

**UNIVERSIDAD DE CÓRDOBA**  
**DEPARTAMENTO DE INGENIERÍA GRÁFICA Y GEOMÁTICA**

**TESIS DOCTORAL**

**DELIMITACIÓN DE ZONAS DE MANEJO EN AGRICULTURA DE PRECISIÓN  
A PARTIR DE MEDIDAS DE CONDUCTIVIDAD ELÉCTRICA APARENTE DEL  
SUELO MEDIANTE EL USO DE SENSORES MÓVILES DE CONTACTO**

**Jose María Terrón López**

**Directores:**

**Francisco Jesús Moral García**

**Jose Rafael Marques da Silva**

**Francisco Javier Rebollo Castillo**

**Córdoba, marzo de 2013**



**TITULO: *DELIMITACIÓN DE ZONAS DE MANEJO EN AGRICULTURA DE  
PRECISIÓN A PARTIR DE MEDIDAS DE CONDUCTIVIDAD  
ELÉCTRICA APARENTE DEL SUELO MEDIANTE EL USO DE  
SENSORES MÓVILES DE CONTACTO***

**AUTOR: JOSÉ MARÍA TERRÓN LÓPEZ**

---

© Edita: Servicio de Publicaciones de la Universidad de Córdoba.  
Campus de Rabanales  
Ctra. Nacional IV, Km. 396 A  
14071 Córdoba

---

[www.uco.es/publicaciones](http://www.uco.es/publicaciones)  
publicaciones@uco.es

---

**UNIVERSIDAD DE CÓRDOBA**

**DEPARTAMENTO DE INGENIERÍA GRÁFICA Y GEOMÁTICA**

**TESIS DOCTORAL**

**DELIMITACIÓN DE ZONAS DE MANEJO EN AGRICULTURA DE PRECISIÓN  
A PARTIR DE MEDIDAS DE CONDUCTIVIDAD ELÉCTRICA APARENTE DEL  
SUELO MEDIANTE EL USO DE SENSORES MÓVILES DE CONTACTO**

**Presentada por el Ingeniero Agrónomo D. Jose María Terrón López**

**para aspirar al grado de Doctor por la Universidad de Córdoba.**

**El Doctorando**



**Fdo. Jose María Terrón López**

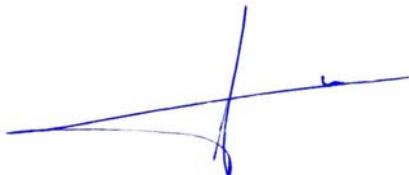
**Córdoba, marzo de 2013**

- Dr. Francisco Jesús Moral García, Profesor Titular de la Universidad de Extremadura.
- Dr. Francisco Javier Rebollo Castillo, Profesor Contratado de la Universidad de Extremadura.
- Dr. Jose Rafael Marques da Silva, Profesor Titular de la Universidad de Évora (Portugal),

CERTIFICAN: El presente trabajo de investigación titulado "Delimitación de Zonas de Manejo de Agricultura de Precisión a partir de medidas de Conductividad Eléctrica Aparente del Suelo mediante el uso de Sensores Móviles de Contacto ", presentado por Jose María Terrón López, bajo su codirección, se considera finalizado, y puede ser presentado para su exposición y defensa como Tesis Doctoral en la Universidad de Córdoba (España).

Y para que conste, firman la presente certificación,

Córdoba, a 14 de marzo de 2013



Fdo. Dr. Francisco Jesús Moral García

Dr. Francisco Javier Rebollo Castillo

Profesor Titular de la UEX

Profesor Contratado de la UEX



Fdo. Dr. Jose Rafael Marques da Silva

Profesor Titular de la Universidad de Évora



**TÍTULO DE LA TESIS: DELIMITACIÓN DE ZONAS DE MANEJO EN AGRICULTURA DE PRECISIÓN A PARTIR DE MEDIDAS DE CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO MEDIANTE EL USO DE SENsoRES MÓVILES DE CONTACTO**

**DOCTORANDO/A:** Jose María Terrón López

**INFORME RAZONADO DE LOS DIRECTOR/ES DE LA TESIS**

Los objetivos que al comienzo de los trabajos de la tesis se plantearon fueron cumpliéndose conforme a los plazos previstos. A medida que los trabajos de campo se iban desarrollando y completando, la información que se precisaba se recopilaba y analizaba, comprobándose que cada uno de los objetivos parciales se iban cumpliendo. Fue necesaria una puesta a punto de los equipos que se emplearon para la medida de la conductividad eléctrica aparente del suelo, de los cuales no existía referencia sobre su uso en las condiciones propias de área de estudio, es decir, en suelos con un alto contenido de arcilla y en condiciones de secano. Asimismo, se realizaron muestreos del suelo para la determinación de diversas variables físico-químicas del mismo. Con todo ello, se generaron unas bases de datos con una gran cantidad de información que fue procesada mediante un sistema de información geográfica para la caracterización de la variabilidad espacial y, con posterioridad, temporal, de la conductividad eléctrica aparente del suelo, que se demostró que es la variable clave para la definición de las zonas de manejo homogéneas en la parcela experimental.

Como todo trabajo de campo que ha sido desarrollado durante varios años, las condiciones fueron cambiando, por lo que la información recabada muestra una variabilidad que la hace óptima para los fines que se perseguían.

Fruto de los resultados que se han ido obteniendo a lo largo del tiempo se han realizado cuatro artículos que han sido publicados en revistas científicas de impacto, así como cinco trabajos, presentados a diferentes congresos internacionales, que se detallan en hojas anexas.

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 15 de marzo de 2013

A handwritten signature in black ink, appearing to read 'Francisco Jesús Moral García'.

Firma del/de los director/es

A handwritten signature in blue ink, appearing to read 'Francisco Javier Rebollo Castillo'.

Fdo.: Dr. Francisco Jesús Moral García

A handwritten signature in blue ink, appearing to read 'Jose Rafael Marques da Silva'.

Fdo.: Dr. Francisco Javier Rebollo Castillo

Fdo. Dr. Jose Rafael Marques da Silva

## **HOJAS ANEXAS AL INFORME:**

### **TRABAJOS PUBLICADOS RELACIONADOS CON LA TESIS:**

1. Moral, F.J., Terrón, J.M., Marques da Silva, J.R. (2010). Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. *Soil & Tillage Research*. 106, 335-343.
2. Terrón, J.M., Marques da Silva, J.R., Moral, F.J., García-Ferrer, A. (2011). Soil apparent electrical conductivity and geographically weighted regression for mapping soil. *Precision Agriculture* 12, 750-761.
3. Moral, F.J., Terrón, J.M., Rebollo, F.J. (2011). Site-specific management zones based on the Rasch model and geostatistical techniques. *Computers and Electronics in Agriculture*. 75, 223-230.
4. Moral, F.J., Rebollo, F.J., Terrón, J.M. (2012). Analysis of soil fertility and its anomalies using an objective model. *Journal of Plant Nutrition and Soil Science* 175, 912-919.

### **CONTRIBUCIONES A CONGRESOS DERIVADAS DE LA TESIS:**

1. Moral, F.J., Terrón, J.M., Marques da Silva, J.R. (2010). Uso de las medidas de la conductividad eléctrica aparente del suelo como base para la determinación de diferentes zonas de manejo. Comunicación oral. Ponencia. III Jornadas Iberoamericanas de Agricultura de Precisión. Évora (Portugal).
2. Terrón, J.M., Marques da Silva, J.R., Moral, F.J., Becerra, (2010). Soil electric apparent conductivity as a decision supporting tool on fertilization. Comunicación oral. 15th World Fertilizer Congress of the International Scientific Centre for fertilizers (CIEC). Bucarest (Rumania).
3. Moral, F.J., Rebollo, F.J., Terrón, J.M. (2012). El modelo de Rasch y la agricultura de precisión. Aplicación al estudio de la fertilidad potencial en una parcela. Comunicación y póster. VI Congreso Ibérico de Agroingeniería. Évora (Portugal).
4. Terrón, J.M., Moral, F.J., Marques da Silva, J.R. (2013). Analysis of spatial pattern and temporal stability of soil apparent electrical conductivity and relationship with yield in a soil of high clay content. Comunicación y poster. Congreso: Third Global Workshop on Proximal Soil Sensing 2013. Potsdam (Alemania).
5. Moral, F.J., Rebollo, F.J., Terrón, J.M. (2013). The integration of on-the-go measurements of soil apparent electrical conductivity in an objective probabilistic model for measuring soil fertility potential in an agricultural field. Comunicación y poster. Third Global Workshop on Proximal Soil Sensing 2013. Potsdam (Alemania).



**TÍTULO DE LA TESIS: Delimitación de Zonas de Manejo de Agricultura de Precisión a partir de medidas de Conductividad Eléctrica Aparente del Suelo mediante el uso de Sensores Móviles de Contacto**

**DOCTORANDO/A: Jose María Terrón López**

**ESCRITO RAZONADO DEL RESPONSABLE DE LA LÍNEA DE INVESTIGACIÓN**

(Ratificando el informe favorable del director. Sólo cuando el director no pertenezca a la Universidad de Córdoba).

La tesis doctoral realizada ha tenido como principal objetivo comprobar el uso de diferentes técnicas geoestadísticas para definir zonas homogéneas de manejo en parcelas agrícolas, basado en estimar las propiedades del suelo a partir de la conductividad del mismo, llegando a obtener los mapas de distribución espaciales de las variables estudiadas para generar zonas potenciales de manejo.

Los resultados obtenidos son satisfactorios y han dado lugar a tres publicaciones en revistas incluidas en el JCR en cuartiles Q1 y Q2..

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 15 de Marzo de 2013

Firma del responsable de línea de investigación

Manuel Sánchez de la Orden  
Fdo.: \_\_\_\_\_

## RESUMEN DE LA TESIS

**Título: “DELIMITACIÓN DE ZONAS DE MANEJO EN AGRICULTURA DE PRECISIÓN A PARTIR DE MEDIDAS DE CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO MEDIANTE EL USO DE SENsoRES MÓVILES DE CONTACTO”**

En Agricultura de Precisión (AP) se utilizan un conjunto de técnicas que permiten dar un tratamiento agrícola diferenciado a cada lugar de una parcela de cultivo en función de las características agronómicas del mismo. Los abonados, la siembra y los tratamientos fitosanitarios a dosis variable, la sectorización de los riegos, de las variedades, de los patrones o, incluso, la determinación de la rentabilidad zonal de los cultivos y la gestión de la trazabilidad de los mismos son algunas de sus múltiples aplicaciones.

La implantación efectiva de la AP requiere la identificación de zonas con características homogéneas (zonas de manejo) que puedan dar lugar a una producción potencial similar. Para ello, la aparición de equipos comerciales dotados de sensores de contacto para el muestreo de la conductividad eléctrica aparente del suelo ( $CE_a$ ), tanto superficial (0-30 cm) como profunda (0-90 cm), ha permitido a los agricultores disponer de un método rápido y poco costoso para obtener dicha información.

Con el fin de caracterizar la variabilidad espacial de las principales propiedades físicas y químicas del suelo a partir de los datos de  $CE_a$  y emplear esa información para determinar las zonas de manejo potenciales, se ha comprobado que el uso de diversas técnicas geoestadísticas univariantes o multivariantes, acompañadas de otros métodos de integración de la información, como son el análisis de los componentes principales o la utilización del modelo de Rasch como técnica de medida, pueden constituir unas herramientas importantes en el ámbito de la AP. De igual forma, cuando se tienen variables correlacionadas espacialmente, como ocurre habitualmente con las propiedades de interés agronómico, deben tenerse en cuenta esas relaciones. En ese sentido, el uso de las regresiones “convencionales”, en las cuales se ignora la componente geográfica de la información, no parece lo más adecuado. Más bien, sería lógico el uso de las denominadas regresiones ponderadas geográficamente (RPG), mediante las cuales es posible establecer las relaciones entre las variables en función de su posición geográfica, lo cual permite

categorizar la importancia de las mismas en cada lugar y decidir cuál es la más adecuada con el fin de estimar la fertilidad potencial del suelo.

En consecuencia, la combinación de técnicas geoestadísticas, el modelo de Rasch y las RPG, pueden constituir una de las formas más apropiadas y novedosas para delimitar, con una base racional, las zonas de las parcelas agrícolas con unas condiciones lo más homogéneas posibles.

A partir de los resultados obtenidos en los trabajos realizados en la parcela experimental se ha comprobado que tanto la conductividad eléctrica aparente superficial ( $CE_s$ ) como la profunda ( $CE_p$ ) son variables adecuadas para modelizar las propiedades de un suelo determinantes de su fertilidad.

También se ha observado que la  $CE_s$  es el parámetro más adecuado para realizar el análisis de la variabilidad temporal de la conductividad eléctrica aparente y relacionarlo con el mismo análisis referido a la producción de girasol en secano. Así mismo se ha encontrado una relación importante con algunas de las propiedades físico-químicas fundamentales del suelo ( contenidos en arcilla y arena, capacidad de intercambio catiónico y pH, principalmente).

La técnica de la regresión ponderada geográficamente, por la dependencia espacial existente entre las variables, puede ser usada para interpretar la variación espacial en ciertas propiedades de suelo así como su correlación con otras variables asociadas a lo largo de la parcela experimental.

Del estudio de la variabilidad temporal de las producciones del cultivo de girasol en la misma parcela experimental se deduce que existe una buena correlación entre los valores obtenidos en diferentes años si bien existen distorsiones debidas a factores externos, como son los daños provocados por las aves silvestres o la pluviometría.

Comparativamente se observa que, a lo largo del tiempo, los valores de los muestreos de  $CE_s$  presentan una mayor estabilidad que los de producción, por lo cual resulta ser un índice mucho más exacto de la medida de la fertilidad potencial del terreno agrícola.

Por último la alta correlación encontrada entre los resultados anteriores y los obtenidos por el modelo del Rasch permiten concluir que este último procedimiento matemático ofrece unos resultados muy fiables.

## ABSTRACT

**Title: DELINEATION OF MANAGEMENT ZONES IN PRECISION AGRICULTURE FROM SOIL APPARENT ELECTRICAL CONDUCTIVITY MEASUREMENTS USING CONTACT MOBILE SENSORS**

Different techniques are used in Precision Agriculture (PA) to manage the variability in each place of an agricultural field depending on the agronomic characteristics of any crop. Fertilization, planting and pesticide treatments to variable rate, the segmentation of irrigation, varieties or even determining zonal crop yield and traceability management are some of its many applications.

The effective implementation of PA requires the identification of areas with homogeneous characteristics (management zones) which lead to similar potential yield. To do that, new commercial equipments with contact sensors to measure shallow (0-30 cm) and deep (0-90 cm) soil apparent electrical conductivity ( $EC_a$ ) has provided to farmers with a quick and cheap method to obtain that information.

With the aim of characterizing the spatial variability of the main soil physical and chemical properties from  $EC_a$  data, and using this information to determine the potential management zones, the use of univariate and multivariate geostatistical algorithms and other methods to integrate the obtained information, as the principal component analysis or the Rasch model, can be important tools for the PA. Moreover, when the variables are spatially correlated, as those of interest in agronomic issues, the relationships have to be taken into account. In this sense, the use of conventional regressions, not considering the geographic component of the data, is not adequate. It is necessary to utilize Geographically Weighted Regressions (GWR) which consider the locations to establish the relationships between variables. This allows to categorize the importance of existing relationships at any place of the field and decide which variable is the more important to estimate potential soil fertility.

In consequence, the combination of geostatistical techniques, the Rasch model and GWR constitutes one of the most appropriate and novel way to delimit with a rational basis the more homogeneous areas in an agricultural field.

From results obtained in the works which were carried out in the experimental field, it has been verified that shallow ( $EC_s$ ) and deep ( $EC_d$ ) soil apparent electrical conductivity are adequate variables to model those soil properties which can inform us about its fertility. Particularly, it has been obtained that  $EC_s$  is the more adequate to perform the temporal variability analysis of apparent electrical conductivity and establish the relationship with the sunflower crop in a dryland field. Moreover, it is closely related to the main soil properties (clay and sand content, cation exchange capacity and pH).

The GWR method can be used to interpret the spatial variability between different soil properties across the experimental field as the spatial dependency between soil variables is very important.

From the study about the crop yield temporal variability in the same field it is evident that a good relationship between years exists, despite some differences due to climate or wild birds attacks. It has been also observed that  $EC_s$  values are more stable than crop yield values, so  $EC_s$  is a proper index to estimate potential soil fertility.

Finally, the high correlation between results obtained by combining principal component analysis and unsupervised classification with those obtained by the Rasch model to generate management zones allows us to conclude that this method can also generate reliable results.

## INDICE

1. AGRADECIMIENTOS	20
2. INTRODUCCIÓN GENERAL	22
2.1. INTRODUCCIÓN	22
2.2. OBJETIVOS	27
2.3. REVISIÓN TEMÁTICA	29
2.3.1. LA AGRICULTURA DE PRECISIÓN	29
2.3.2. LA CE <sub>a</sub> COMO HERRAMIENTA DE MEDIDA DE LA FERTILIDAD DE UN SUELO.	31
2.3.3. USO DE SENsoRES EN AGRICULTURA DE PRECISIÓN.	34
2.3.4. USO DE LA GEOESTADÍSTICA EN LA ELABORACIÓN DE MAPAS DE PROPIEDADES DE SUELOS.	36
2.3.5. LA REGRESIÓN PONDERADA GEOGRÁFICAMENTE	37
2.3.6. EL MODELO DE RASCH	38
3. "DELINEATION OF MANAGEMENT ZONES USING MOBILE MEASUREMENTS OF SOIL APPARENT ELECTRICAL CONDUCTIVITY AND MULTIVARIATE GEOSTATISTICAL TECHNIQUES"	41
4. "SOIL APPARENT ELECTRICAL CONDUCTIVITY AND GEOGRAPHICALLY WEIGHTED REGRESSION FOR MAPPING SOIL"	52
5. "SITE-SPECIFIC MANAGEMENT ZONES BASED ON THE RASCH MODEL AND GEOSTATISTICAL TECHNIQUES"	67
6. ESTUDIO DE LA VARIABILIDAD TEMPORAL DE LA CE <sub>s</sub> Y DE LA PRODUCCIÓN DEL CULTIVO DE GIRASOL EN LA PARCELA DE ENSAYO.	77
6.1. INTRODUCCIÓN	78
6.2. MATERIALES Y MÉTODOS	79
6.3. RESULTADOS Y DISCUSIÓN	83

6.3.1. VARIABILIDAD TEMPORAL DE LA CE <sub>S</sub>	83
6.3.2. VARIABILIDAD TEMPORAL DE LAS PRODUCCIONES.	92
6.3.3. ESTABILIDAD TEMPORAL DE LA CE <sub>S</sub> Y DE LAS PRODUCCIONES.	100
6.3.4. COMPARACIÓN ENTRE LA DISTRIBUCIÓN ESPACIAL DE LA VARIABLE LATENTE “FERTILIDAD POTENCIAL” OBTENIDA POR EL MODELO DE RASCH Y LA COMPONENTE PRINCIPAL PRIMERA DEL ANÁLISIS TEMPORAL ENTRE LA CE <sub>S</sub> N Y EL RSN.	106
6.4. REFERENCIAS BIBLIOGRÁFICAS	108
<b>7. CONCLUSIONES GENERALES.</b>	<b>109</b>
7.1. “USO DE LAS MEDIDAS DE LA CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO COMO BASE PARA LA DETERMINACIÓN DE DIFERENTES ZONAS DE MANEJO”.	109
7.2. “CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO Y REGRESIÓN PONDERADA GEOGRÁFICAMENTE PARA LA ELABORACIÓN DE MAPAS DE SUELOS”.	110
7.3. “EL MODELO DE RASCH Y LA AGRICULTURA DE PRECISIÓN. APlicación AL ESTUDIO DE LA FERTILIDAD POTENCIAL EN UNA PARCELA”.	111
7.4. VARIABILIDAD TEMPORAL DE LAS MEDIDAS DE CE <sub>S</sub> Y DE LAS PRODUCCIONES EN EL CULTIVO DE GIRASOL DE SECANO.	112
<b>8. REFERENCIAS BIBLIOGRÁFICAS</b>	<b>113</b>

## TABLA DE ABREVIATURAS

ABREVIATURA	SIGNIFICADO
ACP	Análisis de Componentes Principales
AP	Agricultura de Precisión
CE <sub>a</sub>	conductividad eléctrica aparente
CE <sub>p</sub>	Conductividad Eléctrica Aparente Profunda
CE <sub>s</sub>	Conductividad Eléctrica Aparente Superficial
CE <sub>N</sub>	Conductividad Eléctrica Aparente Superficial Normalizada
CIC	Capacidad de Intercambio Catiónico
CP	Componente Principal
EC <sub>d</sub>	Electric Conductivity Deep
EC <sub>s</sub>	Electric Conductivity Shallow
EEUU	Estados Unidos de América
EGNOS	European Geostationary Navigation Overlay Service
GIS	Geographic Information System
GNSS	Global Navigation Satellite Systems
GPS	Global Positioning System
GWR	Geographically Weighted Regression
NRC	National Research Council
PORC	Porcentaje
RPG	Regresión Ponderada Geográficamente
RSN	Rendimiento Seco Normalizado
SIG	Sistemas de Información Geográfica
SSCM	Site-Specific Crop Management
VRT	Variable Rate Technology

## INDICE DE FIGURAS

Figura 1 - Semivariogramas experimentales y teóricos para los muestreos de la conductividad eléctrica aparente superficial normalizada, CE <sub>s</sub> N. A) 19/02/2009, B) 24/04/2009, C) 27/01/2011.	85
Figura 2 – Mapas raster de 5 m de resolución espacial de los muestreos de la conductividad eléctrica aparente superficial normalizada, CE <sub>s</sub> N. A) 19/02/2009, B) 24/04/2009, C) 27/01/2011.	86
Figura 3 – Mapas raster de 5 m de resolución de las componentes principales primera (A), segunda (B) y tercera (C), obtenidas del análisis de componentes principales de la conductividad eléctrica aparente superficial normalizada, CE <sub>s</sub> N.	91
Figura 4 – Semivariogramas experimentales y teóricos para el rendimiento seco normalizado, RSN, de los años A) 2007, B) 2010, C) 2011.	95
Figura 5 – Mapas raster de 5 m de resolución espacial del rendimiento seco normalizado, RSN. A) 2007, B) 2010, C) 2011.	96
Figura 6 – Mapas raster de 5 m de resolución de las componentes principales primera (A), segunda (B) y tercera (C), obtenidas del análisis de componentes principales rendimiento seco normalizado, RSN.	99
Figura 7 – Mapas raster de 5 m de resolución espacial del análisis de componentes principales de la componente principal primera de la conductividad eléctrica aparente superficial normalizada, CE <sub>s</sub> N, y la componente principal primera el rendimiento seco normalizado, RSN. A) CE <sub>s</sub> RSNACP <sub>1</sub> , B) CE <sub>s</sub> RSNACP <sub>2</sub> .	102
Figura 8 – Semivariograma experimental y teórico de la correlación local obtenida en los puntos muestrales considerados, para la regresión ponderada geográficamente realizada entre las componentes principales primeras obtenidas en los análisis de variabilidad temporal de la conductividad eléctrica aparente normalizada, CE <sub>s</sub> N, y del rendimiento seco normalizado, RSN, obtenidos mediante la técnica de análisis de componentes principales.	104

Figura 9 – Mapa raster de 5 m de resolución espacial de la correlación local  $R^2$  entre la componente principal primera de la conductividad eléctrica aparente normalizada, CE<sub>s</sub>N, y la del rendimiento seco normalizado, RSN. 104

Figura 10 – Mapa raster de 5 m de resolución espacial de la componente principal primera del análisis de componentes principales de la CE<sub>s</sub>N y el RSN y la variable “fertilidad potencial” obtenida por el Modelo de Rasch. 107

## INDICE DE TABLAS

Tabla 1 – Estadísticos de los muestreos de conductividad eléctrica aparente superficial, CE <sub>s</sub> (mS/m).	83
Tabla 2 – Estadísticos de los muestreos de conductividad eléctrica aparente superficial normalizada, CE <sub>sN</sub> .	84
Tabla 3 – Parámetros correspondientes a los semivariogramas teóricos para los muestreos de la conductividad eléctrica aparente superficial normalizada, CE <sub>sN</sub> , efectuados los días 19/02/2009, 24/04/2009 y 27/01/2011.	84
Tabla 4 - Matriz de covarianza obtenida del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada, CE <sub>sN</sub> .	87
Tabla 5 - Matriz de correlación obtenida del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada, CE <sub>sN</sub> .	87
Tabla 6 – Valores propios obtenidos del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada, CE <sub>sN</sub> .	87
Tabla 7 – Vectores propios obtenidos del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada CE <sub>sN</sub> .	88
Tabla 8 – Datos climáticos de la estación meteorológica de la Finca “la Orden”.	90
Tabla 9 – Estadísticos de los valores de cosecha en rendimiento seco, RS (T/ha).	93
Tabla 10 – Estadísticos de las producciones en rendimiento seco normalizado, RSN.	94
Tabla 11 – Parámetros correspondientes a los semivariogramas teóricos para el rendimiento seco normalizado, RSN, de los años 2007, 2010 y 2011.	94
Tabla 12 - Matriz de covarianza obtenida del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.	97
Tabla 13 - Matriz de correlación obtenida del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.	97

Tabla 14 – Valores propios obtenidos del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.	97
Tabla 15 – Vectores propios obtenidos del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.	98
Tabla 16 - Matriz de covarianza obtenida del análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE <sub>s</sub> N y rendimiento seco normalizado, RSN.	101
Tabla 17 - Matriz de correlación obtenida del análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE <sub>s</sub> N y rendimiento seco normalizado, RSN.	101
Tabla 18 – Valores propios obtenidos en el análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE <sub>s</sub> N y rendimiento seco normalizado, RSN.	101
Tabla 19 – Vectores propios obtenidos en el análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE <sub>s</sub> N y rendimiento seco normalizado, RSN.	102
Tabla 20 – Superficies y porcentajes de ocupación con respecto al área total de la parcela experimental de los diferentes intervalos de valores del coeficiente de determinación de la regresión ponderada geográficamente entre la componente primera del análisis de componentes principales de la CE <sub>s</sub> N y el RSN.	105

**Todos los trabajos realizados en esta Tesis han sido desarrollados en el  
“Centro de Investigación La Orden-Valdesequera”, dependiente de la  
Consejería de Empleo, Empresa e Innovación del Gobierno de Extremadura.**

**El compendio de publicaciones científicas que constituyen el armazón de la  
presente Tesis, se han desarrollado en el seno del Proyecto de Investigación  
denominado “Variabilidad Espacial y Optimización de la Producción del  
Cultivo de Colza en Siembra Directa Mediante Agricultura de Precisión”, nº de  
proyecto PRI07B080, el cual ha sido cofinanciado por la Junta de Extremadura  
y el Fondo Europeo de Desarrollo Regional de la Unión Europea, a través de la  
convocatoria competitiva realizada a través del III Plan Regional de I+D de  
Extremadura (III PRI).**

**Parte de los trabajos contemplados en el Capítulo 6, también se han  
desarrollado en el Proyecto de Investigación “Uso de Sensores de Vegetación  
en Tiempo Real y de Técnicas de Agricultura de Precisión para la Aplicación  
Variable de Abonos en Cultivos Extensivos” nº de proyecto LOI1102002 el  
cual ha sido cofinanciado por la Junta de Extremadura y el Fondo Europeo de  
Desarrollo Regional de la Unión Europea a través de la convocatoria interna  
del Gobierno de Extremadura.**



**UNIÓN EUROPEA**  
Fondo Europeo de  
Desarrollo Regional



**la orden**  
centro de investigación  
la orden - valdesequera

## **1. AGRADECIMIENTOS**

Esta Tesis no habría sido posible sin la colaboración de un grupo de investigadores e Instituciones que desde el primer momento han creído y han apoyado las potencialidades de la Agricultura de Precisión.

En primer lugar he de agradecer a mis directores de Tesis, Francisco Moral, José Rafael Marques da Silva y Javier Rebollo, por su continuo apoyo y entusiasmo, gracias al cual se ha creado un grupo de investigadores, pero sobre todo, de amigos, que compartimos nuestra ilusión por la Agricultura de Precisión. También al resto de compañeros del Grupo de Investigación “Alcántara”, en particular a Juan Morillo, magnífico profesor que con sus enseñanzas, amistad e incondicional ayuda, ha contribuido de forma importante a mi desarrollo profesional.

Mi agradecimiento al Centro de Investigación La Orden-Valdesequera, personalizado en Henar Prieto, que, durante su etapa como Directora del mismo, tuvo fe en mis planteamientos y los apoyó decididamente, dotando al Centro de un equipamiento muy completo, lo cual lo ha posicionado en la vanguardia de la investigación en este área, tanto a nivel nacional como europeo, y ello me ha permitido desarrollar este trabajo.

A mi compañero de La Orden Juan Gragera, cuyas explicaciones sobre algunos conceptos estadísticos han sido de suma utilidad.

A mis amigos del INTA Manfredi de Argentina, que supieron acogerme durante mi estancia con ellos y que tuvieron todo tipo de atenciones durante el tiempo que estuve allí, en una etapa muy difícil de mi vida. He de mencionar expresamente a Mario Bragachini, el alma de la Agricultura de Precisión en ese país, a Andrés Méndez, con el que compartí unas experiencias profesionales inolvidables, a Juan Pablo Vélez y al resto de los compañeros, con ellos percibí que el camino que emprendía en esos momentos era el correcto.

A Don Manuel Pérez, propietario de la Finca “Cerro del Amo”, por haber permitido el desarrollo de los proyectos de investigación en sus tierras.

Cómo no, he de agradecer especialmente a Daniel Becerra, cuya ayuda en el desarrollo de los trabajos, durante el tiempo que estuvo con nosotros en La Orden, fue clave. Al

personal de la TEA de la Orden, con los que he compartido agotadoras jornadas de trabajo de campo, mostrando una profesionalidad que sólo conocemos los que trabajamos en el Centro.

También he de mencionar a mis actuales compañeros Francisco Galea, Jorge Blanco, Francisco Pérez y Jose Angel Salgado, que, aunque llevamos poco tiempo trabajando juntos, me han sabido comprender y se han contagiado de mi pasión por la Agricultura de Precisión.

Un recuerdo especial para mi padre que siempre me apoyó y dedicó todo su esfuerzo y su vida a que sus hijos tuviéramos todas las oportunidades posibles, y lo consiguió.

A mi madre, como no, que siempre ha sido comprensiva y cariñosa y que, de alguna forma, marcó mi vocación profesional con el recuerdo de mi abuelo.

A mi hermana Lola, que tanto apoyo me da en mi vida diaria, que ha contribuido a que pueda dedicar el mayor tiempo posible a mi trabajo.

Y, por fin, a mis hijos, de los que tan orgulloso estoy, por el cariño que me dan, que es el combustible para mantenerme a flote y con ilusión y, como no, a Luisa, con la que comparto mi vida, porque se ha convertido en uno de mis pilares básicos, y gracias a ella soy capaz de seguir adelante y de superar todas las adversidades. A Luisa y a mis hijos dedico este trabajo.

## **2. INTRODUCCIÓN GENERAL**

### **2.1. INTRODUCCIÓN**

En Agricultura de Precisión (AP) se utilizan un conjunto de técnicas que permiten dar un tratamiento agrícola diferenciado a cada lugar de una parcela de cultivo en función de las características agronómicas del mismo. Los abonados, la siembra y los tratamientos fitosanitarios a dosis variable (VRT, “Variable Rate Technology” en literatura anglosajona), la sectorización de los riegos, de las variedades, de los patrones o, incluso, la determinación de la rentabilidad zonal de los cultivos y la gestión de la trazabilidad de los mismos son algunas de sus múltiples aplicaciones. Es un área en continua evolución a medida que la tecnología avanza, surgiendo nuevas aplicaciones en las que la investigación es imprescindible a fin de adaptarlas a la problemática específica del entorno agrícola de cada lugar.

Una buena denominación de estas técnicas es la de “Site-Specific Farming” o “Site-Specific Agriculture”, cuya traducción al castellano no es fácil pero cuyo concepto es muy exacto, porque en definitiva consiste en dar un tratamiento determinado en cada sitio concreto (o específico).

En realidad, la AP es tan antigua como la propia actividad agraria. Desde los inicios de la civilización, los primeros agricultores ya hacían AP desde el momento que concibieron la parcela agrícola como una porción de terreno de características más o menos homogéneas en toda su extensión, dedicando cada zona al uso que consideraban más adecuado. En este sentido, incluso las unidades de superficie hacían referencia a la capacidad de trabajo del agricultor (fanega de puño, fanega de marco, etc.) en función de los medios de que disponía.

Con el comienzo de la mecanización agraria es cuando, para un mejor aprovechamiento de la maquinaria, surge la necesidad de ampliar el tamaño de las parcelas, efecto que se va haciendo más acusado a medida que el tamaño de los equipamientos aumentan. Ello tuvo como efecto colateral la pérdida de “precisión” en las diferentes tareas, derivada del aumento de la variabilidad que conlleva la agrupación de zonas de manejo homogéneas en parcelas mayores.

Con la aparición de las nuevas tecnologías de la informática y de las comunicaciones surgen los Sistemas de Información Geográfica (SIG, o “GIS” en literatura anglosajona) y los sistemas GNSS (“Global Navigation Satellite Systems”), de los cuales, el más difundido, es el Sistema de Posicionamiento Global (“Global Positioning System” o “GPS”), abriéndose nuevos horizontes, con un sinfín de nuevas aplicaciones en el ámbito agrícola. En este punto es cuando podemos considerar que aparece la AP desde la perspectiva que tenemos actualmente de la misma.

El futuro desarrollo e implantación de las técnicas de AP depende de las ventajas de diverso tipo que puedan aportar al agricultor. Entre ellas cabe destacar la mejora en la sostenibilidad medioambiental, las económicas y las relacionadas con la mejora de la gestión empresarial que conlleva su implantación.

La AP permite disminuir de forma acentuada el impacto ambiental de la actividad agraria al facilitar una distribución racional de los insumos, reduciendo la contaminación del medio natural ya que minimiza los excesos en la utilización de productos químicos, tanto fertilizantes como plaguicidas. Paralelamente, esta reducción de insumos de procedencia industrial conlleva un ahorro energético en la producción, el transporte y la distribución de los mismos. Es importante señalar las diferentes estrategias que se pueden utilizar en este campo, que van desde la aplicación de abonos a dosis variable en función de la fertilidad potencial del suelo, el uso de sensores remotos para la detección de carencias en el cultivo o el uso de sensores de vegetación cercanos que permitan la determinación y tratamiento en tiempo real de las necesidades nutritivas del cultivo o, incluso, los tratamientos fitosanitarios o herbicidas.

Adicionalmente, un elemento importante en la AP es el guiado de maquinaria, el cual permite un ahorro energético, al reducir los solapes en determinadas labores agrícolas, aumenta el rendimiento en su uso (laboreo nocturno, con niebla o polvo) y reduce la fatiga del conductor.

En los inicios de la AP la recogida de la información necesaria para evaluar la variabilidad espacial de una parcela pasaba, casi obligatoriamente, por la obtención de mapas de cosecha, de forma que, a medida que se tenía una serie temporal más larga de los

mismos, se alcanzaba mayor exactitud en las estimaciones. Desde la aparición de equipos comerciales de medición en campo de la conductividad eléctrica aparente de los suelos ( $CE_a$ ) esto no es tan necesario, porque su uso como herramienta de evaluación de la variabilidad espacial de las propiedades físico-químicas de los suelos, al tratarse de una medida que puede hacerse antes de la implantación de un cultivo, supone un acortamiento importante del periodo de decisiones por parte del agricultor, pudiendo éste empezar a realizar la siembra o la fertilización a dosis variable de forma inmediata. Hasta ahora ha resultado difícil convencer al agricultor para que comience a implantar la AP, si necesita hacer un cultivo previo para tener la información necesaria sobre la variabilidad de la productividad de las parcelas de su explotación; con la  $CE_a$  como herramienta para la obtención de la misma, el argumento resulta más atractivo.

La implantación efectiva de la AP requiere la identificación de zonas con características homogéneas (zonas de manejo) que puedan dar lugar a una producción potencial similar. Sin embargo, esa tarea no es fácil, debido a la compleja interacción de los factores que pueden afectar a los cultivos. Además, la representación de las diferentes propiedades del suelo de interés con una resolución adecuada es tediosa y cara, por la necesidad de contar con una cantidad de muestras de suelo suficientes y el requerimiento de modelos matemáticos eficientes para que, por un lado, las estimaciones en los puntos muestrales sean precisas y, por otro, se puedan combinar variables que tienen diferentes unidades.

Con el fin de caracterizar la variabilidad espacial de las principales propiedades físicas y químicas del suelo y emplear esa información para determinar las zonas de manejo potenciales, sería deseable la propuesta de diferentes técnicas para considerar las diversas fuentes de información de las que se puede disponer. Por ello, es necesario comprobar si el uso de diversas técnicas geoestadísticas univariantes o multivariantes, acompañadas de otros métodos de integración de la información, como son el análisis de los componentes principales o la utilización del modelo de Rasch como técnica de medida, pueden constituir unas herramientas importantes en el ámbito de la AP. De igual forma, cuando se tienen variables correlacionadas espacialmente, como ocurre habitualmente con las propiedades de interés agronómico, deben tenerse en cuenta esas relaciones. En ese sentido, el uso de la

regresión convencional, en la cual se ignora la componente geográfica de la información, no parece lo más adecuado. Más bien, sería lógico el uso de la denominada regresión ponderada geográficamente (RPG), “Geographically Weighted Regression” o “GWR” en literatura anglosajona, mediante la cual es posible establecer las relaciones entre las variables en función de su posición geográfica, lo cual permite categorizar la importancia de las mismas en cada lugar y decidir cuál es la más adecuada con el fin de estimar la fertilidad potencial del suelo.

En consecuencia, la combinación de técnicas geoestadísticas, el modelo de Rasch y las RPG pueden constituir una de las formas más apropiadas y novedosas para delimitar con una base racional las zonas de las parcelas agrícolas con unas condiciones lo más homogéneas posibles.

La presente tesis, presentada en la modalidad de “compendio de publicaciones”, se fundamenta en tres artículos publicados recientemente:

- **Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques.**

Soil & Tillage Research, 106 (2010) 335–343, EDITORIAL ELSEVIER.

DOI: 10.1016 /j.still.2009.12.002

Autores: F.J. Moral, J.M. Terrón, J.R. Marques da Silva

Clasificación JCR:

Factor de Impacto año 2010 = 2.100

Categoría: SOIL SCIENCE cuartil Q2

- **Soil apparent electrical conductivity and geographically weighted regression for mapping soil**

Precision Agriculture (2011) 12:750–761, EDITORIAL SPRINGER

DOI 10.1007/s11119-011-9218-5

Autores: J. M. Terrón, J. R. Marques da Silva, F. J. Moral, Alfonso García-Ferrer

Clasificación JCR:

Factor de Impacto año 2011 = 1,549

Categoría: AGRICULTURE, MULTIDISCIPLINARY cuartil Q1

- **Site-specific management zones based on the Rasch model and geostatistical techniques**

Computers and Electronics in Agriculture 75 (2011) 223–230, EDITORIAL ELSEVIER.

DOI: 10.1016/j.compag.2010.10.014

Autores: F.J. Moral, J.M. Terrón, F.J. Rebollo

Clasificación JCR:

Factor de Impacto año 2011 = 1,846

Categoría: AGRICULTURE, MULTIDISCIPLINARY cuartil Q1

COMPUTER SCIENCE, INTERDISCIPLINARY APPLICATIONS cuartil Q2

## 2.2. OBJETIVOS

El principal objetivo de la presente tesis es comprobar si el uso de diferentes técnicas con base estadística puede ser apropiado para definir zonas de manejo homogéneas en las parcelas agrícolas, lo cual es fundamental para el inicio de la aplicación de la AP en las mismas.

Para alcanzar este objetivo fundamental es preciso lograr una serie de objetivos secundarios, todos ellos complementarios entre sí, que son:

- Analizar el uso de técnicas geoestadísticas univariantes y multivariantes para caracterizar y mejorar las estimaciones de las propiedades del suelo, considerándose la conductividad aparente del suelo como variable secundaria. [*El cumplimiento de este objetivo se ha abordado en el siguiente artículo: "Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques". Soil & Tillage Research 2010. 106, 335-343.*]

- Determinar si la conductividad eléctrica aparente del suelo, sola o combinada con otras variables, constituye una buena alternativa para lograr unas representaciones gráficas de alta resolución de las principales propiedades del suelo mediante el uso de la RPG. [*El cumplimiento de este objetivo se ha abordado en el siguiente artículo: "Soil apparent electrical conductivity and geographically weighted regression for mapping soil". Precision Agriculture 2011. 12, 750-761.*]

- Utilizar los mapas de distribución espacial de las variables físicas y químicas del suelo para generar las zonas potenciales de manejo, mediante la determinación de los componentes principales y el uso de algoritmos de agrupamientos. [*El cumplimiento de este objetivo se ha abordado en los siguientes artículos: "Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques". Soil & Tillage Research 2010. 106, 335-343; y "Site-specific management zones based on the Rasch model and geostatistical techniques". Computers and Electronics in Agriculture 2011. 75, 223-230.*]

- Emplear el modelo de Rasch como medio objetivo para la obtención de la información relativa al suelo, integrando a las variables que pueden condicionar su fertilidad.

[*El cumplimiento de este objetivo se ha abordado en el siguiente artículo: "Site-specific management zones based on the Rasch model and geostatistical techniques". Computers and Electronics in Agriculture 2011. 75, 223-230.]*

- Comprobar si las medidas de CE<sub>a</sub> son suficientemente estables a lo largo del tiempo para permitir su uso como indicador característico de la potencialidad agrícola de los suelos.

[*El cumplimiento de este objetivo se ha abordado en el capítulo 6 de la Tesis "Estudio de la Variabilidad Temporal de la CE<sub>s</sub> y de la Producción del Cultivo de Girasol en la Parcela de Ensayo", el cual ha sido aceptado y se ha presentado con el título "Analysis of spatial pattern and temporal stability of soil apparent electrical conductivity and relationship with yield in a soil of high clay content" en el próximo "Third Global Workshop on Proximal Soil Sensing 2013" que se celebrará desde el 26 al 29 de mayo de 2013 en la ciudad de Potsdam (Alemania) en forma de comunicación escrita y póster.]*

## **2.3. REVISIÓN TEMÁTICA**

### **2.3.1. LA AGRICULTURA DE PRECISIÓN**

Normalmente, en la gran mayoría de los suelos agrícolas, existe una importante variabilidad espacial de sus principales propiedades físicas y químicas, debido a la gran cantidad de procesos físicos, biológicos y químicos que actúan simultáneamente con una intensidad muy variable. El tratamiento o manejo uniforme que se hace usualmente en una parcela agrícola no tiene en cuenta esa variabilidad espacial, por lo que parece evidente que no es la estrategia de manejo más efectiva.

En el afán de aportar los factores de producción estrictamente necesarios para que se exprese el máximo desarrollo potencial del cultivo haciendo uso de información georeferenciada, nace la AP en los Estados Unidos de América (EEUU) a principios de los años 90 (Morillo, 2003).

Se considera que la AP es la forma más viable para la consecución de una agricultura más eficiente y sostenible (Corwin et al., 1999). Particularmente, el manejo localizado de un cultivo (“Site-Specific Crop Management” en lengua inglesa, “SSCM”) es una variante de la misma por la que las decisiones sobre la aplicación de insumos y las prácticas agronómicas se llevan a cabo para optimizar los requerimientos agronómicos del cultivo en función de su situación en la parcela.

Desde la segunda mitad de los años 80, se han empleado distintos términos para referirse a la AP, empezando por agricultura de base (Reicheberger y Russnogle, 1989), agricultura del suelo (Carr et al., 1991; Larson y Robert, 1991), tecnología de dosis variable (“VRT”) (Sawyer, 1994), variabilidad espacial, precisión, prescripción, o lugar de producción de cultivo (Schueller, 1991) y gestión de cultivos específica (Pierce y Sadler, 1997). Todos estos vocablos tienen en común el concepto de gestión de la variabilidad de la parcela (Morillo, 2003). Otros, usados en la segunda conferencia internacional de AP celebrada en Minneapolis en el año 1994, hacen referencia en su denominación a las tecnologías que le sirven de apoyo: agricultura asistida por ordenador, agricultura por ordenador, agricultura satelital o agricultura sostenible de alta tecnología. Lowenberg-DeBoer (2000), director del

“Site Specific Management Centre” de la Universidad de Purdue (Indiana, EEUU), clarifica el alcance de estos conceptos y considera a la AP como la automatización del “SSCM”, usando ordenadores, sensores y otros equipos.

La intención en la AP es relacionar los insumos agrícolas y las prácticas culturales dentro de una misma parcela para conocer la operación idónea, en el sitio apropiado, en el momento adecuado y de la manera correcta (Pierce et al., 1994).

Robert et al. (1994) considera la AP (“SSCM”) como un sistema de gestión agrícola basado en la tecnología y la información para identificar, analizar y gestionar la variabilidad espacial y temporal dentro de la parcela para optimizar su rentabilidad, sostenibilidad y la protección del medio ambiente.

En el Consejo Nacional de Investigación de EEUU (“NRC”), la Comisión de Agricultura define la agricultura de precisión como la estrategia de gestión que utiliza información tecnológica para obtener datos de distintas fuentes para el apoyo a la toma de decisiones relacionadas con la producción de los cultivos (“NRC”, 1997). Esta definición resalta la dimensión informativa de la AP y recalca el papel de las tecnologías, pero por el contrario no hace el énfasis necesario en la gestión de la variabilidad espacial y temporal.

Bragachini et al. (1998) definen la AP como un conjunto de actividades que incluyen la recolección y manejo de información, la cual permite la toma de decisiones económicas y ambientales, apropiadas para la producción de cultivos.

Según el Congreso de EEUU (1998), la AP se define como un sistema de información y producción agrícola diseñado para aumentar a largo plazo mediante una gestión diferenciada, el rendimiento, la productividad y la rentabilidad, minimizando por otro lado los efectos colaterales para la fauna silvestre y el medioambiente.

Para Pierce y Nowak (1999), la agricultura de precisión es la aplicación de tecnologías y principios para gestionar temporal y espacialmente la variabilidad de todos aquellos aspectos relacionados con la producción con el propósito del incremento de cosecha y la calidad medioambiental.

Todos estos conceptos de AP tienen en común la necesidad de conocer, manejar y considerar la variabilidad espacial de los principales factores que, de una u otra forma, influyen en la productividad potencial de una parcela agrícola y en su sostenibilidad económica y medioambiental.

### **2.3.2. LA CE<sub>a</sub> COMO HERRAMIENTA DE MEDIDA DE LA FERTILIDAD DE UN SUELO.**

El “SSCM” se basa en la delineación de zonas de manejo en la parcela considerada, las cuales deben ser áreas con características similares, tales como la textura, topografía, niveles de nutrientes, etc. Sin embargo, la definición precisa de esas zonas no es fácil, ya que intervienen diversos factores, interaccionando de forma dinámica, susceptibles de afectar al rendimiento del cultivo.

El “SSCM” se fundamenta en el uso de las tecnologías electrónicas y de la información para incorporar, gestionar y analizar la gran cantidad de datos relativos al suelo y al cultivo, necesarios para conocer las variaciones espaciales y temporales que ocurren dentro de una parcela. El uso de técnicas que sean eficientes para la determinación de las variaciones de las propiedades del suelo es imprescindible para la implantación de un “SSCM”.

El muestreo tradicional del suelo es laborioso y costoso, no siendo adecuado para la obtención de un número de datos suficiente que pueda servir como base para una delineación precisa de diferentes áreas de la parcela. Otras fuentes de información más eficientes, tanto por el aporte de datos como por su facilidad de obtención, son necesarias desde la perspectiva de un “SSCM”. En este sentido, la medida de la CE<sub>a</sub> constituye una de las formas más eficientes de trasladar el “SSCM” desde la teoría a la realidad (Corwin y Lesch, 2003). La CE<sub>a</sub> puede ser medida intensivamente de forma fácil y barata, estando normalmente relacionada con diferentes propiedades físico-químicas en distintos tipos de suelos (Sudduth et al., 2005). De esta forma, la CE<sub>a</sub> puede emplearse para mejorar la estimación de muchas variables edáficas, cuando existe una correlación espacial.

Según McNeill (1992) la CE<sub>a</sub> es la medida de la capacidad del suelo de conducir una corriente eléctrica. Se encuentra afectada por la combinación de propiedades físico-químicas, incluyendo sales solubles, contenido de arcilla y su mineralogía, contenido de agua de suelo, densidad del suelo, materia orgánica y temperatura de suelo. Por ello, la medida de la CE<sub>a</sub> ha sido usada a nivel de campo para delimitar la variación espacial de varias propiedad edáficas, como salinidad de suelo, contenido de arcilla o profundidad a capas ricas en arcilla, contenido de agua del suelo, profundidad de sedimentación de arenas y materia orgánica (Corwin y Lesch 2005a). Desde su uso inicial para medir la salinidad de suelo, la aplicación agrícola de CE<sub>a</sub> ha evolucionado, siendo un medio de establecer la variación espacial de las principales propiedades físico-químicas del suelo que afectan a la misma. La medida de CE<sub>a</sub> del suelo es un método rápido, fiable y accesible, y sus valores, a menudo, están, aunque no siempre, relacionados con la producción del cultivo. Por estos motivos, su medida se encuentra entre las herramientas usadas con más frecuencia para la caracterización espacio-temporal de propiedades edáficas y antropogénicas de suelo (Corwin y Lesch 2005a).

Cook and Walker (1992) definieron la CE<sub>a</sub> como la media ponderada en profundidad de la conductividad eléctrica global del suelo. En otras palabras, es la conductividad eléctrica media integrada entre diferentes profundidades del suelo; la profundidad depende del instrumento usado.

Anderson-Cook et al (2002) dedujeron que la CE<sub>a</sub> del suelo medida con métodos de inducción electromagnética, por sí misma, puede ser usada para clasificar el suelo en amplias categorías con una precisión aproximada del 85 %, y, si se combina con datos de producción del cultivo la precisión de la clasificación aumenta al 90 %.

Sudduth et al. (2005) demostraron que las correlaciones de la CE<sub>a</sub> con el contenido de arcilla y la capacidad de intercambio catiónico (CIC) eran generalmente altas en todas las parcelas estudiadas. También obtuvieron que otras propiedades del suelo, como la humedad y los contenidos de limo, arena y carbono orgánico, estaban altamente relacionadas con la CE<sub>a</sub> en algunas parcelas de estudio, pero no en otras. Las regresiones que estiman la arcilla y la CIC en función de la CE<sub>a</sub> en todas las parcelas de estudio eran razonablemente precisas ( $R^2$

< 0.55). Así, puede ser factible establecer relaciones entre  $CE_a$  y arcilla y CIC que serían aplicables en muchos tipos de suelo y condiciones climáticas.

Aimrun et al. (2009) encontraron variaciones de  $CE_a$  respecto a la posición topográfica del suelo, aumentando en las zonas bajas. También encontraron una relación significativa entre  $CE_a$  y el contenido de arcilla pudiéndose además ser empleada para estimar el fosforo disponible, el potasio intercambiable, el magnesio y la producción de peso seco de maíz, habiendo diferencias en la correlación existente entre la  $CE_a$  superficial ( $CE_s$ ) y profunda ( $CE_p$ ) y las diferentes variables. Así  $CE_s$  estaba fuertemente relacionada con el K intercambiable ( $R^2 = 0.726$ ); sin embargo,  $CE_p$  estaba muy influida por el P disponible, el K intercambiable, la arcilla y el Mg, con un coeficiente de determinación de 0.997. La producción de peso seco de maíz podía ser estimada mediante  $CE_p$  con un coeficiente de determinación de 0.772.

Corwin y Lesch (2005b) obtuvieron una alta correlación entre  $CE_a$  y algunas propiedades del extracto de saturación de suelo ( $Cl^-$ ,  $HCO_3^-$ ,  $SO_4^{2-}$ ,  $Na^+$ ,  $K^+$  y  $Mg^{2+}$ ),  $Na^+$  intercambiable y la relación de adsorción de sodio. Sin embargo, las correlaciones eran bajas con otras propiedades, como el contenido de agua, la densidad del suelo, porcentaje de arcilla, porcentaje de saturación, porcentaje de sodio intercambiable, Mo,  $CaCO_3$ , yeso, N total,  $Ca^{2+}$  en el extracto de saturación y cationes intercambiable ( $K^+$ ,  $Ca^{2+}$  y  $Mg^{2+}$ ). La CIC estaba menos correlacionada positivamente con la  $CE_a$ , pero era todavía significativa con un nivel  $p \leq 0.05$ .

Según Fraisse et al. (2001), el rendimiento potencial de un cultivo está altamente relacionado con la cantidad de agua disponible para las plantas. Así, su variabilidad puede ser aproximada sobre la base de las principales propiedades físicas del suelo y la topografía. La  $CE_a$  resulta un excelente indicador de este parámetro al tener una proporcionalidad directa con el contenido de humedad del suelo en suelos no salinos.

### **2.3.3. USO DE SENSORES EN AGRICULTURA DE PRECISIÓN.**

Con la aparición del concepto de AP se ha producido un desarrollo tecnológico muy importante en el diseño de sensores móviles (“on-the-go” en idioma inglés) que permiten medir las propiedades del suelo, lo cual tiene un potencial de beneficio muy importante debido al incremento en la densidad de las medidas a un relativo bajo coste (Pierce y Nowak, 1999).

Numerosos investigadores y fabricantes están intentando desarrollar sensores móviles para su uso en AP, aunque son pocos los sistemas que se encuentran disponibles comercialmente en la actualidad, se está haciendo un esfuerzo continuo en desarrollar nuevos prototipos (Hummel et al, 1996; Sudduth et al, 1997; Adamchuk et al, 2004).

Hay muchos tipos de conceptos de diseño, pero la mayoría de los sensores de suelo móviles (“on-the-go”) utilizan algunos de los siguientes sistemas de medida (Adamchuk et al, 2004):

- Sensores eléctricos y electromagnéticos que miden el efecto de la composición del suelo sobre la resistividad/conductividad o la capacitancia eléctrica.
- Sensores ópticos o radiométricos que utilizan ondas electromagnéticas para detectar el nivel de energía absorbida o reflejada por las partículas de suelo.
- Sensores mecánicos para medir la resistencia del suelo al paso de un dispositivo de laboreo.
- Sensores acústicos que cuantifican el sonido producido por una herramienta al interactuar con el suelo.
- Sensores neumáticos que evalúan la capacidad de inyectar aire en el suelo.
- Sensores electroquímicos que utilizan membranas selectivas de iones que producen una tensión eléctrica de salida en respuesta a la actividad de los iones seleccionados ( $H^+$ ,  $K^+$ ,  $NO^-$ , etc.)

Un sensor de suelo ideal responde a la variabilidad de un atributo del suelo y está altamente correlacionado con las mediciones analíticas convencionales. Sin embargo, la realidad es que cada sensor responde a más de una propiedad del suelo y la diferenciación

de los efectos de cada una de ellas es difícil o, a veces, imposible. En todo caso la respuesta de cada tipo de sensor puede variar según el tipo de suelos sobre el que se esté trabajando.

Muchos de los sensores descritos están en vías de desarrollo y los únicos que están siendo utilizados en muchos lugares comercialmente en agricultura de precisión son los eléctricos y los electromagnéticos. La razón es que este tipo de sensores proporciona una información acerca de los diferentes tipos de suelo, que permite diferenciar áreas relativamente homogéneas para ser usadas como zonas de manejo (Adamchuk et al, 2004).

Los eléctricos, de contacto directo, penetran en el suelo para medir su resistividad mediante el paso de una corriente eléctrica, empleando un par de electrodos circulares móviles emisores (“coulter”), midiendo el gradiente de potencial resultante en el subsuelo usando dos pares más de electrodos del mismo tipo, uno de ellos colocado habitualmente entre los que emiten y el segundo par en los lados exteriores a aquellos. De este modo se pueden obtener simultáneamente dos medidas diferentes, la  $CE_a$  superficial ( $CE_s$ ), y la  $CE_a$  en profundidad ( $CE_p$ ). La profundidad habitual correspondiente al valor de  $CE_s$  va de 0 a 30 cm y el de  $CE_p$  de 0 a 90 cm, si bien estos valores pueden ser alterados en función de la separación a la que se coloquen los electrodos, que es variable según las necesidades o las dimensiones del vehículo que realiza la operación, siendo siempre recomendable para propiciar que la trayectoria de las diferentes cuchillas no coincidan con las huellas de las ruedas del vehículo, con el fin de evitar que la compactación provocada por estas puedan influir sobre el valor de las mediciones. El sensor de contacto más conocido es el Veris (Veris Technologies, Inc., Salinas- Kansas USA).

Los electromagnéticos no entran en contacto con el suelo y trabajan sobre el principio de inducción electromagnética (Taylor et al., 2003); el instrumento consta de una bobina emisora y otra receptora instaladas en los extremos opuestos de una barra no conductora. El EM38 (Geonics Limited, Mississauga, Ontario, Canada) y el DUALEM (Dualem Inc., Milton, Ontario, Canada) son los dos sensores más conocidos de este tipo. Aunque estos modelos difieren en algunas características, el principio en que se basan es similar: una bobina transmisora establece un campo magnético primario a través del suelo que, en función de su capacidad conductora, induce un campo magnético secundario que es detectado por una bobina receptora situada a una cierta distancia de la bobina inductora.

Un circuito electrónico convierte estos campos a valores de  $CE_a$ . La profundidad máxima alcanzada por el campo magnético es de 1,5 m.

Aunque la inducción electromagnética sea un modo fácil y eficiente de medir la  $CE_a$  del suelo (Corwin y Lesch, 2003), se requiere una calibración en campo para permitir interpretar exactamente los datos registrados (Davis, 2007). En este caso, el método de contacto directo tiene algunas ventajas sobre los basados en la inducción electromagnética, a nivel de campo, porque no hay ninguna necesidad de la recalibración del sensor debido a cambios de la temperatura de aire o deriva instrumental y con el método de contacto directo no hay prácticamente ninguna posibilidad de interferencia eléctrica ambiental. Sin embargo, los electrodos usados en el método de contacto directo tienen que penetrar el suelo unos pocos centímetros y esto puede ser una desventaja para el muestreo de suelos pedregosos, típicamente encontrados en las regiones de Mediterráneo. Además, el muestreo por el método de contacto directo ha de ser hecho antes del cultivo o cuando la parcela ha sido laboreada uniformemente.

#### **2.3.4. USO DE LA GEOESTADÍSTICA EN LA ELABORACIÓN DE MAPAS DE PROPIEDADES DE SUELOS.**

Es conocido cómo los algoritmos geoestadísticos constituyen las herramientas más apropiadas para estimar cualquier propiedad del suelo que tenga una estructura de correlación espacial precisa (Goovaerts, 1997). Así mismo, una ventaja fundamental de los métodos geoestadísticos frente a otras técnicas de interpolación es que se tiene en la posibilidad de incorporar la información secundaria, en este caso  $CE_a$ , para mejorar las estimaciones de la variable primaria, siendo esta última cualquier propiedad del suelo con la que esté relacionada. El método más apropiado en ese caso es el uso de los algoritmos geoestadísticos multivariantes, como por ejemplo el cokrigead (Frogbrook y Oliver, 2001; Castrignanò et al., 2008), cuando la variable secundaria no es conocida de forma exhaustiva en el área experimental, o el regresión-krigead (Hengl et al., 2004; Moral, 2010), si se dispone de un conocimiento exhaustivo, o sea, en todos los puntos del área experimental, de dicha variable.

La determinación de las zonas de manejo debe efectuarse de la forma más precisa posible en base a la información espacial que se tenga. Aunque hay diversas técnicas para delimitar estas subparcelas (Kitchen et al., 2005; Ortega y Santibáñez, 2007), los algoritmos de análisis de agrupamientos (Fridgen et al., 2004; Schepers et al., 2004) o análisis de conglomerados, constituyen un método óptimo para dividir una parcela empleando diferentes capas de información almacenadas en un sistema de información geográfica. Además, considerando que los datos que se emplean para definir las zonas de manejo están habitualmente relacionados, la información puede simplificarse mediante el análisis de los componentes principales. Así, los valores de los primeros componentes pueden ser interpolados y representados gráficamente con el fin de delimitar las zonas de manejo mediante el análisis clúster (Morari et al., 2009; Xin-Zhong et al., 2009).

### **2.3.5. LA REGRESIÓN PONDERADA GEOGRÁFICAMENTE**

La RPG es una técnica para el análisis exploratorio de datos espaciales. En la regresión convencional se supone que la relación modelizada lo es para toda el área de estudio, pero en muchas situaciones esto no es necesariamente cierto. Muchas soluciones han sido propuestas para tratar la variación espacial en una relación. La RPG proporciona los medios para modelizar tales relaciones (Brunsdon et al. 2002).

La RPG es una alternativa a la regresión convencional porque proporciona un análisis local de las relaciones en conjuntos de datos multivariantes (Brunsdon et al. 2002). Una ventaja de ella consiste en que está basada en el marco de la regresión tradicional, con el cual la mayor parte de los investigadores están familiarizados. Otra ventaja consiste en que incorpora relaciones espaciales locales en el marco de la regresión de una manera intuitiva y explícita.

El mayor problema de las regresiones convencionales, cuando se aplican a datos espaciales, consiste en que se supone que los procesos examinados son constantes sobre el espacio, es decir, un modelo sirve para toda el área experimental. La RPG produce un conjunto de estimaciones locales para cada relación, pudiéndose representar la variación del coeficiente de determinación de dichas relaciones en el área de estudio. De esta manera, la

RPG proporciona una información muy valiosa sobre la naturaleza de los procesos investigados y sustituye a los sistemas tradicionales de modelado por regresión (Charlton et al., 2005).

Un ejemplo reciente del uso de la RPG se tiene en la elaboración de mapas de CE<sub>a</sub> y de producción de pastos mediante el uso de una sonda de inducción electromagnética, modelo “DUALEM 1S”, en Portugal (Serrano J.M. et al., 2010).

En agricultura de precisión se ha empleado para definir zonas homogéneas y manejar ataques de nematodos y otras enfermedades de la soja (Rupe J. et al., 2004).

### **2.3.6. EL MODELO DE RASCH**

El Análisis de Rasch es un modelo matemático desarrollado en la década de 1950 por el matemático danés Georg Rasch. Una definición del mismo puede ser que “es un modelo que establece la probabilidad de respuesta de una persona ante un estímulo dado, en términos de la diferencia entre la medida del rasgo de la persona y la medida del estímulo utilizado” (Tristán, 2002).

Este modelo surgió ante necesidad de diseñar un método de evaluación de pruebas mentales.

Se trata de un modelo estocástico (no determinista) donde la medida del rasgo de la persona y la medida del estímulo aplicado, quedan ubicadas en la misma escala lineal con un origen común. La variable de interés es la diferencia entre ambas medidas (Tristán, 2002).

Este modelo es un método objetivo para sintetizar los distintos tipos de información con unidades diversas (Rasch, 1980).

El modelo de Rasch se ha aplicado a una amplia gama de áreas científicas, como en la salud (Dallmeijer et al., 2011) o en ciencias sociales (Verheyen et al., 2010).

Hay antecedentes que demuestran sus buenos resultados en otras aplicaciones medioambientales (Moral et al., 2006).

En el ámbito agronómico ha sido usado recientemente para elaborar mapas de probabilidad de rendimiento potencial de una parcela cultivada de maíz a partir de una serie temporal de mapas de cosecha (Marques da Silva et al. 2012).

El modelo de Rasch, considerado como un instrumento de medida (Tristán, 2002; Alvarez, 2004), puede constituir una herramienta importante en la determinación de la fertilidad potencial de un suelo. Este modelo, de variable latente, se fundamenta en la modelación matemática del comportamiento resultante de la iteración de un sujeto con su ítem (Tristán, 2002). Es un modelo uniparamétrico, es decir, considera un solo parámetro de medición, que se corresponde con una sola dimensión relativa a una única escala para medir tanto la clasificación de las muestras de suelo como la de las características del suelo mismo.

Esta metodología tiene la capacidad de sintetizar y consolidar datos aparentemente dispares en un marco analítico uniforme. Así, en el caso de este trabajo, el objetivo de este procedimiento es la consolidación de diversas propiedades del suelo (contenido en arcilla, limo y arena,  $CE_s$  y  $CE_p$ ) en una variable global que simplifique la interpretación de la fertilidad potencial del suelo.

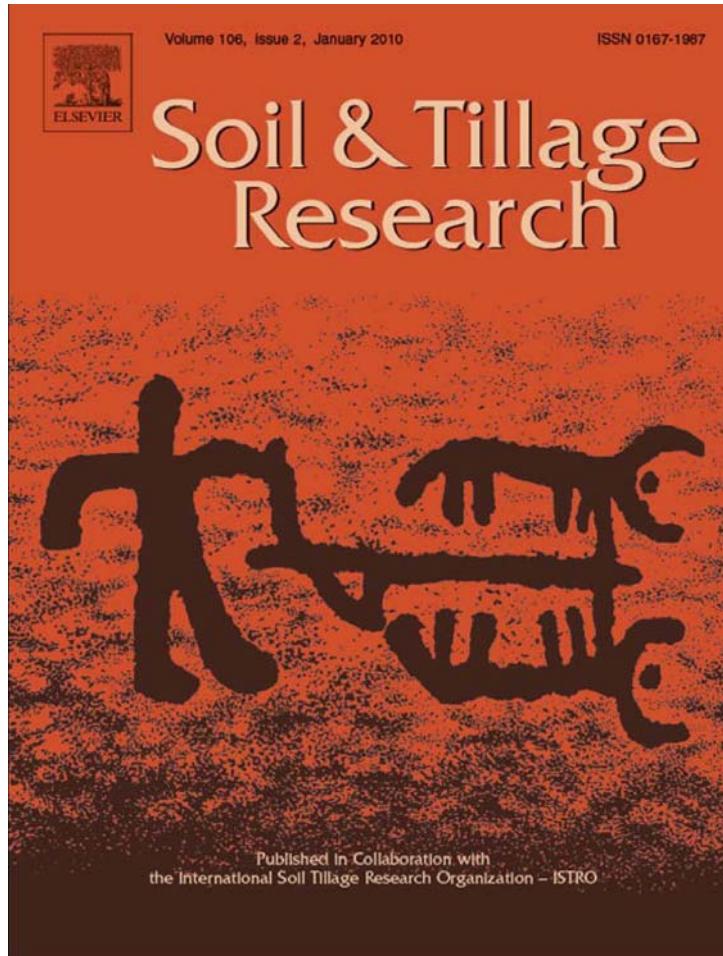
Una característica fundamental del modelo de Rasch es la transformación de los datos originales en unidades lineales, las cuales definen la variable latente. Esta variable constituye la fusión de diferentes datos, los cuales están conceptualmente relacionados con una característica o propiedad latente. Las unidades correspondientes a los diversos datos derivados de las diferentes propiedades del suelo son categorizados en escalas de medidas comunes. Conviene indicarse que la base para la transformación de diversas variables no categóricas, medidas continuas, a categorías comunes ordenadas, es la convicción fundamental que dichas medidas están relacionadas con una variable latente, además del deseo de comprender mejor sus interrelaciones con la mencionada variable latente.

Los modelos estadísticos se utilizan generalmente para describir conjuntos de datos desde un punto de vista paramétrico. Una tendencia (por ejemplo, media) o parámetros de dispersión (por ejemplo desviación típica) se utilizan comúnmente para discriminar diferentes muestras o poblaciones. Cuando se aplica el modelo de Rasch, el objetivo no es

describir los datos, sino determinar si se ajustan o no al modelo probabilístico de Rasch (Andrich, 2004).

**3. “DELINEATION OF MANAGEMENT ZONES USING MOBILE MEASUREMENTS  
OF SOIL APPARENT ELECTRICAL CONDUCTIVITY AND MULTIVARIATE  
GEOSTATISTICAL TECHNIQUES”**

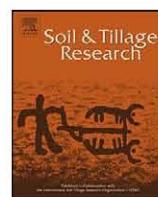
Provided for non-commercial research and education use.  
Not for reproduction, distribution or commercial use.



This article appeared in a journal published by Elsevier. The attached copy is furnished to the author for internal non-commercial research and education use, including for instruction at the authors institution and sharing with colleagues.

Other uses, including reproduction and distribution, or selling or licensing copies, or posting to personal, institutional or third party websites are prohibited.

In most cases authors are permitted to post their version of the article (e.g. in Word or Tex form) to their personal website or institutional repository. Authors requiring further information regarding Elsevier's archiving and manuscript policies are encouraged to visit: <http://www.elsevier.com/copyright>



## Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques

F.J. Moral <sup>a,\*</sup>, J.M. Terrón <sup>b</sup>, J.R. Marques da Silva <sup>c</sup>

<sup>a</sup> Departamento de Expresión Gráfica, Escuela de Ingenierías Industriales, Universidad de Extremadura. Avda. de Elvas, s/n. 06071 Badajoz, Spain

<sup>b</sup> Departamento de Cultivos Extensivos, Centro de Investigación La Orden-Valdesequera, Consejería de Economía, Comercio e Innovación, Junta de Extremadura, 06187 Guadajira, Badajoz, Spain

<sup>c</sup> ICAAM, Rural Engineering Department, Évora University, P.O. BOX 94, 7002-554 Évora, Portugal

### ARTICLE INFO

#### Article history:

Received 25 September 2009

Received in revised form 27 November 2009

Accepted 9 December 2009

#### Keywords:

Regression kriging  
Site-specific crop management  
Soil electrical conductivity  
Principal component analysis  
Fuzzy c-means

### ABSTRACT

Site-specific management promotes the identification and management of areas within the field, which represent subfield regions with homogeneous characteristics (management zones). However, determination of subfield areas is difficult because of the complex combination of factors which could affect crop yield. One possibility to capture yield variability is the use of soil physical properties to define the management zones as they are related to plant available water.

With the aim of characterizing the spatial variability of the main soil physical variables and using this information to determine potential management zones, soil samples were taken from 70 locations in a 33-ha field in Badajoz, southwestern Spain. Firstly, accurate spatial distribution maps of the soil attributes were generated by using regression kriging as the most suitable algorithm in which exhaustive secondary information on soil apparent electrical conductivity (ECa) was incorporated. ECa measurements were carried out with a Veris 3100 operating in both shallow (0–30 cm), ECs, and deep (0–90 cm), ECd, mode. Clay, coarse sand and fine sand were the soil physical properties which exhibited higher correlation with ECa (positively correlated with the finer texture component, clay, and negatively correlated with the coarser ones, coarse and fine sands), particularly with ECs. Thus, this was the secondary variable used to obtain the kriged maps. Later, principal component analysis and fuzzy cluster classification were performed to delineate management zones, resulting in two subfields to be managed separately. This number of subfields was determined using the fuzzy performance index and normalized classification entropy as the way to optimize the classification algorithm.

© 2009 Elsevier B.V. All rights reserved.

### 1. Introduction

High spatial variability is usually found in soils due to many physical, biological and chemical processes acting simultaneously with different intensities. In consequence, uniform management of fields does not take into account the spatial variability, and it is not the most effective management strategy. Precision agriculture is considered the most viable approach for achieving sustainable agriculture (Corwin et al., 1999). Particularly, site-specific crop management (SSCM) is a form of precision agriculture whereby decisions on resource application and agronomic practices are improved to better match soil and crop requirements as they vary in the field. SSCM advocates the identification of regions (management zones) within the area delimited by field boundaries. These subfield regions constitute areas of the field with

similar characteristics, such as texture, topography and nutrient levels. However, it is difficult to accurately define the management zones due to the complex interactions of all factors that could affect crop yield. Furthermore, the fact that factors interact in a dynamic way can make very difficult to determine the management by subfields. According to Fraisse et al. (2001), crop production potential is strongly related to plant available water so its variability can be approximately determined on the basis of soil physical properties and topographic characteristics, when topography change significantly in the field.

SSCM uses rapidly developing information and electronic technologies to change the management of soils and crops considering the field variations spatially and temporarily. To characterize within-field variability of edaphic properties, with the aim to be applied to SSCM, measurements of apparent soil electrical conductivity (ECa) is one of the most reliable technique (e.g., Corwin and Lesch, 2003). Especially, the application of geospatial measurements of ECa has a great potential to provide spatial information for optimizing soil sampling to better

\* Corresponding author. Tel.: +34 924 289600; fax: +34 924 289601.  
E-mail address: [fjmoral@unex.es](mailto:fjmoral@unex.es) (F.J. Moral).

characterize the spatial pattern of edaphic properties influencing crop yield, which in turn can be used to define site-specific management units.

When a farmer decides to consider different management zones, three previous questions should be stated (Fridgen et al., 2004): (a) initial information (basis for delineating the zones within the field); (b) the procedures to process and integrate all information with the aim of defining management units and (c) the number of management zones in which the field is divided.

Efficient techniques for accurately measuring within-field variations in soil properties are very important for SSCM (Bullock and Bullock, 2000). The traditional soil sampling is costly and labour-intensive. Taking into account the necessity of many soils samples to achieve a good representation of any soil property, this traditional method is not viable from a SSCM perspective.

The geospatial measurement of ECa is an efficient ground-based sensing technology that is helping to bring SSCM from a concept to a reality (Corwin and Lesch, 2003). ECa can be intensively recorded, in an easy and inexpensive way, and it is usually related to various soil physico-chemical properties across a wide range of soils (Sudduth et al., 2005). Thus, ECa can be used to improve the estimation of soil variables, when they are spatially correlated. However, modelling the relationships between primary soil variables and ECa is not an easy task. It is due to the dependency of ECa on many soil properties, over different spatial scales, and in a complex way. Some techniques have been suggested to incorporate secondary information, ECa in this case, to improve estimates of primary soil variables. A proven method to generate accurate surfaces is using multivariate geostatistical algorithms, for example cokriging (Frogbrook and Oliver, 2001; Castrignanò et al., 2008) when secondary data is not exhaustive, and kriging with external drift (Wackernagel, 2003), factor kriging analysis (Casa and Castrignanò, 2008; Morari et al., 2009), or regression kriging (Hengl et al., 2004; Moral, in press) when secondary data is exhaustive.

There are two types of electrical conductivity sensors currently on the market to measure soil ECa in the field. They can be divided into two types based on the method of electrical conductivity measurement: contact or non-contact. The first type of sensor, contact method, uses electrodes, usually in the shape of coulters that make contact with the soil to measure the electrical conductivity. In this approach, two to three pairs of coulters are mounted on a toolbar; one pair applies electrical current into the soil while the other two pair of coulters measure the voltage drop between them. Veris sensor systems are the contact type of electrical conductivity measuring device, e.g., Veris 3100 model. The second type of sensor, non-contact method, i.e., it does not contact the soil directly, works on the principle of electromagnetic induction. The instrument is composed of a transmitter and a receiver coil usually installed at opposite ends of a non-conductive bar located at opposite ends of the instrument. EM38, GEM-2 and DUALEM are three popular models of non-contact sensors that are available on the market.

The correct definition of management zones constitutes an important task to properly manage spatial variability within fields (Lark, 1998). Although there are different techniques to delineate management zones (e.g., Brock et al., 2005; Kitchen et al., 2005; Ortega and Santibáñez, 2007), cluster analysis algorithms (e.g., Fridgen et al., 2004; Schepers et al., 2004) is an optimum method to divide a field using different layers of information stored in a geographical information system (GIS). Taking into account that data used to define management zones are usually related (Officer et al., 2004), this information can be summarized by means of principal component analysis. Finally, the values of the main principal components can be interpolated and mapped and these surfaces can be used to generate management zones by cluster analysis (Morari et al., 2009; Xin-Zhong et al., 2009).

The objectives of this study were to: (1) use multivariate geostatistics to characterize and improve the estimation of soil properties using a secondary variable, the ECa data; and (2) utilize distribution maps of the soil physical variables to generate potential management zones by means of principal component analysis and fuzzy cluster algorithm.

## 2. Materials and methods

### 2.1. Study area and soil sampling

The field research was conducted at a farm called Cerro del Amo ( $38^{\circ}58'14''N$ ,  $6^{\circ}33'394''W$ , 225 m a.s.l., Datum WGS84), in the proximity of Montijo, 37 km east from Badajoz (southwestern Spain). The area of the study site is 33 ha approximately (Fig. 1 shows a topographic map of the study field). The field was planted with rape (*Brassica napus* L.).

Gentle hills dominate the topography; in the substrate limestones predominate over intrusive acidic rocks. According to the USDA-NRCS Soil Taxonomy System (1998), the soil is classified as Rhodoxeralf type.

The climate of this area is characterized by a variation in both temperature and precipitation typical of a Mediterranean climate. However, this feature is modified by the interior location and by oceanic influences that penetrate the Iberian peninsula due to its proximity to the Atlantic. Mean annual precipitation reaches less than 500 mm. One of the most important characteristic of the precipitation is its interannual variability. There are a dry season, from June to September, and a wet season, from October to May (80% of the precipitation falls between these months). Winters are mild, with minimum temperature that rarely lower 0 °C, and

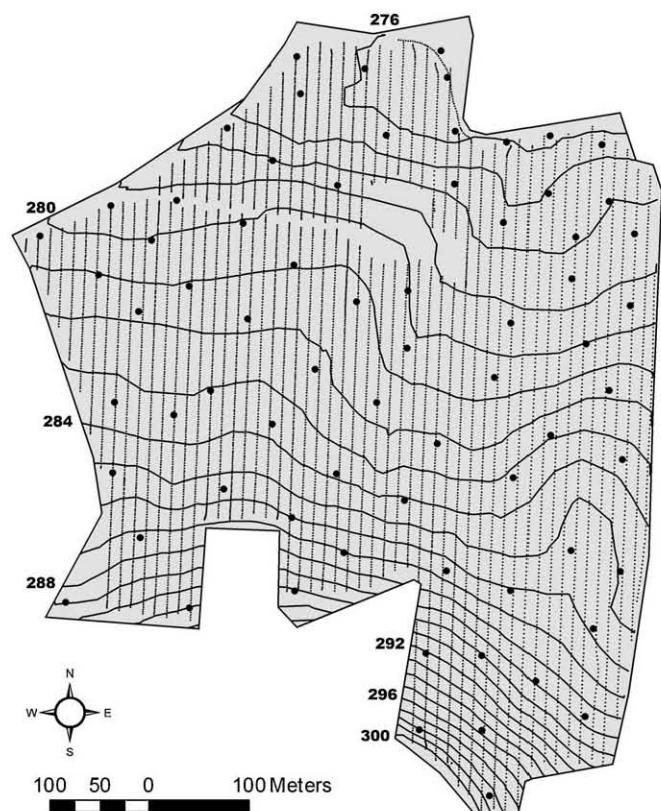


Fig. 1. Study site. Soil sampling points (bigger dots) and transects of the measurements of soil apparent electrical conductivity (smaller dots) are shown. Topographic contour lines (in meters) are also depicted.

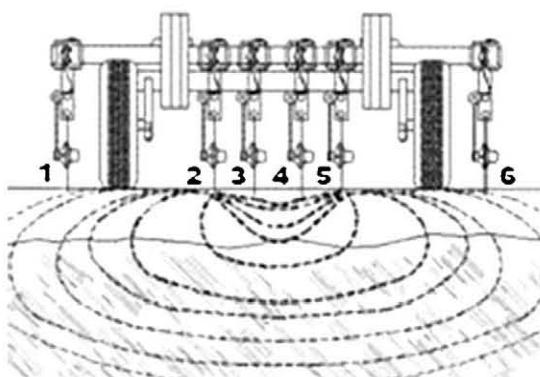
summers are hot, with maximum occasionally reaching more than 40 °C.

Soil sampling was done before planting in November 2008. 70 soil samples were taken from the top layer (0–20 cm), using a stratified random sampling scheme (Burrough and McDonnell, 1998) and their coordinates were determined with a millimetric precision with a Maxor-GGDT differentially corrected global positioning system (Javad Navigation Systems, San Jose, CA, USA). The number of samples was sufficient for the subsequent geostatistical analyses, although a finer estimation of the experimental variogram could have been obtained with a higher sampling density, i.e., if more soil samples had been considered, more points of the experimental variograms would have been calculated, providing more initial data to fit more accurately the theoretical model parameters. However a compromise between the density of samples and the labour-intensive sampling operations was reached.

Soil samples were introduced into plastic bags, air-dried and analysed for particle-size distribution by gravitational sedimentation using the Robinson pipette method (Soil Conservation Service, 1972), after passing the fine components through a 2 mm sieve. These fine components were also analysed for pH, in 1:2.5 (soil:water) suspension, by the electrometric method (Chapman, 1965), electrical conductivity (ECe), measured in a 1:5 (soil:water) suspension, using the electrometric method (Chapman, 1965), and other soil properties including organic matter (OM), determined by dichromate oxidation (Walkley and Black, 1934), cation exchange capacity (CEC), measured by the neutral ammonium acetate method, and total nitrogen (TN), determined by the Kjeldahl method (Bremner, 1960).

## 2.2. Mobile electrical conductivity measurements

The ECa survey was conducted in February 2009 with a 3100 Veris soil electrical conductivity sensor (Veris Technologies Inc., Salina, KS, USA). As the Veris cart is pulled through the field by a tractor, one pair of coulter-electrodes (rotating discs) injects a current into the soil while the other coulter-electrodes measure the voltage drop using a Wenner array. It is known that smaller soil grains (clay soils) conduct more current than larger grains (silty or sandy soils). The system is set up to switch between two configurations: A (shallow) and B (deep). Configuration A uses the four inner discs (2, 3, 4 and 5) as shown in Fig. 2. In this case, the voltage is measured between the two innermost discs (3 and 4). In Configuration B the four outer discs (1, 2, 5 and 6) are used and the voltage is measured between discs 2 and 5. Thus, the Veris 3100 generates two sets of data: topsoil data, weighted depth readings, from 0 to 30 cm (ECs) and deep data from 0 to 90 cm (ECd). ECa measurements were made along different parallel transects



**Fig. 2.** The system components of Veris 3100 soil electrical conductivity sensor. Discs 2, 3, 4 and 5 are used to get weighted depth readings from 0 to 30 cm and all discs are used to obtain readings from 0 to 90 cm.

approximately 12 m apart and the final database contained 9269 values of both ECs and ECd (Fig. 2).

A Beeline/RT20 system (NovAtel Inc., Calgary, Alberta, Canada) with submeter accuracy was used to georeference the ECa measurements. Thus, latitude, longitude, and shallow and deep ECa data by 1 s intervals are recorded on the Veris data logger in an ASCII text format. Later, this raw ASCII file is transferred to other software for further analysis.

## 2.3. Geostatistical interpolation techniques

In this section, the estimators used in the case study are briefly introduced. More information about them can be found in, for instance, Isaaks and Srivastava (1989) and Goovaerts (1997).

Geostatistical methods for interpolation start with the recognition that the spatial variation of any continuous variable, each soil property in this case study, is often too irregular to be modelled by a simple mathematical function. Instead, the variation can be better described by a stochastic surface. Thus, the studied variable is distributed continuously (regionalized variable), taking values everywhere within the study area, and considered random, which means that can take a series of outcome values according to some probability distribution.

Geostatistics is largely based on the concept of random function, whereby the set of unknown values (each unsampled location) is regarded as a set of spatially dependent random variables.

In this study, three phases were completed to conduct the geostatistical work (Isaaks and Srivastava, 1989).

### 2.3.1. Exploratory analysis of data

Data were studied without considering their geographical distribution. Statistics is applied to check data consistency, removing outliers, if they exist, and identifying statistical distribution of data.

### 2.3.2. Structural analysis of data

Spatial distribution of the variable was analysed. Spatial correlation or dependence can be quantified with semivariograms, or simply variograms, which also can characterize and determine distributions patterns such as randomness, uniformity and spatial trend. Variogram function relates the semivariance, half the expected squared difference between paired data values  $Z(x_i)$  and  $Z(x_i + h)$ , to the lag distance,  $h$ , by which sample points are separated. For discrete sampling locations, the function is estimated as:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} \{Z(x_i) - Z(x_i + h)\}^2 \quad (1)$$

where  $\gamma(h)$  is the experimental semivariance value at distance interval  $h$ ,  $Z(x_i)$  are the measured sample values at sample points  $x_i$ , in which there are data at  $x_i$  and  $x_i + h$ ;  $N(h)$  is the total number of sample pairs within the distance interval  $h$ . The variogram shows the degradation of spatial correlation between two points of space when the separation distance increases. This function has two components: (a) The nugget effect, which characterizes the discontinuity jump observed at the origin of distances, quantifies the short-term, erratic variations of the studied phenomenon plus measurements and data errors. (b) The increasing part of the variogram, which may reach the sill (theoretical sample variance), leveling off the curve, for a distance called range, or keep on increasing continuously with distance. The non-nugget part of the variogram measures the nonrandom part of the phenomenon and models its average medium-scale behaviour in space.

When an experimental variogram is defined, i.e., some points of a variogram plot are determined by calculating variogram at different lags, a model (theoretical variogram) should be fitted to

the points. Although there are some statistical techniques to justify the choice of a theoretical variogram (Cressie, 1985), subjective criteria and previous experiences are the main tools to choose one.

### 2.3.3. Predictions

Geostatistics offers a great variety of methods that provide estimates for unsampled locations (Castrignanò and Buttafuoco, 2004; Castrignanò et al., 2003). These methods are known as kriging, in honor of Danie Krige, who first formulated this form of interpolation in 1951. Kriging is regarded as the best linear unbiased estimator (BLUE).

All geostatistical estimators are variants of the linear regression estimator  $Z^*(x)$ :

$$Z^*(x) = \sum_{i=1}^n w_i(x) \cdot [Z(x_i) - m(x_i)] \quad (2)$$

where each datum,  $Z(x_i)$ , has an associated weight,  $w_i(x)$ , and,  $m(x)$  and  $m(x_i)$  are the expected values of  $Z^*(x)$  and  $Z(x_i)$  respectively. The kriging weights must be determined to minimize the estimation variance,  $\text{Var}[Z^*(x) - Z(x)]$ , while ensuring the unbiasedness of the estimator,  $E[Z^*(x) - Z(x)] = 0$ .

All different types of kriging are distinguished depending on the chosen model for the trend,  $m(x)$ , of the random function  $Z(x)$  (e.g., Goovaerts, 1997). Thus,  $m(x)$  is unknown in the ordinary kriging technique and is considered to fluctuate locally, maintaining the stationarity within the local neighbourhood.

When an estimate is computed at any unsampled location, the weights,  $w_i(x)$ , corresponding to each sample point, are generated solving a system of linear equations where the fitted (theoretical) variogram controls the spatial variability of the studied variable (see Isaaks and Srivastava, 1989; Goovaerts, 1997, for a detailed presentation of the kriging algorithms).

Univariate algorithms, for example ordinary kriging, consider the problem of estimating the variable at an unsampled location using only data of the soil property which is being analysed. If auxiliary or secondary information (for instance ECa data) is considered together with the primary data (any soil property), some multivariate extension of kriging can result in better estimates.

Due to the exhaustive soil ECa measurements, ECa data can be used as auxiliary information to improve the estimates of other related soil variables. Regression kriging is an optimal prediction technique in this case (Hengl et al., 2004). However, the use of this method has not been reported in agriculture to map soil properties, probably because of the impossibility to obtain the huge quantity of information which can be acquired with the direct electrical contact techniques at the present time.

When regression kriging is used, predictions are made separately for the trend and residuals and then added back together. Thus, any soil property at a new unsampled point,  $x$ , is estimated,  $Z_{RK}^*(x)$ , using regression kriging as follows:

$$Z_{RK}^*(x) = m(x) + r(x) \quad (3)$$

where the trend,  $m(x)$ , is fitted using linear regression analysis and the residuals,  $r(x)$ , are estimated using ordinary kriging algorithm. If  $c_j$  are the coefficients of the estimated trend model,  $v_j(x)$ , is the  $j$ th predictor at location  $x$ ,  $p$  is the number of predictors,  $w_i(x)$ , are the weights determined by solving the ordinary kriging system of the regression residuals,  $r(x_i)$ , for the  $n$  sample points, the prediction is made by:

$$Z_{RK}^*(x) = \sum_{j=0}^p c_j \cdot v_j(x) + \sum_{i=1}^n w_i(x) \cdot r(x_i) \quad (4)$$

$$v_0(x) = 1$$

In this case study, only one predictor is used, ECa, so  $m(x) = a + b \cdot \text{ECa}(x)$ . In consequence,

$$Z_{RK}^*(x) = a + b \cdot \text{ECa}(x) + \sum_{i=1}^n w_i(x) \cdot r(x_i) \quad (5)$$

The residual at each sampling point,  $r(x_i)$ , is calculated as the difference between the value of the soil property and the estimate by the trend ( $r(x_i) = Z(x_i) - m(x_i)$ ).

The geostatistical analyses were conducted using the Geostatistical and Spatial Analyst extensions of the GIS software ArcGIS (version 9.3, ESRI Inc., Redlands, CA, USA). After modelling the soil properties with the regression kriging algorithms, a set of map layers in raster format, with a 15 m resolution, was generated. All maps were produced with the ArcMap module of the ArcGIS.

### 2.4. Determination of potential management zones. Principal component and fuzzy cluster analyses

Principal component analysis is a dimension reduction method which uses correlated variables and identifies orthogonal linear recombination of the variables that summarize the principal sources of variability in the data. The input for analysis was a correlation matrix involving some selected variables, resulting in normalized principal component analysis. The number of principal components is the same that the number of considered variables, but usually the first few components explain most of the total variance in the data set (Li et al., 2007).

With the aim of generating homogeneous subfields, a fuzzy cluster analysis (e.g., Bezdek et al., 1999; Höppner et al., 1999) was performed, considering the factors, principal components, previously indicated. In this work, the fuzzy c-means, an unsupervised continuous classification procedure, was used to divide the field into different cluster classes. According to Odeh et al. (1992), this classification algorithm is preferred for grouping properties in the soil continuum, because it produces a continuous grouping of objects by assigning partial class membership. More information about the fuzzy c-means clustering process can be found in Fridgen et al. (2004).

Fuzzy c-means classification was carried out using the Management Zone Analyst (MZA) software (Fridgen et al., 2004). The fuzziness exponent was set at the conventional value of 1.35 (Odeh et al., 1992) and the classification was repeated for a range of classes between 2 and 8. Two indices were used to evaluate the optimal number of cluster classes: the fuzziness performance index (FPI) and the normalized classification entropy (NCE) (Odeh et al., 1992; Fridgen et al., 2004). Both indices have values between 0 and 1. FPI is a measure of the degree of membership sharing among classes (0 indicates different classes with no membership sharing and 1 reflects a strong sharing of membership); NCE is an estimate of the amount of disorganization created by a number of classes (0 indicates high organization and 1 represents a strong disorganization). The optimum number of classes is obtained when each index is at minimum, which indicates the least membership sharing (FPI) and greatest amount of organization (NCE) as a result of the clustering process (Fridgen et al., 2004).

## 3. Results and discussion

### 3.1. Exploratory analysis of data

During the first phase of the geostatistical study, exploratory analysis, data distribution was described using classical descriptive statistics (Table 1). With respect to the soil texture, the sandy fraction was predominant, close to the 50%, with an equilibrium between the coarser and finer sand components; clay and silt

**Table 1**

Descriptive statistics of the sample data (soil physical-chemical properties) in the study area; SD, standard deviation; CV, coefficient of variation.

Variable	Mean	Median	SD	Min	Max	CV (%)	Skewness	Kurtosis
Coarse sand (%)	23.03	24.47	5.64	13.22	35.94	24.48	0.22	2.19
Fine sand (%)	25.29	26.30	5.65	16.30	40.38	22.31	0.25	2.52
Silt (%)	20.05	20.06	5.79	4.16	44.72	28.88	0.35	7.35
Clay (%)	31.83	27.60	10.88	15.60	55.60	34.17	0.39	1.88
pH	7.36	7.45	0.53	5.69	8.33	7.31	-0.75	3.85
CEC (mequiv./100g)	26.52	27.40	11.25	6.64	42.89	42.42	-0.19	1.66
OM (%)	1.79	1.78	0.33	0.95	2.94	18.57	0.79	4.91
ECe ( $\text{mS m}^{-1}$ )	17.34	16.62	7.31	5.72	33.00	42.14	0.42	2.07
TN ( $\text{g kg}^{-1}$ )	0.13	0.13	0.01	0.10	0.17	11.91	0.14	2.63
ECs ( $\text{mS m}^{-1}$ )	16.06	18.78	5.57	3.46	22.95	34.68	-0.58	1.97
ECd ( $\text{mS m}^{-1}$ )	53.57	59.18	14.58	18.81	72.71	27.22	-0.73	2.32

CEC, cation exchange capacity; OM, organic matter; ECe, electrical conductivity measured in a 1:5 suspension; TN, total nitrogen; ECs, electrical conductivity measured in shallow mode; ECd, electrical conductivity measured in deep mode.

**Table 2**

Correlation matrix between soil properties in the study area.

	Coarse sand	Fine sand	Silt	Clay	pH	CEC	OM	ECe	ECs	ECd	TN
Coarse sand	1										
Fine sand	0.968	1									
Silt	-0.312	-0.287	1								
Clay	-0.857	-0.869	-0.195	1							
pH	-0.617	-0.612	-0.052	0.660	1						
CEC	-0.732	-0.742	-0.312	0.843	0.838	1					
OM	-0.041	-0.065	0.034	0.038	-0.023	0.013	1				
ECe	-0.294	-0.276	-0.077	0.322	0.300	0.435	0.102	1			
ECs	-0.671	-0.686	-0.141	0.768	0.734	0.879	0.076	0.357	1		
ECd	-0.610	-0.628	-0.078	0.674	0.648	0.781	0.104	0.280	0.954	1	
TN	-0.479	-0.528	0.079	0.482	0.431	-0.256	0.293	0.219	0.483	0.461	1

CEC, cation exchange capacity; OM, organic matter; ECe, electrical conductivity measured in a 1:5 suspension; ECs, electrical conductivity measured in shallow mode; ECd, electrical conductivity measured in deep mode; TN, total nitrogen.

fractions constituted around 32 and 20% respectively. Coefficients of variation (CV) for all textural classes were similar. The soil was slightly alkaline, with mean pH value of 7.36, and soil pH had the lowest CV (7.31%). ECe averaged  $17.34 \text{ mS m}^{-1}$  and had the higher CV (42%). An increase in ECe was observed in depth. Thus, ECs averaged  $16.06 \text{ mS m}^{-1}$ , ranging from  $3.46 \text{ mS m}^{-1}$  to  $22.95 \text{ mS m}^{-1}$ , and the CV was 35%; ECd averaged  $27.22 \text{ mS m}^{-1}$ , ranging from 18.81 to  $72.71 \text{ mS m}^{-1}$ , and the CV was 27%. CVs for soil properties indicated significant spatial variability and suggested the convenience of defining different management zones.

For all considered soil properties, the mean and median values were very similar which was indicative of data coming from a normal distribution. This was ratified by the fact that low skewness values were obtained, furthermore, most of the coefficients of kurtosis were close to 3 (typical of a normal distribution). The skewness value is based on the size of the tails of a distribution and provides a measure of how likely the distribution will produce outliers. Thus, in this work, outliers should be scarce, in fact there were not anyone, which was important to obtain accurate estimates. Although normality is not a prerequisite for kriging, it is a desirable property. Kriging will only generate the best absolute estimate if the random function fits a normal distribution (e.g., Goovaerts, 1997).

The coefficient of correlation between variables is shown in Table 2. With respect to the electrical variables, higher correlation values were obtained with ECs than ECd. Both variables were positively correlated with the finer soil component (ECs and clay,  $r = 0.768$ ; ECd and clay,  $r = 0.674$ ) and negatively with the coarser ones (ECs and coarse sand,  $r = -0.671$ ; ECd and coarse sand,  $r = -0.610$ ; ECs and fine sand,  $r = -0.686$ ; ECd and fine sand,  $r = -0.628$ ). Similar relationships between EC and these soil texture fractions have been reported elsewhere (e.g., Vitharana et al., 2008; Morari et al., 2009). However, no significant correlations were found between EC and silt or OM, although there were important correlations with variables which were related to soil fertility as

pH, CEC and TN. In turn, all these soil fertility variables were highly correlated with sand and clay. ECe and ECs or ECd were not correlated; this was probably due to the relatively low variation of the salinity content in the most superficial soil layer. Morari et al. (2009) found the same lack of correlation between these variables.

The existence of correlations between the electrical and some soil texture variables indicated that principal component analysis should be conducted to find the main sources of variability in the soil data. To facilitate further geostatistical works, those variables showing the highest correlations and being the most representative of the soil characteristics, i.e., ECs, ECd, clay, coarse sand and fine sand, were selected.

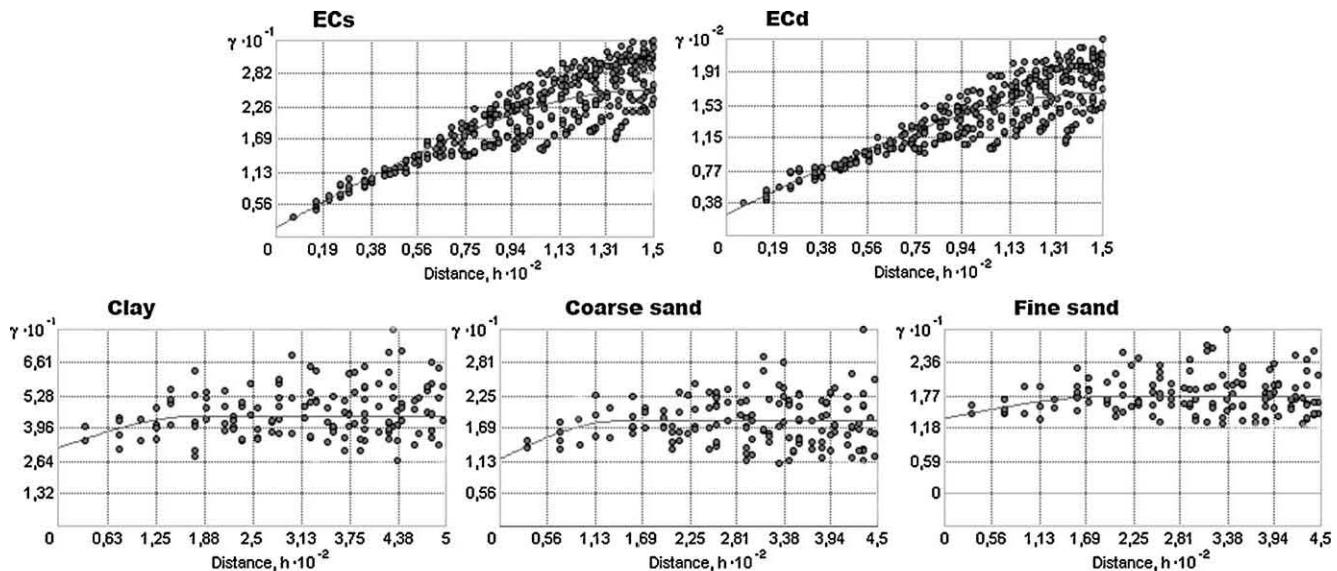
### 3.2. Structural analysis of data

As regression kriging was chosen as the optimum interpolation algorithm for the soil texture variables, due to the scarcity of soil samples, residuals of all dependent (textural) variables were computed. Previously, it was necessary to define the better linear relationship for each case (Table 3). ECs was used as independent variable because it shows higher correlations with textural soil data (Table 2).

When residuals were determined, experimental variograms were computed. Theoretical spherical models provided the best fit for all cases (Fig. 3). The choice of particular variogram model is dependent upon the expected spatial variability. Variables like soil

**Table 3**Linear relationships ( $Y = aX + b$ ) between ECs (X) and soil texture variables (Y).

Y	a	b	$R^2$
Clay	1.498	7.762	0.59
Fine sand	-0.694	36.448	0.47
Coarse sand	-0.679	33.934	0.45



**Fig. 3.** Experimental variograms (points) and theoretical spherical variograms (lines) for soil apparent electrical conductivity in shallow (ECs) and deep (ECd) modes, and clay, coarse sand and fine sand residuals.

**Table 4**  
Theoretical spherical variograms fitted to experimental variograms for the residuals data.

Variable	Range (m)	Sill	Nugget
Clay	180.84	44.36	31.48
Fine sand	193.72	17.35	13.44
Coarse sand	142.73	18.05	11.56

properties can be distributed unevenly in reduced distances and exponential or spherical models are the most suitable (Isaaks and Srivastava, 1989).

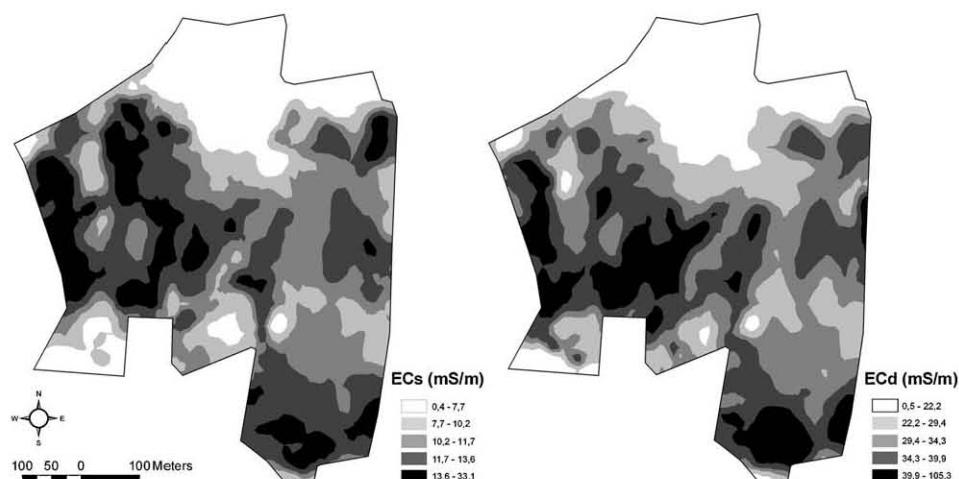
Spatial dependence of textural soil data displayed some differences as determined by variogram analyses (Table 4). In this work, variograms showed a considerable nugget effect. It is a normal situation because soil properties variability can occur at a scale smaller than the minimum lag distance. The nugget effect can be reduced by considering closer samples, but usually it is not feasible for soil variables due to the costly and labour-intensive requirements. According to Cambardella et al. (1994), the ratio of nugget to sill can be used to denote spatial dependence of soil attributes (ratio < 25% indicated strong spatial dependence; between 25 and 75% denoted moderate spatial dependence;

greater than 75% indicated weak spatial dependence). Values of this ratio for clay, fine and coarse sand were 70.96, 77.46 and 64.04% respectively, indicating that the spatial dependence of soil data was generally moderate. This is an additional support to consider regression kriging as the optimum interpolation method for those variables (Hengl et al., 2004). The range, maximum distance of spatial dependence, varied from 142 to 193 m. It was very similar for the three soil variables.

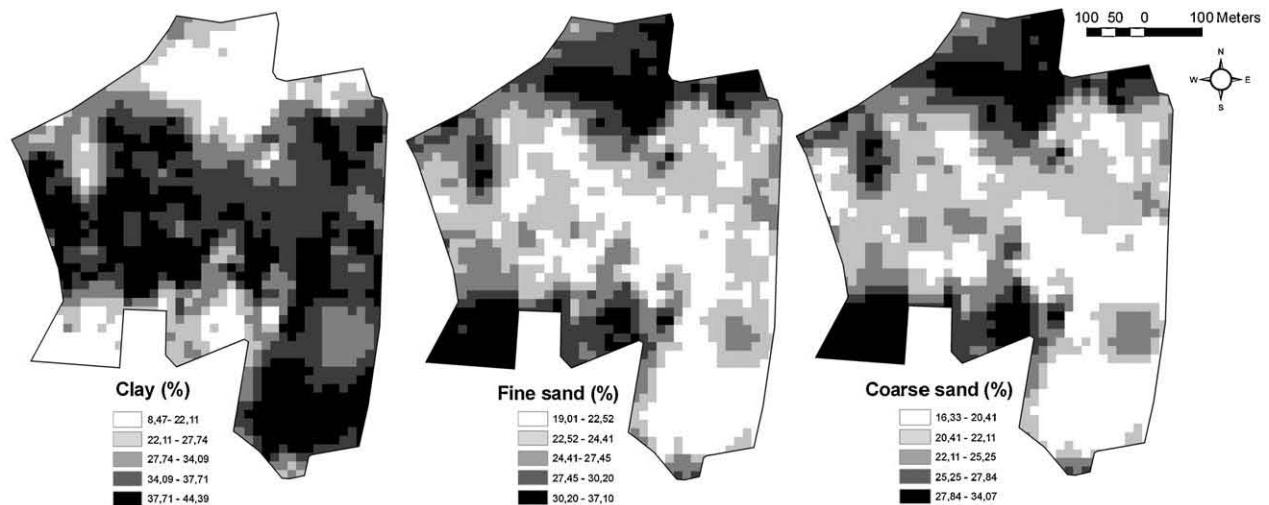
Due to the exhaustive ECs and ECd data, structural analysis was more accurate for these soil properties. Theoretical spherical models provided the best fit for both variables (Fig. 3). Lower nugget effects were obtained, 1.57 and 24.62 for ECs and ECd variograms respectively, with respect to the sill values, 25.36 and 166.81 for ECs and ECd variograms respectively, consequence of the sampling density, although their sills were different because their variances were different as well (Table 1). The ranges for both EC were about 150 m, similar to those obtained for the soil texture properties.

### 3.3. Geostatistical estimation

Estimated ECs and ECd at unsampled locations were carried out with the point ordinary kriging method, integrating the spatial



**Fig. 4.** Kriged maps of soil apparent electrical conductivity in shallow (ECs) and deep (ECd) modes.



**Fig. 5.** Fine sand and coarse sand content maps obtained with the regression kriging technique, with ECs as secondary data.

correlation structures described with the variograms. The kriged maps showing spatial distributions of both variables in the experimental field were obtained from the estimated values (Fig. 4). The distribution maps of clay, fine and coarse sand are shown in Fig. 5. They were produced after estimating at unsampled sites with the regression kriging technique.

The clay fraction prevails in the south and in the central area, mainly in the central west. The ECs distribution pattern is similar to the clay spatial distribution. Thus, high ECs readings were consistently found in areas with finer texture. Inversely, if the spatial distributions of the coarsest soil fractions (fine and coarse sands) are analysed, their relationship with the ECs pattern is opposed. It is important to denote that a single recording of ECs over a field already provides a general pattern of soil properties and delivers insight in the spatial heterogeneity within a field (Benson et al., 1988).

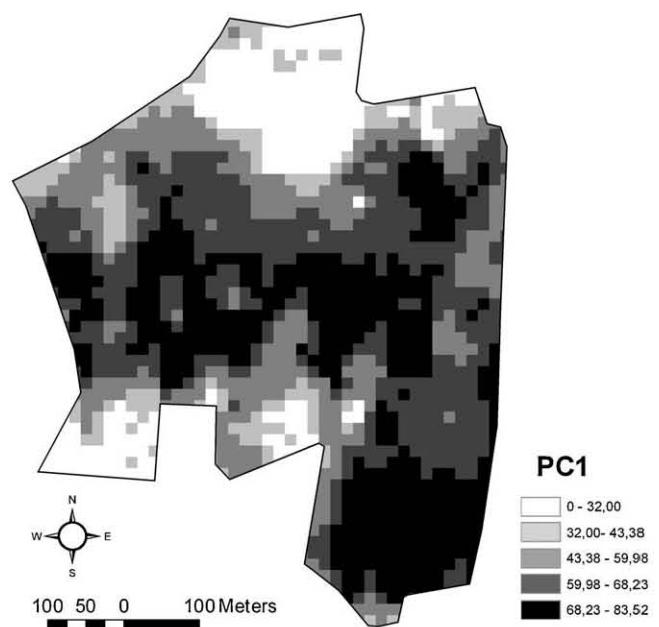
#### 3.4. Principal component and clustering analyses. Definition of potential management zones

To summarize the variability in all considered soil properties, and due to the existence of high correlation between them, principal component analysis was conducted. Table 5 shows that the first eigenvalue has a very high value (345.37), which supposes that the principal component 1 (PC1) has 97.27% component loading, so it explained this percentage of the total variance. PC1 was mainly dominated by ECd, with an important loading for soil clay fraction too. In consequence, the spatial distribution of PC1 (Fig. 6) was very similar to the spatial patterns of ECd and clayey soil fraction. If the principal component 2 (PC2) is considered, both

PC1 and PC2 explained nearly completely (99.09%) the total variance (Table 5).

In this case study, the first two principal components, PC1 and PC2, have been chosen to define potential management zones. This information was introduced into the MZA software to carry out the fuzzy c-means classification procedure. As the variables are orthogonal, the simpler Euclidean distance was computed in this procedure. As a result of the clustering analysis, two classes were obtained, which allowed both FPI and NCE indexes to be minimized (Fig. 7). According to Fridgen et al. (2004), two facts should be taking into account: first, the concordance of the two indexes is an indication of the goodness of the classification, so it is not necessary to perform further analysis to verify the results; secondly, the use of significant continuous variables, some of them integrating the information of auxiliary variables, avoided repetitions of clustering analysis to different input combinations to verify the most important properties for delineating potential management zones.

Fig. 8 shows the map of the potential management zones for the study field. The few small spots within each zone could be removed



**Fig. 6.** Kriged map of the first principal component.

**Table 5**

Results of the principal component analysis for the five soil properties.

Principal component	Eigenvalue	Component loading	Cumulative loading
PC1	345.37	97.27	97.27
PC2	6.48	1.82	99.09
PC3	1.82	0.51	99.60
PC4	1.22	0.34	99.94
PC5	0.17	0.06	100
PC loadings for each variable			
ECs	ECd	Clay	Fine sand
PC1	0.292	0.813	0.414
PC2	-0.324	0.574	-0.533
			-0.206
			0.367
			-0.199
			0.382

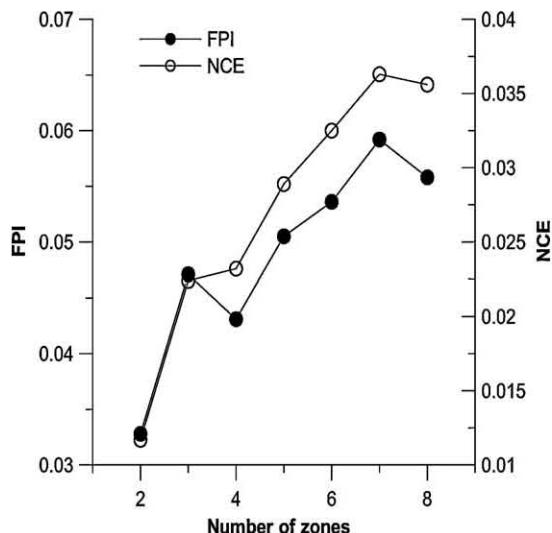


Fig. 7. Fuzziness performance index (FPI) and normalized classification entropy (NCE) as calculated for the study area.

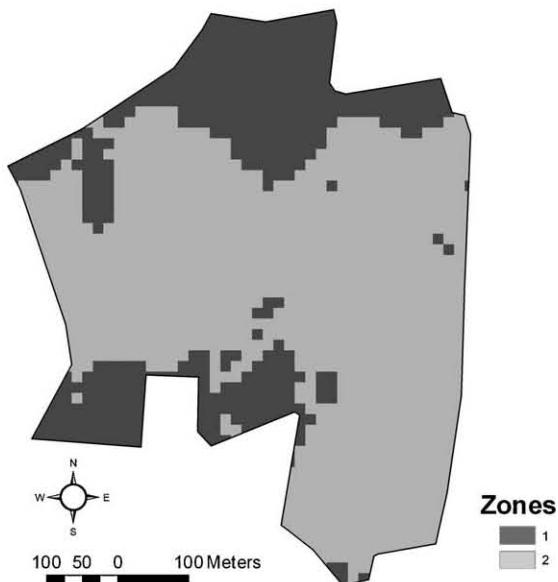


Fig. 8. Management zones map for optimum clusters in study area.

from a practical site-specific management point of view. It could be observed that a clear relationship exists between the soil maps and the management zones map. Areas where clay contents were low (and sand contents are high) correspond with zone 1 and, in turn, it coincides with those locations with low ECs and ECd. However, zone 2 occupies areas with the high clay contents (lower sand contents) and, consequently, with higher ECs and ECd.

#### 4. Conclusions

Georeferenced soil ECa measurements, carried out by the combination of a GPS system and a Veris 3100 electrical conductivity sensor, is a fast and low-cost technique to obtain soil information with high resolution. Shallow (0–30 cm) and deep (0–90 cm) configurations of the electrical system allow to distinguish two ECa measurements, ECs and ECd respectively, for each sampling location. Both of them were related to some fundamental soil properties. Thus, a close positive correlation between ECa and the clay content was found, which was expected

since ECa is mainly controlled by ions near soil constituents with a high surface area. More surprising, in view of the underlying physics, is the correlation between ECa and sand content. Indeed, this correlation is due to the autocorrelation with the clay content.

High correlation coefficients were also found between ECa and other variables related to soil fertility as CEC, pH and TN. In this sense, ECa measurements can be considered an indicator of soil fertility parameters. Thus, soil texture variables (clay, coarse sand and fine sand) and both ECa measurements (ECs and ECd) were considered to delineate management zones.

ECs data were used as auxiliary variable in the regression kriging technique to estimate both clay and sand contents at all unsampled locations within the field. In consequence, spatial distribution of the main soil texture variables was accurately inferred, requiring much less effort than a traditional survey would demand. ECs and ECd estimates were performed by the ordinary kriging algorithm, since initial sampling points were very abundant. Spherical models were fitted to all experimental variograms and their analysis revealed the existence of a moderate spatial dependence among soil data.

After generating five information layers, principal component analysis was conducted to find the main variability sources, being dominated by ECd and soil clay fraction, and the first two principal components, which explained near completely the total variance, were chosen with the aim of defining different potential management zones in the experimental field. A fuzzy c-means classification procedure was used and, as a result of the clustering analysis, two homogeneous zones were delimited. These two areas correspond with zones where clay content were low or high and, consequently, coincide with areas with low and high ECa respectively.

Mobile soil ECa measurements constitute one of the most efficient ways to quickly map soil spatial variability. Furthermore, it is possible to create maps with a very high spatial resolution, as it is needed for precision farming or generally for a site-specific soil management.

Identification of the two management zones is the first necessary stage to implement precision farming in the studied field. During next years, variable-rate application of inputs will be carried out, decreasing fertilization in the less productive area (low ECa) and minimizing the application of chemical substances as a strategy to obtain a more cost-effective field management, including less use of agricultural machinery. Thus, additional environmental, economic and energetic benefits could be expected as an important zone of the field, covering around a quarter of the surface area, will have a reduced treatment. Further studies will be conducted to compare this proposed subfield regions, management zones, with yield maps, to make clearer the agronomic significance of this classification.

#### Acknowledgements

The authors are very grateful to Daniel Becerra for his support in the field operations and also thank the reviewers of this paper for providing constructive comments which have contributed to improve the final version.

#### References

- Bezdek, J.C., Keller, J.M., Krishnapuram, R., Pal, N.R., 1999. Fuzzy Models and Algorithms for Pattern Recognition and Image Processing. Kluwer Academic Publishers, Boston, USA.
- Benson, R., Glaccum, R.A., Noel, M.R., 1988. Geophysical Techniques for Sensing Buried Wastes and Waste Migration. National Water Well Association, Dublin, OH, USA.
- Bremner, J.M., 1960. Determination of nitrogen in soil by Kjeldahl method. *J. Agric. Sci.* 55, 11–33.

- Brock, A., Brouder, S.M., Blumhoff, G., Hofmann, B.S., 2005. Defining yield-based management zones for corn-soybean rotations. *Agron. J.* 97, 1115–1128.
- Bullock, D.S., Bullock, D.G., 2000. Economic optimality of input application rates in precision farming. *Prec. Agric.* 2, 71–101.
- Burrough, P.A., McDonnell, R.A., 1998. Principles of Geographical Information Systems. Oxford University Press, Oxford, UK.
- Cambardella, C.A., Moorman, T.B., Novak, J.M., Parkin, T.B., Karlen, D.L., Turco, R.F., Konopka, A.E., 1994. Field-scale variability of soil properties in Central Iowa soils. *Soil Sci. Soc. Am. J.* 58, 1501–1511.
- Casa, R., Castrignanò, A., 2008. Analysis of spatial relationships between soil and crop variables in a durum wheat field using a multivariate geostatistical approach. *Eur. J. Agron.* 28, 331–342.
- Castrignanò, A., Buttafuoco, G., Giassi, R.C., 2008. Assessment of the risk of groundwater salinisation using multivariate geostatistics. GeoEnv VI—geostatistics for environmental applications. Quantitative Geology and Geostatistics, vol. 15. Springer, Berlin, Germany, pp. 191–202.
- Castrignanò, A., Buttafuoco, G., 2004. Geostatistical stochastic simulation of soil water content in a forested area of south Italy. *Biosyst. Eng.* 87 (2), 257–266.
- Castrignanò, A., Maiorana, M., Fornaro, F., 2003. Using regionalised variables to assess field-scale spatiotemporal variability of soil impedance for different tillage management. *Biosyst. Eng.* 85 (3), 381–392.
- Chapman, H.D., 1965. Cation-exchange capacity. In: Black, C.A. (Ed.), Methods of Soil Analysis, Part 2. American Society of Agronomy, Madison, WI, USA.
- Corwin, D.L., Lesch, S.M., 2003. Application of soil electrical conductivity to precision agriculture: theory, principles and guidelines. *Agron. J.* 95 (3), 455–471.
- Corwin, D.L., Loague, K., Ellsworth, T.R., 1999. Assessing non-point source pollution in the vadose zone with advanced information technologies. In: Corwin, D.L., Loague, K., Ellsworth, T.R. (Eds.), Assessment of Non-point Source Pollution in the Vadose Zone. Geophysical Monogr. 108. AGU, Washington, DC, USA, pp. 1–20.
- Cressie, N., 1985. Fitting variogram models by weighted least squares. *Math. Geol.* 17 (5), 563–586.
- Fraisse, C.W., Sudduth, K.A., Kitchen, N.R., 2001. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. *Trans. ASAE* 44 (1), 155–166.
- Fridgen, J.J., Kitchen, N.R., Sudduth, K.A., Drummond, S.T., Wiebold, W.J., Fraisse, C.W., 2004. Management Zone Analyst (MZA): software for subfield management zone delineation. *Agron. J.* 96, 100–108.
- Frogbrook, Z.L., Oliver, M.A., 2001. Comparing the spatial prediction of soil organic matter by two laboratory methods. *Soil Use Manage.* 17, 235–244.
- Goovaerts, P., 1997. Geostatistics for Natural Resources Evaluation. Oxford University Press, New York.
- Hengl, T., Heuvelink, G.B.M., Stein, A., 2004. A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma* 120, 75–93.
- Höppner, F., Klawonn, F., Kruse, R., Runkler, T.A., 1999. Fuzzy Cluster Analysis. Chichester, UK.
- Isaaks, E.H., Srivastava, R.M., 1989. An Introduction to Applied Geostatistics. Oxford University Press, New York.
- Kitchen, N.R., Sudduth, K.A., Myers, D.B., Drummond, S.T., Hong, S.Y., 2005. Delining productivity zones on claypan soil fields using apparent soil electrical conductivity. *Comp. Electron. Agric.* 46, 285–308.
- Lark, R.M., 1998. Forming spatially coherent regions by classification of multivariate data: an example from the analysis of maps of crop yield. *Int. J. Geogr. Inf. Sci.* 12, 83–98.
- Li, Y., Shi, Z., Li, F., Li, H.Y., 2007. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. *Comp. Electron. Agric.* 56, 174–186.
- Moral, F.J. in press. Comparison of different geostatistical approaches to map climate variables: application to precipitation. *Int. J. Climatol.*, doi:10.1002/joc.1913.
- Morari, F., Castrignanò, A., Pagliarin, C., 2009. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. *Comp. Electron. Agric.* 58, 97–107.
- Odeh, I.O.A., McBratney, A.B., Chittleborough, D.J., 1992. Soil pattern recognition with fuzzy c-means: application to classification and soil-landform interrelationship. *Soil Sci. Soc. Am. J.* 56, 505–516.
- Officer, S.J., Kravchenko, A., Bollero, G.A., Sudduth, K.A., Kitchen, N.R., Wiebold, W.J., Palm, H.L., Bullock, D.G., 2004. Relationships between soil bulk electrical conductivity and the principal component analysis of topography and soil fertility values. *Plant Soil* 258, 269–280.
- Ortega, R.A., Santibáñez, O.A., 2007. Determination of management zones in corn (*Zea mays L.*) based on soil fertility. *Comp. Electron. Agric.* 58, 49–59.
- Schepers, A.R., Shanahan, J.F., Liebig, M.A., Schepers, J.S., Johnson, S.H., Luchiari, A., 2004. Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. *Agron. J.* 96, 195–203.
- Soil Conservation Service, 1972. Soil Survey Laboratory. Methods and procedures for collecting soil samples. Soil Survey Report 1. U.S.D.A. Dept. Agric., WA, USA.
- Sudduth, K.A., Kitchen, N.R., Wiebold, W.J., Batchelor, W.D., Bollero, G.A., Bullock, D.G., Clay, D.E., Palm, H.L., Pierce, F.J., Schuler, R.T., Thelen, K.D., 2005. Relating apparent electrical conductivity top soil properties across the North-Central USA. *Comp. Electron. Agric.* 46, 263–283.
- USDA-NRCS, 1998. Keys to Soil Taxonomy, 8th ed. United States Department of Agriculture-Natural Resources Conservation Service, WA, USA.
- Vitharana, U.W.A., Van Meirvenne, M., Simpson, D., Cockx, L., De Baerdemaeker, J., 2008. Key soil and topographic properties to delineate potential management classes for precision agriculture in the European loess area. *Geoderma* 143, 206–215.
- Wackernagel, H., 2003. Multivariate geostatistics. In: An Introduction with Applications, 3rd ed. Springer Verlag, Berlin, Germany.
- Walkley, A., Black, I.A., 1934. An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Sci.* 37, 29–38.
- Xin-Zhong, W., Guo-Shun, L., Hong-Chao, H., Zhen-Hai, W., Qing-Hua, L., Xu-Feng, L., Wei-Hong, H., Yan-Tao, L., 2009. Determination of management zones for a tobacco field based on soil fertility. *Comp. Electron. Agric.* 65, 168–175.

**4. "SOIL APPARENT ELECTRICAL CONDUCTIVITY AND GEOGRAPHICALLY  
WEIGHTED REGRESSION FOR MAPPING SOIL"**

# *Soil apparent electrical conductivity and geographically weighted regression for mapping soil*

*J. M. Terrón, J. R. Marques da Silva,  
F. J. Moral & Alfonso García-Ferrer*

**Precision Agriculture**

An International Journal on Advances  
in Precision Agriculture

ISSN 1385-2256  
Volume 12  
Number 5

Precision Agric (2011) 12:750–761  
DOI 10.1007/s11119-011-9218-5

Volume 7, Number 1, March 2006

ISSN: 1385-2256

## Precision Agriculture

An International Journal  
on Advances in  
Precision Agriculture

Co-editors  
John Stafford  
Margaret Oliver

 Springer

Available  
online  
[www.springerlink.com](http://www.springerlink.com)

 Springer

**Your article is protected by copyright and all rights are held exclusively by Springer Science+Business Media, LLC. This e-offprint is for personal use only and shall not be self-archived in electronic repositories. If you wish to self-archive your work, please use the accepted author's version for posting to your own website or your institution's repository. You may further deposit the accepted author's version on a funder's repository at a funder's request, provided it is not made publicly available until 12 months after publication.**

## Soil apparent electrical conductivity and geographically weighted regression for mapping soil

J. M. Terrón · J. R. Marques da Silva · F. J. Moral · Alfonso García-Ferrer

Published online: 25 January 2011  
© Springer Science+Business Media, LLC 2011

**Abstract** To resolve the spatial variation in soil properties intensively is expensive, but such knowledge is essential to manage the soil better and to achieve greater economic and environmental benefits. The objective of this study was to determine whether the soil apparent electrical conductivity ( $EC_a$ ), alone or combined with other variables, is a useful alternative for providing detailed information on the soil in the Extremadura region of Spain. Apparent soil electrical conductivity was measured and geographically weighted regression was used to characterize the spatial variation in soil properties, which in turn can be used for soil management. This study shows that soil cation exchange capacity, calcium content, clay percentage and pH have a relatively strong spatial correlation with  $EC_a$  in the soil of the study area.

**Keywords** Soil apparent electrical conductivity ( $EC_a$ ) · Clay soil · Soil mapping · Site-specific management

---

J. M. Terrón

Departamento de Cultivos Extensivos, Centro de Investigación La Orden-Valdesequera, Consejería de Economía, Comercio e Innovación, Junta de Extremadura, 06187 Guadajira, Badajoz, Spain

J. R. Marques da Silva (✉)

Departamento de Engenharia Rural, Instituto de Ciências Agrárias e Ambientais Mediterrânicas (ICAAM), Escola de Ciências e Tecnologia, Universidade de Évora, Apartado 94, 7002-554 Évora, Portugal

e-mail: jmsilva@uevora.pt

F. J. Moral

Departamento de Expresión Gráfica, Escuela de Ingenierías Industriales, Universidad de Extremadura, Avda. de Elvas, s/n, 06071 Badajoz, Spain

A. García-Ferrer

Departamento de Ingeniería Gráfica y Geomática, E.T.S. Ingenieros Agrónomos y Montes, Universidad de Córdoba, Córdoba, Spain

## Introduction

Traditional soil sampling is costly and labor-intensive; nevertheless accurate knowledge of the soil's properties makes it possible to manage the soil better and to achieve greater economic and environmental benefits. Many soil samples are required to represent the spatial variation in soil properties, and consequently the traditional approach is not viable for determining within-field variability. It is known that the soil plays a crucial role in management, e.g. irrigation, fertilizer application, herbicide and pesticide application, and so on.

To characterize within-field variability of edaphic properties, measurement of the soil's apparent electrical conductivity ( $EC_a$ ) is one of the most reliable techniques (Corwin and Lesch 2003). Spatial measurements of  $EC_a$  have great potential for providing spatial information that could optimize soil sampling to characterize the spatial variation in soil properties.

Soil electrical conductivity (EC) is a measure of the soil's ability to conduct an electric current (McNeill 1992). It is affected by a combination of physico-chemical properties, including soluble salts, clay content and mineralogy, soil water content, bulk density, organic matter and soil temperature. Consequently, measurements of EC have been used at the field scale to map the spatial variation of several edaphic properties such as soil salinity, clay content or depth to clay-rich layers, soil water content, the depth of flood deposited sands and organic matter (Corwin and Lesch 2005a). Since its early use to measure soil salinity, the agricultural application of EC has evolved into a widely accepted means of establishing the spatial variation of several soil physico-chemical properties that affect the soil's apparent electrical conductivity,  $EC_a$ . The measurement of soil  $EC_a$  is a rapid, reliable and accessible method, and its values are often, but not always, related to crop yield. For these reasons, its measurement is among the most frequently used tools for spatio-temporal characterization of edaphic and anthropogenic soil properties (Corwin and Lesch 2005a).

Soil apparent electrical conductivity ( $EC_a$ ) is the depth-weighted average of the bulk soil electrical conductivity (Cook and Walker 1992). In other words, it is the average electrical conductivity integrated over different depths of soil; the depth depends on the instrument being used. There are currently two types of electrical conductivity sensor that are used to measure  $EC_a$  in the field: non-contact (electromagnetic induction) sensors and those using the direct contact method (electrical resistivity).

Soil  $EC_a$  alone can be used to classify the soil into broad categories with over 85% accuracy, and when combined with crop yield data the accuracy of classification increased to over 90% (Anderson-Cook et al. 2002).

Although electromagnetic induction is an easy and efficient way to measure soil  $EC_a$  (Corwin and Lesch 2003), some ground-truthing is required to be able to interpret the data recorded accurately (Davis 2007). In this case, the direct contact method has some advantages over those based on electromagnetic induction when working at the field scale because there is no need for re-calibration of the sensor due to changes in air temperature or instrument drift and there is virtually no possibility of ambient electrical interference with the direct contact method. However, the coulter-electrodes from the direct contact method need to penetrate the soil to a few centimeters and this can be a disadvantage for soil surveys of stony soils, typically found in the Mediterranean regions. Furthermore, survey by the direct contact method should be done either prior to tillage or when the field has been uniformly tilled.

Corwin and Lesch (2005b) obtained a strong correlation between  $\text{EC}_a$  and properties of the soil saturation extract ( $\text{Cl}^-$ ,  $\text{HCO}_3^-$ ,  $\text{SO}_4^{2-}$ ,  $\text{Na}^+$ ,  $\text{K}^+$  and  $\text{Mg}^{2+}$ ), exchangeable  $\text{Na}^+$  and sodium adsorption ratio. However, the correlations were weak with other properties such as volumetric water content, bulk density, clay percentage, saturation percentage, exchangeable sodium percentage, organic matter,  $\text{CaCO}_3$ , gypsum, total N,  $\text{Ca}^{2+}$  in the saturation extract and exchangeable cations ( $\text{K}^+$ ,  $\text{Ca}^{2+}$  and  $\text{Mg}^{2+}$ ). Cation exchange capacity (CEC) was less positively correlated with  $\text{EC}_a$ , but still significant at the  $p \leq 0.05$  level.

Sudduth et al. (2005) demonstrated that correlations of  $\text{EC}_a$  with clay content and CEC were generally stronger and more persistent across all fields tested. Other soil properties, such as soil moisture, silt, sand and organic C were strongly related to  $\text{EC}_a$  in some study fields but not in others. Regressions estimating clay and CEC as a function of  $\text{EC}_a$  across all study fields were reasonably accurate ( $R^2 \geq 0.55$ ). Thus, it may be feasible to establish relationships between  $\text{EC}_a$  and clay and CEC that would be applicable across a wide range of soil and climatic conditions.

When establishing statistical relationships in a multivariate dataset we have to be aware of the differences between spatial and aspatial data. Spatial data contain information on both attributes and location, whereas aspatial data contain only attribute information. These differences are important because any statistical technique developed for aspatial data is not valid for spatial data.

Geographically weighted regression (GWR) is an alternative to conventional regression because it provides a local analysis of relationships in multivariate datasets (Brunsdon et al. 2002). One advantage of GWR is that it is based on the traditional regression framework with which most researchers and readers are familiar. Another advantage is that it incorporates local spatial relationships into the regression framework in an intuitive and explicit manner.

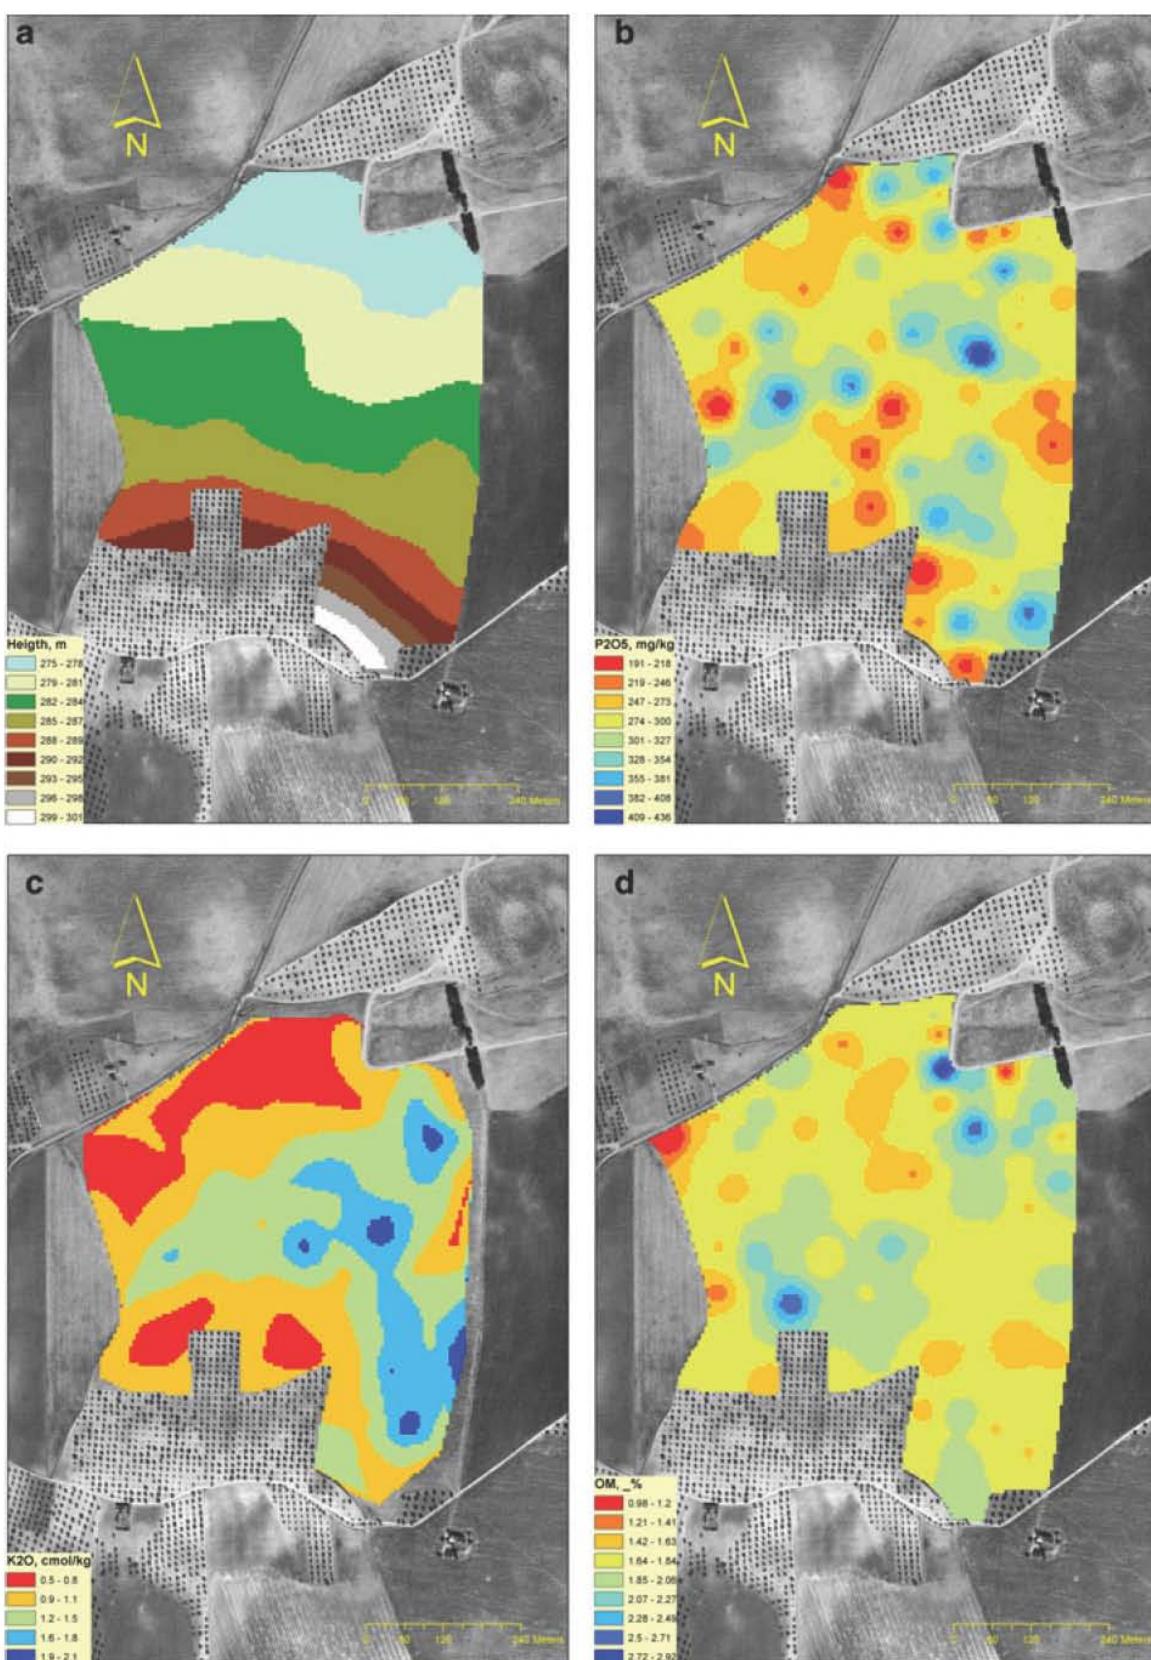
The main objective of this study was to determine whether soil  $\text{EC}_a$  alone or combined with other variables is a useful alternative for providing detailed information on the soils of the Extremadura region of Spain.

## Materials and methods

### Study area and soil sampling

The field research was conducted at a farm called Cerro del Amo ( $38^\circ 58'14''\text{N}$ ,  $6^\circ 33'394''\text{W}$ , 225 m.a.s.l, Datum WGS84) near to Montijo, 37 km East of Badajoz (southwestern Spain). The area of the study site is approximately 33 ha. The topography of this region is undulating with gentle hills in the South of the field (Fig. 1a). The altitude varies from 276 to 300 m, and the slopes vary from 0 to 15% and have a North to northeast aspect. Limestones predominate over intrusive acidic rocks in the substrate. According to the USDA–NRCS Soil Taxonomy System (2006), the soil is classified as Rhodoxeralf type (Order: Alfisols; Suborder: Xeralfs; Great Group: Rhodoxeralf (USDA–NRCS 2006)). The field was planted with rape (*Brassica napus* L.) at the time of the study.

The climate of this area is typical of the Mediterranean. Mean annual precipitation is less than 500 mm; there is a dry season from June to September and a wet season from October to May (80% of the precipitation occurs during this period). Winters are mild, with minimum temperatures that are rarely below  $0^\circ\text{C}$ , and summers are hot with maximum temperatures that occasionally exceed  $40^\circ\text{C}$ .



**Fig. 1** Spatial variation in: **a** elevation, **b** phosphorous; **c** potassium and **d** organic matter

Soil sampling was carried out before planting in November 2008. A stratified random sampling scheme (Burrough and McDonnell 1998) was used to take 70 soil samples from the topsoil (0–20 cm). The coordinates of each sampling site were determined with

millimetre precision using a Maxor-GGDT differentially corrected global positioning system (Javad Navigation Systems, San Jose, CA, USA).

### Mobile electrical conductivity measurements

The EC<sub>a</sub> survey was conducted in February 2009 with a 3100 Veris soil electrical conductivity sensor (Veris Technologies Inc., Salina, KS, USA). The Veris cart was attached to a tractor and was pulled over the field. One pair of coulter-electrodes (rotating discs) injected a current into the soil while the other coulter-electrodes measured the voltage drop using a Wenner array. It is known that smaller soil particles (clay size particles) conduct more current than larger ones (e.g. silty or sandy particle sizes). The system of six rotating discs is set up to switch between two configurations: A (shallow) and B (deep). Configuration A uses the four inner discs and the voltage is measured between the two innermost discs. In Configuration B, the four outer discs are used and the voltage is measured between the two innermost discs of these four. Thus, the Veris 3100 generates two sets of data: topsoil data, weighted depth readings, from 0 to 30 cm (EC<sub>a-30</sub>) and deep data from 0 to 90 cm (EC<sub>a-90</sub>). The EC<sub>a</sub> measurements were recorded along parallel transects approximately 12-m apart; the final database contained 9269 georeferenced values of both EC<sub>a-30</sub> and EC<sub>a-90</sub>.

### Soil sample analyses

The soil samples were air-dried and analyzed for particle size distribution on the <2 mm fraction by gravitational sedimentation using the Robinson pipette method (Soil Conservation Service 1972). The fine fraction was also analyzed for pH in a 1:2.5 (soil:water) suspension and electrical conductivity (EC) measured in a 1:5 (soil:water) suspension using the electrometric method (Chapman 1965). Organic matter (OM) was determined by dichromate oxidation (Walkley and Black 1934), CEC was measured using the neutral ammonium acetate method and total nitrogen (TN) was obtained through the Kjeldahl method (Bremner 1960). Extractable potassium (K<sub>2</sub>O), phosphorous (P<sub>2</sub>O<sub>5</sub>) and calcium (Ca) were determined using the ICP (inductively coupled plasma) method (Isaac and Johnson 1983).

### Geographically weighted regression and statistical analysis

Geographically weighted regression (GWR) is a technique for exploratory spatial data analysis. In ‘conventional’ regression, it is assumed that the relationship being modeled holds globally in the study area, but in many situations this is not necessarily true. Many solutions have been proposed for dealing with spatial variation in a relationship. The GWR provides the means for modeling such relationships (Brunsdon et al. 2002).

A ‘conventional’ regression model with one predictor variable can be written as Eq. 1, where  $y$  is the dependent variable,  $x_1$  is the independent variable,  $a$  and  $b$  are the coefficients to be estimated and  $e$  is a random error term assumed to be normally distributed. The assumption is that  $a$  and  $b$  are constant across the study area and if this is not true the results are erroneous (Brunsdon et al. 2002).

$$y = a + bx_1 + e \quad (1)$$

When  $a$  and  $b$  are not constant across the study area, the model can be rewritten as Eq. 2 where  $m$  and  $p$  are the coordinates of the sampling position. This relation can be fitted by least squares to give an estimate of the model parameters at the sampling location  $m, p$  and a predicted value. This is achieved by implementing the geographical weighting scheme, which is based on the concept that data closer to  $m, p$  are given more weight in the model than the data further away (Brunsdon et al. 2002).

$$y(m, p) = a(m, p) + b(m, p)x_1 + e(m, p) \leftarrow \quad (2) \leftarrow$$

All the data were standardized according to Eq. 3 because the variables are measured on scales.

$$s_i = \frac{x_i - \bar{x}}{\sigma}, \quad (3) \leftarrow$$

where  $s_i$  is the value of the standardized variable at position  $i$ ,  $x_i$  is the variable value at position  $i$ ,  $\bar{x}$  is the mean of all sampled positions for the variable and  $\sigma$  is the standard deviation for all  $i$ .

The first step was an ordinary least squares (OLS) analysis among different variables and EC<sub>a</sub> to understand the degrees of association among them. One of the main reasons for using OLS is because it provides valuable diagnostic information that indicates whether the explanatory variables are significant, whether the residuals are normally distributed and ultimately whether a good model is being used. However, it is sometimes difficult to find an OLS model that fits well because a single global model is not suitable for the entire study area. It is possible that one set of variables provides a good model for part of the study area, but is unsatisfactory for other parts. To determine whether this is the case, several small sample areas within the broader study area can be selected to establish if the explanatory variables for each sub-area change. Alternatively, one can map the local  $R^2$  results from GWR and select areas where this method performs well or poorly. These might be areas with different sets of explanatory variables. It can be useful to examine these areas individually using OLS. If there are good OLS models in several small study areas, this suggests that correlated variables have been found in the small study areas and that regional variation caused the global model to be poor. In this case, one can proceed with GWR and the full set of variables from the whole area because GWR will adjust the coefficients to reflect the regional variation. However, if a good OLS model is not obtained in any of the smaller areas it's possible that the key explanatory variables are too complex to be represented by OLS or GWR methodologies.

Ordinary least square (OLS) analysis was performed with the ARCGIS 9.3.1 OLS tool (ESRI 2009) and GWR analysis with the ARCGIS 9.3.1 GWR tool (ESRI 2009).

After point modelling soil properties with the GWR algorithm, a set of point estimates was obtained. To visualize the values, they were estimated on to a grid with a 5-m resolution for mapping. All maps were produced with the ArcMap/Spatial Analyst module of ArcGIS (version 9.3.1, ESRI Inc, Redlands, CA, USA) by (i) ordinary kriging with spherical variogram models for K<sub>2</sub>O, clay, CEC, EC<sub>a-30</sub>, EC<sub>a-90</sub>, pH, predicted CEC and  $R^2$ , and a search radius that included 12 neighbouring values, (ii) interpolation with inverse squared distance weighting for P<sub>2</sub>O<sub>5</sub> and OM because their variograms were poor and (iii) a linear interpolation method (TIN with ArcMap/Spatial Analyst module of ArcGIS, version 9.3.1) for altitude because these data are dense and representative of the study site.

## Results and discussion

### General characterization

The soil in the experimental field is reasonably fertile, but the spatial variation of the soil properties analyzed is considerable. Figure 1b, c and d shows that in the area studied the  $P_2O_5$  concentration varies between 191 and 436 mg kg<sup>-1</sup>, the  $K_2O$  concentration varies between 0.5 and 2.1 cmol kg<sup>-1</sup> and the organic matter percentage varies between 1 and 3%, respectively.

The variation in clay (Fig. 2a) is between 16 and 52%. Clay has a large impact on cation exchange capacity (CEC, Fig. 2b), with a range of 4–43 cmol kg<sup>-1</sup>. A visual examination of Fig. 2a and b indicates the strong spatial correlation between these two variables.

### Soil apparent electrical conductivity

Figure 2c and d shows the spatial variation in  $EC_{a-30}$  and  $EC_{a-90}$ , respectively, in the study area. These maps indicate that electrical conductivity increases with soil depth, but that this increase varies from area to area. In parts of the north and southwest of the site, the increase in  $EC_a$  with depth is less than in other areas. The spatial variation in soil  $EC_a$  is considerable for this particular field. We can identify two distinct zones: (i) the central and southeastern areas where the  $EC_a$  has the highest values and (ii) northern and southwestern areas where the  $EC_a$  values are the smallest. Visual inspection of Fig. 2b and c shows that  $EC_{a-30}$  and  $EC_{a-90}$  have similar spatial patterns to those of clay (Fig. 2a) and CEC (Fig. 2b). The  $EC_a$  seems to be a good indicator of clay and CEC content for this type of soil.

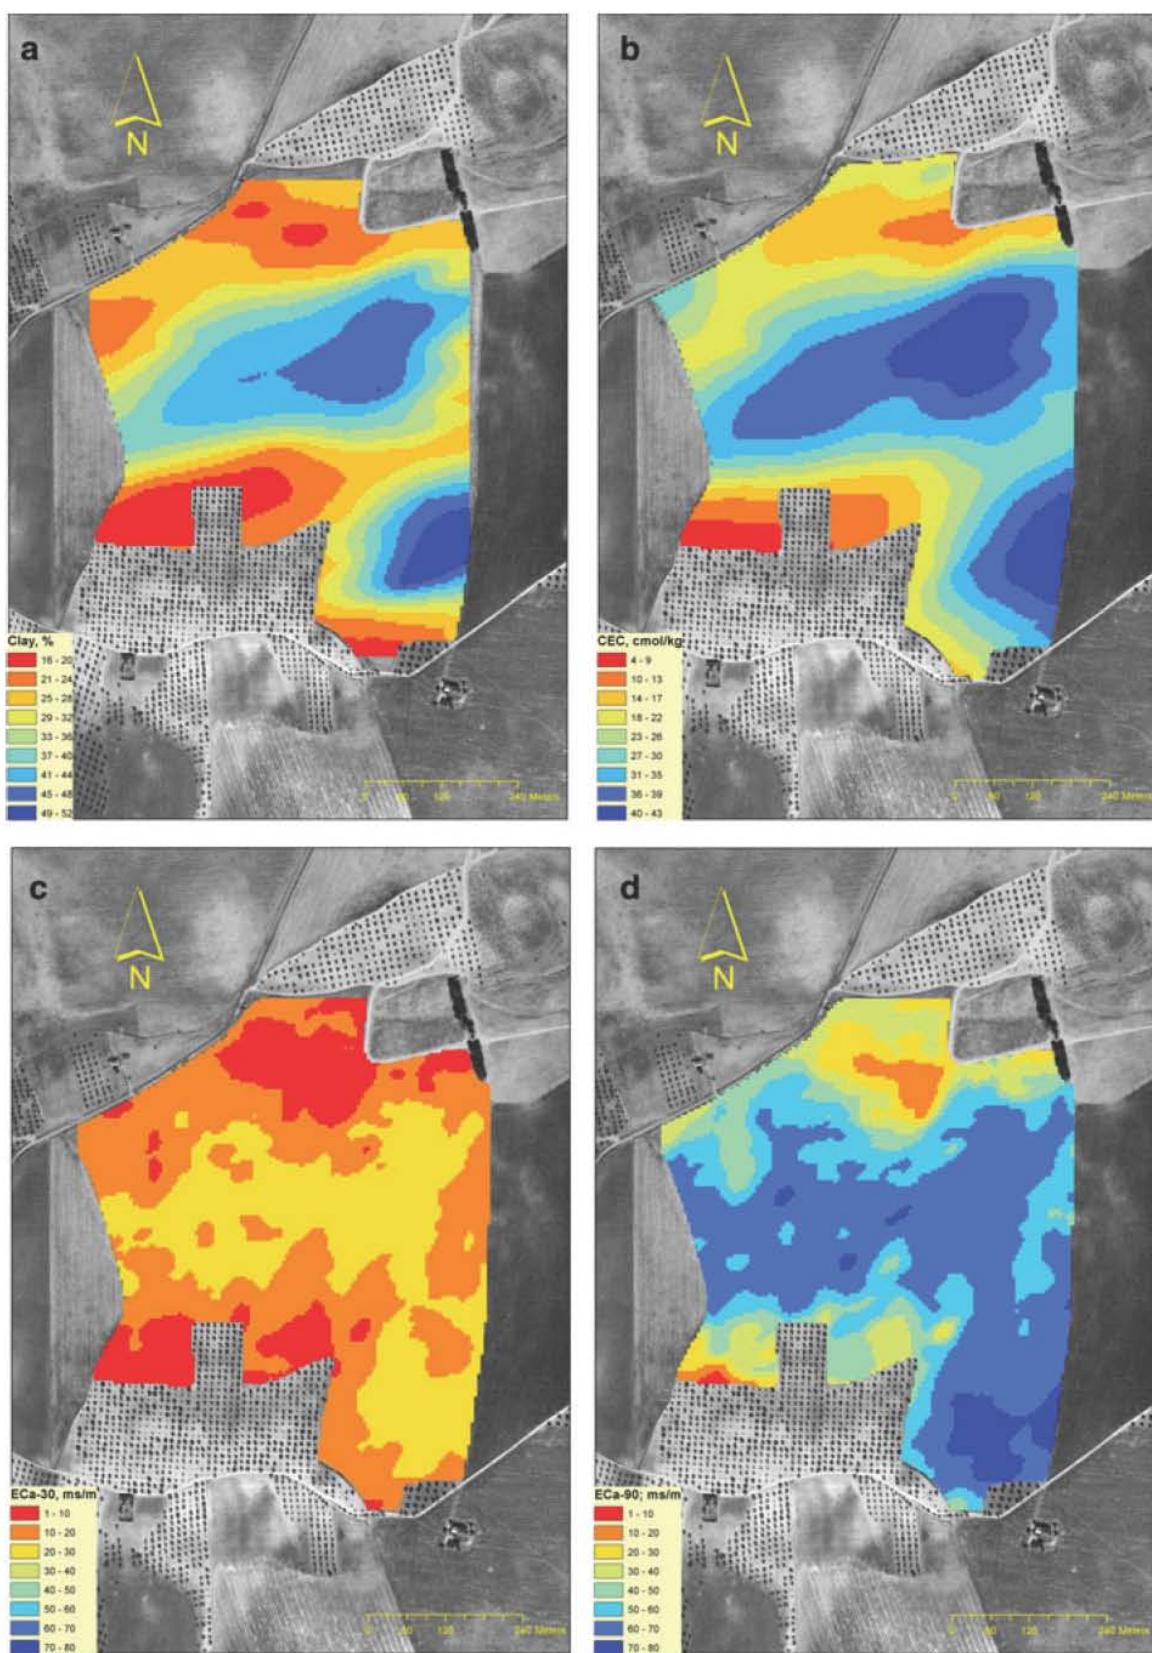
### Geographically weighted regression

Table 1 gives the results of the OLS analysis among the variables studied and  $EC_a$ ; they indicate the degree of association among variables. The OLS adjusted  $R^2$  of this study is large with some values of  $R^2 = 0.99$ . Although these variables are strongly related statistically, from a practical point of view some variables listed in Table 1 would be too expensive to measure simply to estimate soil CEC.

Table 1 shows that of the 12 independent variables, 7 have a variance inflation factor (VIF) greater than 7.5 which indicates that there is a strong probability of their being redundant in relation to CEC (e.g. clay, silt, coarse sand, fine sand, calcium,  $EC_{a-30}$ ,  $EC_{a-90}$ ). Although these variables are a somewhat redundant function of the dependent variable, they provide important information about the statistical association of these variables. Redundant variables usually have a large correlation coefficient between them and give the same type of information. This association among the variables suggests that variables that are easy and less costly to measure, such as  $EC_a$ , can be used to estimate variables that are generally difficult or costly to measure such as CEC, clay, silt, fine sand, coarse sand and Ca.

Table 2 gives the correlation coefficients from GWR among most of the variables analyzed (i.e. the independent variables) and with  $EC_{a-90}$  (i.e. the dependent variable).

The  $R^2$  values for the site given in Table 2 show that  $EC_{a-90}$  is closely linked to CEC. It is also possible to obtain  $R^2$  for particular parts of the site with GWR and these values can be mapped as in Fig. 3c. Furthermore, it is well known that CEC is also closely associated



**Fig. 2** Spatial variation in: **a** clay, **b** cation exchange capacity, **c** apparent electrical conductivity, 30 cm depth,  $EC_{a-30}$  and **d** apparent electric conductivity, 90 cm depth,  $EC_{a-90}$

with soil cations such as calcium, magnesium, potassium and sodium, and with the type and amount of clay. Variables with a smaller geographic correlation with  $EC_{a-90}$  are organic matter, phosphorous, silt, total nitrogen, potassium and coarse sand, Table 2.

**Table 1** Ordinary least squares analysis between cation exchange capacity ( $\text{cmol kg}^{-1}$ ) as dependent variable and 12 other variables as independent variables

Variable	Coef	StdE	t-stat	Prob	VIF
Intercept	0.0000	0.0020	0.00	1.00	–
Organic matter, %	-0.0068	0.0022	-3.11	0.00*	1.18
pH	0.0086	0.0039	2.22	0.03*	3.67
Clay, %	0.0058	0.0180	0.32	0.75	79.67 <sup>#</sup>
Fine sand, %	0.0147	0.0136	1.08	0.28	45.52 <sup>#</sup>
Coarse sand, %	-0.0111	0.0118	-0.94	0.35	34.38 <sup>#</sup>
Silt, %	0.0055	0.0096	0.58	0.57	22.63 <sup>#</sup>
Total nitrogen, $\text{g kg}^{-1}$	0.0014	0.0028	0.50	0.62	1.87
Calcium, $\text{cmol kg}^{-1}$	0.9611	0.0065	148.70	0.00*	10.31 <sup>#</sup>
$\text{K}_2\text{O}$ , $\text{cmol kg}^{-1}$	0.0313	0.0034	9.17	0.00*	2.87
$\text{P}_2\text{O}_5$ , $\text{mg kg}^{-1}$	-0.0012	0.0023	-0.54	0.59	1.25
$\text{EC}_{a-30}$ , $\text{ms m}^{-1}$	0.0166	0.0117	1.42	0.16	33.95 <sup>#</sup>
$\text{EC}_{a-90}$ , $\text{ms m}^{-1}$	-0.0051	0.0087	-0.58	0.56	18.65 <sup>#</sup>

Coef Coefficient, StdE standard error; t-stat t-statistic, Prob probability, VIF variance inflation factor (O'Brien 2007)

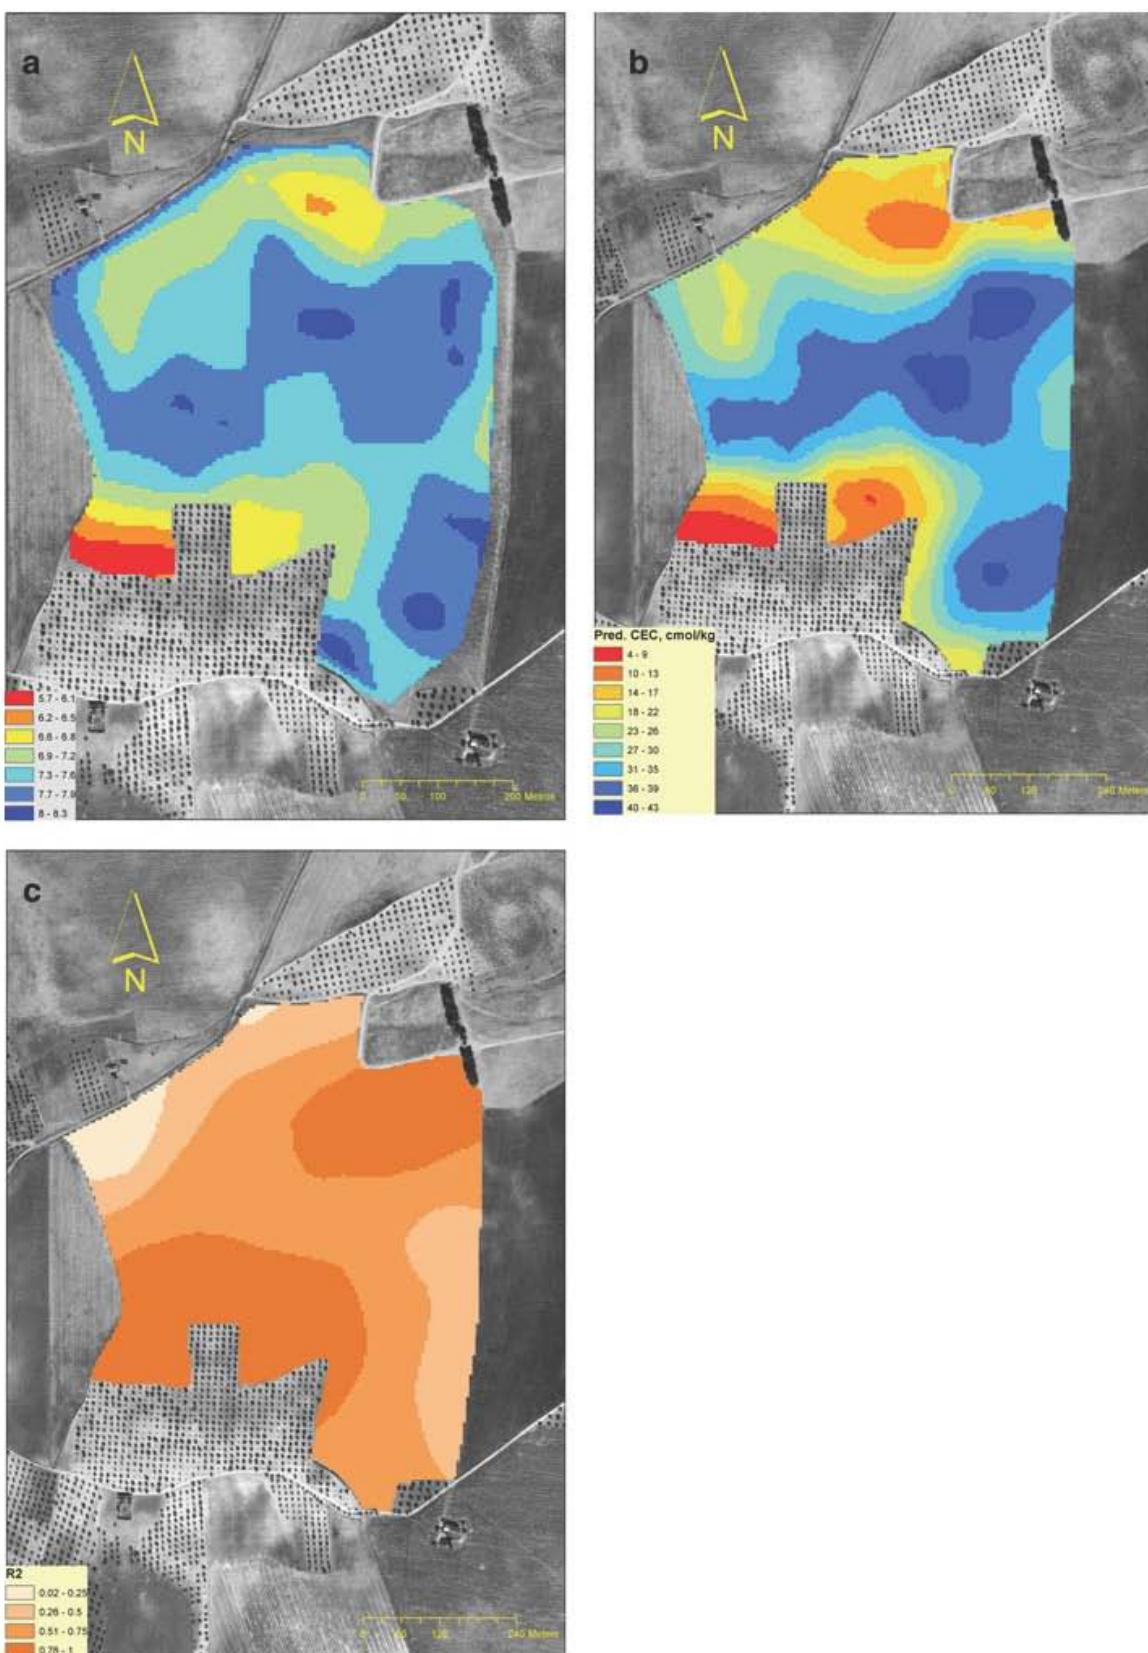
\* Statistically significant at the 0.05 level; <sup>#</sup> Large VIF (>7.5, for example) indicates redundancy in the explanatory variable

**Table 2** Geographic weighted regression, GWR, between different soil variables (independent variables) and weighted soil apparent electrical conductivity from 0 to 90 cm,  $\text{EC}_{a-90}$  (dependent variable)

GWR	Independent variables	Site $R^2$
1	Cation exchange capacity	0.88
2	Calcium	0.85
3	Clay	0.75
4	pH	0.60
5	Fine sand	0.51
6	Coarse sand	0.43
7	$\text{K}_2\text{O}$ , $\text{cmol kg}^{-1}$	0.43
8	Total nitrogen, $\text{g kg}^{-1}$	0.21
9	Silt	0.14
10	$\text{P}_2\text{O}_5$ , $\text{mg kg}^{-1}$	0.02
11	Organic matter	0.01

Therefore, these results indicate that  $\text{EC}_{a-90}$  can be used to estimate the spatial variation in CEC, calcium concentration and clay content at this site for which the result from GWR is statistically significant.

The point to point variation in the statistical parameters from a GWR analysis shows which areas have a stronger relation among the variables and  $\text{EC}_a$  than others. To illustrate, the estimated CEC (Fig. 3b) with a site  $R^2$  of 0.88 (Table 2) is visually close to the measured CEC (Fig. 2b). Figure 3c shows that the coefficient of determination ( $R^2$ ) from the GWR analysis between CEC and  $\text{EC}_{a-90}$  varies spatially. The  $R^2$  values are smaller in the NW and SE of the study site and larger in the N and S. In the NW and SE of the site, variables other than  $\text{EC}_{a-90}$  might explain variation in the dependent variable.



**Fig. 3** Spatial variation in: **a** pH, **b** cation exchange capacity predicted from  $EC_{a-90}$  and **c**  $R^2$  from cation exchange capacity predicted by geographically weighted regression

## Differential application of fertilizers

The CEC in the soil of the study site can be estimated from  $\text{EC}_{a-90}$  as shown in Table 2. The challenge is to obtain information relatively inexpensively on variables that are expensive to measure to improve the management of soil fertility and, consequently, of crop nutrition. Uniform fertilizer application does not promote economic, environmental and energy efficiency, therefore, better knowledge of the spatial variation of the soil is essential for more effective management.

It seems logical that any fertilizer application strategy will have to consider the spatial variation in CEC and pH (Fig. 3a) to improve the effectiveness of its implementation. For example, the use of more acid fertilizers in areas with higher pH and larger amounts of fertilizer in areas with lower soil CEC could provide a decision making strategy for fertilizer application.

## Conclusions

This study shows that soil cation exchange capacity, calcium content, clay percentage and pH have a reasonably strong spatial correlation with apparent electric conductivity ( $\text{EC}_a$ ) of the soil. The use of geo-electric sensors in the particular type of soil of the study site can be promising for the nutritional management of crops. This will enable increased economic, environmental and energy efficiency. It will also make it possible to map the soil at the field scale with a low input of resources.

The GWR technique, because it takes into account the spatial dependence of variables, can be used to interpret the spatial variation in certain soil properties as well as their spatial correlation with other associated variables.

**Acknowledgments** The authors are very grateful to Daniel Becerra for his support in field operations and also thank the Junta de Extremadura and FEDER for providing financial support through PRI07B080 research project.

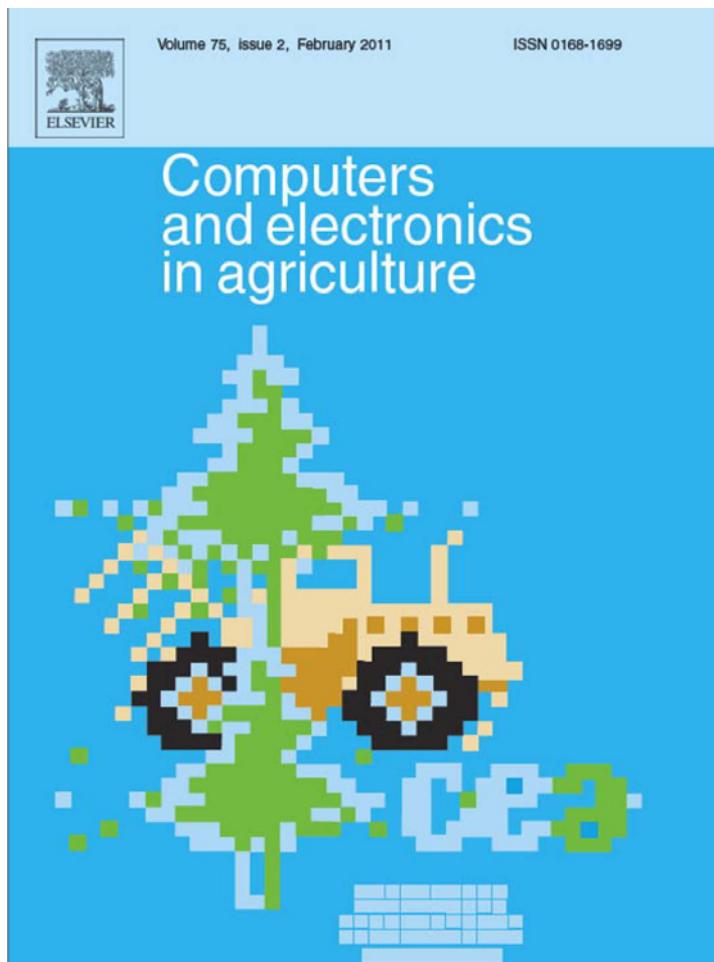
## References

- Anderson-Cook, C. M., Alley, M. M., Roygard, J. K. F., Khosla, R., Noble, R. B., & Doolittle, J. A. (2002). Differentiating soil types using electromagnetic conductivity and crop yield maps. *Soil Science Society America Journal*, 66, 1562–1570.
- Bremner, J. M. (1960). Determination of nitrogen in soil by Kjeldahl method. *Journal Agriculture Science*, 55, 11–33.
- Brunsdon, C., Fotheringham, A. S., & Charlton, M. (2002). Geographically weighted summary statistics: A framework for localized exploratory data analysis. *Computers, Environment and Urban Systems*, 26, 501–524.
- Burrough, P. A., & McDonnell, R. A. (1998). *Principles of geographical information systems*. Oxford: Oxford University Press.
- Chapman, H. D. (1965). Cation-exchange capacity. In C. A. Black (Ed.), *Methods of soil analysis, part 2* (pp. 891–901). Madison, WI: American Society of Agronomy.
- Cook, P. G., & Walker, G. R. (1992). Depth profiles of electrical conductivity from linear combinations of electromagnetic induction measurements. *Soil Science Society America Journal*, 56, 1015–1022.
- Corwin, D. L., & Lesch, S. M. (2003). Application of soil electrical conductivity to precision agriculture: Theory, principles and guidelines. *Agronomy Journal*, 95, 455–471.
- Corwin, D. L., & Lesch, S. M. (2005a). Apparent soil electrical conductivity measurements in agriculture. *Computers and Electronics in Agriculture*, 46, 11–43.

- Corwin, D. L., & Lesch, S. M. (2005b). Characterizing soil spatial variability with apparent soil electrical conductivity: Part II. Case study. *Computers and Electronics in Agriculture*, 46, 135–152.
- Davis, K. M. (2007). *Using apparent electrical conductivity (ECa) via electromagnetic induction (EMI) to characterize soils and the stratigraphy for wetland restoration*. Master of Science Thesis, North Carolina State University.
- ESRI. (2009). *ARCGIS 9.3.1 geographically weighted regression tool*. Redlands, CA: Environmental Systems Research Institute.
- Isaac, R. A., & Johnson, W. C. (1983). High speed analysis of agricultural samples using inductively coupled plasma-atomic emission spectroscopy. *Spectrochimica Acta*, 38B, 277–282.
- McNeill, J. D. (1992). Rapid, accurate mapping of soil salinity by electromagnetic ground conductivity meters. In G. C. Topp, W. D. Reynolds, & R. E. Green (Eds.), *Advances in measurement of soil physical properties: Bringing theory into practice*. SSSA Special Publication 30 (pp. 209–229). Madison, WI: SSSA.
- O'Brien, R. M. (2007). A caution regarding rules of thumb for variance inflation factors. *Quality and Quantity Journal*, 41, 673–690.
- Soil Conservation Service. (1972). *Methods and procedures for collecting soil samples*. Soil survey report 1. Washington, DC: Soil Survey Laboratory, United States Department of Agriculture.
- Sudduth, K. A., Kitchen, N. R., Wiebold, W. J., Batchelor, W. D., Bollero, G. A., Bullock, D. G., et al. (2005). Relating apparent electrical conductivity to soil properties across the north-central USA. *Computers and Electronics in Agriculture*, 46, 263–283.
- USDA-NRCS. (2006). *Keys to soil taxonomy* (10th ed.). Washington, DC: United States Department of Agriculture—National Resources Conservation Service.
- Walkley, A., & Black, I. A. (1934). An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science*, 37, 29–38.

**5. "SITE-SPECIFIC MANAGEMENT ZONES BASED ON THE RASCH MODEL  
AND GEOSTATISTICAL TECHNIQUES"**

**Provided for non-commercial research and education use.  
Not for reproduction, distribution or commercial use.**

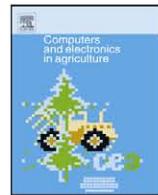


This article appeared in a journal published by Elsevier. The attached copy is furnished to the author for internal non-commercial research and education use, including for instruction at the authors institution and sharing with colleagues.

Other uses, including reproduction and distribution, or selling or licensing copies, or posting to personal, institutional or third party websites are prohibited.

In most cases authors are permitted to post their version of the article (e.g. in Word or Tex form) to their personal website or institutional repository. Authors requiring further information regarding Elsevier's archiving and manuscript policies are encouraged to visit:

<http://www.elsevier.com/copyright>



## Original paper

## Site-specific management zones based on the Rasch model and geostatistical techniques

F.J. Moral<sup>a,\*</sup>, J.M. Terrón<sup>b</sup>, F.J. Rebollo<sup>c</sup><sup>a</sup> Departamento de Expresión Gráfica, Escuela de Ingenierías Industriales, Universidad de Extremadura, Avenida de Elvas s/n, 06006 Badajoz, Spain<sup>b</sup> Departamento de Cultivos Extensivos, Centro de Investigación La Orden-Valdesequera, Consejería de Economía, Comercio e Innovación, Junta de Extremadura, 06187 Guadajira, Badajoz, Spain<sup>c</sup> Departamento de Expresión Gráfica, Escuela de Ingenierías Agrarias, Universidad de Extremadura, Carretera de Cáceres s/n, 06007 Badajoz, Spain

## ARTICLE INFO

## Article history:

Received 1 July 2010

Received in revised form 18 October 2010

Accepted 30 October 2010

## Keywords:

Precision agriculture  
Geostatistics  
Rasch model  
Management zones

## ABSTRACT

Delineation of management zones (MZ), i.e. areas within the field which represent subfield regions of similar production potential, is the first stage to implement site-specific management. During the last years different algorithms have been proposed to define MZ, with different results. In this work, the use of an objective method, the formulation of the Rasch model, which synthesizes data with different units into a uniform analytical framework, is considered to get representative measures of soil fertility potential which could be used to delimit MZ.

To illustrate the method, a case study was conducted in a experimental field using five soil properties: clay, sand and silt content, and deep (ECd) and shallow (ECs) soil apparent electrical conductivity (approximately 0–90 and 0–30 cm depths, respectively). Two main results were obtained after applying this method: (1) a classification of all locations according to the soil fertility potential, which was the value of the Rasch measure and (2) the influence on the soil fertility of each individual soil property, being ECs the most influential and silt content the less influential property.

Later, from the measures of soil fertility potential at sampled points, estimates were carried out using the ordinary kriging technique. Consequently, kriged estimates were utilized to map soil fertility potential and MZ were delimited using an equal-size classification method, which practically coincided with the MZ determined by a unsupervised classification.

It is also shown the possibility of using probability maps to delimit MZ or provide information for hazard assessment of soil fertility in a field.

© 2010 Elsevier B.V. All rights reserved.

## 1. Introduction

Precision agriculture (PA) is spatial information technology (including global positioning systems, geographical information systems, variable-rate technologies, and remote sensing) applied to agriculture to improve the decision-making process in agricultural production. Also known as site-specific farming, it encompasses collecting and analyzing data for different locations within a field in a way that allows management decisions to vary in those diverse locations.

Site-Specific Crop Management (SSCM) is a form of PA whereby decisions on resource application and agronomic practices are improved to better match soil and crop requirements as they vary in the field, in contrast with traditional uniform management across a field which is increasingly viewed as inefficient because it results

in the overapplication of inputs in low-producing areas and suboptimal application in high-producing zones.

The definition of SSCM encompasses the idea that PA is an evolving management strategy. The focus here is on decision-making with regard to resource-use and not necessarily the adoption of information technology on farm (although many new technologies will aid improved decision making). The inference is that better decision-making will provide a wide range of benefits (economic, environmental and social) that may or may not be known or measurable at present.

High spatial variability is usually found in soils due to many physical, biological and chemical processes acting simultaneously with different intensities. In consequence, uniform management of fields does not take into account the spatial variability, and it is not the most effective management strategy.

SSCM advocates the identification of regions within the area delimited by field boundaries. These subfield regions constitute areas of the field with similar characteristics, such as texture, topography, nutrient levels, etc., but it is difficult to accurately define

\* Corresponding author. Tel.: +34 924 289600; fax: +34 924 289601.  
E-mail address: [fjmoral@unex.es](mailto:fjmoral@unex.es) (F.J. Moral).

the subfields due to the complex interactions of all factors that could affect crop yield. However, it is known that the physical and chemical properties of the soil are one of the factors most affecting crop yields (Cambardella et al., 1994; Ortega et al., 1999), so they must be taken into account to delimit homogeneous zones, often referred to as management zones (MZ), which are subfields of similar production potential.

Significant research effort has been directed towards evaluating different techniques to define stratified within-field MZ. These include kriged soil test point data (Mulla, 1991), topography (Kravchenko et al., 2000), soil and relief information (Schepers et al., 2004), electrical conductivity sensors (Johnson et al., 2003), remote sensing (McCann et al., 1996), yield maps (Diker et al., 2004), and the consideration of farmer's knowledge (Fleming et al., 2004). These approaches to SSCM have met with varying degrees of success (highly region or soil specific).

The combination of different layers of information, integrating the most significant variables to properly define the MZ, can be carried out using different algorithms. During the last years the most common option has been the use of a cluster procedure using the fuzzy c-means methods (Fridgen et al., 2004; Xin-Zhong et al., 2009; Moral et al., 2010). Other methodologies include the use of principal component analysis, alone or in combination with the cluster method (Mallarino et al., 1999; Li et al., 2007; Morari et al., 2009), or are based on the use of the coefficient of variation of each data layer (Ortega and Santibáñez, 2007).

In this study a new methodology to properly integrate the data from all considered soil variables, based on the use of the Rasch model (Rasch, 1980), is proposed. It has been used successfully in some environmental applications, for example to define urban areas with different levels of atmospheric pollution (Moral et al., 2006), but, as far we know, it has not been used in agricultural issues. However, the Rasch model generates much useful information about the data, specially from an agronomic point of view and to be used when MZ have to be delimit.

The objectives of this study were to: (1) use the Rasch model as the means to obtain the soil data that summarize all main soil variables which could influence on soil fertility and (2) utilize the Rasch measures and geostatistical techniques to generate potential management zones.

## 2. Materials and methods

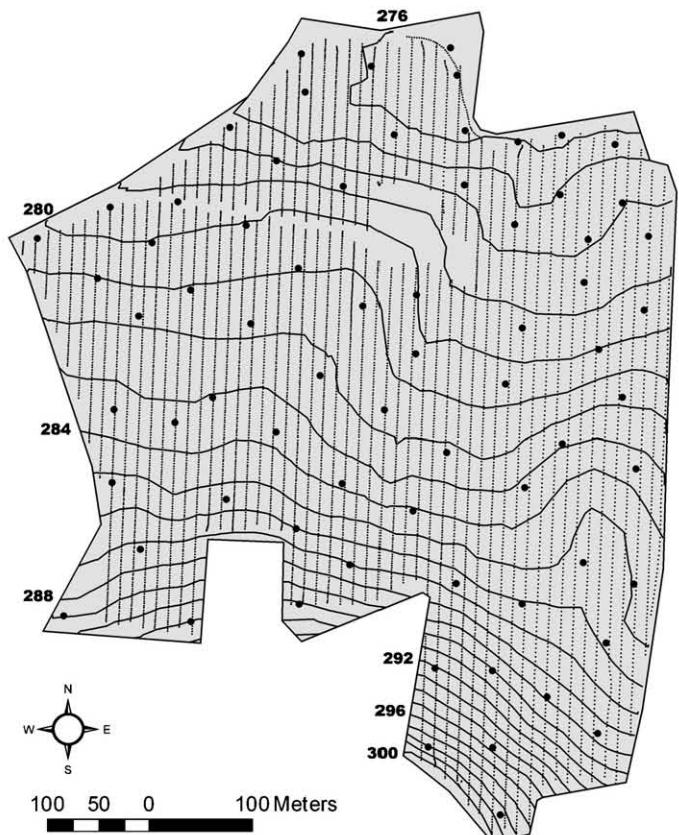
### 2.1. Site description, data collection and measurements

This research was conducted at a farm called Cerro del Amo ( $38^{\circ}58'14''N$ ,  $6^{\circ}33'394''W$ , 225 m a.s.l., Datum WGS84), located in the proximity of Montijo, 37 km east from Badajoz (southwestern Spain). The area of study is 33 ha approximately and an overview of the boundary of the site is given in Fig. 1.

The climate of this area is Mediterranean, modified by the interior location and by oceanic influences from the Atlantic. Highly variable precipitation averages less than 500 mm annually and temperature ranges between  $0^{\circ}C$ , minimum in winter, and more than  $40^{\circ}C$ , maximum in summer.

The topography is dominated by gentle hills dominate; in the substrate limestones predominate over intrusive acidic rocks. According to the USDA-NRCS Soil Taxonomy System (1998), the soil is classified as Rhodoxeralf type.

Soil samples were collected in November 2008. 70 soil samples were taken from the top layer (0–20 cm), using a stratified random sampling scheme (Burrough and McDonnell, 1998) and their coordinates were determined with a millimetric precision with a Maxor-GGDT differentially corrected global positioning system (Javad Navigation Systems, San Jose, CA, USA).



**Fig. 1.** Study site. Soil sampling points (bigger dots) and transects of the measurements of soil apparent electrical conductivity (smaller dots) are shown. Topographic contour lines (in meters) are also depicted.

The following soil properties were determined using standard procedures (Moral et al., 2010): particle-size distribution, pH in suspension, electrical conductivity in suspension, organic matter, cation exchange capacity, available phosphorous, available potassium, and total nitrogen.

Moreover, the entire site was mapped for soil apparent electrical conductivity (ECa) in February 2009 by direct contact, using a Veris 3100 Sensor Cart (Veris Technologies Inc, Salina, KS, USA). The Veris 3100 generates two sets of data: topsoil data, weighted depth readings, from 0 to 30 cm (ECs) and deep data from 0 to 90 cm (ECd). ECa measurements were made along different parallel transects approximately 12 m apart and the final database contained 9269 values of both ECs and ECd. All measurements were georeferenced with submeter accuracy using a Beeline/RT20 system (NovAtel Inc, Calgary, Alberta, Canada). Estimated ECs and ECd at unsampled locations were carried out with the point ordinary kriging method, integrating the spatial correlation structures described with the variograms. The kriged maps showing spatial distributions of both variables in the experimental field were obtained from the estimated values. Later, management zones were determined using principal component analysis and fuzzy cluster classification. In this process, soil texture variables (mainly clay and sand) and both ECs and ECd were considered as they better explained the soil spatial variability and were representative of its fertility. More details about these mobile electrical conductivity measurements, the interpolation process and the delineation of MZ can be found in Moral et al. (2010).

### 2.2. The Rasch model

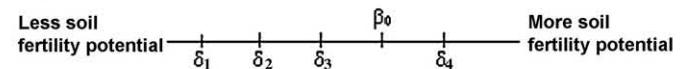
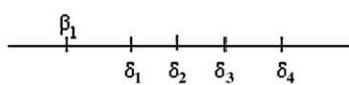
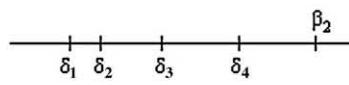
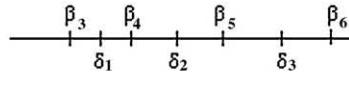
While the Rasch model is well known for its efficiency and precision of transforming categorical item responses to objective scale

measures, it also has an interesting capacity to consolidate data that is already reported sometimes in several scale metrics. If guided by a reasonably coherent conceptual goal, the Rasch model can synthesize and consolidate seemly disparate data into a uniform analytical framework. The purpose of this procedure is to transcend several heterogeneous measures of soil properties (clay, silt, sand, ECs and ECd data) and consolidate them into an overall variable that simplifies interpretation of soil fertility potential.

A key characteristic of the Rasch model is the transformation of raw data to linear units that operationally define a latent variable or theoretical construct. This variable is the amalgamation of noncategorical measures that are conceptually related to a hypothesized latent trait. Their unrelated independent units are then categorized with uniform rating scales and transformed to common logit units with Rasch measurements. However, a question can arise about their meaningfulness. If several soil properties were originally measured in units that fundamentally differ in nature, it is not immediately obvious how to interpret them as ratings (one would legitimately think this situation is similar to summing apples and oranges). Fortunately, meaningfulness of these measures is derived by their probabilistic relations to an overriding theoretical construct, their empirical convergence on an invariant, unidimensional structure. If properties have an *a priori* conceptual relationship with an abstract, hypothetical construct, then their empirical reformulation as ordered categories frees these properties from their prior metric constraints. By describing soil properties in terms of uniform rating categories, unrelated properties and dimensions acquire common ordinality. Through this numerical manipulation, independent scale quantities can be expressed as common ratings ranging from low to high. The rationale for changing several non-categorical, continuous measures to ordered rating categories is a fundamental conviction that these measures are related to an important overall construct, and a desire to better understand their interrelations on this construct.

Let  $n$  be the different locations in the experimental field where measurements of each soil property,  $i$ , were carried out. We define a latent variable or construct, soil fertility potential,  $X_{ni}$ , in which  $n$  refers to the location where the measurement is conducted and  $i$  refers to the soil property. In the case we are studying,  $\beta_n$  ( $n=1, 2, \dots, 70$ ) refers to the 70 locations where the soil texture measurements were carried out, and  $\delta_i$  ( $i=1, 2, 3, 4$ , or 5) refers to the 5 soil properties (clay -1-, sand -2-, silt -3-, ECs -4- and ECd -5-). For instance,  $X_{39,2}$  means the measurement of the property  $i=2$  (sand) at the location, sample point,  $n=39$ . It should be denoted that ECs and ECd data for all locations were obtained from the kriged maps, which were previously generated from the transects of the measurements of soil apparent electrical conductivity (Moral et al., 2010).

$X_{ni}$ , like any another latent variable, can be regarded as a straight line along which items (soil properties),  $\delta_i$ , and sample locations,  $\beta_n$ , are located. The line ranges from less fertility potential to more for any sample location and is operationally defined by the five soil properties previously indicated. The further to the right a sample point is located, the greater its fertility potential. A way to establish the appropriate placement of the locations along the line in terms of items, representing simultaneously the fertility potential of the sample points with respect to the soil properties and vice versa, is as follow: for example,  $X_{01}, X_{02}, X_{03}$  and  $X_{04}$ , means that soil properties  $\delta_1, \delta_2, \delta_3$  and  $\delta_4$  have been measured at the location  $\beta_0$ . In this framework, any soil property has some probability of appearing at any location, and the measurement problem is to represent their linear differences on a probabilistically additive, equal interval scale. The numerical gradient for this scale is called a logit (log odds) and established by estimating ordered category threshold parameters for ratings of soil properties measures collected at sampled locations. To estimate soil property and sample loca-

**Diagram 1****Diagram 2****Diagram 3****Diagram 4**

**Fig. 2.** Representation of the latent variable, soil fertility potential, as a straight line.  $\beta_n$  is the location  $n$ ;  $\delta_i$  is the soil property  $i$ . Diagram 1 illustrates the case of a location  $\beta_0$  which is influenced by the soil properties  $\delta_1, \delta_2, \delta_3$ , but not by  $\delta_4$ . In the diagram 2, the location  $\beta_1$  is not influenced by any soil property. In the diagram 3, the location  $\beta_2$  is influenced by all soil properties. Diagram 4 shows a generalization for some locations and soil properties;  $\beta_3$  is not influenced by any soil property;  $\beta_4$  is influenced by the soil property  $\delta_1$ ;  $\beta_5$  is influenced by the soil properties  $\delta_1$  and  $\delta_2$ ;  $\beta_6$  is influenced by all soil properties,  $\delta_1, \delta_2$  and  $\delta_3$ .

tion positions, this approach was formally implemented in a Rasch model for rating scales (Andrich, 1988; Wright and Masters, 1982).

If at a sampling location  $\beta_n$  all the soil properties  $\delta_i$  do not exert an important influence on soil fertility, then  $\beta_n$  would be placed to the left of these items  $\delta_i$ . On the contrary, if all the properties are exerting an important influence, then  $\beta_n$  will be located on the right of all  $\delta_i$ . The diagram 1 in Fig. 2 illustrates how the location  $\beta_0$ , and the properties  $\delta_1, \delta_2, \delta_3$ , and  $\delta_4$  are located along the line that represents soil fertility potential,  $X_{ni}$ . In this case, soil properties  $\delta_1, \delta_2$ , and  $\delta_3$ , are closer to the left end of the line than location  $\beta_0$  and property  $\delta_4$ ; consequently, at that location, there is fertility potential due to those three properties,  $\delta_1, \delta_2$ , and  $\delta_3$ , but not to  $\delta_4$ . In the diagram 2 (Fig. 2), the location  $\beta_1$  would have little soil fertility potential; neither of the soil properties exerts an important influence on soil fertility potential. In the diagram 3 (Fig. 2), the location  $\beta_2$  would have more soil fertility; all soil properties have influence on fertility potential. If there are two or more locations, their difference in terms of soil fertility potential would be given by their relative positions with respect to the number of soil properties which favors fertility. Thus, the latent variable soil fertility potential,  $X_{ni}$ , is the continuum, represented on a line, along which are located the parameters  $\delta_i$  for the soil properties and  $\beta_n$  for the locations. In the diagram 4 (Fig. 2), location  $\beta_3$  surpasses no soil property; location  $\beta_4$  only surpasses soil property  $\delta_1$ ; location  $\beta_5$  surpasses property  $\delta_1$  and  $\delta_2$ ; and location  $\beta_6$  surpasses all three soil properties. Therefore  $\beta_3$  is the location with least soil fertility, and  $\beta_6$  has the most. Soil property  $\delta_1$  does not exert an influence on the location  $\beta_3$  and influences on the locations  $\beta_4, \beta_5$ , and  $\beta_6$ . For the property  $\delta_2$  is the following: that does not influence on the locations  $\beta_3$  and  $\beta_4$ , and influences on the locations  $\beta_5$  and  $\beta_6$ . Finally, property  $\delta_3$  does not exert an influence on the locations  $\beta_3, \beta_4$ , and  $\beta_5$ , and influences on the location  $\beta_6$ . In this case,  $\beta_6$  is the location where soil fertility potential is greater since it is influenced by all the soil properties,  $\delta_1, \delta_2$ , and  $\delta_3$ ;  $\beta_3$  is the location where soil fertility potential is lower since it is not influenced by any property. On the other hand,  $\delta_1$  is the soil property which more frequently influences on soil fertility potential, and  $\delta_3$  is the soil property which less frequently influences on soil fertility potential.

Consider the dichotomous variable soil fertility potential,  $X_{ni}$ , which describes the fact that a location  $\beta_n$  is influenced by the soil property  $\delta_i$ . If  $X_{ni}=1$  then the location  $\beta_n$  is said to be influenced by that property, and if  $X_{ni}=0$  then location  $\beta_n$  is said not to be

influenced by that property. One way of relating the positions of the locations  $\beta_n$  and of the soil property  $\delta_i$  with the dichotomous variable in terms of probability is:

If  $(\beta_n - \delta_i) > 0$ , means that  $\beta_n$  is on the right of  $\delta_i$  in the line where  $X_{ni}$  is defined; then the probability that the location  $\beta_n$  is influenced by the soil property  $\delta_i$  is higher than 0.5.

If  $(\beta_n - \delta_i) < 0$ , means that  $\beta_n$  is on the left of  $\delta_i$  in the line where  $X_{ni}$  is defined; then the probability that the location  $\beta_n$  is influenced by the soil property  $\delta_i$  is lower than 0.5.

If  $\beta_n = \delta_i$ , means that  $\beta_n$  and  $\delta_i$  coincide in the line where  $X_{ni}$  is defined; then the probability that the location  $\beta_n$  is influenced by the soil property  $\delta_i$  is 0.5:

that is

If  $(\beta_n - \delta_i) > 0$ , then  $P[X_{ni} = 1] > 0.5$ .

If  $(\beta_n - \delta_i) < 0$ , then  $P[X_{ni} = 1] < 0.5$ .

If  $\beta_n = \delta_i$ , then  $P[X_{ni} = 1] = 0.5$ .

The difference  $(\beta_n - \delta_i)$  can range from  $-\infty$  to  $+\infty$ , and the probability from 0 to 1, i.e.:

$$-\infty \leq (\beta_n - \delta_i) \leq +\infty \quad \text{and} \quad 0 \leq P[X_{ni} = 1] \leq 1.$$

If we use the difference as an exponent of  $e$ , then:

$$0 \leq e^{(\beta_n - \delta_i)} \leq +\infty$$

With a further adjustment, we can bring the expression into the interval from zero to one:

$$0 \leq \left\{ \frac{e^{(\beta_n - \delta_i)}}{1 + e^{(\beta_n - \delta_i)}} \right\} \leq 1$$

The relationship can be written as (Álvarez and Pulgarín, 1996):

$$P[X_{ni} = 1; \beta_n, \delta_i] = \frac{e^{(\beta_n - \delta_i)}}{1 + e^{(\beta_n - \delta_i)}}$$

which is the probability that location  $n$  has the influence of the soil property corresponding to item  $i$ , given the parameters  $\beta_n$  and  $\delta_i$ . This is the formula obtained by Rasch (1980) in his treatise on latent variables.

### 2.3. Geostatistical interpolation

The formulation of the Rasch model allowed to obtain values of the soil fertility potential for all sample points, incorporating information of 5 soil properties (clay, sand, silt, ECs and ECd). Later, it was necessary to estimate the soil fertility potential at other locations where direct measurements were not carried out.

Geostatistical methods for interpolation start with the recognition that the spatial variation of any continuous variable, soil fertility potential in this case study, is often too irregular to be modelled by a simple mathematical function. Instead, the variation can be better described by a stochastic surface. Thus, the studied variable is distributed continuously (regionalized variable), taking values everywhere within the study area, and considered random, which means that can take a series of outcome values according to some probability distribution.

It is known that three phases have to be completed to perform a geostatistical work (Isaaks and Srivastava, 1989):

- (1) *Exploratory analysis of data:* Data were studied without considering their geographical distribution. Statistics is applied to check data consistency, removing outliers, if they exist, and identifying statistical distribution of data.
- (2) *Structural analysis of data:* Spatial correlation or dependence of the variable was quantified with semivariograms, or sim-

ply variograms. These functions relates the semivariance, half the expected squared difference between paired data values  $Z(x_i)$  and  $Z(x_i + h)$ , to the lag distance,  $h$ , by which sample points are separated. For discrete sampling locations, the function is estimated as:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} \{Z(x_i) - Z(x_i + h)\}^2$$

where  $\gamma(h)$  is the experimental semivariance value at distance interval  $h$ ,  $Z(x_i)$  are the measured sample values at sample points  $x_i$ , in which there are data at  $x_i$  and  $x_i + h$ ;  $N(h)$  is the total number of sample pairs within the distance interval  $h$ .

When an experimental variogram is defined, i.e. some points of a variogram plot are determined by calculating variogram at different lags, a model (theoretical variogram) should be fitted to the points.

(3) *Predictions:* The main objective of a geostatistical study is to get estimates of values of the studied variable at unsampled locations, considering the spatial distribution pattern from sample points. Geostatistics offers a great variety of methods, known as kriging, that provide estimates for unsampled locations.

All geostatistical estimators are variants of the linear regression estimator  $Z^*(x)$ :

$$Z^*(x) - m(x) = \sum_{i=1}^n w_i(x) \cdot [Z(x_i) - m(x_i)] \quad (2)$$

where each datum,  $Z(x_i)$ , has an associated weight,  $w_i(x)$ , and,  $m(x)$  and  $m(x_i)$  are the expected values of  $Z^*(x)$  and  $Z(x_i)$  respectively. The kriging weights must be determined to minimize the estimation variance,  $\text{Var}[Z^*(x) - Z(x)]$ , while ensuring the unbiasedness of the estimator,  $E[Z^*(x) - Z(x)] = 0$ .

All different types of kriging are distinguished depending on the chosen model for the trend,  $m(x)$ , of the random function  $Z(x)$  (e.g. Goovaerts, 1997). Thus,  $m(x)$  is unknown in the ordinary kriging technique and is considered to fluctuate locally, maintaining the stationarity within the local neighbourhood.

When an estimate is computed at any unsampled location, the weights,  $w_i(x)$ , corresponding to each sample point, are generated solving a system of linear equations where the fitted (theoretical) variogram controls the spatial variability of the studied variable (see Isaaks and Srivastava, 1989, or Goovaerts, 1997, for a detailed presentation of the kriging algorithms).

### 2.4. Data treatment

Different software packages were used to analyse raw data. Winsteps 3.69 computer program was employed to conduct the formulation of the Rasch model (Linacre, 2000). The geostatistical analysis, including all 3 phases described in the previous section, were carried out with the extension Geostatistical Analyst of the GIS software ArcGIS (version 9.3, ESRI Inc, Redlands, CA, USA).

Maps of kriged estimates provided a visual representation of the distribution of the soil fertility potential in the experimental field. These maps were produced with the ArcMap module of the ArcGIS, after conducting the geostatistical study.

## 3. Results and discussion

### 3.1. Determination of soil fertility potential at sample points

The formulation of the Rasch model to get a measure of soil fertility at each sample point, which would take into account the



Fig. 3. Schematic diagram of the stages involved in the formulation of the Rasch model.

**Table 1**

Soil properties measures recoded into rating scale categories.

Clay (%)	Sand (%)	Silt (%)	ECs ( $\text{mS m}^{-1}$ )	ECd ( $\text{mS m}^{-1}$ )	Rating scale value
<9.8 or >54.4	<0.5 or >73.3	<5.8 or >60.9	<5.4	<24.2	0
(9.8–12.3) or [51.9–54.4)	(0.5–1.3) or [68.6–73.3)	(5.8–9.0) or [57.6–60.9)	(5.4–7.4]	(24.2–29.6]	1
(12.3–14.8) or [49.4–51.9)	(1.3–2.7) or [63.9–68.6)	(9.0–12.3) or [54.4–57.6)	(7.4–9.3]	(29.6–34.9]	2
(14.8–17.3) or [46.9–49.4)	(2.7–7.5) or [59.2–63.9)	(12.3–15.5) or [51.1–54.4)	(9.3–11.2]	(34.9–40.4]	3
(17.3–19.7) or [44.5–46.9)	(7.5–12.1) or [54.5–59.2)	(15.5–18.7) or [47.9–51.1)	(11.2–13.2]	(40.4–45.8]	4
(19.7–22.2) or [42.0–44.5)	(12.1–16.7) or [49.8–54.5)	(18.7–21.2) or [44.7–47.9)	(13.2–15.1]	(45.8–51.1)	5
(22.2–24.7) or [39.5–42.0)	(16.7–21.6) or [45.1–49.8)	(21.9–25.2) or [41.4–44.7)	(15.1–17.1]	(51.1–56.5)	6
(24.7–27.1) or [37.1–39.5)	(21.6–26.3) or [40.4–45.1)	(25.2–28.5) or [38.2–41.4)	(17.1–19.0]	(56.5–61.9]	7
(27.1–29.6) or [34.6–37.1)	(26.3–30.1) or [35.7–40.4)	(28.5–31.7) or [34.9–38.2)	(19.0–21.0]	(61.9–67.3]	8
(29.6–34.6)	(30.1–35.7)	(31.7–34.9)	(21.0–22.9]	(67.3–72.7]	9

different contribution of the five soil properties considered (clay, sand, silt, ECs and ECd), was achieved through the stages shown in Fig. 3.

The first stage was a previous transformation of the data to a common scale (Wright and Masters, 1982). Soil properties measures were categorically coded according to a plan where each location was rated on a scale (0–9) for each property. For soil texture properties, the ideal percentage of each texture class was about a third of the total, so the maximum categorical value (9) was assigned for an interval around 33% of clay, sand or silt content. Later, the rating scale values were assigned to classes with similar amplitude for each soil texture property, but different between them, depending on the range of variation of the property, i.e. the minimum and maximum values. It is important to denote that it is penalized not only the shortage but also the excess of each soil texture content. However, in the case of ECs and ECd, classes also had similar amplitude but the categorical values were established to correspond the highest ones with those classes that also contained the highest ECs or ECd measures. Table 1 presents the assignment of categorical values across properties measures. For example, at sampling location 5 ( $\beta_n=5$ , Table 2), the measurements of all soils properties were: clay = 53.76%; sand = 34.24%; silt = 12.01%; ECs =  $21.89 \text{ mS m}^{-1}$ ; ECd =  $68.50 \text{ mS m}^{-1}$ . After coding them, using the categories shown in Table 1, the rating scale values were: clay → 1; sand → 9; silt → 2; ECs → 9; ECd → 9.

After processing all data, results shown in Table 2 were obtained. It should be highlighted the raw score and measure values. The first one shows the sum of points of all scores (rating scale categories) for each soil property. The second one indicates the measures for the locations according to their raw score. For example, at sampling location 5, raw score =  $1+9+2+9+9=30$ , i.e. the rating scale

values for all soil properties were summed. The measure value is estimated with the Winsteps program, where the approach previously described was implemented and parameters  $\delta_i$  and  $\beta_n$  are located in the straight line which represents the latent variable, using an unconditional maximum likelihood procedure (Wright and Panchapakesan, 1969).

Another interesting result, which was obtained after processing the data, is shown in Table 3, where the influence of each individual soil property on the fertility potential can be observed. Thus, the ECs and ECd are the most influential properties on the soil fertility in the experimental field, since they got the highest raw score, and will correspond to the lowest measure, i.e. all locations are influenced by the ECs and ECd. Unlike the ECs and ECd, silt soil content is the property with a lowest raw score but, however, the highest measure; therefore, the influence on the soil fertility in the experimental field is the least important among all individual soil properties, i.e. the silt does not influence as much as the ECs and ECd. This is in accordance with other studies in which soil apparent electrical conductivity is related to different soil fertility variables, as cation exchange capacity, pH or total nitrogen, being considered a good indicator of soil fertility (e.g. Mertens et al., 2008; Moral et al., 2010).

Rasch model can provide more information through the misfitting analysis (Álvarez, 2005). However, the study of misfits has not been included in this paper because we were interested in the global soil fertility potential in the experimental field.

### 3.2. Spatial distribution maps of soil fertility potential and delineation of management zones

A geostatistical work was conducted to estimate soil fertility potential at any unsampled point, using as previous information all measure values obtained with the Rasch model at sample locations (Table 2). During the exploratory analysis of data, it was revealed that they were distributed close to normally. The mean and median

**Table 2**

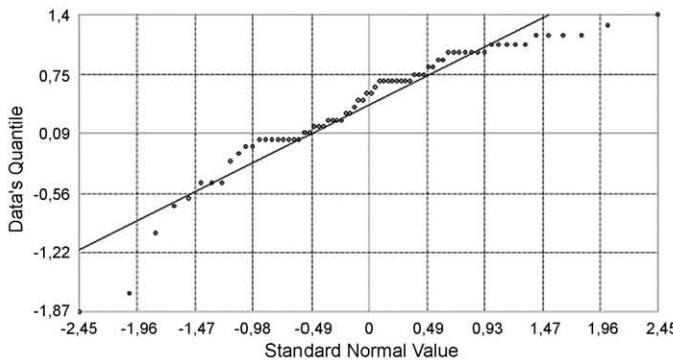
Results obtained after applying the Rasch model: sum of points of the common scale for all individual soil properties (raw score) and soil fertility potential (measure). Only some sampling points are shown. In total there are 70 samples.

Sampling point number ( $\beta_n$ )	Raw score	Measure
1	28	0.46
2	26	0.31
3	31	0.67
4	37	1.17
5	30	0.60
6	29	0.63
7	35	0.98
8	33	0.82
9	31	0.67
...		...

**Table 3**

Influence of each soil property on the fertility potential in the experimental area. The raw score is the sum of points of the common scale for each soil property considering all samples (70). The measure indicates the position of each soil property along the straight line that represents the latent variable, soil fertility potential.

Soil property	Raw score	Measure
Silt	331	0.30
Clay	346	0.22
Sand	408	-0.13
ECs	417	-0.19
ECd	418	-0.19



**Fig. 4.** Normal QQ plot of the measure of soil fertility potential data. In general, the points lie close to the straight line which indicates perfect normality.

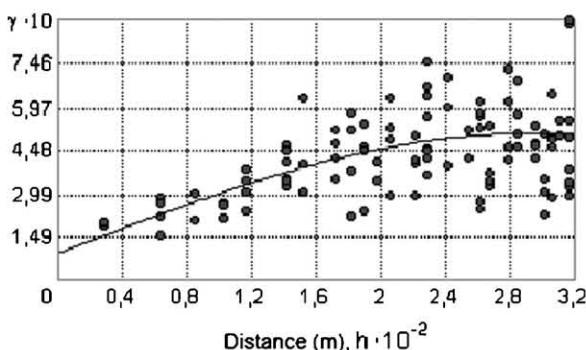
were similar (0.41 and 0.53 respectively), the coefficient of skewness was  $-1.17$ , and the kurtosis was 4.86. A normal QQ plot (Fig. 4) confirms that data could be considered normally distributed. It is known that normality is not a prerequisite for using the geostatistical interpolators, but it is a desirable property because they will only generate the best absolute prediction if the random function fits a normal distribution (e.g. Goovaerts, 1997).

Later, the experimental variogram was computed with a directional tolerance of  $360^\circ$  (omnidirectional). Isotropy conditions were assumed because the anisotropy ratio (quotient between ranges of the directional variograms in the major and minor anisotropy directions) was very low, around 1.37 (e.g. Goovaerts, 1997). After computing the experimental variogram, a spherical theoretical variogram was fitted to their points (Fig. 5). This model was chosen because probably a variable like soil fertility is not evenly distributed in reduced distances, so this kind of spatial variability is explained by those theoretical variograms (Isaaks and Srivastava, 1989).

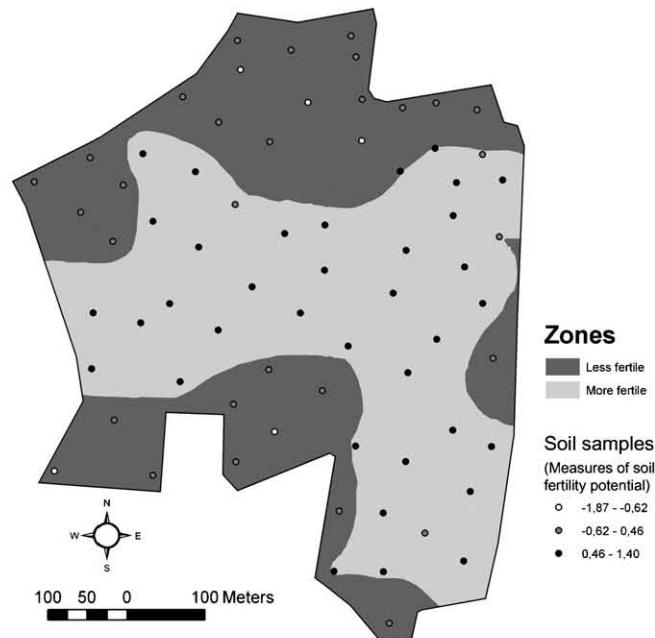
The parameters of the spherical model were: range = 288.4 m; sill = 0.505; nugget effect = 0.093.

According to Cambardella et al. (1994), the ratio of nugget to sill can be used to denote spatial dependence of soil attributes (ratio < 25% indicated strong spatial dependence; between 25 and 75% denoted moderate spatial dependence; greater than 75% indicated weak spatial dependence). In this case study, values of this ratio were 18.42%, indicating that the spatial dependence of the variable was strong. This is an additional support to consider kriging as the optimum interpolation method.

Ordinary kriging was used as the estimation method, integrating the spatial correlation structures described with the variograms. The kriged map showing spatial distribution of the variable in the experimental field can be obtained from the estimated values. From



**Fig. 5.** Experimental variogram (points) and theoretical spherical variogram (line) for the measures of soil fertility potential.



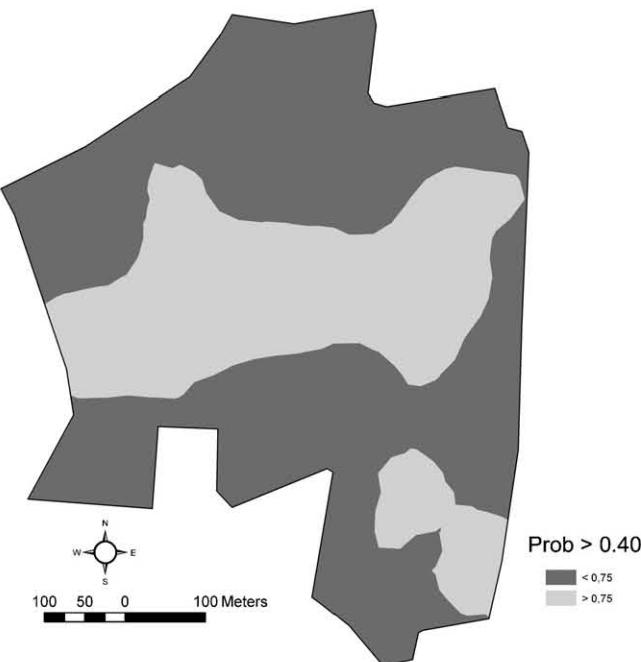
**Fig. 6.** Management zones map based on the kriged map of soil fertility potential and an equal-size classification method in study area. Values of the measure at the sampling locations have been classified according to the natural jenk (breaks) technique.

these estimates, the distribution of soil fertility potential in the experimental field can be mapped.

If, for instance, two different zones should be delimited, a method called equal-size classification could be used, in which the number of soil fertility potential grid cells was divided to identify two zones approximately equal in area (Fig. 6). This two zones have been compared with those delimited using an unsupervised clas-



**Fig. 7.** Management zones map based on a fuzzy cluster, unsupervised, classification in study area (Moral et al., 2010). The white line delimits the management zones obtained using the measure of soil fertilization potential and the equal-size classification method (Fig. 6). Values of the measure at the sampling locations have been classified according to the natural jenk (breaks) technique.



**Fig. 8.** Management zones map based on the probability map of soil fertility potential  $> 0.40$  (Rasch measure) in study area. Light zone could be considered as very fertile (probability to exceed the measure of 0.40 is above 0.75).

sification (Moral et al., 2010), which utilizes an iterative process to group clusters of statistically similar data. Thus, in Fig. 7 a white line to delimit both zones, obtained using the equal-size classes method, has been superimposed on the unsupervised classification map. There is a clear coincidence between both methods. Samples with higher measure (black points in Fig. 7), denoting more soil fertility potential, are included in the most fertile zone defined by any of the methods. Thus, both methodologies may be acceptable bases for determining MZ.

Another interesting application of the geostatistical techniques based on the measures of the soil fertility potential is the generation of probability maps (Goovaerts, 1997), which could also be used to produce MZ. For example, a probability map of soil fertility potential above 0.40 (this is the mean value of the Rasch measure for all samples) could be generated and areas with high probabilities, for instance above 0.75, may be regarded as very fertile (Fig. 8). In this type of map, the probabilities provide a measurement of confidence for hazard assessment of soil fertility potential.

#### 4. Conclusions

The formulation of the Rasch model has been proposed to define a measure of soil fertility potential which integrates different measurements of individual soil variables: clay, sand and silt content, and ECs and ECd. Moreover, this method can detect the influence of each soil property on the fertility potential for each sampling location, showing, in the studied field, that soil apparent electrical conductivity (both ECs and ECd) is the most influential property on soil fertility, being in accordance with other previous studies (Moral et al., 2010) in the same experimental field.

Later, geostatistical techniques were used to estimate soil fertility potential throughout the field. After analysing data and obtaining a good variogram, ordinary kriging was used to estimate at unsampled locations. Subsequently, kriged estimates were employed to map soil fertility potential and management zones were delimited using an equal-size classification method. It was observed that these management zones were very similar to those

obtained by a fuzzy cluster classification. Moreover, another useful information for hazard assessment of soil fertility potential or for alternatively determining management zones was also obtained when a probability map was produced.

The combination of the Rasch model and geostatistical techniques is a powerful tool to developing an objective strategy to define site-specific management zones, which is the first necessary stage to implement precision farming in a field. It constitutes a logical and objective way to map soil spatial variability, making possible the generation of high spatial resolution maps, as it is needed for precision farming or generally for a site-specific soil management.

Thus, in the studied field, identification of the two management zones is the first necessary stage to implement precision farming. Variable-rate application of inputs will be carried out, decreasing fertilization in the less fertile area, less productive, and, in consequence, minimizing the application of chemical substances with the aim of obtaining a more cost-effective field management, including less use of agricultural machinery, which moreover will give place to others additional benefits (environmental, economic and energetic).

#### Acknowledgements

The authors are very grateful to Daniel Becerra for his support in the field operations. This research was financed by the Junta de Extremadura and the European Regional Development Fund (ERDF) through the project PRI07B080 (Spatial variability and optimizing of the colza yield in direct sowing using precision agriculture techniques).

#### References

- Alvarez, P., 2005. Several Noncategorical Measures Define Air Pollution Construct. Rasch Measurement in Health Science. JAM Press, Maple Grove, Minnesota, USA.
- Alvarez, P., Pulgarin, A., 1996. The Rasch Model. Measuring the impact of scientific journals: analytical chemistry. *J. Am. Soc. Inform. Sci.* 47, 458–467.
- Andrich, D., 1988. Rasch Model for Measurement. Sage Publications, Newbury Park, CA, USA.
- Burrough, P.A., McDonnell, R.A., 1998. Principles of Geographical Information Systems. Oxford University Press, Oxford, UK.
- Camardella, C.A., Moorman, T.B., Novak, J.M., Parkin, T.B., Karlen, D.L., Turco, R.F., Konopka, A.E., 1994. Field-scale variability of soil properties in Central Iowa soils. *Soil Sci. Soc. Am. J.* 58, 1501–1511.
- Diker, K., Heermann, D.F., Brodahl, M.K., 2004. Frequency analysis of yield for delineating yield response zones. *Precision Agric.* 5, 435–444.
- Fleming, K.L., Heermann, D.F., Westfall, D.G., 2004. Evaluating soil color with farmer input and apparent soil electrical conductivity for management zone delineation. *Agron. J.* 96, 1581–1587.
- Fridgen, J., Kitchen, N.R., Sudduth, K.A., Drummond, S.T., Wiebold, W.J., Fraisse, C.W., 2004. Management Zone Analyst (MZA): software for subfield management zone delineation. *Agron. J.* 96, 100–108.
- Goovaerts, P., 1997. Geostatistics for Natural Resources Evaluation. Oxford Univ. Press, New York.
- Isaaks, E.H., Srivastava, R.M., 1989. An Introduction to Applied Geostatistics. Oxford Univ. Press, New York.
- Johnson, C.K., Mortensen, D.A., Wienhold, B.J., Shanahan, J.F., Doran, J.W., 2003. Site-specific management zones based on soil electrical conductivity in a semiarid cropping system. *Agron. J.* 95, 303–315.
- Kravchenko, A.N., Bullock, D.G., Reetz, H.F., 2000. Correlation of corn and soybean grain yield with topography and soil properties. *Agron. J.* 92, 75–83.
- Li, Y., Shi, Z., Li, F., Li, H.Y., 2007. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. *Comp. Electron. Agric.* 56, 174–186.
- Linacre, J.M., 2000. Winsteps (Computer Program and Manual). MESA Press, Chicago.
- Mallarino, A.P., Oyarzabal, E.S., Hinz, P.N., 1999. Interpreting within-field relationships between crop yields and soil and plant variables using factor analysis. *Precision Agric.* 1, 15–25.
- McCann, B.L., Pennock, D.J., van Kessel, C., Walley, F.L., 1996. The development of management units for site-specific farming. In: Robert, P.C. (Ed.), Proc. Int. Conf. Precision Agric. 3rd, St Paul, MN, ASA, CSSA, and SSSA, Madison, WI, USA, 23–26 June 1996, pp. 295–302.
- Mertens, F.M., Pätzold, S., Welp, G., 2008. Spatial heterogeneity of soil properties and its mapping with apparent electrical conductivity. *J. Plant Nutr. Soil Sci.* 171, 146–154.

- Moral, F.J., Terrón, J.M., Marques da Silva, J.R., 2010. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. *Soil Till. Res.* 106, 335–343.
- Moral, F.J., Álvarez, P., Canito, J.L., 2006. Mapping and hazard assessment of atmospheric pollution in a medium sized urban area using the Rasch model and geostatistics techniques. *Atmos. Environ.* 40, 1408–1418.
- Morari, F., Castrignanò, A., Pagliarin, C., 2009. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. *Comp. Electron. Agric.* 68, 97–107.
- Mulla, D.J., 1991. Using geostatistics and GIS to manage spatial patterns in soil fertility. In: Kranzler, G. (Ed.), *Automated Agriculture for the 21st Century*. ASAE, St. Joseph, MI, USA, pp. 336–345.
- Ortega, R.A., Santibáñez, O.A., 2007. Determination of management zones in corn (*Zea mays L.*) based on soil fertility. *Comp. Electron. Agric.* 58, 49–59.
- Ortega, R.A., Westfall, D.G., Gangloff, W.J., Peterson, G.A., 1999. Multivariate approach to N and P recommendations in variable rate fertilizer applications. In: Stafford, J.V. (Ed.), *Proceedings of the Second European Conference on Precision Agriculture*. Odense, Denmark, pp. 387–396.
- Rasch, G., 1980. *Probabilistic Models for Some Intelligence and Attainment Tests*, revised and expanded ed. University of Chicago Press, Denmark.
- Schepers, A.R., Shanahan, J.F., Liebig, M.A., Schepers, J.S., Johnson, S.H., Luchiari, A., 2004. Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. *Agron. J.* 96, 195–203.
- USDA-NRCS, 1998. *Keys to Soil Taxonomy*, 8th ed. United States Department of Agriculture-Natural Resources Conservation Service, Washington, USA.
- Wright, B.D., Masters, G.N., 1982. *Rating Scale Analysis*. MESA Press, Chicago.
- Wright, B.D., Panchapakesan, N., 1969. A procedure for sample-item analysis. *Educ. Psychol. Meas.* 29, 23–48.
- Xin-Zhong, W., Guo-Shun, L., Hong-Chao, H., Zhen-Hai, W., Qing-Hua, L., Xu-Feng, L., Wei-Hong, H., Yan-Tao, L., 2009. Determination of management zones for a tobacco field based on soil fertility. *Comp. Electron. Agric.* 65, 168–175.

**6. ESTUDIO DE LA VARIABILIDAD TEMPORAL DE LA CE<sub>s</sub> Y DE LA  
PRODUCCIÓN DEL CULTIVO DE GIRASOL EN LA PARCELA DE ENSAYO.**

## **6.1. INTRODUCCIÓN**

A partir de los resultados obtenidos en los trabajos realizados en la parcela experimental se ha comprobado que tanto la conductividad eléctrica aparente superficial,  $CE_s$ , como la profunda,  $CE_p$ , son variables adecuadas para modelizar las propiedades de un suelo determinantes de su fertilidad. Ambas son fáciles de medir a coste reducido, si se dispone del equipamiento adecuado, y pueden ser utilizadas para la elaboración de los mapas que se precisan a fin de emplear las técnicas de agricultura de precisión en la práctica agrícola. Para ello sólo es necesario obtener el mapa de zonificación y realizar una analítica de suelo mediante un muestreo dirigido a los puntos característicos de las diferentes zonas homogéneas definidas en el mismo, tras lo cual pueden ser elaborados mapas de tratamientos variables en los cultivos.

De los resultados obtenidos en los trabajos, incluidos en el capítulo tercero, se deduce que las correlaciones existentes en las diversas variables físico-químicas estudiadas y la  $CE_s$  son mayores que con la  $CE_p$ , por lo cual la variable  $CE_s$  parece ser más adecuada que la  $CE_p$  para realizar el análisis de la variabilidad temporal de la conductividad eléctrica aparente y relacionarlo con el mismo análisis referido a la producción de girasol en secano.

La variabilidad temporal que pudiera existir en la determinación de la  $CE_s$  no fue considerada en los trabajos precedentes; por ello, a continuación se pretende estudiar este factor a partir de las mediciones realizadas en la parcela de ensayo, en diferentes fechas y condiciones, con el objeto de comprobar si este procedimiento es estable o muestra variabilidad a lo largo del tiempo en la parcela experimental considerada.

Diversos autores han utilizado varios métodos para el análisis de la variabilidad espacial y temporal de la producción. Por ejemplo, Blackmore et al. (2003) emplearon varios estadísticos con el fin de estudiar las tendencias espacio-temporales en diversas parcelas agrícolas, Lark y Stafford (1996) desarrollaron una técnica de análisis no supervisada de agrupamientos con las que identificaron las áreas homogéneas de la parcela sin utilizar ningún concepto agronómico, Larscheid y Blackmore (1996) desarrollaron una técnica para normalizar los datos de rendimiento de una serie de años sucesivos y producir mapas de tendencias, Panneton et al. (2001) usaron una técnica similar para identificar qué parcelas

eran estables e inestables en el tiempo, Fraisse et al. (1999) fueron más allá, incluyendo variables topográficas y la conductividad eléctrica del suelo en su análisis, Marques da Silva (2006), con la metodología propuesta por Blackmore et al. (2003), estudió la variabilidad espacial y temporal de una parcela de maíz de regadío y Swindell (1997) analizó las tendencias espaciales a través del tiempo mediante un sistema de información geográfica (SIG), considerando diversas clasificaciones anuales de los rendimientos para hacer una clasificación de los mismos. Todos ellos han tratado de identificar las áreas de las parcelas analizadas en las que la producción es estable en el tiempo y, en consecuencia, las zonas en las que es inestable, variando de forma significativa en las diferentes campañas agrícolas.

En este trabajo se analizará la variabilidad espacial y temporal del cultivo de girasol en condiciones de secano mediante técnicas de análisis de componentes principales y de regresión ponderada geográficamente, junto con otras herramientas del sistema de información geográfica ArcGIS 10.0.

Como corolario de todos los trabajos realizados, se han contrastado las hipótesis teóricas realizadas, en lo relativo a la “productividad” o a la “fertilidad potencial”, con la evidencia práctica que supone disponer de los mapas de producción citados anteriormente en la parcela experimental.

## 6.2. MATERIALES Y MÉTODOS

La realización del estudio parte de tres muestreos de CE<sub>s</sub>, efectuados los días 13/02/2009, 24/04/2009 y 27/01/2010, con el mismo equipo VERIS 3100 descrito en Moral et al. (2010) (capítulo 3).

Durante el periodo comprendido entre los sucesivos muestreos, la parcela estuvo de barbecho en el año 2009 y sembrada de girasol en el año 2010, no habiéndose aportado ningún tipo de abonado que pudiera alterar alguna de las propiedades químicas del suelo. En consecuencia, la única alteración que se pudo producir se debió a las extracciones de nutrientes por parte del cultivo. No obstante, los dos primeros muestreos se realizaron con dos meses de diferencia, estando la parcela de barbecho, por lo cual el factor cultivo no

existió y las posibles variaciones se debieron exclusivamente a las diferentes condiciones de humedad o de la cobertura vegetal existente. El tercer muestreo se realizó dos años más tarde y, desde el precedente, sólo existió una cosecha de girasol.

Adicionalmente, se dispone de los mapas de cosecha del cultivo de girasol en secano que fue sembrado en la parcela experimental en los años 2007, 2010 y 2011, los cuales fueron elaborados a partir de la información recogida mediante una cosechadora de la marca New Holland, modelo TC56, dotada de un monitor de cosecha de la marca AgLeader, modelo PFAdvantage, con antena GPS monofrecuencia, modelo GPS 1000 Plus, también de la marca AgLeader, y correcciones diferenciales obtenidas a través del sistema EGNOS (European Geostationary Navigation Overlay Service), en tiempo real, con precisión métrica (error absoluto probable comprendido entre 1 y 2 m).

Todos estos datos han permitido realizar un análisis de la variabilidad temporal de la CE<sub>s</sub>, por un lado, y de las producciones en los años mencionados por otro; en ambos casos, se han utilizado las herramientas de “análisis de componentes principales” (ACP) (ArcToolbox/Herramientas de Spatial Analyst/Multivariante /Componentes Principales) del sistema de información geográfica ArcGIS 10.0.

Para la elaboración de cada uno de los mapas de distribución tanto de CE<sub>s</sub> de los días indicados, como de las producciones en los años correspondientes, se emplearon algoritmos geoestadísticos. Por ello, se siguieron las tres etapas de un análisis geoestadístico (e.g. Govaerts, 1997).

Previamente, con el fin de uniformar los datos de los diferentes muestreos, se realizó un proceso de normalización a una distribución de media 0 y desviación típica 1, consistente en aplicar a cada dato la siguiente transformación:

$$X_{norm} = \frac{X_i - \bar{X}}{D_v} \quad (\text{ecuación 1})$$

donde  $X_{norm}$  es el valor normalizado,  $X_i$  es el valor de la variable en cada punto muestral,  $\bar{X}$  es la media y  $D_v$  la desviación típica del muestreo, obteniéndose las nuevas variables

denominadas conductividad eléctrica superficial normalizada ( $CE_sN$ ) y rendimiento seco normalizado (RSN).

Para llevar a cabo los análisis geoestadísticos y obtener los mapas en base a dichos algoritmos se ha empleado la extensión “Geostatistical Analyst” de ArcGIS 10.0.

En el caso de la  $CE_s$ , en los tres días estudiados se utilizó un krigado de tipo ordinario, considerándose un modelo esférico para el variograma teórico.

Para las producciones de girasol el procedimiento fue similar, se realizó un krigado ordinario con un modelo exponencial para el variograma teórico.

Los mapas obtenidos de las distribuciones espaciales de  $CE_s$  y de rendimiento fueron transformados en imágenes con un pixel de 5 m de resolución espacial, para lo cual se empleó la herramienta “exportar a raster” de ArcGIS 10.

El estudio de la variabilidad temporal entre las distribuciones espaciales de  $CE_s$  y los rendimientos en las diferentes fechas consideradas se llevó a cabo con la herramienta mencionada de ACP, obteniéndose información de la correlación existente entre los mismos y, adicionalmente, se han creado los mapas de las componentes principales a considerar, por un lado los mapas de  $CE_s$  y, por otro, los de rendimiento.

Con posterioridad, para efectuar un análisis comparativo acerca de la estabilidad temporal entre la distribución espacial de la  $CE_sN$  y del RSN, en el periodo considerado, se ha llevado a cabo un nuevo ACP entre las componentes principales primeras obtenidas en los análisis de componentes principales previos (con los mapas de  $CE_s$  y RSN).

Para determinar cómo varían espacialmente las relaciones entre las dos variables iniciales consideradas,  $CE_sN$  y RSN, se empleó la herramienta “regresión ponderada geográficamente” (RPG) (Herramientas de estadística espacial/Modelado de relaciones espaciales/Regresión ponderada geográficamente), considerando como variable dependiente la componente principal primera del ACP realizado para el RSN y, la componente principal primera resultado del ACP realizado con la  $CE_sN$  como variable independiente.

Para la RPG se definieron inicialmente un conjunto de puntos distribuidos aleatoriamente en el área experimental, lo cual se hizo mediante la herramienta “crear puntos aleatorios” (“Create Random Points”) de ArcGIS 10.0 (Herramientas de administración de datos/Clase de entidad/Crear puntos aleatorios). De esta forma se obtuvieron 179 puntos.

A continuación se creó una capa formada por círculos con centro en cada uno de los 179 puntos y radio 15 m, mediante la herramienta “zona de influencia” (“Buffer”) de ArcGIS 10.0 (ArcToolbox/Herramientas de análisis/Proximidad/Zona de influencia), y utilizando la herramienta “estadísticas zonales como tabla” (“Zonal Statistics as Table”) (ArcToolbox/Herramientas de Spatial Analyst/Zonal/Estadísticas zonales como tabla), se han extraído, de las capas raster de cada una de las componentes principales primeras, tanto de CE<sub>s</sub>N como del RSN, la media de los valores de las celdas contenidos en cada uno de los círculos, generándose así dos tablas con los 179 puntos muestrales y sus correspondientes valores de las medias de las componentes principales primeras de la CE<sub>s</sub>N y del RSN. Estos valores medios se emplearon como datos para la RPG, dando lugar a una tabla con diferentes estadísticos para cada uno de los puntos. Como último paso, los coeficientes de determinación R<sup>2</sup> obtenidos en la RPG para cada punto se utilizaron como puntos muestrales para, mediante un nuevo krigado ordinario con un modelo gaussiano para el variograma teórico, obtener un mapa en el que se muestra la variación espacial de la correlación entre las dos variables.

Finalmente se ha evaluado la relación entre la distribución espacial de la variable latente “fertilidad potencial”, obtenida en el trabajo incluido en capítulo 5 de la presente tesis, y la componente principal primera del análisis realizado e incluido en el apartado anterior entre la serie temporal de la CE<sub>s</sub>N y del RSN. Para ello, se ha utilizado la herramienta de ACP, obteniéndose el coeficiente de correlación espacial existente entre las dos capas raster.

## **6.3. RESULTADOS Y DISCUSIÓN**

### **6.3.1. VARIABILIDAD TEMPORAL DE LA CE<sub>s</sub>**

En la primera etapa del estudio geoestadístico, el análisis exploratorio de los datos, se obtuvieron los diferentes estadísticos para cada uno de los muestreos de CE<sub>s</sub> y se detectaron los puntos muestrales que tenían un carácter anómalo, ya sea por defecto o por exceso, los cuales se eliminaron de la base de datos para no alterar los procesos de estimación posteriores.

Los estadísticos de la CE<sub>s</sub> en cada muestreo, después de eliminar datos anómalos, se muestran en la tabla 1.

Tabla 1 – Estadísticos de los muestreos de conductividad eléctrica aparente superficial, CE<sub>s</sub> (mS/m).

Fecha de muestreo	19/02/2009	24/04/2009	27/01/2011
Mínimo (mS/m)	0,50	1,20	0,50
Máximo (mS/m)	26,30	20,90	33,50
Media (mS/m)	16,14	10,63	17,56
Desviación típica (mS/m)	5,84	3,59	6,22
Mediana (mS/m)	18,50	10,90	19,50
Coeficiente de sesgo	-0,79	-0,22	-0,76
Curtosis	2,45	2,99	2,64
Primer Cuartil (mS/m)	11,70	8,57	13,40
Tercer Cuartil (mS/m)	20,80	13,00	22,20

En primer lugar cabe destacar que, en todos los casos, los datos se ajustan bastante bien a una distribución normal, ya que la media y la mediana son similares y el coeficiente de sesgo es muy reducido.

Una vez efectuada la normalización se obtuvieron los estadísticos que se recogen en la tabla 2.

Tabla 2 – Estadísticos de los muestreos de conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N.

Fecha de muestreo	19/02/2009	24/04/2009	27/01/2011
Mínimo	-2,68	-2,63	-2,74
Máximo	1,74	2,86	2,56
Mediana	0,40	0,07	0,31
Coeficiente de sesgo	-0,79	-0,22	-0,76
Curtosis	2,45	2,96	2,64
1 Cuartil	-0,76	-0,57	0,67
3 Cuartil	0,80	0,66	0,75

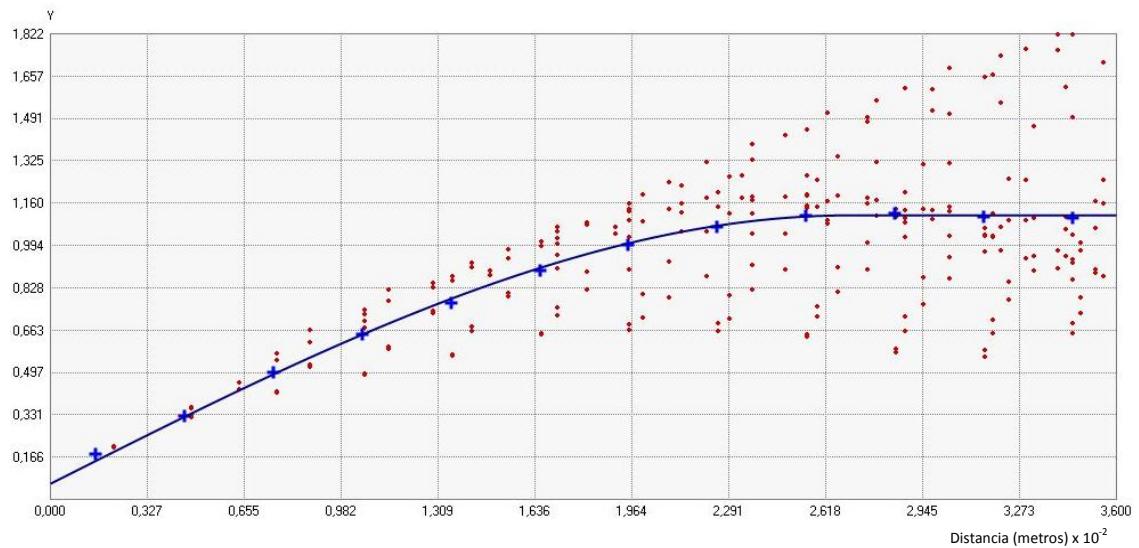
Durante la segunda etapa del estudio geoestadístico, el análisis estructural de los datos, se calcularon los variogramas experimentales y, a estos, se le ajustaron los variogramas teóricos (figura 1).

Los parámetros correspondientes a los tres semivariogramas teóricos de la figura 1 se muestran en la tabla 3.

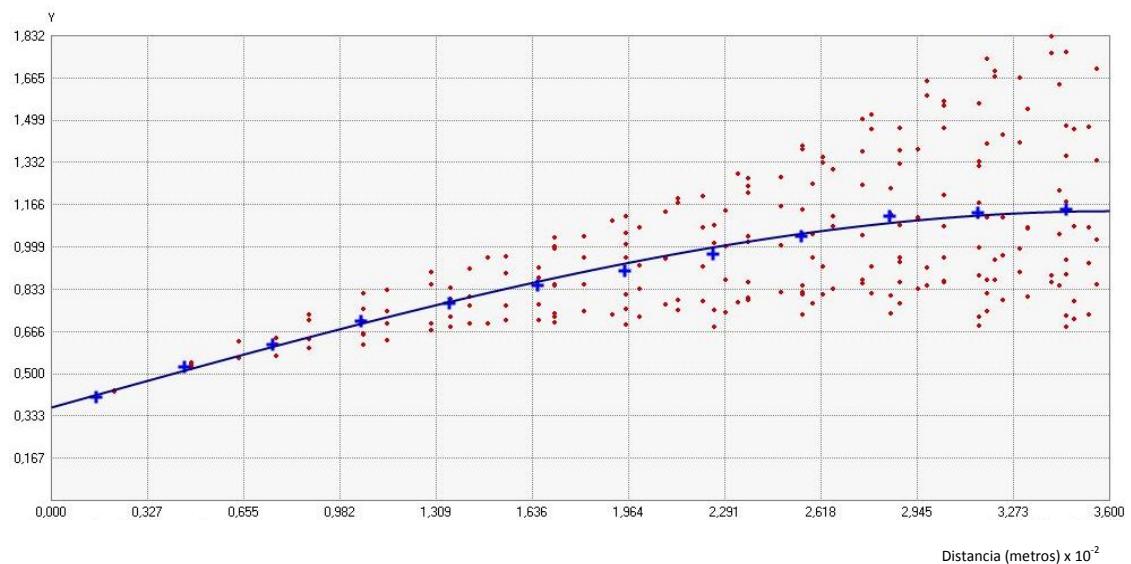
Tabla 3 – Parámetros correspondientes a los semivariogramas teóricos para los muestreos de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N, efectuados los días 19/02/2009, 24/04/2009 y 27/01/2011.

Muestreo	19/02/2009	24/04/2009	27/01/2011
Rango (m)	269,79	360,00	242,99
Efecto pepita	0,06	0,37	0,07
Meseta	1,05	0,77	1,03

A)



B)



C)

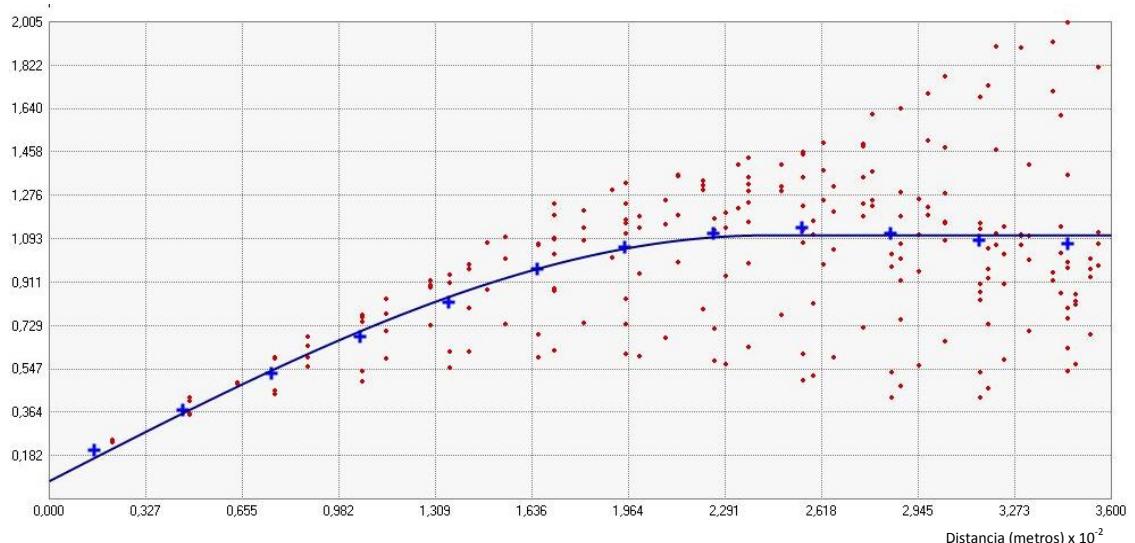


Figura 1 - Semivariogramas experimentales y teóricos para los muestreos de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N. A) 19/02/2009, B) 24/04/2009, C) 27/01/2011.

Una vez que se definieron los variogramas, en la tercera etapa del estudio geoestadístico se incorporó esa información en el algoritmo seleccionado, en este caso el krigado ordinario. Así, se procedió a realizar las estimaciones en los puntos muestrales y, en consecuencia, se generaron los mapas de distribución de  $CE_s$  para cada una de las fechas consideradas. A partir de dichos mapas se procedió a la elaboración de las distribuciones espaciales de  $CE_s$  para una resolución de 5 m (figura 2).

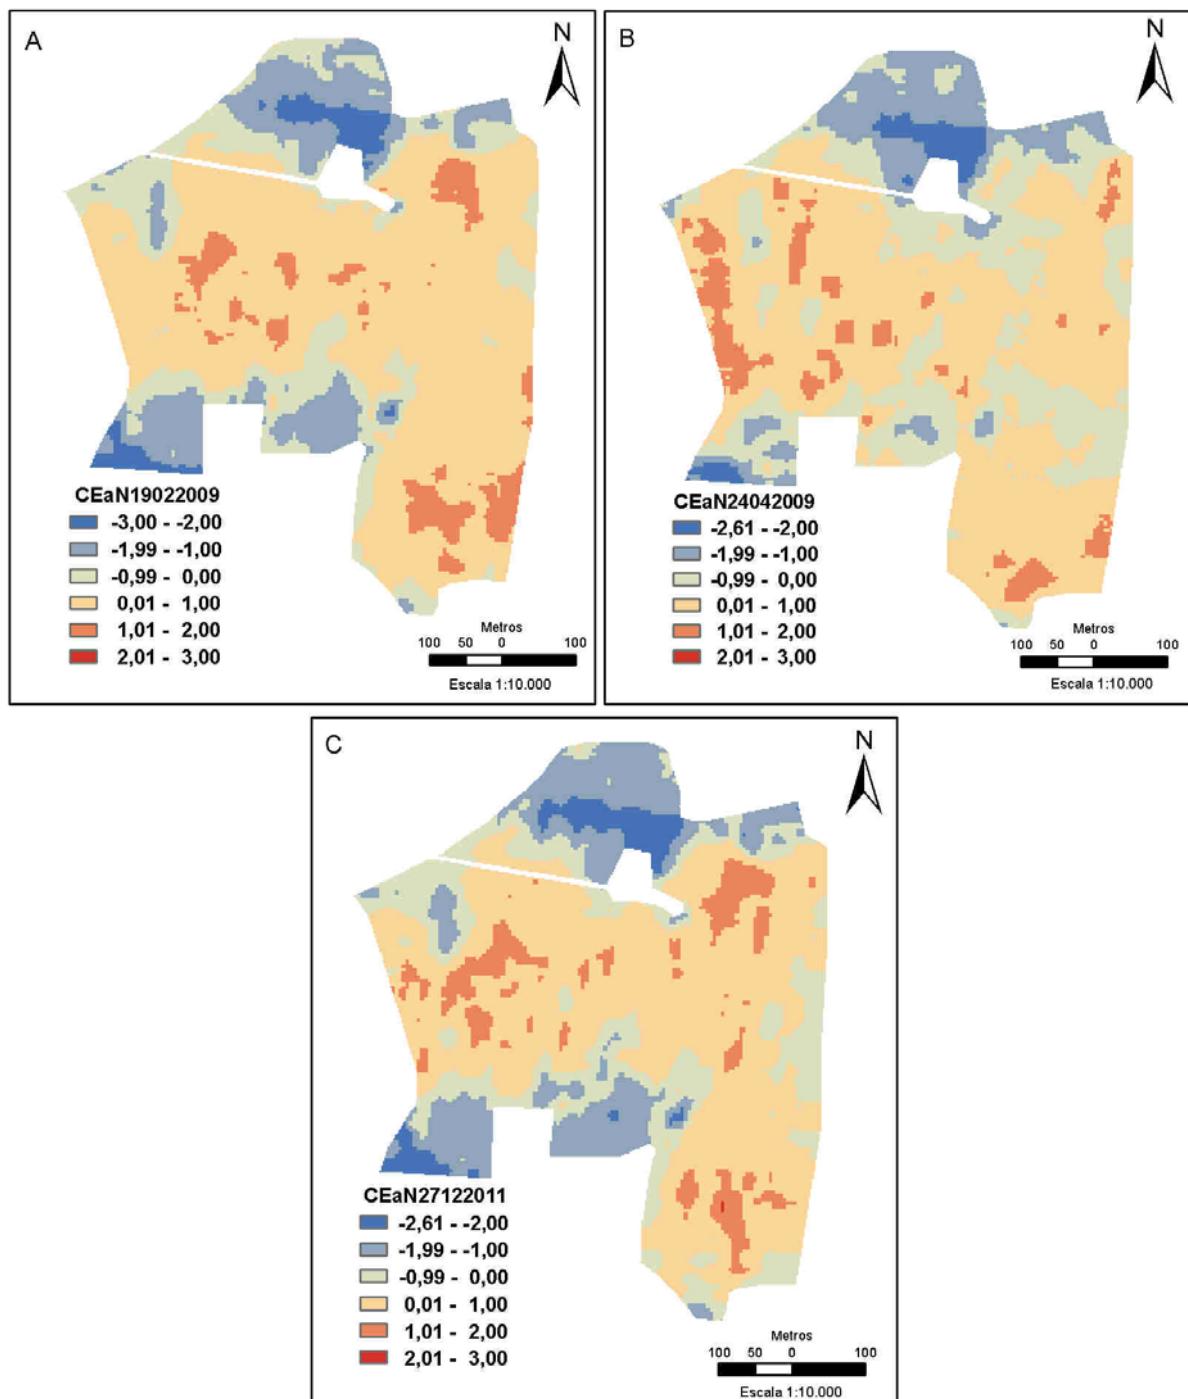


Figura 2 – Mapas raster de 5 m de resolución espacial de los muestreos de la conductividad eléctrica aparente superficial normalizada,  $CE_s$ N. A) 19/02/2009, B) 24/04/2009, C) 27/01/2011.

Los mapas raster que se muestran en la figura 2 se emplearon como capas en un ACP, obteniéndose como resultado las matrices de covarianza y correlación, además de los valores y vectores propios, que se indican en las tablas 4, 5, 6 y 7.

Tabla 4 - Matriz de covarianza obtenida del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N.

CAPa	1	2	3
1	1,00	0,69	0,96
2	0,69	0,77	0,70
3	0,96	0,70	1,02

Capas: mapas de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N, de fechas 1) 19/02/2009, 2) 24/04/2009, 3) 27/01/2011.

Tabla 5 - Matriz de correlación obtenida del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N.

CAPa	1	2	3
1	1,00	0,79	0,95
2	0,79	1,00	0,79
3	0,95	0,79	1,00

Capas: mapas de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N, de fechas 1) 19/02/2009, 2) 24/04/2009, 3) 27/01/2011.

Tabla 6 – Valores propios obtenidos del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N.

CP	1	2	3	TOTAL
Valores Propios	2,52	0,22	0,05	2,79
PORC	90,43	7,81	1,76	100,00

CP = componente principal; PORC = porcentaje de variabilidad explicada por cada CP.

Tabla 7 – Vectores propios obtenidos del análisis de componentes principales a partir de los mapas raster de conductividad eléctrica aparente superficial normalizada CE<sub>s</sub>N.

CAPA	CP <sub>1</sub>	CP <sub>2</sub>	CP <sub>3</sub>
1	0,61	0,34	0,71
2	0,49	0,87	0,00
3	0,62	0,35	0,70

CP: componente principal, Capas: mapas de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N, de fechas 1) 19/02/2009, 2) 24/04/2009, 3) 27/01/2011

Los diferentes mapas de CE<sub>s</sub> muestran una fuerte correlación espacial, ya que el coeficiente de correlación y la covarianza en todos los casos son bastante elevados (tablas 4 y 5). No obstante, las variaciones del coeficiente de correlación inducen a pensar que existen factores desconocidos que influyen en los valores de CE<sub>s</sub>N obtenidos, si bien, la alta correlación evidenciada entre los mapas primero y tercero, distanciados entre sí casi dos años, indican que la estabilidad temporal de la CE<sub>s</sub>N es muy elevada, pudiendo ser debida la desviación del segundo mapa a factores ambientales, en este caso por el hecho que el segundo muestreo se realizó con la parcela ocupada por vegetación espontánea muy desarrollada, considerándose que en el mes de abril suele ser lo normal si las parcelas de cultivo no se han laboreado ni tratado con herbicida, como ocurrió en este caso, y el elevado volumen de raíces vivas en el suelo pudiera afectar a los valores de CE<sub>s</sub>N obtenidos. Probablemente, la temperatura del suelo pudiera haber influido, ya que como se puede ver en la tabla 8, en la que figuran los datos de temperatura y pluviometría de los 45 días anteriores a cada muestreo, procedentes de la estación meteorológica ubicada en la finca “La Orden”, a unos 20 Km de distancia de la parcela experimental, la temperatura media del primero de ellos (8 °C) es inferior a la del segundo (13,9 °C) y, la del tercero, (8,9 °C) es prácticamente igual a la del primero. En el caso de la precipitación acumulada ocurre igual, en el primero (82,2 mm) y en el tercero (106,4 mm) son superiores y más similares entre sí que en el segundo muestreo (35,8 mm). Es evidente que el contenido de agua en el suelo guarda una relación directa con los valores de CE<sub>s</sub>N,

de ahí la necesidad de realizar una normalización previa para poder estudiar la variabilidad temporal de sus medidas.

En la tabla 6 puede comprobarse como la componente principal primera, CP<sub>1</sub>, explica el 90,43% de la variabilidad existente entre todos los mapas analizados. Los valores de esta componente en cada punto se obtienen mediante una combinación lineal de los valores normalizados en el mismo punto de cada uno de los tres mapas, cuantificándose la participación global de cada uno según los valores indicados en la columna CP<sub>1</sub> de la tabla 7. La representación espacial de la CP<sub>1</sub> puede verse en el mapa A de la figura 3, mostrando su variabilidad espacial a lo largo de la parcela.

En función de los resultados anteriores cabe concluir que la distribución espacial de la CE<sub>s</sub>N presenta una gran estabilidad temporal al concentrarse en una sola variable (CP<sub>1</sub>) la mayor parte de información y al contribuir a la misma en forma bastante similar los tres mapas estudiados.

La influencia de la componente principal segunda, CP<sub>2</sub>, explica el 7,81 % de la variabilidad (tabla 6); por tener en ella un peso mucho mayor el segundo mapa (tabla 7). De la tabla 6 se deduce también que la componente principal tercera, CP<sub>3</sub>, sólo explica el 1,76 % de la variabilidad, por lo cual se puede considerar que su influencia en la distribución espacial no tiene relevancia.

En la figura 3 se muestran los mapas de distribución espacial de cada una de las componentes principales.

Tabla 8 – Datos climáticos de la estación meteorológica de la Finca “la Orden”.

19/02/2009					24/04/2009					27/01/2011				
Fecha	T <sup>a</sup> Max (°C)	T <sup>a</sup> Med (°C)	T <sup>a</sup> Min (°C)	Precip. Diaria (mm)	Fecha	T <sup>a</sup> Max (°C)	T <sup>a</sup> Med (°C)	T <sup>a</sup> Min (°C)	Precip. Diaria (mm)	Fecha	T <sup>a</sup> Max (°C)	T <sup>a</sup> Med (°C)	T <sup>a</sup> Min (°C)	Precip. Diaria (mm)
05/01/2009	10,4	7,5	4,7	0,4	10/03/2009	23,4	13,9	5,4	0	13/12/2010	17,9	12,1	8,8	0,2
06/01/2009	10,4	6,1	1,7	0	11/03/2009	23,9	13,2	3,3	0	14/12/2010	10,9	8,9	6,6	0,4
07/01/2009	7,4	4,1	0	0	12/03/2009	25,8	14,3	2,9	0	15/12/2010	10,7	7,3	2,8	0
08/01/2009	7,2	1,1	-2,9	0	13/03/2009	24,9	14,9	7,1	0	16/12/2010	8,2	3,1	-1,3	0
09/01/2009	8,2	0,8	-4,2	0,2	14/03/2009	26,1	15	4,8	0	17/12/2010	8,6	3,5	-2,1	0
10/01/2009	7,2	2,5	-1	0	15/03/2009	26,3	15,7	5,6	0	18/12/2010	10,1	8	4,8	14,6
11/01/2009	12	3,9	-2,3	0	16/03/2009	27	16,7	8	0	19/12/2010	12,9	10,1	7,8	6,2
12/01/2009	15,4	4,4	-2,6	0	17/03/2009	23,9	16,1	9,6	0	20/12/2010	14,2	10,9	8,3	16,6
13/01/2009	11,4	6,1	0,7	3,4	18/03/2009	22,9	13,9	5,6	0	21/12/2010	18,2	14,7	12,5	17,2
14/01/2009	5,3	2,9	0,2	0,2	19/03/2009	24,3	14,5	4,5	0	22/12/2010	14,3	11,6	9	7,8
15/01/2009	10,3	7,1	2,9	4	20/03/2009	26,4	16,2	4,8	0	23/12/2010	11,3	8,6	3,7	0,2
16/01/2009	15,2	8,1	2,7	0	21/03/2009	24,5	15,5	5,8	0	24/12/2010	10,3	5,3	0,9	0
17/01/2009	13,2	5,8	-0,1	0,2	22/03/2009	21	14,5	7,9	0	25/12/2010	7,8	6,3	4,8	1,2
18/01/2009	14,5	8,7	2,1	0	23/03/2009	24	14,9	6	0	26/12/2010	9	4	-0,3	0
19/01/2009	15,4	12,4	8,7	4	24/03/2009	22,9	15,3	7,5	0	27/12/2010	9	4,7	-1,5	0
20/01/2009	9,4	6,1	1,9	0,6	25/03/2009	24,8	15,1	5,5	0	28/12/2010	16,1	11,1	7,6	0
21/01/2009	11,2	5,8	0,4	0	26/03/2009	26,9	16	4,6	0	29/12/2010	16,5	12,2	8,9	0,2
22/01/2009	15,2	12	7,2	1,2	27/03/2009	25,5	16,7	7,4	0	30/12/2010	14,6	12	10,4	6
23/01/2009	16	14,4	12,7	2,6	28/03/2009	19,8	13,7	9,1	0	31/12/2010	16,9	12,6	10,1	17
24/01/2009	14,4	11,3	7,8	0,2	29/03/2009	16,2	10,9	5,3	0	01/01/2011	16,5	12,3	9,8	0
25/01/2009	11,3	8,4	4,2	8,4	30/03/2009	16,8	10,5	2,9	0	02/01/2011	11	9,9	8,6	0
26/01/2009	13,2	7,9	4,1	0,6	31/03/2009	18,7	10,7	1,3	0	03/01/2011	11,8	9,3	7,1	0
27/01/2009	11,6	8,9	5	0	01/04/2009	18,8	11,2	2,1	0	04/01/2011	15	10,2	6,4	0,2
28/01/2009	15,2	12,3	10,3	0	02/04/2009	22,2	13,4	4,5	0	05/01/2011	16,2	12	6,8	3,2
29/01/2009	16,3	13,5	11,5	0,2	03/04/2009	22,6	13,5	5,5	0	06/01/2011	18,7	16,2	14,5	0,2
30/01/2009	15,9	12,1	8,1	9,4	04/04/2009	24,9	15,2	5,8	0	07/01/2011	17,1	14,1	11,3	7,6
31/01/2009	12,5	9,4	7,4	1,8	05/04/2009	25,1	15,7	6,8	0	08/01/2011	15,5	12,4	9,6	2,8
01/02/2009	13,6	9,6	7	21,6	06/04/2009	22,3	15	7,7	0	09/01/2011	13,4	10,4	6,4	0
02/02/2009	12,8	8,5	6,6	4	07/04/2009	19	12,3	5,6	0	10/01/2011	14,9	9,2	2,3	0,2
03/02/2009	12,6	9	5	5,6	08/04/2009	21,2	12,7	4,5	0,4	11/01/2011	16,2	12,9	9,1	0
04/02/2009	12,7	9,3	6,8	4,4	09/04/2009	22,5	14,4	5,1	0	12/01/2011	10,5	8,7	7	0,4
05/02/2009	14,2	7,9	3,7	5,6	10/04/2009	16,8	11,9	7	1	13/01/2011	10,2	8,5	7,2	0
06/02/2009	10,6	6,9	4,3	0	11/04/2009	18,9	12,2	5,9	0	14/01/2011	9,3	7,8	6,4	0,4
07/02/2009	12,1	6,3	1,4	0	12/04/2009	19,5	12,3	4,6	0	15/01/2011	8,9	7,7	6,3	0,2
08/02/2009	12,8	8,5	1,7	0	13/04/2009	21,2	13,2	5	0	16/01/2011	11,2	7,5	5,6	0,2
09/02/2009	15,4	12,5	10,3	1	14/04/2009	15,9	11,1	7,7	4,8	17/01/2011	10,6	7,1	4,6	0,2
10/02/2009	15	10,7	5	1,8	15/04/2009	14,7	9,6	5,7	4,4	18/01/2011	11,4	8,3	6,3	0
11/02/2009	15,4	8	1,9	0	16/04/2009	16,9	11,3	7,6	5,4	19/01/2011	14,4	9,3	5,1	0,2
12/02/2009	16,7	7,8	0,6	0	17/04/2009	16,2	10,8	6,5	7,2	20/01/2011	14,1	7,6	2,1	0,4
13/02/2009	17,1	8,2	1,1	0,2	18/04/2009	14,4	11	7,6	12,4	21/01/2011	11,9	7	2,4	0,2
14/02/2009	17,9	8,3	0,6	0,2	19/04/2009	19,8	14,1	8,9	0	22/01/2011	8,6	3,8	-0,3	0
15/02/2009	17,4	8,5	0,4	0	20/04/2009	21,5	14,3	7,9	0,2	23/01/2011	8,6	4,7	1,6	0
16/02/2009	15,8	8,3	1,7	0,2	21/04/2009	24,4	15,8	7,4	0	24/01/2011	12	7	4,2	0,4
17/02/2009	16,8	8,1	0,9	0,2	22/04/2009	26,2	16,4	6,6	0	25/01/2011	11,6	7,1	4,2	0
18/02/2009	18,1	8,9	1,1	0	23/04/2009	28	18,1	6,4	0	26/01/2011	13	7,6	2	0
19/02/2009	13,1	7	2	0	24/04/2009	26,2	17,4	9	0	27/01/2011	11,1	5,9	0,2	2
MEDIAS	13,2	8,0	3,3	82,2	MEDIAS	22,1	13,9	6,0	35,8	MEDIAS	12,6	8,9	5,6	106,4

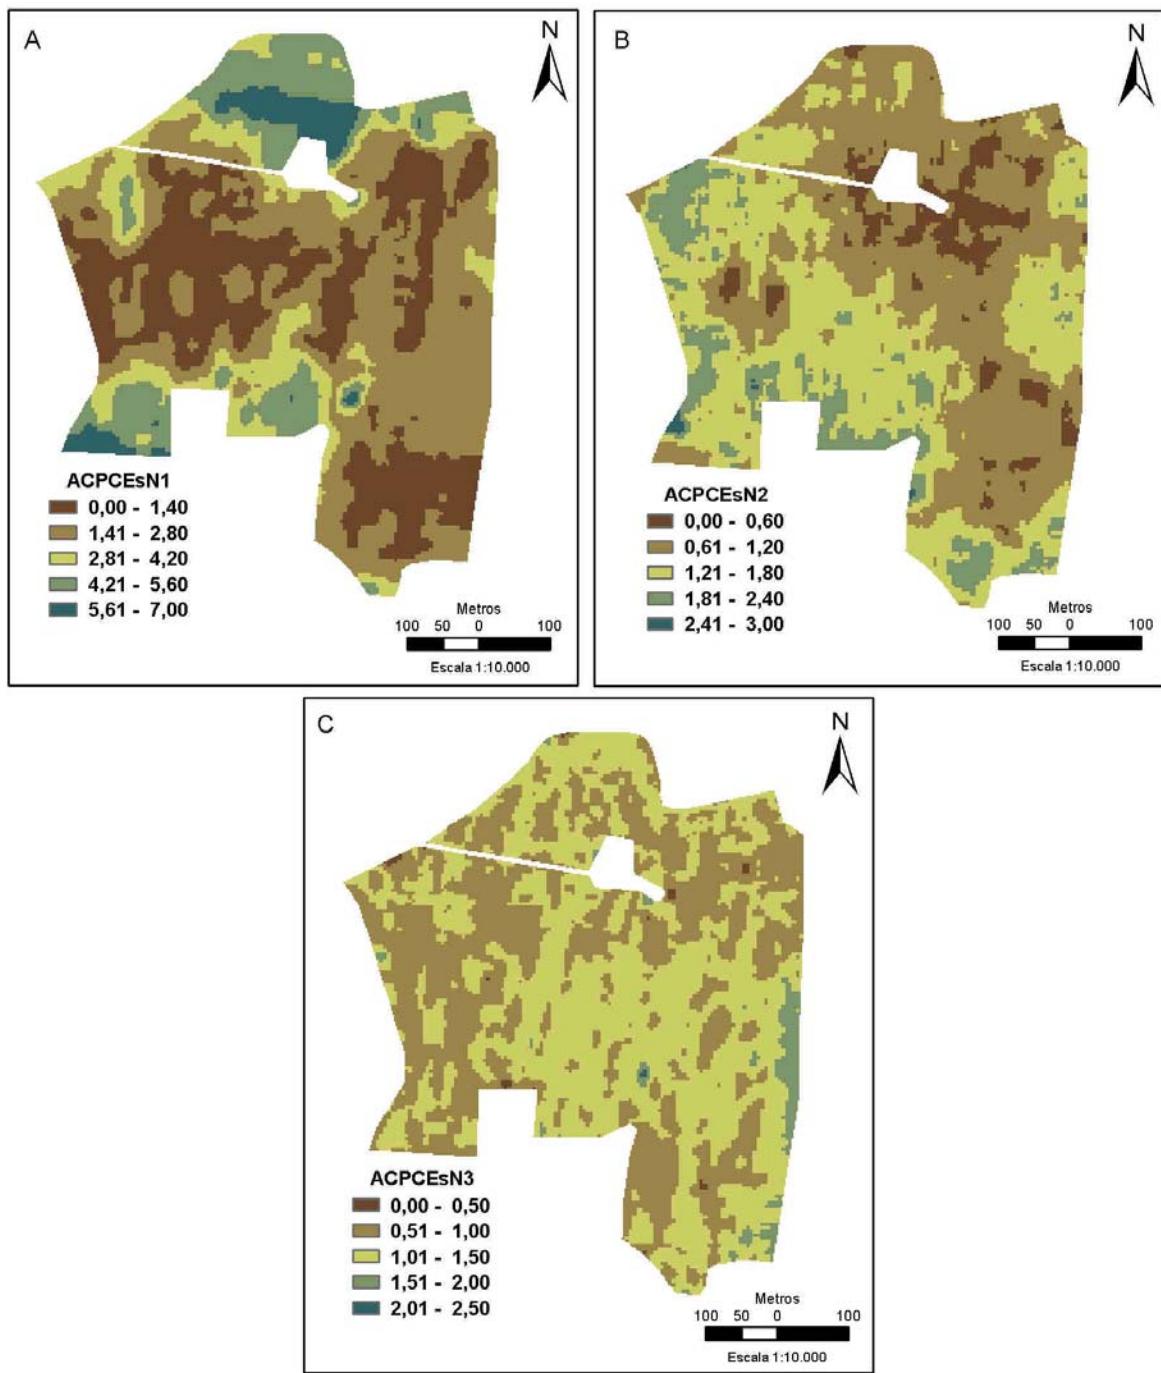


Figura 3 – Mapas raster de 5 m de resolución de las componentes principales primera (A), segunda (B) y tercera (C), obtenidas del análisis de componentes principales de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N.

El mapa A) de la figura 3 representa la distribución espacial de la CP<sub>1</sub> que, por explicar un alto porcentaje de la variabilidad temporal de la CE<sub>s</sub> en los tres mapas considerados (90,43 %, ver tabla 6), viene a representar la distribución espacial de la variable estudiada (CE<sub>sN</sub>) en la parcela experimental considerando la influencia de la componente temporal. Los valores expresados en la leyenda del mapa no se corresponden con los valores absolutos de la variable antes de la normalización, debiendo ser interpretados de forma inversa, es decir, que las zonas con valores bajos de la CP<sub>1</sub> se corresponden con los valores altos de CE<sub>s</sub> y viceversa. Esto es debido a que durante el proceso de ACP, se ha producido un cambio de orientación en los ejes principales.

En el mapa B) de la figura 3 se representa la distribución espacial de la componente principal segunda. La variable que en él se representa tan sólo explica el 7,81 % de la variabilidad temporal (tabla 6), estando muy influida por el segundo muestreo. Lo que explica es en qué zonas la variable estudiada presenta una mayor variabilidad a lo largo del tiempo.

El mapa C) de la misma figura 3 tan sólo explica el 1,76 % de la variabilidad temporal (tabla 6) por lo que su importancia en la descripción de la estabilidad temporal de la variable estudiada es muy escasa.

### **6.3.2. VARIABILIDAD TEMPORAL DE LAS PRODUCCIONES.**

Los estadísticos de la producción expresada en rendimiento seco, RS (T/ha), de cada cosecha se recogen en la tabla 9. En dicha tabla puede apreciarse cómo en todos los casos la aproximación a una distribución normal es importante, ya que la media y la mediana son muy semejantes y el coeficiente de sesgo es bajo.

Tabla 9 – Estadísticos de los valores de cosecha en rendimiento seco, RS (T/ha).

Campaña	2007	2010	2011
Mínimo (Tm/ha)	0,12	0,10	0,47
Máximo (Tm/ha)	1,70	1,80	2,98
Media (Tm/ha)	0,53	0,87	1,67
Desviación típica (Tm/ha)	0,24	0,33	0,47
Mediana (Tm/ha)	0,49	0,89	1,69
Coeficiente de sesgo	0,93	-0,13	-0,02
Curtosis	4,14	2,55	2,12
Primer Cuartil (Tm/ha)	0,34	0,64	1,27
Tercer Cuartil (Tm/ha)	0,67	1,10	2,04

Conviene indicarse que las condiciones de cada cosecha fueron diferentes. Así, en el año 2011 los valores que aparecen en la tabla 9 son mayores que los reales, aunque todos en la misma proporción, debido a un problema ocurrido en la configuración del monitor de cosecha al incrementarse el factor de escala de la placa de impacto. Por esa razón es imprescindible someter los datos de los tres mapas de producción estudiados a un proceso de normalización idéntico al ya descrito con anterioridad (ecuación 1).

Los estadísticos, después de la normalización de los datos de rendimiento seco en cada cosecha, son los que se muestran en la tabla 10.

Tabla 10 – Estadísticos de las producciones en rendimiento seco normalizado, RSN.

Campaña	2007	2010	2011
Mínimo	-1,74	-2,36	-2,57
Máximo	4,80	2,86	2,81
Mediana	-0,16	0,07	0,04
Coeficiente de sesgo	0,93	-0,13	-0,02
Curtosis	4,14	2,55	2,12
Primer Cuartil	-0,76	-0,69	-0,85
Tercer Cuartil	0,60	0,70	0,81

Durante la segunda etapa del estudio geoestadístico, el análisis estructural de los datos, se calcularon los variogramas experimentales y, a estos, se le ajustaron los variogramas teóricos (figura 4).

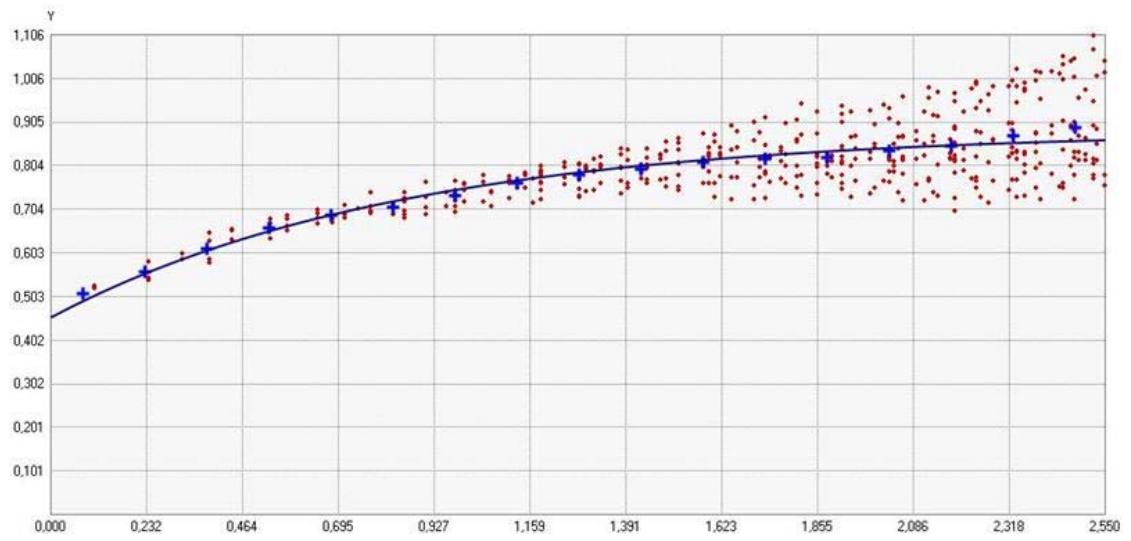
Los parámetros correspondientes a los tres semivariogramas teóricos de la figura 4 se indican en la tabla 11.

Los rangos obtenidos para las diferentes cosechas son bastante semejantes a los que se obtuvieron para la CE<sub>s</sub>N (tabla 3). Esto constituye un primer indicio acerca de la similitud de los patrones de variabilidad espacial de los rendimientos y las CE<sub>s</sub>.

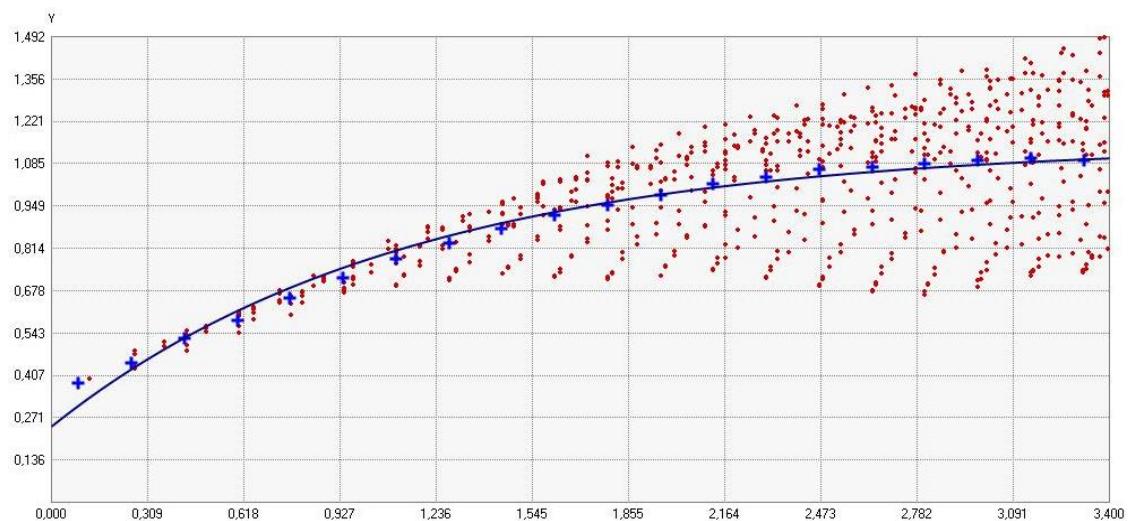
Tabla 11 – Parámetros correspondientes a los semivariogramas teóricos para el rendimiento seco normalizado, RSN, de los años 2007, 2010 y 2011.

Muestreo	2007	2010	2011
Rango (m)	255,00	340,00	255,00
Efecto pepita	0,45	0,24	0,21
Meseta	0,75	0,90	0,85

A)



B)



C)

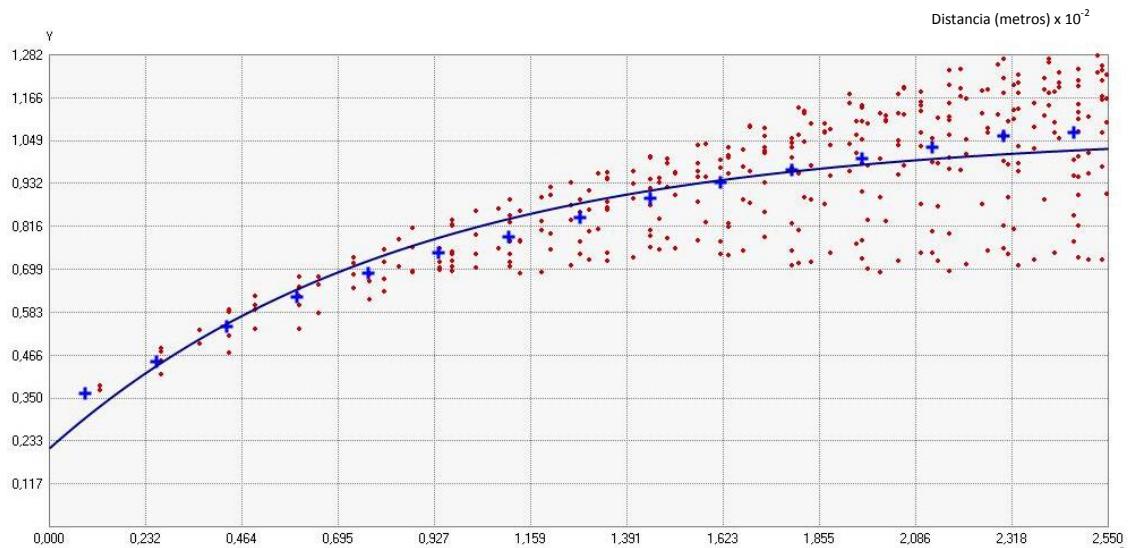


Figura 4 – Semivariogramas experimentales y teóricos para el rendimiento seco normalizado, RSN, de los años A) 2007, B) 2010, C) 2011.

Una vez que se definieron los variogramas, en la tercera etapa del estudio geoestadístico, se incorporó esa información en el algoritmo seleccionado, en este caso el krigado ordinario. Así, se procedió a realizar las estimaciones en los puntos muestrales y, en consecuencia, se generaron los mapas de distribución de RSN para cada uno de los años considerados. A partir de dichos mapas se procedió a la elaboración de las distribuciones espaciales de RSN para una resolución de 5 m (fig. 5).

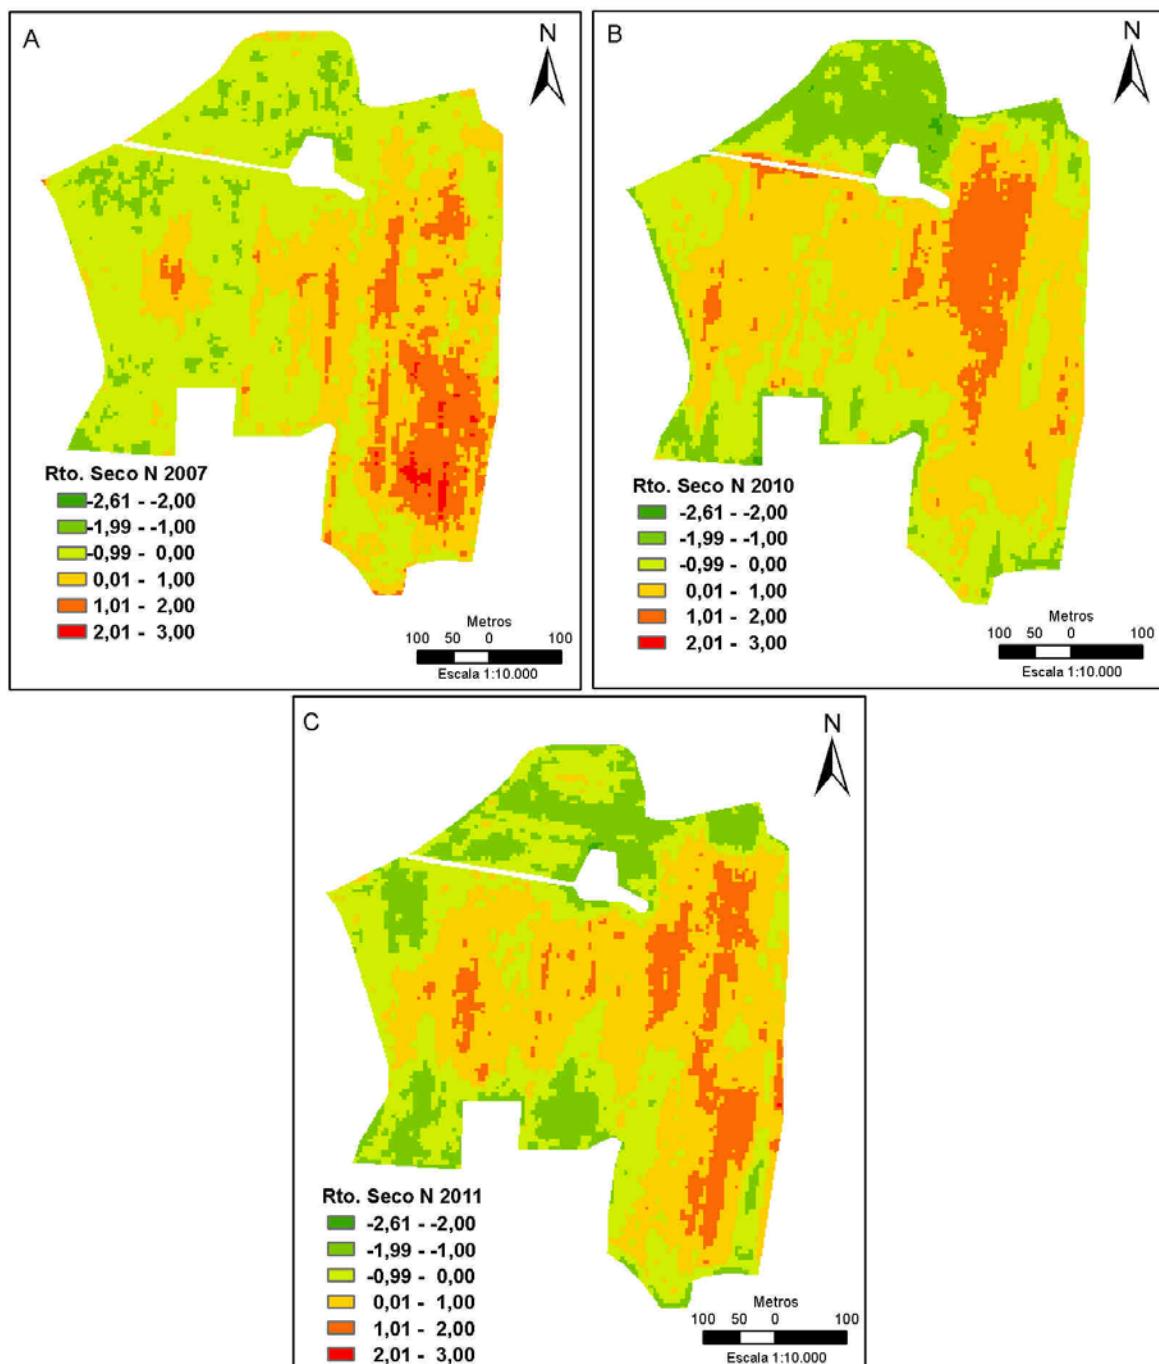


Figura 5 – Mapas raster de 5 m de resolución espacial del rendimiento seco normalizado, RSN.  
A) 2007, B) 2010, C) 2011.

Los mapas raster que se muestran en la figura 5 se emplearon como capas en un ACP, obteniéndose como resultado las matrices de covarianza y correlación, además de los valores y vectores propios, que se indican en las tablas 12, 13, 14 y 15.

Tabla 12 - Matriz de covarianza obtenida del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.

CAPA	1	2	3
1	0,49	0,28	0,36
2	0,28	0,81	0,53
3	0,36	0,53	0,73

Capas: mapas de rendimiento seco normalizado, RSN, de los años 1) 2007, 2) 2010, 3) 2011

Tabla 13 - Matriz de correlación obtenida del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.

CAPA	1	2	3
1	1,00	0,45	0,60
2	0,45	1,00	0,69
3	0,60	0,69	1,00

Capas: mapas de rendimiento seco normalizado, RSN, de los años 1) 2007, 2) 2010, 3) 2011

Tabla 14 – Valores propios obtenidos del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.

CP	1	2	3	TOTAL
Valores Propios	1,50	0,33	0,20	2,03
PORC	74,00	16,29	9,71	100,00

CP=componente principal; PORC=porcentaje de variabilidad explicada por cada CP

Tabla 15 – Vectores propios obtenidos del análisis de componentes principales a partir de los mapas raster de rendimiento seco normalizado, RSN.

CAPA	CP <sub>1</sub>	CP <sub>2</sub>	CP <sub>3</sub>
1	-0,41	0,75	0,52
2	-0,65	-0,64	0,41
3	-0,64	0,18	-0,75

CP=componente principal Capas: mapas de rendimiento seco normalizado, RSN, de los años 1) 2007, 2) 2010, 3) 2011

Según se observa en la tabla 13 el coeficiente de correlación entre las producciones en rendimiento seco normalizado, RSN, de los años 2010 y 2011 (0,69) es superior a los del año 2007 respecto a los años 2010 y 2011 (0,45 y 0,60), respectivamente. Esto puede deberse a que la cosecha de 2007 fue escasa y la incidencia las pérdidas producidas por las aves fue mucho mayor que en los otros dos años. De todas formas este problema afectó a todas las producciones en mayor o menor medida, por lo cual no sería posible que se alcanzaran correlaciones más altas; no obstante, los valores obtenidos pueden ser considerados aceptables, porque de los resultados expresados en la tabla 13 se desprende que existe correlación entre las diferentes cosechas, aunque no sea alta.

En la tabla 14 se muestra que la componente principal primera, CP<sub>1</sub>, explica el 74 % de la variabilidad de las producciones estudiadas, lo cual, si bien no es un valor tan alto como el que presenta la CP<sub>1</sub> en el caso de la CE<sub>s</sub>N, es lo suficientemente aceptable como para considerarse representativo de la variable estudiada.

En la figura 6 se tienen los mapas de distribución espacial de las tres componentes principales para el caso de las diferentes producciones estudiadas.

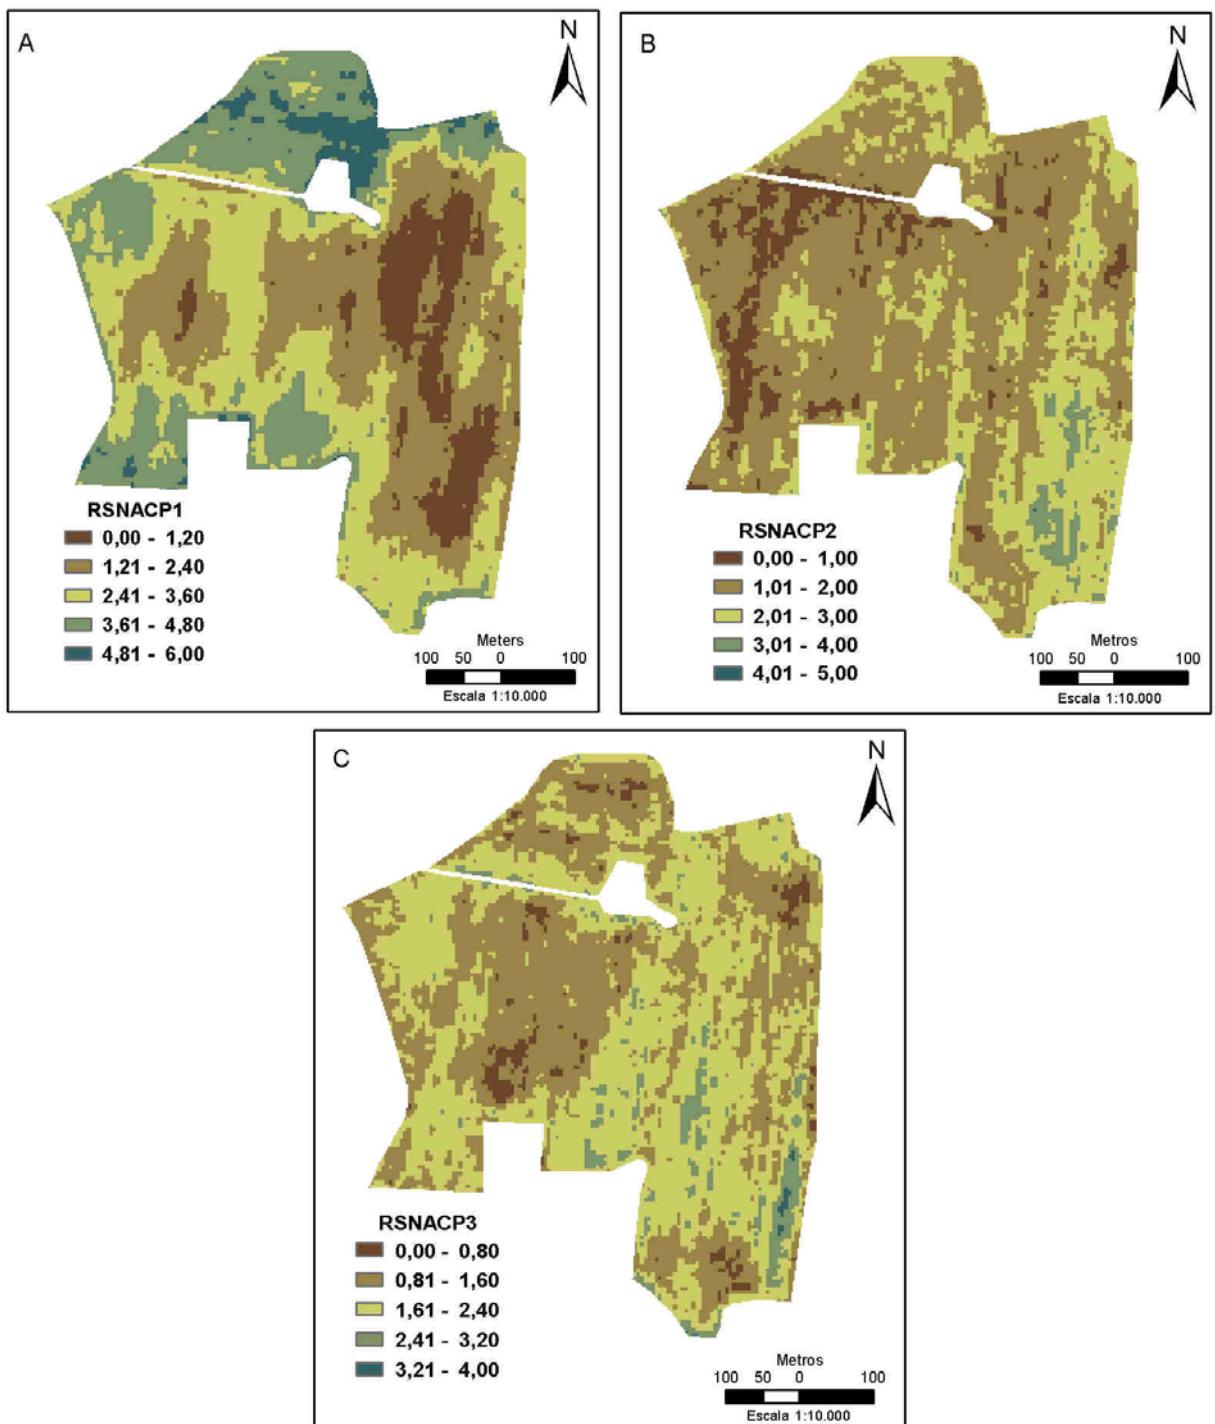


Figura 6 – Mapas raster de 5 m de resolución de las componentes principales primera (A), segunda (B) y tercera (C), obtenidas del análisis de componentes principales rendimiento seco normalizado, RSN.

En el mapa A) de la figura 6 se muestra la distribución espacial de la CP<sub>1</sub>, siendo una variable combinación lineal de las producciones de los tres años estudiados y explicando el 74 % (tabla 14) de la variabilidad temporal existente en esos años. Como en el caso del ACP de la CE<sub>s</sub>, la orientación de los ejes determina que la correspondencia entre los valores de CP<sub>1</sub> sea inversa a los valores de RSN. Es decir que, en este mapa, los menores valores de la CP<sub>1</sub> correspondan a las áreas más productivas. Esta variable tiene una mayor carga de información de los años 2010 y 2011 (tabla 15), los cuales muestran a su vez unos patrones de distribución muy semejantes (tabla 13).

En el mapa B) se representa la CP<sub>2</sub>, que explica el 16,29 % (tabla 14) de la variabilidad temporal existente y su mayor carga de información corresponde al año 2007.

El mapa C) representa 9,71 % (tabla 14) de la variabilidad y no tiene un significado apreciable ni una importancia destacable a la hora de describir la estabilidad temporal de la producción.

### **6.3.3. ESTABILIDAD TEMPORAL DE LA CE<sub>s</sub> Y DE LAS PRODUCCIONES.**

Para completar el análisis de la estabilidad temporal de las dos variables estudiadas se utilizó de nuevo la herramienta de ACP, con el objetivo de comprobar si las dos variables más representativas obtenidas en los anteriores apartados, las componentes principales primeras, estaban correlacionadas y, en el caso de que lo estuvieran, obtener una nueva variable, cuya distribución espacial pudiera caracterizar la fertilidad potencial de la parcela considerando la variabilidad temporal que pudiera existir, con el fin último de compararla con la variable latente “fertilidad potencial”, obtenida por el modelo de Rasch (capítulo 5).

Los resultados del análisis de componentes principales realizado tomando como variables las componentes principales primeras de los ACP efectuado entre los tres muestreos de CE<sub>s</sub>N y los RSN de las cosechas de los tres años estudiados, ha dado los resultados que se recogen en las tablas 16, 17, 18 y 19 .

Tabla 16 - Matriz de covarianza obtenida del análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE<sub>s</sub>N y rendimiento seco normalizado, RSN.

CAPAS	1	2
1	2,52	1,43
2	1,43	1,50

Capas: 1) componente principal primera de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N. 2) componente principal primera del rendimiento seco normalizado, RSN.

Tabla 17 - Matriz de correlación obtenida del análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE<sub>s</sub>N y rendimiento seco normalizado, RSN.

CAPAS	1	2
1	1,00	0,73
2	0,73	1,00

Capas: 1) componente principal primera de la conductividad eléctrica aparente superficial normalizada, CE<sub>s</sub>N. 2) componente principal primera del rendimiento seco normalizado, RSN.

Tabla 18 – Valores propios obtenidos en el análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada CE<sub>s</sub>N y rendimiento seco normalizado, RSN.

CP	1	2	TOTAL
Valores Propios	3,53	0,50	4,03
PORC	87,65	12,34	100,00

CP=componente principal; PORC=porcentaje de variabilidad explicada por cada CP.

Tabla 19 – Vectores propios obtenidos en el análisis de componentes principales a partir de los mapas raster de las componentes principales primeras de los ACP de la conductividad eléctrica aparente superficial normalizada  $CE_sN$  y rendimiento seco normalizado, RSN.

CAPA	CP <sub>1</sub>	CP <sub>2</sub>
1	0,82	0,58
2	0,58	0,82

CP = componente principal Capas: 1) componente principal primera de la conductividad eléctrica aparente superficial normalizada,  $CE_sN$ . 2) componente principal primera del rendimiento seco normalizado, RSN.

Los mapas raster obtenidos para ambas componentes principales se recogen en la figura 7.

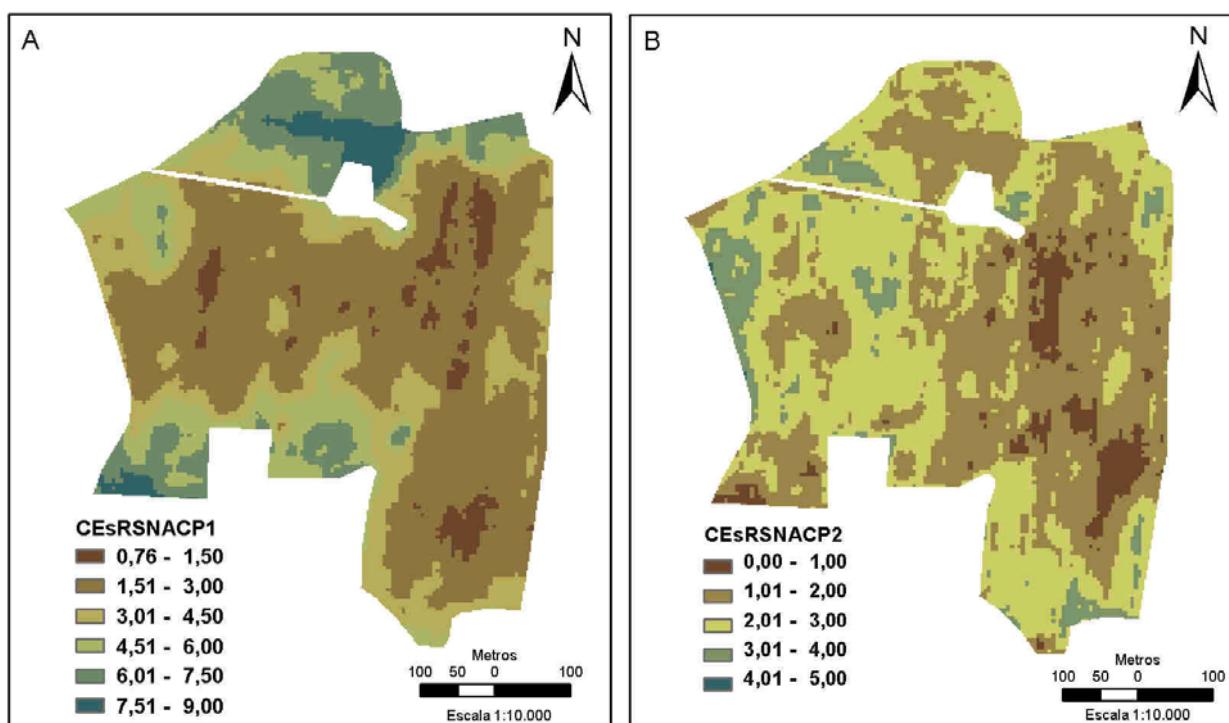


Figura 7 – Mapas raster de 5 m de resolución espacial del análisis de componentes principales de la componente principal primera de la conductividad eléctrica aparente superficial normalizada,  $CE_sN$ , y la componente principal primera el rendimiento seco normalizado, RSN. A)  $CE_sRSNACP_1$ , B)  $CE_sRSNACP_2$ .

Como se expresa en la tabla 17 el coeficiente de correlación entre ambas variables es de 0,73, lo que significa que existe un grado alto de correlación espacial entre las

mismas. Además, la componente principal primera explica un porcentaje de variabilidad espacial del 87,65 % (tabla 18), de lo que se deduce que esta nueva variable obtenida contiene una grado de información muy elevado sobre la distribución espacial de la potencialidad productiva de la parcela, para el cultivo de girasol en secano, con la modulación producida por los análisis de la variabilidad temporal realizados. La distribución espacial de dicha variable se representa en el mapa A de la figura 7 y, como ocurrió en los casos anteriores por la cuestión de la orientación de los ejes en el ACP, la relación entre el valor de la variable y la potencialidad productiva se representa de forma inversa, es decir, que en las zonas más productivas el valor de la componente principal primera es menor y viceversa.

Queda aún una cuestión por determinar, consistente en ver si esta correlación se mantiene en el espacio o varía de un lugar a otro; para ello se ha utilizado la técnica de la RPG.

Los valores de los coeficientes de determinación locales ( $R^2$ ) obtenidos al efectuar la RPG se emplearon como puntos muestrales para proceder, con posterioridad, a realizar la estimación de dichos coeficientes en los puntos no muestrales, empleándose para ello un algoritmo geoestadístico, en concreto el krigado ordinario. Para ello, se procedió al cálculo del variograma experimental y al ajuste de un variograma teórico al mismo; en concreto, en este caso, se utilizó el modelo gaussiano, debido a la naturaleza de la variable a estimar.

Los parámetros representativos del semivariograma teórico gaussiano mencionado (figura 8) son los siguientes: rango = 172,80 m, efecto pepita =  $10^{-3}$  y meseta = 0,07.

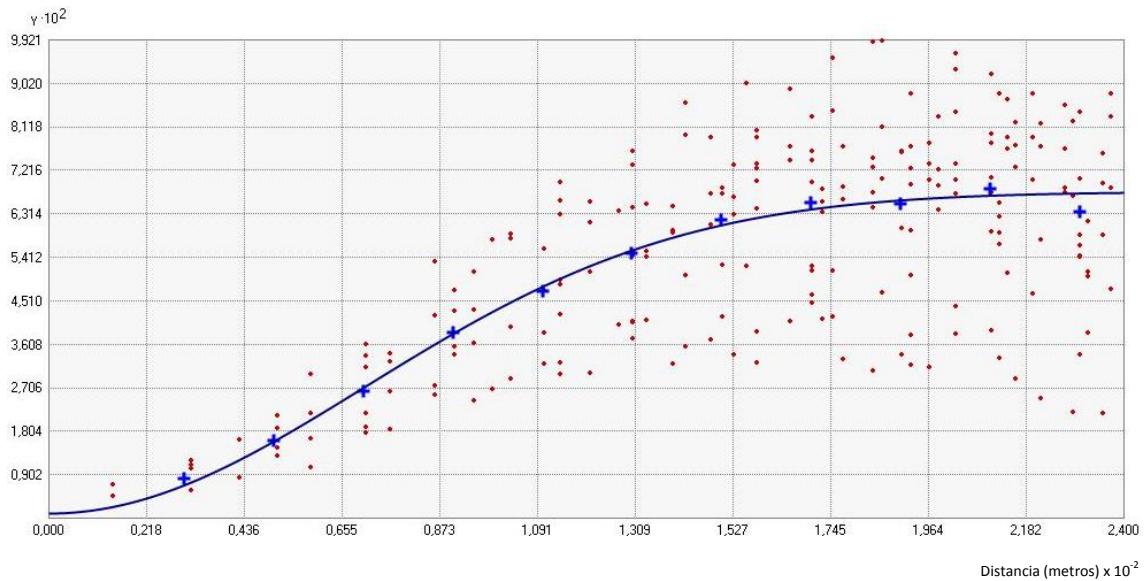


Figura 8 – Semivariograma experimental y teórico de la correlación local obtenida en los puntos muestrales considerados, para la regresión ponderada geográficamente realizada entre las componentes principales primeras obtenidas en los análisis de variabilidad temporal de la conductividad eléctrica aparente normalizada,  $CE_sN$ , y del rendimiento seco normalizado, RSN, obtenidos mediante la técnica de análisis de componentes principales.

El mapa obtenido después de realizar el krigiado y pasarlo a raster se representa en la figura 9.

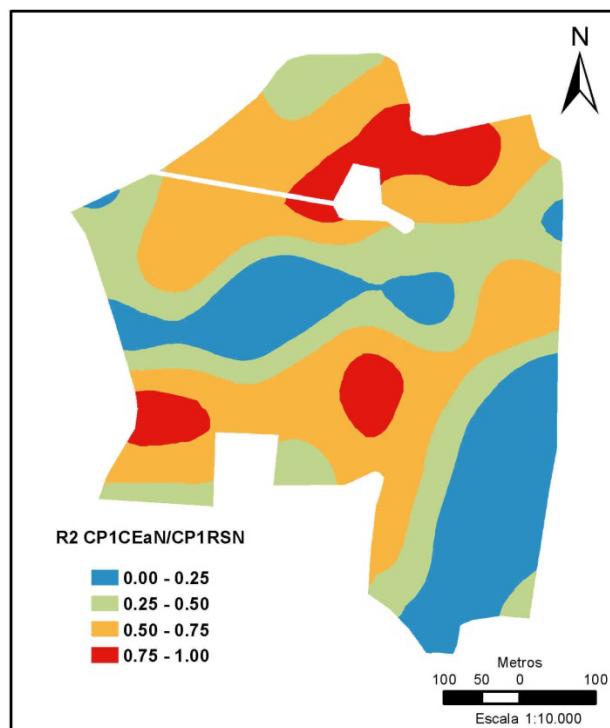


Figura 9 – Mapa raster de 5 m de resolución espacial de la correlación local  $R^2$  entre la componente principal primera de la conductividad eléctrica aparente normalizada,  $CE_sN$ , y la del rendimiento seco normalizado, RSN.

La superficie ocupada por los valores comprendidos entre los diferentes intervalos de los coeficientes de determinación de la figura 9 se indican en la tabla 20.

Tabla 20 – Superficies y porcentajes de ocupación con respecto al área total de la parcela experimental de los diferentes intervalos de valores del coeficiente de determinación de la regresión ponderada geográficamente entre la componente primera del análisis de componentes principales de la CE<sub>s</sub>N y el RSN.

R <sup>2</sup> local	Superficie (ha)	Ocupación
0,00 – 0,25	7,51	23,46 %
0,25 – 0,50	9,18	28,66 %
0,50 – 0,75	12,22	38,16 %
0,75 – 1,00	3,11	9,72 %

Así, en más del 75 % del área de la parcela experimental, el coeficiente de determinación es superior a 0,25. Además, según se tiene en el mapa de la figura 9, los lugares en los que la correlación espacial es más alta coinciden con aquellos en los que la CE<sub>s</sub>N es menor, es decir, las áreas menos productivas.

Una de las razones que podrían influir de forma considerable en las bajas correlaciones en las zonas de mayor CE<sub>s</sub>N, y por tanto potencialmente más productivas, podría deberse al tipo de cultivo, ya que el girasol es especialmente atacado por las aves silvestres de muchas especies, sobre todo cuando no existen parcelas con el mismo cultivo en los alrededores. Este ataque se ha observado con más intensidad en las cercanías de las zonas arboladas, como ocurre en la zona central de la parcela experimental donde se encuentran las edificaciones, o en la zona noreste, donde hay un grupo de eucaliptus, o en la zona sur, colindante con extensos olivares, y, además, es más intenso en la medida que la planta es más vigorosa y productiva, ya que las aves se posan en la cabezuela y picotean la misma cuando aún el grano no está maduro, prefiriendo las plantas más robustas, al soportar mejor su peso. No obstante, en los años 2010 y 2011 se colocaron dos cañones de gas para ahuyentar a las aves, uno ubicado en la zona central de la finca y otro en el centro

sur, en los olivares, por lo cual la incidencia de los daños, aunque disminuyó apreciablemente, estuvo más deslocalizada.

#### **6.3.4. COMPARACIÓN ENTRE LA DISTRIBUCIÓN ESPACIAL DE LA VARIABLE LATENTE “FERTILIDAD POTENCIAL” OBTENIDA POR EL MODELO DE RASCH Y LA COMPONENTE PRINCIPAL PRIMERA DEL ANÁLISIS TEMPORAL ENTRE LA CE<sub>s</sub>N Y EL RSN.**

En este apartado se muestra la comparación entre el mapa raster representativo de la distribución espacial de la componente principal primera del ACP realizado anteriormente, con el de la variable latente “fertilidad potencial” procedente del artículo incluido en el capítulo 5, el cual fue obtenido a partir de la aplicación del modelo de Rasch como instrumento de medida.

Así, se ha empleado la misma técnica de ACP ya utilizada en los anteriores apartados, utilizando como primera variable la componente principal primera CE<sub>s</sub>RSNACP<sub>1</sub> (ver figura 7), a cuyo mapa se le ha practicado un cambio de signo mediante la herramienta “calculadora raster” de ArcGIS 10.0 y, como segunda variable, el mapa de la “fertilidad potencial”. El coeficiente de correlación espacial obtenido entre ambos mapas es de 0,88, lo cual indica que ambos procedimientos conducen a resultados muy aproximados.

El valor propio primero obtenido en el mencionado análisis representa el 98,63 % de la información relativa a la variabilidad espacial de ambas variables y el primer vector propio es una combinación lineal de las dos variables, con un coeficiente de -0,23 para la variable “fertilidad potencial” y de -0,97 para la variable CE<sub>s</sub>RSNACP<sub>1</sub>. Este hecho implica que la distribución espacial de ambas variables es muy similar, si bien el mapa representativo de CE<sub>s</sub>RSNACP<sub>1</sub> presenta una mayor variabilidad, al proceder de una fuente de datos mucho más abundante que la utilizada en el análisis de Rasch, que es sólo de 70 puntos muestrales.

En la figura 9 se incluye el mapa que representa la distribución espacial de la componente principal primera obtenida en el análisis realizado que, como puede observarse, mantiene el mismo patrón espacial de distribución de los mapas de las variables utilizados para realizar el ACP.

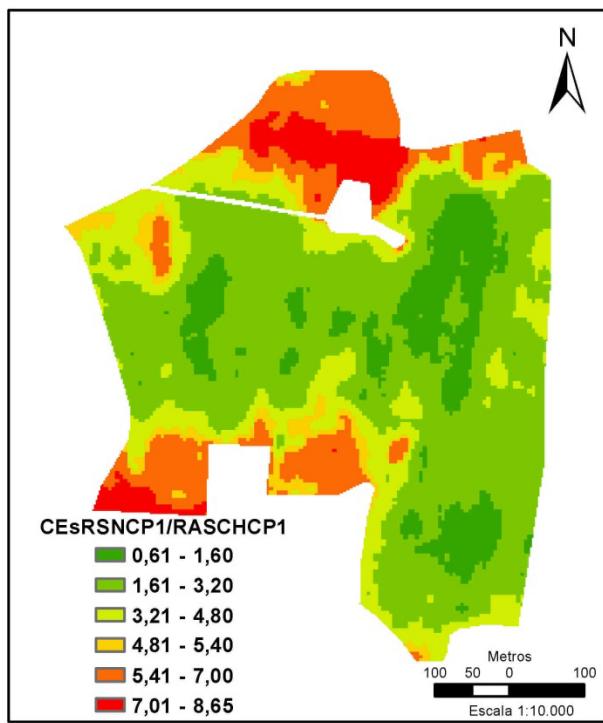


Figura 10 – Mapa raster de 5 m de resolución espacial de la componente principal primera del análisis de componentes principales de la CE<sub>s</sub>N y el RSN y la variable “fertilidad potencial” obtenida por el Modelo de Rasch.

#### **6.4. REFERENCIAS BIBLIOGRÁFICAS**

- Blackmore, B. S., Godwin, R. J., & Fountas, S. (2003). The analysis of spatial and temporal trends in yield map data over six years. *Biosystems Engineering*, 84(4), 455 - 466.
- Fraisse, C.W., Sudduth, K., Kitchen, N.R., Fridgen, J.J. (1999). Use of unsupervised clustering algorithms for delineating within-field management zones. ASAE, St. Joseph, MI, USA.
- Goovaerts, P. (1997). Geostatistics for Natural Resources Evaluation. Oxford University Press, New York.
- Lark, R.M., Stafford, J.V. (1996). Classification as a first step in the interpretation of temporal and spatial variability of crop yield. *Aspects of Applied Biology*, 46, 139 - 142.
- Larscheid, G., Blackmore, B.S. (1996). Interactions between farm managers and information systems with respect to yield mapping. In P. C. Robert, R. H. Rust, & W. E. Larson (Eds.), 3rd International Conference on precision agriculture (pp. 1153e1163). Madison, Winsconsin, USA: ASA, CSSA, SSSA & ASAE
- Marques da Silva, J. R. (2006). Analysis of the spatial and temporal variability of irrigated maize yield. *Biosystems Engeneering*, 94(3), 337 - 349.
- Panneton, B., Brouillard, M., Piekutowski, T. (2001). Integration of yield data from several years into a single map. In G. Grenier, B. S. Blackmore (Eds.), 3rd European conference on precision agriculture (pp. 73e78). Montpellier: Agro Montpellier.
- Swindell, J. (1997). Mapping the spatial variability in the yield potential of arable land through GIS analysis of sequential yield maps. In J. V. Stafford (Ed.), 1st European conference on precision agriculture (pp. 827 - 834). Warwick, UK: BIOS Scientific publishers.

## **7. CONCLUSIONES GENERALES.**

En este apartado se incluyen las conclusiones traducidas al castellano de los tres artículos contenidos en la presente tesis, con objeto de mostrar una visión resumida de los mismos y, a continuación, las referidas al estudio de la variabilidad temporal de la CE<sub>s</sub> y de las producciones del cultivo de girasol en la misma parcela experimental, incluidos en el apartado 6. De este modo, se completan y enlazan los diferentes trabajos que constituyen el armazón de la misma, los cuales describen los métodos estudiados para conseguir el fin planteado de delimitar las zonas de manejo necesarias para aplicar las técnicas de agricultura de precisión, a partir de muestreos de conductividad eléctrica aparente con sensores de contacto y estudiar su variabilidad espacial y temporal, sus relaciones con los parámetros físico-químicos del suelo y con las producciones del cultivo de girasol en secano.

### **7.1. “USO DE LAS MEDIDAS DE LA CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO COMO BASE PARA LA DETERMINACIÓN DE DIFERENTES ZONAS DE MANEJO”.**

Las medidas georreferenciadas de CE<sub>a</sub>, realizadas mediante la combinación de un GPS y un sensor de contacto como el Veris 3100, es una forma rápida y barata de obtener una gran cantidad de información sobre el suelo. La configuración del sensor permite distinguir entre medidas superficiales (0-30 cm), CE<sub>s</sub>, y profundas (0-90 cm), CE<sub>d</sub>. Ambas muestran una relación importante con las propiedades fundamentales del suelo. Así, entre la fracción arcillosa del suelo y CE<sub>a</sub> se encontró una correlación positiva, lo cual era de esperar ya que CE<sub>a</sub> depende de la concentración de iones en las partículas del suelo, siendo mayor en las que tienen un área superficial más amplia. Más sorprendente, en vista de la física que controla el proceso, es la correlación entre CE<sub>a</sub> y la fracción arenosa. Seguramente se deberá a la existencia de una correlación con la fracción arcillosa.

Entre CE<sub>a</sub> y otras variables relacionadas con la fertilidad de un suelo, como CIC, pH y NT, se encontró igualmente una alta correlación. Por ello, las medidas de CE<sub>a</sub> pueden

considerarse como buenos indicadores de diversos parámetros indicativos de la fertilidad del suelo.

Los datos de  $CE_s$  se emplearon como variables secundarias para la interpolación del contenido de arcilla y arena por medio del algoritmo de regresión-krigeado. En consecuencia, la distribución espacial de las principales variables texturales fue estimada de forma bastante precisa, requiriendo mucho menos esfuerzo que el necesario mediante un muestreo tradicional. Las interpolaciones de  $CE_s$  y  $CE_d$  se llevaron a cabo mediante el algoritmo del krigiado ordinario, ya que los puntos muestrales eran muy abundantes.

Después de la generación de cinco capas de información, mediante un análisis de los componentes principales se comprobó como la variabilidad espacial está dominada por la fracción arcillosa del suelo y  $CE_d$ . Los dos primeros componentes principales, los cuales explican casi la totalidad de la varianza, fueron seleccionados para la delimitación de las zonas de manejo potenciales en la parcela. Con ese fin se realizó un análisis de conglomerados y, mediante un procedimiento de clasificación "fuzzy c-means" se delimitaron dos zonas homogéneas, correspondientes con las áreas donde el contenido de arcilla es o bien alto o bien bajo y, en consecuencia,  $CE_a$  es también alto o bajo respectivamente.

La determinación de las zonas de manejo es un primer paso necesario para el establecimiento de una agricultura de precisión en la parcela analizada. Los beneficios que este tipo de agricultura, más sostenible, puede generar son múltiples, tanto desde el punto de vista económico, como energético o medioambiental.

## **7.2. “CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO Y REGRESIÓN PONDERADA GEOGRÁFICAMENTE PARA LA ELABORACIÓN DE MAPAS DE SUELOS”.**

Este estudio mostró que la capacidad de intercambio catiónico del suelo, el contenido de calcio, el porcentaje de arcilla y el pH tienen una correlación espacial razonablemente fuerte con la conductividad eléctrica aparente ( $CE_a$ ) del suelo. El uso de sensores geoeléctricos en el tipo particular de suelo del área experimental puede mejorar la

gestión nutricional de los cultivos. Esto permitirá un incremento de la eficiencia económica, ambiental y energética. Ello también hará posible trazar mapas del suelo con bajo coste.

La técnica RPG, por la dependencia espacial existente entre las variables, puede ser usada para interpretar la variación espacial en ciertas propiedades de suelo así como su correlación espacial con otras variables asociadas.

### **7.3. “EL MODELO DE RASCH Y LA AGRICULTURA DE PRECISIÓN. APLICACIÓN AL ESTUDIO DE LA FERTILIDAD POTENCIAL EN UNA PARCELA”.**

El uso del modelo de Rasch como instrumento de medida aplicado al ámbito agrícola, con el fin de determinar la fertilidad potencial de un suelo, constituye una nueva aplicación de esta metodología de una gran importancia práctica.

En el caso estudiado en el presente trabajo, en el que se han considerado las diferentes fracciones texturales del suelo y la conductividad eléctrica aparente como las variables que influyen en la fertilidad, se ha establecido una clasificación en la que se han discriminado las muestras de suelo y las propiedades del mismo en función de la fertilidad potencial. Así, se ha podido elaborar un listado de las muestras de suelo en función de sus niveles de fertilidad y otro de las propiedades edáficas según su mayor propensión a inducir dicha fertilidad. Además, mediante el análisis de los desajustes, se han detectado qué muestras de suelo y qué propiedades se salen fuera del patrón de comportamiento de la totalidad de los datos considerados.

Con esta metodología se puede discriminar, con una base racional, las localizaciones de la parcela experimental que muestran una mayor propensión a la fertilidad, integrando propiedades aparentemente heterogéneas, con unidades diferentes, pero que comparten el principio común de influir sobre la fertilidad potencial del suelo. En una fase posterior, esta información podría emplearse como base para la delimitación de diferentes ambientes en el área de estudio.

## **7.4. VARIABILIDAD TEMPORAL DE LAS MEDIDAS DE CE<sub>s</sub> Y DE LAS PRODUCCIONES EN EL CULTIVO DE GIRASOL DE SECANO.**

El muestreo de la CE<sub>s</sub> presenta una gran estabilidad a lo largo del tiempo, lo cual, en términos prácticos significa que, una vez efectuado este tipo de muestreo en una parcela agrícola, no es necesario volver a repetirlo, al menos durante un periodo bastante prolongado de tiempo, en todo caso superior a dos años, pues como se ha comprobado, durante ese periodo apenas ha habido variación, con las ventajas de tipo económico que ello conlleva. La necesidad de realizar un nuevo muestreo de CE<sub>s</sub> en una parcela dependerá, en todo caso, de las circunstancias particulares de cada parcela de cultivo y, una vez realizado, será necesario evaluar si la variación existente justifica mantener, acortar o alargar, el periodo de repetición entre los mismos.

Del estudio de la variabilidad temporal de las producciones del cultivo de girasol se deduce que existe una buena correlación entre los valores obtenidos en diferentes años si bien existen distorsiones debidas a factores externos, como son los daños provocados por las aves silvestres o la pluviometría.

Comparativamente se observa que, a lo largo del tiempo, los valores de los muestreos de CE<sub>s</sub> presentan una mayor estabilidad que los de producción, por lo cual resulta ser un índice mucho más exacto de la medida de la fertilidad potencial del terreno agrícola.

El uso de la CE<sub>s</sub> como indicador de la fertilidad potencial de un terreno es especialmente eficaz en la determinación de las áreas menos productivas y, por consiguiente, en la determinación de las zonas menos rentables de la parcela.

Este hecho abre nuevas perspectivas a la Agricultura de Precisión, ya que su uso en cultivos de elevados costes de producción, permiten orientar al agricultor en la toma de decisiones en relación a la determinación de los lugares con poca o negativa rentabilidad, reduciendo de forma importante las necesidades financieras de la explotación.

Por último la alta correlación encontrada entre los resultados anteriores y los obtenidos por el modelo del Rasch permiten concluir que este último procedimiento matemático ofrece unos resultados muy fiables.

## **8. REFERENCIAS BIBLIOGRÁFICAS**

- Adamchuk, V.I., Hummel, J.W., Morgan, M.T., Upadhyaya, S.K. (2004). On-the-go soil sensors for precision agricultura. CVComputers and Electronics in Agriculture. Vol 44(1), pp. 71-91.
- Álvarez, P. (2004). "Transforming non categorical data for Rasch analysis". Rasch Measurement in health sciences. Jam press. Maple Grove, Minnesota, USA.
- Álvarez, P. (2005). Several Noncategorical Measures Define Air Pollution Construct. Rasch Measurement in Health Science. JAM Press. Maple Grove, Minnesota, USA.
- Álvarez, P., Pulgarín, A. (1996). The Rasch Model. Measuring the impact of scientific journals: Analytical Chemistry. Journal of the American Society for Information Science 47,458-467.
- Anderson-Cook, C. M., Alley, M. M., Roygard, J. K. F., Khosla, R., Noble, R. B., Doolittle, J. A. (2002). Differentiating soil types using electromagnetic conductivity and crop yield maps. Soil Science Society America Journal, 66, 1562–1570.
- Andrich, D. (1988). Rasch model for measurement. Newbury Park, CA, USA: Sage Publications.
- Aimrun, W., Amin, MSM., Rusnam, M., Ahmad, Desa., Hanafi, MM., Anuar, AR. (2009). European Journal of Scientific Research Vol.31 No.1, pp. 37-51.
- Benson, R., Glaccum, R.A., Noel, M.R. (1988). Geophysical Techniques for Sensing Buried Wastes and Waste Migration. National Water Well Association, Dublin, OH, USA.
- Bezdek, J.C., Keller, J.M., Krishnapuram, R., Pal, N.R. (1999). Fuzzy Models and Algorithms for Pattern Recognition and Image Processing. Kluwer Academic Publishers, Boston, USA.
- Blackmore, B. S., Godwin, R. J., & Fountas, S. (2003). The analysis of spatial and temporal trends in yield map data over six years. Biosystems Engineering, 84(4), 455 - 466.
- Bragachini, M., Martellotto, E., Bianchini, A., Bongiovanni, R. (1998). Nuevas herramientas para el ajuste del diagnóstico agronómico y aplicación precisa de insumos. INTA.

- Bremner, J.M. (1960). Determination of nitrogen in soil by Kjeldahl method. *J. Agric. Sci.* 55,11-33.
- Brock, A., Brouder, S.M., Blumhoff, G., Hofmann, B.S. (2005). Defining yield-based management zones for corn-soybean rotations. *Agron. J.* 97,1115-1128.
- Brunsdon, C., Fotheringham, A. S., Charlton, M. (2002). Geographically weighted summary statistics: A framework for localized exploratory data analysis. *Computers, Environment and Urban Systems*, 26, 501–524.
- Bullock, D.S., Bullock D.G. (2000). Economic optimality of input application rates in precision farming. *Prec. Agric.* 2, 71-101.
- Burrough, PA, McDonnell RA. (1998). *Principles of Geographical Information Systems*. Oxford University Press, Oxford, UK.
- Cambardella, C.A., Moorman, T.B., Novak, J.M., Parkin, T.B., Karlen, D.L., Turco, R.F., Konopka, A.E. (1994). Field-scale variability of soil properties in Central Iowa soils. *Soil Sci. Soc. Am. J.* 58,1501-1511.
- Carr, P.M., Carlson, G.R., Jacobsen, J.S., Nielsen, G.A., Skogley, E.O. (1991). Farming soils, not fields: A strategy for increasing fertilizer profitability, *J. Prod. Agric.* 4, pp 57-61,.
- Casa, R., Castrignanò, A. (2008). Analysis of spatial relationships between soil and crop variables in a durum wheat field using a multivariate geostatistical approach. *Eur. J. Agron.* 28,331-342.
- Castrignanò, A., Buttafuoco, G. (2004). Geostatistical stochastic simulation of soil water content in a forested area of south Italy. *Biosystems Engineering*, 87(2),257-266.
- Castrignano, A., Buttafuoco, G., Giasi, R.C. (2008). Assessment of the risk of groundwater salinisation using multivariate geostatistics. *GeoEnv VI—geostatistics for environmental applications. Quabtitative Geology and Geostatistics*, vol. 15. Springer, Berlin, Germany, pp. 191–202.
- Castrignanò, A., Maiorana, M., Fornaro, F. (2003). Using regionalised variables to assess field-scale spatiotemporal variability of soil impedance for different tillage management. *Biosystems Engineering*, 85(3),381-392.

- Chapman, H.D. (1965). Cation-Exchange Capacity. In C.A. Black (Ed.). *Methods of Soil Analysis*, Part 2, American Society of Agronomy, Madison, WI, USA.
- Charlton, M., Fotheringham S., Brunsdon C. (2005). Workshop on Geographically Weighted Regression (GWR). University of Leeds, June 2005.
- Cook, P. G., Walker, G. R. (1992). Depth profiles of electrical conductivity from linear combinations of electromagnetic induction measurements. *Soil Science Society America Journal*, 56, 1015–1022.
- Corwin, D.L., Lesch, S.M. (2003). Application of soil electrical conductivity to precision agriculture: theory, principles and guidelines. *Agron. J.* 95 (3), 455–471.
- Corwin, D. L., Lesch, S. M. (2005a). Apparent soil electrical conductivity measurements in agriculture. *Computers and Electronics in Agriculture*, 46, 11–43.
- Corwin, D. L., Lesch, S. M. (2005b). Characterizing soil spatial variability with apparent soil electrical conductivity: Part II. Case study. *Computers and Electronics in Agriculture*, 46, 135–152.
- Corwin, D.L., Loague, K., Ellsworth, T.R., (1999). Assessing non-point source pollution in the vadose zone with advanced information technologies. In: Corwin, D.L., Loague, K., Ellsworth, T.R. (Eds.), *Assessment of Non-point Source Pollution in the Vadose Zone*. Geophysical Monogr. 108. AGU, Washington, DC, USA, pp. 1–20.
- Cressie, N. (1985). Fitting variogram models by weighted least squares. *Mathematical Geology* 17(5), 563–586.
- Dallmeijer, A. J., Scholtes, V. A., Becher, J., Roorda, L. D. (2011). Measuring mobility limitations in children with cerebral palsy: Rasch model fit of a mobility questionnaire, MobQues28. *Archives of Physical Medicine and Rehabilitation*, 92(4), 640 -645.
- Davis, K. M. (2007). Using apparent electrical conductivity (EC<sub>a</sub>) via electromagnetic induction (EMI) to characterize soils and the stratigraphy for wetland restoration. Master of Science Thesis, North Carolina State University.

- Diker, K., Heermann, D.F., Brodahl, M.K. (2004). Frequency analysis of yield for delineating yield response zones. *Precision Agric.* 5,435-444.
- ESRI (2009). ARCGIS 9.3.1 Geographically Weighted Regression Tool. Environmental Systems Research Institute, Redlands, CA, USA.
- Fleming, K.L., Heermann, D.F., Westfall, D.G. (2004). Evaluating soil color with farmer input and apparent soil electrical conductivity for management zone delineation. *Agron. J.* 96,1581-1587.
- Fraisse, C.W., Sudduth, K.A., Kitchen, N.R. (2001). Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. *Trans. ASAE* 44 (1), 155–166.
- Fraisse, C.W., Sudduth, K., Kitchen, N.R., Fridgen, J.J. (1999). Use of unsupervised clustering algorithms for delineating within-field management zones. *ASAE*, St. Joseph, MI, USA.
- Fridgen, J.J., Kitchen, N.R., Sudduth, K.A., Drummond, S.T., Wiebold, W.J., Fraisse, C.W. (2004). Management Zone Analyst (MZA): software for subfield management zone delineation. *Agron. J.* 96, 100–108.
- Frogbrook, Z.L., Oliver, M.A. (2001). Comparing the spatial prediction of soil organic matter by two laboratory methods. *Soil Use Manage.* 17, 235–244.
- Goovaerts, P. (1997). *Geostatistics for Natural Resources Evaluation*. Oxford University Press, New York.
- Hengl, T., Heuvelink, G.B.M., Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma* 120, 75–93.
- Höppner, F., Klawonn, F., Kruse, R., Runkler, T.A. (1999). *Fuzzy Cluster Analysis*. Chichester, UK.
- Hummel, J.W., Gaultney, L.D., and Sudduth, K.A. (1996). Soil property sensing for site-specific crop management. *Computers and Electronics in Agriculture*, Vol. 14, pp 121-136.

- Isaac, R. A., and Johnson, W. C. (1983). High speed analysis of agricultural samples using inductively coupled plasma-atomic emission spectroscopy. *Spectrochimica Acta* 38B, 277-282.
- Isaaks, E.H., Srivastava, R.M. (1989). An Introduction to Applied Geostatistics, Oxford Univ. Press, New York.
- Johnson, C.K., Mortensen, D.A., Wienhold, B.J., Shanahan, J.F., Doran, J.W. (2003). Site-specific management zones based on soil electrical conductivity in a semiarid cropping system. *Agron. J.* 95, 303-315.
- Kitchen, N.R., Sudduth, K.A., Myers, D.B., Drummond, S.T., Hong, S.Y. (2005). Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. *Comp. Electron. Agric.* 46, 285–308.
- Kravchenko, A.N., Bullock, D.G., Reetz, H.F. (2000). Correlation of corn and soybean grain yield with topography and soil properties. *Agron. J.* 92, 75-83.
- Lark, R.M., Stafford, J.V. (1996). Classification as a first step in the interpretation of temporal and spatial variability of crop yield. *Aspects of Applied Biology*, 46, 139 - 142.
- Lark, R.M. (1998). Forming spatially coherent regions by classification of multivariate data: An example from the analysis of maps of crop yield. *Int J. Geogr. Inf. Sci.* 12, 83-98.
- Larscheid, G., Blackmore, B.S. (1996). Interactions between farm managers and information systems with respect to yield mapping. In P. C. Robert, R. H. Rust, & W. E. Larson (Eds.), 3rd International Conference on precision agriculture (pp. 1153e1163). Madison, Winsconsin, USA: ASA, CSSA, SSSA & ASAE
- Larson, W.E. and Robert, P.C. (1991). Farming by soil, Soil Management for Sustainability, pp 103-112. Soil and Water Conservation Society, Ankeny, IA.
- Li, Y., Shi, Z., Li, F., Li, H.Y. (2007). Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. *Comp. Electron. Agric.* 56, 174-186.
- Linacre, J.M. (2000). Winsteps (Computer program and manual). MESA Press, Chicago.

Lowenberg-DeBoer, J. (2000). Nivel de adopción actual y potencial de la Agricultura de Precisión en el mundo y en Argentina. Proyecto Agricultura de precisión, INTA Manfredi (Argentina).

Mallarino, A.P., Oyarzabal, E.S., Hinz, P.N. (1999). Interpreting within-field relationships between crop yields and soil and plant variables using factor analysis. Precision Agric. 1, 15-25.

Marques da Silva, J. R. (2006). Analysis of the spatial and temporal variability of irrigated maize yield. Biosystems Engineering, 94(3), 337 - 349.

Marques da Silva, J.R. , Rebollo, F.J., Sousa, A., Mesquita, P. (2012). Yield potential probability maps using the Rasch model. Biosystems engineering 111, 369 – 380.

McCann, B.L., Pennock, D.J., van Kessel, C., Walley, F.L. (1996). The development of management units for site-specific farming.. In: Robert P.C. (Ed.), Proc. Int. Conf. Precision Agric., 3rd, St. Paul, MN. 23-26 June 1996, ASA, CSSA, and SSSA, Madison, WI, USA, pp. 295-302.

McNeill, J. D. (1992). Rapid, accurate mapping of soil salinity by electromagnetic ground conductivity meters. In G. C. Topp, W. D. Reynolds, & R. E. Green (Eds.), Advances in measurement of soil physical properties: Bringing theory into practice. SSSA Special Publication 30 (pp. 209–229). Madison, WI: SSSA.

Mertens, F.M., Pätzold, S., Welp, G. (2008). Spatial heterogeneity of soil properties and its mapping with apparent electrical conductivity. J. Plant Nutr. Soil Sci. 171, 146-154.

Moral, F.J., Álvarez, P., Canito, J.L. (2006). Mapping and hazard assessment of atmospheric pollution in a medium sized urban area using the Rasch model and geostatistics techniques. Atmos. Environ. 40, 1408–1418.

Moral, F.J. (2010). Comparison of different geostatistical approaches to map climate variables: application to precipitation. International Journal of Climatology. Vol. 30 620-631.

- Moral, F.J., Terrón, J.M., Marques da Silva, J.R. (2010). Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. *Soil & Tillage Research* 106,335-343.
- Morari, F., Castrignano, A., Pagliarin, C. (2009). Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geoelectrical sensors. *Comp. Electron. Agric.* 68, 97–107.
- Morillo, J. (2003). *Agricultura de Precisión*. Universidad de Extremadura.
- Mulla, D.J. (1991). Using geostatistics and GIS to manage spatial patterns in soil fertility. In: Kranzler, G. (Ed.), *Automated Agriculture for the 21st Century*. ASAE, St. Joseph, MI, USA, pp. 336-345.
- National Research Council (NRC) (1997). *Precision Agriculture in the 21st Century: Geospatial and Information Technologies in Crop Management*, NRC National Academy of Sciences, Washington, DC.
- O'Brien, Robert M. (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. *Quality and Quantity Journal*: 41(5):673-690.
- Odeh, I.O:A., McBratney, A.B., Chittleborough, D.J. (1992). Soil pattern recognition with fuzzy c-means: application to classification and soil-landform interrelationship. *Soil Sci. Soc. Am. J.* 56,505-516.
- Officer, S.J., Kravchenko, A., Bollero, G.A., Sudduth, K.A., Kitchen, N.R., Wiebold, W.J., Palm, H.L., Bullock, D.G. (2004). Relationships between soil bulk electrical conductivity and the principal component analysis of topography and soil fertility values. *Plant Soil* 258,269-280.
- Ortega, R.A., Santibáñez, O.A. (2007). Determination of management zones in corn (*Zea mays L.*) based on soil fertility. *Comp. Electron. Agric.* 58, 49–59.
- Panneton, B., Brouillard, M., Piekutowski, T. (2001). Integration of yield data from several years into a single map. In G. Grenier, B. S. Blackmore (Eds.), *3rd European conference on precision agriculture* (pp. 73e78). Montpellier: Agro Montpellier.

- Pierce, F. J., Nowak, P. (1999). Aspects of Precision Agriculture, Advances in Agronomy, vol 67, pp 1-85.
- Pierce, F. J., Robert, P.C., Mangold, G. (1994). Site-specific management: The pros, the cons, and the realities. Proceedings of the International Crop Management Conference, Iowa State University, pp 17-21.
- Pierce, F. J. and Sadler, E.J. (1997). The State of Site-Specific Management for Agriculture, ASA Miscellaneous publication. ASA. CSSA, and SSSA, Madison, WI.
- Rasch, G. (1980). Probabilistic Models for Some Intelligence and Attainment Tests, revised and expanded ed. University of Chicago Press, Denmark.
- Reichenberger, L., Russnogle, J. (1989). Farm by the foot, Farm J. 113, pp 11-15.
- Robert, P. C., Rust, R. H., Larson, W. E. (1994). Preface p. xiii. In Robert et al.(ed.) Site-specific management for agricultural systems. American Society of Agronomy, Madison, WI.
- Rupe J., Kirkpatrick T., Bajwa S., Cartwright R. (2004). Application of precision agriculture technology to define and manage nematodes and diseases of soybean. University of Arkansas and the Arkansas Cooperative Extension Service. 2004. Disponible en: [http://www.ipni.net/far/farguide.nsf/926048f0196c9d4285256983005c64de/8c963348cc505d6f86256e8c005391bc/\\$FILE/AR-24F%20Rupe%202004%20Annual%20rpt.doc](http://www.ipni.net/far/farguide.nsf/926048f0196c9d4285256983005c64de/8c963348cc505d6f86256e8c005391bc/$FILE/AR-24F%20Rupe%202004%20Annual%20rpt.doc)
- Sawyer, J.E. (1994). Concepts of variable rate technology with considerations for fertilizer application, J. Prod. Agric. 7, pp 195-201.
- Schepers, A.R., Shanahan, J.F., Liebig, M.A., Schepers, J.S., Johnson, S.H., Luchiari, A. (2004). Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. Agron. J. 96, 195–203.
- Schueller, J. K. (1991). In-field site-specific crop production. Automatic Agriculture for the 21st Century. Proceedings of the 1991 Symposium, Chicago, IL, pp 16-17.
- Serrano J.M., Oliveira J., Silva J.R., Shahidian S. (2010). Medição e mapeamento da condutividade eléctrica aparente do solo em pastagens. Rev. de Ciências Agrárias, dez. 2010, vol.33, no.2, p.5-14

- Soil Conservation Service, (1972). Soil Survey Laboratory. Methods and procedures for collecting soil samples. Soil Survey Report 1. U.S.D.A., Dept. Agric., Washington, USA.
- Sudduth, K.A., Kitchen, N.R., Wiebold, W.J., Batchelor, W.D., Bollero, G.A., Bullock, D.G., Clay, D.E., Palm, H.L., Pierce, F.J., Schuler, R.T., Thelen, K.D. (2005). Relating apparent electrical conductivity top soil properties across the North-Central USA. Comp. Electron. Agric. 46, 263–283.
- Sudduth, K.A., Hummel, J.W., S.J. Birrell. (1997). Sensors for site-specific management. In The State of Site-Specific Management for Agriculture, Eds. Pierce, F.T. and Sadler, E.J., ASA-CSSA-SSSA, Madison, Wisconsin, USA, pp. 183-210.
- Swindell, J. (1997). Mapping the spatial variability in the yield potential of arable land through GIS analysis of sequential yield maps. In J. V. Stafford (Ed.), 1st European conference on precision agriculture (pp. 827 - 834). Warwick, UK: BIOS Scientific publishers.
- Taylor, J.C.; Wood, G.A.; Earl, R.; Godwin, R.J. (2003). Soil Factors and their Influence on Within-field Crop Variability, Part II: Spatial Analysis and Determination of Management Zones. Biosystems Engineering 84 (4), 441–453.
- Tristán, A. (2002). Análisis de Rasch para todos. CENEVAL.
- USDA-NRCS, (1998). Keys to soil taxonomy, 8th ed. United States Department of Agriculture-Natural Resources Conservation Service, Washington, USA.
- Verheyen, S., Hampton, J. A., Storms, G. (2010). A probabilistic threshold model: analyzing semantic categorization data with the Rasch model. Acta Psychologica, 135(2), 216 - 225.
- Vitharana, U.W.A., Van Meirvenne, M., Simpson, D., Cockx, L., De Baerdemaeker, J. (2008). Key soil and topographic properties to delineate potential management classes for precision agriculture in the European loess area. Geoderma 143, 206-215.
- Wackernagel, H. (2003). Multivariate geostatistics. In: An Introduction with Applications, third edition. Springer Verlag, Berlin, Germany.

Walkley, A., Black, I.A. (1934). An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Sci.* 37,29-38.

Wright, B.D., Masters, G.N. (1982). Rating scale analysis. MESA Press, Chicago.

Wright, B.D., Panchapakesan, N. (1969). A procedure for sample-item analysis. *Educational and Psychological Measurement* 29, 23-48.

Xin-Zhong, W., Guo-Shun, L., Hong-Chao, H., Zhen-Hai, W., Qing-Hua, L., Xu-Feng, L., Wei-Hong, H., Yan-Tao, L. (2009). Determination of management zones for a tobacco field based on soil fertility. *Comp. Electron. Agric.* 65, 168–175.