<sup>-1</sup> mm<sup>-1</sup>, y en el segundo caso fue de 4 kg ha<sup>-1</sup> mm<sup>-1</sup>. Es decir que el rendimiento aumentó en promedio 4,7 kg ha<sup>-1</sup> por mm de lluvia caída cuando en el lote hubo menos de un año con antecesor soja, mientras que si hubo más de dos años con soja, este aumento fue

menor ( $4 \text{ kg ha}^{-1}$  por mm de lluvia caída). El modelo que no incluyó al predictor años con soja presentó un valor de AIC considerablemente superior al resto de los modelos del Cuadro 3.1. Cabe destacar que el predictor del grupo disponibilidad hídrica no fueron las precipitaciones, sino las precipitaciones efectivas. Esto indica que una parte de las lluvias se perdieron por escorrentía, la cual se asocia con el grado de compactación del suelo, agudizado, entre otras causas, por el monocultivo de soja. Todos estos resultados resaltan la importancia de la historia agrícola en la determinación del rendimiento de soja en la Región Chaqueña. En particular, ponen de relieve la importancia de evitar el monocultivo de soja, y recurrir a otras alternativas, como por ejemplo cultivar soja en rotación para aumentar la eficiencia en el uso del agua (una de las principales limitantes agrícolas en la zona). Además las rotaciones se asocian con mejoras en las propiedades físicas y en la materia orgánica del suelo y con la interrupción del ciclo de malezas, factores que también se asocian con disminuciones de rendimiento (Karlen *et al.* 1994, 2006).

En la figura 3.5 se muestra la relación entre el rendimiento y la TDA, y la interacción entre la TDA y el índice de estrés por calor  $D35_{50-100}$ . El coeficiente de correlación de Pearson entre el índice de estrés por calor y la temperatura máxima fue de 0,73. La exclusión de la variable de temperatura (modelo 3) o de estrés por calor (modelo 4) aumentaron el valor de AIC en relación al mejor modelo (modelo 1), pero no en gran magnitud (en 3,9 y 23,8 unidades, respectivamente). En cambio, la exclusión de ambas variables en simultáneo (modelo 5) aumentó considerablemente el valor de AIC (en 3146,2 unidades). Esto remarca, como es sabido, la estrecha correlación entre la temperatura y el estrés por calor, y su importancia en la determinación del rendimiento de soja en la Región Chaqueña, y en particular del estrés por calor. Como era esperable, a medida que la temperatura máxima aumentó, el rendimiento de soja disminuyó (Fig. 3.5). La magnitud de

los efectos del estrés por calor en un cultivo depende de la duración del estrés, del rango de temperatura explorado y de las demás condiciones ambientales (Molino, 2011). En la figura 3.5 se observa que cuando  $D35_{50-100}$  fue mayor a 14 días, la disminución del rendimiento por mayores temperaturas fue más marcada. Es decir que la tolerancia del cultivo a una dada temperatura máxima fue mayor si ocurrieron pocos eventos de estrés por calor. En cambio, si el cultivo estuvo expuesto a mayores días con estrés por calor, su tolerancia al aumento de la temperatura fue menor. Cuando la temperatura máxima estuvo por encima de  $32^{\circ}\text{C}$  el rendimiento fue menor cuando  $D35_{50-100}$  fue superior a 14 días. Cuando la temperatura máxima media estuvo por debajo de aproximadamente  $32^{\circ}\text{C}$ , no ocurrieron eventos de estrés por calor, lo que evidencia la interacción entre ambas variables. En otras palabras, más eventos de estrés por calor resultaron en menores rendimientos con altas temperaturas pero no con bajas. Por ejemplo, observando la figura 3.5, a una temperatura máxima de aproximadamente  $34^{\circ}\text{C}$ , los casos donde los eventos de estrés por calor fueron mayores ( $D35 > 14$  días, curva roja continua) tendieron a rendir menos que aquellos donde los eventos de estrés por calor fueron menores ( $D35 < 14$  días, curva azul punteada). Por lo tanto las consecuencias negativas de las altas temperaturas sobre el rendimiento serán mayores cuanto mayores sean los eventos de estrés por calor, o dicho de otro modo, la relación entre el rendimiento y la temperatura se encuentra modulada por el estrés por calor.

Al analizar los valores del  $R^2$  marginal, el modelo 3 (Cuadro 3.1), que no incluyó al predictor de temperatura (i.e., TDA), presentó un valor de 0,83, mientras que el modelo 4, que no incluyó al predictor de estrés por calor (i.e.,  $D35_{50-100}$ ) tuvo un  $R^2$  marginal menor (i.e., 0,63). Teniendo en cuenta que el  $R^2$  marginal explica la varianza de los factores fijos del modelo, y que es mayor en el modelo con estrés por calor que en el modelo con

temperatura, nuevamente es posible concluir que el estrés por calor tuvo mayor poder explicativo del rendimiento de soja que la temperatura máxima por sí sola.

Además de que el modelo con mejor ajuste haya sido el que incluía la interacción entre la temperatura máxima y el índice de estrés por calor, es habitual también encontrar un efecto interactivo de la temperatura con las precipitaciones sobre el rendimiento. Por ejemplo, Molino (2011), en experimentos a campo en Córdoba, evaluó los efectos de breves episodios de estrés térmico y su interacción con déficit hídrico en soja y encontró que la alta temperatura con secano redujo el rendimiento en un 45% respecto al control regado. En cambio, en este trabajo, el modelo que incluía la interacción entre temperatura y disponibilidad hídrica, presentó un valor de AIC mayor que el modelo 1, es decir, un peor ajuste.

#### 3.4. Conclusión

El rendimiento de soja en la región estuvo fuertemente determinado por variables climáticas. En este trabajo fue posible establecer un umbral de temperatura máxima (35°C) y un umbral de tolerancia de estos eventos de estrés por calor (14 días) a partir de los cuales se ve fuertemente afectado el rendimiento de soja en la región. La estrategia de manejo recomendable es diversificar, en la medida de lo posible, los cultivos sembrados en cada operación. Como se observa en otros capítulos esta diversificación, podría incluir la siembra de híbridos tropicales de maíz, que tienden a soportar mejor las altas temperaturas y el estrés por calor característicos de la Región Caqueña (Casali *et al.*, 2018). En línea con esta recomendación, el análisis con modelos mixtos permitió cuantificar la alta relevancia de la historia agrícola del lote sobre la productividad de soja. En particular se encontró un marcado efecto negativo de la siembra de soja año tras año (i.e. monocultivo) sobre el

mismo suelo. Por otro lado, las precipitaciones, tanto en el periodo pre-siembra como durante el ciclo del cultivo, también conformaron una variable importante en la determinación del rendimiento. Los análisis realizados dejaron en evidencia la importante interacción entre las precipitaciones y los años con soja, con una mayor eficiencia en el uso del agua por parte del cultivo en campos donde no se sembró soja (o sólo se hizo durante una campaña agrícola) en el pasado (i.e., últimos 5 años previos a la siembra).

### 3.5. Material suplementario




Figura S3.1. Frecuencia absoluta de los grupos de madurez de soja de la base de datos.

# CAPÍTULO 4

## Producción resiliente de soja y maíz bajo un clima variable en el Chaco Semiárido y Subhúmedo <sup>2</sup>

<sup>2</sup> El contenido de este capítulo es una transcripción de la publicación: Casali, L., Herrera, J. M., & Rubio, G. 2022. Resilient soybean and maize production under a varying climate in the semi-arid and sub-humid Chaco. *European Journal of Agronomy*, 135, 126463.

#### 4.1. Introducción

Muchas de las tierras agrícolas actuales eran bosques que se deforestaron para destinar esas tierras a la agricultura. La expansión de las fronteras agrícolas continúa hoy en día en varias zonas del mundo, especialmente en áreas de menor aptitud agrícola, ya que las tierras más adecuadas ya están siendo cultivadas (Dang et al., 2019) o gestionadas como áreas protegidas. Las nuevas zonas son, por tanto, excesivamente sensibles a la degradación ambiental y necesitan prácticas de gestión específicas, probablemente diferentes de las que tienen una historia agrícola más larga. La demanda de una gestión adecuada a nivel local debe abordarse debido a la creciente presión por los productos agrícolas. Si la creciente demanda no se satisface con el aumento de la producción, se espera que la expansión de las fronteras agrícolas a expensas de los entornos naturales continúe en el futuro. Uno de los mayores retos a la hora de diseñar estas estrategias es que estas nuevas áreas, por definición, carecen de una historia agrícola suficiente que oriente sobre las mejores prácticas y facilite la adaptación de los cultivos a las condiciones locales.

La región del Chaco, que abarca amplias zonas de Argentina, Brasil y Paraguay, registra una de las mayores tasas de deforestación del mundo (Kuemmerle et al., 2017). En cuanto al clima, se puede dividir en dos subregiones: el Chaco Subhúmedo que tiene un clima subtropical subhúmedo con precipitaciones anuales entre 750 y 950 mm (1901-2011) y el Chaco Semiárido que tiene un clima subtropical semiárido con una precipitación media anual entre 500 y 750 mm (1901-2011) (Naumann et al., 2004). Las precipitaciones se concentran en la época de verano y presentan una gran variabilidad interanual en ambas subregiones, pero especialmente en el Chaco Semiárido. Este régimen permite una agricultura de secano con altos riesgos de sequías y estrés térmico (Ricard et al., 2015). Debido a que las temperaturas anuales más altas coinciden con la temporada de lluvias, las



limitaciones en el crecimiento y la productividad de los cultivos se atribuyen principalmente a los déficits de agua (Giménez et al., 2015; Pérez-Carrera et al., 2008). El desarrollo y la sostenibilidad de la agricultura en la región del Chaco están, por tanto, condicionados por el régimen de precipitaciones y térmico y requieren una adecuada planificación y una correcta gestión de los recursos (Gorleri, 2005). Aunque se han documentado brechas de rendimiento explotables en la Región Caqueña (Aramburu-Merlos et al., 2015), la mejora de la productividad de los cultivos requiere un manejo optimizado en relación con las características de los sitios (Casali et al., 2018). Por ejemplo, Cammarano et al. (2019) mostraron que en la cuenca mediterránea el impacto del clima futuro sobre la productividad de la cebada es negativo, pero algunas localidades se verán menos afectadas que otras.

La seguridad alimentaria y la estabilidad económica de muchos países en desarrollo, como los de la región del Chaco, dependen de la resiliencia de los principales cultivos a la variabilidad climática (Hansen et al., 2019; Kahiluoto et al., 2019). Mientras que la resiliencia representa la capacidad de los sistemas agrícolas para mantener una producción de alimentos suficiente y nutritiva frente a las perturbaciones ambientales (Bullock et al., 2017; Kahiluoto et al., 2019), la variabilidad climática es la forma en que el clima fluctúa por encima o por debajo de un valor medio a largo plazo según Dinse (2009). La resiliencia ha surgido como un concepto clave para estudiar la vulnerabilidad de los sistemas agrícolas a las variaciones de las condiciones ambientales (Douxchamps et al., 2017). Los parámetros a considerar comprenden la producción y la diversidad nutricional, así como la estabilidad socioeconómica del suministro de alimentos (Bullock et al., 2017). El estudio de las respuestas de los cultivos a la variabilidad climática local permite anticipar los riesgos que conlleva y ayudar a diseñar estrategias para mantener altos niveles de resiliencia y

productividad (Ray et al., 2015). Los estudios basados en la variabilidad climática histórica son útiles para detectar tendencias, determinar interacciones, cuantificar impactos y conceptualizar hipótesis (Burnham et al., 2011). Esto es esencial porque el manejo de los cultivos debe garantizar que los sistemas agrícolas sean lo suficientemente resilientes para hacer frente a los impactos del cambio climático. La dinámica temporal de la demanda de agua de los sistemas cultivados está determinada por factores como el genotipo y la fecha de siembra (entre otros). No siguen necesariamente la estacionalidad y la variabilidad interanual de las precipitaciones (Giménez et al., 2020). Los datos climáticos del pasado pueden ser especialmente útiles en zonas sin registros históricos agrícolas, ya que pueden acoplarse a modelos de simulación agronómica para estudiar la asociación entre la variabilidad climática local y el rendimiento de los cultivos. Mediante este enfoque, se puede estimar el rendimiento del grano y evaluar las estrategias de manejo compatibles con las condiciones climáticas locales. Este enfoque ya se ha utilizado en zonas con una larga historia agrícola (e.g., Bell y Fischer, 1994; Lal et al., 1999; Lobell et al., 2013, 2005). Por ejemplo, Lobell et al. (2013), utilizando APSIM y 46 años de datos climáticos del Medio Oeste de Estados Unidos, encontraron una respuesta negativa y marcada en el rendimiento del maíz a las temperaturas superiores a 30°C, y una respuesta relativamente débil a las precipitaciones. Los estudios sobre la relación entre la variabilidad del clima y el rendimiento de los cultivos suelen tener en cuenta las anomalías de las variables climáticas en lugar de los datos sin procesar. Las anomalías climáticas se estiman principalmente mediante tres enfoques: (i) comparando el valor anual de la variable con la media de todos los años disponibles (e.g., Burnham et al. 2011); (ii) comparando el valor anual con el año anterior (e.g., Ray et al. 2015, Giménez et al. 2015); o (iii) comparando el valor anual con el valor estimado a través de una tendencia lineal que considera todo el periodo estudiado

(e.g., Burnham et al. 2011). La mayoría de los estudios sobre la asociación entre la variabilidad climática histórica y la productividad agrícola se centraron en un solo cultivo (e.g. Lobell et al. 2013, Lobell et al., 2014), probablemente porque el objetivo principal era dilucidar los mecanismos fisiológicos. Sin embargo, la decisión de qué cultivos sembrar y cómo distribuir la superficie agrícola entre diferentes cultivos que comparten la misma temporada de crecimiento puede tener importantes consecuencias en la resiliencia de los sistemas agrícolas.

Dado que las regiones semiáridas y subhúmedas del Chaco tienen una historia agrícola corta (<10-15 años), no existen conjuntos de datos fiables que capten los efectos de la variabilidad climática en el rendimiento de los cultivos. En este sentido, los modelos de simulación son una herramienta valiosa para entender la adaptación de los cultivos principales al entorno local (Battisti et al., 2017; Cammarano et al., 2020; Casali et al., 2021). Utilizando este enfoque y los registros climáticos de las últimas décadas, los objetivos de este capítulo fueron: (i) identificar las principales variables climáticas que influyen en la productividad de la soja y el maíz y (ii) evaluar el impacto de la variabilidad interanual de las variables climáticas en la productividad de la soja y el maíz.

Cabe aclarar que en los capítulos 2 y 3 de esta tesis se realizó un análisis con modelos mixtos de una extensa base de datos de campo de la zona con datos entre 2006-2013 y 2010-2014, para soja y maíz respectivamente, con variables climáticas y de manejo, con el objetivo de determinar las principales variables que determinan la productividad de los cultivos de soja y de maíz en la zona de estudio. En este capítulo, con el objetivo de aislar a las variables climáticas de las de manejo y para conocer con mayor exactitud su efecto en los cultivos de maíz y soja en la región, se utilizaron base históricas de datos

climáticos de la zona (1994-2014 y 1967-2014 en Quimili y Las Breñas, respectivamente), y se trabajó con rendimientos simulados.

## 4.2. Materiales y métodos

### 4.2.1. Área de estudio

El trabajo se realizó en dos zonas representativas de la región semiárida y subhúmeda del Chaco: Quimilí (27°38'S, 62°25'O) y Las Breñas (27°04' S, 61°04' E), respectivamente. Esta región presenta una de las mayores tasas de deforestación del mundo (Kuemmerle et al., 2017). Las áreas deforestadas se cultivan principalmente con maíz y soja (Domínguez y Rubio, 2019).

### 4.2.2. Modelos de cultivos

Se utilizaron los modelos CERES-*Maize* y CROPGRO-*Soybean*, que forman parte de DSSAT v4.5 (Hoogenboom et al., 2010), para evaluar el efecto de las variables climáticas en el rendimiento de maíz y soja. Ambos modelos fueron calibrados previamente para la zona de estudio con el híbrido de maíz DK747 (Capítulo 2 - Casali et al., 2018) y el genotipo de soja A8000 (Capítulo 5 - Casali et al., 2021). Los parámetros de manejo del cultivo se ajustaron de acuerdo a las prácticas más frecuentemente utilizadas por los agricultores locales: la fecha de siembra fue el 31 de diciembre, la distancia entre hileras fue de 52 cm y las densidades de plantas fueron de 245.000 y 60.000 plantas ha<sup>-1</sup> para soja y el maíz, respectivamente. Cada simulación comenzó en la fecha de cosecha del cultivo anterior, que fue aproximadamente seis meses antes de la fecha de siembra del cultivo analizado. Los residuos de los cultivos no se incorporaron al suelo, asumiendo prácticas de siembra directa, que es el método habitual de preparación del suelo en la zona de estudio.

El contenido inicial de agua del suelo se fijó en el 60% de la capacidad de almacenamiento de agua del suelo. Las simulaciones fueron realizadas en modo *seasonal*.

Los datos del suelo se obtuvieron de la base de datos SigSE (Angueira et al., 2007). En las simulaciones se utilizó el perfil de suelo más representativo de cada lugar: serie de suelo 7 de agosto (Haplustol Entico) para Quimilí y serie Tizón (Haplustol Óxico) para Las Breñas (Cuadro 4.1).

Cuadro 4. 1. Datos analíticos de los dos perfiles de suelo utilizados en las simulaciones.

Horizonte	Quimili: serie 7 de Agosto, Haplustol éntico				Las Breñas: serie Tizón, Haplustol óxico						
	Ap	IIAC	IIC1	IIC2	Ap12	A	Bw1	Bw2	C	Ck1	Ck2
Profundidad (cm)	0- 15	15-47	47- 77	77- 200	0-19	19- 34	34- 51	51- 81	81- 123	123- 144	144- 200
Arcilla (%)	15	7	9	9	31.5	35.6	36.1	33.7	29.3	27.5	22.4
Arena (%)	31	52	48	46	21.6	16.2	17.7	24.4	18.5	17.7	18.6
C orgánico(%)	1.32	0.58	0.32	0.32	1.25	0.59	0.27	0.12	-	-	-
N total (%)	0.13	0.09	0.05	0.04	0.13	0.01	-	-	-	-	-

La información climática para realizar las simulaciones (i.e. temperatura máxima y mínima diaria, precipitaciones diarias y radiación solar diaria) se obtuvo de las estaciones meteorológicas del INTA (Instituto Nacional de Tecnología Agropecuaria) Las Breñas y la estación meteorológica Quimili, de la Sociedad Rural del Noreste Santiagueño, a excepción de la radiación solar para Quimili, que se extrajo de NASA POWER (<https://power.larc.nasa.gov/data-access-viewer/>). Se utilizaron todos los registros climáticos disponibles: 1994-2014 (21 años) para Quimilí y 1967-2014 (48 años) para Las Breñas para maximizar la probabilidad de detectar anomalías. Para minimizar las fuentes de variación y centrarse en la identificación de los efectos climáticos sobre la productividad de los cultivos, todas las simulaciones se realizaron utilizando las mismas condiciones iniciales del suelo y las

mismas prácticas de manejo. Así, el único parámetro que cambió de un año a otro fueron las condiciones climáticas. Por la misma razón, las simulaciones se realizaron sin limitaciones nutricionales, incluido el nitrógeno.

#### 4.2.3. Modelos mixtos

Se comprobó hasta qué punto las variaciones en las condiciones climáticas (temperaturas máximas y mínimas, precipitaciones y radiación solar) y los fenómenos extremos se traducen en anomalías en el rendimiento de la soja y el maíz. Las anomalías de los rendimientos de grano simulados y de los índices climáticos se estimaron como desviaciones de una tendencia general. Los valores anuales de los índices climáticos se estimaron para un período de tiempo correspondiente a la temporada de crecimiento de los cultivos, de acuerdo con la siguiente fórmula:

$$\Delta x_i = \frac{x_i}{\mu}$$

donde  $\Delta x_i$  es la anomalía de la variable  $x$  para el año  $i$ ,  $x_i$  es el valor medio durante la estación de crecimiento para el año  $i$ , y  $\mu$  es la media global de todos los años con registros climáticos disponibles. Para la tendencia global, se utilizaron 21 años de datos de Quimilí y 48 años de datos de Las Breñas.

Se utilizaron modelos lineales mixtos para definir los modelos que mejor describían la relación entre las anomalías en el rendimiento simulado y las anomalías en los índices climáticos. Estos modelos tienen la ventaja de que pueden utilizarse con datos no balanceados y pueden hacer frente a las observaciones faltantes (Smith et al., 2005). Aunque el objetivo final era hallar modelos multivariados que explicaran la relación entre las anomalías de la variabilidad climática y las anomalías de la variabilidad en el

rendimiento de maíz y de soja, se comenzó por desarrollar modelos simples para cada grupo de variables ambientales similares. Esto se hizo para obtener una visión más detallada de las características y la gravedad de las limitaciones impuestas por cada tipo de variable climática. Los grupos fueron:

a. Temperatura y evapotranspiración. Se consideraron las temperaturas máximas y mínimas ( $^{\circ}\text{C}$ ) para diferentes períodos entre enero y abril, y durante diferentes fases fenológicas. En la soja las fases fueron cinco: VE-R1, R1-R5, R5-R7, E-R7 y de siembra a cosecha. En el maíz, las fases fueron seis: VE-V6, V6 a inducción floral, inducción floral a R1 (i.e., antesis), R1 a inicio de llenado de grano, llenado de grano y de siembra a cosecha. La evapotranspiración (mm) se estimó según el enfoque de Hargreaves (Hargreaves y Samani, 1985) para cuatro períodos (0-50, 0-150, 50-100 y 100-150 días después de la siembra; DDS). En este caso, y también en el de los demás grupos, la razón de utilizar meses, etapas de crecimiento del cultivo y DDS (i.e., tres escalas temporales diferentes) fue minimizar el riesgo de perder información crítica sobre las limitaciones debido a los desajustes entre las escalas temporales y los eventos climáticos. En total, se calcularon 27 variables para la soja y 29 variables para el maíz para este grupo de parámetros.

b. Radiación solar ( $\text{MJ m}^2$ ). Se estimó para los mismos períodos descritos anteriormente. Además, se calculó un cociente fototermal como la relación entre la radiación solar y la temperatura media por encima de la temperatura base (i.e., en soja  $6^{\circ}\text{C}$  y en maíz  $8^{\circ}\text{C}$ ). En total, para este grupo se calcularon 10 variables para la soja y 12 para el maíz.

c. Estrés térmico. Se generaron varios índices basados en los días y los grados acumulados de temperatura máxima ( $^{\circ}\text{C}$ ) por encima de seis umbrales de temperatura (20, 25, 30, 35, 40 y  $45^{\circ}\text{C}$ ) para cuatro períodos del ciclo del cultivo (0-50, 0-150, 50-100 y 100-

150 DDS). En total, se calcularon 48 variables tanto para el maíz como para la soja en este grupo.

d. Disponibilidad de agua e índice de estrés hídrico. En las simulaciones se consideraron las precipitaciones acumuladas (mm) en diferentes periodos entre diciembre y abril, y durante diferentes fases definidas por los estadios fenológicos del cultivo. Además de las mediciones directas más sencillas, se estimaron índices agroclimáticos como la relación entre la evapotranspiración según Hargreaves (mm) y la precipitación acumulada (mm) en cuatro periodos (0-50, 50-100, 100-150 y 0-150, DDS). Además, se consideró un índice de estrés hídrico incluido en DSSAT. Este índice tiene en cuenta la relación entre la absorción de agua del cultivo y el potencial de transpiración (Ritchie, 1998). Por lo tanto, puede cuantificar las condiciones de estrés no sólo basándose en la disponibilidad de agua, sino también teniendo en cuenta la demanda de agua de los cultivos. Se calculó para diferentes periodos entre diciembre y abril, y para diferentes fases definidas por los estados fenológicos de los cultivos. En total, se calcularon 34 variables para la soja y 37 para el maíz.

Se calcularon las anomalías de estas variables ambientales y para identificar las variables más explicativas dentro de cada uno de los cuatro grupos, se evaluaron los coeficientes de correlación de Pearson entre las anomalías de los rendimientos de los cultivos simulados y las anomalías de las variables ambientales. Una vez determinadas las principales variables explicativas del rendimiento dentro de cada grupo, se ajustaron modelos mixtos simples, que fueron del tipo:

$$\text{Anomalía del rendimiento} = \mu + \text{Anomalía del predictor climático} + \text{Año} + e \quad (2)$$



donde  $\mu$  es la anomalía media del rendimiento del grano, la Anomalía del predictor climático es la anomalía de la variable climática, el Año es el efecto del año, y  $e$  es un residual que comprende la variación no explicada por los componentes anteriores. La anomalía del predictor climático se estableció como factor de efecto fijo, mientras que el año se estableció como factor aleatorio. Se evaluaron los predictores climáticos más informativos dentro de cada grupo de variables similares para identificar un modelo mixto multivariado parsimonioso para cada cultivo. En el grupo de radiación solar para la soja, ninguna de las variables mostró una correlación significativa con el rendimiento del cultivo. Por lo tanto, se corrieron los modelos multivariados sin predictor del grupo de radiación solar. La estructura de estos modelos fue la misma que la de los modelos simples pero considerando más de un predictor. En este caso, el predictor climático se estableció como un factor de efecto fijo mientras que el año se estableció como un factor aleatorio.

Se utilizó el paquete lme4 (Bates et al., 2015) del software R (R Development Core Team, 2015) para el análisis de efectos mixtos de las relaciones entre las anomalías en el rendimiento de soja y maíz y los predictores climáticos. Se siguió un protocolo establecido (Zuur et al., 2010) para comprobar (i) valores atípicos, (ii) homogeneidad de la varianza, (iii) distribución normal, (iv) independencia y (v) tipo de relación entre el predictor candidato y la variable respuesta. Para verificar el supuesto de homocedasticidad, se inspeccionaron visualmente los gráficos de los residuos estandarizados para cada una de las variables predictivas. Para verificar el supuesto de normalidad, se realizaron gráficos del tipo qq-plot, para comparar la distribución de los residuales del modelo (que se asumió normal) con la distribución normal teórica. También se controlaron las posibles tendencias espaciales evaluando la homogeneidad de varianzas entre los dos sitios que se consideraron (Quimilí y Las Breñas).

La correlación temporal entre los residuos se evaluó con la función de autocorrelación (ACF). La multicolinealidad entre predictores en los modelos multivariados se evaluó con VIF (Factor de Inflación de la Varianza) del paquete R "car" (Fox y Weisberg, 2018) y siguiendo el criterio de que valores de VIF menores a 10, descartan problemas de multicolinealidad. Para la selección de los modelos se siguió el enfoque de inferencia multimodelo basado en la teoría de la información (Burnham et al. 2011). El enfoque de inferencia multimodelo no se basa en el supuesto de que existe un único "modelo verdadero", sino que se examinan diversas hipótesis que compiten simultáneamente para identificar el mejor conjunto de modelos capaz de resumir qué "efectos" (representados por predictores) pueden ser respaldados por los datos. La selección de los predictores de los modelos se basó en el criterio de información de Akaike (AIC) (Burnham et al. 2011). Para la selección de los predictores para el modelo multivariado final, se siguió la estrategia *top-down* de selección de modelos. La bondad de ajuste de los modelos mixtos se evaluó, además de con su valor de AIC y su peso relativo, con el  $R^2$  de los modelos ajustados siguiendo a Nakagawa y Schielzeth (2013). El  $R^2$  marginal representa la varianza explicada por los factores fijos, mientras que el  $R^2$  condicional representa la varianza explicada por todo el modelo (efectos fijos y aleatorios).

### 4.3. Resultados

#### 4.3.1. Caracterización climática

Durante la temporada de crecimiento de los cultivos de verano (enero-abril), entre 1995-2015 en Quimilí, la media  $\pm$  error estándar de las temperaturas máximas y mínimas fue de  $30,8 \pm 1,3^\circ\text{C}$  y  $19,7 \pm 1,2^\circ\text{C}$ , respectivamente. Estos valores fueron bastante similares en Las Breñas entre 1968-2015:  $31,1 \pm 1,3^\circ\text{C}$  y  $19,3 \pm 0,9^\circ\text{C}$ , respectivamente (Fig. 4.1). La

radiación solar durante el ciclo de cultivo fue en promedio de  $19,4 \pm 1,1 \text{ MJ m}^{-2}$  en ambas localidades, mientras que la precipitación promedio durante el ciclo de cultivo fue menor en Quimilí ( $430,9 \pm 143,4 \text{ mm}$ ) que en Las Breñas ( $519,9 \pm 168,5 \text{ mm}$ ).




Figura 4.1. De arriba a abajo: promedio de temperatura máxima, temperatura mínima, radiación solar y precipitación acumulada durante el ciclo del cultivo (enero-abril) en Quimilí entre 1995 y 2015 (derecha) y en Las Breñas entre 1968 y 2015 (izquierda). En línea punteada se indican los valores medios en cada caso.




Figura 4.2. Rendimiento simulado por los modelos CROPGRO-Soybean y CERES-Maize para soja (arriba) y maíz (abajo) respectivamente, en Quimilí (izquierda) y Las Breñas (derecha). La media se indica en línea punteada.

#### 4.3.2. Soja

Los rendimientos medios de grano de soja simulados para Quimilí y Las Breñas durante los períodos de estudio fueron de 2519 y 2476 kg ha<sup>-1</sup>, respectivamente (Fig. 4.2). Dentro del grupo de temperatura, la anomalía de la temperatura máxima promedio de enero a abril ( $\Delta TM_{1-4}$ ) se identificó como el mejor predictor de las anomalías del rendimiento de la soja ( $r = 0,48$ ) (Fig. 4.3). Este periodo cubre casi todo el ciclo del cultivo, desde la siembra hasta la madurez fisiológica. A mayores valores de  $\Delta TM_{1-4}$ , menores valores de  $\Delta Rend Sim$ . En años en los que la  $\Delta TM_{1-4}$  estuvo 3°C por encima de la temperatura

máxima media de 31°C para ese periodo, el rendimiento de soja simulado fue 600 kg ha<sup>-1</sup> inferior a la media de todo el periodo estudiado (Fig. 4.3).

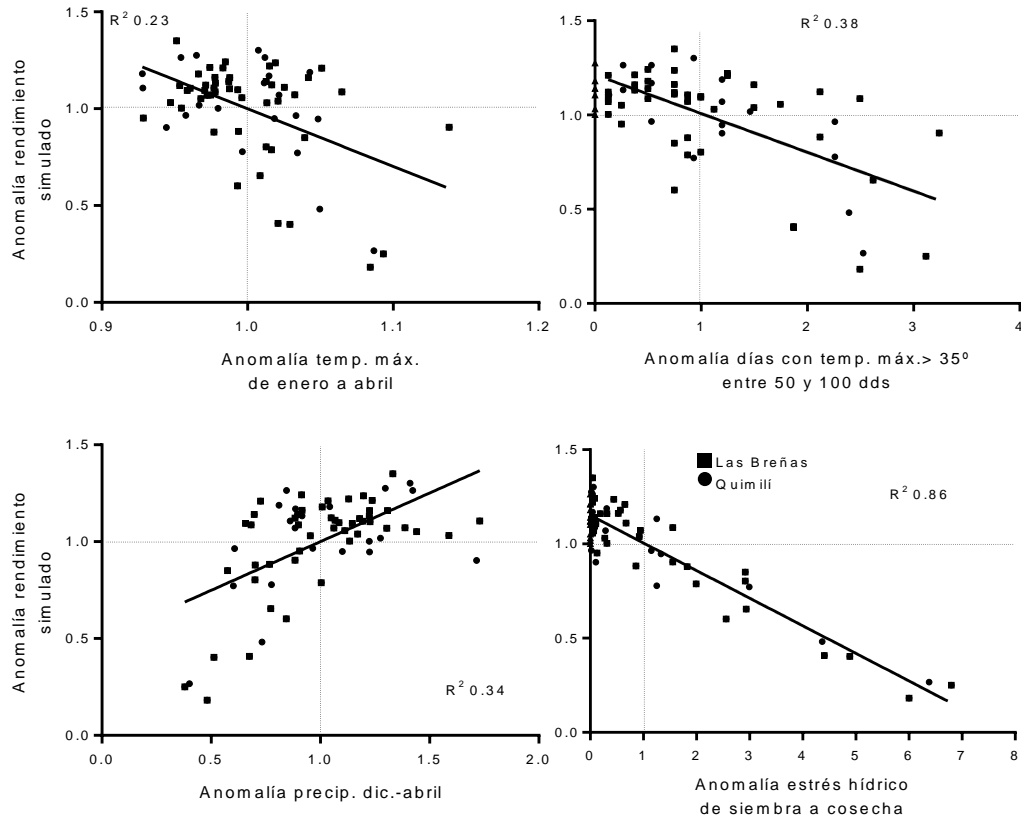


Figura 4.3. Anomalia del rendimiento de la soja simulada por CROPGRO-Soybean en función de a) la anomalía de la temperatura máxima entre enero y abril; b) la anomalía de los días con temperatura máxima superior a 35°C entre los días 50 y 100 después de la siembra; c) la anomalía de la precipitación acumulada entre diciembre y abril; y d) la anomalía del índice de estrés hídrico entre la siembra y la cosecha. La anomalía se representa como una línea recta de la regresión lineal entre ambas variables y el valor  $R^2$  correspondiente. Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimilí. Los triángulos indican los ceros, que no fueron considerados en el análisis de regresión. La correlación fue altamente significativa ( $p < 0,001$ ). Las líneas punteadas indican la anomalía con valor 1. La anomalía se calculó en relación con los valores medios correspondientes a 21 y 48 años de datos en Quimilí y Las Breñas, respectivamente. Ejemplo: un valor de 1 en el eje x indica que en ese año la temperatura máxima coincidió con la media histórica y un valor de 1,1 indica que fue un 10% superior.

En cuanto a las variables relacionadas con el estrés térmico, las correlaciones indicaron que el número de días con más de 35°C durante el periodo 50-100 DDS ( $\Delta D35_{50-100}$ ).

100), que coincide con las fases fenológicas R4 - R6, fue el mejor predictor de las anomalías en el rendimiento de la soja ( $R^2 = 0,38$ ). A mayores valores de  $\Delta D_{35_{50-100}}$ , menores valores de  $\Delta \text{Rend Sim}$ . El rendimiento de grano simulado fue sistemáticamente inferior a la media cuando  $\Delta D_{35_{50-100}}$  fue superior a 2,5, lo que significa que el número de días durante el periodo entre 50 y 100 DDS con temperaturas máximas superiores a 35°C fue superior a 20 (Fig. 4.3). El índice  $\Delta D_{35_{50-100}}$  mostró una mayor asociación con el rendimiento de grano que el mismo índice de estrés térmico calculado para otros períodos del ciclo del cultivo. Ninguna de las variables relacionadas con la radiación solar se asoció significativamente con las anomalías en el rendimiento de grano de la soja, como ya se mencionó en los materiales y métodos.

Entre las variables relacionadas con la disponibilidad de agua, la anomalía de la precipitación de diciembre a abril ( $\Delta P_{12-4}$ ) (Fig. 4.3) fue el predictor que explicó la mayor cantidad de varianza en las anomalías de rendimiento simuladas ( $R^2 = 0,34$ ). Un modelo asintótico se ajustaba mejor a los datos que uno lineal (datos no mostrados), probablemente porque las respuestas a la precipitación disminuían después de alcanzar un cierto umbral (Fig. 4.3). Los valores umbrales a partir de los cuales nuevos incrementos de la precipitación ya no dieron lugar a aumentos en el rendimiento de grano de soja fueron 562 mm en Quimilí y 639 mm en Las Breñas. Estos umbrales correspondieron aproximadamente a la media de las precipitaciones acumuladas entre diciembre y abril.

Entre los diferentes periodos para los que se estimó el índice de estrés hídrico del DSSAT, el índice del ciclo completo del cultivo fue el que mostró una mayor asociación ( $r = 0,92$ ) con la anomalía simulada del rendimiento de soja. A mayores valores del índice de estrés hídrico menores valores de  $\Delta \text{Rend Sim}$ . Los valores inferiores o superiores a 0,05 (la media del índice de estrés hídrico de DSSAT en todos los años estudiados) se asociaron en

general con rendimientos de grano superiores o inferiores, respectivamente, al rendimiento medio de grano de todo el conjunto de datos. El índice de estrés hídrico estimado para periodos más cortos del ciclo de cultivo mostró una correlación menor pero aún significativa con la anomalía de rendimiento simulada (i.e.,  $r = 0,87$  en R5-R7 y  $r = 0,72$  en R1-R5). El índice de estrés hídrico del DSSAT estuvo influenciado principalmente por tres variables climáticas: la cantidad de precipitación de diciembre a abril ( $R^2 = 0,42$ ), la temperatura máxima media entre enero y abril ( $R^2 = 0,39$ ), y el número de días con una temperatura máxima superior a  $35\text{ }^{\circ}\text{C}$  entre 50 y 100 DDS ( $R^2 = 0,40$ ) (Fig. 4.4). Cuando se compararon las pendientes de las tres relaciones, la mayor pendiente se encontró para la temperatura máxima media entre enero y abril (pendiente =  $0,0383$ ). Las pendientes de las relaciones entre el índice de estrés hídrico y la precipitación y entre el índice de estrés hídrico y el estrés térmico, fueron considerablemente menores ( $0,0003$  y  $0,0078$ , respectivamente).




Figura 4.4. Índice de estrés hídrico entre siembra y cosecha simulado por CROPGRO-Soybean en función de las precipitaciones acumuladas entre diciembre y abril (izquierda), la temperatura máxima entre enero y abril (medio) y los días con temperatura máxima por encima de  $35^{\circ}\text{C}$  entre los días 50 y 100 desde la siembra (derecha). Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimili. Se presentan las rectas de las regresiones lineales entre las variables y las correspondientes pendientes. Las tres correlaciones fueron altamente significativas ( $p < 0.001$ ).

Los predictores con mayor poder explicativo para cada grupo de variables se consideraron conjuntamente en modelos multivariados (Cuadro 4.2) que permitieron



identificar los factores más influyentes que afectan al rendimiento del grano de soja. Entre los modelos que se consideraron (Cuadro 4.2), el modelo 1 fue el que mostró un mayor ajuste global. Este modelo incluyó variables previamente identificadas dentro de los grupos de temperatura y evapotranspiración, estrés térmico e índice de estrés hídrico:  $\Delta TM_{1-4}$ ,  $\Delta D35_{50-100}$  y  $\Delta EH_{s-c}$ . Estas variables mostraron relaciones aditivas entre ellas (Cuadro 4.2). Ninguna variable de los grupos de radiación solar y disponibilidad de agua fue retenida por este modelo. El modelo 2 incluyó las mismas tres variables más la variable  $\Delta P_{12-4}$ . Cuando se eliminó  $\Delta EH_{s-c}$  del modelo (modelo 5 en el Cuadro 4.2), el valor de AIC aumentó drásticamente (de -135 a -32), mientras que eliminar  $\Delta TM_{1-4}$  y  $\Delta D35_{50-100}$  tuvo un impacto menor en el AIC (de -135 a -123). Estos resultados indican que  $\Delta EH_{s-c}$  fue la variable con mayor asociación con el rendimiento de la soja, seguida de las variables  $\Delta TM_{1-4}$  y  $\Delta D35_{50-100}$ .

Cuadro 4.2. Estructura general de algunos de los modelos lineales mixtos planteados para predecir la anomalía del rendimiento de soja simulado por el modelo CROPGRO-Soybean en una localidad del Chaco Semiárido (Quimili) y una del Chaco Subhúmedo (Las Breñas), a partir de series climáticas históricas de los períodos 1994-2014 y 1967-2014 para cada localidad, respectivamente. Los modelos difieren en los predictores incluidos y en las relaciones (aditivas o interactivas) entre ellos. Los modelos se encuentran ordenados del mejor al peor ajuste según el criterio de información de Akaike (AIC). En negrita se resaltan los dos mejores modelos (diferencia de AIC < 2).

Variables removidas	Modelo	AIC	Peso	R <sup>2</sup> marg.	R <sup>2</sup> cond.
<b>1. <math>\Delta P_{12-4}</math></b>	<b><math>\Delta \text{Rend Sim}_i = \Delta \text{TM}_{1-4} + \Delta \text{D35}_{50-100} + \Delta \text{EH}_{s-c} + (\text{Año})_i + \epsilon_i</math></b>	<b>-135.1</b>	<b>0.264</b>	<b>0.89</b>	<b>0.93</b>
<b>2. Ninguna</b>	<b><math>\Delta \text{Rend Sim}_i = \Delta \text{TM}_{1-4} + \Delta \text{D35}_{50-100} + \Delta \text{P}_{12-4} + \Delta \text{EH}_{s-c} + (\text{Año})_i + \epsilon_i</math></b>	<b>-133.1</b>	<b>0.097</b>	<b>0.89</b>	<b>0.93</b>
3. $\Delta \text{D35}_{50-100}$	$\Delta \text{Rend Sim}_i = \Delta \text{TM}_{1-4} + \Delta \text{P}_{12-4} + \Delta \text{EH}_{s-c} + (\text{Año})_i + \epsilon_i$	-125.7	0.002	0.88	0.93
4. $\Delta \text{TM}_{1-4}$	$\Delta \text{Rend Sim}_i = \Delta \text{D35}_{50-100} + \Delta \text{P}_{12-4} + \Delta \text{EH}_{s-c} + (\text{Año})_i + \epsilon_i$	-123.7	<0.001	0.87	0.94
5. $\Delta \text{EH}_{s-c}$	$\Delta \text{Rend Sim}_i = \Delta \text{TM}_{1-4} + \Delta \text{D35}_{50-100} + \Delta \text{P}_{12-4} + (\text{Año})_i + \epsilon_i$	-32.0	<0.001	0.51	0.69

$\Delta \text{Rend Sim}_i$ , anomalía\* del rendimiento en grano de soja simulado por CROPGRO-Soybean;  $\Delta \text{TM}_{1-4}$ , anomalía de la temperatura máxima entre enero y abril;  $\Delta \text{D35}_{50-100}$ , anomalía del número de días con temperatura máxima por encima de 35°C entre los días 50 y 100 desde la siembra;  $\Delta \text{P}_{12-4}$ , anomalía de las precipitaciones acumuladas entre diciembre y abril;  $\Delta \text{EH}_{s-c}$ , anomalía del estrés hídrico entre siembra y cosecha.  $\epsilon_i$ , error.

\*Las anomalías fueron calculadas en relación a los valores medios correspondientes a los 21 y 48 años de datos en Quimili y Las Breñas respectivamente.

#### 4.3.3. Maíz

Los rendimientos de maíz simulados durante 1994-2014 en Quimilí y 1967-2014 en Las Breñas promediaron 7026 y 7314 kg ha<sup>-1</sup>, respectivamente (Fig. 4.2). Entre las variables del grupo de temperatura, la temperatura máxima durante el llenado de grano ( $\Delta \text{TM}_{\text{llenado}}$ ) mostró la mayor correlación con la anomalía simulada del rendimiento de maíz ( $r = 0,74$ ) (Fig. 4.5), seguida de la temperatura máxima media entre la siembra y la cosecha ( $r = 0,67$ ). A mayores valores de  $\Delta \text{TM}_{\text{llenado}}$ , menores valores de  $\Delta \text{Rend Sim}$ . En los años en

los que la  $TM_{\text{llenado}}$  fue superior a la media de  $31^{\circ}\text{C}$ , el rendimiento de maíz simulado fue  $1792 \text{ kg ha}^{-1}$  inferior a la media de todo el periodo estudiado (Fig. 4.5).

Entre las variables evaluadas dentro del grupo de estrés térmico, el número de días con temperaturas máximas superiores a  $30^{\circ}\text{C}$  entre 50 y 100 DDS ( $\Delta D_{30_{50-100}}$ ) tuvo la mayor correlación ( $r = 0,6$ ) con las anomalías en el rendimiento de grano del maíz. Como era de esperar, cuanto mayor fue la anomalía de  $\Delta D_{30_{50-100}}$ , menor fue el valor de la anomalía en el rendimiento de grano de maíz simulado (Fig. 4.5). Cuando  $\Delta D_{30_{50-100}}$  superó el promedio de días con temperaturas máximas superiores a  $30^{\circ}\text{C}$  para el período evaluado en cada sitio (24 y 29 días en Quimilí y Las Breñas, respectivamente), los rendimientos de grano de maíz fueron inferiores al promedio de rendimiento de grano en el 93% de los años estudiados, mientras que en el 7% de los años restantes, los rendimientos fueron superiores al promedio de largo plazo. En aquellos años en los que  $\Delta D_{30_{50-100}}$  fue un 50% superior a la media de cada sitio, el rendimiento de maíz se redujo en más de la mitad en comparación con la media a largo plazo. Las temperaturas máximas durante otros períodos del ciclo del cultivo (i.e., 0-50, 0-150 y 100-150 DDS) y otros umbrales de temperatura (rango probado:  $20-45^{\circ}\text{C}$ ) mostraron valores de correlación más bajos con el rendimiento del grano de maíz. Entre el grupo de radiación solar, el coeficiente fototérmico entre la siembra y la cosecha ( $\Delta Q_{s-c}$ ) fue el mejor predictor de las anomalías en el rendimiento de grano de maíz. A mayores valores de  $\Delta Q_{s-c}$ , mayores valores de  $\Delta \text{Rend Sim}$ .

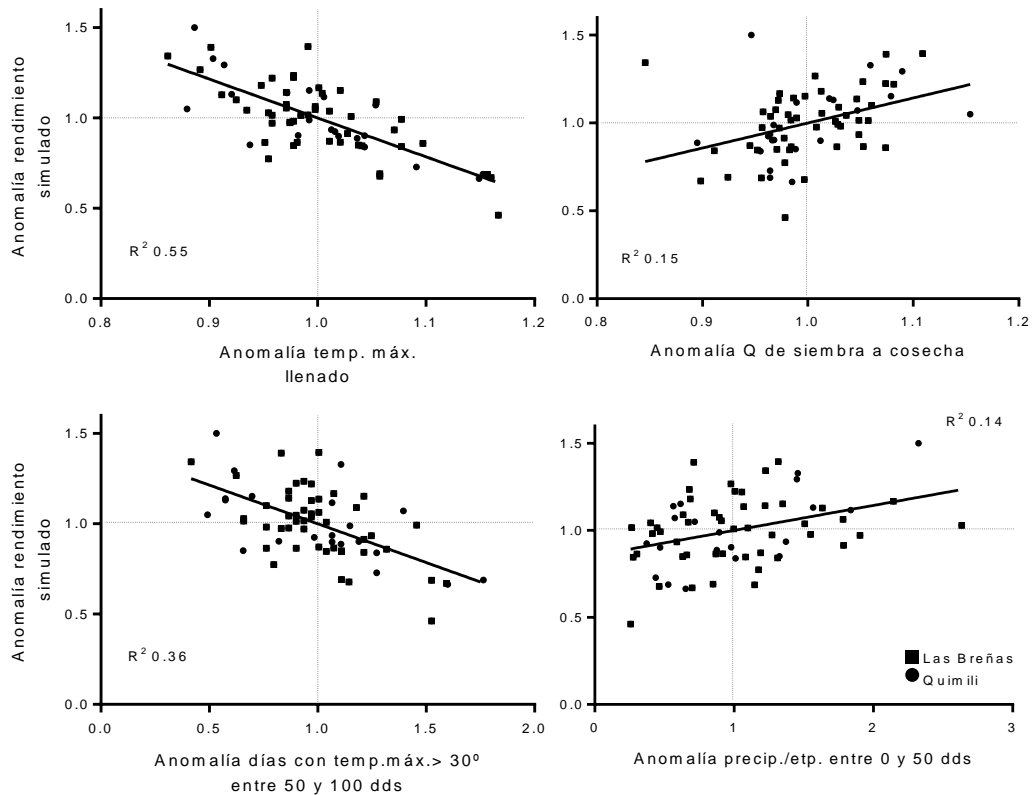


Figura 4.5. Anomalia del rendimiento del grano de maíz simulado por CERES-Maize en función de a) la anomalía de la temperatura máxima durante la fase de llenado del grano; b) la anomalía del cociente fototérmico (Q) entre la siembra y la cosecha; c) la anomalía del número de días con temperatura máxima superior a 30°C entre los días 50 y 100 desde la siembra; d) la anomalía de la relación entre la precipitación acumulada y la evapotranspiración acumulada según Hargreaves entre los días 0 y 50 desde la siembra. Se presenta la recta de la regresión lineal entre ambas variables y el valor de  $R^2$  correspondiente. Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimilí. La correlación fue altamente significativa ( $p < 0,005$ ). Las líneas punteadas indican la anomalía con valor 1. La anomalía se calculó en relación con los valores medios correspondientes a 21 y 48 años de datos en Quimilí y Las Breñas, respectivamente.

Las variables del grupo de disponibilidad de agua tuvieron valores de correlación más bajos con las anomalías de rendimiento de grano del maíz que las de los grupos de temperatura, estrés térmico y radiación solar (Fig. 4.5). Dentro del grupo de disponibilidad de agua, el predictor que explicó la mayor cantidad de varianza en las anomalías de

rendimiento de grano del maíz fue  $\Delta P/ETP_{0-50}$  (anomalía de la relación entre la precipitación acumulada y la evapotranspiración potencial entre 0 y 50 DDS) ( $r = 0,37$ ) cuya relación promedió 0,51 en Quimilí ( $P_{0-50} = 227$  mm y  $ETP_{0-50} = 440$  mm), y 0,58 en Las Breñas ( $P_{0-50} = 261$  mm y  $ETP_{0-50} = 445$  mm). A mayores valores de  $\Delta P/ETP_{0-50}$ , mayores valores de  $\Delta Rend$  Sim. Por otro lado, ninguna de las variables relacionadas con el índice de estrés hídrico mostró una asociación significativa con el rendimiento de maíz simulado.

Al evaluar los modelos multivariados, el modelo más parsimonioso (i.e., el modelo 1 del Cuadro 4.3) incluyó los cuatro predictores que se identificaron dentro de cada grupo de variables. Al igual que en el caso de la soja, los predictores tuvieron efectos aditivos, mientras que las interacciones entre ellos no aumentaron significativamente el poder explicativo. Considerando los valores de AIC de cada modelo al ir removiendo cada una de las variables respecto al modelo completo, se pudo establecer un orden de importancia relativa de cada una de ellas en la determinación del rendimiento. La variable con mayor poder predictivo fue  $\Delta TM_{llenado}$ , ya que al removerla AIC aumentó en 23,2 unidades. Le siguieron  $\Delta Q_{s-c}$  y  $\Delta P/ETP_{0-50}$ , cuya eliminación aumentó el AIC en 14,6 y 6,5, respectivamente. En cambio el estrés por calor ( $\Delta D30_{50-100}$ ) fue la variable con menor importancia relativa, dado que su remoción generó un aumento de AIC de solo 2.2 unidades.

Cuadro 4.3. Estructura general de algunos de los modelos lineales mixtos planteados para predecir la anomalía del rendimiento de maíz simulado por el modelo CERES-Maize en una localidad del Chaco Semiárido (Quimili) y una del Chaco Subhúmedo (Las Breñas), a partir de series climáticas históricas de los períodos 1994-2014 y 1967-2014 para cada localidad, respectivamente. Los modelos difieren en los predictores incluidos y en las relaciones (aditivas o interactivas) entre ellos. Los modelos se encuentran ordenados del mejor al peor ajuste según el criterio de información de Akaike (AIC).

Variables removidas	Modelo	AIC	Peso	R <sup>2</sup> marg.	R <sup>2</sup> cond.
<b>1. Ninguna</b>	$\Delta\text{Rend Sim}_i = \Delta\text{TM}_{\text{llenado}} + \Delta\text{D30}_{50-100} + \Delta\text{pp/etp}_{0-50} + \Delta\text{Q}_{s-c} + (\text{Año})_i + \epsilon_i$	<b>-103.6</b>	<b>0.139</b>	<b>0.64</b>	<b>0.92</b>
2. $\Delta\text{D30}_{50-100}$	$\Delta\text{Rend Sim}_i = \Delta\text{TM}_{\text{llenado}} + \Delta\text{pp/etp}_{0-50} + \Delta\text{Q}_{s-c} + (\text{Año})_i + \epsilon_i$	-101.4	0.048	0.61	0.91
3. $\Delta\text{pp/etp}_{0-50}$	$\Delta\text{Rend Sim}_i = \Delta\text{TM}_{\text{llenado}} + \Delta\text{D30}_{50-100} + \Delta\text{Q}_{s-c} + (\text{Año})_i + \epsilon_i$	-97.1	0.006	0.59	0.90
4. $\Delta\text{pp/etp}_{0-50}$ y $\Delta\text{D30}_{50-100}$	$\Delta\text{Rend Sim}_i = \Delta\text{TM}_{\text{llenado}} + \Delta\text{Q}_{s-c} + (\text{Año})_i + \epsilon_i$	-95.2	0.002	0.57	0.89
5. $\Delta\text{Q}_{s-c}$	$\Delta\text{Rend Sim}_i = \Delta\text{TM}_{\text{llenado}} + \Delta\text{D30}_{50-100} + \Delta\text{pp/etp}_{0-50} + (\text{Año})_i + \epsilon_i$	-89.0	<0.001	0.59	0.88
6. $\Delta\text{TM}_{\text{llenado}}$	$\Delta\text{Rend Sim}_i = \Delta\text{D30}_{50-100} + \Delta\text{pp/etp}_{0-50} + \Delta\text{Q}_{s-c} + (\text{Año})_i + \epsilon_i$	-80.4	<0.001	0.48	0.86
7. $\Delta\text{Q}_{s-c}$ y $\Delta\text{TM}_{\text{llenado}}$	$\Delta\text{Rend Sim}_i = \Delta\text{pp/etp}_{0-50} + \Delta\text{D30}_{50-100} + (\text{Año})_i + \epsilon_i$	-61.5	<0.001	0.38	0.75

$\Delta\text{Rend Sim}_i$ , anomalía\* del rendimiento en grano de maíz simulado por CERES-Maize;  $\Delta\text{TM}_{\text{llenado}}$ , anomalía de la temperatura máxima durante el llenado del grano;  $\Delta\text{D30}_{50-100}$ , anomalía del número de días con temperatura máxima por encima de 30°C entre los días 50 y 100 desde la siembra;  $\Delta\text{pp/etp}_{0-50}$ , anomalía de la relación entre las precipitaciones acumuladas y la evapotranspiración acumulada según Hargreaves, entre los días 0 y 50 desde la siembra;  $\Delta\text{Q}_{s-c}$  anomalía del cociente fototermal entre siembra y cosecha.  $\epsilon_i$ , error.

\*Las anomalías fueron calculadas en relación a los valores medios correspondientes a los 21 y 48 años de datos en Quimili y Las Breñas respectivamente.

#### 4.4. Discusión

##### 4.4.1. Impacto en el rendimiento de soja y maíz

Como era de esperar, hubo tanto coincidencias como divergencias en la influencia de las variables climáticas en las anomalías del rendimiento de soja y maíz. Una de las principales coincidencias fue que sus rendimientos se vieron fuertemente influidos por la

temperatura máxima. Este efecto se observó tanto a través de las temperaturas máximas medias diarias como del número de días con temperaturas superiores a determinados umbrales, cuyo momento y valores mostraron cierta variación entre ambas especies. En el caso de la soja, las temperaturas máximas medias diarias durante todo el ciclo del cultivo ( $\Delta TM_{1-4}$ ) mostraron una asociación más estrecha con el rendimiento ( $r = 0,5$ ) que el mismo parámetro considerado en períodos más cortos. Las temperaturas máximas surgieron como un predictor robusto de los rendimientos de la soja, mientras que ninguna de las variables relacionadas con la radiación solar se asoció significativamente con las anomalías del rendimiento de este cultivo. De forma similar, Bhatia et al. (2008) encontraron una débil asociación entre la radiación solar durante el ciclo del cultivo y los rendimientos de grano simulados de la soja en condiciones de suministro limitado de agua. También sería importante remarcar que la latitud tanto de Quimili como de Las Breñas es la misma, y al no haber existido en las simulaciones distintas fechas de siembra, podría ser esperable que la poca variación en radiación tuviera como consecuencia la no asociación de la radiación con las anomalías de rendimiento. En el caso del maíz, y al igual que en experimentos de campo previos (e.g., Badu-Apraku et al., 1983; Neiff, 2017; Peters et al., 1971), la máxima sensibilidad a las temperaturas máximas medias diarias se observó durante el periodo de llenado del grano ( $\Delta TM_{\text{llenado}}$   $r = 0,74$ ). Mayores temperaturas máximas medias se asociaron con un ciclo de cultivo más corto (Fig. 4.6). Un ciclo de cultivo más corto implica que los cultivos interceptan menos radiación solar, fijan menos carbono, pasan menos tiempo durante el llenado del grano (como se observó en las simulaciones) y, en última instancia, alcanzan menos rendimientos de grano. A diferencia de lo observado para la soja, la radiación apareció como un factor importante para explicar las anomalías en el rendimiento de maíz, como lo indica el impacto del cociente fototérmico en el modelo

multivariado (Cuadro 4.3). Resulta importante aclarar que el cociente fototérmico fue calculado como la relación entre la radiación y la temperatura media, por lo que, la relación encontrada entre el la anomalía del cociente fototérmico y la anomalía del rendimiento en maíz, se vincula no solamente con la radiación, sino también con la temperatura media.




Figura 4.6. Anomalía\* de los días entre siembra y cosecha de maíz, simulado por el modelo CERES-Maize, en función de la anomalía de la temperatura máxima durante el llenado del grano (derecha); y anomalía del rendimiento de maíz simulado por CERES-Maize, en función de la anomalía de los días entre siembra y cosecha (izquierda). Se presentan las rectas de la regresión lineal entre las variables y los correspondientes valores de  $R^2$ . Los cuadrados indican los valores correspondientes a Las Breñas, mientras que los círculos los de Quimili. Ambas correlaciones fueron altamente significativas ( $p < 0.001$ ).

\*La anomalía fue calculada en relación a los valores medios correspondientes a los 21 y 48 años de datos en Quimili y Las Breñas respectivamente.

Otra coincidencia entre ambos cultivos fue que, entre el grupo de variables de estrés térmico, la mayor correlación con las anomalías de rendimiento fue el número de días con temperaturas máximas por encima de umbrales específicos durante el mismo periodo: 50-100 DDS. Sin embargo, el umbral de temperatura que mostró la mayor correlación fue mayor en la soja que en el maíz (35 vs 30°C), lo que sugiere una mayor tolerancia de la soja al estrés térmico. En el caso de la soja, el periodo de máxima sensibilidad a las altas temperaturas coincidió con los estados fenológicos R4-R6 y el umbral de temperatura



observado estuvo en consonancia con Gibson y Mullen (1996), quienes encontraron que el rendimiento de la soja disminuye drásticamente con temperaturas diurnas superiores a 35°C desde la floración hasta el inicio del llenado del grano. Los efectos de las altas temperaturas en los rendimientos de la soja se han atribuido a sus impactos en la tasa de fotosíntesis y respiración (Andrade y Satorre, 2015; Jones et al., 2003; Lal et al., 1999). En lo que respecta al maíz, el período de máxima sensibilidad a las altas temperaturas se produjo durante el período de floración y durante el llenado del grano, que fue reportado como el período más sensible a varios tipos de estrés (e.g., térmico, hídrico y lumínico), afectando la determinación del número de granos y, en última instancia, el rendimiento de grano del maíz (Ceglar et al., 2016; Grant et al., 1989; Kiniry y Ritchie, 1985; Schoper et al., 1987). En el caso concreto del estrés térmico, Rattalino Edreira y Otegui (2012) encontraron efectos más severos en el rendimiento de grano de maíz cuando se producía alrededor de la floración que durante el llenado de grano. El umbral máximo de temperatura para el estrés térmico de 30°C, identificado en las simulaciones de maíz de esta tesis, coincide con Lobell et al. (2013), Schlenker y Roberts (2009) y Lobell et al. (2011).

Entre los parámetros de estrés hídrico, los mejores predictores de los rendimientos de la soja y el maíz fueron los directamente influenciados por la temperatura, lo que pone de manifiesto la contribución crítica de este factor. En el caso de la soja, el índice de estrés hídrico de DSSAT ( $\Delta E H_{s-c}$ ), que tiene en cuenta las precipitaciones, la absorción de agua y la transpiración de la planta (estrechamente regulada por la temperatura), mostró la mayor correlación ( $r = 0,70-0,92$ ) con las anomalías de rendimiento. El mayor impacto de las precipitaciones se observó durante el período comprendido entre diciembre (i.e., un mes antes de la siembra) y abril ( $\Delta P_{12-4}$ ). Esto indica que, además de la disponibilidad de agua durante el período crítico, como observaron previamente Giménez et al. (2015) en la región

del Chaco, el agua almacenada en el suelo antes de la siembra y la disponibilidad de agua a lo largo del ciclo del cultivo fueron también determinantes de los efectos de las anomalías de precipitación sobre la productividad de la soja. Para el maíz, una relación que combina la precipitación y la evapotranspiración en las primeras etapas de crecimiento del maíz (0 y 50 DDS;  $\Delta P/ETP_{0-50}$ ) fue el mejor predictor asociado al agua de las anomalías en el rendimiento del grano de maíz, superando el índice de estrés hídrico DSSAT. Esto indica que los efectos de los bajos niveles de precipitación sobre el rendimiento del maíz estaban regulados por la demanda atmosférica. Cuando la relación fue superior a 0,5, el rendimiento del maíz fue superior a la media en todos los años, excepto en dos. También cabe destacar que, mientras que el mejor predictor de la disponibilidad de agua para el maíz estuvo vinculado a un periodo restringido del ciclo del cultivo (i.e., 0-50 días), para la soja el mejor predictor fue un índice que abarcaba desde un mes antes de la siembra hasta la madurez fisiológica. Es decir que en el maíz el mayor impacto de la sequía fue en los estadios iniciales del desarrollo y hasta los días previos a la floración (que ocurrió alrededor del día 50 DDS en las simulaciones), mientras que la sequía en etapas posteriores tuvo una menor influencia en las anomalías del rendimiento. Las diferencias entre la soja y el maíz pueden explicarse por las diferencias en la profundidad de enraizamiento, dado que la soja suele desarrollar raíces más superficiales que el maíz (Fernández et al., 2009).

Por último, los modelos multivariados que resumieron los principales parámetros climáticos retuvieron la mayoría de los predictores identificados dentro de cada grupo de variables. En el caso de la soja, el modelo más parsimonioso indicó que  $\Delta TM_{1-4}$ ,  $\Delta D35_{50-100}$  y el índice de estrés hídrico de DSSAT medido a lo largo del ciclo del cultivo ( $\Delta EH_{s-c}$ ) fueron los predictores más relevantes de las anomalías de rendimiento (Cuadro 4.2). En el caso del maíz, los parámetros de los modelos multivariados con mayor poder predictivo

fueron las temperaturas máximas durante el llenado del grano ( $\Delta TM_{\text{llenado}}$ ) (etapa que ocurre entre los meses de marzo y abril según las simulaciones), seguidas del cociente fototérmico ( $\Delta Q_{s-c}$ ) y de  $\Delta P/ETP_{0-50}$ .

#### 4.4.2. Implicancias futuras

Hay que hacer una advertencia en relación con los resultados de este estudio. Siguiendo el objetivo propuesto de identificar las principales variables climáticas que influyen en el rendimiento del maíz y la soja en la región, la única fuente de variación de estas simulaciones fueron los parámetros climáticos. Las condiciones sanitarias y nutricionales de los cultivos se mantuvieron constantes y se supuso que estaban en el nivel óptimo. Por lo tanto, la representatividad de los resultados sería máxima sin problemas sanitarios severos y sin deficiencias nutricionales. En cambio se reduciría a medida que las condiciones sanitarias y nutricionales difieran significativamente de las condiciones óptimas. A partir de este estudio se pueden prever varias estrategias de manejo destinadas a mitigar los efectos climáticos negativos sobre el rendimiento de los cultivos. El rendimiento de soja y maíz simulado a lo largo de 69 campañas fue de 2497 y 7170 kg ha<sup>-1</sup>, respectivamente. Esto indica que ambos cultivos son adecuados para las condiciones climáticas del Chaco semiárido y subhúmedo. Sin embargo, los agricultores locales deben ser conscientes de la alta variabilidad interanual en el rendimiento de los granos que se deriva de la variabilidad climática intrínseca. Estos resultados indicaron que deben esperar resultados económicos fluctuantes, aunque con un neto predominio de resultados económicos positivos. En este sentido, los datos de la Fig. 4.2 permiten estimar los resultados económicos en función de los costes de producción expresados en kg de grano. Por ejemplo, si se asume un costo de producción de 1800 kg de soja, los resultados

negativos (rendimientos menores a los costos de producción) se presentaron en el 10% y 13% de los años estudiados en Quimilí y Las Breñas, respectivamente. Para el maíz, asumiendo un costo de producción equivalente a un rendimiento de grano de  $5000 \text{ kg ha}^{-1}$ , se observaron resultados económicos negativos en el 14% y 11% de los años en Quimilí y Las Breñas, respectivamente. Por lo tanto, los agricultores de la zona asumen un menor riesgo al cultivar soja que maíz en Quimilí y maíz en lugar de soja en Las Breñas. Dada la diferente sensibilidad de la soja y el maíz a las variables climáticas, debería evitarse tener un solo cultivo en la explotación para reducir el riesgo de que las malas cosechas afecten a toda la explotación. En este sentido, la diversificación de cultivos parece ser la clave para mejorar la resiliencia del agrosistema y aumentar la probabilidad de aprovechar las condiciones de cultivo favorables, como se ha observado para otras regiones (e.g., Gaudin et al., 2015). La proporción de cada cultivo debe determinarse en función tanto de un esquema general válido a largo plazo como de la información recogida en la campaña concreta. Por ejemplo, la proporción de soja podría incrementarse en aquellos años con contenidos de agua en el suelo relativamente más altos antes de la siembra.

Los resultados obtenidos están en consonancia con un trabajo reciente realizado en el mismo lugar de estudio que demostró que ambos cultivos difieren notablemente en su respuesta al cambio climático proyectado para el futuro cercano (2015-2039) y el lejano (2075-2099) (Casali et al., 2021). Las reducciones significativas en el rendimiento del maíz en los escenarios climáticos futuros (5-42% en comparación con la línea de base 1986-2010) estuvieron más asociadas al aumento de las temperaturas que acortaban el ciclo del cultivo que al estrés hídrico. Por el contrario, se espera que los aumentos de temperatura previstos desempeñen un papel secundario en la determinación de los rendimientos de la soja y que el estrés hídrico siga siendo una limitación importante para el rendimiento de la

soja en el contexto del calentamiento global (Casali et al., 2021). Varios informes sugieren que la variabilidad climática interanual en la Región del Chaco está fuertemente influenciada por el ENSO (El Niño-Oscilación del Sur) (Magrin et al., 2007; Patiño y Vicentini, 2007; Tiedemann, 2011), cuya intensidad y frecuencia se espera que aumente por el cambio climático global (Cleland et al., 2007). Además, se ha reportado una mayor incidencia de enfermedades en los cultivos de maíz durante los períodos de El Niño (Torres, 2001). Por lo tanto, los futuros ensayos en la zona deben considerar la necesidad de adquirir datos de estrés biótico que actualmente no se encuentran disponibles. Ceglar et al. (2016) encontraron notables diferencias espaciales en la contribución de los diferentes factores meteorológicos a la variabilidad del rendimiento de los cultivos y en el momento en que se produce el máximo impacto; el momento exacto de los períodos críticos para la determinación del rendimiento del grano en el maíz y las variables más influyentes fueron muy variables en toda Francia. Asimismo, los resultados de este estudio para la región del Chaco muestran que es necesario realizar estudios locales, como el presente, para identificar las limitaciones de la productividad de los cultivos y las estrategias adecuadas para la adaptación de los sistemas agrícolas locales.

Las estrategias de manejo destinadas a conservar el agua del suelo son de importancia crítica en esta región, como lo indica el papel de las variables relacionadas con el agua en los rendimientos simulados de los granos, especialmente de la soja. Las estrategias disponibles que ayudan a reducir las tasas de evaporación y, en última instancia, a aumentar la conservación del agua del suelo incluyen la no labranza, la fertilización balanceada, las rotaciones con cultivos que dejan grandes cantidades de residuos y el control eficiente de las malezas. El riego suplementario surge como una opción alternativa para aumentar la disponibilidad de agua, especialmente para la soja. Por otro lado, la

identificación de los periodos de mayor sensibilidad a los parámetros climáticos obtenidos en estas simulaciones proporciona una guía para ajustar las estrategias de manejo de los cultivos. Por ejemplo, la alta relevancia del contenido de agua del suelo en el momento de la siembra sugiere que las prácticas que minimizan el consumo de agua del suelo antes de la siembra de la soja pueden ser útiles. Por ejemplo, los cultivos antecesores deberían cosecharse al menos un mes antes de la siembra de soja. Para mitigar el efecto de las altas temperaturas, que es esencialmente un factor que escapa al control directo del agricultor, la principal práctica que se desprende de estas simulaciones es retrasar las fechas de siembra (e.g., hasta finales de enero) para evitar el estrés térmico durante las fases críticas del cultivo. Madias et al. (2021) en un trabajo que incluyó la zona de estudio de esta tesis, identificaron la fecha de siembra como la variable de manejo más relevante para determinar el rendimiento en grano de la soja.

En cuanto al mejoramiento vegetal, las nuevas variedades de cultivos deberían tener perfiles genéticos que alivien las pérdidas derivadas de las múltiples limitaciones ambientales que se encuentran durante su ciclo de vida. De estas simulaciones surgieron al menos tres objetivos de mejoramiento vegetal para las condiciones climáticas locales: (i) genotipos de maíz con períodos de llenado de grano más largos que puedan conferir ventajas para hacer frente a las altas temperaturas; (ii) genotipos con mayor eficiencia en el uso del agua; (iii) mejora de los rasgos fotosintéticos en el maíz, ya que el predictor cociente fototérmico, fue retenido en los modelos que resumieron las principales variables predictoras de las anomalías en el rendimiento del grano. La integración de la comprensión de los mecanismos, la variación genética y la mejora genética será esencial para alcanzar estos objetivos. Los modelos de simulación de cultivos constituyen una herramienta para dilucidar las respuestas mecánicas y diseñar ideotipos de cultivos lo cual es un paso

importante para aumentar el potencial de rendimiento genético en un entorno determinado. Los ideotipos de cultivos optimizados para el clima local podrían proporcionar a los fitomejoradores una hoja de ruta para la selección de los rasgos objetivo y sus combinaciones óptimas para la mejora de los cultivos y la adaptación genética.

#### 4.5. Conclusión

Las principales variables climáticas que determinaron la anomalía en el rendimiento de soja fueron: dentro del grupo de temperatura, la anomalía de la temperatura máxima promedio de enero a abril, dentro de las variables relacionadas con el estrés térmico, la anomalía del número de días con más de 35°C durante el periodo 50-100 DDS, dentro del grupo de variables relacionadas con la disponibilidad de agua, la anomalía de la precipitación de diciembre a abril y por último, dentro del grupo índices de estrés hídrico, la anomalía del índice del ciclo completo del cultivo. Al analizar el efecto de estas variables y sus interacciones con el planteo de modelos multivariados, el modelo con mayor ajuste incluyó las siguientes variables:  $\Delta TM_{1-4}$ ,  $\Delta D_{35_{50-100}}$  y  $\Delta EH_{s-c}$ . Estas variables mostraron relaciones aditivas entre ellas. Mientras que ninguna variable de los grupos de radiación solar y disponibilidad de agua fue retenida por este modelo.

En el caso del maíz, las principales variables ambientales que determinaron el rendimiento fueron: entre las variables del grupo de temperatura, la anomalía de la temperatura máxima durante el llenado de grano, entre las variables evaluadas dentro del grupo de estrés térmico, la anomalía del número de días con temperaturas máximas superiores a 30°C entre 50 y 100 DDS, entre el grupo de radiación solar, la anomalía del coeficiente fototérmico entre la siembra y la cosecha, dentro del grupo de disponibilidad de agua, la anomalía de la relación entre la precipitación acumulada y la evapotranspiración

potencial entre 0 y 50 DDS. Al evaluar los modelos multivariados, el modelo más parsimonioso incluyó los cuatro predictores que se identificaron dentro de cada grupo de variables. Al igual que en el caso de la soja, los predictores tuvieron efectos aditivos, mientras que las interacciones entre ellos no aumentaron significativamente el poder explicativo.



# CAPÍTULO 5

## Modelización de las respuestas del maíz y la soja al cambio climático y la degradación del suelo en una región de Sudamérica<sup>3</sup>

<sup>3</sup> El contenido de este capítulo es una transcripción de la publicación: 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. *Agronomy Journal*, 113(2), 1381-1393.

## 5.1. Introducción

Se prevé que el cambio climático global continúe en el futuro si se mantiene la trayectoria actual de emisiones antropogénicas de gases de efecto invernadero (Zhao et al., 2017). El cambio climático impacta fuertemente sobre la agricultura (y viceversa), dado que los cultivos se ven directamente afectados por la temperatura y otras variables que se ven modificadas por el calentamiento global, como los regímenes de precipitaciones y las concentraciones de CO<sub>2</sub> en el aire (Challinor et al., 2014; Rose et al., 2016). Se asume que esos efectos son cultivo-específicos debido a las condiciones ambientales óptimas para crecer y desarrollarse de cada cultivo (Teixeira et al., 2013). Además, las predicciones indican que los efectos del cambio climático son sitio-específicos y no serán uniformes a través de las latitudes y regiones (Challinor et al., 2014; Teixeira et al., 2013). De hecho, se prevé que los cultivos de las regiones subtropicales se vean más gravemente afectados que los de las zonas templadas (Amouzou et al., 2019; Tao y Zhang, 2011; Teixeira et al., 2013). Por lo tanto, es fundamental cuantificar el impacto del cambio climático en el rendimiento de los cultivos a fin de evaluar los riesgos para la seguridad alimentaria y determinar estrategias para mitigar los efectos adversos resultantes.

Durante las últimas décadas, los cultivos de maíz (*Zea mays* L.) y soja (*Glycine max* L.) se han extendido a zonas antes consideradas marginales, como el Chaco semiárido y subhúmedo, una extensa zona de Sudamérica que incluye parte de Argentina, Paraguay, Brasil y Bolivia (Giménez et al., 2015; Fehlenberg et al., 2017; Casali et al., 2018; Dominguez & Rubio, 2019). Junto con Estados Unidos, Argentina y Brasil se encuentran entre los principales exportadores mundiales de maíz y soja. La expansión de la frontera agrícola se vio favorecida localmente por el aumento de las precipitaciones anuales (aproximadamente 18% en la última década) (Ricard et al., 2015) el incremento del precio

de las commodities y la adopción de la siembra directa. El proceso de expansión fue tan dramático que convirtió a esta zona en una de las que presenta las mayores tasas de deforestación del mundo (Kuemmerle et al., 2017). Estudios a escala global que simulan los efectos del cambio climático sobre la productividad de maíz y soja a partir de bases de datos y modelos, muestran un alto nivel de incertidumbre para la región del Chaco (Elliott et al., 2014; Rosenzweig et al., 2014). Sin embargo, no se encontraron estudios específicos centrados en esta área, donde el maíz y la soja son el principal sustento económico de las comunidades locales. Esta falta de conocimiento resulta particularmente grave en lo que respecta a las estrategias de manejo tendientes a reducir los riesgos económicos y disminuir los impactos futuros en los rendimientos (Fodor et al., 2017). El retraso de las fechas de siembra también puede ser una estrategia viable para hacer frente a las limitaciones climáticas (Saseendran et al., 2005). En el caso del maíz bajo las condiciones climáticas actuales, Maddonni (2012) reportó que el retraso de la fecha de siembra hacia el primero de diciembre mejoraría el balance hídrico en el período crítico, pero también podría aumentar el riesgo de estrés térmico durante los períodos reproductivos.

Los impactos del cambio climático en la producción agrícola pueden verse afectados por los procesos de degradación del suelo (Mullan, 2013). Por ejemplo, un aumento de las temperaturas medias puede incrementar la evaporación del agua del suelo y las pérdidas de carbono en el suelo, lo que, combinado con una mayor frecuencia de eventos de precipitaciones extremas, puede aumentar la erosionabilidad del suelo y reducir su fertilidad (Nearing et al., 2004; Lal, 2012). Los suelos de las regiones subtropicales y tropicales son en general más vulnerables a la degradación que los de las regiones templadas (Ross, 1993; Rubio et al., 2019), especialmente en los casos en que los bosques nativos fueron convertidos en tierras agrícolas (Guillaume et al., 2015), por lo tanto, pueden

ser más susceptibles a los efectos del cambio climático global. Considerar las posibles condiciones del suelo en el futuro mejoraría la precisión en las predicciones de las consecuencias agrícolas del cambio climático. Además, hay una necesidad creciente y urgente de diseñar prácticas agronómicas que mitiguen los efectos del cambio climático en el rendimiento de los cultivos y que preserven la capacidad del suelo para prestar servicios ecosistémicos.

Los modelos de simulación agronómica son un valioso instrumento para estudiar los efectos simultáneos de múltiples factores que, de otro modo, sería muy difícil considerar mediante experimentos de campo (Alton, 2013; Jones et al., 2003). En el caso del calentamiento global, resultan adecuados para predecir el rendimiento de los cultivos en escenarios de cambio climático (Corbeels et al., 2018; Lobell y Burke, 2010). *The Decision Support System for Agrotechnology Transfer* (DSSAT) es una plataforma que agrupa a un conjunto de submodelos que permiten simular el crecimiento y desarrollo de cultivos, integrando información de suelos, clima, cultivos y manejo. Los modelos DSSAT CERES-*Maize* y CROPGRO-*Soybean* han sido utilizados con éxito para evaluar el impacto del cambio climático y/o la variabilidad climática en la productividad agrícola (p.ej. Amouzou et al., 2019; Battisti et al., 2017; Ma et al., 2017) y fueron evaluados para diferentes condiciones argentinas con errores de estimación relativamente bajos (p.ej. Casali et al., 2018; Caviglia et al., 2013; Aramburu-Merlos et al., 2015; Monzon et al., 2012). Aunque los modelos DSSAT se desarrollaron originalmente en regiones templadas, también han sido utilizados en regiones tropicales y subtropicales (Amouzou et al., 2019; Battisti et al., 2017; Liu et al., 2013).

Este capítulo ofrece una evaluación y aplicación de los modelos CERES-*Maize* y CROPGRO-*Soybean* bajo diferentes escenarios climáticos, concentraciones atmosféricas de

CO<sub>2</sub> y regímenes de manejo de cultivos, con un enfoque en la región semiárida del Chaco. Los objetivos del capítulo fueron: i) evaluar el efecto del cambio climático esperado y de los escenarios de concentración de CO<sub>2</sub> en la atmósfera, sobre los rendimientos de maíz y soja en suelos con diferentes grados de degradación; y ii) evaluar el efecto del riego y de diferentes fechas de siembra, como posibles estrategias para mitigar el impacto del cambio climático.

## 5.2. Materiales y métodos

### 5.2.1. Área de estudio

La zona de estudio está situada en Quimilí (27°38'S, 62°25'W), un lugar representativo de la región semiárida del Chaco. Esta región exhibe una de las tasas de deforestación más altas del mundo (Kuemmerle et al., 2017) y está comenzando a mostrar signos crecientes de degradación del suelo (Osinaga et al., 2018). La precipitación media anual histórica es de 692 mm (Angueira et al., 2007), siguiendo un patrón monzónico con mayores precipitaciones en verano (diciembre a marzo) que en invierno (junio a septiembre). Los cultivos de verano suelen estar expuestos a temperaturas superiores a 30°C durante las etapas vegetativa tardía y reproductiva, por lo que se encuentran frecuentemente afectados por el estrés térmico (Casali et al., 2018). Los suelos agrícolas son principalmente Haplustoles y Argiustoles.

### 5.2.2. Calibración y validación de los modelos de cultivo

Los modelos *CERES-Maize* y *CROPGRO-Soybean*, que forman parte del DSSAT v4.5 (Hoogenboom et al., 2010), se utilizaron para evaluar el impacto del cambio climático, la degradación del suelo y las prácticas agrícolas en el rendimiento de grano de maíz y soja.

El CERES-*Maize* ha sido calibrado en el área de estudio para el cultivar DK747 (Casali et al., 2018), mientras que el CROPGRO-*Soybean* fue calibrado para el cultivar A8000 como parte del presente capítulo. El conjunto de datos para la calibración de soja fue recolectado a partir de experimentos de campo realizados por el Instituto Nacional de Tecnología Agropecuaria (INTA) ubicados en La María (28°03'S, 64°15'O), Las Breñas (27°04'S, 61°04'O) y Charata (27°07'S, 61°13'O). Los ensayos cubrieron un amplio rango de fechas de siembra (2 de octubre al 13 de enero) y se realizaron evitando limitaciones hídricas y nutricionales a través del riego y la fertilización. El hecho de que los experimentos cubrieran un amplio rango de condiciones ambientales resultó en una gran variabilidad en los rendimientos de soja (1000 a 4500 kg ha<sup>-1</sup>), la duración del ciclo de cultivo (107 a 207 días entre la siembra y la plena madurez), el número de granos (940 a 2940 granos m<sup>-2</sup>) y el peso medio de los granos (0,10 a 0,18 g). En total, el conjunto de datos utilizado para calibrar el cultivar A8000 abarcó 41 lotes. La validación del cultivar calibrado se hizo con un segundo conjunto de datos que se recolectó de los experimentos de campo realizados por productores. Este conjunto de datos cubrió un amplio rango ambiental y de manejo e incluyó los siguientes sitios: Capdevila (27°23'S, 61°30'O), Cejolao (27°30'S, 62°17'O), El Colorado (27°53'S, 62°12'O), Las Breñas (27°6'S, 61°6'O), Loro Blanco (26°48'S, 61°12'O), Los Frentones (26°23'S, 61°23'O), Otumpa (27°6'S, 62°30'O), Pampa del Infierno (27°36'S, 62°23'O), Pinedo (27°18'S, 61°17'O), Quimilí (27°36'S, 62°23'O) y Roversi (27°36'S, 61°53'O). El conjunto de datos se obtuvo a partir de experimentos de campo pertenecientes a grupos de productores AACREA (Asociación Argentina de Consorcios Regionales de Experimentación Agrícola) Guayacán y Gancedo-La Paloma y a la Red de Evaluación de Cultivares de Soja del NEA de Aapresid (Asociación Argentina de Productores en Siembra Directa) y del INTA. Las fechas de siembra de los ensayos se

concentraron en diciembre y enero. Las precipitaciones durante el ciclo de cultivo variaron de 315 a 790 mm y los suelos fueron Haplustoles y Argiustoles. La densidad de plantas fue de entre 20 y 30 plantas  $m^{-2}$ , mientras que la distancia entre hileras fue de 52 cm en la mayoría de los casos. El rendimiento medio de los granos fue de 3095  $kg\ ha^{-1}$ . Los experimentos que tenían una o más de las siguientes características no se consideraron para la validación del modelo: i) datos básicos faltantes como precipitaciones, densidad de plantas o fecha de siembra; ii) valores de precipitación 30% o más por debajo del promedio del año específico; y iii) valores de rendimiento de los cultivos 40% o más por debajo del promedio de otros lotes en el mismo ambiente (ya que puede atribuirse a errores de medición o a la incidencia de plagas o enfermedades). De esta manera, el conjunto de datos utilizado para validar el modelo *CROPGRO-Soybean* para cv. A8000 cubrió 51 lotes. El ajuste de los datos simulados con los observados se evaluó a través del valor del coeficiente de determinación ( $R^2$ ) (Steel y Torrie, 1985), del índice de ajuste d (Willmott et al., 1985), de la diferencia porcentual (diferencia en la media simulada vs. la observada, expresada como porcentaje de la media observada), del RMSE (*Root Mean Square Error*), y de su expresión como porcentaje del promedio observado (RMSE normalizado o n-RMSE) (Wallach et al., 2014).

### 5.2.3. Modelización de cultivos y escenarios climáticos

Las prácticas de manejo de los cultivos utilizadas en las simulaciones DSSAT se establecieron para reflejar las prácticas habituales de los productores locales. La fecha de siembra y la distancia entre hileras de ambos cultivos fueron el 31 de diciembre y 52 cm, respectivamente, mientras que la densidad de siembra fue de 6 plantas  $m^{-2}$  para el maíz y 24,5 plantas  $m^{-2}$  para la soja. Como cultivo antecesor se utilizó soja para el cultivo de soja y

maíz para el de maíz. Se asumió que los cultivares de maíz y soja eran constantes en todos los escenarios climáticos y que no se incorporaron los residuos de cultivos, asumiendo que la siembra directa es la práctica de preparación del suelo más extendida en la zona de estudio. Cada simulación comenzó en la fecha de cosecha del cultivo antecesor, aproximadamente seis meses antes de la fecha de siembra. La disponibilidad inicial de nitrato de suelo se fijó en  $70 \text{ kg ha}^{-1}$ , sobre la base de análisis de suelo realizados localmente. La disponibilidad inicial de agua del suelo se fijó en el 60% de la capacidad de almacenamiento de agua del suelo.

Los datos de los escenarios climáticos para las simulaciones de cultivos se obtuvieron de un ensamble climático multimodelo. Se utilizaron los valores medios de los datos diarios de los cuatro modelos de circulación general (GCM) con el mejor desempeño en la región de acuerdo a un estudio previo (Secretaría de Ambiente y Desarrollo Sustentable de la Nación, 2014). En este informe se evaluó el desempeño de 27 modelos pertenecientes a la base del CMIP5 (Stouffer et al., 2011; Taylor et al., 2012) (disponible en [3cn.cima.fcen.uba.ar](http://3cn.cima.fcen.uba.ar)) para varias regiones argentinas, mediante el enfoque del Índice Único de Validación de Modelos (IUVM). Este índice varía entre 0 y 1, y los valores cercanos a 1 indican los mejores desempeños. De acuerdo con este enfoque, los cuatro mejores modelos para el sitio de estudio fueron: CNRM-CM5, CMCC-CM, CSIRO-Mk-6-0, y MRI-CGCM3, con valores de IUVM de 0,9, 0,78, 0,71 y 0,70, respectivamente. Estos modelos proporcionan datos de precipitación diaria, temperatura máxima y mínima diaria. La capacidad de predicción del ensamble multimodelo, se verificó mediante un análisis de correlación con los datos obtenidos de una estación meteorológica local (Quimili) para el período 1994-2010. Los resultados fueron satisfactorios ( $R^2$  0,99, 0,97 y 0,93 para las



medias mensuales de las temperaturas máximas y mínimas y las precipitaciones, respectivamente).

Las simulaciones fueron realizadas en modo *seasonal* y se consideraron tres horizontes temporales: i) clima de referencia (1986-2010); ii) futuro cercano (2015-2039), y iii) futuro lejano (2075-2099). (Como se mencionó en el párrafo anterior, los datos climáticos para las simulaciones de cultivos se obtuvieron del ensamble climático multimodelo). Se consideraron dos escenarios de Trayectorias de Concentración Representativas (RCP por sus siglas en inglés) del IPCC que modulan condiciones contrastantes que pueden ocurrir en el futuro: RCP 4.5 (supone cierta estabilización en las emisiones de gases de efecto invernadero) y RCP 8.5 (supone la continuidad de las tasas de emisiones altas) (IPCC, 2014) (Fig. 5.1). Dado que el modelo no estima valores de radiación solar, los mismos se calcularon utilizando la ecuación de Hargreaves y Samani (1985). Las simulaciones se realizaron bajo una concentración básica de CO<sub>2</sub> (360 ppm) y bajo un rango de niveles de concentración más altos (van Vuuren et al., 2011) (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/RCP 4.5, 2075-2099/RCP 4.5, 2015-2039/RCP 8.5 y 2075-2099/RCP 8.5, respectivamente). La inclusión de los tratamientos de CO<sub>2</sub> para el clima de referencia se hizo sólo con fines comparativos y para realizar el análisis estadístico que permitan la adecuada partición de la varianza.

#### 5.2.4. Suelos

El suelo utilizado para las simulaciones fue un Haplustol éntico, serie 7 de Agosto, que es el principal suelo de Quimilí según el Sistema de Información Geográfica de Santiago del Estero (SigSE) (Angueira et al., 2007). Se asumió que la condición prístina de este suelo representaba al suelo no degradado (Cuadro 5.1). Se generaron otros dos suelos

simulados para representar las condiciones de los suelos moderadamente degradado y degradado. Para ello, las propiedades consideradas fundamentales para definir el curso del proceso de degradación (Seybold et al., 1999) se modificaron a partir de la condición prístina. A saber, se redujo 10 y 15% el carbono orgánico y 5 y 10 cm la profundidad del horizonte superficial, respectivamente, para la condición de suelo moderadamente degradado y degradado (Cuadro 5.1). Además, se aumentó el número de curva en 10 y 20 unidades para las dos condiciones degradadas. Este número de curva es un parámetro adimensional de retención de agua en el suelo que varía de 0 a 100 y estima las tasas de infiltración y de escorrentía (Ritchie, 1998).

Cuadro 5.1. Datos analíticos de los tres perfiles de suelo utilizados en las simulaciones (se remarcan en negrita las características que se modificaron en los suelos degradados respecto al no degradado).

Horizonte	No degradado				Moderadamente Degradado				Degradado			
	Ap	IIAC	IIC1	IIC2	Ap	IIAC	IIC1	IIC2	Ap	IIAC	IIC1	IIC2
<b>Profundidad (cm)</b>	<b>0-15</b>	<b>15-47</b>	<b>47-77</b>	<b>77-200</b>	<b>0-10</b>	<b>10-42</b>	<b>42-72</b>	<b>72-195</b>	<b>0-5</b>	<b>5-37</b>	<b>37-67</b>	<b>67-190</b>
Arcilla (%)	15	7	9	9	15	7	9	9	15	7	9	9
Arena (%)	31	52	48	46	31	52	48	46	31	52	48	46
<b>Carbono orgánico (%)</b>	<b>1,32</b>	<b>0,58</b>	<b>0,32</b>	<b>0,32</b>	<b>1,18</b>	<b>0,52</b>	<b>0,28</b>	<b>0,28</b>	<b>1,06</b>	<b>0,47</b>	<b>0,2</b>	<b>0,2</b>
Nitrógeno total (%)	0,13	0,09	0,05	0,04	0,13	0,09	0,05	0,04	0,13	0,09	0,05	0,04
<b>Número de curva</b>			<b>73</b>				<b>83</b>				<b>93</b>	

### 5.2.5. Estrategias de manejo de los cultivos

Se evaluaron dos estrategias de manejo de cultivos: la fecha de siembra y el riego. Los tratamientos de la fecha de siembra fueron tres: convencional (31 de diciembre), temprana (10 de diciembre) y tardía (20 de enero), mientras que los niveles de riego fueron dos: sin riego y con riego. El tratamiento de riego se generó con DSSAT mediante el riego

automático cuando la humedad del suelo alcanzaba el 50% de la capacidad total de almacenamiento de agua, y hasta que alcanzara el 100%.

#### 5.2.6. Análisis estadísticos

Se realizó un Análisis Factorial de Varianza considerando los escenarios climáticos, los niveles de CO<sub>2</sub>, las condiciones de los suelos, las fechas de siembra y los niveles de riego. Los resultados del modelo se analizaron por separado para los niveles base y elevados de CO<sub>2</sub>, tanto para los dos niveles de riego como para las tres fechas de siembra.

### 5.3. Resultados

#### 5.3.1. Escenarios de cambio climático

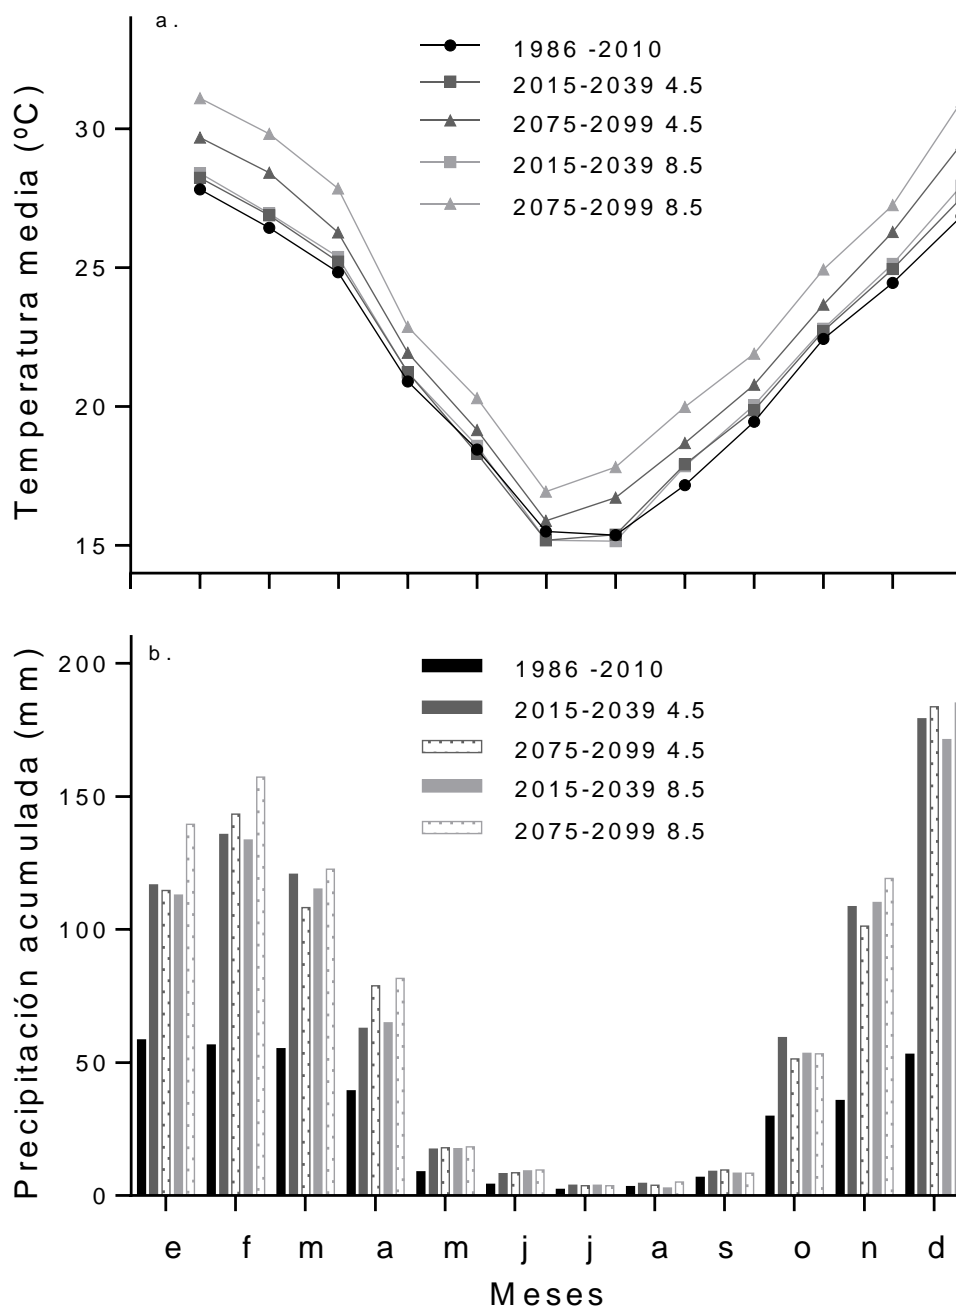


Figura 5. 1. Temperatura media mensual (a) y precipitación acumulada mensual (b) en Quimili, bajo cinco escenarios climáticos generados por el ensamble multimodelo: pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5).

El ensamble multimodelo predijo un aumento significativo de las temperaturas medias mensuales para los escenarios climáticos futuros (Fig. 5.1). Los aumentos de las temperaturas máximas fueron de 0,2 y 1,3°C para el escenario menos dramático (RCP 4.5) y de 0,4 y 2,3°C para el más dramático (RCP 8.5), en el futuro cercano y lejano, respectivamente. En cuanto a las temperaturas mínimas el ensamble predijo un aumento medio de 0,4°C y de 1,6°C en el escenario RCP 4.5 para el futuro cercano y lejano, respectivamente. Para el escenario RCP 8.5 y los mismos periodos, se prevé un aumento de 0,5 y 3,1°C respectivamente. En cuanto a la precipitación anual total, las predicciones muestran la misma tendencia que en el escenario del pasado reciente con una mayor cantidad absoluta. Respecto a la estacionalidad, las predicciones climáticas para los escenarios futuros indican aumentos de las precipitaciones durante la primavera tardía y el verano (noviembre-febrero) (Fig. 5.1).

### 5.3.2. Maíz

Los rendimientos simulados del maíz se vieron significativamente afectados por los niveles de CO<sub>2</sub>, los escenarios climáticos y la degradación del suelo (Cuadro 5.2). El efecto del enriquecimiento de CO<sub>2</sub> fue bajo (media de +2,7%), mientras que el efecto de los escenarios climáticos fue más prominente (Fig. 5.2). En comparación con el periodo 1986-2010, los rendimientos medios del maíz en el escenario RCP 4.5 fueron un 6 y un 20% menores en 2015-2039 y 2075-2099, respectivamente (Fig. 5.2), mientras que bajo el RCP 8.5 fueron un 7 y un 43% menores en 2015-2039 y 2075-2099, respectivamente. Estas disminuciones en el rendimiento se asociaron con el acortamiento del ciclo del cultivo provocado por el aumento de las temperaturas (Fig. 5.3). Por ejemplo, el ciclo del cultivo

fue 17 días más corto (es decir, -16%) en el escenario de temperaturas más altas (2075-2099 - RCP 8.5) en comparación con el periodo 1986-2010.

Cuadro 5.2. Valores de F y significancia del rendimiento simulado de maíz y soja en función de los escenarios climáticos (E), los suelos (S), los tratamientos de riego (R) y los niveles de CO<sub>2</sub> (C).

		E	S	R	C	R×C	R×S	C×E	R×E	C×S	E×S	R×C×E	R×C×S	R×E×S	C×E×S	R×C×E×S
Maíz	F <sup>†</sup>	687	14	1.3	14.6	0.01	0.01	0.5	0.5	0.05	2.47	0.004	0.004	0.01	0.04	0.00008
	p <sup>††</sup>	***	***	ns	***	ns	ns	Ns	ns	ns	*	ns	ns	ns	ns	ns
Soja	F	17.8	6.1	59.4	1461	0.1	0.7	74.9	15	0.25	0.16	0.07	0.0006	0.08	0.02	0.0004
	p	***	***	***	***	ns	ns	***	***	ns	ns	ns	ns	ns	ns	ns

<sup>†</sup> F-value; <sup>††</sup> p-value; <sup>†††</sup> ns, \*, \*\* y \*\*\* indican diferencias no significativas y diferencias significativas a un nivel de 0,05, 0,01 y 0,001, respectivamente.

La interacción degradación del suelo × escenario climático fue la única estadísticamente significativa (Cuadro 5.2). Mientras que en los escenarios 1986-2010, 2015-2039/4.5 y 2015-2039/8.5 no se detectó ningún efecto significativo de la degradación del suelo sobre el rendimiento del maíz, los dos escenarios de emisiones RCP asociados al futuro lejano (es decir, 2075-2099) fueron sensibles al estado de conservación del suelo. En 2075-2099/4.5, el rendimiento del maíz fue un 1 y un 7% inferior en los suelos moderadamente degradado y degradado en comparación con los no degradados, mientras que en 2075-2099/8,5 fueron un 4 y un 14% más bajos, respectivamente.




Figura 5.2. Rendimiento simulado de maíz en Quimili por el modelo CERES-Maize en tres suelos (no degradado, moderadamente degradado y degradado), bajo dos tratamientos de riego (secano y riego) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, y con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 and 800 ppm) en los escenarios 1986-2010, 2015-2039/RCP 4.5, 2075-2099/RCP 4.5, 2015-2039/RCP 8.5 y 2075-2099/RCP 8.5. Las barras representan el error estándar.

Cuadro 5.3. Valores de F y significancia del rendimiento simulado de maíz en función de los escenarios climáticos, los suelos, y las fechas de siembra. Las simulaciones fueron realizadas en secano, y con el nivel base de CO<sub>2</sub> (360 ppm).

	Escenario climático (E)	Suelo (S)	Fecha de siembra (F)	E×S	E×F	S×F	E×S×F
F <sup>†</sup>	457,3	16,3	591,5	0,75	13,2	6	0,22
p <sup>††</sup>	***	***	***	ns	***	***	ns

<sup>†</sup> F-value; <sup>††</sup> p-value; <sup>†††</sup> ns, \*, \*\* y \*\*\* indican diferencias no significativas y diferencias significativas a un nivel de 0,05, 0,01 y 0,001, respectivamente.

Se realizaron simulaciones específicas para evaluar los efectos de modificar las fechas de siembra 20 días antes o después del 31 de diciembre (*i.e.* la fecha de siembra que se considera óptima en la actualidad) en condiciones de secano y una concentración de CO<sub>2</sub>

de 360 ppm en el aire. Los resultados obtenidos indicaron un efecto significativo de la fecha de siembra sobre el rendimiento en grano del maíz y que los escenarios climáticos y los niveles de degradación del suelo modificaron este efecto (Cuadro 5.3). El retraso de las fechas de siembra produjo un aumento significativo del rendimiento del maíz en todos los escenarios climáticos (incluido el pasado reciente). En comparación con la siembra del 31 de diciembre, las siembras del 10 de diciembre y del 20 de enero provocaron una disminución del 18% y un aumento del 18% en los rendimientos, respectivamente (Fig. 5.4). El mayor efecto se observó en el escenario 2075-2099/RCP 8.5, en el que el rendimiento del maíz aumentó un 40% cuando se sembró el 20 de enero en comparación con el 31 de diciembre. En cambio, en el periodo 1986-2010 la diferencia de rendimiento entre estas fechas de siembra fue del 12%. La duración del periodo de llenado del grano también se vio significativamente afectada por la fecha de siembra, que para el escenario 2075-2099/RCP 8.5 pasó de 31 días para las plantas sembradas el 31 de diciembre, a 37 días en las sembradas 20 días después. En cuanto a la interacción fecha de siembra  $\times$  suelo, el maíz sembrado tempranamente (10 de diciembre) mostró un rendimiento significativamente menor (-15%) en el suelo degradado que en los otros dos suelos. En cambio, no se observaron efectos significativos del estado de conservación del suelo en las otras dos fechas de siembra.






Figura 5.3. Largo del ciclo del cultivo simulado por el modelo CERES-Maize (a) y el modelo CROPGRO-Soybean (b), en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, en secano, con el nivel base de CO<sub>2</sub> (360 ppm), y en el suelo no degradado. Las barras representan el error estándar. En el test de comparación de medias para cada cultivo, a < b < c y la misma letra indica que no hay diferencias significativas entre los escenarios climáticos a un nivel de 0,05 usando el test de Tukey.

Cuadro 5.4. Valores de F y significancia del rendimiento simulado de soja en función de los escenarios climáticos, los suelos, y el riego. Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1961-2010, 2015-2039 RCP 4.5, 2075-2099 RCP 4.5, 2015-2039 RCP 8.5 y 2075-2099 RCP 8.5, respectivamente).

		Escenario climático (E)	Suelo (S)	Riego (R)	R×E	R×S	E×S	E×S×R
CO <sub>2</sub> base	F <sup>†</sup>	16.99	4.85	30.77	7.62	0.19	0.09	0.04
	p <sup>††</sup>	***†††	***	***	***	ns	ns	ns
CO <sub>2</sub> aumentado	F	69.24	1.83	28.98	7.74	0.17	0.08	0.04
	p	***	ns	***	***	ns	ns	ns

† F-value; †† p-value; ††† ns, \*, \*\* y \*\*\* indican diferencias no significativas y diferencias significativas a un nivel de 0,05, 0,01 y 0,001, respectivamente.

### 5.3.3. Soja

La fenología y el rendimiento de soja simulados para el cv. A8000 calibrado (Cuadro S5.1) presentaron una aceptable correlación con los datos observados. Los valores

de n-RMSE fueron inferiores al 20% para las diferentes variables fenológicas y de crecimiento simuladas (Cuadro S5.2), indicando una correlación de "buena" a "excelente" entre los valores observados y los simulados (Jamieson et al., 1991). En particular, se simuló con gran exactitud el número de días hasta R1 y hasta R7, con valores de n-RMSE de 10,9 y 4,1% respectivamente, y una diferencia entre los valores observados y los simulados de sólo 1 día en ambos casos (Cuadro S5.2). El rendimiento se simuló satisfactoriamente, con un n-RMSE de 18%, un  $R^2$  de 0,69, y una sobreestimación de 9,4% del promedio observado (Cuadro S5.2).

Los rendimientos de soja simulados se vieron significativamente afectados por los escenarios climáticos, los niveles de CO<sub>2</sub>, la degradación del suelo y los tratamientos de riego, así como por las interacciones riego × escenario climático y nivel de CO<sub>2</sub> × escenario climático (Cuadro 5.2). Entre estos factores, y en contraste con el maíz, el nivel de CO<sub>2</sub> fue uno de los principales factores que regularon el rendimiento de la soja. En general, niveles elevados de CO<sub>2</sub> condujeron a mayores rendimientos (Cuadro 5.2; Fig. 5.5). En comparación con el nivel base de CO<sub>2</sub>, con los niveles aumentados de CO<sub>2</sub> el rendimiento aumentó en un 24, 10, 13, 22 y 40% en los escenarios 1986-2010, 2015-2039/RCP 4.5, 2015-2039/RCP 8.5, 2075-2099/RCP 4.5, y 2075-2099/RCP 8.5, respectivamente (Fig. 5.5). Dados los importantes efectos de los niveles de CO<sub>2</sub> en el rendimiento de soja y que este factor mostró interacciones significativas con los escenarios climáticos (Cuadro 5.3), se realizaron análisis de varianza independientes para los niveles de CO<sub>2</sub> base y elevados (Cuadro 5.4) y, en consecuencia, los resultados se muestran para cada concentración de CO<sub>2</sub>.




Figura 5.4. Rendimiento simulado de maíz por el modelo CERES-Maize bajo tres fechas de siembra (10 y 31 de diciembre y 20 de enero) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5). Las simulaciones fueron realizadas en secano, y con el nivel base de CO<sub>2</sub> (360 ppm). Se muestra el rendimiento simulado en el suelo no degradado. Las barras representan el error estándar.




Figura 5.5. Rendimiento simulado de soja por el modelo CPROGRO-Soybean en tres suelos (no degradado, moderadamente degradado y degradado), bajo dos tratamientos de riego (secano y riego) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas con fecha de siembra 31 de diciembre, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/ RCP 4.5, 2075-2099/ RCP 4.5, 2015-2039/ RCP 8.5 y 2075-2099/ RCP 8.5, respectivamente). Las barras representan el error estándar.

### 5.3.3.1. Nivel base de CO<sub>2</sub>

Bajo el nivel base de CO<sub>2</sub>, los efectos del riego sobre los rendimientos de soja fueron modulados por el escenario climático (Cuadro 5.4). El riego aumentó significativamente los rendimientos en un 12 y un 7% para los periodos 1986-2010 y 2075-2099/RCP 4.5, respectivamente (Fig. 5.5), mientras que no se observaron efectos significativos para los demás escenarios climáticos. Los efectos positivos del riego sobre los rendimientos de la soja se observaron en las tres condiciones de suelo (Cuadro 5.4), con un promedio de 4, 4 y 5% para los suelos no degradado, moderadamente degradado y severamente degradado, respectivamente (Fig. 5.5). Promediando todos los tratamientos, las condiciones de suelo degradado y moderadamente degradado disminuyeron el rendimiento de la soja en un 3 y 2%, respectivamente. Como se mencionó anteriormente, los efectos de los escenarios climáticos sobre los rendimientos de la soja difirieron entre las condiciones de secano y de riego. En condiciones de riego, el escenario 2075-2099 RCP/4.5 fue el único en el que los rendimientos de soja mostraron diferencias significativas (una reducción del 9%) en comparación con el periodo de referencia. Dentro de las situaciones de secano, el rendimiento de soja fue un 8 y un 11% significativamente mayor en los tratamientos 2015-2039/ RCP 4.5 y 8.5 que en 1986-2010, respectivamente (Fig. 5.5).

Cuadro 5.5. Valores de F y significancia del rendimiento simulado de soja en función de los escenarios climáticos, los suelos, y las fechas de siembra. Las simulaciones fueron realizadas en seco, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/ RCP 4.5, 2075-2099/ RCP 4.5, 2015-2039/ RCP 8.5 y 2075-2099/ RCP 8.5, respectivamente).

		Escenario climático (E)	Suelo (S)	Fecha de siembra (F)	F×E	F×S	E×S	E×S×F
CO <sub>2</sub> base	F <sup>†</sup>	15.35	5.41	238.8	1.9	0.08	0.14	0.02
	p <sup>††</sup>	***	***	***	ns	ns	ns	ns
CO <sub>2</sub> aumentado	F	43.89	3.96	211.5	2.19	0.17	0.15	0.02
	p	***	*	***	*	ns	ns	ns

F-value; <sup>††</sup>p-value; <sup>†††</sup> \*, \*\* y \*\*\* indican diferencias significativas a un nivel de 0,05, 0,01 y 0,001 respectivamente; ns = no significativo a un nivel de 0,05.

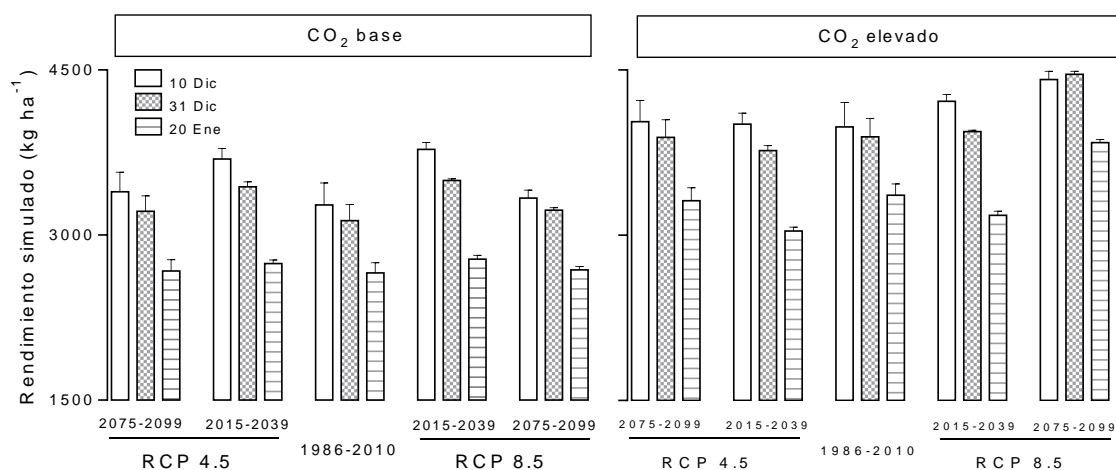


Figura 5.6. Rendimiento simulado de soja por el modelo CPROGRO-Soybean en tres fechas de siembra (10 y 31 de diciembre y 20 de enero) y en cinco escenarios climáticos (pasado reciente (1986-2010) y futuro cercano (2015-2039) y lejano (2075-2099) en dos escenarios de emisión (RCP 4.5 y 8.5)). Las simulaciones fueron realizadas en seco, con el nivel base de CO<sub>2</sub> (360 ppm) y con los niveles aumentados (550, 425, 525, 450 y 800 ppm en el escenario 1986-2010, 2015-2039/ RCP 4.5, 2075-2099/ RCP 4.5, 2015-2039/ RCP 8.5 y 2075-2099/ RCP 8.5, respectivamente). Se muestra el rendimiento simulado en el suelo no degradado. Las barras representan el error estándar.

### 5.3.3.2. Niveles elevados de CO<sub>2</sub>

El rendimiento de la soja bajo niveles elevados de CO<sub>2</sub> se vio significativamente afectado por los escenarios climáticos, el riego y por la interacción entre ellos, pero no se vio afectado por el estado del suelo (Cuadro 5.4). Los efectos del escenario climático no siguieron un patrón claro ni en términos de los escenarios RCPs ni en términos del periodo de años evaluado (Fig. 5.5). En consonancia con los resultados obtenidos con el nivel base de CO<sub>2</sub>, bajo niveles de CO<sub>2</sub> elevado, el riego aumentó significativamente los rendimientos en un 11 y un 7% para los periodos 1986-2010 y 2075-2099/RCP 4.5, respectivamente, en comparación con las condiciones de secano. En los demás escenarios climáticos, los efectos del riego no fueron estadísticamente significativos (Fig. 5.5). En condiciones de secano los efectos de los escenarios climáticos sólo fueron significativos para el tratamiento 2075-2099/8.5, con un aumento del rendimiento del 14% en comparación con 1986-2010. Por otro lado, en condiciones de riego, los escenarios climáticos 2015-2039/4.5, 2015-2039/8.5 y 2075-2099/4.5 mostraron disminuciones de rendimiento del 12, 9 y 5%, respectivamente, en comparación con el periodo de referencia.

El efecto de las fechas de siembra difirió entre los escenarios climáticos (Cuadro 5.5; Fig. 5.6). No se encontraron diferencias entre las fechas de siembra del 10 y el 31 de diciembre en ninguno de los escenarios climáticos evaluados. En cambio, la siembra del 20 de enero en comparación con la del 31 de diciembre, disminuyó los rendimientos en un 16, 20, 21, 16 y 15% en 1986-2010, 2015-2039/4.5, 2015-2039/8.5, 2075-2099/4.5 y 2075-2099/8.5, respectivamente.

#### 5.4. Discusión

La marcada estacionalidad del régimen de lluvias ha determinado el predominio histórico de los cultivos de verano en el Chaco subtropical y semiárido. Según el ensamble climático multimodelo considerado en este estudio, las ventajas de los cultivos de verano se mantendrán en el futuro bajo el cambio global esperado, mientras que los cultivos de invierno tendrán pocas posibilidades de éxito debido a la extrema escasez de lluvias invernales (Fig. 5.1). El patrón estacional de las precipitaciones se acentuará aún más según las predicciones climáticas, con una mayor concentración en verano. Los modelos climáticos también prevén un aumento de las temperaturas medias máximas y mínimas, lo que sugiere que los cultivos se enfrentarán a un mayor estrés térmico, especialmente en verano (Fig. 5.1).

Los rendimientos de maíz simulados en el Chaco semiárido disminuyeron claramente bajo los escenarios climáticos RCP evaluados. En el escenario extremo (2075-2099/RCP 8.5), la disminución del rendimiento fue particularmente grave: -43% en comparación con el período de referencia. Más que con el déficit hídrico, este descenso se asoció principalmente con el aumento de las temperaturas (Fig. 5.1), que condujo a períodos de crecimiento más cortos con menos días para el llenado de los granos (Fig. 5.3) y, finalmente, con menores rendimientos (Fig. 5.2). Dado que se han reportado ciertas limitaciones de CERES-Maize en la simulación de los efectos del estrés térmico (e.g. Gabaldón-Leal et al., 2016), el efecto de estrés térmico podría ser incluso más severo que el que se predice aquí. Las evidencias sobre la prevalencia de la temperatura sobre el déficit hídrico como principal factor responsable de los rendimientos futuros proviene del bajo impacto de la irrigación en todos los escenarios futuros, que contrasta con las respuestas positivas más pronunciadas en el control de referencia (Fig. 5.2). En claro contraste con el

maíz, ambos escenarios climáticos RCP ejercieron una influencia relativamente menor en el rendimiento de la soja (Fig. 5.5). Se obtuvieron resultados mixtos al analizar el papel del agua como factor limitante del rendimiento de la soja. La respuesta robusta y positiva al riego observada en el periodo de referencia confirma que la disponibilidad de agua ha sido el principal factor limitante local para el rendimiento de la soja en el pasado. Sin embargo, el aumento previsto de las precipitaciones en los escenarios futuros llevaría a una dilución del agua como principal factor limitante, lo que explica la menor respuesta al riego. Además, no se prevén respuestas positivas al riego para el escenario más severo (RCP 8.5), lo que podría estar asociado a un aumento de las precipitaciones en los periodos críticos de enero y febrero (Fig. 5.1). Los resultados aquí presentados se encuentran en consonancia con trabajos anteriores que identifican la temperatura como el principal factor que define el rendimiento del maíz en el contexto del cambio global, con un predominio de la disminución de los rendimientos (Bassu et al., 2014; Rose, Osborne et al., 2016; Tao y Zhang, 2011). También son coherentes con los recientes informes de modelización y metaanálisis, que observaron una mayor sensibilidad al aumento de las temperaturas en el maíz que en la soja (Justino et al., 2013; Rose et al., 2016; Zhao et al., 2017).

Trabajos previos de modelización y análisis de los efectos del aumento en los niveles de CO<sub>2</sub>, encontraron una relación positiva entre el rendimiento de maíz (una planta C4) y los niveles de CO<sub>2</sub>, en caso de sequía (Durand et al., 2018; Manderscheid et al., 2014; Meng et al., 2016; Twine et al., 2013). Por el contrario, en condiciones sin limitaciones hídricas, las respuestas del rendimiento eran menos consistentes (Twine et al., 2013; Meng et al., 2016). En las simulaciones llevadas a cabo en esta tesis, el riego tuvo un efecto menor y los niveles de CO<sub>2</sub> tuvieron un efecto muy moderado (< 3%) en los rendimientos. A diferencia del maíz, la soja (una planta C3) mostró una respuesta fuerte y positiva a los



niveles aumentados de CO<sub>2</sub>, con un aumento del rendimiento de hasta el 40% en el período 2075-2099/RCP 8,5/800 ppm de CO<sub>2</sub>. La mayor respuesta de las plantas C3 al enriquecimiento de CO<sub>2</sub> se encuentra bien documentada y se relaciona con la vía fotosintética (e.g., Twine et al., 2013; Fodor et al., 2017). La saturación por el sustrato de las enzimas fotosintéticas de las plantas C4 ocurre con niveles de CO<sub>2</sub> de alrededor de 400 ppm, un valor muy cercano al nivel base o actual de CO<sub>2</sub> en el ambiente (Fodor et al., 2017). Esta diferencia C3/C4 en el comportamiento fotosintético fue capturada por los modelos DSSAT (Hoogenboom et al., 2010). Murgida et al. (2014) estudiaron el efecto del cambio climático sobre los rendimientos simulados de maíz y soja utilizando DSSAT, encontrando resultados similares. Considerando el efecto del CO<sub>2</sub> encontraron disminuciones del rendimiento del 24 y el 14% en el año 2080 bajo los escenarios A2 y B2 respectivamente, en Chaco, y del 15 y el 8% en Santiago del Estero. En cambio en soja encontraron aumentos del rendimiento del 9 y el 23% en Chaco, y del 2 y el 16% en Santiago del Estero, para los escenarios A2 y B2 respectivamente.

Una característica particularmente útil de DSSAT es la capacidad de simular la dinámica del agua del suelo. Por ejemplo, Liu et al., (2013) mostraron que CERES-*Maize* y CROPGRO-*Soybean* proveen predicciones razonables de la dinámica del agua y el rendimiento de los cultivos en Molisoles manejados con prácticas de labranza convencional o de siembra directa. Las simulaciones realizadas en este capítulo en Molisoles indicaron que la degradación del suelo acentuó los efectos negativos del cambio climático, especialmente en los rendimientos de maíz (Fig. 5.2). En comparación con el período de referencia, el maíz cultivado en suelos degradados mostró reducciones de rendimiento del 7, 8, 23 y 48% en 2015-2039/ RCP 4.5, 2015-2039/ RCP 8.5 2075-2099/ RCP 4.5, y 2075-2099/ RCP 8.5, respectivamente. La disminución del rendimiento del maíz en los suelos

degradados fue en promedio de 21%. El rendimiento del maíz en los suelos no degradados fue en promedio un 18% inferior en comparación con el período de referencia en los cuatro escenarios climáticos futuros correspondientes: 6, 7, 18 y 40%. En cambio, los efectos de la degradación del suelo sobre el rendimiento de la soja se limitaron a las situaciones sin riego, en todos los escenarios climáticos, lo que sugiere que la degradación del suelo perjudicó la oferta de agua para el cultivo y que el riego habría enmascarado ese efecto. El mayor impacto de la degradación del suelo sobre el maíz en comparación con la soja podría explicarse por su mayor demanda de nutrientes y agua. En general, los resultados obtenidos indicaron que el impacto de la degradación del suelo varió en función de la magnitud de la degradación y del escenario climático. Sin embargo, como explican claramente Powlson et al. (2016), las prácticas de conservación del suelo deben considerarse como una contribución a la mitigación del cambio climático, independientemente de su efecto en el rendimiento de los cultivos. Estas prácticas proporcionan otros servicios, como el secuestro de carbono en el suelo y una mejora constante de la calidad del suelo, lo que aumenta en gran medida su resiliencia al cambio climático, evitando daños irreversibles como las pérdidas de suelo por erosión (Powlson et al., 2016). En el caso particular de los suelos deforestados del Chaco semiárido, las prácticas de conservación parecen ser imperativas teniendo en cuenta su fragilidad inherente y la necesidad de asegurar un entorno físico adecuado para la conservación del agua y la exploración de las raíces (Rubio et al., 2019). Los cultivos de cobertura pueden ayudar a evitar la degradación del suelo (Villarino et al., 2017), reducir su erosión y mejorar su agregación en climas semiáridos (Blanco-Canqui et al., 2013). Existen diversos reportes sobre el uso de cultivos de cobertura en la zona (e.g. Prieto Angueira et al., 2018a, Prieto Angueira et al., 2018b, Prieto Angueira et al., 2019). Por ejemplo Prieto Angueira et al. (2022) encontraron que los cultivos de cobertura

aportaban restos vegetales que mejoraron la infiltración y almacenaje de agua pero que además incrementaron la disponibilidad de nitrógeno por la fijación biológica y permitieron aumentar hasta un 19% la EUA.

La fecha de siembra ejerció efectos notables sobre los rendimientos de maíz simulados (Fig. 5.4). Cuanto más extremo fue el escenario de cambio climático, mayor fue el beneficio de retrasar la fecha de siembra dentro del rango probado aquí. Retrasar la siembra hasta el 20 de enero, aumentó el rendimiento del maíz en un 29% en comparación con el 10 de diciembre en el periodo 1986-2010, y en un 27 a 134% en los cuatro escenarios climáticos futuros. La siembra tardía implica plantas de maíz expuestas a temperaturas más bajas y consecuentemente con un ciclo y un periodo de llenado de grano más largos (Saseendran et al., 2005). Aunque en general el mejor rendimiento de la soja se verificó en las fechas de siembra intermedias, en algunos casos, las fechas tempranas rindieron más que las intermedias. Los efectos divergentes del cambio de fechas de siembra sobre los rendimientos del maíz y la soja no son inesperados, dada la mayor sensibilidad del maíz al aumento de las temperaturas. Los resultados contrastantes entre ambos cultivos amplían las observaciones realizadas por Olesen et al., (2011) y Teixeira et al., (2013), que identificaron el cambio de los calendarios de cultivo como soluciones adaptativas clave para reducir los impactos negativos del cambio climático en la agricultura.

La mitigación efectiva del cambio climático es muy relevante para mantener la producción agrícola y la seguridad alimentaria futura, especialmente en las zonas donde se espera que las condiciones para los cultivos sean menos favorables. Varias estrategias de manejo de cultivos surgen de las simulaciones realizadas, como herramientas para aliviar las consecuencias del cambio climático en el Chaco semiárido. Como se ha mencionado, retrasar la fecha de siembra surge como una herramienta relativamente sencilla para

manejar el cultivo de maíz en un escenario de calentamiento global. En lugar de cambiar las fechas de siembra, el riego puede ser una herramienta para sostener los rendimientos de la soja en función de los regímenes pluviométricos, como muestran los escenarios climáticos evaluados. En cuanto a la selección de genotipos o la mejora genética de los cultivos, los resultados obtenidos para el maíz muestran que los rasgos asociados a periodos de maduración más largos y tasas de llenado de grano más altas deberían introducirse para mitigar los efectos del cambio climático (Ma et al., 2017). En el caso de la soja, los rasgos asociados a la tolerancia a la sequía, como sistemas radiculares más profundos o la reducción de la sensibilidad del periodo de llenado de grano al déficit hídrico, son características útiles que guían a los mejoradores de cultivos en el desarrollo de nuevos genotipos (Battisti et al., 2017). Las estrategias de adaptación al cambio climático deben ser relevantes a nivel local para ser viables. En tal sentido, los hallazgos de este estudio tienen importantes implicaciones para la adaptación al cambio climático en la región del Chaco. Pueden ser beneficiosos para asignar prioridades a las estrategias de adaptación, incluyendo fechas de siembra alternativas y la adopción de prácticas de riego y conservación del suelo para los dos cultivos más extendidos. Los conocimientos presentados aquí pueden utilizarse para establecer objetivos de mejora genética para el desarrollo de nuevos híbridos y variedades, en particular para tener en cuenta los múltiples estreses a las que se enfrentarán la soja y el maíz en el Chaco. Además, las estrategias de manejo que hacen frente a la variabilidad climática demostraron ser fundamentales para hacer frente a la amenaza del cambio climático en esta región. Este trabajo también muestra limitaciones metodológicas que deben ser abordadas. La investigación futura se verá favorecida por la disponibilidad de marcos de investigación más sinérgicos y holísticos que incluyan una cuantificación fiable de la incertidumbre y herramientas para realizar simulaciones a niveles adecuados de

complejidad espacial. Un marco de este tipo, basado en la modelización y en las características locales, conducirá a mejores métodos para vincular la simulación con las opciones de adaptación del mundo real. Para ello, también es fundamental aumentar la recopilación de información local del ambiente, como los datos meteorológicos de más lugares y el impacto de las prácticas de rehabilitación de los suelos degradados. Dado que la diversificación ha demostrado ser una estrategia de adaptación clave, actualmente se carece de resultados locales de experimentos que pongan a prueba sistemas de cultivo alternativos (por ejemplo, sistemas integrados de cultivo-ganadería-silvicultura), pero pueden ser muy útiles para ampliar el alcance de las recomendaciones más allá del maíz y la soja.

Resulta importante mencionar que en un estudio reciente (Khotari et al., 2022) evaluaron diez modelos, entre ellos EL CROPGRO-Soybean incluido en DSSAT, en condiciones variables de temperatura y concentración atmosférica de CO<sub>2</sub>, para cuantificar la incertidumbre en las simulaciones del rendimiento de la soja en respuesta a estos factores. Encontraron una considerable variabilidad entre los modelos en las respuestas simuladas del rendimiento. Frente a la limitada aplicabilidad de los modelos individuales, los autores recomiendan utilizar la media del conjunto de simulaciones entre modelos ya que fue una herramienta eficaz para reducir la elevada incertidumbre en las simulaciones. El trabajo de Khotari et al. (2022) pone de relieve que es necesario un mayor desarrollo de modelos de soja con experimentos bajo condiciones elevadas de CO<sub>2</sub> y temperatura para reducir la incertidumbre de los modelos individuales.

## 5.5. Conclusiones

En este estudio, se mostró que las prácticas de manejo agrícola son claves para mitigar los efectos del cambio global en el Chaco subtropical y semiárido. Los rendimientos del maíz se redujeron severamente en los escenarios climáticos futuros previstos y esto estuvo relacionado principalmente con los aumentos de temperatura que acortaron el ciclo del cultivo. Al reducir la exposición al estrés por calor, el retraso de la fecha de siembra resultó ser una estrategia de manejo factible para mitigar estos efectos. Sorprendentemente, el riego sólo tuvo efectos menores sobre el rendimiento del maíz en los escenarios de cambio climático analizados. Las simulaciones con soja indicaron que, a diferencia del maíz, el cultivo se beneficiará con el aumento significativo de la concentración de CO<sub>2</sub> en la atmósfera, incluso en el escenario con temperaturas más altas (2075-2099/RCP 8.5). Se espera que los aumentos de temperatura previstos desempeñen un papel secundario en la determinación del rendimiento de la soja. En cambio, el estrés hídrico seguirá siendo una importante limitación para el rendimiento de la soja en el contexto del calentamiento global, pero este efecto parece estar fuertemente afectado por los regímenes pluviométricos en los escenarios futuros. Por último, la degradación del suelo exacerbó los efectos negativos del calentamiento global sobre el rendimiento del cultivo de maíz. Los resultados obtenidos ponen de manifiesto la importancia de las prácticas de conservación del suelo al ofrecer pruebas de que las consecuencias del calentamiento global serán más graves en los suelos degradados. La elevada variabilidad climática interanual observada y la diferente sensibilidad de la soja y el maíz a las variables climáticas podrían sugerir que deben evitarse los monocultivos para disminuir el riesgo de que se produzcan graves pérdidas de cosecha en toda la explotación. En este sentido, la diversificación dentro de las rotaciones de cultivos parece ser la clave para mejorar la resiliencia del agrosistema

y aumentar la probabilidad de aprovechar las condiciones de cultivo favorables, como se ha observado en otras regiones (por ejemplo, Gaudin et al., 2015).

## 5.6. Material suplementario

Cuadro S5.1. Valores de los coeficientes genéticos del cultivar A 8000 antes de ser calibrados, y luego de la calibración con datos de campo utilizando el modelo CROPGRO-Soybean.

Cultivar	GM <sup>a</sup>	CSDL (h)	PPSEN (d h <sup>-1</sup> )	EMFL (dft <sup>b</sup> )	FLSD (dft)	SDPM (dft)	WTPSD (g)	SFDUR (dft)	PODUR (dft)	LFMAX (mgCO <sub>2</sub> m <sup>-2</sup> s <sup>-1</sup> )
A 8000 original	VIII	12	0.3400	19.0	13.00	41.00	0.1650	24.0	11.0	0.8000
A 8000 calibrado	VIII	12	0.3747	14.1	13.92	32.89	0.1769	27.2	15.1	0.8808

<sup>a</sup>GM: grupo de madurez; CSDL: fotoperíodo crítico, a partir del cual la tasa de desarrollo es más lenta; PPSSEN: sensibilidad al fotoperíodo (días de alargamiento por hora, cuando el fotoperíodo supera el fotoperíodo crítico); EMFL: tiempo entre emergencia y R1; FLSD: tiempo entre R1 y R5; SDPM: tiempo entre R5 y R7; WTPSD: peso máximo de una semilla; SFDUR: duración del llenado de una cohorte de semillas; PODUR: tiempo para fijar el número de vainas; LFMAX: fotosíntesis máxima.

<sup>b</sup>dft: días fototermales

Cuadro S5.2. Valores observados y simulados de días desde siembra a floración (R1), a madurez fisiológica (R7) y del rendimiento (kg ha<sup>-1</sup>, 0% humedad), por el modelo CROPGRO Soybean, utilizando el cultivar A 8000 calibrado. Se presenta la comparación estadística entre valores observados y simulados a través del RMSE (*Root Mean Square Error*) y de su expresión como porcentaje del promedio observado (RMSE normalizado o n-RMSE), del coeficiente de determinación R<sup>2</sup>, de la diferencia porcentual (diferencia en la media simulada vs la observada, expresada como porcentaje de la media observada) y del índice de ajuste d. Se indica además el número de datos utilizados en cada caso (N).

	Media observada ±DE	Media simulada ± DE	RMSE	n-RMSE (%)	R <sup>2</sup>	Diferencia (%)	Estadístico d	N
Días a R1	51 ± 8,4	50 ± 6,9	5,6	10,9	0,57	-1,9	0,85	41
Días a R7	143 ± 25,3	144 ± 24,7	5,8	4,1	0,95	0,7	0,99	41
Rendimiento en grano (kg ha <sup>-1</sup> )	2677,0 ± 735,1	2927,5 ± 735,4	494,1	18	0,69	9,4	0,89	51

# CAPÍTULO 6

## Conclusiones generales



## 06. Conclusiones generales

En esta tesis se estudiaron los cultivos de soja y maíz en sistemas de agricultura continua en una región donde, en gran parte, la agricultura se ha introducido recientemente, por lo que aún existen pocos estudios locales sobre ellos. A lo largo esta tesis se pudo recopilar abundante y diversa información en cuanto a las condiciones climáticas de la región y a las características de los sistemas de cultivo. Esto permitió realizar predicciones utilizando modelos de simulación incluidos en el paquete DSSAT para soja y para maíz, lo cual es una importante herramienta de análisis, tanto del efecto de variables climáticas como de manejo sobre los cultivos. Por otro lado, se realizó un análisis utilizando las bases de datos mencionadas para los factores determinantes del rendimiento de los cultivos y, conjuntamente con los modelos de simulación, poder diseñar prácticas de manejo adecuadas que permitan mitigar las limitantes identificadas. Se analizó qué variables climáticas resultan más relevantes para los cultivos, y qué prácticas de manejo son más eficaces. También se estudió qué efecto tendrá en el futuro el cambio climático, para poder prever sus efectos y decidir las estrategias correspondientes.

En una primera etapa de esta tesis, con el objetivo de determinar las principales variables ambientales y de manejo que determinan la productividad de los cultivos de soja y de maíz en la zona de estudio, se realizó un análisis con modelos mixtos de una extensa base de datos de campo de la zona, con variables climáticas y de manejo, (capítulos 2 y 3 sobre maíz y soja, respectivamente). A partir de esta aproximación fue posible conocer las principales limitantes de los sistemas agrícolas de la región. En un siguiente paso, con el objetivo de aislar a las variables ambientales de las de manejo y para conocer con mayor exactitud su efecto en los cultivos de maíz y soja en la región, se utilizaron base históricas de datos climáticos de la zona, para simular los rendimientos de los cultivos utilizando

modelos de simulación previamente calibrados y validados para la región de estudio (capítulo 4). Finalmente, utilizando los modelos de simulación de cultivos y modelos de escenarios de cambio climático, se evaluó el efecto del cambio climático sobre los rendimientos simulados de soja y de maíz, para la región de estudio (capítulo 5).

Los resultados obtenidos en cada uno de los capítulos se complementaron, permitiendo obtener información amplia y robusta sobre los agroecosistemas que incluyen maíz y soja en el Chaco semiárido y subhúmedo. Para ambos cultivos se demostró cómo y cuáles variables climáticas determinaron los rendimientos. Se observó que el promedio de temperatura máxima durante el ciclo del cultivo fue la variable de temperatura de mayor relevancia en la determinación de los rendimientos de ambos cultivos. Este resultado surgió luego de analizar con modelos mixtos la base de datos que incluía variables ambientales y de manejo, y rendimientos (capítulos 2 y 3). Al realizar el análisis con modelos mixtos solamente de variables climáticas y su relación con los rendimientos simulados de soja (capítulo 4), la temperatura máxima durante el ciclo del cultivo continuó siendo la más relevante del grupo de variables de temperatura. En maíz, en cambio, la variable de temperatura de mayor poder predictivo no fue la máxima durante todo el ciclo del cultivo, sino en un período específico: el llenado del grano. En cuanto a los índices de estrés por calor, en ambos cultivos el umbral de temperatura de 35°C se identificó como el valor a partir del cual los rendimientos se vieron fuertemente reducidos. En el caso de la soja, tanto el análisis de la base de datos de campo como el de los rendimientos simulados con el clima histórico, arrojaron el mismo resultado: el índice de estrés por calor más relevante fue la cantidad de días con temperaturas máximas por encima de los 35°C en un periodo acotado del cultivo: entre los 50 y los 100 días desde la siembra, periodo que coincide con el periodo crítico del cultivo. En cambio en maíz, el análisis del capítulo 2 arrojó como

resultado que la sumatoria de grados de temperatura máxima por encima de 35°C durante todo el ciclo del cultivo era la variable de estrés térmico más relevante, mientras que en el análisis del capítulo 4, se acotó dicho período a los días entre 50 y 100 desde la siembra, y a un umbral menor de temperatura: 30°C. Curiosamente, tanto del análisis con modelos mixtos de la base de datos de maíz (capítulo 2) como de soja (capítulo 3), la interacción entre la temperatura máxima y el estrés por calor surgió como una interacción relevante en la determinación del rendimiento. Es decir que para ambos cultivos, la temperatura máxima durante todo su ciclo determina en gran medida el rendimiento, que es finalmente modulado por el estrés térmico. En línea con estos resultados, al evaluar el efecto del cambio climático sobre el rendimiento de los cultivos (capítulo 5), se encontró que en maíz, el aumento de temperaturas en los escenarios de cambio climático, se asoció con fuertes disminuciones de los rendimientos principalmente por un acortamiento del ciclo del cultivo, y en particular del período de llenado, complementando los resultados obtenidos en los capítulos 2 y 4. Cabe aclarar que en el caso de la soja, el efecto del aumento de la temperatura se vio enmascarado por los cambios del régimen pluviométrico previsto en los escenarios de cambio climático. En resumen, a lo largo de los cuatro capítulos experimentales de esta tesis (capítulos 2 a 5), la temperatura y el estrés por calor surgieron en todos los casos como variables de suma relevancia en la determinación de la productividad de los cultivos en la región.

Los resultados obtenidos permitieron precisar de qué modo las precipitaciones son una variable relevante para ambos cultivos. La diferencia radicó en que para el maíz, fueron las precipitaciones durante el mes de febrero las que determinaron en mayor medida el rendimiento, mientras que en el cultivo de soja lo fueron para un período mayor, que abarcó desde la pre-siembra hasta todo el ciclo del cultivo (i.e. octubre a abril) (capítulos 2 y 3

para maíz y soja, respectivamente). Esto indicaría una mayor sensibilidad de la soja en comparación con el maíz, a la disponibilidad hídrica. Este resultado se vio reforzado en los análisis realizados en el capítulo 4, donde se evaluó el efecto del clima histórico sobre los rendimientos simulados de ambos cultivos. Lo que se obtuvo como resultado fue que en el caso de soja, las precipitaciones durante todo el ciclo del cultivo afectaron principalmente al rendimiento, más que las precipitaciones en periodos más acotados. Para el maíz, en cambio, la variable con mayor poder explicativo del rendimiento fue un índice de disponibilidad hídrica (i.e.  $pp/etp$ ) durante casi los dos primeros meses del cultivo (i.e. entre el día 0 y 50 desde la siembra). A su vez, al evaluar el efecto de un índice de estrés hídrico (este índice incluido en DSSAT tiene en cuenta la relación entre la absorción de agua del cultivo y el potencial de transpiración. Por lo tanto, puede cuantificar las condiciones de estrés no sólo basándose en la disponibilidad de agua, sino también teniendo en cuenta la demanda de agua de los cultivos) en diferentes estadios del cultivo, se encontró que el maíz no se veía significativamente afectado por dicho índice, mientras que la soja sí (capítulo 4). Este resultado refuerza que la disponibilidad hídrica es una variable de mayor relevancia en el cultivo de soja que en el de maíz. En la misma línea, al evaluar el efecto del riego sobre la productividad de los cultivos (capítulo 5), se encontró que en maíz, su efecto fue despreciable, mientras que en soja fue significativo, lo cual refuerza el resultado anteriormente mencionado de que la soja se ve en gran medida limitada por el agua. En cambio para el maíz, como se mencionó en el párrafo anterior, la principal limitante fue la temperatura, por lo que el riego no resultó una estrategia de manejo del todo eficiente. En el caso de este último cultivo, la estrategia más favorable fue el retraso de las fechas de siembra (capítulo 5), ya que implica plantas de maíz expuestas a temperaturas más bajas y consecuentemente un ciclo y un periodo de llenado de grano más largos.

Por último, al evaluar variables climáticas asociadas a la radiación solar y su relación con el rendimiento de soja y de maíz (capítulos 2, 3 y 4), se encontró un efecto solamente en este último cultivo, y en el análisis realizado en el capítulo 4. Por lo tanto, de los análisis realizados en esta tesis, la radiación solar surgió como una variable significativa en la determinación del rendimiento del maíz en la región de estudio, pero no de la soja. Esto sugiere como una posible estrategia en este cultivo, la mejora de los rasgos fotosintéticos en los genotipos. Resulta importante aclarar que el cociente fototérmico fue calculado como la relación entre la radiación y la temperatura media, por lo que, la relación encontrada entre el la anomalía del cociente fototérmico y la anomalía del rendimiento en maíz, se vincula no solamente con la radiación, sino también con la temperatura media.

En cuanto al efecto del aumento del CO<sub>2</sub> atmosférico en los escenarios de cambio climático (capítulo 5), se encontró un marcado efecto positivo en el rendimiento de la soja y muy moderado para el maíz. Por lo tanto, en el caso del maíz se prevé que el cambio climático afecte negativamente la productividad, por el aumento de las temperaturas, mientras que la soja no solo no se vería afectada, sino que se beneficiaría por los aumentos de CO<sub>2</sub> en la atmósfera. Sin embargo, al evaluar qué efecto tendrá el cambio climático en suelos con diferente grado de degradación, se encontró que ambos cultivos sufrirán reducciones de rendimiento en suelos moderadamente o completamente degradados, y que esto se verá exacerbado frente a escenarios de cambio climático. Resulta entonces fundamental llevar a cabo prácticas de conservación (y restauración) de los suelos en la región.

Otro tema a destacar que surgió de esta tesis es que la historia agrícola de los lotes surgió como una variable de relevancia para la soja (capítulo 3). En particular, se encontró que la variable “años con soja en los últimos 5 años previos a la siembra”, se asoció

negativamente con la productividad. Esto enfatiza la importancia de evitar el monocultivo de soja, y en cambio alternar con diferentes cultivos. Además se encontró una interacción significativa de la variable con las precipitaciones entre octubre y abril, lo cual sugiere que el efecto negativo del monocultivo de soja se asociaría a una reducción de la disponibilidad hídrica por favorecer la compactación de los suelos. En cuanto al maíz, de los análisis del capítulo 2, la elección del tipo de híbrido en función de las condiciones climáticas, surgió como una interesante herramienta de manejo. Ante altas temperaturas y estés térmico, los híbridos tropicales tendieron a ser más tolerantes que los templados. En cambio, ante la escasa disponibilidad de agua, los híbridos templados vieron menos afectado sus rendimientos.

Cabe aclarar, que tanto en el capítulo 2 como en el 3, la realización de un balance de agua diario hubiera sido muy útil para determinar con mayor precisión el nivel de estrés de los cultivos. Los indicadores de estrés que se consideraron en ambos cultivos son simples y podrían ocultar algunos efectos puntuales que tengan lugar durante pocos días y que podrían coincidir con periodos críticos del cultivo como floración.

En términos de implicancias prácticas, los hallazgos de esta tesis podrían sugerir que una de las estrategias de manejo más efectivas para la zona bajo estudio sería la diversificación de cultivos. Considerando que los mismos son afectados diferencialmente por las variables climáticas y que las mismas poseen una importante variabilidad interanual, esa diversificación permitiría disminuir los riesgos de producción e incrementar la estabilidad de los rendimientos. Por otro lado, resultaría recomendable en maíz hacer foco en precisar las fechas de siembra de modo de mitigar el efecto de altas temperaturas. En el caso de soja, convendría focalizarse en aquellas prácticas tendientes a aumentar la disponibilidad hídrica, tales como prácticas de conservación del agua presente en el suelo o

bien adiciones de agua mediante sistemas de riego. Cabe aclarar que el agua también es importante en la determinación del rendimiento en maíz, pero bajo las fechas de siembra evaluadas, durante el periodo crítico se evitan las limitaciones serias de este recurso. Además de diversificar considerando rotaciones de cultivos y genotipos, también pueden combinarse diferentes cultivos y genotipos en distintos lotes dentro del campo considerando su comportamiento en los diferentes ambientes. Por ejemplo la proporción de soja podría incrementarse en aquellos años con contenidos de agua en el suelo relativamente más altos antes de la siembra. La flexibilidad en cuanto a fechas de siembra también es una estrategia de diversificación recomendable. Además, dado que la diversificación ha demostrado ser una estrategia de adaptación clave, serían interesantes experimentos que pongan a prueba sistemas de cultivo alternativos (por ejemplo, sistemas integrados de cultivo-ganadería-silvicultura), más allá del maíz y la soja.

En cuanto al análisis de las hipótesis planteadas, se puede afirmar que:

La hipótesis 1, a saber: "La alta variabilidad interanual en los niveles de productividad agrícola en el Chaco Semiárido-Subhúmedo es principalmente una consecuencia de la variabilidad climática y puede ser reducida mediante la diversificación de los cultivos, los genotipos y en las prácticas de manejo, a saber:

a) Tanto en maíz como en soja, la extensión de las fechas de siembra desde principios de diciembre hasta los primeros días de enero es una estrategia favorable para evitar los estreses hídricos y térmicos.

b) En maíz, los híbridos tropicales presentan un mejor comportamiento ante altas temperaturas, mientras que híbridos templados presentan un mejor comportamiento ante la escasez de agua.

c) Los cultivos en rotación presentan mayores rendimientos que en monocultivo, además de resultar una práctica agrícola sostenible.

d) La fertilización nitrogenada en maíz, si bien no es una práctica habitual en la zona, tiene un efecto positivo en el rendimiento”.

Se acepta parcialmente.

En cuanto al punto “a”, en el cultivo de soja, la estrategia de retrasar las fechas de siembra no resultó una estrategia favorable para evitar estreses hídricos y térmicos, en cambio sí lo fue en maíz (capítulo 5).

La hipótesis “b” se acepta. Los híbridos tropicales se vieron menos afectados por el estrés térmico y las altas temperaturas que los templados. Sin embargo, los híbridos tropicales se vieron más afectados por la precipitación que los templados. Con escasas precipitaciones, los híbridos templados tendieron a rendir más que los tropicales (Figura 2.3 a) (capítulo 2).

La hipótesis “c” se acepta parcialmente. En el caso de soja se encontró una asociación negativa entre el monocultivo y el rendimiento (capítulo 3), pero tal relación no pudo ser analizada en maíz por falta de datos exhaustivos de rotaciones de cultivos, ya que en esta tesis se trabajó con datos aportados por productores y la rotación es una práctica poco habitual en la zona (capítulo 2).

La hipótesis “d” no puede aceptarse ni rechazarse. Si bien en los análisis del capítulo 2, la fertilización con N no se mantuvo en el modelo multivariado final y tampoco se identificó como un predictor con capacidad explicativa aceptable por los modelos univariados, tres posibles explicaciones pueden ayudar a entender este resultado. Primero, la variabilidad observada en las tasas de fertilización con N fue baja para probar adecuadamente los efectos del N y el contenido real de N en el suelo fue incierto. En



segundo lugar, la disponibilidad de N en el suelo podría ser lo suficientemente alta para los cultivos de verano y adecuada para su demanda, debido a que los suelos locales han comenzado a cultivarse recientemente, por lo que aún mantienen la fertilidad de los suelos vírgenes. Además, las altas temperaturas estivales exacerbaban la mineralización de N, generando pulsos de este nutriente durante los periodos de alta demanda. Tercero, las limitaciones impuestas por la disponibilidad de N pudieron haber sido ocultadas por otras restricciones, que también afectan al rendimiento, e.g., la sequía y el estrés por calor.

La hipótesis 2, a saber: “Los modelos CERES y CROPGRO pueden simular adecuadamente el rendimiento de los cultivos en la zona de estudio, con valores de n-RMSE (RMSE normalizado) de entre el 10% y el 20%, teniendo en cuenta las condiciones climáticas de la zona de estudio, y las limitaciones de los modelos”, fue aceptada (Figura 2.4.a - capítulo 2 y Cuadros S5.1 y S5.3 - capítulo 5).

La hipótesis 3a, a saber: “El aumento de la temperatura consecuencia del cambio climático, provocará disminuciones en el rendimiento de maíz y de soja debido principalmente a una reducción en la duración del ciclo del cultivo. Se acepta parcialmente dado que en el caso de la soja, el efecto del aumento de la temperatura se vio enmascarado por los cambios del régimen pluviométrico previsto en los escenarios de cambio climático, por lo que no se puede afirmar un efecto negativo del aumento de las temperaturas sobre el rendimiento. La hipótesis 3b, a saber: “La magnitud del efecto del aumento de la temperatura será mayor en maíz que en soja”, se acepta. La hipótesis 3c: “El aumento del CO<sub>2</sub> compensará la disminución del rendimiento en soja (por el aumento de la temperatura), se acepta La hipótesis 3d: “En maíz la disminución del rendimiento por mayores temperaturas, no será compensada por el aumento del CO<sub>2</sub>”, se acepta. (capítulo 5).

## Bibliografía

- Adámoli JM, Ginzburg R & Torrella S. 2011. Escenarios productivos y ambientales del Chaco Argentino. 1977–2010. En Fundación Producir Conservando (editores). Buenos Aires. 101 pp.
- Adámoli JM, Sennhauser, Acero J & Rescia A. 1990. Stress and disturbance: vegetation dynamics in the dry Chaco region of Argentina. *Journal of Biogeography* 17: 491–500.
- Albanesi A, Anriquez A & Sanchez AP. 2001. Efectos de la agricultura convencional en algunas formas del N en una toposecuencia de la Región Chaqueña, Argentina. *Agriscientia* 18: 3-11.
- Alton PB. 2013. From site-level to global simulation: Reconciling carbon, water and energy fluxes over different spatial scales using a process-based ecophysiological land-surface model. *Agricultural and Forest Meteorology* 176: 111-114.
- Alvarez R, Alvarez CR, Daniel PE, Richter V & Blotta L. 1998. Nitrogen distribution in soil density fractions and its relation to nitrogen mineralisation under different tillage systems. *Australian Journal of Soil Research* 36: 247–256.
- Amouzou KA, Lamers JP, Naab JB, Borgemeister C, Vlek PL & Becker M. 2019. Climate change impact on water-and nitrogen-use efficiencies and yields of maize and sorghum in the northern Benin dry savanna, West Africa. *Field Crops Research* 235: 104-117.

- Andrade JF, Ermacora M & Satorre EH. 2022. Assessing benefits of land use intensification on extensive grain cropping systems of the Pampas. *European Journal of Agronomy* 135. doi:10.1016/j.eja.2022.126484.
- Andrade JF, Poggio SL, Ermacora M & Satorre EH. 2017. Land use intensification in the Rolling Pampa, Argentina: diversifying crop sequences to increase yields and resource use. *European Journal of Agronomy* 82:1–10.
- Andrade JF & Satorre EH. 2015. Single and double crop systems in the Argentine pampas: environmental determinants of annual grain yield. *Field Crops Research* 177: 137–147.
- Angueira MC, Prieto DR, López J & Barraza G. 2007. SigSE 2.0. Sistema de Información Geográfica de Santiago del Estero. Ediciones INTA. Buenos Aires, Argentina.
- Aramburu-Merlos F, Monzon JP, Mercau JL, Taboada M, Andrade FH, Hall AJ, Jobbagy E, Cassman KG & Grassini P. 2015. Potential for crop production increase in Argentina through closure of existing yield gaps. *Field Crop Research* 184:145–154.
- Araya A, Kisekka I, Gowda PH & Prasad PV. 2017. Evaluation of water-limited cropping systems in a semi-arid climate using DSSAT-CSM. *Agricultural Systems* 150: 86–98.
- Arora VK, Singh H & Singh B. 2007. Analyzing wheat productivity responses to climatic, irrigation and fertilizer-nitrogen regimes in a semi-arid sub-tropical environment using the CERES-Wheat model. *Agricultural Water Management* 94: 22-30.
- Asseng S, Travasso MI, Ludwig F & Magrin GO. 2013. Has climate change opened new opportunities for wheat cropping in Argentina? *Climatic Change* 117: 181-196.

- 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.
- Badu-Apraku, A, Hunter R & Tollenaar M. 1983. Effect of temperature during grain filling on whole plant and grain yield in maize (*Zea mays* L.). Canadian Journal of Plant Science 63: 357–363.
- Baldi G, Houspanossian J, Murray F, Rosales AA, Rueda CV & Jobbágy EG. 2015. Cultivating the dry forests of South America: Diversity of land users and imprints on ecosystem functioning. Journal of Arid Environments 123: 47-59.
- Banterneg P, Hoogenboom G, Patanothai A, Singh P, Wani SP, Pathak P, ... & Jintrawet A. 2010. Application of the Cropping System Model (CSM)-CROPGRO-Soybean for Determining Optimum Management Strategies for Soybean in Tropical Environments. Journal of Agronomy and Crop Science 196: 231-242.
- Barros VR, Boninsegna JA, Camilloni IA, Chidiak M, Magrín GO & Rusticucci M. 2015. Climate change in Argentina: trends, projections, impacts and adaptation. Wiley Interdisciplinary Reviews: Climate Change 6: 151-169.
- Basanta M & Alvarez C. 2015. Manejo sustentable de sistemas agrícolas en la región central de Córdoba: una experiencia de largo plazo en INTA EEA Manfredi. RIA. Revista de investigaciones agropecuarias 41: 215-222.
- Bassu S, Brisson N, Durand JL, Boote K, Lizaso J, Jones JW, ... & Basso, B. 2014. How do various maize crop models vary in their responses to climate change factors? Global Change Biology 20: 2301-2320.
- Bates D, Maechler M, Bolker B & Walker S. 2015. Fitting Linear Mixed-Effects Models Using lme4. Journal of Statistical Software 67: 1-48.

- Battisti R, Sentelhas PC, Boote KJ, Camara G.Md.S, Farias JR & Basso CJ. 2017. Assessment of soybean yield with altered water-related genetic improvement traits under climate change in Southern Brazil. *European Journal of Agronomy* 83: 1–14.
- Bell MA & Fischer RA. 1994. Using yield prediction models to assess yield gains: A case study for wheat. *Field Crops Research* 36: 161-166.
- Bhatia V, Singh P, Wani S, Chauhan G, Rao AK, Mishra A & Srinivas K. 2008. Analysis of potential yields and yield gaps of rainfed soybean in India using CROPGRO-Soybean model. *Agricultural and Forest Meteorology* 148: 1252–1265.
- Blanco-Canqui H. 2013. Crop residue removal for bioenergy reduces soil carbon pools: How can we offset carbon losses?. *Bioenergy Research*, 6: 358-371.
- Boletta PE, Ravelo AC, Planchuelo AM & Grilli M. 2006. Assessing deforestation in the Argentine Chaco. *Forest Ecology and Management* 228: 108-114.
- Boletta PE. 2001. Utilización de información agrometeorológica y satelital para la evaluación de la desertificación en el Chaco Seco-Departamento Moreno, Santiago del Estero. Tesis de maestría en Ciencias Agropecuarias. Facultad de Ciencias Agropecuarias, Universidad Nacional de Córdoba.
- Bonino EE. 2006. Changes in carbon pools associated with a land-use gradient in the Dry Chaco, Argentina. *Forest Ecology and Management* 223: 183-189.
- Boote KJ, Jones JW, Hoogenboom G & Pickering NB. 1998. The CROPGRO Model for Grain Legumes. En Tsuji GY, Hoogenboom G & Thornton PK (editores). *Understanding Options for Agricultural Production*, Kluwer Academic Publishers. Dordrecht. pp 99-128.
- Brisson N, Guevara E, Meira S, Maturano M & Coca G. 2001. Response of five wheat cultivars to early drought in the Pampas. *Agronomie* 21: 483–495.

- Bullock JM, Dhanjal-Adams KL, Milne A, Oliver TH, Todman LC, Whitmore AP & Pywell RF. 2017. Resilience and food security: rethinking an ecological concept. *Journal of Ecology* 105: 880–884.
- Burnham KP, Anderson DR & Huyvaert KP. 2011. AIC model selection and multimodel inference in behavioral ecology. *Behavioral Ecology and Sociobiology* 65: 23–35.
- Bush G. 2005. Fertilización nitrogenada en maíz en la Región Caqueña. Análisis de la respuesta del cultivo mediante un balance de nitrógeno. Trabajo de Intensificación. Facultad de Agronomía, Universidad de Buenos Aires.
- Byrnes J. 2008. Coefficient of determination ( $R^2$ ) when using Lme (). <http://thread.gmane.org/gmane.comp.lang.r.lme4.devel/684>.
- Calviño PA & Monzon JP. 2009. Farming systems of Argentina: yield constraints and risk management. *Crop physiology: Applications for Genetic Improvement and Agronomy* 51. 70 pp.
- Camilloni I & Bidegain M. 2005. Capítulo 4: Climate Scenarios for the XXI century. En Barros V, Menéndez A & Nagy G (editores). *The climate change in the Plata River*. Buenos Aires. pp 33-39.
- Cammarano D, Ceccarelli S, Grando S, Romagosa I, Benbelkacem A, Akar T, Al-Yassin A, Pecchioni N, Francia E & Ronga D. 2019. The impact of climate change on barley yield in the Mediterranean basin. *European Journal of Agronomy* 106: 1–11.
- Cammarano D, Holland J & Ronga D. 2020. Spatial and temporal variability of spring barley yield and quality quantified by crop simulation model. *Agronomy* 10: 393.
- Casali L, Herrera JM, Rubio G. 2021. Modelling maize and soybean responses to climatic change and soil degradation in a region of South America. *Agronomy Journal* 113:1–13.

- Casali L, Rubio G & Herrera JM. 2018. Drought and temperature limit tropical and temperate maize hybrids differently in a subtropical region. *Agronomy for sustainable development* 38: 49.
- Casas RR. 2007. Principales efectos de la intensificación y expansión de la agricultura sobre la salud de los suelos. Consultado el 1-9-2015 en: <http://sedici.unlp.edu.ar>.
- Caviglia OP, Sadras VO & Andrade FH. 2013. Modelling long-term effects of cropping intensification reveals increased water and radiation productivity in the South-eastern Pampas. *Field Crops Research* 149: 300-311.
- Ceglar A, Toreti A, Lecerf R, Van der Velde M & Dentener F. 2016. Impact of meteorological drivers on regional inter-annual crop yield variability in France. *Agricultural and Forest Meteorology* 216: 58–67.
- Challinor AJ, Watson J, Lobell DB, Howden SM, Smith DR & Chhetri N. 2014. A meta-analysis of crop yield under climate change and adaptation. *Nature Climate Change* 4 : 287-291.
- CIAT. 2014. New Carto Chaco platform: Geo-journalism on the Chaco region. Consultado el 4-10- 2015 en:<http://ciat.cgiar.org/position-decision/new-cartochaco-platform-geo-journalism-on-the-chaco-region>.
- Cleland EE, Chuine I, Menzel A, Mooney HA & Schwartz MD. 2007. Shifting plant phenology in response to global change. *Trends in Ecology and Evolution* 22: 357–365.
- Conde C, Liverman D, Flores M, Ferrer R, Araújo R, Betancourt E, Villareal G & Gay C. 1997. Vulnerability of rainfed maize crops in Mexico to climate change. *Climate Research* 9: 17-23.

- Coria RD & Lorenz G. 2004. Influencia de la agricultura en las propiedades hidráulicas del suelo en un paisaje del Chaco Semiárido: I- Suelos en ambientes generadores de escorrentía. Trabajo final de graduación para acceder al título de Licenciado en Ecología y Conservación del Ambiente. Facultad de Ciencias Forestales. Universidad de Santiago del Estero.
- Crookston RK. 1984. The rotation effect. *Crops Soils Mag.* 36: 12.
- Dagliesh NP & Foale MA. 1998. Soil matters: monitoring soil water and nutrients in dryland farming. Agricultural Production Systems Research Unit. Toowoomba, Queensland, Australia. 122 pp.
- Dang DKD, Patterson AC & Carrasco LR. 2019. An analysis of the spatial association between deforestation and agricultural field sizes in the tropics and subtropics. *PLOS One* 14 (1), e0209918.
- Dardanelli JL, Bachmeier OA, Sereno R & Gil R. 1997. Rooting depth and soil water extraction patterns of different crops in a silty loam haplustoll. *Field Crop Research* 54:29–38.
- de Moraes MT, Debiasi H, Carlesso R, Franchini JC, da Silva VR & da Luz FB. 2016. Soil physical quality on tillage and cropping systems after two decades in the subtropical region of Brazil. *Soil and Tillage Research* 155: 351-362.
- Debaeke P & Aboudrare A. 2004. Adaptation of crop management to water-limited environments. *European Journal of Agronomy* 21: 433-446.
- Del Ponte EM, Fernandes JMC, Pierobom CR & Bergstrom GC. 2004. Giberela do trigo— aspectos epidemiológicos e modelos de previsão. *Fitopatologia Brasileira* 29: 587-605.



- Di Mauro G, Borrás L, Rugeroni P & Rotundo JL. 2019. Exploring soybean management options for environments with contrasting water availability. *Journal of Agronomy and Crop Science* 205: 274-282.
- Dinse K. 2009. Climate variability and climate change: what is the difference. *Book climate variability and climate change: What is the difference.*
- Díaz-Zorita M, Duarte GA & Grove JH. 2002. A review of no-till systems and soil management for sustainable crop production in the subhumid and semiarid Pampas of Argentina. *Soil and Tillage Research* 65:1-18.
- Dogan E, Kirnak H & Copur O. 2007. Deficit irrigations during soybean reproductive stages and CROPGRO-soybean simulations under semi-arid climatic conditions. *Field Crops Research* 103: 154-159.
- Dominguez J & Rubio G. 2019. Agriculture, in: G. Rubio, Lavado RS, Pereyra FX (eds) (Ed.), *The Soils of Argentina.*, Springer International Publisher pp. 209-238.
- Douxchamps S, Debevec L, Giordano M & Barron J. 2017. Monitoring and evaluation of climate resilience for agricultural development – a review of currently available tools. *World Development Perspective* 5: 10–23.
- Dzotsi KA, Basso B & Jones JW. 2013. Development, uncertainty and sensitivity analysis of the simple SALUS crop model in DSSAT. *Ecological Modelling* 260: 62-76.
- Edreira JIR & Otegui ME. 2012. Heat stress in temperate and tropical maize hybrids: differences in crop growth, biomass partitioning and reserves use. *Field Crops Research* 130: 87–98.
- Elliott J, Deryng D, Müller C, Frieler K, Konzmann M., Gerten D, Glotter M., Flörke M, Wada Y & Best N. 2014. Constraints and potentials of future irrigation water

availability on agricultural production under climate change. Proceedings of the National Academy of Sciences of the U.S.A. 111: 3239-3244.

Fehlenberg V, Baumann M, Gasparri NI, Piquer-Rodriguez M., Gavier-Pizarro G & Kuemmerle T. 2017. The role of soybean production as an underlying driver of deforestation in the South American Chaco. *Global environmental change* 45, 24-34.

Fernández MC, Belinque H, Gutierrez Boem FH, Rubio G. 2009. Compared phosphorus efficiency in soybean, sunflower, and maize. *Journal of Plant Nutrition* 32: 2027–2043.

Fodor N, Challinor A, Droutsas I, Ramirez-Villegas J, Zabel F, Koehler AK & Foyer CH. 2017. Integrating plant science and crop modeling: assessment of the impact of climate change on soybean and maize production. *Plant Cell Physiology* 58: 1833-1847.

Fox J & Weisberg S. 2018. *An R Companion to Applied Regression*. Sage publications.

Gabaldón-Leal, C., Webber, H., Otegui, M.E., Slafer, G.A., Ordóñez, R., Gaiser, T., Lorite, I., Ruiz-Ramos, M., & Ewert, F. 2016. Modelling the impact of heat stress on maize yield formation. *Field Crops Research* 198: 226-237.

Gambin BL, Coyos T, Di Mauro G, Borrás L & Garibaldi LA. 2016. Exploring genotype, management, and environmental variables influencing grain yield of late-sown maize in central Argentina. *Agricultural Systems* 146: 11-19.

Gaudin ACM, Tolhurst TN, Ker AP, Janovicek K, Tortora C, Martin RC & Deen W. 2015. Increasing crop diversity mitigates weather variations and improves yield stability. *PLOS One* 10 (2), e0113261.

- Gharari S, Hrachowitz M, Fenicia F, Gao H & Savenije HHG. 2014. Using expert knowledge to increase realism in environmental system models can dramatically reduce the need for calibration. *Hydrology and Earth System Sciences* 18: 4839-4859.
- Gibson LR & Mullen RE. 1996. Influence of day and night temperature on soybean seed yield. *Crop Science* 36 (1) cropsoci1996.0011183x003600010018x.
- Giménez VD, Micheloud JR & Maddonni GÁ. 2018. Climatic constraints for the maize-soybean system in the humid subtropical region of Argentina. *Theoretical and Applied Climatology* 134: 753-767.
- Giménez R, Mercau JL, Bert FE, Kuppel S, Baldi G, Houspanossian, J, Magliano P & Jobbagy EG. 2020. Hydrological and productive impacts of recent land-use and land-cover changes in the semiarid Chaco: Understanding novel water excess in water scarce farmlands. *Ecohydrology* 13: e2243.
- Giménez R, Mercau JL, Houspanossian J & Jobbágy EG. 2015. Balancing agricultural and hydrologic risk in farming systems of the Chaco plains. *Journal of Arid Environments* 123: 81-92.
- Goldfarb L & Zoomers A. 2013. The drivers behind the rapid expansion of genetically modified soya production in to the Chaco region of Argentina. En Fang Z (editor). *Biofuels-Economy, Environment and Sustainability*. pp 73-95.
- Goldfarb L, van der Haar G. 2016. The moving frontiers of genetically modified soy production: shifts in land control in the Argentinian Chaco. *The Journal of Peasant Studies* 43:562–582.
- Gorleri MC. 2005. Caracterización climática del Chaco Húmedo. En Di Giacomo AG & Krapovickas SF (editores). *Historia natural y paisaje de la Reserva El Bagual*,

- Formosa, Argentina. Inventario de la fauna de vertebrados y de la flora vascular de un área del Chaco Húmedo. Aves Argentinas / Asociación Ornitológica del Plata. Temas de Naturaleza y Conservación 4. Buenos Aires. pp 13-25.
- Grant RF, Jackson BS, Kiniry JR & Arkin GF. 1989. Water deficit timing effects on yield components in maize. *Agronomy Journal* 81: 61–65.
- Guevara E & Meira S. 1995. Application of CERES-Maize model in Argentina. Second International Symposium on systems approaches for agricultural development (SAAD2). Los Baños-International Rice Research Institute. Philippines.
- Guillaume T, Damris M & Kuzyakov Y. 2015. Losses of soil carbon by converting tropical forest to plantations: Erosion and decomposition estimated by  $\delta^{13}\text{C}$ . *Global Change Biology* 21: 3548-3560.
- Hanft JM & Jones RJ. 1986. Kernel abortion in maize I. Carbohydrate concentration patterns and acid invertase activity of maize kernels induced to abort in vitro. *Plant Physiology* 81: 503-510.
- Hansen J, Hellin J, Rosenstock T, Fisher E, Cairns J, Stirling C, Lamanna C, van Etten J, Rose A, Campbell B. 2019. Climate risk management and rural poverty reduction. *Agricultural System* 172: 28–46.
- Hargreaves GH, Samani ZA. 1985. Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture* 1: 96–99.
- Hoffman J. 1989. Las variaciones climáticas ocurridas en la Argentina desde fines del siglo pasado hasta el presente. En Prego AJ (editor). El deterioro del ambiente en la Argentina (Suelo-Agua-Vegetación-Fauna). Servicio Meteorológico Nacional, Fuerza Aérea Argentina, FECIC. Divulgación 15. 15 pp.

- Holshouser DL & Whittaker JP. 2002. Plant population and row-spacing effects on Early Soybean Production Systems in the Mid-Atlantic USA. *Agronomy Journal* 94: 603–611.
- Hoogenboom G, Jones J, Wilkens P, Porter C, Boote K, Hunt L, Singh U, Lizaso J, White J & Uryasev O. 2010. Decision Support System for Agrotechnology Transfer (DSSAT) Version 4.5. University of Hawaii, Honolulu, p. 1.
- Hulme M, Mitchell J, Ingram W, Johns T, New M & Viner D. 1999. Climate change scenarios for global impacts studies. *Global Environmental Change* 9: S3-S19.
- Hunt LA, White JW & Hoogenboom G. 2001. Agronomic data: advances in documentation and protocols for exchange and use. *Agricultural System* 70: 477–492.
- Hunt LA, Pararajasingham JM, Jones S, Hoogenboom G, Imamura DT & Ogoshi RM. 1993. Gencalc: Software to facilitate the use of crop models for analyzing field experiments. *Agronomy Journal* 85: 1090-1094.
- Intergovernmental Panel on Climate Change (IPCC). 2001. En Houghton JT et al. (editores). *Climate Change 2001: The Scientific Basis. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press. New York. 881 pp.
- IPCC. 2007. *Climate Change 2007: Working Group I: The Physical Science Basis*, [http://www.ipcc.ch/publications\\_and\\_data/ar4/wg1/en/contents.html](http://www.ipcc.ch/publications_and_data/ar4/wg1/en/contents.html) (accessed on June 2018).
- IPCC. 2014. Food security and food production systems. IPCC (Ed.), *Climate Change 2014 – Impacts, Adaptation and Vulnerability: Part A: Global and Sectoral Aspects: Working Group II Contribution to the IPCC Fifth Assessment Report*,

- Jamieson PD, Porter JR & Wilson DR. 1991. A test of the computer simulation model ARCWHEAT1 on wheat crops grown in New Zealand. *Field Crops Research* 27: 337-350.
- Jeuffroy MH, Casadebaig P, Debaeke P, Loyce C, Meynard JM (2014) Agronomic model uses to predict cultivar performance in various environments and cropping systems. A review. *Agronomy for Sustainable Development* 34:121–137.
- Jones JW, Hoogenboom G, Porter CH, Boote KJ, Batchelor WD, Hunt LA, Wilkens PW, Singh U, Gijsman AJ & Ritchie L. 2003. The DSSAT cropping system model. *European Journal of Agronomy* 18: 235–265.
- Jones CA, Kiniry JR & Dyke PT. 1986. CERES-Maize: A Simulation Model of Maize. Growth and Development. Texas A & M University Press. College Station, Texas.
- Jones JW, Boote KJ, Jagtap SS & Mishoe JW. 1991. Soybean development. In *Modeling Plant and Soil Systems*, eds. J. Hanks & JT Ritchie. *Agronomy Monograph* 31, ASA - CSSA - SSSA, Madison, WI.
- Jury WA & Vaux HJ. 2007. The emerging global water crisis: Managing scarcity and conflict between water users. *Advances in Agronomy* 95: 1-76.
- Justino J, Oliveira EC, de Ávila Rodrigues R, Gonçalves PHL, Souza PJ, Stordal F, Marengo J, da Silva TG, Delgado RC & da Silva Lindemann, D. 2013. Mean and interannual variability of maize and soybean in Brazil under global warming conditions. *American Journal of Climate Change* 2: 237-253.
- Kahiluoto H, Kaseva J, Balek J, Olesen JE, Ruiz-Ramos M, Gobin A, Kersebaum KC, Takáč, J, Ruget F, Ferrise R, Bezak P, Capellades G, Dibari C, Mäkinen H, Nendel C, Ventrella D, Rodríguez A, Bindi M & Trnka M. 2019. Decline in climate

- resilience of European wheat. *Proceedings of the National Academy of Sciences* . USA 116: 123–128.
- Karlen DL, Hurley EG, Andrews SS, Cambardella CA, Meek DW, Duffy MD & Mallarino AP. 2006. Crop rotation effects on soil quality at three northern corn/soybean belt locations. *Agronomy Journal* 98: 484-495.
- Karlen DL, Wollenhaupt NC, Erbach DC, Berry EC, Swan JB, Eash NS & Jordahl JL. 1994. Crop residue effects on soil quality following 10-years of no-till corn. *Soil and Tillage Research* 31: 149-167.
- Kiniry JR & Ritchie JT. 1985. Shade-sensitive interval of kernel number of maize 1. *Agronomy Journal* 77: 711–715.
- Kirwan L, Connolly J, Finn JA, Brophy C, Lüscher A, Nyfeler D & Sebasti a MT. 2009. Diversity-interaction modeling: estimating contributions of species identities and interactions to ecosystem function. *Ecology* 90: 2032–2038.
- Koenker R. 2016. *quantreg: Quantile regression*. R package version 5.21. <http://CRAN.R-project.org/package=quantreg>.
- Kothari K, Battisti R, Boote KJ, Archontoulis SV, Confalone A, Constantin J, ... & Salmer n M. 2022. Are soybean models ready for climate change food impact assessments? *European Journal of Agronomy* 135; 126482.
- Kuemmerle T, Altrichter M, Baldi G, Cabido M, Camino M, Cuellar E, Cuellar RL, Decarre J, D az S & Gasparri I. 2017. Forest conservation: remember gran chaco. *Science* 355: 465-465.
- Kumar N, Nain AS & Kumar S. 2012. Sequential simulation of wheat and urd using DSSAT model in mollisol of Uttarakhand. *Journal of Agrometeorology* 14: 158-162.

- Kunst C, Ledesma R, Basan, Nickish MB, Angella G, Prieto D & Godoy J. 2003. Rolado de" fachinales" e infiltración de agua en suelo en el Chaco Occidental (Argentina). RIA 32: 105-126.
- Lal M, Singh KK, Srinivasan G, Rathore LS, Naidu D & Tripathi CN. 1999. Growth and yield responses of soybean in Madhya Pradesh, India to climate variability and change. *Agricultural and Forest Meteorology* 93: 53-70.
- Lal, R. 2012. Climate change and soil degradation mitigation by sustainable management of soils and other natural resources. *Agricultural Research* 1: 199-212.
- Landschoot S, Waegeman W, Audenaert K, Vandepitte J, Haesaert G & De Baets B. 2012. Toward a Reliable Evaluation of Forecasting Systems for Plant Diseases: A Case Study Using Fusarium Head Blight of Wheat. *Plant Disease* 96: 889-896.
- Lavado RS & Taboada MA. 2009. The Argentinean Pampas: a key region with a negative nutrient balance and soil degradation needs better nutrient management and conservation programs to sustain its future viability as a world agresource. *Journal Soil of Water Conservation* 64:150A– 153A.
- Li ZT, Yang JY, Drury CF & Hoogenboom G. 2015. Evaluation of the DSSAT-CSM for simulating yield and soil organic C and N of a long-term maize and wheat rotation experiment in the Loess Plateau of Northwestern China. *Agricultural Systems* 135: 90-104.
- Liu S, Yang J, Zhang X, Drury C, Reynolds W & Hoogenboom G. 2013. Modelling crop yield, soil water content and soil temperature for a soybean–maize rotation under conventional and conservation tillage systems in Northeast China. *Agricultural Water Management* 123: 32-44.



- Lobell DB, Asner GP, Ortiz-Monasterio JI & Benning TL. 2003. Remote sensing of regional crop production in the Yaqui Valley, Mexico: estimates and uncertainties. *Agriculture, Ecosystems & Environment* 94: 205-220.
- Lobell DB & Asner GP. 2003. Climate and management contributions to recent trends in US agricultural yields. *Science* 299, 1032.
- Lobell DB, Bänziger M, Magorokosho C, Vivek B. 2011. Nonlinear heat effects on African maize as evidenced by historical yield trials. *Nature Climate Change* 1: 42–45.
- Lobell DB & Burke MB. 2010. On the use of statistical models to predict crop yield responses to climate change. *Agricultural and Forest Meteorology* 150: 1443-1452.
- Lobell DB, Hammer GL, McLean G, Messina C, Roberts MJ & Schlenker W. 2013. The critical role of extreme heat for maize production in the United States. *Nature Climate Change* 3: 497-501.
- Lobell DB, Ortiz-Monasterio JI, Asner GP, Matson PA, Naylor RL & Falcon WP. 2005. Analysis of wheat yield and climatic trends in Mexico. *Field Crops Research* 94: 250-256.
- Lobell DB, Roberts MJ, Schlenker W, Braun N, Little BB, Rejesus RM. & Hammer GL. 2014. Greater sensitivity to drought accompanies maize yield increase in the US Midwest. *Science* 344(6183): 516-519.
- Lobell DB, Schlenker W & Costa-Roberts J. 2011. Climate trends and global crop production since 1980. *Science* 333: 616-620.
- Long SP, Ainsworth EA, Leakey ADB & Morgan PB. 2005. Global food insecurity. Treatment of major food crops with elevated carbon dioxide or ozone under large-scale fully open-air conditions suggests recent models may have overestimated future yields. *Philosophical Transactions of the Royal Society* 360: 2011–2020.

- Ma L, Ahuja L, Islam A, Trout T, Saseendran, S & Malone R. 2017. Modeling yield and biomass responses of maize cultivars to climate change under full and deficit irrigation. *Agricultural Water Management* 180: 88-98.
- Maddonni GA. 2012. Analysis of the climatic constraints to maize production in the current agricultural region of Argentina—a probabilistic approach. *Theoretical and Applied Climatology* 107:325-345
- Madias A, Di Mauro G, Vitantonio-Mazzini LN, Gambin BL & Borrás L. 2021. Environment quality, sowing date, and genotype determine soybean yields in the Argentinean Gran Chaco. *European Journal of Agronomy* 123: 126-217.
- Magrin GO, Travasso MI, Grondona MO & Rodríguez GR. 2007. Variabilidad climática, cambio climático y sector agropecuario. Presentación en *Clima Latino: Encuentro Internacional sobre Cambio Climático en América Latina*. Quito, Ecuador.
- Malla G. 2008. Climate change and its impact on Nepalese agriculture. *Journal of Agriculture and Environment* 9: 62-71.
- Manuel-Navarrete DM, Gallopín GC, Blanco M, Díaz-Zorita M, Ferraro DO, Herzer H, Lathera P, Murmis MR, Podestá GP, Rabinovich J, Satorre EH, Torres F & Viglizzo EF. 2009. Multi-causal and integrated assessment of sustainability: the case of agriculturization in the Argentine Pampas. *Environment, Development and Sustainability* 11: 621-638.
- Marchesini VA, Nosetto, MD, Houspanossian J & Jobbágy EG. 2020. Contrasting hydrological seasonality with latitude in the South American Chaco: the roles of climate and vegetation activity. *Journal of Hydrology* 587, 124933.

- Maytín CE, Acevedo MF, Jaimez R, Andressen R, Harwell MA, Robock A & Azócar A. 1995. Potential effects of global climatic change on the phenology and yield of maize in Venezuela. *Climatic Change* 29: 189-211.
- Mazzilli SR, Kemanian AR, Ernst OR, Jackson RB, Piñeiro G. 2014. Priming of soil organic carbon decomposition induced by corn compared to soybean crops. *Soil Biology and Biochemistry* 75: 273–281.
- Meira S & Guevara E. 1995. Application of SOYGRO model in Argentina. Second International Symposium on Systems Approaches for Agricultural Development (SAAD2). Los Baños-International Rice Research Institute. Philippines
- Meng Q, Chen X, Lobell DB, Cui Z, Zhang Y, Yang H & Zhang F. 2016. Growing sensitivity of maize to water scarcity under climate change. *Scientific Reports* 6: 19605.
- Mercau JL, Dardanelli JL, Collino DJ, Andriani JM, Irigoyen A & Satorre EH. 2007. Predicting on-farm soybean yields in the pampas using CROPGRO-soybean. *Field Crops Research* 100: 200-209.
- Minetti J & Acuña L. 1994. Régimen de variabilidad interanual de las precipitaciones anuales en el centro-este de la provincia de Santiago del Estero. INTA. Centro Regional Tucumán, Santiago del Estero.
- Molino J. 2011. Estrés térmico por alta temperatura en soja (*Glycine max* (L.) Merr.): análisis de la dinámica de producción y fijación de vainas y su efecto sobre la determinación del rendimiento. Tesis de maestría. Facultad de Agronomía, Universidad de Buenos Aires.
- Monzon JP, La Menza NC, Cerrudo A, Canepa M, Edreira JIR, Specht J, ... & Grassini P. 2021. Critical period for seed number determination in soybean as determined by

- crop growth rate, duration, and dry matter accumulation. *Field Crops Research* 261: 108016.
- Monzon JP, Sadras VO & Andrade FH. 2012. Modelled yield and water use efficiency of maize in response to crop management and Southern Oscillation Index in a soil-climate transect in Argentina. *Field Crops Research* 130: 8-18.
- Monzon JP, Sadras VO, Abbate PA & Caviglia OP. 2007. Modelling management strategies for wheat–soybean double crops in the south-eastern Pampas. *Field Crops Research* 101: 44-52.
- Morello J, Pengue W & Rodríguez A. 2005. Un siglo de cambios de diseño del paisaje: el Chaco Argentino. *Primeras Jornadas Argentinas de Ecología del Paisaje*. pp 1-31.
- Moscuzza C, Pérez Carrera A & Fernández Cirelli A. 2003. Relación entre las actividades agropecuarias y la escasez de agua en la provincia de Santiago del Estero (Argentina). *El agua en Iberoamérica. Aspectos de la Problemática de las Tierras Secas*. pp 35-54.
- Mullan, D. 2013. Soil erosion under the impacts of future climate change: Assessing the statistical significance of future changes and the potential on-site and off-site problems. *Catena* 109: 234-246.
- Murgida AM, Travasso MI, González S & Rodríguez GR. 2014. Evaluación de impactos del cambio climático sobre la producción agrícola en la Argentina. *Serie medio ambiente y desarrollo* 155. Naciones Unidas. Santiago de Chile, Chile.
- Nakagawa S & Schielzeth H. 2013. A general and simple method for obtaining R<sup>2</sup> from generalized linear mixed-effects models. *Methods Ecol. Evol.* 4: 133–142.
- Naumann M. 2006. *Atlas del Gran Chaco Sudamericano*. Sociedad Alemana de Cooperación Técnica (GTZ). Buenos Aires. 92 pp.

- Naumann M, Madariaga MC, Adámoli JM, Herrera P, Torrella SA & Metz R. 2004. Atlas del Gran Chaco Sudamericano.
- Nearing M, Pruski F & O'neal M. 2004. Expected climate change impacts on soil erosion rates: a review. *Journal of Soil and Water Conservation* 59: 43-50.
- Neiff N. 2017. Respuesta fisiológica de genotipos de maíz (*Zea mays* L.) al estrés térmico por alta temperatura durante el periodo crítico del cultivo. Tesis doctoral. Universidad Nacional del Nordeste.
- Ngwira AR, Aune JB & Thierfelder C. 2014. DSSAT modelling of conservation agriculture maize response to climate change in Malawi. *Soil and Tillage Research* 143: 85-94.
- Oesterheld M. 2008. Impacto de la agricultura sobre los ecosistemas: fundamentos ecológicos y problemas más relevantes. *Ecología Austral* 18: 337-346.
- Olesen JE, Trnka M, Kersebaum KC, Skjelvåg A, Seguin B, Peltonen-Sainio P, Rossi F, Kozyra J & Micale F. 2011. Impacts and adaptation of European crop production systems to climate change. *European Journal of Agronomy* 34: 96-112.
- OMM. 2017. Directrices de la Organización Meteorológica Mundial sobre el cálculo de las normales climáticas (OMM-N° 1203), Ginebra.
- Osinaga N, Álvarez CR & Taboada, M. A. Effect of deforestation and management on soil carbon stocks in the South American Chaco. In Proceedings of the Global symposium on soil organic carbon, 2017, Rome, Italy, 21-23 March 2017 (pp. 475-479). Food and Agriculture Organization of the United Nations (FAO).
- Osinaga NA, Álvarez CR & Taboada MA. 2018. Effect of deforestation and subsequent land use management on soil carbon stocks in the South American Chaco. *Soil* 4: 251-257.

- Padarian J, Minasny B, McBratney AB & Dalgliesh N. 2014. Mapping the available water capacity of Australian soils. In: GlobalSoilMap: basis of the global spatial soil information system—Proceedings of the 1st GlobalSoilMap Conference. pp 173–179
- Paruelo JM, Guerschman JP & Verón SR. 2005. Expansión agrícola y cambios en el uso del suelo. *Ciencia Hoy* 15: 14-23.
- Patiño CA & Vicentini GM. 2007. The anegamiento processes or drought in the Great Chaco. Explanation assay. *Revista de Ciencia y Tecnología* 3: 13-21.
- Pérez-Carrera AA, Moscuza CH & Fernández-Cirelli A. 2008. Efectos socioeconómicos y ambientales de la expansión agropecuaria. Estudio de caso: Santiago del Estero, Argentina. *Revista Ecosistemas* 17.
- Peters D, Pendleton J, Hageman R & Brown C. 1971. Effect of night air temperature on grain yield of corn, wheat, and soybeans 1. *Agronomy Journal* 63: 809-809.
- Phillips JG, Cane MA & Rosenzweig C. 1998. ENSO, seasonal rainfall patterns and simulated maize yield variability in Zimbabwe. *Agricultural and Forest Meteorology* 90: 39-50.
- Piquer-Rodríguez M, Torella S, Gavier-Pizarro G, Volante J, Somma D, Ginzburg R & Kuemmerle T. 2015. Effects of past and future land conversions on forest connectivity in the Argentine Chaco. *Landscape Ecology* 30:817–833.
- Powlson DS, Stirling CM, Thierfelde C, White RP & Jat ML. 2016. Does conservation agriculture deliver climate change mitigation through soil carbon sequestration in tropical agro-ecosystems? *Agriculture, Ecosystems & Environment*, 220, 164-174.
- Prieto Angueira S, Berton MC, Ventura J. 2018a. Cultivos de cobertura en Santiago del Estero: I. Biomasa, evapotranspiración y eficiencia de uso del agua. *Actas XXVI*

- Congreso Argentino de Ciencia de Suelo. Asociación Argentina de Ciencia de Suelo – AACS. Ciudad Autónoma de Buenos Aires. Pp 1269-1274. San Miguel de Tucumán, Argentina. 15 al 18 de mayo de 2018. ISBN 978-987-46870-0-5.
- Prieto Angueira S, Berton MC, Ventura J. 2018b. Cultivos de cobertura en Santiago del Estero: II. Dinámica en el contenido de agua del suelo y costo hídrico. Actas XXVI Congreso Argentino de Ciencia de Suelo. Asociación Argentina de Ciencia de Suelo – AACS. Ciudad Autónoma de Buenos Aires. Pp 1275-1280. San Miguel de Tucumán, Argentina. 15 al 18 de mayo de 2018. ISBN 978-987-46870-0-5.
- Prieto Angueira S, Berton MC, Ventura J. 2019. Efecto de los cultivos de servicio sobre la disponibilidad de agua y nitrógeno y el rendimiento en el cultivo de maíz en Santiago del Estero. Simposio de Fertilidad. Copilado por M.F. González Sanjuan y F.O. García. Fertilizar Asociación Civil. Pp 272-277. Rosario, Argentina. 8 y 9 de mayo de 2019. Disponible online. Fecha de acceso: 20/07/2020.
- Prieto Angueira S, Lescano M, Azar A, Ochoa MC, Anriquez A, Savino P, Fuentes F. 2022. Economía del agua y nitrógeno en maíz luego de cultivos de servicio. Congreso de Maíz Tardío. 6 de octubre de 2022. Buenos Aires, Argentina.
- R Core Team. 2015. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria.
- R Development Core Team, 2019. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria.
- Rattalino Edreira JI & Otegui ME. 2012. Heat stress in temperate and tropical maize hybrids: Differences in crop growth, biomass partitioning and reserves use. Field Crops Research 130: 87-98.

- Rattalino Edreira JI, Budakli Carpici B, Sammarro D & Otegui ME. 2011. Heat stress effects around flowering on kernel set of temperate and tropical maize hybrids. *Field Crops Research* 123: 62–73
- Rawls WJ & Brakensiek DL. 1989. Estimation of soil water retention and hydraulic properties. In: Morel-Seytoux HJ (ed) *Unsaturated flow in hydrologic modeling: theory and practice*. Springer, Netherlands, pp 275–300.
- Ray DK, Gerber JS, MacDonald GK & West PC. 2015. Climate variation explains a third of global crop yield variability. *Nat. Commun.* 6: 5989.
- Red Agroforestal Chaco. 1999. Estudio Integral de la Región del Parque Chaqueño. Proyecto Bosques Nativos y Áreas protegidas. Préstamo BIRF N° 4085–AR. Informe General Ambiental. Secretaría de Desarrollo Sustentable y Política Ambiental. 170 pp.
- REGATTA-PNUMA. 2013. Estudio de vulnerabilidad e impacto del cambio climático en el Gran Chaco Americano (Argentina, Bolivia y Paraguay). Informe Avance. Centro de conocimiento para el Gran Chaco Americano y Cono Sur. 219 pp.
- Reicosky DC, Warnes DD & Evans SD. 1985. Soybean evapotranspiration, leaf water potential and foliage temperature as affected by row spacing and irrigation. *Field Crops Research* 10: 37–48.
- Ricard MF, Viglizzo EF & Podestá G. 2015. Comparison of adaptative strategies to climate variability in rural areas of Argentine Chaco and US Southern Plains during the last century. *Journal of Arid Environments* 123: 68-80.
- Rimski-Korsakov H, Rubio G & Lavado RS. 2012. Fate of the nitrogen from fertilizers in field-grown maize. *Nutrient Cycling in Agroecosystem* 93: 253–263.



- Ritchie JT, Singh U, Godwin D & Hunt L. 1989. A usersguide to CERES-maize v2.10. International Fertilizer Development Centre. Muscle Shoals, AL.
- Ritchie JT. 1998. Soil water balance and plant water stress. In: Tsuji, G.Y., Hoogenboom, G., Thornton, P.K. (Eds.), *Understanding Options for Agricultural Production*. Springer Netherlands, Dordrecht, pp. 41–54.
- Rose G, Osborne T, Greatrex H & Wheeler T. 2016. Impact of progressive global warming on the global-scale yield of maize and soybean. *Climatic Change* 134: 417-428.
- Rosenbaum PR. 2002. *Observational studies*, 2nd edn. Springer-Verlag, New York
- Rosenzweig C, Elliott J, Deryng D, Ruane AC, Müller C, Arneth A, Boote KJ, Folberth C, Glotter M, Khabarov N, Neumann K, Piontek F, Pugh TAM, Schmid E, Stehfest E, Yang H & Jones JW. 2014. Assessing agricultural risks of climate change in the 21st century in a global gridded crop model intercomparison. *Proceedings of the National Academy of Sciences of the United States of America* 111: 3268-3273.
- Ross SM. 1993. Organic matter in tropical soils: current conditions, concerns and prospects for conservation. *Progress in physical geography* 17: 265-305.
- Rubio G, Lavado RS, Pereyra FX, Taboada MA, Moretti LM, Rodriguez D, Echeverría, H & Panigatti JL. 2019. Future Issues. In: G. Rubio, R.S. Lavado, & F.X. Pereyra (Eds), *The Soils of Argentina*. (pp. 261-263). Springer International Publishing, Cham.
- Sadras V, Roget D & Krause M. 2003. Dynamic cropping strategies for risk management in dry-land farming systems. *Agricultural Systems* 76: 929-948.
- Saseendran SA, Ma L, Nielse. DC, Vigil MF & Ahuja LR. 2005. Simulating planting date effects on corn production using RZWQM and CERES-Maize models. *Agronomy Journal* 97: 58-71.

- Sauer MV & Nadal NJ. 2011. Respuesta a la fertilización nitrogenada en maíz para el Suroeste del Chaco. Congreso de Biología de Suelos. Salta, julio de 2011.
- Saxton KE, Rawls W, Romberger JS & Papendick RI. 1986. Estimating generalized soil-water characteristics from texture. *Soil Science Society of America Journal* 50: 1031-1036.
- Schlenker, W & Roberts MJ. 2009. Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. *Proceedings of the National Academy of Sciences USA* 106 15594–15598.
- Schooper JB, Lambert RJ, Vasilas BL & Westgate ME. 1987. Plant Factors Controlling Seed Set in Maize The Influence of Silk, Pollen, and Ear-Leaf Water Status and Tassel Heat Treatment at Pollination. *Plant Physiology* 83: 121-125.
- Secretaría de Ambiente y Desarrollo Sustentable de la Nación, 2014. Tercera Comunicación Nacional sobre Cambio Climático. Cambio Climático en Argentina; Tendencias y Proyecciones. (Centro de Investigaciones del Mar y la Atmósfera). Buenos Aires, Argentina.
- Serio LA & Zalazar SMF. 2012. Agricultural expansion and rainfall trends in Chaco y Formosa (Argentina). Cátedra de Climatología y Fenología Agrícolas, Facultad de Agronomía, UBA. Consultado el 1-11-2015 en: <http://www.researchgate.net/publication/268497902>
- Seybold C, Herrick JE & Brejda J. 1999. Soil resilience: a fundamental component of soil quality. *Soil Science* 164: 224-234.
- Sinsawat V, Leipner J, Stamp P & Fracheboud Y. 2004. Effect of heat stress on the photosynthetic apparatus in maize (*Zea mays* L.) grown at control or high temperature. *Environment and Experimental Botany* 52:123–129.

- Smit B & Skinner MW. 2002. Adaptation options in agriculture to climate change: a typology. *Mitigation and Adaptation Strategies for Global Change* 7: 85-114.
- Smith AB, Cullis BR, Thompson R. 2005. The analysis of crop cultivar breeding and evaluation trials: an overview of current mixed model approaches. *Journal Agriculture Science* 143: 449–462.
- Steel RG, Torrie JH & Dickey D. 1980. *Principles and procedures of statistics, a biometrical approach*. New York. Mc Graw-Hill.
- Stouffer RJ, Taylor KE & Meeh GA. 2011. CMIP5 Long-term experimental Design. *CLIVAR Exchanges* 56: 5–7.
- Studdert G & Echeverria H. 2000. Crop Rotations and Nitrogen Fertilization to Manage Soil Organic Carbon Dynamics. *Soil Science Society of American Journal* 64: 1496-1503.
- Tao F & Zhang Z. 2011. Impacts of climate change as a function of global mean temperature: maize productivity and water use in China. *Climatic Change* 105: 409-432.
- Taylor KE, Stouffer RJ & Meehl GA. 2012. An Overview of CMIP5 and the experiment design. *Bulletin of the American Meteorological Society* 93: 485–498.
- Tebaldi C, Hayhoe K, Arblaster J, Meehl G. 2006. Going to the extremes. *Climatic Change* 79: 185–211.
- Teixeira EI, Fischer G, van Velthuisen H, Walter C & Ewert F. 2013. Global hot-spots of heat stress on agricultural crops due to climate change. *Agricultural and Forest Meteorology* 170: 206-215.
- The Nature Conservancy (TNC), Fundación Vida Silvestre Argentina (FVSA), Fundación para el Desarrollo Sustentable del Chaco (DeSdel Chaco) & Wild life Conservation

- Society Bolivia (WCS). 2005. Evaluación Ecorregional del Gran Chaco Americano. Fundación Vida Silvestre Argentina. Buenos Aires.
- Tiedemann JL. 2011. Fenología del bosque de las subregiones naturales: Chaco Semiárido y Chaco Serrano, de Santiago del Estero, Argentina. *Ecología Aplicada* 10: 51-59.
- Tilman D, Fargione J, Wolff B, D'Antonio C, Dobson A, Howarth R, ... & Swackhamer D. 2001. Forecasting agriculturally driven global environmental change. *Science* 292: 281-284.
- Tojo Soler CM, Sentelhas PC & Hoogenboom G. 2007. Application of the CSM-CERES-Maize model for planting date evaluation and yield forecasting for maize grown off-season in a subtropical environment. *European Journal of Agronomy* 27: 165-177.
- Torrella SA & Adámoli J. 2005. Situación ambiental de la ecorregión de Chaco seco. En Brown AD, Martinez-Ortiz U, Acerbi M & Corcuera J (editores). *Situación Ambiental Argentina*. Fundación Vida Silvestre Argentina. Buenos Aires. pp 75–82.
- Torrella SA, Adámoli J, Herrera P & Ginzburg R. 2005. La expansión agrícola en el Chaco argentino: contrastes entre el litoral fluvial y el interior. *Temas de Biodiversidad del Litoral Fluvial Argentino II*, 14.
- Torres, R., 2001. Towards a socially sustainable world economy: An analysis of the social pillars of globalization.
- Travasso MI & Magrin GO. 2001. Testing crop models at the field level in Argentina. Proceedings of the 2nd International Symposium “Modelling Cropping Systems”. July 16–18, 2001. Florencia, Italia. pp 89–90.
- Travasso MI, Magrin GO, Rodriguez GR, Solman S & Nunez M. 2009. Climate change impacts on regional maize yields and possible adaptation measures in Argentina. *International Journal of Global Warming* 1: 201-213.

- Twine TE, Bryant JJ, Richter K, Bernacchi CJ, Mc Connaughay KD, Morris SJ & Leakey AD. 2013. Impacts of elevated CO<sub>2</sub> concentration on the productivity and surface energy budget of the soybean and maize agroecosystem in the Midwest USA. *Global Change Biology* 19: 2838-2852.
- Vallejos M, Volante JN, Mosciaro MJ, Vale LM, Bustamante ML & Paruelo JM. 2014. Transformation dynamics of the natural cover in the Dry Chaco ecoregion: a plot level geo-database from 1976 to 2012. *Journal of Arid Environments* 123: 3-11.
- van Vuuren, DP, Edmonds J, Kainuma M, Riahi K, Thomson A, Hibbard K, Hurtt GC, Kram T, Krey V & Lamarque JF. 2011. The representative concentration pathways: an overview. *Climatic Change* 109: 5.
- Van Wart J, Grassini P, Cassman KG, 2013. Impact of derived global weather data on simulated crop yields. *Global Change Biology* 19: 3822–3834.
- Villarino SH, Studdert GA, Baldassini P, Cendoya MG, Ciuffoli L, Mastrángelo M & Piñeiro G. 2017. Deforestation impacts on soil organic carbon stocks in the Semiarid Chaco Region, Argentina. *Science of the total environment* 575: 1056-1065.
- Wallach, D, Makowski D, Jones JW & Brun, F. 2014. Chapter 9 - Model Evaluation. In: D. Wallach, D. Makowski, J.W. Jones & F. Brun (Eds.). *Working with Dynamic Crop Models (Second Edition)* (pp. 345-406). San Diego: Academic Press.
- Wegerer R, Popp M, Hu X & Purcell L. 2015. Soybean maturity group selection: Irrigation and nitrogen fixation effects on returns. *Field Crops Research*: 180, 1–9.
- White JW, Hoogenboom G, Wilkens PW, Stackhouse PW & Hoel JM. 2011. Evaluation of satellite-based: modeled-derived daily solar radiation data for the continental United States. *Agronomy Journal* 103: 1242–1251.

- Wilhelm WW, Wortmann CS. 2004. Tillage and rotation interactions for corn and soybean grain yield as affected by precipitation and air temperature. *Agronomy Journal* 96: 425–432.
- Willmott CJ, Ackleson SG, Davis RE, Feddema JJ, Klink KM, Legates DR, O'Donnell J & Rowe CM. 1985. Statistics for the evaluation and comparison of models. *Journal of Geophysical Research Oceans* 90: 8995-9005.
- Wright IA, Tarawali S, Blümmel M, Gerard B, Teufel N & Herrero M. 2012. Integrating crops and livestock in subtropical agricultural systems. *Journal of the Science of Food and Agriculture* 92: 1010-1015.
- Yamoah CF, Varvel GE, Francis CA & Waltman WJ. 1998. Weather and management impact on crop yield in rotations. *Journal of Production Agriculture* 11:219–225.
- Yang, X., Lin, E., Ma, S., Ju, H., Guo, L., Xiong, W., ... & Xu, Y. 2007. Adaptation of agriculture to warming in Northeast China. *Climatic Change* 84: 45-58.
- Zhang X, Zhou B, Gao Z, Liu Y, Wang S Li S & Zhang Y. 2010. Effect of different proportion of N, P and K on agronomic traits and yield of continuous planting soybean in white paste soil. *Soybean Science* 29: 659-662.
- Zhao C, Liu B, Piao S, Wang X, Lobell DB, Huang Y, Huang M, Yao Y, Bassu S & Ciais P. 2017. Temperature increase reduces global yields of major crops in four independent estimates. *Proceedings of the National Academy of Sciences of the U.S.A* 114: 9326-9331.
- Zuur AF, Ieno EN & Elphick CS, 2010. A protocol for data exploration to avoid common statistical problems. *Methods Ecology Evolution* 1: 3–14.

