

**UNIVERSIDAD DE LA REPÚBLICA  
FACULTAD DE AGRONOMÍA**

**COMPARACIÓN DE MODELOS DE ANÁLISIS Y SIMULACIÓN  
DE DISEÑOS EXPERIMENTALES EN EL CULTIVO DE ARROZ**

**por**

**Natalia Madelaine BERBERIAN BAKERDJIAN**

TESIS presentada como uno de los  
requisitos para obtener el título de  
*Magister* en Ciencias Agrarias  
opción Bioestadística

**MONTEVIDEO  
URUGUAY  
Marzo 2016**

Tesis aprobada por el tribunal integrado por la Ing. Agr. (Dra) Mónica Cadenazzi, la Ing. Agr. (Mag) Alejandra Borges, y el Ing. Agr. (MSc) Pedro Blanco, el 1 de Marzo de 2016. Autora: Lic. en Estadística Natalia Berberian. Directora Ing. Agr. (PhD) Lucía Gutiérrez, Co-directora Ing. Agr. Lic. Bioq. (Dra) Victoria Bonnecarrère.

Para Fernando Massa, quien en busca de su felicidad me ayudó a encontrar la mía.

## **AGRADECIMIENTOS**

Quisiera agradecer a todos quienes colaboraron en este proceso de aprendizaje que cambió mi vida tanto a nivel personal como profesional. Primeramente agradezco a mi tutora, Lucía Gutiérrez, por ser siempre mi guía, brindando generosamente todo su tiempo y conocimiento en cada etapa de este proceso y respetando siempre mis tiempos. También agradezco a mi cotutora, Victoria Bonnecarrère, por convencerme de arrimarme al vasto mundo del cultivo de arroz, por brindarme su apoyo invaluable y por tenerme mucha paciencia en cada instancia del proceso. Gracias a ambas por confiar en que podría llevar adelante esta tarea. Agradezco a los integrantes del tribunal, Mónica Cadenazzi, Alejandra Borges y Pedro Blanco por ayudarme desde un comienzo, aportando tanto en la interpretación como en la discusión de los resultados haciendo más sencilla la ejecución de esta tesis. Agradezco a mis compañeros del Departamento de Biometría, Estadística y Computación de Facultad de Agronomía, por compartir desinteresadamente sus conocimientos conmigo y por brindarme su apoyo diariamente. En especial a Sofía, Bettina, Analía, Juan, Andrea, Virginia y Alejandra darme siempre los mejores consejos que un amigo puede dar. Un agradecimiento muy especial a mi familia, a mis padres y a mi hermana, por quererme y apoyarme incondicionalmente, por ayudarme a encontrar la mejor solución en cada situación y por respetar siempre todas mis decisiones. Finalmente quiero agradecerle a Fernando por ser mi pilar y mejor amigo, por ayudarme a recuperar la calma y serenidad que muchas veces pierdo y por sobre todo le agradezco que elija caminar a mi lado todos los días, haciéndome reír a cada paso.

## TABLA DE CONTENIDO

	Página
PÁGINA DE APROBACIÓN.....	II
AGRADECIMIENTOS.....	III
RESUMEN .....	VI
SUMMARY.....	VII
<b>1. <u>INTRODUCCIÓN</u> .....</b>	<b>1</b>
<b>1.1. DISEÑOS EXPERIMENTALES Y ESTADÍSTICA ESPACIAL .....</b>	<b>3</b>
<b>1.1.1. <u>Diseño experimental</u>.....</b>	<b>3</b>
<b>1.1.2. <u>Estadística espacial</u>.....</b>	<b>4</b>
<b>1.2. HIPÓTESIS Y OBJETIVOS.....</b>	<b>6</b>
<b>2. <u>MODEL COMPARISON AND EXPERIMENTAL DESIGN SIMULATION</u></b>	
<b><u>INCLUDING NATURAL FIELD VARIABILITY IN RICE CROP (<i>Oryza Sativa L.</i>).....</u></b>	<b>8</b>
<b>2.1. ABSTRACT.....</b>	<b>8</b>
<b>2.2. INTRODUCTION.....</b>	<b>9</b>
<b>2.3. MATERIALS AND METHODS.....</b>	<b>10</b>
<b>2.3.1. <u>Material and Phenotyping</u>.....</b>	<b>10</b>
<b>2.3.2. <u>Field Analysis - Model Comparison</u>.....</b>	<b>12</b>
<b>2.3.3. <u>Experimental Design Comparison based on Simulation</u>.....</b>	<b>14</b>
<b>2.3.3.1. Field and Spatial Variability.....</b>	<b>14</b>
<b>2.3.3.2. Methodology of Simulation.....</b>	<b>15</b>
<b>2.3.3.3. Experimental Design Simulation.....</b>	<b>15</b>
<b>2.4. RESULTS.....</b>	<b>18</b>
<b>2.4.1. <u>Model Comparison Analysis</u>.....</b>	<b>18</b>
<b>2.4.2. <u>Experimental Design Comparison based on Simulation</u>.....</b>	<b>20</b>
<b>2.5. DISCUSSION.....</b>	<b>29</b>
<b>2.5.1. <u>Model Comparison Analysis</u>.....</b>	<b>29</b>
<b>2.5.2. <u>Experimental Design Comparison based on Simulation</u>.....</b>	<b>30</b>

<b>2.6. REFERENCES.....</b>	<b>33</b>
<b>3. <u>DISCUSIÓN GENERAL Y CONCLUSIONES .....</u></b>	<b>39</b>
<b>3.1. COMPARACIÓN DE MODELOS DE ANÁLISIS.....</b>	<b>39</b>
<b>3.2. COMPARACIÓN DE DISEÑOS EXPERIMENTALES BASADOS         EN SIMULACIÓN.....</b>	<b>41</b>
<b>4. <u>BIBLIOGRAFÍA .....</u></b>	<b>46</b>

## RESUMEN

La brecha de producción entre los mejores productores del cultivo de arroz y el rendimiento potencial de las variedades uruguayas es muy estrecha por lo que generar cultivares nacionales de mayor rendimiento y mejor calidad de grano es un gran desafío para los programas de mejoramiento genético nacionales. La obtención de estimaciones precisas depende del modelo de análisis así como de los diseños experimentales implementados. Los objetivos del trabajo fueron: comparar diferentes modelos de análisis que consideren en mayor o menor medida la heterogeneidad espacial del suelo; y simular diseños experimentales alternativos para las condiciones de suelo del campo experimental a partir del kriging de la heterogeneidad natural del suelo. Para llevar a cabo los objetivos del trabajo se contó con una población de aproximadamente 1000 líneas avanzadas de sp. *O. sativa* L. ssp *indica* y *O. sativa* L. ssp. *japonica*, en etapas finales de evaluación del programa de mejoramiento del Instituto Nacional de Investigación Agropecuaria (INIA). Las evaluaciones se realizaron en la Estación Experimental del departamento de Treinta y Tres en las zafras 2010-11, 2011-12 y 2012-13. En base a la comparación de modelos de análisis se concluye que el postblocking, considerando la ubicación en el campo a través de ensayos o posición según fila-columna, mejora las estimaciones de las medias de tratamientos. Asimismo se llega a la conclusión de que para este cultivo y bajo las condiciones de manejo típicas en Uruguay, proponer diseños experimentales más complejos no aporta en términos de eficiencia, sin embargo incluir algún componente de ajuste espacial en el modelo de análisis es crucial para obtener mejores estimaciones de medias de tratamientos. Los resultados a los que se llegó con este trabajo pueden contribuir a los programas de mejoramiento del cultivo de arroz nacionales en cuanto al enfoque de análisis. Se considera que este trabajo aporta una primera aproximación a las metodologías requeridas para trabajar con este cultivo de tanta relevancia a nivel nacional como mundial.

**Palabras clave:** ajuste espacial, diseños experimentales, kriging, arroz.

## **MODEL ANALYSIS COMPARISON AND EXPERIMENTAL DESIGN SIMULATION IN RICE CROP**

### **SUMMARY**

The gap between the best rice producers and the potential yield of Uruguayan varieties is very narrow; therefore, generating higher yielding cultivars with better grain quality is a major challenge for national breeding programs. Accurate estimations depend both on the model of analysis as well as the experimental designs implemented. The objectives of the study were: to compare different models of analysis that consider the soil spatial heterogeneity; and to simulate alternative experimental designs for the experimental field conditions from kriging of the natural soil heterogeneity. To achieve both objectives, we worked on a population of about 1000 advanced lines of sp. *O. sativa* L. ssp. *indica* and *O. sativa* L. ssp. *japonica*, in the final stages of evaluation of the breeding program at the National Institute of Agronomic Research (INIA). The phenotypic data was obtained in the experimental station of Treinta y Tres, during years 2010-11, 2011-12 and 2012-13. Based on model comparison, we concluded that postblocking, considering location either by taking into consideration the trial of evaluation or row-column position, improves means estimations. Moreover, we concluded that complex experimental designs do not provide gain in terms of efficiency, at least not for rice under typical management of the crop in Uruguay, however including some kind of spatial adjustment in the analysis model is crucial to obtain better estimations of means of treatments. These results can contribute to the national rice breeding programs in terms of defining the most appropriate analysis approach. We consider that this work helps to understand the methodologies required to work with this crop of such importance both nationally and globally.

**Keywords:** spatial analysis, experimental design, kriging, rice.

## **1. INTRODUCCIÓN**

El arroz (*Oryza sativa* L.) es el cereal de consumo humano directo más importante a nivel mundial y es la base nutricional de más del 50% de la población en todo el mundo (IRRI, 2006). Es una especie cultivada en todos los continentes, en más de 100 países y se extiende desde las latitudes 50°N hasta 40°S, pudiendo ser sembrada tanto a nivel del mar como a una altitud de 3000 metros (Juliano, 1993). La ubicación geográfica de Uruguay, entre los 30° y 35° latitud sur y entre 53°y 58° de longitud oeste, su terreno con alturas que no superan los 514 metros sobre el nivel del mar y su clima típicamente subtropical templado, le confieren las condiciones óptimas para cultivar cualquiera de las dos subespecies cultivadas en América del Sur, Indica (*Oryza sativa* L. ssp. *indica*) y Japonica (*Oryza sativa* L. ssp. *japonica*) (Glaszmann *et al.*, 1987; Oka, 1988; Mackill y Lei, 1997; Baruah *et al.*, 2009). La subespecie índica de grano largo usualmente se encuentra en regiones tropicales y subtropicales en tierras de baja altitud mientras que la subespecie Japonica, generalmente de grano medio-corto, suele hallarse en regiones de clima templado con terrenos un poco más elevados (Khush, 1997). Estas subespecies pueden ser fácilmente identificables desde el punto de vista morfológico, fisiológico y genético y se desarrollan en regiones con condiciones climáticas diferentes, sin embargo ambas son adecuadas para las condiciones de clima y suelo uruguayos (Oka, 1988; Mackill y Lei, 1997; Garris *et al.*, 2005).

Durante la zafra 2014/15 la producción mundial de este cereal fue de un poco más de 478 millones de toneladas y se estima que para el 2015/16 se alcanzará una producción global de 474.02 millones de toneladas, no obstante, el consumo y uso residual de este cultivo se estima supere dicha producción alcanzando los 482.9 millones de toneladas, excediendo ampliamente el consumo registrado en años anteriores (USDA, 2015; USDA, 2016). En este marco es que Uruguay se afianza en el mercado arrocero como el primer país exportador en América Latina, el octavo a nivel mundial y como el tercero en términos productivos en el mundo (IRRI, 2012; FAO, 2015). En la zafra 2014/15 se estima que fueron sembradas 160,7 mil hectáreas

a nivel nacional y la producción fue estimada en 1.396 miles de toneladas, alcanzando un rendimiento promedio de 8.686 kilos por hectárea, sin embargo esta relación de aproximadamente 8000 kilos promedio por hectárea sembrada se mantiene constante a lo largo de los últimos años (DIEA, 2015). Aproximadamente 95% de la producción se destina a la exportación, principalmente a los países asiáticos Irán e Irak y a los países del cono sur Brasil y Perú (IRRI, 2012). Los registros indican que el valor provisorio de la zafra 2013/14 fue 13,19 dólares por bolsa de 50 kilos, lo que genera ingresos al país por aproximadamente 400 millones de dólares en el año (OPYPA, 2015; DIEA, 2014).

Los elevados niveles de rendimientos en Uruguay pueden ser explicados por el mejoramiento genético con variedades de alto potencial y por las prácticas de manejo aplicadas. Estas implican siembra en seco y riego por inundación definitiva a partir de los 30 a 40 días desde la emergencia hasta alcanzar la madurez fisiológica así como la rotación con pasturas. Generalmente se hace la rotación con pasturas en ciclos de 5 años de los cuales uno o dos son de producción de arroz y los otros tres o cuatro son de pastoreo (ACA, 2009; DIEA, 2014). Esta es una práctica única a nivel mundial puesto que en el resto del mundo este cultivo se trabaja como monocultivo o como parte de una rotación de cultivos. No obstante, el sistema peculiar de rotación cultivo-pastura de nuestro país resulta ser el más sustentable, de menor intensidad e impacto ambiental, presentando mejoras en las propiedades físicas, químicas y biológicas del suelo debido a que éste es utilizado únicamente un 20% o 30% del tiempo para el cultivo (INIA, 1993; ACA, 2009; INIA, 2009; ACA, 2013).

Asimismo, la clave del éxito del sistema productivo arrocero nacional se debe por un lado a la integración vertical, que genera seguridad de comercialización para los agentes productores, ya que se realiza con un precio mínimo garantido y bajo contrato con los molinos. Por otro lado, el transparente relacionamiento entre productores, empresas molineras e investigadores, permite que el proceso se fortalezca en cada una de las etapas que lo conforman, ya sea proporcionando información de las condiciones de campo, brindando accesibilidad a las técnicas de

manejo pioneras en el mundo u ofreciendo las mejores semillas que puedan ser sembradas en las condiciones de suelo nacional (IRRI, 2012).

## **1.1. DISEÑOS EXPERIMENTALES Y ESTADÍSTICA ESPACIAL**

La selección de variedades con mayor desempeño a nivel nacional puede verse afectada por la denominada micro variación de los suelos, es decir, por las prácticas de manejo aplicadas al terreno y por la variación en las propiedades de los suelos, variaciones que se dan a pequeñas distancias en los terrenos. La micro variación puede reflejarse en una alta autocorrelación espacial de los suelos que se traduce en variabilidad en los rendimientos así como en otros caracteres de interés de los cultivos (Grondona *et al.*, 1996; Mulla y McBratney, 2002; Roel y Terra, 2006). Este tipo de variación puede ser controlada a través de diseños experimentales óptimos para las condiciones de suelo.

### **1.1.1. Diseño experimental**

Un buen diseño de experimento debe respetar los tres principios propuestos por R.A. Fisher en 1935; aleatorización, repetición y control local de la variación. Si bien los dos primeros pueden cumplirse fácilmente ya que el investigador puede asegurarse de ello teniendo en cuenta las unidades experimentales disponibles y la cantidad de tratamientos a comparar, el supuesto de control local implica asumir independencia estadística entre los errores de las unidades experimentales. Debido a la micro variación existente en los suelos del Uruguay, mantener vigente este supuesto se torna irreal y por lo tanto tener en cuenta información de las propiedades del suelo en el diseño experimental resulta necesario (Bhatti *et al.*, 1991; Grondona *et al.*, 1996; Mulla y McBratney, 2002; Roel y Terra, 2006). Usualmente el control local de la variabilidad es tomado en cuenta a la hora de proponer los diseños experimentales y los diseños de experimentos más utilizados en las ciencias agrarias por su práctica

implementación son el Diseño Completamente al Azar (DCA) y el Diseño en Bloques Completos al Azar (DBCA) (Borges *et al.*, 2014). Implementar diseños con mayor control de la variabilidad espacial como el Diseño en Bloques Incompletos (DBI) es recomendado en algunas situaciones, aunque esto implica un mayor grado de complejidad en la implementación y en el análisis (Brownie *et al.*, 1993). Sin embargo en el caso de ensayos de evaluación de cultivares, caracterizados por contar con un gran número de tratamientos y por el objetivo de detectar diferencias significativas muy pequeñas, el uso de mejores diseños experimentales así como mejores modelos de análisis es necesario (Casler y Undersander, 2000). Los ensayos de uniformidad son útiles para cuantificar la variabilidad del suelo puesto que son ensayos en los que se siembra una única variedad y se aplican prácticas de manejo uniformes por lo que estos ensayos permiten atribuir las diferencias halladas fundamentalmente a la heterogeneidad del suelo. Sin embargo los ensayos de uniformidad tienen la desventaja de ser muy costosos (Koch y Rigney, 1951). Por otro lado la heterogeneidad espacial puede ser estimada aplicando técnicas de estadística espacial, específicamente la geoestadística (Webster y Oliver, 2007).

### **1.1.2. Estadística espacial**

Con el término geoestadística se hace referencia a una de las tres ramas de la estadística espacial (Cressie, 1993) en la que los datos son una muestra finita de valores de medición que corresponden a un fenómeno espacial de tipo continuo. Actualmente la geoestadística es utilizada en muchas áreas de aplicación, bastante alejadas del contexto de minería en que fue inicialmente desarrollada (Diggle y Ribeiro, 2007). Esta rama aplicada de la estadística se encuentra muy relacionada con los métodos clásicos de interpolación, pero se extiende más allá del problema de interpolar valores. La geoestadística considera el estudio del fenómeno de interés en zonas no relevadas como un conjunto de variables aleatorias correlacionadas y se enfoca en la predicción de las mismas. A su vez permite cuantificar la dependencia y estructura espacial, utilizando esta estructura para la predicción de valores en

regiones no muestreadas. Estos dos pasos implican por un lado la modelación espacial (a través de un semivariograma) y la interpolación espacial (kriging) (Mulla y McBratney, 2002). El semivariograma es una descripción matemática de la relación entre la varianza entre pares de observaciones, es decir puntos de datos, y la distancia que separa a esos puntos (Best y León, 2006) y kriging es el método fundamental de la geoestadística, equivalente a la predicción que minimiza el error cuadrático medio bajo un modelo gaussiano con parámetros conocidos (Watson, 1971; Watson, 1972; Ripley, 1981). Comúnmente son utilizados como modelos de ajuste para el semivariograma empírico el modelo Esférico, el Gaussiano, el Exponencial, el Cauchy y el Estable (Cressie, 1993) y posteriormente se procede a realizar el kriging, la predicción del valor de la variable en estudio para los sitios no muestreados utilizando información recabada en sitios vecinos (Wollenhaupt *et al.*, 1997).

Las técnicas de interpolación, como por ejemplo el kriging, son implementadas con la finalidad de generar mapas de las variables de interés, transformando datos puntuales que provienen de las zonas muestreadas en variables continuas. Para que la interpolación de la información sea posible es necesario que los valores de las variables en estudio se encuentren asociados espacialmente, lo que comúnmente se denomina autocorrelación. La autocorrelación puede definirse como la correlación de una variable con respecto a sí misma, a través del espacio (Best y León, 2006). En geoestadística los objetivos de la determinación de la autocorrelación para las variables en estudio corresponden por un lado a la medición de la fuerza de la autocorrelación espacial dentro de un mapa y por otro lado a probar el supuesto de independencia o aleatoriedad en los datos. Aplicando diversos índices de autocorrelación que permitan determinar la existencia de asociación espacial entre los valores de la variable en estudio se pueden aplicar técnicas de modelaje superficial a través de la interpolación espacial. Los factores que afectan en mayor medida el mapeo de las condiciones de suelo son el número de muestras tomadas, la distancia entre ellas y el método de interpolación utilizado para convertir muestreos discretos en continuos (Kravchenko *et al.*, 2006). La dependencia entre los valores

encontrados, en función de la distancia que separa las muestras se determina a través de la construcción de un semivariograma (Goovaerts, 1999).

En el Uruguay se han realizado varios trabajos con la finalidad de identificar los principales factores que afectan la variación de los rendimientos dentro de las chacras, principalmente de cultivos de secano, encontrando que los factores más relacionados con la variación del rendimiento son los atributos edáficos y topográficos relacionados con la dinámica superficial del agua y capacidad de almacenamiento de la misma en el suelo (Hill *et al.*, 2008; Pravia, 2009). Específicamente, en chacras comerciales de arroz, factores de manejo como lámina de agua y nivel de enmalezamiento, están muy relacionados con la variación de rendimiento del cultivo (Roel *et al.*, 2007; Bonilla *et al.*, 2015).

## **1.2. HIPÓTESIS Y OBJETIVOS**

En los programas de mejoramiento se compara un gran número de tratamientos y por lo tanto seleccionar el diseño experimental adecuado es una tarea compleja. El programa de mejoramiento nacional de arroz, llevado a cabo por el Instituto Nacional de Investigación Agropecuaria (INIA), utiliza actualmente un conjunto de ensayos en un DBCA y luego conecta estos ensayos con testigos repetidos en cada uno de los ellos. Existen varios estudios que respaldan la ventaja del uso de diseños más complejos como el  $\alpha$ -lattice (Brownie *et al.*, 1993) para evaluar un gran número de tratamientos, sin embargo no se conoce la variabilidad natural en ensayos de arroz por lo que se desconoce si estos diseños son ventajosos. El diseño experimental implementado por el INIA permite construir mapas que provean información sobre la variabilidad natural del campo experimental a partir de los resultados de las variedades testigos y de este modo incorporar esta información en el análisis de datos. Por lo tanto es de interés para el programa de mejoramiento, por un lado, la comparación de modelos de análisis que consideraran en mayor o menor medida la

variabilidad espacial existente en el campo, y por otro la simulación de diseños experimentales alternativos bajo estas condiciones de suelo.

Las hipótesis de este trabajo de tesis fueron: (1) incluir una corrección espacial en el análisis de los modelos puede mejorar la precisión de las estimaciones de las medias de los tratamientos evaluados; y (2) la simulación de diseños experimentales, utilizando la variabilidad natural del campo experimental, permite discriminar y evaluar los diseños experimentales en su habilidad para estimar las medias de los tratamientos.

Los objetivos planteados en esta tesis fueron: (1) comparar diferentes modelos de análisis que consideren en mayor o menor medida la heterogeneidad espacial natural del suelo; y (2) simular diseños experimentales alternativos para las condiciones naturales de suelo del campo experimental de INIA.

**2. MODEL COMPARISON AND EXPERIMENTAL DESIGN SIMULATION**  
**INCLUDING NATURAL FIELD VARIABILITY IN RICE CROP (*Oryza***  
***Sativa L.*)<sup>1</sup>**

**Berberian Natalia, Victoria Bonnecarrère, Pedro Blanco, Fernando Pérez de Vida, Juan Rosas, Sebastián Martínez, Borges Alejandra, Cadenazzi Mónica, Gutiérrez Lucía**

**2.1. ABSTRACT**

Rice (*Oryza sativa*, L.) is not only the most important cereal crop for direct human consumption worldwide but also it is the nutritional base for more than half of the global population. Reducing the gap between the best rice producers and the potential yield of varieties is a major challenge for breeding programs. Accurate estimations depend both on the model of analysis as well as the experimental designs implemented in the field. The objectives of this work were to compare different models of analysis that consider the soil spatial heterogeneity; and to simulate alternative experimental designs for the experimental field conditions from kriging the natural soil heterogeneity. To achieve both objectives we worked on a population of about 1000 advanced inbred lines of sp. *O. sativa L.*, ssp *indica* and *O. sativa L.*, ssp. *japonica*, from the Uruguayan National Breeding Program. Phenotypic data was obtained during years 2011, 2012 and 2013. Postblocking, considering location either by taking into consideration the trial of evaluation or row-column position, improves means estimations. Complex experimental designs do not provide any gain in terms of efficiency, at least not for this cereal under typical management of the crop in Uruguay, however including spatial adjustment in the analysis model is crucial to obtain better estimations of means of treatments.

---

<sup>1</sup> Artículo a publicar en: Crop Science Society of America

## **2.2. INTRODUCTION**

Rice (*Oryza sativa*, L.) is not only the most important cereal crop for direct human consumption worldwide but also it is the nutritional base for more than half of the global population (IRRI, 2006). Global production reached approximately 478 million ton in 2014/2015 and is expected to continue growing steadily while consumption is expected to exceed this production (USDA, 2015; USDA, 2016). To meet this demand high yield varieties of good quality need to be developed. For breeding programs it is absolutely relevant to design precise trials so there is a certain guaranty that the varieties selected at the beginning of the program, varieties which will be evaluated on the successive years, are the best in terms of the traits of interest. Since the postulation of R.A. Fisher (1935) of the three basic principles in which every experiment should be based on randomization, replication, and local control, many designs have been developed respecting them. Due to simplicity in implementation and analysis, completely randomized design (CRD) and randomized complete block design (RCBD) are the most considered designs in agricultural experimentation (Brownie *et al.*, 1993; Borges, *et al.*, 2014). Although incomplete block designs (IBD) have better local control, and for that reason are more adequate in some soils conditions (Brownie *et al.*, 1993), they imply a more difficult practical and analytical execution.

Due to micro variation in soil properties and management practices applied to the fields more complex designs are required and therefore including information of the field in the design and analysis is suggested (Mulla and McBratney, 2002; Roel and Terra, 2006; Grondona *et al.*, 1996). Identification of spatial variability, represented by clear patterns in the fields, turns the assumption of independent errors no longer valid (Bhatti *et al.*, 1991). Controlling spatial variability by experimental designs is not always possible (Grondona and Cressie, 1991) causing experimental errors overestimation and therefore reducing the precision of the estimations of treatments effects (Bishop and Lark, 2006). Hence the study of this variability is essential and

could be approached by the inclusion of spatial adjustment in the analysis model (Borges *et al.*, 2014).

Spatial variability generally is the result of complex processes working simultaneously in a certain period of time (Hengl, 2009). Variability in data could be interpretive as the sum of natural spatial variation and experimental error (Burrough and McDonnell, 1998). Assuming measurement errors are ideally minimized then natural spatial variation, mainly due to physical processes, is the objective of geostatistical analysis. Spatial interpolation, frequently known as kriging, provides a shortcut in terms of measurement since from a considerable small number of spots relieved, natural field heterogeneity maps could be elaborated. Spatial patterns on how values vary might appear, showing that nearest observations are more alike than apart ones. To determine how much importance should be given to each neighbor, semivariances differences between neighbors are estimated (Hengl, 2009).

The objective of this work was to compare different experimental designs under spatial variability field conditions by the implementation of simulation as well as to compare classical analysis methodology against geostatistical approach.

## 2.3. MATERIALS AND METHODS

### 2.3.1. Material and Phenotyping

A population of approximately 1000 advanced inbred lines of *Oryza Sariva* L. subspecies Indica and Japonica, from the national breeding program of the National Institute of Agronomic Research (INIA), were used. The experimental station is located in the north-east region of Uruguay, in Treinta y Tres ( $33^{\circ} 13' 51''$  Latitude South,  $54^{\circ} 22' 56''$  Longitude West). Lines were evaluated during 2011, 2012 and 2013 growing season for eight traits. A series of Randomized Complete Block

Designs (RCBD) trials were conducted, each one consisting on approximately of 35 lines with two or three replications and repeated checks (Table 1).

Table 1: Detail of checks used in each trial, total number and identification, number of lines and number of replications for each year and subspecie evaluated in the field

Subspecie	Year	#Lines	#Trials	#Rep	#Total Rep	#Checks	INIA El Paso 144	INIA Olimar	6 other checks	5 other checks	3 other checks
Indica	2011	1152	24	2	48	8	X	X	X		
	2012	384	12	3	36	2	X	X			
	2013	384	12	3	36	2	X	X			
Japonica	2011	824	16	3	48	10	X	X		X	
	2012	402	10	3	30	11	X	X		X	X
	2013	402	10	3	30	11	X	X		X	X

Eight agronomical traits were evaluated: *Yield after milling* (YAM) which is the percentage of polished white rice obtained from 100g of paddy rice dried to 13% of moisture, husked and polished; *Grain Chalkiness* (GC) measured as the percentage of grains that present more than 50% of their area with chalky aspect, this means with a white pale color; *Percentage of Head Rice* (PHR), measured from the proportion of grains that remain whole after milling; *Plant Height* (PH) measured in cm from base to flag leaf between anthesis and harvest time and *Days to Flowering* (DF) measured since sowing until 50% of the plot reaches flowering time. Also were evaluated *Grain Yield* (GY) weighted in kg ha<sup>-1</sup>, and two of the main diseases that affect both rice sheath and stem, Rhizoctonia and Sclerotium, both measured in a scale of 0 to 9 according to the incidence of the diseases in the steams; 0 representing absence of symptom and 9 that at least 80% of steams observed were affected by the diseases.

### **2.3.2. Field Analysis - Model Comparison**

For each one of the traits evaluated, three models with increased degree of spatial variability adjustment were compared. The first model consisted on an individual analysis by trial:

$$[1] \quad y_{jm} = \mu + \beta_j + \gamma_m + \varepsilon_{jm}$$

where  $y_{jm}$  is the response variable,  $\mu$  is the overall mean,  $\beta_j$  is the j-th block effect ( $j=1,2,\dots,\#Total\ Rep$ , Table1),  $\gamma_m$  is the m-th advanced in breed line (genotype), and  $\varepsilon_{jm}$  is the residual error associated to each experimental unit with  $\varepsilon_{jm} \sim N(0, \sigma_\varepsilon^2)$ .

The second model proposed a joint analysis of trials with a spatial adjustment by trial:

$$[2] \quad y_{ijm} = \mu + \underline{\lambda_i} + \underline{\beta_{j(i)}} + \gamma_m + \varepsilon_{ijm}$$

$y_{ijm}$ ,  $\mu$ ,  $\gamma_m$  and  $\varepsilon_{ijm}$  defined as in [1],  $\lambda_i$  is a random effect associated to the i-th trial with  $\lambda_i \sim N(0, \sigma_\lambda^2)$ , and  $\beta_{j(i)}$  is the random effect of the j-th block nested in the i-th trial,  $\beta_{j(i)} \sim N(0, \sigma_\beta^2)$ .

The third model considered the joint analysis of the trials with a spatial correction due to position of rows and columns in the field:

$$[3] \quad y_{ijklm} = \mu + \underline{\lambda_i} + \underline{\beta_{j(i)}} + \underline{\eta_{k(i)}} + \underline{\kappa_{l(i)}} + \gamma_m + \varepsilon_{ijklm}$$

$y_{ijklm}$ ,  $\mu$ ,  $\lambda_i$ ,  $\beta_{j(i)}$ ,  $\gamma_m$  and  $\varepsilon_{ijklm}$  as in [1] and [2],  $\eta_{k(i)}$  is the random effect associated to the k-th row in the i-th trial,  $\eta_{k(i)} \sim N(0, \sigma_\eta^2)$ , and  $\kappa_{l(i)}$  is the random effect associated to the l-th column in the i-th trial,  $\kappa_{l(i)} \sim N(0, \sigma_\kappa^2)$ .

Moreover, a Gridding of Treatments (GOT) was elaborated to compare the proposed models. This process implied an individual analysis by trial conducted in a RCBD with associated model:

$$[4] \quad y_{jm} = \mu + \beta_j + \gamma_m + \varepsilon_{jm}$$

where  $y_{jm}$  is the response variable *Grain Yield*,  $\mu$  is the overall mean,  $\beta_j$  is the j-th block effect,  $\gamma_m$  is the m-th advanced in breed line (genotype), and  $\varepsilon_{jm}$  is the residual error associated to each experimental unit with  $\varepsilon_{jm} \sim N(0, \sigma_\varepsilon^2)$ . Once estimated the means of treatments these were weighted as a ratio respect to the repeated checks and the ranking of treatments was built based on this percentage.

As Maximum Likelihood Estimation (MLE) method was implemented  $\left[ \{\hat{\theta}_{mle}\} \subseteq \left\{ \arg \max_{\theta \in \Theta} \hat{l}(\theta; x_1, \dots, x_n) \right\} \right]$  being  $\hat{l}(\theta; x_1, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n \ln f(x_i | \theta)$ , the Bayesian Information Criterion (BIC)  $\left[ BIC = -2 \log(L(\theta/x)) + \log(n)k \right]$  was used as goodness of fit measure, where  $L(\theta/x)$  is the maximized value of the likelihood function of the model,  $k$  the number of free parameters to be estimated and  $n$  the number of observations. Minimum values of this fit statistic indicate the preferred statistical model. The performances of the models were also evaluated by effect of the models on the modifications of the Ranking of Treatments (ROT), based on Grain Yield performance, compared with the performance of the best model identified by the BIC goodness of fit measure.

### **2.3.3. Experimental Design Comparison based on Simulation**

#### **2.3.3.1. Field and Spatial Variability**

Values for the entire experimental field were interpolated by ordinary kriging procedure, based on the residuals of a simple model that considered only repeated checks. The model considered only the overall mean and the effect of the repeated checks, as follows:

$$[5] \quad y_{ij} = \mu + c_j + \varepsilon_{ij}$$

being  $y_{ij}$  the response variable,  $\mu$  the overall mean,  $c_j$  the j-th effect of the check, and  $\varepsilon_{ij}$  the residual error associated to each experimental unit,  $\varepsilon_{ij} \sim N(0, \sigma_\varepsilon^2)$ .

From the residuals of this model, spatial autocorrelations were studied estimating empirical semivariograms for several models. For semivariogram estimation isotropy was assumed and euclidean distance was used as a measure of distance among observations. Five of the most commonly used models were compared: Spherical, Gaussian, Exponential, Cauchy and Stable model (Cressie, 1993).

The selection of the best model was based on the Sum Squares Error (SSE) for the weighted least square fit of the semivariogram model. Interpolated values for all experimental fields were determined by kriging geostatistical technique using the best model for empirical semivariograms. Response maps for each variable were created assuming that these represented the natural heterogeneity of experimental field.

### 2.3.3.2. Methodology of Simulation

Experimental designs were simulated on top of the existing natural field heterogeneity (i.e. interpolated values for each plot) following Borges *et al.*, 2014. The procedure of analysis was as follows; based on the field maps obtained during the kriging procedure each experimental unit was assigned with a field spatial heterogeneity value ( $\kappa_{ij}$ ), afterwards values to each plot corresponding to the genotypic effect were added ( $\gamma_i$ ), hence this genotype effect was simulated as a centered normal distribution realization with  $\sigma_\gamma^2$  being the genotypic variance of the total genotypes evaluated in fields each year,  $\gamma_i \sim N(0, \sigma_\gamma^2)$ . Therefore the following model was used:

$$[6] \quad y_{ij} = \mu + \gamma_i + \varepsilon_{ij}$$

where  $y_{ij}$  is the response variable,  $\mu$  the overall mean,  $\gamma_i$  the i-th genotypic effect and  $\varepsilon_{ij}$  is the sum of  $\kappa_{ij}$ , the kriged value of the field spatial heterogeneity in each experimental unit, and  $\delta_{ij}$ , the residual error associated to each experimental unit,  $\delta_{ij} \sim N(0, \sigma_\delta^2)$ .

### 2.3.3.3. Experimental Design Simulation

For comparing the performance of different experimental designs four of the most commonly used designs were simulated using the natural field heterogeneity: first, a Completely Randomized Design (CRD) was used, with associated model:

$$[7] \quad y_{ij} = \mu + \tau_i + \varepsilon_{ij}$$

being  $y_{ij}$  the response variable,  $\mu$  the overall mean,  $\tau_i$  the effect of i-th genotype and  $\varepsilon_{ij}$  the residual error associated to each experimental unit,  $\varepsilon_{ij} \sim N(0, \sigma_\varepsilon^2)$ .

Second, a Randomized Complete Block Design (RCBD) with associated model:

$$[8] \quad y_{ij} = \mu + \tau_i + \beta_j + \varepsilon_{ij}$$

where  $y_{ij}$  is the response variable,  $\mu$  the overall mean,  $\tau_i$  the effect of i-th genotype,  $\beta_j$  the fixed effect of th j-th block and  $\varepsilon_{ij}$  the residual error associated to each experimental unit,  $\varepsilon_{ij} \sim N(0, \sigma_\varepsilon^2)$ .

Third, a Randomized Complete Block Design by Trial (RCBD-T) was simulated and the associated model for each trial was the same as for the RCBD.

Finally, an Incomplete Block Design – Alpha Lattice (IBD- $\alpha$ ) with associated model:

$$[9] \quad y_{ijk} = \mu + \tau_i + \beta_j + \gamma_{k(j)} + \varepsilon_{ijk}$$

being  $y_{ijk}$  the response variable,  $\mu$  the overall mean,  $\tau_i$  the effect of i-th genotype,  $\beta_j$  the j-th complete block effect,  $\gamma_{k(j)}$  the random effect of the k-th incomplete block nested on th j-th complete block,  $\gamma_{k(j)} \sim N(0, \sigma_\gamma^2)$  and  $\varepsilon_{ijk}$  the residual error associated to each experimental unit,  $\varepsilon_{ijk} \sim N(0, \sigma_\varepsilon^2)$ .

All four designs were analyzed both, with an uncorrelated error structure where  $\varepsilon \sim N(0, I\sigma_\varepsilon^2)$ , being  $e$  a vector of residual errors and  $I$  an identity matrix, and with

correlated residual errors where  $\varepsilon \sim N(0, R\sigma_\varepsilon^2)$ . The R matrix was obtained by the best adjusted empirical semivariogram for each situation, based on the criteria of minimizing the SSE, in the analysis model. Therefore the variance and covariance matrix (R) presented a structure as follows:

$$R = \begin{bmatrix} \sigma_{\varepsilon_1 \varepsilon_1} & \sigma_{\varepsilon_1 \varepsilon_2} & \cdots & \sigma_{\varepsilon_1 \varepsilon_n} \\ \sigma_{\varepsilon_2 \varepsilon_1} & \sigma_{\varepsilon_2 \varepsilon_2} & & \vdots \\ \vdots & \ddots & & \sigma_{\varepsilon_{n-1} \varepsilon_n} \\ \sigma_{\varepsilon_n \varepsilon_1} & \cdots & \sigma_{\varepsilon_n \varepsilon_{n-1}} & \sigma_{\varepsilon_n \varepsilon_n} \end{bmatrix}$$

being  $\sigma_{\varepsilon_i \varepsilon_j}$  the covariance between plots situated in locations  $i$  and  $j$ , and where  $\sigma_{\varepsilon_i \varepsilon_j} = C_1 + C_0 + \gamma(|i - j|)$ , with  $C_1$  being the partial sill of the semivariogram,  $C_0$  the nugget effect and  $\gamma(|i - j|)$  the semivariogram for the residuals  $\varepsilon_i$  y  $\varepsilon_j$ . Models including this variance-covariance matrix are call in this work as Spatial Models.

The randomization of the effects of the genotypes was done by one of the experimental designs indicated previously, using ‘agricolae’ package of Software R (de Mendiburu, 2012; R Core Team, 2012). For each year, subspecies and design a total of 1000 independent simulations were performed, considering a new randomization in each simulation, using packages ‘geoR’ and ‘nlme’ of Software R (Ribeiro and Diggle, 2001; Pinheiro *et al.*, 2013; R Core Team, 2012).

BIC was implemented as goodness of fit measures. The Root Mean Square Error (RMSE), the F-value of the statistic in the Analysis of Variance (ANOVA) and the Ranking of Treatments (ROT), based on Grain Yield performance, were used as accuracy statistics. For BIC and RMSE lower values of these statistics indicates the better model. For the F-value a higher value indicates more certainty of rejecting the null hypothesis of equal means, so the higher the value the better. Finally, the ROT refers to the ability of the model to recover the top 10 best genotypes.

## **2.4. RESULTS**

### **2.4.1. Model Comparison Analysis**

Based in BIC indicator, the model that proposed an individual analysis by trial considering as fixed effects both treatments and replications (M1), was not the best model in any case (Table 2). These results showed that considering certain spatial information generates better estimations of treatments yield means. Models than include spatial information were: M2 that proposed a joint analysis of trials with a spatial adjustment by trial, using information of the repeated checks; and M3 that considered a joint analysis of the trials with a spatial correction due to position of rows and columns in the field. The second model, M2, was the best model of analysis for both subspecies, in each year, for almost all traits considered in this study except for Grain Yield (GY) and Sclerotium (SCL), in those cases the best analysis model was M3. A singular case for GY trait is year 2012 for subspecie Japonica, since the best model is not M3 but M2.

Moreover, model comparison was performed based on modifications of the ROT (Figure 1). This procedure compared how many of the best 10 genotypes identified by the best model (according to BIC) were recovered by the other models proposed and by the Gridding of Treatments.

Table 2: BIC values for the comparison of models by trial (M1), joint analysis with spatial information by trial (M2), and joint analysis with spatial information by row-column position (M3), for each rice subspecies (Indica and Japonica), trait and year of evaluation in a panel of advanced inbred lines of rice.

		Indica			Japonica		
		M1	M2	M3	M1	M2	M3
2011	Grain Yield (GY)	44747	29199	<u>28553</u>	34574	<u>22546</u>	23071
	Yield after milling (YAM)	7995416	<u>7313952</u>	7794331	9479889	<u>8507472</u>	9012042
	% of Head Rice (PHR)	11504731	<u>9258549</u>	9695119	12630359	<u>10286816</u>	10836496
	Grain Chalkiness (GC)	13287648	<u>10168396</u>	10582998	10666989	<u>9196873</u>	9723612
	Plant Hight (PH)	-	-	-	14598	<u>11391637</u>	11856783
	Sclerotium (SCL)	-	-	-	9409193	8877560	<u>8489919</u>
	Rhizoctonia (ROS)	-	-	-	9513417	<u>8047171</u>	8430982
	Days to flowering (DF)	-	-	-	12293632	<u>9880225</u>	10304438
2012	Grain Yield (GY)	21601	16196	<u>16055</u>	17135	11861	<u>11704</u>
	Yield after milling (YAM)	4475684	<u>4343745</u>	4499474	3854337	<u>3660192</u>	3857855
	% of Head Rice (PHR)	7231483	<u>6246904</u>	6364001	5587689	<u>4723508</u>	4907910
	Grain Chalkiness (GC)	7412068	<u>6387740</u>	6545987	6273526	<u>5174914</u>	5387660
	Plant Hight (PH)	8556049	<u>7148508</u>	7297961	7241957	<u>5748652</u>	5941473
	Sclerotium (SCL)	6527513	6402039	<u>5812014</u>	4433665	<u>4039966</u>	4246935
	Rhizoctonia (ROS)	6623784	<u>5812014</u>	5979003	6126123	<u>5050072</u>	5247436
	Days to flowering (DF)	-	-	-	6414925	<u>5242642</u>	5428993
2013	Grain Yield (GY)	21327	15867	<u>15849</u>	21722	16478	<u>16442</u>
	Yield after milling (YAM)	7181097	<u>6154916</u>	6321936	6076808	<u>5593963</u>	5730463
	% of Head Rice (PHR)	8301109	<u>6973733</u>	7143578	7558941	<u>6604321</u>	6745694
	Grain Chalkiness (GC)	7305518	<u>6281052</u>	6449626	7158126	<u>6334640</u>	6557648
	Plant Hight (PH)	8700272	<u>7253274</u>	7424973	8903416	<u>7510556</u>	7647851
	Sclerotium (SCL)	4946444	4684258	<u>4672512</u>	4912033	4849162	<u>4732040</u>
	Rhizoctonia (ROS)	6126757	<u>5450835</u>	5608880	6427946	<u>5778737</u>	5925995
	Days to flowering (DF)	8001714	<u>6754941</u>	6910133	6801797	<u>6056248</u>	6180779

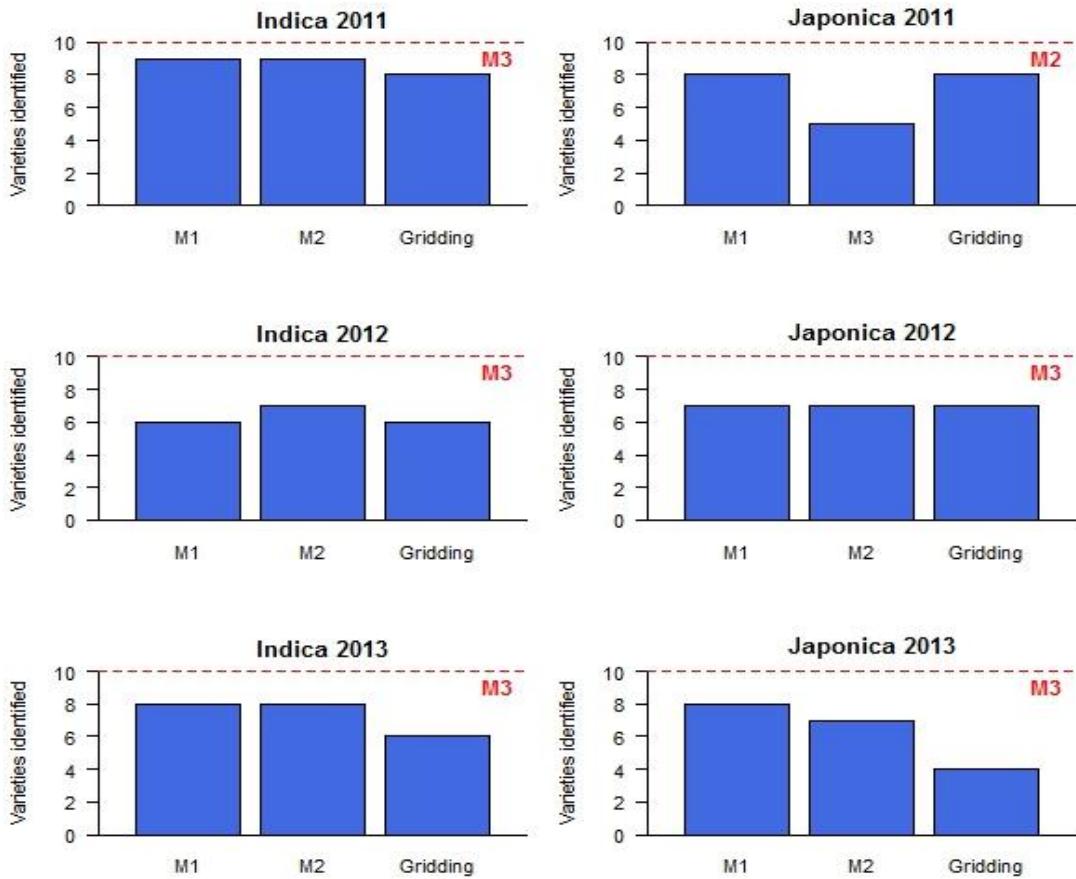


Figure 1: Recovery of the top 10 varieties identified by the best model (indicated in red), according to other models tested and the Gridding of Treatments (GOT) based on Grain Yield performance.

Excluding year 2011 for subspecies Indica, in which case all models as well as gridding of treatments had a great performance, the model selected as the best model by BIC statistic presented a superior performance in all cases in terms of identifying certain genotypes. GOT, which is a method that weighted estimations as a percentage regarding to the repeated checks, showed that as time goes by it recovers less of the top 10 genotypes.

#### **2.4.2. Experimental Design Comparison based on Simulation**

Residuals interpolation of repeated checks indicated that there is no strong spatial variability in field for the eight traits considered in this study (Figure 2).

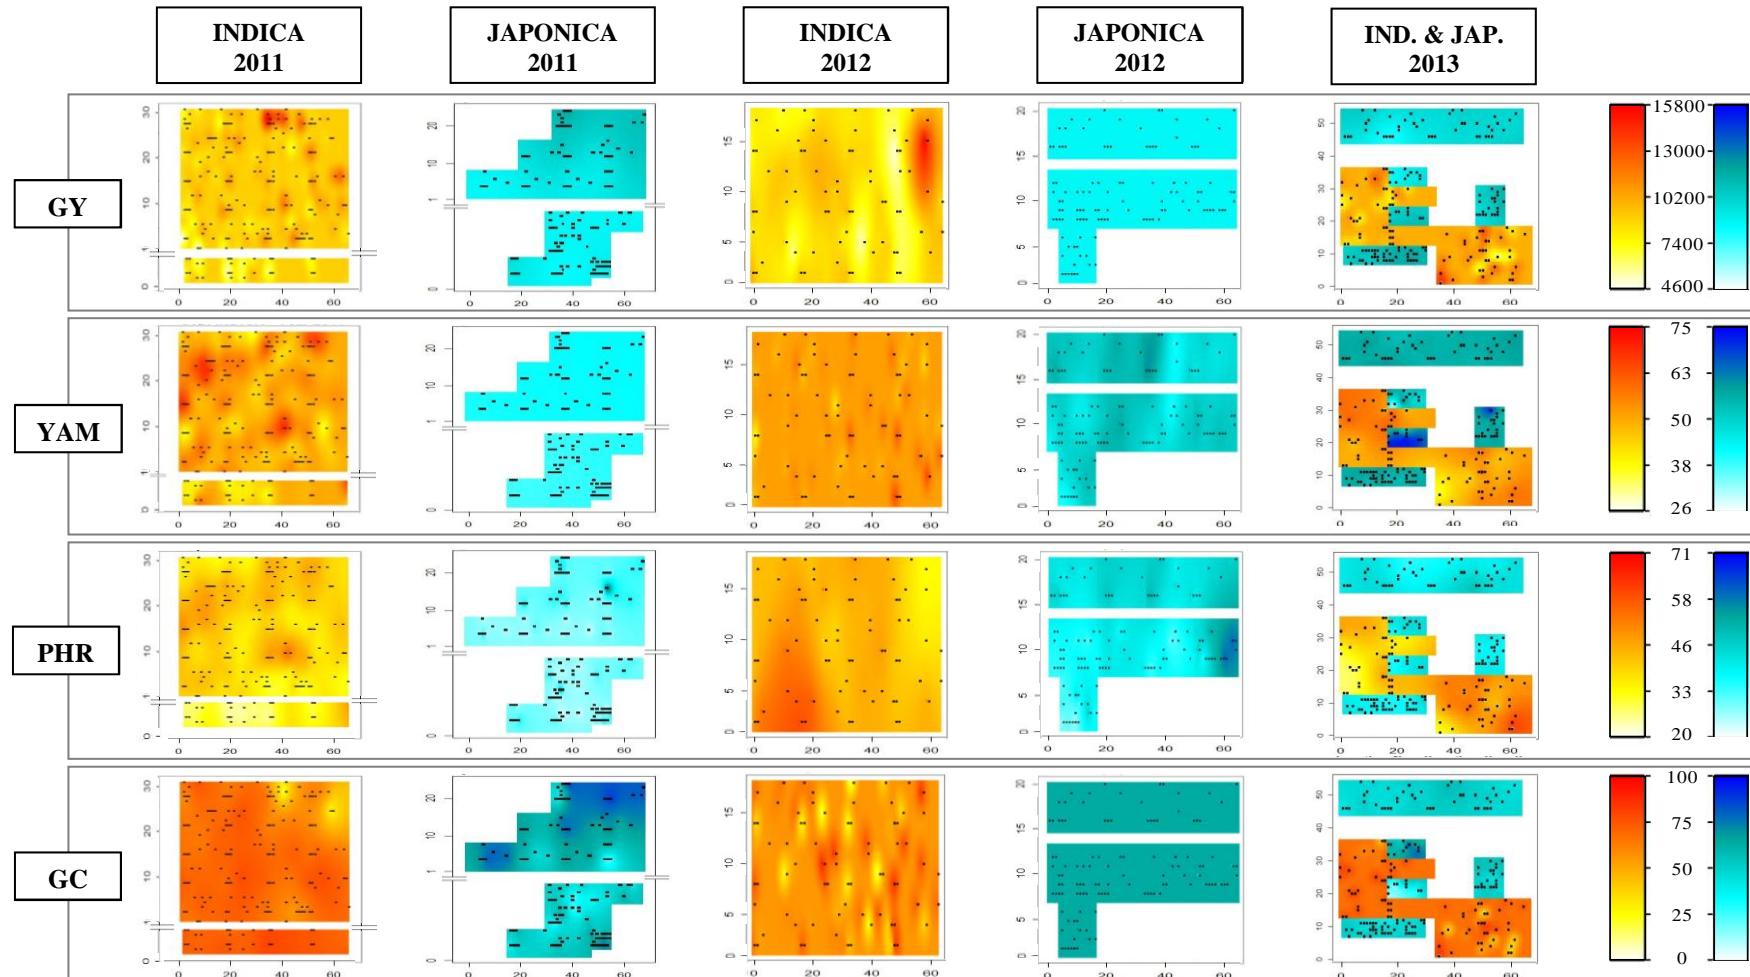


Figure 2: Spatial heterogeneity of the experimental field for the eight agronomic and grain quality features, modeled from checks residuals (indicated in black spots), evaluated over three years for two rice subspecies (Indica and Japonica) [cont. next page].

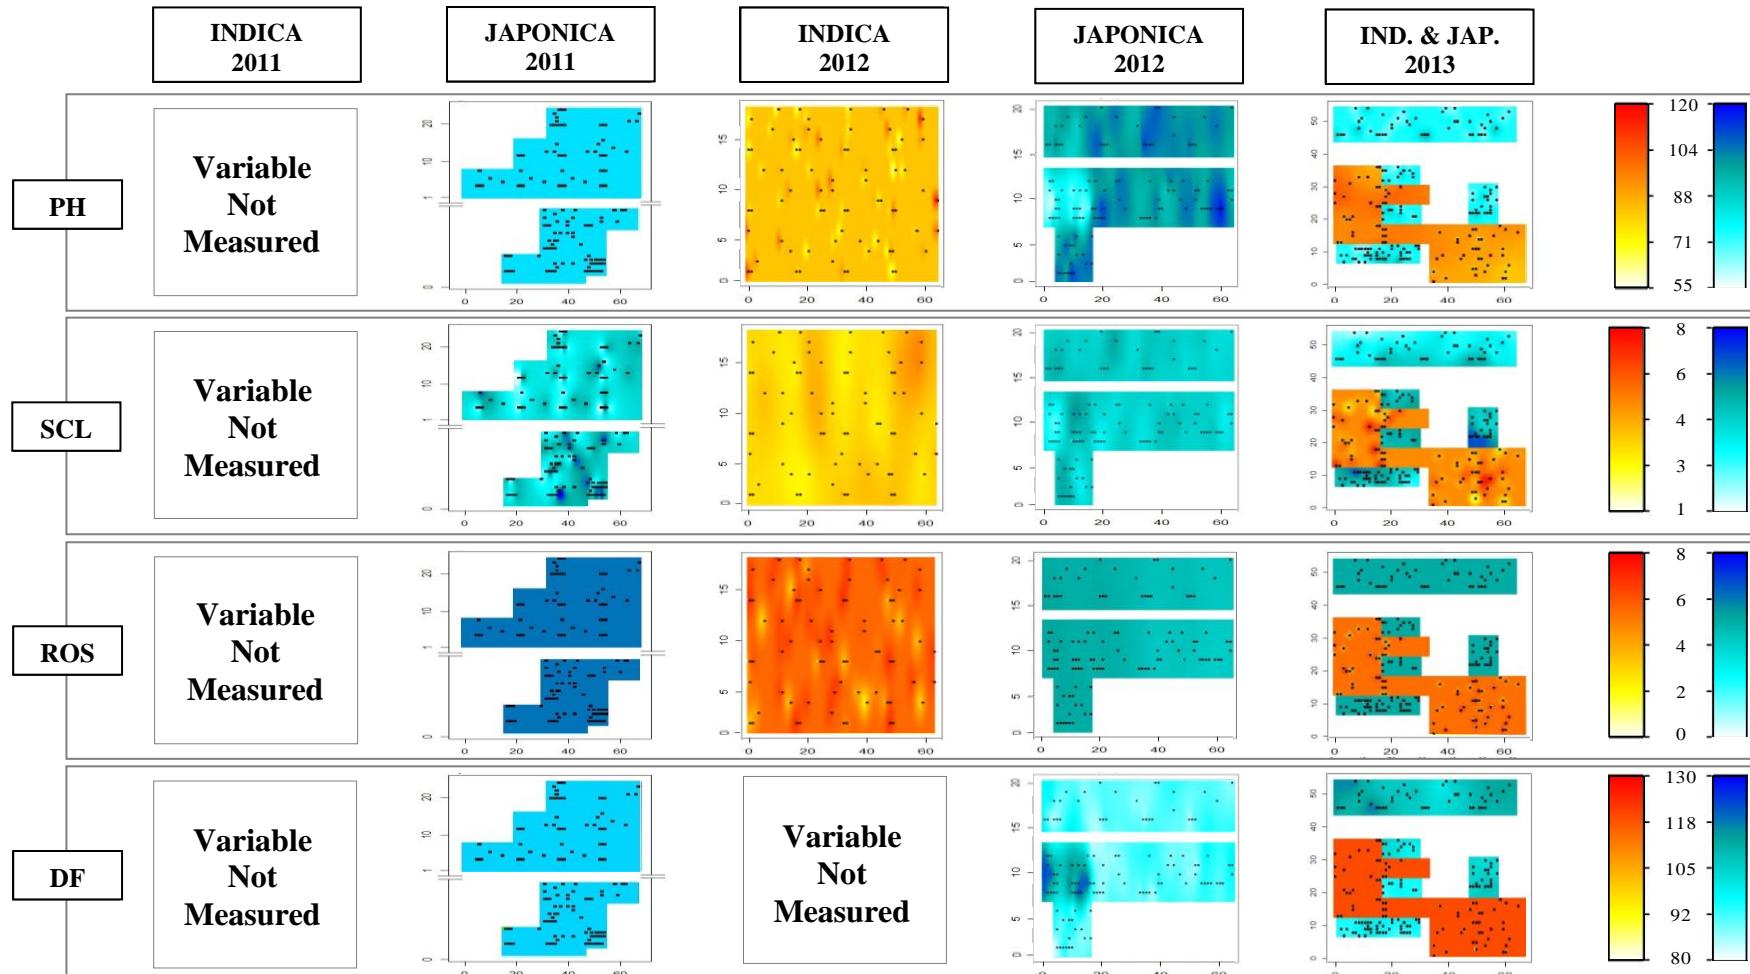


Figure 2 [cont.]: Spatial heterogeneity of the experimental field for the eight agronomic and grain quality features, modeled from checks residuals (indicated in black spots), evaluated over three years for two rice subspecies (Indica and Japonica).

Homogeneity in field maps of Indica, identified by the unified reddish coloration among years, showed evidence across all years and traits. Even though there are some areas of different colors, as is the case of Yield after milling for Indica 2012, where typical patches are identified, we found a lack of strong spatial correlation among plots. Similarly, for Japonica not much variability was identified, visualized through small change in shades of blue color. For Grain Chalkiness in 2011 there were some smooth changes in coloration. Stronger variation is detected in 2012 for both Plant Height and for Days to Flowering. These two variables showed a similar and opposite pattern in the bottom left side of the field. Since they are strongly correlated, and highly heritable traits, this may be attributable to differential field management such as water depth or sowing time.

Nevertheless an analytic study to determine field heterogeneity was performed, by comparison of different spatial adjustment models. Using the criteria of minimizing the SSE to determine the best model, empirical semivariograms were plotted (Figure 3). Based on this graphics there were different scenarios to summarize; the most important difference was between situations where including information about field variability in the analysis models was justified and those situations in which there was little or none spatial correlation detected between plots, therefore there was no need to consider any spatial adjustment. Some situations of correlated field plots were clearly identifiable such as GY in Indica 2011 and 2013, YAM in Indica 2011 and Japonica 2012 and 2013, PHR in Indica 2011 and 2013 as well as Japonica 2012 and GC for Japonica 2011. The other situations, where it was not necessary to include information about spatial variability, could be divided into two big scenarios. The first one were conditions of uncorrelated field plots such as GY for Japonica in 2012, also PH, ROS and DF for Japonica in 2011 and in 2013 for Indica feature DF and for Japonica disease ROS. The second scenario presented situations that showed a considerably good adjustment; however they reported a very large range, exceeding the maximum distance between any two plots in each year of evaluation. Therefore, for these two cases, the implementation of extra spatial adjustment in the models was not justified.

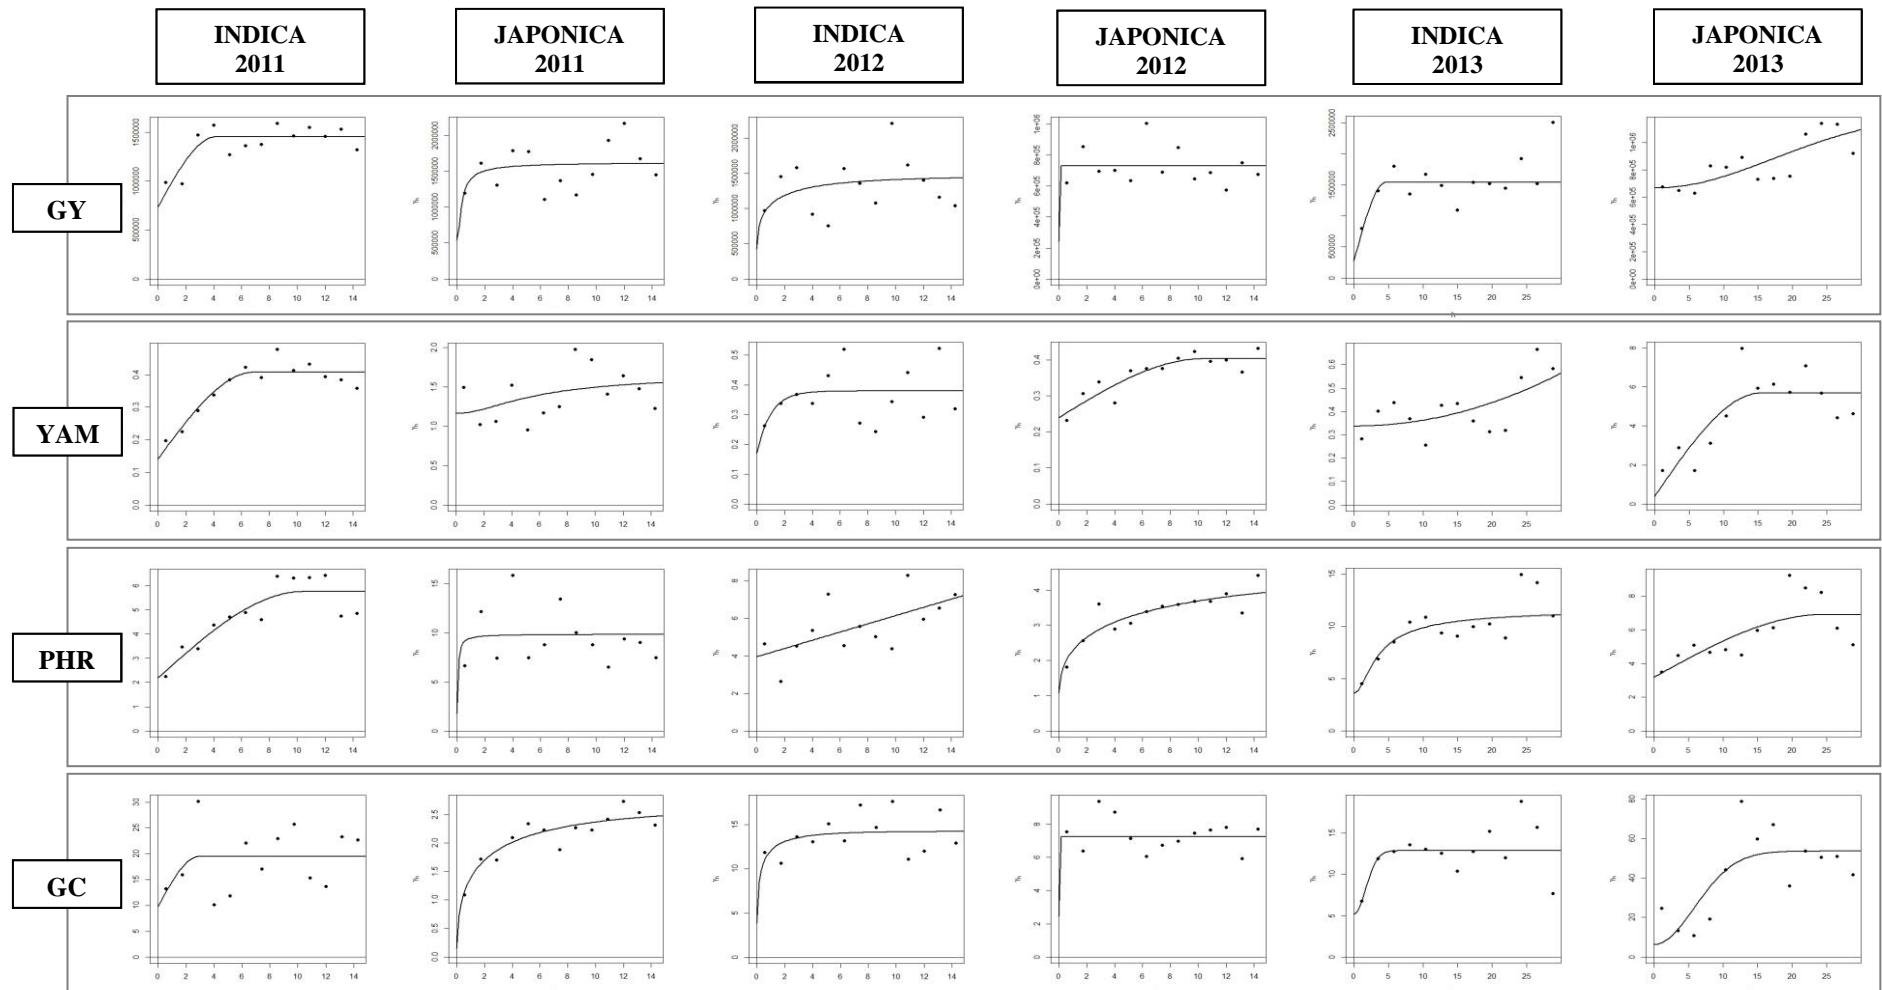


Figure 3: Estimated semivariograms for eight agronomic and grain quality features, evaluated over three years for two rice subspecies (Indica and Japonica) [cont. next page].

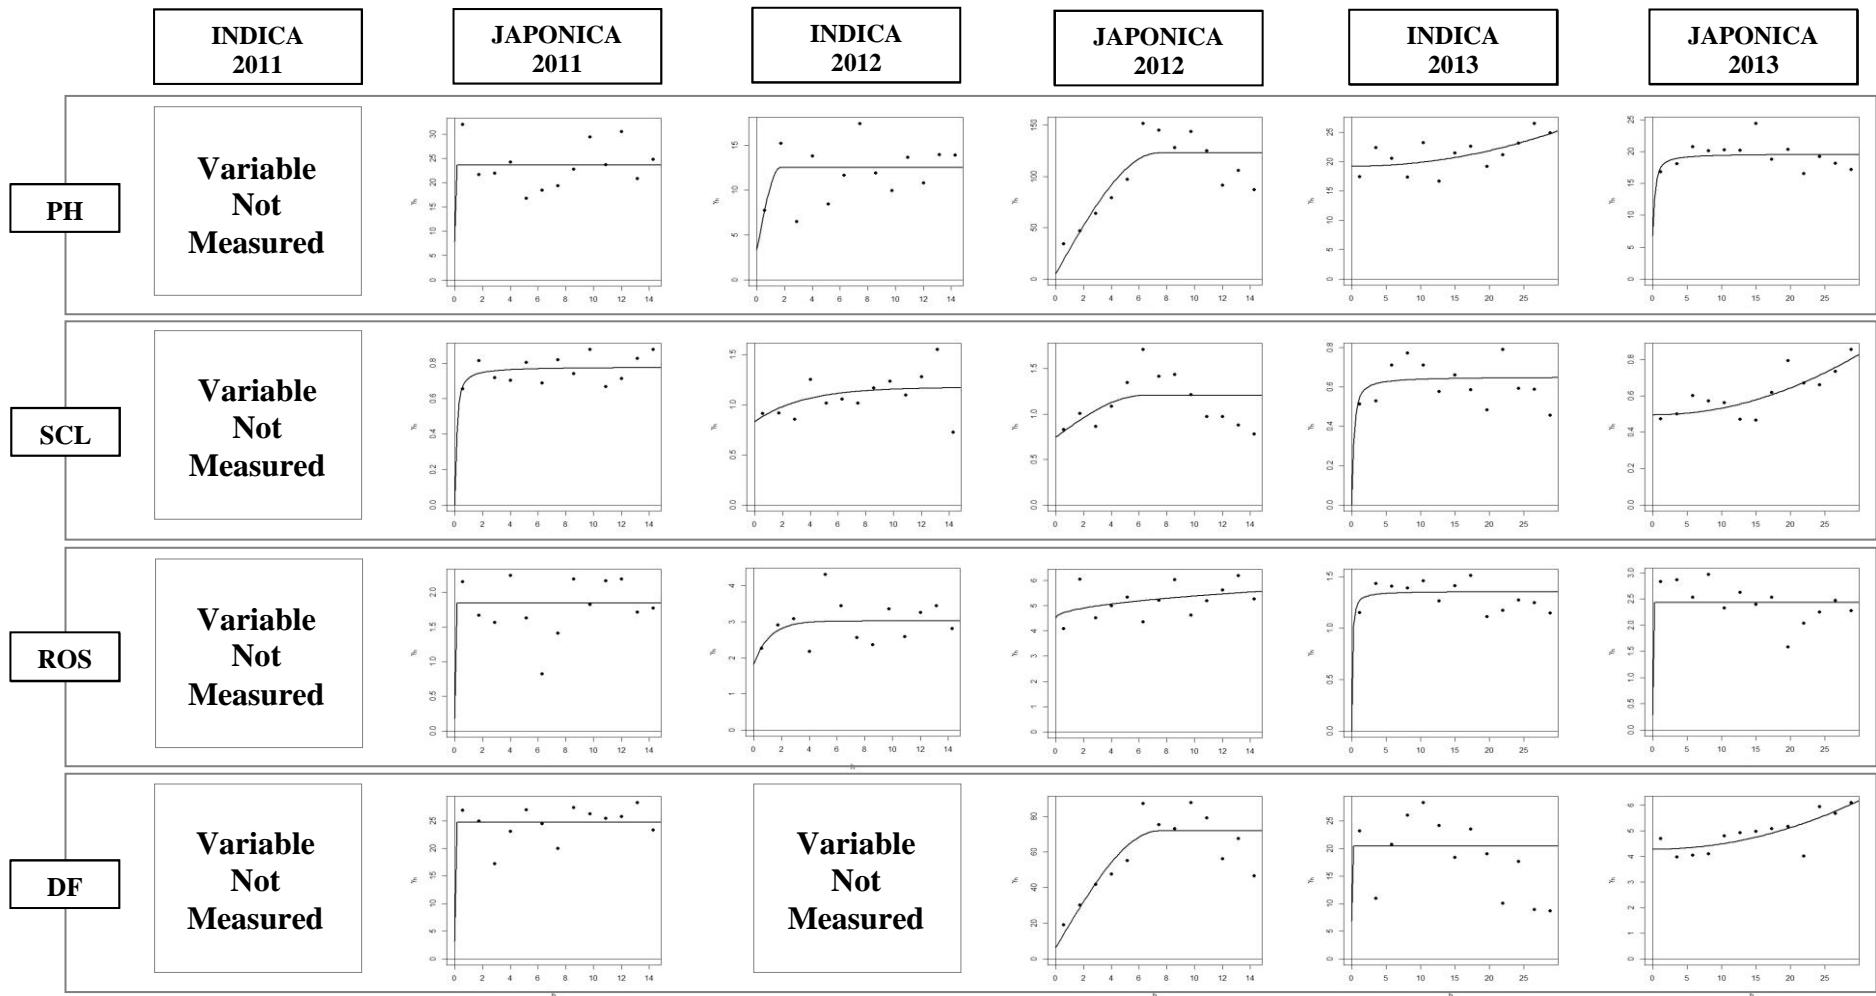


Figure 3 [cont.]: Estimated semivariograms for the eight agronomic and grain quality features evaluated over three years for two rice subspecies (Indica and Japonica).

In design simulation stage a spatial adjustment was included in the analysis model using for each case the best spatial model identified by the minimum SSE in previous stage. We found that there was no unique best spatial model for all traits, year and subspecies evaluated (Table 3).

Some features, in some years of evaluation, reported a null range hence all models evaluated presented the same SSE. Consequently for simulation stage in those cases the model used was the best model reported for that variable, for the same subspecie, the previous year. In case of being the first year of evaluation arbitrary Gaussian model was assigned by default. For Japonica in 2011 features PH, ROS and DF as well as DF in year 2013 for Indica presented range equal to zero, in those cases, being the first year of evaluation and no having a previous year of reference, Gaussian model was used. For Japonica 2013 only one feature (ROS) reported a null range and since the previous year Stable model turned out to be the best model, that was the spatial adjustment model consider for year 2013.

Concluding this stage, experimental design comparison by BIC indicator shown that for most features most complex simulated designs, such as IBD, analyzed assuming uncorrelated covariances (models without spatial adjustment), turned out to be the best designs in several situations (Table 4). Nevertheless the simplest designs were the most adequate for both subspecies and year as long as spatial adjustment is considered (Table 4, “spat” models).

Table 3: SSE values of spatial adjust models Spherical, Gaussian, Exponential, Cauchy and Stable, for each rice subspecie (Indica and Japonica), trait and year of evaluation in a panel of inbred lines of rice. Estimate range of empiric semivariograms for the best model.

		Indica						Japonica					
		Range	Spherical	Gaussian	Exponential	Cauchy	Stable	Range	Spherical	Gaussian	Exponential	Cauchy	Stable
2011	Grain Yield (GY)	4.2	<u>3.3E+13</u>	6.5E+13	3.5E+13	3.6E+13	3.9E+13	4.4	1.6E+14	1.7E+14	1.7E+14	<u>1.6E+14</u>	1.6E+14
	Yield after milling (YAM)	6.9	<u>2.5</u>	2,6	3.2	3.9	4.3	80.4	156.3	156.3	134.7	<u>132.8</u>	138.1
	% of Head Rice (PHR)	10.4	<u>1248</u>	1321	1430	1497	1565	1.0	14468.9	14468.9	14468.9	<u>14438.3</u>	14468.9
	Grain Chalkiness (GC)	2.9	<u>73105</u>	76538	76538	73653	73374	19.4	71.1	72.5	57.7	56.1	<u>52.9</u>
	Plant Height (PH)	-	-	-	-	-	-	0	30557	30557	30557	30557	30557
	Sclerotium (SCL)	-	-	-	-	-	-	1.6	10.0	10.0	10.0	<u>9.2</u>	10.0
	Rhizoctonia (ROS)	-	-	-	-	-	-	0	211.0	211.0	211.0	211.0	211.0
	Days to flowering (DF)	-	-	-	-	-	-	0	12699	12699	12699	12699	12699
2012	Grain Yield (GY)	10.2	1.3E+14	1.3E+14	1.3E+14	1.3E+14	<u>1.2E+14</u>	0	3.3E+13	3.3E+13	3.3E+13	3.3E+13	3.3E+13
	Yield after milling (YAM)	3.0	7.3	7.6	<u>7.3</u>	7.4	7.4	10.3	<u>1.3</u>	1.4	1.5	1.6	1.6
	% of Head Rice (PHR)	6306.2	<u>1182,6</u>	1183.9	1182.6	1184.3	1206.8	53.1	310	214	<u>184</u>	191	<u>171</u>
	Grain Chalkiness (GC)	3.7	4506,9	4506.9	4506.9	4316.1	<u>4306.1</u>	0	1867	1867	1867	1867	1867
	Plant Height (PH)	1.7	<u>4726,6</u>	5109.2	4776.9	4729.0	4743.9	7.3	<u>1037118</u>	1080052	1325445	1461214	1665191
	Sclerotium (SCL)	10.3	32,7	34.8	<u>32,3</u>	32.4	32.4	6.2	<u>170,4</u>	172.0	175.8	182.5	179.9
	Rhizoctonia (ROS)	3.4	231,8	241.0	<u>231,0</u>	231.6	231.3	277190.9	881.1	881.1	881.1	814.1	<u>785.0</u>
	Days to flowering (DF)	-	-	-	-	-	-	7.4	<u>336014</u>	346901	403612	441140	501041
2013	Grain Yield (GY)	4.6	<u>1.1E+14</u>	1.4E+14	1.3E+14	1.2E+14	1.2E+14	42.3	5.4E+13	<u>5.3E+13</u>	5.5E+13	5.6E+13	6.4E+13
	Yield after milling (YAM)	2400.1	12.2	13.0	9.9	<u>8.7</u>	10.6	15.4	<u>5725</u>	5773	7039	7430	8306
	% of Head Rice (PHR)	47.4	2726.7	2751.8	2747.3	<u>2602.3</u>	2607.2	24.5	<u>5923</u>	6088	6601	6610	6810
	Grain Chalkiness (GC)	4.1	5742.1	<u>5741,6</u>	5763.8	5930.6	6157.3	14.2	7.7E+05	<u>7.7E+05</u>	9.6E+05	<u>9.7E+05</u>	1.1E+06
	Plant Height (PH)	378.3	10803.5	10803.5	10803.5	<u>7749.3</u>	8852.0	3.9	19121.0	19121.0	19121.0	<u>18293.4</u>	19121.0
	Sclerotium (SCL)	4	13.8	13.8	13.8	<u>13.2</u>	13.8	1051	25.9	<u>20.1</u>	25.9	20.1	31.6
	Rhizoctonia (ROS)	1.5	21.6	21.6	21.6	<u>21.2</u>	21.6	0	422.2	422.2	422.2	422.2	422.2
	Days to flowering (DF)	0	52535.7	52535.7	52535.7	<u>52535.7</u>	52535.7	471.4	890.5	<u>828.9</u>	890.6	829.0	1049.3

Table 4: BIC values of simulated designs for each rice subspecie (Indica and Japonica), trait and year of evaluation in a panel of inbred lines of rice. Notation of associated models: CRD: Complete Randomized Design, RCBD: Randomized Complete Block Design, RCBD-T: Randomized Complete Block Design by trail, IBD- $\alpha$ : Incomplete Block Design -  $\alpha$  Lattice. “spat.” versions include spatial information in the analysis.

		Indica								Japonica							
		CRD	CRD	RCBD	RCBD	RCBD-T	RCBD-T	IBD- $\alpha$	IBD- $\alpha$	CRD	CRD	RCBD	RCBD	RCBD-T	RCBD-T	IBD- $\alpha$	IBD- $\alpha$
		spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.
2011	Yield after milling (YAM)	698	610	<u>577</u>	624	674	684	705	708	943	<u>683</u>	789	699	958	904	920	922
	% of Head Rice (PHR)	1248	1064	1345	<u>1057</u>	1244	1217	1217	1204	1147	<u>1087</u>	1232	1112	1177	1182	1164	1174
	Grain Chalkiness (GC)	1587	1539	1897	<u>1543</u>	1618	1606	1621	1611	727	<u>314</u>	574	323	738	635	664	601
	Plant Height (PH)	-	-	-	-	-	-	-	-	820	830	<u>749</u>	847	830	835	840	851
	Sclerotium (SCL)	-	-	-	-	-	-	-	-	442	453	<u>181</u>	472	453	458	468	478
	Rhizoctonia (ROS)	-	-	-	-	-	-	-	-	921	<u>409</u>	433	421	913	584	652	641
	Days to flowering (DF)	-	-	-	-	-	-	-	-	1039	<u>885</u>	1011	898	1060	1001	1014	1021
2012	Yield after milling (YAM)	701	<u>469</u>	554	479	730	721	726	697	683	<u>571</u>	586	598	722	715	735	712
	% of Head Rice (PHR)	1245	<u>945</u>	1342	970	1281	1256	1281	1261	1258	<u>963</u>	1362	972	1215	1175	1201	1129
	Grain Chalkiness (GC)	1174	<u>1113</u>	1271	1128	1194	1198	1182	1189	1266	<u>1178</u>	1397	1194	1255	1226	1249	1252
	Plant Height (PH)	1744	<u>1494</u>	2160	1501	1796	1801	1781	1786	1934	<u>1556</u>	2392	1557	1910	1873	1764	1771
	Sclerotium (SCL)	747	637	<u>625</u>	647	778	771	806	795	862	732	785	<u>724</u>	867	859	873	855
	Rhizoctonia (ROS)	986	<u>829</u>	953	841	1007	1006	997	998	1135	<u>1070</u>	1211	1084	1137	1135	1132	1139
	Days to flowering (DF)	-	-	-	-	-	-	-	-	1815	<u>1465</u>	2183	1466	1800	1761	1682	1684
2013	Yield after milling (YAM)	1520	<u>1279</u>	1747	1284	1549	1453	1487	1447	1533	<u>1280</u>	1744	1288	1552	1461	1465	1430
	% of Head Rice (PHR)	1577	<u>1253</u>	1765	1266	1557	1472	1466	1441	1583	<u>1233</u>	1779	1269	1576	1463	1482	1457
	Grain Chalkiness (GC)	1791	1569	2138	<u>1565</u>	1798	1724	1731	1693	1801	1562	2106	<u>1560</u>	1802	1726	1724	1694
	Plant Height (PH)	1224	<u>1230</u>	1364	1246	1235	1233	1230	1240	1212	<u>1221</u>	1375	1256	1234	1239	1235	1243
	Sclerotium (SCL)	636	634	<u>443</u>	643	642	628	654	656	621	620	<u>436</u>	638	653	646	659	664
	Rhizoctonia (ROS)	862	873	<u>813</u>	889	871	876	882	892	856	867	<u>823</u>	896	870	875	882	892
	Days to flowering (DF)	978	<u>930</u>	959	973	1016	1015	987	996	972	<u>941</u>	970	978	975	979	948	958

The remaining model comparison indicators were tested in Grain Yield (Table 5). As BIC, all indicators suggest that the simplest models are the best options, particularly the versions that include spatial adjustment in the analysis. However RMSE indicator for Japonica 2011 reported that the best model, with minimum SSE, was the IBD –  $\alpha$  Lattice without spatial correlation.

Regarding to ROT indicator, we considered as better models those which recovered at least nine of the ten varieties simulated as the top ten, in terms of yield. For this case, most models have a good performance, recovering in the worst situation six of the genotypes and in almost every situation indicates as good options both simple and complex designs. Even though this might seems to be a negative behavior of the indicator, on the contrary this indicates that for Grain Yield, selecting under the ranking of treatments, all designs are appropriate.

Table 5: Comparison of simulated designs CRD, RCBG, RCBG-T and IBD- $\alpha$  Lattice, with or without spatial adjustment, based on BIC, RMSE, F-value y ROT for Grain Yield trait, for each rice subspecies (Indica and Japonica), and year of evaluation in a panel of inbred lines of rice.

		Indica								Japonica							
		CRD	CRD	RCBD	RCBD	RCBD-T	RCBD-T	IBD- $\alpha$	IBD- $\alpha$	CRD	CRD	RCBD	RCBD	RCBD-T	RCBD-T	IBD- $\alpha$	IBD- $\alpha$
		spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.	spat.
2011	BIC	3600	3530	4914	<u>3508</u>	3605	3614	3597	3595	3589	3106	4483	<u>3092</u>	3606	3294	3300	3310
	RMSE	575	1318	<u>464</u>	1020	561	564	539	604	558	497	219	377	568	594	<u>171</u>	174
	F-value	18	<u>43</u>	13	40	20	20	19	24	12	<u>186</u>	30	185	11	102	97	98
	ROT	8	<u>9</u>	<u>9</u>	<u>9</u>	<u>9</u>	<u>9</u>	<u>9</u>	<u>9</u>	8	<u>9</u>	<u>9</u>	<u>9</u>	6	<u>9</u>	8	<u>9</u>
2012	BIC	3615	3302	4960	<u>3292</u>	3647	3645	3613	3607	3378	3328	4578	<u>3325</u>	3387	3391	3370	3369
	RMSE	598	<u>444</u>	502	454	631	631	582	610	322	545	<u>259</u>	581	321	321	311	322
	F-value	6	<u>40</u>	3	40	5	6	6	8	18	<u>32</u>	11	23	17	18	17	19
	ROT	6	8	6	<u>9</u>	8	8	6	6	8	<u>9</u>	7	7	7	7	8	8
2013	BIC	3432	3212	4526	<u>3202</u>	3435	3356	3348	3344	3432	3212	4526	<u>3202</u>	3423	3349	3348	3344
	RMSE	371	9780	<u>236</u>	9092	364	438	247	344	371	9113	<u>236</u>	9005	352	351	247	344
	F-value	41	<u>155</u>	42	146	41	89	76	93	12	<u>43</u>	11	39	13	26	21	26
	ROT	<u>9</u>	<u>9</u>	<u>9</u>	<u>9</u>	8	<u>9</u>	<u>9</u>	<u>9</u>	8	<u>10</u>	<u>9</u>	<u>9</u>	6	8	8	8

## **2.5. DISCUSSION**

### **2.5.1. Model Comparison Analysis**

To account for spatial variation in field trials using additional information to that from the already contained in the experimental design, an alternative analytical methodology known as postblocking was developed. This method enables to explore whether a different system of blocking would have better results compared to those obtain from the original design. This imposes an alternative arrangement on the data and a re-analysis (Ainsley *et al.*, 1987). In our study postblocking improved the efficiency and precision of mean estimates. Yates (1939, 1940) and Cochran and Cox (1957) recommended comparing alternative analysis for data obtained from a lattice design. First analyze it as the proper lattice method, and second analyze it following a randomized complete block analysis. Robinson *et al.* (1988) based on data from a row-column design found potential improvements using alternative analysis designs. The findings of Basford *et al.* (1996) indicate that the best analysis should combine both design and spatial information. Brownie and Gumpertz (1997) showed the superiority of the spatial models over randomized complete block and incomplete block models. Gilmour *et al.* (1997) presented evidence of improved efficiency of the two-dimensional spatial model over the incomplete block model. On the other hand more recently Qiao *et al.* (2000) compared alternative experimental designs and spatial analyses, finding that for row-column trials, models associated to alternative designs, such as incomplete block and latinized row-column, could improve efficiency of the experiment even though postblocking methods had limited application in their trials. Even though there is no single model that best fits all traits for both subspecies in all years evaluated in this study, the joint analysis model that included information about row-column position (M3) seems to be the most adequate model to analyze Grain Yield and Sclerotium disease. Meanwhile, for the rest of the traits measured, the most appropriate model is the joint trial model that considered trial as a random effect, which is the M2 model.

The grid method, proposed by Gardner (1961) is based on the blocking principle for local control (Fisher, 1935). It is thought as a variant of the mass selection method and suggests that selecting plants within grids reduces field variation effect. The grid method divides the experimental field into smaller areas (grids) and, based on their phenotype, the best plants within each area are selected (Moreno-González and Cubero, 1993). By reducing plot to plot environmental variance, the efficiency of plant selection is increased with gridding (Fasoula and Fasoula, 1999). The original design by trials in our study is similar to gridding and our findings reveal that in the majority of the situations, the method succeeded in recovering the top best varieties, comparable to many selection experiments conducted under the grid method (Hallauer and Sears, 1969; Verhalen *et al.*, 1975; Cortez-Mendoza and Hallauer, 1979). Based on the results, this method is well suited when is applied in a high number of treatments, such as year 2011 where 1152 lines were evaluated for Indica and 824 for Japonica. However this method shows a decline in performance when is applied in a reduce number of treatments, such years 2012 and 2013 that were evaluated a total of 384 lines for Indica and 402 for Japonica. Therefore applying this method for genotype selection in a reduce number of lines could have negative repercussions at identifying the best genotypes.

### **2.5.2. Experimental Design Comparison based on Simulation**

Completely randomize (CRD) and randomized complete block designs (RCBD) are the most widely used designs in agricultural experimentation due to simplicity in implementation and analysis (Borges *et al.*, 2014). Nevertheless these designs assume uniform experimental units in which the experiment is conducted (Basford *et al.*, 1996) and in most plant breeding experiments, the presence of heterogeneity among the experimental units is a common feature, making the use of simple designs unsuitable for this kind of experiments (Qiao *et al.* 2000). Micro variation in soil properties and management practices applied to the fields justify considering more complex designs and therefore to include information of the field in the

experimental design (Mulla and McBratney, 2002; Roel and Terra, 2006; Grondona *et al.*, 1996). The benefit of incorporating spatial information in analysis models has been addressed in agricultural experiments with small plots (Brownie, *et al.*, 1993, Casler 1999, Qiao *et al.*, 2000, Smith y Casler, 2004). More precisely, in rice commercial farms, factors such as water depth and weed infestation have been proved to be highly related to the variation in crop yield (Roel *et al.*, 2007; Bonilla *et al.*, 2015). Despite apparent homogeneity in rice fields, the use of yield maps has been successful due to the actual presence of yield variability (Dobermann, 1994; Yanai *et al.*, 2001; Roel and Plant, 2004; Terra *et al.*, 2006, 2008; Simmonds *et al.*, 2013). Even though the experimental field of our study was of a considerably large size, we detected homogeneity in experimental units within the fields. We found similarity in kriging maps colorations which indicates lack of heterogeneity but also, through empiric semivariograms, we found that there are two big scenarios, some situations that presented correlation among plots, and therefore justify the inclusion of spatial information in model analysis, and others that present null or low evidence of spatial correlation among plots. Considering both analyses we came to the conclusion that there is no strong evidence to recommend the implementation of more complex experimental designs than the already proposed in the experimental field, however in some cases including spatial information could improve the efficiency of mean estimates. Moreover all model selection indicators suggest that the models with fewer restrictions in randomization, assuming correlated covariances, are the best designs, this means a CRD or RCBD augmented design. These findings contradict what Borges *et al.* (2014) showed applying the same methodology in simulated yield data for wheat cultivars, where the benefit of proposing an adequate experimental design implied an improvement in terms of mean estimations respect to considering only the best suitable analysis model. We consider that the reduced spatial variability is attributable to the conditions in which experimental fields are evaluated, due flood irrigation system used in Uruguay for rice crop production might be homogenizing the conditions inside each trial and therefore having a direct repercussion in the performance of the experimental

designs, benefiting the simpler designs and making unnecessary the implementation of more complex ones.

## **2.6. REFERENCES**

- Ainsley AE, Patterson LJ, Patterson HD. 1987. A method for predicting the efficiency of incomplete blocks trials. *Biometrics*, 43: 55 – 59.
- Basford KE, Williams ER, Cullis BR, Gilmour A. 1996. Experimental design and analysis for variety trials. En: Cooper M, Hammer GL. (Eds.). *Plant adaptation and crop improvement*. Wallingford, UK. CAB International in association with IRRI and ICRISAT. 125 – 138.
- Bhatti AU, Mulla DJ, Frazier BE. 1991. Estimation of soil properties and wheat yields on complex eroded hills using geostatistics and thematic mapper images. *Remote Sensing of Environment*, 37(3): 181 – 191.
- Bishop TFA, Lark RM. 2006. The geostatistical analysis of experiments at the landscape-scale. *Geoderma*, 133: 87 – 106.
- Bonilla C, Terra JA, Gutiérrez L, Roel A. 2015. Cosechando los beneficios de la agricultura de precisión en un cultivo de arroz en Uruguay. *Agrociencia Uruguay*, 19(1): 112 – 121.
- Borges A, González A, Ernst O, Cadenazzi M, Gutiérrez L. 2014. Comparison of experimental designs and spatial models based on simulated data using real field spatial heterogeneity in agricultural experimentation. Abstract para el XXVIIth International Biometric Conference (Florencia, Italia), sin publicación escrita por parte del congreso. Disponible en: <http://www.ibs-italy.info/ibc-2014.html>. [Datos sin publicar].
- Brownie C, Gumpertz ML. 1997. Validity of spatial analyses for large field trials. *Journal of Agricultural, Biological and Environmental Statistics*, 122: 1 – 23.

Brownie C, Bowman DT, Burton JW. 1993. Estimating Spatial Variation in Analysis of Data from Yield Trials: A Comparison of Methods. *Agronomy Journal*, 85: 1244 – 1253.

Burrough PA, McDonnell RA. 1998. Principles of Geographical Information Systems. Oxford University Press, 1998: 18 – 34.

Casler MD. 1999. Spatial variation affects precision of perennial cool-season forage grass trials. *Agronomy Journal*, 91(1): 75 – 81.

Cochran WG, Cox GM. 1957. Experimental Design. New York: Wiley. 399.

Cortez-Mendoza H, Hallauer AR. 1979. Divergent mass selection for ear length in maize. *Crop Science*, 19(2): 175 – 178.

Cressie, NAC. 1993. Statistics for Spatial Data, revised edition. New York: John Wiley & Sons. 416 – 900.

de Mendiburu F. 2012. *Agricolae: Statistical Procedures for Agricultural Research*, reference index version 1.1-3. [En línea]. Consultado: 31 Octubre 2015. Disponible en: <http://CRAN.R-project.org/> package=agricolae. R Foundation for Statistical Computing, Vienna, Austria.

Dobermann A. 1994. Factors causing field variation of direct-seeded flooded rice. *Geoderma*, 62(1–3): 125 – 150.

Fasoula VA, Fasoula DA. 1999. Honeycomb Breeding: Principles and Applications. En: Janick J. (Eds.). *Plant Breeding Reviews*, Volume 18. Oxford: John Wiley & Sons. 177 – 250.

Fisher RA. 1935. The Design of Experiments (8th ed., 1966). New York: Hafner Press. 1 – 26.

Gardner CO. 1961. An evaluation of effects of mass selection and seed irradiation with thermal neutrons on yield of corn. *Crop Science*, 1: 241 – 245.

Gilmour AR, Cullis BR, Verbyla AP. 1997. Accounting for natural and extraneous variation in the analysis of field experiments. *Journal of Agricultural, Biological and Environmental Statistics*, 2: 269 – 293.

Grondona MO, Crossa J, Fox P, Pfeiffer W. 1996. Analysis of variety yield trials using two-dimensional separable ARIMA processes. *Biometrics*, 52(2): 763 – 770.

Grondona MO, Cressie NAC. 1991. Using Spatial Considerations in the Analysis of Experiments. *Technometrics*, 33(4): 381 – 392.

Hallauer AR, Sears JH. 1969. Mass selection for yield in two varieties of maize. *Crop Science*, 9(1): 47 – 50.

Hengl T. 2009. A Practical Guide to Geostatistical Mapping (2<sup>nd</sup> ed.). Amsterdam: University of Amsterdam. 1 – 60.

IRRI – International Rice Research Institute. 2006. Bringing hope, improving lives: strategic plan 2007-2015. Manila: IRRI. 61.

Moreno-González J, Cubero JI. 1993. Selection strategies and choice of breeding methods. En: Hayward MD, Bosemark NO, Romagosa T. (Eds.). Plant breeding: principles and prospects. Netherlands: Springer Science & Business Media. 281 – 313.

Mulla DJ, McBratney AB. 2002. Soil spatial variability. En: Warrick AW. (Eds.). Soil physics companion. Boca Ratón: CRC. 343 – 373.

Pinheiro J, Bates D, DebRoy S, Sarkar D & the R Development Core Team. 2013. nlme: Linear and Nonlinear Mixed Effects Models, reference index version 3.1-124. [En línea]. Consultado: 18 Enero 2015. Disponible en: <http://CRAN.R-project.org/package=nlme>. R Foundation for Statistical Computing, Vienna, Austria.

Qiao CG, Basford KE, DeLacy LH, Cooper M. 2000. Evaluation of experimental designs and spatial analyses in wheat breeding trials. *Theoretical and Applied Genetics*, 100: 9 – 16.

R Development Core Team. 2012. R: A language and environment for statistical computing, reference index version 3.1.3. [En línea]. Consultado: 20 Julio 2015. Disponible en: <http://www.R-project.org>. R Foundation for Statistical Computing, Vienna, Austria.

Ribeiro Jr. PJ, Diggle PJ. 2001. geoR: A package for geostatistical analysis. *R-NEWS*, 1(2): 15 – 18.

Robinson DL, Kershaw CD, Ellis RP. 1988. An investigation of two-dimensional yield variability in breeders' small plot barley trials. *Journal of Agricultural Science*, 111: 419 – 426.

Roel A, Firpo H, Plant R. 2007. Why do some farmers get higher yields? Multivariate analysis of a group of Uruguayan rice farmers. *Science Direct*, 58: 78 – 92.

Roel A, Terra J. 2006. Muestreo de suelos y factores limitantes del rendimiento. En: Bongiovanni R, Chartuni E, Best S, Roel A. (Eds.). *Agricultura de precisión*;

80 integrando conocimientos para una agricultura moderna y sustentable. Montevideo: PROCISUR. 65 – 80.

Roel A, Plant RE. 2004. Factors underlying yield variability in two California rice fields. *Agronomy Journal*, 96(5): 1481 – 1494.

Simmonds MB, Plant RE, Peña-Barragán JM, van Kessel C, Hill J, Linquist BA. 2013. Underlying causes of yield spatial variability and potential for precision management in rice systems. *Precision Agriculture*, 14: 512 – 540.

Smith KF, Casler MD. 2004. Spatial Analysis of Forage Grass Trials across Locations, Years and Harvests. *Crop Science*, 44: 56 – 62.

Terra JA, Cantou G, Deambrosi E, Molina F, Roel A, Casales LA, Ferreria D, Ferreira D. 2008. Efecto de dos alternativas de densidad de siembra y dosis de nitrógeno en el rendimiento de EP144 a escala de chacra. En: Arroz: Resultados Experimentales 2007-2008. Montevideo: INIA (Actividades de Difusión ; 545). 15 – 22.

Terra JA, Shaw JN, Reeves DW, Raper RL, van Santen E, Schwab EB, MasK PL. 2006. Soil management and landscape variability affects field-scale cotton productivity. *Soil Science Society of America Journal*, 70: 98 – 107.

USDA (United States Department of Agriculture). 2016. Economic Research Service. Rice Outlook N° (RCS-16A) [En línea]. Acceso: 28 Enero 2016. Disponible en: <http://ers.usda.gov/publications/rice-outlook/rice-16a.aspx>

USDA (United States Department of Agriculture). 2015. Economic Research Service. Rice Outlook N° (RCS-15L) [En línea]. Acceso: 28 Enero 2016. Disponible en: <http://ers.usda.gov/publications/rice-outlook/rice-15l.aspx>

Verhalen LM, Baker JL, McNew RW. 1975. Gardener's Grid System and Plant Selection Efficiency in Cotton. *Crop Science*, 15(4): 588 – 591.

Yanai J, Lee CK, Kaho T, Lida M, Matsui T, Umeda M, Kosaki, T. 2001. Geostatistical analysis of soil chemical properties and rice yield in a paddy field and application to the analysis of yield-determining factors. *Soil Science and Plant Nutrition*, 47(2): 291 – 301.

Yates F. 1940. The recovery of interblock information in balanced incomplete block designs. *Annals of Eugenics*, 10: 317 – 325.

Yates, F. 1939. The recovery of inter-block information in variety trials arranged in three dimensional lattices. *Annals of Eugenics*, 9:135 – 156.

### **3. DISCUSIÓN GENERAL Y CONCLUSIONES**

#### **3.1. COMPARACIÓN DE MODELOS DE ANÁLISIS**

Para tener en cuenta la variación especial en los ensayos de campo utilizando información adicional a la considerada en los diseños experimentales, una metodología alternativa denominada postblocking fue desarrollada. Este método permite explorar si un sistema de bloqueo diferente podría presentar mejores resultados que los que se obtienen a partir del análisis según indica el diseño original. Esto implica arreglar de manera diferente los datos así como reanalizarlos (Ainsley *et al.*, 1987). Tanto Yates (1939, 1940) como Cochran y Cox (1957) recomendaron comparar análisis alternativos para datos recabados a partir de la implementación de un diseño latinizado. Los autores sugieren analizar los datos en una primer instancia tal como lo indica el análisis de un diseño lattice, y luego analizarlos siguiendo la metodología correspondiente a un DBCA. Robinson *et al.* (1988) basados en datos provenientes de un diseño columna-hilera (DC-H), encontraron mejoras sustanciales al utilizar diseños de análisis alternativos. Los hallazgos de Basford *et al.* (1996) indican que el mejor análisis debería combinar tanto diseño como información espacial adicional. Brownie and Gumpertz (1997) demostraron la superioridad de los modelos espaciales sobre los modelos de análisis asociados a los DBCA y DBI. Gilmour *et al.* (1997) presentaron evidencia de mayor eficiencia del modelo espacial de dos dimensiones sobre el modelo asociado al DBI. Sin embargo, más recientemente Qiao *et al.* (2000) compararon diseños experimentales alternativos así como diversos modelos de análisis espacial, encontrando que para los ensayos diseñados bajo un DC-H, los modelos de análisis asociados a diseños alternativos, tales como el del DBI o el del DC-H latinizado, podrían mejorar la eficiencia del experimento. No obstante los métodos de postblocking tuvieron limitadas aplicaciones en sus ensayos.

En el presente trabajo la técnica de postblocking presentó mejorías en términos de precisión de las estimaciones de las medias. Los modelos propuestos que

incorporaban información espacial eran el M2; que implicó un análisis conjunto de los ensayos de evaluación, utilizando información de los testigos repetidos y el M3; que proponía un análisis conjunto de los ensayos con una corrección espacial por ubicación según fila y columna en el campo. Se puede concluir que el M2 es el mejor modelo de análisis para todas las variables exceptuando *Rendimiento* (GY) y *Sclerotium* (SCL), para ambas subespecies en todos los años. Para GY el mejor modelo de análisis resulta ser el M3, a excepción de la subespecie Japónica en el año 2012, cuando resulta ser mejor el M2. Por otro lado, para SCL el mejor modelo de análisis es siempre el M3. Se concluye que no existe un modelo único de análisis que sea adecuado para todas las variables medidas, para ambas subespecies, en todos los años. Asimismo el modelo de análisis conjunto de los ensayos que incorpora información de filas y columnas en el campo (M3) pareciera ser el más adecuado para analizar la variable Rendimiento. Finalmente teniendo en cuenta que para la mayoría de las demás variables evaluadas el M2 es el mejor modelo, se podría llegar a la conclusión de que sería lo más apropiado para los próximos años de evaluación considerar realizar el análisis del conjunto de los ensayos de evaluación, utilizando información de los testigos repetidos como modelo de análisis y evaluar la inclusión o no de información espacial.

El método Gridding, propuesto por Gardner (1961) se basa en el principio de control local de la variación (Fisher, 1935). Sin embargo es una variante del método de selección masal y sugiere que seleccionar plantas dentro de grillas reduce el efecto de la variabilidad del campo. El método de grillado divide el campo experimental en áreas más pequeñas (grillas) y basados en su expresión fenotípica, se seleccionan las mejores plantas dentro de cada grilla (Moreno-González and Cubero, 1993). Al reducir la variabilidad ambiental entre parcelas, aumenta la eficiencia en la selección de cultivares al aplicar el método de Gridding (Fasoula and Fasoula, 1999). El diseño por ensayos considerado originalmente en nuestro estudio es similar al método de Gridding y nuestros hallazgos revelan que en la mayoría de las situaciones, el método fue exitoso recuperando las mejores variedades, siendo este resultado comparable con varios experimentos de selección llevados a cabo según el

método Gridding (Hallauer and Sears, 1969; Verhaelen et al., 1975; Cortez-Mendoza and Hallauer, 1979). Basados en los resultados, este método se adapta adecuadamente cuando se aplica a un gran número de tratamientos, tal como es el caso del año 2011 en donde se consideraron 1152 líneas avanzadas de la subespecie Indica y 824 líneas de la subespecie Japónica. Sin embargo, este método presenta una disminución en su desempeño cuando es aplicado en ensayos con pocos tratamientos, como en los años 2012 y 2013 que fueron evaluadas un total de 384 líneas para Indica y 402 para Japónica. Esto puede deberse a que se cuenta con menos grados de libertad o porque además al ocupar menos terreno las zonas son más similares y no hay tanta ganancia en analizarlas por separado para conseguir homogeneidad. Por lo tanto aplicar este método para la selección de cultivares cuando se trabaja con un número reducido de tratamientos puede tener repercusiones negativas a la hora de identificar los mejores genotipos.

### **3.2. COMPARACIÓN DE DISEÑOS EXPERIMENTALES BASADOS EN SIMULACIÓN**

Los diseños más utilizados en la experimentación agronómica son el DCA y el DBCA debido a la simplicidad en su implementación y análisis (Brownie, *et al.*, 1993; Borges *et al.*, 2014). Sin embargo estos diseños asumen que las unidades experimentales sean uniformes (Basford *et al.*, 1996) y en la mayoría de los experimentos de los programas de mejoramiento, la presencia de heterogeneidad entre las unidades experimentales es bastante común, por lo que el uso de diseños experimentales simples es inadecuado para este tipo de experimentos (Qiao *et al.* 2000). La micro variación en las propiedades de suelo y las prácticas de manejo aplicadas al campo justifican considerar diseños experimentales más complejos y por lo tanto incluir información de los campos en los diseños (Mulla and McBratney, 2002; Roel and Terra, 2006; Grondona *et al.*, 1996). El beneficio de incorporar información espacial en los modelos de análisis ha sido demostrado en trabajos de experimentación agronómica, en parcelas de pequeño tamaño (Brownie, *et al.*, 1993,

Casler 1999, Qiao *et al.*, 2000, Smith y Casler, 2004). Más precisamente, en chacras comerciales de arroz, se demostró que factores tales como lámina de riego y enmalezamiento están altamente relacionados con la variación en el rendimiento del cultivo (Roel *et al.*, 2007; Bonilla *et al.*, 2015). Pese a la homogeneidad aparente en las condiciones de suelo el uso de mapas de rendimiento ha sido de gran utilidad en la identificación de la variabilidad en el cultivo de arroz (Dobermann, 1994; Yanai *et al.*, 2001; Roel and Plant, 2004; Terra *et al.*, 2006, 2008; Simmonds *et al.*, 2013). A pesar de que el campo experimental de este estudio era de un tamaño considerablemente grande, detectamos homogeneidad en las unidades experimentales. Encontramos similitud en la coloración de los mapas de kriging y no encontramos una fuerte evidencia que sugiriera recomendar la implementación de un diseño más complejo del ya propuesto en el campo.

A partir de la interpolación de los residuos de los testigos repetidos se observa que no existe una gran variabilidad en el campo para las características evaluadas en este trabajo. Queda en evidencia que para ambas subespecies en ningún año de evaluación se identifica una fuerte heterogeneidad espacial, dado por la coloración pareja en ambas escalas de color así como por los semivariogramas. Sin embargo en algunos casos se encuentran ciertos patrones de variabilidad espacial, como es el caso de GC para Japonica 2011 y GY para Japonica 2012. Asimismo se identifica un leve cambio en la coloración tanto en PH como en DF en la región inferior izquierda del campo experimental para Japonica 2012. Sin embargo esto puede no ser atribuible a la heterogeneidad espacial sino a la variabilidad genética puesto que generalmente plantas de menor altura tienden a ser de ciclos más largos. Se llevó a cabo un estudio más analítico de la heterogeneidad espacial, por medio de la comparación de diversos modelos de ajuste espacial. Usando como criterio de decisión minimizar la Suma de Cuadrados del Error (SCE), se graficaron los semivariogramas empíricos. Basados en los resultados de dichos gráficos se podrían resumir todos los casos en dos grandes situaciones, los casos en que se justificaría la inclusión de la información espacial en los modelos de análisis y los casos en que debido a la escasa o nula variabilidad espacial no estaría justificada esta

consideración. Algunas situaciones que evidencian la ventaja de incluir información espacial en los modelos de análisis son GY en Indica 2011 y 2013, YAM en Indica 2011, Japonica 2012 y 2013, PHR en Indica 2011 y 2013 así como también en Japonica 2012 y finalmente el caso de GC para Japonica 2011 e Indica 2012. Las demás situaciones, aquellas en las que no sería necesario considerar incluir información de la variabilidad espacial en los modelos de análisis, se pueden dividir a su vez en dos grandes escenarios. El primero contempla aquellas situaciones en las que no hay correlación entre los pares de observaciones, como es el caso de GY para Japonica en el 2012; también sería el caso de PH, ROS y DF para la misma subespecie en 2011; por último en 2013 para Indica la característica DF y para Japonica nuevamente la enfermedad ROS. El segundo, situaciones que si bien presentan un gráfico que pareciera ajustar los puntos, presentan un valor de rango muy alto, excediendo la distancia máxima real entre dos observaciones en el campo experimental. Por lo tanto en estos dos escenarios no sería justificable la inclusión de información espacial en el modelo de análisis, puesto que de hacerlo no solo sería inadecuado sino que se estarían desperdiando grados de libertad.

En cuanto al mejor modelo de ajuste, no se puede concluir que exista un único modelo para todas las variables, años y subespecies consideradas. El mejor modelo de ajuste espacial varía entre subespecies y por subespecie a lo largo del tiempo. En la etapa de simulación de diseños se incluyó en el modelo de análisis con ajuste espacial al mejor modelo según cada situación. Puesto que para la etapa de simulación, para los modelos que fueron simulados con ajuste espacial se requería conocer el mejor modelo en cada situación, sin embargo para algunas variables se identificó un valor de rango igual a cero y por lo tanto todas las SCE de los modelos comparados eran iguales entre sí, puesto que dicho valor de rango indica que las observaciones están incorrelacionadas. Por consiguiente en esos casos se utilizó para la etapa de simulación el modelo que fuera indicado como el mejor en el año inmediatamente anterior, para esa variable y subespecie. En los casos en que se tratase del primer año de evaluación, entonces el modelo Gaussiano fue asignado por defecto como modelo de ajuste. Para Japonica en 2011 las variables PH, ROS y DF,

así como DF para Indica del año 2013, reportaron rango igual a cero, por lo tanto en esos casos se utilizó el modelo Gaussiano. Por otro lado para Japonica 2013 solamente una variable (ROS) presentó rango nulo y por lo tanto como en el año anterior el mejor modelo había resultado el modelo “Stable”, este fue el modelo que se utilizó para ajustar en el año 2013.

Concluyendo con la etapa de análisis que se enfoca en los diseños experimentales basados en simulación se presenta la comparación de los diseños experimentales alternativos propuestos en este trabajo según el indicador BIC. Para la mayoría de las características evaluadas, para ambas subespecies y en todos los años, se destacan los diseños más simples como los mejores según el indicador BIC, siempre y cuando se consideren los modelos con ajuste espacial. Sin embargo, los diseños más complejos, especialmente el DBI, resulta ser el mejor modelo en varias situaciones cuando se analiza sin incluir un ajuste espacial.

Además del criterio BIC todos los indicadores evaluados sugieren como mejores opciones a los diseños más simples, en especial las versiones que incluyen en el análisis un ajuste espacial. Este patrón se repite para las demás variables evaluadas y salvo para el indicador RMSE en que para la subespecie Japonica en el año de evaluación 2011 cuando el mejor modelo resulta ser el IBD –  $\alpha$  Lattice sin corrección espacial, en ningún otro caso el diseño más complejo es indicado como el mejor diseño. Con respecto al indicador ROT es importante aclarar que consideramos como mejores modelos aquellos que recuperaban como mínimo nueve de las diez variedades simuladas como las mejores diez. Para este indicador, la mayoría de los modelos presentaron un buen desempeño, recuperando en el peor de los casos seis de las diez variedades pero en la mayoría de las situaciones este indicador sugiere como buenos diseños tanto los simples como los más complejos. Si bien esto podría ser un rasgo negativo de este indicador, por el contrario, esto indica que para la variable Rendimiento, seleccionar bajo el indicador “ranking de tratamientos”, prácticamente cualquier diseño sería adecuado para recuperar las mejores variedades. Esto nos permite concluir que dadas las condiciones de manejo

del cultivo de arroz en el país, que implican riego por inundación, podría estar emparejando las condiciones dentro de cada ensayo y por lo tanto impactando de manera directa en la decisión del diseño experimental más adecuado, beneficiando a los diseños más simples y haciendo innecesaria la implementación de diseños más complejos.

A partir de los hallazgos de este trabajo podemos concluir entonces que los ensayos en arroz, en condiciones experimentales, son homogéneos debido a las condiciones propias del manejo de este cultivo, por lo que el uso de diseños experimentales más complejos que el DBCA no está justificado, siempre y cuando se incorpore información de ajuste espacial. Sin embargo, el uso de testigos repetidos y de un modelo conjunto de análisis a través de los ensayos resulta ser en todos los casos beneficioso para el análisis de los datos. Por otro lado, el uso de corrección espacial en los modelos de análisis ayuda en la mayoría de las situaciones, principalmente para analizar Rendimiento, siendo esta una de las variables de mayor interés en el proceso de selección de cultivares.

#### **4. BIBLIOGRAFÍA**

ACA (Asociación Cultivadores de Arroz). 2013. Guía de buenas prácticas en el cultivo de arroz en Uruguay [En línea]. Consultado: 01 Noviembre 2015. Disponible en:

[http://www.aca.com.uy/wp-content/uploads/2014/07/GUIA\\_DE\\_BUENAS\\_PRACTICAS\\_marzo\\_2013.pdf](http://www.aca.com.uy/wp-content/uploads/2014/07/GUIA_DE_BUENAS_PRACTICAS_marzo_2013.pdf)

ACA (Asociación Cultivadores de Arroz). 2009. Guía de buenas prácticas en el cultivo de arroz en Uruguay [En línea]. Consultado: 15 Noviembre 2015. Disponible en:

[http://www.aca.com.uy/\\_oldsite/revista/Revista%2060/ARROZ%2060/Revista%20en%20pdf/Guia%20de%20Buenas%20Practicas%20Agricolas.pdf](http://www.aca.com.uy/_oldsite/revista/Revista%2060/ARROZ%2060/Revista%20en%20pdf/Guia%20de%20Buenas%20Practicas%20Agricolas.pdf)

Ainsley AE, Patterson LJ, Patterson HD. 1987. A method for predicting the efficiency of incomplete blocks trials. *Biometrics*, 43:55 – 59.

Baruah AR, Ishigo-Oka N, Adachi M, Oguma Y, Tokizono Y, Onishi K, Sano Y. 2009. Cold tolerance at the early growth stage in wild and cultivated rice. *Euphytica*, 165(3): 459 – 470.

Basford KE, Williams ER, Cullis BR, Gilmour A. 1996. Experimental design and analysis for variety trials. En: Cooper M, Hammer GL. (Eds.). *Plant adaptation and crop improvement*. Wallingford: CAB International in association with IRRI and ICRISAT. 125 – 138.

Best S, León L. 2006. Análisis de datos. En: Bongiovanni R, Chartuni E, Best S, Roel A. (Eds.). *Agricultura de precisión; integrando conocimientos para una agricultura moderna y sustentable*. Montevideo: PROCISUR. 145 – 170.

Bhatti AU, Mulla DJ, Frazier BE. 1991. Estimation of soil properties and wheat yields on complex eroded hills using geostatistics and thematic mapper images. *Remote Sensing of Environment*, 37(3): 181 – 191.

Bishop TFA, Lark RM. 2006. The geostatistical analysis of experiments at the landscape-scale. *Geoderma*, 133: 87 – 106.

Bonilla C, Terra JA, Gutiérrez L, Roel A. 2015. Cosechando los beneficios de la agricultura de precisión en un cultivo de arroz en Uruguay. *Agrociencia Uruguay*, 19(1): 112 – 121.

Borges A, González A, Ernst O, Cadenazzi M, Gutiérrez L. 2014. Comparison of experimental designs and spatial models based on simulated data using real field spatial heterogeneity in agricultural experimentation. Abstract para el XXVIIth International Biometric Conference (Florencia, Italia), sin publicación escrita por parte del congreso. Disponible en: <http://www.ibs-italy.info/ibc-2014.html>. [Datos sin publicar].

Brownie C, Gumpertz ML. 1997. Validity of spatial analyses for large field trials. *Journal of Agricultural, Biological and Environmental Statistics*, 122: 1 – 23.

Brownie C, Bowman DT, Burton JW. 1993. Estimating Spatial Variation in Analysis of Data from Yield Trials: A Comparison of Methods. *Agronomy Journal*, 85: 1244 – 1253.

Burrough PA, McDonnell RA. 1998. Principles of Geographical Information Systems. Oxford University Press. 19988: 18 – 34.

Casler MD, Undersander DJ. 2000. Forage Yield Precision, Experimental Design, and Cultivar Mean Separation for Alfalfa Cultivar Trials. *Agronomy Journal*, 92: 1064 – 1071.

Casler MD. 1999. Spatial variation affects precision of perennial cool-season forage grass trials. *Agronomy Journal*, 91(1): 75 – 81

Cochran WG, Cox GM. 1957. Experimental Design. New York: Wiley. 399

Cortez-Mendoza H, Hallauer AR. 1979. Divergent mass selection for ear length in maize. *Crop Science*, 19(2): 175 – 178.

Cressie, NAC. 1993. Statistics for Spatial Data, revised edition. New York: John Wiley & Sons. 416 – 900.

DIEA (Estadísticas Agropecuarias, Ministerio de Ganadería, Agricultura y Pesca). 2015. Anuario Estadístico Agropecuario 2015. Consultado 26 Enero 2016. Disponible en:  
<http://www.mgap.gub.uy/portal/page.aspx?2,diea,diea-anuario-2015,O,es,0>,

DIEA (Estadísticas Agropecuarias, Ministerio de Ganadería, Agricultura y Pesca). 2014. Encuesta de Arroz. Zafra 2013/14. Serie Encuestas N° 322. Consultado 20 Noviembre 2015. Disponible en:  
<http://www.mgap.gub.uy/portal/page.aspx?2,diea,diea-pub-arroz,O,es,0>,

de Mendiburu F. 2012. *Agricolae: Statistical Procedures for Agricultural Research*, reference index version 1.1-3. [En línea]. Consultado: 31 Octubre 2015. Disponible en: <http://CRAN.R-project.org/> package=agricolae. R Foundation for Statistical Computing, Vienna, Austria.

Diggle PJ, Ribeiro Jr. PJ. 2007. Model-based Geostatistics. New York: Springer Science+Business Media. 288.

Dobermann A. 1994. Factors causing field variation of direct-seeded flooded rice. *Geoderma*, 62(1–3): 125 – 150.

FAO (Food and Agriculture Organization of the United Nations). 2015. SMA-Seguimiento del mercado de arroz [En línea]. Consultado: 29 Octubre 2015. Disponible en:  
<http://www.fao.org/economic/est/publications/publicaciones-sobre-el-arroz/seguimiento-del-mercado-del-arroz-sma/es/>

Fasoula VA, Fasoula DA. 1999. Honeycomb Breeding: Principles and Applications. En: Janick J. (Eds.). Plant Breeding Reviews, Volume 18. Oxford: John Wiley & Sons. 177 – 250.

Fisher RA. 1935. The Design of Experiments (8th ed., 1966). New York: Hafner Press. 1 – 26.

Gardner CO. 1961. An evaluation of effects of mass selection and seed irradiation with thermal neutrons on yield of corn. *Crop Science*, 1: 241 – 245.

Garris AJ, Tai TH, Coburn J, Kresovich S, McCouch S. 2005. Genetic structure and diversity in *Oryza sativa* L. *Genetics*, 169: 1631 – 1638.

Gilmour AR, Cullis BR, Verbyla AP. 1997. Accounting for natural and extraneous variation in the analysis of field experiments. *Journal of Agricultural, Biological and Environmental Statistics*, 2: 269 – 293.

Glaszmann, JC. 1987. Isozymes and classification of Asian rice varieties. *Theoretical and Applied Genetics*, 74: 21 – 30.

Goovaerts, P. 1999. Geostatistics in soil science: state-of-the-art and perspectives. *Geoderma*, 89(1-2): 1 – 45.

Grondona MO, Crossa J, Fox P, Pfeiffer W. 1996. Analysis of variety yield trials using two-dimensional separable ARIMA processes. *Biometrics*, 52(2): 763 – 770.

Grondona MO, Cressie NAC. 1991. Using Spatial Considerations in the Analysis of Experiments. *Technometrics*, 33(4): 381 – 392.

Hallauer AR, Sears JH. 1969. Mass selection for yield in two varieties of maize. *Crop Science*, 9(1): 47 – 50.

Hill M, García Prechac F, Terra J, Sawchik J. 2008. Incorporación del efecto del contenido de agua en el suelo en el modelo USLE/RUSLE para estimar erosión en Uruguay. *Agrociencia Uruguay*, XII (2): 57 – 67.

Hengl T. 2009. A Practical Guide to Geostatistical Mapping (2<sup>nd</sup> ed.). Amsterdam: University of Amsterdam. 1 – 60.

INIA (Instituto Nacional de Investigación Agropecuaria). 2009. 10 Años de la Unidad de Producción Arroz-Ganadería. Serie Técnica N° 180 [En línea]. Consultado: 22 Noviembre 2014. Disponible en:  
<http://www.inia.uy/Publicaciones/Documentos%20compartidos/18429091209105753.pdf>

INIA (Instituto Nacional de Investigación Agropecuaria). 1993. Rotación arroz-pasturas: análisis físico económico del cultivo. Serie Técnica N° 38 [En línea]. Consultado: 01 Noviembre 2015. Disponible en:  
<http://www.inia.uy/Publicaciones/Documentos%20compartidos/111219220807121346.pdf>

IRRI (International Rice Research Institute). 2012. Rice Today, 11(3): 21 – 23.

IRRI (International Rice Research Institute). 2006. Bringing hope, improving lives: strategic plan 2007-2015. Manila: IRRI. 61.

Juliano BO. 1993. Rice in human nutrition. FAO Food and Nutrition Series, 26: 1 – 15.

Khush GS. 1997. Origin, dispersal, cultivation and variation of rice. Plant. Molecular Biology. Springer, 35(3): 25 – 34.

Koch E, Rigney J. 1951. A method of estimating optimum plot size from experimental data. Agronomy Journal, 43: 17 – 21.

Kravchenko AN, Robertson GR, Snap SS, Smucker AJM. 2006. Using Information about Spatial Variability to Improve Estimates of Total Soil Carbon. Agronomy Journal, 98(3): 823 – 829.

Mackill DJ, Lei X. 1997. Genetic variation for traits related to temperate adaptation of rice cultivars. Crop Science, 37(4): 1340 – 1346.

Moreno-González J, Cubero JI. 1993. Selection strategies and choice of breeding methods. En: Hayward MD, Bosemark NO, Romagosa T. (Eds.). Plant breeding: principles and prospects. Netherlands: Springer Science & Business Media. 281 – 313.

Mulla DJ, McBratney AB. 2002. Soil spatial variability. En: Warrick AW. (Eds.). Soil physics companion. Boca Ratón: CRC. 343 – 373.

Oka HI. 1988. Origin of cultivated rice. Tokyo/Amsterdam: Japan Scientific Societies Press. Elsevier. 128 – 138.

OPYPA (Oficina de Programación y Política Agropecuaria). 2015. Análisis Sectorial y Cadenas Productivas. Estudios. Temas de Política. Anuario 2015 [En línea]. Consultado: 20 Enero 2016. Disponible en:  
<http://www.mgap.gub.uy/portal/page.aspx?2,opypa,opypa-anuario-2015,O,es,0>,

Pinheiro J, Bates D, DebRoy S, Sarkar D & the R Development Core Team. 2013. nlme: Linear and Nonlinear Mixed Effects Models, reference index version 3.1-124. [En línea]. Consultado: 18 Enero 2015. Disponible en: <http://CRAN.R-project.org/package=nlme>. R Foundation for Statistical Computing, Vienna, Austria.

Pravia MV. 2009. Uso de los elementos de agricultura de precisión y modelos de simulación para la incorporación de la dimensión espacio-temporal en la investigación de cultivos agrícolas. Tesis de Maestría. Universidad de la República Oriental del Uruguay, Facultad de agronomía, Programa de posgrado.

Qiao CG, Basford KE, DeLacy LH, Cooper M. 2000. Evaluation of experimental designs and spatial analyses in wheat breeding trials. *Theoretical and Applied Genetics*, 100: 9 – 16.

R Development Core Team. 2012. R: A language and environment for statistical computing, reference index version 3.1.3. [En línea]. Consultado: 20 Julio 2015. Disponible en: <http://www.Rproject.org>. R Foundation for Statistical Computing, Vienna, Austria.

Ribeiro Jr. PJ, Diggle PJ. 2001. geoR: A package for geostatistical analysis. *R-NEWS*, 1(2): 15 – 18.

Ripley BD. 1981. Spatial Statistics. New York: Wiley. 1 – 272.

Robinson DL, Kershaw CD, Ellis RP. 1988. An investigation of two-dimensional yield variability in breeders' small plot barley trials. *Journal of Agricultural Science*, 111: 419 – 426.

Roel A, Firpo H, Plant R.. 2007. Why do some farmers get higher yields? Multivariate analysis of a group of Uruguayan rice farmers. *Science Direct*, 58: 78 – 92.

Roel A, Terra J. 2006. Muestreo de suelos y factores limitantes del rendimiento. En: Bongiovanni R, Chartuni E, Best S, Roel A. (Eds.). *Agricultura de precisión; 80 integrando conocimientos para una agricultura moderna y sustentable*. Montevideo: PROCISUR. 65 – 80.

Roel A, Plant RE. 2004. Factors underlying yield variability in two California rice fields. *Agronomy Journal*, 96(5): 1481 – 1494.

Simmonds MB, Plant RE, Peña-Barragán JM, van Kessel C, Hill J, Linquist BA. 2013. Underlying causes of yield spatial variability and potential for precision management in rice systems. *Precision Agriculture*, 14: 512 – 540.

Smith KF, Casler MD. 2004. Spatial Analysis of Forage Grass Trials across Locations, Years and Harvests. *Crop Science*, 44: 56 – 62.

Terra JA, Cantou G, Deambrosi E, Molina F, Roel A, Casales LA, Ferreria D, Ferreira D. 2008. Efecto de dos alternativas de densidad de siembra y dosis de nitrógeno en el rendimiento de EP144 a escala de chacra. En: Arroz: Resultados Experimentales 2007-2008. Montevideo: INIA. (Actividades de Difusión; 545). 15 – 22.

- Terra JA, Shaw JN, Reeves DW, Raper RL, van Santen E, Schwab EB, MasK PL. 2006. Soil management and landscape variability affects field-scale cotton productivity. *Soil Science Society of America Journal*, 70: 98 – 107.
- USDA (United States Department of Agriculture). 2016. Economic Research Service. Rice Outlook N° (RCS-16A) [En línea]. Acceso: 28 Enero 2016. Disponible en: <http://ers.usda.gov/publications/rcc-rice-outlook/rcc-16a.aspx>
- USDA (United States Department of Agriculture). 2015. Economic Research Service. Rice Outlook N° (RCS-15L) [En línea]. Acceso: 28 Enero 2016. Disponible en: <http://ers.usda.gov/publications/rcc-rice-outlook/rcc-15l.aspx>
- Verhalen LM, Baker JL, McNew RW. 1975. Gardener's Grid System and Plant Selection Efficiency in Cotton. *Crop Science*, 15(4): 588 – 591.
- Watson GS. 1972. Trend surface analysis and spatial correlation. *Geology Society of America Special Paper*, 146: 39 – 46.
- Watson GS. 1971. Trend-Surface Analysis. *Mathematical Geology*. Springer, 3(3): 215 – 226.
- Webster R, Oliver MA. 2007. *Geostatistics for Environmental Scientists*/2<sup>nd</sup> Edition. Chichester: John Wiley & Sons. 1 – 330.
- Wollenhaupt NC, Mulla DJ, Gotway Crawford, CA. 1997. Soil Sampling and Interpolation Techniques for Mapping Spatial Variability of Soil Properties En: Pierce FR., Sadler EJ. (Eds.). *The State of Site-Specific Management for Agriculture*. Madison: ASA, CSSA, SSSA. 19 – 53.

Yanai J, Lee CK, Kaho T, Lida M, Matsui T, Umeda M, Kosaki, T . 2001. Geostatistical analysis of soil chemical properties and rice yield in a paddy field and application to the analysis of yield-determining factors. *Soil Science and Plant Nutrition*, 47(2): 291 – 301.

Yates F. 1940. The recovery of interblock information in balanced incomplete block designs. *Annals of Eugenics*, 10: 317 – 325.

Yates, F. 1939. The recovery of inter-block information in variety trials arranged in three dimensional lattices. *Annals of Eugenics*, 9:135 – 156.