

Diseños experimentales a escala de lote para detectar variabilidad espacial de la respuesta de cultivos a la aplicación de insumos

Carlos Agustín Alesso^{1*}, Patricia Melina Acetta², Nicolás Federico Martín³, y
Pablo Ariel Cipriotti⁴

¹ ICiAgro Litoral, UNL, CONICET, Fac. de Ciencias Agrarias, Kreder 2805, S3080HOF
Esperanza (Argentina)
calesso@fca.unl.edu.ar

² Facultad de Ciencias Agrarias, UNL, Kreder 2805, S3080HOF, Esperanza (Argentina)
pacetta@fca.unl.edu.ar

³ Dept. of Crop Sciences, University of Illinois, 1102 S Goodwin Ave, 61801 Urbana (USA)
nfmartin@illinois.edu

⁴ IFEVA, UBA, CONICET, Facultad de Agronomía, Av. San Martín 4453, (C1417DSE)
Ciudad de Buenos Aires (Argentina)
cipriott@agro.uba.ar

* Autor de correspondencia

Resumen. La agricultura de precisión supone la existencia de variabilidad espacial de la respuesta de los cultivos a la aplicación de insumos. Los experimentos a escala de lote permiten explorar dicha variabilidad. No obstante, la interacción entre la variabilidad espacial de los factores que controlan la respuesta del cultivo y el diseño experimental aplicado condicionan los resultados. Es necesario identificar diseños experimentales que optimicen la obtención de información fiable de la respuesta de los cultivos. Se evaluaron diseños experimentales a escala de lote con distinta resolución espacial para estimar la variabilidad espacial de la respuesta de un cultivo a la aplicación de insumos. Se simuló patrones espaciales de respuesta como proceso subyacente para generar mapas de rendimiento. Mediante regresión geográficamente ponderada (GWR) se estimaron los patrones de respuesta del cultivo que se compararon con el campo estocástico subyacente. Los resultados indican que los diseños con alta resolución espacial permiten capturar mejor los patrones de variabilidad espacial en un amplio rango de estructuras espaciales consideradas. A su vez, diseños en parcelas tipo tablero de ajedrez superan a los diseños en franjas ya que permiten detectar variabilidad espacial en ambas direcciones. Los resultados son sensibles a la parametrización de GWR, *kernel* y ancho de banda.

Palabras clave: simulación estadística, no estacionariedad, manejo sitio-específico

1 Introducción

El objetivo de la experimentación agrícola en campos de productores es incrementar el conocimiento sobre la respuesta de los sistemas agrícolas a alternativas de manejo para tomar mejores decisiones tendientes a incrementar la productividad, eficiencia, y sustentabilidad en un contexto de variabilidad debida al suelo y el clima [1]. El diseño experimental juega un rol clave para obtener información confiable [2].

Durante la última década, las tecnologías de agricultura de precisión (AP) han ayudado a los productores y asesores a conducir experimentos a escala de lote con mínimo esfuerzo para comparar diferentes prácticas agronómicas o ajustar manejos [3]. A su vez, la estructura de los datos recolectados por la maquinaria ha desafiado la aplicación de los métodos estadísticos clásicos desarrollados para experimentos en micro parcelas requiriendo nuevos enfoques [4, 5]. En un estudio de simulación de experimentos a escala de lote, Alesso et al. [6] han demostrado que, si no es efectivamente modelada, la autocorrelación espacial puede reducir la eficiencia de la estimación de efectos de tratamiento e incrementar las tasas de error tipo I o falsos positivos. Entre los diseños experimentales evaluados, aquellos con unidades experimentales pequeñas y mayor número de réplicas tuvieron mejor desempeño.

El enfoque de manejo por zonas (MZ), una de las formas de AP, ha sido ampliamente adoptado para gestionar la variabilidad intra-lote [7]. Según este enfoque, el lote se clasifica en zonas con características similares dentro de las cuales se asume homogeneidad en la respuesta de los cultivos a la aplicación de insumos. Así, mediante experimentos combinados con MZ permiten cuantificar la respuesta por zona.

El aumento de la resolución espacial a la cual los insumos pueden ser controlados hace que los productores y asesores quieran cuantificar la respuesta sitio-específica en vez de información a nivel de lote o por zonas [8–10]. Se han propuesto diversas alternativas de diseños experimentales, sistemáticos o aleatorizados, y métodos analíticos. Entre los diseños más comunes se encuentran diseños en franjas [11, 12], tableros de ajedrez [13] o lote entero [14]. La variabilidad del lote se divide en unidades de manejo compatibles con la resolución espacial de la maquinaria y se estima la respuesta a dicha escala. Dado que solamente la respuesta a un tratamiento puede ser observada a la vez en la misma unidad de manejo, los efectos de los tratamientos restantes deben ser estimados mediante interpolación geoestadística [3, 15, 16] o por unidades o bloques que contengan una réplica del experimento [11, 12]. Estas metodologías representan una ganancia en la resolución espacial comparadas con el enfoque de MZ.

Trevisan et al. [17] han mostrado el potencial de la aplicación de la técnica de regresión geográficamente ponderada (GWR) en experimentos a escala de lote para desarrollar mapas de prescripción basados en información sitio-específica en lugar de sub-áreas o MZ. Esta técnica permite estimar funciones de respuesta donde los parámetros de los modelos varían en el espacio, y pueden ser mapeados e interpretados como una variable espacial [18]. Este método, desarrollado para procesos no estacionarios, aplica una estimación de mínimos cuadrados ponderados a submuestras vecinas donde los pesos se estiman a través de un núcleo de decaimiento de distancia den-

tro de un ancho de banda. Este método se ha aplicado para hacer inferencias espaciales en varios campos más allá de la geografía [19]. Dado que la inferencia sobre los coeficientes locales es sensible a la selección del ancho de banda y las funciones del núcleo o *kernel*, lo que puede resultar en la detección de relaciones engañosas [19, 20] se informaron varios métodos para calibrar estos aspectos [21].

Un aspecto de importancia en la aplicación de GWR al análisis de experimentos a escala de lote es el efecto de los diseños experimentales y la estructura espacial subyacente en la capacidad de este modelo para aproximar el verdadero patrón espacial de las respuestas de los cultivos. En un trabajo reciente, Alesso et al. [2] han explorado estos efectos considerando diseños en tablero de ajedrez con distinta resolución y aleatorización para estimar curvas de respuesta. El objetivo de este trabajo fue evaluar el efecto de diseños experimentales, la estructura espacial subyacente del efecto de tratamiento, y parámetros sensibles del modelo GWR, sobre la estimación de la variabilidad espacial del efecto de tratamiento en experimentos a escala de lote.

2 Materiales y Métodos

2.1 Experimento hipotético

Se realizó un estudio de simulación para evaluar el efecto de los diseños experimentales en la capacidad de los experimentos a escala de lote para capturar la variabilidad espacial del efecto de tratamiento bajo diferentes escenarios de variabilidad espacial. El experimento hipotético tenía como objetivo estimar la respuesta del cultivo de maíz a la aplicación de una dosis de suficiencia de fertilizante fosfatado. Se consideró un área experimental de 432 m de ancho por 864 m de largo (37 ha). Se asumió que las siguientes configuraciones de maquinaria estaban disponibles para realizar el experimento y recolectar los datos: (1) un tractor con guía automática; (2) sembradora con tecnología de dosificación variable (VRT); y (3) cosechadora equipada con monitor de rendimiento y guía automática. Según las especificaciones de ancho de trabajo de la cosechadora y sembradora, el ancho mínimo de las unidades experimentales fue igual a 9 m. La dimensión del campo era aproximadamente equivalente a 48 y 96 veces el ancho de la cabecera, respectivamente. Se simularon un total de 4608 puntos de datos para cada combinación de escenario espacial y diseño experimental descrito en la siguiente sección. La extensión del campo experimental es comparable a de campos comerciales de la región pampeana, y permite una representación realista de diferentes patrones espaciales y asignación de tamaños de unidades experimentales mientras se mantiene bajo el tiempo computacional. En escenarios reales, se esperarían resoluciones más gruesas debido a huellas de maquinaria más anchas (ancho de cabezal o sembradora) y al proceso de suavizado a lo largo de la dirección de la cosecha [22].

2.2 Diseños experimentales

Los tratamientos simulados consistieron en una aplicación de fósforo a la siembra en dosis recomendada según requerimientos del cultivo y disponibilidad del suelo, y un control sin aplicar. Los tratamientos fueron aplicados simulando una dirección de

siembra sur-norte, con una resolución perpendicular a la dirección de siembra entre 9 y 36 m, lo que equivale a 1 y 4 anchos de cabezal de la cosechadora. La resolución a lo largo de la dirección de siembra fue de entre 36 y 864 m. La longitud mínima fue definida para permitir tiempo suficiente (aproximadamente 18 s) a los actuadores para cambiar la dosis de fertilizante en la marcha y los retrasos del sistema de trilla de granos y monitor de rendimiento. La resolución máxima se incluyó para representar diseños en franjas. Como resultado, los tamaños de unidad experimental más pequeños y más grandes fueron de alrededor de 324 a 31104 m². En la siguiente tabla se detallan los diseños evaluados y se visualizan ejemplos en la Fig. 1B.

Tabla 1. Características de los diseños evaluados.

Código	Ancho (m)	Largo (m)	Réplicas	Área (m ²)
W1L4	9	36	1152	324
W1L8	9	72	576	648
W1L16	9	144	288	1296
W1L24	9	216	192	1944
W1L48	9	432	96	3888
W1L96	9	864	48	7776
W2L4	18	36	576	648
W2L8	18	72	288	1296
W2L16	18	144	144	2592
W2L24	18	216	96	3888
W2L48	18	432	48	7776
W2L96	18	864	24	15552
W4L4	36	36	288	1296
W4L8	36	72	144	2592
W4L16	36	144	72	5184
W4L24	36	216	48	7776
W4L48	36	432	24	15552
W4L96	36	864	12	31104

2.3 Simulación de rendimientos

La respuesta al tratamiento, i.e. aplicación de fósforo, se simuló asumiendo el siguiente modelo lineal con coeficientes variables en el espacio:

$$y_i(s_i) = \beta_0(s_i) + \beta_1(s_i)x_i + \varepsilon_i \quad (1)$$

donde: $y_i(s_i)$ es el valor de rendimiento en el sitio $s_i = (u_i, v_i)$ definido por las coordenadas u_i y v_i ; $\beta_0(s_i)$ y $\beta_1(s_i)$ son los coeficientes de regresión, siendo $\beta_0(s_i)$ el rendimiento del tratamiento control y $\beta_1(s_i)$ es el efecto del tratamiento, i.e. diferencia entre tratado y control, para el mismo sitio s_i ; x_i es una variable dicotómica, siendo 1

para tratamiento y 0 para control; y ε_i el error que se asume independiente y con distribución normal con media igual a 0 y varianza constante $N(0, \sigma_\varepsilon^2)$.

En primer lugar, la distribución espacial de cada coeficiente $\beta_j(s_i)$ de la Eq (1) fue simulada de manera independiente mediante simulación geoestadística Gaussiana no condicionada [23]. Se simularon escenarios de variabilidad espacial asumiendo un proceso estacionario de primer orden con el siguiente modelo lineal:

$$\beta_j(s_i) = \mu_j + \varepsilon_i(s_i) \quad (2)$$

donde: $\beta_j(s_i)$ es el verdadero valor del coeficiente de regresión j en la posición $s_i = (u_i, v_i)$; μ_j es la media general del coeficiente de regresión sobre el área experimental, y $\varepsilon_i(s_i)$ es el error aleatorio con distribución normal con esperanza igual a 0 y matriz de varianza-covarianza espacial en función de las distancias de separación entre ubicaciones $N(0, \Sigma(h))$. Se asumió un modelo de autocorrelación esférico e isotrópico sin efecto pepita y rangos de 0, 200, y 400 m (Eq. 2). Para el escenario con rango = 0 (sin autocorrelación espacial) la matriz de varianza-covarianza se simplifica a $\Sigma(h) = \mathbf{I} \sigma_\varepsilon^2 = \sigma_\varepsilon^2$. Junto con el exponencial, el modelo esférico es uno de los modelos más utilizados en la bibliografía para representar variables de suelo y cultivo [23].

$$C(h) = \begin{cases} \sigma_{sill}^2 \left(\frac{3h}{2a} + \frac{h^3}{2a^3} \right) & 0 \leq h \leq a \\ 0 & h > a \end{cases} \quad (3)$$

donde: $C(h)$ es la función de covarianza espacial entre pares distanciados por h unidades; a es el rango de dependencia espacial en m; σ_{sill}^2 es la varianza total de proceso, la cual se asumió a partir de un coeficiente de variación de 30% alrededor del rendimiento medio del control $\beta_0(s_i)$ 9 Mg/ha y el efecto medio del tratamiento $\beta_1(s_i)$ 1,3 Mg/ha. Por lo tanto los valores de varianza total fueron 7,29 (Mg/ha)² y 0,1521 (Mg/ha)² respectivamente. Para cada escenario se tomó al azar una realización de ambos campos aleatorios de manera independiente las cuales se asumieron como los verdaderos mapas de coeficientes del modelo espacial (Fig. 1A). La correlación entre los mapas de coeficientes fueron despreciables (correlación de Pearson entre -0,3 y 0,12). La combinación de estos mapas de coeficientes permitió representar un amplio rango de respuestas, desde situaciones con bajos rendimientos sin fósforo y no respuesta, lo que ocurre cuando el factor limitante no es el tratamiento, o altos rendimientos sin fósforo y alta respuesta, cuando el sitio tiene alto potencial de respuesta.

Los escenarios de variabilidad espacial incluidos en este estudio tienen como objetivo cubrir un amplio rango de patrones de respuesta observables en el campo, desde patrones aleatorios (rango = 0) hasta bien estructurados (rango = 400) con patrones de variación suavizados. En el primer caso, la falta de estructura espacial de los coeficientes representa una situación donde no es necesario aplicar el procedimiento GWR. En cambio, en escenarios con buena estructura espacial de los coeficientes, la posibili-

dad de utilizar modelos lineales con coeficientes variables en el espacio permitirá estimar la respuesta local a los tratamientos.

Finalmente, para cada combinación de escenario de variabilidad y diseño experimental se simularon 30 mapas de rendimiento de maíz sobre una grilla de 4608 puntos combinando la información de los coeficientes $\beta_j(s_i)$, el tratamiento asignado y un error residual con media 0 y varianza constante alrededor de 30% según el modelo de la Eq. 1 (Fig. 1C). En total, 1620 mapas de rendimiento fueron simulados.

2.4 Análisis de datos

Cada mapa de rendimiento simulado conteniendo 4,608 celdas (cada celda de 81 m²) fue analizado ajustando un modelo GWR (Fotheringham et al., 2002) de la Eq. 1 (Fig. 2). Los coeficientes de regresión en cada ubicación fueron estimados usando mínimos cuadrados ponderados basado en la información de observaciones cercanas:

$$\hat{\beta}_i(s_i) = (\mathbf{X}' \mathbf{W}(s_i) \mathbf{X})^{-1} \mathbf{W}(s_i) \mathbf{y} \quad (3)$$

donde $\mathbf{y}$ el vector conteniendo los rendimientos, $\mathbf{X}$ la matriz de predictores compuesta por una columna representando a la ordenada al origen y una la variable indicadora del efecto $\beta_1(s_i)$; $\hat{\beta}_j(s_i)$ el vector de estimadores $\beta_j(s_i)$ en la ubicación $s_i = (u_i, v_i)$, y $\mathbf{W}(s_i)$ es una matriz diagonal $n \times n$ con los pesos de cada observación en relación al punto s_i en la diagonal. Se probaron dos funciones de densidad con ancho de banda adaptativo: exponencial (Eq. 4) y *bisquare* (Eq. 5):

$$w(s_i, s_j) = \exp\left(\frac{-d(s_i, s_j)}{b(s_i)^{ad}}\right) \quad (4)$$

$$w(s_i, s_j) = \exp\left[1 - \left(\frac{d(s_i, s_j)}{b(s_i)^{ad}}\right)^2\right] \text{ si } d(s_i, s_j) < b(s_i) \text{ y } 0 \text{ caso contrario} \quad (5)$$

donde $w(s_i, s_j)$ es el peso de los datos de la ubicación s_i en relación a la ubicación s_j , $d(s_i, s_j)$ es la distancia euclidiana entre ambas ubicaciones; y $b(s_i)^{ad}$ es el ancho de banda para el sitio s_i . Debido al impacto del número de vecinos en la estimación de los coeficientes, se evaluaron dos tamaños de vecindario: 3 y 5% del total de observaciones, i.e., 138 y 230 vecinos. Dada las dimensiones de las parcelas y la resolución de la grilla estas cantidades de vecinos permitieron representar a los dos tratamientos en un radio de búsqueda para cada punto objetivo. Como resultado, 6840 modelos GWR fueron estimados.




Fig. 1. Esquema de las etapas del experimento de simulación. (A) generación de escenarios de variabilidad espacial de los coeficientes $\beta_j(s_i)$ del modelo de respuesta, (B) diseño de capas vectoriales asociada a cada experimento, (C) simulación de rendimientos y estimación de modelos de coeficientes espacialmente variables a partir de los coeficientes simulados en (C) y diseños en (B), y (D) análisis de concordancia entre los coeficientes estimados en (C) y los coeficientes simulados en (A). El ejemplo considera el diseño X y el escenario de variabilidad Y.

2.5 Comparación de diseños

La concordancia entre el mapa de efectos estimado por el modelo GWR $\hat{\beta}_1(s_i)$ para cada realización de mapa de rendimiento simulado y el verdadero mapa de coeficiente

del efecto $\beta_1(s_i)$ fue evaluada mediante las siguientes métricas: coeficiente de correlación (r), error absoluto medio (MAE), probabilidad de cobertura (CP) y relación entre desviaciones estándar (SDR):

$$r = \frac{\sigma_{\hat{\beta}_1(s_i)\hat{\beta}_1(s_i)}}{\sigma_{\hat{\beta}_1(s_i)}\sigma_{\hat{\beta}_1(s_i)}} \quad (6)$$

$$MAE = \frac{1}{N} \sum |\hat{\beta}_1(s_i) - \beta_1(s_i)| \quad (7)$$

$$CP(d) = P[|\hat{\beta}_1(s_i) - \beta_1(s_i)| \leq d] \quad (8)$$

$$SDR = \frac{\sigma_{\hat{\beta}_1(s_i)}}{\sigma_{\beta_1(s_i)}} \quad (9)$$

El coeficiente de correlación indica el grado de asociación lineal entre los coeficientes estimados y los de referencia. Valores absolutos cerca de la unidad indican que existe relación casi perfecta pero no necesariamente implica la ausencia de sesgo en las estimaciones. El MAE representa la distancia absoluta promedio entre los coeficientes estimados y el de referencia. Idealmente esta medida debería ser 0 pero cuanto menor es, menor el sesgo y mayor es, en promedio, la concordancia entre los coeficientes. Además, para cada mapa estimado se calculó la proporción de ubicaciones donde la distancia absoluta entre los coeficientes estimados y el de referencia fue menor o igual al 15% respecto al de referencia. En otras palabras esta medida representa la proporción del lote donde las diferencias entre los coeficientes de respuesta observados y el verdadero valor del parámetro fueron menores al margen de error predefinido. Finalmente, el SDR captura la relación entre la variabilidad de los coeficientes estimados por GWR y aquellos usados en la simulación. Cuando $SDR > 1$, la variabilidad del mapa de efectos obtenido por GWR es superior a la variabilidad del efecto verdadero.

Como resultado, para cada combinación de estructura espacial (rangos) y diseños, una muestra de 30 valores de cada métrica fueron obtenidos (Fig. 1D) y se calcularon estadísticas descriptivas sobre las mismas. El efecto del diseño y la estructura espacial subyacente en la habilidad del modelo para capturar la estructura espacial de los efectos fueron evaluadas ajustando un modelo factorial completo: 3 anchos x 6 largos x 3 rangos x 2 anchos de banda x 2 *kernels*. La importancia de los factores fue cuantificada calculando los índices de sensibilidad principal y total a partir de las sumas de cuadrado (SC) del ANOVA [24]. El índice de sensibilidad principal (SP) captura la importancia del factor descontando efectos de interacción mientras que el índice de sensibilidad total (ST) incluye el efecto de interacción. Las SC de los factores fueron posteriormente particionadas para evaluar contrastes específicos entre tamaños de parcelas o tipos de diseño.

El procesamiento, visualización y modelado de los datos se realizó utilizando el programa estadístico R [25]. y funciones de los paquetes *gstat* [26], *sf* [27], *tidyverse* [28], *GWmodel* [29, 30].

3 Resultados y Discusión

El coeficiente de determinación local promedio (R^2) osciló entre 5 y 64% dependiendo de la combinación del escenario de variabilidad subyacente, el diseño experimental aplicado y los parámetros de GWR utilizados, i.e. ancho de banda y *kernel*. Independientemente de la selección del *kernel*, la moderada a baja proporción de varianza explicada por estos modelos se relaciona inversamente con la cantidad de variación residual. En este estudio las simulaciones asumieron una variación residual del 30% en torno al rendimiento del control. Se utilizó esta variación residual para poder evaluar diseños en escenarios de alta variabilidad que puede cubrir situaciones reales en experimentos de este tipo a escalas realistas en lotes comerciales de la Región Pampeana. Dado que los coeficientes de regresión estimados por GWR dependen de la función de ponderación [18, 20], se observó que, independientemente de los diseños y ancho de banda utilizado, en promedio los mayores valores de R^2 locales se obtuvieron con el *kernel bisquare* ($R^2 \approx 40\%$) comparado con el exponencial ($R^2 \approx 27\%$). Por otro lado, también se observó que la bondad de ajuste de los modelos locales se incrementó con la estructura espacial del escenario simulado. Esto es esperable dado que a medida que la estructura espacial se incrementa, existe mayor evidencia para considerar un modelo con coeficientes no estacionarios.

La Fig. 2 muestra la importancia de la estructura espacial de los escenarios, las características del diseño experimental (dimensiones de las parcelas) y los parámetros utilizados en el modelo GWR (*kernel* y ancho de banda) en la comparación entre los coeficientes estimados y el verdadero. Como puede observarse, la estructura espacial del escenario simulado tuvo gran impacto sobre casi todas las métricas evaluadas.




Fig. 2. Importancia de la estructura espacial subyacente (rango), el diseño (ancho y largo), y parámetros del modelo GWR (*kernel* y ancho de banda) en la variabilidad de

métricas de concordancia entre los coeficientes estimados por GWR y los verdaderos obtenidos de la realización del campo aleatorio (Eq. 2): coeficiente de correlación (r), error absoluto medio (MAE), probabilidad de cobertura (CP) y relación entre desviaciones estándar (SDR). La importancia de cada factor está determinada por el índice de sensibilidad principal, a mayor índice, mayor proporción de la variación explicada.

La correlación entre los mapas de coeficientes estimados por GWR y los utilizados como referencia fue altamente afectada por la estructura espacial (Fig. 2). Cerca del 97% de la variación fue asociada a ese factor. Este efecto puede explicarse principalmente por el contraste entre el escenario de no estructura espacial y aquellos con patrones de variabilidad estructurados. Cuando la estructura espacial fue nula, los coeficientes de correlación obtenidos fueron casi nulos ($r = 0,008$) indicando que la utilización de GWR en dichos escenarios no es necesaria (Fig. 3). En los escenarios con estructura espacial el coeficiente de correlación promedio fue cerca de 0,66. Estas diferencias representaron el 92% de la variación asociada con este factor.




Fig. 3. Efecto de la estructura espacial y dimensiones de las parcelas en la correlación de los mapas estimados por GWR y la realización del campo aleatorio tomada como referencia.

La CP(15) fue afectado mayormente por la magnitud de la estructura espacial y el *kernel* considerado (Fig. 2). A la inversa de lo observado para el MAE, la proporción de área del lote cuya diferencia entre el efecto estimado y el verdadero fue menor o igual al 15% aumentó con el rango de estructura espacial. En el caso del *kernel bisquare*, en los diseños con parcelas más anchas se observaron menores aumentos de CP(15) comparado con el *kernel* exponencial donde no se diferenciaron los diseños (Fig. 5).

Finalmente, en términos de SDR, se observa un alto impacto del *kernel* en la relación entre la variabilidad estimada de los coeficientes estimada por GWR y la variabilidad subyacente simulada (Fig. 2). En este sentido, el *kernel bisquare* tiende a sobreestimar la variabilidad, con valores de SDR en torno a 1,5 mientras que el exponen-

cial subestima (Fig. 6). En ambos casos, la sobre y subestimación disminuye a medida que la estructura espacial es más fuerte. Por otro lado, en el *kernel* exponencial, si bien subestima la variabilidad, el efecto de las dimensiones de las parcelas, tanto largo como ancho, es menor. En cambio, con el *kernel bisquare*, los diseños con parcelas anchas tienen a sobre-estimar más incluso en escenarios de variabilidad estructurada.




Fig. 4. Efecto de la estructura espacial, *kernel*, y dimensiones de las parcelas en el error absoluto medio (MAE) entre los mapas estimados por GWR y la realización del campo aleatorio tomada como referencia.

4 Conclusiones

En este estudio se corroboraron los efectos de la estructura espacial subyacente en la habilidad del modelo GWR para estimar la variabilidad espacial del efecto de tratamientos, y su interacción con los diseños utilizados en el experimento. Se verificó también el efecto significativo de los parámetros del modelo en los mapas de respuesta obtenidos. En síntesis a mayor estructura espacial, mejor desempeño del modelo GWR para capturar la no estacionariedad de los coeficientes. Entre los diseños evaluados, el ancho y longitud de las parcelas tuvo impacto en las métricas evaluadas. A mayor tamaño de parcelas, menor concordancia entre los coeficientes GWR y la realización del campo aleatorio. El mayor impacto se observó en la medida de error absoluto (MAE) y la estimación de la variabilidad (SDR) la cual mostró interacción con el *kernel* empleado ya que las mayores diferencias se observaron con *bisquare*. Finalmente, la utilización de diseños con parcelas de menor tamaño, en especial tableros de ajedrez en combinación con *kernel exponencial*, mejoran la estimación de los mapas de variabilidad subyacente de la respuesta comparado con diseños de menor resolución espacial.




Fig. 5. Efecto de la estructura espacial, *kernel*, y dimensiones de las parcelas en la probabilidad de cobertura (CP) de los mapas estimados por GWR y la realización del campo aleatorio tomada como referencia.




Fig. 6. Efecto de la estructura espacial, *kernel*, y dimensiones de las parcelas en la relación entre la variabilidad estimada por GWR y la presente en la realización del campo aleatorio tomada como referencia. Valores superiores a 1 indican sobre-estimación de la variabilidad por parte de GWR.

5 Referencias

1. Maat, H.: The history and future of agricultural experiments. *NJAS - Wageningen Journal of Life Sciences*. 57, 187–195 (2011). <https://doi.org/10.1016/j.njas.2010.11.001>.
2. Alesso, C.A., Cipriotti, P.A., Bollero, G.A., Martin, N.F.: Design of on-farm precision experiments to estimate site-specific crop responses. *Agronomy Journal*. 113, 1366–1380 (2021). <https://doi.org/10.1002/agj2.20572>.
3. Panten, K., Bramley, R.G.V., Lark, R.M., Bishop, T.F.A.: Enhancing the value of field experimentation through whole-of-block designs. *Precision Agriculture*. 11, 198–213 (2010). <https://doi.org/10.1007/s11119-009-9128-y>.
4. Hicks, D., Vanden Heuvel, R., Fore, Z.: Analysis and practical use of information from on-farm strip trials. *Better Crops*. 81, 18–21 (1997).
5. Plant, R.E.: Comparison of means of spatial data in unreplicated field trials. *Agronomy Journal*. 99, 481–488 (2007). <https://doi.org/10.2134/agronj2005.0150>.
6. Alesso, C.A., Cipriotti, P.A., Bollero, G.A., Martin, N.F.: Experimental Designs and Estimation Methods for On-farm Research: A Simulation Study of Corn Yields at Field Scale. *Agronomy Journal*. 111, 2724–2735 (2019). <https://doi.org/10.2134/agronj2019.03.0142>.
7. Whelan, B.M., Taylor, J.A.: Precision agriculture for grain production systems. CSIRO Publ, Collingwood (2013).
8. Bullock, D.S., Bullock, D.G.: From agronomic research to farm management guidelines: A primer on the economics of information and precision technology. *Precision Agriculture*. 2, 71–101 (2000).
9. Pringle, M.J., Cook, S.E., McBratney, A.B.: Field-Scale Experiments for Site-Specific Crop Management. Part I: Design Considerations. *Precision Agriculture*. 5, 617–624 (2004). <https://doi.org/10.1007/s11119-004-6346-1>.
10. Piepho, H.P., Richter, C., Spilke, J., Hartung, K., Kunick, A., Thöle, H.: Statistical aspects of on-farm experimentation. *Crop and Pasture Science*. 62, 721 (2011). <https://doi.org/10.1071/CP11175>.
11. Scharf, P.C., Kitchen, N.R., Sudduth, K.A., Davis, J.G., Hubbard, V.C., Lory, J.A.: Field-Scale Variability in Optimal Nitrogen Fertilizer Rate for Corn. *Agronomy Journal*. 97, 452–461 (2005). <https://doi.org/10.2134/agronj2005.0452>.
12. Kyveryga, P.M., Blackmer, A.M., Zhang, J.: Characterizing and Classifying Variability in Corn Yield Response to Nitrogen Fertilization on Subfield and Field Scales. *Agronomy Journal*. 101, 269–277 (2009). <https://doi.org/10.2134/agronj2008.0168>.
13. Kindred, D.R., Milne, A.E., Webster, R., Marchant, B.P., Sylvester-Bradley, R.: Exploring the spatial variation in the fertilizer-nitrogen requirement of wheat within fields. *The Journal of Agricultural Science*. 153, 25–41 (2015). <https://doi.org/10.1017/S0021859613000919>.
14. Panten, K., Bramley, R. g. v.: Whole-of-block experimentation for evaluating a change to canopy management intended to enhance wine quality. *Australian Journal of Grape and Wine Research*. 18, 147–157 (2012). <https://doi.org/10.1111/j.1755-0238.2012.00183.x>.
15. Pringle, M.J., McBratney, A.B., Cook, S.E.: Field-Scale Experiments for Site-Specific Crop Management. Part II: A Geostatistical Analysis. *Precision Agriculture*. 5, 625–645 (2004). <https://doi.org/10.1007/s11119-004-6347-0>.
16. Bishop, T.F.A., Lark, R.M.: The geostatistical analysis of experiments at the landscape-scale. *Geoderma*. 133, 87–106 (2006). <https://doi.org/10.1016/j.geoderma.2006.03.039>.
17. Trevisan, R.G., Bullock, D.S., Martin, N.F.: Spatial variability of crop responses to agronomic inputs in on-farm precision experimentation. *Precision Agric*. 22, 342–363 (2020). <https://doi.org/10.1007/s11119-020-09720-8>.

18. Fotheringham, A.S., Brunson, C., Charlton, M.: Geographically weighted Regression: the analysis of spatially varying relationships. Wiley, Chichester, England (2002).
19. Bivand, R.S., Pebesma, E., Gómez-Rubio, V.: Applied Spatial Data Analysis with R. Springer New York, New York, NY (2013). <https://doi.org/10.1007/978-1-4614-7618-4>.
20. Páez, A., Farber, S., Wheeler, D.: A Simulation-Based Study of Geographically Weighted Regression as a Method for Investigating Spatially Varying Relationships. *Environ Plan A*. 43, 2992–3010 (2011). <https://doi.org/10.1068/a44111>.
21. Farber, S., Páez, A.: A systematic investigation of cross-validation in GWR model estimation: empirical analysis and Monte Carlo simulations. *J Geograph Syst.* 9, 371–396 (2007). <https://doi.org/10.1007/s10109-007-0051-3>.
22. Marchant, B., Rudolph, S., Roques, S., Kindred, D., Gillingham, V., Welham, S., Coleman, C., Sylvester-Bradley, R.: Establishing the precision and robustness of farmers' crop experiments. *Field Crops Research*. 230, 31–45 (2019). <https://doi.org/10.1016/j.fcr.2018.10.006>.
23. Webster, R., Oliver, M.A.: Geostatistics for environmental scientists. Wiley, Chichester, England (2007).
24. Wallach, D., Makowski, D., Jones, J.W.: Working with Dynamic Crop Models: Evaluation, Analysis, Parameterization, and Applications. Elsevier Science (2006).
25. R Core Team: R: A Language and Environment for Statistical Computing, <https://www.R-project.org/>, (2023).
26. Pebesma, E.: Spatio-temporal geostatistics using gstat. (2011).
27. Pebesma, E.: Simple Features for R: Standardized Support for Spatial Vector Data. *The R Journal*. 10, 439–446 (2018). <https://doi.org/10.32614/RJ-2018-009>.
28. Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L.D., François, R., Grolemund, G., Hayes, A., Henry, L., Hester, J., Kuhn, M., Pedersen, T.L., Miller, E., Bache, S.M., Müller, K., Ooms, J., Robinson, D., Seidel, D.P., Spinu, V., Takahashi, K., Vaughan, D., Wilke, C., Woo, K., Yutani, H.: Welcome to the tidyverse. *Journal of Open Source Software*. 4, 1686 (2019). <https://doi.org/10.21105/joss.01686>.
29. Gollini, I., Lu, B., Charlton, M., Brunson, C., Harris, P.: GWmodel: An R Package for Exploring Spatial Heterogeneity Using Geographically Weighted Models. *J. Stat. Soft.* 63, (2015). <https://doi.org/10.18637/jss.v063.i17>.
30. Lu, B., Harris, P., Charlton, M., Brunson, C.: The GWmodel R package: further topics for exploring spatial heterogeneity using geographically weighted models. *Geo-spatial Information Science*. 17, 85–101 (2014). <https://doi.org/10.1080/10095020.2014.917453>.