

Variabilidad espacial multivariada en variables de suelo y rendimiento a escala fina

CÓRDOBA, M¹.; BRUNO, C¹.; COSTA, J².; BALZARINI, M¹.

RESUMEN

El manejo sitio-específico dentro del lote requiere delimitar zonas de manejo (ZM). Múltiples variables, tales como propiedades del suelo, son usadas para la zonificación. El análisis de cluster fuzzy k-means (CFK) es frecuentemente utilizado para la delimitación de ZM. CFK suele aplicarse sobre las variables originales o sobre las componentes principales (CP) derivadas del análisis de componentes principales (PCA). El análisis de correlaciones canónicas (ACC) es otra técnica multivariada que permite cuantificar la magnitud de la relación lineal entre dos grupos de variables métricas como podrían ser los rendimientos de los cultivos y las variables de suelo. Sin embargo, estos análisis no consideran la presencia de correlaciones espaciales. El método MULTISPATI-PCA constituye una forma de PCA que contempla la información espacial previo a la conformación de las CP. En este trabajo evaluamos la capacidad de cinco procedimientos multivariados para delimitar ZM: CFK sobre variables edáficas (CFK-VS), CFK sobre componentes principales del PCA (CFK-CP), CFK sobre CP espaciales (CPE) producidas por MULTISPATI-PCA (CFK-CPE) y partición basada en percentiles de variables canónicas del ACC que correlacionan rendimientos con CP de variables de suelo (ACC-CP) y de variables canónicas elaboradas desde CPE (ACC-CPE). Se compararon las diferencias de rendimientos entre las ZM delimitadas por cada método. Se trabajó con datos de conductividad eléctrica aparente en dos profundidades 0-30 cm y 0-90 cm, elevación, profundidad de tosca y rendimientos de soja y trigo. El método CFK-CPE delimitó ZM con diferencias significativas de rendimiento entre todas las zonas y con mayores diferencias entre las medias ajustadas.

Palabras clave: datos espaciales, componentes principales, MULTISPATI-PCA, cluster fuzzy k-means.

ABSTRACT

1. INTRODUCCIÓN

¹Cátedra de Estadística y Biometría, FCA-UNC y CONICET, Av. Valparaíso s/n. (5000) Ciudad Universitaria, Córdoba, Argentina. mbalzari@agro.unc.edu

² Estación experimental Balcarce INTA, Ruta 226 Km 73,5 (7620) Balcarce, Buenos Aires, Argentina.

33 El conocimiento de la variabilidad del rendimiento dentro de lotes en producción agrícola, es
34 esencial para el manejo sitio específico (MSE), uno de los objetivos de la agricultura de
35 precisión (AP) orientado a optimizar el uso de los insumos agrícolas. El punto de partida
36 para aplicar MSE es delimitar zonas de manejo (ZM) dentro de los lotes. Estas subregiones
37 constituyen áreas con características similares, tales como textura, topografía, estado
38 hídrico y niveles de nutrientes del suelo (Moral et al., 2010). Las propiedades físicas y
39 químicas del suelo y la topografía son frecuentemente utilizadas para delimitar ZM. La
40 conductividad eléctrica aparente (CE) a distintas profundidades está siendo muy utilizada ya
41 que su variabilidad es indicador de la distribución espacial de otras propiedades de suelo
42 (Corwin y Lesch 2010; Moral et al., 2010; Rodríguez-Pérez et al., 2011). Asimismo, la
43 elevación del terreno también provee información para la delimitación de ZM, debido a que
44 afecta el crecimiento y desarrollo de los cultivos y por tanto es buena indicadora de la
45 variabilidad espacial del rendimiento. En suelos pampeanos bajo cultivo de granos, la
46 profundidad del horizonte petrocálcico conocido localmente como tosca, es otra variable que
47 puede resultar útil para la delimitación de ZM. La profundidad de tosca afecta la distribución
48 espacial del agua acumulada en el perfil y, consecuentemente, determina la variabilidad
49 espacial de los rendimientos de los cultivos (Peralta et al., 2011).

50 Dado que en cada sitio del lote se recolecta un conjunto de variables y que el rendimiento
51 depende de todas y sus correlaciones, resulta apropiado analizarlas simultáneamente. Un
52 método de análisis multivariado difundido para este fin es el análisis de cluster mediante el
53 cual cada sitio del lote es asignado a un cluster y estos pueden ser usados como ZM (Li et
54 al., 2007; Ortega y Santibáñez, 2007; Arno et al., 2011). Un software basado en el análisis
55 de cluster especialmente desarrollado para la delimitación de ZM es Management Zone
56 Analyst (MZA) el cual forma los clusters con el algoritmo no supervisado fuzzy k-means
57 (CFK) (Fridge et al., 2004). El método CFK suele aplicarse usando como inputs las variables
58 de suelo medidas originalmente o, alternativamente, combinaciones lineales de éstas que
59 tienen en cuenta las correlaciones esperables entre las variables. El Análisis de
60 Componentes Principales (PCA) es comúnmente usado para construir estas combinaciones
61 lineales o Componentes Principales (CP) (Schepers et al., 2004; Li et al., 2007; Xin-Zhong et
62 al., 2009; Moral et al., 2010). Sin embargo, éstos métodos no tiene en cuenta las
63 correlaciones entre datos debidas a la presencia de estructuras de dependencia esperable
64 en estos datos espaciales. Dray et al. (2008), proponen una forma de PCA que incorpora la
65 información espacial previo a la conformación de las variables sintéticas, el método es
66 conocido como MULTISPATI-PCA. A diferencia del PCA los CPe obtenidos con
67 MULTISPATI-PCA no han sido utilizados como input del análisis de cluster. La restricción
68 dada por los datos espaciales, se incorpora mediante el índice de Moran que mide la
69 dependencia o correlación espacial entre las observaciones en un sitio y el promedio de las

70 observaciones en el vecindario de ese sitio. MULTISPATI-PCA ha resultado provechoso en
71 estudios de suelos realizados a escala macrogeográfica (Arrouays et al., 2011) pero su
72 aplicación en una escala fina como la del lote agrícola es poco conocida.
73 Otra técnica basada en correlaciones entre variables es el análisis de correlaciones
74 canónicas (ACC). El ACC permite cuantificar la magnitud de la relación lineal entre dos
75 grupos de variables métricas, unas consideradas como variables dependientes y otras como
76 independientes; dado que para un mismo clima, los rendimientos están fuertemente
77 determinados por las variables de suelo, se supone que las variables canónicas asociadas a
78 la correlación entre datos de rendimientos cosechados en los distintos sitios de un lote y las
79 variables edáficas de los mismos sitios podrían suministrar información para la partición de
80 sitios en función de su potencial productivo a escala fina. Si bien el ACC tampoco tiene en
81 cuenta las correlaciones debidas a estructuras espaciales (uni o multivariadas), la
82 incorporación de la información espacial puede realizarse usando CPe para la construcción
83 de las variables canónicas. En este trabajo proponemos usar las componentes principales
84 espaciales obtenidas de un análisis MULTISPATI-PCA sobre las variables edáficas como el
85 grupo de variables métricas que se relaciona con los rendimientos recolectados en las
86 últimas cosechas sobre cada sitio del lote. La variable sintética canónica del grupo de
87 atributos edáficos es posteriormente usada para particionar los sitios y delimitar ZM. El
88 objetivo de este estudio es evaluar el desempeño de los distintos procedimientos propuestos
89 para la delimitación de ZM a partir de datos georreferenciados multivariados como los
90 derivados de la aplicación de diversas maquinarias precisas en la agricultura de precisión.

91 **2. METODOLOGÍA**

92 **Datos**

93 Se trabajó con datos provenientes de un lote de 65,4 ha en producción de trigo y soja de
94 segunda, ubicado al sudeste pampeano de la provincia de Buenos Aires, Argentina. Se
95 compilaron valores georreferenciados de conductividad eléctrica aparente (CE) [mS m^{-1}] en
96 dos profundidades 0-30 cm (CE30) y 0-90 cm (CE90), Elevación [m], profundidad de tosca
97 (PT) [cm] y rendimiento de soja (RS) [t ha^{-1}] y trigo (RT) [t ha^{-1}]. Los valores de CE fueron
98 tomados utilizando un sensor (Veris 3100, Division of Geoprobe Systems, Salina, KS) que
99 utiliza el principio de la inducción electromagnética. El sensor Veris 3100 recorrió el lote en
100 una serie de transectas paralelas espaciados a intervalos de 15 a 20 m. El instrumento fue
101 calibrado, según las instrucciones del fabricante, antes de la recolección de los datos. Los
102 datos de CE fueron simultáneamente georreferenciados con un DGPS (Trimble R3, Trimble
103 Navigation Limited, USA) con una exactitud de medición submétrica y configurado para
104 tomar la posición del satélite cada segundo.

105 Los datos de elevación del terreno también se midieron con un DGPS y se procesaron para
106 obtener una precisión vertical de entre 3 y 5 cm aproximadamente. Las mediciones de
107 profundidad de tosca se realizaron utilizando un penetrómetro hidráulico (Gidding) acoplado
108 a un DGPS en una grilla regular de 30 m. Para cuantificar el rendimiento en grano del cultivo
109 se utilizó un monitor de rendimiento acoplado a un equipo de cosecha conectados a un
110 DGPS.

111 Los datos fueron sometidos a procedimientos de depuración vía la construcción de gráficos
112 box-plots para la identificación de valores extremos. Debido a las diferentes resoluciones
113 espaciales de las variables medidas, se promediaron los datos de CE30, CE90, Elevación,
114 RS y RT, que se encontraban dentro de un radio de 14 m desde cada uno de los 664 sitios,
115 dentro del lote, donde se había registrado la variable PT. Este procedimiento se realizó
116 utilizando el software Idrisi Taiga (Eastman et al., 2009). La matriz de datos resultante
117 estuvo conformada por n=672 sitios (filas) y p=5 variables (columnas).

118 **Simulación**

119 Se generó un proceso aleatorio Gaussiano bajo un modelo espacial utilizando un
120 variograma exponencial para simular valores de CE30, CE90, E, PT y rendimiento. Se
121 simularon 100 realizaciones utilizando para cada variable los parámetros estimados a partir
122 de los datos reales. En cada realización se obtuvo una matriz de datos de dimensión 700x5.
123 La simulación se realizó de manera que las variables presentaran una componente espacial
124 individual y una componente común para generar correlación espacial entre ellas (Diggle y
125 Ribeiro, 2007). Las simulaciones se realizaron utilizando el paquete geoR (Ribeiro y Diggle,
126 2001) del software libre R (R Development Core Team, 2012).

127 **Procedimientos analíticos**

128 Se realizó un análisis de conglomerados fuzzy-k means (CFK) a partir de las variables de
129 suelo medidas inicialmente (CFK-VS) con el software Management Zone Analyst 1.0.1
130 (MZA) (Fridgen et al., 2004). Debido a que las variables de suelo presentaban varianzas
131 desiguales y covarianzas no nulas, se utilizó como medida de similitud la distancia de
132 Mahalanobis. Otras opciones de configuración del MZA utilizadas para nuestro estudio
133 fueron: número máximo de iteraciones=300, criterio de convergencia=0.0001, mínimo
134 número de zonas=2 y número máximo de zonas=6. El exponente difuso se fijó en el valor
135 convencional de 1,30 (Odeh et al., 1992). Para determinar el número de ZM dentro del lote,
136 se utilizaron dos índices de desempeño; la entropía normalizada de la clasificación
137 (Normalized Classification Entropy, NCE) y el índice de rendimiento difuso (Fuzziness
138 Performance Index, FPI) (Odeh et al., 1992). El número seleccionado de zonas se determinó
139 cuando ambos, NCE y FPI, se redujeron al mínimo, lo que representa el menor grado de

140 solapamiento (FPI) o la mayor cantidad de organización (NCE) creada por la partición difusa
141 de la matriz de datos original (Fridgen et al., 2004).

142 El análisis CFK también fue realizado sobre las componentes principales. Para el
143 procedimiento denotado como CFK-CP, las variables de suelo se utilizaron en el PCA, se
144 seleccionaron las tres primeras CP (CP1, CP2 y CP3) y estas fueron usadas en MZA para
145 definir ZM, cabe aclarar que estas componentes involucraban aproximadamente la totalidad
146 de la variabilidad en los datos. Adicionalmente se obtuvieron tres nuevas variables sintéticas
147 a partir de MULTISPATI-PCA (CPe1, CPe2 y CPe3) que también fueron usadas como inputs
148 de MZA con una configuración de los parámetros idéntica a la clasificación anterior, el
149 procedimiento fue denotado como CFK-CPe. Finalmente, se utilizó el ACC para evaluar la
150 relación entre las variables de rendimiento y las tres primeras CP, así como con las tres
151 primeras CPe del MULTISPATI-PCA de las variables de suelo. Se obtuvieron nuevas
152 variables sintéticas de la primera correlación canónica significativa, tanto con el ACP (ACC-
153 CP) como desde las derivadas de MULTISPATI-PCA (ACC-CPe). Las variables canónicas
154 fueron posteriormente clasificadas en dos clases y usadas para identificar dos zonas dentro
155 del lote. El software Infostat (Di Rienzo et al., 2012) y la librería ade4 (Chessel et al., 2004)
156 del software R (R Development Core Team, 2012) fue utilizada para el ACC, PCA y
157 MULTISPATI-PCA; para este último análisis también se usó la librería spdep (Bivand et al.,
158 2012).

159 **Criterio de evaluación de los procedimientos**

160 Para comparar el desempeño de los métodos implementados en base a variables de suelo
161 se realizó un análisis de la varianza (ANAVA) evaluando la significancia estadística ($\alpha=0,05$)
162 de las diferencias entre rendimiento promedio de las zonas delimitadas por cada método. El
163 mismo fue aplicado sobre la base de datos real y sobre cada una de las 100 simulaciones.
164 El ANAVA se realizó bajo un modelo de clasificación lineal mixto considerando las
165 correlaciones espaciales entre las observaciones vía un modelo exponencial
166 (Schabenberger y Pierce, 2002). Se compararon no sólo la magnitud de las diferencias en
167 rendimiento de las zonas delimitadas sino también la varianza residual (DE dentro de la
168 zona y EE de la diferencia de medias de zonas).

169 **3. RESULTADOS Y DISCUSIÓN**

170 **Comparación de los métodos multivariados para la delimitación de ZM**

171 En la Figura 1 se representaron gráficamente los valores de FPI y NCE y el número de
172 clusters k (número de zonas) para cada método de comparación (CFK-VS, CFK-CP y CFK-
173 CPe). El número óptimo de zonas se determina cuando FPI y NCE alcanzan el valor
174 mínimo. Como menciona Arno et al. (2011), mientras que la minimización de la FPI es útil

175 porque el solapamiento entre cluster disminuye, la minimización de NCE es importante
 176 porque el grado de organización aumenta como consecuencia de la partición de la matriz de
 177 datos. La expectativa inicial de obtener un resultado coincidente para ambos índices no se
 178 cumplió. Por lo tanto, como recomienda Lark y Stafford, (1997), se seleccionó el menor
 179 número de clases que en este caso fue de dos zonas.

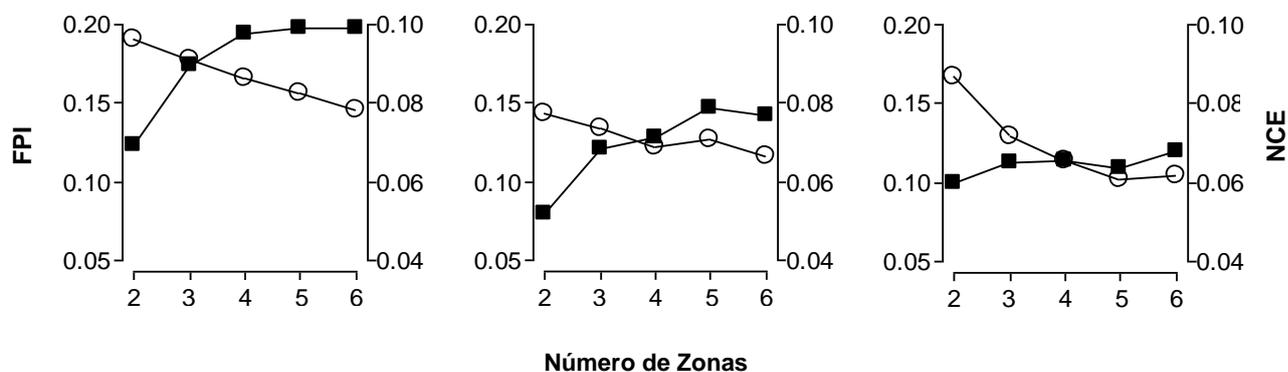


Figura 1. Fuzziness Performance Index (FPI, círculos) y Normalized Classification Entropy (NCE, cuadrados) para tres métodos de zonificación: CFK-VS, CFK-CP y CFK-CPe.

180
 181 En la Tabla 1 se presentan los resultados del ANAVA usado para comparar los rendimientos
 182 promedios entre las dos zonas definidas por cada método. CFK-CPe, ACC-CPe y ACC-CP
 183 fueron los métodos, entre los comparados, que delimitaron ZM con diferencias
 184 estadísticamente significativas de rendimiento tanto para soja como para trigo. CFK-CPe
 185 permitió identificar ZM con mayores diferencias entre las medias ajustadas de rendimiento y
 186 menor variabilidad residual dentro de cada zona y consecuentemente menor EE para las
 187 medias (Tabla 5).

188
 189 Tabla 1. Rendimientos promedios de Soja y Trigo, para dos ZM, según método de
 190 zonificación utilizado.

Método	Estimaciones	Rendimiento de Soja (RS)		Rendimiento de Trigo (RT)	
		Zona I	Zona II	Zona I	Zona II
CFK-VS	Media	1.792 ^a	1.814 ^a	3.680 ^a	3.691 ^a
	EE	0.035	0.036	0.125	0.125
CFK-CP	Media	1.781 ^a	1.827 ^a	3.672 ^a	3.702 ^a
	EE	0.035	0.036	0.125	0.125
CFK-CPe	Media	1.675 ^a	1.910 ^b	3.563 ^a	3.805 ^b
	EE	0.031	0.030	0.110	0.110
ACC-CP	Media	1.730 ^a	1.876 ^b	3.637 ^a	3.746 ^b
	EE	0.034	0.034	0.118	0.119
ACC-CPe	Media	1.687 ^a	1.918 ^b	3.579 ^a	3.814 ^b

EE 0.030 0.031 0.110 0.110

*Letras diferentes indican diferencias estadísticamente significativas ($p < 0.05$) entre las medias ajustadas de rendimiento para las distintas zonas de manejo delimitadas

191

192 El la Figura 2 se muestra las dos zonas definidas a partir de cada uno de los cinco
193 procedimientos comparados. Aun cuando las diferencias visuales entre los mapas no son
194 grandes, los rendimientos difirieron entre una y otra zona en los mapas 2c, 2d y 2e. Luego,
195 sólo estas zonas son indicativas de diferentes condiciones de suelo que impactan de
196 manera diferencial sobre la productividad de los cultivos.

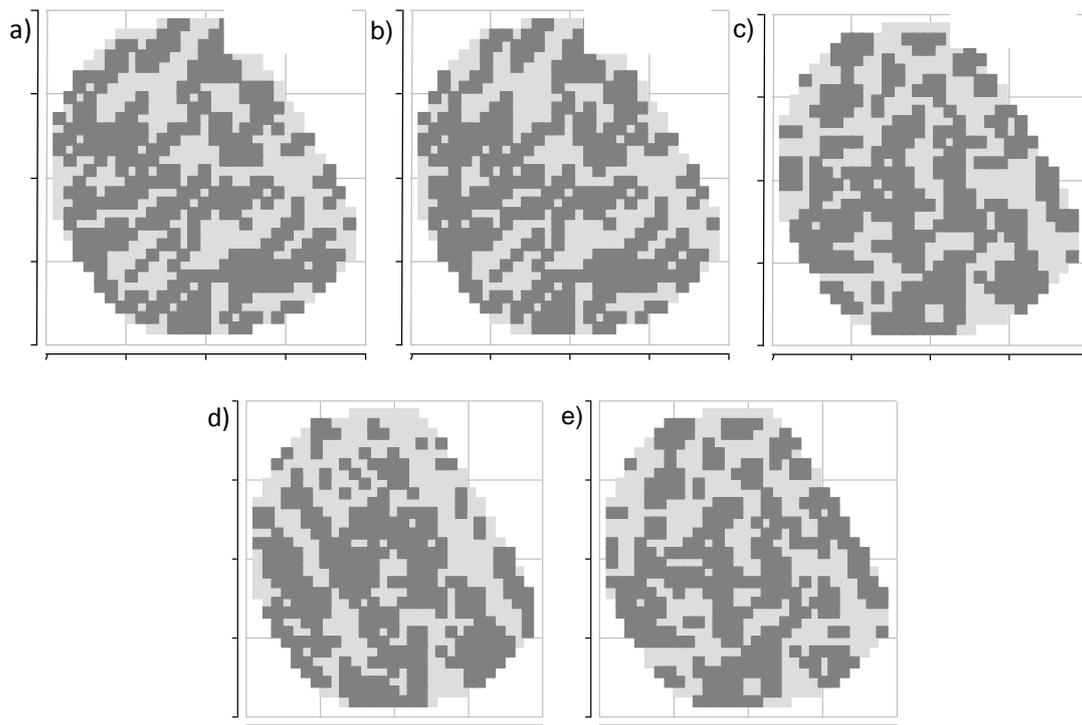


Figura 2. Zona 1 (gris claro) y zona 2 (gris oscuro) de un lote según cinco métodos de zonificación: a) CFK-VS, b) CFK-CP, c) CFK-CPe, d) ACC-CP y e) ACC-CPe.

197

198 El advenimiento de las nuevas tecnologías de información espacial utilizadas en la AP,
199 proporcionan a los productores la posibilidad de obtener información y manejar de manera
200 diferencial pequeñas áreas dentro del lote (Bullock et al., 2007). Las ZM no son
201 necesariamente estáticas y posiblemente varíen ante cambios que van surgiendo en el
202 manejo del lote a través de las campañas. Por ello, los mapas de variabilidad y la
203 clasificación de los sitios en zonas constituyen una práctica iterativa que está siendo
204 constantemente evaluada y ajustada, siendo importante utilizar los métodos estadísticos
205 más apropiados para el uso eficiente de esos datos.

206 Sin bien no existen reglas fijas para la elección del tamaño y la forma de las zonas de
 207 manejo y la limitación suele estar dada por la habilidad del productor de poder manejarlas
 208 individualmente (dimensiones y capacidades del parque de maquinaria, características
 209 físicas del lote y patrón de trabajo de la maquinaria) (Roel et al., 2007), siempre interesan
 210 zonas cuyas diferencias se expresen en los rendimientos. En este trabajo el tamaño total de
 211 las ZM obtenidos con CFK-CPe fueron para la zona I y II de 30.08 y 35.32 ha,
 212 respectivamente y las diferencias de rendimiento fueron aproximadamente del 10% tanto
 213 para soja como para trigo.

214 **Resultados de simulaciones**

215 En la Tabla 2 se presentan indicadores de la performance relativa de tres procedimientos
 216 comparados obtenidos desde las simulaciones. El método CFK-CPe detectó diferencias
 217 estadísticamente significativas entra rendimiento de las ZM delimitadas en un 81% de las
 218 base de datos simuladas, mientras que CFK-CP y CFK-VS en el 79 y 67%, respectivamente.
 219 Además CFK-CPe en el 39 % de las simulaciones identificó ZM con la mayor magnitud en
 220 las diferencias de medias de rendimiento. En el 43% de los análisis realizados sobre datos
 221 simulados, CFK-CPe generó zonas con la menor variabilidad residual.

222

223 Tabla 2. Resultados de la simulación. Porcentaje de simulaciones que identifican ZM con
 224 diferencias significativas de rendimiento

Método	ZM con diferencias en rendimiento (%)	> Magnitud Diferencias (%)	< Variabilidad residual dentro de cada ZM (%)
CFK-VS	67	27	21
CFK-CP	79	34	36
CFK-CPe	81	39	43

225 **4. CONCLUSIONES**

226 El método CFK es frecuentemente utilizado en AP sobre variables edáficas debido a que es
 227 una técnica simple de aplicar y se encuentra disponible en software. Sin embargo, en la
 228 base de datos reales usada en este trabajo, CFK sobre variables de suelo no resultó el
 229 mejor método para delimitar ZM con diferencias estadísticamente significativas respecto a
 230 su potencial productivo. El mismo resultado se obtuvo con CFK-CP el cual ha sido
 231 ampliamente utilizado en trabajos para delimitar ZM (Li et al., 2007; Xin-Zhong et al., 2009;
 232 Moral et al., 2010). ACC-CPe, ACC-CP y CFK-CPe delimitaron ZM con diferencias
 233 significativas en rendimiento, aunque CFK-CPe delimitó ZM con mayores diferencias entre
 234 las medias ajustadas de rendimiento y menor EE. Estos resultados fueron corroborados con
 235 las simulaciones que muestran un mejor desempeño del método de cluster cuando es

236 utilizado sobre variables sintéticas derivadas de MULTISPATI-PCA, considerando así no
237 sólo la correlación entre las variables sino también la estructura de dependencia espacial de
238 éstas sobre el terreno.

239 **5. AGRADECIMIENTOS**

240 Los autores expresan sus agradecimientos a los Ing. Agr. Jose Luis Costa y Nahuel Peralta
241 de la EEA INTA Balcarce, por su ayuda en la recopilación de los datos que se ofrecen en los
242 campos donde se realizó el estudio. El presente trabajo es parte del trabajo de tesis de
243 Mariano Córdoba para el cumplimiento de los requisitos del Doctorado en Ciencias
244 Agropecuarias de la Universidad Nacional de Córdoba y del programa de becas de
245 posgrado del Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET).

246 **6. REFERENCIAS**

- 247 ARNO, J.; MARTÍNEZ-CASASNOVAS, J.A.; RIBES-DASI, M.; ROSELL, J.R. 2011.
248 Clustering of grape yield maps to delineate site-specific management zones. Span. J. Agric.
249 Res. 9(3), 721–729.
- 250 ARROUAYS, D.; SABY, N.P.A.; THIOULOUSE, J.; JOLIVET, C.; BOULONNE, L.; RATIÉ, C.
251 2011. Large trends in French topsoil characteristics are revealed by spatially constrained
252 multivariate analysis. Geoderma 161:107–114.
- 253 BIVAND, R.S. 2012. spdep: Spatial Dependence: Weighting Schemes, Statistics and
254 Models. R package version 0.5-46, URL <http://CRAN.R-project.org/package=spdep>.
- 255 BULLOCK, D.S.; KITCHEN, N.; BULLOCK, D.G. 2007. Multidisciplinary Teams: A Necessity
256 for Research in Precision Agriculture Systems. Crop Sci. 47:1765–1769.
- 257 CHESSEL, D.; DUFOUR A.B.; THIOULOUSE, J. 2004. The ade4 package-I- One-table
258 methods. R News 4:5–10.
- 259 CORWIN, D.L.; LESCH, S.M. 2010. Delineating site-specific management units with
260 proximal sensors. En: OLIVER, M. (Ed.) Geostatistical applications in precision agriculture.
261 Springer. New York. pp.139–165.
- 262 DI RIENZO, J.A.; CASANOVES, F.; BALZARINI, M.G.; GONZALEZ, L.; TABLADA, M.;
263 ROBLEDO, C.W. InfoStat versión 2012. Grupo InfoStat, FCA, Universidad Nacional de
264 Córdoba, Argentina. URL <http://www.infostat.com.ar>
- 265 DIGGLE, P.J.; RIBEIRO JNR, P.J. 2007. Model-based Geostatistics. Springer, New York.
266 228 p.
- 267 DRAY, S.; SAID, S.; DEBIAS, F. 2008. Spatial ordination of vegetation data using a
268 generalization of Wartenberg's multivariate spatial correlation. J. Veg. Sci. 19:45–56.

269 EASTMAN, J.R. 2009. IDRISI Taiga (Worcester, MA: Clark University).

270 FRIDGEN, J.J.; KITCHEN, N.R.; SUDDUTH, K.A.; DRUMMOND, S.T.; WIEBOLD, W.J.;

271 FRAISSE, C.W. 2004. Management Zone Analyst (MZA): Software for Subfield Management

272 Zone Delineation. *Agron. J.* 96:100–108.

273 LARK, R.M.; STAFFORD, J.V. 1997. Classification as a first step in the interpretation of

274 temporal and spatial variation of crop yield. *Ann. Appl. Biol.* 130:111–121.

275 LI, Y.; SHI, Z.; LI, F.; LI, H.Y. 2007. Delineation of site-specific management zones using

276 fuzzy clustering analysis in a coastal saline land. *Comp. Electron. Agric.* 56:174–186.

277 MORAL, F.J.; TERRÓN, J.M.; MARQUES DA SILVA, J.R. 2010. Delineation of management

278 zones using mobile measurements of soil apparent electrical conductivity and multivariate

279 geostatistical techniques. *Soil Till. Res.* 106:335–343.

280 ODEH, I.O.A.; MCBRATNEY, A.B.; CHITTLEBOROUGH, D.J. 1992. Soil pattern recognition

281 with fuzzy c-means: application to classification and soil-landform interrelationship. *Soil Sci.*

282 *Soc. Am. J.* 56:505–516.

283 ORTEGA, R.A.; SANTIBAÑEZ, O.A. 2007. Determination of management zones in corn (*Zea*

284 *mays* L.) based on soil fertility. *Comp. Electron. Agric.* 58:49–59.

285 PERALTA, N.R.; CASTRO FRANCO, M.; Costa, J.L. 2011. Relación espacial entre variables

286 de sitio y rendimiento para la delimitación de zonas de manejo mediante el uso de

287 herramientas informáticas. Congreso AgroInformática. Córdoba, Argentina.

288 R DEVELOPMENT CORE TEAM 2012. R: A language and environment for statistical

289 computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0,

290 URL <http://www.R-project.org/>.

291 RIBEIRO JNR, P.J.; DIGGLE, P.J. 2001. geoR: A package for geostatistical analysis. *R*

292 *News*, 1(2):15–18.

293 RODRÍGUEZ-PÉREZ, J.R.; PLANT, R.E.; LAMBERT, J.J.; SMART, D.R. 2011. Using

294 apparent soil electrical conductivity (ECa) to characterize vineyard soils of high clay content.

295 *Precis. Agric.* 12(6): 775–794.

296 ROEL, A.; TERRA, J. 2007. Muestreo de suelos y factores limitantes del rendimiento. En:

297 BONGIOVANNI, R. et al., (Eds.) *Agricultura de Precisión: Integrando conocimientos para*

298 *una agricultura moderna y sustentable*. PROCISUR/IICA, Montevideo. pp. 65–80.

299 SCHABENBERGER, O.; PIERCE, F.J. 2002. *Contemporary statistical models for the plant*

300 *and soil sciences*. Taylor and Francis, CRC Press, Florida 738 p.

301 XIN-ZHONG, W.; GUO-SHUN, L.; HONG-CHAO, H.; ZHEN-HAI, W.; QING-HUA, L.; XU-
302 FENG, L.; WEI-HONG, H.; YAN-TAO, L. 2009. Determination of management zones for a
303 tobacco field based on soil fertility. *Comp. Electron. Agric.* 65:168–175.