

CONTROL DE LA CORRELACION ESPACIAL EN EXPERIMENTOS DE CAMPO EN EL SECTOR AGRICOLA

Control of spatial variability in field plot experiments

Ricardo Martínez B¹

RESUMEN

El objetivo primordial de la mayoría de los experimentos agrícolas de campo es la estimación eficiente e insesgada de los contrastes entre tratamientos. La manera común de lograr esa estimación es mediante la aplicación de mínimos cuadrados ordinario a un modelo lineal, en el cual el valor esperado de cada observación es la suma de una media general, un efecto de tratamiento y varios efectos ambientales tales como bloques o efectos de filas y columnas. Si el modelo supuesto es correcto, este enfoque da lugar a estimadores que son funciones lineales de las observaciones y son insesgados. Para analizar los datos provenientes de experimentos de campo, se han propuesto otras alternativas: los métodos espaciales. Estas alternativas buscan neutralizar el efecto que pueda tener la heterogeneidad espacial de las unidades experimentales sobre la estimación de los contrastes entre tratamientos. El propósito de este artículo es analizar y comparar críticamente algunas de las metodologías espaciales usadas en los experimentos de campo del sector agrícola.

Palabras claves

Variabilidad espacial, efecto de vecinos.

SUMMARY

The primary objective of most agricultural field experiments and other spatial experiments is the unbiased and efficient estimation of treatment contrasts. The most common way to their estimation is to apply ordinary least squares to a linear model in which the expected value of each observa-

tion is taken to be the sum of an over all mean, a treatment effect, and various environmental effects such as block or row and column effects. This approach yields estimators which are linear functions of the observations and which are unbiased if the assumed model is correct. Other alternatives, the spatial methods, have been proposed for the analysis of data from field-plot experiments. These alternatives attempt to neutralize the effect that the spatial heterogeneity of the experimental units can have on the estimation of treatment contrasts. The purpose of this paper is to analyze and compare critically some of the most important approaches about «neighbour» or «spatial» methods of analysis of field experiments, where an attempt is made to estimate and remove the effects of association of neighbouring plots from the treatment contrast.

Keywords

spatial variability, neighbor effect.

INTRODUCCION

El interés de todos los investigadores que hacen experimentos espaciales en el sector agrícola es estimar eficientemente los contrastes entre los tratamientos. En esos experimentos, las unidades experimentales ocupan sitios fijos y, típicamente, presentan heterogeneidad sistemática (causada por la heterogeneidad del suelo, manejo experimental y otros factores ambientales) entre esas unidades, lo cual produce una apreciable correlación entre parcelas vecinas, hecho que puede llevar a que los supuestos que, tradicionalmente se hacen para lograr a cabo los análisis de varianza, bajo los diseños clásicos, no se cumplan a pesar de que se tengan en cuenta los principios básicos en los cuales descansan tales diseños. Esto es, se confía en que la aleatorización neutralice los efectos negativos de la correlación espacial. Además, el control local que hacen los modelos

¹ Profesor, Facultad de Agronomía, Universidad Nacional de Colombia, Santafé de Bogotá, D.C.

de bloques es de tipo discontinuo, pero en muchos ensayos de campo, las parcelas presentan un patrón continuo lo cual puede llevar a que el tamaño y la forma de los bloques sea de alguna manera, arbitrario. De esta forma, el modelo de bloques bien puede resultar artificial, aunque logre dar una aproximación razonable de la variabilidad del sitio, con la ventaja de que los estimadores de la precisión de los contrastes de los tratamientos pueden demostrar su validez bajo el principio de la aleatorización.

Bajo diferentes metodologías, se ha tratado de controlar la correlación espacial por métodos diferentes a los clásicos. Así, los procedimientos empleados por los diseños de **Vecino mas cercano (VC)** han tratado de obtener estimadores mas eficientes de los tratamientos mediante una modelación mas realistica de la variación de campo, y esta variación se considera como una gradiente continua y se supone una estructura para el error. Dentro de este enfoque se han presentado un número apreciable de modelos, tales como los construidos por Papadakis (1938), Bartlett (1978), Wilkinson et al (1983), Green, Jennison y Seheult (1985), Williams (1986a), Besag y Kempton (1986), Gleeson y Cullis (1987) y Cullis y Gleeson (1991). Estos modelos han buscado controlar la correlación espacial en forma indirecta, bien sea a través de diferencias o mediante el uso de desvíos o residuos de las parcelas vecinas como covariables.

De otra parte Zimmerman y Harville (1991), con su modelo lineal de campo aleatorio, involucran directamente la heterogeneidad espacial, a través de un análisis aleatorio de datos provenientes de ensayos de uniformidad.

Con este artículo, dada esta diversidad de propuestas, se pretende hacer un análisis crítico de comparación de las diferentes metodologías, para facilitar su uso a los investigadores que usan experimentos espaciales.

EL PROBLEMA

Cuando las variables son dependientes espacialmente, por lo general, los métodos clásicos de análisis no son válidos; por eso, cuando un experimentador trabaja con datos orientados espacialmente, se enfrenta a dos preguntas:

- ¿Son los datos espacialmente dependientes?

- Si es así, los análisis de varianza y regresión no son apropiados; entonces, ¿qué hacer?

Los datos son espacialmente dependientes cuando la observación de una unidad vecina da alguna información sobre la observación de una unidad experimental, tal como su valor o magnitud. Dado que una parcela vecina puede estar cerca o relativamente lejos de una determinada unidad experimental, las observaciones tomadas en condiciones similares bien pueden ser espacialmente dependientes o independientes de acuerdo con la distancia que exista entre las observaciones vecinas.

METODOS DE CONTROL DE LA CORRELACION ESPACIAL

Cuando la correlación espacial se encuentra presente, bien sea a escala micro o macro es necesario controlarla mediante:

- Ajuste del diseño experimental,
- Diseños de vecino mas cercano,
- Diseños de Williams,
- Método de Gleeson y Cullis (una dimensión),
- Método de Cullis y Gleeson (dos dimensiones), o
- Métodos de Zimmerman y Harville.

El problema de la escogencia de la metodología a usar es mayor cuando la correlación espacial no es detectable aparentemente, situación que se presenta con mayor frecuencia.

Primeras propuestas de control de la correlación espacial.

Aunque originalmente se pretendía corregir el problema generado por la correlación mediante el principio de **aleatorización** en los diseños de experimentos clásicos propuesto por Fisher y Yates, varios autores encontraron que la protección que daba ese principio no era suficiente y que era mas limitado de lo que originalmente se creía. Además, consideraban que el supuesto de igualdad de los errores para muchos diseños ortogonales o balanceados clásicos bien podía ser una ilusión matemática. Entonces aparecen las primeras propuestas para subsanar las deficiencias presentadas por las metodologías tradicionales. Con Papadakis (1937) se inicia la metodología que propone **ajustes** mediante el

VECINO MAS CERCANO (VC) usando parcelas tratadas. Papadakis usa como covariable los desvíos de las parcelas vecinas con relación a la media de sus respectivos tratamientos; este método es relativamente válido pero no muy eficiente. Seguidamente, Bartlett (1978) reexaminó las propiedades teóricas del modelo de Papadakis, en términos de modelos de vecino mas cercano de la forma autoregresiva simétrica y entonces, sugiere el uso de un proceso iterativo en la aplicación del método de Papadakis, esto es, utilizar la covariable propuesta por este autor, pero corrigiendo las medias de los tratamientos y generar una covariable nueva representada por los desvíos de las parcelas vecinas con respecto a las medias corregidas de los tratamientos. Este proceso se repite iterativamente hasta que no haya diferencias apreciables entre los sucesivos ajustes. Este método resultó mas eficiente, pero presentaba un sesgo positivo en el valor de F del análisis correspondiente, era menos válido y no era robusto.

A continuación, aparece el trabajo de Wilkinson et al (1983) con el **Análisis del Vecino más cercano** en experimentos de campo. Se basa en un modelo de tendencia suave con error independiente aplicable en varias áreas, especialmente en los ensayos varietales usados en fitomejoramiento. Su mayor ventaja consistía en la flexibilidad en el diseño bajo un número grande de tratamientos, pero, no presentan una forma satisfactoria de estimar la estructura de correlación en presencia de los efectos de los tratamientos. De otra parte la validez y la robustez de la metodología necesitaba mucha mas investigación y elaboración. El método proporciona una forma continua de control local para el control de las gradientes.

Las propuestas posteriores, especialmente las de Williams (1986a) y Besag y Kempton (1986), de alguna manera se parecen al trabajo de Wilkinson et al, en el sentido de que casi todos usan alguna forma de diferenciación de las parcelas vecinas para eliminar las gradientes supuestas en el terreno experimental, además casi todas se basan en modelos de gradiente y error independiente o variables dentro del error. Las mayores diferencias entre estas diferentes metodologías estaban en las técnicas de estimación, en especial en la varianza de los parámetros. Este hecho generó mucho desacuerdo y ambigüedad, a pesar de ser

modelos válidos para un rango amplio de respuestas de rendimiento y de ser mas eficientes que los modelos clásicos.

Modelos más recientes

En 1987, Gleeson y Cullis consideran que el error de los datos de los experimentos de campo pueden tratarse como un proceso **ARIMA (p,d,q)**, o sea, como un promedio móvil integrado autoregresivo con el cual se obtienen estimadores mas exactos de los tratamientos que los diseños de bloques incompletos aleatorizados y permiten diagnosticar los datos dependientes cuando se trabaja con una dimensión y con parcelas y áreas experimentales rectangulares. Sin embargo, cuando las parcelas y áreas experimentadas eran cuadrados o cuando se presentaban gradientes bajo dos dimensiones este modelo no era eficiente, por esta razón, Cullis y Gleeson (1991) extienden el modelo a dos dimensiones, usando como técnica de estimación la misma usada para una dimensión, es decir, la técnica de máxima verosimilitud restringida (REML) y derivan chequeos de diagnóstico para probar lo adecuado de los modelos. Con 24 ensayos de uniformidad ilustran la necesidad de los modelos de dos dimensiones, a pesar de que las unidades experimentales fueran muy rectangulares y, en comparación con los análisis de filas mas columnas, encuentran una ganancia potencial apreciable. Encontraron que la mayoría de los datos de esos ensayos se ajustaban a la subclase de modelos ARIMA (p_1, d_1, q_1) X ARIMA (p_2, d_2, q_2) con $p_1=p_2=0$ y $q_1=q_2=0,1$ y $d_1=d_2=0,1$.

Casi simultáneamente Zimmerman y Harville (1991) elaboran su **Modelo Lineal de Campo Aleatorio (MLCA)**, donde tienen en cuenta en forma directa la heterogeneidad espacial. La metodología es similar al análisis Kriging usado en geostatística para hacer predicciones espaciales; consideran las observaciones como el resultado parcial de un campo aleatorio. En el MLCA la heterogeneidad espacial se visualiza así, la de gran escala (las gradientes) se modela mediante una estructura de medias y la de pequeña escala mediante una estructura de correlación. Basados en un análisis aleatorio de datos provenientes de ensayos de uniformidad, encontraron que: su MLCA proporciona estimadores mas exactos para los contrastes entre tratamientos que los métodos de vecino mas cercano (VC); que el método de

Papadakis 2 es bastante bueno; que su metodología es bastante flexible y que puede usarse para diferentes dimensiones en conjunción con cualquier sistema de bloqueo sin importar el tamaño y forma de parcela.

En la Facultad de Agronomía de Bogotá de la Universidad Nacional de Colombia, Martínez (1992), está trabajando en la comparación de diferentes metodologías, con especial atención al uso de variables regionalizadas (análisis Kriging), el método Papadakis 2 y el modelo lineal de campo aleatorio. A continuación se presentan algunos resultados de ensayos realizados en Colombia en cultivos de arroz y flores.

Variabes Regionalizadas

Los investigadores pueden trabajar con variables espacialmente dependientes mediante la teoría de las variables regionalizadas, cuya rama más importante es el **análisis Kriging**. Este método es excelente para analizar datos con correlación espacial porque: 1) Es un método no sesgado; 2) Proporciona un estimativo de la varianza del valor interpolado y esa varianza es mínima comparada con todos los posibles métodos de estimación no sesgados.

Cuando una variable se distribuye en el espacio se dice que está regionalizada. Ejemplos típicos de esas variables son: la producción de un cultivo, la distribución de un elemento en el suelo, el precio de los cerdos en el mercado, etc. Una variable regionalizada es una función $f(x)$ que toma un valor en cada punto (sitio) x_i con las coordenadas X_u, X_v, X_w en un espacio tridimensional; X_u representa la posición del punto en la primera dimensión, X_v la posición en la segunda dimensión y X_w la posición en la tercera dimensión. Para ilustrar, consideremos muestras de suelos tomadas en un campo para determinar la distribución de calcio. La localización de la muestra puede describirse así: X_u localización en el sentido norte-sur, X_v localización en la dirección este-oeste y X_w profundidad. La localización del calcio para este ejemplo se considera como una variable regionalizada tridimensional. El punto (X_u, X_v, X_w) se denota mediante x_i donde i va de 1 a n , o sea el número de puntos u observaciones tomados. La variable regionalizada, que con frecuencia es muy irregular, posee dos características: una característica de tipo local que es aleatoria y una característica estructural general. Para tener en cuenta ambas

características se usan funciones aleatorias. Entonces, $Z(x)$ es un conjunto de variables aleatorias y $Z(x_i)$ definida en cada punto del conjunto D.

$$Z(x) = \{ Z(x_i) \text{ para todo } x_i \in D \}$$

donde:

- Los $Z(x_i)$ están correlacionados
- La correlación entre los $Z(x_i)$ depende de h (módulo o distancia y dirección absolutas) separando x_i y x_i+h .

La primera etapa para la obtención de los estimativos Kriged de las localidades consiste en calcular un **semivariograma**.

Ahora bien, para evaluar cuantitativamente la dependencia espacial de un proceso bajo estudio debe definirse una relación funcional entre el patrón espacial de los puntos muestreados y sus valores observados.

La función del variograma se define como la varianza del incremento $[Z(x_i) - Z(x_j)]$ y se designa mediante:

$$2\Gamma(x_i, x_j) = V[Z(x_i) - Z(x_j)] \quad [1]$$

Una estacionalidad de segundo orden implica que el variograma es:

$$2\Gamma(h) = E\{(x+h) - Z(x)\}^2 \quad [2]$$

$$2\Gamma(h) = V[Z(x+h) - Z(x)]^2$$

Se usa la mitad del variograma, el cual se define como $\Gamma(h)$ y se llama semivariograma. El semivariograma permite una interpretación fácil de la variabilidad espacial.

COMPARACION DE ALGUNAS METODOLOGIAS USADAS PARA CONTROLAR LA CORRELACION ESPACIAL.

Para comparar los diferentes enfoques usados en el análisis de datos con variación espacial, se presenta a continuación la información obtenida de algunos experimentos llevados a cabo en Colombia, Martínez (1992) (Cuadro 1).

El experimento involucró 16 tratamientos y 64 unidades experimentales, distribuidos en una red 8x8. Cada uno de los 4 cuadrados tuvo una replicación completa. Cada replicación se distribuyó bajo un diseño látice 4x4. Así, el

experimento se pudo analizar como un diseño de bloques completos aleatorizados o como un diseño de bloques incompletos aleatorizados (látice).

El análisis de los residuos mostró una fuerte evidencia de variabilidad espacial. Los datos se volvieron a analizar mediante el ajuste hecho con una estructura de vecino mas cercano (AVC), con las covariables tanto EO como NS. También se usó el método de Mínimos Cuadrados Generalizados (MCG) con estimadores de los parámetros de Máxima Verosimilitud Restringida (MVRE) para un modelo de varianza-covarianza esférico. Los resultados sobresalientes se dan en los Cuadros 2 y 3.

Cuadro 1. Datos usados para comparar los análisis de bloques completos aleatorizados, bloques incompletos (látice), Ajuste de Vecino mas Cercano (AVC) y Mínimos Cuadrados Generalizados (MCG) esféricos. REP indica bloques completos, INC-BLK indica bloques incompletos (látice), FILA y COL identifican la posición espacial de la observación, TRT corresponde a tratamiento y Y es la respuesta.

OBS	REP	INC-BLK	FILA	COL	TRT	Y
1	1	1	1	1	1	15,03
2	1	1	1	2	2	12,99
3	1	1	1	3	3	12,90
4	1	1	1	4	4	12,83
5	1	3	2	1	5	14,44
6	1	3	2	2	6	13,96
7	1	3	2	3	7	10,03
8	1	3	2	4	8	7,72
9	1	5	3	1	9	13,37
10	1	5	3	2	10	13,40
11	1	5	3	3	11	8,27
12	1	5	3	4	12	6,15
13	1	7	4	1	13	10,05
14	1	7	4	2	14	11,88
15	1	7	4	3	15	7,84
16	1	7	4	4	16	6,53
17	2	9	5	1	1	15,50
18	2	9	5	2	5	14,48
19	2	9	5	3	9	12,28
20	2	9	5	4	13	9,79
21	2	11	6	1	2	15,30
22	2	11	6	2	6	14,52

Cuadro 1. (Continuación)

OBS	REP	INC-BLK	FILA	COL	TRT	Y
23	2	11	6	3	10	12,75
24	2	11	6	4	14	10,74
25	2	13	7	1	13	13,71
26	2	13	7	2	7	14,12
27	2	13	7	3	11	11,46
28	2	13	7	4	15	6,91
29	2	15	8	1	4	12,43
30	2	15	8	2	8	12,75
31	2	15	8	3	12	11,29
32	2	15	8	4	16	6,01
33	3	2	1	5	1	13,05
34	3	2	1	6	6	8,74
35	3	2	1	7	11	6,13
36	3	2	1	8	16	3,52
37	3	4	2	5	5	8,44
38	3	4	2	6	2	11,24
39	3	4	2	7	15	6,62
40	3	4	2	8	12	9,58
41	3	6	3	5	9	7,79
42	3	6	3	6	14	9,70
43	3	6	3	7	3	15,72
44	3	6	3	8	8	10,42
45	3	8	4	5	13	8,76
46	3	8	4	6	10	13,88
47	3	8	4	7	7	13,02
48	3	8	4	8	4	11,22
49	4	10	5	5	1	15,28
50	4	10	5	6	14	10,04
51	4	10	5	7	7	9,15
52	4	10	5	8	12	7,03
53	4	12	6	5	13	10,05
54	4	12	6	6	2	12,94
55	4	12	6	7	11	7,56
56	4	12	6	8	8	8,83
57	4	14	7	5	5	10,86
58	4	14	7	6	10	10,15
59	4	14	7	7	3	11,92
60	4	14	7	8	16	7,91
61	4	16	8	5	9	8,99
62	4	16	8	6	6	12,91
63	4	16	8	7	15	8,21
64	4	16	8	8	4	13,34

Al comparar los diferentes análisis, vale la pena resaltar algunos hechos:

1. Debido a la variabilidad espacial varias medias de tratamientos para el diseño BCA, no se estiman exactamente. Por ejemplo, los tratamientos 1, 3, 10 y 14 tienen medias irrealmente altas, mientras los tratamientos 11 y 16 se subestiman. Ni el látice, ni el ajuste llevado a cabo por el vecino mas cercano son efectivos para controlar estos problemas. Por ejemplo, AVC corrige la sobreestimación del tratamiento 2, 3 y algo la del 10 pero nada hace para corregir el problema de los tratamientos 1 y 14 (Cuadro 2).

Cuadro 2. Comparación de los promedios estimados mediante cuatro métodos.

Parámetro: Medias	Método			
	BCA ¹⁾	BIA	AVC	MCG
Tratamiento 1	14,72	15,02	15,21	14,38
Tratamiento 2	13,12	13,20	13,62	13,54
Tratamiento 3	13,56	13,53	12,90	12,94
Tratamiento 4	12,45	12,23	11,40	12,14
Tratamiento 5	12,05	12,17	12,68	12,06
Tratamiento 6	12,53	12,71	12,87	12,64
Tratamiento 7	11,58	11,51	11,51	11,16
Tratamiento 8	9,93	9,83	9,96	10,06
Tratamiento 9	10,61	10,42	10,20	10,56
Tratamiento 10	12,55	12,44	12,35	11,61
Tratamiento 11	8,36	8,54	9,28	9,29
Tratamiento 12	8,51	8,59	8,60	9,39
Tratamiento 13	9,66	9,44	9,29	8,90
Tratamiento 14	10,59	10,52	10,68	9,74
Tratamiento 15	7,40	7,29	6,83	7,22
Tratamiento 16	5,99	6,17	6,22	6,66

1]

BCA: Bloques Completos Aleatorizados
 BIA: Bloques Incompletos Aleatorizados
 AVC: Ajuste mediante Vecino mas Cercano
 MCG: Mínimos Cuadrados Generalizados

El látice comparado con BCA no mejora para nada la situación. De otro lado, el análisis de MCG esférico sí corrige significativamente el problema de la sub y sobre estimación.

2. Otro punto de interés tiene que ver con los errores estándar de las diferencias entre

tratamientos [e.s.(dif)]. En el Cuadro 3, se puede observar que esos errores son considerablemente mas bajos cuando se usa el método MCG que cuando se utilizan los otros métodos. Adicionalmente, los tratamientos 1 y 2 presentaron respuestas mas cercanas que lo que lo hicieron el 1 y el 4 bajo esta metodología particular. Ahora bien, en presencia de variabilidad espacial se esperaría una mejor estimación entre la diferencia de los tratamientos 1 y 2 que entre 1 y 4. Obsérvese que el error estándar de la diferencia del método MCG refleja con mucha exactitud ese hecho, tal como se puede observar en el Cuadro 3. El e.s.(dif) para el AVC, también es diferente, pero solo en grado pequeño. En cambio, los análisis bajo los diseños BCA y BIA no presentan estas diferencias.

Cuadro 3. Comparación entre las diferencia de medias y la varianza de los estimadores de los parámetros para los diferentes análisis.

Parámetro:	Método			
	BCA	BIA	AVC	MCG
Diferencias de Tratamientos				
Trt. 1 - Trt. 2	1,60	1,82	1,59	0,84
Trt. 1 - Trt. 4	2,26	2,79	3,81	2,24
Error estándar de la diferencia				
Trt. 1 - Trt. 2	1,20	1,28	1,07	0,61
Trt. 1 - Trt. 4	1,20	1,28	1,11	0,89
Parámetros de Varianza-covarianza				
Rango	n.a ¹⁾	n.a ¹⁾	n.a ¹⁾	n.a ¹⁾
$\hat{\sigma}^2_{\text{bloque}}$	0,80	0,67	n.a ¹⁾	n.a ¹⁾
$\hat{\sigma}^2_{\text{error}}$	2,89	2,98	2,24	2,81

¹⁾ n.a: No se puede aplicar.

3. Un tercer punto tiene que ver con los parámetros estimados para varianza y covarianza. Los análisis bajo BCA y BIA involucran la estimación de la varianza de bloques y del error ($\hat{\sigma}^2_{\text{bloque}}$ y $\hat{\sigma}^2_{\text{error}}$, respectivamente). Estas componentes de varianza no tienen mucho sentido dado que el bloqueo realizado para los datos no se basó en un criterio de variación claramente definido, sino, solo esperando que subgrupos mas

pequeños de unidades experimentales presentasen mayor homogeneidad que grupos mas grandes. En efecto, el valor pequeño de σ^2_{bloque} para los dos análisis (BCA y BIA) indica que el bloqueo no fue efectivo para controlar la variación. De otra parte, los parámetros estimados bajo el análisis MCG conllevan un significado muy identificable en el contexto del problema: el rango es 3,05 -o sea, unidades experimentales dentro de una distancia de 3 presentan respuestas correlacionadas y, a distancias mayores, se comportan independientemente- además la varianza es de 2,81.

Por último, el procedimiento MCG converge bastante rápido a la solución. Acá, tomó cinco iteraciones. Al usar procesos de simulación con el modelo esférico, con 10 iteraciones la convergencia se presentó en el 75% del tiempo y con 20 iteraciones en el 95%. Con 50 iteraciones ningún conjunto de datos dejó de converger. El proceso se implementó en un computador Mainframe via SAS-IML y en un PC con GAUSS (Aptech Systems, 1988).

LITERATURA CITADA

1. Aptech Systems. 1988. GAUSS Version 2.0 System and Graphics Manual, Aptech Systems, INC, Kent, WA.
2. Bartlett. M. S. J. 1938. Agric. Sci. 38, 418-427.
3. _____. 1978. J. Royal Statistical Society, B. 40, 147-174.
4. Besag, J. y Kempton, R. 1986. Statistical analysis of field experiments using neighbouring plots. Biometrics 42, 231-251.
5. Box, G. E. P. y Pierce, D. A. 1970. Distribution of residual autocorrelations in autoregressive integrated moving average time series models. Journal of American Statistical Association 65, 1509-1524.
6. Cullis, B. R. y Gleeson, A. C. 1989. The efficiency of neighbour analysis for replicated variety trials in Australia. Journal of Agricultural Science, Cambridge 113, 233-239.
7. _____. 1991. Spatial analysis of field experiments - An extension to two dimensions. Biometrics 47, 1449-1460.
8. Gleeson, A. C. y Cullis, B. R. 1987. Residual maximum likelihood (REML) estimation of a neighbour model for field experiments. Biometrics 43, 277-288.
9. Harville, D. A. 1977. J. of the Amer. Stat. Assoc. 72, 320-338.
10. Kempton, R. A. 1985. Comparison of nearest neighbour and classical methods of analysis. Biometric Society Workshop on Spatial Methods in Field Experiments, R. A. Kempton (ed.), 51-52. Durham: University of Durham.
11. Kempton, R. A. y Howes, C. W. 1991. The use of neighbouring plot values in the analysis of variety trials. Applied Statistics 30, 59-70.
12. Matheron, G. 1962-1963. Traité de Géostatistique Appliquée, Vols 1 y 2, Technip, París.
13. _____. 1965. Les Variables Régionalisées et leur Estimation. Masson, Paris.
14. Martínez, R. 1993. Control de la Correlación Espacial en Diseños de Experimentos. En Simposio de Estadística-Universidad Nacional de Colombia.
15. Papadakis, J. S. 1937. Bull. Inst. Amél. Plantes à Salonique, No. 23.
16. Williams, E. R. y Lockett, D. J. 1988. The use of uniformity data in the design and analysis of cotton and barley variety trials. Australian Journal of Agricultural Research 39, 339-350.
17. Zimmerman, D. L. y Harville, D. A. 1991. A random field approach to the analysis of field-plot experiments and other spatial experiments. Biometrics 47, 223-240.