

## Número de mapas de rendimiento necesarios para identificar patrones de productividad dentro un lote: aproximación por simulación de cultivos

C. Agustín Alesso<sup>1,2</sup>, Pablo D. Masciangelo<sup>3</sup>, Silvia Imhoff<sup>1,2</sup> y Miguel Á. Pilatti<sup>1</sup>

<sup>1</sup> Facultad de Ciencias Agrarias, UNL.

<sup>2</sup> Instituto de Agrobiotecnología del Litoral, CONICET

<sup>3</sup> Asesor privado

[calesso@fca.unl.edu.ar](mailto:calesso@fca.unl.edu.ar), [pablomasciangelo@yahoo.com.ar](mailto:pablomasciangelo@yahoo.com.ar), [simhoff@fca.unl.edu.ar](mailto:simhoff@fca.unl.edu.ar),  
[mpilatti@fca.unl.edu.ar](mailto:mpilatti@fca.unl.edu.ar)

**RESUMEN.** Los mapas de rendimiento son de gran utilidad para estimar la variación espacial y temporal de los cultivos. El tamaño de las series multi-temporales disponibles es reducido lo que dificulta establecer el número mínimo de años para identificar patrones de rendimiento estables dentro del lote. El objetivo de este trabajo fue estimar dicho número mediante simulación de cultivos. Se utilizó el modelo FitoSIM para estimar mapas de rendimientos y se analizó la variabilidad espacial y temporal de los mismos. Se cuantificó la concordancia entre los patrones de rendimiento de la serie completa y aquellos identificados con menor cantidad de mapas. Se observó un alto grado de estabilidad temporal con una escala de variación espacial a corta distancia. En secano se logró concordancias mayores a 0,9 con 8 a 11 mapas. Es necesario explorar el efecto de diferentes cultivos, dosis de fertilización, fechas de siembra, contenidos de agua inicial.

**PALABRAS CLAVES:** Agricultura de precisión, zonas de manejo, variabilidad espacial y temporal de rendimientos, modelos de simulación de cultivos.

### 1 Introducción

La Agricultura de Precisión (AP) tiene como objetivo la optimización de la producción agrícola atendiendo a la variabilidad espacial y temporal de los sistemas de producción [1]. El enfoque de zonas de manejo (ZM) busca simplificar la representación espacial de dicha variabilidad identificando áreas dentro de la unidad de manejo (i.e. lote) definidas por su relativa homogeneidad en los factores de suelo y cultivo, y para la cual es necesaria una única dosis de insumos [2, 3].

La delimitación de ZM no es una tarea sencilla ya que en cada caso se requiere conocer el tipo de información a utilizar, cómo debe ser procesada y el número de ZM en que debe ser dividido el lote [4]. En la literatura se han propuesto numerosos métodos para delimitar ZM potenciales en los cuales se utilizaron (i) propiedades de suelo directamente relacionadas con los rendimientos de los cultivos, (ii) atributos secundarios relacionados con los factores limitantes del cultivo y (iii) estimaciones de

rendimiento. Mientras que en los dos primeros enfoques se asume una relación directa o indirecta entre los atributos de suelo y rendimientos, el tercero se basa en el supuesto de que la identificación de patrones de rendimiento estables en el tiempo se corresponde con áreas de similares atributos de suelo, y por lo tanto, necesidades de manejo comunes [5].

Las aproximaciones utilizadas para delinear zonas homogéneas a partir de series multi-temporales de mapas de rendimientos son variadas. Lark y Stafford [6] identificaron patrones espaciales de rendimientos asociados a diferencias de humedad edáfica utilizando un algoritmo de clasificación difusa no supervisado. Brock et al. [7], utilizando el mismo algoritmo, clasificaron una serie de 6 mapas de rendimiento de secuencias soja-maíz y encontraron diferencias en los patrones espaciales en función del tipo de cultivo. Jaynes et al. [5, 8] identificaron patrones de rendimiento de soja y maíz mediante análisis de conglomerados y los relacionaron con la conductividad eléctrica aparente (ECa). Por su parte, Blackmore et al. [9] desarrollaron un método empírico para delinear zonas en función de su nivel de productividad y estabilidad temporal a partir de mapas de rendimiento. Dicho enfoque, les permitió identificar zonas de rendimiento altas o bajas consistentes entre campañas y zonas inestables temporalmente. En un enfoque similar, Cox y Gerard [10] derivaron zonas de manejo mediante el análisis de la estabilidad de rendimientos. Diker et al. [11] delimitaron zonas de manejo aplicando análisis de frecuencias a dos mapas de rendimiento. En un estudio comparativo, Dobermann et al. [12] aplicaron métodos de clasificación empíricos y no empíricos (jerárquicos y no jerárquicos) a mapas de rendimiento de maíz bajo riego y determinaron una mayor reducción de la varianza mediante estos últimos por sobre los empíricos.

La información contenida en los *ensayos de uniformidad*<sup>1</sup> es de gran utilidad para estimar la variación espacial y temporal de los cultivos [13], no obstante la inestabilidad de los rendimientos producto de la variabilidad temporal de las condiciones meteorológicas entre campañas es frecuentemente citada como una limitante para identificar patrones de rendimientos consistentes entre años [14]. En general los estudios son realizados a partir de series temporales reducidas por lo que la determinación de la cantidad de años a considerar para identificar patrones de rendimiento es subjetiva [12]. Boydell y McBratney [15], abordaron este inconveniente mediante estimaciones de rendimiento de algodón en Australia obtenidas a partir de una serie de imágenes satelitales. Para dichas condiciones bajo riego los autores sugieren que series de  $5 \pm 2$  años son suficientes para estimar adecuadamente los patrones de rendimiento.

Los modelos de simulación de cultivos son ampliamente reconocidos por su capacidad de integrar la dinámica temporal de los factores que interaccionan el crecimiento del cultivo en distintas condiciones ambientales y de manejo [16]. No obstante, éstos han sido diseñados para realizar simulaciones puntuales (no espaciales) por lo que se han propuesto algunas estrategias para su utilización en la estimación de la variabilidad espacial. Irmak et al. [17] a partir de datos obtenidos en un muestreo en grilla, simularon la variabilidad espacial de rendimientos de soja utilizando el modelo CROPGRO. Del mismo modo, van Uffelen et al. [18] simularon

---

<sup>1</sup> Mapas de rendimiento de lotes con manejo uniforme.

los rendimientos a partir de una grilla de datos y obtuvieron mapas de rendimiento mediante técnicas de interpolación geostatística. Un enfoque alternativo para reducir la cantidad de datos requeridos por el modelo y el número de simulaciones a realizar es la simulación por zonas homogéneas definidas a partir de información secundaria [16, 19]

El objetivo de este trabajo es determinar el número de mapas de rendimiento de maíz necesarios para identificar patrones espaciales de productividad dentro de un lote utilizando un modelo de simulación de cultivos.

## 2 Materiales y Métodos

El estudio se llevó a cabo en el distrito La Pelada, provincia de Santa Fe, Argentina (30° 56' 17" S, 60° 55' 23" O). Se seleccionó un lote destinado a agricultura continua en siembra directa con secuencia de cultivos soja-maíz y dosis moderadas de fertilizantes nitrogenados y fosforados (50 kg N ha<sup>-1</sup> y 46 kg P<sub>2</sub>O<sub>5</sub> ha<sup>-1</sup>). Se simuló la variabilidad espacial y temporal de los rendimientos con el modelo de simulación de cultivos FitoSIM [20–22]. Para ello se utilizaron datos analíticos de los primeros 20 cm de suelo obtenidos en un muestreo en grilla 25x50 dentro de una parcela de 475 x 100 m (n = 60). Detalles del diseño de muestreo y determinaciones analíticas se detallan en [23]. Para cada sitio muestreado se generó un conjunto de datos de entrada para el modelo utilizando los datos de densidad de suelo (Ds, g cm<sup>-3</sup>) [24], contenido de arcilla y arena (A y Ar, g kg<sup>-1</sup>), C orgánico (CO, g kg<sup>-1</sup>), N total (Nt, g kg<sup>-1</sup>), N de nitratos (N-NO<sub>3</sub>, mg kg<sup>-1</sup>), P extractable (P, mg kg<sup>-1</sup>), pH, conductividad eléctrica (CE, dS m<sup>-1</sup>). Adicionalmente, en cada sitio se registró la profundidad al inicio del horizonte B. Los parámetros de la curva de resistencia mecánica y retención hídrica en cada punto de muestreo fueron estimados mediante funciones de edafotransferencia [25]. Los datos del resto del perfil fueron tomados de un suelo Argiudol típico serie Esperanza descripto en la carta de suelos [26] como perfil representativo del área de estudio.

Las condiciones simuladas fueron las siguientes: (a) cultivo de maíz en secano y no fertilizado (R0F0), (b) cultivo de maíz en secano con adición de 46 kgN ha<sup>-1</sup> y 36 kg P<sub>2</sub>O<sub>5</sub> ha<sup>-1</sup> como urea y superfosfato triple de calcio (R0F1); y (c) idem R0F1 pero bajo riego (R1F1). Se utilizó la serie de datos meteorológicos diarios 1977/2010 (*t* = 33 años) registrados en la estación meteorológica INTA EEA Rafaela. Las simulaciones se realizaron de manera independiente para cada año (*i.e.* no seriadas) a los efectos de considerar las condiciones meteorológicas de cada campaña como una posible realización de las condiciones climáticas de la zona. Para este ejemplo se asumió un contenido hídrico inicial de 60% del agua útil en todas las corridas. A los rendimientos de cada sitio se les asignó la coordenada y se examinó su estructura espacial por campaña mediante variogramas.

La identificación de patrones espaciales de rendimientos se realizó mediante el procedimiento de clasificación difusa *fuzzy k-means*. A diferencia de otros algoritmos de clasificación dura, éste realiza una clasificación no jerárquica en la cual cada observación puede pertenecer a más de una clase a la vez lo cual es más correcto en

aplicaciones donde la variabilidad del fenómeno en estudio es continua [6]. Para esto se clasificó la serie multitemporal de rendimientos completa de 33 años ( $t = 33$ ) evaluando distinto número de grupos ( $k = 2$  a  $6$ ) de acuerdo a lo utilizado por otros autores [6, 7, 12]. Dado que la estructura de los datos es desconocida, el número óptimo de grupos ( $k_{t=33}$ ) se determinó mediante la interpretación índice de borrosidad (FPI), el cual cuantifica el grado de superposición entre clases, y el de entropía normalizada (NCE) que resume el nivel de desorganización de la clasificación resultante. Según Lark y Stafford [6], el mínimo de ambos indicadores representa la mejor clasificación ya que se minimiza la superposición de clases mientras que se mantiene bajo el nivel de desorganización dentro de las clases. La solución obtenida a partir de la serie completa se consideró como la mejor estimación del número de grupos presentes en el conjunto de datos y se utilizó como referencia para las comparaciones con las clasificaciones obtenidas a partir de series reducidas.

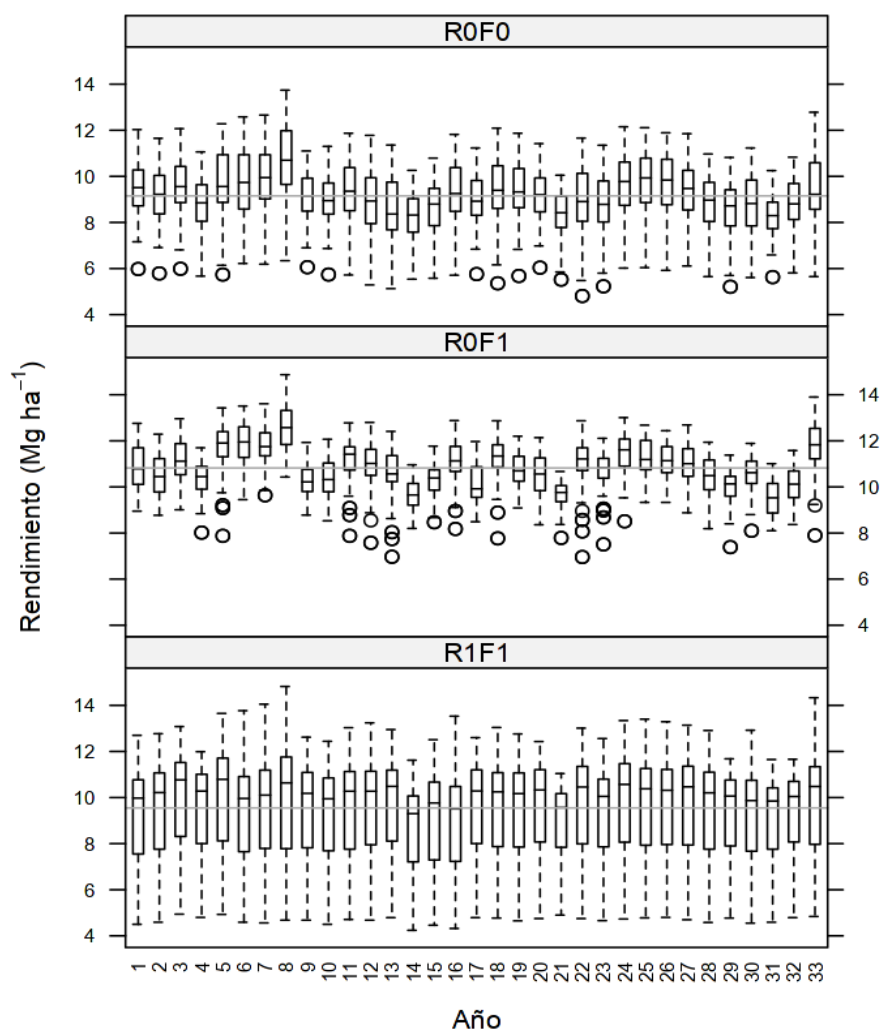
Posteriormente, para determinar el número mínimo de mapas para identificar patrones espaciales de rendimiento consistentes se procedió a realizar la clasificación de series multitemporales de tamaño creciente ( $t = 2, 3, \dots, 32$  años) comparando el grado de concordancia de éstos con aquellos identificados en la serie completa. Para ello, se tomaron 20 muestras aleatorias no ordenadas de los rendimientos de las 34 campañas simuladas y se clasificó en  $k_{t=33}$  grupos utilizando el mismo algoritmo de clasificación. La evaluación de la concordancia entre los patrones de cada clasificación con la serie de referencias se realizó mediante la elaboración de tablas de contingencia y el cálculo del índice de concordancia kappa de Cohen ( $\kappa$ ) [27].

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (1)$$

donde:  $p_o$  es la proporción de observaciones dentro de las celdas diagonales de la tabla de contingencia y  $p_e$  son las proporciones esperadas en dicha diagonal bajo la hipótesis nula de no asociación entre mapas. Dicho índice mide el grado de concordancia entre dos variables categóricas en una escala de 0 a 1. A mayor cantidad de observaciones en la diagonal de la tabla de contingencia entre dos clasificaciones, mayor es el grado de concordancia y por lo tanto el índice tiende a 1. Por el contrario, valores de kappa cercanos a 0 indican independencia entre ambas clasificaciones [15]

Finalmente, los índices de concordancia obtenidos se graficaron en función del tamaño de la serie de mapas de rendimiento y se estableció un umbral de concordancia de 0,9 para determinar el tamaño mínimo de la serie. Si bien valores inferiores pueden considerarse como aceptables, se optó un umbral elevado dado que se trabajó con mapas de rendimiento simulados que no incorporan factores reductores del rendimiento como plagas, malezas y enfermedades.


La generación de los datos de entrada de cada sitio y la ejecución del modelo así como la recuperación de los resultados se realizó mediante un script *ad-hoc* escrito en el lenguaje de programación Python 2.7.4 [28]. Estadísticas de resumen, variografía de los datos de rendimiento, análisis de cluster y de concordancia entre los mapas clasificados fue realizado en el entorno de programación R 2.15.3 [29] utilizando los paquetes *gstat* [30], *sp* [31], *cluster* [32] y *irr* [33].



**Fig. 1.** Distribución de los rendimientos de maíz simulados en cada año de la serie meteorológica Rafaela 1977/2010 a partir de la información de suelos de 60 sitios dentro del área de estudio. (Ver descripción de condiciones simuladas en pág. 3).

### 3 Resultados y Discusión


El rendimiento medio de maíz en la mayoría de las campañas simuladas fue mayor en las condiciones de R0F1 (Fig. 1), mientras que R0F0 tuvo los menores rendimientos. Cuando se simuló riego y fertilización (R1F1), los rendimientos medios fueron intermedios o similares a los obtenidos en R0F1 en algunas campañas. La variabilidad



**Fig. 2.** Distribución espacial de los rendimientos promedio interanuales para cada condición simulada.

temporal en seco (R0F0 y R0F1) fue mayor debido a la influencia de las variaciones en las condiciones ambientales registradas en cada año de la serie climática (Fig. 1).

A su vez, el contraste entre R0F0 y R0F1 muestra una leve reducción de la dispersión de los rendimientos dentro de cada campaña en el primer caso. Cabe destacar que la dosis de fertilizante fue constante para cada año simulado. En cambio, cuando se simuló R1F1, la variabilidad temporal disminuyó, mientras que se maximizaron las diferencias entre los distintos sitios dentro del lote y por lo tanto aumentó la dispersión de los rendimientos dentro de cada campaña. Mientras que el riego reduce la influencia de la variabilidad interanual de las condiciones climáticas, el menor rendimiento medio y mayor heterogeneidad dentro de cada campaña podría explicarse por la variabilidad espacial de propiedades de suelo relacionadas con retención hídrica y deficiencias de aireación.



**Fig. 3.** Distribución espacial de los coeficientes de variación interanuales (CV) de los rendimientos de maíz simulados para cada condición.

En la Fig. 2 y Fig. 3 se muestra la distribución espacial de los rendimientos promedio y sus coeficientes de variación interanual para cada condición simulada. Se observa mayor homogeneidad espacial en las condiciones de secano con fertilizante respecto a bajo riego. El 50% de los sitios simulados tuvieron rendimientos promedio entre 10,3 y 11,2 Mg ha<sup>-1</sup>, mientras que en la alternativa bajo riego, la mitad de los sitios tuvieron rendimientos promedio entre 7,8 y 10,9 Mg ha<sup>-1</sup>. Cuando se simuló el cultivo en secano sin fertilización, la dispersión de los rendimientos promedio fue intermedia (rango intercuartílico = 1,8 Mg ha<sup>-1</sup>) con rendimientos medios inferiores a las otras alternativas simuladas.

Tal como se describiera para la tendencia central del área de estudio, la variación interanual del rendimiento de cada sitio simulado en particular fue menor cuando se simularon condiciones de R1F1 (CV < 10%), lo cual se explicaría por la menor influencia de la variabilidad climática en lo que se refiere a la disponibilidad de agua

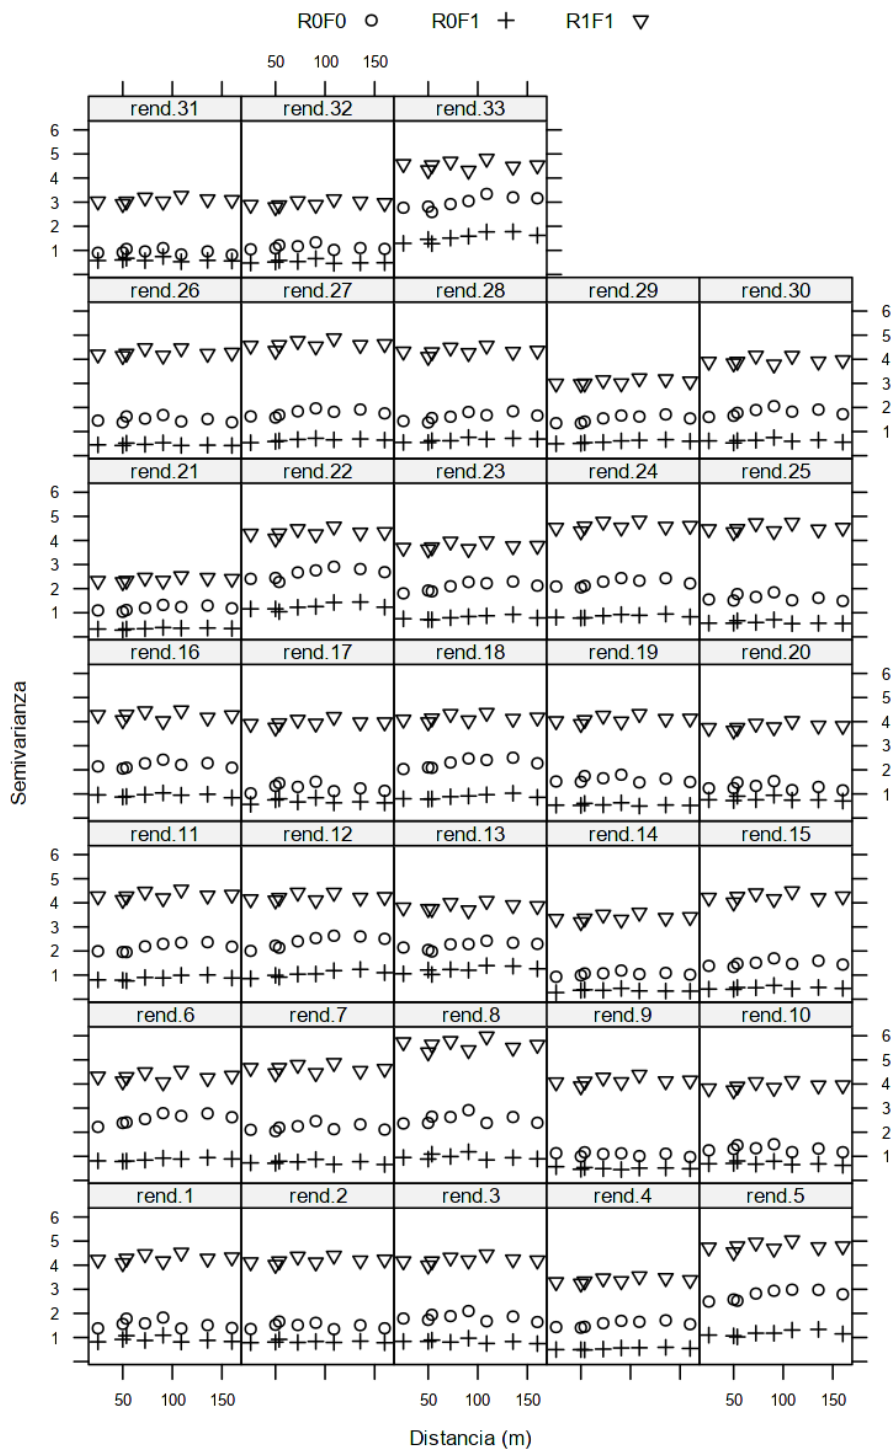
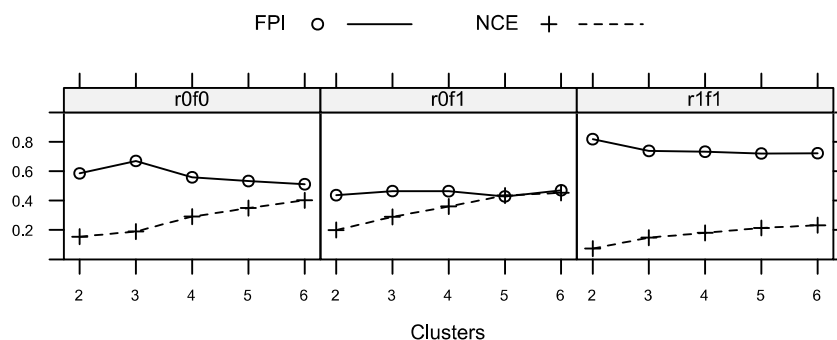


Fig. 4. Variogramas empíricos de los rendimientos anuales para las distintas condiciones simuladas.





**Fig. 5.** Índice de performance de borrosidad (FPI) y entropía de agrupamiento normalizada (NCE) utilizados para determinación del número óptimo de zonas.

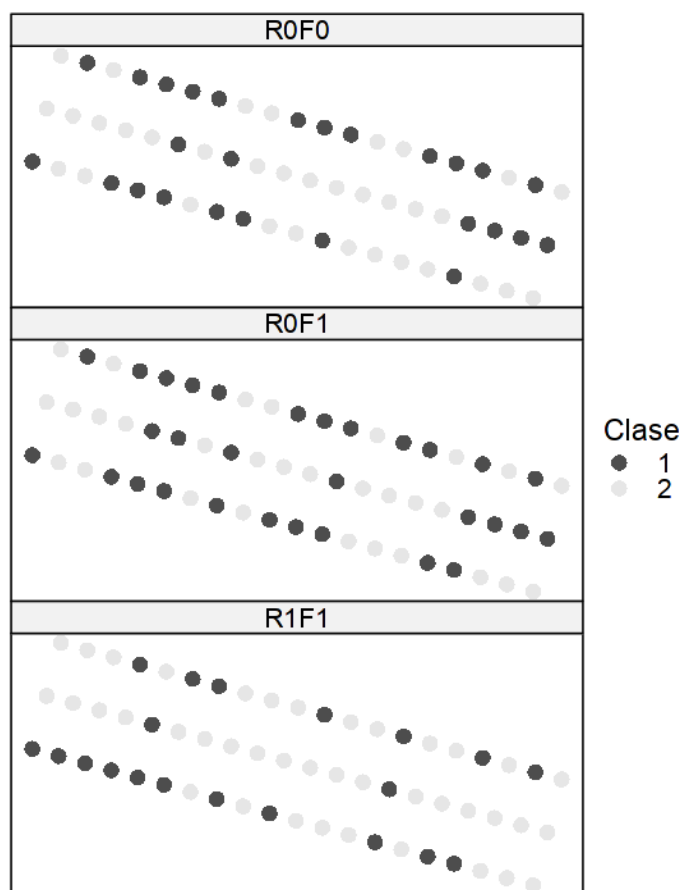
para el cultivo. Por su parte, los rendimientos en secano presentaron similar nivel de variación interanual entre sí con el 75% de los sitios con  $CV < 10\%$ .

Al examinar la estructura espacial de los rendimientos mediante variogramas (Fig. 4) se observó que la resolución espacial de la grilla de muestreo no fue capaz de capturar la estructura de variación de los rendimientos. Así mismo, en la Fig. 4 se corroboran las diferencias en la magnitud de variación de los rendimientos según las condiciones simuladas.

La ausencia de estructura espacial a la escala de observación concuerda con los resultados del análisis individual de los atributos edáficos [23]. Por otro lado, la estructura espacial observada en los variogramas de los datos de rendimiento reales obtenidos con monitores de las cosechadoras (datos no mostrados por falta de espacio) son consistentes con lo observado en el presente trabajo. Dichos variogramas muestran que cerca del 50% de la variabilidad de se encuentra estructurada a corta distancia, entre 20 y 30 m, mientras que la variabilidad remanente tiene una distancia de alcance mayor a la distancia máxima explorada por la grilla. Según estos resultados, el análisis de la estabilidad de los patrones de rendimiento se realizó a partir de los mapas de puntos.

### 3.1 Número óptimo de zonas

La solución óptima de clusters es aquella donde se produce el mínimo de los indicadores FPI y NCE [4]. En este estudio, la estructura de los conjuntos de datos no pudo ser identificado claramente mediante el mínimo de FPI y NCE ya que la menor entropía o nivel de desorden de la clasificación indicada por el NCE se produce dividiendo los rendimientos en 2 grupos (alto y bajo), mientras que el índice de borrosidad FPI varía ligeramente conforme se disminuye el número de clases (Fig. 5). Por lo tanto se aplicó el criterio de parsimonia y se seleccionó el menor número de clusters en función de NCE. Brock et al. [7] discuten las dificultades de interpretar estos indicadores y proponen criterios de selección del número de clusters en función



**Fig. 6.** Mapa de puntos clasificados en función de los rendimientos de 33 años simulados para cada condición.

de la reducción de la varianza.

En la Fig. 6 se presentan los mapas de puntos clasificados en dos grupos de rendimientos (1 = bajo rendimiento y 2 = alto rendimiento). Los patrones de puntos definidos en función de los rendimientos simulados en secano (R0F0 y R0F1) tienen mayor concordancia entre sí ( $\kappa=0,69$ ) que entre estos y el correspondiente a los mapas de rendimiento R1F1 ( $\kappa=0,128$  y  $\kappa=0,32$  para R1F1 vs. R0F0 y R0F1 respectivamente). En la Fig. 7 el rendimiento medio de cada grupo en cada uno de los años simulados. Se observa que en todos los años, los rendimientos de la 2 (alto rendimiento) fue superior variando su distancia respecto al grupo 1 en función de las condiciones ambientales particulares de cada año. Las mayores diferencias entre ambos grupos se produjeron en las condiciones bajo riego. Esto podría explicarse por

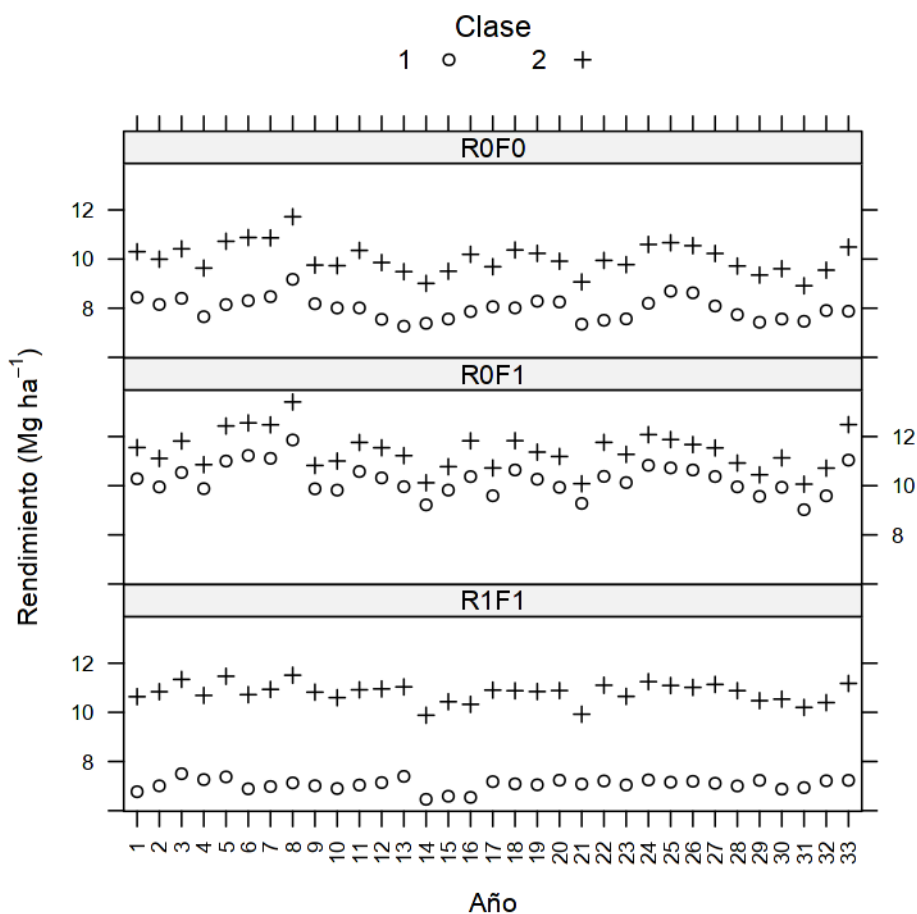



Fig. 7. Rendimientos medios de cada clase para cada año simulado.

la menor porosidad de aireación de estos sitios.

### 3.2 Determinación del número mínimo de mapas de rendimiento

El análisis de concordancia entre los patrones de rendimiento identificados a partir de conjunto de datos completo (Fig. 6) y aquellos utilizando menor cantidad de mapas de rendimiento se muestran en la Fig. 8. El alto grado de estabilidad temporal observada en los rendimientos se tradujo en altos niveles de concordancia aún cuando se se consideran pocos mapas de rendimientos. Asumiendo arbitrariamente un valor de concordancia mínimo de 0.9 se observa que para las simulaciones en secano (R0F0 y R0F1) serían necesarios al menos entre 8 y 11 mapas de rendimiento para superar



**Fig. 8.** Índice de concordancia Kappa en función del número de mapas de rendimientos usados para identificar patrones de rendimiento bajo las condiciones simuladas.

dicho umbral. En cambio, en las condiciones de R1F1 los resultados muestran índices de concordancia se estabilizan en valores muy altos con 1 o 2 mapas de rendimiento. Boydel y McBratney [15] fijando umbrales de concordancia más bajos determinaron que es preciso contar con  $5 \pm 2$  mapas de rendimiento de cultivo de algodón bajo riego para identificar patrones de rendimiento estables. Doberman et al. [12] trabajaron con una serie de 6 mapas de rendimiento de maíz bajo riego y concluyeron que 5 mapas podrían ser suficientes para identificar patrones espacio-temporales debido a la minimización de los efectos climáticos debido al riego. En cambio, para cultivos en seco, las series de mapas deberían ser mayores (entre 5 y 10 años aproximadamente).

Umbral inferior al utilizado en este estudio indicarían que el número de mapas requeridos se reduce significativamente. No obstante, en este trabajo los mapas de rendimiento se obtuvieron a partir de datos de suelo y clima utilizando un modelo de simulación de cultivos que no simula el efecto de adversidades o plagas por lo que es de esperar que en condiciones reales, para un mismo umbral de concordancia, el número mínimo de mapas necesarios para identificar patrones estables sea mayor. Es por ello que para compensar el efecto de los factores no incluidos en la simulación, se optó por un umbral elevado de concordancia. Un aspecto importante de este enfoque fue la posibilidad de trabajar con series de datos climáticos permitió estimar la variabilidad temporal en un conjunto mayor de mapas de rendimiento.

#### 4 CONCLUSIONES

Asumiendo que los mapas de rendimiento obtenidas por simulación permiten estimar razonablemente la variabilidad temporal y espacial de los rendimientos, la metodología aquí presentada permitió explorar la variabilidad temporal de los rendimientos y aproximar de manera cuantitativa el número mínimo de años necesarios para definir patrones estables dentro de un lote.

El caso estudiado mostró un alto grado de estabilidad temporal de rendimientos con una escala de variación espacial a corta distancia, reflejado en los altos niveles de concordancia iniciales. Es necesario ampliar la cantidad de posibles simulaciones para cada año climático para explorar el efecto de diferentes dosis de fertilización, fechas de siembra, contenidos de agua inicial, etc.

#### BIBLIOGRAFÍA

1. Pierce, F.J., Nowak, P.: Aspects of Precision Agriculture. *Adv. in Agron.* 67, 1–85 (1999).
2. Roudier, P., Tisseyre, B., Poilvé, H., Roger, J.-M.: A technical opportunity index adapted to zone-specific management. *Precision Agric.* 12, 130–145 (2010).
3. Doerge, T.A.: *Management Zone Concepts*, (1999).
4. Fridgen, J.J., Kitchen, N.R., Sudduth, K.A., Drummond, S.T., Wiebold, W.J., Fraisse, C.W.: Management zone analyst (MZA): Software for subfield management zone delineation. *Agronomy Journal*. 96, 100–108 (2004).
5. Jaynes, D.B., Colvin, T.S., Kaspar, T.C.: Identifying potential soybean management zones from multi-year yield data. *Computers and Electronics in Agriculture*. 46, 309–327 (2005).
6. Lark, R.M., Stafford, J.V.: Classification as a first step in the interpretation of temporal and spatial variation of crop yield. *Annals of Applied Biology*. 130, 111–121 (1997).
7. Brock, A., Brouder, S.M., Blumhoff, G., Hofmann, B.S.: Defining Yield-Based Management Zones for Corn-Soybean Rotations. *Agronomy Journal*. 97, 1115–1128 (2005).
8. Jaynes, D.B., Colvin, T.C., James, T.S., others: Cluster analysis of spatiotemporal corn

- yield patterns in an Iowa field. *Agronomy Journal*. 95, 574–586 (2003).
9. Blackmore, S., Godwin, R.J., Fountas, S.: The analysis of spatial and temporal trends in yield map data over six years. *Biosystems engineering*. 84, 455–466 (2003).
  10. Cox, M.S., Gerard, P.D.: Soil Management Zone Determination by Yield Stability Analysis and Classification. *Agronomy Journal*. 99, 1357–1365 (2007).
  11. Diker, K., Heermann, D.F., Brodahl, M.K.: Frequency analysis of yield for delineating yield response zones. *Precision Agriculture*. 5, 435–444 (2004).
  12. Dobermann, A.P., Adamchuk, J.L., Simbahan, V.I., Ferguson, G.C.: Classification of Crop Yield Variability in Irrigated Production Fields. *Agronomy Journal*. 95, 1105–1120 (2003).
  13. Whelan, B.M., McBratney, A.B.: The “Null Hypothesis” of Precision Agriculture Management. *Precis. Agric.* 2, 265–279 (2000).
  14. Florin, M.J., McBratney, A.B., Whelan, B.M.: Quantification and comparison of wheat yield variation across space and time. *European Journal of Agronomy*. 30, 212–219 (2009).
  15. Boydell, B., McBratney, A.B.: Identifying potential within-field management zones from cotton-yield estimates. *Precision agriculture*. 3, 9–23 (2002).
  16. Basso, B., Ritchie, J.T., Pierce, F.J., Braga, R.P., Jones, J.W.: Spatial validation of crop models for precision agriculture. *Agricultural Systems*. 68, 97–112 (2001).
  17. Irmak, A., Jones, J.W., Batchelor, W.D., Irmak, S., Paz, J.O., Boote, K.J.: Analysis of spatial yield variability using a combined crop model-empirical approach. *Transactions of ASAE*. 49, 811 (2006).
  18. Van Alphen, B.J., Stoorvogel, J.J.: A functional Approach to Soil Characterization in Support of Precision Agriculture. *Soil Science American Journal*. 64, 1706–1713 (2000).
  19. Miao, Y., Mulla, D.J., Robert, P.C.: Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agric.* 7, 117–135 (2006).
  20. Grenón, D.A., Pilatti, M.A.: II.9. Fitosim: modelo de simulación para el entrenamiento en toma de decisiones en Producción Vegetal. In: Galusi, A.A., Moya, M.E., and Lallana, M.C. (eds.) *Del aula al campo, el desafío cotidiano*. pp. 609–622. Eduner, Paraná, Argentina (2010).
  21. Pilatti, M.A.: *Análisis agrofísico de la relación entre la dinámica hídrica en la fitosfera y el desarrollo y producción de los cultivos*, (1986).
  22. Pilatti, M.A., Norero, A.L.: *Simulación de cultivos anuales. Formulacións básicas del desenvolvimiento normal*. Ed. Universidad Nacional del Litoral, Santa Fe, Argentina (2004).
  23. Alesso, C.A., Pilatti, M.A., Imhoff, S., Grilli, M.P.: Variabilidad espacial de atributos químicos y físicos en un suelo de la Pampa Llana Santafesina. *Ci. Suelo*. 30, 85–93 (2012).
  24. Forsythe, W.: *Manual de laboratorio de física de suelos*. IICA, San José, Costa Rica (1975).
  25. Imhoff, S., da Silva, A.P., Ghiberto, P., Tormena, C.A., Pilatti, M.A., Libardi, P.L.: Funciones de edafotransferencia para determinar el intervalo hídrico óptimo de suelos de la provincia de Santa Fe. *Actas del XXIII Congreso Argentino de la Ciencia del Suelo*. AACs, Mar del Plata, Argentina (2012).

26. INTA: Carta de Suelos de la República Argentina: hojas 3160-26 y 25, Esperanza-Pilar. INTA EEA Rafaela (1991).
27. Carstensen, L.W.: A Measure of Similarity for Cellular Maps. *The American Cartographer*. 14, 345–358 (1987).
28. Lutz, M.: *Learning Python*. O'Reilly (2009).
29. R Development Core Team: *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Viena, Austria (2013).
30. Pebesma, E.J.: Multivariable geostatistics in S: the gstat package. *Computers & Geosciences*. 30, 683–691 (2004).
31. Bivand, R.S., Pebesma, E.J., Gómez-Rubio, V.: *Applied Spatial Data Analysis with R*. Springer, New York, USA (2008).
32. Maechler, M., Rousseeuw, P., Struyf, A., Hubert, M., Hornik, K.: *cluster: Cluster Analysis Basics and Extensions*. (2012).
33. Gamer, M., Lemon, J., Fellows, I., Pususpendra, S.: *irr: Various Coefficients of Interrater Reliability and Agreement*. (2012).