



Universitat de Lleida

## Evaluación de alternativas para el análisis estadístico y de aspectos del diseño en ensayos de larga duración para estudios agronómicos

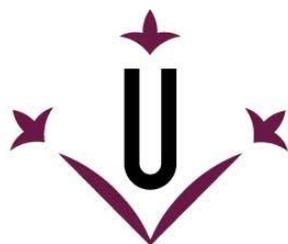
María Gloria Monterubbianesi

<http://hdl.handle.net/10803/457696>

**ADVERTIMENT.** L'accés als continguts d'aquesta tesi doctoral i la seva utilització ha de respectar els drets de la persona autora. Pot ser utilitzada per a consulta o estudi personal, així com en activitats o materials d'investigació i docència en els termes establerts a l'art. 32 del Text Refós de la Llei de Propietat Intel·lectual (RDL 1/1996). Per altres utilitzacions es requereix l'autorització prèvia i expressa de la persona autora. En qualsevol cas, en la utilització dels seus continguts caldrà indicar de forma clara el nom i cognoms de la persona autora i el títol de la tesi doctoral. No s'autoritza la seva reproducció o altres formes d'explotació efectuades amb finalitats de lucre ni la seva comunicació pública des d'un lloc aliè al servei TDX. Tampoc s'autoritza la presentació del seu contingut en una finestra o marc aliè a TDX (framing). Aquesta reserva de drets afecta tant als continguts de la tesi com als seus resums i índexs.

**ADVERTENCIA.** El acceso a los contenidos de esta tesis doctoral y su utilización debe respetar los derechos de la persona autora. Puede ser utilizada para consulta o estudio personal, así como en actividades o materiales de investigación y docencia en los términos establecidos en el art. 32 del Texto Refundido de la Ley de Propiedad Intelectual (RDL 1/1996). Para otros usos se requiere la autorización previa y expresa de la persona autora. En cualquier caso, en la utilización de sus contenidos se deberá indicar de forma clara el nombre y apellidos de la persona autora y el título de la tesis doctoral. No se autoriza su reproducción u otras formas de explotación efectuadas con fines lucrativos ni su comunicación pública desde un sitio ajeno al servicio TDR. Tampoco se autoriza la presentación de su contenido en una ventana o marco ajeno a TDR (framing). Esta reserva de derechos afecta tanto al contenido de la tesis como a sus resúmenes e índices.

**WARNING.** Access to the contents of this doctoral thesis and its use must respect the rights of the author. It can be used for reference or private study, as well as research and learning activities or materials in the terms established by the 32nd article of the Spanish Consolidated Copyright Act (RDL 1/1996). Express and previous authorization of the author is required for any other uses. In any case, when using its content, full name of the author and title of the thesis must be clearly indicated. Reproduction or other forms of for profit use or public communication from outside TDX service is not allowed. Presentation of its content in a window or frame external to TDX (framing) is not authorized either. These rights affect both the content of the thesis and its abstracts and indexes.



**Universitat de Lleida**

**TESIS DOCTORAL**

**EVALUACIÓN DE ALTERNATIVAS PARA EL ANÁLISIS  
ESTADÍSTICO Y DE ASPECTOS DEL DISEÑO EN ENSAYOS DE  
LARGA DURACIÓN PARA ESTUDIOS AGRONÓMICOS**

María Gloria Monterubbianesi

Memoria presentada para optar al grado de Doctor por la Universitat de Lleida  
Programa de Doctorado en Ciencia y Tecnología Agraria y Alimentaria

Directores

Dr. Carlos Cantero Martínez  
Dr. Guillermo Alberto Studdert

Lleida, abril de 2017

## AGRADECIMIENTOS

Quisiera agradecer a quienes de una forma u otra me dedicaron parte de su tiempo y me ayudaron en cada paso del proceso que llevó a la concreción de este trabajo, y muy especialmente:

A Guillermo Studdert por darme la posibilidad de gestar este proyecto y acompañarme desde el inicio del mismo, por contactarme con la Universidad de Lleida, por alentarme continuamente, por facilitarme la información de sus ensayos y datos, y por brindarme sus valiosas sugerencias.

A Carlos Cantero Martínez por aceptarme como su tesista, por brindarme todo su apoyo y aliento, por su trato cordial, por facilitarme la información de sus ensayos y datos, por sus aportes agronómicos y por su gestión en los trámites administrativos y académicos.

A Silvina San Martino por sus valiosas contribuciones en los aspectos estadísticos y sus orientaciones generales. Pero por sobre todo por su compañerismo, apoyo y aliento, y por depositar su confianza en mí y en mi trabajo.

A Marcos, mi esposo, por tanto acompañamiento y comprensión, y a mis hijos, Manuel y Martín. A ellos, mi familia, porque son el pilar para poder enfrentar proyectos como este.

A mis amigos y en especial a María Martha por apoyar y compartir con alegría este proyecto.

A mis compañeros de Estadística y Diseño que aliviaron mis actividades docentes en el último tramo de este trabajo y por su disposición a colaborar en lo que fuera necesario.

A María Coll Huguet de la Sección de Doctorado, UdL, por asistirme y guiarme en todo lo referente a los trámites que debí realizar en la sección de doctorado.

A Ester Zamuner, por contagiarme, tal vez sin saberlo, el “se puede”.

A la Facultad de Ciencias Agrarias de la UNMDP, institución donde trabajo, y a la Universidad de Lleida por facilitarme a través de la Red AGROFORALIA - Programa Pablo Neruda la primera estadía en la Escuela Técnica Superior de Ingeniería Agraria, UdL.

Al personal de la Biblioteca de la Unidad Integrada Balcarce por su asistencia a mis consultas.

## INDICE GENERAL

INDICE DE TABLAS .....	vi
INDICE DE FIGURAS .....	ix
RESUMEN .....	xv
SUMMARY .....	xvii
1.    CAPÍTULO 1. INTRODUCCIÓN .....	1
1.1    Ensayos de larga duración en agricultura: generalidades y relevancia .....	1
1.2    Diseños y análisis de los ELDA: revisión y consideraciones .....	3
1.3    Objetivos .....	9
1.4    Organización del trabajo .....	10
2.    CAPÍTULO 2. DESCRIPCIÓN DE LOS ENSAYOS Y VARIABLES .....	13
2.1    Introducción .....	13
2.2    Ensayos en el Valle del Ebro Oriental, España .....	13
2.2.1    Ensayo de Sistemas de Manejo de Suelos .....	13
2.3    Ensayos en el Sudeste Bonaerense, Argentina .....	16
2.3.1    Ensayo de Agricultura Continua .....	17
2.3.2    Ensayo de Secuencias Agrícolas y Sistemas de Laboreo .....	18
2.3.3    Ensayo de Sistemas de Laboreo .....	19
2.3.4    Ensayo de Rotaciones Mixtas y Sistemas de Laboreo .....	19
2.4    Síntesis de los ELDA descriptos .....	22
3.    CAPÍTULO 3. MODELOS ESTADÍSTICOS .....	23
3.1    Descripción de variables y distribuciones .....	23
3.1.1    Variables respuesta: características .....	23
3.1.2    Distribuciones continuas asimétricas .....	24
3.1.3    ¿Cómo identificar la distribución de una variable? .....	28
3.2    Modelos estadísticos para el análisis: Especificaciones, supuestos, interpretaciones .....	29
3.2.1    Modelo lineal general .....	30
3.2.2    Modelo lineal mixto .....	34
3.2.3    Modelo lineal generalizado y modelo lineal generalizado mixto .....	39
3.2.4    Modelo aditivo generalizado .....	40
3.2.5    Modelo aditivo generalizado para localización, escala y forma .....	42
4.    CAPÍTULO 4. APLICACIONES: ENSAYO DE AGRAMUNT. I .....	45
4.1    El CN: descripción y exploración de los datos .....	45

4.2	El modelo lineal general como herramienta exploratoria.....	52
4.2.1	Primer modelo (modelo 0.1) .....	53
4.2.2	Segundo modelo (modelo 0.2) .....	57
4.3	Modelos de mediciones repetidas para el análisis.....	60
4.3.1	Modelo básico de mediciones repetidas.....	62
4.3.2	Modelo de mediciones repetidas con heterogeneidad de varianzas .....	70
4.3.3	Consideraciones parciales de los modelos ajustados .....	76
4.3.4	Modelo de mediciones repetidas con heterogeneidad de varianzas y correlación entre errores .....	78
4.4	Pruebas de efectos fijos y comparaciones de medias .....	82
4.5	Síntesis del capítulo.....	85
5.	CAPÍTULO 5. APLICACIONES: ENSAYO DE AGRAMUNT. II .....	87
5.1	Modelos GAMLSS y procesos de selección y evaluación.....	87
5.2	Primera etapa .....	90
5.2.1	Ajuste de modelos y selección .....	90
5.2.2	Distribución inversa gaussiana .....	94
5.2.3	Diagnóstico .....	96
5.3	Segunda etapa .....	102
5.3.1	Ajuste de modelos y selección .....	102
5.3.2	Diagnóstico .....	102
5.4	Evaluación de términos en los predictores del modelo seleccionado .....	106
5.5	Síntesis del capítulo.....	108
6.	CAPÍTULO 6. ENSAYOS DE SISTEMAS DE CULTIVO CON ROTACIONES DE CULTIVOS.....	109
6.1	Términos básicos en una rotación.....	110
6.2	ELDA, rotaciones de cultivos y consideraciones de diseño .....	110
6.2.1	Ensayo comparativo de rotaciones de cultivos y fertilización .....	113
6.2.2	Ensayo comparativo de tres rotaciones de cultivos con laboreos contrastantes.....	121
6.2.3	Ensayo comparativo de laboreos y tratamientos adicionales con única rotación de cultivos. ....	124
6.2.4	Ensayo comparativo de rotaciones mixtas de pastura y agricultura con laboreos contrastantes.....	125
6.3	Propuestas de análisis estadístico para las variaciones del COT .....	130
6.3.1	Análisis 1 .....	132
6.3.2	Análisis 2.....	133

6.3.3	Análisis 3 .....	138
6.4	Síntesis del capítulo.....	141
7.	CAPÍTULO 7. IMPLEMENTACIÓN EN R .....	143
7.1	Guía para el análisis de datos provenientes de ELDA .....	143
7.2	Sentencias R utilizadas en el capítulo 4 .....	144
7.2.1	Adecuando el conjunto de datos .....	145
7.2.2	Sentencias usadas para la Sección 4.1. ....	145
7.2.3	Sentencias usadas para la Sección 4.2. ....	146
7.2.4	Sentencias usadas para la Sección 4.3. ....	148
7.2.5	Sentencias usadas para la Sección 4.4 .....	153
7.3	Sentencias R utilizadas en el capítulo 5 .....	155
7.3.1	Sentencias usadas para la Sección 5.2 .....	155
7.3.2	Sentencias usadas para la Sección 5.3. ....	158
7.3.3	Sentencias usadas para la Sección 5.4. ....	158
8.	CAPÍTULO 8. DISCUSIÓN GENERAL .....	161
9.	CAPÍTULO 9. CONCLUSIONES.....	169
10.	BIBLIOGRAFÍA.....	171

## INDICE DE TABLAS

Tabla 2.1. Secuencias de cultivos probadas en el ensayo de agricultura continua entre los años 1984 y 1996. ....	18
Tabla 2.2. Esquema de las rotaciones en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo entre 1976 y 1993 y los sistemas de cultivo (SC) con el que continuó a partir de 1994. ....	21
Tabla 2.3. Esquema de los sistemas de cultivos (SC) en el ensayo de Rotaciones Mixtas y Sistemas de Laboreo entre 1994 y 2017. ....	21
Tabla 2.4. Síntesis de información sobre los ELDA analizados en este trabajo de Tesis. ....	22
Tabla 4.1. Denominación de los modelos de mediciones repetidas que se ajustan para al logaritmo del contenido de nitrógeno (CN) del suelo en el perfil completo (0-90 cm). ....	61
Tabla 5.1. Modelos aditivos generalizados para parámetros de localización, escala y forma (GAMLSS) ajustados al contenido de nitrógeno del suelo (CN) a 0-90 cm, las distribuciones de probabilidad utilizadas y sus funciones de ligaduras y funciones en el paquete <code>gamlss</code> de R para ajustar los modelos y funciones de ligadura. Las letras griegas representan los parámetros de la distribución ( $\mu$ : de localización, $\sigma$ : de escala, $\nu$ y $\tau$ : de forma). ....	91
Tabla 5.2. Valores de los criterios de información de Akaike (AIC) e información de Akaike generalizados (GAIC, $k=\log(n)$ y $k=2.8$ ) para los modelos ajustados (Tabla 5.1.) al contenido de nitrógeno (CN) en Agramunt y $n=893$ . ....	93
Tabla 5.3. Medidas descriptivas calculadas para los residuos normalizados de los modelos con distribución Inversa Gaussiana (mod.IG), distribución de Box, Cox, Cole y Green (mod.BCCG), distribución lognormal (mod.LOGNO), distribución gamma (mod.GA) y distribución potencial exponencial de Box y Cox (mod.BCPE). ....	99
Tabla 5.4. Valores de los criterios de información de Akaike (AIC) e información de Akaike generalizados (GAIC, $k=\log(n)$ y $k=2.8$ ) para los modelos seleccionados en la primera etapa entre los modelos de la Tabla 5.1. para el contenido de nitrógeno a 0-90 cm (CN) en Agramunt y $n=892$ . ....	102
Tabla 5.5. Medidas descriptivas calculadas para los residuos normalizados de los modelos con distribución de Box, Cox, Cole y Green (mod.BCCG), distribución gamma (mod.GA) y distribución potencial exponencial de Box y Cox (mod.BCPE). ....	103
Tabla 6.1. Secuencias de cultivos probadas en el Ensayo de Agricultura Continua. Los recuadros de bordes grises encierran secuencias con uno y dos trigos. ....	114

Tabla 6.2. Desarrollo de las secuencias de cultivos MTT y TMT en todo el período del ensayo. ....	114
Tabla 6.3. Desarrollo de las secuencias de cultivos MTT y TMT (Tabla 6.1) en todo el período del ensayo, evidenciando en ambas la ocurrencia de la secuencia MTT. ....	116
Tabla 6.4. Esquema de las tres posibles secuencias para cada una de las rotaciones básicas maíz (M)-trigo (T)-T (MTT) y MMT, con tres inicios escalonados en los primeros doce años de un ensayo. P: pastura. ....	118
Tabla 6.5. Esquema de las tres posibles secuencias de la rotación básica maíz (M)-trigo(T)-T iniciadas en cada una de sus fases y con cuatro ciclos completos de cada una. Los recuadros identifican los primeros ciclos completos de: a) la secuencia MTT en el esquema de cada una de las tres secuencias; b) la secuencia TMT en el esquema de cada una de las tres secuencias; c) la secuencia TTM en el esquema de cada una de las tres secuencias. ....	120
Tabla 6.6. Esquema de las rotaciones mixtas considerando las tres secuencias de cultivos (maíz (M) - soja (S) -trigo (T), STM y TMS) para un ensayo de rotaciones mixtas. Sistemas de cultivos: (1) pastura permanente, (2) agricultura continua por 3 años con LC seguida de pastura continua por 3 años, (3) agricultura continua por 3 años con SD seguida de pastura continua por 3 años, (4) agricultura continua por 9 años con LC seguida de pastura continua por 3 años, (5) agricultura continua por 9 años con SD seguida de pastura continua por 3 años, (6) agricultura permanente con LC, (7) agricultura permanente con SD. Secuencias: A, B y C representan a MST, STM y TMS respectivamente en los sistemas de cultivo (2) y (3), D, E y F representan a MST, STM y TMS respectivamente en los sistemas de cultivo (4) y (5), y G, H, I representan a MST, STM y TMS respectivamente en los sistemas de cultivo (6) y (7). Las secuencias de cultivos se inician en diferentes años (Inicio). Las celdas sombreadas en gris corresponden a años con pastura. M: maíz, T: trigo, S: soja. ....	127
Tabla 6.7. Sistemas de cultivos en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo, identificando tramos de pastura y de agricultura. Sistemas de cultivos: pastura permanente (Pastura), agricultura continua por 3 años con LC seguida de pastura continua por 3 años (50%LC), agricultura continua por 3 años con SD seguida de pastura continua por 3 años (50%SD), agricultura continua por 9 años con LC seguida de pastura continua por 3 años (75%LC), agricultura continua por 9 años con SD seguida de pastura continua por 3 años (75%SD), agricultura permanente con LC (100%LC) y agricultura permanente con SD (100%SD). LC: laboreo convencional, SD: laboreo con siembra directa. ....	131
Tabla 6.8. Promedios de COT (Mg ha <sup>-1</sup> ) al final de la primera etapa del ensayo (1993, datos tomados en 1994) para cada una de las rotaciones y profundidades, y que luego continúa en el “Ensayo de Rotaciones Mixtas y Sistemas de Laboreo”. ....	132

Tabla 6.9. Salida del programa R para los análisis de regresiones segmentadas para COT. Estimaciones de pendientes (Est.), sus errores estándar (St. Err.), valores t para las pruebas de significancia de las pendientes (t value) y límites de los intervalos de confianza del 95% para las pendientes. ....135

## INDICE DE FIGURAS

Fig. 2.1. Imagen satelital (Google Maps) del Ensayo de Sistema de Manejo de Suelos en Agramunt y ubicación geográfica de Agramunt en Catalunya, España. ....	15
Fig. 2.2. Imagen satelital (Google Maps) de los ensayos de larga duración en Balcarce, su ubicación relativa en Balcarce y ubicación geográfica de Balcarce en la provincia de Buenos Aires, Argentina. ....	17
Fig. 3.1. Funciones de densidad de distribuciones gamma según (3.1.) para algunos valores de los parámetros $\mu$ y $\sigma$ . ....	26
Fig. 3.2. Funciones de densidad de distribuciones lognormal según (3.2.) para algunos valores de los parámetros $\mu$ y $\sigma$ . ....	27
Fig. 3.3. (a) Distribuciones normales con diferentes varianzas y medias ( $N(2,0.5)$ curva naranja y $N(5,2)$ curva gris). (b) Distribuciones de las diferencias de cada variable en a) respecto a su media. ....	29
Fig. 3.4. Modelo de regresión lineal (3.4.) y visualización de algunos supuestos con un ejemplo numérico arbitrario. La recta representa a $E(y_i x_i) = \beta_0 + \beta_1 x_i$ . ....	32
Fig. 4.1. Contenido de nitrógeno mineral (CN) en el perfil total de suelo (0-90 cm) en el ensayo de Agramunt a través del tiempo, desde el año 1995 hasta el año 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsolado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel, la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la línea naranja es un suavizado. ....	48
Fig. 4.2. Contenido de nitrógeno mineral (CN) en el suelo a 0-30 cm de profundidad en el ensayo de Agramunt a través del tiempo, desde el año 1995 al 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsolado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la línea naranja es un suavizado. ....	49
Fig. 4.3. Contenido de nitrógeno mineral (CN) en el suelo a 30-60 cm de profundidad en el ensayo de Agramunt a través del tiempo, desde el año 1995 al 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsolado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la	

línea naranja es un suavizado. ....	50
Fig. 4.4. Contenido de nitrógeno mineral (CN) en el suelo a 60-90 cm de profundidad en el ensayo de Agramunt a través del tiempo, desde el año 1995 al 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsulado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la línea naranja es un suavizado. ....	51
Fig. 4.5. Residuales crudos (a) y estandarizados (b) versus los respectivos valores ajustados o predichos, para el modelo 0.1. CN: contenido de nitrógeno mineral en el suelo a 0-90 cm. ....	55
Fig. 4.6. Diagramas de caja para los residuales estandarizados del modelo 0.1 en cada tipo de laboreo. ....	55
Fig. 4.7. (a) Histograma de densidad y función de densidad teórica para una distribución normal (línea roja) para los residuos crudos del modelo 0.1. (b) Gráfico cuantil-cuantil (qq plot) para los residuos crudos del modelo 0.1 y sus correspondientes cuantiles de una distribución normal, donde la línea de referencia (línea recta) indica la concordancia total. Gráficos obtenidos con funciones del paquete <code>fitdistrplus</code> de R. ....	56
Fig. 4.8. Residuales crudos (a) y estandarizados (b) versus los respectivos valores ajustados o predichos, para el modelo 0.2. CN: contenido de nitrógeno mineral en el suelo a 0-90 cm. ....	58
Fig. 4.9. Diagramas de caja para los residuales estandarizados del modelo 0.2 en cada tipo de laboreo. ....	58
Fig. 4.10. (a) Histograma de densidad y función de densidad teórica para una distribución normal (línea roja) para los residuos crudos del modelo 0.2. (b) Gráfico cuantil-cuantil (qq plot) para los residuos crudos del modelo 0.2 y sus correspondientes cuantiles de una distribución normal, donde la línea de referencia (línea recta) indica la concordancia total. Gráficos obtenidos con funciones del paquete <code>fitdistrplus</code> de R. ....	59
Fig. 4.11. (a) Residuales estandarizados versus valores ajustados en <code>mm1.logCN.cs</code> discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo <code>mm1.logCN.cs</code> (gráfico cuantil-cuantil) discriminados para cada laboreo. ....	64
Fig. 4.12. Gráficos de diagnóstico sobre los eblups (mejores predictores lineales insesgados empíricos) de efectos de parcelas del <code>mm1.logCN.cs</code> . (a) histograma de densidad y la función de densidad teórica según una distribución normal, (b) gráfico cuantil-cuantil según una distribución normal, (c) función de distribución acumulada (FDA) dada por los datos (empírica) y la teórica según una distribución normal, y (d) gráfico probabilidad-probabilidad según una distribución normal. Gráficos obtenidos con funciones del paquete <code>fitdistrplus</code> de R. ....	65

Fig. 4.13. Gráficos de diagnóstico sobre los eblups (mejores predictores lineales insesgados empíricos) de efectos de subparcelas del mm1.logCN.cs. (a) histograma de densidad y la función de densidad teórica según una distribución normal, (b) gráfico cuantil-cuantil según una distribución normal, (c) función de distribución acumulada dada por los datos (empírica) y la teórica según una distribución normal, y (d) gráfico probabilidad-probabilidad según una distribución normal. Gráficos obtenidos con funciones del paquete <code>fitdistrplus</code> de R. ....	66
Fig. 4.14. Diagramas de caja para los eblups de los efectos aleatorios de subparcelas del modelo mm1.logCN.cs. en cada tipo de laboreo. ....	67
Fig. 4.15. (a) Residuales estandarizados versus valores ajustados en mm1.logCN discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo mm1.logCN (gráfico cuantil-cuantil) discriminados para cada laboreo. ....	70
Fig. 4.16. (a) Residuales estandarizados versus valores ajustados en mm2.logCN.cs discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo mm2.logCN.cs (gráfico cuantil-cuantil) discriminados para cada laboreo. ....	71
Fig. 4.17. (a) Residuales estandarizados versus valores ajustados en mm2.logCN discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo mm2.logCN (gráfico cuantil-cuantil) discriminados para cada laboreo. ....	75
Fig. 4.18. Logaritmo del contenido de nitrógeno (CN) en el perfil completo del suelo (0-90 cm) través del tiempo, desde el año 1995 al 2015, cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsulado profundo). Los puntos representan el logaritmo del promedio de CN en las submuestras, con diferentes colores se distinguen los cuatro bloques, en cada panel la línea entrecortada gris indica el valor de logaritmo de CN promedio en todo el período y la línea continua negra es una curva de suavizado. ....	77
Fig. 4.19. Semivariograma muestral correspondiente a los residuos estandarizados del modelo mm2.logCN (puntos grises). Se superpone el semivariograma muestral agrupando las distancias en 20 intervalos (puntos azules) y un suavizado loess (línea azul). ....	79
Fig. 4.20. Gráficos de semivariogramas para algunos modelos de correlaciones espaciales isotrópicos adaptado de la figura 5.9 de Pinheiro y Bates (2000), con parámetro de correlación $\rho = 1$ y semivariograma = 0.1 para distancia 0 (efecto pepita). ....	80
Fig. 4.21. Semivariograma muestral (círculos azules) y semivariograma ajustado en el modelo mm3.logCN con estructura cuadrática racional. ....	82
Fig. 4.22. Medias mínimo cuadrados $\pm$ error estándar según el modelo mm2.logCN para	

los cuatro laboreos en cada fecha de muestreo. En cada fecha, con asterisco gris (\*) se indica que hubo diferencia significativa entre, al menos, dos laboreos, nivel de significancia 0.05 ajustado para la comparación de cuatro medias, grados de libertad para le estadístico de prueba = 9. ....84

Fig. 4.23. Medias mínimo cuadrados  $\pm$  error estándar según el modelo mm1.logCN para los cuatro laboreos en cada fecha de muestreo. En cada fecha, con asterisco gris (\*) se indica que hubo diferencia significativa entre, al menos, dos laboreos, nivel de significancia 0.05 ajustado para la comparación de cuatro medias grados de libertad para le estadístico de prueba = 9. En cada fecha, con asterisco negro (\*) se indica que hubo diferencia significativa entre, al menos, dos laboreos, nivel de significancia 0.05 ajustado para la comparación de cuatro medias y aproximación de Kenward-Roger.....85

Fig. 5.1. Valores para los criterios de información de Akaike generalizados (GAIC) para cada uno de los modelos aditivos generalizados de localización, escala y forma (GAMLSS) ajustados (Tabla 5.1), ordenados de menor a mayor según valor de AIC (GAIC con  $k=2$ , círculo vacío). Valores de GAIC con  $k=\log(n)$  (círculo relleno) y GAIC con  $k=2.8$  (triángulo) ( $k$ : constante de penalización). En rojo se han destacado los tres menores valores de cada GAIC. El mod.LOGNO2 (Tabla 5.1.) fue excluido del gráfico. ....94

Fig. 5.2. Funciones de densidad para dos distribuciones inversas gaussianas (IG). ....96

Fig. 5.3. Gráficos gusano para los residuos normalizados de los modelos (Tabla 5.1.) mod.IG (a), mod.BCCG (b), mod.LOGNO (c), mod.GA (d) y mod.BCPE (e). En mod.BCPE hay un punto que representa un desvío superior a 1 y menor que 1.1 correspondiente al mayor valor de cuantil normal. ....98

Fig. 5.4. Residuales normalizados para el modelo mod.IG .....99

Fig. 5.5. Residuales normalizados para el modelo mod BCCG .....100

Fig. 5.6. Residuales normalizados para el modelo mod.LOGNO.....100

Fig. 5.7. Residuales normalizados para el modelo mod.GA. ....101

Fig. 5.8. Residuales normalizados para el modelo mod. BCPE. ....101

Fig. 5.9. Gráficos gusano para los residuos normalizados de los modelos mod.BCCG (a), mod.GA (b) y mod.BCPE (c) sin el dato extremo para algunos modelos de los primeros ajustes. ....104

Fig. 5.10. Residuales normalizados para el mod.BCCG sin dato extremo.....105

Fig. 5.11. Residuales normalizados para el mod.GA sin dato extremo.....105

Fig. 5.12. Residuales normalizados para el mod.BCPE sin dato extremo. ....106

Fig. 5.13. Parámetro de localización (mediana) estimado para la distribución de probabilidad de CN por el modelo GAMLSS mod.BCPE (Tabla 5.1.) (sin un dato extremo),

para cada laboreo, bloque y fecha de muestreo. ....107

Fig. 5.14. Parámetro de escala (aproximación del coeficiente de variación) estimado para la distribución de probabilidad de CN por el modelo GAMLSS mod.BCPE (Tabla 5.1.) (sin un dato extremo), para cada laboreo, bloque y fecha de muestreo. ....107

Fig. 6.1. Diagrama de un ensayo para evaluar tres rotaciones de cultivo (R1, R2, R3) y dos laboreos contrastantes (Laboreo Convencional y Siembra directa) en seis bloques. Cada fase de cada rotación está presente en dos bloques todos los años. R1: trigo (T) (Fase 1), maíz (M)(Fase 2), M (Fase 3); R2: T (Fase 1), soja (S)(Fase 2), S (Fase 3): R3: T (Fase 1), M (Fase 2), S (Fase 3). ....123

Fig. 6.2. Diagrama de un ensayo para evaluar nueve secuencias de cultivo (tres secuencias de tres rotaciones: R1, R2, R3) y dos laboreos contrastantes (Laboreo Convencional y Siembra directa) en dos bloques. Cada fase de cada rotación está presente en los mismos dos bloques todos los años. R1: trigo (T)(Fase 1), maíz (M)(Fase 2), M (Fase 3); R2: T (Fase 1), soja (S)(Fase 2), S (Fase 3): R3: T (Fase 1), M (Fase 2), S (Fase 3). ....123

Fig. 6.3. Valores de carbono orgánico del suelo (COT) determinados a 20 cm de profundidad para cada sistema de cultivo en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo. Las líneas corresponden a los ajustes de las regresiones segmentadas. Sistemas de cultivos: pastura permanente (Pastura), agricultura continua por 3 años con LC seguida de pastura continua por 3 años (50%LC), agricultura continua por 3 años con SD seguida de pastura continua por 3 años (50%SD), agricultura continua por 9 años con LC seguida de pastura continua por 3 años (75%LC), agricultura continua por 9 años con SD seguida de pastura continua por 3 años (75%SD), agricultura permanente con LC (100%LC) y agricultura permanente con SD (100%SD). LC: laboreo convencional, SD: laboreo con siembra directa. ....136

Fig. 6.4. Cambios porcentuales del COT a 0-20 cm de profundidad en períodos de 3 años de agricultura continua o de pastura continua en el ensayo de rotaciones mixtas, según tipo de laboreo (LC: laboreo convencional, SD: laboreo con siembra directa) para los de agricultura y nivel inicial de COT en el período de 3 años. ....139

Fig. 6.5. Cambios porcentuales del COT a 0-20 cm de profundidad en períodos de 3 años de agricultura continua o de pastura continua ( $(\Delta COT / COT_{inicial})\%$ ) en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo, según tipo de laboreo para los tratamientos que incluyen agricultura y nivel inicial de COT en el período de 3 años ( $COT_{inicial}(\text{Mg ha}^{-1})$ ). En cada caso se distingue el sistema de cultivo al cual corresponde el período observado y se ajusta un suavizado. Sistemas de cultivos: pastura permanente (Pastura), agricultura por 3 años con LC seguida de pastura por 3 años (50%LC), agricultura por 3 años con SD seguida de pastura por 3 años (50%SD), agricultura por 9 años con LC seguida de pastura por 3 años (75%LC), agricultura por 9

años con SD seguida de pastura por 3 años (75%SD), agricultura continua con LC (100%LC) y agricultura continua con SD (100%SD). En el panel “Agricultura+LC” se grafican los datos correspondientes a períodos de 3 años con agricultura y LC, en el panel “Agricultura+SD” se grafican los datos correspondientes a períodos de 3 años con agricultura y SD, en el panel “Pastura” se grafican los datos correspondientes a períodos de 3 años de pastura. LC: laboreo convencional, SD: laboreo con siembra directa.....140

## RESUMEN

Revisar la forma de análisis estadístico de los datos generados en los ensayos en agricultura, es importante, en particular, en los ensayos de larga duración en agricultura (ELDA). Las metodologías estadísticas que se refieren como clásicas y de las que se hace uso frecuente, muchas veces son aplicadas sin evaluar el grado de adecuación de los supuestos. Por otro lado, existen nuevas alternativas metodológicas disponibles que deben investigarse y probarse. Asimismo, los recaudos que deben tomarse en el diseño y conducción de los experimentos son, sin dudas, tanto o más importantes, más aún cuando se proyecta que aquellos perduren varios años. Se utilizó una serie de 20 años de datos de un ELDA ubicado en Agramunt, Catalunya, España ( $41^{\circ} 48' 33.6''$  N,  $1^{\circ} 7' 2.3''$  E), para modelar los cambios en el contenido del nitrógeno mineral (CN) del suelo en el perfil total (0-90 cm), en función de los efectos de los tipos de laboreo, del tiempo y de su interacción. Para tal fin se aplicaron modelos lineales mixtos (MLM) y modelos aditivos generalizados para localización, escala y forma (GAMLSS). Un MLM con heterogeneidad de varianzas en el error dependiendo de los laboreos y con errores independientes, fue el mejor modelo entre los MLM probados para CN. No obstante, la magnitud de la diferencia en las varianzas no impactó en importantes diferencias entre las pruebas de efectos fijos y las comparaciones de medias realizadas bajo el modelo con heterogeneidad de varianzas y el respectivo con homogeneidad de varianzas. Los GAMLSS son de desarrollo relativamente reciente y su aplicación a ensayos agronómicos diseñados (sean ELDA o no) es aún muy poco frecuente o casi inexistente. A través de los GAMLSS, el CN se modeló en función del tiempo dependiendo de los laboreos (interacción) utilizando suavizados P-splines. Se probaron y evaluaron modelos GAMLSS con diferentes distribuciones de probabilidad para CN. Si bien la distribución lognormal resultó de buena concordancia para CN en los MLM, entre los GAMLSS, la distribución potencial exponencial de Box y Cox, en primer término, y la gamma, dentro de las tres mejores, resultaron más acordes que la lognormal. Además, se revisaron aspectos de diseños para cuatro ELDA ubicados en Balcarce, Sudeste de la provincia de Buenos Aires, Argentina ( $37^{\circ} 45' 11.4''$  S;  $58^{\circ} 17' 49.7''$  O). Todos ellos son ensayos con sistemas de cultivos que involucran rotaciones de cultivos, tres con rotaciones básicas de tres fases en agricultura continua y el restante, comprendiendo rotaciones mixtas (agricultura-pastura). En los casos en que se observó alguna deficiencia, se indicó cómo podría salvarse en el mismo ensayo o en ensayos futuros con los mismos objetivos. En otros casos, también se sugirieron diseños alternativos. Asociado con los ensayos

de rotaciones de cultivos o cultivos y pastura y el contenido de carbono orgánico total (COT) del suelo se dieron pautas para el análisis estadístico. Una de las propuestas se basa en evaluar los efectos de interés sobre la variable diferencia de COT entre final e inicio en ciertos períodos de tiempo o años. En cada una de las etapas de ajuste, evaluación y selección de los modelos más adecuados (tanto MLM como GAMLSS), se mostraron qué herramientas estadísticas utilizar, y cómo utilizarlas e interpretarlas. Estas herramientas fueron implementadas en el ambiente computacional R. Las sentencias utilizadas, pueden ser adaptadas, generalizadas y extendidas para el análisis de otras variables respuesta y otros ELDA. Dichas sentencias son la base para la creación de un paquete para el análisis estadístico en los ELDA. Para ello, la diferente naturaleza de las variables respuesta (así como CN y COT), debe ser tomada en cuenta para la elección del modelo y las interpretaciones de los resultados.

## SUMMARY

It is important to revise how data generated in experiments on agriculture is statistically analyzed. This is especially so for long term agriculture experiments (ELDA). The frequently used statistical methodologies referred to as classical, are very often used without evaluating the degree of adequacy of the inherent assumptions. On the other hand, there exist several new alternative methodologies that should be investigated and tested. Likewise, care and attention on experiment design and conduction is, undoubtedly, as much important as statistical analysis, especially for long lasting experiments. It was used a 20-year-long data series from an ELDA at Agramunt, Catalunya, Spain ( $41^{\circ} 48' 33.6''$  N,  $1^{\circ} 7' 2.3''$  E) to model changes of soil mineral nitrogen (CN) content in the whole profile (0-90 cm), as a function of the effect of tillage system, time, and their interaction. For that, mixed linear models (MLM) and generalized additive models for localization, scale and shape (GAMLSS), were used. A MLM with variance heterogeneity in the error as depending on tillage systems and with independent errors, was the best model among the tested for CN. However, the magnitude of variance differences did not impact seriously on differences in fixed effect tests and on mean comparisons done with the models either considering variance heterogeneity and not. The GAMLSS have been recently developed and have almost not been used for experiments on agriculture (either ELDA or not). Mineral nitrogen was modeled as a function of time and depending on tillage systems (interaction), through GAMLSS using P-splines. Some GAMLSS using different probability distributions of CN, were tested and evaluated. Despite among MLM, models using lognormal distribution adequately modeled CN, among the GAMLSS, Box-Cox potential-exponential distribution, in first place, and gamma distribution, among the three best, resulted better than those using lognormal distribution. On the other hand, design aspects of four ELDA at Balcarce, southeastern Buenos Aires province, Argentina ( $37^{\circ} 45' 11.4''$  S;  $58^{\circ} 17' 49.7''$  W), were evaluated. All of them are cropping-system experiments, three including three-phase crop-basic-rotations under continuous cropping and the other, including cropping-pasture rotations. In the cases where design deficiencies were observed, it was indicated how they could be overcome in the experiment itself or in new experiments with the same objectives. In some other cases, alternative designs were also indicated. Some suggestions for statistical analysis of soil organic carbon content (COT) were done both for continuous cropping rotations and for cropping-pasture rotations. One of the proposals is based on the evaluation of the effect of treatment factors on a variable generated as the

difference of COT between the end and the beginning of defined time periods. Statistical tools to be used in each one of the stages of model fitting, evaluation and selection (both of MLM and of GAMLSS) and how to use and interpret them, were shown. All these tools were implemented in the R computational environment. The sentences used, can be adapted, generalized and extended for the analysis of others response variables and others ELDA. Such sentences are the base for a package for statistical analysis of ELDA. Response variable nature (that show differences as CN and COT do), must be taken into account for model selection and result interpretation.

## 1. CAPÍTULO 1. INTRODUCCIÓN

### 1.1 Ensayos de larga duración en agricultura: generalidades y relevancia

La ciencia es una búsqueda a largo plazo y si bien la investigación a menudo se practica y busca resultados en períodos cortos, existen ciertas investigaciones cuyos resultados no pueden precipitarse y su logro requiere de relativamente largos períodos de estudio (Owens, 2013). Así, ensayos o experimentos de larga duración son utilizados en diferentes áreas de estudio y, en particular, en agronomía. Pocos experimentos tienen tanta antigüedad como los de agricultura en Rothamsted, Reino Unido, cuyos inicios datan del año 1843 y siguen aún vigentes (Johnston, 1997; Peterson *et al.* 2012; Owens, 2013). Cochran (1939) se refiere a los experimentos de larga duración en agricultura (ELDA) como aquellos experimentos en agricultura que están planeados para persistir en el mismo sitio durante un número de años. Los ELDA son el interés de este trabajo de tesis y, a pesar de estar restringidos a la agricultura, son variados en objetivos, planificación, ejecución y duración. Como otros experimentos que operan a largo plazo, los ELDA muchas veces se enfrentan a los cambios de prioridades y tecnologías de investigación, y su existencia se ve amenazada regularmente por las dificultades en la financiación y los cambios en la administración. Cada uno posee sus propias características y, también, sus propios problemas de planificación, ejecución, análisis estadístico e interpretación, lo que generalmente lleva a un tratamiento particularizado a fin de evitar posibles inconvenientes (McRae y Ryan, 1996). No obstante, en general, todos ellos tienen por objetivo principal comparar los efectos de los tratamientos objeto de estudio, aplicados durante un período de tiempo prolongado (Loughin *et al.*, 2007).

Agricultura sostenible implica, entre otras cosas, conservación de los sistemas naturales a largo plazo, producción óptima con reducidos costos de producción, adecuado nivel de ingreso y de beneficio por unidad de producción, satisfacción de las necesidades alimentarias básicas, y suficiente abastecimiento para cubrir las demandas y necesidades de las familias y las comunidades rurales (Zinck *et al.*, 2005). Más sintéticamente, un sistema de agricultura sostenible es un sistema de producción que satisface las necesidades humanas en cuanto a alimentos y calidad de vida, a través del uso eficiente y seguro de los recursos naturales y de los insumos (Studdert, 2006). Así, los ELDA están estrechamente ligados al concepto de agricultura sostenible (Frye y Thomas, 1991; Jenkinson, 1991; Johnston, 1997; Loughin, 2006;

Payne, 2015), dado que brindan información que permiten el manejo de los procesos y mecanismos para su logro.

Las prácticas de manejo que se aplican en los agroecosistemas constituyen uno de los factores más importantes a tener a cuenta en el desarrollo de sistemas productivos sostenibles (Blanco y Lal, 2010; Reicosky *et al.*, 2011). La rotación de cultivos es una práctica de manejo clave para la sostenibilidad del agroecosistema, ya que contribuye a preservar y/o mejorar su productividad y su rentabilidad. Ejerce una marcada influencia sobre las relaciones suelo-planta que condicionan el comportamiento de los cultivos (Power y Follett, 1987) e inciden sobre los procesos edáficos (Quiroga y Studdert, 2014). Asimismo, el efecto de aquellas prácticas que se aplican directamente al suelo (p.e. laboreo, enmiendas, fertilización) no pueden considerarse separadamente de los cultivos, ni de los aspectos económico-financieros del sistema de producción, ya que están estrechamente relacionados entre sí (Quiroga y Studdert, 2014). Así, otras prácticas que hacen al manejo del ciclo de los nutrientes, de plagas y enfermedades y al uso de agroquímicos, también deben tenerse en cuenta para el logro de una agricultura sostenible. Los sistemas de laboreo y las rotaciones de cultivos, así como la relación entre ellos, son elementos clave en este aspecto (Studdert, 2006). Las rotaciones de cultivos, acompañadas de las variantes en otras prácticas de manejo, como los sistemas de laboreo, la fertilización mineral y la aplicación de abonos orgánicos y la irrigación, entre otros, conforman en conjunto el sistema de cultivo.

El desarrollo de sistemas de cultivo sostenibles se basa en un profundo conocimiento del ambiente natural y biológico y de las complejas interacciones entre éstos y los componentes del sistema de cultivo (Costamagna *et al.*, 2006). Por ello, los ELDA son de particular interés en agricultura y la ciencia del suelo para estudiar los efectos de los sistemas de cultivo y las variantes de algunos de sus componentes. Así, los ELDA son esenciales en la investigación de los factores que determinan la producción sostenible y se busca que brinden pautas para la modificación del manejo según el ambiente y los efectos esperados en el tiempo. En muchos casos, los efectos de dichos factores o las interacciones entre ellos se pueden observar o se vuelven evidentes sólo después de un tiempo prolongado (Poulton, 1995). En este sentido, los ELDA han contribuido y contribuyen al conocimiento de las relaciones entre las características del agroecosistema (suelo, clima y relieve, aspectos socio-económicos) y de los efectos de las prácticas de manejo. La comprensión en profundidad de todo esto es imprescindible para la

toma de decisiones que contribuyan a la sostenibilidad del agroecosistema (Luna y House, 1990).

Los primeros ELDA tenían sus objetivos más orientados a la producción (Berti *et al.*, 2016), pero hoy no hay dudas de que sus aportes tienen o pueden tener un valor más amplio. Los ELDA han demostrado su capacidad para proporcionar datos importantes y orientación para mejorar el manejo del suelo. En particular, los ELDA realizan una contribución científica a la comprensión del ciclo de carbono (Peterson *et al.*, 2012) y de las dinámicas de los nutrientes en el sistema suelo-atmósfera, como así también a la producción de alimentos y a la mejora del manejo de los suelos (Richter *et al.*, 2007) para mantener o mejorar su funcionamiento.

## **1.2 Diseños y análisis de los ELDA: revisión y consideraciones**

La conducción y mantenimiento de los ELDA se torna compleja, no sólo por lo difícil de la gestión de campo y de los recursos, sino también porque, al perdurar durante varios años, muchos aspectos que hacen a su funcionamiento (p.e. cultivares, productos agroquímicos, equipos de laboreo) y hasta el personal a cargo de la investigación (Cady, 1991), van cambiando o evolucionando. Más aún, la complejidad de estos ensayos se incrementa al considerar al sistema de cultivo con sus distintos componentes y variantes. Muchos de los problemas de gestión en los ELDA se pueden resolver o disminuir, en gran medida, con un diseño adecuado (Jenkinson, 1991) y flexible a los posibles cambios futuros. Un diseño resulta flexible si permite manejar nuevos tratamientos que surjan *a posteriori* del planteo inicial, por ejemplo, mediante la división de las parcelas existentes (Cady, 1991), o manejar cambios en los tratamientos originales. En gran medida, el valor de estos experimentos se ha mantenido porque han permitido introducir modificaciones para considerar nuevas hipótesis o considerar otras alternativas de manejo o productivas.

Si los ELDA tienen por finalidad evaluar la sostenibilidad de los sistemas agrícolas, proporcionar material de investigación para comprender mejor los procesos del suelo y de las plantas, y producir datos de beneficio para los agricultores, entonces, los cambios en los ensayos deben hacerse sólo ocasionalmente. Para lograr sus objetivos, en los experimentos de Rothamsted se han ido introduciendo cambios al planteo original que han mejorado

considerablemente su valor (Johnston, 1997). En el futuro, los ELDA pueden ampliar nuestra comprensión de las tendencias del comportamiento del suelo a largo plazo y respecto a si los suelos están siendo gestionados de manera que mantengan toda su gama de funciones. Para lograrlo es importante revisar la base de investigación a largo plazo sobre el suelo para abordar científicamente los muchos asuntos críticos que involucran la gestión del suelo y el cambio global (Richter *et al.*, 2007).

Sin embargo, mientras que el diseño de experimentos a largo plazo debe tener flexibilidad para introducir cambios, es crucial evitar que ellos ocurran con frecuencia y, más aún, que se los haga para acomodar el ELDA a demandas efímeras o coyunturales (Johnston, 1997). De hecho, los primeros ELDA han sobrevivido a pesar de la falta de repetición, debido a que, como las parcelas eran en su mayoría de gran tamaño, pudieron ser subdivididas y así permitieron incorporar nuevos tratamientos y repeticiones, pero sin descuidar ni perder el rumbo planteado originalmente. Incluso, los primeros ELDA se iniciaron antes de sentarse las bases del diseño experimental clásico tal cual es conocido hoy, gracias a los aportes de Ronald Fisher en la segunda década del siglo pasado (Parolini, 2015). Dichas bases establecen los tres principios básicos del diseño experimental: el control local, la repetición y la aleatorización. Además del buen diseño y la planificación, es totalmente relevante que las muestras de cultivos y de suelo se archiven en condiciones apropiadas (Johnston, 1997). Los diseños de inicios escalonados son propuestos para que los efectos a largo plazo de los tratamientos estén repetidos en diferentes condiciones de sucesión de años (Loughin, 2006; Loughin *et al.*, 2007).

Cochran (1939) clasifica los ELDA en dos grandes grupos o tipos, según involucren cultivos anuales o cultivos perennes o árboles. Dentro de los ELDA con cultivos anuales están aquéllos que incluyen rotaciones de dichos cultivos. Los términos básicos relativos a estos experimentos y sus aspectos estadísticos han sido definidos y tratados, respectivamente, en trabajos como los de Cochran (1939), Yates (1954) y Patterson (1964) y luego revisados por Preece (1986). Una rotación de cultivos es un sistema en el cual diferentes cultivos se realizan combinados espacial y/o temporalmente sobre la misma unidad de superficie, a lo largo de un tiempo determinado. Los experimentos que involucran rotaciones de cultivos son variados, hay experimentos que comprenden una sola rotación y otros que involucran más de una, incluyendo, a veces, cultivos perennes como las pasturas. En este tipo de ELDA se comparan

los efectos de las combinaciones de cultivos y las relaciones entre ellos, y clásicamente han estado enfocados en evaluar el comportamiento (i.e. rendimiento) de alguno de los cultivos intervinientes, tomado como testigo (Yates, 1954, Patterson, 1964). En estos experimentos debe procurarse que los efectos de las secuencias de cultivos no se confundan con los efectos de las condiciones de cada año involucrado. Por ello, se han propuesto distintos diseños buscando que todas las fases (i.e. cada cultivo componente) de las secuencias estén presentes todos los años (Patterson, 1964). Así, una vez que ha tenido lugar un ciclo completo, se pueden hacer comparaciones entre las secuencias en cada año subsiguiente. Además, si se dispone de recursos suficientes para tener más de una repetición en cada año, será posible, también, realizar análisis intermedios con los datos de un solo año (Payne, 2015). Si bien un ensayo de rotación de cultivos no es necesariamente un ensayo de larga duración, claramente perdura más de un año y, dependiendo de la cantidad de cultivos que involucre y de la necesidad de generar más de un ciclo de rotación, pueden convertirse en ensayos de larga duración. Así, los efectos a evaluar trascenderán a los ocasionados por los cultivos y podrá pensarse en considerar cómo las rotaciones y las demás prácticas involucradas inciden sobre el funcionamiento del sistema suelo-planta-atmósfera. Es común que los ELDA comprendan al menos una rotación de cultivos o de cultivos y pasturas. De este modo, dependiendo de las características particulares, de la estructura de los sistemas de cultivo implementados y de otros tratamientos adicionales que puedan incorporarse, el diseño y los análisis estadísticos de los ELDA se harán más o menos complejos. A dicha complejidad se agrega la consideración y definición de cuáles son la frecuencia (anual, varias veces en el año u otra escala temporal) y la oportunidad (puede ser diferente según la variable a evaluar y las prácticas involucradas) con que deben tomarse datos en el ensayo.

La amplia variedad de posibilidades y objetivos de los ELDA dificulta uniformar reglas para la aplicación de procedimientos estadísticos para sus análisis y, por ello, cada uno debería ser tratado individualmente (McRae y Ryan, 1996). No obstante, hay aspectos comunes que permitirían un mínimo de generalización. En principio, una de las características comunes sobresalientes es la existencia de mediciones repetidas a lo largo del tiempo en una misma unidad experimental, ya que se realizan mediciones periódicas y, generalmente, con distinta frecuencia, sobre las mismas parcelas. Asimismo, por lo general, es más frecuente encontrar heterogeneidad de varianzas entre períodos o años, que contar con varianzas homogéneas.

Estos son dos aspectos que deben considerarse al momento de definir o realizar el análisis estadístico de los datos. Así, distintas estructuras de correlación entre las observaciones o en los errores de un modelo lineal, la especificación de efectos de algunas fuentes de variación como aleatorios, al igual que el modelado de la heterogeneidad de varianzas, podrían cubrir estos aspectos y resultar en análisis más adecuados que aquéllos que ignoran estas particularidades.

Los modelos lineales mixtos permiten abordar una variedad de estructuras de datos, tales como datos jerárquicos o multiniveles y mediciones repetidas en el tiempo, los que dan lugar a observaciones correlacionadas (Pinheiro y Bates, 2000; Milliken y Johnson, 2009) y también permiten modelar la heterogeneidad de las varianzas. Es decir, los modelos lineales mixtos permiten contemplar una variedad de situaciones más allá de los supuestos de independencia y homogeneidad de varianzas en los modelos clásicos de análisis de la varianza. En el contexto de los modelos lineales mixtos para experimentos diseñados existen varias propuestas (Piepho *et al.*, 2004) que deben adaptarse a cada caso particular. Si bien estos aspectos han sido ilustrados en los análisis de algunos ELDA, la mayoría han sido aplicados a la variable rendimiento del cultivo (Patterson y Lowe, 1970; Singh y Jones, 2002; Payne, 2015; Richter y Kroschewski, 2006) y muy pocos a variables de suelo, como su contenido de carbono orgánico (Richter y Kroschewski, 2006). Existen, además, otras variantes para analizar las situaciones descriptas, dependiendo de los objetivos particulares de cada ensayo y de las características propias de las variables y de los datos. En este mismo sentido, una alternativa a explorar es el modelado del efecto del tiempo en ensayos diseñados y con mediciones repetidas a través de suavizados (Verbyla *et al.*, 1999; Orchard *et al.*, 2000).

Por un lado, la estructura y las características del diseño y de las mediciones repetidas son aspectos importantes a considerar, pero también lo es la consideración del tipo de distribución de la o las variables respuesta a analizar. Variables como rendimiento de los cultivos o contenido de carbono orgánico del suelo son clásicamente analizadas bajo el supuesto de normalidad. No obstante, variables como el contenido de nitrógeno mineral y propiedades físicas del suelo como, por ejemplo, la infiltración de agua, podrían ser analizadas bajo otros modelos probabilísticos, o bien, sin asumir un patrón de distribución conocido. En general, si las variables respuesta de interés no mantuvieran una correspondencia aceptable con una distribución de probabilidad normal, será necesario aplicar metodologías de análisis

estadístico que no adopten tal supuesto. En este sentido, en los análisis estadísticos de variables registradas en algunos ELDA, como rendimiento o contenido de carbono, se han aplicado recientemente metodologías más modernas, por ejemplo, la relativa a modelos mixtos. Pero no es frecuente encontrar publicaciones en las que se realicen análisis estadísticos utilizando metodologías modernas en variables con patrones de distribución no normal o que contemplen y exploren más opciones frente a la dispar variabilidad entre tratamientos/sistemas de cultivo y/o diferentes momentos de muestreo que puedan presentarse. Por otro lado, es común que en los ELDA haya registros incompletos de todas o alguna de las variables respuesta, en por lo menos algún momento de muestreo y/o para alguna/s de las unidades experimentales. Así, un aspecto que debe explorarse para proponer el análisis de estos ensayos es la incidencia de los datos perdidos o faltantes en las estimaciones y pruebas de hipótesis sobre los parámetros de interés.

Los modelos lineales generalizados mixtos (Mc Culloch y Searle, 2001; Gbur *et al.*, 2012) avanzan sobre el análisis de variables respuesta cuya distribución de probabilidad es alguna dentro de la familia exponencial, tanto discreta como continua, es decir, binomial, *poisson*, gamma, normal inversa, e incluso normal. En este sentido, los modelos lineales mixtos son un caso particular de aquéllos. Las ecuaciones de estimación generalizadas (Hardin y Hilbe, 2003) pueden ser aplicadas cuando la variable no se ajusta a una distribución en particular, pero sí muestra una determinada relación entre su media y su varianza. Por otro lado, los modelos aditivos generalizados (Hastie y Tibshirani, 1990; Wood, 2006) pueden ser utilizados para una amplia variedad de distribuciones de probabilidad de la variable respuesta y, en simultáneo, modelar el efecto del tiempo a través de suavizados. Modelos más amplios aún son los modelos aditivos generalizados de localización, escala y forma (Rigby y Stasinopoulos, 2005; Stasinopoulos *et al.*, 2017). Estos permitirían, no sólo evaluar los efectos de los tratamientos sobre la media de la distribución de la variable respuesta, sino también sobre otros parámetros de la distribución, enriqueciendo la interpretación de los resultados y contribuyendo a la comprensión de diversos aspectos del sistema en estudio.

Hoy día, en general, no es un obstáculo el aspecto computacional para el ajuste de algunos modelos. Uno de los ambientes computacionales de uso y difusión creciente en los ámbitos académicos es el ambiente R (R Core Team, 2016). El R es un ambiente estadístico de acceso libre y gratuito, y, además, de gran potencial y capacidad para el desarrollo de “paquetes”

orientados a aplicaciones específicas de la estadística, abarcando una multiplicidad de disciplinas. Paquetes en R como el `nlme` (Pinheiro *et al.*, 2014), `lme4` (Bates *et al.*, 2014), `mgcv` (Wood, 2006, 2011) y `gamlss` (Rigby y Stasinopoulos, 2005), entre otros, permiten el manejo de modelos lineales mixtos, modelos lineales generalizados mixtos, modelos aditivos generalizados mixtos, y modelos aditivos generalizados de localización, escala y forma. No obstante, la facilidad al acceso operativo del ajuste de modelos complejos hace necesario evaluar si la mayor complejidad incorporada a un modelo produce mejoras sustanciales frente a los más sencillos. Asimismo, debe asegurarse que los resultados obtenidos utilizando métodos estadísticos más actuales provean elementos para realizar interpretaciones útiles al objeto de estudio.

Existe una amplia gama de metodologías potenciales para el análisis estadístico de los ELDA, pero que no han sido aplicadas a casos particulares y, menos aún, estudiadas, evaluadas, comparadas o detalladas explícitamente. Si bien a través de los ELDA se ha generado una gran cantidad de información relevante, que ha sido en gran parte analizada y publicada, los desarrollos de nuevas metodologías estadísticas no convencionales y la gran capacidad computacional existente y accesible hoy, permitirían re-analizar aquellos datos experimentales con los recursos actualmente disponibles. Esto permitiría revisar y re-evaluar determinados ELDA en sus aspectos de diseño y de análisis estadístico con la ayuda de nuevas herramientas y, además, hacer comparaciones con lo realizado a la fecha. En consecuencia, podría generarse información que validara lo hecho y/o, de ser necesario, permitiera proponer modificaciones a futuro. Eventualmente, podrían darse recomendaciones para la adaptación del diseño, marco fundamental para la obtención de datos confiables. De esta forma, podría, o bien mejorarse la posibilidad de logro de los objetivos originales, o bien adaptarse a posibles nuevos objetivos. Con ello se justificaría su continuidad futura y, al mismo tiempo, se propondrían formas alternativas de análisis de datos que resultaran superadoras de las clásicamente aplicadas.

Por otro lado, no hay metodologías de análisis estadístico sistematizadas para los ELDA. Si bien no sería posible ni se pretendería una sistematización completa, a partir la evaluación de técnicas estadísticas alternativas y de paquetes computacionales actuales, podría proponerse la estandarización de algunos aspectos o bien establecerse alguna guía para el análisis estadístico de los ELDA. Asimismo, la falta de claridad o de detalle en la exposición de algunas

de las metodologías estadísticas existentes, hace que el acceso a su aplicación por parte de los investigadores tenga cierto grado de dificultad, al igual que la interpretación de los resultados obtenidos. La implementación u operatoria de dichas metodologías es muchas veces otro obstáculo. Existe una gran variedad de programas estadísticos que podrían ser utilizados y que, de hecho, se utilizan. No obstante, no hay ninguno que se estructure siguiendo específicamente las necesidades de los análisis de los datos generados en experimentos con las características de los ELDA y que acompañen completamente las metodologías de análisis estadísticos apropiadas o sugeridas para ellos. Se plantea entonces como de gran utilidad para los investigadores del área, la disponibilidad de lineamientos básicos o de una guía metodológica para el diseño y análisis estadístico de algunas situaciones frecuentes en la ciencia del suelo y/o en el estudio del comportamiento de los cultivos. Esto podría permitir desarrollar a futuro una plataforma computacional orientada a una operatividad simplificada de los análisis de los ELDA.

### **1.3 Objetivos**

#### **Objetivo general**

Se propone evaluar métodos alternativos para el análisis estadístico de los datos provenientes de ELDA con diferentes sistemas de cultivo. Con ello, se pretende elaborar alguna guía de los métodos de análisis estadísticos más adecuados, de acuerdo con las particularidades de cada ensayo y la naturaleza de las variables estudiadas, junto con una herramienta operativa computacional para realizarlos. Asimismo, se propone revisar los diseños comúnmente utilizados en dichos ELDA, identificando sus ventajas y desventajas, a fin de elaborar, eventualmente, recomendaciones para mejoras a futuro y pautas para nuevos ensayos.

#### **Objetivos particulares**

Los objetivos particulares de este trabajo, referidos a los ELDA con diferentes sistemas de cultivo, son:

1. Proponer alternativas metodológicas para el análisis estadístico de datos, basadas en modelos que contemplen las características particulares de cada variable

respuesta, diferentes estructuras de efectos fijos, diferentes supuestos sobre efectos aleatorios, y estructuras de correlación, temporal y/o espacial.

2. Facilitar el uso e interpretación de las metodologías de análisis estadístico propuestas, a los investigadores de las áreas de aplicación (agronomía, ciencia del suelo).
3. Evaluar el desempeño de las metodologías estadísticas propuestas en ELDA que consideran distintos tipos de variables bajo diversos sistemas de cultivo y ambientes.
4. Revisar aspectos de los diseños experimentales utilizados en ELDA con distintos sistemas de cultivo y ambientes, a fin de establecer aspectos positivos y limitaciones en los mismos, generando, eventualmente, recomendaciones para mejoras a futuro y/o para el inicio de nuevos ELDA.
5. Orientar a una operatividad simplificada de los análisis estadísticos de los datos utilizando el ambiente computacional R, sentando bases para el desarrollo de una plataforma computacional específica para los ELDA con distintos sistemas de cultivo y ambientes (ej. Desarrollo de funciones o un paquete en R).

#### **1.4 Organización del trabajo**

Este trabajo de tesis se organiza en nueve capítulos. En el presente Capítulo se introduce al tema y se plantean los objetivos del trabajo. En el Capítulo 2 se presentan y caracterizan los ensayos de larga duración en agricultura de Agramunt, Catalunya, España, y del Sudeste de la provincia de Buenos Aires (Sudeste Bonaerense), Argentina. En el Capítulo 3 se presentan los aspectos generales y teóricos de los modelos estadísticos en los que se basan las alternativas de análisis propuestos para algunas variables medidas en los ELDA descriptos. En los Capítulos 4 y 5 se aplican los análisis propuestos en forma exhaustiva a la variable contenido de nitrógeno mineral en el suelo (CN) en el ensayo de Agramunt. En el Capítulo 6 se analizan aspectos de diseño para los ensayos del Sudeste Bonaerense y se proponen alternativas de análisis de la variable contenido de carbono orgánico del suelo (COT). En el Capítulo 7 se dan las bases para la implementación computacional de los análisis en el ambiente computacional

R. Finalmente, en el Capítulo 8 se presenta la discusión general y en el Capítulo 9 las conclusiones del trabajo.



## **2. CAPÍTULO 2. DESCRIPCIÓN DE LOS ENSAYOS Y VARIABLES**

### **2.1 Introducción**

En este capítulo se presentan y describen los ELDA que son utilizados en los capítulos siguientes para ilustrar los análisis estadísticos que se proponen y la evaluación de los aspectos del diseño experimental que se discuten. Las denominaciones utilizadas para referir a los ensayos son las utilizadas comúnmente por el grupo de investigación que los lleva adelante.

### **2.2 Ensayos en el Valle del Ebro Oriental, España**

En las comarcas de la Segarra y l'Urgell, Catalunya, y en la Comunidad de Aragón, España, hay ocho ELDA conducidos y gestionados por los Grupos de Investigación "Agronomía y Medio Ambiente en Sistemas Agrícolas Mediterráneos" del Departament de Producció Vegetal i Ciència Forestal, Universitat de Lleida y "Grupo de Física de Suelos" del Departamento de Suelos y Agua de la Estación Experimental Aula Dei del Consejo Superior de Investigación Científica de España. Los de mayor antigüedad fueron iniciados hace 12, 21, 27 y 30 años y prueban, prioritariamente, diferentes manejos de suelo y/o tipos de fertilización. Los ELDA de inicio más reciente, desde el año 2010 al año 2013, son ensayos destinados al estudio de dosis y tipos de fertilización y de sistemas de riego por aspersión. Uno de los ensayos de mayor antigüedad y que se analiza en esta Tesis, es presentado a continuación.

#### **2.2.1 Ensayo de Sistemas de Manejo de Suelos**

El objetivo general en este ensayo es demostrar que sistemas de laboreo de conservación como la siembra directa, son más adecuados agronómica, ambiental y económicamente para las zonas mediterráneas del valle del Ebro (Cantero-Martínez, C., com. pers., 2016).

Los objetivos particulares son: 1) cuantificar el rendimiento y la biomasa del cultivo bajo diferentes sistemas de manejo de suelo (laboreos o labranzas), 2) cuantificar la economía (productividad del agua), obtener datos de eficiencia de uso del agua bajo diferentes laboreos, 3) cuantificar la dinámica de nitrógeno (N) mineral (CN) del suelo para obtener datos de

eficiencia de uso del N bajo diferentes laboreos. Asimismo, es de interés analizar y detectar si los tratamientos que involucran sistemas de laboreo han generado diferencias en la dinámica de agua y CN del suelo por profundidades (i.e. distintas capas de suelo), estudiando también la interacción entre profundidades y sistemas de laboreo a lo largo de todo el período.

El ensayo ubicado en la localidad de Agramunt (41° 48' 33.6" N, 1° 7' 2.3" E, 352 msnm, Fig. 2.1.) se inició en la campaña 1990-1991, bajo un diseño en bloques completos aleatorizados con cuatro bloques. El factor de tratamiento es el sistema de laboreo y sus niveles son: Siembra directa (SD), Subsulado profundo, Chisel, Arado de vertedera. El sistema de laboreo SD es considerado un sistema de laboreo de conservación mientras los otros tres son considerados sistemas de laboreo intensivo. El sistema denominado "Arado de vertedera" consistió en la utilización del arado de vertedera (30-35 cm de profundidad) más uno o dos pasadas de cultivador de campo (15 cm de profundidad) en septiembre. El sistema "Chisel" consistió en una pasada con un arado de cincel (20 cm de profundidad) antes de la siembra de los cultivos. El "Subsulado profundo" se llevó a cabo en agosto a profundidades de 40-50 cm con un subsolador de brazos rígidos. Tanto en "Chisel" como en "Subsulado profundo" las operaciones se completaron con una sola pasada de cultivador de campo cuando las condiciones del suelo eran apropiadas para la siembra. En SD, los cultivos fueron sembrados sin laboreo (apertura del surco de siembra si disturbar el resto de la superficie del suelo) después de que las parcelas hubieran sido rociadas con herbicida. En algunos años, se usó un rodillo para romper terrones y promover la germinación en todos los sistemas en que se empleara alguno de los tipos de laboreo intensivo. En 2011-12 se incluyó el factor fertilización con N en vegetación con un diseño en parcelas divididas. Cada parcela (unidad experimental) es de 50 m x 9 m (450 m<sup>2</sup>).

En la Fig. 2.1. puede apreciarse una imagen satelital del ensayo en la cual se ven delimitadas las parcelas. El sitio se caracteriza por un clima mediterráneo templado continental (Papadakis, 1966) de pluviometría media anual entre 400-450 mm, con una evapotranspiración potencial media anual de 855 mm y una temperatura media anual de 13.8 °C. El suelo es un Xerochrept Típico (Soil Survey Staff, 2014) de textura franco arcillo limoso y con una profundidad efectiva de 90 cm. El carbono orgánico de suelo es de 7.6 g kg<sup>-1</sup> (Lampurlanés *et al.*, 2016), lo que equivale aproximadamente a 30 Mg ha<sup>-1</sup> de carbono orgánico en el suelo en los 30 primeros cm (Cantero-Martínez, com. pers., 2017).

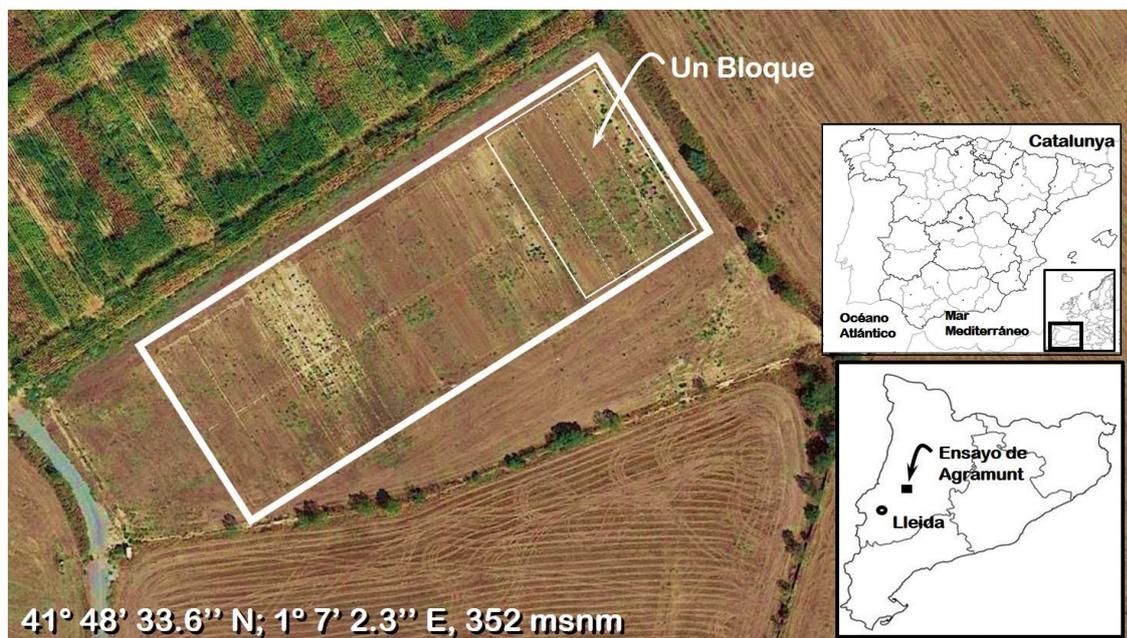


Fig. 2.1. Imagen satelital (Google Maps) del Ensayo de Sistema de Manejo de Suelos en Agràmut y ubicación geográfica de Agràmut en Catalunya, España.

Hay disponibilidad de datos de variables de suelo desde la campaña 1995-96 a la 2014-15, en tres profundidades (0-30 cm, 30-60 cm, 60-90 cm). En cada año se realizaron tres muestreos de suelo. Las variables registradas por profundidad son, contenido de agua por gravimetría (humedad gravimétrica), contenido de agua expresado en volumen (humedad volumétrica), densidad aparente, CN. Las tres fechas de muestreo en cada año corresponden a tres de las estaciones del año: septiembre u octubre (otoño en el hemisferio norte), enero o febrero (invierno en el hemisferio norte), junio o julio (verano en el hemisferio norte) y coinciden con los momentos de pre-siembra, inicio del ahijamiento del cereal y post-cosecha. También se registraron los rendimientos de los cultivos.

En este ensayo los cultivos son: cebada (*Hordeum vulgare* L.), trigo (*Triticum aestivum* L.) y triticale (*Triticosecale* Wittm.) en diferentes años. Desde el inicio del ensayo en 1990-1991 hasta 1999-2000 se cultivó solo cebada, luego se siguió con un año con trigo y a continuación otro año con cebada, repitiendo el esquema hasta 2006-2007 (Cantero-Martínez *et al.*, 2007), en 2007-2008 se cultivó triticale, y luego en cada año hasta la actualidad hubo solo cebada o trigo o tricale (Lampurlanés *et al.*, 2016).

### **2.3 Ensayos en el Sudeste Bonaerense, Argentina**

En la Unidad Integrada Balcarce se llevan o se han llevado adelante cuatro ensayos de larga duración (tres activos actualmente). Los mismos son gestionados por el Grupo de Investigación “Manejo Sustentable del Suelo” de la Facultad de Ciencias Agrarias, Universidad Nacional de Mar del Plata que integra el Grupo “Gestión Ambiental y Recursos Naturales” del Instituto Nacional de Tecnología Agropecuaria. Estos ensayos son descriptos a continuación.

Los objetivos generales de estos ELDA son (Studdert, G.A., com. pers., 2016): 1) evaluar la dinámica de parámetros físicos, químicos y biológicos del suelo bajo combinaciones de cultivos (rotaciones mixtas, agricultura continua, uso de cultivos puente verde) y sistemas de laboreo contrastantes y fertilización nitrogenada; 2) determinar el efecto de sistemas de cultivo contrastantes sobre el comportamiento de cultivos importantes del área de influencia de la Unidad Integrada Balcarce; 3) identificar combinaciones de prácticas de manejo (laboreo, combinación de cultivos, fertilización nitrogenada) conducentes a asegurar la sostenibilidad del sistema de producción.

Los ensayos ubicados en Balcarce (37° 45' 11.4" S; 58° 17' 49.7" O, 138 msnm, Fig. 2.2.) se hallan sobre un complejo de Argiudol Típico (Soil Survey Staff, 2014) y Argiudol Petrocálcico (Soil Survey Staff, 2014) (con el horizonte petrocálcico por debajo de los 70 cm de profundidad (INTA, 1979)). La textura del horizonte superficial es franca y el sitio no presenta problemas serios de erosión. El clima es clasificado como mesotermal sub-húmedo a húmedo según la clasificación de Thornthwaite. La mediana de la precipitación anual, la media de evapotranspiración potencial anual y el promedio de la temperatura media diaria del aire fueron 939 mm, 947 mm y 13.9 °C, respectivamente (Moreno *et al.*, 2016).

Los ELDA ubicados en Balcarce, Sudeste Bonaerense, son denominados: Ensayo de Agricultura Continua, Ensayo de Secuencias Agrícolas y Sistemas de Laboreo, Ensayo de Sistemas de Laboreo, y Ensayo de Rotaciones Mixtas y Sistemas de Laboreo. En la Fig. 2.2. puede apreciarse una imagen satelital de los mismos (Studdert, G.A., com. pers., 2017).

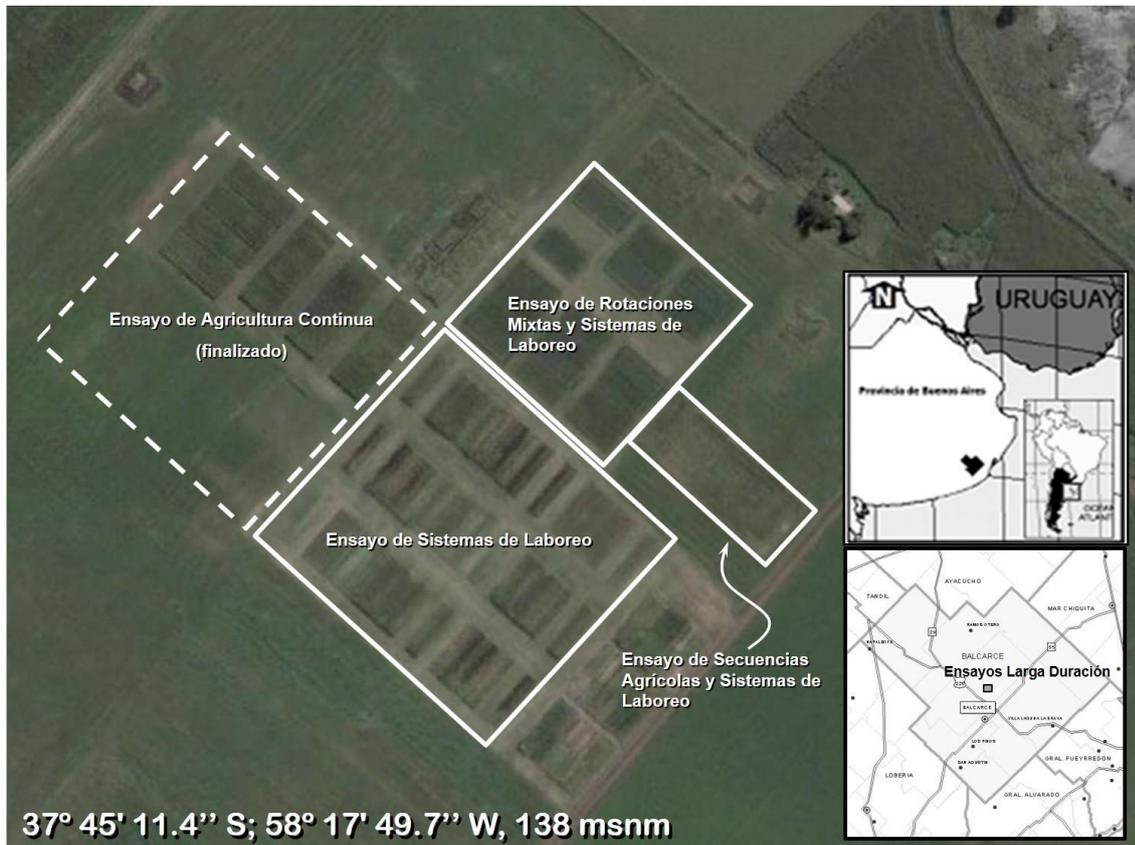


Fig. 2.2. Imagen satelital (Google Maps) de los ensayos de larga duración en Balcarce, su ubicación relativa en Balcarce y ubicación geográfica de Balcarce en la provincia de Buenos Aires, Argentina.

### 2.3.1 Ensayo de Agricultura Continua

Este ensayo (Fig. 2.2) estuvo activo entre los años 1984 y 1996. Los factores de tratamiento involucrados fueron: 1) secuencia de cultivos, se generaron dieciséis secuencias de cultivos con período de tres años, los cultivos intervinientes fueron cuatro, los más comunes en la zona en ese momento, trigo, maíz (*Zea mays* L.) y girasol (*Helianthus annuus* L.) y un cultivo poco difundido en la región en aquella época, la soja (*Glycine max* (L.) Merr.) (Tabla 2.1.); 2) fertilización nitrogenada en los cultivos de trigo y maíz con dosis que fueron variando en el tiempo, los niveles fueron con y sin fertilización. El sistema de laboreo empleado fue siempre convencional (LC: arado de vertedera, rastra de discos, rastra de dientes y/o vibro cultivador). El diseño fue en bloques divididos con cuatro repeticiones, y de cada una de las secuencias se realizaron cuatro ciclos, es decir se repitieron cuatro veces en el tiempo (Studdert y Echeverría, 2000).

Tabla 2.1. Secuencias de cultivos probadas en el ensayo de agricultura continua entre los años 1984 y 1996.

Secuencias iniciadas con			
Maíz (M)	Soja (S)	Girasol (G)	Trigo (T)
MMT	SMT	GMT	TMT
MST	SST	GST	TST
MGT	SGT	GGT	TGT
MTT	STT	GTT	TTT

Se cuenta con información archivada de los rendimientos de los cultivos y de los contenidos de carbono orgánico del suelo (COT) resultantes del análisis de muestras de suelo tomadas previo a la siembra de los cultivos.

### 2.3.2 Ensayo de Secuencias Agrícolas y Sistemas de Laboreo

Este ELDA (Fig. 2.2) con sistemas de laboreo para distintas secuencias de cultivos en un esquema de agricultura continuada, fue iniciado en el año 2005 sobre un suelo que había estado bajo pastura con base de gramíneas por más de cinco años. Los factores de tratamiento que intervienen en el ensayo y sus niveles son: 1) sistema de laboreo: SD, LC; 2) secuencias de cultivos: a) maíz-maíz-trigo, b) soja-soja-trigo, c) maíz-soja-trigo. La particularidad de este ensayo es que cada fase de cada secuencia se encuentra representada cada año y, además, cada fase está presente en dos bloques cada año. En el otoño de cada año desde 2005 se han tomado muestras de suelo de la capa arable (0-5 cm y 5-20 cm de profundidad) para la determinación del contenido de COT, y del carbono orgánico particulado (COP) y densidad aparente. Se dispone de información de rendimiento de los cultivos y de las tres variables de suelo para todos los años.

### 2.3.3 Ensayo de Sistemas de Laboreo

Este ELDA (Fig. 2.2) con sistemas de laboreo y una única secuencia de cultivos, fue iniciado en el año 1997. La secuencia de cultivos establecida es maíz-girasol-trigo y cada fase de la secuencia está presente cada año. Los factores de tratamiento que intervienen en el ensayo y sus niveles son 1) sistema de laboreo: a) SD, b) LC, c) bajo cubierta con herramientas de disco (rastra de discos liviana y rastra de dientes y/o vibrocultivador o cultivador de campo), d) bajo cubierta con herramientas de laboreo vertical (arado de cinceles y vibrocultivador o cultivador de campo), y e) combinada (SD para girasol y maíz y LC para trigo); 2) fertilización nitrogenada: 0 y 120 kg N ha<sup>-1</sup>; 3) Cultivo de cobertura: sin Vicia y con Vicia (a partir de 2006). En el otoño de cada año desde 1997 se han tomado muestras de suelo de la capa arable (0-5 y 5-20 cm de profundidad) para determinación de contenido de COT, COP y densidad aparente. Desde el año 2006 en adelante y cada tres años se han realizado determinaciones de propiedades físicas (resistencia mecánica a la penetración, estabilidad de agregados, tasa de infiltración) de la capa arable. Se cuenta con información archivada de rendimientos de los cultivos, COT y COP (algunos años) y de las propiedades físicas mencionadas (desde 2006 en adelante y para algunas unidades experimentales).

### 2.3.4 Ensayo de Rotaciones Mixtas y Sistemas de Laboreo

Este ELDA (Fig. 2.2) fue iniciado en el año 1976 y continúa vigente. Se denomina de rotaciones mixtas porque rotan cultivos agrícolas y pasturas con base de gramíneas e incluyendo leguminosas. Desde su inicio y hasta el año 1993, el sistema de laboreo en este ensayo fue LC y las rotaciones realizadas fueron (Tabla 2.2.):

- a) Tres ciclos de: 2 años pastura / 4 años agricultura,
- b) Cuatro años de pastura / 4 años de agricultura / 5 años de pastura / 5 años de agricultura,
- c) Dos años de agricultura / 2 años de pastura / 7 años de agricultura / 2 años de pastura / 5 años de agricultura,
- d) Seis años de agricultura / 4 años pastura / 8 años de agricultura,
- e) Dos años de pastura / 6 años de agricultura / 2 de años pastura / 8 años de agricultura,

- f) Dieciséis años de agricultura / 2 años pastura,
- g) Agricultura continua.

A partir de 1994 se introdujo la variable sistema de laboreo (SD y LC) y los factores de tratamiento (con sus niveles) resultantes son: 1) rotación: a) pastura permanente, b) agricultura permanente, c) 50% del tiempo (3 años consecutivos) bajo agricultura y 50% del tiempo (3 años consecutivos) bajo pastura, d) 75% del tiempo (9 años consecutivos) bajo agricultura y 25% del tiempo (3 años consecutivos) bajo pastura; 2) sistema de laboreo: SD y LC (cada rotación, excepto la pastura permanente, se realiza con cada uno de estos sistemas de laboreo); 3) fertilización nitrogenada: cuatro dosis de fertilizante nitrogenado (0, 60, 120, y 180 kg N ha<sup>-1</sup>) en los cultivos agrícolas. La secuencia de cultivos establecida para los períodos bajo agricultura es maíz-soja-trigo. Las combinaciones de las rotaciones y los dos sistemas de laboreo dan siete sistemas de cultivo (Tabla 2.3.) las cuales se asignaron a las parcelas de acuerdo con la rotación previa (Tabla 2.2.). A partir de 1994 el ensayo se constituyó en un diseño en bloques con parcelas divididas, los siete sistemas de cultivo (Tabla 2.3.) en las parcelas principales y los niveles de fertilización en las subparcelas, en los 3 bloques preexistentes. En el otoño de cada año desde 1994 se han tomado muestras de suelo de la capa arable (0-5 cm y 5-20 cm de profundidad) para la determinación de los contenidos de COT y COP y de la densidad aparente. También se realizaron determinaciones de propiedades físicas del suelo (resistencia mecánica a la penetración, estabilidad de agregados, tasa de infiltración) de la capa arable a partir del año 2000 y cada tres años. Se cuenta con información archivada de rendimientos de los cultivos, contenidos de COT y COP en la capa arable en varios de los años entre 1976 y 1993, todos los años entre 1994 y 2006 y cada tres años entre 2006 y 2012.

Tabla 2.2. Esquema de las rotaciones en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo entre 1976 y 1993 y los sistemas de cultivo (SC) con el que continuó a partir de 1994.

Rotación	Año													SC a partir de 1994										
	1976	1977	1978	1979	1980	1981	1982	1983	1984	1985	1986	1987	1988		1989	1990	1991	1992	1993					
A	Pp		P	T	A	P	T	Pp		P	T	A	P	T	Pp		P	T	A	P	T	Pp		
B	Pp				P	M	T	A	G	Pp							P	T	M	G	T	3 años Pp + 3 años agric LC (50%SD)		
C	T	A	G	Pp		P	M	T	A	G	T	A	G	T	Pp		P	T	P	T	M	3 años Pp + 3 años agric SD (50%SD)		
D	T	A	G	P		M	T	A	G	Pp				P	T	P	T	M	G	T	G	3 años Pp + 9 años agric LC (75%LC)		
E	Pp		P		P	M	T	A	G	T	A	G	Pp		P	T	M	G	T	G	T	3 años Pp + 9 años agric SD (75%SD)		
F	P	T	Av	P	T	Av	P	T	Av	P	T	ATr	agric. continua LC (100%LC)											
G	P	T	A	P	T	A	P	T	A	P	T	A	P	T	A	P	T	A	P	T	A	P	T	agric. continua SD (100%SD)

Pp: pastura; P: papa; T: trigo; M: maíz; G: girasol; A: avena; Av: avena + vicia; ATr: avena + trébol rojo; LC: laboreo convencional; SD: siembra directa

Tabla 2.3. Esquema de los sistemas de cultivos (SC) en el ensayo de Rotaciones Mixtas y Sistemas de Laboreo entre 1994 y 2017.

SC	Año																								
	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	
Pp																									
50%LC				M	S	T	Pp			M	S	T	Pp			M	S	T	Pp			M	S	T	
50%SD				M	S	T	Pp			M	S	T	Pp			M	S	T	Pp			M	S	T	
75%LC				M	S	T	M	S	T	M	S	T	Pp			M	S	T	M	S	T	M	S	T	
75%SD				M	S	T	M	S	T	M	S	T	Pp			M	S	T	M	S	T	M	S	T	
100%LC	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	
100%SD	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T	

Pp: pastura; M: maíz, S: soja, T: trigo  Laboreo convencional  Siembra directa

## 2.4 Síntesis de los ELDA descriptos

En la Tabla 2.4. se sintetizan algunos aspectos de los ELDA presentados en este Capítulo. Asimismo, es importante destacar que las variables analizadas o consideradas preponderantemente en este trabajo de tesis son: CN en Agramunt y COT en los ensayos del Sudeste Bonaerense.

Tabla 2.4. Síntesis de información sobre los ELDA analizados en este trabajo de Tesis.

Característica	Ensayo				
	Manejo de suelos	Agricultura Continua	Secuencias Agrícolas y Sistemas de Laboreo	Sistemas de Laboreo	Rotaciones Mixtas y Sistemas de Laboreo
Ubicación	Agramunt (41° 48' 33.6" N, 1° 7' 2.3" E, 352 msnm)	Balcarce (37° 45' 11.4" S; 58° 17' 49.7" O, 138 msnm)			
Desde	Año 1990	Año 1984	Año 2005	Año 1997	Año 1976
Hasta	Continúa	Año 1996	Continúa	Continúa	Año 1993 (etapa 1) y continúa (etapa 2)
Duración (a marzo de 2017)	27 años	12 años	12 años	20 años	41 años
Factores de Tratamientos	- SL (4 niveles) - FN (desde el año 2011, 2 niveles)	-Secuencias de tres cultivos (trigo, maíz, girasol, soja, 16 niveles) - FN	-Secuencias de cultivos (trigo, maíz, soja, 3 niveles) - SL (2 niveles)	- una sola secuencia de cultivos (maíz, girasol, trigo) - SL (5 niveles) - FN (2 niveles) - Cultivo de cobertura (2 niveles)	Etapa 1: - Rotaciones mixtas Etapa 2: - Rotaciones de cultivos (pastura, agricultura, rotaciones mixtas, 4 niveles) - SL (2 niveles) - FN (4 niveles)
Variables de suelo	Humedad en peso y en volumen, DA, CN	COT	COT, COP, DA, resistencia mecánica a la penetración, estabilidad de agregados, tasa de infiltración		
Diseño	Parcelas divididas en bloques (desde 2011).	Bloques divididos	Parcelas divididas en bloques.	Parcelas sub-sub-divididas en bloques.	"Parcelas divididas"(*) en bloques (etapa 2).

SL: sistema de laboreos; FN: fertilización nitrogenada; CN: contenido de nitrógeno del suelo; DA: densidad aparente; COT: carbono orgánico del suelo; COP: carbono orgánico particulado (\*) estrictamente no es parcelas divididas ya que las parcelas con pasturas no son divididas para asignar fertilización.

### 3. CAPÍTULO 3. MODELOS ESTADÍSTICOS

Al momento de analizar los datos provenientes de cualquier ELDA, es claro que deben tenerse muy presentes los objetivos del ensayo y del plan de investigación. A partir de allí, se sugiere plantearse tres preguntas centrales. Ellas son: ¿qué características tienen las variables respuesta que se van a analizar? ¿Cuál es la estructura de los tratamientos y las características del diseño del experimento? ¿Se harán mediciones repetidas sobre la misma unidad experimental? ¿Con qué herramienta computacional se harán los análisis estadísticos? El para qué, con qué y cómo conducirá a generar alternativas de análisis estadístico y a la selección final de los modelos más adecuados con criterios predeterminados.

Muchos de los análisis estadísticos, entre ellos los estándares o clásicos, que se aplican en agronomía están basados en el supuesto de distribución de probabilidad normal para la variable respuesta. Pero no todas las variables de interés en el estudio tienen necesariamente esta distribución. De particular interés pueden ser variables con distribuciones asimétricas. Atendiendo a este aspecto, en la sección 3.1. se muestran distribuciones continuas asimétricas las que pueden ser utilizadas en el modelado de variables tales como el contenido de nitrógeno (N) mineral del suelo (CN). Como la distribución de probabilidad normal es ampliamente conocida, no es descripta particularmente en este trabajo de tesis. En las secciones siguientes se presentan modelos alternativos con diferentes supuestos sobre la distribución de probabilidad de la variable respuesta, comenzando con los de distribución normal. Los modelos son presentados sin detallar los procedimientos de estimación y pruebas de hipótesis.

#### 3.1 Descripción de variables y distribuciones

##### 3.1.1 Variables respuesta: características

Las variables respuesta en un ensayo, como rendimiento, carbono orgánico del suelo (COT), CN, humedad relativa, son variables aleatorias. Las mencionadas, además, son variables aleatorias continuas, pero las hay también discretas o mezclas de ambas. El patrón de distribución de las variables aleatorias está dado por su distribución de probabilidad, aunque esta no siempre es conocida. Por ejemplo, es clásico el supuesto de distribución normal para

el rendimiento de un cultivo o el contenido de carbono orgánico del suelo, pero hay otras variables cuyas distribuciones de probabilidad no se ajustan o no se aproximan a modelos probabilísticos conocidos. Los modelos probabilísticos están determinados por ciertos parámetros, por ejemplo, por la media y la varianza en el caso de una distribución normal. Cuando se estudia cómo una variable es afectada por otras (variables explicativas o predictoras) o cómo se relaciona con otras, lo que se estudia es cómo esos parámetros se modifican por el efecto de las variables predictoras. Por ello, un aspecto importante es poder determinar cuál es la distribución de probabilidad que mejor describe o a la cual se ajusta la variable respuesta.

El CN del suelo, desde el punto de vista estadístico, es una variable continua con un comportamiento, en general, alejado de una distribución normal. El CN es una variable que siempre toma valores positivos y se distribuye de tal forma que valores altos son menos frecuentes que los más bajos (asimetría a izquierda o positiva). En estos casos, la mediana siempre es inferior a la media. La distribución de probabilidad para CN puede ser considerada igual a la de nitrato en el suelo, sobre todo en las condiciones del sitio de Agramunt, donde el contenido de N-amoniaco es muy bajo. Algunos autores proponen para el nitrato en el suelo una distribución gamma o lognormal (Gbur *et al.*, 2012).

A continuación, se presentan estas dos distribuciones que podrían describir al CN y en la sección 3.2.5. se agregan otras que también podrían ser adecuadas.

### **3.1.2 Distribuciones continuas asimétricas**

Entre las distribuciones de probabilidad para variables aleatorias continuas y positivas se encuentran: gamma, Box Cox Cole y Green, potencial exponencial de Box Cox, inversa gaussiana o normal inversa, inversa gaussiana generalizada, lognormal, inversa gamma, Pareto tipo 2, Weibull, t de Box Cox y gamma generalizada (Johnson *et al.*, 1994, Stasinopoulos *et al.*, 2008).

Las distribuciones gamma para variables que toman solo valores positivos quedan determinadas con dos parámetros. Una de las parametrizaciones es la que explicita los parámetros de forma y escala (Johnson *et al.*, 1994) y otras resaltan otras características como

en la expresión de la función de densidad de probabilidad que se presenta a continuación (Stasinopoulos *et al.*, 2008):

$$f_Y(y|\mu, \sigma) = \frac{1}{(\sigma^2\mu)^{1/\sigma^2}} \frac{y^{(1/\sigma^2)-1} e^{-y/(\sigma^2\mu)}}{\Gamma(1/\sigma^2)} \quad (3.1)$$

para  $y > 0$ ,  $\mu > 0$ ,  $\sigma > 0$ , donde,  $\mu$  es la esperanza o valor medio de la variable  $Y$ ,  $\sigma$  es el coeficiente de variación y por lo tanto la varianza es  $\sigma^2\mu^2$ . En la expresión (3.1) el parámetro de forma es  $1/\sigma^2$  y el parámetro de escala es  $\sigma^2\mu$ . Así, se observa que la varianza de la variable  $Y$  depende de su valor medio, de tal forma que, a mayor media, mayor varianza.

En la Fig. 3.1. pueden observarse los gráficos de las funciones de densidad (3.1.) para distribuciones gamma, correspondientes a diferentes valores, arbitrarios, de  $\mu$  y  $\sigma$ . Por ejemplo, se observa que, si  $\sigma = 1$  y en consecuencia el parámetro de forma es 1, la distribución gamma se reduce a la distribución exponencial (gráficos en la segunda columna de Fig. 3.1.). En los casos donde el parámetro de forma es 1, el parámetro de escala coincide con la media y es el único caso en que la forma de la distribución es de "J" invertida.

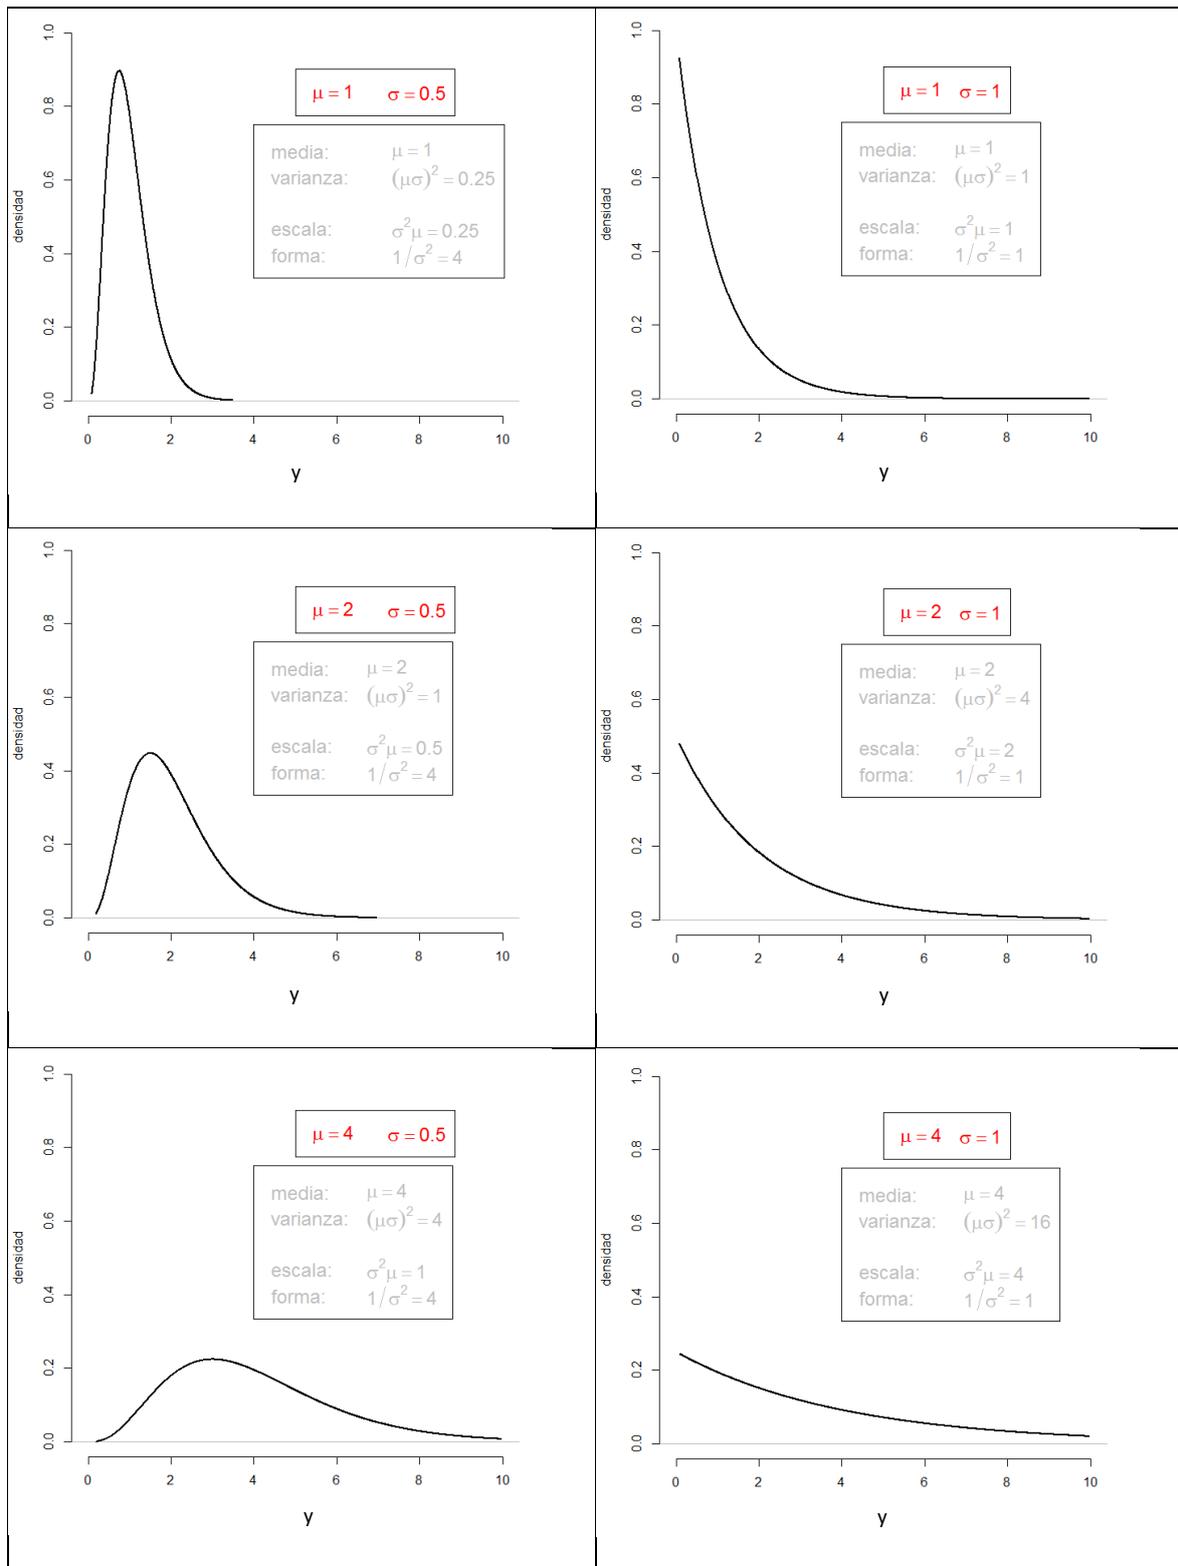


Fig. 3.1. Funciones de densidad de distribuciones gamma según (3.1.) para algunos valores de los parámetros  $\mu$  y  $\sigma$ .

Una variable lognormal puede caracterizarse por dos parámetros,  $\mu$  y  $\sigma$ , siendo su función de densidad de probabilidad (Stasinopoulos *et al.*, 2008):

$$f_Y(y|\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \frac{1}{y} e^{-\frac{[\log(y)-\mu]^2}{2\sigma^2}} \quad (3.2)$$

Para  $y > 0$ ,  $\mu > 0$ ,  $\sigma > 0$ . Aquí, la esperanza de la variable  $Y$  es  $\omega^{1/2}e^\mu$  y la varianza es  $\omega(\omega - 1)e^{2\mu}$ , donde  $\omega = e^{\sigma^2}$ . Puede observarse que la media y la varianza están relacionadas. También puede apreciarse desde la ecuación 3.2 que el  $\log(y)$  (logaritmo natural de  $y$ ) tiene distribución normal con media  $\mu$  y varianza  $\sigma^2$ . Por ejemplo, si en la escala logarítmica la variable lognormal tiene media 0 y varianza 1, es decir sigue una distribución normal estándar, en la escala original la media es  $e^{1/2} = 1.65$  y la varianza es  $e(e - 1) = 4.67$ .

En la Fig. 3.2. pueden observarse los gráficos de las funciones de densidad (3.2.) para distribuciones lognormal correspondientes a diferentes valores, arbitrarios, de  $\mu$  y  $\sigma$ .

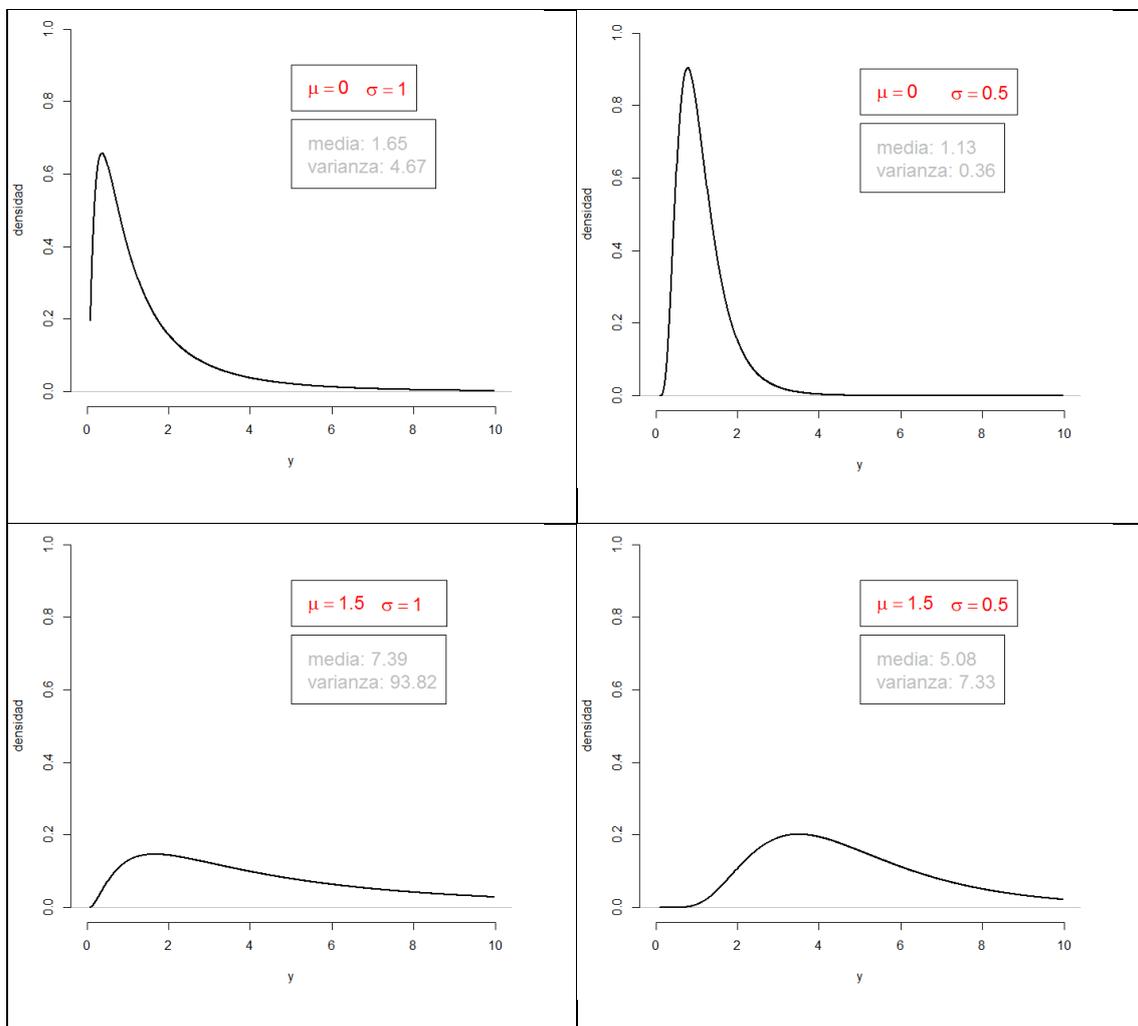


Fig. 3.2. Funciones de densidad de distribuciones lognormal según (3.2.) para algunos valores de los parámetros  $\mu$  y  $\sigma$ .

### 3.1.3 ¿Cómo identificar la distribución de una variable?

¿Cómo evaluar si una distribución se ajusta a los datos que se tienen? ¿Puede hacerse? ¿Puede determinarse la mejor distribución que se ajuste a nuestros datos? Debe tenerse cuidado en la aplicación de técnicas y su interpretación. En un conjunto de datos donde se ha medido una variable, en general hay varias poblaciones (en el sentido estadístico) presentes, con igual tipo de distribución, pero que pueden diferir en, por lo menos, alguno de sus parámetros. Esto último es lo que quiere probarse. Es por ello que, para evaluar cuál es la distribución de la variable, no puede ignorarse la existencia de grupos, y habitualmente el diagnóstico de la distribución se hace en base a los residuos de los modelos ajustados.

Ejemplo: Sean dos variables normales, de la misma naturaleza como, por ejemplo, los rendimientos de un mismo cultivo, pero en dos ambientes. Las variables y sus distribuciones se pueden expresar como  $y_A \sim N(\mu_A, \sigma_A^2)$  y  $y_B \sim N(\mu_B, \sigma_B^2)$ , donde A y B corresponden a los dos ambientes,  $y_A$  es el rendimiento del cultivo en el ambiente A e  $y_B$  es el rendimiento del cultivo en el ambiente B. Puede ser que ambas distribuciones no difieran en sus dos parámetros ( $\mu_A = \mu_B, \sigma_A^2 = \sigma_B^2$ ) o difieran por lo menos en uno.

Si las varianzas son iguales, es decir  $\sigma_A^2 = \sigma_B^2 = \sigma^2$ , las variables que surgen a partir de las diferencias de cada variable original y su media,  $y_A - \mu_A$  y  $y_B - \mu_B$ , tienen la misma distribución entre sí con iguales parámetros, es decir, se tiene la misma variable con distribución  $N(0, \sigma^2)$ . En cambio, si las varianzas son distintas, es decir  $\sigma_A^2 \neq \sigma_B^2$ , la sola diferencia entre cada variable original y su media no genera una única variable, sino que siguen siendo dos, cada una con media cero, pero conservando su varianza (Fig.3.3.).

La idea de descontar de la variable su valor medio es la utilizada en algunos modelos para evaluar los supuestos realizados, en particular los supuestos sobre distribución y homogeneidad de varianzas. En modelos que solo consideran diferencias en las medias de las distribuciones como los modelos lineales generales con supuesto de distribución normal en los errores e igualdad de varianzas. Así surgen como herramientas de diagnóstico los llamados residuos o residuales del modelo. Esto resulta útil particularmente en ensayos diseñados, en los cuales la cantidad de datos en cada grupo en los cuales es clasificada la variable respuesta no es suficiente para decidir sobre la concordancia a un modelo probabilístico considerando un grupo por vez.

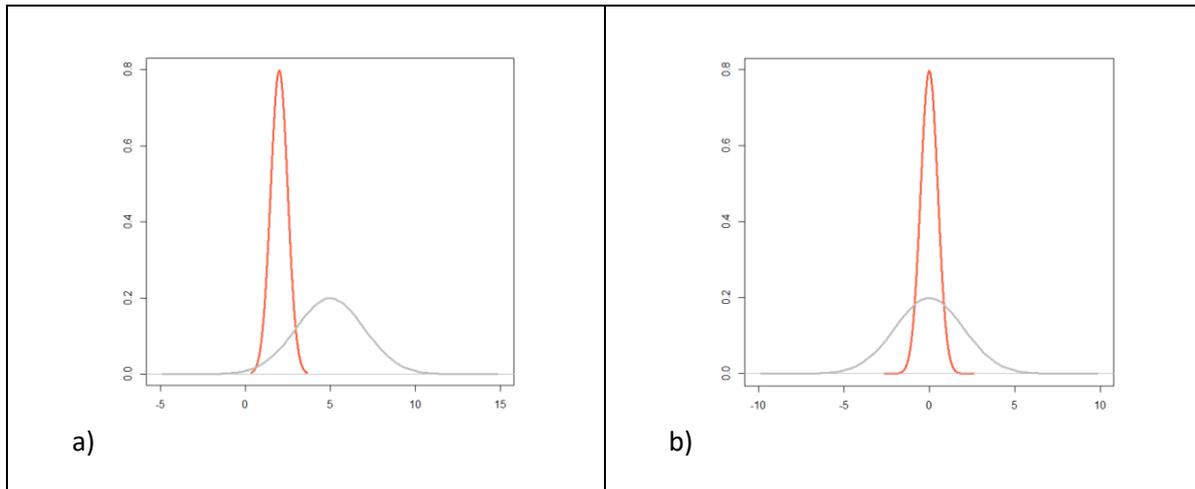


Fig. 3.3. (a) Distribuciones normales con diferentes varianzas y medias ( $N(2,0.5)$  curva naranja y  $N(5,2)$  curva gris). (b) Distribuciones de las diferencias de cada variable en a) respecto a su media.

En los casos de las distribuciones asimétricas, como la gamma y la lognormal, además hay que tener otros cuidados. Como se observó anteriormente, en ambas distribuciones, la media y la varianza están relacionadas. En el caso particular de la lognormal si se transforma la variable a través del logaritmo, se pueden aplicar los mismos mecanismos que para variables normales, ya que, como se dijo antes, el logaritmo de una lognormal es normal. Pero en términos generales, los análisis para diagnósticos de la distribución de probabilidad, además de la validación de otros supuestos, se realizan tomando como herramienta básica los residuales apropiados en cada modelo ajustado. A partir de diversos gráficos y de medidas resumen de dichos residuos puede considerarse la necesidad de utilizar alguna otra distribución (diferente de la normal) para caracterizar los datos. Algunas veces, en dichos gráficos se evidencian patrones de variación o ciertas características en los residuos que ayuda en la consideración de posibles distribuciones a utilizar.

### **3.2 Modelos estadísticos para el análisis: Especificaciones, supuestos, interpretaciones**

En muchas ocasiones cuando se tiene el interés de estudiar cómo ciertos factores (variables de clasificación o categóricas) y/o variables cuantitativas afectan o se relacionan con otra variable (variable respuesta) se postulan modelos. Estos modelos plantean la forma en que la variable respuesta cambia o varía respecto a los cambios en los niveles de los factores y/o en los valores de las variables cuantitativas. Tanto estas variables como los factores son llamados variables predictoras o explicativas de la variable respuesta.

Más precisamente estos modelos postulan la forma en que uno o algunos de los parámetros de la distribución de la variable respuesta cambia o cambian en función de las variables explicativas. En definitiva, a través de un modelo podrá reflejarse cómo las variables explicativas modifican la distribución de la variable respuesta.

Así, en la definición del modelo intervendrán:

- a. El supuesto de distribución de probabilidad para la variable respuesta,
- b. La identificación de las variables predictoras que pueden o deben incluirse y cómo incluirlas (i.e. incorporar términos de interacción, términos cuadráticos, etc.)
- c. Algún juicio previo de cómo se relacionan las variables predictoras con los parámetros de la distribución de probabilidad de la variable respuesta.

A partir de un modelo inicial pueden ir complejizándose o simplificándose las expresiones buscando un mejor modelo que explique la respuesta en función de las variables explicativas y/o fuentes de variación.

A continuación, se presentan y describen las características esenciales de algunos modelos que pueden ser utilizados en los análisis de datos provenientes de ELDA, los que son ejemplificados y aplicados particularmente en los Capítulos 4 y 5 a la variable CN del ELDA en el sitio de Agramunt. En dichos capítulos se emplean técnicas de diagnósticos y evaluación de los supuestos de los modelos, se realizan pruebas de hipótesis y aplican métodos de selección de modelos.

### **3.2.1 Modelo lineal general**

Los modelos generales clásicos tienen la siguiente estructura (Schabenberger y Pierce, 2002): variable respuesta = estructura media + error. En particular, los modelos lineales son aquellos que modelan la esperanza o valor medio o promedio poblacional de la variable respuesta como función lineal de las variables explicativas, sean estas, factores y/o variables cuantitativas. El valor medio se expresa como una combinación lineal de otros parámetros que deben ser estimados.

La expresión general del modelo lineal en forma matricial es bien conocida y es la siguiente:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \text{ con } \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}) \quad (3.3)$$

En la expresión (3.3),  $\mathbf{Y}$  es el vector de observaciones de la variable respuesta de longitud  $n$ ,  $\mathbf{X}$  es la matriz de diseño o matriz del modelo de  $n$  filas y  $k$  columnas, cada columna contiene 1 y/o 0 o los valores de una variable predictora cuantitativa y asocia cada observación a los parámetros  $\boldsymbol{\beta}$  correspondientes,  $\boldsymbol{\beta}$  es el vector de parámetros de longitud  $k$ , cuyas componentes corresponden a los efectos de los niveles de los factores y/o los coeficientes de regresión para cada variable predictora cuantitativa y  $\boldsymbol{\varepsilon}$  es el vector de errores de longitud  $n$ , donde cada elemento de dicho vector tiene distribución normal con media 0, varianza  $\sigma^2$  y son independientes unos de otros. De la expresión (3.3) se desprende que  $\mathbf{Y}$  tiene distribución normal con esperanza o media igual a  $\mathbf{X}\boldsymbol{\beta}$  y matriz de varianzas-covarianzas igual a la del vector  $\boldsymbol{\varepsilon}$ , es decir,  $\sigma^2 \mathbf{I}$ . El término  $\mathbf{X}\boldsymbol{\beta}$  en (3.3) es llamado el predictor lineal del modelo.

Los modelos clásicos de regresión lineal simple y múltiple, los modelos de análisis de varianza con efectos principales y/o de interacción y los modelos de análisis de covarianza, entre otros, son casos particulares de estos modelos lineales generales. Hay extensa bibliografía sobre modelos lineales generales y sus aplicaciones, y cubren en forma completa los aspectos de estimación, pruebas de hipótesis y validación de supuestos. No obstante, se presentan tres modelos básicos, para interpretar y remarcar algunos aspectos de los modelos lineales que ayudarán a comprender más adelante modelos más avanzados. Uno de ellos es el modelo de regresión lineal simple y los otros corresponden a modelos con un factor y una variable cuantitativa como variables explicativas.

Así, el modelo lineal básico para la regresión lineal de  $Y$  sobre la variable cuantitativa  $X$  puede expresarse como

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (i = 1, \dots, n) \quad \text{con } \varepsilon_i \sim \text{indep } N(0, \sigma^2) \quad (3.4)$$

Lo que se está diciendo o expresando en (3.4.) es que la media de la variable  $Y$ , cambia linealmente en función de los valores de la variable  $X$ , esto es,  $E(y_i | x_i) = \beta_0 + \beta_1 x_i$ , no se dice que un valor individual de  $Y$  ( $y$ ), cambia linealmente en función de  $X$ , sino su media (para un valor de  $X$  ( $x$ ) en particular), y que los valores  $y$  varían alrededor de esa media con varianza de magnitud  $\sigma^2$ , donde esta varianza es la misma para todos los valores  $x$ . También se supone que los errores  $\varepsilon_i$  tienen distribución de probabilidad normal y son independientes entre sí. Así, cada valor  $x$  determina una población de la variable  $Y$  con distribución normal cuyo valor

medio depende linealmente de  $x$ , pero con varianza común o constante a través de los valores de  $X$ . Otra forma de expresar el modelo (3.4.) es  $y_i \sim indep N(\beta_0 + \beta_1 x_i, \sigma^2)$ , ( $i = 1, \dots, n$ ) y gráficamente se muestra en la Fig. 3.4.

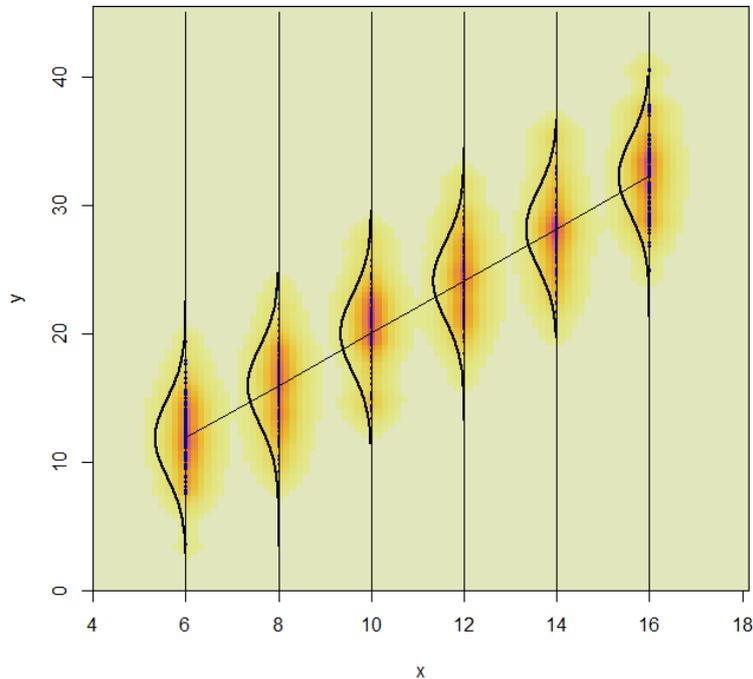


Fig. 3.4. Modelo de regresión lineal (3.4.) y visualización de algunos supuestos con un ejemplo numérico arbitrario. La recta representa a  $E(y_i|x_i) = \beta_0 + \beta_1 x_i$

Supongamos ahora que hay un factor A con dos niveles o categorías, y que sus efectos sobre la variable Y son  $\tau_1$  y  $\tau_2$ , respectivamente, y que hay una variable X que toma valores  $x_{ik}$  en el nivel k del factor. Entonces, un modelo lineal que busca explicar la variable Y en función del factor A y la variable cuantitativa X es

$$y_{ik} = \beta_0 + \beta_1 x_{ik} + \tau_k + \varepsilon_{ik} \quad (i = 1, \dots, n_k, k = 1, 2) \quad \text{con} \quad (3.5)$$

$$\varepsilon_{ik} \sim indep N(0, \sigma^2)$$

En (3.5.) se está expresando que el valor esperado de la variable Y es  $\beta_0 + \beta_1 x_{ik} + \tau_k$ , es decir que el valor esperado de Y depende del valor de la variable X, pero también del nivel del factor con el que se corresponde. El valor esperado de Y cambia linealmente con el valor  $x$ , así ante un cambio unitario en  $x$ , el valor esperado de Y cambia (aumenta o disminuye)  $\beta_1$  unidades, mientras que, para un mismo valor  $x$ , la diferencia entre los valores esperados de Y de los dos niveles del factor es  $\tau_1 - \tau_2$ . Esto puede verse ya que

$$E(y_{i1}|x_{i1}, \tau_1) = \beta_0 + \beta_1 x_{i1} + \tau_1 \quad (3.6)$$

$$E(y_{i2}|x_{i2}, \tau_2) = \beta_0 + \beta_1 x_{i2} + \tau_2$$

Los efectos de los niveles del factor A sólo actúan sobre la ordenada al origen y no sobre la pendiente. En (3.6.) quedan explícitas las ordenadas al origen en cada caso ( $\beta_0 + \tau_1$  y  $\beta_0 + \tau_2$ ).

Si, además, la pendiente cambia según el nivel del factor A, al modelo anterior se le puede incorporar otro término que refleje tal situación, quedando de la siguiente manera:

$$y_{ik} = \beta_0 + \beta_1 x_{ik} + \delta_k x_{ik} + \tau_k + \varepsilon_{ik} \quad (i = 1, \dots, n_k, k = 1, 2) \quad \text{con} \quad (3.7)$$

$$\varepsilon_{ik} \sim \text{indep } N(0, \sigma^2)$$

Y reordenando y asociando algunos términos en (3.7) esto es equivalente a

$$y_{ik} = (\beta_0 + \tau_k) + (\beta_1 + \delta_k) x_{ik} + \varepsilon_{ik} \quad (i = 1, \dots, n_k, k = 1, 2) \quad \text{con} \quad (3.8)$$

$$\varepsilon_{ik} \sim \text{indep } N(0, \sigma^2)$$

En (3.8) puede apreciarse que tanto la ordenada como la pendiente de la regresión de Y sobre X, dependen del nivel del factor en el que esté observada la variable respuesta.

Se ha presentado el modelo lineal general y se han descrito algunos de los más básicos, lo común en todos ellos es que:

- a) Modelan la esperanza o media de la variable respuesta, poniendo a esta en función de las variables o factores bajo estudio.
- b) Esta función de las variables o factores, es una función lineal de los mismos, denominado predictor lineal.
- c) Un valor particular de la variable respuesta está dado por la media más un desvío hacia ella (positivo o negativo), dado por el término de error, el cual se supone con distribución normal, independiente uno de otro y con varianza constante.
- d) De b) y c) se deduce que la variable respuesta también tiene distribución normal.
- e) Excepto el término de error en el modelo, todos los parámetros, efectos de factores o coeficientes de regresión de variables predictivas cuantitativas (ej pendientes) son efectos fijos.

A pesar de la amplia variedad de los modelos lineales generales, estos no cubren todas las situaciones que puedan presentarse. Así, avanzando en alternativas de modelado se

encuentran, por un lado, los modelos lineales mixtos y, por otro, los modelos lineales generalizados. Y, luego la combinación de ambos, los modelos lineales generalizados mixtos. A su vez, otros modelos mucho más flexibles son los modelos aditivos generalizados.

### 3.2.2 Modelo lineal mixto

Los modelos mixtos son usados para describir datos provenientes de experimentos o estudios que necesitan más de un parámetro de varianza-covarianza e involucran algunos parámetros de efectos fijos (Milliken y Johnson, 2009). Tal es el caso de los datos provenientes de experimentos con medidas repetidas, como los ELDA.

En un modelo, un efecto fijo es una constante desconocida, no varía, en cambio, un efecto aleatorio es una variable aleatoria. Los efectos aleatorios surgen desde el submuestreo, la selección aleatoria de niveles de tratamiento, y de procesos aleatorios jerárquicos, es decir datos agrupados. Un modelo de efectos mixtos, tiene algunos efectos fijos y otros aleatorios, sin contar el intercepto y el término de error (Schabenberger y Pierce, 2002).

La expresión general del modelo lineal mixto en forma matricial es bien conocida y es la siguiente:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon} \quad (3.9)$$

$$\text{con } \mathbf{b} \sim N(\mathbf{0}, \mathbf{G}), \quad \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \mathbf{R}) \text{ y } \text{Cov}[\mathbf{b}, \boldsymbol{\varepsilon}] = \mathbf{0}$$

En la expresión (3.9)  $\mathbf{Y}$ ,  $\mathbf{X}$ ,  $\boldsymbol{\beta}$  y  $\boldsymbol{\varepsilon}$  representan los mismos términos que en el modelo lineal general (3.3) y los componentes que se agregan son  $\mathbf{Z}$  y  $\mathbf{b}$ .  $\mathbf{Z}$  representa otra matriz de diseño de dimensión  $n \times q$ , matriz especificada en forma similar que  $\mathbf{X}$  y que asocia cada observación a los efectos aleatorios correspondientes, y  $\mathbf{b}$  es el vector de longitud  $q$  de términos aleatorios (efectos o coeficientes) que se asume con distribución normal de media  $\mathbf{0}$  y matriz de varianzas-covarianzas  $\mathbf{G}$ . Sobre el vector  $\boldsymbol{\varepsilon}$  se asume distribución normal con media  $\mathbf{0}$  y matriz de varianzas-covarianzas  $\mathbf{R}$ . Los términos aleatorios  $\mathbf{b}$  y los de error  $\boldsymbol{\varepsilon}$ , se suponen independientes unos de otros. La matriz  $\mathbf{R}$  se supone  $\sigma^2\mathbf{I}$  cuando se considera que los términos de error (generalmente asociados a la unidad experimental) son independientes y tienen la misma varianza  $\sigma^2$ .

De la expresión (3.9) se desprende que, la distribución condicional de  $\mathbf{Y}$  dado  $\mathbf{b}$  es normal con esperanza o media igual a  $\mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b}$  y matriz de varianzas-covarianzas igual a la del vector  $\boldsymbol{\varepsilon}$ , es decir  $\mathbf{R}$ . La distribución marginal de  $\mathbf{Y}$  es normal con media  $\mathbf{X}\boldsymbol{\beta}$  y matriz de varianzas-covarianzas  $\mathbf{Z}\mathbf{G}\mathbf{Z}' + \mathbf{R}$ . Tanto la estructura de correlaciones como la presencia de varianzas heterogéneas pueden ser especificadas a través de la modelación de las matrices de covarianza  $\mathbf{G}$  y/o  $\mathbf{R}$ .

Los paquetes `nlme` (Pinheiro y Bates, 2000) y `lme4` (Bates *et al.*, 2015) del ambiente computacional R (R Core Team, 2016) ajustan modelos lineales mixtos. En ambos se pueden obtener estimaciones de los efectos fijos, de las matrices de varianzas-covarianzas y los mejores predictores lineales insesgados empíricos (*eblups*) de los efectos aleatorios. El paquete `lsmeans` (Lenth, 2016), del mismo programa estadístico, permite la comparación de medias marginales de modelos ajustados con la función `lme` del paquete `nlme` y también con la función `lmer` del paquete `lme4`.

### 3.2.2.1 Modelo lineal mixto para los diseños con medidas repetidas, un modelo básico

Al igual que los experimentos que utilizan un diseño de parcelas divididas, los experimentos que utilizan diseños de mediciones repetidas involucran más de un tamaño de unidad experimental. Por ejemplo, un sujeto (parcela, animal, árbol, etc.) puede ser medido a través del tiempo y el tiempo es tomado como un factor en la estructura de tratamientos del experimento. Por obtener mediciones u observaciones en el mismo sujeto en varios tiempos, el sujeto esencialmente es dividido en partes, intervalos de tiempo o momentos puntuales, y la variable respuesta es medida en cada parte. Así, la unidad experimental mayor es cada sujeto o colección de intervalos de tiempo. La unidad experimental de menor tamaño, que está incluida en la mayor, es un intervalo de tiempo entre dos tiempos de medición (Milliken y Johnson, 2009).

Los diseños con mediciones repetidas difieren de los de parcelas divididas en que los niveles de uno o más factores no pueden ser asignados aleatoriamente a una o más tamaños de unidades experimentales en el experimento. En este caso, los niveles del tiempo no pueden ser asignados al azar a los intervalos de tiempo, y entonces analizar un experimento de

medidas repetidas como si fuera un experimento de parcelas divididas puede no ser válido. El análisis de un experimento de medidas repetidas como si se tratara de un experimento de parcelas divididas se denomina a menudo un análisis de parcelas divididas en el tiempo (Milliken y Johnson, 2009). No obstante, debido a aquella ausencia o imposibilidad de asignación aleatoria, los errores correspondientes a las unidades experimentales respectivas pueden tener una matriz de varianzas-covarianzas que no se ajusta a la matriz de varianzas-covarianzas correspondiente a los experimentos para los que es válido el análisis usual de parcelas divididas.

Para el caso donde el factor A, con  $a$  niveles, es el factor de tratamiento en un diseño con bloques completos aleatorizados, en el cual se realizan mediciones en  $t$  tiempos en cada parcela, el modelo de mediciones repetidas análogo al de parcelas divididas se describe a continuación en (3.10). Mientras que en las secciones 3.2.2.2 y 3.2.2.3 se presentan formas de análisis más generales, también a través del uso de modelos mixtos. Dado que es común en los ELDA el uso de bloques, se plantea el modelo para esa situación.

$$y_{ijk} = \mu + \gamma_j + \tau_i + b_{ij} + \beta_k + (\tau\beta)_{ik} + \varepsilon_{ijk} \quad i=1, \dots, a \quad j=1, \dots, r \quad k=1, \dots, t$$

con

$$b_{ij} \sim \text{indep } N(0, \sigma_b^2)$$

$$\varepsilon_{ijk} \sim \text{indep } N(0, \sigma_e^2)$$

$b_{ij}$  y  $\varepsilon_{ijk}$  independientes entre sí

donde,  $y_{ijk}$  es la observación de la variable respuesta para el nivel  $i$  del factor A en el bloque  $j$  (en la parcela  $ij$ ) en el tiempo  $k$ ,  $\mu$  es una constante,  $\gamma_j$  es el efecto del bloque  $j$ ,  $\tau_i$  es el efecto del nivel  $i$  de A,  $b_{ij}$  es el efecto (aleatorio) de la parcela  $ij$ , la parcela del bloque  $j$  que recibió o tiene asignado el nivel  $i$  de A,  $\beta_k$  es el efecto del tiempo  $k$ ,  $(\tau\beta)_{ik}$  es el efecto de interacción correspondiente a la combinación del nivel  $i$  de A y el tiempo  $k$ ,  $\varepsilon_{ijk}$  es el error experimental de la parcela  $ij$  en el tiempo  $k$ . El modelo (3.10) es un modelo lineal mixto.

Una forma alternativa más simple de expresar el modelo (3.10) es:

$$\text{variable } y_{ijk} = \text{intercepto} + \text{bloque}_j + A_i + \text{parcela}_{ij} + \text{Tiempo}_k + A:\text{Tiempo}_{ik} + \text{error}_{ijk}$$

$$i = 1, \dots, a \quad j = 1, \dots, r \quad k = 1, \dots, t$$

con  $\text{parcela}_{ij} \sim \text{indep } N(0, \sigma_b^2)$ ,  $\text{error}_{ijk} \sim \text{indep } N(0, \sigma_e^2)$   $\text{parcela}_{ij}$  y  $\text{error}_{ijk}$  independientes entre sí

En el modelo (3.10), en cualquiera de sus expresiones, se indica que, tanto los efectos de parcelas como los errores son aleatorios con distribución normal, con media cero y magnitudes de varianzas de parcela y de error, respectivamente, que no dependen del factor A ni del tiempo, ni de ningún otro factor (supuesto de homogeneidad de varianzas). Los efectos de parcelas y los errores también se suponen independientes entre sí.

De lo anterior se deduce que la esperanza o valor medio de la variable Y en el bloque j, nivel i de A en el tiempo k es:

$$E[y_{ijk}] = \mu + \gamma_j + \tau_i + \beta_k + (\tau\beta)_{ik} \quad (3.11)$$

Y la varianza es:

$$Var[y_{ijk}] = \sigma_b^2 + \sigma_e^2 \quad (3.12)$$

La covarianza entre dos observaciones cualesquiera en tiempos k y k' en una misma parcela, por ejemplo, la parcela ij, es

$$Cov(y_{ijk}, y_{ijk'}) = \sigma_b^2 \quad (3.13)$$

Así, la correlación entre esas dos observaciones está dada por la correlación intraclase (adaptada de Schabenberger y Pierce, 2002):

$$correlación(y_{ijk}, y_{ijk'}) = \frac{\sigma_b^2}{\sigma_b^2 + \sigma_e^2} \quad (3.14)$$

En la expresión (3.14) de la correlación intraclase se observa que si la magnitud de la componente de varianza debida a parcelas,  $\sigma_b^2$ , es pequeña en relación a la varianza total, las observaciones pueden considerarse prácticamente independientes a través del tiempo.

### 3.2.2.2 Modelo lineal mixto para diseños con medidas repetidas y heterogeneidad de varianzas

En el modelo (3.10) se ha supuesto homogeneidad de varianzas, es decir que las varianzas debidas a efectos de parcelas y la debida al error no cambian ni con los niveles de A ni con los diferentes tiempos ni con la interacción entre ambos. También se supone que la varianza debida al error no cambia entre las parcelas. Este supuesto a veces no se cumple, así que pueden postularse y ajustarse modelos con heterogeneidad de varianzas, dada la

disponibilidad operatoria y las capacidades computacionales que permiten la implementación de los métodos de estimación y pruebas de hipótesis adecuadas. Así, la expresión para la media de la variable Y es la misma que en (3.10), pero los supuestos sobre los efectos aleatorios pueden ser alguno de los siguientes, teniendo en cuenta algún tipo de heterogeneidad de varianzas en alguna de las dos componentes o en ambas:

- a) Heterogeneidad a nivel parcela, es decir, varianza debida a parcelas para cada nivel de A o para cada grupo de niveles de A (pueden agruparse los niveles de A por algún criterio). Simbólicamente:

$$b_{ij} \sim N(0, \sigma_{bi}^2) \text{ independientes } \text{ o } b_{ij} \sim N(0, \sigma_{bgAi}^2) \text{ independientes}$$

La expresión  $\sigma_{bi}^2$  indica varianza entre efectos de parcelas para el nivel i de A

La expresión  $\sigma_{bgAi}^2$  indica varianza entre efectos de parcelas para el grupo gAi de niveles de A (la cantidad de grupos de niveles de A es menor a la cantidad de niveles de A)

- b) Heterogeneidad a nivel error, donde puede pensarse la varianza de error dependiente de A (para cada nivel o por grupos) o dependiente del tiempo (para cada nivel o por grupos) o dependiente de la combinación de ambos, o dependiente de las parcelas. Simbólicamente se presentan alguno de los supuestos alternativos mencionados

$$\varepsilon_{ijk} \sim N(0, \sigma_{ei}^2) \text{ independientes (una varianza de error para cada nivel de A) o}$$

$$\varepsilon_{ijk} \sim N(0, \sigma_{ek}^2) \text{ independientes (una varianza de error para cada nivel de tiempo) o}$$

$$\varepsilon_{ijk} \sim N(0, \sigma_{eik}^2) \text{ independientes (una varianza de error para cada combinación de nivel de A con tiempo) o}$$

$$\varepsilon_{ijk} \sim N(0, \sigma_{eij}^2) \text{ independientes (una varianza de error para cada parcela)}$$

No necesariamente debe haber un parámetro de varianza por cada nivel de A o por cada tiempo o cada parcela, puede haber un parámetro de varianza para cada grupo de niveles. Por ejemplo, si el tiempo corresponde a diferentes momentos en un mismo año en varios años, como ocurre con los ELDA, pueden modelarse diferentes varianzas para cada estación del año. Si las varianzas responden a diferentes patrones según grupos de niveles de A, también podrá reducirse el número de parámetros de varianza. Sobre todo, esto toma mayor sentido cuando el número de niveles de A o la cantidad de tiempos hace que la cantidad de parámetros de varianza a estimar sea muy grande si se toma uno por nivel.

### *3.2.2.3 Modelo lineal mixto para diseños con medidas repetidas y estructuras de correlación*

En los experimentos a campo, las autocorrelaciones seriales, espaciales o de otro tipo son típicamente debidas a la ausencia de aleatorización (Schabenberger y Pierce, 2002). En los modelos de mediciones repetidas, los efectos de los sujetos (parcelas) suelen suponerse independientes por el procedimiento de diseño que asignó, al azar, los niveles del factor A a los sujetos y garantizó independencia entre sus efectos. No sucede lo mismo para los términos de error, que en el modelo básico (3.10) se suponen independientes entre sí, pero pueden no serlo, dado que se observa al mismo sujeto en diferentes tiempos. Así que, modelos alternativos son los que incluyen alguna estructura de correlación en los errores.

Hay varias estructuras de correlación implementadas en programas computacionales estadísticos como SAS, R, ASReml, entre algunos de los más relevantes. No obstante, una de las más utilizadas y que ha resultado suficiente, en varias ocasiones, para modelar la correlación entre los errores en ensayos a campo es la correlación autorregresiva de orden 1 (Richter y Kroschewski, 2006). Esta estructura requiere que las mediciones estén tomadas en tiempos (o espacios) equidistantes o equiespaciados. Si no es así, puede utilizarse una generalización de esta estructura, denominada autorregresiva continua de orden 1 (Pinheiro y Bates, 2000), la cual se caracteriza, también, por tener un solo parámetro de varianza-covarianza,  $\rho$ , pero considerando la diferencia entre los tiempos. Así, en ambos casos, la correlación entre errores cercanos en el tiempo es más alta que entre dos alejados.

### **3.2.3 Modelo lineal generalizado y modelo lineal generalizado mixto**

Los modelos lineales generalizados son modelos estadísticos para una familia de distribuciones de probabilidad conocida como la familia exponencial. Esta familia incluye distribuciones como la normal, gamma, chi-cuadrado, beta y normal inversa dentro de las continuas y binomial y Poisson dentro de las discretas (Schabenberger y Pierce, 2002).

En un modelo lineal generalizado, una función de la esperanza de la variable Y es modelada a través de un predictor lineal. Dicha función es llamada la función de enlace o ligadura (g) porque es la que liga o relaciona la esperanza con el predictor lineal. Es decir,

$$g[E(\mathbf{Y})] = \mathbf{X}\boldsymbol{\beta} \quad (3.15)$$

Las funciones de ligadura deben cumplir con determinadas condiciones que no se detallarán aquí. Cada distribución de probabilidad tiene una función de ligadura específica, llamada canónica, que posee propiedades teóricas especiales, aunque también pueden utilizarse otras. La forma que puede tomar el predictor lineal  $\mathbf{X}\boldsymbol{\beta}$  es como la indicada en la sección 3.2.1.

Un modelo lineal generalizado se especifica con tres componentes: 1) distribución de la variable respuesta, 2) predictor lineal, 3) función de ligadura. El modelo lineal general planteado en (3.1) es un caso particular de un modelo lineal generalizado donde la variable respuesta tiene distribución normal, el predictor lineal es  $\mathbf{X}\boldsymbol{\beta}$  y la función de ligadura es la identidad, ya que  $E(\mathbf{Y}) = \mathbf{X}\boldsymbol{\beta}$ .

Ejemplo de un modelo simple: Si Y tiene distribución gamma con media  $\mu$  como en (3.1) y X es una variable cuantitativa regresora, el predictor lineal es  $\beta_0 + \beta_1 x$ , la función de ligadura canónica es la función inversa  $g(\mu) = 1/\mu$ , entonces el modelado de la media es a través de  $1/\mu = \beta_0 + \beta_1 x$ .

Más detalles sobre modelos lineales generalizados pueden encontrarse en varios libros, en particular en los de McCullagh y Nelder (1989), Mc Culloch y Searle (2001), Dobson y Barnett (2008) y Myers *et al.* (2010).

Los modelos lineales generalizados mixtos agregan a los modelos lineales generalizados términos de efectos aleatorios (Wood, 2006, Faraway, 2016,). Así en (3.15) se agrega el término  $\mathbf{Z}\mathbf{b}$  análogo al de (3.9) en general con iguales supuestos para el vector  $\mathbf{b}$ .

### 3.2.4 Modelo aditivo generalizado

En los ELDA el tiempo es una de las variables explicativas de relevancia en el estudio. El gran número de momentos en que se realizan mediciones a veces hace que considerarlo como

una variable de clasificación o factor con demasiadas categorías o niveles en un modelo de análisis no sea aconsejable. Además, resulta engorroso captar la tendencia de cambios en la variable respuesta a través del tiempo si el tiempo es introducido como factor. Lo mismo sucede si el tiempo es tratado como una variable cuantitativa predictiva en modelos con términos polinómicos, pero si solo se incluye el término lineal puede resultar en un modelo que simplifica demasiado la verdadera relación. Entonces, una tercera alternativa es utilizar las técnicas de suavizados. Con estas se puede modelar la tendencia de la variable respuesta a través del tiempo sin forzar a que la relación tome alguna forma particular.

Las técnicas de suavizados comenzaron a popularizarse en la década de 1980 (Stasinopoulos *et al.*, 2017). Hay una amplia variedad de métodos de suavizados, entre los que se destacan los *splines* suavizados o *P-splines*. Estos consisten en una regresión *splines* con penalización sobre los coeficientes del suavizado por rugosidad (Eilers y Marx, 2010). Las regresiones *splines* son regresiones donde la matriz de diseño está conformada por una base de tramos polinomiales. Una de las bases más utilizadas es la de *splines* cúbicos, es decir una base de tramos polinomiales de grado 3. El coeficiente de penalización por rugosidad es el parámetro de suavizado, habitualmente denotado por la letra griega  $\lambda$ .

Los modelos aditivos incluyen suavizados de una o más variables explicativas. La forma general del modelo aditivo, adaptada de Hastie y Tibshirani (1990), es:

$$y_i = \beta + s_1(x_{1i}) + \dots + s_p(x_{pi}) + \varepsilon_i \quad i=1, \dots, n \quad (3.16)$$

donde los errores  $\varepsilon_i$  son independientes con media 0 y varianza  $\sigma^2$ . Las  $s_j$  ( $j=1, \dots, p$ ) son funciones de suavizados asociadas a cada predictor  $x_j$ . Los modelos aditivos generalizan a los modelos lineales, permitiendo una mayor flexibilidad en la forma de la relación entre la respuesta y las variables predictoras. De la misma forma, los modelos aditivos generalizados generalizan a los modelos lineales generalizados (Hastie y Tibshirani, 1990).

Los modelos aditivos generalizados son introducidos por Hastie y Tibshirani (1990) difiriendo del modelo lineal generalizado en que un predictor aditivo reemplaza al predictor lineal en (3.15). La distribución de probabilidad de  $Y$  es una de la familia exponencial, y entonces la media y el predictor aditivo se ligan a través de la función de ligadura  $g$ :

$$g[E(y)] = \beta + s_1(x_1) + \dots + s_p(x_p) \quad (3.17)$$

Una expresión más general de los modelos aditivos generalizados es la dada por Stasinopoulos *et al.* (2017), quienes proponen reemplazar a  $\beta$  por un predictor lineal ( $X\beta$ ) (3.18.).

Las funciones  $s_j$  pueden ser funciones de suavizado no paramétrico para algunas de las variables explicativas continuas. La idea es dejar que los datos determinen la relación entre la variable respuesta y las variables explicativas en lugar de forzar una relación lineal (o polinomial).

Al igual que los modelos lineales mixtos incorporan efectos aleatorios a los modelos lineales, los modelos aditivos generalizados mixtos incorporan términos de efectos aleatorios a los modelos aditivos generalizados. Los paquetes `mgcv` (Wood, 2006) y `gamm4` (Wood y Scheipl, 2016) de R ajustan estos modelos. El paquete `mgcv` da la posibilidad de ajustar estructuras de correlación en los errores con distribución normal invocando al paquete `nlme`. El paquete `gamm4` ajusta la parte aleatoria del modelo recurriendo a rutinas del paquete `lme4`.

### 3.2.5 Modelo aditivo generalizado para localización, escala y forma

En los modelos especificados desde 3.2.1 a 3.2.4, básicamente se ha planteado modelar la media de la distribución de la variable respuesta, si bien, tanto en los modelos con efectos aleatorios como en los generalizados se ha avanzado en modelar varianzas. En particular, en los modelos mixtos planteando heterogeneidad de varianzas y en los generalizados porque la relación media-varianza en algunas distribuciones de probabilidad hace que, modelando la media se modele indirectamente la varianza. No obstante, podría extenderse la forma en que se modela la media a otros parámetros de la distribución, incluso con suavizados.

Por ejemplo, la distribución gamma tiene dos parámetros: la media de la distribución,  $\mu$ , y un parámetro de escala (coeficiente de variación),  $\sigma$ , ambos relacionados con la varianza por la ecuación  $\text{Var}(Y) = \sigma^2\mu^2$  (sección 3.1.2.). Hay ocasiones en las que la suposición de un parámetro de escala constante no es apropiada. Entonces un modelo para el parámetro de escala se hace necesario. También hay distribuciones cuya asimetría y kurtosis no quedan determinadas con solo dos parámetros, como el de localización y el de escala, y entonces se

determinan con tres o cuatro parámetros. La modelización simultánea de estos parámetros mediante un modelo aditivo es lo que permiten los modelos aditivos generalizados para localización, escala y forma (GAMLSS, por sus siglas en inglés) introducidos por Rigby y Stasinopoulos (2005). Los cuales se formulan como:

$$\begin{aligned}
 & y \sim D(\mu, \sigma, \nu, \tau) \text{ independientes} \\
 & g_1(\mu) = \mathbf{X}_1 \boldsymbol{\beta}_1 + s_{11}(x_{11}) + \dots + s_{1p_1}(x_{1p_1}) \\
 & g_2(\sigma) = \mathbf{X}_2 \boldsymbol{\beta}_2 + s_{21}(x_{21}) + \dots + s_{2p_2}(x_{2p_2}) \\
 & g_3(\nu) = \mathbf{X}_3 \boldsymbol{\beta}_3 + s_{31}(x_{31}) + \dots + s_{3p_3}(x_{3p_3}) \\
 & g_4(\tau) = \mathbf{X}_4 \boldsymbol{\beta}_4 + s_{41}(x_{41}) + \dots + s_{4p_4}(x_{4p_4})
 \end{aligned} \tag{3.19}$$

donde  $D(\mu, \sigma, \nu, \tau)$  es la distribución de la variable respuesta  $Y$ ,  $\mu$  es un parámetro de localización (media o mediana, en general),  $\sigma$  es un parámetro de escala,  $\nu$  y  $\tau$  son parámetros de forma, los cuales a menudo se relacionan con la asimetría y la curtosis. Las  $\mathbf{X}_k$  son las matrices de diseño que incorporan los términos lineales a los modelos,  $\boldsymbol{\beta}_k$  son los vectores de parámetros de efectos fijos o coeficientes de regresión y  $s_{kj}$  representan diferentes funciones de suavizados para variables explicativas  $x_{kj}$  que pueden ser diferentes ( $k = 1; 2; 3; 4$ ).

Estos modelos son ajustados con el paquete `gamLSS` de R (Rigby y Stasinopoulos, 2005), abarcando un gran número de distribuciones. La distribución de la variable  $Y$  en (3.19) se deja deliberadamente sin ninguna distribución explícita, ya que la única restricción para la implementación de los GAMLSS en R es que la función de densidad de  $Y$ , sus primeras derivadas (y opcionalmente las segundas derivadas y derivadas cruzadas) respecto a cada uno de los parámetros  $\mu, \sigma, \nu$  y  $\tau$  deben ser computables (Stasinopoulos y Rigby, 2007).

Distribuciones asimétricas definidas en los números reales positivos con tres o cuatro parámetros son, por ejemplo, las distribuciones de Box-Cox Cole y Green (BCCG) y la distribución potencial exponencial de Box-Cox (BCPE), respectivamente. Las cuales se presentan a continuación.

Una variable  $Y$  con dominio en los números reales positivos tiene distribución de Box-Cox Cole y Green si su función de densidad de probabilidad está dada por

$$f_Y(y|\mu, \sigma, \nu) = \frac{y^{\nu-1} \exp\left(-\frac{1}{2}z^2\right)}{\mu^\nu \sigma \sqrt{2\pi}}$$

donde la transformada Z está definida como

$$z = \begin{cases} \frac{1}{\sigma\nu} \left[ \left(\frac{y}{\mu}\right)^\nu - 1 \right] & \text{si } \nu \neq 0 \\ \frac{1}{\sigma} \log\left(\frac{y}{\mu}\right) & \text{si } \nu = 0 \end{cases} \quad (3.20)$$

con  $\mu > 0$ ,  $\sigma > 0$ ,  $-\infty < \nu < \infty$ , y Z sigue una distribución normal estándar truncada. La condición  $0 < y$  es requerida para que  $y^\nu$  esté definida para cualquier valor de  $\nu$  (Stasinopoulos *et al.*, 2008). La mediana de Y es  $\mu$ .

La distribución potencial exponencial de Box-Cox se define con cuatro parámetros. La variable aleatoria Y definida en los números reales positivos tiene distribución potencial exponencial de Box-Cox si su transformada a través de la transformación Z (3.20) tiene distribución potencial exponencial estándar truncada con parámetro de potencia  $\tau > 0$ , parámetro continuo. Así, la función de densidad de probabilidad de Y está dada por

$$f_Y(y|\mu, \sigma, \nu, \tau) = \frac{y^{\nu-1} f_T(z)}{\mu^\nu \sigma}$$

Para  $y > 0$ , donde  $\mu > 0$ ,  $\sigma > 0$ ,  $-\infty < \nu < \infty$ , Z es dada en (3.20),  $f_T$  es la función de densidad de probabilidad de una variable aleatoria T con distribución potencial exponencial estándar (PE(0,1,  $\tau$ )). La variable Y tiene mediana  $\mu$ . Una variable con distribución potencial exponencial está definida en todos los números reales, es decir puede tomar valores reales tanto positivos como negativos e incluir el cero. La distribución normal es un caso particular de una distribución potencial exponencial, aunque esta también incluye distribuciones leptocúrticas y platicúrticas. La distribución BCPE generaliza la distribución BCCG para permitir el modelado de ambos parámetros de asimetría y curtosis (Stasinopoulos y Rigby, 2007).

#### 4. CAPÍTULO 4. APLICACIONES: ENSAYO DE AGRAMUNT. I

En este capítulo se aplican algunas de las metodologías presentadas en el Capítulo 3 para el análisis de la variable contenido de nitrógeno (N) mineral (CN) del suelo en el ensayo de Sistemas de Manejo de Suelos en Agramunt (Capítulo 2, sección 2.3.1 y Tabla 2.4.). Si bien los modelos son presentados exhaustivamente para el caso de CN del suelo en el perfil completo, consideraciones análogas pueden hacerse para CN en cada una de las tres profundidades.

De acuerdo con lo explicado en el Capítulo 3, cabe resaltar que, para el análisis de una variable respuesta en particular, debe tenerse en cuenta:

- a) la distribución de probabilidad de dicha variable, o la más aceptable posible,
- b) las variables predictivas o factores que se quieren estudiar en cuanto a su relación o efectos sobre la variable respuesta, y
- c) la estructura del diseño y de los tratamientos. Es decir, considerar la manera en que las variables predictivas y factores conforman un predictor lineal o intervienen en las componentes de varianzas.

##### 4.1 El CN: descripción y exploración de los datos

Es importante que, previo al ajuste de cualquier modelo que pretenda evaluar efectos o relaciones entre variables, se realice un análisis exploratorio y una depuración de los datos. Esta instancia es parte del análisis estadístico. La revisión preliminar de los datos, los cuales con frecuencia se disponen en una planilla de cálculo, se orienta a detectar, si los hay, algunos de los siguientes errores más comunes: errores de tipeo, en variables alfanuméricas falta de uniformidad en el formato de sus valores (igual valor de variable puede aparecer indicado con por lo menos dos formas o nombres diferentes), asignación de valor cero a la variable cuando en verdad corresponde a dato perdido. También muchas veces conviene dar a los datos el formato adecuado en la planilla de cálculo para que, al ser importados desde el programa computacional estadístico, las variables puedan ser tomadas directamente por los procedimientos que se apliquen. Luego, la visualización de los datos a través de diferentes gráficos, a fin de poner de manifiesto las relaciones entre las variables y factores, es de gran

utilidad y guía durante todo el análisis subsiguiente, y simultáneamente ayuda a la identificación de datos anómalos.

Del ensayo de Agramunt se dispone de datos de CN (expresado en  $\text{kg ha}^{-1}$ ) en las parcelas que no recibieron fertilización con N desde 1995-96 hasta 2014-15, excepto para la campaña 1996-97. En cada fecha de muestreo (otoño, invierno y verano del hemisferio norte, Capítulo 2) y cada parcela donde se aplicó un determinado sistema de laboreo se tomaron dos muestras (submuestras), excepto durante las campañas 1995-96 y 2012-2013. De cada submuestra se obtuvo el CN en cada una de las tres profundidades (0-30 cm, 30-60 cm y 60-90 cm, Capítulo 2). No hay datos disponibles para el muestreo de otoño de 1995 y para las otras dos fechas de muestreo de la misma campaña (invierno y verano de 1996) hay datos de tres submuestras por fecha de muestreo y parcela. Asimismo, para febrero del año 2012-13 se dispone de datos de una sola submuestra por parcela. Con la información de cada profundidad se obtiene el CN del perfil total (sumando los CN de las tres profundidades).

Los CN del suelo a través del tiempo bajo cada sistema de laboreo y en cada bloque se muestran en la Fig. 4.1. para todo el perfil del suelo y en las Fig. 4.2., 4.3., y 4.4. para cada una de las tres profundidades muestreadas (0-30 cm, 30-60 cm y 60-90 cm, respectivamente). Los datos mostrados tienen descartados los ceros y valores muy pequeños (menores que 1). Las fechas de muestreo están en el formato específico para “fechas”, día-mes-año, una de las maneras de respetar la separación cronológica real entre ellas.

De la observación de la Fig 4.1. surgen, en primera instancia, algunos aspectos destacados que requieren mayor exploración y que cualquier modelo de análisis estadístico debería tener la capacidad de tratar. Estos son: 1) la variable CN puede depender de interacciones entre laboreos, tiempos y bloques, tanto en parámetros de localización como de dispersión; 2) se observa más variación de CN en alguna situación que en otra (p.e. Arado de vertedera en bloque 4 vs Subsulado profundo en bloque 2) y en general parece haber mayor variabilidad en CN para Arado de vertedera que en los otros laboreos; 3) la complejidad de la relación entre CN y el tiempo, podría requerir de funciones de suavizado; 4) más allá de los efectos ambientales de cada momento de muestreo, son menos frecuentes los valores altos de CN que los bajos, lo que indica una asimetría en la distribución de la variable, sin descartar que algunos datos altos puedan ser valores extremos como los que se observan al finalizar el

período de muestreo en algunos laboreos y bloques (p.e. en bloque 1 y Subsulado profundo y en Chisel). De la observación de las Fig. 4.2., 4.3. y 4.4. surge que para cada una de las profundidades muestreadas pueden hacerse comentarios similares a los realizados sobre la variable CN en el perfil total del suelo (Fig. 4.1).

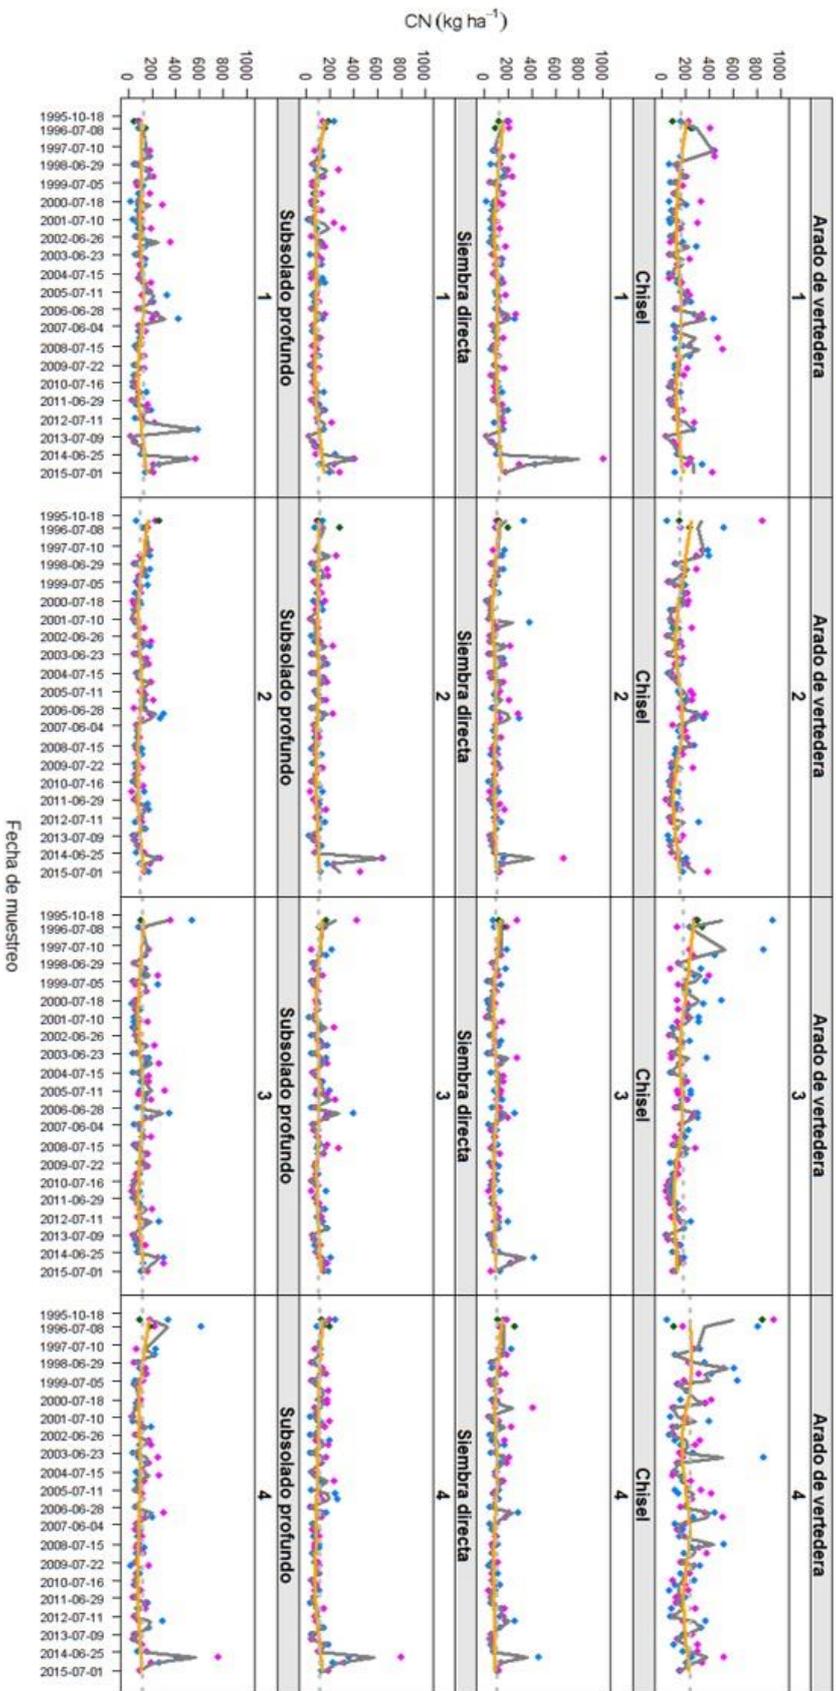


Fig. 4.1. Contenido de nitrógeno mineral (CN) en el perfil total de suelo (0-90 cm) en el ensayo de Agrament a través del tiempo, desde el año 1995 hasta el año 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsoliado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel, la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la línea naranja es un suavizado.

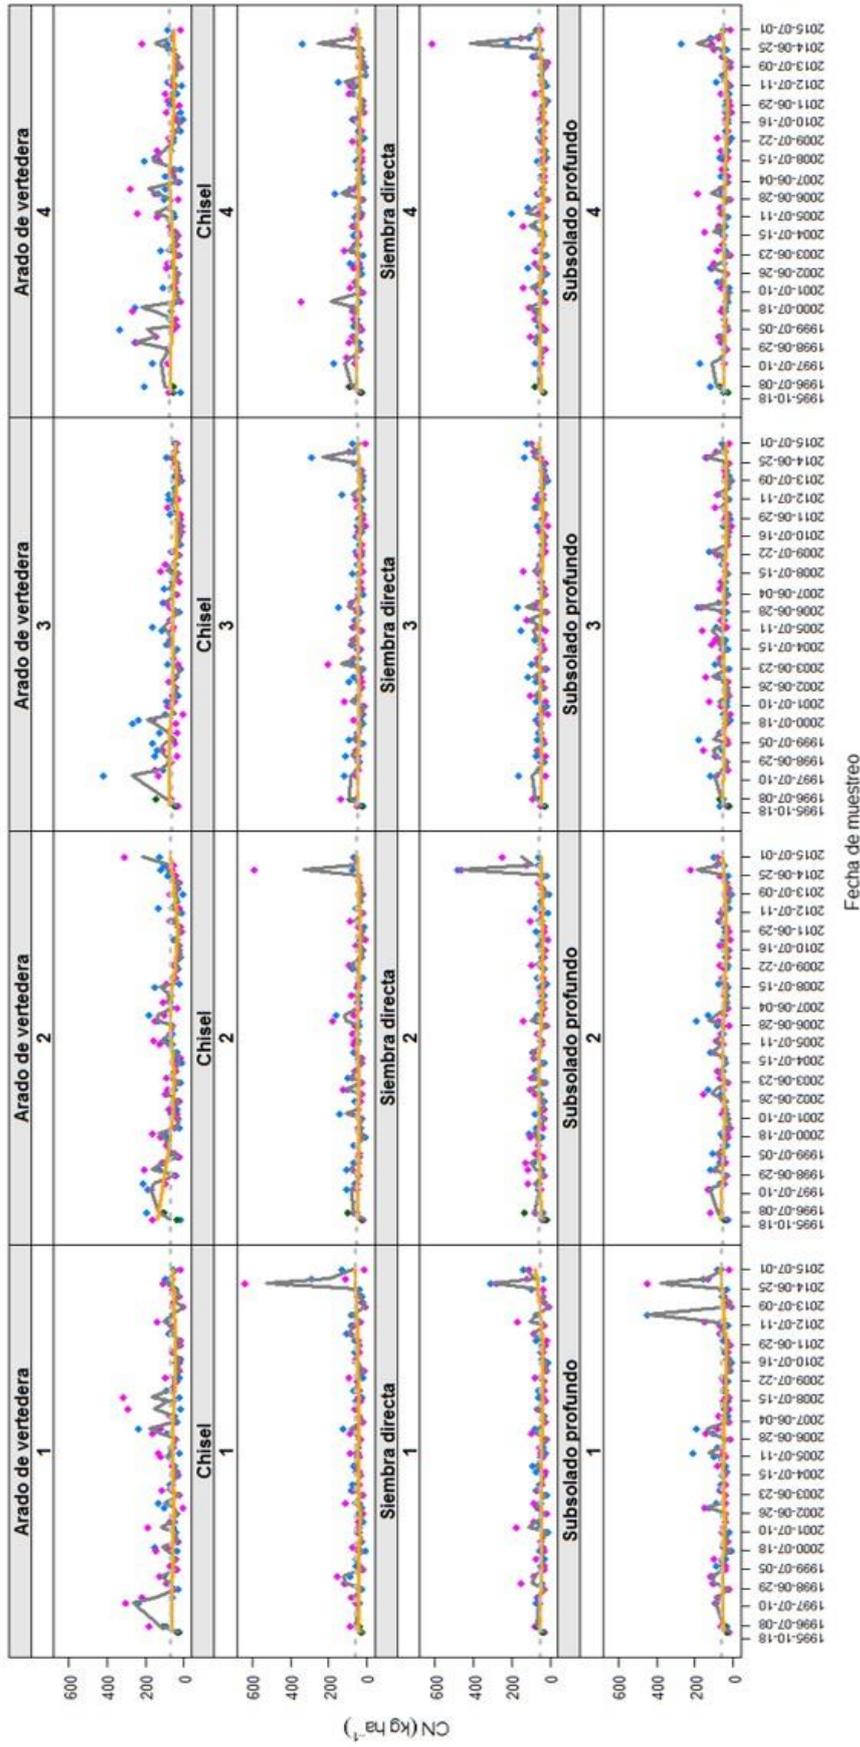


Fig. 4.2. Contenido de nitrógeno mineral (CN) en el suelo a 0-30 cm de profundidad en el ensayo de Agramunt a través del tiempo, desde el año 1995 al 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsulado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la línea naranja es un suavizado.

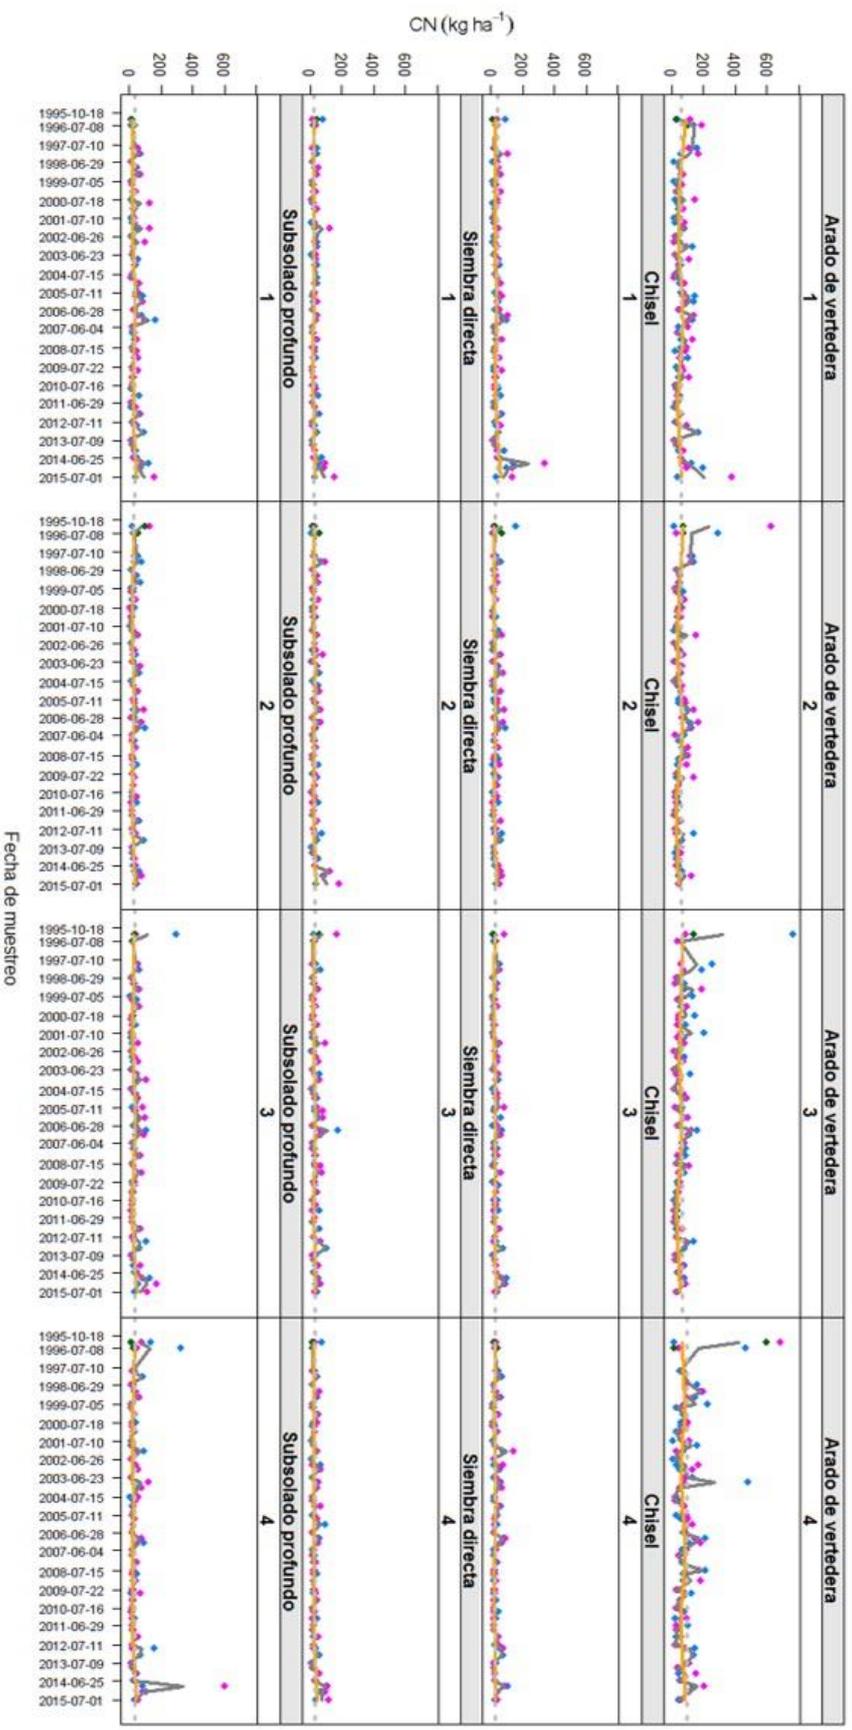


Fig. 4.3. Contenido de nitrógeno mineral (CN) en el suelo a 30-60 cm de profundidad en el ensayo de Agramunt a través del tiempo, desde el año 1995 al 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsulado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestréos en cada fecha. En cada panel la línea entrecortada gris indica el valor de CN promedio, la línea continua gris une promedios de CN por fecha de muestreo y la línea naranja es un suavizado.

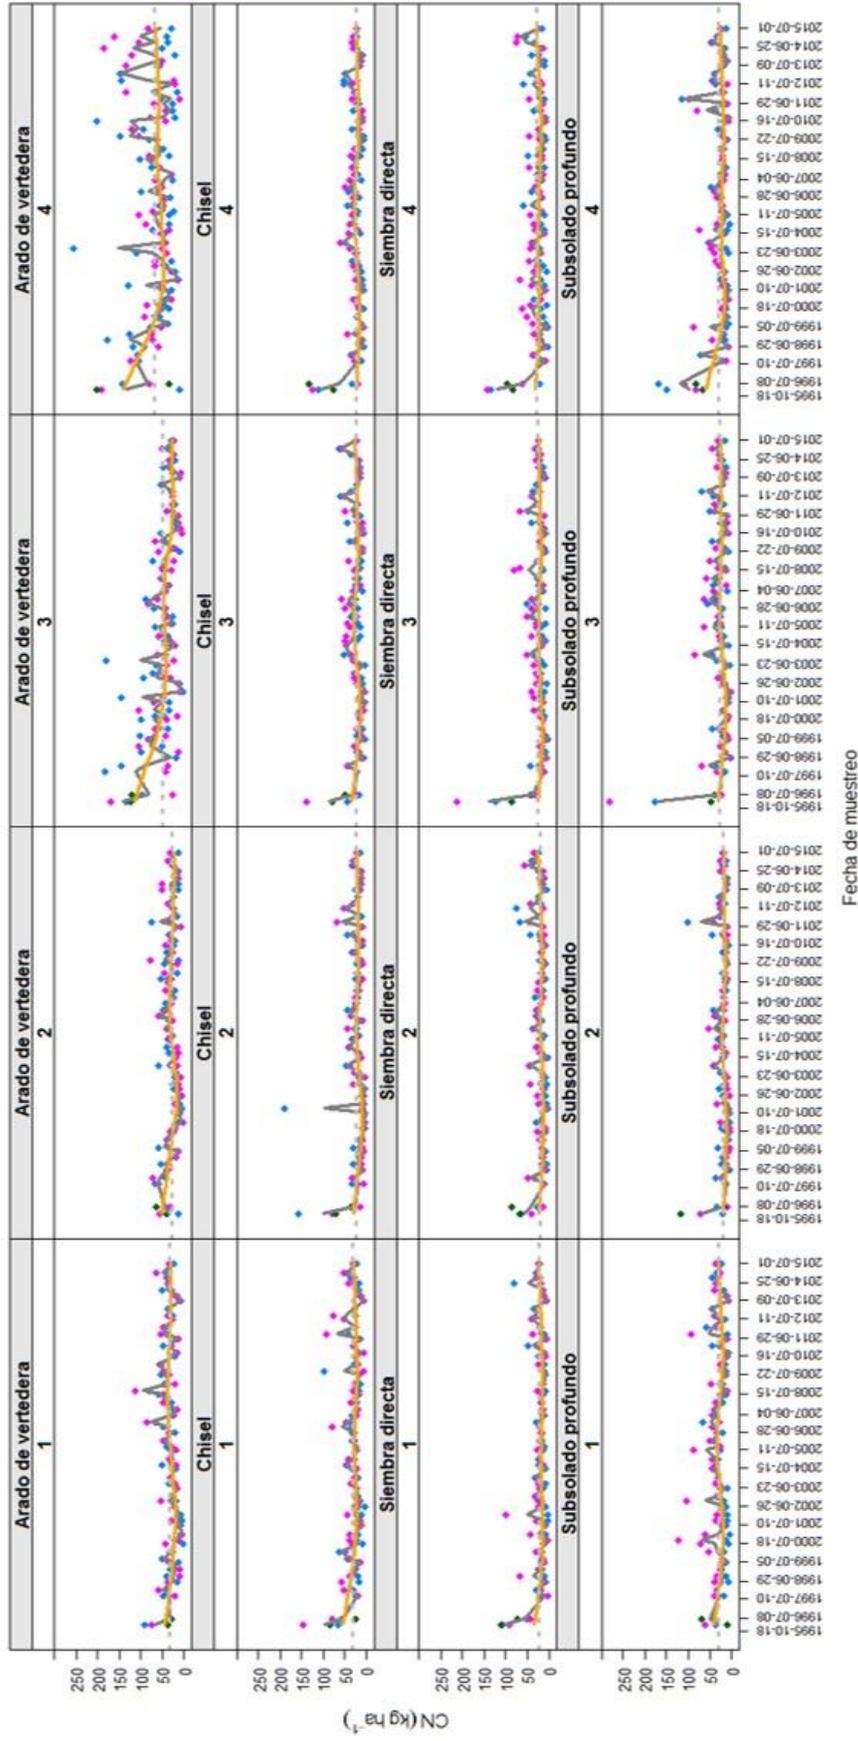


Fig. 4.4. Contenido de nitrógeno mineral (CN) en el suelo a 60-90 cm de profundidad en el ensayo de Agramunt a través del tiempo, desde el año 1995 al 2015. Cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsulado profundo) y bloque (1, 2, 3 y 4). Puntos con diferentes colores distinguen los submuestreos en cada fecha. En cada panel la línea entrecortada gris indica el valor de CN promedio, la línea continua gris un promedio de CN por fecha de muestreo y la línea naranja es un suavizado.

En las Fig. 4.1 a 4.4 se mostró el CN (en  $\text{kg ha}^{-1}$ ) a través del tiempo para cada sistema de laboreo y en cada bloque, en todo el perfil del suelo y para cada una de las tres profundidades. Lo observado en dichas figuras lleva a rescatar la importancia de considerar los siguientes aspectos, para el modelado de la variable,

- a) la distribución de la variable respuesta
- b) las variables explicativas
- c) la complejidad de los predictores (lineales, suavizados, etc.)
- d) los parámetros a modelar (incluye heterogeneidad de varianzas).

#### **4.2 El modelo lineal general como herramienta exploratoria**

Algunos autores han propuesto una distribución de probabilidad lognormal o gamma para el contenido de nitrato en suelo (Gbur *et al.*, 2012). Aquellas distribuciones pueden ser trasladadas al contenido de CN en el suelo dado que, generalmente, la mayor parte del CN está constituida por N de nitrato en solución. No obstante, esto debe ser analizado en base a los datos del ensayo de Agramunt.

También, en el Capítulo 3 se indicó que es muy difícil determinar la distribución de una variable que potencialmente o eventualmente está influida por otras variables o factores en un estudio diseñado a priori del ajuste de algún modelo. Esto es así porque para cada combinación de niveles de los factores y valores de otras variables explicativas, por lo general, hay muy pocas observaciones de la variable en cuestión como para poder evaluar el tipo de distribución a utilizar. Tal es el caso del CN en el ensayo de Agramunt, si bien hay 1803 datos de CN para el perfil completo de suelo, estos corresponden a parcelas con diferentes tipos de laboreo (4), bloques (4) y fechas de muestreo (3 por año) a través de veinte años. Lo mismo ocurre para los datos de CN en cada una de las tres profundidades de suelo muestreadas.

Así, siguiendo con la etapa exploratoria, se busca en principio caracterizar a grandes rasgos la distribución de la variable CN en base al análisis de los residuos de un modelo lineal general (Capítulo 3, sección 3.2.1.). El modelo que se propone ajustar para explicar CN en el perfil total contempla en su predictor lineal los efectos de laboreo, bloque, fecha de muestreo (fecha) e interacción laboreo por fecha (laboreo:fecha), con errores independientes entre sí a través de

fechas (modelo 0.1, sección 4.2.1.). Dado que hay 19 años con datos de CN y 3 fechas por año, el factor fecha tiene un total de 57 niveles o valores. Considerar fecha como factor en el predictor lineal es equivalente a considerar el factor año (19 niveles) y momentos o estaciones dentro de año. Luego, un segundo modelo (modelo 0.2, sección 4.2.2.) que descuenta más variación del término de error respecto al modelo 0.1 también es considerado. En este segundo modelo se incluyen interacciones entre bloque y laboreo, bloque y fecha y la interacción triple entre bloque, laboreo y fecha. Con estos modelos lo que se busca es descartar el supuesto de distribución normal para CN y avanzar sobre modelos con distribuciones asimétricas.

#### 4.2.1 Primer modelo (modelo 0.1)

El modelo 0.1 puede ser expresado en forma sencilla como:

modelo 0.1:  $CN = \text{bloque} + \text{laboreo} + \text{fecha} + \text{laboreo:fecha} + \text{error}$ ,

donde bloque, laboreo y fecha en el modelo representan los efectos principales sobre CN de los respectivos factores y son considerados de efectos fijos, la interacción laboreo con fecha (laboreo:fecha) por lo tanto también es de efectos fijos. El predictor lineal es “bloque + laboreo + fecha + laboreo:fecha”.

Y de manera más formal:

$$CN_{ikjl} = \mu + \text{bloq}_k + \text{lab}_i + \text{fech}_j + \text{lab:fech}_{ij} + \varepsilon_{ikjl}^{(0)} \quad (\text{modelo 0.1})$$

$(i = 1, \dots, 4, j = 1, \dots, 57, k = 1, \dots, 4, l = 1, 2)$  con  $\varepsilon_{ikjl}^{(0)} \sim \text{indep } N(0, \sigma^2)$

El modelo 0.1 responde a la forma del modelo lineal general (Capítulo 3 sección 3.2.1 modelo (3.3)) donde el predictor lineal es  $\mu + \text{bloq}_k + \text{lab}_i + \text{fech}_j + \text{lab:fech}_{ij}$  (bloque + laboreo + fecha + laboreo:fecha), es decir  $\mu_{ikj} = \mu + \text{bloq}_k + \text{lab}_i + \text{fech}_j + \text{lab:fech}_{ij}$  donde  $\mu_{ikj}$  es la media o esperanza de CN de suelo en el perfil total para el laboreo i, fecha j en el bloque k (i = 1 (Subsolado profundo), 2 (Siembra directa), 3 (Chisel), 4 (Arado de Vertedera), j = 1, ..., 57, k = 1, ..., 4). Los  $\mu_{ikj}$  estimados con los datos del ensayo ( $\hat{\mu}_{ikj}$ ) a partir de las estimaciones de los componentes del predictor lineal también son llamados valores predichos

o ajustados por el modelo. El subíndice  $l$  en el modelo identifica a cada una de las dos submuestras en cada fecha de muestreo, laboreo y bloque. El término de error en el modelo 0.1 ( $\varepsilon_{ikjl}^0$ ) contiene el error experimental ( $lab: bloq_{ik} + bloq: fech_{kj} + lab: bloq: fech_{ikjl}$ ) más el submuestreo.

Los residuos o residuales del modelo 0.1 ( $\hat{\varepsilon}_{ikjl}^0$ ) se definen como las diferencias entre los valores de CN y los efectos estimados en el predictor lineal, es decir  $\hat{\varepsilon}_{ikjl}^0 = CN_{ikjl} - \hat{\mu}_{ikjl}$ . También, estos suelen ser denominados residuos crudos. Los residuos estandarizados, tal como son referidos en el ambiente R, son los residuos crudos divididos por la raíz cuadrada de la estimación de la varianza de error sin el dato correspondiente a ese residuo ( $\hat{\sigma}_{-(ikjl)}$ ), es decir estos son  $\hat{\varepsilon}_{ikjl}^0 / \hat{\sigma}_{-(ikjl)}$ . En consecuencia, los residuos estandarizados carecen de unidades de medida.

Se analizaron los residuales crudos y los residuos estandarizados del modelo 0.1. En la Fig. 4.5 (a y b) se observa que los mayores residuales, en valor absoluto, corresponden a valores mayores de los predichos. Es decir que, a mayor nivel de CN la variación entre los datos observados es mayor. Esto claramente atenta contra el supuesto de homogeneidad de varianzas. En particular, en la Fig. 4.5.b se observa que hay varios valores de residuos que, en valor absoluto, superan el valor 3, indicando también alguna falla en el supuesto de distribución normal de los errores y/o la presencia de datos extremos. Incluso los residuales extremos positivos llegan a valores cercanos a 8, en cambio, en los negativos no son inferiores a -6, mostrando cierta asimetría positiva. Estos comportamientos son los esperados bajo el supuesto que la variable CN se distribuya en forma asimétrica positiva.

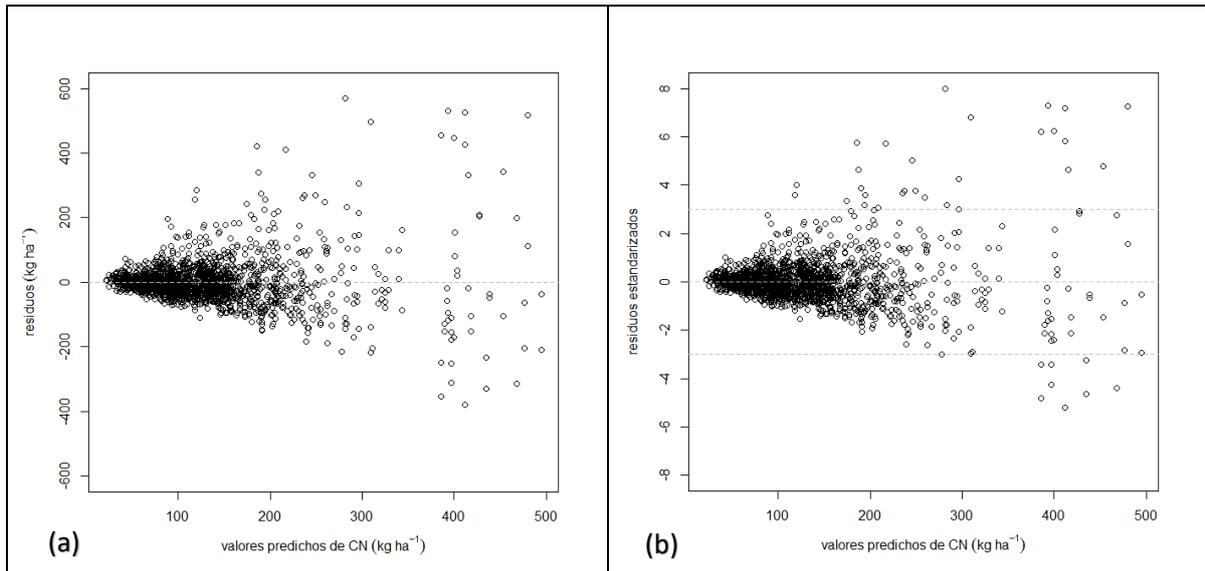


Fig. 4.5. Residuales crudos (a) y estandarizados (b) versus los respectivos valores ajustados o predichos, para el modelo 0.1. CN: contenido de nitrógeno mineral en el suelo a 0-90 cm.

Otros gráficos que también pueden ser de utilidad, son aquellos que permiten observar el comportamiento de los residuales según algún factor de clasificación especificado en el modelo. En la Fig. 4.6. se muestra el gráfico de residuales por cada nivel del factor de clasificación “laboreo”.

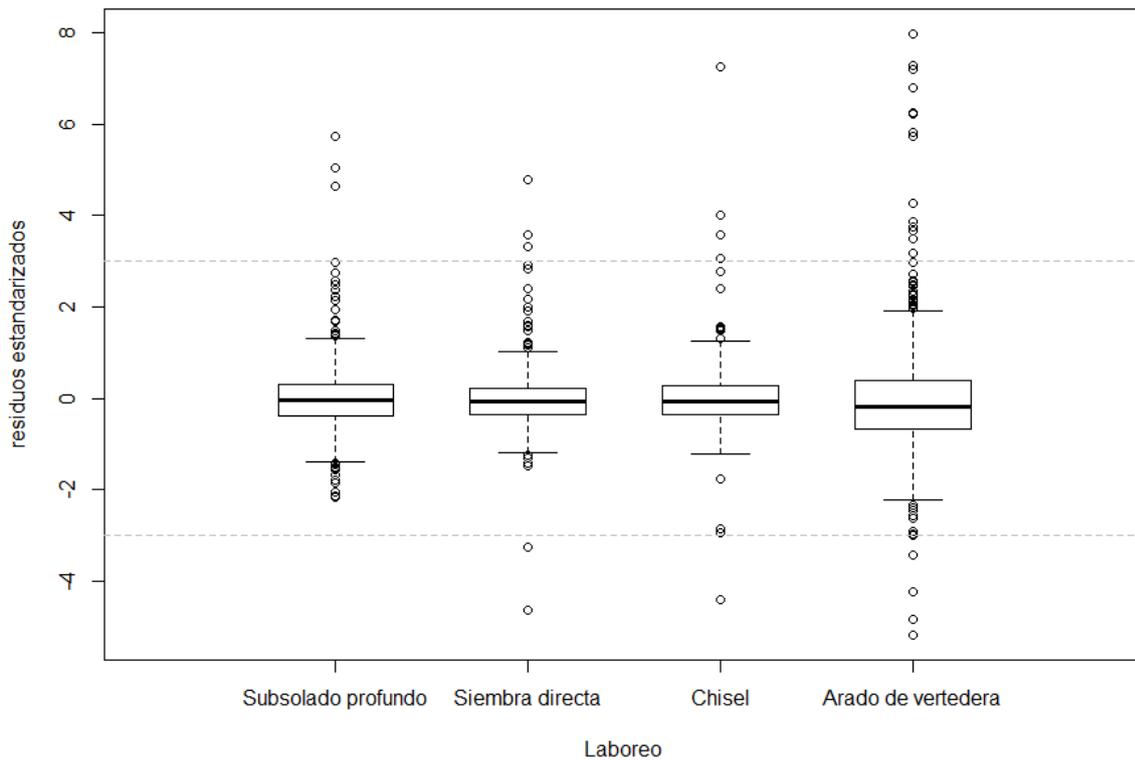


Fig. 4.6. Diagramas de caja para los residuales estandarizados del modelo 0.1 en cada tipo de laboreo.

En la Fig. 4.6 se observa que para los cuatro tipos de laboreo existen residuos mayores que 3, en valor absoluto, habiendo más residuos en estas condiciones en el laboreo “Arado de vertedera”. Así mismo, en “Arado de vertedera” se presentan los más grandes y también los más pequeños valores de residuos en relación a los otros laboreos. También se observa asimetría positiva para CN en cada tipo de laboreo.

Existen herramientas gráficas específicas que permiten visualizar el grado de concordancia de un conjunto de valores de una variable con una determinada distribución de probabilidad. El paquete `fitdistrplus` (Delignette-Muller y Dutang, 2015) en el ambiente R utiliza este tipo de herramientas. En particular estas posibilidades gráficas son utilizadas para evaluar la concordancia de los residuales crudos del modelo 0.1 con una distribución normal.

En la Fig. 4.7. se muestran un histograma de densidad y función de densidad teórica para una distribución normal para los residuos crudos del modelo 0.1. (Fig. 4.7.a.) y un gráfico cuantil-cuantil (qq plot) para los residuos crudos del modelo 0.1 (Fig. 4.7.b.). Tanto en la Fig. 4.7.a como en la 4.7.b se observa falta de concordancia de los residuos crudos del modelo 0.1 con una distribución normal y asimetría positiva en los residuos.

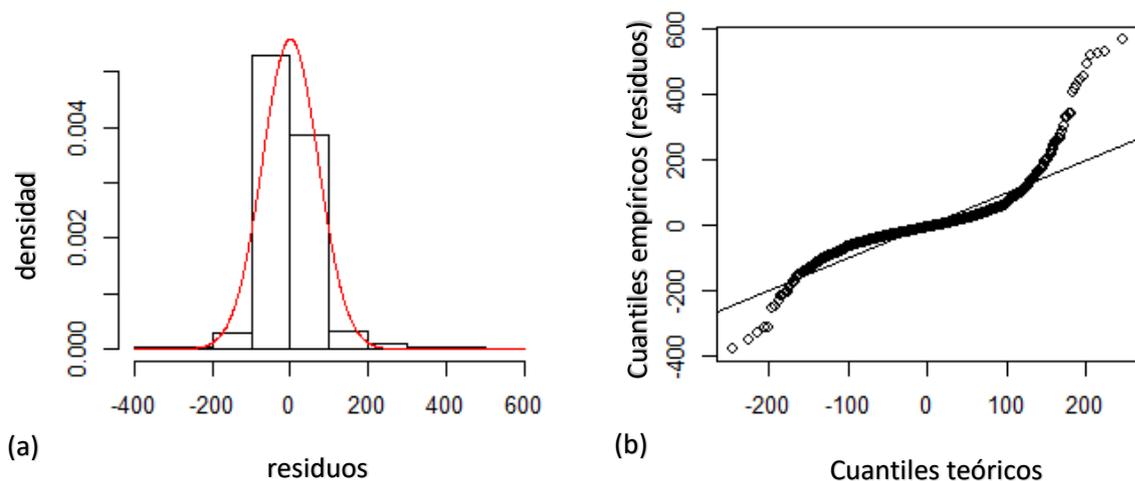


Fig. 4.7. (a) Histograma de densidad y función de densidad teórica para una distribución normal (línea roja) para los residuos crudos del modelo 0.1. (b) Gráfico cuantil-cuantil (qq plot) para los residuos crudos del modelo 0.1 y sus correspondientes cuantiles de una distribución normal, donde la línea de referencia (línea recta) indica la concordancia total. Gráficos obtenidos con funciones del paquete `fitdistrplus` de R.

#### 4.2.2 Segundo modelo (modelo 0.2)

Un modelo más exhaustivo que el modelo 0.1, es aquel que separa del término de error del modelo 0.1 algunas interacciones que involucran a los bloques.

El modelo que se ajusta es el modelo 0.2,

modelo 0.2:  $CN = \text{bloque} + \text{laboreo} + \text{fecha} + \text{laboreo:fecha} + \text{laboreo:bloque} + \text{bloque:fecha} + \text{laboreo:bloque:fecha} + \text{error}$ ,

donde todos los términos, excepto el de error, son efectos fijos y conforman el predictor lineal. En este caso, especificar la interacción triple tiene sentido dado que para cada laboreo, bloque y fecha hay más de una observación (submuestreo).

Y de manera más formal:

$$CN_{ijkl} = \mu + \text{bloq}_k + \text{lab}_i + \text{fech}_j + \text{lab:fech}_{ij} + \text{lab:bloq}_{ik} + \text{bloq:fech}_{kj} + \text{lab:bloq:fech}_{ijk} + \varepsilon_{ijkl}^{(1)} \quad (\text{modelo 0.2})$$

$$(i = 1, \dots, 4 \quad j = 1, \dots, 57, \quad k = 1, \dots, 4, \quad l = 1, 2) \quad \text{con} \quad \varepsilon_{ijkl}^{(1)} \sim \text{indep } N(0, \sigma^2)$$

Del error del modelo 0.1 ( $\varepsilon_{ijkl}^{(0)}$ ) se han descontado los términos de interacción con bloque para obtener el error del modelo 0.2 ( $\varepsilon_{ijkl}^{(1)}$ ). No obstante, la equivalencia  $\varepsilon_{ijkl}^{(0)} = \text{lab:bloq}_{ik} + \text{bloq:fech}_{kj} + \text{lab:bloq:fech}_{ijk} + \varepsilon_{ijkl}^{(1)}$  no es total debido a que los términos que involucran bloques en esta igualdad son de efectos fijos en modelo 0.2 y no aleatorios como en modelo 0.1.

De forma análoga a la evaluación de residuales del modelo 0.1, se realiza la de los residuales del modelo 0.2.

Comportamientos similares a los residuos del modelo 0.1 (Fig. 4.5.) se observan en los residuos del modelo 0.2 (Fig. 4.8) en cuanto a que los mayores residuos se corresponden con mayores predichos. También, en las Fig. 4.8 a) y b) se observa simetría de los residuos respecto al eje horizontal (residuo=0), pero esta simetría es una particularidad de este conjunto de datos, o de cualquiera que en cada combinación de niveles de factores tenga dos observaciones. En este caso, en casi todas las combinaciones de laboreo, bloque y fecha hay dos submuestras, entonces los dos residuos que se generan son dos valores opuestos. La

simetría no es perfecta justamente porque no todas las combinaciones tienen las dos submuestras.

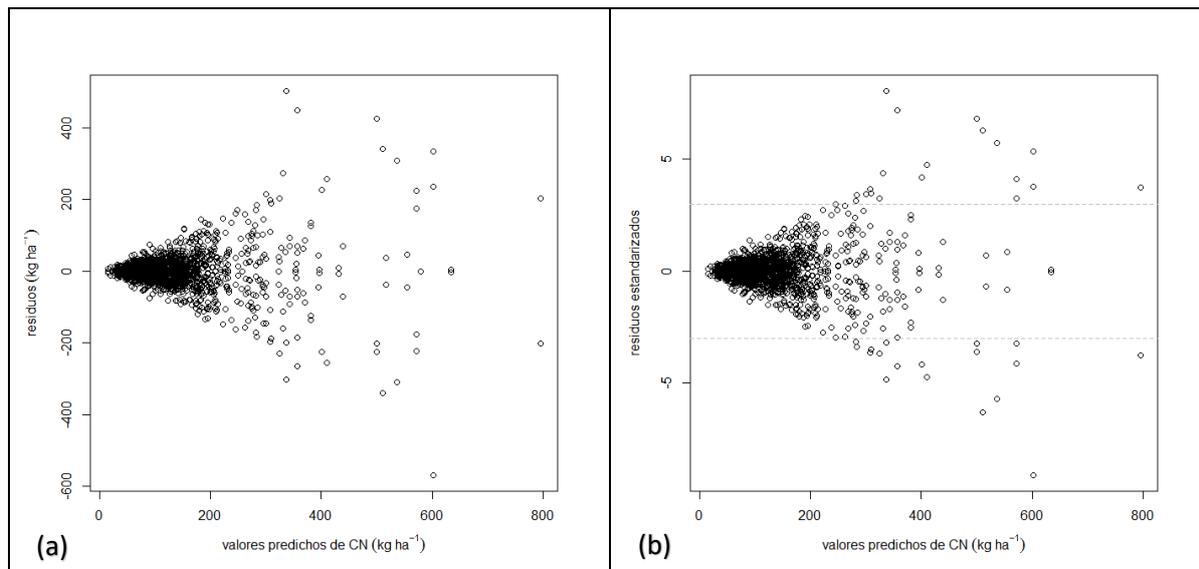


Fig. 4.8. Residuales crudos (a) y estandarizados (b) versus los respectivos valores ajustados o predichos, para el modelo 0.2. CN: contenido de nitrógeno mineral en el suelo a 0-90 cm.

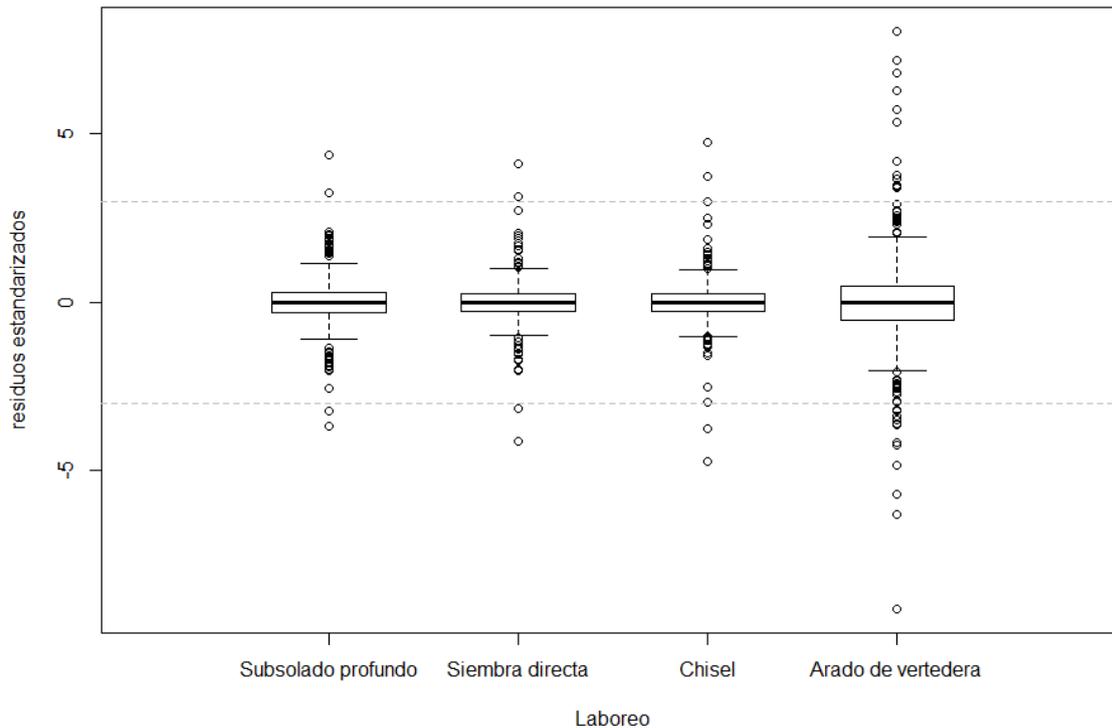


Fig. 4.9. Diagramas de caja para los residuales estandarizados del modelo 0.2 en cada tipo de laboreo.

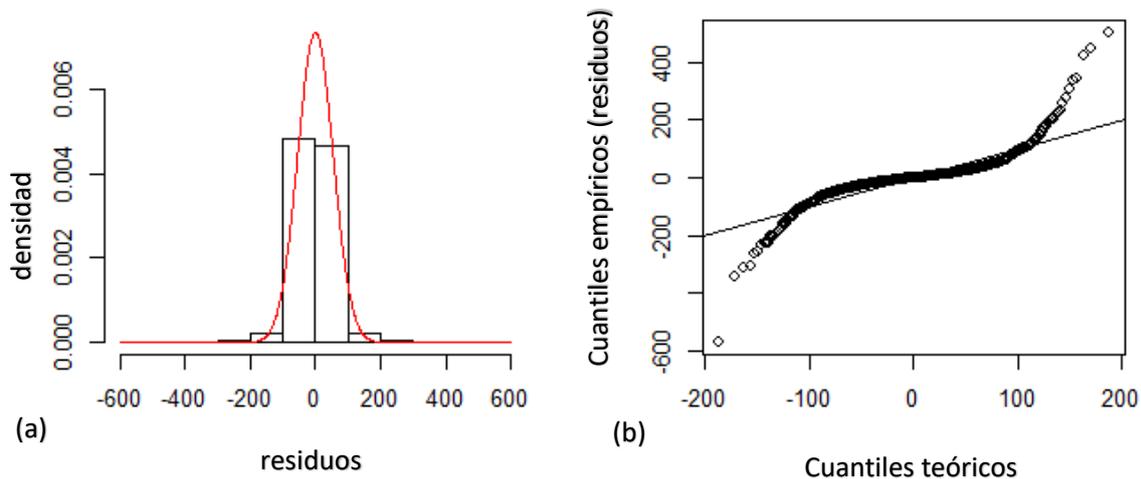


Fig. 4.10. (a) Histograma de densidad y función de densidad teórica para una distribución normal (línea roja) para los residuos crudos del modelo 0.2. (b) Gráfico cuantil-cuantil (qq plot) para los residuos crudos del modelo 0.2 y sus correspondientes cuantiles de una distribución normal, donde la línea de referencia (línea recta) indica la concordancia total. Gráficos obtenidos con funciones del paquete `fitdistrplus` de R.

Tanto en la Fig. 4.9 como en la Fig. 4.10 (a y b) se observa la simetría de los residuos del modelo 0.2, pero la falta de ajuste a una distribución normal. En las tres figuras se observa el alejamiento de los residuos de una distribución normal sobre todo en los valores ubicados en los extremos (colas pesadas). En la Fig. 4.9. se observa mayor variación en los residuos para un tipo de laboreo (Arado de vertedera) que para los demás.

Los modelos 0.1 y 0.2, si bien no han respetado la estructura de agrupamiento de los datos (mediciones en el tiempo dentro de una misma parcela y submuestras para una misma fecha dentro de una parcela) han permitido mostrar algunas características de CN. Se ha vislumbrado falta de normalidad y posible falta de homogeneidad de varianzas entre laboreos.

Cabe entonces, plantear modelos alternativos que, por ejemplo, consideren el agrupamiento de los datos, la transformación de la variable CN a través del logaritmo y alternativas de heterogeneidad de varianzas en el contexto de los modelos lineales mixtos.

### 4.3 Modelos de mediciones repetidas para el análisis

Los modelos presentados aquí se encuadran dentro de los modelos lineales mixtos. La variable respuesta considerada es el logaritmo de CN, teniendo en cuenta los resultados de la sección previa, en los que se ha evidenciado una mala correspondencia de la variable en la escala original con una distribución normal y los antecedentes sobre supuesto de distribución lognormal para CN. Si CN tiene distribución lognormal, el logaritmo de CN tiene distribución normal.

Uno de los modelos lineales mixtos básicos para datos de diseños con mediciones repetidas a través del tiempo es el que toma los efectos de los “sujetos” como aleatorios y fueron presentados en la sección 3.2.2.1, modelo (3.10) (Capítulo 3). En el caso que se está analizando, cada parcela en un bloque que recibió un laboreo es un sujeto o individuo o unidad de agrupamiento. Los efectos de estas parcelas son considerados aleatorios en el modelo (parcela=laboreo:bloque). Los efectos fijos de bloque, laboreo, fecha e interacción laboreo:fecha conforman el predictor lineal. El modelo lineal así planteado es coincidente con el clásico modelo lineal de parcelas divididas. En este caso, el sujeto o parcela, tiene el rol de la parcela principal en el modelo de parcelas divididas y cada una de las fechas de evaluación realizada en cada parcela (parcela:fecha) tiene el rol de la subparcela. Los efectos de parcela:fecha también son considerados aleatorios, como lo son los efectos de subparcelas en un parcelas divididas y son los que definen el segundo término de error. En particular, como en cada parcela y fecha se registró más de una observación de CN, dos o tres, en este modelo también puede especificarse el nivel de submuestreo. Las submuestras están agrupadas en cada parcela:fecha. El efecto de submuestra, si es especificado en el modelo, es un tercer efecto aleatorio. Si el término de submuestreo no es explicitado en el modelo los valores de CN para las submuestras de una misma parcela y fecha deben promediarse previamente, constituyendo así el valor de la variable respuesta a ajustar en el modelo ( $\overline{CN}$ ).

Los modelos que se proponen ajustar considerando la estructura de mediciones repetidas se indican en la Tabla 4.1. En forma alternativa se ajustan modelos que explicitan el submuestreo y los que no. El proceso que se sigue para el ajuste de los modelos es uno en el que se van tomando decisiones paso a paso para el ajuste del próximo modelo. Se comienza con un modelo simple, en este caso con mm1.logCN.cs o mm1.logCN (Tabla 4.1.), luego se

continúa con los modelos que incorporan heterogeneidad de varianzas (mm2.logCN.cs o mm2.logCN, Tabla 4.1.) y, finalmente, los que incorporan correlaciones. La estructura de correlación es agregada a un modelo con heterogeneidad de varianzas una vez que esta componente en el modelo fue evaluada y aceptada, si no, la estructura de correlación es probada en el modelo básico correspondiente (modelo con homogeneidad de varianzas).

Los modelos se ajustan con la función `lme` del paquete `nlme` (Pinheiro y Bates, 2000). También puede ajustarse con la función `lmer` del paquete `lme4` (Bates *et al.*, 2015), excepto los modelos con correlaciones en los términos aleatorios incluidos el término de error.

Tabla 4.1. Denominación de los modelos de mediciones repetidas que se ajustan para al logaritmo del contenido de nitrógeno (CN) del suelo en el perfil completo (0-90 cm).

	Denominación	Término de Submuestreo
Modelo básico de mediciones repetidas		
(1)	mm1.logCN.cs	con submuestreo
(2)	mm1.logCN	promedio de submuestras
Modelo de mediciones repetidas + heterogeneidad de varianzas		
(3)	mm2.logCN.cs	con submuestreo
(4)	mm2.logCN	promedio de submuestras
Modelo de mediciones repetidas + errores correlacionados		
(5)	mm3.logCN	promedio de submuestras

El método de estimación utilizado es el de máxima verosimilitud restringida (REML). La comparación de modelos anidados a fin de evaluar la significancia de componentes de varianza es realizada a través de la prueba del cociente de verosimilitud. Por ejemplo, mm2.logCN y mm1.logCN comparados a través de esta prueba permite concluir si la heterogeneidad de varianzas que postula mm2.logCN realiza un aporte significativo o no respecto al modelo de homogeneidad de varianzas de mm1.logCN. Posteriormente, luego del ajuste de cada modelo se evalúan los supuestos realizados.

En los modelos de la Tabla 4.1., el término aleatorio en el nivel más bajo de agrupamiento (submuestreo en los “con submuestreo” y subparcela en los “promedio de submuestras”) genera los residuales del modelo, de forma análoga a los residuales de los modelos modelo 0.1 y modelo 0.2 de la sección 4.2. La diferencia con esos modelos es que, en los modelos mixtos aquí propuestos, el residual se obtiene no solo descontando del valor del logaritmo de CN la estimación de la media marginal (valor ajustado o predicho) sino también la predicción

de los otros efectos aleatorios (mejores predictores lineales insesgados empíricos, eblups). La validación de supuestos para los otros términos aleatorios se realiza en base a sus eblups.

### 4.3.1 Modelo básico de mediciones repetidas

#### 4.3.1.1 Modelo con especificación del submuestreo

El modelo básico de mediciones repetidas para el logaritmo de CN en el perfil total del suelo en el ensayo de Agramunt incluyendo el término de submuestreo (Tabla 4.1.), expresado en forma simple, es

**(mm1.logCN.cs):**  $\log(\text{CN}) = \text{bloque} + \text{laboreo} + \text{parcela} + \text{fecha} + \text{laboreo:fecha} + \text{subparcela} + \text{submuestreo}$ , con efectos aleatorios de *parcela*, *subparcela* y *submuestreo*, cada uno con distribución normal de media cero y varianzas desconocidas.

El modelo expresa que el valor del logaritmo de CN depende del bloque, del laboreo, de la fecha de muestreo, de la interacción laboreo:fecha (efectos fijos), y también de la parcela, de la interacción parcela:fecha (subparcela) y de la submuestra (lugar de la parcela y demás condiciones en que se tomó la submuestra)(efectos aleatorios).

O, en términos más formales,

**(mm1.logCN.cs):**  $\log(\text{CN})_{ikjl} = \mu + \text{bloq}_k + \text{lab}_i + \delta_{ik} + \text{fech}_j + \text{lab:fech}_{ij} + \varepsilon_{ikj} + \zeta_{ikjl}$

$(i = 1, \dots, 4 \quad j = 1, \dots, 57, \quad k = 1, \dots, 4, \quad l = 1, 2)$  con  $\delta_{ik} \sim \text{indep } N(0, \sigma_p^2)$ ,  $\varepsilon_{ikj} \sim \text{indep } N(0, \sigma_{pf}^2)$ ,

$\zeta_{ikjl} \sim \text{indep } N(0, \sigma_{subm}^2)$  y

*todos los términos aleatorios independientes entre sí*

En el modelo **mm1.logCN.cs** el logaritmo de CN se supone con distribución normal con media marginal (promediado a través de los efectos aleatorios) que depende fundamentalmente del laboreo y la fecha de muestreo, y también del bloque ( $\mu_{ikj} = \mu + \text{bloq}_k + \text{lab}_i + \text{fech}_j + \text{lab:fech}_{ij}$ ). En la media marginal solo intervienen los efectos fijos. Y la varianza marginal es  $\sigma_p^2 + \sigma_{pf}^2 + \sigma_{subm}^2$ . Aquí se está asumiendo que hay homogeneidad de varianzas, que la varianza del logaritmo de CN no cambia con el laboreo, ni con la fecha ni con el bloque, y la magnitud de esa varianza es  $\sigma_p^2 + \sigma_{pf}^2 + \sigma_{subm}^2$ .

El modelo **mm1.logCN.cs** postula implícitamente una correlación entre las observaciones en la misma parcela a distintas fechas. Esta correlación está inducida por los efectos aleatorios de parcelas. La magnitud de la varianza del logaritmo del CN entre parcelas impacta directamente sobre la magnitud de dicha correlación. Más específicamente, la correlación en términos de las componentes de varianza está dada por,

$$\sigma_p^2 / \sqrt{\sigma_p^2 + \sigma_{pf}^2 + \frac{\sigma_{subm}^2}{n1_{subm}}} \sqrt{\sigma_p^2 + \sigma_{pf}^2 + \frac{\sigma_{subm}^2}{n2_{subm}}}$$

donde  $n1_{subm}$  y  $n2_{subm}$  son las cantidades de submuestras en una fecha y otra, respectivamente, para la misma parcela. Si el número de submuestras es el mismo,  $n_{subm}$ , entonces la correlación es  $\sigma_p^2 / (\sigma_p^2 + \sigma_{pf}^2 + \frac{\sigma_{subm}^2}{n_{subm}})$ . Este es un caso particular de la expresión dada en (3.14) del Capítulo 3, donde  $\sigma_b^2 = \sigma_p^2$  y  $\sigma_e^2 = \sigma_{pf}^2 + \frac{\sigma_{subm}^2}{n_{subm}}$ .

Se observa que el modelo **mm1.logCN.cs** plantea observaciones correlacionadas a través del tiempo, a pesar de suponer errores independientes, pero la magnitud de la correlación entre las observaciones es la misma para dos fechas cualesquiera, y no depende de la distancia entre las mismas.

En el modelo **mm1.logCN.cs** hay tres términos aleatorios, el término asociado a efecto de submuestra genera los residuos de este modelo y permite evaluar los supuestos sobre  $\zeta_{ikjl}$ .

En la Fig. 4.11 se puede apreciar que la dispersión de los residuos estandarizados depende en alguna medida del sistema de laboreo.

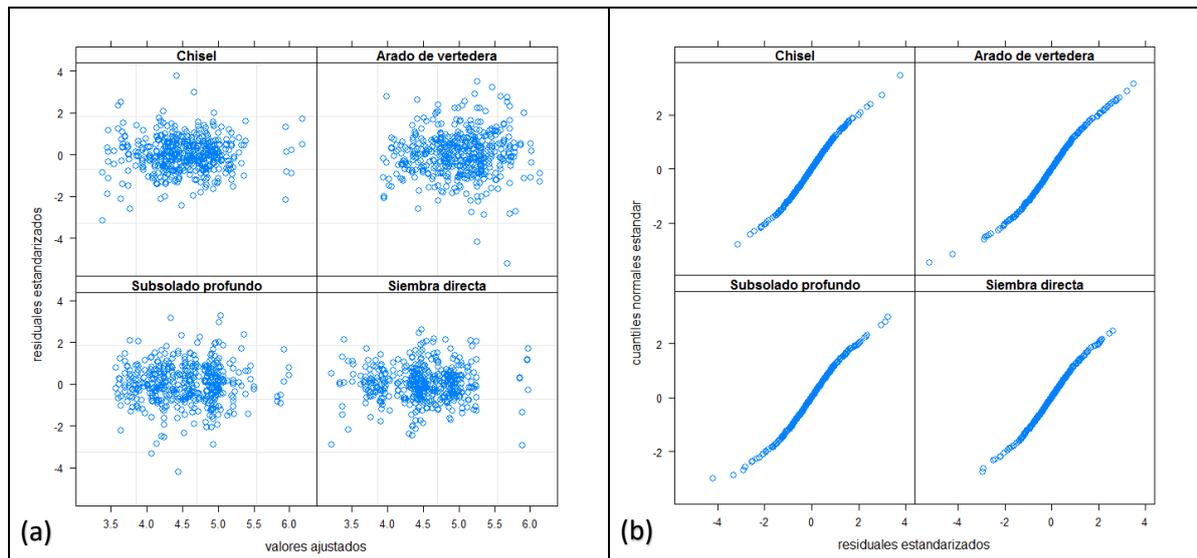


Fig. 4.11. (a) Residuales estandarizados versus valores ajustados en mm1.logCN.cs discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo mm1.logCN.cs (gráfico cuantil-cuantil) discriminados para cada laboreo.

En Siembra directa se observa la menor dispersión de los residuales a nivel submuestra y en Arado de vertedera la mayor (Fig. 4.11.a)). También se observan algunos datos atípicos (residuos estandarizados en valor absoluto mayores que 3) en todos los laboreos excepto en Siembra directa (Fig.4.11.a) y b)). Esto estaría indicando una falta de adecuación de los datos a una distribución normal o la falla en otros supuestos, como el de homogeneidad de varianzas.

La evaluación de los supuestos sobre los otros efectos aleatorios del modelo, los de subparcelas y parcelas en este caso, se realizan en base a los eblups. Sobre todo, se hace hincapié en la evaluación de los efectos de subparcelas y no así en los de parcelas ya que para estos la cantidad de datos (16 parcelas, 4 para cada laboreo) no es suficiente para diagnosticar la distribución de probabilidad ni las características de las varianzas. No obstante, a continuación, se muestran en la Fig. 4.12 cuatro gráficos de diagnóstico para los efectos de parcelas, a través de sus eblups. Un histograma de densidad y la función de densidad teórica según una distribución normal, en el primer panel, la función de distribución acumulada dada por los datos (empírica) y la teórica, un gráfico cuantil-cuantil y un gráfico probabilidad-probabilidad.

Si bien de las Fig. 4.12. no se ve un buen ajuste de los eblups de efectos de parcelas al supuesto de normalidad, se vuelve a destacar que el número de datos (16) no permite obtener información que confirme o no este supuesto.

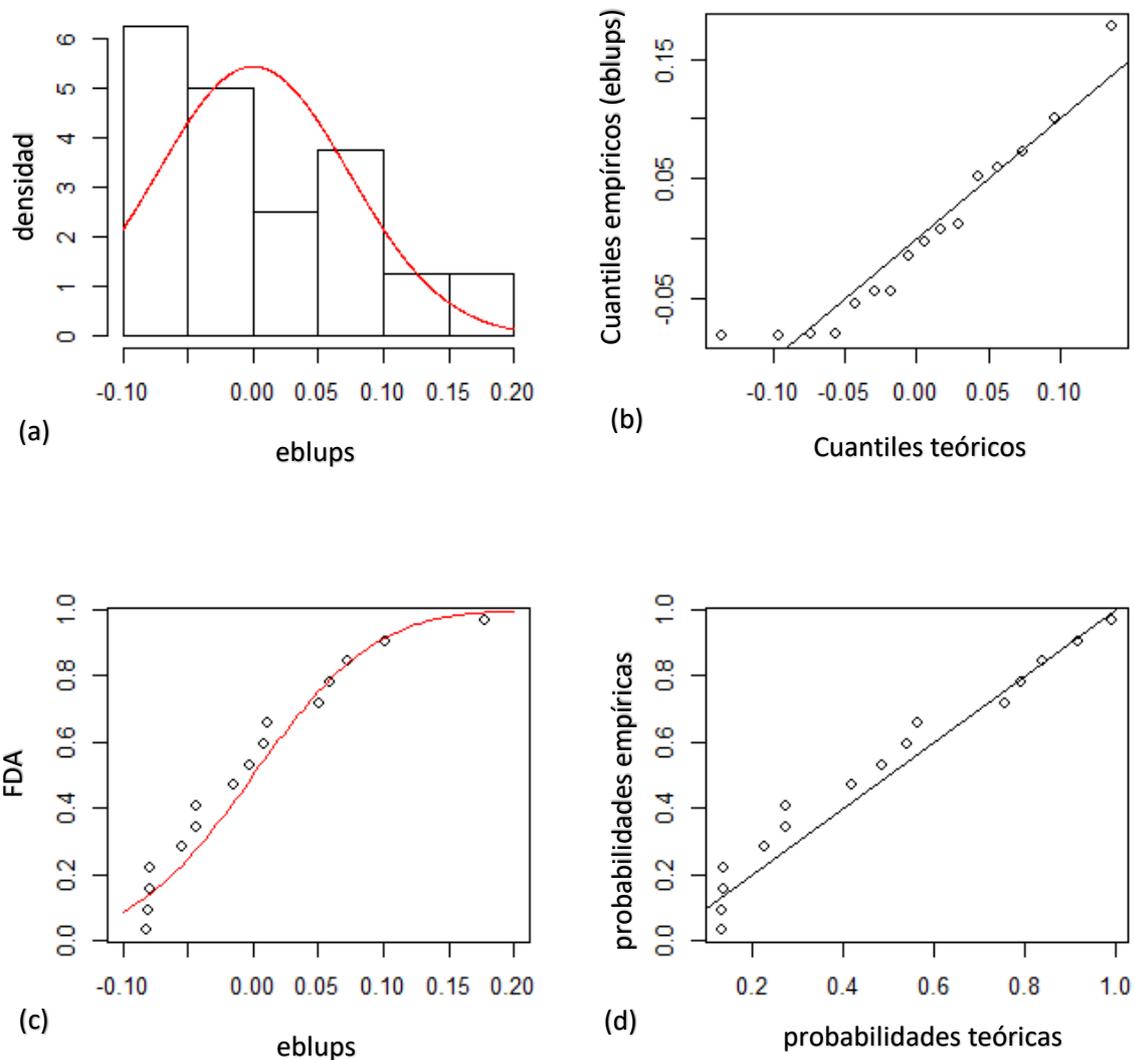


Fig. 4.12. Gráficos de diagnóstico sobre los eblups (mejores predictores lineales insesgados empíricos) de efectos de parcelas del mm1.logCN.cs. (a) histograma de densidad y la función de densidad teórica según una distribución normal, (b) gráfico cuantil-cuantil según una distribución normal, (c) función de distribución acumulada (FDA) dada por los datos (empírica) y la teórica según una distribución normal, y (d) gráfico probabilidad-probabilidad según una distribución normal. Gráficos obtenidos con funciones del paquete `fitdistrplus` de R.

Los efectos aleatorios de subparcelas muestran una leve distribución asimétrica (Fig.4.13.a) y sobre todo en la Fig. 4.13. b) se observa en forma más marcada el alejamiento de la

distribución normal en los valores extremos, se observan colas pesadas en la distribución de los residuos.

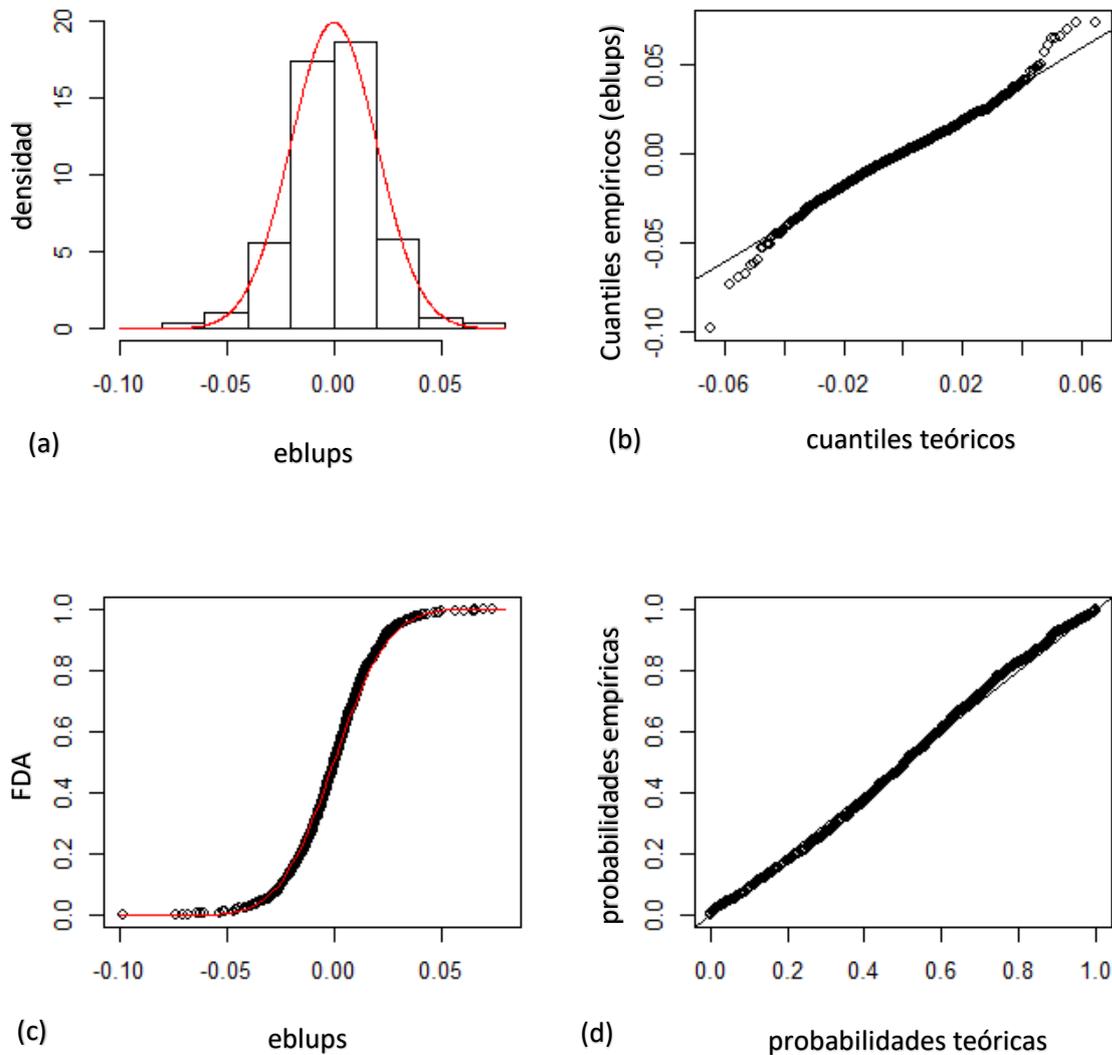


Fig. 4.13. Gráficos de diagnóstico sobre los eblups (mejores predictores lineales insesgados empíricos) de efectos de subparcelas del mm1.logCN.cs. (a) histograma de densidad y la función de densidad teórica según una distribución normal, (b) gráfico cuantil-cuantil según una distribución normal, (c) función de distribución acumulada dada por los datos (empírica) y la teórica según una distribución normal, y (d) gráfico probabilidad-probabilidad según una distribución normal. Gráficos obtenidos con funciones del paquete `fitdistrplus` de R.

En la Fig. 4.14. puede apreciarse que la varianza entre los efectos de subparcelas es bastante similar entre los cuatro laboreos.

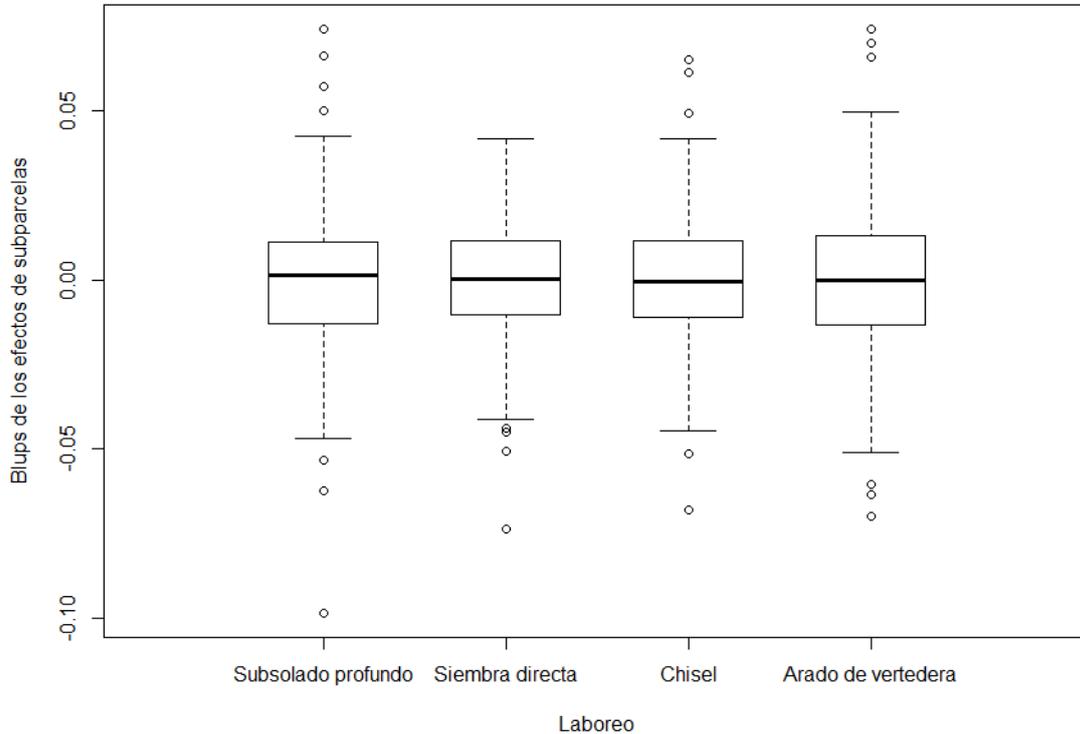


Fig. 4.14. Diagramas de caja para los eblups de los efectos aleatorios de subparcelas del modelo mm1.logCN.cs. en cada tipo de laboreo.

Las pruebas F para los efectos fijos (Salida 4.1.) y las estimaciones de varianzas (Salida 4.2.) que se obtienen son (sentencia R y salida):

Salida 4.1. Sentencia y salida R para las pruebas de efectos fijos del modelo mm1.logCN.cs.

```
anova(mm1.logCN.cs)
```

```
##           numDF denDF   F-value p-value
## ...
## bloque           3     9     0.991 0.4397
## laboreo          3     9    18.036 0.0004
## FECHA            55    660   30.512 <.0001
## laboreo:FECHA    165    660    2.185 <.0001
```

Salida 4.2. Sentencia y salida R para las estimaciones de varianzas (Variance) y desvíos estándar (StdDev) para el modelo mm1.logCN.cs.

```
VarCorr(mm1.logCN.cs)
```

```
##           Variance   StdDev
## bqL =      pdLogChol(1)
## (Intercept) 0.011053071 0.10513359
## bqL.F =      pdLogChol(1)
## (Intercept) 0.007179916 0.08473439
## Residual    0.176703904 0.42036163
```

Así, las estimaciones de las componentes de varianza obtenidas son:  $\hat{\sigma}_p^2 = 0.01105$ ,  $\hat{\sigma}_{pf}^2 = 0.00718$ ,  $\hat{\sigma}_{subm}^2 = 0.17670$  (Salida 4.2.), donde los valores están en escala logarítmica del CN en  $\text{kg ha}^{-1}$ .

La correlación, postulada por este modelo, entre observaciones de dos fechas de muestreo en una misma parcela es estimada en 0.1037 para el caso en que se han tomado dos submuestras en cada una, 0.1219 para el caso de dos submuestras para una fecha y tres submuestras para la otra y 0.1433 para el caso de dos fechas donde se han tomado tres submuestras en cada una. En cualquier caso, las correlaciones son bajas desde que la varianza debida a efectos de parcelas (0.0111) es relativamente baja (5.7%) respecto a la varianza total (0.1949).

#### 4.3.1.2 Modelo sin especificación del submuestreo

El modelo básico de mediciones repetidas para el logaritmo de CN en el perfil total del suelo en el ensayo de Agramunt con promedio de submuestras, expresado en forma simple, es

**(mm1.logCN):**  $\log(\overline{\text{CN}}) = \text{bloque} + \text{laboreo} + \text{parcela} + \text{fecha} + \text{laboreo:fecha} + \text{subparcela}$ , con efectos aleatorios de *parcela* y *subparcela* (error), cada uno con distribución normal de media cero y varianzas desconocidas.

El modelo expresa que el valor del logaritmo de CN (promedio de las submuestras en una parcela y fecha de muestreo,  $\log(\overline{\text{CN}})$ ) depende del bloque, del laboreo, de la fecha de muestreo, de la interacción laboreo:fecha (efectos fijos), y también de la parcela y de la interacción parcela:fecha (subparcela) (esta última incluye la variación entre submuestras) (efectos aleatorios).

O, en términos más formales,

**(mm1.logCN):**  $\log(\overline{\text{CN}})_{ikj} = \mu + \text{bloq}_k + \text{lab}_i + \delta_{ik} + \text{fech}_j + \text{lab:fech}_{ij} + \varepsilon_{ikj}^*$

$(i = 1, \dots, 4 \quad j = 1, \dots, 57, \quad k = 1, \dots, 4)$  con  $\delta_{ik} \sim \text{indep } N(0, \sigma_p^2)$ ,  $\varepsilon_{ikj}^* \sim \text{indep } N(0, \sigma_e^2)$  y

*todos los términos aleatorios independientes entre sí*

En el modelo **mm1.logCN** el logaritmo de CN (promedio de las submuestras en una parcela y fecha de muestreo) se supone con distribución normal con media marginal (promediado a través de los efectos aleatorios) que depende fundamentalmente del laboreo y la fecha de muestreo, y también del bloque ( $\mu_{ikj} = \mu + bloq_k + lab_i + fech_j + lab:fech_{ij}$ ). En la media marginal solo intervienen los efectos fijos. Y la varianza marginal es  $\sigma_p^2 + \sigma_e^2$ . La varianza del logaritmo de  $\overline{CN}$  no cambia con el laboreo, ni con la fecha ni con el bloque, y la magnitud de esa varianza es  $\sigma_p^2 + \sigma_e^2$ .

Al igual que mm1.logCN.cs, el modelo **mm1.logCN** postula implícitamente una correlación entre las observaciones en la misma parcela a distintas fechas. Esta correlación está inducida por los efectos aleatorios de parcelas. La magnitud de la varianza del logaritmo de  $\overline{CN}$  entre parcelas impacta directamente sobre la magnitud de dicha correlación. Más específicamente la correlación en términos de las componentes de varianza está dada por,

$$\sigma_p^2 / (\sigma_p^2 + \sigma_e^2)$$

Se observa que la magnitud de correlación entre las observaciones en una misma parcela para dos fechas cualesquiera no depende de la distancia entre ellas. El modelo se ajusta con la función `lme` del paquete `nlme`. También puede ajustarse con la función `lmer` del paquete `lme4`.

En el modelo **mm1.logCN** hay dos términos aleatorios, el término asociado a efecto de subparcela es el que genera los residuos de este modelo.

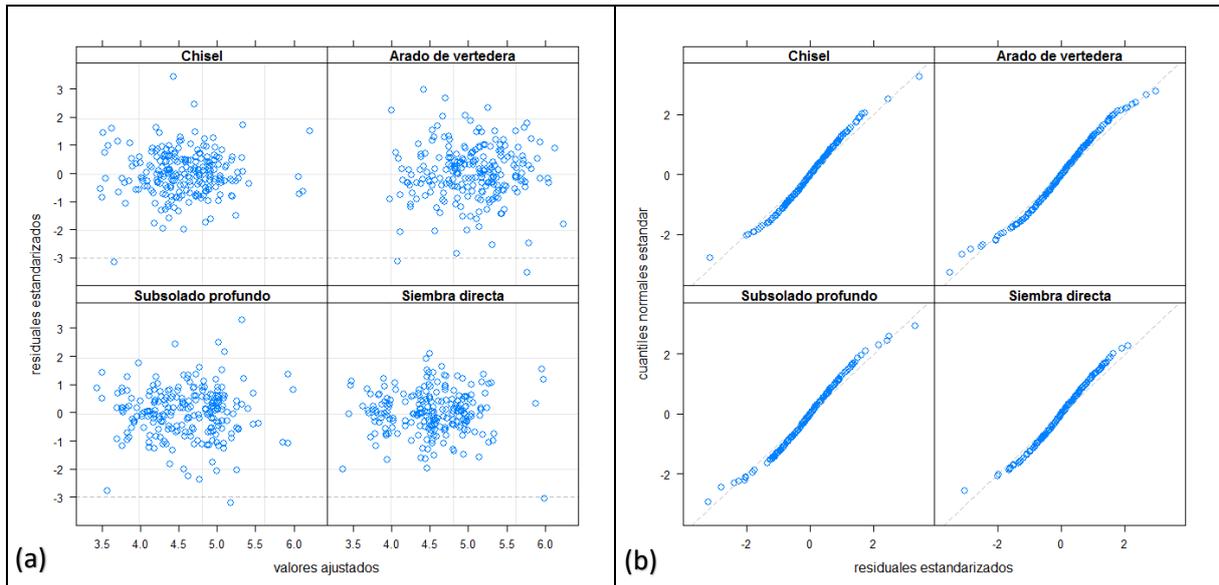


Fig. 4.15. (a) Residuales estandarizados versus valores ajustados en mm1.logCN discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo mm1.logCN (gráfico cuantil-cuantil) discriminados para cada laboreo.

En la Fig. 4.15. (a y b) se observa en Siembra directa la menor dispersión de los residuales, con todos los residuos, excepto uno, entre valores muy cercanos a -2 y 2. También se observa una aceptable concordancia con una distribución normal y algunos pocos datos atípicos (residuos estandarizados en valor absoluto mayores que 3) en todos los laboreos excepto en Siembra directa (Fig.4.11.a) y b)).

#### 4.3.2 Modelo de mediciones repetidas con heterogeneidad de varianzas

##### 4.3.2.1 Modelo con especificación del submuestreo

De acuerdo con los resultados previos, el próximo modelo a considerar es aquel que contempla heterogeneidad de varianza residual (término aleatorio a nivel submuestra), mm2.logCN.cs (Tabla 4.1). Este modelo se especifica igual que el modelo mm1.logCN.cs, excepto en los supuestos sobre el término de submuestreo. Estos supuestos en el modelo de heterogeneidad de varianzas, **mm2.logCN.cs**, son

$$\zeta_{ikjl} \sim \text{indep } N(0, \sigma_{\text{subm},i}^2) \quad i = \text{"Subsolado profundo", "Siembra directa", "Chisel", "Arado de vertedera"}$$

Es decir, en el modelo **mm2.logCN.cs** se definen cuatro parámetros de varianza de submuestreo, uno para cada laboreo, donde el subíndice "i" en  $\sigma_{\text{subm},i}^2$  refleja esta particularidad.

Es claro que no es el único modelo que considera heterogeneidad de varianzas. Hay muchas formas en que las varianzas pueden diferir entre sí, algunas de esas formas se indicaron en la sección 3.2.2.2. del Capítulo 3.

La validación de supuestos se realiza solo a nivel efectos de submuestras a través de los residuos del modelo. En la Fig. 4.16 a) puede apreciarse una dispersión similar de los residuos estandarizados entre los cuatro laboreos, producto de haber considerado en cada uno su varianza propia.

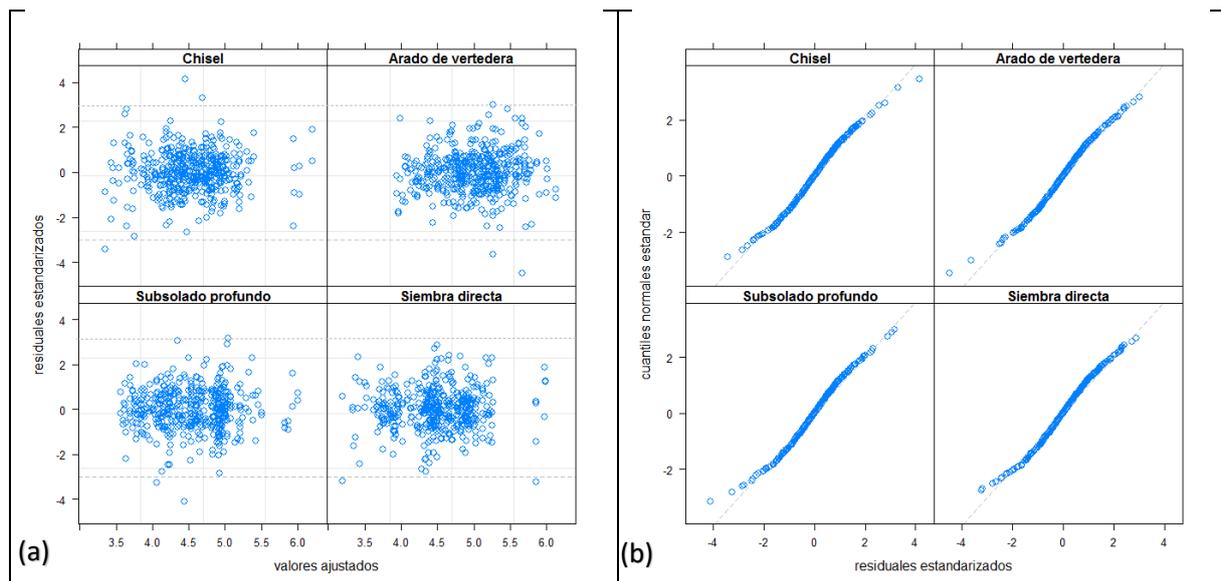


Fig. 4.16. (a) Residuales estandarizados versus valores ajustados en `mm2.logCN.cs` discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo `mm2.logCN.cs` (gráfico cuantil-cuantil) discriminados para cada laboreo.

Tanto en la Fig. 4.16.a como en la fig. 4.16.b pueden observarse algunos datos atípicos, bajos para Subsulado profundo y Arado de vertedera, y altos para Chisel.

Si el supuesto de distribución normal no es tan alejado de la realidad de los datos, la prueba del cociente de verosimilitud, indica (Salida 4.3.,  $p < 0.0001$ ) que un modelo con distintas varianzas en el submuestreo según tipo de laboreo (`mm2.logCN.cs`) es mejor que uno con componente única para varianza de submuestreo (`mm1.logCN.cs`). La salida (y sentencia) obtenida en el ambiente R para esta prueba es:

Salida 4.3. Prueba del cociente de verosimilitud para la igualdad de varianzas de submuestreo entre laboreos

```
anova(mm2.logCN.cs, mm1.logCN.cs)
```

```
##      Model      df      AIC      BIC      logLik      Test      L.Ratio      p-value
## mm2.logCN.cs  1 233 2725.490 3974.986 -1129.745
## mm1.logCN.cs  2 230 2754.059 3987.468 -1147.030 1 vs 2 34.56917 <.0001
```

Las estimaciones de las componentes de varianzas del logaritmo de CN para el modelo mm2.logCN.cs, la varianza debida a parcelas, la varianza debida a subparcelas y la varianza debida a submuestreo, se obtienen de las siguientes salidas (Salida 4.4. y Salida 4.5.):

Salida 4. 4. Sentencia y salida R para las estimaciones de varianzas (Variance) y desvíos estándar (StdDev) para el modelo mm2.logCN.cs.

**VarCorr**(mm2.logCN.cs)

```
##      Variance      StdDev
## bqL =      pdLogChol(1)
## (Intercept) 0.010701196 0.10344659
## bqL.F =      pdLogChol(1)
## (Intercept) 0.008423519 0.09177973
## Residual 0.183749405 0.42866001
```

Salida 4.5. Salida R para las estimaciones de desvíos estándar (StdDev, Parameter estimates) para el modelo mm2.logCN.cs.

```
## Random effects:
## Formula: ~1 | bqL
##      (Intercept)
## StdDev: 0.1034466
##
## Formula: ~1 | bqL.F %in% bqL
##      (Intercept) Residual
## StdDev: 0.09177973 0.42866
##
## Variance function:
## Structure: Different standard deviations per stratum
## Formula: ~1 | laboreo
## Parameter estimates:
## Subsulado profundo      Siembra directa      Chisel
##      1.0000000      0.8749196      0.8783832
## Arado de vertedera
##      1.1350930
## Number of Observations: 1803
## Number of Groups:
##      bqL bqL.F %in% bqL
##      16      896
```

Así,  $\hat{\sigma}_p^2 = 0.0107$ ,  $\hat{\sigma}_{pf}^2 = 0.0084$  (Salida 4.4.) y hay una componente  $\hat{\sigma}_{subm}^2$  para cada laboreo, todas en escala logarítmica ( $\log(\text{kg ha}^{-1})$ ).

Las estimaciones rotuladas como “Residual” en ambas salidas (Salida 4.4. y Salida 4.5.) corresponden a las estimaciones de desvío estándar y varianza para el submuestreo en el

72

laboreo de Subsulado profundo. Los coeficientes en la salida (Parameter estimates, Salida 4.5.) rotulados con los nombres de los laboreos: 1, 0.875, 0.878 y 1.135 indican que los desvíos estándar para los otros laboreos, Siembra directa, Chisel y Arado de vertedera, son aproximadamente el 87.5%, 87.8% y 113.5% del desvío estándar correspondiente a Subsulado profundo. Entonces los desvíos estándar estimados para el submuestreo son (en  $\log(\text{kg ha}^{-1})$ ):

$$\hat{\sigma}_{\text{subm,Subsolado profundo}} = 0.4287, \hat{\sigma}_{\text{subm,Siembra directa}} = 0.3750, \hat{\sigma}_{\text{subm,Chisel}} = 0.3765, \\ \hat{\sigma}_{\text{subm,Arado de vertedera}} = 0.4866$$

Y las varianzas para el submuestreo, son (en  $\log^2(\text{kg ha}^{-1})$ ):

$$\hat{\sigma}_{\text{subm,Subsolado profundo}}^2 = 0.1837, \hat{\sigma}_{\text{subm,Siembra directa}}^2 = 0.1407, \hat{\sigma}_{\text{subm,Chisel}}^2 = 0.1418, \\ \hat{\sigma}_{\text{subm,Arado de vertedera}}^2 = 0.2367$$

La varianza de submuestreo más grande (Arado de vertedera) es 1.68 veces la varianza más chica (Siembra directa), es decir la primera es 68% mayor a la segunda. Si bien la prueba del cociente de verosimilitud indicó que las cuatro varianzas de submuestreo no son iguales, la mayor varianza no llega a ser el doble de la más pequeña lo que no incide demasiado en el análisis de los efectos fijos y se refleja a continuación. Los resultados obtenidos son muy similares a las pruebas F del modelo mm1.logCN.cs.

Las pruebas F correspondientes a los efectos fijos, siguiendo el modelo mm2.logCN.cs, arrojan (sentencia R y salida):

Salida 4.6. Sentencia y salida R para las pruebas de efectos fijos del modelo mm2.logCN.cs.

```
anova(mm2.logCN.cs)
##           numDF denDF   F-value p-value
## ...
## bloque           3     9    0.961  0.4520
## laboreo          3     9   18.057  0.0004
## FECHA           55   660   32.402 <.0001
## laboreo:FECHA   165   660    2.070 <.0001
```

Al igual que en el modelo mm1.logCN.cs, en el modelo mm2.logCN.cs, la interacción laboreo:fecha es significativa con  $p < 0.0001$ . Los efectos del laboreo sobre el logaritmo del CN a través del tiempo no son los mismos para los cuatro laboreos, o de otro modo, las diferencias entre los promedios de logaritmo del CN en por lo menos dos laboreos cambian, por lo menos, entre dos fechas.

Continuando con la consideración de heterogeneidad de varianzas en un modelo con submuestreo se ajusta el modelo **mm2.logCN.cs.B** (no figura en Tabla 4.1.), el cual solo difiere del modelo mm2.logCN.cs en los supuestos sobre los efectos de subparcelas. Agregando ahora diferentes varianzas entre efectos de subparcelas para cada laboreo. En relación al modelo mm2.logCN.cs se modifican los supuestos sobre  $\varepsilon_{ikj}$  de la siguiente manera:

$$\varepsilon_{ikj} \sim \text{indep } N(0, \sigma_{sp,i}^2) \quad i = \text{"Subsolado profundo", "Siembra directa", "Chisel", "Arado de vertedera"}$$

Es decir, el modelo **mm2.logCN.cs.B** contempla en el modelo con submuestreo diferentes varianzas entre subparcelas y diferentes varianzas en submuestreo, en ambos casos, según laboreos. Sin embargo, la comparación del modelo **mm2.logCN.cs.B** con el modelo **mm2.logCN.cs** a través de la prueba del cociente de verosimilitud indica que no es necesario considerar diferentes varianzas entre laboreos a nivel subparcela ( $p=0.6046$ ).

#### 4.3.2.2 Modelo sin especificación del submuestreo

Si bien en el modelo mm1logCN no resultó evidente la necesidad de modelar heterogeneidad de varianzas residuales (a nivel subparcela) se ajusta el modelo mm2logCN (Tabla 4.1). Este modelo se especifica igual que el modelo mm1.logCN, excepto en los supuestos sobre el término de subparcela. Estos supuestos en el modelo de heterogeneidad de varianzas, **mm2.logCN**, son

$$\varepsilon_{ikj} \sim \text{indep } N(0, \sigma_{e,i}^2) \quad i = \text{"Subsolado profundo", "Siembra directa", "Chisel", "Arado de vertedera"}$$

Es decir, en el modelo **mm2.logCN** se definen cuatro parámetros de varianza de error, una para cada laboreo, donde el subíndice "i" en  $\sigma_{e,i}^2$  refleja este supuesto.

Es claro que no es el único modelo que considera heterogeneidad de varianzas. Hay muchas formas en que las varianzas pueden diferir entre sí, algunas de esas formas se indicaron en la sección 3.2.2.2. del capítulo 3.

La validación de supuestos se realiza solo a nivel de los residuos del modelo. En la Fig. 4.17 a) puede apreciarse una dispersión similar de los residuos estandarizados entre los cuatro laboreos, producto de haber considerado en cada uno su varianza propia. Se observan pocos datos atípicos (Fig. 4.17. a y b).

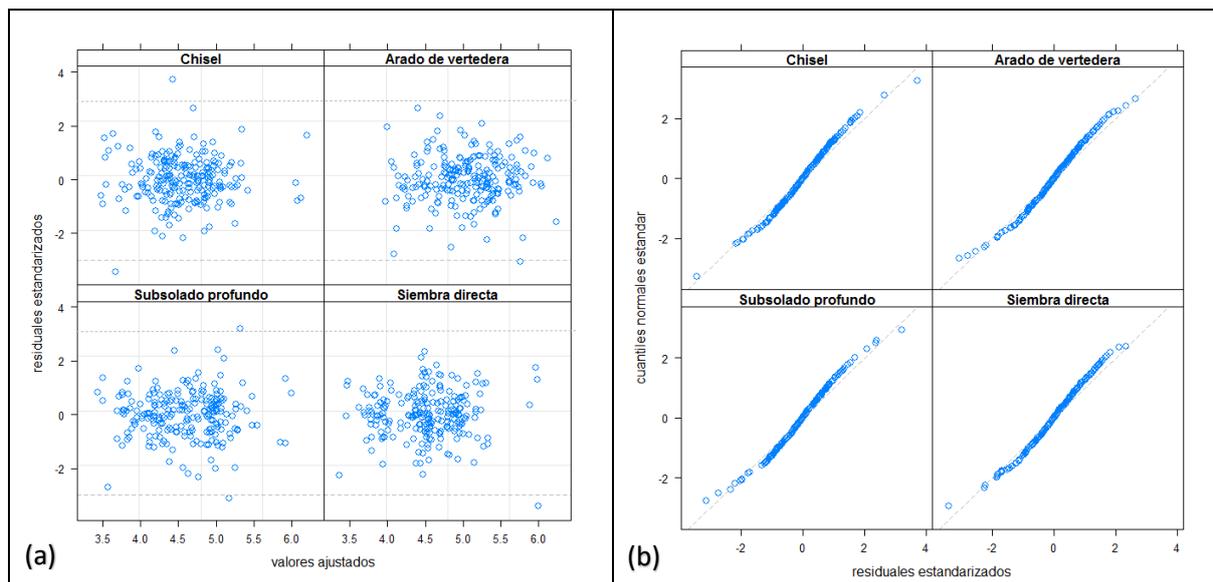


Fig. 4.17. (a) Residuales estandarizados versus valores ajustados en  $\text{mm}2.\log\text{CN}$  discriminados para cada laboreo, (b) cuantiles de una distribución normal versus residuales estandarizados del modelo  $\text{mm}2.\log\text{CN}$  (gráfico cuantil-cuantil) discriminados para cada laboreo.

La prueba del cociente de verosimilitud indica que hay distintas varianzas (Salida 4.7.,  $p = 0.0078$ ) para el término de error (subparcela) según tipo de laboreo ( $\text{mm}2.\log\text{CN}$ ). La salida (y sentencia) obtenida en el ambiente R para esta prueba se muestra en la salida 4.7.

Salida 4.7. Prueba del cociente de verosimilitud para la igualdad de varianzas de error entre laboreos.

```
anova(mm2.logCN, mm1.logCN)
```

```
## Model      df      AIC      BIC      logLik  Test  L.Ratio p-value
## mm2.logCN 1 232 1142.272 2186.571 -339.136
## mm1.logCN 2 229 1148.141 2178.936 -345.070 1 vs 2 11.86893 0.0078
```

Salida R en la que se obtiene información sobre estimaciones de varianzas para el modelo  $\text{mm}2.\log\text{CN}$ :

Salida 4.8. Salida R para las estimaciones de desvíos estándar (StdDev, Parameter estimates) para el modelo  $\text{mm}2.\log\text{CN}$ .

Random effects:

```
Formula: ~1 | bqL
```

```
(Intercept) Residual
```

```
StdDev: 0.1049814 0.3232159
```

Variance function:

```
Structure: Different standard deviations per stratum
```

```
Formula: ~1 | laboreo
```

Parameter estimates:

Subsolado profundo	Siembra directa	Chisel	Arado de vertedera
1.0000000	0.8683493	0.8978903	1.1034844

Number of Observations: 893

Number of Groups: 16

La estimación rotulada como “Residual” en la salida corresponde a la estimación de desvío estándar para el error en el laboreo de Subsolado profundo. Los coeficientes 1, 0.868, 0.898 y 1.103 indican que los desvíos estándar para los errores de los otros laboreos, Siembra directa, Chisel y Arado de vertedera, son aproximadamente el 86.8%, 89.8% y 110.3% del desvío estándar correspondiente a Subsolado profundo. Entonces los desvíos estándar estimados para el error son (en  $\log(\text{kg ha}^{-1})$ ):

$$\hat{\sigma}_{e,\text{Subsolado profundo}} = 0.3232, \quad \hat{\sigma}_{e,\text{Siembra directa}} = 0.2807, \quad \hat{\sigma}_{e,\text{Chisel}} = 0.2902, \\ \hat{\sigma}_{\text{subm},\text{Arado de vertedera}} = 0.3567$$

Y las varianzas para el término de error, son (en  $\log^2(\text{kg ha}^{-1})$ ):

$$\hat{\sigma}_{e,\text{Subsolado profundo}}^2 = 0.1045, \quad \hat{\sigma}_{e,\text{Siembra directa}}^2 = 0.0788, \quad \hat{\sigma}_{\text{subm},\text{Chisel}}^2 = 0.0842, \\ \hat{\sigma}_{\text{subm},\text{Arado de vertedera}}^2 = 0.1272$$

La varianza de error más grande (Arado de vertedera) es 1.61 veces la varianza más chica (Siembra directa), es decir la primera es 61% mayor a la segunda. Si bien la prueba del cociente de verosimilitud indicó que las cuatro varianzas de error no son iguales, la mayor varianza no llega a ser el doble de la más pequeña.

### 4.3.3 Consideraciones parciales de los modelos ajustados

Los modelos con heterogeneidad de varianzas han mostrado mejoras respecto a los modelos de homogeneidad de varianzas sobre todo en aquel que explicita el término de submuestreo, menos marcado en el modelo sin especificación de submuestreo. El próximo paso es avanzar sobre la posible estructura de correlación entre los efectos de subparcelas (error) a través del tiempo en la misma parcela, los que hasta ahora se han supuesto independientes. Como la operatividad en R, y las funciones preestablecidas en el paquete `nLme` facilitan la especificación de algunas estructuras de correlación serial sobre el término

“residual”, es decir el último nivel de efecto aleatorio (error) en el modelo, con una sola observación en cada tiempo por sujeto (parcela en este caso) se continúan los ajustes de modelos sobre el conjunto de datos promediando las submuestras de CN en cada subparcela. Es decir, en la línea de los modelos mmX.logCN (i.e. mm1.logCN y mm2.logCN, Tabla 4.1.).

En la Fig. 4.18 se observa un valor muy bajo en todos los laboreos, excepto en Arado de vertedera, o por lo menos no tan marcado como en los otros tres laboreos, en un mismo bloque para una misma fecha. La inspección del conjunto de datos lleva a identificar que efectivamente el 9/07/2013 en el bloque 1 hay solo una determinación (una sola submuestra) para cada uno de esos tres laboreos y son datos extremos en relación al resto. La eliminación de esos datos no cambia sustancialmente los ajustes realizados de los modelos de mediciones repetidas en las secciones previas de este capítulo, por lo cual esos datos se mantienen en el conjunto de datos para los próximos análisis.

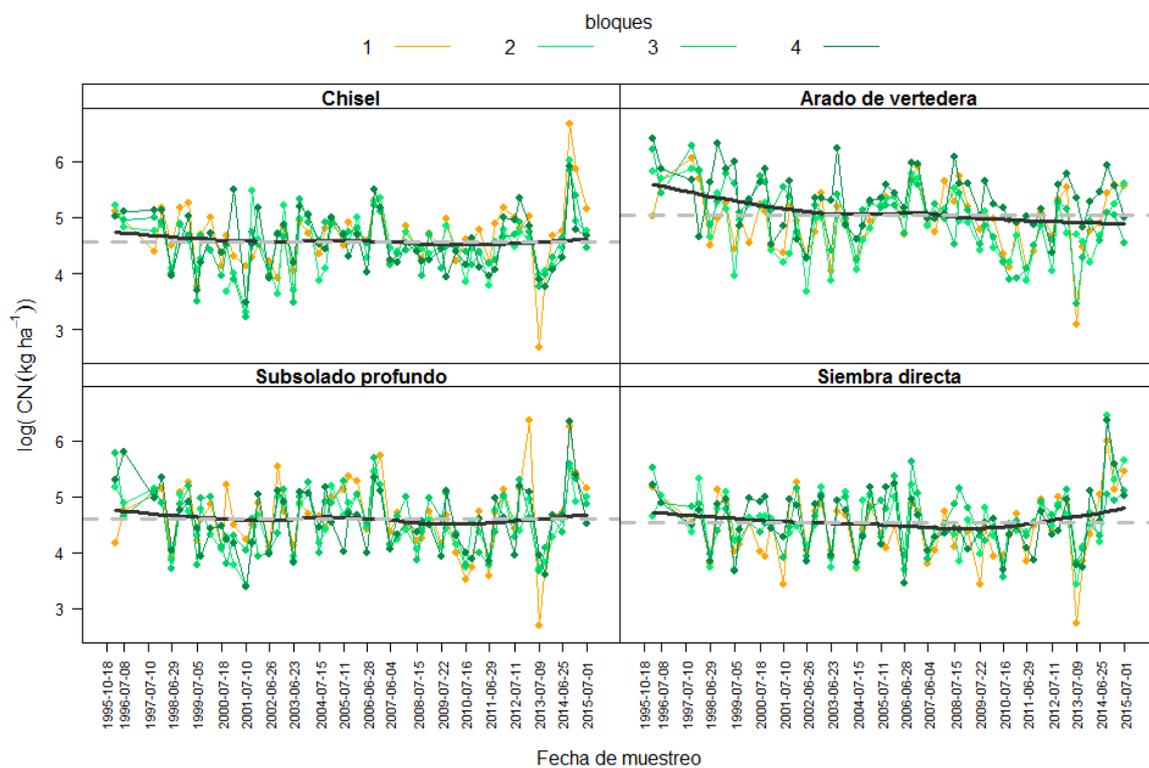


Fig. 4.18. Logaritmo del contenido de nitrógeno (CN) en el perfil completo del suelo (0-90 cm) a través del tiempo, desde el año 1995 al 2015, cada panel corresponde a un tipo de laboreo (Arado de vertedera, Chisel, Siembra directa y Subsulado profundo). Los puntos representan el logaritmo del promedio de CN en las submuestras, con diferentes colores se distinguen los cuatro bloques, en cada panel la línea entrecortada gris indica el valor de logaritmo de CN promedio en todo el período y la línea continua negra es una curva de suavizado.

#### 4.3.4 Modelo de mediciones repetidas con heterogeneidad de varianzas y correlación entre errores

Es generalmente aceptado que, si hubiese correlación en una serie de observaciones o errores, esta sería mayor entre observaciones o errores más cercanos que entre dos observaciones o errores más alejados entre sí. Así, una de las estructuras de correlación serial más utilizada y que aplica este concepto, es la autorregresiva de orden 1 (AR1). Tiene varios aspectos a favor, por un lado, con un solo parámetro la estructura queda definida y desde lo conceptual, como ya se dijo, modela observaciones más cercanas con mayor correlación que las alejadas entre sí. Es decir, la correlación entre dos observaciones o términos aleatorios en una estructura autorregresiva de orden 1 depende de un parámetro y de la distancia existente entre las mismas. Una desventaja es que solo puede utilizarse en mediciones equiespaciadas. Pero una generalización de esta para el caso de no equiespaciamiento es la autorregresiva continua de orden 1 implementada en R (función `corCAR1`). Dentro de los modelos de correlaciones espaciales implementados en el paquete `n1me` de R y que pueden adaptarse al caso unidimensional (tiempo) se hallan los modelos, exponencial (es equivalente a la `corCAR1`), gaussiano, lineal, cuadrático racional y esférico (Pinheiro y Bates, 2000).

En esta instancia, para el análisis de posibles estructuras de correlación en los errores, se necesita en el archivo de datos contener una variable cuantitativa con valores monótonamente crecientes que identifique las fechas de muestreo desde la primera fecha de muestreo en el año 1995 hasta la última fecha de muestreo en el año 2015. Esa variable debe reflejar el tiempo transcurrido entre las fechas en alguna unidad temporal (días, meses, etc.). De esa forma se define la variable “días” utilizando paquetes y funciones apropiadas en R para el manejo de fechas.

Se explora si las correlaciones entre errores mantienen un patrón de cambio o no en función de la distancia en el tiempo, a través del semivariograma. En particular, se utiliza un estimator robusto del semivariograma propuesto por Cressie y Hawkins e implementado en el paquete `n1me` (Pinheiro y Bates, 2000), que reduce la influencia de datos extremos. El semivariograma es calculado en base a los residuos estandarizados del modelo `mm2.logCN` adaptando la función de R para este trabajo de tesis. La Fig. 4.19 muestra el semivariograma

muestral, al que también se le agrega un suavizado para facilitar la visualización del patrón del semivariograma.

El análisis de posibles correlaciones en los errores es importante porque algunos autores indican que, si existe la correlación en los mismos y no se especifica en el modelo, las pruebas de hipótesis para los efectos fijos tienden a dar valores de significación menores a los que debería (Schabenberger y Pierce, 2002).

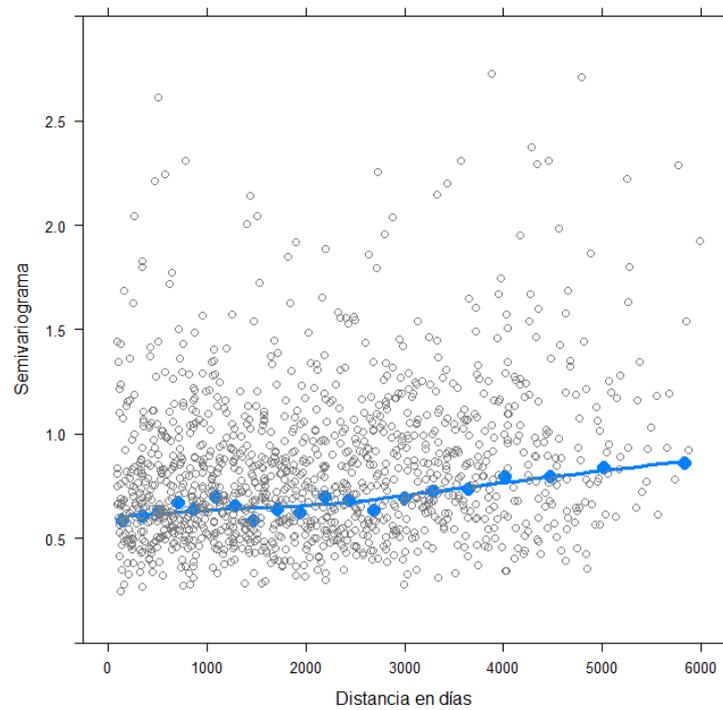


Fig. 4.19. Semivariograma muestral correspondiente a los residuos estandarizados del modelo mm2.logCN (puntos grises). Se superpone el semivariograma muestral agrupando las distancias en 20 intervalos (puntos azules) y un suavizado loess (línea azul).

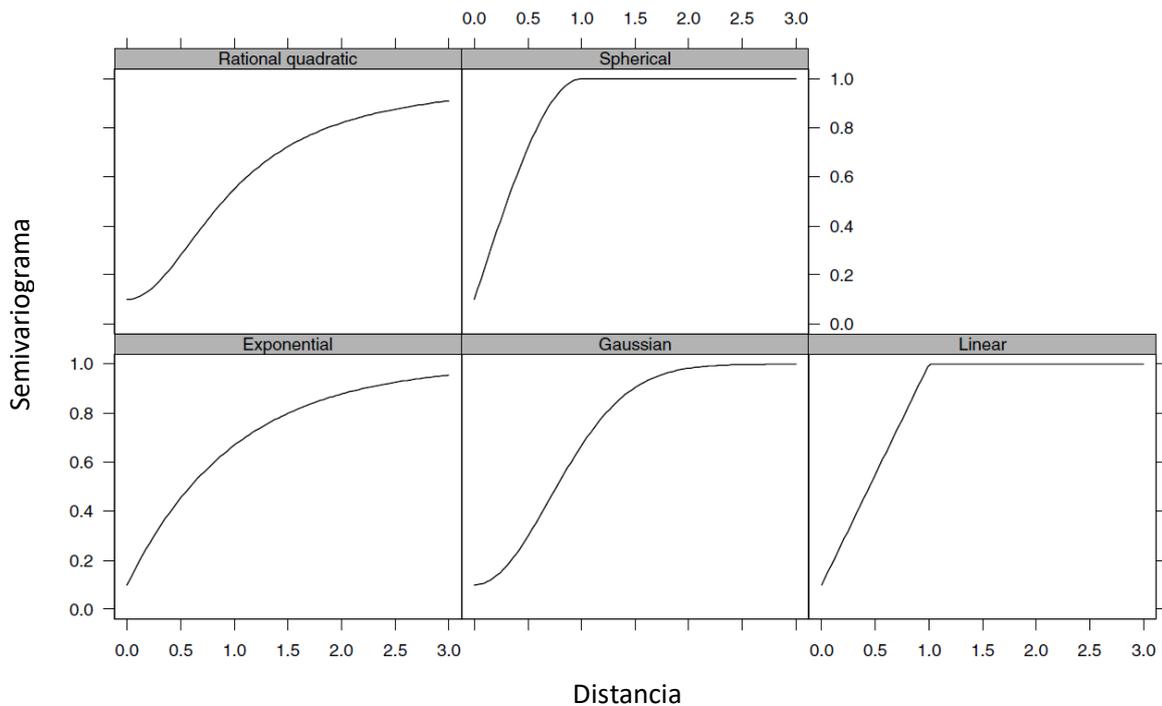


Fig. 4.20. Gráficos de semivariogramas para algunos modelos de correlaciones espaciales isotrópicos adaptado de la figura 5.9 de Pinheiro y Bates (2000), con parámetro de correlación  $\rho = 1$  y semivariograma = 0.1 para distancia 0 (efecto pepita).

Los semivariogramas de la Fig. 4.20 crecen monótonamente con la distancia y varían entre 0 y 1, correspondiendo a funciones de correlación no negativas que decrecen monótonamente (Pinheiro y Bates, 2000).

De la Fig. 4.19 se observa un semivariograma con patrón de crecimiento lineal, aunque de pendiente poco pronunciada. La correlación disminuye linealmente a medida que aumenta la distancia entre residuos, pero con un patrón leve. El semivariograma mostrado en la Fig. 4.19 no guarda analogía con ninguna de las estructuras de correlación espaciales mencionadas e implementadas en R (Fig. 4.20.) para poder ser ajustadas con la función `lme`. No obstante, a modo de ejemplificar el ajuste y evaluación del modelo se ajusta un modelo para mediciones repetidas con diferentes varianzas residuales para laboreos y correlación de estructura cuadrática racional entre los errores a través del tiempo para una misma parcela.

Se ajusta el **mm3.logCN** (Tabla 4.1.) al conjunto de datos habiendo promediado los CN en las submuestras, como ya se indicó. Al modelo **mm2.logCN** con heterogeneidad de varianzas residuales se le incorpora la estructura de correlación cuadrática racional entre los errores. Es decir,

**(mm3.logCN):**  $\log(\overline{CN}) = \text{bloque} + \text{laboreo} + \text{parcela} + \text{fecha} + \text{laboreo:fecha} + \text{error}$ ,

O en términos más formales

**(mm3.logCN):**  $\log(\overline{CN})_{ikj} = \mu + \text{bloq}_k + \text{lab}_i + \delta_{ik} + \text{fech}_j + \text{lab:fech}_{ij} + \varepsilon_{ikj}^*$

$(i = 1, \dots, 4 \ j = 1, \dots, 57, \ k = 1, \dots, 4)$  con  $\delta_{ik} \sim \text{indep } N(0, \sigma_p^2)$ ,  $\varepsilon_{ikj}^* \sim N(0, \sigma_{e,i}^2)$

y  $\text{Corr}(\varepsilon_{ikj}^*, \varepsilon_{ikj'}^*) = \rho_{jj'}$

*los términos aleatorios de parcelas y errores independientes entre sí*

La distancia en el tiempo entre los errores  $\varepsilon_{ikj}^*$  y  $\varepsilon_{ikj'}^*$  es  $|t_j - t_{j'}|$ , entonces la correlación de estructura cuadrática racional ( $c_0$  es el efecto pepita,  $\rho$  es el parámetro de correlación o rango en la literatura geoestadística) es:

$$\rho_{jj'} = \begin{cases} 1 - c_0 + (1 - c_0) \left[ \left( \frac{t_j - t_{j'}}{\rho} \right)^2 / \left( 1 + \left( \frac{t_j - t_{j'}}{\rho} \right)^2 \right) \right] & \text{si } |t_j - t_{j'}| > 0 \\ 1 & \text{si } |t_j - t_{j'}| = 0 \end{cases}$$

Si bien la comparación de los modelos **mm3.logCN** y **mm2.logCN** a través de la prueba del cociente de verosimilitud indicó un modelo de correlación significativa entre errores (Salida 4.9.,  $p=0.0034$ ), el modelo no fue adecuado (Fig. 4.21). El rango se estimó en  $\rho = 2223$  días y  $c_0 = 0.875$ . Implicando correlaciones entre errores entre 0.02 y 0.12 según distancia (mayor distancia menor correlación). Sentencia R y salida de la prueba de cociente de verosimilitud correspondiente está en la salida 4.9.

Salida 4.9. Prueba del cociente de verosimilitud para la comparación de los modelos mm3.logCN, mm2.logCN.

`anova(mm3.logCN, mm2.logCN)`

##	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
##	mm3.logCN	1	234	1134.932	2188.234	-333.466		
##	mm2.logCN	2	232	1142.272	2186.571	-339.136	1 vs 2	11.3396 0.0034

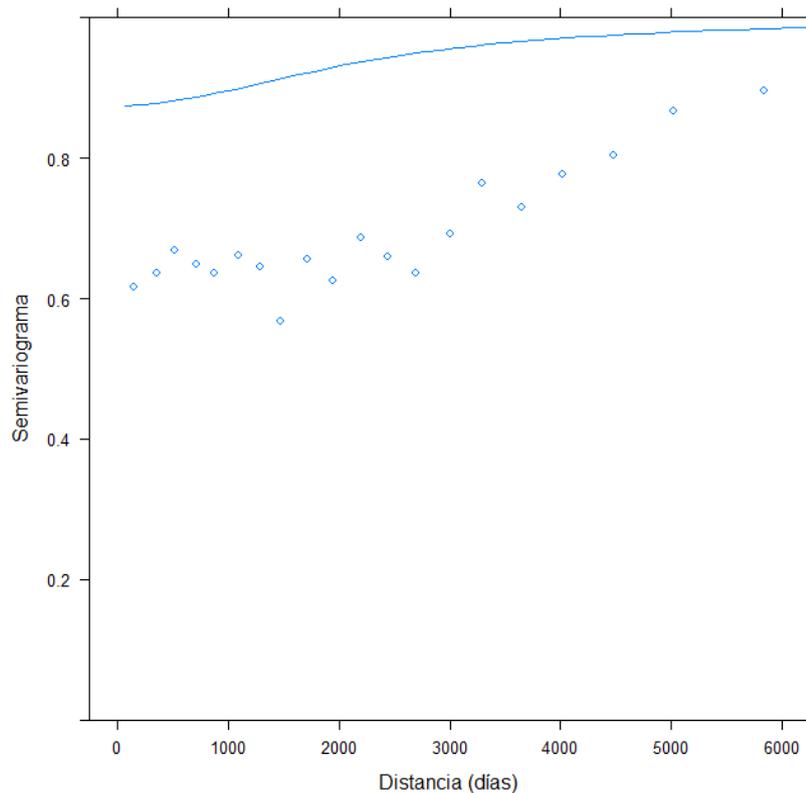


Fig. 4.21. Semivariograma muestral (círculos azules) y semivariograma ajustado en el modelo mm3.logCN con estructura cuadrática racional.

También se probaron las estructuras de correlación para el error exponencial o corCAR1 (reemplazando en **mm3.logCN**  $\rho_{jj'}$  por  $\rho_{jj'} = \rho^{|t_j - t_{j'}|}$ ) y estructura de simetría compuesta, pero en ambos casos la prueba del cociente de verosimilitud arrojó estructuras no significativas respecto al modelo mm2.logCN ( $p = 0.1378$  y  $p = 0.4016$ , respectivamente).

#### 4.4 Pruebas de efectos fijos y comparaciones de medias

Establecido el mejor modelo para la estructura de efectos aleatorios, se continúa con el análisis de los efectos fijos. En este sentido, los modelos con heterogeneidad de varianzas en los residuos, mm2.logCN.cs y mm2.logCN, son elegidos según la prueba de cociente de verosimilitud, respecto a los de homogeneidad de varianzas (mm1.logCN.cs y mm1.logCN). La incorporación de estructura de correlación en los errores no mejoró el modelo mm2.logCN. Por otro lado, el modelo mm2.logCN mostró un ajuste levemente mejor que mm2.logCN.cs al supuesto de normalidad. Por ello, y sumado a que en general es necesario tomar submuestras

para obtener una mejor representación de la respuesta en la unidad experimental, pero no se está interesado en estudiar la variación debida a submuestra, se continúan los análisis de los efectos fijos con el modelo mm2.logCN.

Salida 4.10. Pruebas F para los efectos fijos del modelo mm2.logCN. Sentencia R y salida.

```
anova(mm2.logCN)
##              numDF denDF   F-value p-value
## bloque           3     9     0.925  0.4673
## laboreo          3     9    17.929  0.0004
## FECHA           55    657    31.057 <.0001
## laboreo:FECHA   165    657     1.900 <.0001
```

La interacción laboreo con fecha sobre el logaritmo de CN es significativa (Salida 4.10.,  $p < 0.0001$ ). Los efectos de los laboreos a través del tiempo cambian. Una forma de continuar analizando esta interacción es a través de la comparación de las medias para los laboreos en cada fecha.

Esta comparación, fecha por fecha, de los laboreos se realizó con la función `lsmeans` (Lenth, 2016) del paquete del mismo nombre. Las medias y las diferencias de medias por mínimos cuadrados generalizados y los errores estándar correspondientes son los que se deducen del modelo. Los grados de libertad (gl) del estadístico para la comparación de medias entre laboreos en cada fecha son iguales a los grados de libertad del denominador del estadístico F para efectos de laboreo, en este caso  $gl = 9$ . Se puede obtener tanto, valores p ajustados por número de medias a comparar, en este caso cuatro por fecha, o bien valores p sin ajustar.

En la Fig. 4.22. se muestran las medias y sus errores estándar y se indica si hubo diferencias significativas ( $p < 0.05$ ) en la comparación de medias para cada fecha, con valor p ajustado (familia de cuatro medias por fecha). En 16 fechas de muestreo se encontraron diferencias significativas entre al menos dos laboreos (Fig. 4.22).

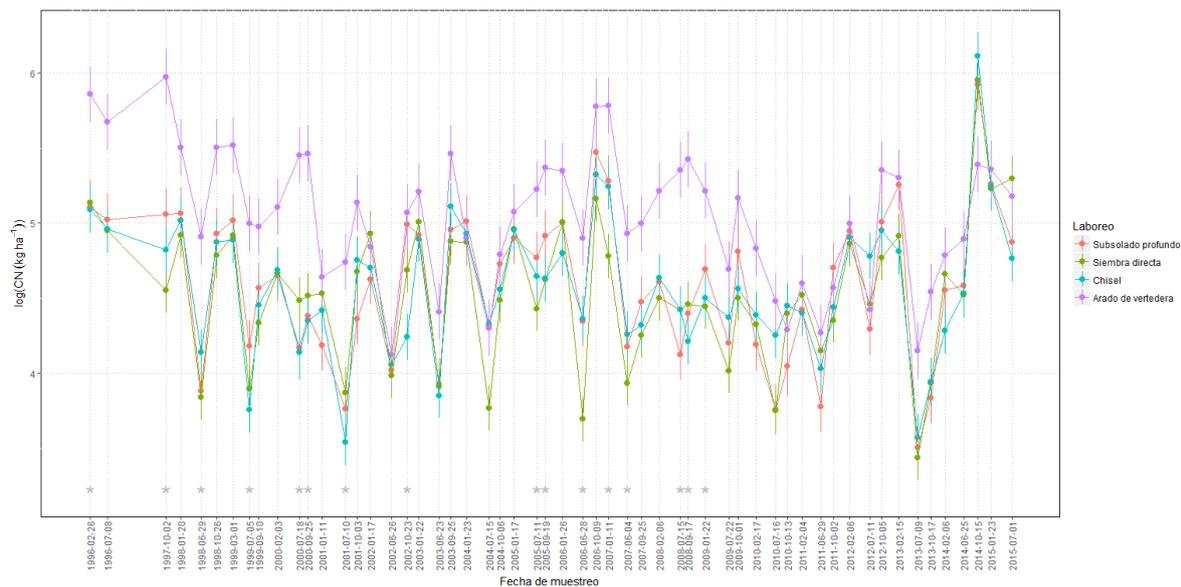


Fig. 4.22. Medias mínimo cuadrados  $\pm$  error estándar según el modelo mm2.logCN para los cuatro laboreos en cada fecha de muestreo. En cada fecha, con asterisco gris (\*) se indica que hubo diferencia significativa entre, al menos, dos laboreos, nivel de significancia 0.05 ajustado para la comparación de cuatro medias, grados de libertad para le estadístico de prueba = 9.

Considerando que en el modelo mm2.logCN la varianza de error más grande (Arado de vertedera) es 1.61 veces la varianza más chica (Siembra directa) (sección 4.3.2.) también se realizaron los análisis de los efectos fijos para el modelo mm1.logCN para luego comparar lo obtenido en ambos análisis.

El resultado de la prueba F para la interacción laboreo con fecha en el modelo mm1.logCN (Salida 4.11.) es muy similar al obtenido para el modelo mm2.logCN.

Salida 4.12. Pruebas F para los efectos fijos del modelo mm1.logCN. Sentencia R y salida.

```
anova(mm1.logCN)
##          numDF denDF  F-value p-value
## bloque          3     9    0.960  0.4528
## laboreo          3     9   17.844  0.0004
## FECHA          55   657   29.413 <.0001
## laboreo:FECHA  165   657    2.000 <.0001
```

En la Fig. 4.23. se muestran las medias y sus errores estándar y se indica si hubo diferencias significativas ( $p < 0.05$ ) en la comparación de medias para cada fecha, con valor p ajustado (familia de cuatro medias por fecha). En 19 fechas de muestreo se encontraron diferencias significativas entre al menos dos laboreos (Fig. 4.23).

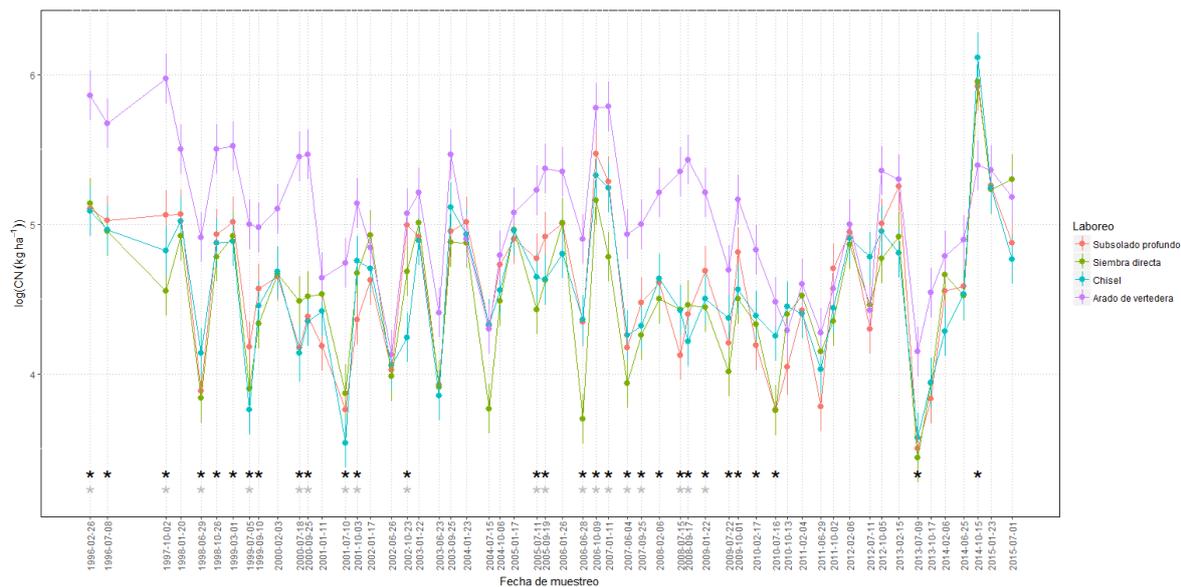


Fig. 4.23. Medias mínimo cuadrados  $\pm$  error estándar según el modelo mm1.logCN para los cuatro laboreos en cada fecha de muestreo. En cada fecha, con asterisco gris (\*) se indica que hubo diferencia significativa entre, al menos, dos laboreos, nivel de significancia 0.05 ajustado para la comparación de cuatro medias grados de libertad para le estadístico de prueba = 9. En cada fecha, con asterisco negro (\*\*) se indica que hubo diferencia significativa entre, al menos, dos laboreos, nivel de significancia 0.05 ajustado para la comparación de cuatro medias y aproximación de Kenward-Roger.

En la Fig. 4.23. puede observarse que la comparación de medias con ajuste de grados de libertad por el método de Kenward-Roger (Kenward y Roger, 1997) detectó diferencias entre al menos dos laboreos en 30 de las fechas de muestreo.

#### 4.5 Síntesis del capítulo

En este capítulo se trabajó con la variable CN del ensayo de Agramunt. Una variable muy variable y dependiente de condiciones ambientales del momento y previas al muestreo. Se inició la etapa exploratoria a través de gráficos de dispersión de CN en función de las fechas de muestreo, discriminando por laboreos y bloques, para el perfil completo del sello y cada profundidad. A partir de los mismos se observó la tendencia a una distribución asimétrica, con diferente variabilidad según laboreos y/o bloques y algunos posibles datos extremos. La etapa exploratoria continuó con el ajuste de dos modelos lineales generales simples y a través de la evaluación de sus residuos se determinó la falta de concordancia, muy marcada, con una distribución normal. Esta parte de la etapa exploratoria podría haberse realizado

directamente con los modelos lineales mixtos para mediciones repetidas (modelo básico de mediciones repetidas) con la variable en escala original y respetando la estructura de agrupamiento característica de las mediciones repetidas. Ya en la etapa de búsqueda del modelo para el análisis se utilizaron modelos lineales mixtos y, en particular, se ajustaron los modelos de mediciones repetidas, con la variable CN transformada a logaritmo. Se utilizó esta transformación teniendo en cuenta algunas referencias respecto a que la variable nitrato en el suelo puede ser tratada con distribución lognormal. Se inició con el modelo básico de mediciones repetidas, análogo al modelo utilizado para datos proveniente de un diseño en parcelas divididas, ajustando un modelo que estima varianza entre submuestras (mm1.logCN.cs) y otro que no, promediando submuestras para generar el dato a nivel “subparcela” (mm1.logCN). Se evaluó la adecuación de cada uno respecto a los supuestos, a través de gráficos de sus residuos y predictores empíricos (eblups) de sus efectos aleatorios. A partir de ello se reajustaron los modelos básicos incorporándole heterogeneidad de varianzas a diferentes niveles debidas a laboreos. Los modelos con heterogeneidad de varianzas a nivel submuestra en un caso (mm2.logCN.cs) y a nivel de error en el otro (mm2.logCN), resultaron significativamente mejores que los respectivos con homogeneidad de varianzas (prueba de cociente de verosimilitud). La evaluación de los residuales fue satisfactoria. El paso siguiente fue explorar la posible existencia de correlación entre errores en el modelo mm2.logCN, pero el patrón de autocorrelación mostró valores de correlación muy bajos y ninguno de los modelos de correlación probados se ajustó adecuadamente. Determinada la estructura de efectos aleatorios se continuó con el análisis de los efectos fijos, en el modelo mm2.logCN, es decir con las pruebas de hipótesis F para la interacción laboreo con fecha de muestreo y las comparaciones de medias posteriores, en un esquema de análisis clásico. Los resultados obtenidos aquí fueron comparados con los análisis análogos en el modelo mm1.logCN, siendo en ambos casos muy similares. En los modelos con heterogeneidad de varianzas, la mayor varianza no llegó a ser el doble de la más pequeña y entonces esa diferencia en varianzas no tuvo gran impacto sobre el análisis de los efectos fijos. El procedimiento seguido aquí trata de ejemplificar el proceso que debe seguirse en el ajuste de modelos lineales mixtos en general. Establecer la estructura de la matriz de varianzas-covarianzas de las observaciones, comenzando con modelos sencillos e proceder con la complejización del modelo según se vayan detectando deficiencias y, finalmente, evaluar los efectos fijos.

## 5. CAPÍTULO 5. APLICACIONES: ENSAYO DE AGRAMUNT. II

En este capítulo se exploran varias opciones como distribución de probabilidad para CN y se selecciona la más adecuada. Simultáneamente se modelan los efectos del tiempo de forma flexible sin suponer forma alguna, a través de suavizados. Son utilizados los modelos aditivos generalizados para parámetros de localización, escala y forma (GAMLSS) presentados en el Capítulo 3 (sección 3.2.5.).

### 5.1 Modelos GAMLSS y procesos de selección y evaluación

El modelado del CN en el perfil completo a través de los modelos GAMLSS se puede realizar siguiendo diferentes etapas. En primer lugar, si no se asume de antemano una distribución de probabilidad para la variable respuesta, se ajustan modelos con diferentes distribuciones y con el mismo predictor para el mismo parámetro a través de los distintos modelos. Es importante mantener el mismo predictor en cada parámetro, cuando el parámetro existe en las distribuciones especificadas, porque eso permite que al comparar los modelos se comparen las distribuciones. Entonces, a partir de la comparación de dichos modelos, se selecciona la distribución de probabilidad que mejor se ajusta a los datos. En particular, para CN se consideran distribuciones de probabilidad definidas en los números reales positivos (Tabla 5.1.).

La selección del mejor modelo entre los ajustados se realiza utilizando el criterio de información de Akaike generalizado (cuyas siglas en inglés son GAIC, Akaike, 1983). Para un modelo determinado, el GAIC se obtiene sumando a la deviance general ajustada una penalidad fija  $k$  para cada grado de libertad efectivo usado en el modelo. Poniendo de manifiesto que el GAIC depende de la penalidad elegida también puede expresarse como GAIC( $k$ ), así

$$GAIC(k) = -2l(\hat{\theta}) + k \times gl,$$

donde  $l(\hat{\theta})$  es la verosimilitud maximizada con  $\hat{\theta}$  el vector de parámetros del modelo estimado,  $-2l(\hat{\theta})$  es la deviance general y  $gl$  son los grados de libertad efectivos. Si  $k=2$  se obtiene el criterio de información de Akaike propiamente dicho (AIC, Akaike, 1974) y para  $k=\log(n)$ , donde  $n$  es el número de observaciones de la variable respuesta utilizadas en el

ajuste del modelo, se obtiene el criterio de información bayesiano de Schwartz (Schwarz, 1978). Stasinopoulos *et. al* (2017) sugieren tomar un valor para la penalidad  $k$  entre 2.5 y 4, particularmente 2.8 y, si se toman valores entre 2.5 y 4, también sugieren investigar la sensibilidad de la selección del modelo a la elección del valor  $k$ . El uso de  $GAIC(k)$  permite que se apliquen diferentes sanciones  $k$  para diferentes propósitos de modelado (Claeskens y Hjort, 2003). Según estos criterios la distribución de probabilidad seleccionada es la que corresponde al modelo con menor GAIC.

Los diagnósticos de la adecuación del modelo seleccionado se realizan en base a los residuos que genera. En particular, los residuos de un modelo GAMLSS para variables respuesta continuas como la que se analiza aquí, son los residuos normalizados (Dunn y Smyth, 1996). Estos residuos (teóricos) están dados por  $r_i = \Phi^{-1}(u_i)$  donde  $\Phi^{-1}$  es la inversa de la función de distribución acumulativa de la normal estándar, y  $u_i = F(y|\theta)$  con  $F$  representando a la función de distribución acumulativa para la variable  $y$  bajo la distribución asumida en el modelo GAMLSS. Es decir, la función de distribución acumulativa  $F$  asigna a la observación  $y$  el valor  $u$  (probabilidad). Si el modelo está correctamente especificado,  $u$  tiene una distribución uniforme entre cero y uno. Una vez ajustado el modelo, se obtienen los residuos  $\hat{r}_i = \Phi^{-1}(\hat{u}_i)$  con  $\hat{u}_i = F(y|\hat{\theta})$ .

La principal ventaja de los residuos normalizados es que, si el modelo es correcto, sus valores siempre tienen una distribución normal estándar, independientemente de la distribución de la variable respuesta. Dado que dentro de la literatura estadística abundan las herramientas para comprobar la suposición de normalidad, la utilización de los residuos normalizados facilita la evaluación de la adecuación de un modelo GAMLSS. En particular, las características de los residuos normalizados pueden visualizarse en los gráficos gusano (van Buuren y Fredriks, 2001). Estos gráficos deben su nombre a la forma en que se disponen los puntos en ellos. Cada punto en un gráfico gusano representa un cuantil de la distribución normal estándar en el valor de abscisa, y el correspondiente desvío de ese cuantil al residuo normalizado que le corresponde, en el de ordenada. El gráfico muestra también bandas de confianza del 95% para los desvíos, con lo cual, el modelo resulta correcto mientras aproximadamente el 95% de los desvíos se mantengan dentro de los límites dados por las bandas. La región comprendida por estas dos bandas podría referirse como zona de "aceptación" (Stasinopoulos *et al.*, 2017). El gráfico incluye el ajuste de un polinomio de tercer

grado a los puntos y se espera que, si el modelo es adecuado, la curva resultante no adquiera una forma específica. No obstante, si la curva obtenida evidenciara forma cuadrática o cúbica, esto sería un indicador de la presencia de asimetría o curtosis, respectivamente, en los residuos (Stasinopoulos *et al.*, 2017).

Para complementar el análisis de la adecuación de los residuos a una distribución normal, se utilizan también medidas de resumen de los residuos. Por lo tanto, para los residuos de cada modelo ajustado deben calcularse, además, la media, la varianza, y coeficientes de asimetría, de curtosis y de correlación de Filliben (Filliben, 1975). Los valores esperados de estas medidas como indicadores de una correcta adecuación de los residuos a una distribución normal estándar son (se espera que se den en forma aproximada): 0 para la media, 1 para la varianza, 0 para el coeficiente de asimetría, 3 para el coeficiente de curtosis y 1 para el coeficiente de correlación de Filliben. Un coeficiente de curtosis menor que 3 indica distribución platicúrtica y mayor que 3, distribución leptocúrtica.

El proceso continúa volviendo a reajustar, el o los modelos seleccionados en caso de ser necesario si, por ejemplo, se detectaran datos extremos que debieran ser dejados de lado, lo que lleva a una nueva selección y evaluación. También podrían reajustarse los modelos seleccionados si se decidiera probar la incorporación o quita de términos en los predictores y lo que lleva también a una nueva evaluación de la adecuación.

Un modelo puede ser adecuado, pero estar sobre-parametrizado. Es decir, los datos pueden estar bien representados por la distribución en el modelo, pero puede ser que algunos de los términos incorporados en el predictor, en la componente lineal o de suavizado, no realicen un aporte significativo en la modelación de los parámetros (localización, escala y forma). Así que, el próximo paso es evaluar los aportes de cada término. Desde otro punto de vista, para datos provenientes de ensayos diseñados, en particular para datos provenientes de ELDA, este paso es el de prueba de hipótesis sobre los efectos de los tratamientos, del tiempo y su interacción. Para estas pruebas se utilizan estadísticos de distribución aproximada chi-cuadrado.

## **5.2 Primera etapa**

### **5.2.1 Ajuste de modelos y selección**

Los GAMLSS (Capítulo 3, sección 3.2.5.) pueden ser trabajados a través del paquete `gamlss` (Rigby y Stasinopoulos, 2005) del ambiente computacional R. En este paquete se encuentran disponibles varias distribuciones de probabilidad, continuas, discretas y mezcla de ambas. En particular, en este capítulo las distribuciones utilizadas son las que tienen dominio en los números reales positivos (Tabla 5.1.). Estas distribuciones son evaluadas como posibles distribuciones de probabilidad para los datos de CN en el perfil total del suelo en el ensayo de Agramunt. En la Tabla 5.1. también se muestran las denominaciones que se dan a los modelos GAMLSS que se ajustan en este capítulo.

Tabla 5.1. Modelos aditivos generalizados para parámetros de localización, escala y forma (GAMLSS) ajustados al contenido de nitrógeno del suelo (CN) a 0-90 cm, las distribuciones de probabilidad utilizadas y sus funciones de ligaduras y funciones en el paquete `gamLSS` de R para ajustar los modelos y funciones de ligadura. Las letras griegas representan los parámetros de la distribución ( $\mu$ : de localización,  $\sigma$ : de escala,  $\nu$  y  $\tau$ : de forma).

Denominación del modelo GAMLSS	Distribución de probabilidad		Función de ligadura				Función en el paquete <code>gamLSS</code>
	nombre	Cantidad de parámetros	$\mu$	$\sigma$	$\nu$	$\tau$	
mod.GA	gamma	2	log	log	--	--	GA
mod.IGAMMA	inversa gamma		log	log	--	--	IGAMMA
mod.IG	inversa gaussiana		log	log	--	--	IG
mod.LOGNO mod.LOGNO2	lognormal		Id log (Según parametrización)	log	--	--	LOGNO LOGNO2 (Según parametrización)
mod.WEI mod.WEI2 mod.WEI3	Weibull		log	log	--	--	WEI WEI2 WEI3 (Según parametrización)
mod.BCCG	Box-Cox Cole y Green	3	Id	log	Id	--	BCCG
mod.GG	gamma generalizada		log	log	Id	--	GG
mod.GIG	inversa gaussiana generalizada		log	log	Id	--	GIG
mod.BCPE	potencial exponencial de Box-Cox	4	Id	log	Id	log	BCPE
mod.BCT	t de Box-Cox		Id	log	Id	log	BCT

Id: Identidad

Los modelos ajustados inicialmente para los datos de CN en el perfil total del suelo son los trece indicados en la Tabla 5.1. En cada uno de ellos, el predictor considerado para el parámetro de localización está conformado por un suavizado de CN a través del tiempo y que depende del tipo de laboreo (interacción laboreo con tiempo) más los efectos de laboreo, de bloque y de interacción laboreo con bloque. La forma general de estos modelos GAMLSS fue dada en el Capítulo 3, sección 3.2.5. El tiempo interviene a través de la variable cuantitativa

“días” que representa a las fechas de muestreo y cuenta los días desde la primera fecha. Esquemáticamente, el predictor para el parámetro de localización es:

$$s(días) + s(días, laboreo) + laboreo + bloque + laboreo:bloque,$$

donde  $s(días)$  representa a un suavizado de CN con variable explicativa “días”,  $s(días, laboreo)$  representa al término que hace que haya un suavizado de CN a través de “días” para cada tipo de laboreo,  $laboreo$ ,  $bloque$  y  $laboreo:bloque$  representan los efectos fijos de los laboreos, bloques e interacción laboreo con bloque. En forma similar, el predictor para el parámetro de escala es:

$$s(días) + s(días, laboreo) + laboreo + bloque.$$

Para los parámetros de forma se propone realizar una modelación con términos constantes, es decir los parámetros de forma no se modelan en función ni del laboreo, ni del tiempo.

Así, por ejemplo, el modelo mod.GA (Tabla 5.1) asume distribución gamma para el CN con los parámetros de localización y escala dependiendo del laboreo, bloque y tiempo (a través de la variable “días”). El modelo mod.GA puede expresarse como:

$$CN_{ijk} \sim GA(\mu_{ijk}, \sigma_{ijk})$$

$i = 1$  (“Subsolado profundo”),  $2$  (“Siembra directa”),  $3$  (“Chisel”),  $4$  (“Arado de vertedera”)

$j = 1, \dots, 57$

$k = 1, 2, 3, 4$

donde  $\mu_{ijk}$  es el valor medio y  $\sigma_{ijk}$  es el parámetro de escala (coeficiente de variación) tal que la varianza es  $\mu_{ijk}^2 \sigma_{ijk}^2$  para el CN en el laboreo  $i$  ( $lab_i$ ), día  $j$  ( $d_j$ ) y bloque  $k$  ( $bloq_k$ ). Las funciones de ligadura ( $g_1$  y  $g_2$ ) respectivas y los predictores de componente lineal más los suavizados, son:

$$g_1(\mu_{ijk}) = \log(\mu_{ijk}) = s(d_j) + s(d_j, lab_i) + lab_i + bloq_k + lab:bloq_{ik}$$

$$g_2(\sigma_{ijk}) = \log(\sigma_{ijk}) = s(d_j) + s(d_j, lab_i) + lab_i + bloq_k$$

En particular, los suavizados ajustados ( $s$ ) para los modelos de la Tabla 5.1. son B-splines penalizados (P-splines), de orden 3 para los polinomios de la base splines y orden 2 para la

matriz de diferencias (Eilers y Marx, 2010). Estos modelos fueron descriptos brevemente en el Capítulo 3, sección 3.2.4.

En la Tabla 5.2. se muestran los valores de AIC (GAIC con  $k=2$ ) y GAIC (para  $k=\log(n)$  y  $k=2.8$ ) de los modelos ajustados (Tabla 5.1.), acompañados del número de orden de menor a mayor para cada criterio de información.

Tabla 5.2. Valores de los criterios de información de Akaike (AIC) e información de Akaike generalizados (GAIC,  $k=\log(n)$  y  $k=2.8$ ) para los modelos ajustados (Tabla 5.1.) al contenido de nitrógeno (CN) en Agramunt y  $n=893$ .

modelo	gl	AIC (orden*)	GAIC (k=n, orden*)	GAIC (k=2.8, orden*)
<b>mod. IG</b>	80.37	9449.395 (1)	9834.722 (9)	9513.688 (1)
mod. LOGNO	80.82	9451.241 (2)	9838.726 (10)	9515.895 (3)
mod. BCPE	73.72	9455.390 (3)	9808.851 (4)	9514.367 (2)
<b>mod. BCCG</b>	70.25	9460.519 (4)	9797.329 (1)	9516.717 (4)
mod. BCT	72.55	9461.756 (5)	9809.614 (5)	9519.798 (5)
mod. GA	69.31	9470.392 (6)	9802.722 (2)	9525.843 (6)
mod. GG	70.30	9471.594 (7)	9808.672 (3)	9527.837 (7)
mod. IGAMMA	92.66	9474.339 (8)	9918.597 (11)	9548.466 (10)
mod. WEI3	68.56	9491.391 (9)	9820.090 (7)	9546.236 (8)
mod. WEI	68.17	9491.936 (10)	9818.774 (6)	9546.471 (9)
mod. WEI2	61.28	9533.181 (11)	9826.991 (8)	9582.204 (11)
mod. LOGNO2	157.65	9873.234 (12)	10629.077 (12)	9999.350 (12)
mod. NO*	67.36	9697.980 -	10020.933 -	9751.866 -
mod. GIC	sin convergencia			

\* entre paréntesis se indica el orden en que se ubica el modelo según cada uno de los criterios utilizados.

\* se ajustó el modelo con distribución normal (función NO()) en gamlss) como referencia

El resumen de la Tabla 5.2. puede verse en la Fig. 5.1. El mod.LOGNO2 con cualquiera de los criterios se ubicó en último lugar y muy alejado del resto por lo que se excluyó del gráfico.

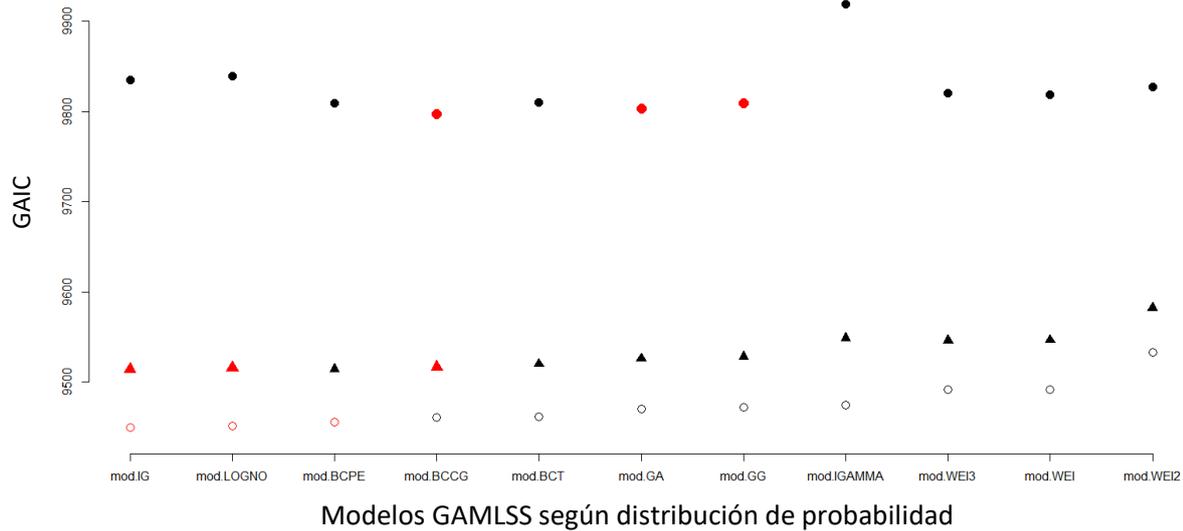


Fig. 5.1. Valores para los criterios de información de Akaike generalizados (GAIC) para cada uno de los modelos aditivos generalizados de localización, escala y forma (GAMLSS) ajustados (Tabla 5.1), ordenados de menor a mayor según valor de AIC (GAIC con  $k=2$ , círculo vacío). Valores de GAIC con  $k=\log(n)$  (círculo relleno) y GAIC con  $k=2.8$  (triángulo) ( $k$ : constante de penalización). En rojo se han destacado los tres menores valores de cada GAIC. El mod.LOGNO2 (Tabla 5.1.) fue excluido del gráfico.

El modelo mod.IG es el que tiene menor valor de AIC y GAIC con  $k=2.8$  respecto a los otros modelos (Tabla 5.2 y Fig. 5.1). Así, el modelo que se selecciona como el mejor según los criterios AIC y GAIC con  $k=2.8$ , es aquel que ajusta una distribución de probabilidad Inversa Gaussiana a la variable CN. Con el criterio GAIC con  $k=\log(n)$ , el modelo seleccionado es aquel que especifica distribución de Box-Cox Cole y Green (mod.BCCG, Tabla 5.2 y Fig. 5.1.). En los segundos lugares se ubican los modelos con distribución lognormal (mod.LOGNO) para AIC, con distribución gamma (mod.GA) para GAIC con  $k=\log(n)$  y con la distribución potencial exponencial de Box Cox (mod.BCPE) para GAIC con  $k=2.8$  (Tabla 5.2 y Fig. 5.1). Cabe destacar que, como se esperaba, los valores de AIC y de los GAIC para el modelo con distribución normal, mod.NO (Tabla 5.2) son muy superiores a los del resto de los modelos probados, y en consecuencia un modelo malo para el CN. La adecuación de estos cinco modelos es evaluada.

## 5.2.2 Distribución inversa gaussiana

Dado que la distribución inversa gaussiana fue seleccionada como la mejor en dos de los criterios de información de Akaike, se la describe y caracteriza a continuación. Las

distribuciones lognormal, gamma, de Box-Cox Cole y Green, y de potencial exponencial de Box Cox fueron descritas en el Capítulo 3.

La distribución inversa gaussiana es útil para describir variables de valores positivos y altamente asimétricos con sesgo positivo. La función de densidad de probabilidad para una variable  $Y$  con distribución inversa gaussiana, en la parametrización utilizada en el paquete `gamlss`, es

$$f_Y(y|\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2 y^3}} \exp\left[-\frac{1}{2\mu^2\sigma^2 y}(y - \mu)^2\right]$$

Para  $y > 0$ , donde  $\mu > 0$  y  $\sigma > 0$ , con esperanza o media  $E(Y) = \mu$  y varianza  $\text{Var}(Y) = \sigma^2\mu^3$  (Stasinopoulos *et al.*, 2008).

En la Fig. 5.2. se ejemplifican dos distribuciones de probabilidad Inversas Gaussianas. Las mismas corresponden a valores de los parámetros  $\mu$  y  $\sigma$  de tal forma que, la media y la varianza pueden corresponder aproximadamente a valores de media y varianza de la variable CN ( $\text{kg ha}^{-1}$ ) en alguna situación. Para  $\mu = 50$  y  $\sigma = 0.1$ , la media es 50 y la varianza 1250 ( $50^3 \cdot 0.1^2$ ), para  $\mu = 100$  y  $\sigma = 0.1$ , la media es 100 y la varianza 10000 ( $100^3 \cdot 0.1^2$ ). En ambas figuras puede apreciarse la característica de asimetría con sesgo positivo que poseen las distribuciones inversas gaussianas, valores centrales alrededor de la media y datos altos menos “frecuentes”.

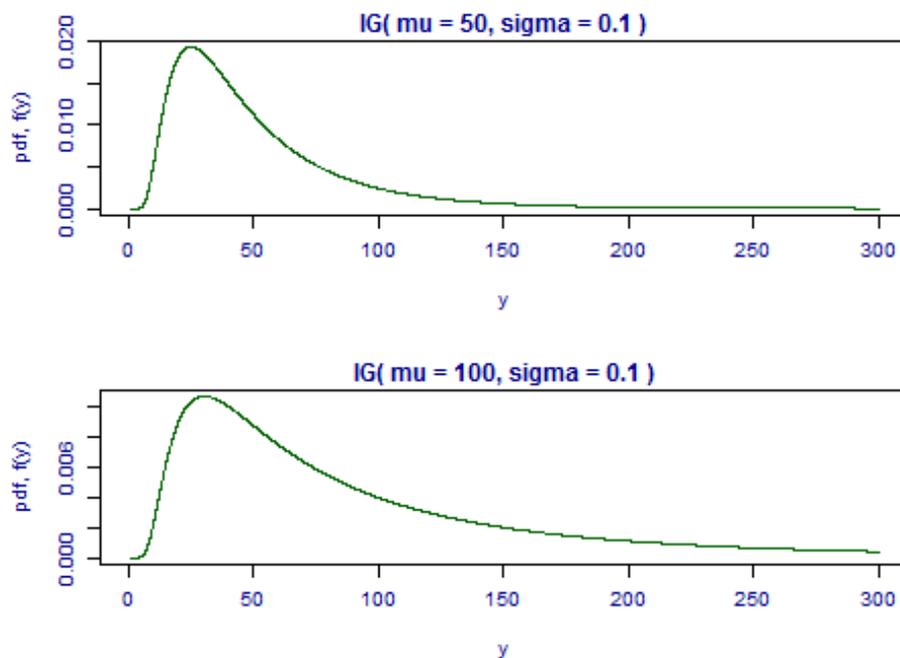


Fig. 5.2. Funciones de densidad para dos distribuciones inversas gaussianas (IG).

### 5.2.3 Diagnóstico

Los gráficos gusano para los residuos de los modelos mod.IG, mod.BCCG, mod.LOGNO, mod.GA y mod.BCPE (Tablas 5.1. y 5.2.) se muestran en la Fig. 5.3. Se evidencia alguna falta de adecuación del modelo mod.IG ya que hay varios puntos, más del 5% del total, fuera de las bandas de confianza del 95% (Fig. 5.3.a). También, el ajuste polinómico cúbico a los puntos del diagrama del gusano para este modelo, muestra una marcada forma de “S” girada a izquierda (Fig. 5.3.a, curva en color rojo), lo que refleja que los residuos tienen una distribución con colas más pesadas que la distribución normal (curtosis alta o distribución platicúrtica) (Stasinopoulos *et al.* 2017). El valor del coeficiente de curtosis para los residuos del modelo mod.IG es menor que 3 (Tabla 5.3.) confirmando lo observado en el gráfico gusano. Asimismo, el gráfico gusano para los residuos del modelo mod.LOGNO (Fig. 5.3.c) revela un comportamiento similar a lo observado para los residuos del mod.IG, excepto que en mod.LOGNO hay menos puntos fuera de la zona delimitada por las bandas de confianza. Tanto para mod.IG como para mod.LOGNO se corresponden los menores valores de coeficiente de curtosis y los más alejados del valor 3 (Tabla 5.3.).

Los mejores ajustes a una distribución normal lo muestran los residuos de los modelos mod.GA (Fig. 5.3. d), mod.BCCG (Fig. 5.3.b) y mod.BCPE (Fig. 5.3 Tabla 5.3). En cada uno de ellos, hay muy pocos puntos (menos del 5%) por fuera o sobre las bandas de confianza, y un punto más alejado del resto correspondiente al mayor valor de cuantil normal estándar que, para los mod.GA (Fig. 5.3. d) y mod.BCPE (Fig. 5.3.e), está fuera de la región de “aceptación”(Fig. 5.3). Si bien en los casos de mod.BCCG y mod.GA se muestra una leve tendencia a una distribución platicúrtica, ésta no es marcada. Los valores de coeficiente de curtosis para los residuos de estos dos modelos (mod.BCCG y mod.GA) son menores que 3, pero cercanos a ese valor (Tabla 5.3.). No obstante, el coeficiente de curtosis correspondiente a los residuos de mod.BCPE es el más cercano y levemente superior a 3, coincidiendo con lo que se observa en el gráfico gusano respecto a una mayor concordancia con una distribución normal (Fig. 5.3.e).

En las Fig. 5.4 a 5.8 se muestran gráficos de residuos normalizados para los modelos seleccionados para mayor evaluación en esta primera etapa. Se grafican residuos normalizados vs valores ajustados, residuos normalizados vs el orden de la observación asociada en el conjunto de datos, funciones de densidad empíricas (histogramas de densidad suavizados) y gráficos cuantil-cuantil para una distribución normal para mod.IG (Fig 5.4.), mod.BCCG (Fig. 5.5.) , mod.LOGNO (Fig. 5.6.), mod.GA (Fig. 5.7.) y mod.BCPE (Fig. 5.8.). De la comparación visual de las cinco figuras, una para cada modelo, muestra que el mejor comportamiento de los residuales al supuesto de distribución normal corresponde al modelo mod.BCPE, en los cuatro gráficos de diagnóstico. Histograma de densidad con mejor forma de campana, gráfico cuantil-cuantil con puntos bien dispuestos sobre una línea recta, excepto por un solo punto (Fig. 5.8). Un solo dato extremo (residuo mayor que 3) se observa para el modelo mod.BCPE, sobre todo en tres de los cuatro gráficos de la Fig 5.8 (gráficos de dispersión y cuantil-cuantil).

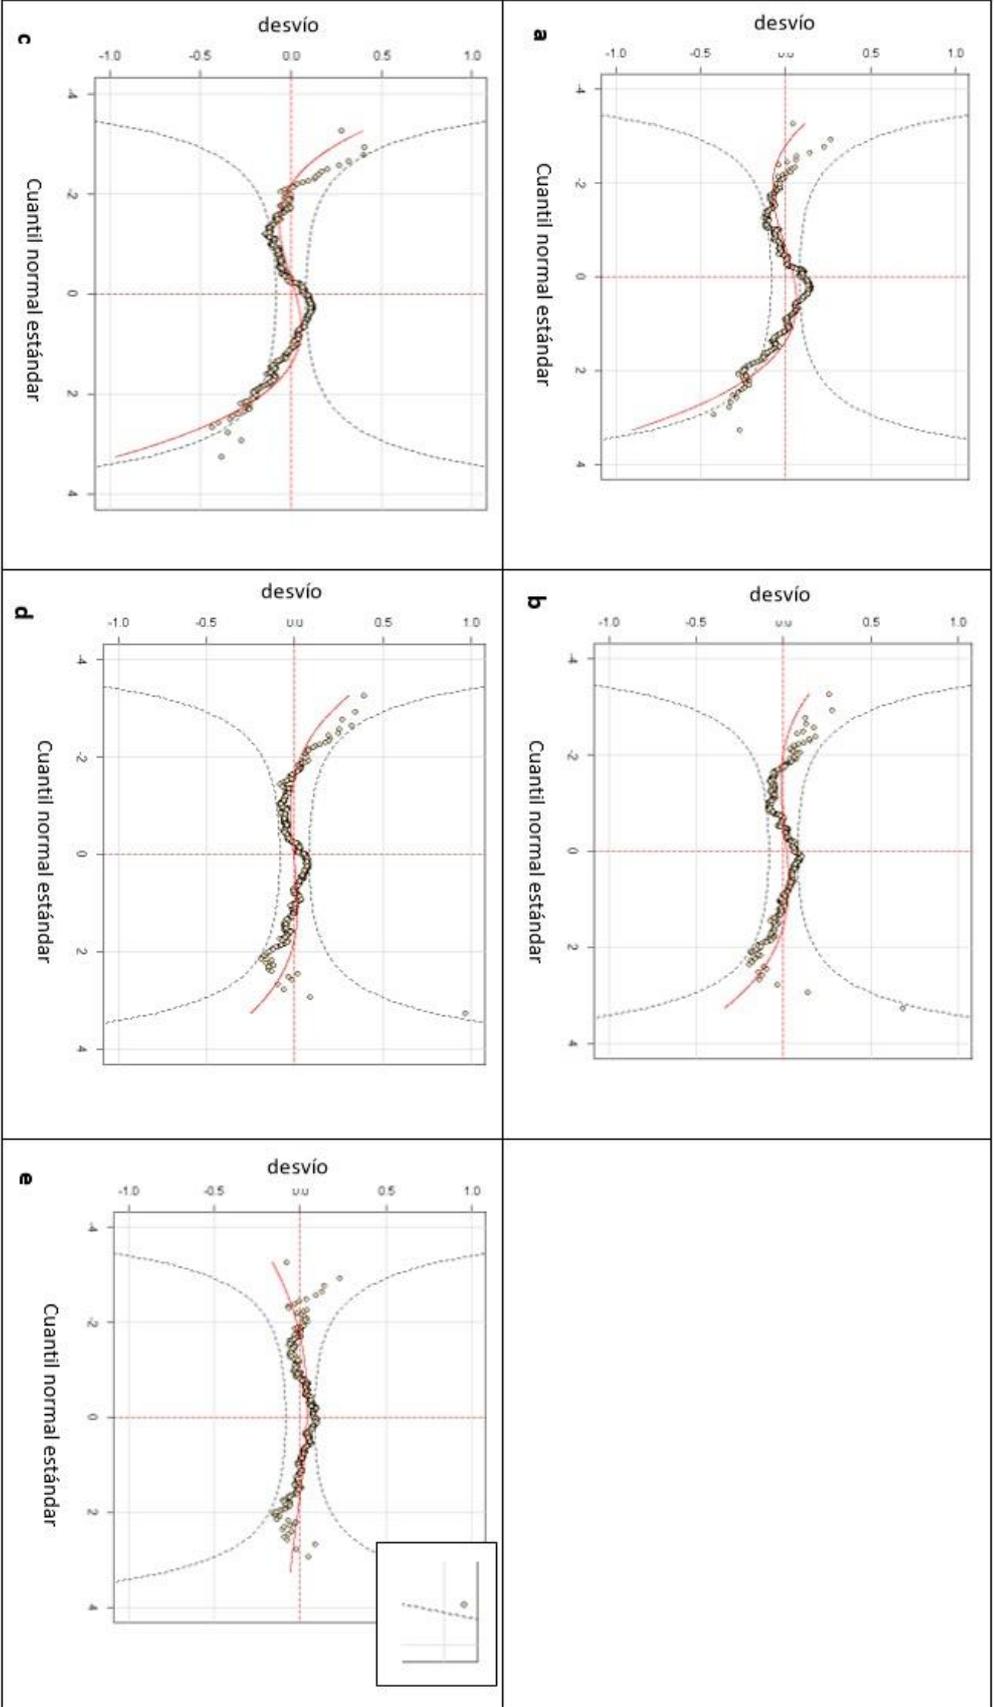


Fig. 5.3: Gráficos gusano para los residuos normalizados de los modelos (Tabla 5.1.) mod:IG (a), mod:BCCG (b), mod:LOGNO (c), mod:GA (d) y mod:BCPE (e). En mod:BCPE hay un punto que representa un desvío superior a 1 y menor que 1.1 correspondiente al mayor valor de cuantil normal.

Tabla 5.3. Medidas descriptivas calculadas para los residuos normalizados de los modelos con distribución Inversa Gaussiana (mod.IG), distribución de Box, Cox, Cole y Green (mod.BCCG), distribución lognormal (mod.LOGNO), distribución gamma (mod.GA) y distribución potencial exponencial de Box y Cox (mod.BCPE).

Medidas descriptivas	mod.IG	mod.BCCG	mod.LOGNO	mod.GA	mod.BCPE
Media	0.0065	0.0097	-0.0031	-0.0018	0.0244
Varianza	1.0068	1.0010	1.0011	1.0002	1.0015
Coficiente de asimetría	-0.2288	-0.0594	-0.1644	0.0253	-0.0653
Coficiente de curtosis	2.5849	2.8172	2.4598	2.8400	3.1208
Coficiente de correlación de Filliben	0.9956	0.9979	0.9957	0.9977	0.9982

Celdas sombreadas en gris destacan los valores más cercanos a los valores esperados según una distribución normal estándar.

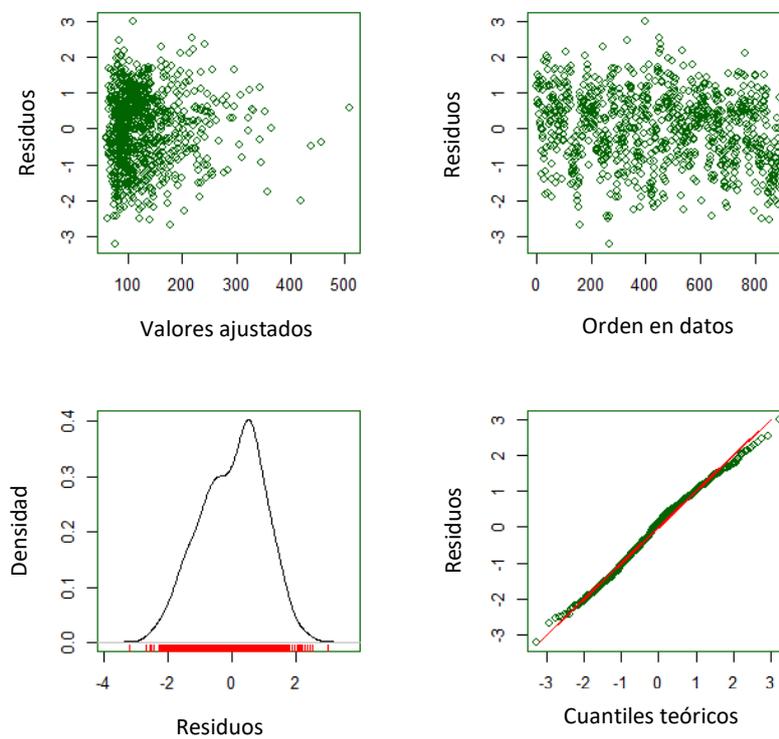


Fig. 5.4. Residuales normalizados para el modelo mod.IG

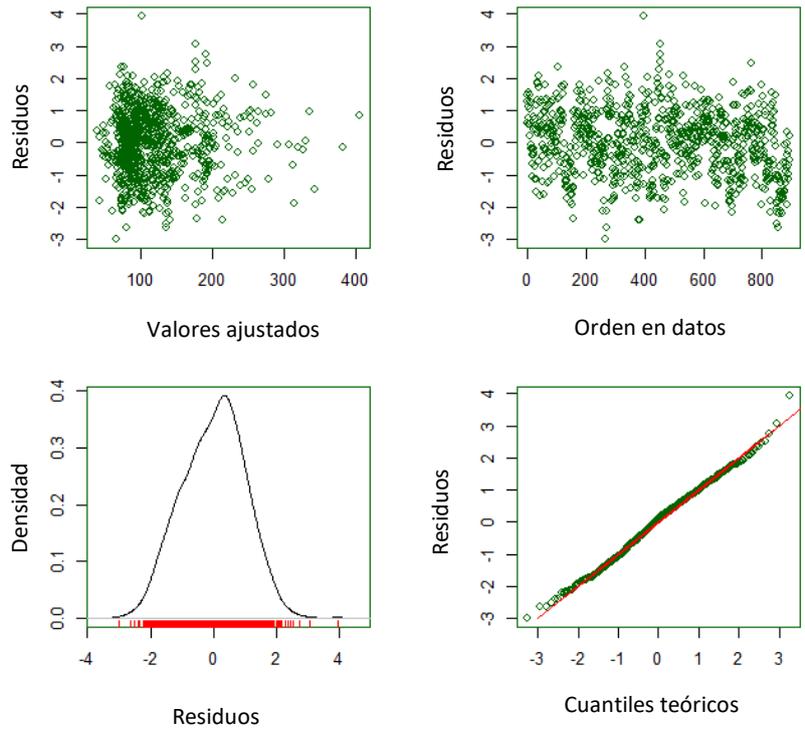


Fig. 5.5. Residuales normalizados para el modelo mod BCCG

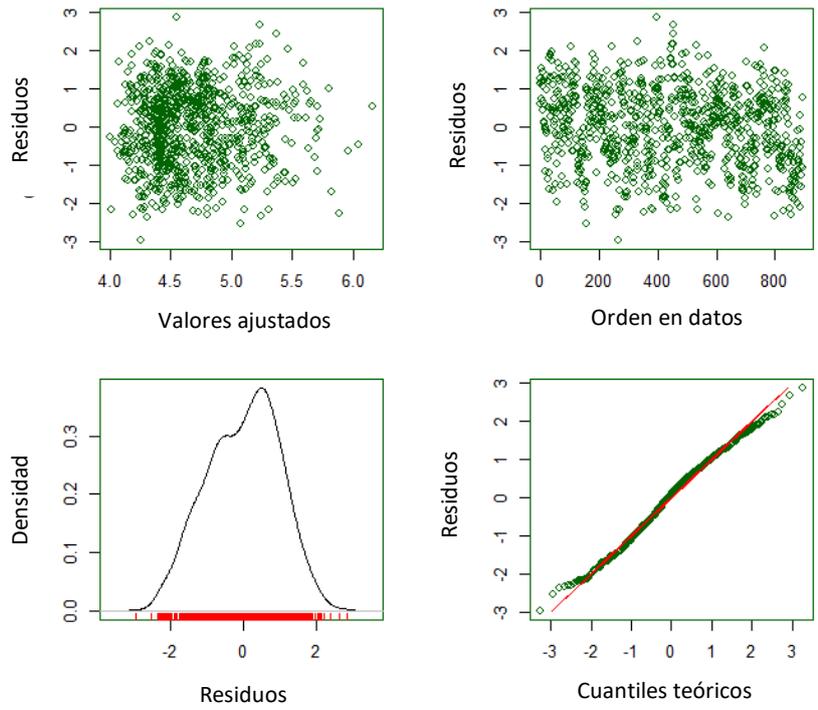


Fig. 5.6. Residuales normalizados para el modelo mod.LOGNO.

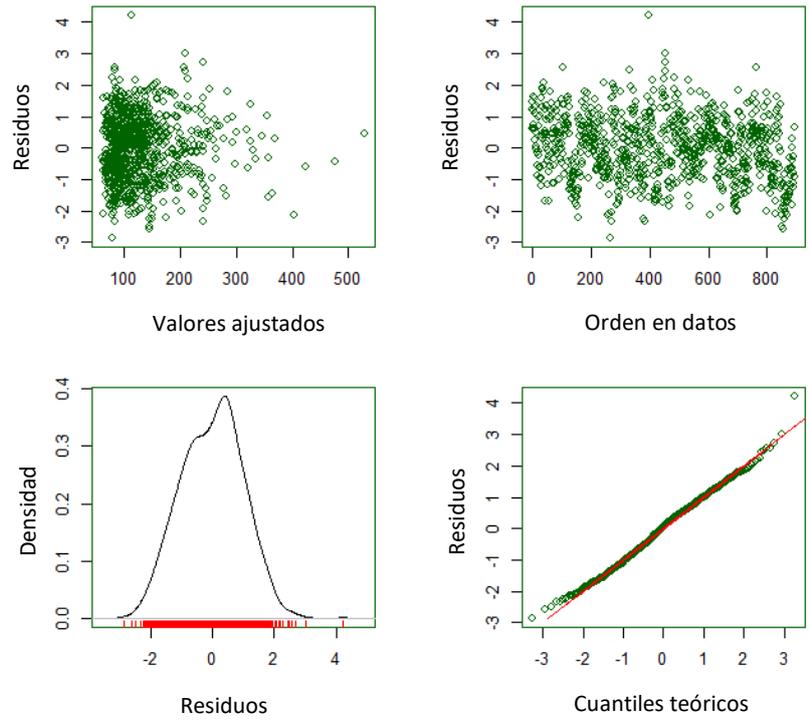


Fig. 5.7. Residuales normalizados para el modelo mod.GA.

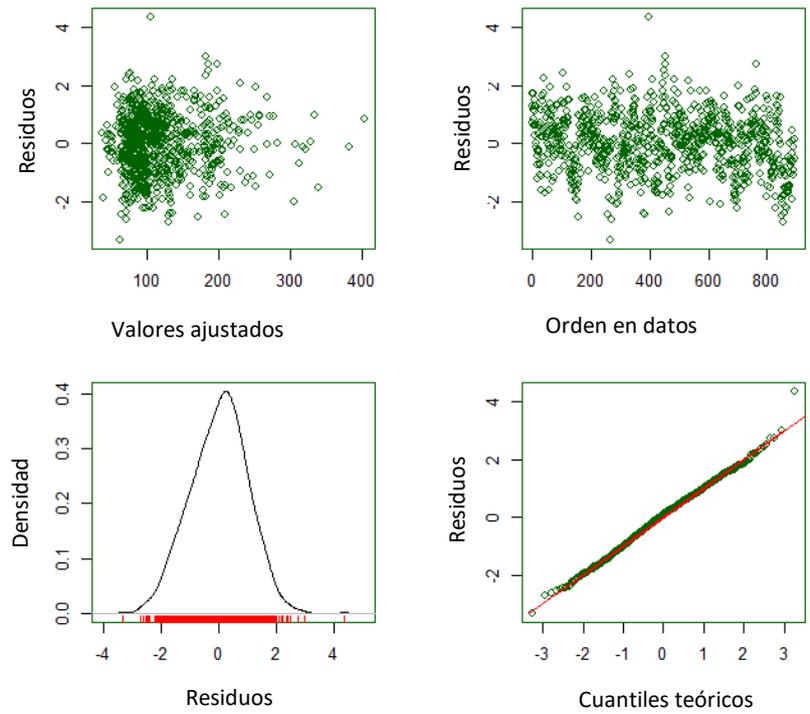


Fig. 5.8. Residuales normalizados para el modelo mod. BCPE.

### 5.3 Segunda etapa

#### 5.3.1 Ajuste de modelos y selección

Se plantea excluir el dato identificado como extremo en mod.BCPE, mod.GA y mod.BCCG y volver a ajustar estos cinco modelos. El dato corresponde a un valor de CN = 578.64 kg ha<sup>-1</sup>, en el bloque 1 fecha de muestreo 15/02/2013 para el laboreo "Subsolado profundo", dato que también puede apreciarse en la Fig. 4.18 del Capítulo 4.

Los valores de AIC para las tres penalidades ( $k = 2$ ,  $k = \log(n)$ ,  $k = 2.8$ ) para los modelos ajustados con 892 datos de CN, excluido el dato identificado como extremo en la primera etapa de ajuste se muestran en la Tabla 5.4.

Tabla 5.4. Valores de los criterios de información de Akaike (AIC) e información de Akaike generalizados (GAIC,  $k=\log(n)$  y  $k=2.8$ ) para los modelos seleccionados en la primera etapa entre los modelos de la Tabla 5.1. para el contenido de nitrógeno a 0-90 cm (CN) en Agramunt y  $n=892$ .

modelo	gl	AIC (orden)	GAIC (k=n, orden)	GAIC (k=2.8, orden)
mod. BCPE	73.25600	9411.636 (1)	9762.868 (1)	9470.240 (1)
mod. BCCG	71.37639	9424.964 (2)	9767.184 (3)	9482.065 (2)
mod. LOGNO	80.42835	9428.628 (3)	9814.249 (5)	9492.971 (4)
mod. GA	69.00574	9434.075 (4)	9764.929 (2)	9489.280 (3)
mod. IG	70.02715	9462.002 (5)	9797.753 (4)	9518.023 (5)

En base a los criterios de mayor penalización se seleccionan los modelos mod.BCPE (siempre seleccionado primero), mod.GA y mod.BCCG. A continuación, se evalúan las adecuaciones de los ajustes.

#### 5.3.2 Diagnóstico

De la observación del resumen de medidas descriptivas de la Tabla 5.5 y de los gráficos de la Fig. 5.9., como mejor modelo, surge aquél con distribución potencial exponencial de Box y Cox (mod.BCPE).

Tabla 5.5. Medidas descriptivas calculadas para los residuos normalizados de los modelos con distribución de Box, Cox, Cole y Green (mod.BCCG), distribución gamma (mod.GA) y distribución potencial exponencial de Box y Cox (mod.BCPE).

Medidas descriptivas	mod.BCCG	mod.GA	mod.BCPE
Media	0.0096	-0.0016	0.0295
Varianza	1.0010	1.0002	0.9997
Coefficiente de asimetría	-0.0581	-0.0491	-0.0597
Coefficiente de curtosis	2.6248	2.5721	2.9801
Coefficiente de correlación de Filliben	0.9980	0.9981	0.9993

Celdas sombreadas en gris destacan los valores más cercanos a los valores esperados según una distribución normal estándar.

En las Fig. 5.10 a 5.12 se muestran gráficos de residuos normalizados para los modelos seleccionados para mayor evaluación en esta segunda etapa, habiendo descartado del conjunto de datos el dato extremo detectado en algunos modelos de la primera etapa. Se grafican residuos normalizados vs valores ajustados, residuos normalizados vs el orden de la observación asociada en el conjunto de datos, funciones de densidad empíricas (histogramas de densidad suavizados) y gráficos cuantil-cuantil para una distribución normal para mod.BCCG (Fig. 5.10.), mod.GA (Fig. 5.11.) y mod.BCPE (Fig. 5.12.). De la comparación visual de las tres figuras, una para cada modelo, surge que el mejor comportamiento de los residuales al supuesto de distribución normal corresponde al modelo mod.BCPE, sobre todo en dos de los gráficos de diagnóstico. Histograma de densidad con mejor forma de campana, gráfico cuantil-cuantil con puntos bien dispuestos sobre una línea recta (Fig. 5.12). En ningún caso se evidencian datos extremos (residuos en valor absoluto mayores que 3) (Fig.5.10, 5.11 y 5.12).

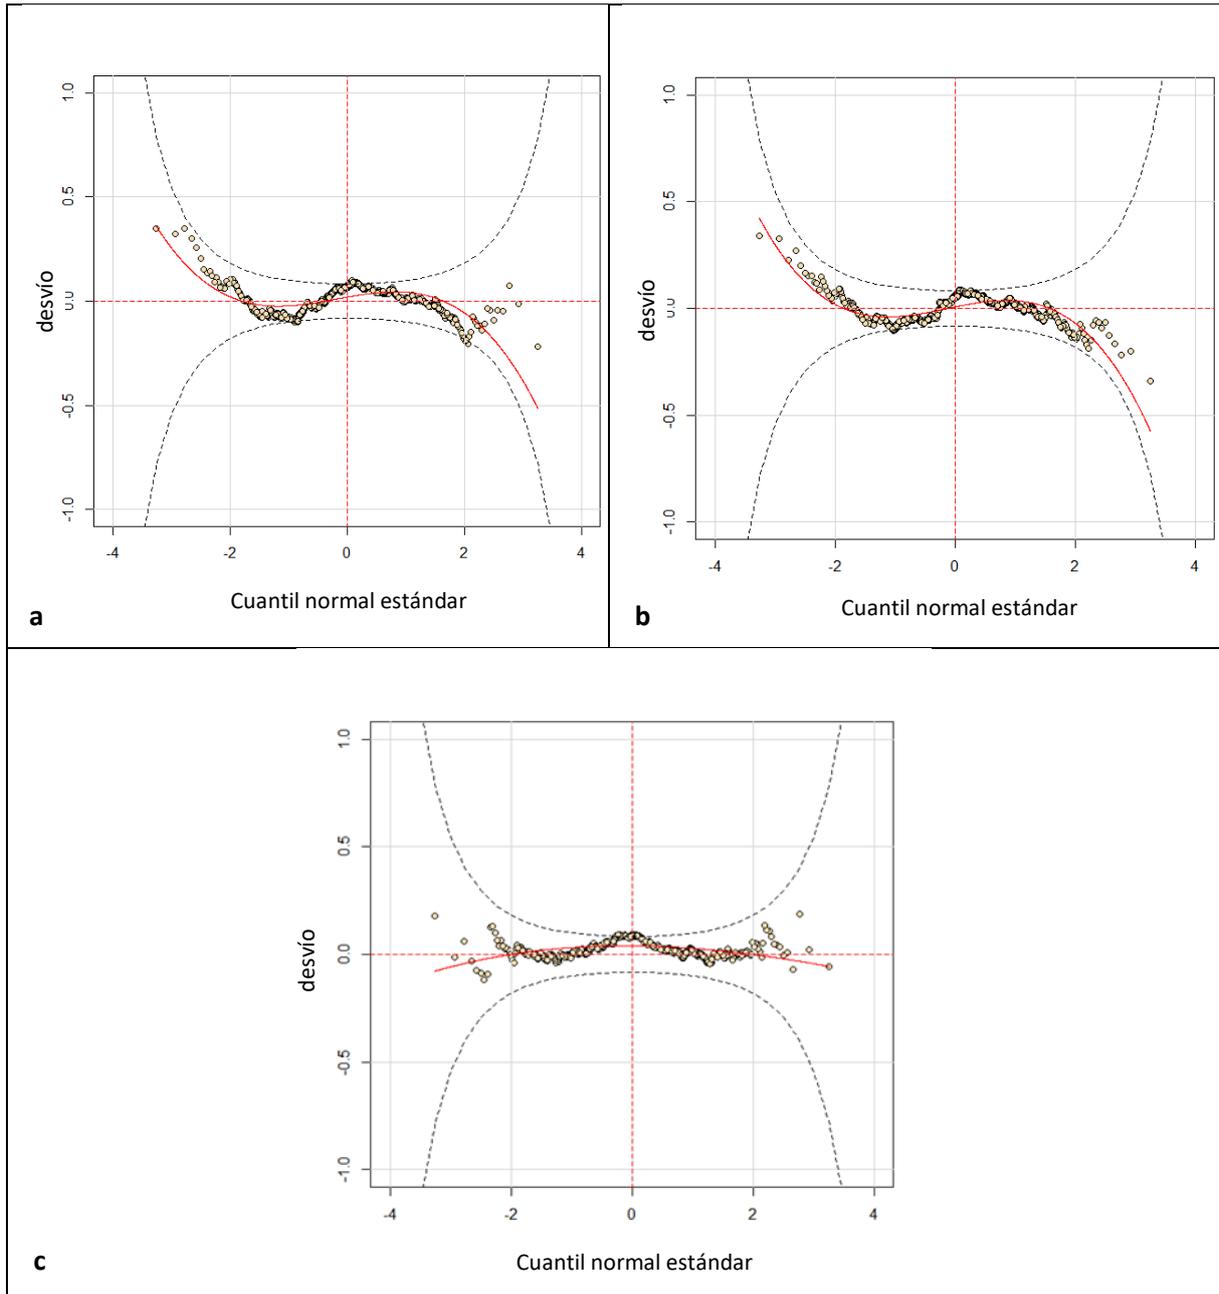


Fig. 5.9. Gráficos gusano para los residuos normalizados de los modelos mod.BCCG (a), mod.GA (b) y mod.BCPE (c) sin el dato extremo para algunos modelos de los primeros ajustes.

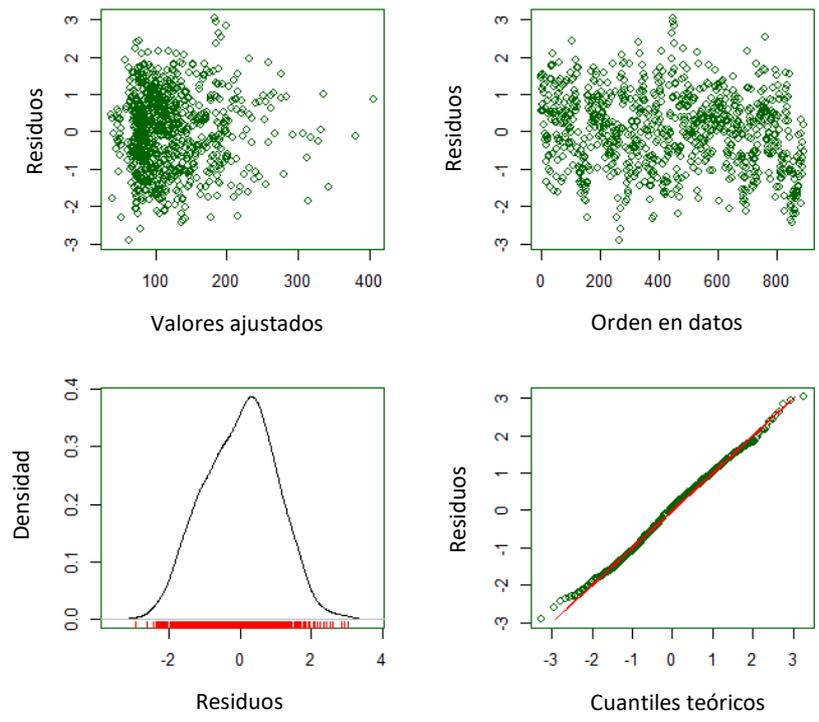


Fig. 5.10. Residuales normalizados para el mod.BCCG sin dato extremo.

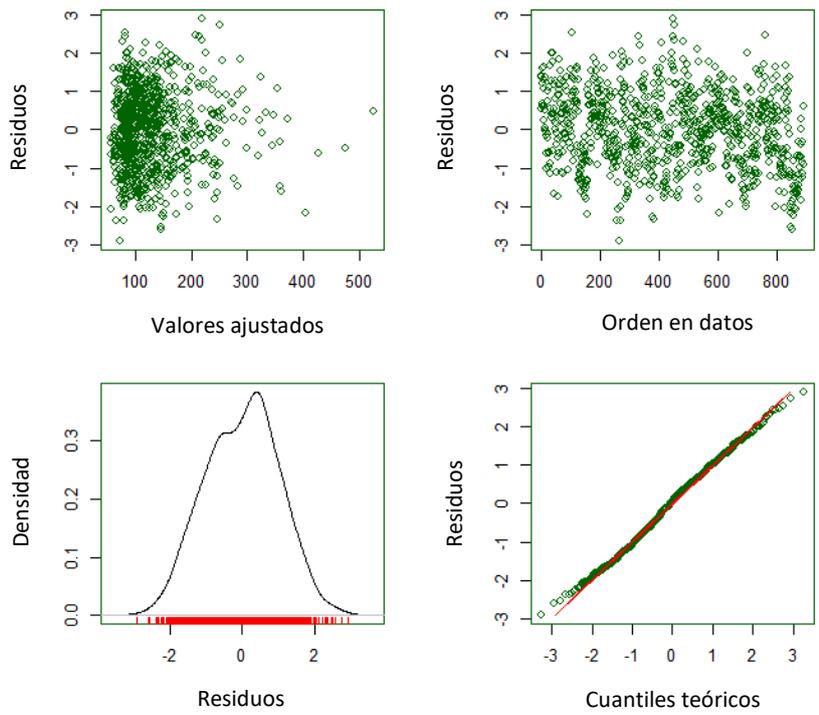


Fig. 5.11. Residuales normalizados para el mod.GA sin dato extremo.

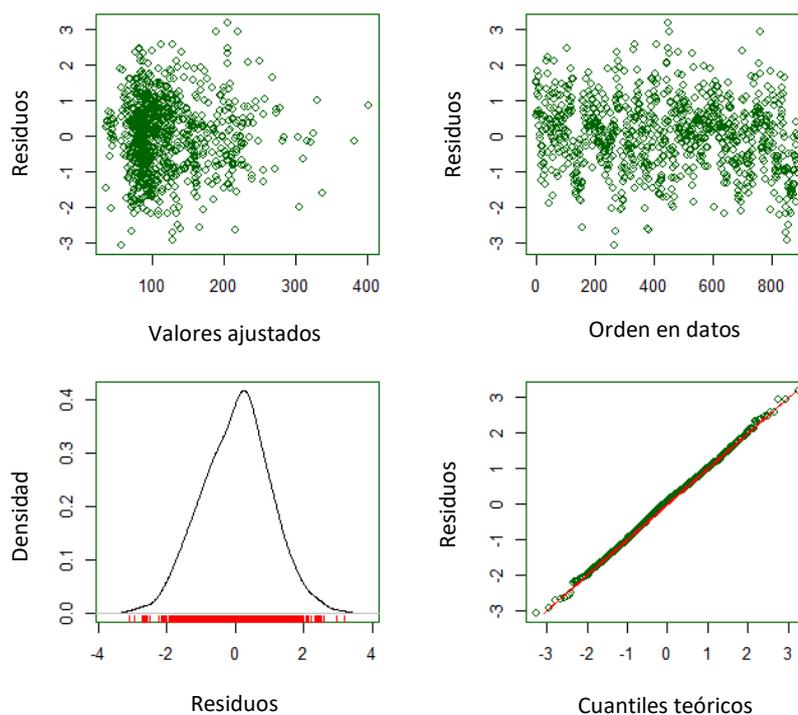


Fig. 5.12. Residuales normalizados para el mod.BCPE sin dato extremo.

#### 5.4 Evaluación de términos en los predictores del modelo seleccionado

La distribución potencial exponencial de Box-Cox (BCPE), proporciona un modelo para una variable dependiente  $Y$  que muestra tanto asimetría como curtosis (leptocurtosis o platicurtosis). La distribución tiene cuatro parámetros y los parámetros,  $\mu$ ,  $\sigma$ ,  $\nu$ ,  $\tau$ , pueden interpretarse en relación con la localización (mediana), la escala (aproximación del cociente de variación), la asimetría y la curtosis, respectivamente (Rigby y Stasinopoulos, 2004). Es de destacar entonces, que lo que se ha modelado en mod.BCPE es la mediana del CN ( $\mu$ ), el coeficiente variación en forma aproximada ( $\sigma$ ), el coeficiente de asimetría ( $\nu$ ) y el coeficiente de curtosis ( $\tau$ ).

Las diferencias en los parámetros de localización son más marcadas entre el laboreo Arado de vertedera y los demás. Esas diferencias entre los laboreos cambian a través del tiempo (Fig. 5.13.), incluso en algunos períodos, alrededor de las campañas 2002/03 y 2003/2004 y a partir de la campaña 2010/11 no se evidencian diferencias entre laboreos. Asimismo, para Arado de vertedera, también se observa una diferencia notable entre uno de los bloques y los demás (Fig. 5.13.). En cuanto al parámetro de escala, las diferencias más notables se dan entre Chisel y los demás laboreos en diferentes períodos y con distintas diferencias (Fig. 5.14.).

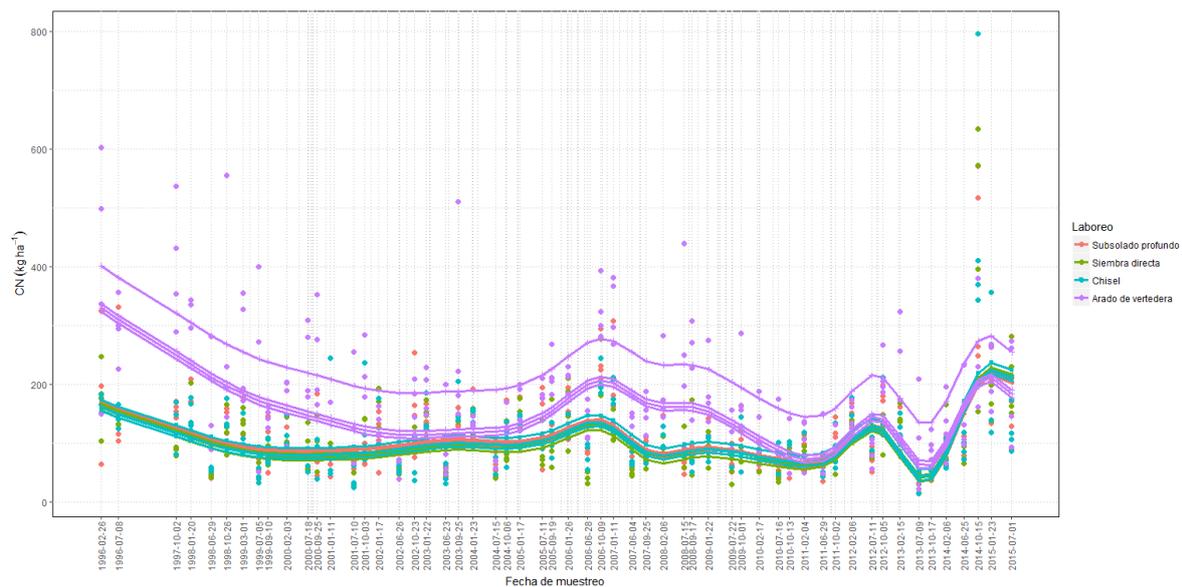


Fig. 5.13. Parámetro de localización (mediana) estimado para la distribución de probabilidad de CN por el modelo GAMLSS mod.BCPE (Tabla 5.1.) (sin un dato extremo), para cada laboreo, bloque y fecha de muestreo.

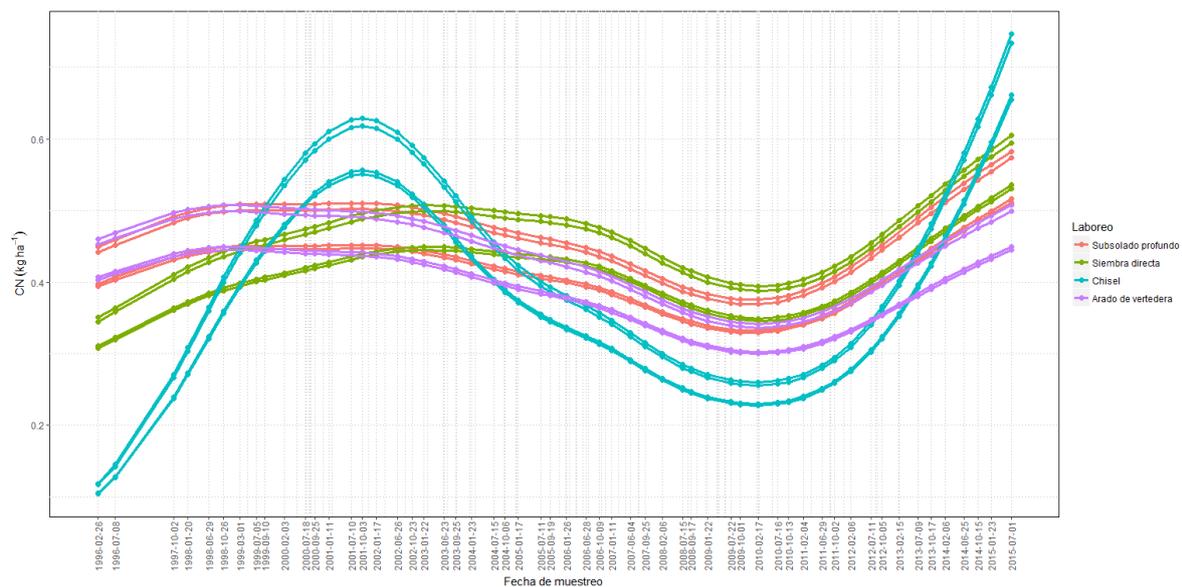


Fig. 5.14. Parámetro de escala (aproximación del coeficiente de variación) estimado para la distribución de probabilidad de CN por el modelo GAMLSS mod.BCPE (Tabla 5.1.) (sin un dato extremo), para cada laboreo, bloque y fecha de muestreo.

El análisis podría continuar con pruebas de hipótesis para los efectos fijos e intervalos de confianza para los parámetros de la distribución de probabilidad bajo el modelo seleccionado, e incluso reajustando el modelo, incorporando algún otro término en los predictores o

eliminando algún término para evitar la sobre-parametrización. Sobre estos aspectos que deben ser estudiados con cuidado para aplicaciones como las realizadas aquí puede consultarse a Stasinopoulos *et. al.*, 2017.

## **5.5 Síntesis del capítulo**

En este capítulo se ajustaron al CN del suelo en el perfil total modelos GAMLSS. Los modelos GAMLSS posibilitaron modelar los parámetros de localización (p.e. medias y medianas), escala y forma, en una importante variedad de distribuciones de probabilidad. También permiten ajustar relaciones en forma más flexibles que las regresiones lineales con métodos de modelos aditivos (suavizados). En particular, para CN se probaron modelos con distribuciones de probabilidad definida en los números reales positivos. Para definir el mejor modelo, con los predictores que se establecieron, se siguió un proceso general iterativo de ajuste, selección y evaluación de la adecuación del modelo, que requirió de dos etapas. En este proceso se utilizaron los criterios de información de Akaike generalizado para la selección en una primera instancia, la evaluación de los residuales normalizados de los modelos, a través de diversos gráficos, incluidos los gráficos gusanos, y medidas de resumen. El modelo seleccionado como el más adecuado para el CN es el de distribución potencial exponencial de Box Cox, una distribución de cuatro parámetros, cuando los predictores para la localización y la escala incluyeron suavizados (P-splines) a través del tiempo y dependiendo del laboreo (mod.BCPE).

## 6. CAPÍTULO 6. ENSAYOS DE SISTEMAS DE CULTIVO CON ROTACIONES DE CULTIVOS

Muchas veces los ELDA involucran rotaciones de cultivos que forman parte de los tratamientos cuyos efectos se desean evaluar. Cómo considerar las secuencias de cultivos según objetivos y variables respuestas en los diseños y análisis estadísticos, es de importancia relevante.

Uno de los aspectos más importantes para tener en cuenta en los ELDA, es el manejo de los efectos del “tiempo+ambiente” y cómo evitar que se confundan con los efectos de los tratamientos. Los efectos sobre las variables respuesta son el resultado de los tratamientos más las condiciones ambientales y/o las situaciones tecnológicas particulares que se dan en cierto período de años y, muchas veces, estos efectos no pueden separarse. ¿Qué estrategias pueden adoptarse y cómo deben planificarse los ensayos para garantizar que los efectos acumulados de los tratamientos no se confundan con los ambientales? ¿Cómo diseñar el experimento para evitar, por lo menos, la confusión total de efectos? Y de darse, aunque sea una confusión parcial, ¿qué cuidados deben tenerse al interpretar resultados y sus alcances? Por otro lado, muchas veces no es necesario aislar efectos, sino entender el proceso como una sumatoria de causas. En particular, cómo contemplar estas características en los ELDA con sistemas de cultivo con rotaciones de cultivos, es uno de los objetivos de este capítulo.

Cuando se va a iniciar un ELDA, advertir ciertas características que permitan clasificarlo, ayudará a su planificación y, posteriormente, a analizar adecuadamente las variables respuesta obtenidas. Si el ELDA ya está en marcha, su clasificación en función de aquellas características, también permitirá evaluar sus alcances y limitaciones y, de ser necesario y posible, reorientar su rumbo. Con esta idea, a continuación, se analizan los ensayos del Sudeste Bonaerense presentados en el Capítulo 2, según aspectos de su diseño. Se presentan algunas propuestas que podrían mejorar su diseño y de análisis estadístico de los datos, también se dan sugerencias de diseño para ensayos similares a futuro.

## 6.1 Términos básicos en una rotación

Es importante definir ciertos términos que permitirán llevar una lectura clara y precisa a lo largo de este Capítulo y lo que resta de este trabajo de tesis. A continuación, se definen o precisan dichos términos. Algunos de ellos fueron tomados y/o adaptados de Yates (1954) y Patterson (1964).

Una *rotación de cultivos* es un sistema en el cual diferentes cultivos combinados de una manera particular se realizan en la misma porción de terreno, a través del tiempo. Por otro lado, una *rotación básica* es el mínimo grupo de cultivos, que pueden repetirse o no en la sucesión, con el que se realiza la rotación de cultivos. Ejemplo, si A y B son dos cultivos, una rotación básica podría ser ABB. Muchas veces una rotación de cultivos se da por una repetición cíclica de una rotación básica.

Una *secuencia* de la rotación de cultivos es una sucesión ordenada de los cultivos en la rotación básica. Por ejemplo, si la rotación está constituida por los cultivos A, B y C, donde se quiere que A anteceda a B, B anteceda a C y C a A, hay tres secuencias posibles: i) la que inicia en A (ABC), ii) la que inicia en B (BCA), y iii) la que inicia en C (CAB). Si a cada una de las componentes de la rotación básica se la denomina *fase*, entonces cada posible secuencia inicia en una fase diferente.

Una *rotación cíclica* se da cuando una secuencia de cultivos se sucede a sí misma, constituyendo los *ciclos* de la rotación. Cada vez que se realiza una rotación básica se constituye un ciclo. La primera vez que se realiza es el primer ciclo, la repetición en el tiempo luego del primer ciclo es el segundo ciclo y así siguiendo. Cada *ciclo* es una repetición de la rotación básica que acumula efectos del ciclo anterior. Así, el *período* de la rotación básica es el número de años, u otra unidad de tiempo, que comprende un ciclo.

## 6.2 ELDA, rotaciones de cultivos y consideraciones de diseño

Los experimentos que involucran rotaciones de cultivos son variados. Hay experimentos de una sola rotación de cultivos y los hay que involucran más de una, incluyendo, a veces, pasturas. En todos estos experimentos se comparan los efectos de las secuencias de cultivos

o de cultivos y pasturas, combinados con los niveles de otros factores, como fertilización o laboreo y, clásicamente, están enfocados en los efectos sobre el rendimiento de un cultivo testigo (Yates, 1954; Patterson, 1964).

Los experimentos de rotación de cultivos no necesitan ser complejos en el largo plazo (Patterson, 1964). No obstante, la repetición cíclica de una rotación básica da lugar a un ELDA o, del mismo modo, se transforma en un ELDA si la rotación básica comprendiera gran cantidad de componentes o fases, o combinación de distintas rotaciones básicas. En las rotaciones cíclicas, generalmente hay especial interés en los efectos de los ciclos.

Un principio fundamental en el diseño de un experimento de rotación cíclica es que todas las secuencias pertenecientes a cada rotación básica deben incluirse en el experimento, es decir, todas las fases deben ocurrir cada año (Patterson, 1964). Esto es para que el efecto ambiente, que incluye el año, esté combinado con todas las fases. De esta forma, por ejemplo, si en el experimento se incluyera un año favorable para los cultivos, el hecho de que todos ellos estén presentes ese año hace que ninguno esté beneficiado más que otro o, en forma análoga, si el año fuera desfavorable. Es decir, si las fases están presentes todos los años, se evita confundir los efectos de los cultivos con los efectos de los años (ambientes).

Las primeras publicaciones sobre el diseño y el análisis de los ELDA hacen referencia principalmente o casi exclusivamente al rendimiento de los cultivos como variable respuesta. Este aspecto no es menor, ya que las consideraciones a realizar sobre el diseño y los análisis estadísticos deberán realizarse de acuerdo con la variable o variables respuesta sobre las que se estudien los efectos de los tratamientos. Así, si en un ensayo se persiguieran objetivos de producción comparando dos o más rotaciones de cultivos, en particular la comparación de rendimientos, es necesario que entre las rotaciones haya, por lo menos, un cultivo en común (i.e. cultivo testigo). Si el objetivo del experimento fuera estudiar las variaciones de ciertas variables de suelo, como, por ejemplo, la dinámica del carbono, no se necesitaría tener cultivos comunes en las rotaciones.

En los experimentos de rotación cíclica, Patterson (1964) distingue tres tipos de diseño: los “básicos”, los “reducidos” y los de “fases-confundidas”. Según aquel autor, los diseños “básicos” son los que incluyen todas las secuencias de las rotaciones en un mismo bloque. Así,

se evita el confundimiento del efecto de los bloques y el de las secuencias. Aquí la referencia a los bloques deja en claro que el experimento sólo se concebía en bloques, tal vez porque, dadas sus dimensiones, un diseño completamente aleatorizado no sería opción en la gran mayoría de los casos. La variación en el suelo y la imposibilidad de un manejo integral uniforme de todo el ensayo lleva a tener que planificarlo en bloques más que sin ellos. Estos diseños básicos pueden realizarse para cualquier conjunto de rotaciones, por lo menos desde lo conceptual, pero tal vez no desde lo práctico. La desventaja principal del diseño básico es que, a veces, se pueden necesitar bloques de gran tamaño. Bajo ciertas condiciones, esta dificultad puede ser superada dividiendo las secuencias de cultivo en grupos, dependiendo de su comparabilidad.

Los diseños de experimentos con rotaciones cíclicas “reducidos” se basan en establecer grupos de secuencias comparables. Cada grupo de secuencias comparables se asigna a un mismo bloque, así los bloques resultan incompletos y sus efectos, confundidos con los de las secuencias que se probaron en ellos. Si se está pensando en comparar rendimiento de los cultivos, dos secuencias, para rotaciones iguales o diferentes, se describirán como comparables con respecto a un cultivo testigo si, en al menos un año, coinciden en la presencia de ese cultivo testigo (Patterson, 1964). Con este criterio de comparabilidad, este tipo de diseño no es posible para cualquier conjunto de rotaciones.

Según Patterson (1964), los diseños de “fases confundidas” son, en definitiva, los que confunden efectos de bloques con efectos de fases, o que los efectos de fases son parte de los efectos de bloques. Hay un bloque para cada fase de todas las secuencias. Lo que siempre se respeta es que todas las fases están todos los años, pero no en un mismo bloque. De esta forma se prioriza el efecto diferencial que puede haber entre condiciones ambientales cambiantes de un año a otro, respecto a las variaciones en el sitio dentro de un mismo año.

Loughin (2006) marca una deficiencia en los diseños “estándar” de los ELDA dada por la falta de repetición de los factores ambientales a los que las parcelas tratadas están expuestas. Para subsanar esta deficiencia, el mismo autor revaloriza los diseños de “inicio escalonado” que fueron propuestos por otros autores tanto en las ciencias de los cultivos como en otras disciplinas donde se realizan ensayos de larga duración. Loughin (2006) también señala que los inicios escalonados no se encuentran aplicados con frecuencia y especula con que esto se

debe a que los inconvenientes sustanciales del diseño estándar de los ELDA y los correspondientes beneficios del diseño de “inicio escalonado” no son bien comprendidos por los investigadores que diseñan, conducen y analizan los ELDA. Al respecto, McRae y Ryan (1996) enfatizan que los comienzos escalonados de los ensayos deben considerarse cuando el clima en el año del establecimiento del ensayo pueda afectar grandemente el crecimiento de un cultivo perenne en los años siguientes.

Loughin (2006) señala que lograr una verdadera replicación en el tiempo de la manera habitual -repetición del experimento completo varias veces, cada uno en sucesión a la conclusión de la réplica anterior- no es factible con los ELDA, cuya duración puede ser de muchos años. Por ello, dicho autor expresa que una buena solución de compromiso entre varios aspectos y que logra la replicación con relativamente poco tiempo, es escalar el inicio de los tratamientos en diferentes bloques a través de los años. Es decir, bloques dentro del experimento se ejecutan iniciando el Bloque 1 en el primer año, el Bloque 2 en el segundo año, y así sucesivamente para tantas repeticiones como estén planificadas en la investigación. Así, de forma análoga a los diseños de “fases-confundidas” de Patterson, se proponen los diseños de “inicios-confundidos”, ya que en ambos casos se confunden los efectos de bloques o bien con los efectos de las fases, o bien con los efectos de los inicios.

Por último, los ELDA pueden organizarse de acuerdo con cualquier diseño experimental válido, incluyendo los diseños en bloques, pero no exclusivamente. Los diseños en parcelas divididas y bloques divididos, entre otros, pueden ser útiles para arreglar dos o más factores de tratamiento.

### **6.2.1 Ensayo comparativo de rotaciones de cultivos y fertilización**

El ensayo de “Agricultura continua” fue descrito en la sección 2.2.1 (Capítulo 2). En este ensayo se probaron 16 secuencias de cultivos conjuntamente con la aplicación o no de fertilizante nitrogenado, y estuvo vigente durante 12 años.

Las secuencias probadas en el ensayo (Studdert y Echeverría, 2000) contienen maíz (M), soja (S), girasol (G) o trigo (T) y se muestran en el Tabla 6.1. Se observan nueve secuencias con un solo trigo, seis secuencias con dos trigos y una secuencia de sólo trigo.

Tabla 6.1. Secuencias de cultivos probadas en el Ensayo de Agricultura Continua. Los recuadros de bordes grises encierran secuencias con uno y dos trigos.

Secuencias iniciadas con			
Maíz	Soja	Girasol	Trigo
MMT	SMT	GMT	TMT
MST	SST	GST	TST
MGT	SGT	GGT	TGT
MTT	STT	GTT	TTT

M: maíz, S: soja, G: girasol, T: trigo

En los 12 años del ensayo, se realizaron cuatro ciclos de cada secuencia. Tomando como ejemplo las secuencias MTT y TMT, a través de los años ocurrieron siguiendo el esquema que se muestra en el Tabla 6.2.

Tabla 6.2. Desarrollo de las secuencias de cultivos MTT y TMT en todo el período del ensayo.

Secuencia	Año											
	1984	1985	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995
	Ciclo											
	1			2			3			4		
MTT	M	T	T	M	T	T	M	T	T	M	T	T
TMT	T	M	T	T	M	T	T	M	T	T	M	T

M: maíz, T: trigo

El análisis de las secuencias MTT y TMT (Tablas 6.1. y 6.2.) indica que:

1. Ambas secuencias presentan una misma rotación básica y, por lo tanto, para tener todas las fases en un mismo año como indica Patterson (1964), faltaría la secuencia TTM.
2. Ambas secuencias inician el mismo año y se repiten en cuatro ciclos. Al finalizar cada ciclo pueden evaluarse los efectos de las secuencias en uno, dos, tres o cuatro ciclos, cada uno acumulando los efectos previos. No obstante, por otro lado, el efecto de cada ciclo está confundido con el de la sucesión de años en que se realizó. Para

cualquiera de las secuencias (Tabla 6.1.), el ciclo 1 (Tabla 6.2.) es la secuencia de tres cultivos luego de una situación de pastura (sección 2.2.1.), pero sólo se puso a prueba en el período 1984-1986. Por otro lado, el ciclo 2 (Tabla 6.2.), que acumula el efecto del ciclo 1, sólo se puso a prueba en el período 1987-1989, y así siguiendo con los restantes ciclos.

3. Si se hubiese tenido la secuencia TTM, al finalizar cada ciclo podría haberse evaluado el efecto de la rotación básica con todas sus variantes de inicio en diferentes fases de la rotación básica, pero, al igual que como fuera mencionado en 2., confundida con los años.
4. La rotación cíclica de una de las secuencias, genera repeticiones en el tiempo de la otra y viceversa. Por ejemplo, la secuencia MTT (Tabla 6.2.), puede verse como iniciada dos veces, en dos años consecutivos: una repetición inició en 1984 y la otra en 1985 (Tabla 6.3.). Luego, la rotación cíclica de aquella secuencia completó cuatro ciclos en las parcelas en que se había iniciado en 1984, mientras que en las parcelas en que se inició en 1985, el cuarto ciclo se hubiese completado en 1996. La diferencia entre ambas (la iniciada en 1984 y la iniciada en 1985) es que el antecesor inmediato en cada una cambia, en una es pastura (sección 2.2.1.) y en la otra, es un año de T luego de la pastura (sección 2.2.1., Tabla 6.3.). Es decir, ambas secuencias inician sobre parcelas con diferentes condiciones previas. No obstante, esta diferencia en las condiciones de inicio podría no tener ningún impacto en el largo plazo. De esta manera, la secuencia MTT y sus ciclos estarían repetidos en el tiempo, aquí con dos repeticiones en el tiempo en el mismo bloque, y a cada una de ellas se las podría denominar *serie*. En el siguiente esquema se resalta la existencia de dos series de la misma secuencia (MTT):

Tabla 6.3. Desarrollo de las secuencias de cultivos MTT y TMT (Tabla 6.1) en todo el período del ensayo, evidenciando en ambas la ocurrencia de la secuencia MTT.

Secuencia	Año											
	1984	1985	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995
	Ciclo de MTT											
	1			2			3			4		
MTT	M	T	T	M	T	T	M	T	T	M	T	T
		1			2			3				
TMT	T	M	T	T	M	T	T	M	T	T	M	T

M: maíz, T: trigo

Así, el ciclo 1 de MTT está probado en las secuencias de años 1984-1986 y 1985-1987 (Tabla 6.3.), aunque con diferente historia previa (pastura o T luego de la pastura, en el año previo). Sin embargo, como se indicó, se espera que luego de varios ciclos el efecto de la diferencia en el inicio no sea importante. Por ejemplo, al finalizar el tercer ciclo de MTT tanto en la secuencia MTT como en la TMT (Tabla 6.3.), se habrán acumulado los efectos de dos ciclos previos de la secuencia. Podría esperarse que estos efectos fueran más relevantes que los de los respectivos cultivos previos al inicio de la rotación cíclica de MTT en cada secuencia.

Del mismo modo, lo observado para las secuencias MTT y TMT (Tabla 6.3.), es lo que sucedería con las secuencias STT y TST, y las secuencias GTT y TGT (Tabla 6.1.). Es decir, los tres grupos de secuencias presentan un cultivo en común (M, G o S), y dos cultivos de T. Cada uno de los tres grupos presenta una misma rotación básica, pero coinciden en que para completar la evaluación del efecto las rotaciones básicas en los mismos períodos de años (Patterson, 1964), adolecen de las secuencias TTM, TTS y TTG, respectivamente. Asimismo, al igual que MTT y TMT (Tabla 6.3.), tanto STT y TST y sus ciclos, como GTT y TGT y sus ciclos, podrían verse como repeticiones en el tiempo de una misma secuencia. De hecho, según lo mostrado en la Figura 2 del trabajo publicado por Studdert y Echeverría (2000), el promedio anual de la cantidad de carbono retornado al suelo a través de los residuos de las secuencias STT y TST, GTT y TGT, y MTT y TMT no difirieron entre secuencias dentro de cada grupo.

Por otro lado, a diferencia de lo ocurrido con las secuencias con dos cultivos de T, las que presentaban un solo cultivo de T (MMT, MST, MGT, SMT, SST, SST, SGT, GMT, GST y GGT) (Tabla 6.1.), fueron puestas a prueba con inicio en 1984 con sólo una de las tres posibles fases de cada una de sus rotaciones básicas. Es decir, por ejemplo, en el período 1984-1986 se puso

a prueba MMT, pero no se pusieron a prueba MTM, ni TMM. Por lo tanto, en el ensayo de “Agricultura continua” (sección 2.2.1.) hubo nueve rotaciones básicas que al iniciar el ensayo comenzaron en una sola de las posibles fases, tres rotaciones básicas que al iniciar el ensayo comenzaron en dos de sus posibles fases, y otra rotación que correspondió a T continuo.

Según Patterson (1964), todas las fases de una rotación deben estar presentes todos los años y, por otro lado, según Loughin (2006), debe existir un inicio escalonado de todas las secuencias. Entonces, teniendo en cuenta estas dos sugerencias, para cada una de las rotaciones básicas con tres fases (son 12 más una constituida por sólo T (Tabla 6.1.)) habría que probar tres secuencias de cada una que involucrara cultivos diferentes. En consecuencia, el ensayo debería haber iniciado el primer año con 37 secuencias ( $12 \times 3 + 1$ ), aquí un primer inicio de todos los tratamientos. Además, por lo menos en otro año (comúnmente en el segundo año de ensayo), deberían haber vuelto a iniciarse todos los primeros ciclos de todas las secuencias, segundo inicio. El primer ciclo de cada secuencia se iniciaría más de una vez, es decir en más de un año, generando repeticiones en el tiempo (diseño de inicio escalonado). La cantidad de veces que se inicien las secuencias es arbitraria, y depende de los recursos y la planificación. Así, por ejemplo, el esquema de tratamientos mostrando las tres secuencias de una de las rotaciones básicas con dos T (de las tres rotaciones básicas en este ensayo con dos T, Tabla 6.1.) y las tres secuencias de una rotación básica con un solo T (de las nueve rotaciones básicas en este ensayo con un solo T, Tabla 6.1.), y con tres inicios escalonados (este número es arbitrario, el mínimo es dos), se muestra en el Tabla 6.4.

Tabla 6.4. Esquema de las tres posibles secuencias para cada una de las rotaciones básicas maíz (M)-trigo (T)-T (MTT) y MMT, con tres inicios escalonados en los primeros doce años de un ensayo. P: pastura.

Rotación Básica	Secuencia	Año											
		1	2	3	4	5	6	7	8	9	10	11	12
MTT	MTT	M	T	T	M	T	T	M	T	T	M	T	T
		P	M	T	T	M	T	T	M	T	T	M	T
		P	P	M	T	T	M	T	T	M	T	T	M
	TMT	T	M	T	T	M	T	T	M	T	T	M	T
		P	T	M	T	T	M	T	T	M	T	T	M
		P	P	T	M	T	T	M	T	T	M	T	T
	TTM	T	T	M	T	T	M	T	T	M	T	T	M
		P	T	T	M	T	T	M	T	T	M	T	T
		P	P	T	T	M	T	T	M	T	T	M	T
MMT	MMT	M	M	T	M	M	T	M	M	T	M	M	T
		P	M	M	T	M	M	T	M	M	T	M	M
		P	P	M	M	T	M	M	T	M	M	T	M
	MTM	M	T	M	M	T	M	M	T	M	M	T	M
		P	M	T	M	M	T	M	M	T	M	M	T
		P	P	M	T	M	M	T	M	M	T	M	M
	TMM	T	M	M	T	M	M	T	M	M	T	M	M
		P	T	M	M	T	M	M	T	M	M	T	M
		P	P	T	M	M	T	M	M	T	M	M	T

Series probadas en el "Ensayo de agricultura continua"

Series no probadas en el "Ensayo de agricultura continua"

Entonces, si los primeros ciclos de las 37 secuencias se iniciaran en, por ejemplo, 3 años (es decir 3 veces replicadas en el tiempo), se necesitarían  $37 \times 3 = 111$  parcelas sólo para una sola repetición en el espacio. O sea que, si se pretendieran dos repeticiones en el espacio o dos bloques, se necesitarían  $111 \times 2 = 222$  parcelas. Este número parece excesivo desde el punto de vista operativo y para su implementación aún sin restricciones de recursos. Entonces surgen las siguientes preguntas: a) ¿puede diseñarse de otra manera?; b) ¿es necesario probar todas las rotaciones en un solo ensayo?; c) sin realizar los inicios escalonados, ¿podría compensarse de alguna manera lo buscado con los inicios escalonados? Para la respuesta a esta última pregunta, habría que tener en cuenta lo manifestado respecto a que en cada secuencia de una misma rotación básica pueden tenerse repeticiones en el tiempo de las otras secuencias de la

misma rotación básica (Tabla 6.3.), con la salvedad de que las condiciones previas a los primeros ciclos son diferentes.

La pregunta b) obligaría a replantear los objetivos de estudio, lo que puede llevar a la reducción del número de rotaciones para un ensayo. La pregunta a) podría ser respondida siguiendo otra sugerencia de Loughin (2006), aunque esta implica confundir efectos de bloques con efectos de inicios. Esta consiste en iniciar cada bloque con las 37 secuencias en diferentes años (inicios -confundidos). En este caso, para 3 inicios escalonados la cantidad de parcelas sería de 111 ( $37 \times 3$ ), es decir las 37 secuencias en un bloque se iniciarían el primer año, luego al segundo año se iniciarían las 37 secuencias en otro bloque y lo mismo en el tercer año. En este caso, si los bloques en principio estuvieran controlando variabilidad espacial y/o tratando de controlar posible variabilidad derivada de aspectos operativos, también a cada uno se le estaría sumando el efecto de la serie de años que le correspondió.

Para responder a la pregunta c) se podría considerar el esquema presentado en la Tabla 6.5. En esta Tabla se muestran las tres posibles secuencias de la rotación básica MTT, iniciadas un mismo año y con cuatro ciclos. En la Tabla 6.5. se puede ver que cada una de las tres posibles secuencias están repetidas en el tiempo, al probarse otras secuencias, al considerarse los distintos inicios de la rotación básica, con diferencia de la situación previa al inicio entre repeticiones en el tiempo.

Tabla 6.5. Esquema de las tres posibles secuencias de la rotación básica maíz (M)-trigo(T)-T iniciadas en cada una de sus fases y con cuatro ciclos completos de cada una. Los recuadros identifican los primeros ciclos completos de: a) la secuencia MTT en el esquema de cada una de las tres secuencias; b) la secuencia TMT en el esquema de cada una de las tres secuencias; c) la secuencia TTM en el esquema de cada una de las tres secuencias.

Secuencia	Año											
	1	2	3	4	5	6	7	8	9	10	11	12
a)												
MTT	M	T	T	M	T	T	M	T	T	M	T	T
TMT	T	M	T	T	M	T	T	M	T	T	M	T
TTM	T	T	M	T	T	M	T	T	M	T	T	M
b)												
MTT	M	T	T	M	T	T	M	T	T	M	T	T
TMT	T	M	T	T	M	T	T	M	T	T	M	T
TTM	T	T	M	T	T	M	T	T	M	T	T	M
c)												
MTT	M	T	T	M	T	T	M	T	T	M	T	T
TMT	T	M	T	T	M	T	T	M	T	T	M	T
TTM	T	T	M	T	T	M	T	T	M	T	T	M

Las variaciones de variables como carbono orgánico total del suelo (COT) debidas a las secuencias de cultivos, en particular a secuencias como las planteadas en esta sección, pueden analizarse tomando diferencias de contenido cada tres años (duración del ciclo de la secuencia), en términos absolutos o relativos al del inicio del período. Analizar las diferencias de COT sería una forma de aislar el efecto de la secuencia del de las condiciones previas que no son las mismas para todas las repeticiones de las secuencias.

Por ejemplo, en las parcelas correspondientes a la secuencia MTT (Tabla 6.5.), las diferencias de contenido de COT entre los años 3 y 1 informarían sobre el efecto de la secuencia MTT (Tabla 6.5. a)). Por otro lado, las diferencias de contenido de COT entre los años 4 y 2 informarían sobre el efecto de TTM (Tabla 6.5. c)), mientras que las diferencias entre los años 5 y 3, lo harían sobre el efecto de TMT (Tabla 6.5. b)). Lo mismo ocurriría con las secuencias TMT y TTM (Tabla 6.5.). Lo dicho se refiere a la consideración de sólo el primer ciclo. No obstante, también podrían obtenerse las diferencias en contenido de COT entre el último y el primer año de cada uno del segundo, tercer, y cuarto ciclos, en los casos en que

fuera posible. A su vez, estas diferencias podrían ser clasificadas según el ciclo a que correspondan si es de interés separar el efecto del ciclo de los demás efectos que intervengan en el análisis (p.e. diferencias en la duración y características en el período previo al primer año del ciclo analizado). Asimismo, para evaluar efectos de más largo plazo, podrían considerarse las diferencias entre inicio y fin de un período de mayor duración. Así, cada 6 años se podría evaluar el efecto de dos ciclos acumulados, cada 9 para evaluar el efecto de tres ciclos acumulados, y así siguiendo. Estas diferencias de COT en cada parcela también pueden ser tomadas relativas a los valores iniciales en cada período. Los análisis de las diferencias, absolutas o relativas, también pueden incluir estos valores iniciales como valores de una covariable en modelos lineales adecuados.

### **6.2.2 Ensayo comparativo de tres rotaciones de cultivos con laboreos contrastantes**

En el “Ensayo de Secuencias Agrícolas y Sistemas de Laboreos” presentado en la Sección 2.2.2. (Capítulo 2) se observa:

1. Hay tres rotaciones básicas: M - M - T, M - soja (S) - T, S - S - T.
2. Las tres secuencias posibles de cada una de ellas están probadas en el ensayo. Son nueve secuencias en total. Las secuencias son TMM (1), MTM (2) y MMT (3) para una rotación básica, TMS (1), STM (2) y MST (3) para otra rotación básica y TSS (1), STS (2) y SST (3) de la tercera rotación básica.
3. Las secuencias identificadas con (1) formaron un grupo (T como primera fase), lo mismo que las identificadas con (2) (T como segunda fase) y también con (3) (T como tercera fase). Cada uno de estos grupos fueron asignados a dos bloques.
4. En cada bloque los laboreos se asignaron a las parcelas principales.
5. En las subparcelas dentro de cada parcela principal se asignaron las secuencias de las tres rotaciones básicas en la fase correspondiente a ese bloque. Pero las secuencias dentro de las parcelas principales siempre se asignaron en el mismo orden, es decir siempre la secuencia de una rotación básica, seguía a una de otra rotación básica, no estaban aleatorizadas.

6. En todo el ensayo hay seis bloques. Dos bloques para cada fase, en definitiva, dos repeticiones en el espacio para cada fase y laboreos.
7. Carece de inicios escalonados de las secuencias de cultivos.

El diseño de este ensayo es del tipo “fases-confundidas” como los indicados por Patterson (1964). No obstante, presenta la ventaja de que se realizaron dos repeticiones en el espacio para cada fase.

Dejando de lado en principio la planificación de los inicios escalonados, si el espacio a utilizar y toda la conducción del ensayo se pudiese mantener uniforme conformando bloques del triple del tamaño de cada bloque en el ensayo original se podría haber realizado un diseño básico. En un diseño básico todas las secuencias y sus combinaciones con los laboreos, en este caso, están presentes en un mismo bloque. A continuación, se muestran los posibles diagramas de diseños de ensayos ocupando la misma superficie de sitio que el original y afectando el mismo recurso. El diseño realizado en esta experiencia asignó cada fase a dos bloques cercanos en el espacio. De esta forma puede pensarse cada fase como un ensayo con dos repeticiones. El caso a) que se presenta es muy similar al ensayo original, pero con otra asociación de las fases a los bloques en el espacio. Para el caso b) se han supuesto características en el material experimental que posibilita la formación de los bloques que se presentan.

- a) Si las fases más el espacio definen los bloques, el diseño puede ser considerado de bloques completos con parcelas divididas. Sería un bloque completo dado que, para una misma fase se encuentran todas las combinaciones de rotaciones y laboreos en el bloque (tres rotaciones con dos laboreos). Habría seis bloques, los laboreos asignados al azar a las parcelas principales y las rotaciones básicas asignadas al azar a las subparcelas dentro de una parcela principal. Un posible diagrama de campo que responde a este diseño se muestra en la Fig. 6.1.

Fase 1						Fase 2						Fase 1					
R1	R3	R2	R3	R1	R2	R3	R2	R1	R1	R2	R3	R2	R1	R3	R3	R2	R1
T	T	T	T	T	T	S	S	M	M	S	S	T	T	T	T	T	T
M	M	S	M	M	S	T	T	T	T	T	T	S	M	M	M	S	M
M	S	S	S	M	S	M	S	M	M	S	M	S	M	S	S	S	M

Fase 3						Fase 3						Fase 2					
R2	R1	R3	R1	R2	R3	R2	R3	R1	R2	R3	R1	R1	R3	R2	R1	R3	R2
S	M	M	M	S	M	S	M	M	S	M	M	M	S	S	M	S	S
S	M	S	M	S	S	S	S	M	S	S	M	T	T	T	T	T	T
T	T	T	T	T	T	T	T	T	T	T	T	M	M	S	M	M	S

Laboreo Convencional
  Siembra directa

Fig. 6.1. Diagrama de un ensayo para evaluar tres rotaciones de cultivo (R1, R2, R3) y dos laboreos contrastantes (Laboreo Convencional y Siembra directa) en seis bloques. Cada fase de cada rotación está presente en dos bloques todos los años. R1: trigo (T) (Fase 1), maíz (M)(Fase 2), M (Fase 3); R2: T (Fase 1), soja (S)(Fase 2), S (Fase 3); R3: T (Fase 1), M (Fase 2), S (Fase 3).

b) Si se tuviera la posibilidad de delimitar 18 subparcelas con condiciones homogéneas en un sector (bloque 1) y otras 18 en otro sector (bloque 2), el diseño podría ser un diseño en bloques completos aleatorizados con parcelas divididas. El ensayo tendría dos bloques, con los laboreos asignados en las parcelas principales y las nueve secuencias asignadas al azar a las subparcelas dentro de cada parcela principal.

Bloque 1																	
T	M	T	M	T	S	S	S	M	S	M	T	S	T	T	M	M	S
M	T	S	M	M	S	T	T	S	S	S	M	T	S	M	M	T	T
M	M	S	T	S	T	M	S	T	T	T	M	S	S	S	T	M	M

Bloque 2																	
M	T	M	S	M	T	S	T	S	T	M	M	S	T	M	T	S	S
T	S	M	T	S	M	T	M	S	M	M	T	T	S	S	M	T	S
M	S	T	M	T	M	S	S	T	S	T	M	M	S	T	M	S	T

Laboreo Convencional
  Siembra directa

Fig. 6.2. Diagrama de un ensayo para evaluar nueve secuencias de cultivo (tres secuencias de tres rotaciones: R1, R2, R3) y dos laboreos contrastantes (Laboreo Convencional y Siembra directa) en dos bloques. Cada fase de cada rotación está presente en los mismos dos bloques todos los años. R1: trigo (T)(Fase 1), maíz (M)(Fase 2), M (Fase 3); R2: T (Fase 1), soja (S)(Fase 2), S (Fase 3); R3: T (Fase 1), M (Fase 2), S (Fase 3).

Para agregar inicios escalonados en cualquiera de los esquemas de las Fig 6.1 y 6.2, se podrían iniciar nuevas repeticiones del ensayo en próximos años en nuevos bloques. Esto, para el caso a) sería conducir otros seis bloques en cada inicio, o tres, uno para cada fase. Para el caso del diseño básicos (b, Fig. 6.2.) también se realizarían dos bloques en cada inicio, si los recursos fueran suficientes, o bien un bloque por inicio. Iniciar el ensayo con dos bloques en cada año, como mínimo, da la posibilidad de las repeticiones en el espacio para cada inicio. Un bloque en cada inicio lleva a un diseño de inicio- confundido.

### **6.2.3 Ensayo comparativo de laboreos y tratamientos adicionales con única rotación de cultivos.**

En el “Ensayo de Sistemas de Laboreos” presentado en la sección 2.2.3. se observa:

1. Hay una única rotación básica: T - M – girasol (G).
2. Las tres secuencias posibles están incluidas en el ensayo, TMG, MGT y GTM, de tal forma que las tres fases están presentes en todos los años del ensayo.
3. En cada año, ambiente, hay tres repeticiones en el espacio ya que hay tres bloques, cada uno con las tres secuencias.
4. El diseño del ensayo es un diseño en bloques completos aleatorizados con parcelas subdivididas. Las parcelas principales tienen asignadas las secuencias, las subparcelas tienen asignadas los laboreos, las sub-subparcelas los niveles de fertilización con N y las sub-sub-subparcelas los niveles de cultivo cobertura.
5. No hay inicios escalonados de cada secuencia.

Es un diseño básico (Patterson, 1964), pues todas las secuencias están en un bloque.

Las consideraciones para completar el ensayo con inicios de las secuencias en otros años es similar a las ya hechas en las secciones previas. Es decir, si el sitio y los recursos lo permitiesen, se podría iniciar una repetición (mínimo) de todo el ensayo en un nuevo bloque y, de esa manera, habría una realización en otra serie de años de todas las secuencias con los laboreos y demás tratamientos adicionales. Con los mismos recursos se podría haber realizado un ensayo con inicios escalonados. Cada uno de los tres bloques podrían haber iniciado en diferentes años. No obstante, como ya se ha indicado, este tipo de diseño confunde los efectos

de los bloques con los de la serie de años o, dicho de otro modo, el bloque quedaría definido por el espacio más la serie de años en que se lleva adelante esa parte del ensayo.

#### **6.2.4 Ensayo comparativo de rotaciones mixtas de pastura y agricultura con laboreos contrastantes**

En el “Ensayo de Rotaciones Mixtas y Sistemas de Laboreo”, presentado en la sección 2.2.4. (Capítulo 2), a partir del año 1994 hay siete sistemas de cultivo considerando dos sistemas de laboreo (LC: laboreo convencional, SD: laboreo con siembra directa). Los sistemas de cultivo considerados son:

- (1) pastura permanente (Pp),
- (2) agricultura continua por 3 años con LC seguida de pastura continua por 3 años (50%LC),
- (3) agricultura continua por 3 años con SD seguida de pastura continua por 3 años (50%SD),
- (4) agricultura continua por 9 años con LC seguida de pastura continua por 3 años (75%LC),
- (5) agricultura continua por 9 años con SD seguida de pastura continua por 3 años (75%SD),
- (6) agricultura permanente con LC (100%LC),
- (7) agricultura permanente con SD (100%SD).

En el esquema de las secuencias de cultivos en la sucesión de años (Capítulo 2, Tabla 2.3) se observa:

1. en agricultura continua la única rotación básica es M - T - S y sólo se presenta una posible secuencia. Se inicia con M, se sigue con T y luego con S de tal forma que, en un mismo año, si hay agricultura, está presente un cultivo.
2. Para cada uno de los sistemas (2), (3), (4) o (5), los períodos de agricultura y los de pastura están asociados a únicos períodos de años. Por ejemplo, en (2) y (3) el primer ciclo de agricultura MST fue probado en el período de años 1997-1998-1999.

De esta forma, los efectos de los sistemas de cultivo están confundidos con los efectos ambientales propios de los años en que fueron probados.

De acuerdo con estas observaciones, a continuación, se presenta un esquema “ideal” para evitar la confusión de efectos y tener todas las fases de las rotaciones de los cultivos todos los años en que hay agricultura (Tabla 6.6). El esquema presentado en la Tabla 6.6. sólo muestra los primeros 15 años del ensayo.

El esquema sugerido tiene las secuencias MST, STM y TMS en los mismos períodos de tres años para tener la representación completa de la rotación básica en cada período. Es decir, se completa el esquema original para tener todas las fases de la rotación básica un mismo año. Por otro lado, también se consideran inicios desplazados en un año de cada secuencia, para asegurar que los períodos de agricultura o pastura no se correspondan con únicas sucesiones de años (Tabla 6.6.).

Tabla 6.6. Esquema de las rotaciones mixtas considerando las tres secuencias de cultivos (maíz (M) - soja (S) -trigo (T), STM y TMS) para un ensayo de rotaciones mixtas. Sistemas de cultivos: (1) pastura permanente, (2) agricultura continua por 3 años con LC seguida de pastura continua por 3 años, (3) agricultura continua por 3 años con SD seguida de pastura continua por 3 años, (4) agricultura continua por 9 años con LC seguida de pastura continua por 3 años, (5) agricultura continua por 9 años con SD seguida de pastura continua por 3 años, (6) agricultura permanente con LC, (7) agricultura permanente con SD. Secuencias: A, B y C representan a MST, STM y TMS respectivamente en los sistemas de cultivo (2) y (3), D, E y F representan a MST, STM y TMS respectivamente en los sistemas de cultivo (4) y (5), y G, H, I representan a MST, STM y TMS respectivamente en los sistemas de cultivo (6) y (7). Las secuencias de cultivos se inician en diferentes años (Inicio). Las celdas sombreadas en gris corresponden a años con pastura. M: maíz, T: trigo, S: soja.

Sistema de cultivo	Secuencia	Inicio	Año															
			1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	
(1)	--	único																
(2), (3)	A	1				M	S	T				M	S	T				
	B	1				S	T	M				S	T	M				
	C	1				T	M	S				T	M	S				
	A	2					M	S	T				M	S	T			
	B	2					S	T	M				S	T	M			
	C	2					T	M	S				T	M	S			
	A	3						M	S	T				M	S	T		
	B	3						S	T	M				S	T	M		
	C	3						T	M	S				T	M	S		
	A	4	M	S	T					M	S	T				M	S	T
	B	4	S	T	M					S	T	M				S	T	M
	C	4	T	M	S					T	M	S				T	M	S
	A	5		M	S	T					M	S	T				M	S
	B	5		S	T	M					S	T	M				S	T
	C	5		T	M	S					T	M	S				T	M
	A	6			M	S	T					M	S	T				M
	B	6			S	T	M					S	T	M				S
	C	6			T	M	S					T	M	S				T
(4), (5)	D	1				M	S	T	M	S	T	M	S	T				
	E	1				S	T	M	S	T	M	S	T	M				
	F	1				T	M	S	T	M	S	T	M	S				
	D	2					M	S	T	M	S	T	M	S	T			

	E	2					S	T	M	S	T	M	S	T	M		
	F	2					T	M	S	T	M	S	T	M	S		
	D	3						M	S	T	M	S	T	M	S	T	
	E	3						S	T	M	S	T	M	S	T	M	
	F	3						T	M	S	T	M	S	T	M	S	
	D	4							M	S	T	M	S	T	M	S	T
	E	4							S	T	M	S	T	M	S	T	M
	F	4							T	M	S	T	M	S	T	M	S
	D	5								M	S	T	M	S	T	M	S
	E	5								S	T	M	S	T	M	S	T
	F	5								T	M	S	T	M	S	T	M
	D	6									M	S	T	M	S	T	M
	E	6									S	T	M	S	T	M	S
	F	6									T	M	S	T	M	S	T
	D	7										M	S	T	M	S	T
	E	7										S	T	M	S	T	M
	F	7										T	M	S	T	M	S
	D	8											M	S	T	M	S
	E	8											S	T	M	S	T
	F	8											T	M	S	T	M
	D	9												M	S	T	M
	E	9												S	T	M	S
	F	9												T	M	S	T
	D	10	M	S	T	M	S	T	M	S	T				M	S	T
	E	10	S	T	M	S	T	M	S	T	M				S	T	M
	F	10	T	M	S	T	M	S	T	M	S				T	M	S
	D	11		M	S	T	M	S	T	M	S	T				M	S
	E	11		S	T	M	S	T	M	S	T	M				S	T
	F	11		T	M	S	T	M	S	T	M	S				T	M
	D	12			M	S	T	M	S	T	M	S	T				M
	E	12			S	T	M	S	T	M	S	T	M				S
	F	12			T	M	S	T	M	S	T	M	S				T
(6), (7)	G	único	M	S	T	M	S	T	M	S	T	M	S	T	M	S	T
	H	único	S	T	M	S	T	M	S	T	M	S	T	M	S	T	M
	I	único	T	M	S	T	M	S	T	M	S	T	M	S	T	M	S

En la Tabla 6.6. se muestran 58 ( $1 + 6 \times 3 + 12 \times 3 + 1 \times 3$ ) combinaciones de secuencias de cultivos y pastura con períodos de tiempo (series). De las 58 secuencias, una es de pastura continua y las otras 57 contienen agricultura con laboreo LC, entonces en el ensayo completo habría 115 ( $1 + 2 \times 57$ ) combinaciones de secuencias de cultivos y pastura con períodos de tiempo y los dos laboreos. Claramente, este es un planteo de máxima e ideal, y muy difícil de poder llevar a la práctica en el campo. Sin embargo, si se llevaran adelante todas estas combinaciones, habría varias formas de acomodar las secuencias en bloques incompletos, de tal forma que cada bloque quedaría determinado por cuestiones de sitio o espaciales y por el período de años que abarcará en el ensayo. De acuerdo con esto, las posibilidades serían:

- a) Determinar tres bloques de 39 parcelas cada uno. En un bloque se probaría pastura continua y las secuencias con MST (A, D y G, Tabla 6.6.) combinadas con los dos laboreos. Las series con la secuencia A son 6, las series con la secuencia D son 12 y para la secuencia G hay una serie, para cada uno de los dos laboreos. En un segundo bloque también se probaría la pastura continua y las secuencias con STM (B, E y H, Tabla 6.6.) combinadas con los dos laboreos. Las series con la secuencia B son 6, las series con la secuencia E son 12 y para la secuencia H hay una serie, para cada uno de los dos laboreos. En el tercer bloque se probaría pastura continua y las secuencias con TMS (C, F e I, Tabla 6.6) combinadas con los dos laboreos. Las series con la secuencia C son 6, las series con la secuencia F son 12 y la serie con la secuencia I es una, para cada uno de los dos laboreos. Así serían 117 parcelas en todo el ensayo. El diseño que se conforma así, es un diseño fases-confundidas, en cada bloque una fase y todos los inicios escalonados. La pastura continua es el único sistema de cultivo en los tres bloques. Los sistemas mixtos se repiten en los bloques, pero en diferentes fases.
- b) El esquema sería como el planteado en a), en cuanto a la conformación de los tres grupos de secuencias que se asignan a los tres bloques en a), ahora se plantea asignar dos bloques como mínimo a cada uno de esos grupos. En este caso el número mínimo de bloques en el ensayo es seis, cada bloque con 39 parcelas. Considerando el caso de seis bloques así conformados, habría 234 ( $39 \times 6$ ) parcelas en todo el ensayo. Cada combinación de secuencia de cada rotación, laboreo y sucesión de años está repetida dos veces. Cada combinación de rotación, laboreo y

sucesión de años está repetida seis veces (cada rotación mixta o de agricultura continua tiene tres secuencias y cada secuencia se repite dos veces, la pastura continua está una vez en cada uno de los seis bloques).

Si no se llevaran adelante todas las combinaciones de secuencias de cultivos y pastura con períodos de tiempo y los dos laboreos (115) en el ensayo, se podrían plantear las siguientes preguntas: ¿qué es más importante o qué es de mayor interés estudiar?, ¿tener todas las secuencias (MST, STM, y TMS) en un mismo período de tres años, es decir todas las fases de cultivo en un mismo año de un período agrícola o tener sólo una secuencia, ejemplo MST, con varios inicios? De acuerdo con la respuesta que se dé a estas preguntas, lo que implica objetivos agronómicos y las posibilidades de recursos, algunas alternativas serían:

- a) Si se priorizara tener todas las fases de la rotación básica agrícola (M, S, T) en un mismo año, pero probadas en períodos fijos, entonces habría 9 series iniciadas en un mismo año (por ejemplo, las identificadas con Inicio = 1 e Inicio = único, Tabla 6.6.) más la pastura continua. Las combinaciones con laboreos generarían 18 (9x2) secuencias más pastura continua y serían 19 secuencias en total y estas podrían probarse en un diseño con bloques completos.
- b) Si se priorizara probar la rotación básica de cultivos agrícolas iniciando con M, por ejemplo, es decir considerando sólo MST, las series que se pondrían a prueba en el ensayo serían las identificadas con A, D y G, o las series B, E y H, o series C, F e I (Tabla 6.6.). En este caso habría 19 secuencias agrícolas combinadas con los dos laboreos, resultando 38 combinaciones más la pastura continua, es decir 39 secuencias a probar. Si se realizara en un diseño en bloques completos, cada bloque debería tener 39 parcelas.

### **6.3 Propuestas de análisis estadístico para las variaciones del COT**

Para el “Ensayo de Rotaciones Mixtas y Sistemas de Laboreo” y la variable COT se presentan algunos aspectos relevantes para realizar futuros análisis estadísticos. El hincapié no está hecho en el análisis mismo sino en delinear ideas básicas para abordar algunas alternativas de análisis estadísticos y ayudar a definir el análisis más adecuado. En este proceso debe darse

una discusión profunda respecto a los objetivos agronómicos y la contribución que cada alternativa de análisis estadístico pueda brindar. Las metodologías de los análisis definitivos pueden ser aquéllas de las presentadas en el Capítulo 3 y aplicadas en los Capítulos 4 y 5.

En el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo (secciones 2.2.4, Capítulo 2, y 6.2.4) un ciclo completo en todo el ensayo es de 12 años. Cuando se completa un ciclo de los sistemas de 9 años de agricultura + 3 años de pastura (75%LC y 75%SD), se completan dos ciclos de 3 años de agricultura + 3 años de pastura (50%LC y 50%SD). En la Tabla 6.7. se muestra una síntesis de cómo los siete sistemas de cultivo se realizaron en el período de años 1994-2006 y también se indica la situación previa. Las determinaciones de COT en la capa arable son las resultantes del análisis de muestras de suelo tomadas anualmente y previo a la siembra de los cultivos.

Tabla 6.7. Sistemas de cultivos en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo, identificando tramos de pastura y de agricultura. Sistemas de cultivos: pastura permanente (Pastura), agricultura continua por 3 años con LC seguida de pastura continua por 3 años (50%LC), agricultura continua por 3 años con SD seguida de pastura continua por 3 años (50%SD), agricultura continua por 9 años con LC seguida de pastura continua por 3 años (75%LC), agricultura continua por 9 años con SD seguida de pastura continua por 3 años (75%SD), agricultura permanente con LC (100%LC) y agricultura permanente con SD (100%SD). LC: laboreo convencional, SD: laboreo con siembra directa.

Tramos	Sistemas de cultivo						
	Pastura	50%LC	50%SD	75%LC	75%SD	100%LC	100%SD
Antes de 1994	rotaciones mixtas con distintas duraciones de períodos agrícolas + LC y de pastura						Agricultura +LC
	últimos 4 años Agricul- tura	últimos 5 años Agricultura		últimos 8 años Agricultura		últimos 2 años pastura	
1) 1994 a 1997 (0 a 3 años)	pastura	pastura	pastura	pastura	pastura	Agricultura	Agricultura
2) 1997 a 2000 (3 a 6 años)	pastura	Agricultura	Agricultura	Agricultura	Agricultura	Agricultura	Agricultura
3) 2000 a 2003 (6 a 9 años)	pastura	pastura	pastura	Agricultura	Agricultura	Agricultura	Agricultura
4) 2003 a 2006 (9 a 12 años)	pastura	Agricultura	Agricultura	Agricultura	Agricultura	Agricultura	Agricultura

A continuación, se presentan algunas consideraciones y aspectos preliminares según alternativas de análisis estadístico para la variación del COT. Para simplificar la presentación

de los análisis en las secciones 6.3.1 y 6.3.2. no se tomó en cuenta el factor fertilización con nitrógeno.

### 6.3.1 Análisis 1

Un objetivo puede ser comparar los efectos de los sistemas de cultivo sobre el COT para cada profundidad al finalizar el primer ciclo completo de todo el ensayo, es decir, al finalizar 12 años de ensayo. Para ello una alternativa es basar los análisis estadísticos en la variable diferencia de COT en el año 12 (final de ciclo completo) con el COT del año de inicio del ensayo. De cada parcela se obtiene un valor de diferencia. La relevancia de descontar del COT final el COT inicial no es sólo por la posible variación del COT inicial parcela a parcela, que puede incidir en la cantidad final de COT, sino también porque cada sistema de cultivo y la pastura están en parcelas que tuvieron diferentes sistemas de cultivos previos al ensayo actual. Esta última observación es la que se ve reflejada en los valores de COT (Tabla 6.8.)

Tabla 6.8. Promedios de COT ( $\text{Mg ha}^{-1}$ ) al final de la primera etapa del ensayo (1993, datos tomados en 1994) para cada una de las rotaciones y profundidades, y que luego continúa en el “Ensayo de Rotaciones Mixtas y Sistemas de Laboreo”.

Rotación 1976/1993(*)	Años pastura + agricultura	Sistema desde 1994	Profundidad (cm)		
			0-5	5-20	0-20
Tres ciclos de: 2 años pastura/4 años agricultura (papa, trigo, avena-papa, trigo)	6 + 12	Pastura continua	18.8	55.3	74.0
4 años pastura/4 años agricultura (papa, maíz, trigo, avena-girasol)/5 años pastura/5 años agricultura (papa, trigo, maíz, girasol, trigo)	9 + 9	50%LC	19.5	57.8	77.3
2 años agricultura (trigo, avena-girasol)/2 años pastura /7 años agricultura (papa, maíz, trigo, avena-girasol, trigo, avena-girasol, trigo)/2 años pastura /5 años agricultura (papa, trigo, papa, trigo, maíz)	4 + 14	50%SD	18.6	55.1	73.7
6 años agricultura (trigo, avena-girasol, papa, maíz, trigo, avena-girasol)/4 años pastura/8 años agricultura (papa, trigo, papa, trigo, maíz, girasol, trigo, girasol)	4 + 14	75%LC	18.7	55.1	73.8
2 años pastura/6 años agricultura (papa, maíz, trigo, avena-girasol, trigo, avena-girasol)/2 años pastura /8 años agricultura (papa, trigo, maíz, girasol, trigo, maíz, girasol, trigo)	4 + 14	75%SD	18.8	55.6	74.4
1 año agricultura (papa)/Siete ciclos de: 2 años agricultura (trigo, avena+vicia-papa)/1 año agricultura (trigo)/2 años pastura (avena+trébol)	2 + 16	100%LC	18.5	54.6	73.1
1 año agricultura (papa)/Ocho ciclos de: 2 años agricultura (trigo, avena-papa)/1 año agricultura (trigo)	0 + 18	100%SD	17.6	51.8	69.4

(\*) los sistemas de cultivo se completan con un laboreo convencional.

Al finalizar el período 1976/1993 a grandes rasgos se observa que (Tabla 6.8.):

1. Los mayores niveles de COT se lograron con la rotación mixta de mayor cantidad de años con pastura (9 de 18) y aportes de M (en 2 de los 9 años de agricultura).
2. Los menores niveles de COT se lograron con agricultura continua, y en este caso no hubo aporte de M.
3. En 1994 las parcelas asignadas a 50%LC son las que iniciaron con mayor nivel promedio de COT, y las asignadas a 100%SD con el menor nivel promedio, en todas las profundidades. Esto es importante a tener en cuenta cuando se analicen y comparen los sistemas de cultivo a partir del año 1994, año en el que se inician los siete sistemas de cultivo (Pastura, 50%LC, 50%SD, 75%LC, 75%SD, 100%LC y 100%SD).

De acuerdo con lo observado, un análisis adecuado para los efectos de los sistemas de cultivos sobre el COT final luego de un ciclo completo del ensayo, debe considerar los niveles iniciales del COT. Los análisis pueden realizarse con un modelo lineal general para la variable diferencia con supuesto de distribución normal y efectos de sistemas de cultivos y bloques como efectos fijos. Así sería un análisis para cada profundidad (0-5cm, 0-15cm, 0-20cm).

### **6.3.2 Análisis 2**

El objetivo podría ser comparar los efectos de los sistemas de cultivo sobre el COT durante y al finalizar el primer ciclo completo. Esto puede realizarse de varias maneras, con la variable COT directamente o con la variable diferencia de COT entre fin e inicio de ciertos períodos de años. Algunas de estas alternativas son:

- a) Análisis en base a la diferencia de COT en ciertos períodos de 3 años. Estos períodos son los “Tramos” indicados en la Tabla 6.7. Así, se consideran las determinaciones de COT en los años 1994 (inicio del ensayo), 1997 (fin “Tramo 1”), 2000 (fin “Tramo 2”), 2003 (fin “Tramo 3”) y 2006 (fin “Tramo 4”), ya que desde el inicio y cada tres años algunos sistemas de cultivo cambian de pastura a agricultura o viceversa. Para cada profundidad, Las diferencias de COT entre fin e inicio en cada tramo pueden analizarse simultáneamente en un modelo lineal mixto con supuesto de distribución

normal para la variable diferencia, con sistemas de cultivos, “tramos”, bloques, interacción sistemas de cultivos con “tramos” como efectos fijos y efectos de parcelas aleatorios. En este modelo mixto, las parcelas funcionan como unidades de agrupamiento de las diferencias para los cuatro tramos, al igual que en el modelo de mediciones repetidas en el tiempo, por eso tienen un análisis similar a éste. También pueden considerarse y evaluarse algunas estructuras de correlación entre errores.

- b) Análisis en base a los valores de la variable COT registrados todos los años. Análisis de regresiones segmentadas de COT sobre “años desde el inicio” (esta variable toma valores enteros desde 0 a 12), considerando los mismos tramos definidos en a) (Tabla 6.7.). Este análisis se ejemplifica con COT a 20 cm de profundidad. Se dan las estimaciones puntuales y por intervalos del 95% de confianza de las pendientes para cada tramo y sistema de cultivo (Tabla 6.9.). El análisis fue realizado utilizando el paquete *segmented* (Muggeo, 2003, 2008) del ambiente R. En la Figura 6.1. se muestran los datos de COT a 20 cm de profundidad en cada sistema de cultivo y la pastura continua con los ajustes de las regresiones segmentadas. Los datos mostrados aquí corresponden a datos de COT en parcelas con y sin nitrógeno (no hubo efecto de la fertilización nitrogenada, datos no mostrados).

Tabla 6.9. Salida del programa R para los análisis de regresiones segmentadas para COT. Estimaciones de pendientes (Est.), sus errores estándar (St. Err.), valores t para las pruebas de significancia de las pendientes (t value) y límites de los intervalos de confianza del 95% para las pendientes.

```

a) # TRAMO 1, de 0 a 3 años
##           Est. St.Err. t value CI(95%).l CI(95%).u
## Pastura  2.8430 0.6844  4.1540   1.4980   4.187
## 50LC     2.2540 0.7467  3.0180   0.7863   3.721
## 50SD     3.4430 0.7123  4.8330   2.0430   4.842
## 75LC     2.3970 0.6814  3.5180   1.0580   3.736
## 75SD     3.3300 0.6844  4.8660   1.9860   4.675
## 100LC    -0.1515 0.6814 -0.2224  -1.4900   1.187
## 100SD     2.7370 0.6814  4.0170   1.3980   4.076

b) # TRAMO 2, de 3 a 6 años
##           Est. St.Err. t value CI(95%).l CI(95%).u
## Pastura  0.7910 1.077  0.7342  -1.326   2.9080
## 50LC    -3.6050 1.077 -3.3460  -5.722  -1.4880
## 50SD    -2.2050 1.180 -1.8690  -4.524   0.1139
## 75LC    -2.2610 1.077 -2.0990  -4.378  -0.1445
## 75SD    -1.1120 1.077 -1.0320  -3.228   1.0050
## 100LC   0.9023 1.077  0.8375  -1.215   3.0190
## 100SD   0.3231 1.077  0.2999  -1.794   2.4400

c) # TRAMO 3, de 6 a 9 años
##           Est. St.Err. t value CI(95%).l CI(95%).u
## Pastura  0.67170 1.128 0.59520  -1.546   2.889
## 50LC     5.50800 1.180 4.66800   3.189   7.827
## 50SD     4.16000 1.249 3.33100   1.706   6.614
## 75LC     0.97340 1.077 0.90360  -1.144   3.090
## 75SD     0.39030 1.077 0.36230  -1.727   2.507
## 100LC    0.06978 1.077 0.06478  -2.047   2.187
## 100SD    0.21010 1.077 0.19500  -1.907   2.327

d) # TRAMO 4, de 9 a 12 años
##           Est. St.Err. t value CI(95%).l CI(95%).u
## Pastura  -2.608  1.077 -2.421  -4.725  -0.4908
## 50LC     -8.025  1.077 -7.449  -10.140 -5.9080
## 50SD     -5.763  1.077 -5.349  -7.880  -3.6460
## 75LC     -3.834  1.077 -3.558  -5.951  -1.7170
## 75SD     -2.840  1.077 -2.636  -4.957  -0.7231
## 100LC    -3.627  1.077 -3.367  -5.744  -1.5100
    
```

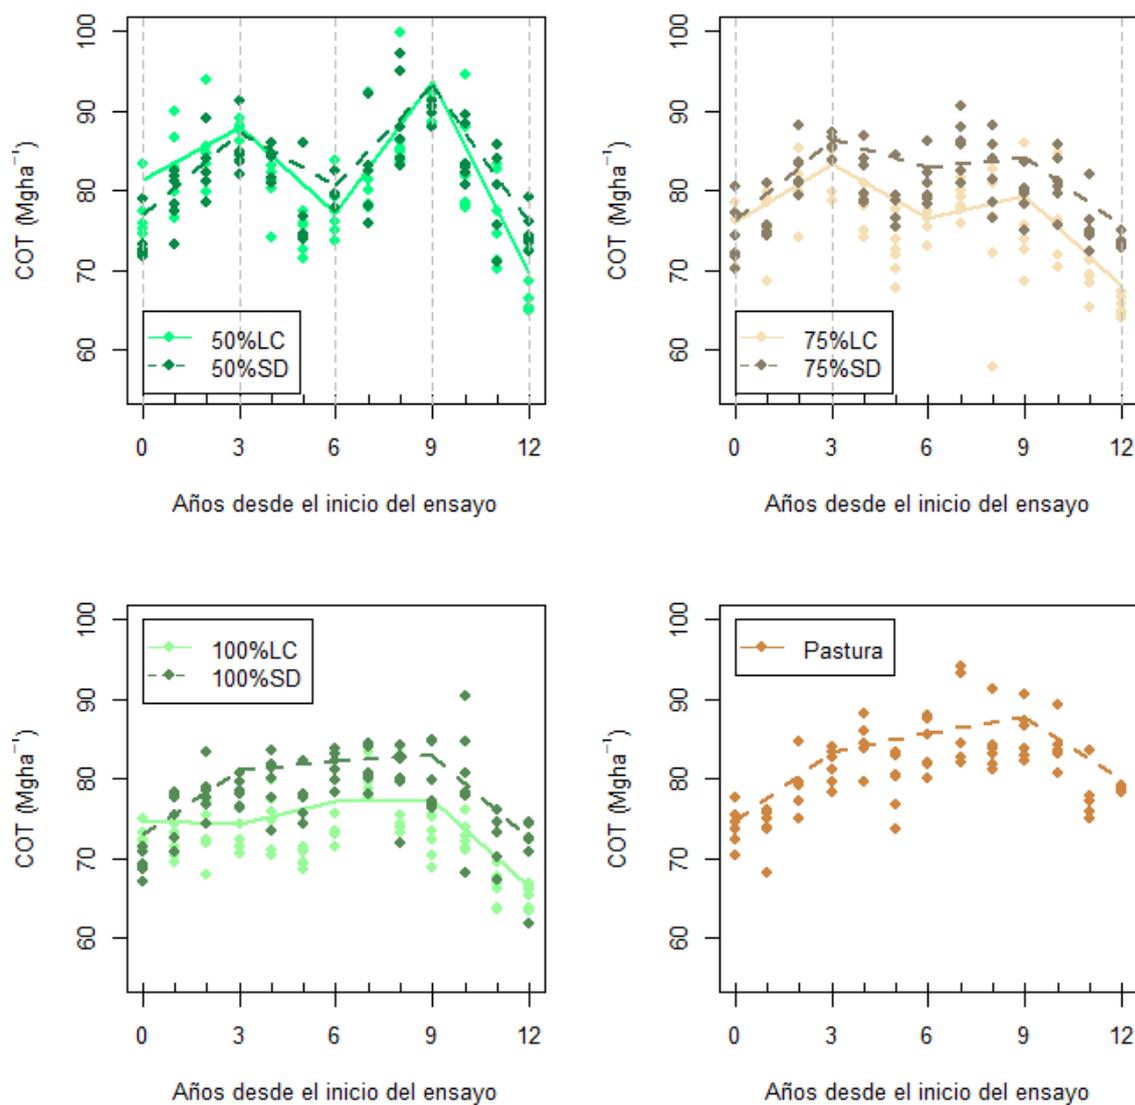


Fig. 6.3. Valores de carbono orgánico del suelo (COT) determinados a 20 cm de profundidad para cada sistema de cultivo en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo. Las líneas corresponden a los ajustes de las regresiones segmentadas. Sistemas de cultivos: pastura permanente (Pastura), agricultura continua por 3 años con LC seguida de pastura continua por 3 años (50%LC), agricultura continua por 3 años con SD seguida de pastura continua por 3 años (50%SD), agricultura continua por 9 años con LC seguida de pastura continua por 3 años (75%LC), agricultura continua por 9 años con SD seguida de pastura continua por 3 años (75%SD), agricultura permanente con LC (100%LC) y agricultura permanente con SD (100%SD). LC: laboreo convencional, SD: laboreo con siembra directa.

A continuación, se hacen algunos comentarios e interpretaciones desde los resultados obtenidos del análisis de regresión segmentada (Tabla 6.9.). En principio, es importante destacar que, en todos los casos, los períodos de años corresponden a determinados años en

particular y, en consecuencia, conllevan efectos ambientales propios de esos años. Esto ya fue observado en 6.2.4, de tal forma que las conclusiones tienen ese alcance.

En el Tramo de 0 a 3 años, todos los sistemas de cultivo, excepto los de agricultura continua (100%) están con pasturas (Tabla 6.7.). Al finalizar este período se están comparando los efectos de 3 años de pastura vs 3 años de agricultura (combinado con sistema de laboreo, LC o SD) (Tabla 6.7.). Al inicio de este período, el sistema de cultivo 50%LC se presenta con el mayor nivel de COT promedio (77.3 de 0-20 cm) y 100%SD con el menor (69.4 de 0-20cm), teniendo los demás sistemas, niveles promedio similares entre sí e intermedios a los dos mencionados (Tabla 6.8.). En cada uno de ellos incluso en agricultura continua bajo siembra directa (100%SD), el contenido de COT aumenta en el período (pendientes positivas, Tabla 6.9., Fig. 6.3.).

En el Tramo de 3 a 6 años todos los sistemas de cultivo, excepto pastura continua están con cultivo agrícola (Tabla 6.7.). Al finalizar esta etapa se comparan los efectos acumulados de 6 años de pastura (sistema Pastura), con 6 de agricultura (sistemas 100%Lc y 100%SD) y también con 3 años de pastura seguidos de 3 de agricultura (50%LC, 50%SD, 75%LC, 75%SD) (Tabla 6.7.). Asimismo, al finalizar la etapa de 3 a 6 años, los sistemas 50%LC y 50%SD, pasarán a pastura, pero los demás seguirán en agricultura. Desde el inicio (1994, año 0) hasta el final de esta etapa (6 años después del inicio, año 2000) los sistemas 50%LC y 75%LC (Tabla 6.7.) son indistinguibles (3 años pastura + 3 años agricultura) y, por lo tanto, no deberían diferir en los efectos del tratamiento sobre el COT. Lo mismo ocurre entre los sistemas 50%SD y 75%SD (Tabla 6.7.). El COT desciende para 50%LC y 75%LC (pendientes e intervalos de confianza en valores negativos, Tabla 6.9., Fig. 6.3.). El COT se mantiene para 50%SD y 75%SD (intervalos de confianza que incluyen al cero, Tabla 6.9., Fig. 6.3.).

En el Tramo de 6 a 9 años ya todos los sistemas son distintos entre sí (Tabla 6.7.). En esta etapa, los sistemas “del 50%” (Tabla 6.7.) están en pastura y son los únicos que muestran un aumento del COT (pendientes e intervalos de confianza en valores positivos, Tabla 6.9., Fig. 6.3.).

En el Tramo de 9 a 12 años, todos los sistemas, excepto pastura (Tabla 6.7.), están con cultivos agrícolas. Al finalizar este período y desde el inicio del ensayo, los sistemas “del 75%”

han acumulado 3 años de pastura seguidos de 9 años agricultura, los “del 100%” acumularon 12 años de agricultura, los “del 50%” acumularon 3 pastura + 3 agricultura + 3 pastura + 3 agricultura (Tabla 6.7.). Todos han mostrado descensos del COT (pendientes e intervalos de confianza en valores negativos, Tabla 6.9. Fig. 6.3.). Si se toma a “pastura” como una situación testigo, los “del 50%” son los que muestran mayor tasa de descenso respecto a esa situación.

### 6.3.3 Análisis 3

En este análisis se comparan los efectos de una determinada cantidad de años de agricultura y la misma cantidad de años de pastura. En este caso, primero se determina la cantidad de años de interés para el período de agricultura y de pastura. Por ejemplo, uno, dos, tres o más años donde sólo haya agricultura o pastura, según corresponda. Luego se definen las diferencias entre COT en el fin y el inicio de cada período en términos absolutos o relativos. En el caso de querer definirse diferencias relativas, éstas se calculan como el cociente entre la diferencia absoluta y el COT al inicio del período (de agricultura o pastura en la cantidad de años que se haya definido). Se espera que el análisis de esta nueva variable en relación con los sistemas de cultivo dé información de la variación de COT en función de la cantidad de años de agricultura o pastura y dependiendo del nivel de COT de partida. Esto sería particularmente así en relación con los efectos de los laboreos y también al valor del COT al inicio del período considerado bajo cada situación (agricultura o pastura). Para el caso de variables como el COT, la propuesta es tener en cuenta la condición previa (historia) de cada parcela a través del nivel de COT al inicio de un cierto período. Consideraciones similares pueden hacerse para otras variables de suelo.

Esta propuesta de análisis se ejemplifica tomando períodos de 3 años de agricultura y 3 años de pastura. Así, para el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo podría concluirse cómo pueden ser afectados los niveles de COT en cada profundidad por 3 años de agricultura continua o 3 años de pastura continua, dependiendo del nivel inicial de COT. De todas maneras, los datos disponibles para realizar este análisis están restringidos a ciertos años. Por ello, para conclusiones más generales debería contarse con datos obtenidos a partir de esquemas experimentales como el mostrado en la Tabla 6.6.

El análisis se complementa con gráficos como el de la Figura 6.4. que describe los cambios porcentuales del COT a 0-20 cm de profundidad en períodos de 3 años de agricultura continua o de pastura continua en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo, según tipo de laboreo para los tratamientos con agricultura y el nivel inicial de COT en cada período de 3 años. En el gráfico de la Fig. 6.4. se utilizan suavizados para ayudar a captar el patrón medio de las relaciones. Así, se observa que, en los 0-20 cm de profundidad, los menores valores de COT inicial se asocian con ganancias en COT luego de 3 años de pastura continua o agricultura continua, pero sobre todo con pastura. Por otro lado, a mayores contenidos de COT inicial, los cambios en COT tienden a ser pérdidas, con diferentes umbrales para cada situación (pastura, SD, o LC). En un extremo, para valores bajos de COT inicial, a igual valor de COT inicial se gana más COT con 3 años de pastura que con 3 años de agricultura con SD y, asimismo, con este sistema de laboreo se gana COT más que con 3 años de agricultura con LC. En el otro extremo, para altos valores de COT inicial, a igual valor de COT inicial se pierde menos COT con 3 años de pastura que con 3 años de agricultura con SD y, de mismo modo, con este sistema de laboreo se pierde menos COT que con 3 años de agricultura con LC (Fig. 6.4.).

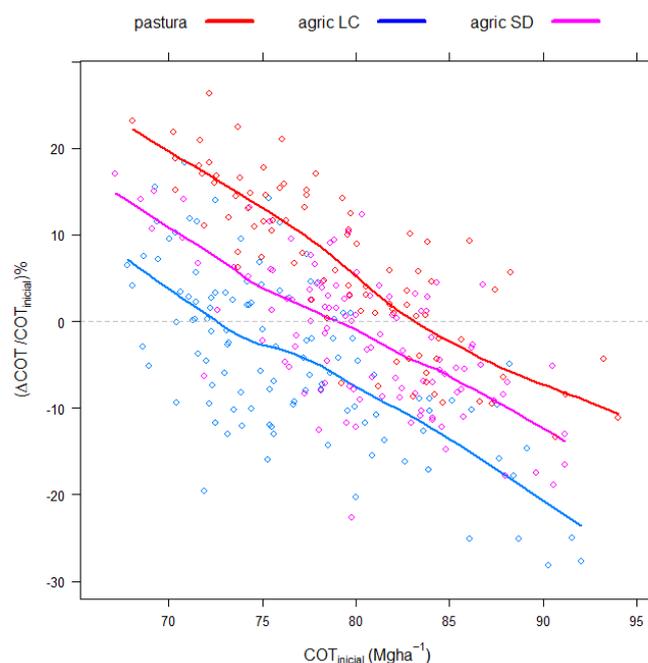


Fig. 6.4. Cambios porcentuales del COT a 0-20 cm de profundidad en períodos de 3 años de agricultura continua o de pastura continua en el ensayo de rotaciones mixtas, según tipo de laboreo (LC: laboreo convencional, SD: laboreo con siembra directa) para los de agricultura y nivel inicial de COT en el período de 3 años.

Algunas dudas que pueden surgir de lo que se muestra en la Fig. 6.4. son las siguientes: ¿de qué sistemas de cultivo provienen cada uno de los puntos graficados?, ¿es esta información importante o necesaria, o con la sola consideración del COT inicial ya se tiene la información relevante? Así, con la Fig. 6.5. se intenta brindar información para discutir, descriptivamente, sobre las cuestiones planteadas. Por ejemplo, puede observarse que, luego de los períodos de 3 años de agricultura, en los sistemas “del 50%” (Tabla 6.7.), hay pérdidas de COT, siendo éstas más marcadas cuanto mayor sea el COT inicial del período. Para estos casos, sistemas 50%LC y 50%SD, los datos representados corresponden a períodos de agricultura que son precedidos por pastura por definición de los sistemas de cultivo (Tabla 6.7.).

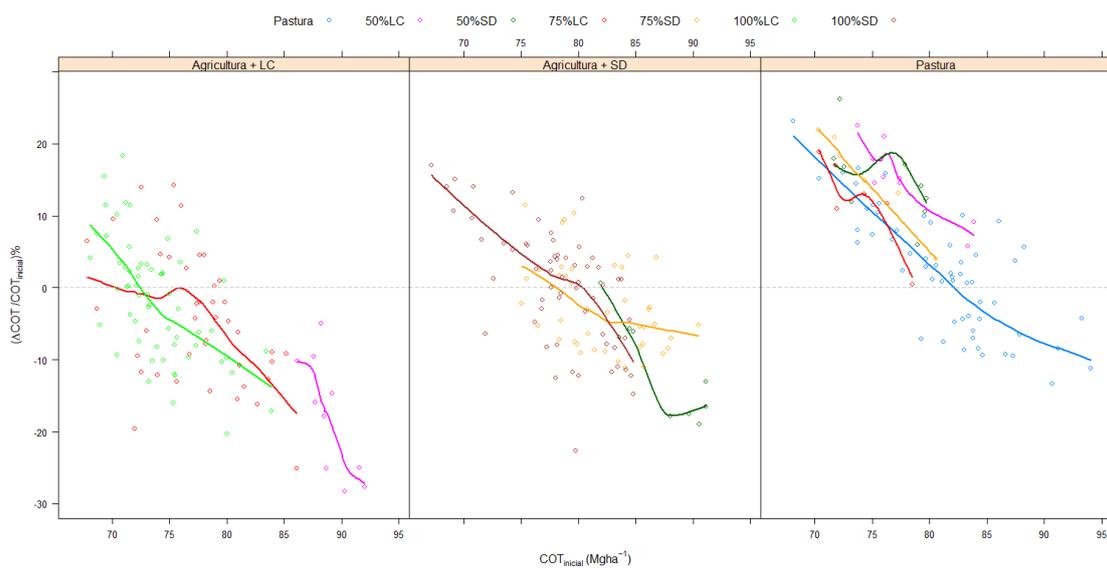


Fig. 6.5. Cambios porcentuales del COT a 0-20 cm de profundidad en períodos de 3 años de agricultura continua o de pastura continua ( $(\Delta COT / COT_{inicial})\%$ ) en el Ensayo de Rotaciones Mixtas y Sistemas de Laboreo, según tipo de laboreo para los tratamientos que incluyen agricultura y nivel inicial de COT en el período de 3 años ( $COT_{inicial} (Mg\ ha^{-1})$ ). En cada caso se distingue el sistema de cultivo al cual corresponde el período observado y se ajusta un suavizado. Sistemas de cultivos: pastura permanente (Pastura), agricultura por 3 años con LC seguida de pastura por 3 años (50%LC), agricultura por 3 años con SD seguida de pastura por 3 años (50%SD), agricultura por 9 años con LC seguida de pastura por 3 años (75%LC), agricultura por 9 años con SD seguida de pastura por 3 años (75%SD), agricultura continua con LC (100%LC) y agricultura continua con SD (100%SD). En el panel “Agricultura+LC” se grafican los datos correspondientes a períodos de 3 años con agricultura y LC, en el panel “Agricultura+SD” se grafican los datos correspondientes a períodos de 3 años con agricultura y SD, en el panel “Pastura” se grafican los datos correspondientes a períodos de 3 años de pastura. LC: laboreo convencional, SD: laboreo con siembra directa.

#### **6.4 Síntesis del capítulo**

En este capítulo se analizaron los diseños de los ELDA del Sudeste Bonaerense. Todos ellos comprenden rotaciones de cultivos en sus sistemas de cultivos. En el Ensayo de Agricultura Continua (sección 6.2.1) se probaron 16 secuencias cada una de tres fases (cultivos), pero correspondían a 13 rotaciones básicas (una con sólo trigo). Cada rotación básica no estaba representada por sus tres secuencias posibles, es decir no estaban todas las fases de cada rotación un mismo año. De haberse dado todas las fases todos los años se tendrían que haber considerado 37 secuencias, aunque esto incrementaría notablemente el requerimiento de recursos y, tal vez, tornara inmanejable o difícil de controlar las variaciones debidas a otros factores. Se dieron alternativas de diseño para este caso. También se observa que, si se tuvieran todas las fases en un mismo año (todas las secuencias probadas) estarían implícitos los inicios escalonados (Tabla 6.5.), y sería de esperar que los efectos de las diferencias en los primeros años de los ciclos en el ensayo no impactaran a largo plazo.

En el Ensayo de Secuencias de Cultivos y Sistemas de Laboreo (sección 6.2.2.) y Ensayo de Sistemas de Laboreo (sección 6.2.3.) se prueban tres y una, respectivamente, rotaciones básicas de tres cultivos. El primero responde a un diseño “fases-confundidas” y el segundo a un diseño básico, en ambos casos según la clasificación de Patterson (1964). Para el Ensayo de Secuencias de Cultivos y Sistemas de Laboreo se muestra cómo sería un diseño básico utilizando el mismo recurso que se utilizó para el ensayo. En ambos, todas las fases están presentes todos los años y, por lo tanto, el inicio escalonado está implícito en cada uno. En cambio, en el Ensayo de Rotaciones Mixtas y Sistemas de Cultivos (sección 6.2.4.) la estructura de las rotaciones (agricultura-pastura) hace que los inicios escalonados sean importantes. Así, cada período de pastura o agricultura no queda asociado a un período de años fijo. Para este caso también se mostró y discutió un esquema ideal para evitar la confusión de efectos de rotaciones con series de años.

Se bosquejaron alternativas de análisis estadísticos para la variable COT, basadas en la generación de diferencias de COT entre fin e inicio de ciertos períodos de años.



## 7. CAPÍTULO 7. IMPLEMENTACIÓN EN R

En este capítulo se da una orientación para la sistematización de los análisis de los datos recolectados en los ELDA utilizando el ambiente computacional R (R Core Team, 2016). En particular se dan las sentencias R más relevantes utilizadas en los capítulos 4 y 5 y que servirán de base para desarrollar rutinas que puedan ser aplicadas a situaciones similares.

### 7.1 Guía para el análisis de datos provenientes de ELDA

Una guía metodológica para el análisis estadístico de algunas situaciones frecuentes en la ciencia del suelo y/o en el estudio del comportamiento de los cultivos puede ser de ayuda a los investigadores, acompañada de una herramienta operatoria. El desarrollo de una plataforma computacional orientada a una operatividad simplificada de los análisis de los ELDA en el ambiente R es una posibilidad. Dicha plataforma puede lograrse a través del desarrollo de un paquete o un conjunto de paquetes en R e incluso incorporarle una interface al usuario con sistema de menú. La plataforma podría incluir en principio una serie de preguntas que lleven a los modelos de análisis en forma automática o a opciones de algunos modelos entre los cuales elegir.

Dentro de las primeras decisiones que se podrían tomar, ya con los datos importados y guiados por el programa, estarían:

- ¿Cuál o cuáles son las variables respuesta a analizar (tanto continuas como discretas)? Si son varias considerar una por vez, salvo que se busque relacionarlas.
  - ¿Quiere analizarse la variable tal cual está registrada? ¿Se conoce la distribución de probabilidad o puede suponerse alguna? ¿Cuál? (elegir entre opciones)
  - ¿Quiere definirse alguna variable diferencia en base a la variable seleccionada? ¿o alguna transformación de la variable?
- ¿Cuáles son los factores de tratamientos? ¿Cuáles sus niveles? ¿intervendrán todos en el análisis? ¿Sólo algunos?
- ¿Cuál es la estructura del diseño? (p.e. bloques, parcelas divididas, bloques divididos)
- ¿Hay mediciones repetidas en el tiempo? ¿para qué variables respuesta?
- ¿Cuál es el período que se quiere analizar?

- ¿Se quieren realizar análisis independientes para algunos momentos (años o períodos cortos)? ¿Cuáles?
- ¿Se quiere analizar períodos de mayor duración? Definir inicio y final del período de interés
- ¿Cómo quiere considerarse el tiempo?
  - Como variable cuantitativa
  - Como variable categórica

Las diferentes combinaciones de respuestas a estas preguntas llevarían a plantearse diferentes análisis. Los que pueden incluir desde modelos lineales generales hasta modelos aditivos generalizados para los parámetros de localización, escala y forma (GAMLSS). Modelos lineales generalizados, modelos lineales mixtos, modelos lineales generalizados mixtos, modelos aditivos y modelos aditivos generalizados también pueden ser incluidos, aunque no todos estos hayan sido ejemplificados en este trabajo de tesis, una plataforma completa debería ir incorporando estas y otras opciones gradualmente. También debería incluirse etapas descriptivas y exploratorias de los datos.

A continuación, se detallan las sentencias de programación más relevantes utilizadas en los capítulos 4 y 5. Las mismas utilizan funciones y paquetes de R preestablecidos y también programación propia y adaptaciones a los casos particulares de este trabajo de tesis. Las sentencias que se muestran en este capítulo y otras que también han sido utilizadas, como en el capítulo 6, servirán de base para la programación de rutinas que puedan ser aplicadas a situaciones similares.

## **7.2 Sentencias R utilizadas en el capítulo 4**

El archivo de datos Excel con los datos del ensayo de Agramunt fue importado a R conservando la mayoría de los nombres originales de las variables incluso el conjunto de datos en R se denominó igual que el archivo Excel (PR.AG.V2). Las variables en PR.AG.V2 inicialmente fueron: YEAR (campaña agrícola), NMT (número de muestreo), DATE (fecha de muestreo), BLOC (bloque), DEPTH (profundidad), TIL (sistema de laboreo), NNITRICO (Contenido de nitrógeno mineral en una profundidad), NNITRICOTOT (Contenido total de NNITRICO sumando las 3 profundidades). Luego se fueron incorporando otras variables y creando otros

conjuntos de datos a partir de aquel a medida que se iban necesitando. El número de observaciones importadas fueron de 5760.

### 7.2.1 Adecuando el conjunto de datos

```
PR.AG.V2$bloque<-factor(PR.AG.V2$BLOC) # crea bloque como factor
PR.AG.V2$laboreo<-factor(PR.AG.V2$TIL) # crea laboreo como factor
PR.AG.V2$muestreo<-factor(PR.AG.V2$NMT) # crea muestreo como factor
PR.AG.V2$fecha<-as.Date(PR.AG.V2$DATE,"%d/%m/%Y") # convierte el factor "DATE" en
variable "fecha" con formato de fecha año-mes-día
```

### 7.2.2 Sentencias usadas para la Sección 4.1.

```
library(lattice)

# Para Figura 4.1.
win.graph()
xyplot(NNITRICOtot~fecha|bloque+laboreo,group=subm,pch=16,
  par.settings = list(strip.background=list(col=c("white",gray(0.9)))),
  par.strip.text=list(font=2),
  scales=list(x=list(at=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    labels=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    tck=c(1,0),
    cex=0.7,
    rot=90,alternating = 1),
    y=list(alternating=1,tck=c(1,0))),
  panel=function(x,y,...){panel.xyplot(x,y,...);
    panel.average(x,y,mean,lty=1,col=gray(0.5),lwd=3,horizontal=FALSE,...);
    panel.loess(x,y,lwd=3,col="orange",span = 2/5, degree = 1,...);
    panel.abline(h=mean(y),lty=3,col="grey",lwd=3,...)},
  ylab=expression(paste("CN ",("kg " * ha^-1))),
  xlab="Fecha de muestreo",
  data=PR.AG.V2, subset=NNITRICOtot>1)
```

```
# Para Figura 4.2.
win.graph()
xyplot(NNITRICO~fecha|bloque+laboreo,group=subm,pch=16,
  par.settings = list(strip.background=list(col=c("white",gray(0.9)))),
  par.strip.text=list(font=2),
  scales=list(x=list(at=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    labels=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    tck=c(1,0),
    cex=0.7,
    rot=90,alternating = 1),
    y=list(alternating=1,tck=c(1,0))),
  panel=function(x,y,...){panel.xyplot(x,y,...);
    panel.average(x,y,mean,lty=1,col=gray(0.5),lwd=3,horizontal=FALSE,...);
    panel.loess(x,y,lwd=3,col="orange",span = 2/5, degree = 1,...);
    panel.abline(h=mean(y),lty=3,col="grey",lwd=3,...)},
  ylab=expression(paste("CN ",("kg " * ha^-1))),
  xlab="Fecha de muestreo",
  data=PR.AG.V2, subset=DEPTH==1&NNITRICO>1)
```

```

# Para Figura 4.3.
win.graph()
xyplot(NNITRICO~fecha|bloque+laboreo,group=subm,pch=16,
  par.settings = list(strip.background=list(col=c("white",gray(0.9)))),
  par.strip.text=list(font=2),
  scales=list(x=list(at=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    labels=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    tck=c(1,0),
    cex=0.7,
    rot=90,alternating = 1),
    y=list(alternating=1,tck=c(1,0))),
  panel=function(x,y,...){panel.xyplot(x,y,...);
    panel.average(x,y,mean,lty=1,col=gray(0.5),lwd=3,horizontal=FALSE,...);
    panel.loess(x,y,lwd=3,col="orange",span = 2/5, degree = 1,...);
    panel.abline(h=mean(y),lty=3,col="grey",lwd=3,...)},
  ylab=expression(paste("CN ",("kg " * ha^-1))),
  xlab="Fecha de muestreo",
  data=PR.AG.V2, subset=DEPTH==2&NNITRICO>1)

```

```

# Para Figura 4.4.
win.graph()
xyplot(NNITRICO~fecha|bloque+laboreo,group=subm,pch=16,
  par.settings = list(strip.background=list(col=c("white",gray(0.9)))),
  par.strip.text=list(font=2),
  scales=list(x=list(at=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    labels=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
    tck=c(1,0),
    cex=0.7,
    rot=90,alternating = 1),
    y=list(alternating=1,tck=c(1,0))),
  panel=function(x,y,...){panel.xyplot(x,y,...);
    panel.average(x,y,mean,lty=1,col=gray(0.5),lwd=3,horizontal=FALSE,...);
    panel.loess(x,y,lwd=3,col="orange",span = 2/5, degree = 1,...);
    panel.abline(h=mean(y),lty=3,col="grey",lwd=3,...)},
  ylab=expression(paste("CN ",("kg " * ha^-1))),
  xlab="Fecha de muestreo",
  data=PR.AG.V2, subset=DEPTH==3&NNITRICO>1)

```

## 7.2.3 Sentencias usadas para la Sección 4.2.

### 7.2.3.1 Sentencias usadas para la Sección 4.2.1.

```

# Ajuste del modelo 0.1 - exploratorio (lm.Ntot es modelo 0.1)
lm.Ntot<-lm(NNITRICOtot~bloque+laboreo*DATE,
  data=PR.AG.V2, subset=YEAR!="1996-97"&DATE!="18/10/1995"&NNITRICOtot>1
)

```

```

# Para Figura 4.5.a.
win.graph()
plot(resid(lm.Ntot)~fitted(lm.Ntot),xlab=expression(paste("valores predichos de CN
",("kg " * ha^-1))), ylab=expression(paste("residuos ",("kg " * ha^-1))))

```

```

# Para Figura 4.5.b.
win.graph()
plot(rstandard(lm.Ntot)~fitted(lm.Ntot),xlab=expression(paste("valores predichos d

```

```
e CN ", ("kg " * ha^-1))), ylab="residuos estandarizados")
abline(h=c(-3,3), lty=2, col="grey")

# Para Figura 4.6.
win.graph()
dd<-subset(PR.AG.V2, YEAR!="1996-97"&DATE!="18/10/1995"&NNITRICOtot>1)
boxplot(rstandard(lm.Ntot)~dd$laboreo,
        boxwex = 0.3, at=seq(1,2.5,0.5), xlim=c(0.5,3),
        ylab="residuos estandarizados",
        xlab="Laboreo")
abline(h=c(-3,3), lty=2, col="grey")

# Para Figura 4.7.a. y b.
library(fitdistrplus)
dpn.Ntot <- fitdist(resid(lm.Ntot), "norm")
win.graph()
plot(dpn.Ntot)
```

### 7.2.3.2 Sentencias usadas para la Sección 4.2.2.

```
# Ajuste del modelo 0.2 - exploratorio (lm.Ntot.b es modelo 0.2)
lm.Ntot.b<-lm(NNITRICOtot~bloque*laboreo*DATE,
             data=PR.AG.V2, subset=YEAR!="1996-97"&DATE!="18/10/1995"&NNITRICOtot>1
)

# Para Figura 4.8.a.
win.graph()
plot(resid(lm.Ntot.b)~fitted(lm.Ntot.b), xlab=expression(paste("valores predichos d
e CN ", ("kg " * ha^-1))), ylab=expression(paste("residuos ", ("kg " * ha^-1))))

# Para Figura 4.8.b.
win.graph()
plot(rstandard(lm.Ntot.b)~fitted(lm.Ntot.b), xlab=expression(paste("valores predich
os de CN ", ("kg " * ha^-1))), ylab="residuos estandarizados")
abline(h=c(-3,3), lty=2, col="grey")

# Para Figura 4.9.
win.graph()
dd<-subset(PR.AG.V2, YEAR!="1996-97"&DATE!="18/10/1995"&NNITRICOtot>1)
boxplot(rstandard(lm.Ntot.b)~dd$laboreo,
        boxwex = 0.3, at=seq(1,2.5,0.5), xlim=c(0.5,3),
        ylab="residuos estandarizados",
        xlab="Laboreo")
abline(h=c(-3,3), lty=2, col="grey")

# Para Figura 4.10.a. y b.
library(fitdistrplus)
dpn.Ntot.b <- fitdist(resid(lm.Ntot.b), "norm")
win.graph()
plot(dpn.Ntot.b)
```

## 7.2.4 Sentencias usadas para la Sección 4.3.

### 7.2.4.1 Sentencias usadas para la Sección 4.3.1

#### 7.2.4.1.1 Sentencias usadas para la Sección 4.3.1.1.

```
# Adecuación del conjunto de datos
PR.AG.V2$bqL<-with(PR.AG.V2,bloque:laboreo)
PR.AG.V2$FECHA<-as.factor(PR.AG.V2$fecha)
PR.AG.V2$bqL.F<-with(PR.AG.V2,bqL:FECHA)
PR.AG.V2.sr0<-subset(PR.AG.V2,NNITRICO>1) # este archivo incluye al PR.AG.V2.sr
PR.AG.V2.sr<-subset(PR.AG.V2,NNITRICOtot>1)

# Ajuste del modelo mm1.LogCN.cs (lme.LogNtot es mm1.LogCN.cs)
library(nlme)
lme.logNtot<-lme(log(NNITRICOtot)~bloque+laboreo*FECHA,
                random=~1|bqL/bqL.F, #o random=~1|bqL/FECHA,
                data=PR.AG.V2.sr,na.action=na.omit)

# Para Figura 4.11.a
win.graph()
plot(lme.logNtot,
     par.settings = list(strip.background=list(col="white")),
     par.strip.text=list(font=2),
     xlab="valores ajustados",
     ylab="residuales estandarizados",
     scales=list(x=list(alternating = 1),
                y=list(alternating=1,tck=c(1,0))),
     form = resid(., type = "p") ~ fitted(.)|laboreo)

# Para Figura 4.11.b.
win.graph()
qqnorm(lme.logNtot,
       par.settings = list(strip.background=list(col="white")),
       par.strip.text=list(font=2),
       ylab="cuantiles normales estandar",
       xlab="residuales estandarizados",
       scales=list(x=list(alternating = 1),
                  y=list(alternating=1,tck=c(1,0))),
       ~resid(., type = "p") |laboreo)

# Para Figuras 4.12. a., b., c. y d.
blup.parcela<-ranef(lme.logNtot)[["bqL"]][[1]] # a nivel "parcela" (bloque:laboreo
)
# o ranef(lme.logNtot, level = 1)
library(fitdistrplus)
win.graph()
plot(fitdist(blup.parcela,"norm"))

# Para Figuras 4.13. a., b., c. y d.
library(fitdistrplus)
blup.subparcela<-ranef(lme.logNtot)[["bqL.F"]][[1]]
win.graph()
plot(fitdist(blup.subparcela,"norm")) # a nivel "subparcela" bloque:laboreo:FECHA

# Para Figura 4.14.
datos.subp<-data.frame(blup=ranef(lme.logNtot, level = 2)[["(Intercept)"]],
```

```

laboreo=laboreo) # crear data.frame
win.graph()
with(datos.subp,plot(blup~as.factor(laboreo),
                    boxwex = 0.3,at=seq(2.5,1,-0.5),xlim=c(0.5,3),
                    xlab="Laboreo",ylab="Blups de los efectos de subparcelas"))

# Pruebas F para efectos fijos y Estimación de varianzas
anova(lme.logNtot)
VarCorr(lme.logNtot)

```

#### 7.2.4.1.2 Sentencias usadas para la Sección 4.3.1.2.

```

# Creación del archivo NitricoTotal.prom2 con Los promedios de submuestras
NitricoTotal.prom<-with(PR.AG.V2.sr0,
                      aggregate(list(NNITRICOtot=NNITRICOtot,fecha=fecha,dias.de.corri
do=dias.de.corrido),
                              list(bloque=bloque,laboreo=laboreo,DATE=DATE),mean,na.
rm=TRUE))
NitricoTotal.prom$bqL<-with(NitricoTotal.prom,bloque:laboreo)
NitricoTotal.prom$FECHA<-as.factor(NitricoTotal.prom$fecha)

mes<-strftime(NitricoTotal.prom$fecha, "%m")
NitricoTotal.prom$estacion<-ordered(ifelse(mes=="01"|mes=="02","invierno",ifelse(m
es=="06"|mes=="07","verano","otoño")), c("invierno","verano","otoño"))

NitricoTotal.prom2<-with(NitricoTotal.prom,NitricoTotal.prom[order(bloque,laboreo,
fecha),]) # ordenado por fecha dentro de laboreo y bloque

# Ajuste del modelo mm1.LogCN (lme.LogNtot.pro es mm1.LogCN)
library(nlme)
lme.logNtot.pro<-lme(log(NNITRICOtot)~bloque+laboreo*FECHA,
                    random=~1|bqL,
                    data=NitricoTotal.prom2,na.action=na.omit)

# Para Figura 4.15.a.
win.graph()
plot(lme.logNtot.pro,
     par.settings = list(strip.background=list(col="white")),
     par.strip.text=list(font=2),
     xlab="valores ajustados",
     ylab="residuales estandarizados",
     scales=list(x=list(alternating = 1),
                 y=list(at=seq(-3,3,1), labels=seq(-3,3,1),alternating=1,tck=c(1,0
))),
     abline=-3,lty=2,col.line="grey",
     form = resid(., type = "p") ~ fitted(.)|laboreo)

# Para Figura 4.15.b.
win.graph()
qqnorm(lme.logNtot.pro,
       par.settings = list(strip.background=list(col="white")),
       par.strip.text=list(font=2),
       ylab="cuantiles normales estandar",
       xlab="residuales estandarizados",
       scales=list(x=list(alternating = 1),
                   y=list(alternating=1,tck=c(1,0))),
       abline=c(0,1),lty=2,col.line="grey",
       ~resid(., type = "p") |laboreo)

```

## 7.2.4.2 Sentencias usadas para la Sección 4.3.2

### 7.2.4.2.1 Adecuación del conjunto de datos

```
# creación de variable "estacion"
mes<-strftime(PR.AG.V2$fecha, "%m")
PR.AG.V2$estacion<-ordered(iffelse(mes=="01"|mes=="02", "invierno",
                                   iffelse(mes=="06"|mes=="07", "verano",
                                           "otoño")), c("invierno", "verano", "otoño")
)
```

### 7.2.4.2.2 Sentencias usadas para la Sección 4.3.2.1.

```
# Ajuste de modelo mm2.LogCN.cs (lme2.logNtot es mm2.LogCN.cs)
library(nlme)
lme2.logNtot<-update(lme.logNtot, weights=varIdent(form=~1|laboreo))

# Para Figura 4.16.a.
win.graph()
plot(lme2.logNtot,
     par.settings = list(strip.background=list(col="white")),
     par.strip.text=list(font=2),
     xlab="valores ajustados",
     ylab="residuales estandarizados",
     scales=list(x=list(alternating = 1),
                 y=list(alternating=1,tck=c(1,0))),
     abline=-3,lty=2,col.line="grey",
     form = resid(., type = "p") ~ fitted(.)|laboreo)

# Para Figura 4.16.b.
win.graph()
qqnorm(lme2.logNtot,
       par.settings = list(strip.background=list(col="white")),
       par.strip.text=list(font=2),
       ylab="cuantiles normales estandar",
       xlab="residuales estandarizados",
       scales=list(x=list(alternating = 1),
                   y=list(alternating=1,tck=c(1,0))),
       abline=c(0,1),lty=2,col.line="grey",
       ~resid(., type = "p") |laboreo)

# Pruebas F para efectos fijos y Estimación de varianzas
anova(lme2.logNtot)
VarCorr(lme2.logNtot)

# Ajuste del modelo mm2.LogCN.cs.B (lme3.logNtot es mm2.LogCN.cs.B)
lme3.logNtot<-update(lme2.logNtot, random=list(bqL=~1,bqL.F=pdDiag(~laboreo-1)))
anova(lme3.logNtot, lme2.logNtot)
```

### 7.2.4.2.3 Sentencias usadas para la Sección 4.3.2.2.

```
# Ajuste de modelo mm2.LogCN (lme2a.LogNtot.pro es mm2.LogCN)
library(nlme)
lme2a.logNtot.pro<-update(lme.logNtot.pro,weights=varIdent(form=~1|laboreo))
anova(lme2a.logNtot.pro,lme.logNtot.pro) # p=0.0078

# Para Figura 4.17.a.
win.graph()
plot(lme2a.logNtot.pro,
     par.settings = list(strip.background=list(col="white")),
     par.strip.text=list(font=2),
     xlab="valores ajustados",
     ylab="residuales estandarizados",
     scales=list(x=list(alternating = 1),
                 y=list(alternating=1,tck=c(1,0))),
     abline=-3,lty=2,col.line="grey",
     form = resid(., type = "p") ~ fitted(.)|laboreo)

# Para Figura 4.17.b.
win.graph()
qqnorm(lme2a.logNtot.pro,
       par.settings = list(strip.background=list(col="white")),
       par.strip.text=list(font=2),
       ylab="cuantiles normales estandar",
       xlab="residuales estandarizados",
       scales=list(x=list(alternating = 1),
                   y=list(alternating=1,tck=c(1,0))),
       abline=c(0,1),lty=2,col.line="grey",
       ~resid(., type = "p") |laboreo)
```

### 7.2.4.3 Sentencias usadas para la Sección 4.3.3

```
# Para Figura 4.18.
library(lattice)
win.graph()
xyplot(log(NNITRICOtot)~fecha|laboreo,group=bloque,type="b",pch=16,
       auto.key=list(space="top", columns=4,
                     title="bloques", cex.title=1,
                     lines=TRUE, points=FALSE),
       par.settings = list(strip.background=list(col=c("white",gray(0.9))),
                           superpose.symbol = list(
                             col = c("orange","springgreen2","springgreen3","springgreen4"), fill
= c("orange", "springgreen2", "springgreen3", "springgreen4")),
                           superpose.line = list(col = c("orange", "springgreen2",
"springgreen3", "springgreen4"))),
       par.strip.text=list(font=2),
       scales=list(x=list(at=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
                           labels=unique(PR.AG.V2$fecha)[c(1,seq(3,60,by=3))],
                           tck=c(1,0),
                           cex=0.7,
                           rot=90,alternating = 1),
                 y=list(alternating=1,tck=c(1,0))),
       panel=function(x,y,...){panel.xyplot(x,y,...);
       panel.loess(x,y,lwd=3,col=gray(0.2),...);
```

```

    panel.abline(h=mean(y,na.rm=TRUE),lty=2,col="grey",lwd=3,...)},
    main=" ",layout=c(2,2),ylab=expression(paste("log( CN ",("kg "*ha^-1),")"))
  ,
  xlab="Fecha de muestreo",
  data=with(NitricoTotal.prom,NitricoTotal.prom[order(laboreo,bloque,fecha),]
))

```

#### 7.2.4.4 Sentencias usadas para la Sección 4.3.4

##### 7.2.4.4.1 Adecuación del conjunto de datos

```

# Agrego una escala de tiempo continua

# Primero consigo la variable numérica para el tiempo
dias<-with(PR.AG.V2,as.integer(format(fecha,"%j"))) # para años bisiestos 1:366
dias2<-with(PR.AG.V2,as.POSIXlt(fecha)$yday) # para años NO bisiestos
anio<-strftime(PR.AG.V2$fecha, "%Y")

PR.AG.V2$dias<-with(PR.AG.V2,ifelse(strftime(PR.AG.V2$fecha, "%Y")%in%c("1996","20
00","2004","2008","2012"),
                                as.integer(format(fecha,"%j")),
                                as.POSIXlt(fecha)$yday))

library(chron)
PR.AG.V2$dias.de.corrido<-with(PR.AG.V2,
                                julian(as.numeric(strftime(fecha, "%m")),
                                        as.numeric(strftime(fecha, "%d")),
                                        as.numeric(strftime(fecha, "%Y"))),
                                origin.= c(month = 1, day = 1, year = 19
95)))

```

##### 7.2.4.4.2 Adaptación de función variogram

```

mi.variog<-Variogram(lme2a.logNtot.pro, form = ~ dias.de.corrido|bqL,
                    resType = "pearson",collapse = "none",
                    robust=TRUE)
# para obtener el semivariograma para cada distancia (sin agrupar distancias como
hace
# "Variogram.lme" por defecto, hago lo siguiente:)
variograma<-mi.variog
n<-length(unique(variograma$dist))
v.dist.variog<-data.frame(dist=rep(0,n),variog=rep(0,n))
j=1
for(i in sort(unique(variograma$dist))){
  variog<-mean(variograma[variograma$dist==i,"variog"])
  v.dist.variog[j,"dist"]<-i
  v.dist.variog[j,"variog"]<-variog
  j=j+1
}

# Para Figura 4.19.
win.graph()
plot(Variogram(lme2a.logNtot.pro, form = ~ dias.de.corrido|bqL,
              resType = "pearson",robust=TRUE),
      ylim=c(0,3),pch=16,cex=1.5,lwd=3,xlab="Distancia en días",ylab="Semivariogram

```

```
a")
with(v.dist.variog,points(dist,variog,cex=1,col=grey(0.5)))
```

#### 7.2.4.4.3 Aplicación de función variogram y ajuste

```
# Ajuste del modelo mm3.LogcN (prueba.corRatio es mm3.LogcN)
prueba.corRatio<-update(lme2a.logNtot.pro,
  corr = corRatio(c(5000,0.4),
    form = ~ dias.de.corrido | bqL,nugget=TRUE),
  na.action=na.omit)

# Para Figura 4.21.
win.graph()
plot( Variogram(prueba.corRatio, form = ~ dias.de.corrido|bqL),
  ylim=c(0,1),xlab="Distancia (días)",ylab="Semivariograma")

# Prueba de cociente de verosimilitud
anova(prueba.corRatio,lme2a.logNtot.pro) #0.0034

# Función para calcular correlación en errores de mm3.LogcN
correl.corRatio<-function(rho,c0,dist){
  semivar=((dist/rho)^2/(1+(dist/rho)^2))
  correl= 1-(c0+(1-c0)*semivar)
  print(correl)
}
> correl.corRatio(2223,0.8747666,100)
[1] 0.1249805
> correl.corRatio(2223,0.8747666,1000)
[1] 0.1041565
> correl.corRatio(2223,0.8747666,6000)
[1] 0.01511586
```

#### 7.2.5 Sentencias usadas para la Sección 4.4

```
# Comparaciones de medias, modelo mm2.LogCN
library(lsmmeans)
library(multcomp)
cm.p.ajust.letras<-cld(lsmmeans(lme2a.logNtot.pro,pairwise~laboreo|FECHA),alpha=.05
,Letters=letters)

# Para Figura 4.22.
mee <-lsmmeans(lme2a.logNtot.pro,~laboreo|FECHA)
m.y.ee<-summary(mee)[c("laboreo", "FECHA","lsmmean", "SE")]
para.graficar<-m.y.ee
para.graficar$Laboreo<-para.graficar$laboreo
para.graficar$min<-para.graficar$lsmmean-para.graficar$SE
para.graficar$max<-para.graficar$lsmmean+para.graficar$SE
para.graficar$fecha<-rep(unique(NitricoTotal.prom2$fecha),each=4)
para.graficar$dias.d.c<-rep(unique(NitricoTotal.prom2$dias.de.corrido),each=4)
win.graph()
plot(para.graficar$dias.d.c~para.graficar$fecha)

library(ggplot2)
```

```

win.graph()
p<-ggplot(para.graficar, aes(x=dias.d.c, y=lsmean, colour=Laboreo))
p+theme(axis.text.x=element_text(angle = 90,vjust = 0.5 , hjust = 1),
        panel.background=element_rect(fill="white",colour="black"),
        panel.grid.major=element_line(colour="gray",linetype = "dotted"))+
  theme(axis.line=element_line(size=3,colour="red",linetype="dotted"))+
  geom_pointrange(aes(ymin=min, ymax=max),
                 position=position_dodge(0.05)) +
  geom_line(aes(group=Laboreo)) +
  annotate("text", label = "*", x = unique(para.graficar$dias.d.c)[c(1,3,5,8,11,12
,14,18,26,27,29,31,32,35,36,37)],
        y = 3.2, size = 8, colour = "gray")+
  labs(title="",x="Fecha de muestreo")+
  ylab(expression(paste("log(CN ",("kg " * ha^-1),")")))+
  scale_x_continuous(limits = c(400, 7500),
                    breaks=unique(para.graficar$dias.d.c),
                    labels = unique(para.graficar$fecha))

# Comparaciones de medias, modelo mm1.LogCN (Lme)
library(lsmeans)
mm1.logCN.cm.p.ajust.letras<-cld(lsmeans(lme.logNtot.pro,pairwise~laboreo|FECHA),a
lpha=.05,Letters=letters)

# Ajuste del modelo mm1.LogCN con función lmer
library(lme4)
lmeR.logNtot.pro<-lmer(log(NNITRICOtot)~bloque+laboreo*FECHA+(1|bqL/bqL.F),
                      data=PR.AG.V2.sr0,na.action=na.omit)

# Comparaciones de medias, modelo mm1.LogCN (Lmer)
library(lsmeans)
library(multcomp)
cm.mm1.logCN.R.p.ajust.letras<-cld(lsmeans(lmeR.logNtot.pro,pairwise~laboreo|FECHA
),alpha=.05,Letters=letters)

#Figura 4.23
mee.mm1.logCN<-lsmeans(lme.logNtot.pro,~laboreo|FECHA)
m.y.ee<-summary(mee.mm1.logCN)[c("laboreo", "FECHA","lsmean", "SE")]
para.graficar.mm1.logCN<-m.y.ee
para.graficar.mm1.logCN$Laboreo<-para.graficar.mm1.logCN$laboreo
para.graficar.mm1.logCN$min<-para.graficar.mm1.logCN$lsmean-para.graficar.mm1.logC
N$SE
para.graficar.mm1.logCN$max<-para.graficar.mm1.logCN$lsmean+para.graficar.mm1.logC
N$SE
para.graficar.mm1.logCN$fecha<-rep(unique(NitricoTotal.prom2$fecha),each=4)
para.graficar.mm1.logCN$dias.d.c<-rep(unique(NitricoTotal.prom2$dias.de.corrido),e
ach=4)

library(ggplot2)
win.graph()
p<-ggplot(para.graficar.mm1.logCN, aes(x=dias.d.c, y=lsmean, colour=Laboreo))
p+theme(axis.text.x=element_text(angle = 90,vjust = 0.5 , hjust = 1),
        panel.background=element_rect(fill="white",colour="black"),
        panel.grid.major=element_line(colour="gray",linetype = "dotted"))+
  theme(axis.line=element_line(size=3,colour="red",linetype="dotted"))+
  geom_pointrange(aes(ymin=min, ymax=max),
                 position=position_dodge(0.05)) +
  geom_line(aes(group=Laboreo)) +
  # signific. para modelo ajustado con lme

```

```

  annotate("text", label = "*", x = unique(para.graficar.mm1.logCN$dias.d.c)[c(1,3
,5,8,11,12,14,15,18,26,27,29,30,31,32,33,35,36,37)],
    y = 3.2, size = 8, colour = "gray")+
  # signific. para modelo ajustado con lmer
  annotate("text", label = "*",
    x = unique(para.graficar.mm1.logCN$dias.d.c)[c(1,2,3,5:9,11,12,14,15,18
,26,27,29:41,50,54)],
    y = 3.3, size = 8, colour = "black")+
  labs(title="", x="Fecha de muestreo")+
  ylab(expression(paste("log(CN ", ("kg " * ha^-1), ")")))+
  scale_x_continuous(limits = c(400, 7500),
    breaks=unique(para.graficar.mm1.logCN$dias.d.c),
    labels = unique(para.graficar.mm1.logCN$fecha))

```

## 7.3 Sentencias R utilizadas en el capítulo 5

### 7.3.1 Sentencias usadas para la Sección 5.2

```

library(gamlss)

# Ajustes de modelos GAMLSS
# el archivo "depurado" es na.omit(NitricoTotal.prom)
mod.LOGNO2<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = LOGNO2,data=depurado)

mod.IGAMMA<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = IGAMMA,data=depurado)
mod.IGAMMA<-refit(mod.IGAMMA)

mod.GA<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = GA,
  data=depurado)

mod.LOGNO<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = LOGNO,
  data=depurado)

mod.IG<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = IG,
  data=depurado)

```

```

mod.IG<-refit(mod.IG)

mod.WEI<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = WEI,
  data=depurado)

mod.WEI2<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = WEI2,
  data=depurado)
mod.WEI2<-refit(mod.WEI2)

mod.WEI3<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  family = WEI3,
  data=depurado)

mod.BCCG<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  nu.formula = ~1,
  family = BCCG,
  data=depurado)
mod.BCCG<-refit(mod.BCCG)

mod.GIG<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  nu.formula = ~1,
  family = GIG,
  data=depurado)
mod.GIG<-refit(mod.GIG)
# Warning message:
# In RS() : Algorithm RS has not yet converged
# GAMLSS-RS iteration 810: Global Deviance = 9306.483

mod.GIG.CG<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  nu.formula = ~1,
  family = GIG,method=CG(),
  data=depurado)

mod.GG<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  nu.formula = ~1,
  family = GG,

```

```

data=depurado)

mod.BCPE<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  nu.formula = ~1,
  tau.formula = ~1,
  family = BCPE,
  data=depurado)

mod.BCT<-gamlss(NNITRICOtot~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo*bloque,
  sigma.formula = ~pb(dias.de.corrido)+
  pvc(dias.de.corrido,by=laboreo)+laboreo+bloque,
  nu.formula = ~1,
  tau.formula = ~1,
  family = BCT,
  data=depurado)

sel.AIC<-AIC(mod.BCT, mod.BCPE,mod.GG,mod.BCCG,mod.WEI3,mod.WEI2,mod.WEI,
  mod.IG,mod.LOGNO,mod.GA,mod.IGAMMA,mod.LOGNO2) # k=2,

sel.GAIC<-GAIC(mod.BCT, mod.BCPE,mod.GG,mod.BCCG,mod.WEI3,mod.WEI2,mod.WEI,
  mod.IG,mod.LOGNO,mod.GA,mod.IGAMMA,mod.LOGNO2,
  k=log(length(depurado$NNITRICOtot)))

sel.GAIC.2.8<-GAIC(mod.BCT, mod.BCPE,mod.GG,mod.BCCG,mod.WEI3,mod.WEI2,mod.WEI,
  mod.IG,mod.LOGNO,mod.GA,mod.IGAMMA,mod.LOGNO2,
  k=2.8)# k=2.8 valor sugerido por Stasinopoulos y Rigby

# Para Figura 5.1.

sel.AIC$modelo<-rownames(sel.AIC)
sel.AIC$orden.AIC<-order(sel.AIC$AIC)

names(sel.GAIC)[2]<-"GAIC.kn"
sel.GAIC$modelo<-rownames(sel.GAIC)
sel.GAIC$orden.GAIC.kn<-order(sel.GAIC$GAIC.kn)

names(sel.GAIC.2.8)[2]<-"GAIC.k2.8"
sel.GAIC.2.8$modelo<-rownames(sel.GAIC.2.8)
sel.GAIC.2.8$orden.GAIC.k2.8<-order(sel.GAIC.2.8$GAIC.k2.8)
sel.GAIC.2.8$orden.GAIC.kn<-NULL

tabla.AIC<-merge(sel.AIC,sel.GAIC,by="modelo")
tabla.AIC<-merge(tabla.AIC,sel.GAIC.2.8,by="modelo")

tabla2.AIC<-tabla.AIC[,names(tabla.AIC)[c(1,8,3,4,6,7,9,10)]]
tabla2.AIC<-tabla2.AIC[order(tabla2.AIC$AIC),]

win.graph()
plot(tabla2.AIC$AIC[-12],cex.lab=1.5,
  xlab="Modelo según distribución de probabilidad",
  ylab="GAIC",
  col=c("black", "red")[c(2,2,2,rep(1,8))],cex=1.5,axes=FALSE,ylim=c(9440,9920))
axis(1,at=1:11,labels=rownames(sel.AIC)[-12])
axis(2)

```

```

points(1:11,tabla2.AIC$GAIC.kn[-12],pch=16,col=c("black","red")[c(rep(1,3),2,1,2,2,
,1,1,1,1)], cex=c(1.5,1.8)[c(rep(1,3),2,1,2,2,1,1,1,1)])
points(1:11,tabla2.AIC$GAIC.k2.8[-12],pch=17,col=c("black","red")[c(2,2,1,2,rep(1,
7))]),
      cex=c(1.5,1.8)[c(2,2,1,2,rep(1,7))])

# Para Figura 5.2.
library(gamlss)
win.graph()
pdf.plot(family=IG(),mu=c(50,100), sigma=0.1, min=1, max=300,step=.05)

# Para Figura 5.3.
library(gamlss)
win.graph()
wp(mod.IG,ylim.all=1)

win.graph()
wp(mod.LOGNO,ylim.all=1)

win.graph()
wp(mod.BCCG,ylim.all=1)

win.graph()
wp(mod.GA,ylim.all=1)

win.graph()
wp(mod.BCPE,ylim.all=1) #ylim.all=1.1

# Para Tabla 5.3. y Figuras 5.5. mod.IG (como ejemplo), para los otros modelos sol
o
# cambia el nombre del modelo
library(gamlss)
win.graph()
nuevopar<-par(mfrow=c(2,2),col.axis="black",
              col="darkgreen", mar=par("mar")+c(0,1,0,0),bg="white")
plot(mod.IG,par=nuevopar)
par(mfrow=c(1,1))

```

### 7.3.2 Sentencias usadas para la Sección 5.3.

Las sentencias R utilizadas en la sección 5.3. repiten el esquema de algunas utilizadas en 5.2., por lo cual no se presetan.

### 7.3.3 Sentencias usadas para la Sección 5.4.

```

library(gamlss)
# Para Figura 5.14
depurado.sin399$Laboreo<-depurado.sin399$laboreo
ajustados.BCPE<-depurado.sin399
fitted_mu <- fitted(mod.BCPE.sin399, parameter = "mu", which = "dias.de.corrido",
                    type = "response")
ajustados.BCPE$fitted_mu<-fitted_mu

library(ggplot2)
win.graph()
p<-ggplot(ajustados.BCPE, aes(x=dias.de.corrido, y=NNITRICOtot, colour=Laboreo))
p+theme(axis.text.x=element_text(angle = 90,vjust = 0.5 , hjust = 1),

```

```

    panel.background=element_rect(fill="white",colour="black"),
    panel.grid.major=element_line(colour="gray",linetype = "dotted"),
    panel.grid.minor=element_line(colour="gray",linetype = "dotted"))+
  theme(axis.line=element_line(size=3,colour="red",linetype="dotted"))+
  geom_point(aes(group=Laboreo),size=2) +
  geom_point(aes(x=dias.de.corrido+2, y=fitted_mu, shape=Laboreo,colour=Laboreo)
)+
  geom_line(aes(y=fitted_mu,group=Laboreo:bloque),size=1.2) +
  labs(title="",x="Fecha de muestreo")+
  ylab(expression(paste("CN ",("kg " * ha^-1))))+
  scale_x_continuous(limits = c(400, 7500),
                     breaks=unique(ajustados.BCPE$dias.de.corrido),
                     labels = unique(ajustados.BCPE$fecha))

# Para Figura 5.15
fitted_sigma <- fitted(mod.BCPE.sin399, parameter = "sigma", which = "dias.de.corrido",
                      type = "response")
ajustados.BCPE$fitted_sigma<-fitted_sigma

win.graph()
p<-ggplot( ajustados.BCPE, aes(x=dias.de.corrido, y=fitted_sigma, colour=Laboreo))
p+theme(axis.text.x=element_text(angle = 90,vjust = 0.5 , hjust = 1),
        panel.background=element_rect(fill="white",colour="black"),
        panel.grid.major=element_line(colour="gray",linetype = "dotted"),
        panel.grid.minor=element_line(colour="gray",linetype = "dotted"))+
  theme(axis.line=element_line(size=3,colour="red",linetype="dotted"))+
  geom_point(aes(group=Laboreo),size=2) +
  geom_line(aes(group=Laboreo:bloque),size=1.2) +
  labs(title="",x="Fecha de muestreo")+
  ylab(expression(paste("CN ",("kg " * ha^-1))))+
  scale_x_continuous(limits = c(400, 7500),
                     breaks=unique(ajustados.BCPE$dias.de.corrido),
                     labels = unique(ajustados.BCPE$fecha))

```



## 8. CAPÍTULO 8. DISCUSIÓN GENERAL

Revisar la forma de análisis estadístico de los datos generados en los ensayos en agricultura, es importante, en particular, en los ensayos de larga duración en agricultura (ELDA). Las metodologías que se refieren como clásicas y de las que se hace uso frecuente, muchas veces son aplicadas sin evaluar el grado de adecuación de los supuestos. En ocasiones, esto puede llevar a ocultar, sin intencionalidad, los verdaderos comportamientos de los fenómenos objeto de estudio o a interpretaciones erróneas de los resultados obtenidos. Por otro lado, el desarrollo de la Estadística y sus múltiples aplicaciones, han crecido enormemente en los últimos años lo que, juntamente con el crecimiento tecnológico (capacidad de cómputo), permiten investigar y probar nuevas alternativas metodológicas. Sin dudas, tanto o más importantes son los recaudos que deben tomarse en el diseño y conducción de los experimentos, más aún cuando se proyecta que el ensayo perdure varios años. Un buen diseño, es el marco fundamental para la obtención de datos confiables.

En los Capítulos 3, 4, 5 y 6 se presentaron y/o aplicaron algunas alternativas metodológicas para los análisis estadísticos. En el Capítulo 4, particularmente, se aplicaron modelos lineales mixtos (MLM) (Tabla 4.1.) y en el Capítulo 5, modelos aditivos generalizados de localización, escala y forma (GAMLSS) (Tabla 5.1.) para explicar cambios en el contenido del nitrógeno mineral (CN) del suelo en el perfil total (0-90cm), principalmente en función de los efectos del laboreo, del tiempo y de su interacción para los datos del ensayo de Agramunt (Capítulo 2, sección 2.2.). En las aplicaciones de los MLM, el tiempo se trató como una variable de clasificación (factor) como el laboreo o el bloque, con tantos niveles como fechas de muestreo se realizaron. No obstante, pueden considerarse también MLM similares tomando el tiempo como: a) un factor desglosado en el factor campaña agrícola o estación de crecimiento (desde “1995-96” a “2014-15”, Capítulo 2, sección 2.2.) y el factor momento (estación del año) anidado en campaña agrícola, es decir separando el efecto del tiempo en variación entre años y variación dentro de años, o b) variable explicativa cuantitativa. Los análisis mostrados en este trabajo de tesis se realizaron sobre toda la serie desde “1995-96” a “2014-15”, pero pueden realizarse análisis similares con una parte de los datos, por ejemplo, los de una misma estación del año, o lo que se defina según los objetivos. En los GAMLSS la variable tiempo fue

tratada como una variable cuantitativa y la forma en que el CN se relacionó con la misma dependiendo de los laboreos (interacción) fue modelada a través de suavizados.

En los ELDA existen las mediciones repetidas en el tiempo, lo que *a priori*, hace sospechar que los errores dentro de una misma unidad experimental a través del tiempo puedan estar correlacionados o, por lo menos, que no se pueda garantizar independencia entre los mismos. En este trabajo de tesis se propone explorar la existencia de correlación antes de ajustar alguna estructura de autocorrelación en los errores en un modelo lineal mixto. En el Capítulo 4 se ejemplificó esta propuesta haciendo uso de una herramienta de geoestadística, el semivariograma (Fig. 4.19 y Fig. 4.21). Es común que muchas veces se ajusten diversas estructuras de correlación y luego se seleccione el mejor modelo a través de algún criterio como el criterio de información de Akaike (AIC), pero no se evalúa la adecuación del modelo. Por ejemplo, Richter y Kroschewski (2006) ajustaron modelos lineales mixtos de mediciones repetidas para la variable carbono orgánico del suelo (COT) en un ELDA de 30 años, con diferentes estructuras de correlación y seleccionaron por AIC, pero no hicieron una exploración previa ni evaluaron la adecuación del modelo seleccionado.

En los MLM para mediciones repetidas, el modelado de la heterogeneidad de las varianzas también requiere de exploración previa, ajuste y evaluación posterior. En el Capítulo 4 se mostró (pruebas de cociente de verosimilitud) que las cuatro componentes de varianzas residuales, una para cada laboreo considerado en el ensayo de Agramunt, eran significativamente diferentes entre sí en los dos modelos con heterogeneidad de varianzas para el logaritmo de CN (Capítulo 4, sección 4.3.2.). Sin embargo, en ambos casos la mayor de las varianzas (Arado de vertedera) fue inferior al doble de la menor (Siembra directa). Esta diferencia en varianzas no impactó en diferencias importantes en las comparaciones de medias según el modelo con homogeneidad de varianzas y las respectivas en el modelo con heterogeneidad (Salida 4.10., Salida 4.11., Fig. 4.22 y Fig. 4.23), para el caso que se probó (modelo sin término de submuestreo). Por otro lado, en los ELDA pueden ser estudiadas otras formas de heterogeneidad de varianzas. Por ejemplo, podrían considerarse varianzas residuales diferentes dependiendo del tiempo, en particular diferentes varianzas para cada estación del año en el ensayo de Agramunt, a los efectos de no sobre-parametrizar el modelo.

Las posibilidades que brindan los GAMLSS no son sólo las de ajustar relaciones en forma más flexible con métodos de modelos aditivos (suavizados, Hastie y Tibshirani, 1990). Estos modelos permiten, además, modelar los parámetros de localización (que a veces serán medias y otras no), escala y forma, a la vez que abarcan una importante variedad de distribuciones de probabilidad. La distribución lognormal resultó de buena concordancia para CN, y coincide con que los MLM dieron buenos diagnósticos para el logaritmo de CN (Fig. 4.16 y Fig. 4.17). Sin embargo, entre los GAMLSS hubo distribuciones para CN más acordes que la lognormal. Éstas fueron la distribución potencial exponencial de Box y Cox (BCPE), en primer término, y la gamma, dentro de las tres mejores seleccionadas (Tabla 5.4., Tabla 5.5, Fig. 5.9, Fig. 5.11 y Fig. 5.12). Gbur *et al.* (2012) utilizaron modelos lineales generalizados mixtos (MLGM) para modelar el nitrato del suelo para datos de un ensayo de sistemas de cultivos durante cuatro años, con diferentes estructuras de varianza-covarianza para el término de error incluido errores independientes y obtuvieron, en general, un mejor ajuste de la distribución lognormal que de la distribución gamma.

También es importante observar que la selección de la distribución de probabilidad en los GAMLSS depende de los predictores y de las funciones de ligadura utilizados para cada parámetro. De la misma forma que los predictores en los modelos lineales generales, los predictores y las funciones de ligadura en los modelos lineales generalizados (Mc Cullagh y Nelder, 1989, Myers *et al.*, 2010) inciden en la adecuación del modelo. Por otro lado, los criterios de información de Akaike generalizados (GAIC) no deben tomarse como únicos criterios para la elección del mejor modelo, sino que debe acompañarse con la evaluación del comportamiento de los residuales del modelo. Como se observó en el Capítulo 5, un modelo con GAIC (con penalidad  $k=2$  y  $k=2.8$ ) más bajo no fue el más adecuado (Tabla 5.2, Tabla 5.3 y Fig. 5.3).

En el Capítulo 6 se dieron pautas para el análisis del COT a través de la variable diferencia de su contenido final e inicial en períodos de cierta duración de años, a fin de evaluar efectos de secuencias de cultivos o pastura en ensayos de sistemas de cultivos con rotaciones de cultivos. Se propone continuar el análisis a través de modelos lineales generales, MLM o GAMLSS según los casos, y con supuesto de distribución normal.

Así como las mediciones repetidas en el tiempo conforman una estructura de datos agrupados, y así fueron tratadas en los MLM de mediciones repetidas en el Capítulo 4, las mediciones en el suelo a diferentes profundidades pueden ser consideradas en forma análoga. En este caso, las mediciones a diferentes profundidades constituyen mediciones repetidas en el espacio. En el Capítulo 2 (sección 2.2.) se indicó que uno de los objetivos del ensayo en Agramunt era evaluar los efectos de la interacción entre los sistemas de laboreo y las profundidades (i.e. distintas capas de suelo) sobre el CN del suelo a lo largo de todo el período. Por ello, una alternativa de análisis de las tres profundidades muestreadas (0-30 cm, 30-60 cm y 60-90 cm) a lo largo del tiempo, es considerar simultáneamente ambos tipos de mediciones repetidas, en el tiempo y en el espacio, en un modelo mixto (Gbur *et al.*, 2012; Monterubbianesi *et al.*, 2012). La unidad de agrupamiento para las mediciones en el espacio es la parcela (la asignada a un laboreo en un bloque) en una misma fecha de muestreo. Lo mismo para COT en los ELDA del Sudeste Bonaerense (Capítulo 2, sección 2.3.), si fuera de interés estudiar las mediciones en las diferentes profundidades de suelo en forma simultánea.

Los GAMLSS son de desarrollo relativamente reciente y su aplicación a ensayos agronómicos diseñados (sean ELDA o no) es aún muy poco frecuente o casi inexistente. Por ello, y dadas las ventajas demostradas en esta Tesis, es necesario profundizar el estudio sobre sus posibilidades, alcances y limitaciones en el campo de la agronomía y particularmente en situaciones como las que se presentan en los ELDA. Por otro lado, los métodos de estimación de los parámetros utilizan algoritmos iterativos que, en algunos casos, por ejemplo, con modelos complejos y/o pocos datos, pueden resultar computacionalmente intensivos o sin convergencia a la solución. Para más detalles sobre los métodos de estimación y algoritmos puede remitirse a Stasinopoulos *et al.* (2017) y Wood (2006, 2011).

Modelos intermedios entre los MLM y los GAMLSS, como los MLGM (McCulloch y Searle, 2001, Gbur *et al.*, 2012) o los modelos aditivos mixtos (Wood, 2006, Faraway, 2016), podrían también ser utilizados para modelar con suavizados los efectos del tiempo e incorporar efectos aleatorios y correlaciones entre errores u observaciones para el análisis de variables tanto como el CN del suelo, como de variables del tipo de COT. No obstante, estos modelos también pueden tener inconvenientes de velocidad y de convergencia en su implementación computacional (Wood y Scheipl, 2016).

Por otra parte, es importante notar que CN y COT son variables de naturaleza muy diferente. El CN es extremadamente variable y su nivel y ubicación en el suelo (profundidad) depende mucho de condiciones ambientales del momento y previas al muestreo. Así, las condiciones previas al momento de la toma de muestras pueden alterar los niveles de CN de manera temporaria y generar alguna distorsión transitoria respecto a lo que se espera asociado con los efectos a mediano a largo plazo de las prácticas de manejo. Asimismo, los niveles de CN pueden estar condicionados por las características (cantidad, calidad, forma física, entre otras) de los residuos del cultivo que antecedió al muestreo. Estas características también deberían ser tenidas en cuenta al momento de definir la forma y el modelo de análisis y, sobre todo, para interpretar los resultados obtenidos del análisis y elaborar las posibles conclusiones. En cambio, las variaciones del COT son más “estables”. Sus cambios dependientes de las condiciones previas al muestreo son casi despreciables y, por eso, es más claro ver cambios en el tiempo y relacionarlos más fácilmente con variables explicativas asociadas con los cambios producidos por el manejo (historial de rendimientos, laboreos, fertilización, riego, entre otras). Esa diferente naturaleza incide también en la elección del modelo o de los modelos para el análisis y en la posibilidad de que exista o no heterogeneidad de varianzas, correlaciones entre errores, etc.

En cada una de las etapas de ajuste, evaluación y selección de los modelos más adecuados (tanto MLM como GAMLSS), se mostraron qué herramientas estadísticas utilizar, y cómo utilizarlas e interpretarlas (Capítulo 4, 5 y 7). Estas herramientas fueron implementadas en el ambiente computacional R (Capítulo 7). Las sentencias utilizadas, pueden ser adaptadas, generalizadas y extendidas para el análisis de otras variables respuesta y otros ELDA. Dichas sentencias son la base para la creación de un paquete para el análisis estadístico en los ELDA. Para ello, la diferente naturaleza de las variables respuesta (así como CN y COT), debe ser tenida en cuenta para la especificación y la elección del modelo y las interpretaciones de los resultados.

Respecto a los diseños, una condición señalada como importante para tener en cuenta en los ELDA, es la de iniciar repeticiones del ensayo en diferentes años (Loughin, 2006). McRae y Ryan (1996) indican que deberían considerarse los inicios escalonados de los ensayos cuando los fenómenos meteorológicos en el año del establecimiento puedan afectar grandemente el

crecimiento de los cultivos involucrados (estos autores se basan en cultivos perennes) en los años siguientes. Con los diseños de inicios escalonados se hace hincapié en que los efectos acumulados de los tratamientos en un ELDA deben estar repetidos no solo en el espacio (bloque) sino también en diferentes series de años. Así, los efectos acumulados de los tratamientos se encuentran probados en más de una sucesión de años y no en una sola (cuando hay un solo año de inicio), lo que implica diferentes condiciones meteorológicas y de características propias de las series de años. Por otro lado, y en particular para los ensayos de rotación, todas las fases de una misma rotación deben estar presentes en cada año del ensayo (Patterson, 1964), en este caso para evitar confundir efectos de años y fases. Atendiendo a estos dos aspectos, en el Capítulo 6 se evaluaron los diseños de los ELDA del Sudeste Bonaerense (Capítulo 2, sección 2.3.) que tienen la particularidad de involucrar rotaciones de cultivos en los sistemas de cultivo. Se observó que en el Ensayo de Agricultura Continua (sección 2.3.1.) algunas de las secuencias probadas correspondían a la misma rotación básica de tres cultivos (sección 6.2.1. y Tabla 6.2.), pero no estaban probadas todas las posibles secuencias de cada una de las rotaciones básicas (12 rotaciones básicas más una con sólo trigo), es decir no estaban todas las fases de cada rotación un mismo año. De haberse dado todas las fases todos los años se tendrían que haber considerado 37 secuencias (vs 16 que se probaron), lo que incrementaría notablemente el requerimiento de recursos. Opcionalmente, si las 16 secuencias originales se hubiesen iniciado durante un segundo y un tercer año (inicios escalonados), a partir del tercer año se tendrían todas las fases en un mismo año (Tabla 6.4.). También se observa que si en rotaciones agrícolas cíclicas se tienen todas las fases en un mismo año (todas las secuencias probadas), se tienen implícitos los inicios escalonados (Tabla 6.5.), y es de esperar que los efectos de los primeros años en el ensayo no impacten a largo plazo.

En el Ensayo de Secuencias de Cultivos y Sistemas de Laboreo (sección 2.3.2.) y Ensayo de Sistemas de Laboreo (sección 2.3.3.) se prueban tres y una, respectivamente, rotación básica de tres cultivos. En estos ensayos, todas las fases están presentes todos los años y, por lo tanto, el inicio escalonado está implícito en cada uno, de la misma manera que lo observado, en este sentido, para el Ensayo de Agricultura continua (Tabla 6.5). En cambio, en el Ensayo de Rotaciones Mixtas y Sistemas de Cultivos (sección 2.3.4.), la estructura de las rotaciones (agricultura-pastura) hace que los inicios escalonados sean importantes. Así, cada período de

pastura o agricultura no quedaría asociado a un período de años fijo (Tabla 6.6.). En definitiva, dependiendo del tipo de rotación, en algunos casos cumplir con la premisa de tener todas las fases en cada año, a largo plazo sería equivalente a tener inicios escalonados. Por otro lado, una secuencia de cultivos iniciada escalonadamente genera repeticiones en el tiempo y a partir de cierto año la presencia de todas las fases un mismo año. Por último, es importante remarcar que, como en los sistemas de cultivos se combinan las rotaciones de cultivos, con sistemas de laboreo, fertilizaciones y otros tratamientos auxiliares (p.e. cultivo de cobertura) en general, no debe pretenderse comparar un gran número de rotaciones en un mismo ensayo.



## 9. CAPÍTULO 9. CONCLUSIONES

En relación a los objetivos planteados para los ELDA con diferentes sistemas de cultivo:

- Se propusieron alternativas metodológicas para el análisis estadístico de datos, una basada en modelos lineales mixtos (MLM), que suelen ser los más frecuentemente usados, y otra, basada en modelos aditivos generalizados de localización, escala y forma (GAMLSS), que son más flexibles y de desarrollo relativamente reciente. Ambos tipos de modelos permiten caracterizar el comportamiento de la variable respuesta en función de los predictores no solo a través de la media de la distribución de probabilidad correspondiente sino también considerando otros parámetros (ej. varianza) de dicha distribución.
- Los MLM son propuestos para variables respuestas con distribución normal y mediciones repetidas en el tiempo y los GAMLSS para una amplia gama de distribuciones de probabilidad para las variables respuestas y/o el modelado flexible (suavizados) de la relación de la variable respuesta con algunos predictores (tiempo).
- Las metodologías propuestas fueron ejemplificadas exhaustivamente para la variable contenido de nitrógeno del suelo y efectos de los laboreos en un ELDA, pero lo realizado puede ser aplicado y adaptado para otras variables respuestas con otras características, así como a otras estructuras de diseño.
- A fin de evaluar el desempeño de las metodologías estadísticas propuestas, se analizó la adecuación de los modelos estadísticos ajustados, etapa imprescindible en todo proceso de análisis. Dichos análisis se realizaron en cada caso mostrando las herramientas utilizadas y su interpretación. Adicionalmente, se mostró que un modelo más complejo no siempre resulta el más adecuado.
- Dado que los GAMLSS son de aparición reciente, sus aplicaciones a ensayos agronómicos diseñados son aún muy poco frecuentes o casi inexistentes. Por ello, y dadas las ventajas demostradas en esta Tesis, es necesario profundizar el estudio sobre sus posibilidades, alcances y limitaciones en el campo de la agronomía y particularmente en situaciones como las que se presentan en los ELDA.
- Se revisaron aspectos de diseño en los ELDA ubicados en el sudeste bonaerense, Argentina, que corresponden a ensayos de rotaciones de cultivos o rotaciones de cultivos

y pasturas. En cuanto a recomendaciones para mejoras a futuro y/o para el inicio de nuevos ELDA, se muestra la importancia de la presencia de todas las fases de las rotaciones en un mismo año, durante todos los años de ensayo. Por otro lado, se establecieron aspectos positivos y limitaciones en los mismos.

- A fin de facilitar a los investigadores de las áreas de aplicación (agronomía, ciencia del suelo) el uso futuro de las metodologías propuestas, así como la interpretación de los resultados, se explicitaron detalladamente los pasos seguidos en los análisis propuestos y las sentencias utilizadas en el ambiente computacional R. Esto último, permite sentar las bases para el desarrollo de una plataforma computacional específica (desarrollo de funciones o un paquete en R) para los análisis de los datos provenientes de ELDA con distintos sistemas de cultivo y ambientes, ya que constituye una versión inicial y simplificada de dicho proceso.

## 10. BIBLIOGRAFÍA

- AKAIKE, H. 1974. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*. 19(6):716-723.
- AKAIKE, H. 1983. Information measures and model selection. *Bulletin of the International Statistical Institute*. 50:277-290.
- BATES, D.; MAECHLER, M.; BOLKER, B.; WALKER, S. 2014. lme4: linear mixed-effects models using Eigen and S4. R package version 1.1-6. [en línea] <<http://CRAN.R-project.org/package=lme4>> [consulta: 20 agosto 2014].
- BATES, D.; MAECHLER, M.; BOLKER, B.; WALKER, S. 2015. Fitting linear mixed-effects models using lme4. *J. Statistical Software*. 67(1):1-48.
- BERTI, A.; DALLA MARTA, A.; MAZZONCINI, M.; TEI, F. 2016. An overview on long-term agro-ecosystem experiments: present situation and future potential. *European Journal of Agronomy*. 77:236-241.
- BLANCO, H.; LAL, R. 2010. *Principles of Soil Conservation and Management*. Springer Science Business Media B.V. New York, New York, USA. 641 p.
- CADY, F.B. 1991. Experimental design and data management of rotation experiments. *Agronomy Journal*. 83:50-56.
- CANTERO-MARTÍNEZ, C.; ANGÁS, P.; LAMPURLANÉS, J. 2007. Long-term yield and water use efficiency under various tillage systems in Mediterranean rainfed conditions. *Annals of Applied Biology*. 150(3):293-305.
- CLAESKENS, G.; HJORT, N.L. 2003. The focused information criterion. *Journal of the American Statistical Association*. 98(464):900-916.
- COCHRAN, W.G. 1939. Long-term agricultural experiments (with discussion). *Journal of the Royal Statistical Society*. 6(suppl.):104-148.
- COSTAMAGNA, O.A.; GUALATI A.T.; STUDDERT, G.A. 2006. Breve reseña histórica del ensayo de rotaciones mixtas de la Unidad Integrada Balcarce. Taller "Sustentabilidad agrícola: el rol de los ensayos de larga duración". Unidad Integrada Balcarce, Balcarce, Buenos Aires, Argentina, noviembre de 2006. En CD.
- DELIGNETTE-MULLER, M.L.; DUTANG, C. 2015. fitdistrplus: an R package for fitting distributions. *Journal of Statistical Software* 64(4):1-34.
- DUNN, P.K.; SMYTH, G.K. 1996. Randomised quantile residuals. *Journal of Computational and Graphical Statistics*. 5(3):236-244.
- DOBSON, A.J.; BARNETT, A. 2008. *An Introduction to Generalized Linear Models*, 3rd ed. Chapman and Hall/CRC, Boca Raton, Florida, USA. 320 p.
- EILERS, P.H.C.; MARX, B.D. 2010. Splines, knots, and penalties. *Wiley Interdisciplinary Reviews: Computational Statistics*. 2(6):637-653.
- FARAWAY, J.J. 2016. *Extending the linear model with R. Generalized linear, mixed effects and nonparametric regression models*, 2nd ed. Chapman & Hall/CRC. Boca Raton, Florida, USA. 399 p.

- FILLIBEN, J.J. 1975. The probability plot correlation coefficient test for normality. *Technometrics*. 17(1):111-117.
- FRYE, W.W.; THOMAS, G.W. 1991. Management of long-term field experiments. *Agronomy Journal*. 83(1):38-44.
- GBUR, E.E.; STROUP, W.W.; McCARTER, K.S.; DURHAM, S.; YOUNG, L.J.; CHRISTMAN, M.; WEST, M.; KRAMER, M. 2012. Analysis of generalized linear mixed models in the agricultural and natural resources sciences. American Society of Agronomy, Soil Science Society of America, Crop Science Society of America, Madison, Wisconsin, USA. 283 p.
- HARDIN, J.W.; HILBE, J.M. 2003. Generalized Estimating Equations. Chapman & Hall/CRC. Boca Raton, Florida, USA. 222 p.
- HASTIE, T.J.; TIBSHIRANI, R.J. 1990. Generalized Additive Models. Chapman & Hall/CRC. Boca Raton, Florida, USA. 335 p.
- INTA. 1979. Carta de Suelos de la República Argentina. Hoja: 3757-31, Balcarce., Instituto Nacional de Tecnología Agropecuaria, Secretaría de Agricultura, Ganadería y Pesca, Buenos Aires, Argentina.
- JENKINSON, D.S. 1991. The Rothamsted long-term experiments: are they still of use? *Agronomy Journal*. 83(1):2-10.
- JOHNSON, N.L.; KOTZ, S.; BALAKRISHNAN, N. 1994. Continuous Univariate Distributions, Volume I. 2nd ed. Wiley, New York, New York, USA. 784 p.
- JOHNSTON, A.E. 1997. The value of long-term field experiments in agricultural, ecological, and environmental research. *Advances in Agronomy* 59:291-333.
- KENWARD, M.G.; ROGER, J.H. 1997. Small Sample Inference for Fixed Effects from Restricted Maximum Likelihood. *Biometrics*. 53: 983-997.
- LAMPURLANÉS, J.; PLAZA-BONILLA, D.; ÁLVARO-FUENTES, J.; CANTERO-MARTÍNEZ, C. 2016. Long-term analysis of soil water conservation and crop yield under different tillage systems in Mediterranean rainfed conditions. *Field Crops Research* 189:59–67.
- LENTH, R.V. 2016. Least-squares means: the R package lsmeans. *Journal of Statistical Software*. 69(1):1-33.
- LOUGHIN, T. 2006. Improved experimental design and analysis for long-term experiments. *Crop Science*. 46(6):2492-2502.
- LOUGHIN, T.M.; ROEDIGER, M.P.; MILLIKEN, G.A.; SCHMIDT, J.P. 2007. On the analysis of long-term experiments. *Journal of the Royal Statistical Society, Series A-Statistics in Society*. 170(1):29-42.
- LUNA, J.M.; HOUSE, G.J. 1990. Pest management in sustainable agricultural systems. In: Edwards, C.A.; Lal, R.; Madden, P.; Miller, R. H.; House, G. (eds.) Sustainable agricultural systems. Soil and Water Conservation Society, Ankeny, Iowa, USA. pp. 157-173.
- Mc CULLAGH, P.; NELDER, J.A. (1989). Generalized Linear Models, 2nd Ed. Chapman & Hall/CRC. Boca Raton, Florida, USA. 532 p.
- Mc CULLOCH, C.E.; SEARLE, S.R. 2001. Generalized, Linear, and Mixed Models. Wiley & Sons. New York, New York. USA. 325 p.

- McRAE, K.B.; RYAN, D.A.J. 1996. Design and planning of long term experiments. *Canadian Journal of Plant Science*. 76(4):595-601.
- MILLIKEN, G.A.; JOHNSON, D.A. 2009. Analysis of messy data. Volume 1. Designed Experiments. 2nd ed. Chapman & Hall/CRC. Boca Raton, Florida, USA. 674 p.
- MONTERUBBIANESI, M.G.; WALICKI, V.; CASTRO, I.; CONCHA, A. 2012. Suavizado para mediciones repetidas: aplicación en un estudio ambiental. X Congreso Latinoamericano de Sociedades de Estadística. Córdoba, Argentina, octubre 2012.
- MORENO, R.; STUDDERT, G.A.; MONTERUBBIANESI, M.G.; IRIGOYEN, A.I. 2016. Soil organic carbon simulated with the AMG model in a high-organic-matter Mollisol. *Spanish Journal of Soil Science*. 6(3):212-229.
- MUGGEO, V.M.R. 2003. Estimating regression models with unknown break-points. *Statistics in Medicine*. 22: 3055-3071.
- MUGGEO, V.M.R. 2008. Segmented: an R Package to Fit Regression Models with Broken-Line Relationships. *R News*, 8(1):20-25. [en línea] <<http://cran.r-project.org/doc/Rnews/>> [consulta: 15 junio 2015].
- MYERS, R.H.; MONTGOMERY, D.C.; VINING, G.G.; ROBINSON, T.J. 2010. Generalized linear models With Applications in Engineering and the Sciences, 2nd Ed. Wiley, Hoboken. Nueva Jersey, USA. 496 p.
- ORCHARD, B.A.; CULLIS, B.R.; COOMBES, N.E.; VIRGONA, J.M.; KLEIN, T. 2000. Grazing management studies within the temperate pasture sustainability key program: Experimental design and statistical analysis. *Australian Journal of Experimental Agriculture* 40(2):143-154.
- OWENS, B. 2013. Long-term research: slow science. *Nature*. 495(7441):300-303
- PAPADAKIS, J. 1966. Climates of the world and their agricultural potentialities. Editorial Albatros, Buenos Aires, Argentina. 174 p.
- PAROLINI, G. 2015. The Emergence of Modern Statistics in Agricultural Science: Analysis of Variance, Experimental Design and the Reshaping of Research at Rothamsted Experimental Station, 1919–1933. *Journal of the History of Biology*. 48:301–335.
- PATTERSON, H.D. 1964. Theory of cyclic rotation experiments. *Journal of the Royal Statistical Society, Series B-Statistical Methodology*. 26(1):1-45.
- PATTERSON, H.D.; LOWE, B.I. 1970. The errors of long-term experiments. *Journal of Agricultural Science, Cambridge*. 74(1):53-60.
- PAYNE, R.W. 2015. The design and analysis of long-term rotation experiments. *Agronomy Journal*. 107(2):772-785.
- PETERSON, G.A.; LYON, D.J.; FENSTER, C.R. 2012. Valuing long-term field experiments: quantifying the scientific contribution of a long-term tillage experiment. *Soil Science Society of America Journal*. 76(3):757-765.
- PIEPHO, H.P.; BÜCHSE, A.; RICHTER, C. 2004. A mixed modelling approach for randomized experiments with repeated measures. *Journal of Agronomy and Crop Science*. 190(4):230-247.

- PINHEIRO, J.; BATES, D. 2000. Mixed-effects models in S and S-Plus. Springer-Verlag. New York, New York, USA. 528 p.
- PINHEIRO, J.; BATES, D.; DEBROY, S.; SARKAR, D.; R CORE TEAM. 2014. nlme: linear and nonlinear mixed effects models. R package version 3.1-117, [en línea] <<http://CRAN.R-project.org/package=nlme>> [consulta: 20 agosto 2014].
- POULTON, P.R. 1995. The importance of long-term trials in understanding sustainable farming systems: the Rothamsted experience. *Australian Journal of Experimental Agriculture*. 35(7):825-834.
- POWER, J.F.; FOLLETT, R.F. 1987. Monoculture. *Scientific American*. 256(3):78-86.
- PREECE, D.A. 1986. Some general principles of crop rotation experiments. *Experimental Agriculture*. 22(2):187-198.
- QUIROGA, R.A.; STUDDERT, G.A. 2014. Manejo del suelo e intensificación agrícola: agua y materia orgánica, dos aspectos clave. En: Echeverría, H.E.; García, F.O. (eds.) *Fertilidad de suelos y fertilización de cultivos*, 2da ed. Ediciones INTA. Buenos Aires, Argentina. pp. 73-100.
- R CORE TEAM. 2016. R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. [en línea] <<http://www.R-project.org/>> [consulta: 20 julio 2016].
- REICOSKY, D.C.; SAUER, T.J.; HATFIELD, J.L. 2011. Challenging balance between productivity and environmental quality: tillage impacts. In: Hatfield, J.L.; Sauer, T.J. (eds.) *Soil Management: Building a Stable Base for Agriculture*. American Society of Agronomy, Soil Science Society of America. Madison, Wisconsin, USA. pp. 13-37.
- RICHTER, D.; HOFMOCKEL, M.; CALLAHAM, M.A.; POWLSON, D.S.; SMITH, P. 2007 Long-term soil experiments: keys to managing Earth's rapidly changing ecosystems. *Soil Science Society of America Journal*. 71(2):266–279.
- RICHTER, D.; KROSCHEWSKI, B. 2006 Analysis of a Long-term Experiment with Repeated-measurement Models *Journal of Agronomy and Crop Science*. 192: 55-71.
- RIGBY, R.A.; STASINOPOULOS, D.M. 2004. Smooth centile curves for skew and kurtotic data modelled using the Box-Cox Power Exponential distribution. *Statistics in Medicine*. 23(19):3053–3076.
- RIGBY, R.A.; STASINOPOULOS, D.M. 2005. Generalized additive models for location, scale and shape (with discussion). *Applied Statistics*. 54(3):507-554.
- SCHABENBERGER, O.; PIERCE, F.J. 2002. *Contemporary Statistical Models for the Plant and Soil Sciences*. CRC Press. Boca Raton, Florida, USA. 738 p.
- SCHWARZ, G. 1978. Estimating the dimension of a model. *Ann. Statist.* 6:461-464.
- SINGH, M.; JONES, M. 2002 Modeling yield sustainability for different rotations in long-term barley trials. *Journal of Agricultural, Biological, and Environmental Statistics*. 7(4):525–535.
- SOIL SURVEY STAFF. 2014. *Keys to soil taxonomy*. USDA, Natural Resources Conservation Service. Washington, DC, USA. 372 p.
- STASINOPOULOS, D.M.; RIGBY, R.A. 2007. Generalized additive models for location scale and shape(GAMLSS) in R. *Journal of Statistical Software*. 23(7):1-46.

- STASINOPOULOS, D.M.; RIGBY, R.A.; AKANTZILIOTOU, C. 2008. Instructions on how to use the gamlss package in R. 2nd ed. 206 p. [en línea] <<http://www.gamlss.org/>> [consulta: 20 octubre 2016].
- STASINOPOULOS, D.M.; RIGBY, R.A.; VOUDOURIS, V.; HELLER, G.; VOUDOURIS, V.; DE BASTIANI, F. 2017. Flexible Regression and Smoothing: Using GAMLSS in R. Chapman and Hall/CRC. Boca Raton, Florida, USA. 549 p.
- STUDDERT, G.A. 2006. Rotaciones de cultivos en el sudeste de la provincia de Buenos Aires (Argentina): una herramienta para el manejo de la dinámica del nitrógeno y del carbono en el suelo. Tesis Doctoral. Universitat de Lleida. Escola Tècnica Superior D'Enginyeria Agraria. Lleida, Catalunya, España. 196 p.
- STUDDERT, G.A.; ECHEVERRÍA, H. 2000. Crop rotations and nitrogen fertilization to manage soil organic carbon dynamics. *Soil Science Society of America Journal*. 64:1496-1503.
- VAN BUUREN, S.; FREDRIKS, M. 2001. Worm plot: a simple diagnostic device for modelling growth reference curves. *Statistics in Medicine*. 20(8):1259-1277.
- VERBYLA, A.P.; CULLIS, B.R.; KENWARD M.G.; WELHAM S.J. 1999. The analysis of designed experiments and longitudinal data by using smoothing splines. *Applied Statistics*. 48(3):269-311.
- WOOD, S.N. 2006. *Generalized Additive Models: An Introduction with R*. Chapman & Hall/CRC. Boca Raton, Florida, USA. 410 p.
- WOOD, S.N. 2011. Fast stable restricted maximum likelihood and marginal likelihood estimation of semiparametric generalized linear models. *Journal of the Royal Statistical Society, Series B- Statistical Methodology*. 73(1):3-36.
- WOOD, S.; SCHEIPL, F. 2016. gamm4: Generalized Additive Mixed Models using 'mgcv' and 'lme4'. R package version 0.2-4. [en línea] <<https://CRAN.R-project.org/package=gamm4>> [consulta: 1 febrero 2017].
- YATES, F. 1954. The analysis of experiments containing different crop rotations. *Biometrics*. 10(3):324-346.
- ZINCK, J.A.; BERROTERÁN, J.L.; FARSHAD, A.; MOAMENI, A.; WOKABI, S.; VAN RANST, E. 2005. La sustentabilidad agrícola: un análisis jerárquico. Instituto Nacional de Ecología, México. *Gaceta Ecológica*. 76:53-72.