

Productividad de los suelos pampeanos para el cultivo de trigo

Soil productivity of the Pampas related to wheat

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

*Thesis submitted in partial fulfillment for the title of Doctor in Sciences/Biology at the
University of Antwerp*

Josefina Luisa De Paepe

(M. Sc. in Biology, University of Antwerp, Belgium – 2007)

Lugar de trabajo: Cátedra de Fertilidad y Fertilizantes
Facultad de Agronomía – Universidad de Buenos Aires



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



University of Antwerp
Faculty of Sciences
Department of Biology

Buenos Aires, Argentina – 2015

COMITÉ CONSEJERO

Director de tesis

Roberto Álvarez

Ingeniero Agrónomo (Universidad de Buenos Aires)

Co-director

Reinhart Ceulemans

Biology (Universidad de Amberes - Bélgica)

Doctor en Ciencias Naturales (University of Antwerp - Bélgica)

Consejero de Estudios

José María Paruelo

Ingeniero Agrónomo (Universidad de Buenos Aires)

Doctor en Ciencias Naturales (Colorado State University - USA)

JURADO DE TESIS

Director de tesis

Roberto Álvarez

Ingeniero Agrónomo (Universidad de Buenos Aires)

JURADO

Daniel E. Buschiazzo

Ingeniero Agrónomo (Universidad Nacional del Sur)

Magister en Ciencias del Suelo (Universidad Nacional del Sur)

Doctor en Ciencias Agrarias (Universidad Hohenheim – Alemania)

JURADO

Octavio P. Caviglia

Ingeniero Agrónomo (Universidad Nacional de Entre Ríos)

Doctor en Ciencias Agrarias (Universidad Nacional de Mar del Plata)

JURADO

Alberto R. Quiroga

Ingeniero Agrónomo (Universidad Nacional del Litoral)

Magister en Ciencias Agrarias (Universidad Nacional del Sur)

Doctor en Agronomía (Universidad Nacional del Sur)

“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”.

AGRADECIMIENTOS – ACKNOWLEDGMENTS

A Roberto por tu paciencia, para definir juntos el proyecto y discutir los resultados que iban surgiendo sobre la marcha, y tu impaciencia por seguir adelante siempre. Por tus carcajadas durante los momentos más nerviosos y tu apoyo positivo cuando sentía que todo estaba trabado. A Haydeé, que junto con Roberto son mi grupo de trabajo, porque compartir la oficina con vos fue lo mejor. Gracias por tu interés, tu curiosidad y por tus preguntas y porque siempre lograste sacar lo mejor de mis nervios.

A special Thank You goes to Prof. Reinhart Ceulemans for your support during this interesting research process. Thanks to you I was shipped in this Joint Ph.D. adventure and I now realize that it is an opportunity for me to keep on working with you and other PLECO-members. Those seven months at Antwerp were most precious to me not only because of what I learned through the interaction with researchers and other Ph.D. students but because when I'm back in Antwerp I feel a little bit as at home.

Mama en papa, om jullie te kunnen bedanken ga ik altijd woorden te kort hebben! Eén van de vele dingen die ik van jullie geleerd heb is dat je moet doen wat je gelukkig maakt en die vrijheid is het beste wat je als dochter kan krijgen. Tali en Javier, gracias por la buena onda de siempre, jullie zijn écht schatjes! Jullie zijn altijd zo geduldig geweest en al de dingen die we samen gedaan hebben al deze laatste jaren hebben deze periode onvergetelijk gemaakt. Love you all forever!

A Pablit, mi compañero de ruta, que estuviste presente en la etapa más difícil de esta tesis y me salvaste de explotar de cansancio. No me puedo imaginar una vida sin vos porque cada día a tu lado es un sueño irrepitible. Gracias por todo y por tanto.

A mis amigos gracias por el aguante en cada momento, haber compartido estos años con ustedes fue una de las mejores cosas que me pasó. Gracias por cada momento, por las vacaciones, por las escapadas, por los mates, por los bailes y por todo lo que compartimos estos últimos años. Los quiero tanto!

*White is poison to a picture: use it only in highlights.
Peter Paul Rubens*

TRABAJOS PUBLICADOS DERIVADOS DE LA TESIS

En revistas científicas

1. **J.L. De Paepe** y R. Alvarez. 2013. Development of a soil productivity index using an artificial neural network approach. *Agron. J.* 105: 1803-1813.
2. G. Berhongaray, R. Alvarez, **J.L. De Paepe**, C. Caride y R. Cantet. 2013. Land use effects on soil carbon in the Argentine Pampas. *Geoderma* 192: 97-110.
3. R. Alvarez, H. Steinbach y **J.L. De Paepe**. 2014. A regional audit of nitrogen fluxes in pampean agroecosystems. *Agric. Ecosys. Environ.* 184: 1-8.

En capítulos de libros

1. A. Bono, **J.L. De Paepe**, R. Alvarez. 2011. In-season wheat yield prediction in the Semiarid Pampa of Argentina using artificial neural networks. *Progress in Food Science and Technology*. Vol. 1. Pág. 133-149. Ed. A.J. Greco, Nova Science Publishers, Inc.
2. R. Alvarez, **J.L. De Paepe**. 2011. Establishing productivity indices for wheat in the Argentine Pampas by an artificial neural network approach. *Focus on Artificial Neural Networks*. Pág. 75-95. Ed. John A. Flores, de Nova Science Publishers, Inc.
3. R. Alvarez, **J. L. De Paepe**, H. S. Steinbach, G. Berhongaray, M. M. Mendoza, A. A. Bono, N. F. Romano, R. J. C. Cantet y C. R. Alvarez. 2014. Land use effects on soil carbon and nitrogen stocks and fluxes in the Pampas: Impact on productivity. *Soil carbon. Types, management practices, and environmental benefits*. Vol. 1. Pág. 51-90, Ed. A. Margit. Nova Science Publishers Inc.
4. R. Álvarez, **J. L. De Paepe**, H. Steinbach, P. Fernández y C. Álvarez. 2014. Cambios en los niveles de carbono y nitrógeno de los suelos pampeanos producidos por el uso. En *Suelos, producción Agropecuaria y Cambio Climático: avances en la Argentina*. Eje temático 2: El suelo, la producción agropecuaria y las emisiones de gases de efecto invernadero (GEI). Pág. 91-108. Ministerio de Agricultura Ganadería y Pesca.
- 5.

Premio

Premio de la Fundación Pérez Compañc-versión 2012 otorgado por la Academia de Agronomía y Veterinaria sobre: “Consecuencias del manejo agropecuario sobre la sustentabilidad y/o la provisión de servicios ecosistémicos”. Título del trabajo presentado: *Productividad, fertilidad y secuestro de carbono en suelos pampeanos: efecto del uso agrícola*. R. Álvarez, G. Berhongaray, **J.L. De Paepe**, M. R. Mendoza, H. Steinbach, C. Caride y R. Cantet. Publicado como:

R. Alvarez, G. Berhongaray, **J.L. De Paepe**, M. Mendoza, H.S. Steinbach, C. Caride y R. Cantet. 2012. Productividad, fertilidad y secuestro de carbono en suelos pampeanos: efecto del uso agrícola. *Anales de la Academia Nacional de Agronomía y Veterinaria* 46: 381-426.

ÍNDICE GENERAL

ÍNDICE GENERAL	vi
ÍNDICE DE CUADROS.....	ix
ÍNDICE DE FIGURAS.....	x
ABREVIATURAS.....	xiv
RESUMEN	xv
ABSTRACT	xvi
EXTENDED ABSTRACT.....	xvii
ABSTRACT in Flemish / Nederlandse samenvatting	xix
CAPITULO 1. Introducción general.....	21
1.1. Productividad de suelos	21
1.2. La Región Pampeana y el cultivo de trigo.....	22
1.2.1. Factores climáticos que influyen el rendimiento de trigo.....	24
1.2.2. Factores edáficos que influyen el rendimiento de trigo.....	25
1.2.3. Factores de manejo que influyen el rendimiento de trigo.....	26
1.3. Modelización empírica del rendimiento de trigo	27
1.4. Brecha de rendimiento y productividad.....	28
1.5. Objetivo general de la tesis	30
1.6. Estructura de la tesis.....	30
CAPITULO 2. Generación de la base de datos	32
2.1. Introducción.....	32
2.1.1. Área de estudio.....	32
2.1.2. Escalas de análisis	32
2.2. Escala de análisis regional - Partido.....	34
2.2.1. Clima.....	34
2.2.2. Suelo	36
2.2.3. Manejo	45
2.2.4. Rendimiento	48
2.3. Escala de análisis regional - Unidad geográfica	52
2.4. Escala de análisis sitio.....	55
2.4.1. Información de ensayos experimentales.....	55
2.4.2. Información de experimentos de la red INASE para validación de EPIC.....	57
2.5. Consideraciones finales.....	57
CAPITULO 3. Modelización del rendimiento de trigo	60
3.1. Introducción.....	60

3.1.1. Interacción entre variables biofísicas	60
3.1.2. Métodos de modelización empírica.....	63
3.2. Objetivo.....	65
3.3. Hipótesis.....	65
3.4. Materiales y métodos	66
3.5. Resultados	69
3.6. Discusión.....	78
3.7. Consideraciones finales.....	80
CAPITULO 4. Productividad de los suelos pampeanos.....	83
4.1. Introducción.....	83
4.1.1. Índices de productividad inductivos.....	83
4.1.2. Índices de productividad deductivos	85
4.2. Objetivos	86
4.3. Materiales y métodos	86
4.3.1. Índices inductivos de productividad de suelos.....	86
4.3.2. Índices deductivos de productividad de suelos.....	89
4.4. Resultados	89
4.5. Discusión.....	94
4.6. Consideraciones finales.....	96
CAPITULO 5. Brecha de rendimiento y productividad	97
5.1. Introducción.....	97
5.1.1. Modelos de simulación.....	99
5.1.2. Función de frontera estocástica.....	100
5.1.3. Generación de la hipótesis	104
5.2. Objetivo.....	104
5.3. Hipótesis.....	104
5.4. Materiales y métodos	104
5.4.1. Modelo de simulación- EPIC.....	104
5.4.2. Función de frontera estocástica.....	109
5.4.3. Estimación de la brecha de rendimiento-productividad	110
5.5. Resultados	110
5.5.1. Modelo de simulación - EPIC.....	110
5.5.2. Función de frontera estocástica.....	111
5.6. Discusión.....	121
5.7. Consideraciones finales	125
CAPITULO 6. Discusión general.....	127

6.1. Contexto de la problemática abordada	127
6.2. Alcances y limitaciones de los resultados de la tesis	127

ÍNDICE DE CUADROS

Cuadro 2.1. Rango y promedio de variables climáticas agregadas a escala partido de la Región Pampeana para el período 1967-2006.....	35
Cuadro 2.2. Promedio, desvío estándar y rango de variables edáficas estimadas por partido de la Región Pampeana para el período 1967/1968-2006/2007 hasta una profundidad de 0-100 cm o hasta el límite superior de la capa petrocálcica en caso de presentarse.....	41
Cuadro 2.3. Sistemas de labranza predominantes por década analizada en esta tesis y por sub-región pampeana. La información está basada en la comunicación personal con expertos y se presenta en forma de porcentaje.	47
Cuadro 2.4. Coeficientes de correlación de Pearson entre el rendimiento de trigo, campaña y las variables de manejo integradas a nivel partido (P = 0,05).	48
Cuadro 2.5. Coeficientes de correlación de Pearson de las variables de clima y suelo por unidad geográfica. Cuando la probabilidad no fue significativa se usó la abreviatura “ns” (P = 0,05).	54
Cuadro 2.6. Rango y promedio de algunas de las características de suelo, clima y manejo medidas en los ensayos experimentales realizados en la Pampa Ondulada y la Región Semiárida Pampeana.....	56
Cuadro 3.1. Modelo de regresión polinómica ($R^2 = 0,528$, P = 0,05). Se indican los términos lineales, cuadráticos e interacciones seleccionados por su significancia estadística ($p < 0,01$).....	71
Cuadro 5.1. Precipitación por campaña y datos de suelo de los ensayos experimentales de las cinco localidades utilizadas para la validación del modelo EPIC.	106
Cuadro 5.2. Datos de manejo de los ensayos experimentales de las cinco localidades utilizadas para la validación del modelo EPIC.....	107
Cuadro 5.3. Función de frontera estocástica para la estimación del rendimiento alcanzado de trigo por unidad geográfica y para las 40 campañas (período 1967-2006) analizadas. Se agregan además el error estándar, los valores de z y P correspondientes cuyo significado se detallan en el texto.	112

ÍNDICE DE FIGURAS

Figura 1.1. Sub-regiones pampeanas: 1) Pampa Mesopotámica, 2) Pampa Ondulada, 3) Pampa Arenosa, 4) Región Semiárida Pampeana, 5) Pampa Austral y 6) Pampa Deprimida. Adaptado de Hall et al. (1992) y Viglizzo et al. (2004) y los contornos se ajustaron a los límites políticos de los partidos. Isohietas e isotermas anuales fueron estimadas con datos climáticos interpolados de 1967-2006.....	23
Figura 2.1. Guía de lectura de la escala de análisis de la base de datos elaborada para la tesis y descripta en este capítulo.....	33
Figura 2.2. Distribución geográfica de las estaciones meteorológicas de INTA y del Servicio Meteorológico Nacional en la Región Pampeana y zonas circundantes para un año determinado.....	34
Figura 2.3.A. Distribución espacial por partido del índice climático precipitación/evapotranspiración promedio ponderado y B. el coeficiente fototérmico promedio ambos para el período 1967-2006.....	36
Figura 2.4. Mapa de suelos de INTA correspondiente a una parte del partido Marcos Juárez de la Provincia de Córdoba y las unidades cartográficas que la componen. Se indica la unidad cartográfica MJen-5 que es explicada en el texto.	37
Figura 2.5.A. Representación gráfica de información presentada en tablas de los valores de las variables de suelo publicados en los mapas de suelo de INTA y un modelo curvilíneo ajustado. B. Datos estimados por estrato de 25 cm hasta el primer metro de profundidad de suelo a través del modelo de estimación en profundidad. C. Estimación de los contenidos de la variable edáfica con la densidad aparente estimada con las ecuaciones de pedotransferencia de Rawls (1983).	39
Figura 2.6. A. Distribución geográfica del pH promedio y B. el contenido carbono de carbonatos ($t\ ha^{-1}$) promedio por partido estimado hasta el metro de profundidad del perfil del suelo o hasta el límite superior de la capa petrocálcica.	42
Figura 2.7.A. Distribución geográfica del contenido de arcilla + limo promedio y B. la CAAU (capacidad de almacenamiento de agua útil) estimada a través de las funciones de pedotransferencia de Rawls et al. (1982) hasta un metro de profundidad o hasta el límite superior de la capa petrocálcica.	43
Figura 2.8.A. Relación entre el contenido de carbono orgánico y la capacidad de almacenamiento de agua útil para el gradiente regional pampeano abarcado. B. Relación entre el contenido de arena hasta el primer metro de profundidad y la capacidad de almacenamiento de agua útil correspondiente a la misma profundidad.	44
Figura 2.9. A. Distribución geográfica del contenido de carbono orgánico por partido hasta un metro de profundidad basado en los datos publicados de los mapas de suelo de INTA y B. el contenido por partido estimado como por Berhongaray et al. (2013).....	45
Figura 2.10. Evolución en el tiempo del rendimiento de trigo por partido de la Región Pampeana desde la campaña 1967 hasta 2006.	50
Figura 2.11.A. Distribución geográfica del rendimiento alcanzado por partido durante la primera campaña (1967) y B. la última campaña (2006).	51

- Figura 2.12.A.** La evolución promedio por campaña en el tiempo de la producción total de trigo (Mt) desde 1967 hasta 2006. **B.** Evolución en el tiempo de la superficie sembrada (Mha) promedio por campaña para todo el período analizado. 51
- Figura 2.13.** Distribución de las 41 unidades geográficas. El color gris claro denota una situación climática semiárida y el color gris oscuro representa la porción más húmeda pampeana. La división se realizó utilizando la isohieta anual histórica de 800 mm. 52
- Figura 3.1.** Curvas de respuesta hipotéticas que muestran la relación entre el rendimiento de un cultivo y el aumento de la variable de suelo 1 cuando se incrementa la variable de suelo 2. Las diferencias entre las pendientes expresan la interacción entre las variables de suelo. 62
- Figura 3.2.** Representación de la estructura del árbol de regresión. n = número de datos en grupo, \bar{x} = promedio de la variable explicativa, A = segunda variable regresora, B = tercera variable regresora, ambas utilizadas para particionar la población en sub-sets homogéneos. 64
- Figura 3.3.** Representación de una red neuronal artificial mostrando capas de neuronas de entrada, escondida y salida, y las conexiones entre las mismas. Adaptado de Álvarez (2009). 65
- Figura 3.4. A.** Estimación del rendimiento de la última década utilizando el promedio del rendimiento alcanzado durante las tres décadas previas. **B.** R^2 de la regresión lineal entre el rendimiento alcanzado promedio de la última década y el promedio del rendimiento alcanzado en 1, 2, 3, 5, 7 y 10 campañas elegidas al azar. 70
- Figura 3.5. A. B. C. D. E.** Efecto de variables independientes sobre el rendimiento estimado con la regresión polinómica seleccionada. **F.** Presenta el impacto directo de variables independientes como la diferencia entre el rendimiento estimado para el valor máximo menos el mínimo. 72
- Figura 3.6.** Modelo explicativo de rendimiento desarrollado con un árbol de regresión ($R^2 = 0,609$. $P = 0,05$). Cada nodo contiene: número de observaciones, el rendimiento promedio estimado y el error estimado. 73
- Figura 3.7.** Modelo de estimación del rendimiento de trigo regional basado en la metodología de RNA ($R^2 = 0,614$; $P = 0,05$). 74
- Figura 3.8.** Performance de la metodología de la regresión polinómica (A. y B.), árboles de regresión (C. y D.) y redes neuronales (E. y F.). *Training set* (75 % los datos, $n = 1230$) y *test set* (correspondiente al 25 % de los datos, $n = 410$). 75
- Figura 3.9.** Rendimiento de trigo estimado por una red neuronal artificial (RNA) para dos escenarios de capacidad de almacenamiento de agua útil (CAAU) contrastantes bajo el gradiente climático promedio de la Región Pampeana. 76
- Figura 3.10.** Relación entre la capacidad de almacenamiento de agua útil (CAAU) y el rendimiento estimado por la RNA bajo dos escenarios de CO (carbono orgánico) contrastantes. 77
- Figura 3.11.** Relación entre el rendimiento estimado con una red neuronal artificial (RNA) vs. el rendimiento observado correspondiente a datos de ensayos experimentales distribuidos en la Pampa Ondulada (círculos llenos) y la Región Semiárida Pampeana (círculos vacíos). 77

- Figura 4.1.A.** Distribución espacial del índice de productividad de suelos basado en la metodología propuesta por la FAO (Riquier et al., 1970) por unidad geográfica y **B.** muestra su relación con el rendimiento promedio del período 1967-2006. 90
- Figura 4.2. A.** Relación entre el índice de productividad de suelo inductivo Kiniry-Pierce y **B.** su versión adaptada con la inclusión de una suficiencia para materia orgánica vs. el rendimiento promedio de trigo por unidad geográfica. 91
- Figura 4.3.A.** Distribución espacial del índice de productividad deductivo promedio estimado con una RNA y **B.** representa la relación del índice deductivo con el rendimiento promedio durante 1967-2006. 92
- Figura 4.4.** Relación entre las variables independientes de suelo y clima del modelo de RNA vs. el índice de productividad de suelos de la FAO. 93
- Figura 4.5.** Interacción entre el contenido de carbono orgánico de suelo y capacidad de almacenamiento de agua útil (CAAU) que conforman el índice de productividad estimado por el modelo de RNA. 94
- Figura 5.1.** Función de frontera estocástica (FFE) (Coelli et al., 2005). Los valores de producción observados (x) y frontera (○) se encuentran indicados. La FFE está basada en los valores observados más altos alcanzados bajo la variable independiente tomando en cuenta el efecto del error estadístico (ν_i). Desviaciones de los valores observados con respecto a esta frontera son causadas por efecto de la ineficiencia técnica (μ_i). La producción frontera q_i puede ubicarse por encima o por debajo de la FFE dependiente del efecto de error estadístico (ν_i). 103
- Figura 5.2.** Validación modelo de simulación EPIC con datos de ensayos experimentales ubicados en cinco localidades distribuidas en la Región Pampeana. .. 111
- Figura 5.3.** Relación entre la CAAU (capacidad de almacenamiento de agua útil) A., el coeficiente fototérmico B., el índice climático de PPT/ETP durante el barbecho C. y durante la fase vegetativa D. vs. el rendimiento máximo alcanzado o FFE. 113
- Figura 5.4. A.** Relación entre el rendimiento máximo alcanzado o rendimiento FFE y el rendimiento observado. **B.** Rendimiento observado, estimado con una red neuronal artificial (RNA) y por la función de frontera estocástica (FFE) vs. las campañas. 114
- Figura 5.5.** Relación entre el rendimiento observado y el estimado por la función de frontera estocástica (FFE) para las sub-regiones pampeanas: A. Pampa Mesopotámica, B. Pampa Ondulada, C. Pampa Arenosa, D. Región Semiárida Pampeana y E. Pampa Austral. 115
- Figura 5.6.A.** Relación entre el rendimiento máximo alcanzado estimado con una función de frontera estocástica (FFE) y **B.** la brecha de productividad vs. el índice de productividad desarrollado con una red neuronal artificial (RNA). 116
- Figura 5.7.** Relación entre la RMSE (*root mean square error*) del la brecha de rendimiento en función de los valores del índice de productividad que fueron subdivididos en rangos. 117
- Figura 5.8. A.** Rendimiento alcanzado promedio por unidad geográfica para el período 1967-2006 estimado con una función de frontera estocástica. **B.** Brecha de productividad estimada como la diferencia promedio entre el rendimiento máximo

alcanzado estimado por una FFE y el rendimiento promedio estimado por una red neuronal artificial.....	118
Figura 5.9. Ajuste del modelo regional generado con una red neuronal artificial (RNA) para la estimación de la brecha de rendimiento para los dos sets de datos independientes A. <i>training</i> y B. <i>validation</i>	119
Figura 5.10. Relación entre la brecha de rendimiento estimada con una RNA regional y la precipitación del barbecho y el ciclo del cultivo.	120
Figura 5.11. Relación entre las variables edáficas carbono orgánico y la CAAU de los suelos pampeanos, para un escenario climático promedio, con respecto a la brecha de productividad.....	121

ABREVIATURAS

Sigla/Abreviatura	Significado
CAAU	Capacidad de almacenamiento de agua útil
ETP	Evapotranspiración potencial del cultivo
RNA	Red neuronal artificial
RMSE	<i>Root mean square error</i>
FFE	Función de frontera estocástica
C	Labranza convencional
SD	Siembra directa.
PDA	Fosfato diamónico
UAN	Urea más nitrato de amonio
NPS	Fertilizante con nitrógeno, fósforo y azufre.

RESUMEN

PRODUCTIVIDAD DEL AGROECOSISTEMA PAMPEANO PARA EL CULTIVO DE TRIGO

La productividad de los suelos determina su capacidad de producir biomasa y es importante entenderla y cuantificarla ya que regula el rendimiento. El objetivo general fue determinar la productividad de los suelos con respecto al cultivo de trigo ya que su distribución espacio-temporal ubicua permite analizar los amplios gradientes biofísicos pampeanos. La información de rendimiento de trigo de 165 partidos, correspondiente al período 1967-2006, fue asociada a variables biofísicas y de manejo que tuvieron que ser agregadas espacialmente a este nivel de análisis. Se generaron 1440 mapas climáticos de interpolación y se modelizaron en profundidad 7 variables de 1000 perfiles de suelo. La información se modelizó por diferentes estrategias. El mejor modelo explicativo del rendimiento se obtuvo usando una red neuronal artificial (RNA) ($R^2 = 0,641$; $P = 0,05$) que permitió establecer que el carbono orgánico y la capacidad de almacenamiento de agua útil de los suelos y su interacción regulan el rendimiento alcanzando un óptimo en los niveles medios-altos de ambas variables. También se utilizó esta RNA como herramienta para generar un índice de productividad de suelos que mostró una performance muy superior ($R^2 = 0,728$; $P = 0,05$) a la metodología de la FAO usada en Argentina hasta el momento ($R^2 = 0,433$; $P = 0,05$). Con una función de frontera estocástica se estimó el rendimiento máximo alcanzado en diferentes áreas de la Región Pampeana. Adicionalmente se calculó la brecha de rendimiento que caracteriza espacialmente áreas productivas con respecto a valores medios de potencial de producción. Esta brecha está determinada por las dos mismas variables edáficas que definen la productividad con un mínimo cercano a la combinación donde se registra la máxima productividad. La brecha de productividad fue mayor en la Región Semiárida Pampeana y la Pampa Mesopotámica por lo que los esfuerzos para achicarla deberían concentrarse allí.

Palabras clave: Redes neuronales artificiales, índices de productividad, brecha de productividad, capacidad de almacenamiento de agua útil, análisis regional.

ABSTRACT
PAMPEAN AGROECOSYSTEM PRODUCTIVITY
RELATED TO WHEAT

Soil productivity determines soil ability to produce biomass and its understanding and quantification is important as it regulates yield. The overall objective was to determine soil productivity related to wheat yield as the significant spatio-temporal distribution of this crop allows analyzing the broad biophysical gradients of the Pampean Region. Wheat yield data from 165 counties for the 1967-2006 period was used and related to climate, soil, and management information that had to be spatially aggregated to this scale of analysis. 1440 climate interpolation maps were generated and 7 variables of 1000 soil profiles were modeled up to one meter depth. The best regional yield model was obtained with an artificial neural network (ANN) ($R^2 = 0.614$; $P = 0.05$) that established that soil organic carbon and soil water holding capacity had the largest effect on yield. The model detected that these variables positively interact reaching an optimum at their intermediate levels. This ANN was used as a tool to generate a productivity index that had a greater performance ($R^2 = 0.728$; $P = 0.05$) compared to the FAO index that is currently used in Argentina ($R^2 = 0.433$; $P = 0.05$). With a stochastic frontier function maximum attained yield was estimated for different areas of the Pampean Region. Additionally, yield gap was calculated to spatially characterize productive areas with intermediate values of their production potential. This gap was determined by the same soil variables that define productivity obtaining a minimum value that results from the combination were maximum productivity was registered. The largest productivity gap was obtained in the Semiarid Pampas and Mesopotamic Pampas, and it is in both these areas that the efforts to reduce is should be focused.

Key words: Artificial neural networks, productivity indices, productivity gap, soil water holding capacity, regional analysis.

EXTENDED ABSTRACT

Soil productivity determines soil ability to produce biomass, and its understanding and quantification are important as soil productivity determines yield. Regional soil productivity characterization can be performed through soil productivity indices that provide information regarding the expected yield under different production and conservation scenarios. Zoning assists farmers in the ranking of areas in relation to soil productivity as it is expected that in areas where soil productivity indices are large, crop yield will also be high. This type of regional appraisal is also relevant for the determination of state taxes.

Agroecosystems, for which reliable information is available, constitute an ideal case for the analysis of the biophysical factors that determine productivity at various scales. The Argentine Pampas covers an area of ca. 50 Mha and comprises a flat, or slightly rolling, tree-less region naturally dominated by grasslands. The Pampean climate is sub-humid temperate and the well drained soils are mainly Mollisols. These factors make this cropping region of major interest within the context of the world food security. The combination of a temperate climate with a rainfall gradient between 500 mm and 1200 mm, and the fertile soils made only fertilization necessary and a common practice since 1980. Wheat, corn, sunflower, and soybean are the principal crops and the last mentioned one has spatially expanded over the last 15 years. Wheat has been produced in the Pampas for over the last 100 years and it covers the entire spatial scale including the coldest and warmest sub-regions and soils that have large sand and clay contents. The overall objective of this thesis was to determine soil productivity in relation to wheat yield comprising the interesting spatio-temporal Pampean gradients of climate, soil, and management variables.

Wheat yield data from national statistics are available at county scale, implying that all climate, soil and management variables had to be aggregated to this spatial level of analysis to make information compatible. Yield information of 165 counties for the 1967-2006 period was used. Climate information measured at approx. 80 meteorological stations was spatially aggregated using the inverse distance weighting method and generating 1140 climate interpolation maps. The used climate variables included temperature, rainfall, potential evapotranspiration, a.o. Published soil survey information was used to model 7000 soil profiles in layers of 25 cm and up to a depth of 1 m or to the upper layer of the petrocalcic layer if present. Modeled soil information was transformed to the cartographic scale and afterwards aggregated up to the county scale accounting for influence areas. Soil water holding capacity (SWHC), organic carbon, texture, depth, pH, and others were used as soil variables. Management information included genetic improvement, predominant tillage systems, fertilization rate, etc. resulting from inquiries with farmers and from national research agencies. The Pampas Region was divided in 41 geographic units, each with an area of 1 ± 0.5 Mha and comprising up to three counties on average, to harmonize the large areal differences.

More than 61 % of the variation in annual regional yield was explained using an artificial neural network (ANN) that included climate and soil variables along with time as explicative variables ($R^2 = 0.614$; $P = 0.05$). Other empirical statistical methods compared included polynomial regression and regression trees. The ANN model selected soil organic carbon and SWHC as significant soil variables because of their major effect on yield. Both these variables interact positively reaching a yield optimum at their mean levels. This regional model was used as a tool to generate a highly performant productivity index ($R^2 = 0.728$; $P = 0.05$). The highest productivity indices were obtained in the Rolling and in the Southern Pampas that matched the largest observed yields.

Maximum attained yield per year was estimated using a stochastic frontier production function (SFPP) ($R^2 = 0.453$; $P = 0.05$) that included climate, soil, and management factors. This function estimates maximum yield per year that can be achieved for a combination of inputs. The regional yield gap was estimated as the difference between SFPP minus yield estimated by the ANN regional model. The ANN yield was used as the average yield per year and per geographic unit instead of the observed yield available from national statistics because this information had a lower annual dispersion. The regional productivity gap enabled describing areas according to this characteristic and was calculated as the average yield gap of the 40 analyzed years. This gap was calculated as the average yield gap per geographic unit and was defined by the same soil variables as the average yield ($R^2 = 0.74$; $P = 0.05$). Major productivity gaps were obtained in the Semiarid Pampas and in the Mesopotamic Pampas that comprise the driest and the most humid Pampean sub-regions, respectively. The results related to the productivity gap implied that future research should aimed to decrease the productivity gap should focus on these two sub-regions.

Key words: Artificial neural networks, productivity indices, productivity gap, soil water holding capacity, regional analysis.

ABSTRACT in Flemish / Nederlandse samenvatting

Bodemproductiviteit bepaalt de potentiële biomassa-productie, en de kwantificering ervan is belangrijk omdat het de opbrengst van gewassen bepaalt. Deze kwantificering wordt gerealiseerd door het gebruik van indices die de verwachte opbrengst kunnen anticiperen over verschillende productiviteits- en duurzaamheidsscenario's. De algemene doelstelling van deze thesis was om de productiviteit van de bodem met betrekking tot de tarweopbrengst te bepalen. Dit gewas wordt nu al meer dan 100 jaar in de Pampas regio geproduceerd over een oppervlakte van ca. 50 Mha met een interessante spatiale en temporale verdeling voor de analyse van klimaat- en bodemgradiënten. Gegevens m.b.t. de tarweopbrengst waren beschikbaar per county in de Pampas voor de periode 1967-2006 periode terwijl gegevens m.b.t. klimaat, bodem en beheer geaggregeerd werden naar deze spatiale eenheid. Er werden 1140 klimaatinterpolatiekaarten geproduceerd, en 7000 bodemprofielen werden geschat door middel van potentiële en exponentiële functies.

Bijna 62 % van de variabiliteit in de jaarlijkse opbrengst werd verklaard met een artificieel neuraal netwerk (ANN) model ($R^2 = 0.614$, $p = 0.05$). Dit ANN-model werd gebruikt als instrument om een bodemproductiviteitsindex te berekenen ($R^2 = 0.728$, $p = 0.05$) die rekening hield met bodem- en klimaatgegevens. Het gehalte aan organische koolstof en het waterhoudend vermogen van de bodem interageerden positief met elkaar. De productiviteits'gap' (of yield gap) werd bepaald als het verschil tussen de maximaal bereikte opbrengst geschat door een stochastische 'frontier production' functie ($R^2 = 0.453$; $p = 0.05$) minus de opbrengt geschat door de ANN. Een ander ANN-model toonde aan dat dat de regionale productiviteits'gap' door de zelfde bodemvariabelen bepaald werd ($R^2 = 0.74$; $p = 0.05$). De grootste productiviteits'gaps' werden vastgesteld in de semi-ariëde Pampas. Dit impliceert dat inspanningen om deze 'gaps' te verkleinen op deze gebieden moeten focussen.

CAPITULO 1

INTRODUCCIÓN GENERAL

CAPITULO 1. Introducción general

1.1. Productividad de suelos

Se define la productividad del suelo como la capacidad del mismo de producir biomasa vegetal o semilla de cosecha (Yang et al., 2003). La productividad del agroecosistema es un concepto más abarcativo ya que incluye además la influencia del clima (Lavado y Steinbach, 2012). Es importante entender y cuantificar la productividad ya que regula el rendimiento de los cultivos (Sauerborn, 2002). Se puede caracterizar la productividad edáfica a través de índices que representan la capacidad de producir cierta cantidad de producto por hectárea y por año, expresada como porcentaje respecto de la productividad máxima que proporcionaría un suelo ideal en su primer año de cultivo (Huddleston, 1984). Para una escala definida, los factores seleccionados para los índices deben tener un efecto significativo sobre la productividad del suelo (identificado por la relación entre éstos y el rendimiento de cultivos) (Dumanski y Pieri, 2000). El valor del factor debe ser cuantitativo e incluir un rango considerable de tipos y usos de suelo.

El propósito de la evaluación de tierras de una región para usos agrícolas, a través de índices de productividad, es poder predecir su comportamiento para diferentes alternativas de producción, conservación y sistemas de manejo. El resultado permite cuantificar, sistematizar y categorizar los conocimientos del recurso suelo a fin de dar respuesta a requerimientos planteados por productores agrícolas. Esta cuantificación permitiría ordenar el territorio zonificando sus áreas productivas. Con esta información los productores pueden anticipar cuál es el rendimiento esperado de un cultivo determinado para sus lotes de producción. En las regiones donde el índice de productividad obtiene valores altos se esperan rendimientos altos e impuestos estatales mayores ya que la valoración de la productividad también es una información requerida a nivel nacional por agentes oficiales para la determinación de impuestos territoriales.

Los agroecosistemas, para los cuales se dispone de información confiable, constituyen un sistema de estudio ideal para la investigación de los efectos y la interacción de variables biofísicas, es decir de clima y suelo, sobre la productividad regional. La distribución ubicua del cultivo de trigo en la Región Pampeana presenta una oportunidad para definir índices de productividad para un agroecosistema a lo largo del amplio gradiente biofísico pampeano. Es importante destacar que la distribución espacial y temporal del cultivo de trigo en la Región Pampeana es mayor a la de cualquier otro cultivo en la región, exceptuado el caso del incremento de la extensión de la superficie cultivada con soja de las últimas 15 campañas agrícolas (MinAgri, 2014).

Existen índices de productividad inductivos y deductivos (Huddleston, 1984). Los índices inductivos se generan a partir de caracterizaciones de los suelos basadas en hipótesis previas y estas inferencias teóricas no incluyen una validación con datos de rendimiento de cultivos (Huddleston 1984). En la Argentina y en la Región Pampeana, el índice de productividad de suelo aplicado es aquel originalmente desarrollado por la FAO en 1970 (Riquier et al., 1970), aplicado a la información relevada en los mapas de suelo y para el cuál no se ha realizado una validación con datos de rendimiento de cultivos a nivel regional (GeoINTA, 2014). Para 47 sitios distribuidos en seis partidos de la provincia de Entre Ríos y para una campaña (2009/2010) se testeó el índice para trigo (*Triticum aestivum* L.) con malos resultados ($R^2 = 0,052$, $P = 0,05$) (Gvozdenovich et al., 2012). También se realizó una validación con datos de rendimiento de maíz (*Zea Mays* L.) de siete partidos entrerrianos con datos de 11 campañas en este caso con buenos resultados ($R^2 = 0,357$, $P = 0,05$) (Tasi et al., 2010). Estos antecedentes muestran por un lado que el índice de la FAO pareciera mostrar

mejores resultados al validarlo con datos de series temporales más extensas que con datos de campañas específicas. Por otro lado, se sabe que el cultivo de maíz es menos sensible a variaciones en el suelo que trigo (Sadras y Calviño, 2001). Por esto sería interesante validar el índice propuesto por la FAO para trigo y para una serie temporal.

Los índices de productividad deductivos son aquellos basados en modelos empíricos validados directamente con información de rendimiento (Huddleston, 1984). Como ejemplo, se han desarrollado índices deductivos para maíz y soja [*Glycine max* (L.) Merr.] en Illinois, U.S.A. (García-Paredes et al., 2000), para soja en México (Yang et al., 2003) y para sorgo [*Sorghum bicolor* (L.) Moench] en Australia (Potgieter et al., 2005).

En la Región Pampeana, la productividad de los suelos para trigo fue definida recientemente por 10 valores de un índice de productividad deductivo generado con una red neuronal artificial (Alvarez y De Paepe, 2010). El índice definido se encuentra determinado por el contenido de carbono orgánico y la capacidad de almacenamiento de agua útil del suelo (CAAU). El área de estudio fue de aproximadamente 40 Mha, incluye parte de las Provincias de Buenos Aires, La Pampa y Santa Fe, fue dividida en 10 unidades de 4 Mha en promedio, que se caracterizaron por un patrón de precipitación y temperatura similar. A cada unidad le corresponde un valor del índice deductivo. La variabilidad temporal fue de 10 campañas recientes (1995-2004) que incluyen parcialmente los cambios tecnológicos que marcaron la evolución en el rendimiento de las últimas décadas. El set de datos generado fue de 100 valores por lo que no se pudieron evaluar las interacciones entre las variables edáficas. Estas estimaciones no fueron validadas con datos de rendimiento de escalas menores, por ejemplo de ensayos experimentales.

Ante el escenario actual y futuro de incremento exponencial de la población mundial, la seguridad alimentaria dependerá del aumento de la producción de los tres principales cultivos de granos: trigo, arroz (*Oryza sativa* L.) y maíz así como también de cambios en la distribución y acceso de los mismos (Cassman et al., 2010). Cultivado desde tiempos prehistóricos, actualmente el cultivo de trigo es la principal fuente de calorías en más de ochenta países, lo que corresponde a cerca del 30 % de la población mundial (FAOstat, 2014). Durante el Siglo XX, el rendimiento mundial de trigo aumentó en promedio de menos de 1 a 2.5 t ha⁻¹ en las últimas décadas (Cassman et al., 2010). Este incremento fue la característica más notable de la intensificación del sistema de producción agrícola y es atribuido en gran parte a las mejores prácticas de manejo y la implementación de nuevos genotipos (Slafer y Andrade 1989; Cassman, 1999).

Los suelos más fértiles del Mundo deberán responder en las próximas décadas a las fuertes presiones para satisfacer la demanda de alimentos generada por el aumento esperado de la población y de su nivel de consumo (Watson y Zakri, 2005). En primer lugar es importante mejorar el conocimiento de los factores biofísicos que determinan la productividad del suelo para el rendimiento de trigo en áreas de importancia productiva como la Región Pampeana. En segundo lugar la cuantificación del peso de dichos factores podría servir para la generación de índices de productividad regionales que puedan predecir respuestas a escenarios futuros de clima y de manejo. Finalmente, comprender los patrones de variación espacial y temporal de la productividad podría mejorar la comprensión de las causas de la brecha entre el rendimiento alcanzado y el alcanzable.

1.2. La Región Pampeana y el cultivo de trigo

A escala mundial la Región Pampeana es considerada una de las regiones más importantes del Mundo por su producción de cereales y oleaginosas (Satorre y Slafer 1999; Lawlor y Mitchell, 2000). Es una planicie de ca. 55 Mha (Hall et al., 1992), ubicada entre los

28-40 ° sur y 67-57 ° oeste, de la cual en la actualidad más del 60% de la superficie se destina a agricultura (MinAgri 2014). La región se encuentra dividida en las Provincias de Buenos Aires Córdoba, Entre Ríos, La Pampa y Santa Fe y estas Provincias a su vez en partidos para el caso de Buenos Aires y departamentos para el resto. En esta tesis se va a usar el término partido. La superficie sembrada con cultivos anuales y en particular el cultivo de soja se ha expandido rápidamente en la región, con algunas diferencias entre sub-regiones pampeanas, desplazando pasturas y forrajeras (Baldi y Paruelo 2008; Álvarez et al., 2013).

Basado en la geomorfología y el drenaje, la geología, los suelos y la vegetación, se divide a la Región Pampeana en seis sub-regiones (Soriano 1991; Hall et al., 1992): Pampa Mesopotámica, Pampa Ondulada, Pampa Arenosa, Región Semiárida Pampeana, Pampa Austral y Pampa Deprimida (**Figura 1.1.**).

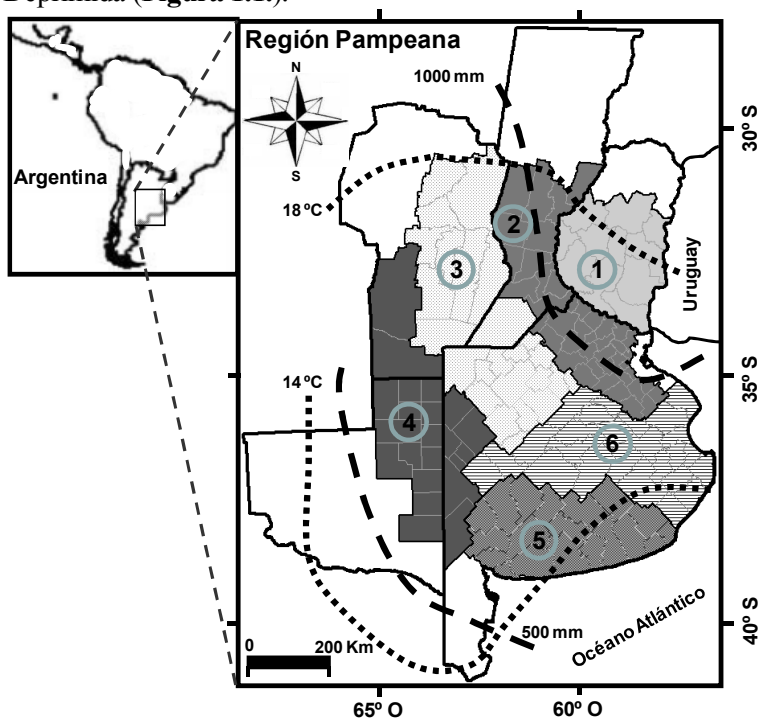


Figura 1.1. Sub-regiones pampeanas: 1) Pampa Mesopotámica, 2) Pampa Ondulada, 3) Pampa Arenosa, 4) Región Semiárida Pampeana, 5) Pampa Austral y 6) Pampa Deprimida. Adaptado de Hall et al. (1992) y Viglizzo et al. (2004) y los contornos se ajustaron a los límites políticos de los partidos. Isohietas e isotermas anuales fueron estimadas con datos climáticos interpolados de 1967-2006.

La Pampa Mesopotámica comprende gran parte de la Provincia de Entre Ríos y se encuentra situada entre los ríos Uruguay y Paraná, presenta un relieve ondulado y una red compleja de ríos y arroyos (Hall et al., 1992). La Pampa Ondulada se caracteriza por tener un relieve levemente ondulado y un buen sistema de drenaje, de tipo exorreico, provisto de una red de valles fluviales tributarios del Río de la Plata y del Río Paraná. La vegetación natural ha sido reemplazada casi en su totalidad por cultivos y la historia agrícola es de más de un siglo (Paruelo et al., 2006). La Pampa Arenosa es un área modelada topográficamente por el viento, no tiene una red fluvial y su paisaje plano se encuentra interrumpido únicamente por dunas de arena fijas y médanos (Ghersa et al., 2002). La Región Semiárida Pampeana se caracteriza por tener un clima sub-húmedo y semiárido (Buschiazzo et al., 1998). La Pampa

Austral es la sub-región situada más al sur de la región, su red fluvial está bien definida y funciona como exorreica y es conocida como la principal región triguera argentina (Viglizzo et al., 2001). La Pampa Deprimida se caracteriza por la presencia de bajos, resultado del relieve plano, suavemente deprimido y de muy baja pendiente, que se pueden ver afectados por inundaciones largas y extensas durante períodos con mucha lluvia (Perelman et al., 2001).

En la actualidad la superficie sembrada con trigo ocupa menos del 20 % de la superficie total, sin embargo la distribución espacial se ha mantenido relativamente estable durante las últimas décadas (MinAgri, 2014; FAOstat, 2014). En promedio se producen 14 Mt por año y el rendimiento promedio durante el período 2006-2010 rondó las 2.5 t ha⁻¹. Se utiliza primeramente para el autoabastecimiento nacional (ca. del 50%) y el restante se exporta a países vecinos (MinAgri 2014). El ciclo de crecimiento del cultivo arranca con la siembra a mediados de junio y termina con la cosecha en noviembre-diciembre (Satorre y Slafer 1999). Hace ca. 100 años cuando el cultivo de trigo empezó a expandirse en la región (Tombetta y Nisi, 2000), el cultivo formaba parte de un sistema mixto de producción agrícola-pastoril, en los cuales se alternaba un período de 4 años de pastura con 6-10 años de agricultura, mientras que ahora el sistema es casi enteramente agrícola, y casi siempre con rotación de cultivos (alternancia en el tiempo, en el mismo predio, de distintos cultivos) (Viglizzo et al., 2001).

Desde la última década, los cultivos económicamente más importantes son trigo, maíz y soja, cultivados en rotaciones que van desde la rotación trigo-soja de segunda-maíz a soja como casi único cultivo, pasando por muchas alternativas intermedias. La fertilización es reciente y se incorporó como práctica común hace unos 15 años debido principalmente a la alta fertilidad natural de los suelos (Hall et al., 1992; Alvarez y Steinbach 2009). El uso de fertilizantes se incrementó casi ocho veces en los últimos 15 años (Álvarez et al., 2013) pero la intensidad de uso sigue siendo menor a la del hemisferio norte (Viglizzo et al., 2001). La evolución en el tiempo del consumo de nutrientes provenientes de fertilizantes muestra que el aumento fue exponencial con muy bajo consumo en la década del 60 alcanzando valores de aproximadamente 0,8 Mt de nitrógeno, 0,2 Mt de fósforo y 0,1 Mt de azufre en el año 2010 (Álvarez et al., 2013).

1.2.1. Factores climáticos que influyen el rendimiento de trigo

Las precipitaciones constituyen la fuente climática de variación y el control climático más importante sobre el rendimiento del cultivo de trigo en la Región Pampeana (Satorre y Slafer, 1999). Eventos de estrés hídrico antes de antesis o floración (octubre-noviembre) pueden limitar el rendimiento de trigo (Travasso et al., 1999). A nivel regional se observaron aumentos en la precipitación anual y especialmente durante los meses de verano probablemente como consecuencia del cambio climático (Viglizzo et al., 1995; Magrin et al., 2005).

La temperatura se asocia negativamente al rendimiento de trigo durante el período de llenado de grano (Stone y Nicolas, 1995). A nivel regional también se detectaron disminuciones en la temperatura máxima y aumentos en la temperatura mínima (Viglizzo et al., 1995; Magrin et al., 2005). Existe una relación positiva entre el rendimiento trigo y el cociente fototérmico (relación entre radiación incidente y temperatura) durante gran parte del período crítico, comprendido en 20 días antes a 10 días después de la floración (período de crecimiento de espiguilla, durante el cual se define el número de granos) que fue demostrada originalmente para Australia y Méjico (Fischer, 1985) y posteriormente también para el rendimiento potencial de trigo en la Región Pampeana (Abbate et al, 1995; Menéndez y Satorre, 2007).

A escala sub-regional, en la Pampa Ondulada, se observó que el estrés hídrico puede restringir la producción de biomasa y en consecuencia el rendimiento de trigo (Brisson et al., 2001). La precipitación y la disponibilidad de nutrientes explican entre 50 y 70% de la variabilidad en el rendimiento en algunas zonas (Alvarez y Grigera 2005). La relación entre el rendimiento y la precipitación es curvilínea alcanzando un óptimo entre 350 y 400 mm durante el ciclo de crecimiento y disminuyendo al superar estos valores (Alvarez y Grigera 2005). En la Pampa Austral, en suelos con alto contenido de materia orgánica, el déficit de agua durante el período crítico, y la temperatura durante el llenado de grano, explican la mitad de la variabilidad del rendimiento (Calviño y Sadras 2002).

Para la Región Pampeana, bajo condiciones de producción y usando datos a escala partido, la variabilidad interanual del rendimiento de trigo es explicada por el coeficiente fototérmico y por las precipitaciones en un 13 % y 7 % respectivamente (Verón et al., 2004). Bajo condiciones hídricas óptimas y sin limitantes nutricionales se puede explicar un 52 % de la variabilidad en el rendimiento de trigo con el coeficiente fototérmico (Magrin et al., 1993). A nivel regional la varianza del rendimiento de trigo fue explicada en un 30 % por el índice de precipitación sobre evapotranspiración potencial durante las fases de barbecho y crecimiento vegetativo del cultivo y un 5 % por el coeficiente fototérmico (Alvarez 2009). Como ya se mencionó anteriormente, la base de datos de éste último análisis fue de 100 valores y la región fue dividida en solo 10 unidades con superficies extensas por lo que no se pudo analizar la interacción entre variables edáficas bajo distintos escenarios climáticos. Ya se ha demostrado para otras regiones que para poder analizar la interacción de las variables climáticas con las características del suelo se requiere una base de datos más detallada para poder abarcar los amplios rangos biofísicos regionales (Olesen et al., 2000).

1.2.2. Factores edáficos que influyen el rendimiento de trigo

El inicio de la actividad agrícola para un suelo puede llevar a la degradación del mismo respecto de la situación no cultivada (Staben et al., 1997; Saviozzi et al., 2001). En la Pampa Ondulada (Vázquez et al., 1990; Andriulo y Cordone, 1998; Alvarez y Grigera, 2005), en la Región Semiárida Pampeana (Buschiazzi et al., 1991) y en la Pampa Mesopotámica (Novelli et al., 2011; 2013) existe evidencia de la degradación de suelos como resultado de su historia agrícola, con pérdida de materia orgánica principalmente. Las pérdidas pueden atribuirse a la erosión, la disminución de los aportes de residuos vegetales de sistemas cultivados respecto de pastizales y/o a incrementos de la mineralización de la materia orgánica en los suelos labrados (Alvarez, 2001).

En algunos suelos pampeanos se detecta la presencia de una capa petrocálcica, también denominada tosca, que impide la exploración y penetración del sistema radical de los cultivos (Alvarez y Lavado, 1998). En la Pampa Austral, donde la tosca es una limitante frecuente, se demostró que el rendimiento de trigo era mayor en suelos más profundos (de entre 100 y 120 cm de profundidad efectiva del suelo) y fue atribuido a limitaciones en la capacidad de almacenaje de agua de los suelos (Sadras y Calviño, 2001, Calviño y Sadras, 2002). La CAAU edáfica incrementa con la profundidad del suelo y con texturas finas y es una variable condicionante de la productividad primaria neta de un agroecosistema (Alvarez, 2009).

En la Pampa Ondulada, los suelos presentan niveles de materia orgánica superiores a 70 t ha^{-1} y no se ha podido demostrar una relación significativa de ésta variable con el rendimiento (Alvarez et al., 2002; Alvarez y Grigera, 2005). En cambio, en la Región Semiárida Pampeana, en suelos con menor contenido de materia orgánica, en lotes de producción sin fertilización, la materia orgánica se ha propuesto como el principal

factor asociado al rendimiento de trigo que explicaría un 48% de la variabilidad del mismo (Díaz-Zorita et al., 1999). Se estudió la relación del rendimiento con las precipitaciones, el contenido de materia orgánica de los suelos y su contenido de nutrientes. Se generó un modelo que propone que bajo condiciones climáticas semiáridas y suelos con un bajo contenido de materia orgánica, el rendimiento de trigo está relacionado a la materia orgánica como predictor y sigue una tendencia lineal-plateau, con un nivel crítico en 72 t ha^{-1} de materia orgánica en los primeros 20 cm del perfil. La parte lineal del modelo predice que una disminución de 1 Mg de materia orgánica por hectárea (0-20 cm) está asociada a una pérdida en el rendimiento de trigo de aproximadamente $41 \text{ kg de grano ha}^{-1}$. Sin embargo, para la misma subregión, se demostró que al aumentar la capacidad de retención de agua de los suelos, función de la textura del suelo y la profundidad (Alvarez et al., 2006), se incrementa su contenido de materia orgánica (Quiroga y Funaro, 2004), lo que hace necesario desglosar posibles efectos confundidos.

Paralelamente a estos trabajos se generó una base de datos muy amplia en esta región, compuesta por 85 experimentos de fertilización realizados en 8 años (Bono y Alvarez, 2009) que incluyó unos 918 datos de rendimiento de trigo bajo condiciones muy contrastantes de clima, suelo y manejo. Este estudio analizó las relaciones entre rendimiento y profundidad, textura, contenido de materia orgánica y nutrientes del suelo, variables de manejo, incluyendo dosis de nutrientes, y precipitaciones. Permite elaborar un modelo de regresión-covarianza explicativo del 48% de la variabilidad del rendimiento usando como predictores la profundidad y textura del suelo, su nivel de humedad a la siembra, su contenido de nitrógeno total y nitratos, la dosis de nitrógeno del fertilizante y el sistema de labranza. El modelo no detectó interacciones entre las variables asociadas a la capacidad de almacenamiento de agua y el nitrógeno total y permite desglosar los efectos de las propiedades físicas del suelo de los de la materia orgánica. La respuesta del rendimiento a la materia orgánica (estimada a partir del dato de nitrógeno total) es de tipo curvilíneo con un máximo en 55 t ha^{-1} de materia orgánica y una pendiente promedio de $45 \text{ kg grano t}^{-1}$ de materia orgánica. Si bien la pendiente es semejante a la estimada por Díaz-Zorita et al. (1999), se estableció un máximo bastante diferente y el modelo además indicaba un efecto mucho mayor sobre el rendimiento de las variables físicas que de la materia orgánica. El conjunto de variables físicas, asociadas a la disponibilidad de agua para el cultivo, sumaba efectos sobre el rendimiento de $2500 \text{ kg grano ha}^{-1}$, entre valores mínimos y máximos, mientras que la materia orgánica impactaba el rendimiento en $1300 \text{ kg grano ha}^{-1}$. Con la misma base de datos se mejoró el modelo ($R^2=0,90$) empleando una RNA que usó como inputs las mismas variables de la regresión, sumando antecesor y disponibilidad de fósforo (Bono et al., 2011).

En el estudio realizado a nivel de toda la Región Pampeana comentado inicialmente (Alvarez, 2009) se determinó que las variables edáficas CAAU y contenido de carbono orgánico explican el 39 % y 26 % respectivamente de la variabilidad del rendimiento de trigo. Como ya se indicó, la reducida variabilidad espacial y temporal del set de datos no permitió realizar un análisis de la interacción de las variables edáficas entre sí y tampoco de su posible interacción con las variables climáticas. Cambiar la resolución de la escala a una más detallada permitiría definir si las variables edáficas que afectan el rendimiento son las mismas a nivel de toda la Región Pampeana y sus sub-regiones al incluir más información de los gradientes biofísicos regionales.

1.2.3. Factores de manejo que influyen el rendimiento de trigo

El sistema de labranza afecta la dinámica del nitrógeno mineral y el contenido de agua del suelo y, consecuentemente, el rendimiento de los cultivos. La siembra directa, adoptada en

la Región Pampeana a partir de la década del '90, es una práctica que se caracteriza por el control químico de malezas y por dejar sobre la superficie del suelo el rastrojo del cultivo anterior (Díaz-Zorita et al., 2002). Bajo siembra directa la humedad del suelo es mayor debido a la mayor infiltración de agua y/o por la menor evaporación (Panigatti et al., 1998; Bolinder et al., 1999). Además, comúnmente se encuentran niveles de nitratos menores que bajo un sistema de labranza convencional (Abascal et al., 2003). Esto se atribuye a que en sistemas labrados los residuos son incorporados directamente al suelo, su descomposición es más rápida y esta liberación de nitrógeno ocurre durante el barbecho (Alvarez y Steinbach 2009).

Cuando no se implementa la fertilización nitrogenada, los rendimientos de trigo son mayores bajo sistemas con labranza, tendiendo a disminuir las diferencias, entre el sistema con labranza y el sistema bajo siembra directa, al fertilizar los cultivos (Alvarez y Steinbach 2009). Esta última revisión regional integra principalmente información de ensayos experimentales llevados a cabo en suelos de textura fina de la porción húmeda pampeana. Hay pocos estudios hechos para la Región Semiárida Pampeana que comparen los rendimientos alcanzados bajo distintos sistemas de labranza y únicamente se ha detectado una tendencia a encontrar rendimientos más altos (6%) bajo siembra directa (Alvarez y Steinbach 2009). Estos resultados implicarían que la adopción generalizada de la siembra directa en la región genera la necesidad de incrementar el uso de fertilizantes nitrogenados para mantener el rendimiento de cultivos de trigo (Alvarez y Steinbach 2009).

1.3. Modelización empírica del rendimiento de trigo

En Argentina los datos de rendimiento de todos los cultivos se encuentran publicados por el Ministerio de Agricultura de la Nación a escala de partido (MinAgri 2014). Es importante destacar que a pesar de la importancia ecológica y económica de la actividad agrícola regional, los datos de la superficie sembrada de los cultivos derivan de información provista por informantes calificados. Estas personas generan una evaluación cualitativa de su área de influencia por lo que esta información puede presentar incertidumbres (Paruelo et al., 2004). Existen pocos estudios regionales que relacionen el rendimiento de trigo con propiedades biofísicas y esto probablemente se deba a la complejidad de agregar espacialmente a la escala de partido la información edáfica, climática y de manejo disponible de los datos de agentes oficiales. En cuanto a datos de manejo del cultivo (como la dosis de fertilizante aplicado, el sistema de labranza, la mejora genética de variedades, etc.), es muy poca la información disponible para la situación actual, y mucho menos para las décadas del '60, '70 y '80, y las estimaciones a nivel partido únicamente se pueden basar en estudios puntuales y/o encuestas.

A través de una regresión múltiple se han vinculado algunos factores biofísicos al rendimiento de trigo de la Región Pampeana usando como único dato de suelo el porcentaje de suelos sin problemas de drenaje para el horizonte más superficial por partido para el horizonte más superficial descripta en el Atlas de Suelo de Argentina de INTA (escala 1:1.000.000) (Verón et al., 2002; Verón et al., 2004). Se estimó la proporción por partido de la clase de drenaje y no se incluyeron otras características edáficas como la materia orgánica, la textura y/o la profundidad de suelo cuyo efecto significativo sobre el rendimiento de trigo ya ha sido demostrado previamente en algunas sub-regiones pampeanas. Verón et al. (2001) encontraron que el 36 % de variabilidad interanual del rendimiento se encontraba explicada por el porcentaje de suelos sin problemas de drenaje mencionado mientras que Verón et al. (2004) encontraron que 34 % de ésta variabilidad se encontraba explicada por la precipitación durante el ciclo y el cociente fototérmico.

A nivel local se han comparado tres metodologías empíricas, promedios simples, regresiones polinómicas y redes neuronales artificiales, para generar un modelo regional

explicativo del rendimiento de trigo con variables edáficas y climáticas (Alvarez, 2009). La metodología con mejor ajuste estadístico fue la RNA y se detectaron con impacto significativo variables edáficas y climáticas. Las variables edáficas fueron integradas de los mapas de suelo de INTA que corresponden a un área que cubre el 70 % de la superficie actual sembrada con trigo. Tanto la variabilidad espacial de las características biofísicas pampeanas como la variabilidad temporal de este trabajo fueron limitadas y tampoco fueron analizadas las interacciones entre variables biofísicas. La interacción entre variables climáticas entre sí y con respecto a escenarios de suelo es lo que se pretende evaluar en esta tesis.

Para aprovechar la información de rendimiento de trigo publicada por el Ministerio Agricultura de la Nación y generar un modelo regional explicativo y comprender sus patrones espaciales y temporales, hay que agregar espacialmente la información disponible por partido. En primer lugar, es necesario agregar la información edáfica de las series de suelo publicada en los mapas de suelo de INTA de todas las provincias pampeanas. En segundo lugar, la información climática disponible de estaciones meteorológicas del Servicio Meteorológico Nacional y estaciones de INTA tendría que ser agregada a través de un método de interpolación espacial. Finalmente, los pocos datos de manejo disponibles como datos puntuales de encuestas y/o de ensayos experimentales también tienen que ser agregados espacialmente.

Disponer de un modelo regional del rendimiento de trigo que permita evaluar la interacción de las propiedades de los suelos pampeanos con el clima permitiría: 1) evaluar el efecto de las variables biofísicas sobre el rendimiento, 2) detectar la variabilidad espacial y temporal de sus factores limitantes, 3) estimar el efecto de los cambios tecnológicos y de manejo, 4) proponer prácticas de manejo sustentables por zonas y 5) establecer futuras líneas de investigación.

1.4. Brecha de rendimiento y productividad

El rendimiento potencial se define como el rendimiento de un cultivar cuando crece en un ambiente al cual está adaptado bajo condiciones no limitantes de agua y nutrientes y los componentes de estrés bióticos se encuentran efectivamente controlados (Van Ittersum y Rabbinge 1997; Evans 1998) (**Figura 1.2.**). Los factores que lo definen son aquellos que determinan el crecimiento potencial: las características de la planta (fisiológicos y fenológicos), la temperatura y la radiación solar.

Cuando agua y/o nutrientes son limitantes, se obtiene el rendimiento alcanzable que es determinado por la radiación solar, la temperatura, la cantidad y la distribución de agua y nutrientes (Cassman 1999; Passioura 2006) (**Figura 1.2.**). Este nivel de rendimiento se obtiene cuando el cultivar está adaptado al ambiente en el que crece y los factores bióticos están controlados y las prácticas de manejo son óptimas (Van Ittersum y Rabbinge 1997). Los factores limitantes comprenden todos los recursos abióticos que cuando su control no es adecuado causan reducciones en la tasa de crecimiento de las plantas. Los productores influyen este nivel de rendimiento a través de variables de manejo como la fecha de siembra, la madurez del cultivar, la densidad de plantas, el espaciado entre plantas, etc. (Lobell et al., 2002). Sin embargo, antes que aumentar el rendimiento se apunta a maximizar la ganancia, dentro de un rango aceptable de riesgo, y para ello se utilizan prácticas que son económicamente viables pero que no necesariamente maximizan el rendimiento (Cassman et al., 2010).

Cuando se usan series históricas de datos de rendimiento en lugar de resultados de experimentos, los máximos alcanzados representan la mejor combinación de clima y manejo para un escenario de bajo efecto de adversidades en un sitio, acercándose al rendimiento alcanzable. El rendimiento máximo alcanzado representa el nivel de rendimiento más alto que

puede lograrse en un área con el manejo que se aplica comúnmente por la mayoría de los productores. La brecha de rendimiento entre este máximo y los rendimientos logrados en situaciones menos favorables permite estudiar el efecto de factores de clima, suelo y manejo sobre la productividad del agroecosistema para el escenario tecnológico medio del momento (Laborte et al., 2012). Cuando se presenta una gama de limitantes hídricas, nutricionales y efectos bióticos y abióticos adversos se logra el rendimiento alcanzado que es el nivel de rendimiento logrado por productores (Van Ittersum y Rabbinge 1997) (**Figura 1.2.**). Los factores que reducen el rendimiento disminuyen o dificultan el crecimiento y comprenden factores bióticos (plagas, pestes de insectos y enfermedades, etc.) y/o abióticos (granizo, inundaciones, heladas, contaminantes, etc.) más las limitaciones que imponen en un área el clima (precipitación) y el suelo (fertilidad y propiedades físicas) bajo el manejo del cultivo habitual.

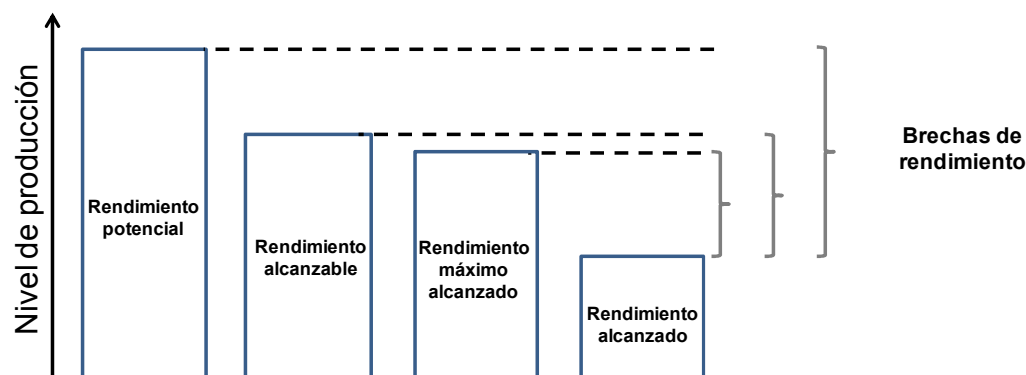


Figura 1.2. La relación entre los rendimientos potencial, alcanzable, máximo alcanzado y alcanzado. La brecha de rendimiento se calcula como la diferencia entre los primeros tres y el último según el caso. (Modificado de Van Ittersum y Rabbinge, 1997).

La brecha de rendimiento se define como la diferencia entre un rendimiento máximo y el observado. Como máximo puede tomarse el rendimiento potencial, el alcanzable o el máximo alcanzado (**Figura 1.2.**) y cada una de esas brechas tendrá diferente interpretación. Generar estimaciones regionales de la brecha de rendimiento puede servir como una herramienta para explorar el potencial de intensificación agrícola por área, definir la naturaleza de las limitantes bajo el desarrollo tecnológico actual y evaluar su distribución (Grassini et al., 2009). La demostración de la existencia de esta brecha provee el marco esencial para priorizar los esfuerzos de investigación y gestión necesarios para su reducción. Actualmente se acepta que es muy difícil reducir la brecha de rendimiento a cero por las limitantes en las prácticas de manejo y limitantes económicas ampliamente difundidas (Fischer et al., 2009). Estudios empíricos sugieren como límite inferior de la brecha de rendimiento a valores entre 20 y 25 % del rendimiento alcanzable (Fischer et al., 2009). Sin embargo, este mínimo sólo se ha logrado en algunos agroecosistemas manejados muy intensamente (Grassini et al., 2011).

En algunas regiones del Mundo se ha observado que el rendimiento alcanzado de trigo y arroz se aproxima a un plateau mientras que en otras regiones todavía se observan aumentos en el rendimiento que permitirían achicar la brecha de rendimiento (Hall y Richards 2013). Mantener dichos aumentos es difícil ya que para ello se requiere eliminar pequeñas imperfecciones en las prácticas de manejo del sistema de producción que comúnmente no son económicamente viables (Cassman et al., 2010).

La consideración explícita de variaciones temporales en el análisis de brechas de rendimiento es particularmente importante en ambientes de producción de cultivos bajo condiciones de secano y no existen muchos antecedentes (Abeledo et al., 2008). En cambio, la dimensión espacial de esta brecha fue analizada para varias escalas como la de sitio (Lobell et al., 2007), la regional (Grassini et al., 2011; Hall et al., 2013), la nacional o la de mega-ambientes (Fischer et al., 2009) e inclusive la escala global (Gerber et al., 2010; Licker et al., 2010).

En la Región Pampeana no se han realizado estimaciones del rendimiento alcanzable o máximo alcanzado de trigo a nivel regional. Existe un antecedente para el cultivo de girasol donde se detectaron brechas entre el rendimiento alcanzable y el alcanzado que estaban principalmente dominadas por prácticas de manejo deficientes y efectos ambientales (Hall et al., 2013). Por su relevancia agrícola y los gradientes biofísicos que presenta, es importante definir cuál es el rendimiento alcanzable o el máximo alcanzado de trigo e identificar las variables que la definen a escala regional. Resulta importante ubicar espacialmente la brecha de rendimiento y de esta manera detectar las principales limitantes climáticas, edáficas y/o de manejo, zonificar dichas limitantes y proponer prácticas de manejo más adecuadas para reducirla en cada sub-región pampeana. En esta tesis se va a introducir además el concepto de brecha de productividad para la caracterización de áreas con respecto a las variables biofísicas que la determinan. La brecha de productividad se calculará como el promedio de los valores de brecha de rendimiento anual para un área y permitirá la caracterización de la misma en función de la variación espacial de las propiedades de clima y suelo.

1.5. Objetivo general de la tesis

Determinar la productividad regional de suelos pampeanos para trigo.

1.6. Estructura de la tesis

Esta tesis está organizada en seis capítulos; en el Capítulo 1 (**Introducción general**) se desarrollaron los antecedentes sobre el tema, los cuales dan sustento a la formulación del objetivo general. En el Capítulo 2 (**Generación de la base de datos**) se describe la base de datos generada que fue utilizada en los tres capítulos de resultados que están vinculados a los objetivos específicos. En el Capítulo 3 (**Modelización del rendimiento de trigo**) se propone un modelo explicativo de rendimiento de trigo a través de la comparación de varias metodologías estadísticas complejas a escala regional. En el Capítulo 4 (**Productividad de suelos pampeanos**) se utiliza el modelo seleccionado para generar un índice de productividad deductivo. Además se correlacionaron con datos de rendimiento el índice de la FAO utilizado en Argentina y otros existentes. En el Capítulo 5 (**Brecha de rendimiento y productividad**) se estiman las brechas de rendimiento y de productividad de la Región Pampeana relacionándolas a variables de suelo. Por último, el Capítulo 6 (**Discusión general**) incluye brevemente el estado del conocimiento antes del desarrollo de la tesis, una síntesis de resultados más relevantes y las implicancias para investigaciones futuras.

CAPITULO 2

GENERACIÓN DE LA BASE DE DATOS

CAPITULO 2. Generación de la base de datos

2.1. Introducción

2.1.1. Área de estudio

La Región Pampeana es una amplia pradera con clima templado húmedo y el régimen de precipitación puede ser muy variable, sobre todo en el oeste (Hall et al., 1992) (**Figura 1.1.**). La temperatura tiene un gradiente que aumenta de sur a norte y la precipitación aumenta en dirección sudoeste-noreste, con distribución monsonal (Hall et al., 1992). Los suelos dominantes son Molisoles, fértiles y aptos para cultivos, desarrollados sobre sedimentos eólicos cuaternarios profundos aunque también hay suelos Vertisoles, Inceptisoles, Entisoles, y Alfisoles (Moscatelli 1991; Alvarez y Lavado 1998). La deposición de sedimentos eólicos generó un gradiente de textura: gruesas (arena) en el sudoeste y más finas (limo y arcilla) en el noreste. Esta situación, en combinación con el gradiente de precipitación, que aumenta en la misma dirección, produce una secuencia geográfica de suelos: Haplustoles Énticos en el límite oeste, con la aparición progresiva de Hapludoles Énticos, Hapludoles Típicos, Argiudoles Típicos y Argiudoles Vérticos más hacia el este de la región (Alvarez y Lavado 1998).

En la Pampa Ondulada se presentan suelos bien drenados y profundos con un horizonte argílico y los más representativos son el Argiudol Típico y el Argiudol Vértico (Hall et al., 1992). En la Pampa Mesopotámica se presenta un área extensa con suelos Vertisoles que son poco aptos para agricultura con arado y los problemas de erosión hídrica en los lotes agrícolas son los más graves de la Región Pampeana (Moscatelli 1991). En la Pampa Arenosa los suelos son profundos y predominan texturas arenosas y limosas y los suelos más representativos son el Haplustol Éntico y el Hapludol Éntico (Hall et al., 1992). La textura gruesa y las bajas precipitaciones hacen que estos suelos sean poco propensos al anegamiento. En la mayor parte de esta sub-región se puede cultivar aunque la susceptibilidad a la erosión eólica puede ser una limitante. Los suelos más representativos de la Región Semiárida Pampeana son el Paleustol petrocálcico y el Ustipsament Típico. El contenido de materia orgánica es bajo y los suelos presentan una densa capa petrocálcica (también denominada tosca) a profundidades variables.

El suelo más representativo de la Pampa Austral también es el Argiudol Típico con una textura más gruesa que aquellos presentes en la Pampa Ondulada, además de un horizonte argílico menos desarrollado (Hall et al., 1992; Viglizzo et al., 2001). Una limitante importante para los cultivos de granos es la presencia de una capa de tosca que es frecuente y se presenta a poca profundidad pero es posible realizar cultivos de invierno en gran parte de su superficie (Viglizzo et al., 2001). La Pampa Deprimida es un área donde predominan bajos con presencia de la napa freática muy cercana a la superficie, los suelos predominantes son Natracuales Típicos y Natracualfes Típicos, y los pastizales naturales siguen siendo el principal recurso productivo (Perelman et al., 2001).

2.1.2. Escalas de análisis

Para poder utilizar los datos de rendimiento de trigo por partido provenientes de estadísticas nacionales del Ministerio de Agricultura, Ganadería y Pesca de la Nación fue necesaria la agregación espacial de la información de clima, suelo y manejo disponible a esta escala. El resumen de las dos escalas de análisis utilizadas para alcanzar los objetivos específicos de cada capítulo se encuentran diagramados en la **Figura 2.1.**

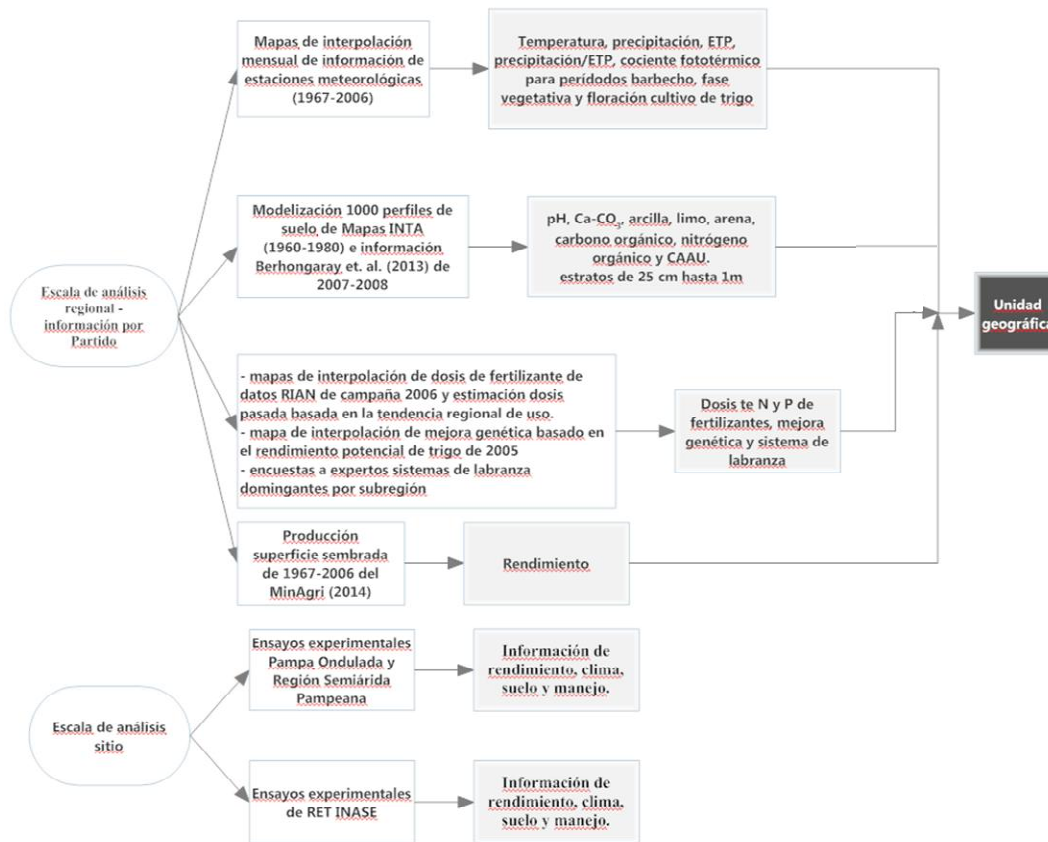


Figura 2.1. Guía de lectura de la escala de análisis de la base de datos elaborada para la tesis y descrita en este capítulo.

En primer lugar se trabajó a escala regional, que comprende casi la totalidad de la Región Pampeana, que a su vez fue dividida en la escala partido y la escala unidad geográfica. La escala partido comprende a los partidos pampeanos donde se cultiva trigo y para la cual se realizó una agregación espacial de información de clima, suelo, manejo y rendimiento. La escala unidad geográfica resulta de la agregación espacial de la información por partido. En segundo lugar se evaluó la escala sitio que comprende la información de ensayos experimentales realizados por el grupo de trabajo en distintas localidades de la Pampa Ondulada y la Región Semiárida Pampeana. También se usaron resultados de experimentos que formaron parte de las redes experimentales del INASE.

A continuación se detallan las metodologías de agregación espacial para obtener las escalas de análisis regional y sitio. En primer lugar se describe la metodología de agregación aplicada a los datos disponibles de clima, suelo, manejo y rendimiento para alcanzar la escala regional partido. En segundo lugar se explica cómo se agregaron los datos por partido para obtener información a escala unidad geográfica. En tercer lugar se describen los datos de los ensayos experimentales utilizados correspondientes a la escala de análisis de sitio. Alguna información fue presentada en forma de mapa utilizando el programa ArcGIS 9.1 (ESRI, Copyright © 2005).

2.2. Escala de análisis regional - Partido

2.2.1. Clima

La agregación espacial se realizó a partir de datos no publicados provenientes de estaciones meteorológicas del Servicio Meteorológico Nacional (SMN) y del INTA, disponibles a pedido. Las variables climáticas solicitadas fueron: la temperatura mensual máxima y mínima (°C) y la precipitación mensual (mm) desde enero hasta diciembre desde la campaña 1967 hasta 2006. En total, se contó con un set de datos proveniente de aproximadamente 80 estaciones meteorológicas distribuidos dentro y alrededor de la Región Pampeana como se muestra en la **Figura 2.2**. El número de estaciones meteorológicas con información disponible no fue constante para todos los años y varió de 74 en el año 1967 a 86 en el año 2005.

Las variables climáticas por partido fueron estimadas a partir de datos medidos en estaciones meteorológicas a través del método de interpolación espacial inverso a la distancia, con la extensión Spatial Analyst de ArcGIS 9.1 (ESRI, Copyright © 2005). El método estima, para un punto dado, datos climáticos a partir de promedios entre las estaciones meteorológicas que lo rodean, dándole a cada estación vecina un peso que es inversamente proporcional a la distancia de la estación meteorológica (Zimmerman et al., 1999).

Se generaron 1440 mapas de interpolación (40 años x 12 meses x 3 variables climáticas) que cubrían la totalidad de la superficie de la Región Pampeana. Con la información interpolada espacialmente, se estimaron la temperatura máxima y mínima y la precipitación mensual por partido para todas las campañas desde 1967 hasta 2006. La temperatura mensual fue estimada como el promedio de la temperatura máxima y mínima mensual de cada campaña.



Figura 2.2. Distribución geográfica de las estaciones meteorológicas de INTA y del Servicio Meteorológico Nacional en la Región Pampeana y zonas circundantes para un año determinado.

La validación del método de interpolación utilizado se realizó a través de la comparación de valores medidos en las estaciones meteorológicas con datos estimados para las mismas ubicaciones geográficas. Las variables comparadas fueron la temperatura máxima y mínima y precipitación mensual en 30 estaciones meteorológicas, seleccionadas por presentar una amplia distribución geográfica, y durante 5 campañas elegidas al azar ($n = 30 \times 5 \times 12 \times 3 = 1800$ datos por variable climática). Se compararon valores estimados y observados a través del R^2 (*F-test*, $P = 0,01$) de su regresión simple y análisis estadístico de la ordenada al origen y la pendiente, iguales a 0 y a 1 respectivamente (*t-test*, $P = 0,05$). La estimación de la temperatura mensual a través de esta metodología resultó en un ajuste óptimo entre valores observados y estimados por el método del inverso a la distancia ($R^2 > 0,90$, *test* de F $P = 0,01$, ordenada y pendiente igual a 0 y 1 respectivamente, $P = 0,05$). La

estimación de la precipitación mensual para el período estudiado resultó en estimaciones buenas ($R^2 > 0,70$, $P = 0,05$) pero la ordenada y la pendiente fueron distintos de 0 y 1 respectivamente aunque la diferencia entre valores estimados y observados fue menor al 5 %.

No existen suficiente mediciones de radiación solar a nivel local como para poder utilizarlos en este análisis por lo que esta variable tuvo que ser estimada. Se estimó la radiación solar incidente a través del método propuesto por Hunt et al. (1998), pero modificado a nivel local posibilitando así una estimación de la transmitancia atmosférica que se ajusta más a la radiación de mediciones radiométricas en la Región Pampeana (Alonso et al., 2002). La radiación solar en la superficie externa de la atmósfera se calculó a través de algoritmos incluidos en RadEst 3.00 (Donatelli et al., 2003).

Se estimaron los promedios ponderados por el número de días correspondientes a los meses de abril, mayo y junio para la fase de barbecho, para los meses de julio, agosto y septiembre para la fase vegetativa de crecimiento y para los meses de octubre y noviembre para la floración de cada partido. Los promedios ponderados por número de días se estimaron para todas las variables climáticas utilizadas. Adicionalmente se calculó el índice precipitación/evapotranspiración para los períodos ya que existen antecedentes de su aplicación a nivel regional (Alvarez, 2009). En el **Cuadro 2.1.** se resumen los rangos y promedios de las variables climáticas agregadas a la escala partido. La temperatura promedio durante la floración (18.1 °C) es superior a la temperatura durante las fases de barbecho (11.3 °C) y crecimiento vegetativo (12.6 °C). Los partidos del norte tienen temperaturas superiores a los del sur durante todo el período estudiado y no se detectó un patrón en el sentido este-oeste.

Cuadro 2.1. Rango y promedio de variables climáticas agregadas a escala partido de la Región Pampeana para el período 1967-2006.

Variable	Mínimo	Promedio \pm DE	Máximo
Temperatura barbecho (°C) ¹	8,47	11,3 \pm 0,771	18,5
Temperatura fase vegetativa (°C) ²	7,67	12,6 \pm 0,764	18,2
Temperatura floración (°C) ³	13,5	18,1 \pm 0,879	22,8
Precipitación barbecho (mm) ¹	18	176 \pm 43	691
Precipitación fase vegetativa (mm) ²	7	126 \pm 30	420
Precipitación floración (mm) ³	38	202 \pm 40	670
ETP barbecho (mm) ¹	70	131 \pm 8,9	191
ETP fase vegetativa (mm) ²	67	134 \pm 10	209
ETP floración (mm) ³	189	302 \pm 18	431
Precipitación/ETP barbecho ¹	0,12	1,4 \pm 0,4	1,4
Precipitación/ETP fase vegetativa ²	0,04	0,98 \pm 0,3	3,7
Precipitación/ETP floración ³	0,13	0,68 \pm 0,2	1,9
Coefficiente fototérmico (MJ m ⁻² d ⁻¹ °C ⁻¹) ⁴	0,87	1,4 \pm 0,1	2,2

DE = desvío estándar. ETP = ETP del cultivo de trigo. ¹ aprox. abril-mayo-junio. ² aprox. julio-agosto-septiembre. ³ aprox. octubre-noviembre. ⁴ período crítico de un mes antes de antesis (aprox. noviembre).

La precipitación fue la variable climática que mostró la mayor variabilidad entre los partidos pampeanos tanto en el barbecho previo a la siembra, como en la fase de crecimiento vegetativo y la floración. En la Región Semiárida Pampeana, la precipitación durante el barbecho más el ciclo del cultivo (sumatoria de precipitación durante fase de crecimiento vegetativo y floración) fue de 362 mm en promedio mientras que el promedio observado en la Pampa Ondulada fue de 530 mm. En la Pampa Mesopotámica los valores de precipitación fueron los más altos de toda la región con un promedio de 621 mm durante los tres períodos. La ETP calculada por partido tuvo un mismo patrón espacial parecido al de temperatura.

El índice climático precipitación/evapotranspiración promedio ponderado por el número de días de las tres fases y para las 40 campañas analizadas mostró una distribución espacial con una tendencia a aumentar de oeste a este (**Figura 2.3.A.**). Los valores mínimos se obtuvieron en el oeste de la Provincia de Córdoba (0,5) y los máximos (1.6) hacia el sudeste de la Provincia de Buenos Aires. Este índice climático no mostró un gradiente latitudinal. Los valores mínimos del oeste implican que las precipitaciones, durante los períodos analizados, llegan a la mitad de lo que el cultivo pierde por la ETP en el peor de los casos; en el este la situación es inversa. El gradiente térmico relacionado a la radiación incidente resultó además en la variación del coeficiente fototérmico con un claro gradiente de norte a sur con un rango de $0,94 - 2,05 \text{ MJ m}^{-2} \text{ d}^{-1} \text{ }^{\circ}\text{C}^{-1}$ como promedio de 40 campañas (**Figura 2.3.B.**). No se observa un gradiente de este a oeste. Los valores máximos se ubican en el Sudeste Bonaerense y los mínimos en el norte de la Pampa Mesopotámica.

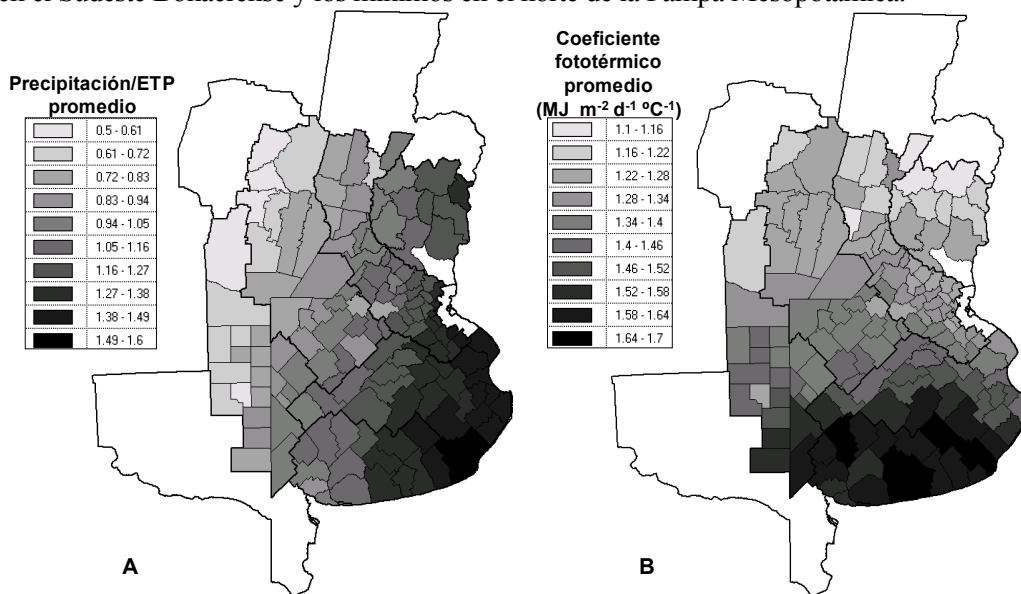


Figura 2.3.A. Distribución espacial por partido del índice climático precipitación/evapotranspiración promedio ponderado y **B.** el coeficiente fototérmico promedio ambos para el período 1967-2006.

2.2.2. Suelo

Los datos de suelo fueron agregados a la escala partido a partir de información edáfica publicada en los mapas de suelos (escala 1:500,000) de INTA de las provincias de Buenos Aires (INTA 1989), Córdoba (INTA 2003), Entre Ríos (INTA 1984), La Pampa (INTA 1980) y Santa Fe (INTA 1981, 1989). La superficie total relevada en estos documentos es de 87,5 Mha y corresponde a la casi totalidad de la superficie de las cinco provincias y representa

más del 95% de la superficie dedicada al cultivo de trigo de la Región Pampeana. Los relevamientos de suelo llevados a cabo para completar los mapas de suelo de INTA corresponden al período 1960-1980 aproximadamente. La información de los mapas de suelos de INTA está basada en la descripción de perfiles típicos (en total más de 1000 perfiles para las cinco provincias) que contienen determinaciones de: carbono orgánico (%), nitrógeno orgánico (%), carbono en carbonato de calcio (CaCO_3) (%), composición textural: arcilla (%), limo (%), arena (%), pH y profundidad hasta la tosca. Por lo tanto se elaboraron 7000 perfiles de estimación.

Cada dato de los perfiles típicos descriptos representa el valor medido de una variable edáfica correspondiente a un estrato del perfil suelo de una profundidad determinada. La agrupación espacial de perfiles típicos define una unidad cartográfica y la agrupación espacial de unidades cartográficas constituye un partido, ambos niveles de agrupación están determinados por diseños espaciales específicos. A modo de ejemplo se muestra una sección del mapa de suelos del partido Minas - Córdoba (**Figura 2.4.**). Las unidades cartográficas representan áreas con una composición similar de varios suelos, cuyo porcentaje está definido en el mapa. Por ej. en la Figura 2.4 la unidad MJen-5 está compuesta por 80% de Hapludol Éntico y 20% (perfil 37) de Hapludol Típico (perfil 44).

Para utilizar la información publicada de los mapas de suelo de INTA a escala partido es necesario agregar espacialmente la descripción de los perfiles de suelo y también la información de las unidades cartográficas. En primer lugar se calcularon promedios ponderados por el área de influencia de los perfiles típicos. En segundo lugar se calcularon promedios ponderados por el área de influencia de las unidades cartográficas por partido. Los promedios ponderados se calcularon por estrato del perfil de suelo analizado.




Figura 2.4. Mapa de suelos de INTA correspondiente a una parte del partido Marcos Juárez de la Provincia de Córdoba y las unidades cartográficas que la componen. Se indica la unidad cartográfica MJen-5 que es explicada en el texto.

Las profundidades de los estratos de suelos de los perfiles descriptos dependen del espesor de los horizontes de los mismos y por lo tanto son muy variables (**Figura 2.5.A.**). Para poder realizar la agregación espacial a la escala partido es necesario homogeneizar la profundidad de los estratos de los perfiles de suelo (Jobbagy y Jackson 2000). Una manera de lograr esto es ajustando modelos curvilíneos a la información edáfica publicada por perfil de suelo descripto. Se ajustaron modelos curvilíneos, en su mayoría exponenciales y potenciales, a cada variable medida.

Se utilizó el programa Table Curve para ajustar todas las curvas y el mejor modelo fue seleccionado en base al R^2 (**Figura 2.5.B.**). Se ajustaron modelos curvilíneos para estimar los valores de las variables edáficas cada 25 cm hasta 1 metro de profundidad o hasta el límite superior de la capa de tosca en caso de presentarse la misma. El R^2 promedio de todas las

estimaciones de las 7 variables fue superior a 0,90. En total se modelizaron en profundidad 1000 perfiles de suelo y 7 variables: pH, carbono de carbonatos, arcilla, limo, arena, carbono orgánico y nitrógeno orgánico (7000 estimaciones = 1000 perfiles x 7 variables de suelo). La variable nitrógeno orgánico pudo ser modelizada únicamente hasta los primeros 25 cm del perfil de suelo porque las descripciones de los perfiles típicos de los mapas de suelo de INTA estaban incompletas. Con las descripciones de los perfiles típicos además se determinó la profundidad de cada perfil de suelo. La información edáfica agregada por partido fue representada gráficamente a través de 28 mapas (28 mapas = 7 variables x 4 profundidades) y en este capítulo se presentan algunos.

Se integró la información edáfica hasta 1 m de profundidad y no más porque muchos perfiles estaban incompletos debajo de ese límite. Se ha demostrado, sobre la base de una gran cantidad de perfiles de absorción, que el trigo absorbe agua intensamente hasta 1.6 m de profundidad tanto bajo escenarios de fuerte déficit hídrico como con riego (Cabelguenne y Debaeke, 1998). En ambientes con marcados déficits hídricos, aproximadamente un 30% de la absorción de agua del cultivo se produce en los primeros 20 cm del perfil donde es mayor la densidad de raíces (Cabelguenne y Debaeke, 1998), pero un 70% del agua absorbida proviene de las capas profundas hasta 1.6 m. La modelización de la absorción de agua por los cultivos también ha demostrado que la absorción de ésta es muy intensa en trigo entre 50 y 100 cm de profundidad, a pesar de la menor densidad de raíces en los estratos más profundos del perfil (Dardanelli et al., 2004). En la Región Semiárida Pampeana el contenido de agua del suelo durante el ciclo de trigo y otros cultivos de 0 a 140 cm de profundidad copia la evolución del contenido de agua de 0 a 20 cm (Quiroga et al., 1998 a,b). Cuando hay sequía de 0 a 20 cm, también se produce en todo el perfil del suelo, siendo la absorción desde todo el perfil unas cinco veces mayor a la que proviene del estrato superficial (Quiroga et al., 1998 a,b). Por ello hubiera sido deseable integrar información a mayor profundidad que 1 metro en este trabajo, pero no fue posible.

Los valores de las variables de suelo descritas en los mapas de suelo de INTA se encuentran en porcentaje (%) y fueron transformados a contenidos es decir en unidades de masa por superficie ($t\ ha^{-1}$). La estimación del contenido de una variable edáfica resulta primeramente del cálculo del peso de la capa de suelo ($10,000\ (m^2) \times$ profundidad estrato (cm) \times densidad aparente ($g\ cm^{-3}$) y luego se lo multiplica por el porcentaje de la variable para el estrato determinado (Alvarez y Lavado, 1998) (**Figura 2.5.C.**). La densidad aparente del suelo fue estimada usando datos texturales y de materia orgánica (Rawls, 1983). Las estimaciones de densidad aparente fueron corregidas en un 4 % por una sobreestimación de la metodología descrita en Berhongaray et al. (2013).




Figura 2.5.A. Representación gráfica de información presentada en tablas de los valores de las variables de suelo publicados en los mapas de suelo de INTA y un modelo curvilíneo ajustado. **B.** Datos estimados por estrato de 25 cm hasta el primer metro de profundidad de suelo a través del modelo de estimación en profundidad. **C.** Estimación de los contenidos de la variable edáfica con la densidad aparente estimada con las ecuaciones de pedotransferencia de Rawls (1983).

El contenido de materia orgánica fue calculado sobre la base del contenido de carbono orgánico, asumiendo que el contenido de materia orgánica es igual a 1.72 por el contenido de carbono orgánico (Nelson y Sommers 1996). El método de medición del porcentaje de carbono orgánico se denomina Walkley-Black y detecta carbono a través de la oxidación. La fracción de carbono orgánico oxidado disminuye con la profundidad del perfil analizado por lo que se aplicó una ecuación de corrección de carbono oxidado en profundidad basado en datos de un trabajo local (Richter et al., 1973). La función ajustada tenía un ajuste de $R^2 = 0,5802$ y se estima así:

Profundidad media del estrato (cm) = $0,0034 \times \text{carbono orgánico oxidado} + 1.18$, $P = 0,05$.

Los coeficientes de corrección fueron 1.22; 1.31; 1.39 y 1.48 para los estratos de 0-25 cm; 25-50 cm; 50-75 cm y 75-100 cm respectivamente.

Se estimó la capacidad de almacenamiento de agua útil (CAAU) para cada estrato y también hasta el metro de profundidad o el límite superior de la capa de tosca usando el método propuesto por Rawls et al. (1982). Para éste cálculo se necesitaron las variables en porcentaje de arena, limo, arcilla y materia orgánica. Para el cálculo de los porcentajes de las unidades cartográficas se asumió que el suelo (100 %) está conformado de la suma de la parte textural y la materia orgánica. La CAAU se estimó como la diferencia entre la capacidad de campo (-0.33 bares) y el punto de marchitez (-15 bares) estimadas por la metodología citada.

Como el contenido de carbono orgánico puede verse afectado por el uso del suelo se utilizaron los datos agregados de los mapas de suelo de INTA únicamente para la primera década de análisis (1967-1976). Para la última década de análisis (1997-2006) se utilizó la información por partido estimada con una red neuronal basada en información de un muestreo regional reciente de Berhongaray et al. (2013). En este estudio se tomaron muestras de suelo cada 25 cm y hasta el primer metro de profundidad de 380 sitios distribuidos en la Región Pampeana y se estimó el contenido de carbono orgánico con una red neuronal artificial (Berhongaray et al., 2013). Los tipos de uso de suelo predominantes fueron muestreados y con la información proveniente de imágenes satelitales de la superficie dedicada a cada tipo de uso se estimó el contenido por partido. Se estimaron los datos de carbono orgánico por partido correspondientes a las dos décadas intermedias a través de una regresión lineal entre los valores de la primera (datos agregados de los mapas de suelo de INTA) y última década (datos del relevamiento regional reciente) del partido.

En el **Cuadro 2.2.** se resumen los rangos de las variables de suelo estimadas por partido. La profundidad promedio fue de 92.9 cm y en el 48 % de los partidos no se detectó tosca en el primer metro de profundidad. El suelo más somero fue de 40,7 cm de profundidad en la Región Semiárida Pampeana y los de los partidos de la Pampa Ondulada (específicamente de la Provincia de Santa Fe) y la Pampa Mesopotámica no presentaron tosca. En la mayoría de los partidos de la Pampa Austral la presencia de tosca a menos de un metro de profundidad representa una limitante frecuente. El pH regional promedio se acerca a la neutralidad, el rango de carbono en carbonatos varía de 0 a valores mayores a 400 t ha^{-1} y el rango textural en el área de estudio es notable. El contenido promedio de carbono orgánico hasta los primeros 50 cm de profundidad es de 65.7 t ha^{-1} mientras que el contenido de nitrógeno orgánico promedio de los primeros 25 cm del perfil de suelo es de 4.73 t ha^{-1} . La CAAU puede variar desde 77.9 mm hasta 211 mm hasta el primer metro de profundidad. Para la mejor comprensión de la distribución espacial de estas variables de suelo se hace uso de mapas por partido que se presentan a continuación.

Cuadro 2.2. Promedio, desvío estándar y rango de variables edáficas estimadas por partido de la Región Pampeana para el período 1967/1968-2006/2007 hasta una profundidad de 0-100 cm o hasta el límite superior de la capa petrocálcica en caso de presentarse.

Variable	Mínimo	Promedio \pm DE	Máximo
Profundidad (cm)	40,7	92,9 \pm 10,2	100
pH	5,96	7,05 \pm 0,65	8,87
C-CaCO ₃ (t ha ⁻¹)	0,00	28,1 \pm 62,9	417
Arcilla (g kg ⁻¹)	55,3	257 \pm 160	591
Limo (g kg ⁻¹)	19,7	363 \pm 182	743
Arena (g kg ⁻¹)	20,1	367 \pm 238	860
Carbono orgánico (t ha ⁻¹) ¹	28,1	65,7 \pm 16,5	131
Nitrógeno total (t ha ⁻¹) ²	1,745	4,73 \pm 16,5	16,2
CAAU (mm)	77,9	144 \pm 2,04	211

DE = desvío estándar. CAAU = capacidad de almacenamiento de agua útil. ¹ contenido estimado para una profundidad de 0-50 cm del perfil de suelo con datos integrados de los mapas de suelo de INTA para la primer década (1967-1976) y datos del muestreo de Berhongaray et al. (2013) para la última década (1997-2006). ² contenido estimado para el estrato de 0-25 cm del perfil de suelo.

La integración de los datos de los mapas de suelo de INTA de la variable pH (**Figura 2.6.A**) mostró una amplia variación entre partidos. Los valores de pH más elevados se observaron en las sub-regiones de la Pampa Deprimida y la Región Semiárida Pampeana con valores de 8 en promedio mientras que los suelos de menos pH se ubican en la Pampa Ondulada y específicamente en la Provincia de Santa Fe. No se observa un gradiente de norte a sur y tampoco un gradiente de este a oeste, únicamente se destacan valores altos en la Depresión del Salado donde el pH de los suelos está afectado por la presencia de suelos alcalinos.

La distribución de carbono inorgánico en carbonatos no mostró un patrón espacial definido pero los suelos con más contenido de carbono inorgánico se ubicaron en la Región Semiárida Pampeana (**Figura 2.6.B**). Esta última sub-región tuvo contenidos de carbonatos variables que en promedio fueron hasta 5 veces mayores a los contenidos de la Pampa Austral considerando el primer metro que además coincide con la presencia frecuente de la capa petrocálcica a profundidades someras.

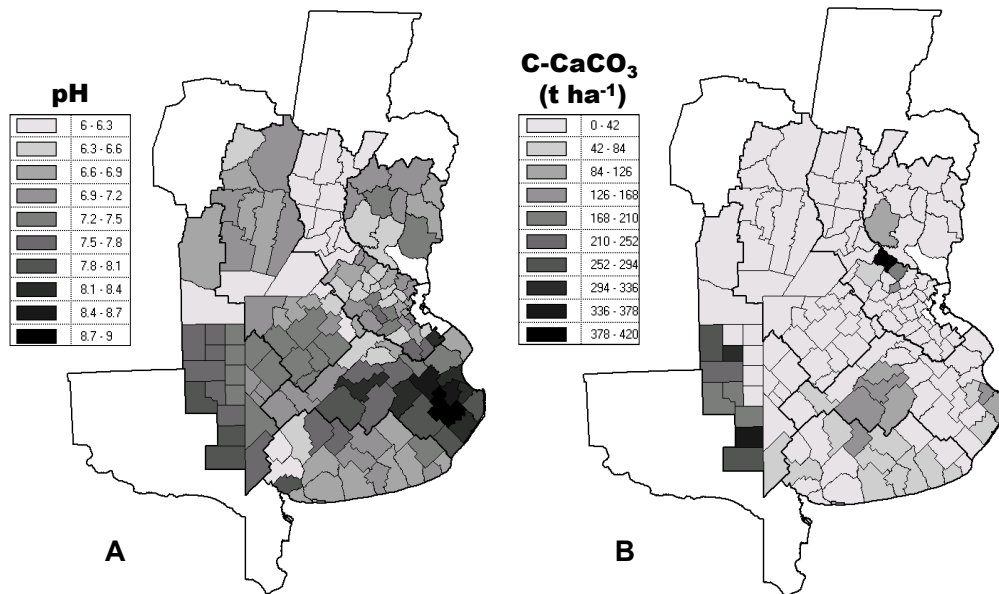


Figura 2.6. A. Distribución geográfica del pH promedio y **B.** el contenido carbono de carbonatos ($t\ ha^{-1}$) promedio por partido estimado hasta el metro de profundidad del perfil del suelo o hasta el límite superior de la capa petrocálcica.

En la **Figura 2.7.A.** se presenta la variable arcilla más limo por partido con un amplio rango de variación desde 205 a 996 $g\ kg^{-1}$ a escala regional. Los suelos más arcillosos y limosos se encuentran en lo que corresponde a la Pampa Ondulada y los más arenosos se ubican en la Región Semiárida Pampeana. El patrón espacial que se observa en este mapa corresponde a la deposición eólica de loess pampeano que tuvo una dirección de sudoeste a noreste y como consecuencia no se observa un gradiente de norte a sur. Los suelos de los partidos del este de la Provincia de Córdoba tienen contenidos de arcilla+limo altos. Los suelos del oeste, en la Región Semiárida, tienen el mayor contenido de arena y los suelos de la Pampa Mesopotámica y Pampa Ondulada los menores.

En coincidencia con la distribución espacial del contenido de arcilla+limo se observa la distribución de la CAAU en el primer metro del perfil de los suelos pampeanos por partido (**Figura 2.7.B.**). Los suelos con la capacidad de retención de agua mayor se ubican en la porción húmeda y específicamente en la Pampa Ondulada y Pampa Mesopotámica y llegan a valores de 200 mm hasta el primer metro de profundidad. Los suelos de la Pampa Austral podían almacenar hasta 100 mm de agua útil en promedio y esto se relaciona a los suelos someros de esta sub-región que pueden almacenar menos agua que suelos más profundos. Los suelos arenosos del oeste semiárido tienen baja retención de agua.

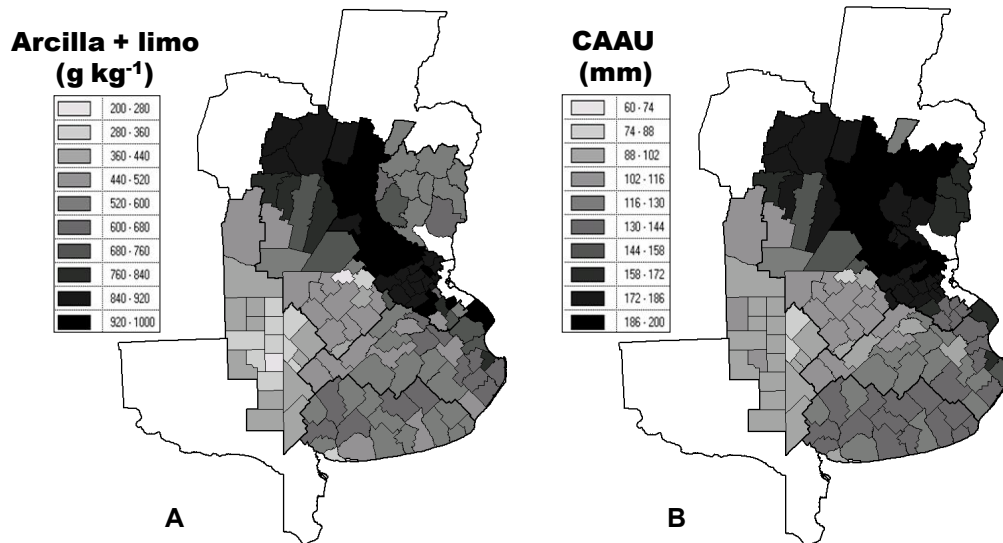


Figura 2.7.A. Distribución geográfica del contenido de arcilla + limo promedio y **B.** la CAAU (capacidad de almacenamiento de agua útil) estimada a través de las funciones de pedotransferencia de Rawls et al. (1982) hasta un metro de profundidad o hasta el límite superior de la capa petrocálcica.

Se utilizó la CAAU promedio de los suelos durante los 40 años analizados ya que se asumió que no hubieron cambios significativos en la textura y tampoco en la profundidad de los mismos entre la primera (1967-1976) y la última década (1997-2006) del análisis. La textura y la profundidad son características estables que varían muy lentamente a lo largo de los años (Gee y Bauder 1996). En la Pampa Ondulada se han estimado pérdidas de suelo hasta los primeros 3 cm del perfil de suelo por erosión hídrica (Alvarez 2001). La pérdida de suelo por erosión es menor y el contenido de carbono orgánico que se podría haber perdido en esos pocos centímetros igualmente afecta muy poco la CAAU de los suelos pampeanos (De Paepe y Alvarez, 2012) por lo que se asume un valor de CAAU para todo el período estudiado. El método de Rawls (1982) estima la CAAU por capa de suelo en función del espesor del mismo, su textura y porcentaje de materia orgánica. Las dos primeras variables tienen un impacto enorme en la estimación pero no así la tercera (De Paepe y Alvarez, 2012). Dentro de los rangos comunes de variación de la materia orgánica en suelos pampeanos esta variable afecta en no más de un 10% la CAAU de los suelos pampeanos si se desglosa el efecto de la textura (Alvarez y Steinbach, 2012). Versiones más modernas del método de Rawls et al. (2003) arrojan similares resultados (datos no presentados). De esto resulta que la relación entre CAAU y carbono orgánico resultó poco estrecha en el set de datos **Figura 2.8.A**, asociándose CAAU principalmente a textura **Figura 2.8.B**. Tampoco la profundidad tuvo mucho efecto en este set de datos porque no sufrió variaciones importantes entre unidades geográficas (+-10%).




Figura 2.8.A. Relación entre el contenido de carbono orgánico y la capacidad de almacenamiento de agua útil para el gradiente regional pampeano abarcado. **B.** Relación entre el contenido de arena hasta el primer metro de profundidad y la capacidad de almacenamiento de agua útil correspondiente a la misma profundidad.

En cuanto a la distribución espacial del carbono orgánico se observaron los valores más altos en los partidos correspondientes a la Mesopotamia con valores estimados de 66.3 t ha⁻¹ hasta los primeros 50 cm y 86.1 t ha⁻¹ hasta el primer metro de profundidad (o hasta el límite superior de la capa petrocálcica). En los primeros 50 cm del perfil se encontró en promedio de toda la región 92.9 t ha⁻¹ y los valores más bajos en la Región Semiárida Pampeana con un promedio de 49.3 t ha⁻¹ (**Figura 2.9.A.**). Los suelos de la Pampa Ondulada y de la Pampa Austral varían entre 63 t ha⁻¹ y 108 t ha⁻¹. Estos datos de carbono orgánico de los mapas de INTA fueron utilizados para la primera década analizada (1967-1976).

Berhongaray et al. (2013) estimaron el contenido de carbono orgánico por partido con una red neuronal artificial basado en la información de un muestreo realizado durante 2007 y 2008. El contenido estimado de carbono orgánico promedio hasta los primeros 50 cm fue de 65.7 t ha⁻¹ y hasta el primer metro de profundidad de 91.6 t ha⁻¹. El contenido de carbono orgánico almacenado en los primeros 50 cm del perfil fue similar a lo que se observó en los datos de los mapas de suelo de INTA. En el **Figura 2.9.B.** se observa la distribución espacial del contenido de carbono orgánico estimado por partido que comparada con el mapa resultante de la integración de los mapas de suelos de INTA presenta una especie de uniformización espacial de los contenidos con menos valores extremos. Los valores más altos corresponden a los partidos de la Pampa Austral (con valores de 97-108 t ha⁻¹, de 0-50 cm) y los partidos con los menores contenidos se ubican en la Región Semiárida Pampeana (53.3 t ha⁻¹, de 0-50 cm).

La distribución del contenido de nitrógeno total de los primeros 25 cm del perfil de suelo fue muy similar a la de carbono orgánico la correlación de ambas variables edáficas es positiva y significativa ($R^2 = 0,741$, $P = 0,05$). Por esta alta relación utilizó únicamente la variable carbono orgánico en los análisis. La relación C/N del estrato 0-25 cm de suelo tiene un promedio de 9.24 y el rango varía desde 5.0 hasta 12.8.

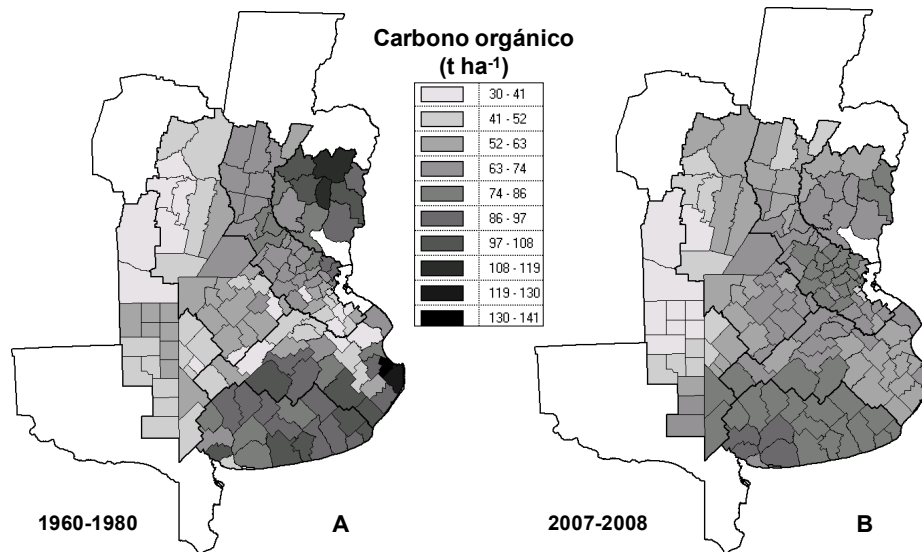


Figura 2.9. A. Distribución geográfica del contenido de carbono orgánico por partido hasta un metro de profundidad basado en los datos publicados de los mapas de suelo de INTA y **B.** el contenido por partido estimado como por Berhongaray et al. (2013)

2.2.3. Manejo

Se realizó la agregación espacial de la información disponible de dosis de fertilizante, sistema de labranza y mejora genética. Se utilizaron los datos de prácticas de manejo para el cultivo de trigo no publicados provenientes del proyecto RIAN (Red de Información Agropecuaria Nacional) correspondientes a las campañas 2002-2006 y disponibles a pedido (RIAN, 2014). La información solicitada proviene de encuestas a productores y su ubicación fue a nivel partido. Se estimó la dosis aplicada de nutrientes, nitrógeno y fósforo, a partir del porcentaje del nutriente en los fertilizantes comúnmente aplicados en la Región Pampeana para trigo: urea (46, 0), urea más nitrato de amonio (UAN) (31, 0), fosfato mono-amónico (11, 23), fosfato di-amónico (18, 20) y superfosfato triple (0, 20) (Álvarez et al., 2013). En las encuestas también se incluye información sobre el momento de aplicación de fertilizantes.

Con esta información se estimaron los promedios ponderados por la superficie aplicada por partido de la dosis de nutriente de las campañas disponibles. Se estimó la dosis promedio de las campañas 2002-2006 aplicada de nutrientes de 75 partidos. Con esta información por partido se generó un mapa de interpolación con el método del inverso a la distancia con la extensión Spatial Analyst de ArcGIS 9.1 (ESRI, Copyright © 2005). La interpolación permitió estimar las dosis de nitrógeno y fósforo de fertilizantes para todos los partidos de la Región Pampeana. Se utilizó la tendencia nacional de consumo de fertilizantes nitrogenados y fosfatados, la Región Pampeana representa 80 % del consumo nacional, (Álvarez et al., 2013) para estimar la dosis de nutrientes desde las campañas recientes del mapa de interpolación.

Se hicieron consultas a expertos acerca de los sistemas de labranza predominantes por sub-región pampeana y por década (comunicación personal M. Taboada para la Pampa Ondulada, G. Studdert para la Pampa Austral, A. Bono para la Región Semiárida y Pampa Arenosa y C. Quintero para la Pampa Mesopotámica). Los sistemas de labranza analizados fueron: labranza convencional (remoción del suelo con reja o disco), labranza reducida (movimiento de suelo con cincel o discos más verticales) y siembra directa. Se calculó el porcentaje de siembra directa más labranza reducida por partido (labranza reducida + siembra

directa/ labranza convencional + labranza reducida + siembra directa).

Se estimó la evolución de la mejora genética en trigo teniendo en cuenta la distribución espacial del rendimiento potencial del cultivo a nivel de la Región Pampeana y su velocidad de cambio. El rendimiento potencial por sub-regiones se tomó de Magrin (2004), que estimó, usando el modelo de simulación CERES-Wheat, dicha variable para los cultivares Pro-INTA Oasis y Baguette 10, ampliamente difundidos en toda la Región Pampeana. Con el mapa de rendimiento potencial se calcularon los rendimientos potenciales de trigo por partido por interpolación aplicando la extensión de Geoprocessing de ArcGIS 9.1 (ESRI, Copyright © 2005). Se asumió que el valor del rendimiento estimado con el modelo de simulación por partido representaba el rendimiento potencial que se puede alcanzar en ese partido en relación a los demás y al máximo rendimiento se asignó un valor de 1, relativizando los demás valores. Esos valores asumidos para la última campaña del análisis de la serie histórica de la tesis se redujeron anualmente con la pendiente de la mejora genética de trigo estimada localmente por Calderini et al. (1995). En este estudio se analizaron los resultados de ensayos experimentales con siete cultivares de trigo que fueron liberados durante el Siglo XX. La pendiente de la mejora genética fue estimada como el cociente entre la diferencia entre los rendimientos alcanzados y la diferencia entre los años analizados para el primer y último año de liberación de los cultivares después del año 1900. La pendiente promedio reportada fue de 0,741 %. Con este coeficiente se afectó a todos los rendimientos potenciales relativos al máximo; de esta manera se estimó la mejora genética por partido. Se asumió un incremento lineal y constante de la mejora genética con el tiempo.

Como resultado de la agregación espacial realizada se determinó que en la Región Pampeana la aplicación de fertilizantes para el cultivo de trigo empezó durante la campaña 1984 (Álvarez et al., 2013; RIAN 2014). Durante las primeras campañas la dosis promedio de fertilizante nitrogenado aplicado era de 10 kg N ha⁻¹ mientras que durante las últimas campañas se incrementó hasta alcanzar los 80 kg N ha⁻¹. La correlación de la dosis de nitrógeno en fertilizante fue significativa con el tiempo ($R^2 = 0,69$; $P = 0,05$). La misma tendencia se observó para el nutriente fósforo. La aplicación de fertilizantes nitrogenados está altamente relacionada a la aplicación de fertilizantes fosfatados ($R^2 = 0,83$; $P = 0,05$).

Durante la primera década analizada (1967-1976) el sistema de labranza predominante en todas las sub-regiones pampeanas fue la labranza convencional mientras que durante la última década lo fue la siembra directa (**Cuadro 2.3**). Actualmente 50 % de la superficie cultivada con trigo de la Pampa Ondulada ocurre bajo siembra directa. La proporción de labranza reducida y siembra directa sobre el total aumenta significativamente con el tiempo ($R^2 = 0,59$; $P = 0,05$).

Cuadro 2.3. Sistemas de labranza predominantes por década analizada en esta tesis y por sub-región pampeana. La información está basada en la comunicación personal con expertos y se presenta en forma de porcentaje.

Década	Labranza convencional (%)	Labranza reducida (%)	Siembra directa (%)
Pampa Mesopotámica			
1967-1976	100	0	0
1977-1986	100	0	0
1987-1996	80	0	20
1997-2006	20	0	80
Pampa Ondulada			
1967-1976	95	5	0
1977-1986	70	20	10
1987-1996	30	35	35
1997-2006	10	40	50
Pampa Arenosa = Región Semiárida Pampeana			
1967-1976	100	0	0
1977-1986	100	0	0
1987-1996	80	0	20
1997-2006	60	0	40
Pampa Austral			
1967-1976	100	0	0
1977-1986	95	5	0
1987-1996	90	10	0
1997-2006	45	20	35

En cuanto a la mejora genética se estimó que el rendimiento relativo al máximo para la campaña 1967 para todos los partidos fue de 0,612% de incremento de rendimiento por año llegando hasta 0,818 para la campaña 2006, el rango fue de mínimo 0,506 y máximo 1. La mejora genética tiene una relación significativa con el tiempo ($R^2 = 0,46$; $P = 0,05$).

En el **Cuadro 2.4.** se presenta la matriz de correlación entre las variables de manejo agregadas a la escala partido y el rendimiento. El rendimiento de trigo por partido se correlacionó con las tres variables pero principalmente con la mejora genética y la proporción de siembra directa más labranza reducida. Las tres variables de manejo se encontraron fuertemente correlacionadas con la variable campaña (el tiempo). El nitrógeno de fertilizantes se encontró significativamente relacionado a la mejora genética y también a la proporción de siembra directa más labranza reducida. Por esta alta correlación de estas variables de manejo entre sí se va a utilizar la variable campaña como sustituta de las mismas, no pudiéndose desglosar el efecto independiente de cada una de ellas sobre el rendimiento de trigo.

Cuadro 2.4. Coeficientes de correlación de Pearson entre el rendimiento de trigo, campaña y las variables de manejo integradas a nivel partido ($P = 0,05$). $n = 1640$.

	Campaña	Rendimiento (kg ha ⁻¹)	N - fertilizante (kg ha ⁻¹)	(Lab. Red + Siembra directa)/ total (%)
Rendimiento (kg ha⁻¹)	0,612			
N - fertilizante (kg ha⁻¹)	0,834	0,647		
(Lab. Red + Siembra directa)/total (%)	0,766	0,534	0,724	
Mejora genética relativa (%)	0,680	0,679	0,683	0,482

Lab. Red. = labranza reducida.

2.2.4. Rendimiento

Con los datos de producción (t) y superficie sembrada (ha) por partido y por campaña publicados por el Ministerio de Agricultura, Ganadería y Pesca (MinAgri 2014) se calculó el rendimiento promedio de trigo (kg ha⁻¹) por partido y por campaña. Este cálculo se realizó para 165 partidos de las Provincias de Buenos Aires, Córdoba, Entre Ríos, La Pampa y Santa Fe desde la campaña 1967 hasta la campaña 2006. El conjunto total de datos de rendimientos fue de aproximadamente 6600 ($n = 165$ partidos x 40 campañas).

El rendimiento de trigo varió significativamente entre los 165 partidos y a lo largo de los 40 años analizados mostrando una clara evolución positiva con el tiempo, con un aumento

de rendimiento promedio por campaña de 36.9 kg ha^{-1} (**Figura 2.10.**). El rango de rendimiento alcanzado por partido varió desde un mínimo de 400 kg ha^{-1} hasta un máximo de 4600 kg ha^{-1} con un promedio regional de 1921 kg ha^{-1} . La variabilidad espacial, es decir la diferencia entre rendimientos máximos y mínimos alcanzados, desde la primera campaña hasta la última campaña del set de datos también aumenta. La diferencia entre el rendimiento máximo y mínimo para la campaña de 1967 es de 1500 kg ha^{-1} mientras que la diferencia aumenta a 3800 kg ha^{-1} para la campaña 2006.

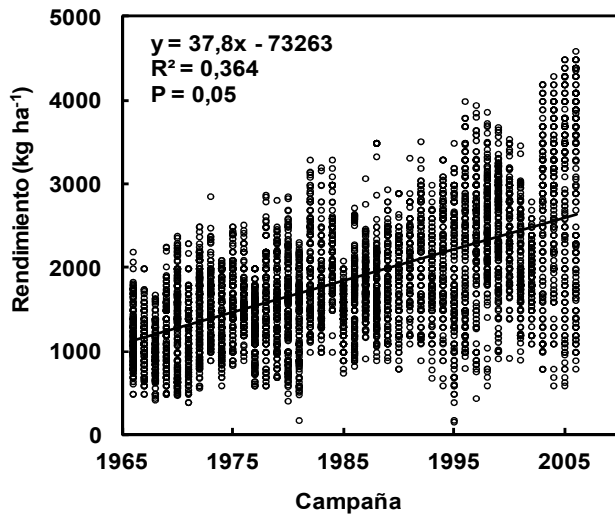


Figura 2.10. Evolución en el tiempo del rendimiento de trigo por partido de la Región Pampeana desde la campaña 1967 hasta 2006.

A la información de los 165 partidos se le descontó la información de 51 partidos, resultando en un total de 114 partidos, el set de datos fue de 4560 ($n = 114$ partidos \times 40 campañas). De estos 51 partidos excluidos del análisis, 40 pertenecían a la sub-región Pampa Deprimida. No fueron incluidos en el análisis regional ya que en esta sub-región pampeana predominan los suelos hidromórficos que no son aptos para el uso agrícola y esto significa que en estos partidos, mucho más que en otros, se hace una selección de sitios aptos para el cultivo de trigo. En estos partidos la superficie sembrada con trigo fue menor al 30 % de la superficie política total durante los 40 años analizados, indicando que este cultivo no es un constituyente principal de las rotaciones de cultivos anuales (MinAgri 2014). El dato de suelo agregado de los mapas de suelo de INTA no correspondería a la condición promedio de los suelos cultivados de estos partidos. Los 11 partidos restantes que tampoco fueron incluidos no contaban con información de superficie sembrada y/o producción para las 40 campañas consideradas.

Debido a la variabilidad climática interanual, se observaron diferencias de rendimiento de hasta 6 veces en algunos partidos al comparar el rendimiento más alto con el más bajo de la serie temporal analizada. El rendimiento alcanzado aumentó un 60 % al comparar el rendimiento promedio de la primera campaña vs. la última campaña. En promedio para las 40 campañas, en los partidos de la porción húmeda (comprende la Pampa Ondulada y Pampa Mesopotámica) los rendimientos fueron aproximadamente 28 % mayor que los rendimientos observados en la Región Semiárida Pampeana. En la **Figura 2.11.A.** y **B.** se muestra la distribución espacial de los rendimientos alcanzados por partido durante el primer (1967-1971) y último quinquenio (2002-2006) analizados. Especialmente se puede inferir que los rendimientos más altos alcanzados en ambos quinquenios se relacionan consistentemente a los mismos partidos, es decir a las mismas condiciones biofísicas.

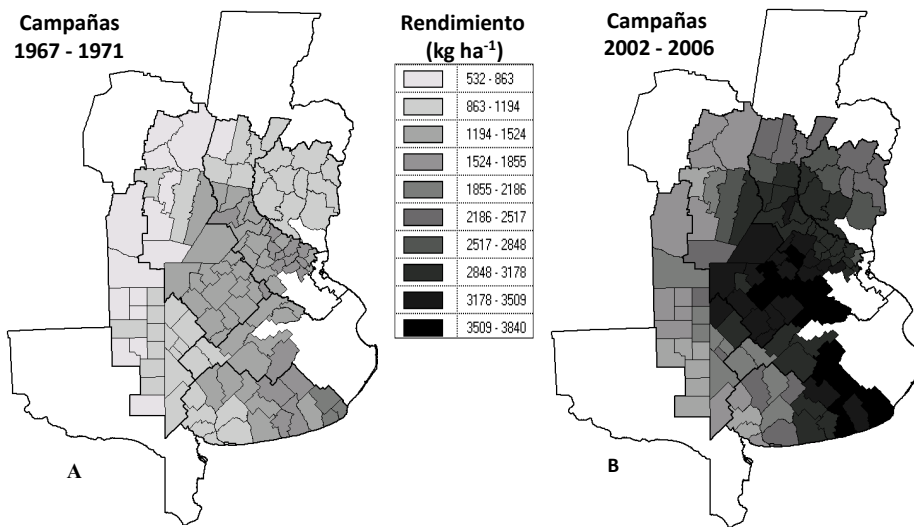


Figura 2.11.A. Distribución geográfica del rendimiento alcanzado por partido durante la primera campaña (1967) y **B.** la última campaña (2006).

Relacionado al incremento del rendimiento alcanzado por partido la evolución de la producción de trigo promedio por campaña de la Región Pampeana también tuvo una tendencia lineal positiva con el tiempo durante las 40 campañas analizadas (**Figura 2.12.A.**). Por otro lado, se observa que la superficie sembrada con trigo regional no fue modificada significativamente para la serie temporal analizada y se mantuvo relativamente constante sin observarse aumentos ni disminuciones significativas (**Figura 2.12.B.**). Esto implica que el aumento en el rendimiento de trigo a nivel de la Región Pampeana no se dió por el corrimiento de la frontera agrícola de éste cultivo hacia el oeste o norte del país, como sí sucedió con otros cultivos anuales, sino más bien por mejoras tecnológicas que permitieron aumentar el rendimiento sin necesidad de expandir el área de producción.

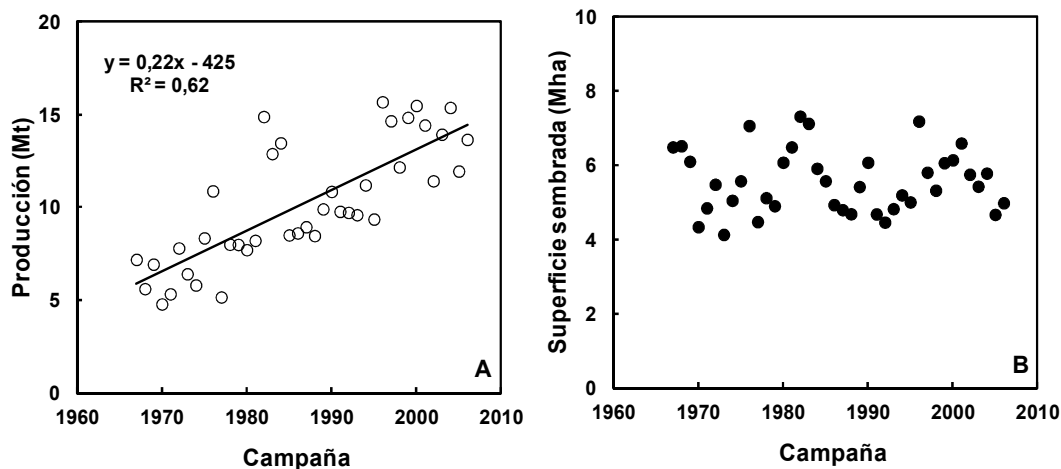


Figura 2.12.A. La evolución promedio por campaña en el tiempo de la producción total de trigo (Mt) desde 1967 hasta 2006. **B.** Evolución en el tiempo de la superficie sembrada (Mha) promedio por campaña para todo el período analizado.

2.3. Escala de análisis regional - Unidad geográfica

La diferencia máxima en superficie política entre el partido más extenso y el más pequeño fue de hasta 30 veces con muchos valores intermedios. Se ha demostrado para otras regiones que estas diferencias en superficie pueden llevar a errores estadísticos ya que no son comparables por lo que es mejor agregar espacialmente la información a unidades de análisis de superficies similares (Monfreda et al., 2008). Se han comparado dos bases de datos de producción de cultivos en la Región Pampeana, la Bolsa de Cereales de Buenos Aires y la base de datos del Ministerio de Agricultura, Ganadería y Pesca de la Nación, y se observó que cuanto más grande es la superficie de los partidos menor es la diferencia de rendimiento publicada (Sadras et al., 2014). Por esto se agregó espacialmente la información por partido a escala unidad geográfica.

La información de 114 partidos fue agregada a 41 unidades geográficas de un área promedio de 1 Mha \pm 0,5 Mha, es decir que el n para esta escala de análisis es 1640 ($n = 41$ unidades geográficas \times 40 años) (**Figura 2.13.**). Las unidades geográficas en promedio agregan información de tres partidos. La agregación espacial fue llevada a cabo utilizando como características de clasificación el relieve, tipo de paisaje y clases de suelo previamente definidas para las sub-regiones pampeanas (Alvarez y Lavado 1998). La información de los partidos fue agregada aplicando promedios ponderados por partido y corregidos por su área de influencia.

Se estimó precipitación anual por partido como el promedio de la sumatoria de la precipitación de todos los meses desde el año 1967 hasta el año 2006. Con esta información se delimitó la isohieta de 800 mm de precipitación anual para estas 40 campañas para dividir a la región y definir la porción húmeda hacia el este y la porción semiárida hacia el oeste. La porción húmeda fue delimitada de la porción semiárida respetando los contornos de los límites políticos de los partidos que conforman los partidos de las unidades geográficas.




Figura 2.13. Distribución de las 41 unidades geográficas. El color gris claro denota una situación climática semiárida y el color gris oscuro representa la porción más húmeda pampeana. La división se realizó utilizando la isohieta anual histórica de 800 mm.

Se examinó la asociación, a través de una matriz de correlación de Pearson, entre el rendimiento de trigo por unidad geográfica para las 40 campañas analizadas con las variables biofísicas, clima y suelo, y la variable campaña como sustituta de las variables de manejo (**Cuadro 2.5.**). Como ya se había observado, el rendimiento tiene una relación positiva fuerte con la variable campaña. En cuanto a las variables de clima, el rendimiento se asocia a la

precipitación y a la relación precipitación/ETP durante el barbecho y negativamente a la temperatura durante el período de floración. En cuanto a las variables de suelo, el rendimiento se asocia levemente con el contenido de carbono orgánico de los suelos.

El contenido de carbono orgánico de los suelos se asoció positivamente a la precipitación de todos los períodos y la relación precipitación/ETP durante el barbecho y la fase vegetativa pero se asoció negativamente a la temperatura durante los tres períodos del cultivo (**Cuadro 2.5**). Las unidades geográficas más húmedas y menos cálidas tenían más carbono en su perfil (**Cuadro 2.5**). La variabilidad del carbono orgánico también pudo ser explicada por su relación con la CAAU de los suelos, la relación fue positiva lo que implicó que los suelos con mayor capacidad de retención de agua también tienen más carbono, aunque como ya se mostró la relación fue laxa. La textura y la profundidad del suelo regularon la producción primaria a través de la capacidad de almacenamiento de agua. Suelos con mayor capacidad de almacenamiento tienen mayor productividad primaria (Quiroga et al., 1996; Alvarez, 2009). Suelos más profundos tenían mayores contenidos de carbono orgánico. Cuando la precipitación no fue limitante, las arcillas tuvieron un efecto positivo sobre la productividad primaria neta pero cuando las precipitaciones fueron escasas el efecto fue negativo (Epstein et al., 1997). Además, se ha atribuido a las partículas finas un efecto protector de la degradación microbiana de la materia orgánica (Hassink, 1997). Se observó además que la CAAU se asoció positivamente a las variables de temperatura y precipitación pero la relación es negativa con el cociente fototérmico (**Cuadro 2.5**). Esto último no se debe a una relación funcional sino a que en el sur de la Región Pampeana aumenta el coeficiente fototérmico pero tiende a decrecer la CAAU de los suelos.

La asociación entre las variables de temperatura durante el barbecho, la fase vegetativa y la floración no fue fuerte y tampoco su asociación con la precipitación durante los mismos períodos (**Cuadro 2.5**). La relación entre la precipitación y el índice climático precipitación/ETP durante los tres períodos se encontraba relacionada. La asociación entre el cociente fototérmico y la temperatura durante la floración fue fuerte y esto se vinculó a que el período abarcado en el cálculo de coeficiente abarcó el mes de octubre que fue uno de los meses de la floración del cultivo.

Cuadro 2.5. Coeficientes de correlación de Pearson de las variables de clima y suelo por unidad geográfica. Cuando la probabilidad no fue significativa se usó la abreviatura “ns” (P = 0,05). n = 1640

	Rendimiento	Campaña	Carbono orgánico	CAAU	T barb.	T fase veg.	T flor.	Precip. Barb.	Precip. fase veg.	Precip. flor	Precip/ETP barb.	Precip/ETP fase veg.	Precip/ETP flor
Campaña	0,613												
Carbono orgánico (t ha⁻¹)¹	0,186	-0,061											
CAAU (mm)²	0,080	ns	0,281										
Temperatura barbecho (°C)³	-0,072	ns	-0,187	0,607									
Temperatura fase vegetativa (°C)⁴	-0,124	ns	-0,221	0,598	0,790								
Temperatura floración (°C)⁵	-0,164	0,074	-0,402	0,492	0,658	0,793							
Precip. barbecho (mm)³	0,241	0,135	0,305	0,278	0,282	0,078	-0,057						
Precip. fase vegetativa (mm)⁴	0,085	-0,098	0,389	0,134	ns	ns	-0,161	0,068					
Precip. floración (mm)⁵	0,050	0,110	0,068	0,212	0,199	0,178	0,172	0,233	0,191				
Precip/ETP barbecho³	0,287	0,148	0,386	0,117	ns	-0,140	-0,261	0,938	0,088	0,151			
Precip/ETP fase vegetativa⁴	0,165	-0,051	0,461	ns	-0,272	-0,286	-0,404	ns	0,931	0,118	0,141		
Precip/ETP floración⁵	0,116	0,095	0,201	0,062	ns	-0,053	-0,129	0,225	0,280	0,933	0,219	0,296	
Coef. fototérmico (MJ m⁻² d⁻¹ °C⁻¹)⁶	ns	-0,164	0,292	-0,397	-0,517	-0,616	-0,762	-0,079	ns	-0,503	0,075	0,157	-0,287

ETP = ETP del cultivo. ¹ de 0-50 cm de profundidad, ² de 0-100 cm de profundidad o hasta el límite superior de la capa petrocálcica en caso de presentarse, ³ abril-mayo-junio, ⁴ julio-agosto-septiembre, ⁵ octubre-noviembre, ⁶ período crítico de un mes antes de antesis (octubre).

2.4. Escala de análisis sitio

2.4.1. Información de ensayos experimentales

Se utilizó información publicada de 217 ensayos de fertilización y 130 lotes de producción correspondientes (n = 347) al período 1996-2001 ubicados en la Pampa Ondulada (Alvarez y Grigera 2005). Los sistemas de labranza fueron labranza con arado de raja y vertedera (n = 77), rastras, discos o siembra directa (n = 270). El cultivo antecesor fue soja (n = 63) y otros cultivos con predominancia de maíz (n = 284). Los suelos de esta sub-región son profundos y principalmente Argiudoles y Hapludoles y no presentan limitantes para el cultivo de trigo.

Para la Región Semiárida Pampeana se utilizó información publicada de 85 ensayos de fertilización realizados durante 1996-2004 que por la combinación de año x sitio x manejo resultaron en un set de datos de 912 (Bono et al., 2010). Los sistemas de labranza fueron con remoción (rastras y discos) (n = 693) y siembra directa (n = 219). Los cultivos antecesores fueron girasol (n = 465), soja (n = 201), trigo (n = 128) y otros cultivos (n = 118). Los suelos de esta sub-región no son profundos en muchos casos y la capa petrocálica se presenta a menos de un metro de profundidad, se encuentran principalmente Haplustoles, Hapludoles y Ustipsaments.

El diseño experimental de ambas redes de ensayos fue variable estando los experimentos en general bloqueados con 3 repeticiones asignadas al azar dentro de cada bloque y cada valor de rendimiento reportado es el promedio de por lo menos 3 repeticiones por tratamiento.

Los ensayos fueron instalados en distintos tipos de suelos, con profundidades y texturas muy contrastantes (**Cuadro 2.6**). En todos los experimentos se comparó un testigo no fertilizado con tratamientos fertilizados con distintas dosis de N y P. El efecto del momento de aplicación del fertilizante y la fuente no fueron significativos por lo que los datos de rendimiento fueron promediados por tratamiento. Los fertilizantes nitrogenados fueron aplicados al voleo en diferentes momentos del ciclo del cultivo y los fosforados incorporados en bandas a la siembra. A la siembra se determinó (para el estrato superior de 0-20 cm de profundidad): materia orgánica, nitratos a la siembra y fósforo extractable. Se registraron las precipitaciones mensuales desde la siembra hasta la cosecha en cada sitio. En madurez fisiológica del cultivo se determinó el rendimiento del grano (14 % de humedad).

Estos datos a escala sitio van a ser utilizados para validar la información a escala regional generada en los capítulos de resultados posteriores.

Cuadro 2.6. Rango y promedio de algunas de las características de suelo, clima y manejo medidas en los ensayos experimentales realizados en la Pampa Ondulada y la Región Semiárida Pampeana.

Pampa Ondulada								
Profundidad	Materia orgánica	Precipitación	N-NO ₃ siembra	Dosis N fertilizante	P disponible	Dosis P fertilizante	Rendimiento	
suelo (cm)	0-20 cm (%)	ciclo (mm)	(kg ha ⁻¹)	(kg ha ⁻¹)	(kg ha ⁻¹)	(kg ha ⁻¹)	(kg ha ⁻¹)	
Máximo	5,93	615	196	132	182	40	6250	
Mínimo	1,88	189	4,7	0	10,4	0	640	
Promedio	> 100	2,81	453	50,6	54,8	34,6	17,2	3044

Región Semiárida Pampeana								
Profundidad	Materia orgánica	Precipitación	N-NO ₃ siembra	Dosis N fertilizante	P disponible	Dosis P fertilizante	Rendimiento	
suelo (cm)	0-20 cm (%)	ciclo (mm)	(kg ha ⁻¹)	(kg ha ⁻¹)	(kg ha ⁻¹)	(kg ha ⁻¹)	(kg ha ⁻¹)	
Máximo	> 100	3,21	543	91,7	150	129	31	5699
Mínimo	40,0	0,65	38,1	6,67	0	1,58	0	197
Promedio	70,5	1,66	306	22,9	69,9	40,1	20,6	2241

2.4.2. Información de experimentos de la red INASE para validación de EPIC

Se generó otra base de datos con información de ensayos experimentales que forman parte la RET (Red de Ensayos de Cultivares de Trigo) del INASE (Instituto Nacional de Semillas) (INASE 2014) y de boletines de extensión de INTA (INTA 2008; Romano 2010) para la validación del modelo EPIC. Los resultados de estos experimentos se tomaron como determinaciones de rendimiento alcanzable por ser los experimentos controlados para evitar problemas de adversidades y manejo. Las cinco localidades elegidas por contar con datos generales y específicos fueron: Anguil (campañas 2008 y 2010), Balcarce (campañas 2008, 2009, 2010), Manfredi (campañas 2005, 2007 y 2010), Rafaela (campañas 2005, 2007, 2009 y 2010) y Venado Tuerto (campañas 2005 y 2007). Las localidades presentan una amplia distribución geográfica lo que permitiría correr el modelo para gran parte del gradiente edafoclimático del área de estudio.

2.5. Consideraciones finales

Para evaluar el rendimiento de trigo en la Región Pampeana fue necesario abarcar los amplios rangos de las variables biofísicas que caracterizan a la región. Los datos de rendimiento publicados en las estadísticas nacionales se pueden calcular por partido por lo que fue inevitable agregar la información de clima, suelo y manejo disponible a esta escala. A lo largo de la serie temporal se observa que en los partidos con rendimientos altos consistentemente se alcanzan valores altos en las primeras y últimas campañas de los 40 años analizados. La base de datos descripta comprende la escala de análisis regional (partidos y unidades geográficas) y sitio (ensayos experimentales) y fue generada para alcanzar los objetivos e hipótesis específicas de los capítulos que siguen.

La generación de 1440 mapas de interpolación de datos climáticos para agregar la información a la escala partido permitió incluir la Región Semiárida Pampeana donde se cultiva trigo bajo condiciones semiáridas con precipitaciones promedio de 255 de mm durante el ciclo y las sub-regiones más húmedas con precipitaciones promedio de 388 mm. Esta amplia variación se relaciona además al índice precipitación/ETP del cultivo que incluye partidos donde las precipitaciones representan menos de la mitad del agua evapotranspirada y partidos adonde las precipitaciones superan hasta 2 veces el agua que se pierde a la atmósfera.

Se modelizaron en profundidad 7000 combinaciones de perfil x variable de suelo de los mapas de suelo de INTA para agregar esta información a la escala partido y se observa un rango amplio de texturas y profundidades de los suelos. Los partidos con las texturas más gruesas se ubican en el sudoeste y las texturas más finas se ubican en el noreste pampeano, pasando por varias composiciones intermedias. La profundidad del suelo es una limitante del rendimiento de trigo y la presencia de la capa petrocálcica a menos de un metro de profundidad fue detectada en suelos de la Región Semiárida pero sobre todo en los suelos de la Pampa Austral. La variable CAAU integra ambas propiedades edáficas, copia en parte su distribución espacial y varía de 77 mm a 211 mm.

Como el contenido de carbono de los suelos fue variable en el tiempo y sobre todo porque puede ser afectado por el manejo agrícola se agregó la información de los mapas de suelo de INTA aplicable a la primera década y para la última década se utilizó información reciente de Berhongaray et al. (2013). Comparando el carbono orgánico correspondiente a ambas décadas parece haberse uniformizado espacialmente su distribución. El pH promedio de los suelos pampeanos se aproxima a la neutralidad y el carbono de carbonatos presenta el rango más amplio de todas las variables edáficas integradas ya que en varios partidos no se presenta mientras que en otros partidos alcanza valores de 200 t ha^{-1} cuando se detecta la capa

de tosca. Suelos más finos se relacionan a una posible productividad primaria mayor bajo condiciones climáticas húmedas al igual que suelos más profundos.

Las variables de manejo agregadas a la escala partido, principalmente provenientes de encuestas del RIAN, se encuentran muy relacionadas significativamente entre sí y sobre todo con el tiempo por lo que se va a utilizar el tiempo como sustituta de los cambios en las prácticas de manejo y la mejora genética del cultivo.

Por las grandes diferencias entre las superficies de los partidos pampeanos se agregó espacialmente la información a escala unidad geográfica para uniformizar el área de las unidades de estudio. Gran parte de la variabilidad interanual del rendimiento de trigo está explicada por el tiempo, la temperatura tiene un efecto negativo y las precipitaciones se asocian positivamente y en particular las que ocurren durante el barbecho. El rendimiento se relaciona positivamente con el contenido de carbono orgánico en los primeros 50 cm del perfil pero la relación e impacto de esta última variable sobre la CAAU de los suelos son bajas.

Con 1259 datos de ensayos experimentales que abarcan gran parte de la variabilidad de las características climáticas y edáficas de la Pampa Ondulada y la Región Semiárida Pampeana se van a validar las estimaciones generadas a escala regional de partido y/o unidad geográfica. Con datos del INASE se intentará validar el modelo EPIC.

CAPITULO 3 MODELIZACIÓN DEL RENDIMIENTO DE TRIGO

Development of a soil productivity index using an artificial neural network approach.

J.L. De Paepe y R. Alvarez. Agron. J. 105: 1803-1813. 2013.

CAPITULO 3. Modelización del rendimiento de trigo

3.1. Introducción

3.1.1. Interacción entre variables biofísicas

La generación de modelos cuantitativos de rendimiento de cultivos para la descripción de los sistemas naturales o alterados, como los agroecosistemas, y la toma de decisiones del manejo de recursos naturales debe ser considerada como prioritaria (Bellocchi et al., 2010). Esto se debe a que los modelos tienen una multitud de usos para científicos, gestores y responsables políticos que investigan y que manejan los recursos naturales. Con los modelos se pueden identificar incertidumbres y mejorar el conocimiento científico de los procesos biofísicos del rendimiento pero además pueden funcionar como herramientas de apoyo para la comunicación de cuestiones complejas para un público sin un *background* científico.

Para el caso del cultivo de trigo en la Región Pampeana, asociado a la amplia distribución espacio-temporal y su importancia agroeconómica, es necesario contar con un modelo regional explicativo del rendimiento por tres razones principales. En primer lugar, un modelo regional permitiría entender cuáles son las variables biofísicas que determinan la variabilidad del rendimiento. En segundo lugar, se podría evaluar si existen interacciones entre las variables de clima y/o suelo seleccionadas. Por último, se podría utilizar este modelo para la generación de un índice de productividad deductivo para zonificar la productividad de los suelos pampeanos que es una herramienta requerida por productores agrícolas y agentes oficiales.

Para obtener estimaciones del rendimiento de cultivos a nivel regional o nacional es necesario agregar información espacialmente. Existe un determinado nivel de agregación de datos en el que las variables se mantienen lo suficientemente preservadas (Easterling et al., 1998). Alejarse de éste nivel implicaría la pérdida de propiedades estadísticas y/o biológicas de las variables. No es sencillo determinar cuál es la escala óptima de análisis de un set de datos a nivel regional ya que hay varios factores biofísicos y/o de manejo afectando el rendimiento (LeDuc y Holt, 1987; Olesen et al., 2000). Existen varios estudios que ejemplifican la aplicación de modelos de estimación del rendimiento de cultivos para combinaciones de condiciones climáticas y edáficas de áreas pequeñas (Semenov et al., 1996; Brown y Rosenberg 1997) y algunos estudios regionales (García-Paredes et al., 2000; Kaul et al., 2005). Modelos generados a escala regional son útiles para el Estado mientras que los modelos a escala sitio las pueden utilizar los productores por esta razón es interesante evaluar si los modelos regionales pueden ser aplicables a escala sitio.

El rendimiento agregado de un cultivo es el resultado de la suma ponderada de rendimientos obtenidos bajo condiciones de clima, suelo y manejo distintas (Olesen et al., 2000). Las variables explicativas y su interacción afectan la variabilidad temporal y espacial del rendimiento agregado en un modelo empírico. Agregar información espacial implica promediar outliers de las variables independientes y con mejores resultados a medida que la superficie aumenta (Bakker et al., 2005). Los datos de rendimiento publicados por partido por el Ministerio de Agricultura de la Nación son promedios ponderados de rendimientos altos, medios y bajos (MinAgri, 2014).

La respuesta del rendimiento de trigo al agua almacenada en el suelo varía de acuerdo al régimen hídrico y al tipo de suelo (Anderson, 2010). Para el cultivo de trigo ante un escenario de baja precipitación y bajo contenido de agua útil almacenada en el suelo a la siembra se puede producir una desaceleración o finalización del proceso de germinación reduciendo la densidad de plantas y finalmente el rendimiento (Passioura, 2006). La cantidad y la distribución de las precipitaciones durante el ciclo de crecimiento de un cultivo son determinantes de la variabilidad temporal del rendimiento. En sitios con CAAU bajas se observan pérdidas de agua importantes por drenaje y son consistentemente sitios de

rendimientos bajos (Lawes et al., 2009). Estos sitios además tienen una variabilidad temporal alta ya que el agua adicional de las precipitaciones en años más húmedos es aprovechado con mayor eficiencia que en los sitios con CAAU más altos. Contrariamente, en los sitios con CAAU altas generalmente se observan rendimientos altos con respuestas menores y menos eficientes a las variaciones interanuales de las precipitaciones que resultan en una menor variabilidad temporal.

En Australia, durante años húmedos, la variabilidad espacial del rendimiento de trigo fue más pronunciada en suelos con CAAU mayor (Wong y Asseng, 2006). Cuando se presentan estaciones favorables en estos ambientes semiáridos, o sea las precipitaciones durante el crecimiento del cultivo son suficientes, la variabilidad espacial del rendimiento probablemente va a disminuir a menos de que el rendimiento esté fuertemente afectado por otro factor limitante (Lawes et al., 2009). Contrariamente, la variabilidad espacial aumenta en relación a la variación en la CAAU en estaciones con precipitaciones óptimas en fases tempranas de crecimiento pero continuadas por períodos posteriores de estrés hídrico. Diferencias en precipitaciones entre estaciones resultan en cambios en la estructura espacial del rendimiento a nivel regional y los suelos con CAAU más bajas son aquellos que muestran las diferencias más marcadas.

Así como se ha analizado la relación entre la CAAU, característica genética de los suelos, y la productividad de cultivos, también se ha examinado la relación del carbono orgánico de los suelos y su relación con esta productividad. Algunos estudios han encontrado correlaciones positivas y significativas entre el contenido de materia orgánica de los suelos y el rendimiento de cultivos (García-Paredes et al., 2000; Catching et al., 2002), pero otros no lo han detectado (Jiang y Thelen, 2004; Alvarez y Grigera, 2005).

Las leyes básicas de la fertilidad del suelo hacen referencia a la relación entre el rendimiento y el agregado de un nutriente esencial y limitante, caracterizado a través de una curva de respuesta. Para analizar la interacción entre variables edáficas y su relación con el rendimiento se puede hacer una analogía con estas leyes de fertilidad. La ley de los incrementos decrecientes, también denominada de rendimientos no proporcionales, propone que los rendimientos no aumentan en proporción directa al agregado de un nutriente y pueden ser representados con una función exponencial denominada “Mitscherlich” (Browne, 1942). Según esta función curva, cada agregado del nutriente limitante produce un incremento del rendimiento menor al rendimiento anterior. La tasa de incremento en el rendimiento es relativamente baja en el punto que corresponde a la máxima aplicación de un nutriente por lo que pareciera que la curva se acerca a un máximo a partir del cual cantidades adicionales del nutriente no resultan en rendimientos más altos. Se puede extrapolar esta relación nutriente-rendimiento a la relación de las variables de suelo que impactan el rendimiento. La respuesta a un nutriente o variable de suelo depende de la disponibilidad de otro y si las limitaciones son severas el rendimiento resultante tendría que ser bajo.

En la **Figura 3.1.** se observan las curvas de respuesta del rendimiento de un cultivo ante el aumento de una variable de suelo bajo incrementos de una segunda variable de suelo. La variable de suelo 1 podría ser el contenido de materia orgánica y la variable 2 la CAAU de un suelo. Utilizando esta figura como ejemplo teórico se podría plantear que cuando un suelo tiene un bajo contenido de materia orgánica, es decir que además se encuentra limitado en la provisión de nutrientes relacionada a esta característica edáfica, pero tiene una CAAU alta, el rendimiento resultante tendría que ser bajo. Lo mismo tendría que suceder en suelos que tienen contenidos de materia orgánica mayores pero con una CAAU baja. Como la Región Pampeana presenta un rango de amplio de características edáficas, donde se incluyen necesariamente escenarios con limitaciones severas de variables edáficas, comprende una oportunidad para el análisis de interacciones.

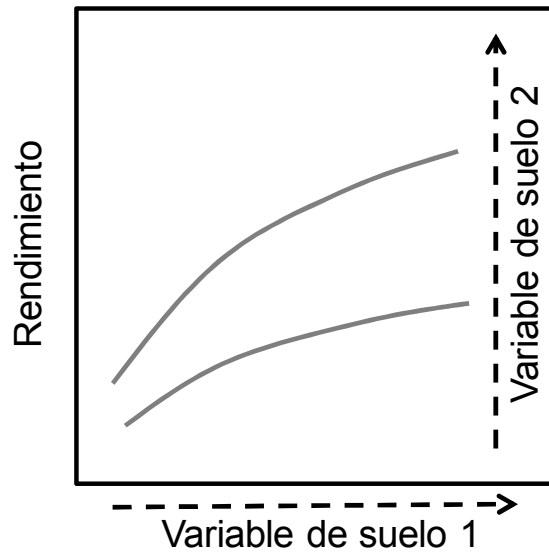


Figura 3.1. Curvas de respuesta hipotéticas que muestran la relación entre el rendimiento de un cultivo y el aumento de la variable de suelo 1 cuando se incrementa la variable de suelo 2. Las diferencias entre las pendientes expresan la interacción entre las variables de suelo.

A través de un modelo de regresión múltiple se explicó el 48 % de variabilidad del rendimiento de trigo de la Región Semiárida Pampeana (Bono y Alvarez 2009). La humedad a la siembra y variables relacionadas con una mayor capacidad de retención de agua en el perfil como la profundidad y la textura tuvieron incidencia significativa en el rendimiento. Este modelo predice los rendimientos más altos para la combinación de nitrógeno orgánico (0,15 %) y humedad a la siembra del cultivo de 450 mm hasta una profundidad de 140 cm. Los rendimientos menores se alcanzan cuando ambas variables alcanzan sus valores mínimos, es decir 0,03 % de nitrógeno orgánico y 70 mm de humedad, pero no detecta el modelo interacción entre ambas variables. Para la misma sub-región pampeana, con una red neuronal artificial (RNA) se pudo explicar el 90 % de la variabilidad del rendimiento de trigo pero las interacciones entre variables edáficas, en este último caso, no fueron analizadas (Bono et al., 2010).

En la Pampa Ondulada se pudo explicar el 67 % de la variabilidad interanual del rendimiento de trigo con una regresión múltiple con efectos significativos de: nitrógeno del suelo, fósforo disponible, fertilizante nitrogenado y fosfatado, precipitación y cultivo antecesor (Alvarez y Grigera 2005). El factor ambiental con más peso sobre el rendimiento fue la precipitación pero no se analizaron interacciones de distintos escenarios de la misma para distintas combinaciones de las otras variables independientes.

Existe una interacción positiva entre la disponibilidad de agua y la de nitrógeno en la determinación del rendimiento y la respuesta a la fertilización del cultivo de trigo en la Región Pampeana (Álvarez y Steinbach, 2013; Romano et al. 2015). Las respuestas a nitrógeno son mayores en zonas húmedas (Pampas Ondulada) que en zonas semiáridas (Región Semiárida Pampeana) y las pendientes de esta relación son distintas. La interacción positiva entre la precipitación y la fertilización nitrogenada también fue demostrada en dos localidades con regímenes de precipitación contrastante, Pergamino y Bordenave, con estimaciones del modelo de simulación CERES (Magrin, 1994), para la Pampa Ondulada para años húmedos, promedio y secos (Satorre et al., 2001) y en un trabajo regional sobre la mineralización de nitrógeno (Alvarez y Steinbach, 2011). A escala regional, se ha detectado el efecto significativo del carbono orgánico y la CAAU de los suelos sobre el rendimiento (Alvarez, 2009) pero todavía no se ha analizado si la interacción entre estas variables es significativa y tampoco se ha analizado la interacción bajo un gradiente climático amplio como tiene la Región Pampeana. El análisis de la interacción entre variables de suelo bajo escenarios

climáticos variados permitiría no sólo enriquecer el conocimiento científico sobre los agroecosistemas pampeanos sino también determinar prácticas de manejo ajustadas a la interacción mencionada (Wainwright y Mulligan, 2004).

3.1.2. Métodos de modelización empírica

Los modelos cuantitativos pueden ser empíricos o basados en procesos. Se define un modelo empírico como una reconstrucción aproximada de un fenómeno real y una integración de procesos naturales en fórmulas matemáticas (Bellocchi et al., 2010). Los modelos empíricos tienen varias aplicaciones entre las que se destacan: la exploración de interacciones e identificación de incertidumbres (Park et al., 2005). Modelos empíricos complejos suelen detectar más efectos significativos de variables independientes sobre la variable dependiente analizada que modelos más sencillos como regresiones simples por ejemplo. Esto implicaría que estos modelos empíricos permiten una mejor comprensión del proceso analizado. Métodos empíricos muy sencillos como la “adivinanza a ciegas”, que consiste en calcular promedios de rendimiento durante determinadas campañas, también pueden lograr ajustes muy buenos (Alvarez 2009).

Los modelos basados en procesos se construyen con ecuaciones matemáticas para modelizar las interacciones entre las variables ambientales y las del cultivo (Sinclair y Seligman 1996). El principal factor limitante para su aplicación es la demanda de mucha información para los procesos de parametrización y validación que no siempre se encuentra disponible. El nivel de incertidumbre puede ser importante porque la información se toma de investigaciones previas que se realizan bajo condiciones ambientales que no son similares o de opinión de expertos.

Como se mencionó previamente, una de las metodologías empíricas más sencillas para la estimación del rendimiento fue denominada “adivinanza a ciegas” (Alvarez 2009). Específicamente, esta metodología consiste en calcular promedios de rendimiento sin tendencia temporal para un número específico de campañas que se define previamente. Como se trabaja únicamente con datos de rendimiento no se dispone de información de las variables biofísicas y/o de manejo que determinan el rendimiento estimado con esta metodología, de ahí el porqué del nombre. Esta metodología es muy sencilla y aunque no se puede realizar una caracterización de las variables que determinan el rendimiento si se puede evaluar si los rendimientos altos actuales corresponden a rendimientos altos de campañas pasadas también se puede determinar si los datos de rendimientos de campañas pasadas pueden ser aprovechados para estimar el rendimiento presente. Con esta metodología se podría llegar a caracterizar la productividad de una región utilizando tan sólo algunos datos de rendimiento correspondiente a algunas campañas.

La regresión polinómica (Neter et al., 1990), los árboles de regresión (Lobell et al., 2005) y las RNA (Kaul et al., 2005; Park et al., 2005) son algunas de las metodologías empíricas que han mostrado buenos ajustes en la estimación del rendimiento de cultivos a escala regional. A continuación se describen estas metodologías y se discuten las ventajas y desventajas de cada una de ellas.

Regresión polinómica

Modelos de regresión polinómica han sido utilizados frecuentemente en la evaluación de experimentos agronómicos, con efectos esperados lineales positivos y cuadráticos negativos (Colwell, 1994). Es una metodología que requiere la normalidad de los datos. Las técnicas de regresión lineal simple y múltiple permiten un análisis empleando modelos de superficie con efectos lineales, curvilíneos e interacciones (Neter et al., 1990). Se puede evaluar el efecto de cada variable biofísica por separado sobre el rendimiento y, a su vez, las

interacciones entre las variables independientes (Laird y Cady 1969; Nelson et al., 1985). La expresión matemática de un modelo de respuesta polinomial de superficie se presenta a continuación:

$$\begin{aligned} \text{Rendimiento} = & \mathbf{a_0} + \mathbf{a_1v_1} - \mathbf{a_2v_1^2} + \mathbf{a_3v_2} - \mathbf{a_4v_2^2} + \mathbf{a_5v_1v_2} + \dots \\ & + \mathbf{a_{n-2}v_x} - \mathbf{a_{n-1}v_x^2} + \mathbf{a_nv_xv_{x-1}} \end{aligned}$$

Donde, a_0 a a_n son coeficientes de regresión; y v_1 a v_x son variables independientes. Los modelos de regresión polinomial permiten analizar relaciones curvilíneas entre la variable dependiente y las independientes pero únicamente de segundo grado.

Árboles de regresión

Una técnica más reciente, no paramétrica, es la de los árboles de regresión (Digby y Kempton 1994). Los árboles explican la variación de una única variable respuesta por una o más variables explicativas, que pueden ser numéricas o categóricas. El árbol se construye separando repetidamente el set de datos, por una regla simple basada en una única variable explicativa, que particiona a la población en grupos homogéneos por medio de una regresión (Steinberg y Colla 1995). Cada grupo (nodo) se caracteriza por un valor promedio de la variable respuesta, el tamaño del grupo y los valores de las variables explicativas que lo definen. Un grupo se separa nuevamente únicamente cuando la heterogeneidad es lo suficientemente alta que permite una partición en grupos más homogéneos y cuando el tamaño del nodo es superior al mínimo establecido para continuar el algoritmo (McKenzie y Ryan 1999). El proceso de partición se aplica a cada nuevo grupo por separado hasta lograr el modelo que mejor explique la variación en la variable dependiente. El proceso de partición minimiza la suma de cuadrados dentro de los nodos. Esta metodología empírica no permite analizar los efectos curvilíneos de las variables independientes.

Los árboles son representados gráficamente, en la parte superior del diagrama se representa el conjunto total del set de datos aún sin particionar y hacia abajo se encuentran las ramificaciones y los nodos que representan los grupos finales seleccionados por el modelo (**Figura 3.2.**). Esta metodología estadística se diferencia de las técnicas de regresión en que no requieren la normalidad de los datos. Los árboles de regresión tienen la ventaja de ser flexibles para un gran rango de distintos tipos de variables explicativas. Las variables utilizadas pueden ser transformadas y la interpretación del árbol de regresión seleccionado es fácil. Se trata de descartar modelos con una estructura compleja y con demasiadas ramificaciones para evitar *overfitting* (De'Ath y Frabricius 2000). Las particiones las definen los valores umbrales de las variables independientes designadas por el modelo por su nivel de significancia. Las regresiones simples que determinan la estimación de la variable dependiente por nodo describen efectos lineales.




Figura 3.2. Representación de la estructura del árbol de regresión. n = número de datos en grupo, \bar{x} = promedio de la variable explicativa, A = segunda variable regresora, B = tercera variable regresora, ambas utilizadas para particionar la población en sub-sets homogéneos.

Redes neuronales artificiales (RNA)

Las RNA son metodologías de modelización con mayor capacidad predictiva que la regresión, no requieren conocer a priori la estructura de los datos, y permiten describir procesos curvilíneos y exponer interacciones escondidas entre variables (Batchelor et al., 2002). El análisis con redes neuronales permite acomodar las respuestas de las variables dependientes a las tendencias curvilíneas de las variables independientes (Somaratgne et al., 2005). Una red neuronal típica tiene una estructura de tres capas (**Figura 3.3.**) la primer capa se denomina de entrada, la segunda escondida y la última de salida. La información fluye desde la capa de entrada, a través de la capa escondida y finalmente hacia la capa de salida y el proceso de aprendizaje se desarrolla al revés, ajustando los pesos asociados a las funciones de transferencia entre las capas en sentido inverso (Jorgensen y Bendoricchio, 2001).

Esta metodología permite analizar relaciones curvilíneas entre variables independientes y la variable dependiente de un determinado set de datos. Comúnmente se utilizan funciones de transferencia lineales para conectar las neuronas de la capa de entrada a la capa escondida y funciones sigmoideas para conectar estas últimas a las neuronas de la capa de salida (Lee et al., 2003). Cada neurona de la capa de entrada corresponde a una variable de entrada de información, la capa de salida tiene una neurona por cada variable a estimar y la estructura de la capa escondida se determina empíricamente. La red neuronal desarrollada es el resultado de un proceso de aprendizaje supervisado que usa el algoritmo de *back propagation* (Kaul et al., 2005) que ajusta los pesos a las funciones entre las capas de neuronas del modelo (Rogers y Dowla 1994).

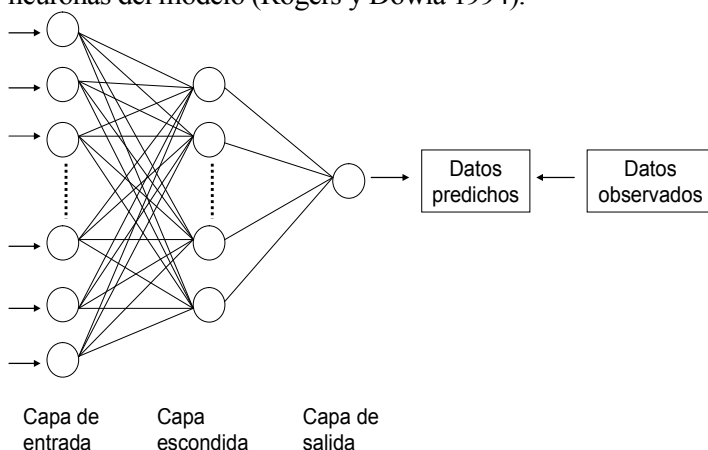


Figura 3.3. Representación de una red neuronal artificial mostrando capas de neuronas de entrada, escondida y salida, y las conexiones entre las mismas. Adaptado de Álvarez (2009).

3.2. Objetivo

Generar un modelo empírico explicativo del rendimiento de trigo en función de características biofísicas y/o de manejo que pueda ser utilizado para construir un índice de productividad.

3.3. Hipótesis

El rendimiento de trigo a nivel de la Región Pampeana depende de la interacción entre la CAAU y el contenido de carbono orgánico del suelo.

Los modelos empíricos que explican la variabilidad interanual del rendimiento de trigo a escala regional pueden ser utilizados a escala de sitio.

3.4. Materiales y métodos

El set de datos que se generó para la modelización empírica del rendimiento de trigo a escala regional fue de 1640 ($n = 41$ unidades geográficas \times 40 campañas (1967-2006)). Los cálculos y estimaciones que fueron necesarios para la generación de esta base de datos se encuentran descritos en detalle en el Capítulo 2. Se testearon cuatro métodos de modelización empírica del rendimiento: 1) “adivinanza a ciegas”, 2) regresión polinómica, 3) árboles de regresión y 4) RNA.

El primer método empírico de modelización del rendimiento fue el de “adivinanza a ciegas”. Como la característica más obvia de series temporales de rendimiento, de la mayoría de los cultivos y en gran parte de las regiones, es la tendencia positiva y altamente significativa con el tiempo (Ray et al., 2012), se tuvo que eliminar la misma del set de datos. Esta tendencia resulta en gran parte por las mejoras en la tecnología, como la adopción de nuevos cultivares y el aumento en el uso de fertilizantes. Considerando que la variación en el rendimiento entre campañas en diferentes partes del registro temporal se debe a diferencias tecnológicas, el efecto del clima por ejemplo es difícil de discernir de los datos crudos de rendimiento. Para poder estimar el rendimiento con la metodología de “adivinanza a ciegas” se procedió a eliminar la tendencia temporal de los datos de rendimiento para eliminar la influencia de la tecnología. Existen varios métodos para hacer esto y ninguno es claramente óptimo. Uno de esos métodos es llevar todos los datos de rendimiento a la escala del último año usando una regresión (Lobell y Field, 2007). Para cada unidad geográfica se calculó la regresión simple del rendimiento vs. campaña para el período 1967-2006. Con la ecuación (rendimiento = ordenada + campaña*coeficiente) generada se calculó el rendimiento equivalente a la última campaña de la serie temporal analizada (2006) para de esta forma eliminar la tendencia temporal de los datos de rendimiento.

La variable dependiente de la metodología “adivinanza a ciegas” fue el rendimiento promedio por unidad geográfica de las últimas 10 campañas de la serie temporal analizada (1997-2006). Se correlacionó esta variable dependiente vs.:

El rendimiento por unidad geográfica de las 30 campañas previas a la última década de la serie temporal, es decir desde 1967 hasta 1996 (1967-1976, 1977-1986, 1987-1996).

El rendimiento de 1 ($n = 30$), el promedio de 2 ($n = 15$), 3 ($n = 10$), 5 ($n = 6$), 7 ($n = 4$) y 10 ($n = 3$) campañas elegidas al azar y previas a la campaña 1997.

Para ambas opciones se estimó el R^2 de la regresión simple de la variable dependiente (rendimiento promedio de la última década) vs. el rendimiento estimado y fue utilizado como medida estadística de la performance de esta metodología.

El segundo método empírico testeado fue el de la regresión polinómica. Antes de su aplicación se testeó la normalidad de las variables regresoras a través del *test* de Shapiro Wilks. Al no encontrar evidencia de normalidad en los datos, se intentaron transformaciones como aplicación de logaritmos, de exponenciales, inverso de seno, exponentes y finalmente del método Box-Cox (Peltier et al., 1998). Como no se pudo obtener la normalidad de los datos, pero la distribución de los datos se acercaba a la distribución normal, se optó por restringir el tamaño del *test* de hipótesis ($P = 0,01$) por argumentos asintóticos (Amemiya 1985). Términos lineales, cuadráticos e interacciones fueron incorporados en el modelo únicamente si eran significativos en $P = 0,01$ y todo el modelo con un $P = 0,01$ (*F test*).

Se aplicó la metodología de forward stepwise para la selección de variables regresoras hasta obtener un modelo sencillo pero con el máximo R^2 posible. El rendimiento de trigo fue estimado utilizando como variables regresoras: campaña, precipitación mensual (mm), temperatura mensual ($^{\circ}\text{C}$), ETP potencial mensual (mm), índice precipitación/ETP mensual, coeficiente fototérmico ($\text{MJ m}^{-2} \text{d}^{-1} \text{ }^{\circ}\text{C}^{-1}$), profundidad de suelo (cm), arcilla (t ha^{-1}), limo (t ha^{-1}), arena (t ha^{-1}), carbono orgánico (t ha^{-1}) y CAAU (mm). Existen antecedentes locales que

detectan algunas de las variables climáticas testeadas para las fases de barbecho, fase vegetativa y floración, por lo que también fueron calculados los promedios ponderados por el número de días de dichas variables y testeados como variables independientes (Alvarez 2009). La probable autocolinealidad de las variables independientes se testeó por el valor de VIF (variance inflation factor), no aceptando la entrada de variables que tuvieron valores superiores a 7 (Neter et al., 1990).

Para evaluar la capacidad de generalización del modelo de regresión polinómica se utilizó el 75 % de los datos seleccionados al azar para generar el modelo (set de *training*) y el 25 % de datos independientes restantes (set de validación) fue utilizado para validar el mismo. La aproximación implementada fue jerárquica ya que se combinaron variables independientes para calcular nuevas variables con el propósito de incluir los efectos de las variables del primer orden y lograr la simplificación del modelo seleccionado (Schaap y Bouten 1996). La regresión de rendimiento estimado y observado y el análisis de pendientes y ordenadas al origen fue comparada a través de un *test* de t usando el software IRENE (Fila et al., 2003). Se realizó una estimación del impacto de las variables independientes sobre el rendimiento corriendo el modelo para el rango entre el 10 y el 90 % de cada variable para evitar efectos de sub- y/o sobre-estimación. El impacto sobre el rendimiento de cada variable independiente fue determinado calculando la diferencia entre el rendimiento para el valor mínimo y el valor máximo (10 y 90 %) de cada variable independiente. Para este mismo rango por variable independiente se graficó el efecto sobre el rendimiento para identificar la forma de la misma. La metodología de la regresión polinómica obtiene los mejores resultados cuando se trabaja con valores medios de las variables ya que la extrapolación hacia valores extremos (mínimos o máximos) puede resultar en estimaciones erradas (Onken et al., 1985).

El tercer método empírico aplicado fue el de los árboles de regresión para el que se utilizaron las mismas variables regresoras testeadas con la metodología de la regresión polinómica. Para evitar el problema de *overfitting*, cuando el algoritmo de partición extrae demasiada información del set de datos incluyendo además la información que no puede ser predicha de la población con el set de predictores (variación aleatoria), hay que detener a tiempo la partición del árbol. Otro problema que se presenta cuando hay *overfitting* es que con el modelo no se puede predecir una muestra de nuevas observaciones. Se detuvo la generación de nuevos nodos de partición cuando las particiones subsecuentes únicamente resultaban en muy pequeñas mejoras en la predicción final. Estos métodos de poda o pruning de árboles sirven para seleccionar el árbol más sencillo, pero a la vez aquel que es igualmente preciso en la predicción o clasificación de nuevas observaciones.

Se evaluó la capacidad de generalización del árbol seleccionado a través de la *validation* con el 25 % de datos independientes (misma subdivisión de datos aplicada a la metodología de la regresión polinómica). El software utilizado para generar un árbol de regresión fue Cubist 2.05 (Rulesquest's, © 2011).

El cuarto y último método empírico testado fue el de las RNA, y específicamente aquellas con propagación *feed-forward-back* (Kaul et al., 2005). Se aplicó la estructura más común de tres capas de neuronas. Se aplicaron funciones de transferencia lineales a las funciones que unen la capa de entrada con la capa escondida y las que unen la capa de salida con la salida de la red, y una función sigmoideal para conectar la capa escondida con la capa de salida (Lee et al., 2003). La RNA desarrollada resulta de un proceso de aprendizaje supervisado que usa el algoritmo de back propagation para ajustar los pesos a las funciones (Rogers y Dowla 1994).

A las variables de entrada se les ajusta una escala entre 0 y 1 por medio del método de minimax para hacer que los rangos de variación sean más uniformes y que el set de datos sea más apto para una función sigmoideal (Park et al., 2005). Las salidas de las redes fueron

transformadas a su escala original de unidades. La tasa de aprendizaje controla el tamaño del cambio en el peso ajustado por el algoritmo en cada iteración (Kaul et al., 2005). El tamaño de la epoch representa el número de iteraciones para el cual corre el algoritmo, en cada epoch el set de *training* completo pasa por la red, y es usado para ajustar los pesos de las redes, se usó un tamaño de epoch de 100 (Somaratgne et al., 2005). Se buscó la simplificación máxima posible de las redes para reducir el número de neuronas en la capa de entrada y la oculta sin afectar el R^2 del modelo. Se efectuó un análisis de sensibilidad para evaluar el peso de las variables independientes sobre el rendimiento de trigo (output de la red) calculando un sensitivity ratio (SR) (Miao et al., 2006). Solo variables predictoras con un ratio mayor a 1 fueron seleccionados ya que valores menores indican que no impactan significativamente el output de la red. A continuación se detallan los pasos seguidos para ajustar una RNA:

Paso 1: identificación de variables

En el programa STATISTICA Neural Networks se indica qué columnas son inputs, variables independientes, y cuál es la columna output, variable dependiente, que van a ser utilizados para generar un modelo explicativo con esta metodología. Automáticamente se transforman los valores de inputs y outputs con el método min-max para la modelización y una vez finalizada vuelven a sus valores originales.

Paso 2: empieza el ajuste del diseño de la RNA

Para poder personalizar el proceso de diseño de la red se trabaja con ajustes avanzados de programación feed-forward-back que define la autocorrección de las estimaciones. El tipo de red en este caso es estándar porque cada valor es independiente. Se definen las funciones de transferencia entre capas de neuronas cuyos pesos van a ser ajustados por un algoritmo de back propagation. Se eligen funciones de transferencia lineales para conectar las neuronas de la capa de entrada con la escondida y también para la capa de neuronas de salida con la salida de la red. Se aplica una función sigmoideal para unir la capa de neuronas escondida con la capa de salida.

Paso 3: división del set de datos

Se sub-divide aleatoriamente el set de datos en tres sets independientes. Con el 50 % de los datos se genera un *training* set para desarrollar una red cuyas funciones de transferencia y pesos son ajustados a través un proceso de aprendizaje supervisado usando el 25 % del set de datos denominado *validation* set que se usa para detener el ajuste de la red cuando hay *overlearning*. Con el 25 % restante, llamado el test set, se valida el modelo generado. El epoch size es determinado en 100.

Paso 4: multilayer perceptron

Se trabaja con la red neuronal de tipo multilayer perceptron que comprende una estructura en tres capas: entrada, oculta y salida. El número de neuronas de la capa oculta se define manualmente y no debería exceder por mucho el número de neuronas de la capa de entrada.

Paso 5: duración del proceso de aprendizaje

Se elige la opción de búsqueda minuciosa, que conduce una búsqueda extensiva de la red con la mejor performance. Cuánto más tiempo tarda la selección de redes, más alta es la probabilidad de descubrir redes con mejores performances.

Paso 6: selección de redes

El programa experimenta con muchas redes y se puede almacenar un número determinado de las mejores en el Network set. Se pide que se guarden máximo 10 de las mejores redes y automáticamente se reemplazan las viejas redes por las nuevas en caso de ser mejores.

Paso 7: resultados

Las variables input seleccionadas en la red tienen un Sensitivity Ratio (SR) mayor a 1 tienen un efecto significativo sobre la variable output. En el resumen estadístico se pueden ver los valores de la variable output observados, estimados, la diferencia entre ambos de la variable output. También se incluye el error estándar de la red seleccionada. Manualmente se grafican los valores estimados y los observados para determinar el R^2 del *validation* set y así determinar el ajuste del modelo.

Paso 8: análisis gráfico de resultados

Se puede observar la estructura de la red para ver gráficamente cuántas neuronas entran en la capa de entrada y oculta. Para analizar el efecto de las variables que entraron por su efecto significativo sobre el output el programa permite hacer un gráfico 2D de la variable output vs. las variables input en sus valores medios. También se puede analizar la interacción de dos variables input sobre el output a través de una figura 3D.

Paso 9: selección final de la red con mejor performance

Se reiteran varias veces los pasos anteriores hasta lograr una red cuyos inputs tengan un SR mayor a 1, el número de neuronas en la capa oculta no sea excesivo, los efectos de los inputs sobre el output sea aceptable y la performance en términos estadísticos sea óptima.

Se utilizaron las mismas variables predictoras que para las otras metodologías de modelización del rendimiento. Se particionó al set de datos de la siguiente manera: 50 % *training* set, 25 % *validation* set y el 25 % restante correspondió al *test* set. El *test* set es independiente y es el mismo que se utilizó para validar las dos metodologías empíricas anteriores. Los modelos fueron ajustados con el set de aprendizaje y se aplicó la metodología de early stopping del ajuste de pesos cuando el R^2 del set de *test* era menor que el R^2 del *training* set (Kleinbaum y Kupper 1979). Se utilizó el software Statistica Neural Networks (versión 2011, StatSoft, Tulsa).

La performance de los modelos fue comparada a través de su R^2 y el RMSE (root mean square error) (Kobayashi y Salam 2000). Las posibles diferencias entre los R^2 fueron analizados a través de un *test* específico de la transformación de Fisher's Z (Kleinbaum y Kupper 1979). El modelo empírico con la mejor performance estadística y ambiental fue seleccionado para la estimación del rendimiento por unidad geográfica y también para el análisis de la interacción entre variables edáficas y climáticas. Se corrió el modelo empírico seleccionado para la información publicada de 1259 datos resultantes de ensayos experimentales distribuidos en la Pampa Ondulada (Alvarez y Grigera 2005) y en la Región Semiárida Pampeana (Bono et al., 2010). La descripción de los ensayos experimentales, variables biofísicas medidas y rendimientos alcanzados en cada caso se encuentra detallada en el Capítulo 2.

3.5. Resultados

La metodología de “adivinanza a ciegas” permitió muy buenas estimaciones del rendimiento de trigo por unidad geográfica. En primer lugar al utilizar el promedio de rendimiento de las primeras tres décadas analizadas (1967-1976, 1977-1986, 1987-1996) para estimar el rendimiento promedio de la última década (1997-2006), el ajuste fue alto con un $R^2 = 0,987$ ($p = 0,05$) (**Figura 3.4.A.**). Las unidades geográficas que en el pasado alcanzaban rendimientos bajos mantienen valores bajos durante la última década de la serie temporal analizada y la tendencia a alcanzar rendimientos altos de algunas unidades geográficas también fue proyectada hacia la última década.

En segundo lugar, cuando se calcularon los rendimientos promedios para determinadas combinaciones de rendimientos alcanzados durante campañas pasadas elegidas al azar, la performance de esta metodología empírica también fue muy buena (**Figura 3.4.B.**).

Al utilizar únicamente datos de una campaña para estimar el rendimiento promedio por unidad geográfica de la última década el R^2 de la relación entre estimado vs. observado varió entre 0,442 hasta 0,954. Cuando se calcula el promedio de dos campañas previas y elegidas al azar este rango del R^2 decrece y varía entre 0,786 a 0,938. A medida que se incrementa el número de campañas promediadas sigue disminuyendo este rango del R^2 y además va aumentando el ajuste. Cuando se estima el rendimiento alcanzado durante la última década con datos de 3 a 5 campañas previas a la campaña 1997 y elegidas al azar, el R^2 de la relación entre ambos parece estabilizarse. Es decir que utilizando el promedio de tan sólo 3, 4 o 5 campañas pasadas por unidad geográfica se puede estimar con buen ajuste el rendimiento alcanzado para esta escala de análisis para el período 1997-2006.

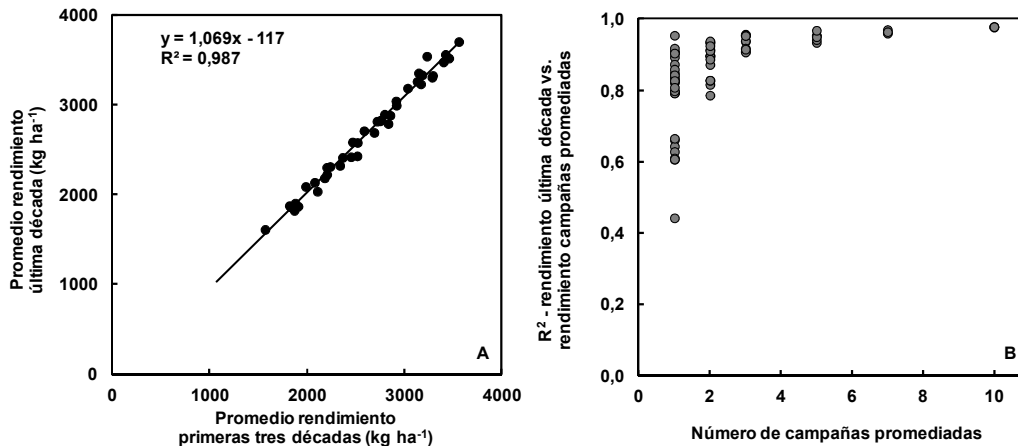


Figura 3.4. A. Estimación del rendimiento de la última década utilizando el promedio del rendimiento alcanzado durante las tres décadas previas. **B.** R^2 de la regresión lineal entre el rendimiento alcanzado promedio de la última década y el promedio del rendimiento alcanzado en 1, 2, 3, 5, 7 y 10 campañas elegidas al azar.

El modelo de respuesta polinomial de superficie incluyó como variables regresoras: precipitación/ETP potencial durante el barbecho y fase vegetativa, coeficiente fototérmico y CAAU. El R^2 de éste modelo fue de 0,528 con un $RMSE = 474 \text{ kg ha}^{-1}$ (**Cuadro 3.1**). El modelo predice un aumento del rendimiento con el tiempo y con incrementos en los índices climáticos, el coeficiente fototérmico y la CAAU. A través de la inspección visual de residuos se observó que la distribución de frecuencias era parecida a la distribución normal.

Cuadro 3.1. Modelo de regresión polinómica ($R^2 = 0,528$, $P = 0,05$). Se indican los términos lineales, cuadráticos e interacciones seleccionados por su significancia estadística ($p < 0,01$).

Variable	Parámetro $p < 0,05$
Términos lineales	
Intercepto	2008793
Campaña	-2059
Términos cuadráticos	
Campaña ²	0,528
CAAU ²	-0,0483
Precipitación/ETP barbecho ²	-114
Precipitación/ETP fase vegetativa ²	-173
Coefficiente fototérmico ²	-870
Interacciones	
Precipitación/ETP barbecho x Precipitación/ETP fase vegetativa	-169
CAAU x Coeficiente fototérmico	12,4
Precipitación/ETP barbecho x Coeficiente fototérmico	483
Precipitación/ETP fase vegetativa x Coeficiente fototérmico	608

CAAU = CAAU hasta 100 cm de profundidad o hasta el límite superior de la capa petrocálcica en caso de presentarse. ETP = ETP potencial.

En la **Figura 3.5.** se observan los efectos de las variables independientes seleccionadas por la metodología de la regresión polinómica sobre el rendimiento de trigo para un rango que excluye los valores extremos. Los efectos de las variables climáticas, tanto el coeficiente fototérmico, como la relación entre la precipitación y la ETP potencial durante el barbecho y la fase vegetativa, son curvilíneas y el rendimiento estimado alcanza un máximo para disminuir nuevamente después del mismo cuando los valores de las variables incrementan (**Figura 3.5. A. B. D.**). La CAAU también tiene un efecto curvilíneo sobre el rendimiento pero después del rendimiento máximo estimado parece seguir respuesta de tipo plateau para suelos que logran captar más de 170 mm de agua en el primer metro del perfil (**Figura 3.5. C.**). La variable campaña (tiempo) tiene un efecto lineal sobre el rendimiento estimado, los rendimientos estimados durante las primeras campañas son menores a los rendimientos de las campañas más recientes, y también es la variable cuyo efecto directo fue el mayor (**Figura 3.5. E. y F.**). Los efectos directos sobre el rendimiento se encuentran graficados por orden de magnitud en la última sub-figura (**Figura 3.5. F.**).

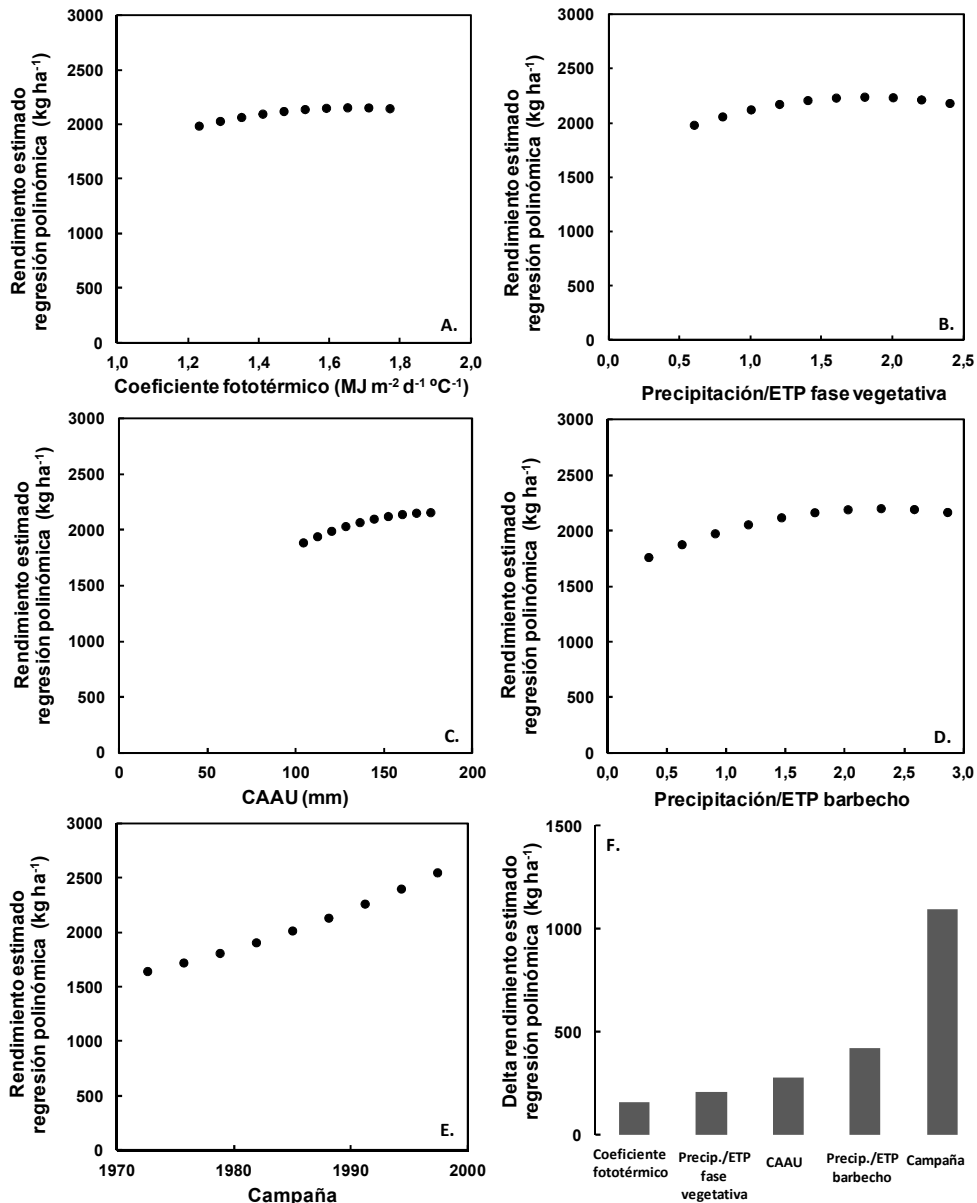


Figura 3.5. A. B. C. D. E. Efecto de variables independientes sobre el rendimiento estimado con la regresión polinómica seleccionada. F. Presenta el impacto directo de variables independientes como la diferencia entre el rendimiento estimado para el valor máximo menos el mínimo.

El mejor modelo regional seleccionado con la metodología de árboles de regresión utilizó las mismas variables independientes que el modelo de la regresión polinómica pero además detectó el efecto significativo del contenido de carbono orgánico de los primeros 50 cm del perfil de suelo ($R^2 = 0,601$, $RMSE = 433 \text{ kg ha}^{-1}$). El árbol de regresión seleccionado contó con siete particiones o reglas y la variable que definió la primera partición fue la CAAU de los suelos, hasta el primer metro de profundidad o hasta el límite superior de la capa petrocálcica en caso de presentarse, con un valor de 92 mm (**Figura 3.6**). Por un lado, el

modelo indicó que los rendimientos más altos se alcanzaron después de la campaña 1994 en suelos con una CAAU mayor a 117 mm y con contenidos de carbono orgánico mayores a 64 t ha⁻¹. Por otro lado, los rendimientos más bajos fueron alcanzados en suelos con CAAU menor a 92 mm. La variable campaña es una variable que varias veces fue seleccionada por la metodología para la partición del árbol. Las tres variables independientes principales que definen la partición del set de datos son campaña (presente en el 100 % de las regresiones simples), CAAU (presencia 89 %) y carbono orgánico (presencia 84 %). Las variables climáticas seleccionadas no determinan las particiones del modelo.

Las regresiones que determinan las particiones del árbol de regresión son simples, por lo tanto describen únicamente efectos lineales de las variables independientes sobre el rendimiento estimado. Los efectos lineales de las variables independientes se pueden graficar únicamente por nodo. Esta metodología estadística no permite analizar las interacciones entre variables independientes. Únicamente se puede hacer una estimación del rendimiento sin la interpretación de los efectos de las variables independientes ya que el grado de complejidad es alto. El proceso de pruning permitió evitar *overfitting* de la estimación del rendimiento por unidad geográfica.

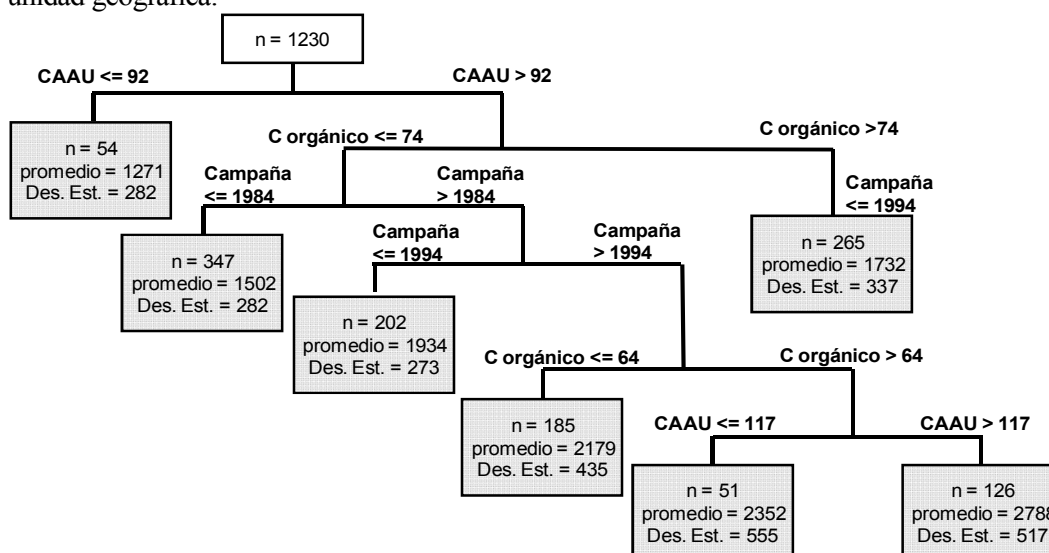


Figura 3.6. Modelo explicativo de rendimiento desarrollado con un árbol de regresión ($R^2 = 0,609$. $P = 0,05$). Cada nodo contiene: número de observaciones, el rendimiento promedio estimado y el error estimado.

El mejor modelo seleccionado con la metodología de RNA tenía 7 neuronas en la capa oculta e incluyó las mismas variables independientes que el árbol de regresión pero además incluyó la relación precipitación/ETP durante la floración del cultivo ($R^2 = 0,614$; $RMSE = 429 \text{ kg ha}^{-1}$) (**Figura 3.7.**). La variable campaña tuvo un efecto positivo y lineal sobre el rendimiento, es decir que los rendimientos más altos estimados por el modelo corresponden a las campañas más recientes. La relación entre el contenido de carbono orgánico de los primeros 50 cm de los suelos y el rendimiento estimado es curvilíneo pasando por un máximo en 70 t ha⁻¹ aproximadamente. El rendimiento es afectado de manera positiva por la CAAU de los suelos, la relación también es curvilínea pero no se obtiene un máximo sino más bien la relación el lineal-plateau cuando la CAAU es mayor a 140 mm aproximadamente. La relación entre la relación precipitación/ETP durante el barbecho y el rendimiento estimado es curvilíneo y alcanza un máximo en el valor 1,23, la relación durante la fase vegetativa tiene una forma parecida pero el máximo si alcanza en 1,25 y por último la

relación durante la floración desciende a partir del valor 0,515 aproximadamente. El coeficiente fototérmico también está relacionado con el rendimiento estimado de manera curvilínea y el máximo pasa por el valor de $1,63 \text{ MJ m}^{-2} \text{ d}^{-1} \text{ }^{\circ}\text{C}^{-1}$.




Figura 3.7. Modelo de estimación del rendimiento de trigo regional basado en la metodología de RNA ($R^2 = 0,614$; $P = 0,05$).

Las tres metodologías estadísticas aplicadas tuvieron un buen ajuste ($R^2 \geq 0,528$, $\text{RMSE} \leq 474 \text{ kg ha}^{-1}$) (**Figura 3.8**). Con las tres metodologías empíricas se seleccionaron variables independientes similares. La capacidad de generalización de los modelos fue buena al no observarse diferencias significativas entre los R^2 de los *training* (*training* y *validation* sets) y *test* sets. Las pendientes de la relación entre rendimientos estimados y observados no fueron distintas de 1 y 0 respectivamente ($P = 0,05$). Sin embargo, los modelos seleccionados con la metodología de árboles de regresión y redes neuronales fueron más exitosas en predecir el rendimiento de trigo al obtener R^2 más altos comparados al R^2 alcanzado con la metodología de la regresión polinómica ($P = 0,05$). Es decir que la capacidad de generalización del modelo generado con la metodología de árboles de regresión y el de la RNA no fue estadísticamente diferente ($P = 0,05$) así como tampoco lo fueron sus RMSE ($P = 0,05$).

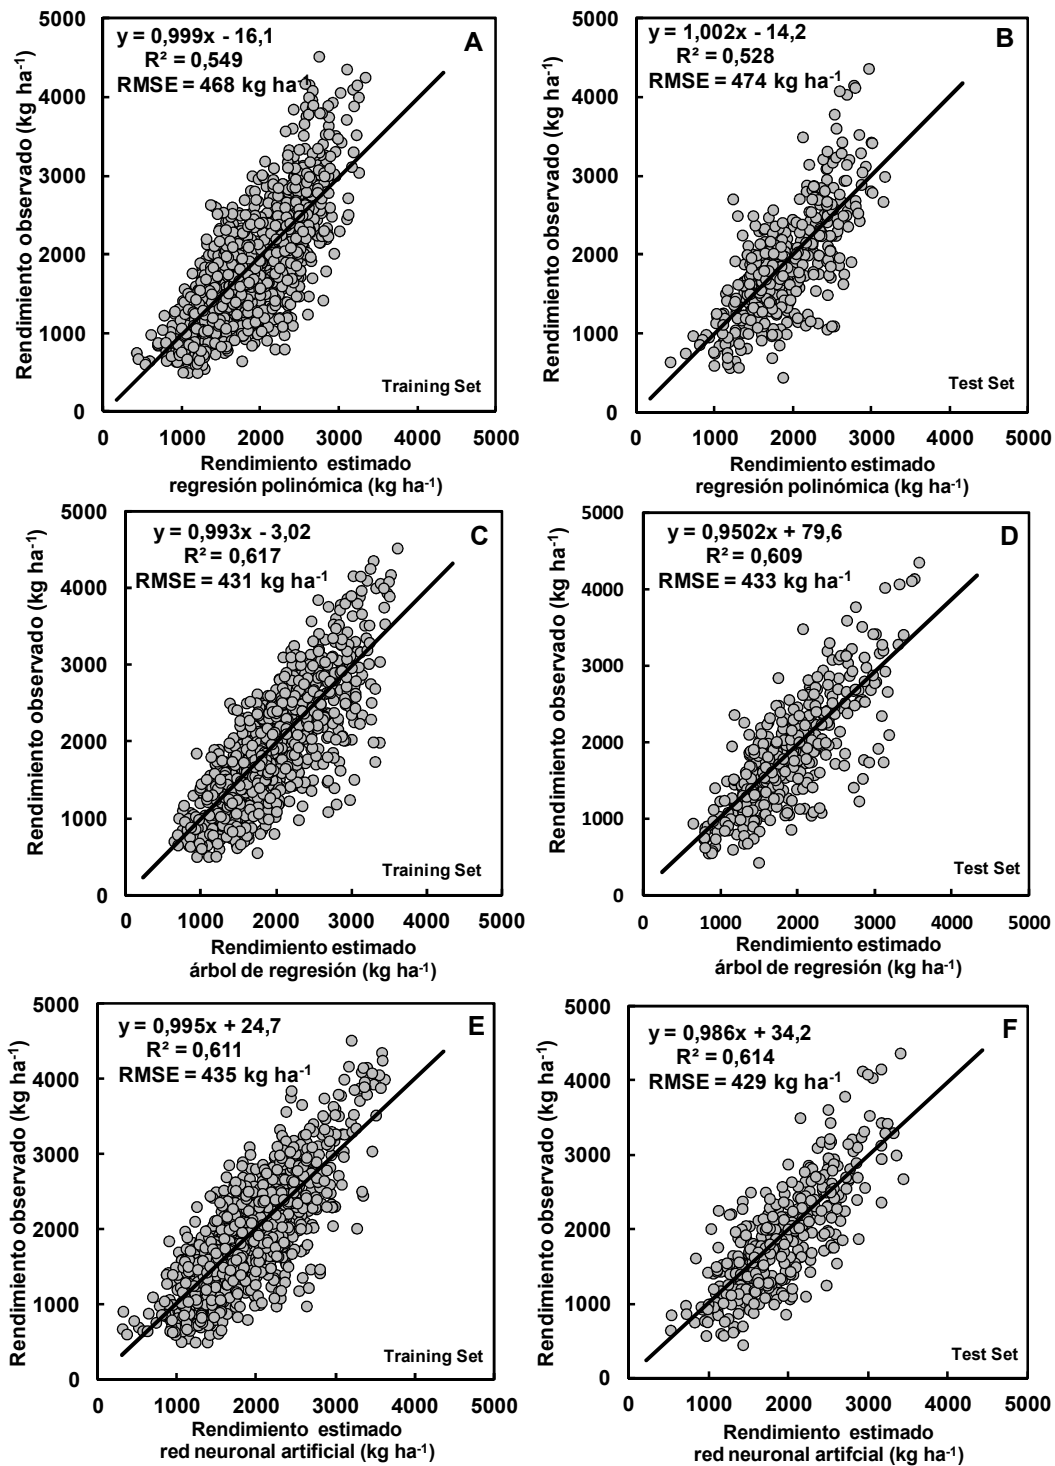


Figura 3.8. Performance de la metodología de la regresión polinómica (A. y B.), árboles de regresión (C. y D.) y redes neuronales (E. y F.). *Training set* (75 % los datos, n = 1230) y *test set* (correspondiente al 25 % de los datos, n = 410).

Como el modelo ajustado con la RNA obtuvo un ajuste ligeramente mejor, aunque no significativo, que el modelo logrado con la metodología de árboles de regresión fue seleccionado para analizar el efecto de la interacción de las variables independientes. Este modelo basado en una RNA fue utilizado posteriormente en el Capítulo 4 para generar un índice de productividad deductivo.

Se corrió el modelo seleccionado para suelos con CAAU de 160 mm y 80 mm que representan suelos típicos de la Pampa Ondulada y la Región Semiárida Pampeana respectivamente. Cuando se analiza el impacto de la CAAU bajo el gradiente climático pampeano (se estimó el promedio ponderado por el número de días de la relación precipitación/ETP durante el barbecho, la fase vegetativa y la floración del cultivo), se observa que la respuesta del rendimiento a la CAAU fue mayor en escenarios que corresponden a climas semiáridos (**Figura 3.9**). La diferencia en la respuesta a ambos valores de CAAU decrece hasta casi igualarse cuando mejora la situación climática, es decir cuando el índice climático promedio aumenta.

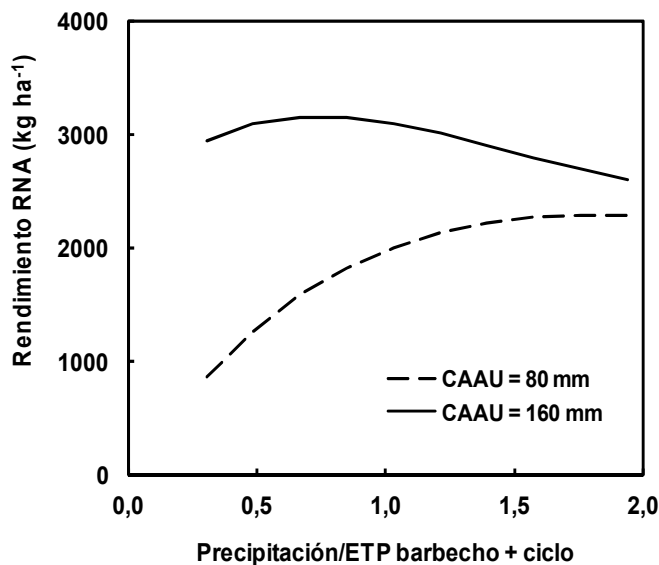


Figura 3.9. Rendimiento de trigo estimado por una red neuronal artificial (RNA) para dos escenarios de capacidad de almacenamiento de agua útil (CAAU) contrastantes bajo el gradiente climático promedio de la Región Pampeana.

Se analizó la interacción de las variables edáficas seleccionadas por el modelo de RNA, carbono orgánico y CAAU, bajo un escenario climático regional promedio (**Figura 3.10**). Por un lado, se observa que al aumentar la CAAU para un suelo típico de la Pampa Ondulada (80 t ha^{-1}) el rendimiento estimado por la RNA aumenta de forma curvilínea y pasando por un máximo. Por otro lado, para suelos típicos de la Región Semiárida Pampeana (40 t ha^{-1}) el rendimiento estimado no parece aumentar tan marcadamente. En la porción húmeda pampeana parece ser que cuando la capacidad de retención de agua de los suelos supera los 140 mm el efecto del contenido de carbono orgánico deja de tener un peso marcado sobre el rendimiento. Cuando la CAAU fue baja se observa una diferencia mayor entre el rendimiento alcanzado en suelos con bajo y alto contenido de carbono orgánico indicando que la interacción positiva entre ambas variables hace que cuando el contenido de carbono orgánico es bajo no hay respuesta al agua en el perfil.

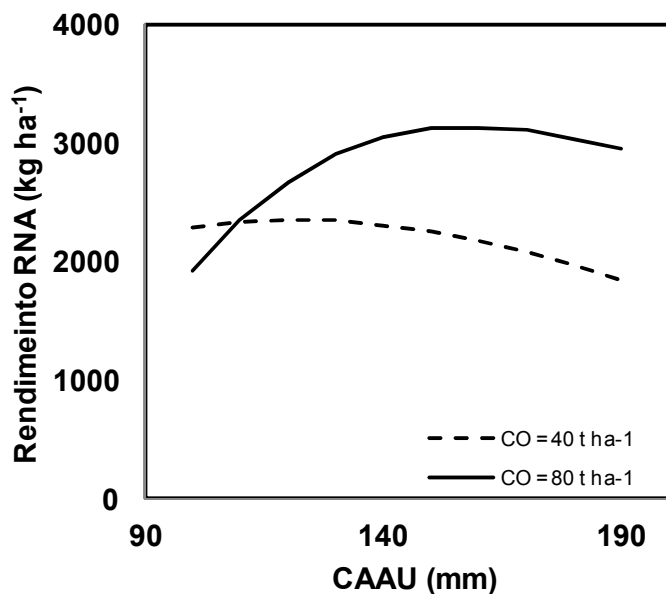


Figura 3.10. Relación entre la capacidad de almacenamiento de agua útil (CAAU) y el rendimiento estimado por la RNA bajo dos escenarios de CO (carbono orgánico) contrastantes.

Finalmente, se testeó si el modelo empírico desarrollado a escala regional basado en el modelo generado por una RNA podía ser validado contra datos resultantes de ensayos experimentales a escala sitio (**Figura 3.11.**). No se observó una relación significativa entre el rendimiento estimado a escala regional y el rendimiento observado a escala sitio. El modelo regional subestima el rendimiento alcanzado en los ensayos experimentales probablemente debido a que el ruido ambiental presente en los sitios evaluados no pudo ser modelizado por la red neuronal que utiliza promedios ponderados de rendimiento de partidos por unidad geográfica. El rendimiento promedio estimado por el modelo de la RNA para la combinación de variables de clima y suelo fue de 2000 kg ha^{-1} , con un mínimo estimado de 500 kg ha^{-1} y un máximo de 2900 kg ha^{-1} , mientras que el rendimiento promedio observado fue de 3400 kg ha^{-1} con un rango de 600 kg ha^{-1} a 6200 kg ha^{-1} . El rendimiento observado de los ensayos experimentales fue casi el doble del rendimiento estimado para esos sitios específicos.

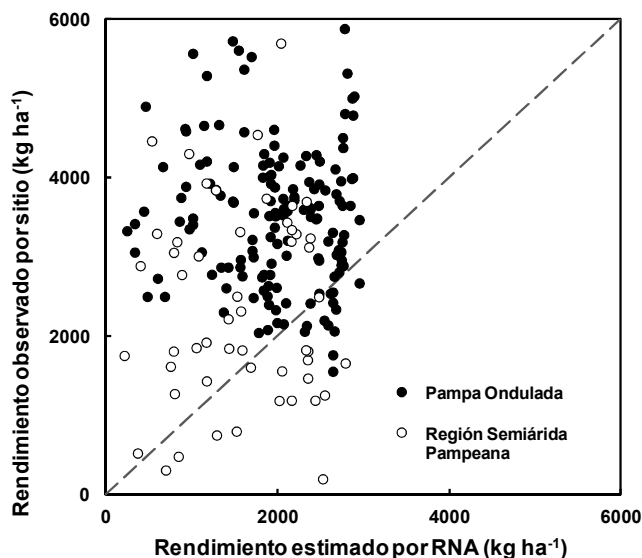


Figura 3.11. Relación entre el rendimiento estimado con una red neuronal artificial (RNA) vs. el rendimiento observado correspondiente a datos de ensayos experimentales distribuidos en la Pampa Ondulada (círculos llenos) y la Región Semiárida Pampeana (círculos vacíos).

3.6. Discusión

La metodología más sencilla utilizada en este capítulo, “adivinanza a ciegas”, permitió lograr las mejores estimaciones de rendimiento de trigo a nivel regional para la serie temporal analizada. No hace falta contar con información de muchas campañas ya que se obtienen resultados estables a partir de disponer información de 3-5 campañas. En los casos en los que no existe información climática y/o edáfica lo suficientemente detallada como para utilizar modelos empíricos esta metodología basada en datos de rendimiento únicamente es una buena alternativa de estimación y/o predicción a escala unidad geográfica pampeana. Esta metodología permitió comprender que las unidades geográficas cuya combinación de propiedades de suelo, características climáticas y manejo agrícola (comprendida en la variable campaña) resultan en rendimientos bajos durante campañas pasadas van a seguir alcanzando rendimientos bajos en las campañas más actuales. Lo mismo sucede en las unidades con rendimientos altos alcanzados en campañas pasadas. Además esta metodología permitió la caracterización regional de la productividad pampeana actual en términos del rendimiento de trigo utilizando datos de campañas pasadas (por ejemplo utilizando el promedio de rendimiento de las tres primeras décadas para estimar el rendimiento por unidad geográfica de la última década).

La modelización empírica del rendimiento de trigo a través de metodologías más complejas permitió alcanzar buenas predicciones usando información fácilmente alcanzable para condiciones ambientales de amplios rangos como los de la Región Pampeana. La fracción de la variabilidad del rendimiento no explicado por los modelos testeados en este capítulo (aproximadamente un 40 %) puede corresponder a variables ambientales que no fueron incluidas como variables independientes en los modelos. La información de rendimiento de trigo por campaña estaba disponible a escala partido mientras que datos climáticos y edáficos estaban disponibles a escalas más pequeñas lo que hace que agregar espacialmente para propósitos de modelización empírica sea dificultoso ya que las escalas de trabajo tendrían que ser similares.

La comparación de las tres metodologías de modelización empírica del rendimiento de trigo a escala regional demostró que cuanto más sofisticada la metodología utilizada más efectos de variables biofísicas pueden ser detectadas. La estimación del rendimiento con una regresión polinómica tuvo el ajuste más bajo comparado con los modelos regionales generados con las metodologías de árboles de regresión y RNA. La capacidad de generalización de estas últimas dos metodologías empíricas no difirió significativamente. Sin embargo, por un lado la complejidad en la estructura del árbol de regresión no permitió la interpretación de los efectos de las variables independientes sobre el rendimiento de trigo y únicamente puede ser utilizado para su estimación. Las regresiones simples que definen la estimación del rendimiento por nodo, afectado por las variables independientes incluidas en las mismas, únicamente permite estudiar efectos lineales sobre el rendimiento y esto únicamente para el conjunto de datos correspondiente al nodo en cuestión. Resumiendo, no se pudo evaluar el efecto de la interacción de variables independientes con el árbol de regresión.

Por otro lado, el modelo generado con la metodología de redes neuronales no sólo detectó efectos significativos de más variables de suelo y clima sino que el efecto de estas variables independientes sobre el rendimiento tienen la forma curvilínea esperable. La red neuronal seleccionada tiene un buen nivel de ajuste ($R^2 = 0,614$) si consideramos que no solo se trata de una escala regional que implica que cada variable biofísica seleccionada tiene un amplio rango de variación sino que además se analizaron 40 campañas. Esta metodología permite el análisis de la interacción entre variables de suelo que es algo que no se había podido hacer hasta el momento en la Región Pampeana. Estudios previos a este análisis regional, contaban con un set de datos menor y no permitieron evaluar la interacción entre

variables de suelo y su relación con el escenario climático (Verón et al., 2002; Alvarez 2009; Bono et al., 2010). Si se correlaciona el rendimiento estimado por la metodología de “adivinanza a ciegas” y el de la RNA promedio por unidad geográfica, el ajuste es muy bueno ($R^2 = 0,880$, $P = 0,05$) lo cual es esperable ya que ambos estiman de manera óptima el rendimiento.

El efecto positivo del tiempo (o campaña) sobre el rendimiento de trigo en la Región Pampeana y en otras muchas regiones del Mundo, es decir cuando el rendimiento en las campañas actuales supera en todos los casos el alcanzado en las primeras campañas de una serie temporal, puede atribuirse principalmente a dos razones: la mejora genética de trigo (Calderini y Slafer 1998) y la adopción de fertilizantes (FAOstat 2014). La relación estrecha y significativa del tiempo con el rendimiento alcanzado también se observó para las tres variables de manejo estimadas: la dosis de fertilizante ($R^2 = 0,696$, $P = 0,05$), el sistema de labranza ($R^2 = 0,587$, $P = 0,05$) y la mejora genética ($R^2 = 0,462$, $P = 0,05$) (Ver Capítulo 2, Cuadro 2.4.). Además de la fuerte correlación con el tiempo, estas variables de manejo también estaban significativamente correlacionadas entre sí. Consecuentemente, por estas dos razones se utilizó el tiempo como la variable sustituta de la mejora tecnológica regional de rendimiento como se ha hecho en otros trabajos (Lobell et al., 2005). Dos argumentos apoyan esta decisión de trabajar con una variable sustituta. Por un lado, en las tres metodologías empíricas de estimación del rendimiento que fueron comparadas se detectaron efectos significativos de por lo menos tres variables climáticas, por lo que se considera que la variación interanual climática está captada en estas variables independientes específicas. Por otro lado, no se detectaron incrementos, y tampoco se detectó una tendencia en este sentido, en la precipitación durante el barbecho y el ciclo del cultivo de trigo desde la campaña 1967 hasta la campaña 2006.

El impacto de la disponibilidad de agua sobre el crecimiento del cultivo depende de la fase analizada (Brisson et al., 2001). La relación precipitación/ETP es un índice climático que ya fue detectado por su efecto significativo sobre el contenido de carbono orgánico y arcilla de los suelos (Alvarez y Lavado 1998) y también sobre el rendimiento de trigo a escala regional (Alvarez 2009). En este análisis se detectó el impacto significativo de éste índice climático durante el barbecho previo a la siembra del cultivo y también durante las fases de crecimiento vegetativo y la floración del mismo. Se atribuye este resultado, durante el barbecho, a la importancia del contenido de agua a la siembra sobre el rendimiento como ya fue identificado en experimentos a campo en la Región Semiárida Pampeana (Bono et al., 2010).

La CAAU depende principalmente de la textura y la profundidad de los suelos y, en menor medida, el contenido de materia orgánica del suelo (De Paepe y Alvarez 2012). En la Región Pampeana, así como en otras regiones cultivadas, se ha observado una influencia importante de esta variable edáfica sobre el rendimiento de cultivos. Por ejemplo, en Australia, se observaron relaciones lineales entre la CAAU y el rendimiento de trigo alcanzando un límite de 65 mm (Lawes et al., 2009), los rendimientos parecen estar regulados por esta variable en Francia (Wassenaar et al., 1999) y también para USA se han determinado patrones geográficos de esta capacidad de retención hídrica de los suelos por su relación con la productividad (Kern 1995). Así, la determinación de la CAAU fue necesaria para el desarrollo de modelos que permiten entender la influencia del suelo sobre el rendimiento bajo las condiciones de la Región Pampeana.

Se observó un efecto positivo de la materia orgánica sobre el rendimiento de trigo y esto puede ser la consecuencia de su función como fuente de nutrientes. En la Región Pampeana, se demostró que los niveles de nitratos a la siembra de trigo son más altos en suelos ricos en carbono orgánico (Álvarez y Steinbach 2012). Al aumentar el contenido de la

materia orgánica de los suelos también aumenta su capacidad de mineralización de nitrógeno durante las fases de crecimiento de trigo (Alvarez y Steinbach 2011). La relación significativa entre la materia orgánica y el rendimiento de un cultivo a escala regional como fue detectado en este análisis también fue establecida en otros estudios desarrollados en otras partes del Mundo (García-Paredes et al., 2000). Pero cuando esta relación no pudo ser identificada en algunas regiones (Jiang y Thelen 2004), pareció deberse a estrechos gradientes de carbono orgánico y condiciones de manejo; por ejemplo a altas dosis de fertilizante.

Se pudo probar la primera hipótesis de éste capítulo sobre como la interacción entre la CAAU y el contenido de carbono orgánico del suelo definen el rendimiento de trigo a nivel de la Región Pampeana. Se encontró que en el modelo desarrollado con una RNA ambas variables afectaron significativamente el rendimiento de trigo a nivel regional y que además interactúan de forma positiva. Volviendo a la analogía planteada sobre la ley de los incrementos decrecientes con respecto a las variables edáficas contenido de carbono orgánico y la CAAU se pudo ejemplificar esta interacción positiva para dos suelos con contenido de carbono orgánico contrastantes, uno correspondiente a la Pampa Ondulada (80 t ha^{-1}) y otro a la Región Semiárida Pampeana (40 t ha^{-1}), para el rango de CAAU regional. Las curvas de respuesta a la CAAU muestran que el rendimiento además depende del contenido de carbono orgánico de los suelos. A lo largo del gradiente observado de CAAU, la respuesta del rendimiento siempre fue mayor para el suelo con más carbono orgánico. Se pudo demostrar además que la respuesta del rendimiento a la CAAU de los suelos disminuye cuando la condición hídrica mejora (evaluada a través del aumento en la relación precipitación/ETP).

Los datos a nivel partido utilizados y provenientes de las estadísticas nacionales (MinAgri 2014) son estimaciones promedio de rendimientos alcanzados por partido que pueden variar entre valores bajos, medios y altos. El modelo regional desarrollado para la escala de análisis de unidad geográfica no pudo ser aplicado a datos correspondientes a la escala de análisis sitio. Como el modelo regional subestima, en promedio 2000 kg ha^{-1} por debajo, los valores de rendimiento alcanzado en los ensayos experimentales correspondientes a la escala de análisis de sitio se rechazó la segunda hipótesis de éste capítulo. La población de datos parece estar desfasada hacia debajo de la línea 1:1 y se podría evaluar si las estimaciones mejoran al usar algún factor de corrección. Este resultado también indica que el índice de productividad deductivo que va a ser desarrollado en el capítulo siguiente no va a poder ser utilizado a escala sitio y únicamente a escala unidad geográfica ya que los resultados muestran que estas escalas de análisis no son intercambiables. Al agregar información espacialmente se trabaja con promedios que no incluyen posibles outliers como podrían ser los rendimientos muy altos alcanzados bajo situaciones de manejo muy buenas (como por ejemplo en ensayos experimentales). En general los rendimientos alcanzados en estos ensayos siempre son más altos que los promedios estimados a nivel partido por las estadísticas nacionales (Hall et al., 2013).

3.7. Consideraciones finales

En la Región Pampeana con el dato de rendimiento promedio alcanzado en 3, 4 y/o 5 campañas anteriores a la campaña 1997 se pudo obtener una estimación muy buena del rendimiento de trigo durante la década 1997-2006. La metodología para esta estimación es muy sencilla y permite predecir espacialmente la tendencia en valores de rendimientos alcanzados a nivel regional. Sin embargo, la metodología no permite analizar el efecto de variables de clima, suelo, manejo y/o de interacciones entre estas variables que podrían estar determinando el rendimiento a escala regional y es por esta razón que fue denominada “adivinanza a ciegas”.

Observamos que cuanto más compleja fue la metodología empírica aplicada, más efectos significativos de variables independientes se detectaron. El modelo generado con la

RNA fue seleccionado para la modelización del rendimiento de trigo porque permite analizar no sólo cómo es el efecto de las variables independientes sobre el rendimiento estimado sino que también permite el análisis de interacciones entre las mismas.

La RNA pudo detectar efectos significativos de dos variables edáficas; el contenido de carbono orgánico y la CAAU que además interactúan de forma positiva. Esta interacción indica que en suelos con contenidos bajos de carbono orgánico, el rendimiento estimado se mantiene por debajo del promedio regional para todo el gradiente regional de la CAAU que varía de 90 mm hasta 190 mm. La interacción entre ambas variables edáficas se hace evidente en suelos con contenidos de carbono orgánico altos que resultan en valores de rendimiento que incrementan a medida que el gradiente regional observado de la capacidad de retención de los suelos también aumenta. Las escalas de análisis de unidad geográfica y sitio no son intercambiables.

CAPITULO 4 PRODUCTIVIDAD DE LOS SUELOS PAMPEANOS

Development of a soil productivity index using an artificial neural network approach.

J.L. De Paepe y R. Alvarez. Agron. J. 105: 1803-1813. 2013.

CAPITULO 4. Productividad de los suelos pampeanos

4.1. Introducción

Para entender las relaciones causales de las propiedades del suelo y el rendimiento de los cultivos, los suelos han sido agrupados y clasificados según su productividad (Sarkar et al., 1966; Allgood y Gray 1978). La capacidad productiva de los suelos varía espacialmente como resultado de diferencias entre propiedades edáficas, la ubicación en el paisaje, la profundidad del suelo y la hidrología (Daniels et al., 1987). La reducción de la productividad de suelos por las acciones humanas y/o procesos naturales ha incrementado la necesidad de desarrollar métodos de cuantificación de la misma (Kim et al., 2000).

Algunas de las características de los suelos más productivos se relacionan a su contenido de carbono orgánico (Janzen et al., 1998; Doran 2002). Aproximadamente el 55 % de la materia orgánica de los suelos está compuesto de carbono orgánico y este porcentaje es relativamente estable en todos los suelos (Nelson y Sommers 1996). El carbono orgánico imprime características positivas sobre el suelo, algunas de las cuales se relacionan a otras propiedades físicas y químicas. Una propiedad física influenciada por el carbono orgánico es la estructura del suelo, vinculada a la agregación y su estabilidad (Six et al., 1999). A su vez, esta agregación y la estabilidad de la misma afectan la infiltración de agua, la CAAU y la aireación, así como también a la densidad aparente y la resistencia a la penetración (Carter 2002). En cuanto a las propiedades químicas, que en parte dependen del carbono orgánico, se incluye el pH, la disponibilidad y ciclado de nutrientes, la capacidad de intercambio catiónico y la capacidad buffer (Tisdall et al., 1986).

Un índice de productividad, que representa la capacidad de producir cierta cantidad de producto por hectárea y por año, está relacionado a propiedades edáficas a los que se les designa una valoración numérica por horizonte de suelo y, además puede incluir los requisitos nutricionales de un cultivo específico (Gale et al., 1991). La determinación de un índice de productividad permite establecer comparaciones entre las capacidades de producción de los distintos tipos de suelo presentes en una superficie determinada para establecer prácticas de manejo sustentables.

Para elaborar índices de productividad comúnmente se ha utilizado información sobre factores topográficos (Iqbal et al., 2005), la profundidad del horizonte A (Yang et al., 2003), la capacidad de almacenamiento de agua útil (Martín et al., 2006) o la fertilidad química (Udawatta y Henderson 2003). Una de las variables relacionadas a la fertilidad más empleadas para establecer la productividad de los suelos ha sido su nivel de materia orgánica (Bauer y Black 1994). Las propiedades microbiológicas del suelo, como por ejemplo la capacidad de mineralización de carbono y nitrógeno (Olson et al., 1996), también han sido usadas para cuantificar la productividad. Además, se pueden establecer índices de productividad de suelo que monitorean cambios en el perfil del suelo como resultado de procesos de erosión del suelo causados por el agua (Schumacher et al., 1999). Existen índices de productividad de tipo inductivo y deductivo que son detallados a continuación.

4.1.1. Índices de productividad inductivos

Los índices de productividad inductivos apuntan a determinar la productividad edáfica basados en asunciones teóricas referidas a la importancia de propiedades de suelo sobre el rendimiento de un cultivo (Huddleston 1984). De esta manera se generan calificaciones numéricas acerca de un suelo sin usar datos de rendimiento pero que pueden ser calibrados o evaluados posteriormente con esta información para un cultivo y región determinados.

La organización internacional FAO desarrolló un índice de productividad de suelos que considera nueve factores incorporados en una fórmula matemática multiplicativa (Riquier et al., 1970). De entre las varias características que influyen la productividad fueron

seleccionadas aquellas cuyo impacto sobre la productividad es más comúnmente aceptado, aquellas que se ya se encuentran disponibles de la literatura sobre la temática, aquellas que son de fácil medición y aquellas que tienen la menor cantidad posible de características secundarias en común para evitar la exageración de su significancia. Bajo la sección 4.3.1. se puede encontrar más información detallada de los factores incluidos en el índice de la FAO. En el cálculo se considera la interacción entre los factores y el factor limitante es el que finalmente determina el valor del índice de la FAO. Esta metodología demanda la disponibilidad de mucha información detallada, sin embargo ha sido aplicada en algunos países y para algunos cultivos se obtuvieron buenas correlaciones. En la Argentina, se aplicó este método a la información relevada para los mapas de suelo provinciales (GeoINTA 2014).

Para la implementación del índice desarrollado por la FAO en la Argentina, se hizo una regionalización climática a priori dividiendo a la República Argentina en ocho regiones (Sobral y Nakama 1988). Para esta regionalización se utilizaron las siguientes variables climáticas: isolíneas de índices hídricos con la metodología de Thornwaite (Burgos y Vidal 1951), isotermas medias anuales (Servicio Meteorológico Nacional, estadísticas climáticas) y regímenes de temperatura y humedad de suelos (Van Wambeke y Scoppa 1976). Además fueron consultadas otras clasificaciones como la Regionalización ecológica de la República Argentina (INTA-CIRN 1981) y los Distritos Agroclimáticos Argentinos (De Fina 1978). La Región Pampeana se encuentra ubicada en la Región I y es denominada Chaco-Pampeana Sur. Su límite norte es la isoterma media anual de 19 °C, por el este y sudeste está limitada por los Ríos Uruguay, La Plata y el Mar Argentino. En el sudoeste y el oeste el límite está constituido por la isolínea -20 del índice hídrico que representa la relación entre precipitación y evapotranspiración potencial (Burgos y Vidal 1951). Por la variación edafo-climática que presenta esta región además se la subdivide en sectores separados entre sí por las isolíneas +20, +10, 0 y -10 del índice hídrico y la isoterma media anual de 16 °C.

El índice de la FAO, se interpreta como una proporción del rendimiento máximo potencial de los cultivos más comunes de la región, bajo un nivel de manejo de medio a alto. La diferencia a 100, que es el máximo posible, del valor obtenido corresponde al porcentaje de disminución experimentado en los rendimientos máximos debido al efecto de una o más características. En Argentina ha sido validado únicamente con datos de rendimiento de trigo y maíz de sitios distribuidos en algunos partidos de la Provincia de Entre Ríos para la campaña 2009/2010 (Tasi et al., 2010; Gvozdénovich et al., 2012). No se ha validado este índice inductivo para trigo, u otros cultivos, a nivel regional. Tampoco se ha validado este índice para una serie temporal extensa para determinar si el índice puede incluir la variabilidad temporal del rendimiento de trigo en la Región Pampeana.

Más recientemente Kiniry et al., (1983) y Pierce et al., (1983) desarrollaron de manera independiente una metodología sencilla de evaluación cuantitativa de la productividad relacionada a la aptitud de un suelo para el crecimiento de raíces en el Corn Belt de Estados Unidos. Estos índices están basados en la tesis de Neill (1979), se pueden combinar, para aprovechar la información disponible, en un índice de productividad que en esta tesis se denomina índice Kiniry-Pierce. El ambiente edáfico se describe en términos de su suficiencia para el crecimiento radical y a su vez está influenciado por cinco variables de suelo. Este índice de productividad estudia cambios en profundidad de las características edáficas y estima la productividad de un suelo al caracterizar el ambiente edáfico para el enraizamiento del cultivo, además de evaluar la vulnerabilidad del suelo a la erosión (Pierce et al., 1983). Esta metodología también es multiplicativa lo que implica que cualquier variable puede ser limitante y al ser un método flexible, se permiten adaptaciones de los factores originales de suficiencia. Existen varias versiones modificadas de estos índices en los que declaraciones del mismo fueron alteradas o se incluyeron nuevas para representar características edáficas

locales (Rijsberman y Wolman 1985; Wilson et al., 1991). Este índice propuesto por Kiniry y Pierce, o su combinación, todavía no ha sido aplicado ni validado para ningún cultivo en la Región Pampeana.

4.1.2. Índices de productividad deductivos

Los índices de productividad deductivos se generan utilizando información de rendimiento obtenidos con modelos basados en procesos o ecuaciones empíricas (Huddleston 1984). Los modelos basados en procesos se construyen con ecuaciones matemáticas para modelar de manera cuantitativa las interacciones entre variables ambientales y factores del cultivo (Sinclair y Seligman 1996). Sin embargo, el factor limitante principal para su aplicación es la demanda de información para los procesos de parametrización y validación que no siempre se encuentra disponible particularmente en países en vías de desarrollo. La incertidumbre aumenta cuando la información proviene de investigaciones previas llevadas a cabo en condiciones ambientales no adecuadas o únicamente de opiniones de expertos (Park et al., 2005).

Los modelos empíricos apuntan a determinar relaciones funcionales entre factores de clima, suelo y manejo vs. el rendimiento de cultivos utilizando información disponible o experimentos a campo especialmente diseñados (Jame y Cutforth 1996). Cuando la información requerida está disponible, este tipo de modelos empíricos ofrecen una metodología confiable para investigar la respuesta de un cultivo determinado a condiciones ambientales. Una ventaja a destacar es que son relativamente fáciles de desarrollar y aplicar.

Se han desarrollado varios índices de productividad deductivos aplicados a varios cultivos. Con la información de rendimiento de maíz y soja, García-Paredes et al. (2000) generaron dos modelos con regresiones múltiples con los que generaron índices de productividad de suelos para Illinois, Estados Unidos. En el modelo de maíz se detectaron ocho variables de suelo mientras que en el modelo de soja seis; en ambos el efecto del contenido de arcilla, materia orgánica y limo fueron significativos. No se presenta un análisis del efecto de cada variable sobre el rendimiento o la interacción entre variables y no se puede realizar un análisis de la variabilidad interanual del set de datos ya que se trabajó con datos promedio de 10 campañas. Usando la misma metodología empírica se generaron modelos de estimación de la productividad de soja para las campañas 1982 y 1983 en Georgia (Bruce et al., 1990). Las isolíneas del rendimiento de soja muestran que el patrón de productividad está afectado por el contenido de carbono orgánico y arcilla de los suelos. Cuando el porcentaje de arcilla excedía el 20 %, la variable que definía la productividad de soja era el carbono.

Se ha descrito la productividad de los suelos pampeanos para trigo a través de un modelo generado con una RNA detectando efectos significativos de la CAAU y la fertilidad de los suelos (Alvarez y De Paepe 2010). El área de estudio fue de 26 Mha, que comprendía parte de las Provincias de Buenos Aires, La Pampa y Santa Fe, fue dividida en 10 unidades geográficas de ca. 2.6 Mha, cada una se asocia a una distribución edáfica y climática determinada y le corresponde un valor del índice de productividad. Se promedió la información de 10 campañas recientes (1995-2004) lo que no sólo redujo el set de datos a 100 ($n = 10$ unidades geográficas \times 10 campañas) sino que tampoco permitió el análisis de interacciones entre las variables con efecto significativo. Este índice de productividad deductivo no fue validado con datos de rendimiento asociados a escalas más pequeñas, como escala sitio, y/o más grandes como para un área de estudio más extensa. A partir de este antecedente local surge la necesidad de contar con un índice de productividad que permita evaluar la interacción entre las variables edáficas entre sí o bajo escenarios climáticos determinados y que además pueda ser validado a distintas escalas.

4.2. Objetivos

Testear con datos de rendimiento de trigo el índice inductivo de productividad de suelo desarrollado por la FAO aplicado en Argentina y el índice Kiniry-Pierce que es de fácil aplicación.

Generar un índice deductivo de productividad de suelos validado con datos de rendimiento de trigo a escala regional pampeana.

4.3. Materiales y métodos

4.3.1. Índices inductivos de productividad de suelos

La metodología de la FAO (Riquier et al., 1970) se utilizó en la Región Pampeana para calificar la productividad de los suelos y esta información se encuentra disponible en los mapas de suelo publicados por el INTA (INTA 1980, 1981, 1984, 1989a, 1989b, 2003). El índice de productividad de suelos propuesto por la FAO constituye un valor continuo que varía entre 0 y 100 pero fue adaptado para que varíe de 0 a 1 para poder compararlo con los otros índices de productividad testeados en esta tesis. Al ser un índice de productividad de tipo multiplicativo, el factor menos favorable es el que determina el valor final del mismo. También se considera la interacción entre factores ya que un suelo somero pero químicamente rico puede ser más productivo que un suelo más profundo pero más pobre. Este método permite una fácil y directa utilización del tipo y formato de la información edáfica existente. La expresión del índice de productividad es la siguiente:

$$IP = H \times D \times Pe \times Ta \times Tb \times Sa \times Na \times Mo \times T \times E$$

donde “IP” es el índice de productividad del perfil del suelo considerado, “H” la disponibilidad de agua, “D” el drenaje que representa el peligro de inundación, “Pe” la profundidad efectiva es decir el espesor útil del suelo para la penetración de raíces, “Ta” la textura del horizonte superficial, “Tb” la textura del horizonte subsuperficial, “Sa” el contenido de sales solubles, “Na” la alcalinidad sódica, “Mo” el contenido de materia orgánica (en el caso de estar expresado como carbono orgánico se multiplica por el factor 1.72) en el horizonte superficial, “T” la capacidad de intercambio catiónico y “E” la erosión. Los factores utilizados para el cálculo son seleccionados por su incidencia en el crecimiento y rendimiento de cultivos, pasturas y forestales más comunes de la región. Cada característica incluida en el índice tiene definido un rango crítico que corresponde al nivel de limitación presentado por el suelo para cada propiedad.

Los índices de productividad basados en la metodología de la FAO, que resultan de la combinación de todas estas variables que se multiplican entre sí, se encuentran publicados en los mapas de suelo de INTA por serie de suelo, por unidad cartográfica de suelo o por partido. Los valores del índice estaban publicados por lo tanto no fueron estimados y no se conocen los valores de los factores que los determinan ya que el detalle del cálculo no estaba incluido en los Mapas de Suelo utilizados. Para agregar espacialmente los valores del índice de productividad publicados por serie o por unidad cartográfica de suelo se siguió la metodología aplicada a las variables de suelo basada en promedios ponderados por superficie para obtener valores por unidades geográficas (Capítulo 2, ver sección Escala de análisis regional – Partido: Suelo). En el caso de que los valores ya se encontraran publicados por partido, la agregación espacial fue más directa ya que se calcularon los promedios ponderados por la superficie política de los partidos que conforman las unidades geográficas (Capítulo 2, ver sección Escala de análisis regional – Unidad geográfica). Finalmente, los datos del índice de productividad de suelos de la FAO agregados a la escala de análisis de unidad geográfica

fueron relacionados con datos de rendimiento correspondientes al período 1967-2006.

Los índices de productividad desarrollados por Kiniry et al. (1983) y Pierce et al. (1983) se basan en funciones de respuesta del crecimiento de raíces a las variables edáficas, llamadas suficiencias, que según estos autores determinan el rendimiento de un cultivo. Cada variable se evalúa en términos de la respuesta radical y cada estrato de suelo se pondera de acuerdo a una distribución de enraizamiento ideal. Las variables incluidas en el cálculo son la CAAU, la aireación, la densidad aparente, el pH y la conductividad eléctrica. Las suficiencias de estas cinco variables se calculan para cada estrato de suelo y varían de 0 a 1 y el producto de todas las suficiencias describe la suficiencia fraccionaria de cada estrato de suelo para el crecimiento radical. Los valores del índice de productividad Kiniry-Pierce, cuya estimación se detalla a continuación, fueron agregados a la escala de análisis de unidad geográfica y además relacionados con datos de rendimiento correspondientes al período 1967-2006.

El modelo de índice de productividad desarrollado por Neill (1979) se desarrolló originalmente para el cultivo de maíz y para poder aplicarlo al cultivo de trigo se adaptó la variable profundidad de enraizamiento específica de un cultivo de la ecuación de Horn (Horn 1971). La ecuación de Horn permite estimar la fracción de raíces en profundidad para suelos que presentan condiciones ideales para su crecimiento relacionado principalmente al consumo de agua. La profundidad de enraizamiento óptima para trigo en la Región Pampeana que se utilizó fue de 100 cm según estimaciones de Calviño y Sadras (2002). La ecuación aplicada se describe de la siguiente manera:

$$F = 0.152 \log\left(R + \sqrt{R^2 + 6.45}\right) - 0.152 \log\left(P + \sqrt{P^2 + 6.45}\right)$$

donde “F” es la fracción de raíces para un estrato de suelo determinado, “R” es la profundidad de enraizamiento óptima del cultivo y “P” es la profundidad del estrato.

El trigo se cultiva en suelos bien drenados que no tienen problemas de salinidad por lo que se asumió un valor de 1 para la suficiencia de conductividad eléctrica que también se propone en el trabajo de Kiniry et al. (1983). En aproximadamente la mitad de los perfiles de suelo descriptos en los mapas de suelo de INTA no se reportan los valores de conductividad eléctrica, generalmente porque son suelos no salinos, por lo que no es posible agregar espacialmente esta información a escala partido y ajustar las suficiencias a estos datos. También la suficiencia para la aireación fue establecida en un valor de 1 ya que las áreas inundables del área de estudio donde podrían presentarse problemas de anoxia fueron descartados previamente del set de datos como se describe en el Capítulo 2 (ver sección Escala de análisis regional – Partido: Rendimiento).

Las suficiencias para la CAAU, densidad aparente y pH fueron estimadas por cada estrato de 25 cm hasta un metro de profundidad o hasta el límite superior de la capa petrocálcica. La suficiencia para la CAAU se basa en la estimación de la cantidad de agua necesaria para suplir el déficit hídrico que rige cuando la precipitación durante el período de crecimiento no cubre lo que se pierde por evapotranspiración. Los valores de CAAU estimados por partido a partir de los datos de los mapas de suelo de INTA se encontraban en mm de agua por estrato de 25 cm de suelo según se detalla en el Capítulo 2 (ver sección Escala de análisis regional – Partido: Suelos) y fueron afectados por un factor de 0,1 para pasar a datos de cm de agua por cm de suelo para el cálculo de la suficiencia. Según Kiniry et al. (1983) la suficiencia de CAAU se estima dividiendo el valor de la CAAU (cm cm^{-1}) por 0,2. Cuando la CAAU de un estrato determinado es mayor a 0,2, la suficiencia de CAAU es igual a 1, lo que se interpreta como que ese estrato de suelo no presenta condiciones limitantes para el enraizamiento del cultivo.

Con los datos de integrados de los mapas de suelo de INTA cada 25 cm hasta el primer metro de profundidad o hasta el límite superior de la capa petrocálcica, se estimó la

densidad aparente (g cm^{-3}) siguiendo la metodología propuesta en el trabajo de Rawls (1983) como se detalla en el Capítulo 2 (ver sección Escala de análisis regional – Partido: Suelo). Este método sobreestima un 4 % la densidad aparente con respecto de los valores medidos a campo en la Región Pampeana según Berhongaray et al. (2013) y por esta razón se afectaron por este porcentaje a todos los valores estimados. La suficiencia de la densidad aparente, que constituye un indicador del desarrollo radical del cultivo, propuesta por Pierce et al. (1983) se representa a través de una curva. La curva de suficiencia va disminuyendo a medida que la densidad aparente va aumentando y atraviesa tres sectores: primero el sector “no limitante” (con un valor de suficiencia 1), segundo el sector “crítico” cuando la suficiencia disminuye hasta un valor de 0,826 y tercero el sector “limitante” cuando la suficiencia sigue disminuyendo por debajo del valor crítico hasta restringir totalmente el desarrollo radical. Para la estimación de la suficiencia de la densidad aparente se utilizó una adaptación realizada por Udawatta y Henderson (2003) que permite utilizar la información disponible de porcentaje de arena, limo y arcilla por estrato de suelo. Las ecuaciones definen las suficiencias de las densidades aparentes (g cm^{-3}) de los puntos de inflexión que definen los tres sectores:

$$\text{Densidad aparente "no-limitante"} = 0,0165 \times \text{arena} + 0,0141 \times \text{limo} + 0,0117 \times \text{arcilla}$$

$$\text{Densidad aparente "crítica"} = 0,0175 \times \text{arena} + 0,0168 \times \text{limo} + 0,0122 \times \text{arcilla}$$

$$\text{Densidad aparente "limitante"} = 0,0192 \times \text{arena} + 0,0182 \times \text{limo} + 0,0124 \times \text{arcilla}$$

La suficiencia de densidad aparente es 1 para el valor de densidad aparente estimado con la ecuación de “no limitante”, la suficiencia es 0,83 para el valor de densidad aparente estimado con la ecuación de “crítico” y la suficiencia es 0 para el valor de la densidad aparente estimado con la ecuación de “limitante”. A través de una interpolación lineal de la ecuación correspondiente a la línea recta entre los dos puntos de suficiencia y sus respectivos valores de densidad aparente estimados con las ecuaciones correspondientes se determinaron los valores intermedios de suficiencia de las densidades aparentes.

Se utilizaron las tres ecuaciones propuestas en el trabajo de Pierce et al. (1983) para determinar los valores de la suficiencia de pH que se relaciona a la toxicidad de aluminio sobre los cultivos. La suficiencia de pH fue de 1 cuando el valor estimado de pH se encontraba dentro del rango 7.5 – 5.5, cuando los valores de pH eran menores correspondientes al rango de 5.5-5 se utilizó la ecuación $\text{pH} = 0,16 \cdot \text{pH} + 0,2$; mientras que si el rango era de 5-2.9 la ecuación utilizada era $\text{pH} = 0,446 \cdot \text{pH} - 1.31$.

Kiniry et al. (1983) además propone incluir una suficiencia relativa de clima a las suficiencias de las variables edáficas mencionadas utilizando una regresión múltiple con datos climáticos como en el trabajo de Leeper et al. (1974). La metodología de estimación de esta suficiencia fue la de regresión de respuesta polinomial de superficie con el rendimiento de trigo sin tendencia temporal como variable dependiente y se ajustaron modelos con las siguientes variables climáticas: temperatura, precipitación, evapotranspiración potencial y coeficiente fototérmico mensuales (desde abril hasta noviembre) en combinaciones varias e integradas para las fases de barbecho, crecimiento vegetativo y floración del cultivo. El 75 % de los datos fueron utilizados para generar el modelo para estimar la suficiencia relativa de clima y el 25 % independiente y restante fue utilizado para validar el mismo. El valor más alto de rendimiento estimado obtuvo el valor de 1 de suficiencia y todos los otros valores fueron relativizados con respecto a este máximo. Para cada partido se utilizó el promedio histórico de la suficiencia relativa de clima.

Los valores de la fracción de raíces, la suficiencia de CAAU, de densidad aparente, de pH y de clima fueron multiplicados por estrato y estos valores a su vez fueron sumados desde el estrato 0-25 cm hasta el estrato 75-100 cm, o hasta la profundidad del límite superior de la

capa de tosca, resultando en un valor de índice de productividad de suelos Kiniry-Pierce por partido. Los valores de estos índices por partido fueron ponderados por su superficie para obtener índices por unidad geográfica.

Siguiendo la propuesta por Wilson et al. (1991) se incorporó además una suficiencia del contenido de materia orgánica de los suelos al índice de productividad de Kiniry-Pierce. Esta suficiencia fue incluida como un factor aditivo ya que su efecto no es proporcional al rendimiento lo que significa que los aumentos de materia orgánica no necesariamente resultan en aumentos en el rendimiento según Pierce et al. (1983) y Kiniry et al. (1983). Esta suficiencia, correspondiente al estrato 0-25 cm, fue considerada como factor aditivo al índice de productividad. Se consideró el promedio del contenido de carbono orgánico, para el estrato mencionado, correspondiente a las cuatro décadas analizadas ya que se trabajó con el promedio del rendimiento para el mismo período. La pendiente de la relación del contenido de carbono orgánico y el rendimiento fue de 10,3, lo que indica que un incremento de ca. 10 t ha⁻¹ de carbono orgánico en suelos resulta en el aumento de aproximadamente 100 kg ha⁻¹ en el rendimiento. Por esta relación, a los partidos con suelos tenían 30-40 t ha⁻¹ de carbono orgánico en el estrato superficial se le sumó un factor de suficiencia equivalente a 0,04, 0,05 cuando el contenido varió entre 40-50 t ha⁻¹, 0,07 cuando varió entre 50-60 t ha⁻¹, 0,08 cuando varió entre 60-70 t ha⁻¹, 0,09 cuando varió entre 70-80 t ha⁻¹ y 0,1 cuando varió de 80-90 t ha⁻¹.

4.3.2. Índices deductivos de productividad de suelos

Se testearon tres metodologías de modelización empírica del rendimiento regional de trigo de la Región Pampeana: regresión polinómica, árboles de regresión y RNA. Los resultados de estas modelizaciones empíricas fueron desarrollados y discutidos en el Capítulo 3. La metodología empírica seleccionada para la generación de un índice de productividad deductivo fue el modelo ajustado con una RNA porque obtuvo el mejor ajuste ($R^2 = 0,614$, $P = 0,05$), el menor error ($RMSE = 429 \text{ t ha}^{-1}$) y la mayor cantidad de variables de clima y suelo detectadas con un efecto significativo. El peso de cada variable seleccionada por esta metodología así como la interacción entre las variables independientes bajo distintos escenarios y su efecto sobre el rendimiento fueron evaluados en el capítulo anterior de esta tesis.

Para generar un índice de productividad deductivo utilizando el modelo de la RNA se le designó un valor de 1 al rendimiento más alto estimado, considerando todas las unidades geográficas y para las 40 campañas analizadas, y todos los otros rendimientos estimados recibieron valores relativos a éste máximo. De esta manera se obtuvo un set de datos de 1640 valores del índice de productividad deductivo. También se estimó el promedio histórico por unidad geográfica del índice deductivo, y este valor fue correlacionado al promedio de rendimiento correspondiente al mismo período de la misma unidad geográfica.

Tanto los índices de productividad inductivos y como los deductivos fueron presentados en forma de mapas utilizando el programa ArcGIS 9.1 (ESRI, Copyright © 2005).

4.4. Resultados

El índice de productividad de suelos de tipo inductivo propuesto por la FAO y aplicado en la Región Pampeana a escala unidad geográfica varió de 0,29 a 0,89. Si se considera la distribución geográfica de los valores se observa que 22 unidades geográficas tienen índices menores a 0,5 y los valores más bajos corresponden a las unidades geográficas

de la Región Semiárida Pampeana. Únicamente 6 unidades geográficas tienen un índice que supera el valor 0,7 y éstos se ubican en la Pampa Ondulada principalmente (**Figura 4.1.A**). Los valores intermedios fueron estimados para la Pampa Austral. Un 43,3 % de la variabilidad en el rendimiento promedio por unidad geográfica fue explicado por el índice de la FAO pero esta relación lineal presenta dispersión (**Figura 4.1.B**). La pendiente, que fue distinta de 1, de esta relación lineal significa que por un aumento de 0,1 en el índice de productividad el rendimiento promedio aumentaba 170 kg ha^{-1} y la ordenada además fue distinta de 0.

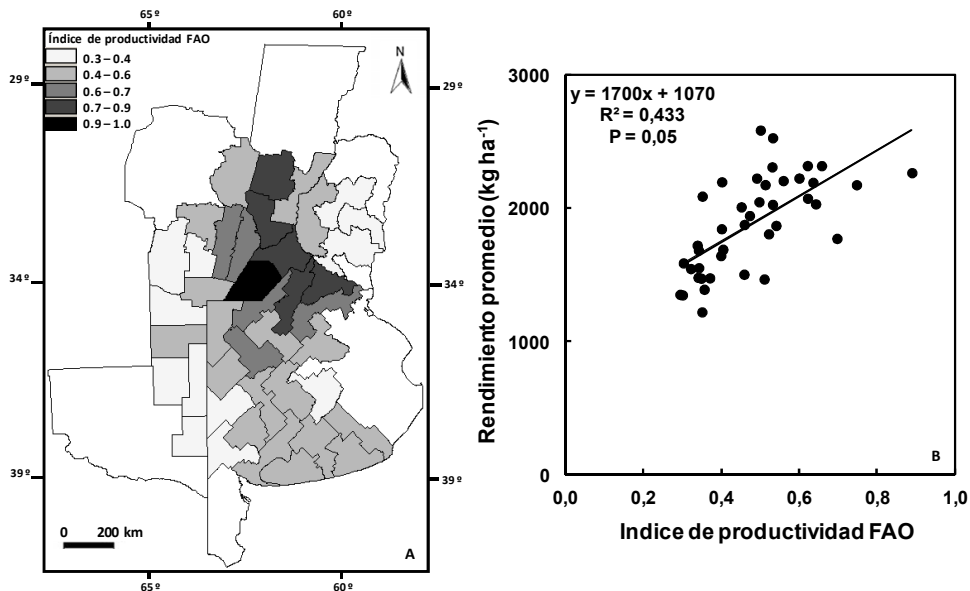


Figura 4.1.A. Distribución espacial del índice de productividad de suelos basado en la metodología propuesta por la FAO (Riquier et al., 1970) por unidad geográfica y **B.** muestra su relación con el rendimiento promedio del período 1967-2006.

Los factores por los que fueron afectados los estratos de suelo 0-25 cm, 25-50 cm, 50-75 cm y 75-100 cm al aplicar la ecuación de Horn de la fracción de raíces fueron 0,567; 0,268; 0,129 y 0,037 respectivamente. Los valores más altos de la suficiencia de la CAAU se encontraron en el estrato superficial y en las unidades geográficas ubicadas en la Pampa Ondulada y la Pampa Mesopotámica recibieron valores de 1. Las suficiencias de CAAU menores correspondían al estrato 75-100 cm de las unidades geográficas de la Región Semiárida Pampeana. En cuanto a la suficiencia de la densidad aparente, en ningún caso fue necesario estimar la ecuación correspondiente al sector “limitante” porque los valores se encontraban por debajo de la densidad aparente que limita el crecimiento radical. Las suficiencias de la densidad aparente fueron de 1 casi en todos los casos exceptuando algunos estratos de unidades geográficas de la Mesopotámica. En esta sub-región pampeana el valor más alto de densidad aparente registrado fue de 1.42 g cm^{-3} en el estrato más profundo; para este valor y varios otros se estimaron los puntos de inflexión de “no limitante” y “crítico” para definir la ecuación del sector y estimar las suficiencias correspondientes y calculadas por interpolación lineal. La suficiencia de pH fue de 1 para todos los estratos de todas las unidades geográficas porque los valores siempre superaron el valor crítico de 5.5.

Se desarrolló un modelo de regresión múltiple, para generar una suficiencia relativa al clima, que tuvo un ajuste de $R^2 = 0,247$ ($P = 0,05$). Las variables climáticas incluidas fueron: la precipitación/evapotranspiración durante el período de barbecho, fase vegetativa y floración

y coeficiente fototérmico. Se obtuvieron valores de 0,64-0,67 en promedio en las unidades geográficas ubicadas hacia el oeste del área de estudio, específicamente en la Provincia de Córdoba y La Pampa, mientras que los del este, y específicamente en la Pampa Austral, obtuvieron las mayores suficiencias y equivalentes a 0,85. Finalmente, en cuanto a la suficiencia del contenido de carbono orgánico promedio se observaron variaciones de entre 0,06 y 0,15 y el menor valor corresponde a una unidad geográfica del oeste de Córdoba mientras que los valores más altos fueron estimados para las unidades geográficas de la Pampa Austral.

El promedio del índice Kiniry Pierce de 0,55 (0,33-0,76) fue menor al promedio de 0,67 (0,40-0,89) del índice adaptado al que se le agregó una suficiencia de materia orgánica (**Figura 4.2.A. y B.**). A pesar de esta diferencia, que también se observa en los mayores valores máximos y mínimos del índice adaptado, la relación del índice original y su versión adaptada con el promedio de rendimiento de las 40 campañas por unidad geográfica fue muy similar tanto en el nivel de ajuste de la relación lineal como en su dispersión. En ambos casos la pendiente fue distinta de 1 y la ordenada distinta de 0.

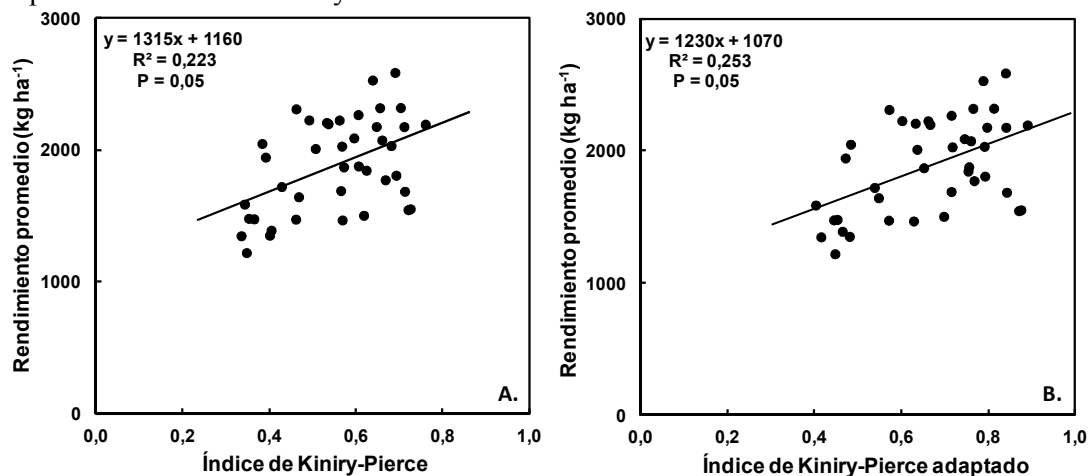


Figura 4.2. A. Relación entre el índice de productividad de suelo inductivo Kiniry-Pierce y B. su versión adaptada con la inclusión de una suficiencia para materia orgánica vs. el rendimiento promedio de trigo por unidad geográfica.

Con respecto a la distribución espacial del índice de productividad regional del modelo basado en una RNA se observaron valores de productividad más altos en las unidades geográficas de la porción húmeda y más bajos en las de la porción semiárida (**Figura 4.3.A**). Un 17 % de las unidades geográficas obtuvieron un valor estimado de índice de productividad mayor a 0,9, un 60 % varió entre 0,7 – 0,9 y en un 23 % se observaron valores menores a 0,7. El índice de productividad deductivo promedio por unidad geográfica para los 40 años analizados fue correlacionado con el rendimiento promedio histórico alcanzando un buen ajuste ($R^2 = 0,728$) con una ordenada al origen de 0 y pendiente de 1 (**Figura 4.3.B**).

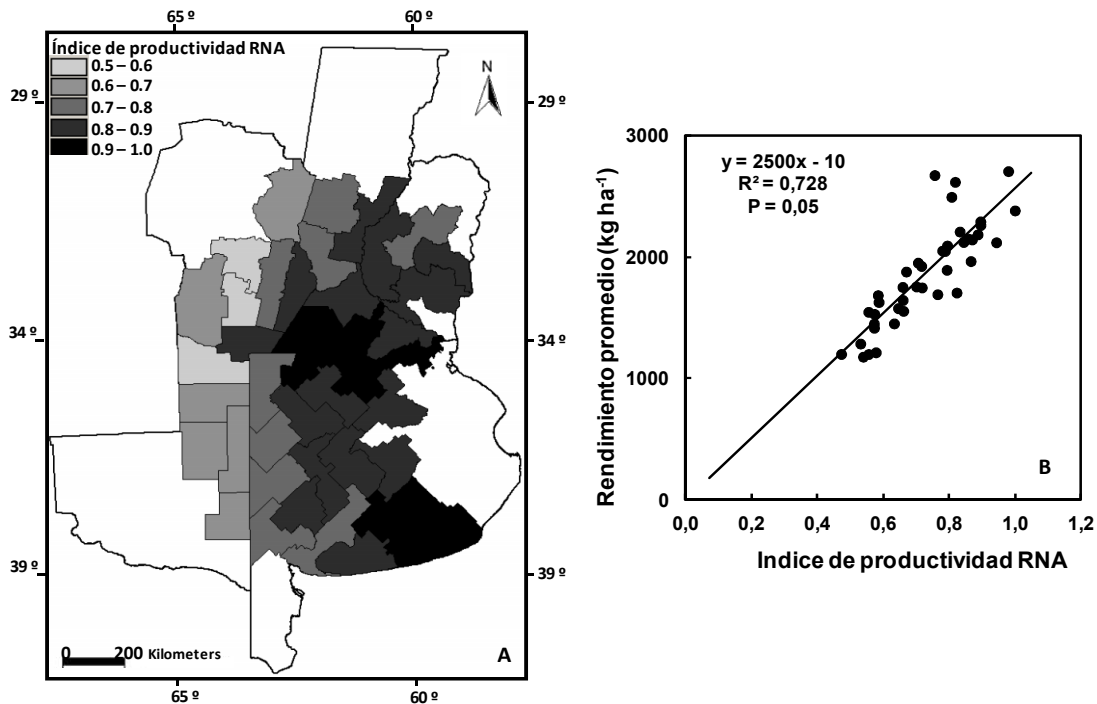


Figura 4.3.A. Distribución espacial del índice de productividad deductivo promedio estimado con una RNA y **B.** representa la relación del índice deductivo con el rendimiento promedio durante 1967-2006.

Al relacionar las variables independientes promedio por unidad geográfica del modelo de la RNA con el índice de productividad de la FAO se observa que la CAAU es la variable que se encuentra más relacionada explicando casi un 22 % de la variabilidad del índice (**Figura 4.4.B.**). Las otras variables independientes de clima y suelo no se relacionan significativamente con el rendimiento promedio (**Figura 4.4. A., C., D., E. y F.**). La relación del carbono orgánico promedio de los últimos 40 años parece mostrar una relación curvilínea con el índice de productividad de la FAO, aunque no es significativa estadísticamente (**Figura 4.4.A.**).

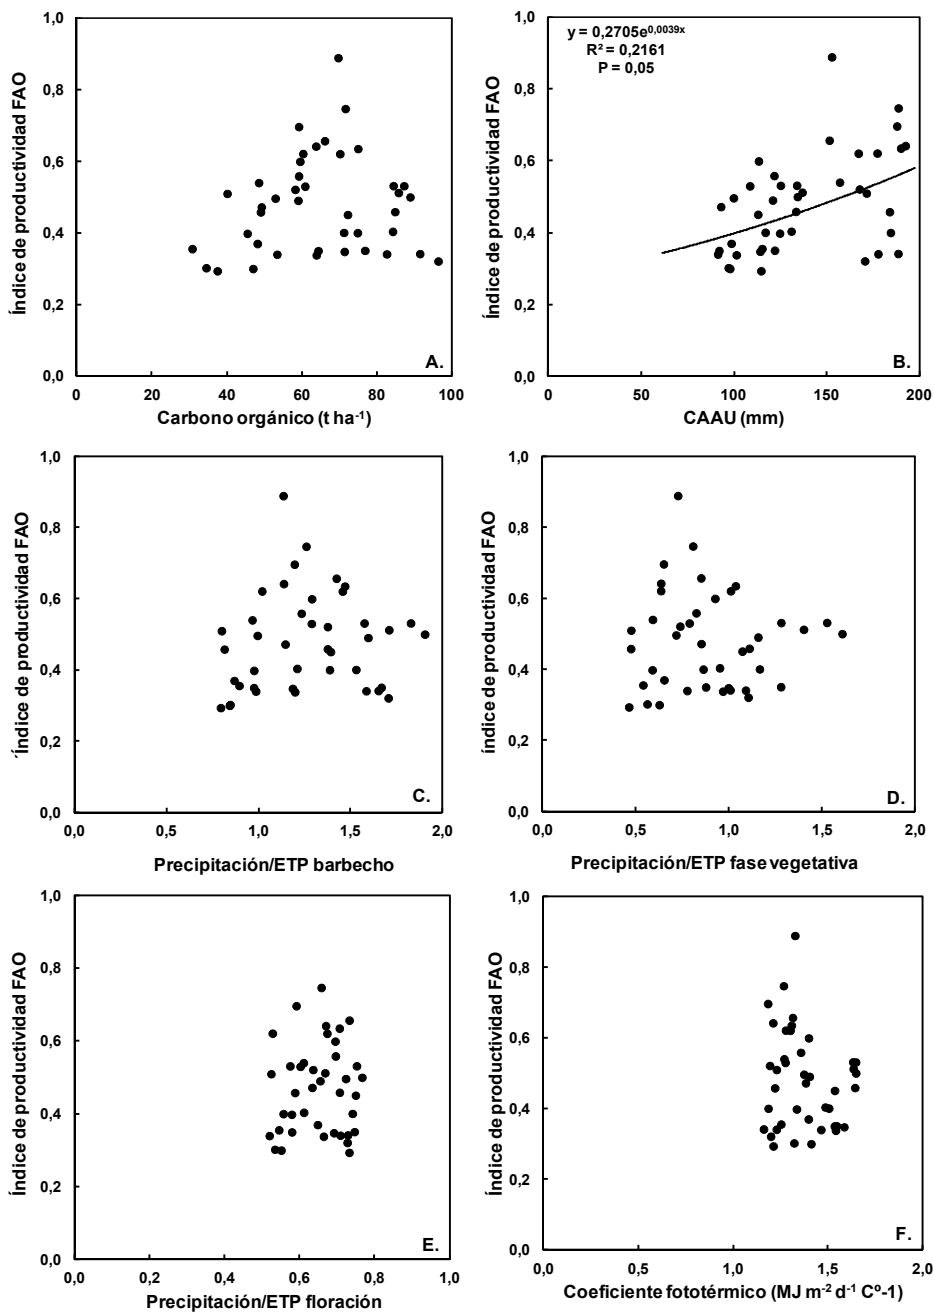


Figura 4.4. Relación entre las variables independientes de suelo y clima del modelo de RNA vs. el índice de productividad de suelos de la FAO.

El modelo empírico basado en una red neuronal fue utilizado para predecir la productividad de suelos pampeanos para combinaciones de variables de suelo a través de un índice. Las dos variables de suelo, CAAU y carbono orgánico, detectadas por su efecto significativo presentan una interacción positiva (**Figura 4.5**). El modelo indica que la productividad máxima se logra en suelos con un contenido de carbono orgánico promedio de $70\ t\ ha^{-1}$ que además tienen la capacidad de retener hasta 140 mm de agua útil en el primer metro de su perfil. Cuando el contenido de carbono es muy bajo, inferior a las $30\ t\ ha^{-1}$, se

observan valores muy bajos del índice aún en suelos con CAAU altas. Lo mismo se observa en suelos cuya CAAU es inferior a los 100 mm en combinación con contenidos de carbono orgánicos altos, superiores a las 80 t ha⁻¹, que resultan en valores bajos del índice. Si bien la salida del modelo se ha graficado en forma completa en la **Figura 4.5**, en el set de datos usados para desarrollar la RNA no existieron datos con baja CAAU y más de 80 t ha⁻¹ de carbono, por lo que las isolíneas del extremo inferior derecho de la figura no están validadas por información de rendimiento.




Figura 4.5. Interacción entre el contenido de carbono orgánico de suelo y capacidad de almacenamiento de agua útil (CAAU) que conforman el índice de productividad estimado por el modelo de RNA.

4.5. Discusión

La variabilidad del rendimiento de trigo explicado por el índice de productividad inductivo desarrollado por la FAO llega a un 43 %, que considerando la complejidad de determinación de algunos de los parámetros incluidos en el mismo no es menor. El índice se encuentra afectado por nueve variables de suelo de los cuales algunos requieren métodos de estimación en laboratorio complejos, como el caso de la variable “T” (capacidad de intercambio catiónico) de cuyo valor depende la variable “Na” (alcalinidad sódica), y otros de conocimiento de expertos basado en ensayos experimentales de largo plazo como el parámetro “E” (erosión). Para determinar la variable climática “H” (disponibilidad de agua) se requiere de un conocimiento detallado por parte de un especialista de los regímenes de temperatura y humedad de los suelos.

La relación del índice de productividad de la FAO con el rendimiento promedio por unidad geográfica presentó una amplia distribución y por ejemplo para un valor de 0,5 del índice de productividad de la FAO el rendimiento promedio varió ampliamente pasando por un valor de rendimiento mínimo de 1400 kg ha⁻¹ a un máximo de 2600 kg ha⁻¹. Cuando se relacionan algunas de las variables independientes seleccionadas por su efecto significativo sobre el rendimiento a escala regional, únicamente la CAAU explica un porcentaje significativo, más de un 21 %, de la variabilidad del índice de la FAO, indicando que la capacidad de predicción de la productividad de los suelos pampeanos por parte del índice de la FAO mejora cuando los suelos incrementan su CAAU. Ninguna otra variable independiente, tanto de suelo como de clima, se relaciona significativamente a éste índice.

Los índices de productividad de Kiniry et al., (1983) y Pierce et al., (1983)

combinados en un índice denominado Kiniry-Pierce para aprovechar la información disponible no mostraron ser una buena herramienta para estimar el rendimiento a escala regional. Este índice todavía no había sido aplicado en la Región Pampeana y fue seleccionado por la sencillez de estimación de sus parámetros, denominados suficiencias. La suficiencia de pH en ningún caso fue menor a 1 porque no se detectaron suelos con pH menores a 5.5 que adquiere importancia con respecto a la toxicidad de aluminio. La suficiencia de la densidad aparente en muy pocos casos fue menor a 1 y esto concuerda con un relevamiento regional reciente que muestra que los suelos pampeanos rara vez superan umbrales de densidad aparente de 1.5 g ml^{-1} (Álvarez et al., 2014).

La relación de éste índice con el rendimiento promedio no fue muy buena y tampoco mejoró mucho al incluir una suficiencia de materia orgánica, contrariamente a lo que pasó en el trabajo de Wilson et al. (1991) donde la estimación del rendimiento de trigo y cebada mejoró un 44 % en promedio. Cabe mencionar que el modelo original se desarrolló para cereales que crecían en el Corn Belt estadounidense y los ensayos experimentales del trabajo de Wilson et al. (1991) se ubicaron en el norte de las grandes planicies es decir que no están tan alejadas espacialmente. Duan et al. (2009) también pudieron mejorar este índice inductivo agregando como parámetros el contenido de arcilla y materia orgánica para estimar el rendimiento de maíz en el noreste de China. A pesar de la lejanía espacial, las condiciones climáticas de esta última región, con temperaturas medias anuales que varían de -5.7 a 4.1°C , son semejantes a las condiciones de los ensayos de Wilson et al. (1991). La variabilidad no explicada por el índice Kiniry-Pierce y su adaptación propuesta aquí, postula la necesidad de desarrollar otras suficiencias no incluidas en el modelo original o reemplazar las existentes para adaptarlo a las condiciones, principalmente, climáticas más cálidas de la Región Pampeana y mejorar el mismo para además poder monitorear su variación geográfica.

La evaluación de la productividad basada en propiedades edáficas puede presentar una variación espacial considerable (Lindstrom et al., 1992). Con el índice deductivo estimado a través de una RNA se pudo explicar casi el 73 % de la variabilidad del rendimiento promedio por unidad geográfica. Esta alta correlación con el rendimiento también se ve reflejada en la distribución espacial representada a través de un mapa. Los valores más altos del índice se observan en las sub-regiones de la Pampa Ondulada, que presenta los suelos más profundos con contenidos de carbono orgánico medios, y en la Pampa Austral, que son algo más someros pero con contenidos de carbono orgánico altos, ambos con regímenes de precipitación mayores a los 850 mm anuales. Por un lado, la CAAU tiene un efecto significativo sobre la productividad de los suelos pampeanos, esta propiedad es crucial para lograr una productividad alta ya que es un requisito para el crecimiento vegetal (Shaxson 2006) y por lo tanto se correlaciona fuertemente con el rendimiento de cultivos (Wong y Asseng 2006). La importancia de esta variable definiendo la productividad de los suelos pampeanos fue reafirmada cuando fue detectada por su efecto significativo sobre el índice de la FAO, explicando casi un 22 % de la variabilidad del mismo. Por otro lado, el carbono orgánico influencia la estructura física de los suelos (Franzluebbers 2002) y la disponibilidad de nutrientes, ambos relacionados a la productividad (Mueller et al., 2010).

La productividad de los suelos pampeanos está determinada por la CAAU y el carbono orgánico, según el índice desarrollado con una RNA, y estas dos variables de suelo no requieren métodos de estimación en laboratorio complejos. El contenido de carbono orgánico de los suelos puede ser estimado a través de dos técnicas de medición muy conocidas. Para la determinación de la CAAU, se necesita información de la textura que se estima a través del método del hidrómetro de Bouyoucous (Gee y Bauder 1996) para aplicar las ecuaciones de Rawls (1982) descrito en el Capítulo 2.

El análisis de la interacción de las variables edáficas seleccionadas muestra que la

productividad edáfica pampeana pasa por un óptimo. Se observan disminuciones en la productividad estimada por este modelo en suelos con texturas finas en combinación con índices climáticos de precipitación/evapotranspiración elevados (durante el barbecho, fase vegetativa del crecimiento del cultivo y floración). Esto se atribuye a un posible efecto confundido que se puede dar en la porción más húmeda, como la Pampa Mesopotámica, en la que predominan suelos con texturas finas junto los regímenes de lluvia intensos que determinan disminución en el rendimiento de trigo por enfermedades (Annone, 2001) y condiciones de anegamiento temporales (De San Celedonio et al., 2014). Efectos confundidos entre variables ambientales son problemas comunes de la modelización del rendimiento de cultivos y por este motivo es importante tener precauciones al interpretar los resultados de dichas predicciones (Bakker et al., 2005).

La interacción de la CAAU y la fertilidad edáfica bajo distintos escenarios climáticos representativos de la Región Húmeda y Semiárida Pampeanas (este y oeste de la isohieta anual de 800 mm) muestra efectos significativos sobre el índice de productividad. Para la Región Semiárida Pampeana cuando el contenido de carbono orgánico aumentó de 40 t ha^{-1} a 70 t ha^{-1} , el índice aumentó de 0,3 a 0,9 mientras que este aumento en la región húmeda resultó en un aumento mucho menor de 0,7 a 0,9 (datos no mostrados). De manera similar un aumento en la capacidad de almacenamiento de agua útil de 100 mm a 140 mm en la Región Semiárida Pampeana resultó en un incremento de 0,5 unidades en el índice de productividad mientras que sólo resultó en un aumento de 0,2 unidades en la porción húmeda pampeana.

4.6. Consideraciones finales

El modelo de estimación del rendimiento ajustado con una RNA resultó ser una buena herramienta para desarrollar un índice de productividad para los suelos pampeanos a nivel regional. El ajuste con el rendimiento promedio de las unidades geográficas analizadas fue de aproximadamente un 30 % mejor que lo logrado con el índice de la FAO y 50 % mejor que lo logrado con el índice Kiniry-Pierce. No se pudo mejorar el ajuste del índice Kiniry-Pierce al agregarle una suficiencia relacionada al contenido de carbono orgánico de los suelos lo que indicaría que este índice probablemente no corresponde a las condiciones climáticas regionales más cálidas que las condiciones para las que fue diseñado el índice original.

El índice de productividad basado en la RNA mostró que la producción de trigo a escala regional está determinada por la interacción positiva entre el carbono orgánico y la CAAU. La RNA puede ser utilizada como herramienta para generar índices de productividad deductivos en otras regiones y para otros cultivos.

CAPITULO 5
BRECHA DE RENDIMIENTO
Y PRODUCTIVIDAD

CAPITULO 5. Brecha de rendimiento y productividad

5.1. Introducción

La dieta humana depende en gran medida de la producción de trigo, maíz y arroz cuya producción se incrementó significativamente durante los últimos 50 años en parte debido a extensiones en el área cultivada y el uso de nuevas variedades pero, principalmente, como consecuencia de la intensificación del manejo agrícola e introducción de nuevas tecnologías (Cassman 1999; Foley et al., 2005). La demanda de productos agrícolas seguirá aumentando en el futuro (Rosegrant y Cline 2003) y es muy poco probable que sea satisfecha por la ampliación de la superficie cultivada únicamente ya que las tierras productivas restantes son escasas y su demanda para otros usos también está en aumento (DeFries et al., 2004). La intensificación de la agricultura juega un rol fundamental en lograr mayores rendimientos que apuntan al suministro de alimentos (Ruttan 2002), sin embargo, en varias regiones los rendimientos parecen haber alcanzado un plateau o inclusive se encuentran en disminución (Trostle 2008).

La brecha de rendimiento es la diferencia entre el rendimiento potencial, el alcanzable o el máximo alcanzado con respecto a un rendimiento menor que puede ser el logrado por productores durante una campaña determinada (van Ittersum et al., 2013). El rendimiento potencial es específico de una ubicación geográfica y en teoría no depende de las propiedades del suelo asumiendo que la cantidad de agua y nutrientes requeridos puede ser agregada a través del manejo del cultivo (Evans, 1998). Este nivel de rendimiento es el punto de referencia más relevante en sistemas irrigados o en sistemas de producción húmedos donde la provisión de agua es suficiente para evitar déficits hídricos. En cambio, el rendimiento alcanzable es un punto de referencia útil en sistemas donde el cultivo sí atraviesa períodos de estrés hídrico durante algún momento de su crecimiento y por lo tanto depende en mayor medida del tipo de suelo, definido por la capacidad de almacenamiento de agua útil y profundidad de enraizamiento, y la topografía del lote que se relaciona con la escorrentía (Van Ittersum et al., 2013). El rendimiento máximo alcanzado por productores es aquel nivel de producción que se logra por la combinación de condiciones climáticas y de suelo óptimas durante una campaña determinada, con muy bajo impacto de adversidades y fallas de manejo. El rendimiento alcanzado representa la variación en tiempo y espacio en una región geográfica del rendimiento bajo las prácticas de manejo comúnmente utilizadas (Van Ittersum et al., 2013) y casi siempre es mucho menor al rendimiento máximo alcanzado (Laborte et al., 2012).

La cuantificación de la brecha de rendimiento pretende ayudar a comprender cómo y cuánto debería aumentar el rendimiento alcanzado para lograr un nivel de producción mayor (Evans, 1998). En los sistemas de producción de secano la brecha de rendimiento se estima con respecto al rendimiento alcanzable (Evans, 1998) o al rendimiento máximo alcanzado que se determina a partir de información de estadísticas nacionales (Hall et al., 2012). La brecha calculada en el último caso permitiría identificar aquellas combinaciones de condiciones tecnológicas locales relacionadas a condiciones edafo-climáticas que resultan en las menores diferencias bajo escenarios de manejo habituales.

Se han observado brechas de rendimiento de magnitudes importantes para varios cultivos y para diversas regiones del Mundo (Abeledo et al., 2008) así como también regiones donde esta brecha se está achicando (van Rees et al., 2014). Varios estudios presentaron estimaciones de la brecha de rendimiento para la producción de trigo en los Países Bajos (van Ittersum et al., 2013) y en Australia (Hochman et al., 2013), para arroz en el sudeste de Asia (Kropff et al., 1993) y para

maíz en Nebraska-USA (Grassini et al., 2011). Existen varias aproximaciones de estimación de esta brecha, comentadas en el Capítulo 1 (**Figura 1.2.**), cada una con sus respectivas ventajas y desventajas, y algunas son más útiles para determinadas regiones que otras (Coelli et al., 2005; Fischer et al., 2009). A nivel local se ha analizado la brecha de rendimiento de girasol en secano durante el período 2000-2007 y los resultados muestran que varió entre 0,37 y 1,18 t ha⁻¹, con un promedio de 0,75 t ha⁻¹ que equivale a un 41 % del promedio nacional de rendimiento (1,85 t ha⁻¹) sin identificarse los factores que lo determinan (Hall et al., 2013).

En esta tesis se introduce, adicionalmente, el concepto de brecha de productividad, calculada como la diferencia promedio entre el rendimiento máximo alcanzado y un nivel de rendimiento promedio logrado a lo largo del tiempo (Figura 1.2.). Al trabajar con promedios de rendimiento en lugar de datos anuales se elimina la variabilidad climática interanual (Lobell et al., 2005) pudiéndose caracterizar aéreas. Existen algunas dificultades para hacer estimaciones confiables de la brecha de rendimiento-productividad a escala regional. Principalmente existe poca información consistente sobre variables de manejo y su contribución relativa tanto en zonas tropicales (Keys y McConnell 2005) como en zonas templadas (Reidsma et al., 2007). Al cuantificar los cambios en los rendimientos de cultivos, muchas veces únicamente se consideran factores biofísicos, como el clima, mientras que las restricciones de manejo para aumentar los rendimientos son ignoradas o capturados en una única variable que tendría que incluir todos aquellos factores que generan la diferencia con respecto al rendimiento alcanzado (Long et al., 2006).

El análisis de la brecha de rendimiento-productividad es importante en el contexto global de aumento continuo de la demanda de alimentos y energía por el incremento de la población y el ingreso promedio en combinación con la desaceleración de las tasas de rendimiento de cereales en algunas regiones (van Ittersum et al., 2013). La comprensión de la existencia de brechas de rendimiento-productividad considerables es necesaria por dos razones principales. En primer lugar, para colaborar en los informes de las proyecciones de rendimiento futuras de diferentes regiones y cultivos ya que la proximidad de los rendimientos a su límite superior podría indicar que las tasas de crecimiento ya no están aumentando. En segundo lugar, para la identificación de los factores del cultivo, clima y/o suelo que limitan los rendimientos actuales y prácticas de manejo mejoradas para achicar dichas brechas.

El rendimiento en el nivel de producción alcanzable se puede estimar a través de 1) el uso de datos de ensayos experimentales o concursos de rendimiento, 2) el uso de modelos de simulación y 3) la determinación de una frontera del rendimiento. Los ensayos experimentales y los concursos de rendimiento se pueden usar para estimar el rendimiento limitado por agua para una ubicación determinada y para un conjunto de prácticas de manejo sitio-específicos. En el caso de los ensayos experimentales se requieren manejos adecuados que permitan eliminar los factores limitantes y reductores del rendimiento y deben ser replicados varios años para obtener estimaciones sólidas del rendimiento promedio y su variación (Cassman et al., 2003). Esta repetición en el tiempo puede ser una limitación importante porque es muy difícil evitar todos los factores de estrés abiótico y biótico y hacerlo de manera consistente en un estudio a campo que tiene una duración de varios años. Los concursos de rendimiento tampoco tienen constancia en el tiempo y por lo general no representan los sistemas de producción predominantes y tienen fechas de siembra y/o cosecha diferentes lo que restringe usar sus resultados como límites de rendimiento (van Ittersum et al., 2013). Ambas aproximaciones son válidas para determinar el máximo rendimiento alcanzado para una ubicación determinada, es decir que podrían representar el mejor resultado de la interacción genotipo x ambiente x manejo, pero es difícil constatar si

fueron eliminados todos los factores de estrés. Por esta razón las estimaciones del rendimiento alcanzable determinados con este método no son adecuados para representar las condiciones de clima y suelo para un sistema o región de producción. Por consiguiente, usar datos estadísticos para determinar el rendimiento máximo alcanzado y subrogar con él el rendimiento alcanzable parece una opción adecuada en muchos casos, siempre que se interprete adecuadamente el significado de la brecha de rendimiento-productividad calculada de esta forma.

A continuación se detallan las dos aproximaciones restantes y aplicadas en esta tesis para la estimación de la brecha de rendimiento-productividad: uso de modelos de simulación y la determinación de una frontera de rendimiento.

5.1.1. Modelos de simulación

Debido a lo lento de algunos procesos naturales, los efectos de nuevas prácticas de manejo y/o cambios en variables biofísicas sobre el rendimiento de cultivos sólo pueden evaluarse en experimentos de muy larga duración, en algunos casos de más de un siglo, y una alternativa es estimarlo mediante modelos de simulación (Paustian et al., 1997). También el rendimiento alcanzado de un cultivo, es decir cuando agua y/o nutrientes son limitantes, puede ser estimado mediante modelos de simulación (Cassman 1999).

Existen varios modelos de simulación que son utilizados regularmente para estimaciones de rendimientos de cultivos y diferentes escalas sin embargo no todos se encuentran validados para la Región Pampeana. El modelo CERES (Crop Estimation through Resource and Environment Synthesis) ha sido utilizado con éxito en varias regiones y para diferentes cultivos del Mundo (Lobell et al., 2005). En la Región Pampeana, específicamente en Pergamino y Marcos Juárez, se realizaron estimaciones de rendimiento de trigo con CERES para distintas estrategias de manejo con buenos resultados (Savin et al., 1995). Sin embargo, el modelo CERES requiere de información detallada de coeficientes genéticos de cada variedad de cultivo, que describen los procesos fisiológicos y las diferencias en desarrollo de híbridos y cultivares (Ritchie y Otter 1985) para la estimación del rendimiento (Jones et al., 2003). Esto presenta una limitante para la aplicación de éste modelo de simulación ya que la información sobre los coeficientes genéticos probablemente se pueda conseguir para las variedades de trigo sembradas en la actualidad pero son muy difíciles de conseguir hacia el pasado y menos para las variedades sembradas en la década del '60 que es hasta donde llega la base de datos utilizada en esta tesis (comunicación personal D. Miralles y R. Miranda). Otra opción es estimar los coeficientes genéticos a través de ensayos experimentales para ajustarlos a las condiciones locales como se realizó en el valle del Ebro para ajustar el modelo a las condiciones mediterráneas (Abeledo et al., 2008). Sin embargo, esta aproximación excede el marco temporal de esta tesis.

El modelo de simulación EPIC (Environmental Policy Integrated Climate, anteriormente denominado Erosion Productivity Impact Calculator) no requiere información sobre estos coeficientes para la estimación del rendimiento y su aplicación se encuentra bastante difundida. Este modelo fue originalmente desarrollado para evaluar la erosión del suelo pero también genera estimaciones del rendimiento de cultivos por lo que constituye una herramienta analítica capaz de complementar estudios agronómicos y ecológicos (Williams et al., 1983). Se pueden encontrar varios ejemplos de su aplicación y con buenos resultados para diferentes cultivos en la India para trigo, maíz y arroz (Priya y Shibasaki 2001) e incluso estudios mundiales donde se vinculó la producción de trigo a la disponibilidad de agua (Liu et al., 2007). El modelo define al rendimiento del cultivo como la parte comercializable del total de la biomasa aérea producida por la planta (Williams 1990). A través de la estimación de la radiación fotosintéticamente activa se estima la

energía interceptada. Ésta energía captada determina el incremento potencial de biomasa diario que es afectado por el parámetro específico del cultivo para convertir energía en biomasa (3 g MJ^{-1} para trigo) que depende del índice de área foliar (Steiner et al., 1987). La partición de material seco hacia partes de la planta es controlada por la acumulación de unidades de calor. El modelo estima el crecimiento potencial vegetal y se pueden incluir factores limitantes como precipitaciones, temperaturas extremas, deficiencias nutricionales, falta de aireación del suelo, etc.

Las variables incluidas en EPIC pueden representar limitaciones hídricas y/o nutricionales que afectan el crecimiento potencial vegetal calculado por lo que es posible de estimar el rendimiento alcanzado de un cultivo mediante este modelo (Williams et al., 1983). De esta manera la biomasa potencial calculada se ajusta al efecto de los factores estresantes (agua, temperatura, nitrógeno, fósforo y aireación) proporcional a su peso. Los rendimientos calculados no toman en cuenta posibles adversidades reales que se pueden presentar en el campo, como el exceso de lluvias que anegan los suelos y pueden resultar en enfermedades, heladas y/o granizo. El rendimiento estimado para un cultivo y para una escala determinada se calcula como la multiplicación de la biomasa aérea en madurez por el índice de cosecha, que a su vez es ajustado por el estrés hídrico. Para el cultivo de trigo, se calcula el rendimiento de granos con una humedad de 14% (Bessembinder et al., 2005).

A nivel local se ha aplicado el modelo EPIC a algunos partidos del noreste de la Provincia de La Pampa para estimar el rendimiento de trigo, maíz y girasol (Bernardos et al., 2001). El R^2 de la estimación del rendimiento para trigo fue de 0,39 y la validación se realizó con datos de estadísticas nacionales de rendimiento de los tres cultivos mencionados a nivel partido del Ministerio de Agricultura, Ganadería y Pesca de la Nación. El modelo EPIC también ha sido utilizado previamente en la Pampa Ondulada para evaluar el efecto de dos escenarios de clima sobre algunas propiedades de suelo como su contenido de carbono orgánico y nitrógeno total (Díaz et al., 1997). Sin embargo, no se ha utilizado este modelo de simulación para estimar el rendimiento de trigo, u otros cultivos, luego de una validación del mismo con datos a nivel de análisis sitio en el marco de un análisis de productividad regional. La validación de un modelo de simulación es un paso importante y necesario previo a su aplicación (Yang et al., 2014).

Dos razones motivaron la elección del modelo EPIC para la estimación del rendimiento alcanzable limitado por agua para cálculo de la brecha de productividad:

- EPIC es un modelo de simulación que no precisa de información detallada sobre coeficientes genéticos que son difíciles de conseguir y aún más para variedades que se cultivaban hace 40 años y ya no en la actualidad y
- la posibilidad de trabajar junto al Dr. Jimmy Williams, el autor del modelo, para la validación del mismo a las condiciones locales.

Se han realizado comparaciones de las performances de los modelos CERES y EPIC para la estimación del rendimiento promedio de una serie temporal en Canadá con performances parecidas (Moulin y Beckie 1993). También en las Grandes Planicies americanas la estimación del rendimiento de trigo y maíz bajo dos escenarios de cambio climático y escalas diferentes obtuvo resultados comparables con ambos modelos (Mearns et al., 1999).

5.1.2. Función de frontera estocástica

Si se conocen todos los recursos de producción, incluidas las condiciones edáficas, y los niveles de entrada se pueden identificar los rendimientos más altos para un nivel determinado de disponibilidad de recursos (Hochman et al., 2013). La metodología denominada línea de

máximos, o Bolides (boundary line development system) por sus siglas en inglés, utiliza un algoritmo matemático que permite, a través de cinco pasos, ajustar una línea que atraviesa el límite superior de un set de datos para un espacio bidimensional (Schnug et al., 1996). Por un lado, con esta metodología se pudo relacionar la brecha de rendimiento de arroz en el delta español del Ebro a propiedades de suelo (Casanova et al., 1999). Por otro lado, se determinó que la brecha de rendimiento de mandioca en el este de África depende de la fertilidad y textura de los suelos así como también de la precipitación y el control de malezas (Fermont et al., 2009). Una desventaja de esta aproximación es que previamente se eligen cuáles son las variables independientes que impactan significativamente el rendimiento y al elegir los mejores rendimientos para los rangos de las variables independientes con la línea de máximos estimada, con la que posteriormente se estima la brecha de productividad, no se puede analizar el impacto de variables independientes en conjunto y tampoco la interacción entre las mismas.

En el análisis de función de máxima el rendimiento es regresado vs. el agua disponible para un determinado período y se ajusta una función lineal a los puntos que parecen definir el límite superior del rendimiento limitado por agua (Passioura 2006). Esta aproximación ha sido aplicada al cultivo de girasol en la Región Pampeana por Grassini et al. (2009) y permite determinar cuán limitado por agua está un cultivo y cuál es la eficiencia del uso del agua disponible. Sin embargo, para determinar la frontera del rendimiento y vincularlo a los factores biofísicos que lo determinan, y no únicamente a la disponibilidad de agua, se debe ajustar una función de frontera estocástica (FFE) que permite incluir varias variables y además un término de error estadístico aleatorio y un término que define la ineficiencia del sistema de producción (Coelli et al., 2005).

La función de frontera tiene sus orígenes en la econometría y fue desarrollada para calcular la eficiencia de firmas o unidades económicas (Aigner et al., 1977; Meeusen y Broeck 1977). Como los campos de producción agrícolas son una forma especial de firmas se puede aplicar esta metodología econométrica para estimar la eficiencia de la producción. Esta función representa el máximo alcanzado de la variable dependiente para un set determinado de variables independientes (Coelli et al., 2005). En el caso de la producción agrícola, la función de frontera representa el mayor rendimiento máximo observado o rendimiento frontera (o rendimiento FF) para una combinación de variables independientes específicas. La ineficiencia en la producción agrícola resulta en rendimientos que difieren del rendimiento alcanzado, es decir que se ubican por debajo del límite definido por la función de frontera.

Para analizar la producción de agroecosistemas, generalmente se calcula la producción frontera a través de la aproximación de Cobb-Douglas (Aigner et al., 1977):

$$\ln q_i = \mathbf{x}_i' \beta - \mu_i \quad i = 1, \dots, I$$

donde q_i representa la salida de la firma i , \mathbf{x}_i es un vector de tipo $k \times 1$ que comprende los logaritmos de las entradas, β es el vector de los parámetros desconocidos y μ_i es una variable aleatoria asociada a la ineficiencia técnica. Existen varias técnicas para estimar los parámetros desconocidos de éste modelo pero el más común es a través de la estimación de las máximas probabilidades (likelihood). El modelo presentado es determinístico en el sentido que q_i está limitado desde arriba por la cantidad no aleatoria $\exp(\mathbf{x}_i' \beta)$. El problema con éste tipo de funciones de frontera es que no se consideran errores que se pueden generar en las mediciones y otras fuentes de ruido estadístico y se asume que todas las desviaciones con respecto a esa función de frontera son el resultado de la ineficiencia técnica. Una solución a éste problema es la introducción de otra variable aleatoria que representa el ruido estadístico y esta función resultante se denomina una FFE que fue propuesta de manera independiente por Aigner et al (1977) y

Meeusen y Van den Broeck (1977):

$$\ln q_i = \mathbf{x}_i' \boldsymbol{\beta} + v_i - \mu_i$$

que es idéntica a la función anterior exceptuando un error aleatorio simétrico v_i que fue agregado para comprender el ruido estadístico. El error estadístico surge de la omisión inadvertida de variables relevantes del vector \mathbf{x}_i ; así como también de errores en la medición. El error estadístico es una propiedad inherente de sets de datos que corresponden a escalas de análisis regional que puede resultar de errores en la presentación de informes e inconsistencia en los sistemas de reportaje de datos y muestreos. La variable no negativa μ_i representa el efecto de la ineficiencia de la producción y es independiente de v_i . En la FFE los valores de salida están limitados desde arriba por la variable estocástica (o aleatoria) $\exp(\mathbf{x}_i' \boldsymbol{\beta} + v_i)$. El error aleatorio v_i puede ser positivo o negativo y de esta manera las salidas de la FFE pueden variar alrededor de la parte determinística del modelo, $\exp(\mathbf{x}_i' \boldsymbol{\beta})$.

La ventaja principal de las funciones de tipo Cobb-Douglas es que las devoluciones de escala pueden ser crecientes, decrecientes o constantes, dependiendo de la suma de sus términos (Bravo-Ureta y Pinheiro 1993). Con respecto a esto último, por un lado se dice que la devolución de escala es constante cuando la variable dependiente aumenta en la misma proporción de cambio en la variable independiente. Por otro lado, cuando la variable dependiente aumenta menos que el cambio proporcional en la variable independiente, entonces la devolución de escala es decreciente. Se entiende además que la devolución creciente es aquella en la que la variable dependiente aumenta más que los cambios en la variable independiente.

Si se restringe la atención a una firma que produce la salida q_i utilizando únicamente un input x_i entonces la FFE Cobb-Douglas adquiere la siguiente forma y estas características importantes se ilustran en la **Figura 5.1.**:

$$\begin{aligned} & \ln q_i = \beta_0 + \beta_1 \ln x_i + v_i - \mu_i \\ \text{o} & \quad q_i = \exp(\beta_0 + \beta_1 \ln x_i + v_i - \mu_i) \\ \text{o} & \quad q_i = \underbrace{\exp(\beta_0 + \beta_1 \ln x_i)}_{\text{componente determinístico}} \times \underbrace{\exp(v_i)}_{\text{ruido}} \times \underbrace{\exp(-\mu_i)}_{\text{ineficiencia}} \end{aligned}$$

En la **Figura 5.1.** se esquematizan las variables independientes y dependientes de dos firmas, A y B, y se ilustra el componente determinístico de la función de frontera. Los valores de las variables independientes son medidos sobre el eje horizontal mientras que los valores de las variables dependientes se pueden medir en el eje vertical.

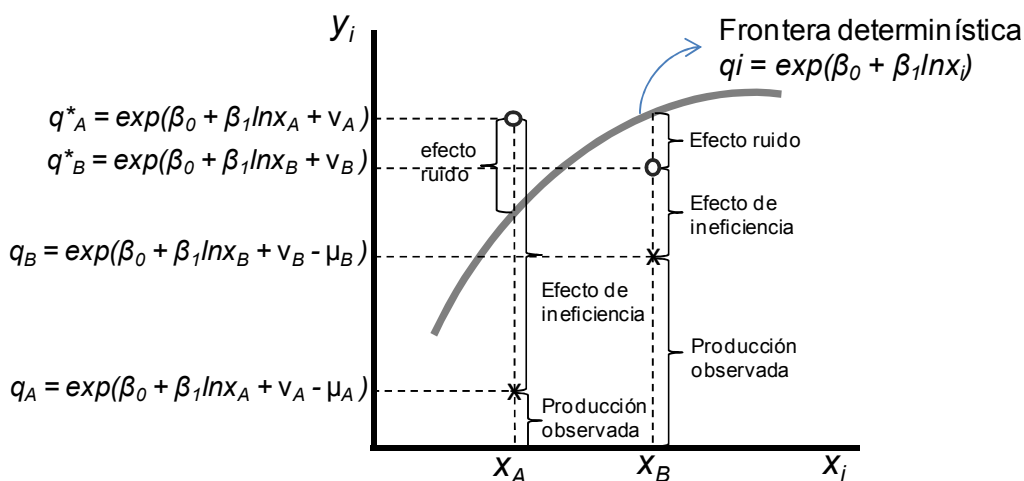


Figura 5.1. Función de frontera estocástica (FFE) (Coelli et al., 2005). Los valores de producción observados (x) y frontera (\bullet) se encuentran indicados. La FFE está basada en los valores observados más altos alcanzados bajo la variable independiente tomando en cuenta el efecto del error estadístico (v_i). Desviaciones de los valores observados con respecto a esta frontera son causadas por efecto de la ineficiencia técnica (μ_i). La producción frontera q_i puede ubicarse por encima o por debajo de la FFE dependiente del efecto de error estadístico (v_i).

La firma A utiliza el nivel de la variable independiente x_A para producir q_A , mientras que la firma B usa x_B para producir q_B (estos valores observados se indican con puntos marcados con x). En caso de no existir ineficiencia en el agroecosistema estudiado (es decir cuando $\mu_A = 0$ y $\mu_B = 0$) entonces las funciones de frontera serían las siguientes:

$$q^*_A = \exp(\beta_0 + \beta_1 \ln x_A + v_A)$$

$$q^*_B = \exp(\beta_0 + \beta_1 \ln x_B + v_B)$$

para las firmas A y B respectivamente. Estos valores frontera están indicados con el símbolo \bullet . Se observa que la frontera de la firma A se ubica por encima de la parte determinística de la función de producción únicamente porque el efecto del ruido es positivo ($v_A > 0$), mientras que la frontera de la firma B se encuentra por debajo de la parte determinística del modelo porque el efecto del ruido es negativo ($v_B < 0$). También se ve que la producción observada de la firma A se ubica por debajo de la parte determinística de la frontera porque la suma del efecto del ruido y la ineficiencia es negativa ($v_A - \mu_A < 0$). En la FFE el término μ_i , es decir la ineficiencia de la producción, no varía con el tiempo es decir que para determinar cuáles son los factores biofísicos que resultan en los rendimientos observados menores con respecto al rendimiento estimado con la FFE se debe proceder al desarrollo de otro modelo explicativo cuya variable dependiente es la brecha de rendimiento-productividad (Battese y Coelli 1995). Este procedimiento metodológico se denomina de dos etapas.

Lo que se observa en la figura se puede generalizar para firmas que tienen varias variables independientes. Las producciones frontera tienden a estar igualmente distribuidas por encima y

por debajo de la parte determinística del modelo. Únicamente se ubican por encima de la parte determinística de la función cuando el efecto del ruido es positivo y mayor al efecto de la ineficiencia ($q^*i > \exp(\xi\beta)$ si $v_i - \mu_i > 0$). A través de la aplicación de la FFE se ha comparado la eficiencia de sistemas productivos de distintos países (Headey et al., 2010) y también la brecha de rendimiento global de trigo, maíz y arroz (Neumann et al., 2010).

5.1.3. Generación de la hipótesis

El modelo regional explicativo de rendimiento, desarrollado a través de una RNA en el Capítulo 3, mostró óptimos aproximados de 1,3 y 0,9 para las variables climáticas de precipitación/EPT durante el período de barbecho y fase vegetativa respectivamente. La base de datos generada para esta tesis y descripta en el Capítulo 2, muestra que por un lado la Pampa Ondulada se encuentra más cerca de éste óptimo en algunas campañas con valores promedio de 1.31 y 0.84, respectivamente. Por otro lado, en la Región Semiárida Pampeana las condiciones climáticas se encuentran más alejadas de éstos óptimos regionales con valores de 0,92 y 0,73. Con respecto a la CAAU el modelo regional de rendimiento desarrollado con la RNA se definió al valor de 150 mm hasta el primer metro de profundidad, o hasta el límite superior de la capa petrocálcica en caso de presentarse, como un óptimo regional. Las unidades geográficas correspondientes a la Pampa Ondulada, en todos los casos superan este valor mientras que los de la Región Semiárida Pampeana no llegan a los 100 mm. Algo similar sucede con el carbono orgánico, cuyo óptimo es 65 t ha^{-1} en los primeros 50 cm de profundidad, la otra variable edáfica seleccionada por su efecto significativo sobre el rendimiento. Teniendo en cuenta estos valores observados de las distintas variables biofísicas descriptas como significativas por su impacto sobre el rendimiento para la Región Pampeana se podrían esperar mayores brechas de productividad en la Región Semiárida Pampeana que en la región más húmeda.

5.2. Objetivo

Asociar la brecha de rendimiento-productividad a patrones ambientales de clima y suelo.

5.3. Hipótesis

La brecha de rendimiento-productividad es mayor en ambientes de baja productividad.

5.4. Materiales y métodos

5.4.1. Modelo de simulación- EPIC

Se utilizó el modelo EPIC (versión 0509) como herramienta de estimación del rendimiento alcanzable de trigo. Este modelo simula procesos físicos que afectan al crecimiento vegetal e incluye componentes para la simulación del clima, la hidrología, el ciclado de nutrientes, el crecimiento vegetal, la labranza y el manejo del cultivo. EPIC utiliza un único modelo para simular todos los cultivos, aunque cada cultivo tiene valores únicos para sus parámetros y se utiliza la eficiencia en el uso de la radiación para calcular la producción fotosintética de biomasa. La biomasa potencial es ajustada diariamente a factores de estrés de los siguientes factores: agua, temperatura, nutrientes (nitrógeno y fósforo), aereación y radiación. La concentración atmosférica de CO_2 por un lado afecta la fotosíntesis a través del término de la eficiencia en el uso de la radiación y por otro lado la eficiencia en el uso del agua a través del

término de la conductividad estomática del modelo de Penman-Monteith. El rendimiento de un cultivo se estima multiplicando la biomasa aérea en madurez (determinada por la acumulación de unidades de calor o una fecha de cosecha específica) por el índice de cosecha (rendimiento económico dividido por la biomasa aérea) para un cultivo determinado.

A pesar de que EPIC es lo suficientemente flexible como para estimar el rendimiento de cultivo en condiciones de secano bajo una variedad de ambientes y condiciones, la validación del mismo es necesaria antes de correr el modelo a escala partido y su agregación posterior a escala unidad geográfica. En base a lo indicado en el trabajo original de Williams et al. (1990) la información requerida por el modelo EPIC se agrupó en cinco categorías:

- a) datos generales (dimensiones del área, ubicación geográfica, elevación, etc.),
- b) clima (temperatura, precipitación, humedad relativa, evaporación y radiación),
- c) características generales del suelo y descripción físico-química de cada estrato de suelo, d) manejo del cultivo (fechas y prácticas agrícolas aplicadas al cultivo), y
- e) variables fisiológicas del cultivo (altura de la planta, índice de área foliar, relación biomasa-energía e índice de cosecha).

Las variables climáticas necesarias para correr EPIC son: precipitación, temperatura del aire, radiación solar y velocidad del viento. En caso de no tener tanta información detallada disponible el modelo provee algunas opciones para estimar los valores diarios a partir de combinaciones de las cinco variables con datos mensuales basado en promedios de series históricas con un generador estocástico de clima incorporado en EPIC (Williams et al., 1990). En los ensayos experimentales de todas las localidades se midió la temperatura máxima, mínima y la precipitación mensual (**Cuadro 5.1**). Para la estimación de la evapotranspiración potencial se utilizó el método propuesto por Hargreaves y Samani (1985) que únicamente requiere las temperaturas máxima y mínima.

En cuanto a las características del suelo se utilizó la descripción de la serie de suelo correspondiente a los lotes agrícolas sobre los que se realizaron los ensayos experimentales del INASE y publicada en los mapas de suelo de INTA (**Cuadro 5.1**). El set mínimo de datos disponible en todos los casos incluyó: profundidad del suelo, contenido de carbono orgánico, porcentaje de arena y arcilla, y pH y con estos datos se estimó además la densidad aparente por estrato aplicando las fórmulas de Rawls (1983).

En todos los ensayos se trabajó con varias variedades de trigo y de ciclo largo, largo-intermedio, intermedio-corto y corto cuya fecha de siembra y cosecha se detalla en la **Cuadro 5.2**. Además se disponía de información de tipo de fertilizante, la dosis aplicada y el sistema de labranza utilizado. La ocurrencia de heladas fue documentada y las plagas, como las pestes, fueron controladas por lo que la competencia por agua y nutrientes de malezas no fue significativa. Los parámetros específicos del cultivo, se obtienen por defecto del archivo de trigo del modelo a excepción del índice de cosecha que fue reemplazado por un valor de 0,45 (comunicación personal D. Miralles).

Cuadro 5.1. Precipitación por campaña y datos de suelo de los ensayos experimentales de las cinco localidades utilizadas para la validación del modelo EPIC.

Localidad		Precipitación	Tipo o serie	Estrato del	Carbono			Densidad	
lat/long	Campaña	total (mm)	de suelo	perfil (cm)	orgánico (%)	Arena (%)	Arcilla (%)	pH	aparente (g cm ⁻³)
Anguil 36.53° S 64.01° O	2010	498	Haplustol Éntico	0-20	1,35	49	12	6,7	1,19
				20-40	0,71	49	12	6,7	1,21
				40-60	0,38	49	12	6,7	1,23
				60-80	0,37	49	12	6,7	1,24
Balcarce 37.76° S 58.31° O	2008	885	Mar del Plata	0-15	4,03	41,1	23,1	5,9	0,92
	2009	731		15-29	3,06	44	22,4	6,1	1,11
	2010	903		29-39	1,74	40,1	23,6	6,3	1,13
				39-58	1,36	37,5	33,3	6,7	1,13
				58-76	0,58	34,2	31,4	7	1,13
				76-110	0,29	49,1	19,6	7,2	1,13
110-160	0,04	52,6	13,7	7,6	1,13				
Manfredi 37.41° S 63.25° O	2005	838	Oncativo	0-23	1,9	16,5	16,7	6,4	1,33
	2010	618		23-53	0,96	16,1	12,2	7,1	1,41
				> 53	0,4	15,8	10,2	8,3	1,29
Rafaela 31.27° S 61.48° O	2005	1035	Rafaela	may-15	1,47	2,2	26	6,2	1,18
	2007	1146		25-30	0,9	2,8	27,5	6,3	1,24
				40-55	0,51	2,1	38	6,5	1,23
	2010	799		70-85	0,37	1,7	40,5	6,7	1,28
				100-110	0,24	2,2	33	7,2	1,28
				120-135	0,17	1	30,5	7,4	1,28
145-160	0,11	4,8	29,5	8,2	1,31				
Venado Tuerto 32.24° S 60,04° O	2007	885	Maggiolo	0-21	1,29	46,3	17,8	6,7	1,28
				21-46	0,77	46	24,4	7	1,33
				46-74	0,39	50,1	18,6	7,3	1,26
				>74		55,3	12,9	7,5	1,25

Cuadro 5.2. Datos de manejo de los ensayos experimentales de las cinco localidades utilizadas para la validación del modelo EPIC.

Localidad	Fecha siembra	Fecha cosecha	Variedades trigo	Sistema labranza	Fertilizante aplicado	Dosis (kg ha⁻¹)	Rendimiento (kg ha⁻¹)	Desvío estándar (kg ha⁻¹)
Anguil	02/06/2010	01/12/2010	25	C ¹	Urea	174	3061	792
	22/06/2010	31/11/2010	29	C ¹			2441	404
	13/07/2010	15/12/2010	34	C ¹			3208	407
	26/07/2010	15/12/2010	26	C ¹			2894	237
Balcarce	12/06/2008	01/12/2008	30	SD ²	Urea	200	5539	459
	30/06/2008	28/11/2008	35	SD ²	PDA ³	150	4949	473
	18/07/2008	06/12/2008	38	SD ²			4729	301
	11/08/2008	07/12/2008	29	SD ²			4250	395
	13/06/2009	09/12/2009	28	SD ²	Urea	200	4818	349
	10/07/2009	04/12/2009	33	SD ²	PDA ³	150	4625	411
	20/07/2009	09/12/2009	35	SD ²			4582	565
	12/08/2009	19/12/2009	28	SD ²			4756	364
	11/06/2010	18/12/2010	28	SD ²	PDA ³	100	7236	553
	30/06/2010	08/11/2010	33	SD ²	Urea	217	7478	688
	05/08/2010	20/12/2010	37	SD ²			7093	463
05/08/2010	20/12/2010	27	SD ²			6705	482	
Manfredi	08/06/2005	28/11/2005	23	SD ²	Urea	100	2972	361
	21/06/2005	06/12/2005	27	SD ²	UAN ⁴	133	3421	459
	05/07/2005	06/12/2005	22	SD ²			2827	519
	09/06/2010	05/12/2010	27	SD ²	Urea	207	4020	513
	15/06/2010	24/11/2010	30	SD ²			4305	745

Cuadro 5.2. Continuación.

Localidad	Fecha siembra	Fecha cosecha	Variedades trigo	Sistema labranza	Fertilizante aplicado	Dosis (kg ha ⁻¹)	Rendimiento (kg ha ⁻¹)	Desvío estándar (kg ha ⁻¹)		
Rafaela	20/05/2005	10/11/2005	21	C ¹	Urea	113	3617	477		
	13/06/2005	13/11/2005	26	C ¹			4305	450		
	22/06/2005	07/11/2005	27	C ¹			3534	447		
	05/07/2005	13/11/2005	20	C ¹	Urea	113	3807	402		
	24/05/2007	10/11/2007	21	C ¹			4948	883		
	06/06/2007	15/11/2007	25	C ¹			5095	629		
	22/06/2007	15/11/2007	22	C ¹			5085	426		
	11/07/2007	15/11/2007	18	C ¹			5181	595		
	19/05/2010	04/11/2010	22	SD ²			Urea	152	5460	448
	25/06/2010	19/11/2010	30	SD ²					4333	521
07/07/2010	15/11/2010	27	SD ²	3539	406					
Venado	30/05/2007	11/12/2007	23	SD ²	NPS ⁵ (7-40-5)	400	6752	419		
Tuerto	19/06/2007	12/12/2007	27	SD ²			6440	494		
	25/06/2007	12/12/2007	28	SD ²			6569	481		
	06/07/2007	12/12/2007	20	SD ²			5808	582		

¹C = Labranza convencional. ²SD = siembra directa. ³PDA = Fosfato diamónico, ⁴UAN = urea más nitrato de amonio ⁵NPS = fertilizante con nitrógeno, fósforo y azufre. Desvío estándar fue calculado con respecto a los rendimientos de todas las variedades comparadas en los ensayos experimentales.

Se corrió EPIC para las cinco localidades donde se radicaron los experimentos para cada campaña analizada ($n = 36$) y se relacionó el valor del rendimiento alcanzable estimado con el valor de rendimiento observado a través de una regresión lineal y la comparación de promedios a través de un *test* de *t*. Cuánto más se acercan los valores de esta regresión simple a la línea 1:1, con pendiente igual a 1 y ordenada al origen igual a 0, más correcta es la estimación del rendimiento estimado por EPIC.

Si el modelo podía ser validado correctamente para las condiciones de la Región Pampeana se procedería a la estimación del rendimiento alcanzable de trigo por partido, que posteriormente será agregado a la escala unidad geográfica, para estimar la brecha de rendimiento-productividad.

5.4.2. Función de frontera estocástica

El modelo de FFE se desarrolló a través del Software Stata12 (versión 2012, Stata Corp L.P.). La variable dependiente fue el rendimiento observado de trigo desde la campaña 1967 hasta 2006 publicado por el Ministerio de Agricultura, Ganadería y Pesca y agregado espacialmente por unidad geográfica como se explica en el Capítulo 2. El rendimiento de trigo representa el rendimiento ponderado por superficie de lotes agrícolas con rendimientos altos, medios y bajos que pueden encontrarse afectados por adversidades que pueden variar de una campaña a otra. De esta manera el rendimiento estimado con la FFE representa el rendimiento máximo alcanzado en una unidad geográfica para una campaña determinada que puede estar afectado por adversidades en algunas campañas y este efecto reductor del rendimiento tendría que ser captado por el término v_i de la FFE. Se utilizaron las siguientes variables independientes para ajustar una FFE a los datos observados de rendimiento:

- Carbono orgánico ($t\ ha^{-1}$): hasta los primeros 50 cm y hasta 100 cm del perfil de suelo o hasta el límite superior de la capa petrocálcica.
- CAAU (mm): hasta el primer metro de profundidad o hasta el límite superior de la capa petrocálcica.
- Arcilla, limo y arena ($t\ ha^{-1}$): en estratos de 25 cm y hasta el primer metro del perfil o hasta el límite superior de la capa petrocálcica.
- pH: en estratos de 25 cm y hasta el primer metro del perfil.
- $CaCO_3$ ($t\ ha^{-1}$): en estratos de 25 cm y hasta el primer metro del perfil.
- Temperatura ($^{\circ}C$), precipitación (mm), evapotranspiración potencial (ETP) (mm) y el índice climático precipitación/ETP: por mes desde abril hasta noviembre o promedios ponderados por número de días de los períodos de barbecho, fase vegetativa y floración del cultivo.
- Coeficiente fototérmico ($MJ\ m^{-2}\ d^{-1}\ ^{\circ}C^{-1}$): período crítico de un mes antes de antesis.
- Campaña, 1967-2006.

El detalle de la estimación de cada una de estas variables se encuentra en la descripción de la generación de la base de datos del Capítulo 2 de esta tesis. El set de datos utilizado para la FFE fue de 1640 (41 unidades geográficas x 40 años).

Cuando los errores están distribuidos normalmente o el set de datos es grande, se pueden testear las hipótesis referidas a la existencia o ausencia de ineficiencia de los coeficientes β a través de un test de *z* (con nivel de significancia de 5 %). Un coeficiente positivo de un parámetro en la FFE indica que la variable tiene una influencia positiva sobre la variable dependiente

mientras que un coeficiente negativo indica lo contrario. La función de log likelihood expresa la probabilidad de observar una muestra de observaciones como una función de parámetros desconocidos β y la varianza σ^2 . Con el valor del log likelihood-ratio se puede testear, a través de un *test* de χ^2 con un nivel de significancia al 5 %, si la mejora tecnológica fue constante o no a través de la serie temporal analizada. Si los valores de $\gamma = \sigma_{\mu} / \sigma^2$ son altos, la variación en el error compuesto es causada por el componente de la ineficiencia principalmente.

5.4.3. Estimación de la brecha de rendimiento-productividad

En primer lugar se va a estimar la brecha de rendimiento por campaña para el período 1967-2006 y por unidad geográfica y en segundo lugar se va a calcular el promedio de las 40 campañas por unidad geográfica para determinar la brecha de productividad. De esta manera, la aproximación propuesta es en dos etapas:

Primera etapa: estimación de la brecha de rendimiento

Según la metodología utilizada la estimación se hizo como se detalla a continuación:

- Modelo de simulación EPIC validado: diferencia entre el rendimiento alcanzable y el rendimiento observado por unidad geográfica y por campaña.
- FFE: diferencia entre el rendimiento máximo alcanzado y el rendimiento medio estimado con el modelo de RNA por unidad geográfica y por campaña. Se eligió calcular las brechas como la diferencia entre los valores de la FFE y los estimados por la RNA del Capítulo 3 en lugar que los valores observados para eliminar ruido estadístico no explicado.

Luego, generó un modelo explicativo de la brecha de rendimiento determinada con 1) el rendimiento alcanzable estimado por EPIC o 2) el rendimiento máximo alcanzado estimado con la FFE. La metodología seleccionada para el desarrollo de un modelo explicativo de las brechas fue una RNA cuyo detalle metodológico de ajuste se describe en el Capítulo 3. La variable dependiente a estimar va a ser la brecha de rendimiento y las variables independientes van a ser la campaña, y las variables de clima y suelo agregados a la escala de análisis unidad geográfica descriptos en el Capítulo 2. La población de datos se particiona en 75 % para desarrollar el modelo (*training set*) y el 25 % restante e independiente para validar el mismo (*validation set*).

Estos resultados van a ser presentados en forma de mapas utilizando el programa ArcGIS 9.1 (ESRI, Copyright © 2005).

Segunda etapa: cálculo de la brecha de productividad

La brecha de productividad se calcula como el promedio de la brecha de rendimiento para las 40 campañas comprendidas en el análisis por unidad geográfica y va a ser presentado en forma de mapa con el programa ArcGIS 9.1. (ESRI, Copyright © 2005) para el análisis de la distribución espacial. Utilizando el modelo regional ajustado con una RNA correspondiente a la etapa anterior se va a evaluar la interacción entre variables independientes con respecto a la brecha de productividad.

5.5. Resultados

5.5.1. Modelo de simulación - EPIC

La regresión lineal del rendimiento alcanzable estimado por el modelo de simulación EPIC vs. el rendimiento observado de los ensayos experimentales de las cinco localidades seleccionadas mostró mucha dispersión (**Figura 5.2.**). El ajuste de esta relación no es significativo, la pendiente es distinta de 1 y la ordenada al origen es distinta de 0, Aproximadamente la mitad de los valores

se ubican por encima de la línea 1:1 y la otra mitad por debajo. Por un lado, se detecta que el rendimiento estimado para la localidad de Venado Tuerto es inferior en casi un 50 % al rendimiento observado para todas las estimaciones. Por otro lado, para la localidad de Balcarce, específicamente para las cuatro fechas de siembra de la campaña 2008, los rendimientos estimados también son inferiores a los observados pero en este caso la diferencia es menor. Para las localidades de Rafaela y Manfredi la distribución de los datos estimados es variada pero el mejor ajuste se observa para la localidad de la Provincia de La Pampa, en la Estación Experimental Anguil-INTA. El modelo pareció ser más sensible al cambio de localidad (clima y suelo) que al cambio de fecha de siembra o de otros factores de manejo dentro de cada localidad, porque la variación del rango de rendimiento estimado fue muy estrecho en cada localidad y la variación entre localidades muy importante.

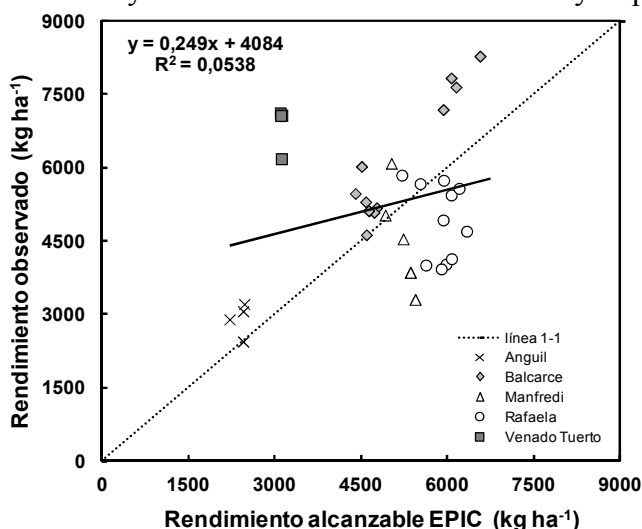


Figura 5.2. Validación modelo de simulación EPIC con datos de ensayos experimentales ubicados en cinco localidades distribuidas en la Región Pampeana.

Por esta gran dispersión y por la ausencia de un patrón en los valores estimados con respecto a los observados no se prosiguió a realizar las corridas para la escala de análisis partido, y su posterior agregación a la escala unidad geográfica, para estimar la brecha de rendimiento-productividad regional.

5.5.2. Función de frontera estocástica

La FFE seleccionada detectó efectos significativos sobre el rendimiento máximo alcanzado de cinco variables independientes (**Cuadro 5.3**). Todos los coeficientes de los parámetros β de la función ajustada fueron significativos al compararlos con su valor crítico correspondiente con lo cual se rechaza la hipótesis nula de que no existen ineficiencias (al nivel de significancia de 5 %). Los coeficientes además fueron positivos, es decir que afectan incrementando el rendimiento estimado, a excepción de la constante de la función que es negativa. El término μ (ineficiencia) del error compuesto de éste modelo es constante para todas las unidades geográficas y para las 40 campañas estudiadas lo que indica que es un valor que se le resta al valor del rendimiento alcanzado estimado por la FFE. La función del log likelihood es significativa estadísticamente y el log likelihood ratio excede los valores críticos al 1 % para 5 grados de libertad, lo que indica que los retornos de escala no son constantes (Kodde & Palm, 1986). El valor de γ indica que únicamente podemos explicar un poco menos de la mitad de la variación de la producción regional de trigo por la ineficiencia del sistema y que el resto de la

variabilidad la genera el error estadístico.

Cuadro 5.3. Función de frontera estocástica para la estimación del rendimiento alcanzado de trigo por unidad geográfica y para las 40 campañas (período 1967-2006) analizadas. Se agregan además el error estándar, los valores de z y P correspondientes cuyo significado se detallan en el texto.

Variable	Parámetro	Coefficiente	Error estándar	z	$P > z$
Constante	β_0	-73443	1851	-38,9200	0,000
Campaña	β_1	37,7	0,922	40,4000	0,000
CAAU	β_2	1,61	1,65	0,8700	0,000
Precipitación/ETP barbecho ¹	β_3	87,4	17,3	4,1500	0,000
Precipitación/ETP fase vegetativa ²	β_4	130	19,2	5,7800	0,000
Coefficiente fototérmico ³	β_5	388	29,1	2,8700	0,004
Estadística					
μ		425	148	3,18	0,001
σ^2	σ^2_s	12,6	0,166		
γ	γ	0,418	0,096		
Log-likelihood	-12304				
Likelihood ratio (LR)	1722,6				

CAAU = capacidad de almacenamiento de agua útil (mm) de 0-100 cm o hasta el límite superior de la capa petrocálcica, ETP = evapotranspiración potencial del cultivo de trigo. ¹: abril, mayo y junio; ²: julio, agosto y septiembre; ³: durante el período crítico del cultivo ($\text{MJ m}^{-2} \text{d}^{-1} \text{°C}^{-1}$).

Al relacionar las variables independientes seleccionadas por el modelo de FFE vs. el rendimiento máximo alcanzado promedio estimado con la FFE por campaña se pudo determinar que el efecto del tiempo tuvo el peso más importante ($R^2 = 0,91$, $P = 0,05$). La CAAU fue la única variable de suelo seleccionada con un efecto positivo y curvilíneo sobre el rendimiento alcanzado pasando por un óptimo, aunque no muy marcado, en suelos con una CAAU 140 mm (**Figura 5.3.A.**). Aproximadamente un 24 % de la variabilidad de rendimiento estimado pudo ser explicado con el promedio de la CAAU ($R^2 = 0,235$, $P = 0,05$).

Los índices climáticos de la precipitación/ETP durante el barbecho y la fase vegetativa del cultivo tuvieron un efecto lineal y significativo sobre el rendimiento estimado con ajustes muy altos en ambos casos ($R^2 > 0,791$, $P = 0,05$) (**Figura 5.3.C.D.**). El coeficiente fototérmico también explicó una parte de la variabilidad del rendimiento con un impacto lineal pero con un ajuste menor ($R^2 = 0,351$, $P = 0,05$) (**Figura 5.3.B.**). Para el rango de variación promedio en las variables explicativas de la FFE se determinó que ésta tiene buena capacidad de modelar el rendimiento máximo alcanzado pero que la variación del mismo es baja. Esto se debe a que la cuando una función se ajusta a solo los máximos no representa al resto de la población de valores.

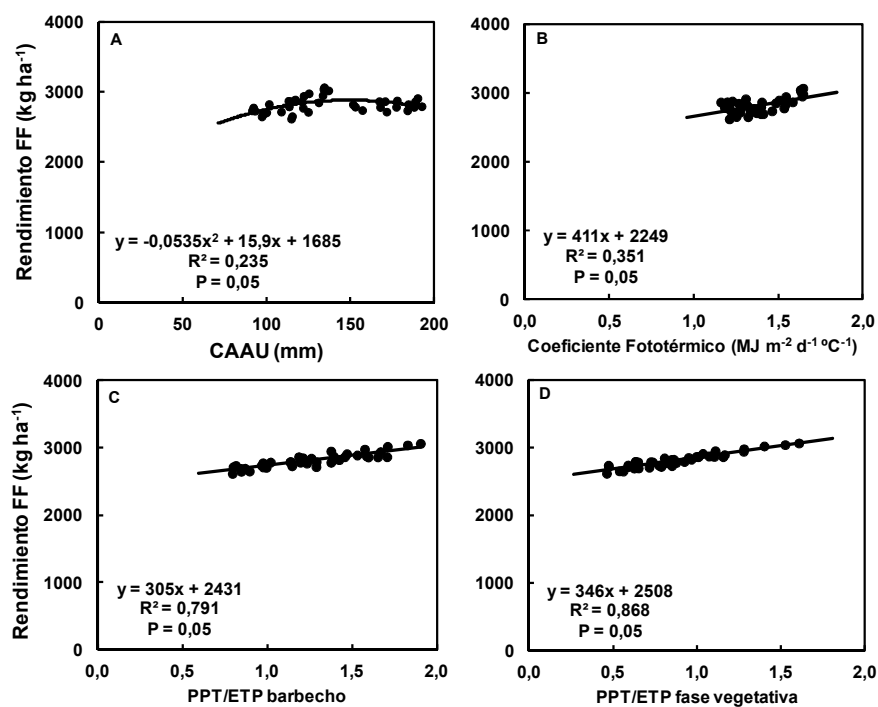


Figura 5.3. Relación entre la CAAU (capacidad de almacenamiento de agua útil) **A.**, el coeficiente fototérmico **B.**, el índice climático de PPT/ETP durante el barbecho **C.** y durante la fase vegetativa **D.** vs. el rendimiento máximo alcanzado o FFE.

El rendimiento máximo alcanzado estimado con una FFE tuvo un promedio de 2816 kg ha⁻¹ con un rango de entre 1819 kg ha⁻¹ y 3899 kg ha⁻¹. La relación entre valores estimados y observados tiene ordenada al origen distinta de cero y pendiente igual a 1 ($P = 0,05$). Cada punto de la **Figura 5.4.A.** corresponde a un dato de rendimiento de una unidad geográfica para una campaña determinada. Se observa que el rendimiento máximo alcanzado estimado por la FFE se encuentra linealmente correlacionado al rendimiento observado ($R^2 = 0,453$, $P = 0,05$). Menos del 5 % de los puntos caen por encima de la línea 1:1 de esta relación es decir que el resto de los valores estimados con la FFE cae por debajo de esta línea conformando lo que se denomina el límite máximo alcanzado del rendimiento observado para este set de datos.

Cuando se comparan el rendimiento observado, el rendimiento medio estimado con una RNA y el rendimiento máximo alcanzado estimado con la FFE, se observa que el rango de dispersión varía en el orden rendimiento observado > rendimiento medio > rendimiento máximo alcanzado (**Figura 5.4.B.**).

La máxima dispersión se presenta en los rendimientos observados, la dispersión media la tienen los rendimientos estimados con la RNA y la menor dispersión la tienen los rendimientos máximos alcanzados estimados con la FFE. Para la primera campaña la diferencia entre el rendimiento observado máximo y el mínimo fue de 1312 kg ha⁻¹ y para la última campaña esta diferencia fue de 3608 kg ha⁻¹. Esta dispersión es copiada por el rendimiento estimado por la RNA, con una diferencia calculada de 1286 kg ha⁻¹ para la campaña 1967 y 3259 kg ha⁻¹ en el 2006. Contrariamente, la dispersión de los valores de rendimiento máximos alcanzados estimados por la FFE desde la primera hasta la última campaña tiene un promedio de 495 kg ha⁻¹ que no sólo es mucho menor sino que se mantiene casi constante a lo largo de las 40 campañas.




Figura 5.4. A. Relación entre el rendimiento máximo alcanzado o rendimiento FFE y el rendimiento observado. B. Rendimiento observado, estimado con una red neuronal artificial (RNA) y por la función de frontera estocástica (FFE) vs. las campañas.

5.5.3. Brecha de productividad

En la **Figura 5.5**, se observan los rendimientos promedio estimados a través del modelo de la RNA y alcanzados estimados con la FFE para la 40 campañas para todas las sub-regiones pampeanas. En la Región Semiárida y en la Pampa Mesopotámica se observan las brechas de productividad más grandes, mientras que en la sub-región pampeana de la Pampa Ondulada se observa la menor y además se mantiene durante todo el período analizado. La menor brecha promedio de las 40 campañas fue la de la Pampa Austral (858 kg ha^{-1}) y la mayor en la Región Semiárida Pampeana (1108 kg ha^{-1}). En esta última sub-región al comparar la brecha promedio de las primeras 10 campañas con el promedio de las últimas 10 campañas la diferencia es de 481 kg ha^{-1} más en las campañas actuales.

El rendimiento máximo alcanzado estimado por la FFE se encuentra linealmente relacionada con el índice de productividad desarrollado con una RNA del Capítulo 4 de esta tesis ($P = 0,679$, $P = 0,05$) (**Figura 5.6.A**). Esta relación es lineal y positiva y se observa que a medida que aumenta el índice de productividad también aumenta el rendimiento máximo alcanzado y esto se mantiene a lo largo del período analizado y en todas las unidades geográficas. En cambio esta relación es inversa, es decir lineal pero con signo negativo, cuando se relaciona la brecha de rendimiento vs. el índice de productividad ajustado con una RNA (**Figura 5.6.B**). A medida que aumenta el índice ajustado con la RNA, o el rendimiento medio, de las unidades geográficas disminuye la brecha de rendimiento calculada como la diferencia entre el rendimiento máximo alcanzado y el rendimiento medio estimado con una RNA.

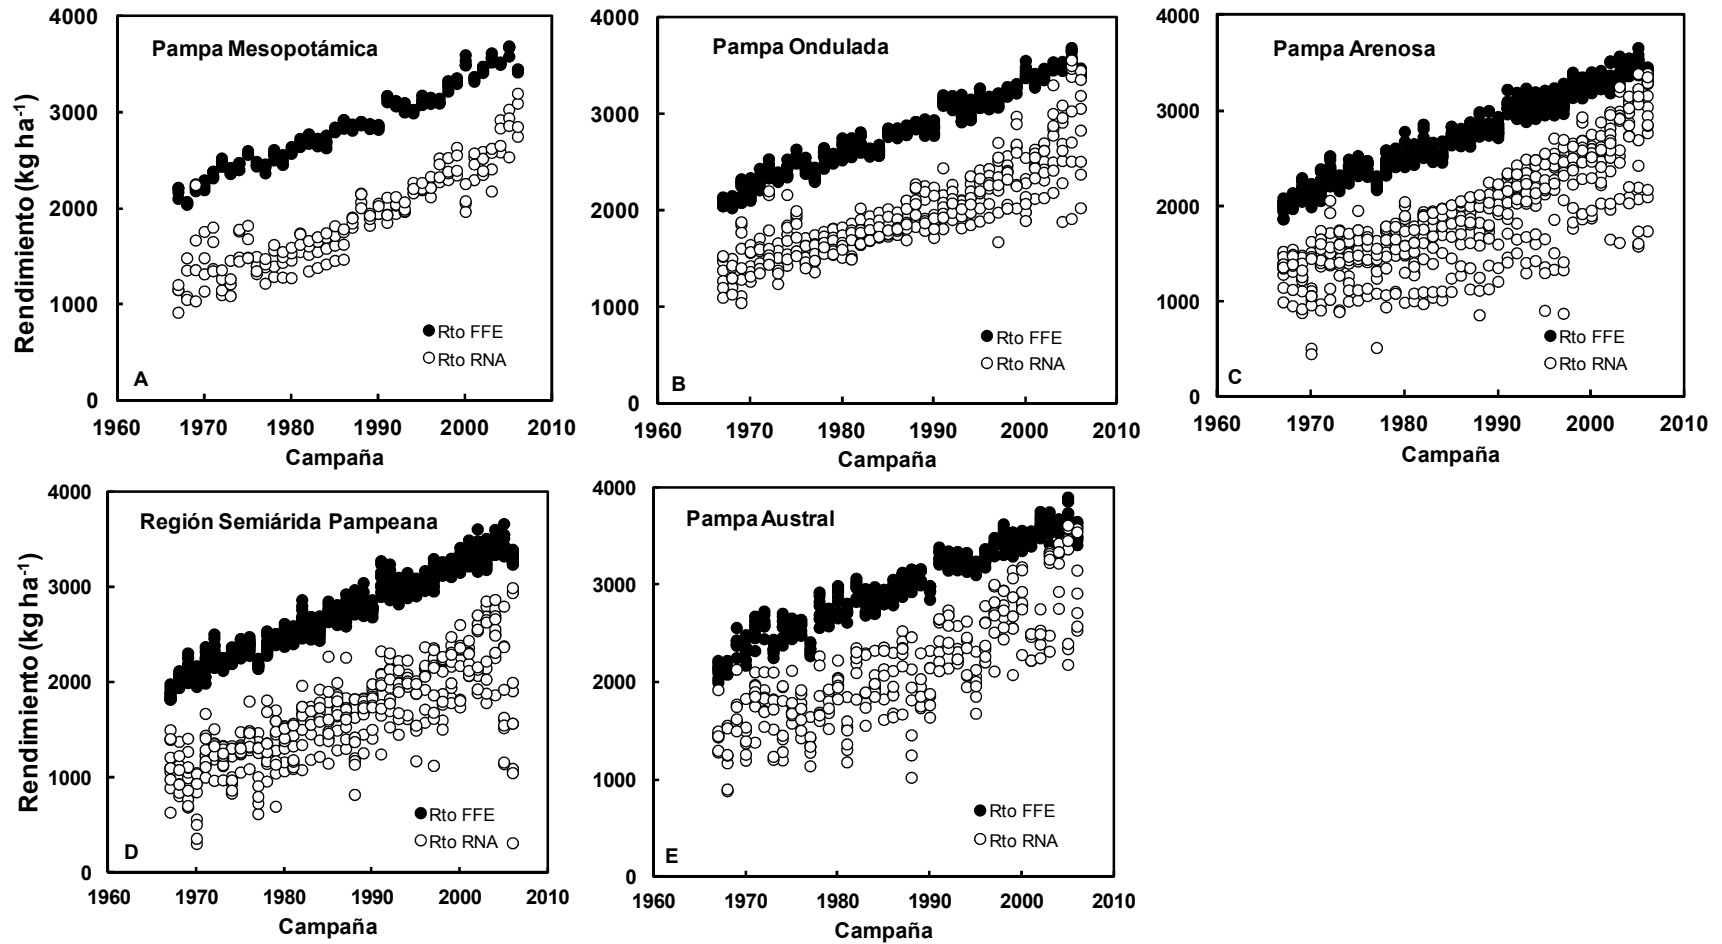


Figura 5.5. Relación entre el rendimiento observado y el estimado por la función de frontera estocástica (FFE) para las sub-regiones pampeanas: A. Pampa Mesopotámica, B. Pampa Ondulada, C. Pampa Arenosa, D. Región Semiárida Pampeana y E. Pampa Austral.

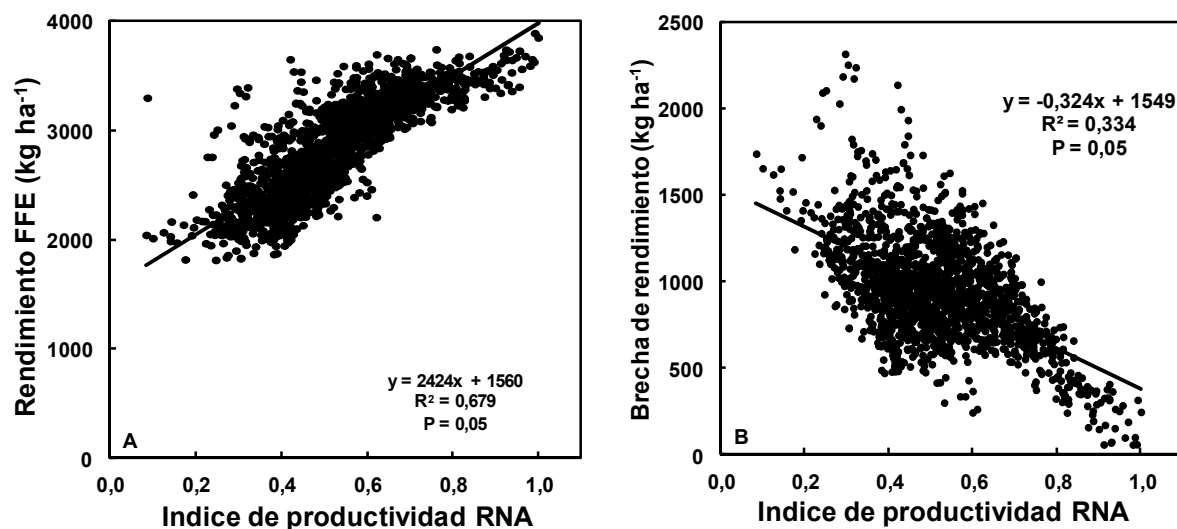


Figura 5.6.A. Relación entre el rendimiento máximo alcanzado estimado con una función de frontera estocástica (FFE) y **B.** la brecha de productividad vs. el índice de productividad desarrollado con una red neuronal artificial (RNA).

Tanto la brecha de rendimiento como el índice de productividad se calcularon con la misma RNA. A medida que aumenta el índice también aumenta el rendimiento medio del sitio x momento (descontado al rendimiento frontera), lo que pareciera que necesariamente debe llevar a los resultados de la **Figura 5.6 B.** Sin embargo, en la misma dirección cambia el rendimiento frontera, con valores mayores a mayor productividad (**Figura 5.6 A**), lo que va en dirección opuesta, tendiendo a reducir las brechas en el rango de baja productividad. La resultante de estas dos tendencias es la brecha calculada, que no resulta entonces de una relación espuria entre las variables regresionadas en la **Figura 5.6 B.**

La variabilidad, usando como medida de dispersión la RMSE, de la brecha de rendimiento fue mayor en sitios de baja productividad que en los de alta productividad (**Figura 5.7.**). Posiblemente esto esté asociado a la variabilidad de las condiciones climáticas de la Región Semiárida Pampeana y la Mesopotamia, donde muchos años las precipitaciones son menores o mayores respectivamente a los óptimos para el cultivo.




Figura 5.7. Relación entre la RMSE (*root mean squared error*) del la brecha de rendimiento en función de los valores del índice de productividad que fueron subdivididos en rangos.

En la **Figura 5.8.A.** se observa la distribución geográfica del promedio de 40 campañas del rendimiento máximo alcanzado estimado con la FFE por unidad geográfica desde la campaña 1967 hasta 2006. El promedio de este rendimiento estimado no varía mucho al comparar los valores de las distintas unidades geográficas, en la Pampa Austral se obtienen los valores más altos con un promedio de 3000 kg ha⁻¹ y la Región Semiárida Pampeana con los valores promedios más bajos rondando el valor de 2600 kg ha⁻¹. En cambio lo que se muestra la **Figura 5.8.B.** es la distribución geográfica de la brecha de productividad que muestra que los valores más altos de la misma se obtienen en las unidades geográficas perimetrales del área de estudio, en la Región Semiárida Pampeana y en la Pampa Mesopotámica principalmente.

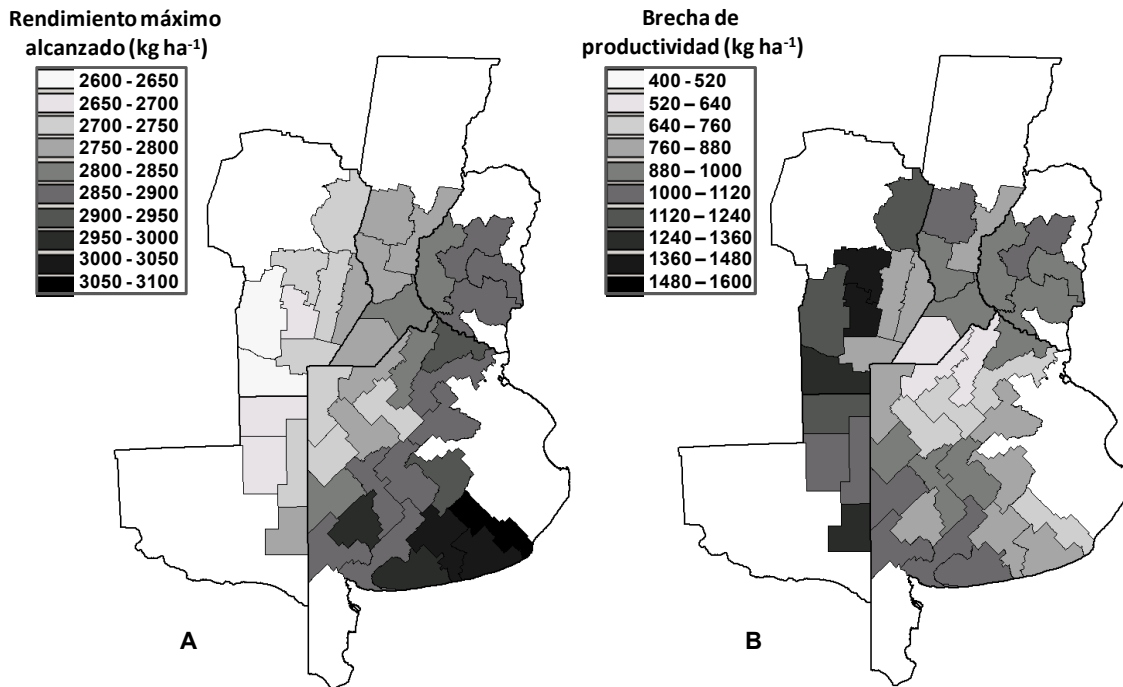


Figura 5.8. **A.** Rendimiento alcanzado promedio por unidad geográfica para el período 1967-2006 estimado con una función de frontera estocástica. **B.** Brecha de productividad estimada como la diferencia promedio entre el rendimiento máximo alcanzado estimado por una FFE y el rendimiento promedio estimado por una red neuronal artificial.

Finalmente, se pudo ajustar un modelo explicativo de la brecha de rendimiento a través de una RNA que detectó con efecto significativo las siguientes variables: campaña, carbono orgánico, CAAU, precipitación/ETP durante el barbecho, la fase vegetativa y la floración del cultivo así como también el efecto del coeficiente fototérmico. Las neuronas en la capa oculta fueron 7. Tanto para el set de datos de *training* (75 % del total) como para el set de *validation* (el 25 % restante e independiente) el R^2 fue mayor a 75, con un RMSE menor a 144 kg ha⁻¹ (**Figura 5.9**). En ambas regresiones lineales la pendiente es igual a 1 y la ordenada al origen es igual a 0.

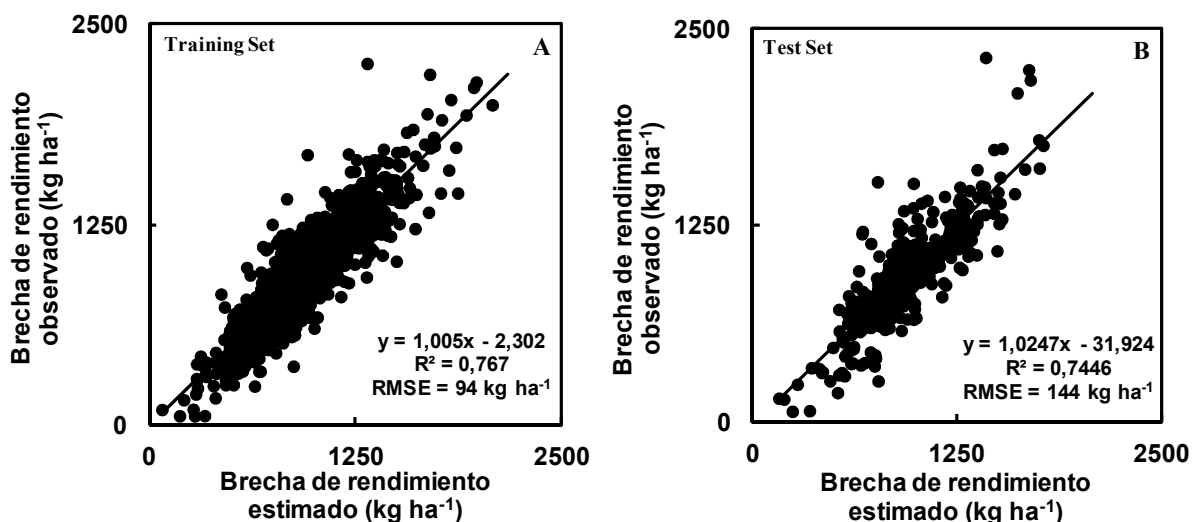


Figura 5.9. Ajuste del modelo regional generado con una red neuronal artificial (RNA) para la estimación de la brecha de rendimiento para los dos sets de datos independientes **A.** *training* y **B.** *validation*.

Se relacionó la brecha de rendimiento estimada con la RNA con la precipitación (**Figura 5.10**). Las menores brechas se producen en el rango de precipitación 400-600 mm con un promedio cercano a 900 kg ha⁻¹. En las áreas o años donde la precipitación fue muy baja la brecha aumenta. Por debajo de 300 mm algunos años la brecha llega hasta 2000 kg ha⁻¹. También aumenta la brecha en áreas o años de muy altas precipitaciones. Por encima de 700 mm en algunos casos la brecha llega a 1500 kg ha⁻¹. La mayor parte de los casos con muy baja precipitaciones corresponden a la Región Semiárida Pampeana, mientras que los casos de precipitaciones excesivas corresponden mayormente a la Mesopotamia.




Figura 5.10. Relación entre la brecha de rendimiento estimada con una RNA regional y la precipitación del barbecho y el ciclo del cultivo.

La brecha de productividad, es decir el promedio de la brecha de rendimiento por unidad geográfica, se encuentra relacionada a las dos variables edáficas seleccionadas: el contenido de carbono orgánico para la profundidad 0-50 cm y la CAAU para la profundidad 0-100 cm o hasta el límite superior de la capa petrocálcica en caso de presentarse. Se observa que la brecha de productividad tiene un óptimo o mínimo equivalente a 300 kg ha^{-1} aproximadamente cuando los suelos tienen un contenido de carbono orgánico de $60\text{-}70 \text{ t ha}^{-1}$ y una CAAU de 140 mm (**Figura 5.11.**). Por un lado, en suelos con contenidos de carbono altos en combinación con una CAAU inferior a los 100 mm la brecha llega a los valores más altos (ca. 2400 kg ha^{-1}). Sin embargo, en suelos con poco carbono orgánico pero en combinación con CAAU altas la brecha llega a valores que cuadruplican el óptimo llegando a valores de hasta 1200 kg ha^{-1} . Esta interacción positiva entre ambas variables de suelo también se observa para la combinación de niveles altos de ambas donde la brecha de productividad alcanza valores de 900 kg ha^{-1} .

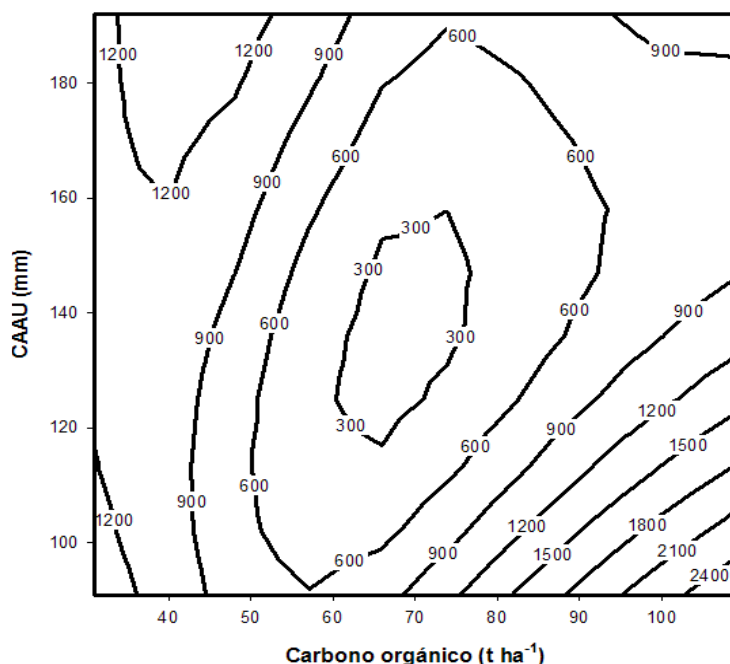


Figura 5.11. Relación entre las variables edáficas carbono orgánico y la CAAU de los suelos pampeanos, para un escenario climático promedio, con respecto a la brecha de productividad.

5.6. Discusión

Los modelos de simulación permiten superar las dificultades de mantener ensayos experimentales de larga duración. La desventaja de utilizar modelos de simulación es que requieren datos detallados a nivel sitio-específico que no suelen estar disponibles para escalas geo-espaciales adecuadas. La validación de EPIC con datos de ensayos experimentales de cinco localidades de la Región Pampeana no fue exitosa y tampoco se logró mejorarla con la ayuda de Jimmy Williams y no se pudo determinar la razón exacta por la cual los ajustes de EPIC para trigo no fueron buenos. Hay dos aspectos que se deberían considerar para poder responder a estos resultados. Por un lado, se podría pensar que como el modelo de simulación EPIC fue desarrollado para la estimación del rendimiento de trigo adaptado a las condiciones de las Grandes Planicies Americanas no se pudieron incorporar correctamente las condiciones pampeanas al mismo. El cultivo de trigo para el que fue creado el modelo es de invierno, es decir que se siembra durante el otoño, atraviesa el invierno cubierto por nieve en algún momento y finalmente cosechado en verano. El trigo en la Región Pampeana es conocido como de primavera, puesto que se siembra a mediados de invierno bajo un escenario de mucho menos frío que en USA y estas diferencias varietales podrían ser la causa del fracaso local de EPIC. En aproximadamente un 50 % de los casos los valores estimados de rendimiento fueron menores a los valores observados en los ensayos experimentales de INASE. Por otro lado, los datos de INASE usados para la evaluación fueron de experimentos tomados de la bibliografía. Fallas en la descripción de esos experimentos podrían explicar las diferencias. Díaz (1996) realizó calibraciones y validaciones con ensayos de labranza con más de 10 años de duración para la rotación trigo/soja de segunda/maíz en la Estación Experimental de INTA en Pergamino también con malos ajustes para trigo con este modelo. Bernardos et

al, (2001) usaron el EPIC para estimar el rendimiento de cinco partidos de la Provincia de La Pampa pero sin una validación previa.

Existen otros varios ejemplos de aplicaciones exitosas de la aplicación de modelos de simulación para la estimación de brechas de rendimiento. Con el modelo ORYZA2000 se pudo estimar la brecha de productividad de arroz en el Sudeste Asiático y se determinó que los productores que lograban los mejores rendimientos eran los más capacitados y los que además usaban los fertilizantes y los métodos de labranza de manera más eficiente (Laborte et al., 2012). Se estimó la brecha de rendimiento para la producción a pequeña escala de maíz en el centro Brasil con el modelo STICS vinculándolo a la fecha de siembra y a la capacidad de retención de los suelos principalmente (Affholder et al., 2003). En el valle mediterráneo del Ebro se utilizó el modelo wheat-CERES para vincular la brecha del rendimiento de trigo para determinar además cómo la fertilización nitrogenada es una herramienta para reducirla (Abeledo et al., 2008).

Algunos factores ambientales, y cuya simulación con modelos de simulación es complicada, como sequías, inundaciones y/o suelos infértiles imponen límites severos a la posibilidad de aumentar el rendimiento por más de que los productores tengan acceso a variedades mejoradas y fertilizantes (Cassman 1999). Las prácticas de manejo modernas han tenido un impacto significativo sobre el rendimiento en ambientes de producción bajo secano donde la calidad climática y edáfica es favorable para el crecimiento del cultivo como en el noroeste y centro de Europa para trigo y en el cinturón maicero de Estados Unidos para el cultivo de maíz. En sistemas de producción de secano bajo condiciones climáticas semiáridas y en combinación con suelos pobres, la producción de trigo y maíz se ha incrementado lentamente en los últimos 30 años (Cassman 1999).

Una ventaja importante del análisis con la FFE es el uso consistente de un set de datos del rendimiento observado a partir del cual se va a estimar el rendimiento alcanzado máximo (Neumann et al., 2010). Los datos de producción de trigo por campaña utilizados fueron publicados por el Ministerio de Agricultura, Ganadería y Pesca de la Nación. Los datos publicados se presentan a escala departamento que por la incertidumbre que pueden tener, sobre todo aquellos de superficies pequeñas (Sadras et al., 2014) se utilizaron los datos agregados espacialmente a la escala unidad geográfica. Estos datos de rendimiento alcanzado pueden presentar adversidades, como heladas, ataques de fusarium, etc., en algunas campañas. Por esta razón el rendimiento estimado por la FFE es considerado el rendimiento alcanzado máximo del set de datos de rendimiento que resulta de la mejor combinación de clima x suelo x manejo bajo condiciones de secano pampeanos.

El rendimiento observado se encuentra linealmente relacionado al rendimiento máximo alcanzado estimado por la FFE. El rendimiento máximo alcanzado mostró una menor dispersión anual que el rendimiento promedio estimado por una RNA y el rendimiento observado por partido. La FFE subestima para un 5 % de los casos el rendimiento alcanzado máximo y esto probablemente se deba a que fueron campañas con menos déficit hídrico y/o mayor disponibilidad de nutrientes. Esto también fue observado en lotes agrícolas irrigados para la rotación trigo-maíz en China y maíz en secano en Zimbabue (Carberry et al., 2013) así como también para trigo producido en secano en Victoria, Australia, (van Ittersum et al., 2013).

También el índice de productividad generado con una RNA, se relaciona linealmente y de manera positiva con el rendimiento máximo alcanzado estimado con la FFE lo que podría significar que en los partidos donde alguna vez el rendimiento máximo alcanzado fue alto también los rendimientos promedio son altos. Del análisis de la distribución geográfica de los rendimientos máximos alcanzados estimados por la FFE se deduce que las sub-región Pampa

Austral es el área donde la combinación de las variables biofísicas y las de manejo permitieron el rendimiento más alto durante las 40 campañas analizadas. Por su ubicación meridional el cociente fototérmico promedio de esta sub-región es alto, las precipitaciones medias anuales llegan a los 1000 mm y aunque los suelos no son muy profundos, el contenido de carbono orgánico es muy alto (Alvarez y Lavado, 1998).

La FFE detectó el efecto de la campaña como la variable significativa de más peso en todas las sub-regiones pampeanas. Como se mencionó previamente en el Capítulo 3, no se pudo desagregar el factor campaña en las variables dosis de fertilizante, mejora genética relativa y evolución en el sistema de labranza, estimadas ambas a partir de bases de datos incompletas y consultas a expertos, por estar muy correlacionadas. También en el trabajo de Neumann et al. (2010) se menciona la dificultad de trabajar con datos de manejo detallados, como la aplicación de fertilizante. Los índices climáticos precipitación/ETP durante el barbecho y la fase vegetativa y el coeficiente fototérmico tienen un efecto significativo sobre el rendimiento alcanzado estimado por la FFE, aunque la respuesta del rendimiento no es marcada ya que se trataría del rendimiento máximo alcanzado con una variabilidad interanual muy baja.

La CAAU promedio de los suelos pampeanos explica casi un 24 % de la variabilidad del rendimiento máximo alcanzado promedio cuyo efecto sobre el rendimiento medio de trigo ya fue detectado previamente en otros estudios (Alvarez 2009; Bono et al., 2010) y también en el modelo regional desarrollado en esta tesis. Utilizando una FFE Verburg et al. (2000) determinaron que en las regiones del oeste de China, se podría achicar la brecha entre el rendimientos frontera y el observado al mejorar la ineficiencia en el uso de insumos agrícolas y aumentar las dosis de fertilizante aplicado. Neumann et al. (2010) combinaron esta metodología econométrica con un análisis espacial para explorar el rendimiento alcanzado y la brecha de rendimiento de trigo, maíz y arroz a nivel mundial. Los resultados de éste estudio global muestran que en algunas regiones los rendimientos ya se aproximan a sus niveles máximos alcanzados mientras que en promedio los rendimientos alcanzados se encuentran a un 64 %, 50 % y 64 % para trigo, maíz y arroz respectivamente, de su rendimiento frontera.

La brecha de rendimiento de trigo calculada en la Región Pampeana varió entre -45.5 kg ha^{-1} y 2989 kg ha^{-1} para las 40 campañas y las 41 unidades geográficas analizadas. En las sub-regiones ubicadas en el perímetro externo de la Región Pampeana, como en la Región Semiárida Pampeana y la Pampa Mesopotámica, las brechas son las mayores y estos resultados concuerdan con la hipótesis planteada de éste capítulo. El rendimiento máximo alcanzado en éstos ambientes en algún momento, seguramente en alguna campaña con precipitaciones cercanas al óptimo y combinado con dosis de fertilizante óptimas, fue mucho mayor al rendimiento promedio alcanzado regularmente. Esto también se confirmó al analizar la relación entre la brecha de rendimiento y el rango de las precipitaciones regionales abarcadas en el análisis. Las mayores brechas de rendimiento se identificaron en los extremos del rango de precipitación analizado, específicamente en las áreas con precipitaciones menores a 300 mm y mayores a 700 mm. Por un lado, la alta variabilidad climática característica de la Región Semiárida, que ha sido documentada previamente (Hall et al., 1992), puede ser una de las razones por las cuales tanto la brecha de rendimiento como la de productividad obtiene valores altos. Por otro lado, cuando en la Pampa Mesopotámica las precipitaciones son excesivas el rendimiento decae y esto probablemente se deba a enfermedades (Annone, 2001) y anegamiento de lotes (De San Celedonio et al., 2014).

La relación entre la brecha de rendimiento y el índice de productividad determinado por una RNA es negativa es decir que en áreas productivas los rendimientos observados se

encuentran cercanos a su rendimiento máximo alcanzado. A escala mundial la brecha de rendimiento para trigo definida como la diferencia entre el rendimiento máximo alcanzado y el rendimiento observado obtuvo un rango de 0 a 3.5 t ha⁻¹ durante el año 2000 aproximadamente (Neumann et al., 2010).

A nivel regional la brecha de rendimiento es menor en ambientes productivos que resultan en rendimientos de trigo más elevados. Este patrón se repite al analizar espacialmente el promedio de las 40 campañas del rendimiento máximo alcanzado estimado por la FFE que muestra que las mayores brechas se producen en el perímetro de la Región Pampeana. Datos locales muestran brechas de rendimiento, estimadas como la diferencia entre el rendimiento alcanzable estimado con CERES-wheat y el observado, promedio de 2.0 t ha⁻¹ y de hasta 3.6 t ha⁻¹ para la Región Semiárida Pampeana (Monzón et al., 2013). En África subsahariana, la variabilidad interanual de la brecha de rendimiento de maíz disminuyó al aumentar la dosis de fertilizante en áreas menos productivas con bajos contenidos de carbono orgánico (Sileshi et al., 2010). Cuanto mayor es el rendimiento alcanzable de trigo en la España mediterránea, menor es la brecha con respecto al rendimiento potencial y esto tanto para condiciones medias y altas de fertilización nitrogenada (Abeledo et al., 2008). Esos resultados son similares a los encontrados en esta tesis donde suelos de mayor productividad tienen las menores brechas de rendimiento.

La brecha de productividad regional, es decir el promedio de la diferencia entre el rendimiento máximo alcanzado estimado por la FFE y el rendimiento medio modelizado con una RNA, fue de 944 kg ha⁻¹ para las 40 campañas y varió de 400-1600 kg ha⁻¹ entre las 41 unidades geográficas analizadas. Así como la brecha de rendimiento era mayor en las unidades geográficas perimetrales del área de estudio, la brecha de productividad también fue mayor en la Región Semiárida Pampeana.

En cuanto a la brecha de productividad para trigo en otras regiones del Mundo, hay varias estimaciones hechas y con distintas aproximaciones metodológicas. Para poder comparar los resultados es necesario tener en cuenta la definición específica de la brecha para cada caso y el período comprendido en el promedio que representa la brecha de productividad. La diferencia entre el rendimiento potencial y alcanzable en condiciones mediterráneas alcanza valores promedio de hasta 7 t ha⁻¹ (Abeledo et al., 2008), mientras que cuando se calcula con respecto al rendimiento observado promedio llega a valores de 2.5 t ha⁻¹ en el oeste de Australia (Anderson 2010). También en Australia, se logran valores de 2.0 t ha⁻¹ cuando se estima la brecha de rendimiento como la diferencia entre rendimiento alcanzable y el alcanzado por productores (Hochman et al., 2013), de 0,48 t ha⁻¹ cuando se calcula con respecto a resultados de encuestas (van Rees et al., 2014) y de 0,8 t ha⁻¹ cuando se hace referencia al rendimiento alcanzado promedio (van Ittersum et al., 2013).

Sadras y Angus (2006) estimaron para los cuatro mega-ambientes del sudeste de Australia, las Grandes Planicies Americanas, el Plateau de Loess de China y la cuenca del Mediterráneo la diferencia entre el rendimiento alcanzable y el rendimiento alcanzado medido en lotes de producción que varió de -0,5 t ha⁻¹ a 2.8 t ha⁻¹ a partir de datos publicados correspondientes a 10 campañas. En algunos casos determinaron qué factores fueron los responsables de la brecha como en el trabajo regional de Sileshi et al. y (2010) que se menciona el contenido de arcilla y la precipitación media anual y en el trabajo global de Neumann et al. (2010) esta ineficiencia es relacionada a variables de manejo.

El modelo regional explicativo de la brecha de rendimiento de trigo para la Región Pampeana pudo vincularla a factores biofísicos y a la campaña. Un 75 % de su variabilidad interanual pudo ser explicada a través del modelo de la RNA ajustado. El modelo explicativo

detectó a la variable campaña como la de más peso significativo y mostró un efecto curvilíneo mostrando que la brecha disminuye en las campañas más recientes. Una de las ventajas de desarrollar modelos con la metodología de RNA es que se puede analizar la interacción entre las variables detectadas como significativas sobre la brecha de rendimiento en este caso. Bajo un escenario climático medio, se detectó que existe un mínimo u óptimo en la brecha de productividad pampeana para valores medios de carbono orgánico y la CAAU. Específicamente, este mínimo estimado fue de 300 kg ha^{-1} que resulta de la combinación de contenidos de carbono orgánico de 65 t ha^{-1} y una CAAU de entre 120 mm y 150 mm.

La brecha de rendimiento aumenta hasta 2400 kg ha^{-1} aproximadamente en suelos con altos contenidos de carbono en el perfil pero con baja retención de agua útil. En la Región Semiárida Pampeana se pudo determinar que el agua retenida a la siembra podía reducir la intensidad del estrés hídrico sufrido por el cultivo de girasol y así reducir la brecha entre el rendimiento observado y el valor de la función de frontera con respecto a la disponibilidad de agua observada (Grassini et al., 2009). En este estudio se pudieron identificar algunas causas de la reducción del rendimiento, y el incremento de la brecha asociada, sin embargo no se asignaron pesos a esos efectos. En África subsahariana se detectó una relación cuadrática del efecto del porcentaje de arena de los suelos sobre la brecha de rendimiento de maíz, también la elevación de los lotes y la precipitación media anual tuvieron impacto en la brecha, pero estas relaciones fueron menos claras (Sileshi et al., 2010).

5.7. Consideraciones finales

Se estimó la brecha de rendimiento de trigo de la Región Pampeana como la diferencia entre el rendimiento máximo alcanzado estimado con una FFE y el rendimiento medio modelizado con una RNA. Al analizar temporal y espacialmente esta brecha se pudo detectar que las diferencias mayores se ubican en el perímetro del área de estudio y en particular en la Región Semiárida Pampeana. En esta sub-región pampeana la brecha de rendimiento promedio para las 40 campañas analizadas llega a valores de más de 1000 kg ha^{-1} , decreciendo en los últimos años.

Muchos estudios locales e internacionales pudieron hacer estimaciones sobre la brecha de rendimiento; sin embargo son muy pocos los estudios que lograron asociarla a patrones de clima y suelo. La brecha de productividad pampeana, definida en este capítulo como la diferencia entre rendimiento máximo alcanzado y el rendimiento promedio esperado, muestra una distribución espacial que aporta evidencia para aceptar la hipótesis planteada según la cual la brecha de productividad es mayor en los suelos menos productivos. Se pudieron determinar los factores determinantes de la brecha de productividad a través de una RNA. Se determinó que la menor brecha, equivalente a 300 kg ha^{-1} , se obtiene en suelos con valores medio de carbono orgánico y CAAU. En suelos con contenidos mayores a 65 t ha^{-1} de carbono orgánico en sus perfiles pero con una CAAU menor a 100 mm se detectaron brechas de productividad muy altas que rondan los 2400 kg ha^{-1} , mientras que en suelos con bajos contenido de carbono orgánico pero con CAAU altas la brechas fueron de 1200 kg ha^{-1} aproximadamente.

CAPITULO 6

DISCUSIÓN GENERAL

CAPITULO 6. Discusión general

6.1. Contexto de la problemática abordada

En el contexto global de aumento de la población, el nivel de consumo asociado y la desaceleración en las tasas de aumento de los rendimientos de los cultivos detectadas en algunas áreas, es importante analizar la productividad de agroecosistemas de alto potencial productivo (Hafner 2003). Adicionalmente, la cuantificación de la productividad de los suelos a través de índices permite predecir su comportamiento para distintos usos y zonificar regiones (Cassman 1999; Foley et al., 2005). La Región Pampeana, además de ser un área productora de granos de importancia a nivel mundial, presenta un sistema de estudio ideal para el análisis de la productividad regional por la muy amplia variación de sus condiciones climáticas y edáficas. El trigo se cultiva en toda la región (MinAgri, 2014) sobre suelos de características muy contrastantes permitiendo un análisis muy abarcativo de productividad, cuyas conclusiones pueden ser de interés para otros cultivos y en otras regiones productivas.

Muchos índices de productividad se desarrollaron en el Mundo previamente a esta tesis, algunos inductivos, basados en consideraciones teóricas y otros pocos deductivos, basados en modelos de rendimiento (García-Paredes et al., 2000), pero en su elaboración solo se habían usado métodos estadísticos de regresión sencillos (Neter et al., 1990), que presentan limitaciones para exponer relaciones ocultas e interacciones entre variables (Bakker et al., 2005). Por ejemplo en Argentina se usó en la elaboración de los mapas de suelo de INTA el índice inductivo de FAO (Riquier et al., 1970), no validado localmente. Las técnicas de regresión habían mostrado efectos de diferentes variables de suelo sobre la productividad pero sus interacciones no fueron en general analizadas (Tasi et al., 2010). Como muestra de esto puede indicarse que en la Región Pampeana eran conocidos los efectos de la materia orgánica (Díaz-Zorita et al., 1999) y la capacidad de almacenamiento de agua (Alvarez, 2009) sobre el rendimiento de trigo, sin haberse cuantificado la posible interacción entre ambas o con el escenario climático.

La brecha de rendimiento ha sido estudiada para muchos cultivos y regiones pero en muy pocos casos se trató de asociar la misma a factores de clima y suelo (Abeledo et al., 2008; Licker et al., 2010). No se habían desarrollado metodologías que permitan estudiar las relaciones entre la brecha y dichos factores. Localmente se estimó esta brecha solamente para el cultivo de girasol en la Región Semiárida Pampeana sin asociarla a factores ambientales (Grassini et al., 2009). A partir de este escenario es que se fijó el objetivo general de la tesis, estudiar la productividad de los suelos pampeanos para trigo y la brecha de productividad, definida aquí como la brecha promedio de rendimiento de un área, la que puede asociarse a las condiciones de esa área. Para cumplir este objetivo se generó una base de datos de suelos y clima única hasta el momento en el país. La misma fue utilizada en la tesis y también para estudios de dinámica de carbono y nitrógeno en los suelos pampeanos. Actualmente está siendo usada en estudios de fósforo del suelo.

6.2. Alcances y limitaciones de los resultados de la tesis

A través de una analogía con la ley de los rendimientos no proporcionales se planteó la hipótesis: *el rendimiento de trigo a nivel de la Región Pampeana depende de la interacción entre la CAAU y el contenido de carbono orgánico del suelo*. Para testearla se desarrollaron

varias metodologías de modelización del rendimiento. De éstas una RNA resultó la mejor por el ajuste logrado ($R^2 = 0.614$; $P = 0.05$) y la capacidad de incluir variables con efecto significativo sobre el rendimiento. Esta metodología pudo detectar una interacción significativa entre las dos variables de suelo mencionadas confirmando la hipótesis (**Figura 4.9**). Esta interacción define el rendimiento de trigo a escala de la Región Pampeana. Como en trabajos previos (Park et al., 2005; Alvarez, 2009) la inteligencia artificial resultó la mejor herramienta para modelizar el rendimiento de un cultivo. Pero en la tesis se dió un paso más en el uso de redes neuronales generando un índice de productividad de suelo con una RNA. Esta propuesta metodológica es novedosa. La misma permitió proponer un índice de productividad basado en la interacción entre carbono orgánico y CAAU para los suelos pampeanos (**Figura 4.3**) con una performance muy superior ($R^2 = 0.728$; $P = 0.05$) a la de la metodología de la FAO ($R^2 = 0.433$; $P = 0.05$) usada en Argentina hasta el momento. Las curvas de rendimiento generadas con la RNA para diferentes escenarios de carbono orgánico y CAAU reafirman la interacción positiva detectada entre ambas variables y permiten generar tendencias del rendimiento ante combinaciones variables de suelo y clima (**Figura 3.9** y **3.10**). Existe un óptimo de la productividad cuando la CAAU se aproxima a los 140 mm y el contenido de carbono orgánico de los suelos es de 65 t ha^{-1} en los primeros 50 cm. Los valores más altos del índice de productividad se producen en la Pampa Ondulada y en la Pampa Austral, disminuyendo a medida que los suelos se alejan de la combinación óptima, lo que ocurre en la Región Semiárida Pampeana y la Pampa Mesopotámica.

A pesar de las ventajas de la metodología de RNA desarrollada en esta tesis cabe destacar que el usuario debe tener acceso al programa para correr el modelo y esto puede significar una limitación para su uso que solo se supera parcialmente usando el nomograma de salida de la productividad para condiciones climáticas promedio. Una posibilidad de soslayar esta limitación es hacer una evaluación a nivel de unidad cartográfica (definida en los mapas de INTA) de la productividad y hacerla de dominio público. Esto queda fuera de los alcances de esta tesis.

La RNA ajustada solo es de aplicación a escala regional y no se tuvo éxito al intentar aplicarla a datos generados a escala de sitio (**Figura 3.11**) por lo que la hipótesis: *los modelos empíricos que explican la variabilidad interanual del rendimiento de trigo a escala regional pueden ser utilizados a escala de sitio*, debió ser rechazada. Si bien era esperable que la RNA ajustada con valores promedio de rendimiento regional subestimara los alcanzados en experimentos, tampoco se logró un ajuste aceptable. Las causas de esto no pudieron ser aclaradas, pero una limitante de trabajar a escala regional es que en algunos casos puntuales los patrones generales no se cumplen lo que dificulta la validación a nivel sitio (Górski y Górka, 2003).

El tiempo se utilizó como input de la RNA subrogando los efectos de la mejora tecnológica. Se atribuyó este efecto a que las variables de manejo (mejora genética, fertilización y sistema de labranza) estaban muy correlacionadas con el tiempo y a que la RNA separaba la variabilidad espacial e interanual climática del tiempo por lo que no es probable encontrar efectos confundidos entre ambos. Debido a que las variables de manejo se correacionaban fuertemente entre sí (**Cuadro 2.4**) no se pudo aislar el efecto de cada una de ellas. Dificultades similares debidas a la autocorrelación entre el tiempo y el manejo han sido descritas anteriormente (Lobell et al., 2005).

Cuando el escenario productivo se aleja de la combinación óptima de factores determinantes del rendimiento es más probable que aumente la proporción de combinaciones desfavorables. Esto llevó a plantear la hipótesis: *la brecha de rendimiento-*

productividad es mayor en ambientes de baja productividad. Para testearla se ajustó una FFE que permitió estimar la variación espacial y temporal de los rendimientos máximos alcanzados en la Región Pampeana. Se desarrolló una metodología de dos etapas en la que primero se estimaba la brecha de rendimiento y luego se la modelizaba con una RNA para identificar los factores reguladores y cuantificar sus efectos. Este fue otro de los aportes originales de la tesis. Esta metodología podrá ser usada de aquí en más para otros cultivos y regiones. Las brecha de rendimiento y la de productividad fueron mayores en las áreas pampeanas menos favorables para el trigo lo que llevó a aceptar la hipótesis. El análisis espacial de la brecha de productividad por unidad geográfica mostró que los mayores valores se producían en las áreas perimetrales de la Región Pampeana como la Región Semiárida Pampeana y la Pampa Mesopotámica.

Con un modelo regional explicativo de la brecha de productividad ajustado con una RNA ($R^2 = 0,7446$; $P = 0.05$) se pudo determinar que la brecha está definida por la CAAU y el contenido de carbono orgánico a través de una interacción positiva (**Figura 5.11**). Esta interacción de ambas variables edáficas además resulta en un mínimo de 300 kg ha^{-1} , 32 % del promedio regional, cuando la CAAU es de 120 mm y los suelos tienen 65 t ha^{-1} de carbono orgánico. Un mínimo muy cercano al óptimo observado para el índice de productividad. A medida que las condiciones se alejan del óptimo de productividad aumenta la brecha de productividad, en una relación aparentemente regulada por la disponibilidad de agua (**Figura 5.10**). En la Región Semiárida Pampeana son muy altas las brechas en años secos y en la Pampa Mesopotámica lo son en años muy húmedos. Sobre la base de los resultados disponibles solo puede especularse sobre las causas de estos resultados pero parece probable que prácticas de manejo que apunten a mejorar la disponibilidad de agua para el trigo en la primera (elección del cultivo, fecha de siembra, duración del barbecho, sistema de labranza, etc.) y limiten posibles problemas de enfermedades o encharcamiento en la segunda (uso de variedades resistentes, fungicidas, selección de lotes, etc.) lleven a reducir la brecha de productividad. En estas sub-regiones se deberían enfocar los esfuerzos técnicos y de investigación para que los rendimientos se aproximen más a sus máximos alcanzables.

Para la Región Pampeana a escala regional la tesis ha abarcado toda la información disponible al momento tanto para las características de suelo como las de clima evitando efectos confundidos entre variables biofísicas en el análisis de la productividad de los suelos gracias a las metodologías desarrolladas. A pesar de esto se debe destacar como limitante de la base de datos la ausencia de información sobre adversidades y problemas de manejo que afectan negativamente al rendimiento. Con respecto a los datos de suelo tampoco se dispuso de variables de fertilidad como contenido de nitratos, fósforo extractable, etc. cuyo efecto sobre el rendimiento de trigo ha sido identificado a nivel regional (Alvarez y Steinbach 2009). Estas limitaciones deberían ser superadas en trabajos futuros.

Esta tesis mostró que las acciones para mejorar la comprensión de los sistemas de producción con respecto a la brecha de productividad deberían enfocarse en la Región Semiárida Pampeana y en la Pampa Mesopotámica ya que es en esta sub-región donde los rendimientos están más alejados de sus óptimos. En este sentido se podría generar información a través de redes de ensayos experimentales ubicados en éstas sub-regiones que apunten a ese objetivo.

7. BIBLIOGRAFIA

- Abbate, P. E., F. H. Andrade y J. P. Culot (1995). The effects of radiation and nitrogen on number of grains in wheat. *The Journal of Agricultural Science* 124(03): 351-360.
- Abascal, S. A., D. E. Buschiazzo y H. R. Mirasson (2003). Almacenaje de agua y nitratos por barbechos para girasol en un suelo Haplustol Éntico de la Región Semiárida Pampeana Central. Cultivos de cosecha gruesa. *Boletín de Divulgación Técnica. INTA Anguil* 77: 85-89.
- Abeledo, L. G., R. Savin y G. A. Slafer (2008). Wheat productivity in the Mediterranean Ebro Valley: Analyzing the gap between attainable and potential yield with a simulation model. *Europ. J. Agron.* 28(4): 541-550.
- Affholder, F., E. Scopel, J. M. Neto y A. Capillon (2003). Diagnosis of the productivity gap using a crop model. Methodology and case study of small-scale maize production in central Brazil. *Agronomie.* 23(4): 305-325.
- Aigner, D., C. A. K. Lovell y P. Schmidt (1977). Formulation and estimation of stochastic frontier production function models. *J. Econometrics.* 6: 21-37.
- Alonso, M., R. Rodriguez, S. Gomez y R. Giagnoni (2002). Un método para estimar la radiación global con la amplitud térmica y la precipitación diarias. *Rev. Fac. Agron. UBA* 22: 51-56.
- Álvarez, C. R., H. S. Steinbach y R. Álvarez (2013). El rol de los fertilizantes en la agricultura. En 'Fertilización de cultivos y pasturas'. R. Álvarez. Buenos Aires, Argentina, (Editorial Facultad Agronomía. Universidad de Buenos Aires).
- Álvarez, C. R., H. S. Steinbach y R. Álvarez (2013). El rol de los fertilizantes en la agricultura. En 'Fertilización de cultivos y pasturas'. R. Álvarez. Buenos Aires, Argentina, (Editorial Facultad Agronomía. Universidad de Buenos Aires).
- Alvarez, R. (2001). Estimation of carbon losses by cultivation from soils of the Argentine Pampa using the Century Model. *Soil Use Manage.* 17(2): 62-66.
- Alvarez, R. (2009). Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *Eur. J. Agron.* 30(2): 70-77.
- Alvarez, R., C. R. Alvarez y H. Steinbach (2002). Association between soil organic matter and wheat yield in humid pampa of Argentina. *Commun. Soil Sci. Plant Anal.* 33(5&6): 749-757.
- Álvarez, R., G. Berhongaray, A. Bono, H. S. Steinbach y J. L. De Paepe (2014). Rangos de densidad aparente medidos en suelo pampeanos. XXIV Congreso Argentino de la Ciencia del suelo II Reunión Nacional de Materia Orgánica y sustancias Húmicas. Producción sustentable en Ambientes Frágiles, Bahía Blanca. Argentina, AACCS.
- Alvarez, R. y J. De Paepe (2010). Establishing productivity indices for wheat in the Argentine Pampas by an artificial neural network approach. En 'Artificial Neural Networks'. S. J. Kwon, (Nova Science Publishers, Inc.).
- Alvarez, R. y S. Grigera (2005). Analysis of soil fertility and management effects on yields of wheat and corn in the Rolling Pampa of Argentina. *J. Agron. Crop Sci.* 191: 321-329.
- Alvarez, R. y R. S. Lavado (1998). Climate, organic matter and clay content relationships in the Pampa and Chaco soils, Argentina. *Geoderma* 83: 127-141.
- Alvarez, R. y H. S. Steinbach (2013). Dosificación de la fertilización en trigo. En 'Fertilización de cultivos y pasturas. Diagnóstico y recomendación en la Región Pampeana'. R. Alvarez, P. Prystupa, M. B. Rodríguez y C. Alvarez. Buenos Aires, (Editorial Facultad de

- Agronomía).
- Alvarez, R. y H. S. Steinbach (2011). Modeling apparent nitrogen mineralization under field conditions using regressions and artificial neural networks. *Agron. J.* 103(4): 1159-1168.
- Alvarez, R. y H. S. Steinbach (2009). A review of the effects of tillage systems on some soil physical properties, water content, nitrate availability and crops yield in the Argentine Pampas. *Soil Till. Res.* 104(1): 1-15.
- Álvarez, R. y H. S. Steinbach (2012). Capítulo 7. Disponibilidad de nitrógeno en función del manejo. En 'Fertilidad de suelos. Caracterización y manejo en la Región Pampeana'. R. Álvarez, G. Rubio, C. R. Álvarez y R. Lavado. Buenos Aires, (Editorial Facultad de Agronomía. Universidad de Buenos Aires). Segunda Edición.
- Álvarez, R. y H. S. Steinbach (2012). Capítulo 1. Materia orgánica y productividad. En 'Fertilidad de suelos. Caracterización y manejo en la Región Pampeana'. R. Álvarez. Buenos Aires, Argentina, (Editorial Facultad Agronomía. Universidad de Buenos Aires).
- Álvarez, R. y H. S. Steinbach (2013). Capítulo 9. Dosificación de la fertilización en trigo. En 'Fertilización de cultivos y pasturas'. R. Álvarez, P. Prystupa, M. B. Rodríguez y C. R. Álvarez. Buenos Aires, (Editorial Facultad de Agronomía Universidad de Buenos Aires). Segunda Edición.
- Allgood, F. P. y F. Gray (1978). Utilization of Soil Characteristics in Computing Productivity Ratings of Oklahoma Soils. *Soil Sci.* 125(6): 359-366.
- Amemiya, T. (1985). *Advanced econometrics*. Cambridge, MA, Harvard University Press.
- Anderson, W. K. (2010). Closing the gap between actual and potential yield of rainfed wheat. The impacts of environment, management and cultivar. *Field Crop. Res.* 116: 14-22.
- Andriulo, A. y G. Cordone (1998). Impacto de labranzas y rotaciones sobre la materia orgánica de suelos de la Región Pampeana Húmeda. *Siembra Directa*. Eds JL Panigatti, H. Marelli, D. Buschiazzo, R. Gil. Buenos Aires, Argentina, Hemisferio Sur: 65-96.
- Annone, J. G. (2001). Criterios empleados para la toma de decisiones en el uso de fungicidas en trigo. *Rev. Tec. Agropecuaria* 6: 16-20.
- Bakker, M. M., G. Govers, F. Ewert, M. Rounsevell y R. Jones (2005). Variability in regional wheat yields as a function of climate, soil and economic variables: Assessing the risk of confounding. *Agr. Ecosyst. Environ.* 110(3-4): 195-209.
- Baldi, G. y J. M. Paruelo (2008). Land-use and land cover dynamics in South American temperate grasslands. *Ecol. Soc.* 13(2): 6.
- Batchelor, W. D., B. Basso y J. O. Paz (2002). Examples of strategies to analyze spatial and temporal yield variability using crop models. *Eur. J. Agron.* 18(1-2): 141-158.
- Battese, G. E. y T. J. Coelli (1995). A model for technical inefficiency effects in a stochastic frontier production function for panel data. *Emp. Econ.* 20(2): 325-332.
- Bauer, A. y A. Black (1994). Quantification of the effect of soil organic matter content on soil productivity. *Soil Sci Soc Am J* 58: 185-193.
- Bellocchi, G., M. Rivington, M. Donatelli y K. Matthews (2010). Validation of biophysical models: issues and methodologies. A review. *Agron. Sustain. Dev.* 30(1): 109-130.
- Berhongaray, G., R. Alvarez, J. L. De Paepe, C. Caride y R. Cantet (2013). Land use effects on soil carbon in the Argentine Pampas. *Geoderma* 192: 97-110.
- Bernardos, J. N., E. F. Viglizzo, V. Jouvét, F. A. Lértora, A. J. Pordomingo y F. D. Cid (2001). The use of EPIC model to study the agroecological change during 93 years of farming transformation in the Argentine pampas. *Agr. Syst.* 69(3): 215-234.
- Bessembinder, J. J. E., P. A. Leffelaar, A. S. Dhinwal y T. C. Ponsioen (2005). Which crop and

- which drop, and the scope for improvement of water productivity. *Agr., Water Manage.* 73(2): 113-130.
- Bolinder, M., D. Angers, E. Gregorich y M. Carter (1999). The response of soil quality indicators to conservation management. *Can. J. Soil Sci.* 79: 37-45.
- Bono, A. y R. Alvarez (2009). Rendimiento de trigo en la Región Semiárida y Subhúmeda Pampeana. Un modelo predictivo de la respuesta a la fertilización nitrogenada. *Informaciones Agronómicas* 41(1): 18-21.
- Bono A., J.L. De Paepe, R. Alvarez. 2011. In-season wheat yield prediction in the Semiarid Pampa of Argentina using artificial neural networks. *Progress in Food Science and Technology*. Vol. 1. Pág. 133-149. Ed. A.J. Greco, Nova Science Publishers, Inc.
- Bravo-Ureta, B. E. y A. E. Pinheiro (1993). Efficiency analysis of developing country agriculture: a review of the frontier function literature. *Agricultural and Resource Econ. Rev.* 22(11): 88-101.
- Brisson, N., E. Guevara, S. Meira, M. Maturano y G. Coca (2001). Response of five wheat cultivars to early drought in the Pampas. *Agronomie* 21(5): 483-495.
- Brown, R. A. y N. J. Rosenberg (1997). Sensitivity of crop yield and water use to change in a range of climatic factors and CO₂ concentrations: a simulation study applying EPIC to the central USA. *Agr. Forest Meteorol.* 83: 171-203.
- Browne, C.A. 1942. Liebig and the law of the minimum. In: C.A. Browne, R. Bradfield, H.B. Vickery (Eds.). *Liebig and after Liebig, A century of progress in agricultural chemistry*. American Association for the Advancement of Science, Washington, D.D. pgs. 71-82.
- Bruce, R. R., W. M. Snyder, A. W. White, A. W. Thomas y G. W. Langdale (1990). Soil variables and interactions affecting prediction of crop yield pattern. *Soil Sci. Soc. Am. J.* 54: 494-501.
- Burgos, J. y A. Vidal (1951). Los climas de la República de Argentina según la nueva clasificación de Thornwaite. *Revista de meteorología y geofísica del Servicio Meteorológico Nacional* 1(1).
- Buschiazzo, D., E. , A. Quiroga, R. y K. Stahr (1991). Patterns of Organic Matter Accumulation in Soils of the Semiarid Argentinian Pampas. *Zeitschrift für Pflanzenernährung und Bodenkunde* 154(6): 437-441.
- Buschiazzo, D. E., J. L. Panigatti y P. W. Unger (1998). Tillage effects on soil properties and crop production in the subhumid and semiarid Argentinean Pampas. *Soil Till. Res.* 49(1-2): 105-116.
- Cabelguenne, M. y P. Debaeke (1998). Experimental determination and modelling of the soil water extraction capacities of crops of maize, sunflower, soya bean, sorghum and wheat. *Plant Soil* 202(2): 175-192.
- Calderini, D. F., M. F. Dreccer y G. A. Slafer (1995). Genetic improvement in wheat yield and associated traits. A re-examination of previous results and the latest trends. *Plant Breeding* 114(2): 108-112.
- Calderini, D. F. y G. A. Slafer (1998). Changes in yield and yield stability in wheat during the 20th century. *Field Crop. Res.* 57: 335-347.
- Calviño, P. y V. Sadras (2002). On-farm assessment of constraints to wheat yield in the south-eastern Pampas. *Field Crop. Res.* 74: 1-11.
- Carberry, P. S., W.-I. Liang, S. Twomlow, D. P. Holzworth, J. P. Dimes, T. McClelland, N. I. Huth, F. Chen, Z. Hochman y B. A. Keating (2013). Scope for improved eco-efficiency varies among diverse cropping systems. *Proceedings of the National Academy of Sciences*

- 110(21): 8381-8386.
- Carter, M. R. (2002). Soil quality for sustainable land management: organic matter and aggregation interactions that maintain soil functions. *Agron. J.* 94: 38-47.
- Casanova, D., J. Goudriaan, J. Bouma y G. F. Epema (1999). Yield gap analysis in relation to soil properties in direct-seeded flooded rice. *Geoderma* 91(3-4): 191-216.
- Cassman, K. G. (1999). Ecological intensification of cereal production systems: yield potencial, soil quality, and precision agriculture. *Proc. Nat. Acad. Sci. USA* 96: 5952-5959.
- Cassman, K. G., A. Dobermann, D. T. Walters y H. Yang (2003). Meeting cereal demand while protecting natural resources and improving environmental quality. *Annual Review of Environment and Resources* 28(1): 315-358.
- Cassman, K. G., P. Grassini y J. van Wart (2010). Crop yield potential, yield trends and global food security in a changing climate. En 'Handbook of climate change and agroecosystems: Impacts, adaptation, and mitigation.'. D. Hillel y D. Rosenzweig. NJ, (World Scientific, Hackensack): 37-51 pp.
- Catching, W. E., K. Hawkins, L. A. Sparrow, B. E. McCorkell y W. Rowley (2002). Crop yield and soil properties on eroded slopes of red ferrosols in north-west Tasmania. *Aust. J. Soil Res.* 40: 625-642.
- Coelli, T., P. Rao, C. J. O'Donnell y G. E. Battese (2005). An introduction to efficiency and productivity analysis. Norwell, Massachusetts, Kluwer Academic Publishers.
- Colwell, J. (1994). Estimating fertilizer requirements. A quantitative approach. UK, CAB International.
- Daniels, R. B., J. W. Gilliam, D. K. Cassel y L. Nelson (1987). Quantifying the effects of past soil erosion on present soil productivity. *J. Soil Water Conserv.* 42: 183-187.
- Dardanelli, J. L., J. T. Ritchie, M. Calmon, J. M. Andriani y D. J. Collino (2004). An empirical model for root water uptake. *Field Crop. Res.* 87(1): 59-71.
- De'Ath, G. y K. E. Frabricsius (2000). Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology* 81(11): 3178-3192.
- De Fina, A. L. (1978). Mapa nacional de distritos agroclimáticos argentinos. Buenos Aires.
- De Paepe, J. L. y R. Alvarez (2012). Estimacion de la capacidad de almacenamiento de agua util de suelos pampeanos con informacion textural. XIX Congreso Latinoamericano de la Ciencia del Suelo. XXII Congreso argentino de la Ciencia del Suelo. Mar del Plata, Argentina.
- DeFries, R. S., J. A. Foley y G. P. Asner (2004). Land-use choices: balancing human needs and ecosystem function. *Front. Ecol. Environ.* 2(5): 249-257.
- De San Celedonio, R. C., J. R. Micheloud, L. G. Abeledo, D. Miralles y G. A. Slafer (2014). Riesgo de anegamiento en trigo (*Triticum aestivum* L.) para distintas localidades de la región triguera argentina. *Ciencia del Suelo* 32(2): 233-246.
- Díaz-Zorita, M., G. A. Duarte y J. H. Grove (2002). A review of no-till systems and soil management for sustainable crop production in the subhumid and semiarid Pampas of Argentina. *Soil Till. Res.* 65(1): 1-18.
- Díaz, R. A. (1996). Calibration and validation of model EPIC for the Pampean region of Argentina. Proyecto "Hydrological determinants of agriculture in South America: remote sensing and numerical simulation": 78-82.
- Díaz, R. a., G. O. Magrin, M. I. Travasso y R. O. Rodríguez (1997). Climate change and its impact on the properties of agricultural soils in the Argentinean Rolling Pampas. *Clim. Res.* 9: 25-30.

- Díaz-Zorita, M., D. E. Buschiazzi y N. Pienemann (1999). Soil organic matter and wheat productivity in the Semiarid Argentine Pampas. *Agron. J.* 91: 276-279.
- Digby, P. y R. Kempton (1994). Multivariate analysis of ecological communities. London, UK.
- Donatelli, M., G. Bellocchi y F. Fontana (2003). RadEst3.00: software to estimate daily radiation data from commonly available meteorological variables. *Eur. J. of Agr.* 18(3-4): 363-367.
- Doorenbos, J. y W. Pruitt (1977). Crop water requirements. Irrigation and drainage paper. Rome, Italy, FAO.
- Doran, J. W. (2002). Soil health and global sustainability: Translating science into practice. *Agr. Ecosyst. Environ.* 88(119-127).
- Duan, X.-w., Y. Xie, Y.-j. Feng y S.-q. Yin (2009). Study on the Method of Soil Productivity Assessment in Black Soil Region of Northeast China. *Agr. Sci. China* 8(4): 472-481.
- Dumanski, J. y C. Pieri (2000). Land quality indicators: research plan. *Agr. Ecosyst. Environ.* 81(2): 93-102.
- Easterling, W. E., A. Weiss, C. J. Hays y L. O. Mearns (1998). Spatial scales of climate information for simulating wheat and maize productivity: the case of the US Great Plains. *Agr. Forest Meteorol.* 90(1-2): 51-63.
- Epstein, H. E., W. K. Laurenroth y I. C. Burke (1997). Effects of temperature and soil texture on ANPP in the US Great Plains. *Ecology* 8: 2628-2631.
- Evans, L. T. (1998). Feeding the ten billion. Plants and population growth. Cambridge, UK, 247 pp, Cambridge University Press.
- FAOstat (2014). www.faostat.com.
- Fermont, A. M., P. J. A. van Asten, P. Tittonell, M. T. van Wijk y K. E. Giller (2009). Closing the cassava yield gap: An analysis from smallholder farms in East Africa. *Field Crop. Res.* 112(1): 24-36.
- Fila, G., G. Bellocchi, M. Acutis y M. Donatelli (2003). IRENE: a software to evaluate model performance. *Eur. J. Agron.* 18(3-4): 369-372.
- Fischer, R. A. (1985). Number of kernels in wheat crops and the influence of solar radiation and temperature. *The Journal of Agricultural Science* 105(02): 447-461.
- Fischer, R. A., D. Byerlee y G. O. Edmeader (2009). Can technology deliver on the yield challenge to 2050? FAO Expert Meeting on How to Feed the World in 2050, Rome, FAO.
- Foley, J. A., R. DeFries, G. P. Asner, C. Barford, G. Bonan, S. R. Carpenter, F. S. Chapin, M. T. Coe, G. C. Daily, H. K. Gibbs, J. H. Helkowski, T. Holloway, E. A. Howard, C. J. Kucharik, C. Monfreda, J. A. Patz, I. C. Prentice, N. Ramankutty y P. K. Snyder (2005). *Global Cons. Land Use. Science* 309(5734): 570-574.
- Franzluebbers, A. J. (2002). Water infiltration and soil structure related to organic matter and its stratification with depth. *Soil Till. Res.* 66: 197-205.
- Gale, M. R., D. F. Grigal y R. B. Harding (1991). Soil Productivity Index: Predictions of Site Quality for White Spruce Plantations. *Soil Sci. Soc. Am. J.* 55(6): 1701-1708.
- García-Paredes, J. D., K. R. Olson y J. M. Lang (2000). Predicting corn and soybean productivity for Illinois soils. *Agr. Syst.* 64: 151-170.
- Gee, G. W. y J. W. Bauder (1996). Particle-size analysis. En 'Methods of soil analysis. Part 3: Physical and mineralogical methods'. Madison, Wisconsin, USA, (Soil Sci. Soc. Am.): 383-412.
- GeoINTA (2014). "www.geointa.inta.gov.ar."
- Gerber, J., N. Mueller y J. Foley (2010). Empirical estimation of global yield gaps. XC European Society of Agronomy Congress, Montpellier, Francia.

- Ghersa, C. M., D. O. Ferraro, M. Omacini, M. A. Martínez-Ghersa, S. Perelman, E. H. Satorre y A. Soriano (2002). Farm and landscape level variables as indicators of sustainable land-use in the Argentine Inland-Pampa. *Agr. Ecosyst. Environ.* 93(1-3): 279-293.
- Górski, T. y K. Górski (2003). The effects of scale on crop yield variability. *Agr. Syst.* 78(3): 425-434.
- Grassini, P., A. J. Hall y J. L. Mercau (2009). Benchmarking sunflower water productivity in semiarid environments. *Field Crop. Res.* 110(3): 251-262.
- Grassini, P., J. Thorburn, C. Burr y K. G. Cassman (2011). High-yield irrigated maize in the Western U.S. Corn Belt: I. On-farm yield, yield potential, and impact of agronomic practices. *Field Crop. Res.* 120(1): 142-150.
- Grassini, P., H. Yang y K. G. Cassman (2009). Limits to maize productivity in the Western Corn-Belt: a simulation analysis for fully irrigated and rainfed conditions. *Agr. Forest Meteorol.* 149(8): 1254-1265.
- Grassini, P., H. Yang, S. Irmak, J. Thorburn, C. Burr y K. G. Cassman (2011). High-yield irrigated maize in the Western U.S. Corn Belt: II. Irrigation management and crop water productivity. *Field Crop. Res.* 120(1): 133-141.
- Gvozdenovich, J., P. Barbagelata, H. Tasi y O. Papparotti (2012). Validación del índice de productividad específico para trigo como predictor del rendimiento. XIX Congreso Latinoamericano de Ciencias del Suelo. XXIII Congreso Argentino de la Ciencia del Suelo. Mar del Plata, Argentina, AACs: 1-4.
- Hafner, S. (2003). Trends in maize, rice, and wheat yields for 188 nations over the past 40 years: a prevalence of linear growth. *Agr. Ecosyst. Environ.* 97(1-3): 275-283.
- Hall, A. J., C. Feoli, J. Ingaramo y M. Balzarini (2013). Gaps between farmer and attainable yields across rainfed sunflower growing regions of Argentina. *Field Crop. Res.* 1: 119-129.
- Hall, A. J., C. Rebella, C. Guersa y J. Culot (1992). Field-crop system of the Pampas. In: Pearson CJ, editor. Field crop ecosystems. Amsterdam, Elsevier.
- Hall, A. J. y R. A. Richards (2013). Prognosis for genetic improvement of yield potential and water-limited yield of major grain crops. *Field Crop. Res.* 143(1): 18-33.
- Hargreaves, G. H. y Z. A. Samani (1985). Reference crop evaporation from temperature. *App. Eng. Agr.* 1: 96-99.
- Hassink, J. (1997). The capacity of soils to preserve organic C and N by their association with clay and silt particles. *Plant Soil* 191: 77-87.
- Headey, D., M. Alauddin y D. S. P. Rao (2010). Explaining agricultural productivity growth: an international perspective. *Agr. Econom.* 41(1): 1-14.
- Hochman, Z., P. S. Carberry, M. J. Robertson, D. S. Gaydon, L. W. Bell y P. C. McIntosh (2013). Prospects for ecological intensification of Australian agriculture. *Eur. J. Agr.* 44(0): 109-123.
- Hochman, Z., D. Gobbett, D. Holzworth, T. McClelland, H. van Rees, O. Marinoni, J. N. Garcia y H. Horan (2013). Reprint of "Quantifying yield gaps in rainfed cropping systems: A case study of wheat in Australia". *Field Crop. Res.* 143(0): 65-75.
- Horn, F. W. (1971). The prediction of amounts and depth distribution of water in a well-drained soil, M. S. Thesis University of Missouri-Columbia. M. S. Thesis.
- Huddleston, J. H. (1984). Development and use of soil productivity ratings in the United States. *Geoderma* 32(4): 297-317.
- Hunt, L. A., L. Kuchar y C. J. Swanton (1998). Estimation of solar radiation for use in crop modelling. *Agr. Forest Meteorol.* 91(3-4): 293-300.

- INASE (2014). "www.inase.gov.ar."
- INTA-CIRN (1981). Departamento de Suelos, Carta de Suelos del Delta Entrerriano, Aptitud forestal de los suelos. INTA 172.
- INTA (2008). "Ensayos comparativos de rendimiento de trigo en la EEA INTA Anguil, campaña 2008."
- INTA (1980). Inventario integrado de los recursos naturales de la Provincia de La Pampa. Buenos Aires, Argentina, Instituto Nacional de Tecnología Agropecuaria.
- INTA (1981). Mapa de suelos de la Provincia de Santa Fe, Parte I. Buenos Aires, Argentina, Instituto Nacional de Tecnología Agropecuaria.
- INTA (1984). Plan Mapa de suelos de la Provincia de Entre Ríos. Convenio INTA-Gobierno de Entre Ríos. Suelos y erosión de la provincia de Entre Ríos. Paraná, Entre Ríos, INTA-EEA.
- INTA (1989a). Mapa de suelos de la Provincia de Buenos Aires. Buenos Aires, Argentina, Instituto Nacional de Tecnología Agropecuaria.
- INTA (1989b). Mapa de suelos de la Provincia de Santa Fe, Parte II. Buenos Aires, Argentina, Instituto Nacional de Tecnología Agropecuaria.
- INTA (2003). Recursos naturales de la Provincia de Córdoba.
- Iqbal, J., J. Read, A. Thomasson y J. Jenkins (2005). Relationships between soil-landscape and dryland cotton lint yield. *Soil Sci. Soc. Am. J* 69: 872-882.
- Jame, Y. W. y H. W. Cutforth (1996). Crop growth models for decision support systems. *Can. J. Plant Sci.* 76(1): 9-19.
- Janzen, H. H., C. A. Campbell, E. G. Gergorich y B. H. Ellert (1998). Soil carbon dynamics in Canadian agroecosystems. En 'Soil processes and carbon cycles'. R. L. e. al. Boca Raton, FL, (CRC Press).
- Jiang, P. y K. D. Thelen (2004). Effect of soil and topographic properties on crop yield in a North-Central corn-soybean cropping system. *Agron. J.* 96(1): 252-258.
- Jobbagy, E. G. y R. B. Jackson (2000). The vertical distribution of soil organic matter and its relation to climate and vegetation. *Ecolog. App.* 10: 423-436.
- Jones, J. W., G. Hoogenboom, C. H. Porter, K. J. Boote, W. D. Batchelor, L. A. Hunt, P. W. Wilkens, U. Singh, A. J. Gijsman y J. T. Ritchie (2003). The DSSAT cropping system model. *Eur. J. Agr.* 18(3-4): 235-265.
- Jorgensen, S. y G. Bendoricchio (2001). Fundamentals of Ecological modelling. Third edition. Oxford, UK.
- Kaul, M., R. L. Hill y C. Walthall (2005). Artificial neural networks for corn and soybean yield prediction. *Agr. Syst.* 85(1): 1-18.
- Kern, J. S. (1995). Geographic patterns of soil water-holding capacity in the contiguous United States. *Soil Sci. Soc. Am. J.* 59(4): 1126-1133.
- Keys, E. y W. J. McConnell (2005). Global change and the intensification of agriculture in the tropics. *Global Environ. Change* 15(4): 320-337.
- Kim, K., B. L. Barham y I. Coxhead (2000). Recovering soil productivity attributes from experimental data: a statistical method and an application to soil productivity dynamics. *Geoderma* 96(3): 239-259.
- Kiniry, L., C. Scrivener y M. Keener (1983). A soil productivity index based upon predicting water depletion on root growth. *Missouri Agri. Exp. Stn. Res. Bull.* 1051.
- Kleinbaum, D. G. y L. L. Kupper (1979). Applied regression analysis and other multivariable methods. North Scituate, MA., Duxbury Press.
- Kobayashi, K. y M. U. Salam (2000). Comparing simulated and measured values using mean

- squared deviation and its components. *Agron. J.* 92(2): 345-352.
- Kropff, M. J., K. G. Cassman, H. H. Van Laar y S. Peng (1993). Nitrogen and yield potential of irrigated rice. *Plant Soil* 155-156(1): 391-394.
- Laborte, A. G., K. de Bie, E. M. A. Smaling, P. F. Moya, A. A. Boling y M. K. Van Ittersum (2012). Rice yields and yield gaps in Southeast Asia: Past trends and future outlook. *Eur. J. Agr.* 36(1): 9-20.
- Laird, R. y F. Cady (1969). Combined analysis of yield data from fertilizer experiments. *Agron. J.* 61: 829-834.
- Lavado, R. y H. Steinbach (2012). Capítulo 1. La fertilidad del suelo, sus características y la utilización de fertilizantes. En 'Fertilidad de suelos. Caracterización y manejo en la Región Pampeana'. R. Álvarez, G. Rubio, C. R. Álvarez y R. Lavado. Buenos Aires, (Editorial Facultad de Agronomía. Universidad de Buenos Aires). Segunda Edición.
- Lawes, R. A., Y. M. Oliver y M. J. Robertson (2009). Integrating the effects of climate and plant available soil water holding capacity on wheat yield. *Field Crop. Res.* 113(3): 297-305.
- Lawlor, D. y R. Mitchell (2000). Crop ecosystem responses to Climatic Change: Wheat. En 'Climate change and global crop productivity'. K. Reddy y H. Hodges. London, UK, (CABI Publishing).
- LeDuc, S. K. y D. A. Holt (1987). The scale problem: modeling plant yield over time and space. En 'Plan growth modeling for resource management. Volume 1. Current models and methods'. C. Press. Boca Ratón, FL. (USA): 125-137.
- Lee, J. H. W., Y. Huang, M. Dickman y A. W. Jayawardena (2003). Neural network modelling of coastal algal blooms. *Ecol. Model.* 159(2-3): 179-201.
- Leeper, R. A., E. C. A. Runge y H. M. Walker (1974). Effect of plant available stored soil moisture on corn yield: II variable climatic conditions. *Agron. J.* 66: 728-733.
- Licker, R., M. Johnston, J. A. Foley, C. Barford, C. J. Kucharik, C. Monfreda y N. Ramankutty (2010). Mind the gap: how do climate and agricultural management explain the 'yield gap' of croplands around the world? *Global Ecology Biogeogr.* 19(6): 769-782.
- Linacre, E. (1977). A simple formula for estimating evapotranspiration rates in various climates, using temperature data alones. *Agr. Meteorol* 18: 409-424.
- Lindstrom, M. J., T. E. Schumacher, T. E. Jones y C. J. Gantzer (1992). Productivity index model comparison for selected north central region soils. *J. Soil Water Conserv.* 47: 491-494.
- Liu, J., J. R. Williams, A. J. B. Zehnder y H. Yang (2007). GEPIC- modelling wheat yield and crop water productivity with high resolution on a global scale. *Agr. Syst.* 94: 478-493.
- Lobell, D. B., K. G. Cassman y C. B. Field (2009). Crop Yield Gaps: Their Importance, Magnitudes, and Causes. *Ann. Rev. Env. Res.* 34(1): 179-204.
- Lobell, D. B. y C. Field (2007). Global scale climate-crop yield relationships and the impacts of recent warming. *Env. Res. Lett.* 2: 1-7.
- Lobell, D. B., I. J. Ortiz-Monasterio, L. C. Addams y G. Asner (2002). Soil, climate, and management impacts on regional wheat productivity in Mexico from remote sensing. *Agr. Forest Meteorol.* 114: 31-43.
- Lobell, D. B., I. J. Ortiz-Monasterio, G. P. Asner, R. L. Naylor y W. P. Falcon (2005). Combining field Surveys, remote sensing, and regression rees to understand yield variations in an irrigated wheat landscape. *Agron. J.* 97: 241-249.
- Lobell, D. B., J. I. Ortiz-Monasterio, G. P. Asner, P. A. Matson, R. L. Naylor y W. P. Falcon (2005). Analysis of wheat yield and climatic trends in Mexico. *Field Crop. Res.* 94(2-3): 250-256.

- Lobell, D. B., J. I. Ortiz-Monasterio y W. P. Falcon (2007). Yield uncertainty at the field scale evaluated with multi-year satellite data. *Agr. Syst.* 92(1-3): 76-90.
- Long, S. P., E. A. Ainsworth, A. D. B. Leakey, J. Nösberger y D. R. Ort (2006). Food for Thought: Lower-Than-Expected Crop Yield Stimulation with Rising CO₂ Concentrations. *Science* 312(5782): 1918-1921.
- Loveland, P. y J. Webb (2003). Is there a critical level of organic matter in the agricultural soils of temperate regions: a review. *Soil Till. Res.* 70(1): 1-18.
- Magrin, G., A. J. Hall, G. Baldi y M. Grondona (1993). Spatial and interannual variations in the photothermal quotient: implications for the potential kernel number of wheat crops in Argentina. *Agr. Forest Meteorol.* 67: 29-41.
- Magrin, G. y M. Travasso (1997). Potencial de producción de cultivo de trigo (*Triticum aestivum* L.) en la Región Pampeana argentina. Reunión de Planificación Estratégica de Trigo INTA-CIMMYT. Mar del Plata.
- Magrin, G., M. Travasso y G. R. Rodriguez (2005). Changes in climate and crop production during the 20th century in Argentina. *Climatic. Change* 72: 229-249.
- Magrin, G. O. (1994). Los modelos de simulación agronómica. *Revista CREA* 167(32-36).
- Magrin, G. O. (2004). Rendimientos potenciales de trigo en las distintas zonas trigueras. *Sistema de Información Clima y Agua - INTA*: 1-7.
- Martín, N., G. Bollero, N. Kitchen, A. Kravchenko, K. Sudduth, W. Wiebold y D. Bullock (2006). Two classification methods for developing and interpreting productivity zones using site properties. *Plant Soil* 288: 357-371.
- McKenzie, N. J. y P. J. Ryan (1999). Spatial prediction of soil properties using environmental correlation. *Geoderma* 89(1-2): 67-94.
- Mearns, L. O., T. Mavromatis, E. Tsvetsinskaya, C. Hays y W. Easterling (1999). Comparative responses of EPIC and CERES crop models to high and low spatial resolution climate change scenarios. *J. Geophys. Res.: Atmospheres* 104(D6): 6623-6646.
- Meeusen, W. y J. v. D. Broeck (1977). Efficiency estimation from Cobb-Douglas production functions with composed error. *Int. Econom. Rev.* 18: 435-444.
- Menéndez, F. J. y E. H. Satorre (2007). Evaluating wheat potential determination in the Argentine Pampas. *Agr. Syst.* 95: 1-10.
- Miao, Y., D. Mulla y P. Robert (2006). Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precis. Agr.* 7(2): 117-135.
- MinAgri (2014). www.MinAgri.com.ar.
- Monfreda, C., N. Ramankutty y J. A. Foley (2008). Farming the planet: 2. Geographic distribution of crop areas, yields, physiological types, and net primary production in the year 2000, *Global Biogeochem. Cycles* 22(1): GB1022.
- Monzón, J. P., F. Aramburu Merlos, J. L. Mercau, P. Grassini, F. H. Andrade, M. Taboada, A. J. Hall, K. G. Cassman y E. Jobbagy (2013). Magnitude and variability of maize, wheat and soybean yield gaps in Argentina. Poster presentado en "Water, food, energy and innovation for a sustainable world. ASA, CSSA, y SSSA International Annual Meetings", Tampa - USA.
- Moscatelli, G. (1991). Los suelos de la Región Pampeana. En 'El desarrollo agropecuario pampeano. INDEC-INTA-IICA'. Buenos Aires, Argentina: 1-76 pp.
- Moosavizadeh-Mojarad, R. y A. R. Sepaskhah (2011). Comparison between rice grain yield predictions using artificial neural networks and a very simple model under different levels of water and nitrogen application. *Arch. Agr. Soil Sci.* 58(11): 1271-1282.

- Moulin, A. P. y H. J. Beckie (1993). Evaluation of the CERES and EPIC models for predicting spring wheat grain yield over time. *Canadian J. Plant Sci.* 73(3): 713-719.
- Mueller, L., U. Schindler, W. Mirschel, T. Graham Shepherd, B. C. Ball, K. Helming, J. Rogasik, F. Eulenstein y H. Wiggering (2010). Assessing the productivity function of soils. A review. *Agr. Sustain. Dev.* 30(3): 601-614.
- Neill, L. (1979). An evaluation of soil productivity based on root growth and water depletion. M.S. Tesis, Univ. Mo., Columbia.
- Nelson, L. y L. Sommers (1996). Total carbon, organic carbon, and organic matter. En 'Methods of Soil Analysis'. S. S. S. Am. Madison, Wisconsin, USA. Part 3 - Chemical Methods: 961-1010,
- Nelson, L., R. Voss y J. Pesek (1985). Agronomic and statistical evaluation of fertilizer response. En 'Fertilizer technology and use'. O. Englestad. Madison, WI, USA, (Soil Science Society of America): 53-90,
- Neter, J., W. Wasserman y M. Kutner (1990). Applied linear statistical models. Illinois, USA, Ed. Irwin.
- Neumann, K., P. H. Verburg, E. Stehfest y C. Müller (2010). The yield gap of global grain production: a spatial analysis. *Agr. Syst.* 103: 316-326.
- Novelli, L. E., O. P. Caviglia y R. J. M. Melchiori (2011). Impact of soybean cropping frequency on soil carbon storage in Mollisols and Vertisols. *Geoderma* 167–168(0): 254-260.
- Olesen, J. E., P. K. Bøcher y T. Jensen (2000). Comparison of scales of climate and soil data for aggregating simulated yields of winter wheat in Denmark. *Agr., Ecosyst. Environ.* 82(1-3): 213-228.
- Novelli, L. E., O. P. Caviglia, M. G. Wilson y M. C. Sasal (2013). Land use intensity and cropping sequence effects on aggregate stability and C storage in a Vertisol and a Mollisol. *Geoderma* 195–196(0): 260-267.
- Olson, B., H. Janzen, F. Larney y L. Selinger (1996). A proposed method for measuring the effect of soil quality on productivity. *Agron. J.* 88: 497-500.
- Onken, A. B., R. L. Matheson y D. M. Nesmith (1985). Fertilizer nitrogen and residual nitrate-nitrogen effects on irrigated corn yield. *Soil Sci. Soc. Am. J.* 49: 134-139.
- Panigatti, J. L., H. Marelli, D. E. Buschiazzo y R. Gil (1998). Siembra Directa. Editorial Hemisferio Sur S.A. Buenos Aires, Argentina.
- Park, S. J., C. S. Hwang y P. L. G. Vlek (2005). Comparison of adaptive techniques to predict crop yield response under varying soil and land management conditions. *Agr. Syst.* 85(1): 59-81.
- Paruelo, J., J. P. Guerschman, G. Baldi y C. Di Bella (2004). La estimacion de la superficie agricola. Antecedentes y una propuesta metodologica. *Interciencia* 29: 421-427.
- Paruelo, J. M., J. P. Guerschman, G. Piñeiro, E. G. Jobbagy, S. R. Verón, G. Baldi y S. Baeza (2006). Cambios en el uso de la tierra en la Argentina y Uruguay: Marcos conceptuales para su análisis. *Agrociencia X*: 47-61.
- Passioura, J. (2006). Increasing crop productivity when water is scarce—from breeding to field management. *Agr. Water Manage.* 80(1-3): 176-196.
- Paustian, K., O. Andrén, H. Janzen, R. Lal, P. Smith, G. Tian, H. Tiessen, M. Van Noordwijk y P. Woomer (1997). Agricultural soils as a sink to mitigate CO₂ emissions. *Soil Use Manage.* 13: 230-244.
- Peltier, M. R., C. J. Wilcox y D. C. Sharp (1998). Technical note: Application of the Box-Cox data transformation to animal science experiments. *J. Anim. Sci.* 76(3): 847-849.

- Perelman, S. B., R. J. C. León y M. Oesterheld (2001). Cross-scale vegetation patterns of Flooding Pampa grasslands. *J. Ecol.* 89(4): 562-577.
- Pesaran, M. H. y P. Schmidt (1999). *Handbook of applied econometrics*, Blackwell Publishers.
- Pierce, F., W. Larson, R. Dowdy y W. Graham (1983). Productivity of soils: Assessing long-term changes due to erosion. *J. Soil Water Conserv.* 38: 39-44.
- Potgieter, A. B., G. L. Hammer, A. Doherty y P. de Voil (2005). A simple regional-scale model for forecasting sorghum yield across North-Eastern Australia. *Agr. Forest Meteorol.* 132(1-2): 143-153.
- Priya, S. y R. Shibasaki (2001). National spatial crop yield simulation using GIS-based crop production model. *Ecol. Modelling* 136(2-3): 113-129.
- Quiroga, A. R., D. E. Buschiazzo y N. Peinemann (1996). Soil Organic Matter Particle Size Fractions in Soils of the Semiarid Argentinian Pampas. *Soil Sci.* 161(2): 104-108.
- Quiroga, A. R.; D. E. Buschiazzo; N. Peinemann. 1996. Propiedades físicas de suelos de la región semiárida pampeana. Influencia de la textura, contenidos de materia orgánica y el manejo. Actas del XV Congreso Argentino de la Ciencia del Suelo, Santa Rosa.
- Quiroga, A. R., D. O. Funaro, R. Fernández y E. Noellemeyer (2005). Factores edáficos y de manejo que condicionan la eficiencia del barbecho en la Región Pampeana. *Ciencia del Suelo* 23(1): 79-86.
- Quiroga, A., Ormeño, O y Peinemann N. 1998 a. Efectos de la siembra directa sobre propiedades físicas de los suelos. En "Siembra directa". J.L. Panigatti, H. Marelli y D. Buschiazzo (Eds.) Editorial Hemisferio Sur S.A.
- Quiroga, A., Ormeño, O y Otamendi H. 1998 b. La siembra directa y el rendimiento de los cultivos en la Región Semiárida Central. En "Siembra directa". J.L. Panigatti, H. Marelli y D. Buschiazzo (Eds.) Editorial Hemisferio Sur S.A.
- Rawls, W. (1983). Estimating soil bulk density from particle size analysis and organic matter content. *Soil Sci.* 135: 123-125.
- Rawls, W., D. Brakensiek y K. Saxton (1982). Estimation of soil water properties. *Trans. ASAE* 25: 1316-1332.
- Rawls, W. J., Y. A. Pachepsky, J. C. Ritchie, T. M. Sobecki y H. Bloodworth (2003). Effect of soil organic carbon on soil water retention. *Geoderma* 116(1-2): 61-76.
- Ray, D. K., N. Ramankutty, N. D. Mueller, P. C. West y J. A. Foley (2012). Recent patterns of crop yield growth and stagnation. *Nat Commun* 3: 1293.
- Reidsma, P., F. Ewert y A. Oude Lansink (2007). Analysis of farm performance in Europe under different climatic and management conditions to improve understanding of adaptive capacity. *Clim. Change* 84(3-4): 403-422.
- RIAN (2014). Red de Información Agropecuaria Nacional. www.rian.gov.ar.
- Richter, M., G. Massen y I. Mizurno (1973). Total organic carbon and oxidable organic carbon by the Walkley-Black procedure in some soils of the Argentine Pampa. *Agrochem.* 17: 462-473.
- Rijsberman, F. R. y M. G. Wolman (1985). Effect of erosion on soil productivity: An international comparison. *J. Soil Water Conserv.* 40(4): 349-354.
- Riquier, J., D. L. Bramao y J. P. Cornet (1970). A new system of soil appraisal in terms of actual and potential productivity (first approximation). En 'Food and Agriculture Organization of the United Nations. Soil Resources, Development and Conservation Service, Land and Water Development Division'. Rome, (FAO): 38 pp.
- Ritchie, J. T. y S. Otter (1985). Description and performance of CERES-Wheat: a user-orientes

- wheat yield model. USDA-ARS. 38: 159-175.
- Rogers, L. L. y F. U. Dowla (1994). Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. *Water Resour. Res.* 30(2): 457-481.
- Romano, N. F. (2010). Ensayos comparativos de rendimiento de trigo pan en la Región Semiárida Pampeana "Campaña 2010". .pp 1-10. http://inta.gov.ar/documentos/ensayos-comparativos-de-rendimiento-de-trigo-pan-en-la-region-semiarida-pampeana/at_multi_download/file/Informe.pdf
- Romano, N. F., R. Alvarez, A. A. Bono y H. S. Steinbach (2015). Comparison of nitrogen fertilizer demand for wheat production between humid and semi-arid portions of the Argentinean Pampas using a mass balance method. *Arch. Agr. Soil Sci.*: 1-14.
- Rosegrant, M. W. y S. A. Cline (2003). Global Food Security: Challenges and Policies. *Science* 302 (5652): 1917-1919.
- Ruttan, V. W. (2002). Productivity Growth in World Agriculture: Sources and Constraints. *J. Econom. Perspect.* 16(4): 161-184.
- Sadras, V. y J. Angus (2006). Benchmarking water-use efficiency of rainfed wheat in dry environments. *Australian J. Agr. Res.* 57: 847-856.
- Sadras, V. O. y P. A. Calviño (2001). Quantification of Grain Yield Response to Soil Depth in Soybean, Maize, Sunflower, and Wheat. *Agron. J.* 93(3): 577-583.
- Sadras, V. O., P. Grassini, R. Costa, L. Cohan y A. J. Hall (2014). How reliable are crop production data? Case studies in USA and Argentina. *Food Security* 6(4): 447-459.
- Sarkar, P. K., O. W. Bidwell y L. F. Marcus (1966). Selection of characteristics for numerical classification of soils. *Soil Sci. Soc. Am. J.* 30(2): 269-272.
- Satorre, E., R. Ruíz, D. Miralles, D. F. Calderini y G. Madonni (2001). Bases de decisión para la fertilización nitrogenada de las Zonas Norte de Buenos Aires, Sur de Santa Fe y Centro de AACREA. *CREA Cuaderno de actualización técnica.* 63: 30-38.
- Satorre, E. y G. Slafer (1999). Wheat production systems of the Pampas. En 'Wheat. Ecology and physiology of yield determination.'. E. T. H. Press. New York: 333-348.
- Sauerborn, J. (2002). Site productivity, the Key to crop productivity. *J. Agr. Crop Sci.* 188: 363-367.
- Savin, R., S. EH, A. J. Hall y S. GA (1995). Assessing strategies for wheat cropping in the monsoonal climate of the Pampas using the CERES-Wheat simulation model *Field Crops Research* 42: 81-91.
- Saviozzi, A., R. Levi-Minzi, R. Carelli y R. Riffaldi (2001). A comparison of soil quality in adjacent cultivated, forest and native grassland soils. *Plant Soil* 233: 251-259.
- Schaap, M. G. y W. Bouten (1996). Modeling water retention curves of sandy soils using neural networks. *Water Resour. Res.* 32(10): 3033-3040.
- Schnug, E., J. Heym y F. Achwan (1996). Establishing critical values for soil and plant analysis by means of the Boundary Line Development System (Bolides). *Commun. Soil Sci. Plant. Anal.* 27(13 & 14): 2738-2748.
- Schumacher, T. E., M. J. Lindstrom, J. A. Schumacher y G. D. Lemme (1999). Modeling spatial variation in productivity due to tillage and water erosion. *Soil Till. Res.* 51(3-4): 331-339.
- Semenov, M. A., J. Woli, L. G. Evans, H. Eckersten y A. Iglesias (1996). Comparison of wheat simulation models under climate change. II Application of climate change scenarios. *Clim. Res.* 7: 271-281.
- Shaxson, T. S. (2006). Re-thinking the conservation of carbon, water and soil: a different

- perspective. *Agron. Sustain. Dev.* 26: 9-19.
- Sileshi, G., F. K. Akinnifesi, L. K. Debusho, T. Beedy, O. C. Ajayi y S. Mong'omba (2010). Variation in maize yield gaps with plant nutrient inputs, soil type and climate across sub-Saharan Africa. *Field Crop. Res.* 116(1-2): 1-13.
- Sinclair, T. R. y N. a. G. Seligman (1996). Crop modeling: From infancy to maturity. *Agron. J.* 88(5): 698-704.
- Six, J., E. T. Elliott y K. Paustian (1999). Aggregate and soil organic matter dynamics under conventional and no-tillage systems. *Soil Sci. Soc. Am. J.* 63: 1350-1358.
- Slafer, G. A. y F. H. Andrade (1989). Genetic improvement in bread wheat (*Triticum aestivum*) yield in Argentina. *Field Crop. Res.* 21(3-4): 289-296.
- Sobral, R. y V. Nakama (1988). Indices de productividad, metodo parametrico para evaluacion de tierras. Congreso Argentino de la Ciencia del Suelo XII, Buenos Aires, Argentina.
- Somaratne, S., G. Seneviratne y U. Coomaraswamy (2005). Prediction of soil organic carbon across different land-use patterns: a neural network approach. *Soil Sci. Soc. Am. J.* 69: 1580-1589.
- Soriano, A. (1991). Río de La Plata grasslands. En 'Ecosystems of the world. 8A. Natural Grasslands.'. R. Coupland. Amsterdam, The Netherlands, (Elsevier): 367-407 pp.
- Staben, M., D. Bezdicsek, J. Smith y M. Fauci (1997). Assessment of soil quality in conservation reserve program and wheat-fallow soils. *Soil Sci. Soc. Am. J.* 25: 1580-1589.
- Steinberg, D. y D. Colla (1995). CART: Tree-structured non-parametric data analysis. San Diego, CA, USA.
- Steiner, J. L., J. R. Williams y O. R. Jones (1987). Evaluation of the EPIC Simulation Model Using a Dryland Wheat-Sorghum-Fallow Crop Rotation1. *Agron. J.* 79(4): 732-738.
- Stone, P. y M. Nicolas (1995). A survey of the effects of high temperature during grain filling on yield quality of 75 wheat cultivars. *Aust. J. Agric. Res.* 46: 475-492.
- Szulczewski, W., A. Żyromski y M. Biniak-Pieróg (2012). New approach in modeling spring wheat yielding based on dry periods. *Agr. Water Manage.* 103(0): 105-113.
- Tasi, H., P. Barbagelata, G. Schulz y A. Paz González (2010). Indices de productividad específico para maíz como potencial predictor del rendimiento y su variabilidad. XXII Congreso Argentino de la Ciencia del Suelo. Rosario, Argentina., AACs: 1-4 pp.
- Tisdall, J. M., W. L. Nelson y J. D. Beaton (1986). Soil fertility and fertilizers. New York, Macmillan Publ. Co.
- Tombetta, E. y J. Nisi. 2000. 100 años del trigo argentino. Ing. Tombetta e Ing. Nisi editores.
- Totis, L. y O. Perez (1994). Relaciones entre el consumo de agua máximo de la secuencia de cultivo trigo/soja y la evapotranspiración potencial para el cálculo de la dosis de riego. En 'Carpeta de Producción Vegetal'. INTA-Pergamino. 12: 1-4.
- Travasso, M., G. Magrin y M. Grondona (1999). Relations between climatic variability related to ENSO and maize production in Argentina. Proceedings 10th Symposium on Global Change Studies. T. Dallas, AMS. Boston, MA: 67-68.
- Trostle, R. (2008). Global agricultural supply and demand: factors contributing to the recent increase in food commodity prices, United States Department of Agriculture.
- Udawatta, R. P. y G. S. Henderson (2003). Root distribution relationships to soil properties in Missouri oak stands: A productivity index approach. *Soil Sci. Soc. Am. J.* 67(6): 1869-1878.
- van Ittersum, M. K., K. G. Cassman, P. Grassini, J. Wolf, P. Tittonell y Z. Hochman (2013). Yield gap analysis with local to global relevance—A review. *Field Crop. Res.* 143(0): 4-17.

- Van Ittersum, M. K., P. A. Leffelaar, H. van Keulen, M. J. Kropff, L. Bastiaans y J. Goudriaan (2003). On approaches and applications of the Wageningen crop models. *Europ. J. Agron.* 18: 201-234.
- Van Ittersum, M. K. y R. Rabbinge (1997). Concepts in production ecology for analysis and quantification of agricultural input-output combinations. *Field Crop. Res.* 52(3): 197-208.
- van Rees, H., T. McClelland, Z. Hochman, P. Carberry, J. Hunt, N. Huth y D. Holzworth (2014). Leading farmers in South East Australia have closed the exploitable wheat yield gap: Prospects for further improvement. *Field Crop. Res.* 64(0): 1-11.
- Van Wambeke, A. y C. O. Scoppa (1976). Las taxas climáticas de los suelos argentinos. Determinación de las definiciones de Soil Taxonomy mediante el modelo matemático de Newhall y su resolución por computación de Fortran IV. *RIA:* 7-39.
- Vázquez, M., L. Berasategui, E. Chamorro, L. Taquini y L. Barberis (1990). Evolución de la estabilidad estructural y diferentes propiedades químicas según el uso de los suelos en tres áreas de la Pradera Pampeana. *Ciencia del Suelo* 8: 203-210.
- Verburg, P. H., Y. Chen y T. Veldkamp (2000). Spatial explorations of land use change and grain production in China. *Agr. Ecosyst. Environ.* 82(1-3): 333-354.
- Verón, S. R., J. M. Paruelo, O. E. Sala y W. K. Laurenroth (2002). Environmental Controls of Primary Production in Agricultural Systems of the Argentine Pampas. *Ecosystems* 5: 625-635.
- Verón, S. R., J. M. Paruelo y G. A. Slafer (2004). Interannual variability of wheat yield in the Argentine Pampas during the 20th century. *Agr., Ecosyst. Environ.* 103: 177-190.
- Viglizzo, E. F., F. Lértora, A. J. Pordomingo, J. N. Bernardos, Z. E. Roberto y H. Del Valle (2001). Ecological lessons and applications from one century of low external-input farming in the pampas of Argentina. *Agr., Ecosyst. Env.* 83: 65-81.
- Viglizzo, E. F., A. J. Pordomingo, M. G. Castro, F. A. Lértora y J. N. Bernardos (2004). Scale-dependent controls on ecological functions in agroecosystems of Argentina. *Agr., Ecosyst. Environ.* 101(1): 39-51.
- Viglizzo, E. F., Z. E. Roberto, M. C. Filippin y A. J. Pordomingo (1995). Climate variability and agroecological change in the Pampas of Argentina. *Agr., Ecosyst. Environ.* 55: 7-16.
- Wainwright, J. y M. Mulligan (2004). Environmental modelling. Chichester, Wiley & Sons.
- Walkley, A. y I. A. Black (1934). An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Sci.* 63: 251-563.
- Wassenaar, T., P. Lagacherie, J.-P. Legros y M. D. A. Rounsevell (1999). Modelling wheat yield responses to soil and climate variability at the regional scale. *Clim. Res.* 11: 209-220.
- Watson, R. y A. H. Zakri (2005). MA Conceptual framework. En 'Ecosystems and Human well-being: Scenarios'. Washington DC, (Inland Press.). 2: 22-33.
- Wilson, J. P., S. P. Sandor y G. A. Nielsen (1991). Productivity index model modified to estimate variability of Montana small grain yields. *Soil Sci. Soc. Am. J.* 55(1): 228-234.
- Williams, J. R. (1990). The Erosion-Productivity Impact Calculator (EPIC) Model: A Case History. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences* 329(1255): 421-428.
- Williams, J. R., C. A. Jones y P. T. Dyke (1990). The EPIC Model. En 'EPIC - Eorsion Productivity Impact Calculator. 1. Model documentation'. J. R. Williams, (U.S. Department of Agriculture Technical Bulletin). No. 1768: 3-86.
- Williams, J. R., K. G. Renard y P. T. Dyke (1983). EPIC: A new method for assessing erosion's

- effect on soil productivity. *J. of Soil and Water Conservation* 38(5): 381-383.
- Wong, M. y S. Asseng (2006). Determining the Causes of Spatial and Temporal Variability of Wheat Yields at Sub-field Scale Using a New Method of Upscaling a Crop Model. *Plant Soil* 283(1): 203-215.
- Yang, J., R. Hammer, A. Thompson y R. Planchar (2003). Predicting soybean yield in a dry and wet year using a soil productivity index. *Plant Soil* 270: 175-182.
- Yang, J. M., J. Y. Yang, S. Liu y G. Hoogenboom (2014). An evaluation of the statistical methods for testing the performance of crop models with observed data. *Agr. Syst.* 127(0): 81-89.
- Zimmerman, D., C. Pavlik, A. Ruggles y M. Armstrong (1999). An experimental comparison of ordinary and universal Kriging and inverse distance weighting. *Math. Geol.* 31(4): 375-390.