

# LA GEOESTADÍSTICA COMO HERRAMIENTA DE ANÁLISIS ESPACIAL DE DATOS DE INVENTARIO FORESTAL

**M. Chica-Olmo**

Universidad de Granada. Departamento de Geodinámica/CEAMA. Avda. Fuente Nueva s/n. 18071-GRANADA (España). Correo electrónico: mchica@ugr.es

## Resumen

Entre la diversidad de métodos existentes de análisis de datos espaciales destacan los métodos geoestadísticos, tanto por su carácter operativo como por la calidad de sus resultados. Así, entre otros aspectos de interés, los métodos de estimación, krigeaje, o de simulación condicional, facilitan la creación de cubiertas temáticas (mapas temáticos) a partir de datos experimentales de distinta naturaleza (cualitativos y cuantitativos), lo que resulta de una ayuda inestimable en el proceso de integración de datos a través de un SIG. En este trabajo se presenta una síntesis de los fundamentos de los métodos geoestadísticos de estimación y simulación y su aplicación al análisis de datos de inventario forestal. Particularmente, se ha querido estudiar el problema de creación de mapas temáticos mediante la aplicación de dichos métodos geoestadísticos que, aún siendo todavía poco utilizados, quizá debido a una infundada complejidad teórica, ofrecen excelentes posibilidades de aplicación. Con ello pretendemos facilitar al interesado en el estudio de los recursos forestales la comprensión de los aspectos teóricos fundamentales y de las reglas prácticas necesarias para el desarrollo de una aplicación geoestadística. La explicación se apoya en diversas variables tomadas de la base de datos de parcelas del Inventario Ecológico y Forestal de Cataluña.

Palabras clave: *Geoestadística, Krigeaje, Métodos de Estimación, Simulación Condicional*

## LA APROXIMACIÓN GEOESTADÍSTICA

El análisis espacial de datos experimentales constituye un tema importante en cualquier proyecto relacionado con el estudio del medio ambiente. Con gran frecuencia este análisis persigue el objetivo de crear información temática cartográfica, a modo de mapas que representen de la forma más fiable posible la distribución de la variable experimental en el área de estudio. Además, es muy posible que dicha información sea posteriormente integrada con otras informaciones incluidas en la base de datos SIG (gestión medioambiental). El problema se presenta habi-

tualmente en estudios en los que se dispone de observaciones experimentales (muestreos) a partir de las cuales deseamos predecir (cartografiar) la distribución espacial de las variables o atributos estudiados. Dos cuestiones que recaban nuestra atención subyacen en tal situación: en primer lugar, los datos, aquella parte de la realidad desconocida a la que podemos acceder experimentalmente y, en segundo lugar, los métodos de análisis numérico que aplicaremos al estudio de los datos anteriores. En esencia, se desea resolver una ecuación simple pero a la vez tan compleja como *datos más análisis igual a información*.

La toma de datos experimentales es una parte esencial en cualquier estudio de variables espaciales, que en el caso que nos ocupa están referidas al inventario forestal, y que es obvio tiene connotaciones tanto prácticas como económicas. Frecuentemente, la localización de los puntos (áreas) de observación se hace de forma irregular, atendiendo a criterios preferenciales del experto; aunque en otros casos, la ubicación de los puntos se hace atendiendo a lo dictado por modelos estadísticos derivados de la teoría de muestreo. En cualquier caso, los datos (muestras) deben cumplir los criterios de homogeneidad y representatividad del fenómeno estudiado, para que puedan ser utilizados, por ejemplo, para la elaboración de mapas temáticos mediante técnicas de interpolación espacial. Además, el muestreo debe de establecer el soporte de información más adecuado; es frecuente ver estudios que mezclan soportes de información de las variables lo cual es un error manifiesto. Dejando a un lado el factor económico, que a fin de cuentas establece el número total de muestras a tomar, es el factor de la variabilidad espacial de las variables estudiadas al que debemos prestar especial atención, puesto que, a ser posible, el método de análisis de datos escogido deberá de considerarlo explícitamente en sus fundamentos. Esta característica de variabilidad es inherente a

cada variable y viene impuesta por los propios procesos naturales que han dado origen al recurso estudiado, en nuestro caso, al desarrollo de la vegetación forestal (clima, relieve, geología, suelos, etc). Es precisamente al estudio de este factor al que se dirige nuestra atención, escogiendo, arbitrariamente, para ello un marco conceptual topo-probabilístico en el cual se fundamenta la metodología geoestadística. Como se muestra a lo largo de este trabajo, la metodología geoestadística que tiene su fundamento en la Teoría de las Variables Regionalizadas (MATHERON, 1970), se adapta bien al estudio de las variables del inventario forestal, resolviendo problemas de índole práctica que surgen en la gestión de estos recursos naturales, por medio de los métodos de estimación y simulación espaciales.

En la figura 1 se ha querido esquematizar las etapas básicas de un estudio geoestadístico. Como hipótesis de partida se asume que la variables experimentales forestales, p.e. área basal, volumen del tronco, índice de área foliar, etc, son variables regionalizadas; es decir, variables que tienen una distribución espacial y que presentan una estructura de variabilidad, o de correlación, caracterizada por la función variograma; características que, sin lugar a dudas, posee cualquiera de las variables del inventario forestal mencionadas. En el análisis estructural se calcula, interpre-

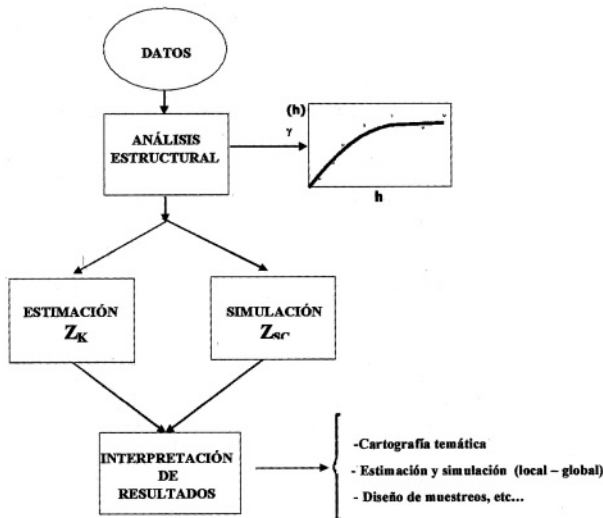


Figura 1. Esquema metodológico de un estudio geoestadístico

ta y modela la función variograma como paso previo a la aplicación posterior de un método de estimación o de simulación espacial. Los métodos de estimación son de aplicación en aquellos estudios que exigen el conocimiento del *valor más probable* de la variable en un punto o área no muestreada (problema de estimación lineal). Aunque también pueden estimarse funciones de la variable, como por ejemplo la estimación de la probabilidad de que en un área determinada la producción maderable supere un valor límite, aspecto interesante en gestión medioambiental (problema de estimación no lineal). La simulación es aplicable a problemas relacionados con el análisis de la variabilidad espacial y proporciona un modelo numérico que reproduce la variabilidad observada en la variable; es, por tanto, un *valor posible* de la realidad desconocida. El gran interés radica en hacer un uso conjunto (según la naturaleza del estudio) de ambas metodologías, a modo de una herramienta que nos ofrezca una gran potencialidad para la gestión de los recursos forestales. La idea es sencilla, si admitimos que las decisiones puedan tomarse sobre los valores estimados (planificación prevista) y analizar el alcance de las mismas a través del modelo simulado (planificación realizada). Son numerosos los casos prácticos en los que esta aproximación ya ha sido utilizada para la planificación de explotación de recursos, especialmente minerales (CHICA, 1983, 1987).

## VARIABILIDAD ESPACIAL Y VARIOGRAMA

Desde que MATHERON (1970) formula su Teoría de Variables Regionalizadas en 1970, los métodos geoestadísticos han tenido una progresiva y amplia aceptación en un amplio espectro del ámbito científico, como metodología capaz de dar una respuesta adecuada a problemas “prácticos” relacionados con la estimación o simulación de variables espaciales. Esta teoría se fundamenta en la interpretación de las variables experimentales como *variables regionalizadas*, es decir como variables caracterizadas por una distribución espacial y una estructura de variabilidad espacial (o de correlación espacial). Como se señalaba anteriormente, esta última característica es un fac-

tor de gran importancia a tener en cuenta no sólo en el reconocimiento experimental, sino también a la hora de elegir el modelo de estimación espacial más adecuado. Ningún otro método considera de forma explícita la variabilidad espacial del fenómeno estudiado, impuesta por los procesos genéticos que lo han originado. Precisamente en el estudio de este aspecto se encuentra la base de la metodología geoestadística.

Una variable regionalizada se interpreta como una función aleatoria  $Z(x)$  que da el valor de la variable  $Z$  en un punto del espacio  $x$  del espacio. Es obvio que un gran número de las variables forestales y, en general, medioambientales pueden ser interpretadas como variables regionalizadas, p.e. área basal o la producción maderable. Estas variables poseen un carácter aleatorio, que induce a la noción de variable aleatoria (pero sin asumir la independencia entre variables como preconiza la estadística clásica) y un carácter estructural, propio de cada fenómeno estudiado o regionalización, definido por la función variograma.

La función variograma ( $h$ ), herramienta de análisis de la variabilidad espacial, se define como una función aleatoria intrínseca que representa la mitad de los incrementos cuadráticos medios de  $Z(x)$  para puntos distantes el vector  $h$ :

$$\gamma(h) = 1/2 E \{Z(x) - Z(x+h)\}^2$$

El variograma es una función vectorial cuyo argumento es el vector de distancia  $h$ , que cuantifica la varianza de los incrementos de primer orden de la función (MATHERON, 1970; CHICA, 1987). Es manifiesto el interés práctico que suscita el estudio de esta función, pues conduce al conocimiento de la variabilidad espacial de la variable; es, en consecuencia, una herramienta potente, reveladora de la estructura de variación espacial de la variable forestal  $Z(x)$ . La estimación experimental de la función a partir del conjunto de datos experimentales se efectúa aplicando la siguiente fórmula clásica (estimador insesgado):

$$\gamma(h) = \frac{1}{2NP(h)} \sum_{i=1}^{NP(h)} \{z(x_i) - z(x_{i+h})\}^2$$

donde  $z(x_i)$  y  $z(x_{i+h})$  son los valores numéricos de la variable forestal observada en los puntos  $x_i$  y  $x_{i+h}$ ;  $NP(h)$  es el número de parejas formadas para una distancia  $h$ .

El análisis estructural (o variográfico) comprende tres etapas: la estimación e interpretación del variograma, el ajuste del estimador a un modelo teórico y la validación del modelo ajustado. Es especialmente importante el estudio del comportamiento del gráfico del variograma al proporcionar una descripción de la estructura de variación espacial de la variable. Esta información puede resumirse en: zona de influencia (valores de alcance y meseta), comportamiento en el origen (efecto de pepita), anisotropías (factores de anisotropía zonal o geométrica), asimismo de comportamientos particulares (CHICA, 1987). Las figuras 2a-b representan los variogramas de las variables “área basal” y “cobertura arbustiva” de los datos correspondientes al inventario Ecológico y Forestal de Cataluña (comarca del Valles Occidental). Como se constata son dos variables que tienen distinto comportamiento en su distribución espacial, con modelos de variograma que se diferencian esencialmente en su componente aleatoria (efecto de pepita) y en el alcance del variograma, mucho mayor para la variable “área basal”.

El variograma es una función vectorial por lo que puede calcularse en cualquier dirección del espacio, facilitando así el estudio de anisotropías en la distribución espacial de la variable. Un ejemplo correspondiente a la variable “volumen del tronco” se presenta en la figura 3.

Otro aspecto de interés es el análisis de variabilidad espacial entre variables, que puede hacerse por medio del variograma cruzado de las variables  $Z_j(x)$  y  $Z_k(x)$ , cuya expresión es la siguiente:

$$\gamma_{jk}(h) = \frac{1}{2n(h)} \sum_{i=1}^{n(h)} \{Z_j(x_i) - Z_j(x_i+h)\} \cdot \{Z_k(x_i) - Z_k(x_i+h)\}$$

Un ejemplo de variograma cruzado entre las variables “volumen tronco” y “área basal” se presenta en la figura 4. De esta gráfica se deduce la correlación entre las dos variables en función del vector  $h$  de distancia; concretamente, para el ejemplo mostrado, las variables mantienen una buena correlación cruzada espacial que sugiere un uso conjunto en un procedimiento de coestimación de cualquiera de ellas (cokrigeaje), con el beneficio consiguiente de reducción de los errores de estimación.

## LA ESTIMACIÓN ESPACIAL: EL KRIGEAJE

El krigaje (traducción al español del término original francés *Krigeage* propuesto por MATHERON) es el método de estimación geoestadística que proporciona el *valor más probable* de una variable espacial en un punto (o bloque) no experimental. El krigaje es un estimador ELIO (*Estimador Lineal, Insesgado y Óptimo*), del que existe una gran variedad de métodos propuestos para abordar las diversas situaciones de índole teórica o práctica que encontramos en estimación espacial (krigeaje ordinario, krigaje simple, krigaje universal, krigaje disyuntivo, krigaje de indicatrices, etc). Estos métodos se clasifican en dos grandes grupos en función de la estructura del estimador, lineales y no lineales. Seguidamente, se exponen de forma resumida los fundamentos de algunos de estos métodos más representativos, atendiendo a la sencillez de su aplicación y a la calidad de los resultados obtenidos.




Figura 2. Variogramas experimentales de las variables “Área basal” (a) y “Cobertura arbustiva” (b)

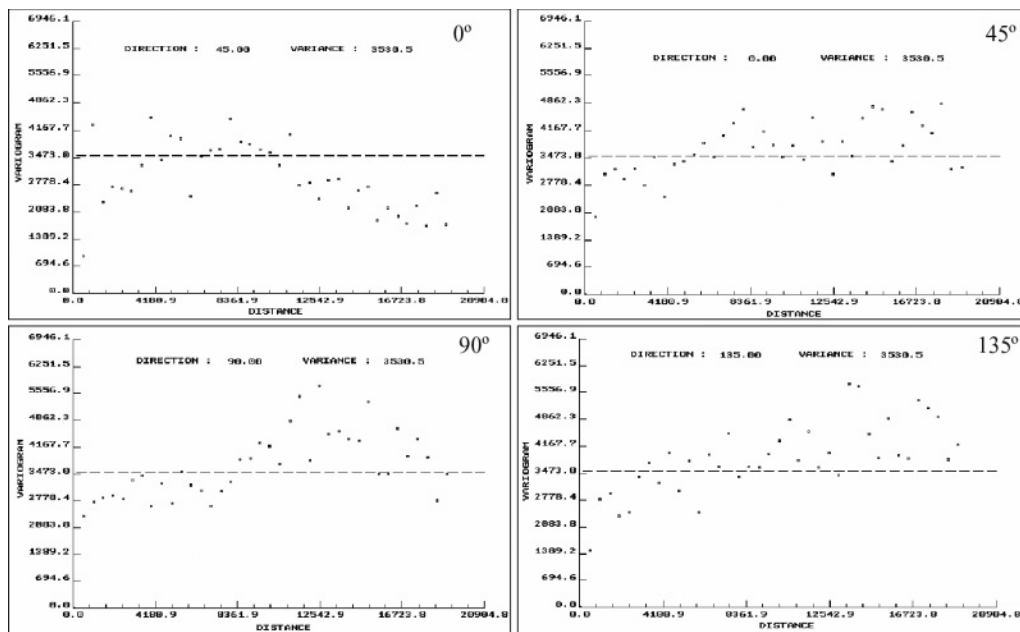


Figura 3. Variogramas experimentales direccionales de la variable “Volumen tronco”

**Krigeaje Ordinario (KO)**

El objetivo de aplicar un método de estimación espacial (interpolación) es predecir el valor de la variable estudiada en localizaciones (puntos o áreas) no reconocidos experimentalmente. El método de krigeaje aborda este problema proporcionando un estimador óptimo del valor de la variable  $Z(x)$  en el soporte de información  $v$  (puntual o valor medio),  $Z_v(x)$ . Para ello utiliza

el conjunto de datos experimentales  $\{z(x_i), i=1...n\}$  y la función variograma  $\gamma(h)$  que caracteriza la estructura de variabilidad espacial de la variable. Como hipótesis asumimos que  $Z(x)$  es una función aleatoria estacionaria de segundo orden; es decir, con esperanza constante  $E\{Z(x)\}=m$  y dotada de covarianza  $C(h)$ , o lo que es igual de variograma  $\gamma(h)$  (sólo en el caso estacionario).

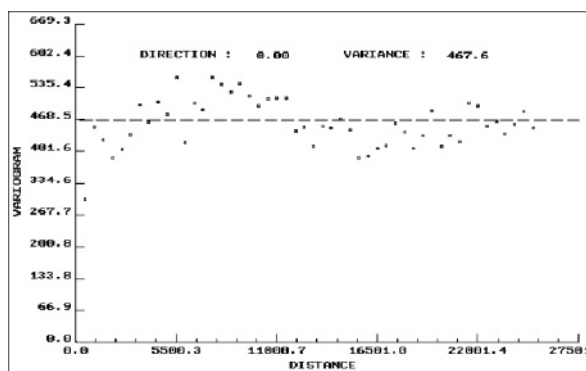


Figura 4. Variograma cruzado experimental de las variables “Área basal” y “Volumen tronco”

El estimador de Krigeaje Ordinario  $Z_{KO}$  (MATHERON, 1970; JOURNEL & HUIJBREGTS, 1978) del valor buscado es simplemente una ponderación lineal de los valores experimentales  $Z(x_i)$  por coeficientes  $\lambda_i$  desconocidos (ponderadores de krigeaje):

$$Z_{KO}(x) = \sum_{i=1}^n \lambda_i Z(x_i)$$

Cabe señalar que la estructura lineal anterior es equivalente a la de otros muchos métodos no geoestadísticos, basados en aspectos geométricos o funciones deterministas (p.e. inverso de la distancia). La diferencia radica en el procedimiento de búsqueda de los ponderadores  $\lambda_i$ . Para ello se quiere que el estimador  $Z_{KO}$  sea óptimo cumpliendo las condiciones de no sesgo y de error de estimación mínimo. La primera condición, expresada de la forma  $E\{Z_v\} = E\{Z_{KO}\}$ , se obtiene imponiendo que  $\sum \lambda_i = 1$ , (condición de universalidad) que asegura que la estimación es insesgada. Además, otra condición aún más fuerte es sobre el error de estimación, que sea mínimo  $\sigma_{KO}^2 = E\{Z_v - Z_{KO}\}^2 \rightarrow 0$ , expresión que admite un desarrollo cuadrático en términos de la función variograma,  $\gamma(h)$  (JOURNEL & HUIJBREGTS, 1978). La minimización de la expresión del error por medio de la técnica de Lagrange, bajo la condición de universalidad, conduce al sistema de krigeaje, cuya solución es el conjunto de ponderadores de krigeaje  $\lambda_i$  y el parámetro de Lagrange  $\mu$ .

$$\sum \lambda_\beta \gamma(\alpha, \beta) + \mu = \gamma(\alpha, v)$$

$$\forall \alpha, \beta = 1, \dots, n$$

$$\sum \lambda_\alpha = 1 \quad \mu = \text{parámetro de Lagrange}$$

En un contexto operacional de estimación de recursos naturales, las ventajas más importantes del método, pueden sintetizarse de la siguiente forma: el estimador  $Z_v^{ko}$  es óptimo en el sentido de minimización del error de estimación; tiene en cuenta el soporte de información  $v$ , puntual o valor medio; considera la geometría del conjunto estimador y estimado; y proporciona una valoración probabilística del error de estimación  $\sigma_{KO}^2$ , lo que sin duda es de gran valor para la interpretación de los resultados sobre todo, de cara a la integración de los datos estimados en un SIG (p.e. Sistema Soporte de Decisión):

$$\sigma_{KO}^2 = \sum_{\alpha} \lambda_{\alpha} \gamma(\alpha, v) + \mu - \gamma(v, v)$$

Un ejemplo de aplicación del método se muestra en la figura 5a-b, que representa el mapa de estimación por bloques de la variable “área basal” junto con el mapa de errores de estimación.

### Estimación de funciones de la variable: El Krigeaje de Indicatrices

El análisis de datos espaciales requiere, en muchas ocasiones, estimar funciones de  $Z(x_0)$ , lo que implica estimar la función de distribución condicional local  $\{Z(x_0)/z(x_i), i=1, \dots, n\}$  (CHICA Y LUQUE, 2002). Esta situación es frecuente en ciencias ambientales cuando el especialista busca áreas en las que un determinado contaminante supera un valor límite *problema de alerta*. Con excesiva frecuencia, se observa que la solución práctica adoptada se reduce a la simple estimación de  $Z$  en el área de estudio, por cualquier método, y, seguidamente, aplicar un corte al valor estimado ( $Z^*(x_0) > z_c$ ). Es importante recordar que la distribución de  $Z$  y  $Z^*$  no coinciden y, por tanto, los resultados de aplicar el corte sobre el estimador no son óptimos, desde el punto de vista de los resultados, por lo que los errores en la toma de decisiones pueden ser importantes. El problema se reduce a determinar la función de distribución acumulada  $F(z) = \Pr\{Z(x_0) < z_c\}$  cuando el límite  $z_c$  varía en un rango de valores (CHILÈS & DELFINER, 1999; CHICA Y LUQUE, 2002). Por tanto, ahora, se necesita estimar una función de  $Z(x_0)$  y no solamente la esperanza matemática de  $Z$  en el punto  $x_0$ , como ocurría en el caso anterior (KO). Además, otro aspecto a considerar es la escala local para estimar la función de distribución. Para la resolución de este problema de estimación local de la función de distribución condicional de una variable, se han propuestos diversos métodos geoestadísticos paramétricos y no paramétricos. Entre los primeros destaca el método de estimación no lineal de Krigeaje Disyuntivo, y entre los segundos el método de Krigeaje de Indicatrices. Por su sencillez de aplicación se expondrá un breve resumen de este segundo método propuesto por JOURNEL (1983, 1984); no obstante en CHICA Y LUQUE (2002) puede verse una aplicación de ambos métodos en ciencias ambientales.

El método de kriging de indicatrices consiste en una transformación binomial de la variable  $Z(x)$  en la variable indicatriz,  $I(x_0, z_c) = \{1 \text{ si } Z(x_0) \leq z_c; 0 \text{ si } Z(x_0) > z_c\}$ . Un kriging simple de  $I(x_0, z_c)$  nos da la probabilidad estimada que  $Z(x)$  sea inferior al valor de corte  $z_c$ . El planteamiento del método es sencillo, basta repetir el proceso de estimación de las indicatrices obtenida para diferentes valores de  $z_c$ , para así obtener una aproximación discreta de la función de distribución condicional.

La ventaja del método radica en su gran simplicidad práctica, debido a que la transformación es sencilla e, incluso, aplicable a variables categóricas. Como inconveniente señalamos el cálculo de la función mediante un proceso de discretización que necesita un número suficiente de valores de corte  $z_c$ . Para cada uno de estos valores se debe realizar un análisis variográfico y resolver un sistema de kriging. Para evitar este proceso, que puede ser largo y tedioso, se aplica una simplificación basada en el uso de un único variograma indicatriz correspondiente a la mediana de la variable. Esta estructura se deduce del valor de corte coincidente con la mediana de los datos y es aplicable a todas las indicatrices. De esta forma se asume que todos los variogramas de las indicatrices son proporcionales y consecuentemente los pesos obtenidos de los sistemas de kriging son iguales (DEUTSCH & JOURNAL, 1993). Esta hipótesis simplifica notablemente el proceso de cálculo, resultando la siguiente expresión para la estimación de la probabilidad  $\Pr\{Z(x_0) < z_c\}$ :

$$I(x_0, z_c)_{SK}^* = \sum_{i=1}^n \lambda_i(z_c) I(x_i, z_c) + \left[ 1 - \sum_{i=1}^n \lambda_i(z_c) \right] F(z_c)$$

donde los  $\lambda_i$  son los pesos de kriging simple, iguales para todos los valores de corte  $z_c$ . El sistema de ecuaciones se expresa en términos del variograma de la indicatriz mediana  $\gamma_1(h, z_c) = 1/2 E\{I(x+h, z_c) - I(x, z_c)\}^2$ :

$$\sum_{j=1}^n \lambda_j(z_c) \gamma_j(x_i, x_j) = \gamma_i(x_0 - x_i), \quad i, j = 1, \dots, n$$

$$\sigma_{IK}^2 = \sum_{i=1}^n \lambda_i(z_c) \gamma_i(x_i, x_0) - \gamma_i(x_0 - x_0), \quad i = 1, \dots, n$$

El error de kriging viene dado por:

Como ejemplo la figura 6a-d representa una aplicación del método para elaborar un mapa de isoprobabilidad correspondiente a que la variable “área basal” supere un valor de corte  $z_c = 25$ .

### SIMULACIÓN ESPACIAL: LA SIMULACIÓN CONDICIONAL

Con carácter general debe decirse que los métodos de estimación no pueden ser utilizados para elaborar modelos numéricos que reproduzcan la variabilidad espacial de la variable. La razón esencial reside en la característica de suavizado del valor real que posee cualquier estimador; incluso el kriging que es óptimo en el sentido de minimizar el error de estimación. Por ello, hay que recurrir a otros métodos como es la Simulación Condicional (JOURNAL, 1974; CHICA, 1987), que permite elaborar un modelo con las siguientes características:

1. El modelo numérico de simulación reproduce los parámetros estadísticos y de distribución de los datos experimentales, media, varianza, histograma y variograma. Es decir, si  $Z_{sc}(x)$  representa la variable simulada y  $Z(x)$  la variable experimental, se tiene que:  

$$E\{Z(x)\} = E\{Z_{sc}(x)\}$$

$$\text{Var}\{Z(x)\} = \text{Var}\{Z_{sc}(x)\}$$

$$F\{Z(x)\} = F\{Z_{sc}(x)\}$$

$$\gamma(h) = \gamma_{sc}(h)$$
 donde  $E\{\cdot\}$  es la esperanza matemática,  $\text{Var}\{\cdot\}$  la varianza,  $F\{\cdot\}$  la función de distribución y  $\gamma(\cdot)$  la función variograma.
2. El modelo está condicionado a los datos experimentales “condicionamiento”; en cualquier punto experimental valor real y simulado coinciden.
3. El modelo se conoce para todo punto o área perteneciente al espacio simulado, a diferencia de la realidad sólo conocida en los puntos experimentales, y para cualquier soporte de información, puntual o valor medio.

Todas estas características infieren a la Simulación Condicional unas excelentes posibilidades de aplicación, aún más si es utilizada conjuntamente con el método de Kriging, para el estudio de problemas encontrados en la gestión forestal (planificación de recursos).

La figura 7 muestra un ejemplo de simulación condicional de la variable “área basal”. Como se puede apreciar, la distribución de los valores presenta un aspecto más irregular que la estimación por krigeaje (figura 5), al no existir el efecto de suavizado de la estimación. En consecuencia este tipo de información puede ser utilizada en la práctica como una “*versión*” posible de la realidad forestal para cualquier punto del área de estudio. A efectos de comparación en la figura 8 se han representado los histogramas de los datos experimentales y de los valores estimados y simulados; destaca el efecto de suavizado introducido por el krigeaje (varianza de datos estimados menor que la varianza experimental) y el parecido entre el histograma experimental y el de los datos simulados.

**CONCLUSIONES**

Con cierta frecuencia se constata en la práctica que los métodos de estimación espacial (interpolación) son utilizados de forma un tanto arbitraria, quizá sin mediar un análisis previo de

las características y naturaleza de estos métodos y, en un gran número de situaciones, escogidos por la ventaja manifiesta que supone aparecer en el menú de análisis espacial del software utilizado. Aunque es cierto que la mayor parte de estos métodos conducen a estimaciones globales insesgadas, no ocurre lo mismo a nivel local, lo cual plantea un problema serio que con demasiada frecuencia pasa inadvertido para el usuario. Sólo las estimaciones realizadas mediante métodos geoestadísticos proporcionan estimaciones locales fiables, fundamentadas en el uso de la estructura de variabilidad espacial, es decir el variograma. Por esta razón los métodos geoestadísticos de estimación / simulación poco a poco van ocupando un lugar relevante en el análisis de datos espaciales, en general, entre los que deben de incluirse los datos de inventario forestal.

El método de krigeaje, en sus diferentes modalidades, produce estimaciones óptimas de la variable espacial, al minimizar el error de estimación y por la condición de no sesgo del estimador, tanto a escala global como local. El mapa de estimación elaborado por este método debe interpretarse en la práctica como la “*imagen*”

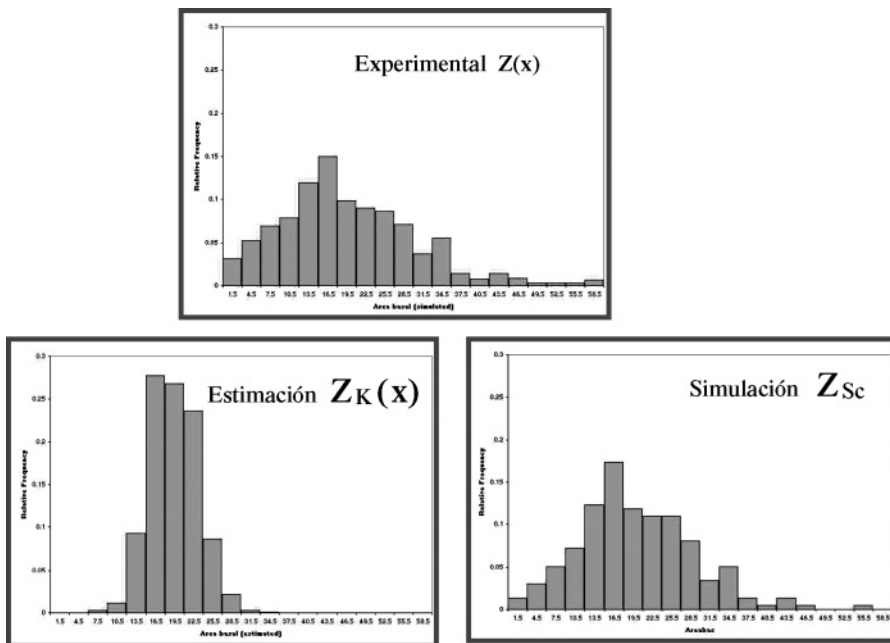


Figura 8. Comparación de histogramas experimental, estimación y simulación condicional



más probable de la distribución espacial de la variable estudiada. Su estructura de datos ráster hace que sea fácilmente integrable en bases de datos geoespaciales como cubierta de información SIG. Además, el método proporciona el mapa de errores de estimación, aspecto de máximo interés en actividades de planificación medioambiental, a través de la interpretación de los errores relativos de estimación.

Otras ventajas, nada despreciables, son que el método considera el efecto de soporte en la estimación y su adaptación a cualquier problema particular relacionado con la estimación de la variable o de funciones de ésta (valor medio, estimación de funciones de distribución local, etc.).

De su parte, la simulación condicional al reproducir la variabilidad experimental observada, puede interpretarse como una “versión” posible de la realidad desconocida. Su robustez, en cuanto a la reproducción de estadísticos, de distribución espacial y condicionamiento, hace que las posibilidades de aplicación del método, junto con el de krigeaje, sean muy variadas e interesantes en el estudio de problemas encontrados en la gestión forestal.

### Agradecimientos

El autor desea manifestar su agradecimiento al Dr. Santiago Saura de la Universitat de Lleida por su amable invitación a participar en estas I Jornadas sobre Inventario y Teledetección Forestal; asimismo, por haber facilitado la base de datos del Inventario Ecológico y Forestal de Cataluña (comarca del Vallès Occidental), que ha permitido desarrollar las aplicaciones geoestadísticas mostradas en el trabajo. Igualmente, decir que este trabajo ha sido desarrollado en el

marco del Proyecto HIDROGIS del MCyT (BTE2002-00152).

### BIBLIOGRAFÍA

- CHICA, M.; 1983. *Approche Géostatistique de la Caractérisation des Ressources en Charbon*. Thèse Docteur Ingénieur de Mines. École Nationale Supérieure des Mines de Paris. Paris.
- CHICA, M.; 1987. *Análisis Geoestadístico en la Explotación de los Recursos Minerales*. Ed. Mario Chica-Olmo. Granada.
- CHICA, M. & LUQUE, J.A.; 2002. Applications of the local estimation of the probability distribution function in environmental sciences by kriging methods. *Inverse Problems*. 18: 25-36. London.
- CHILES, J.P. & DELFINER, P.; 1999. *Geostatistics. Modelling Spatial Uncertainty*. Ed. John Wiley & Sons. New York.
- DEUTSCH, C.V. & JOURNAL, A.G.; 1993. *GSLIB : Geostatistical Software Library and User's Guide*. Ed. Oxford University Press. New York.
- JOURNAL, A.G.; 1983. Non parametric estimation of spatial distributions. *Math. Geol.* 15: 445-468.
- JOURNAL, A.G.; 1984. *The place of non-parametric geostatistics*. Proc. NATO ASI. Lake Tahoe.
- JOURNAL, A.G. & HUIJBREGTS, C.J.; 1978. *Mining Geostatistics*. Academic Press. London.
- MATHERON, G.; 1970. *La Théorie des Variables Régionalisées et ses applications*. Centre Géostatistique et Morphologie Mathématique. Ecole Nationale Supérieure des Mines de Paris. Paris.

# LA GEOESTADÍSTICA COMO HERRAMIENTA DE ANÁLISIS ESPACIAL DE DATOS DE INVENTARIO FORESTAL

M. Chica-Olmo

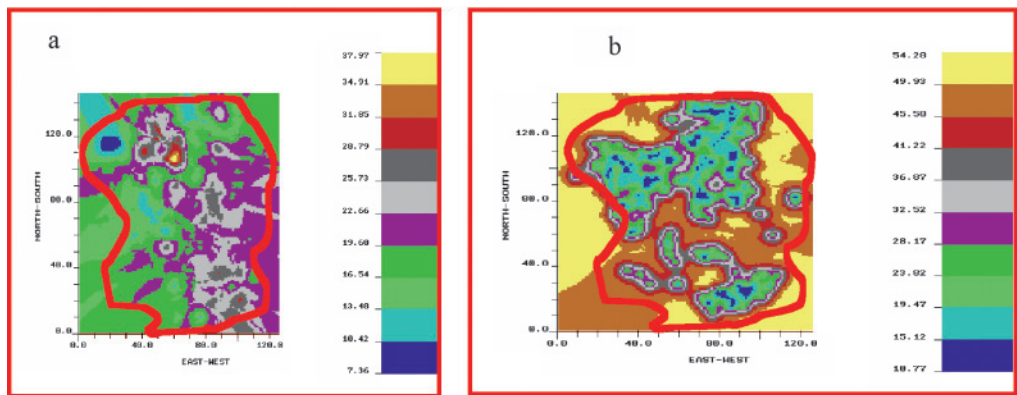


Figura 5. Mapa krigeado (a) y errores de estimación (b) de la variable “Área basal”

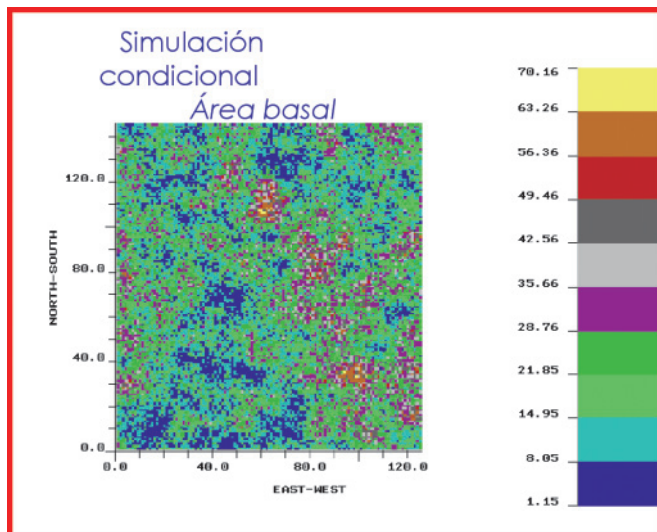


Figura 7. Simulación condicional de la variable “área basal” sobre soporte de bloque

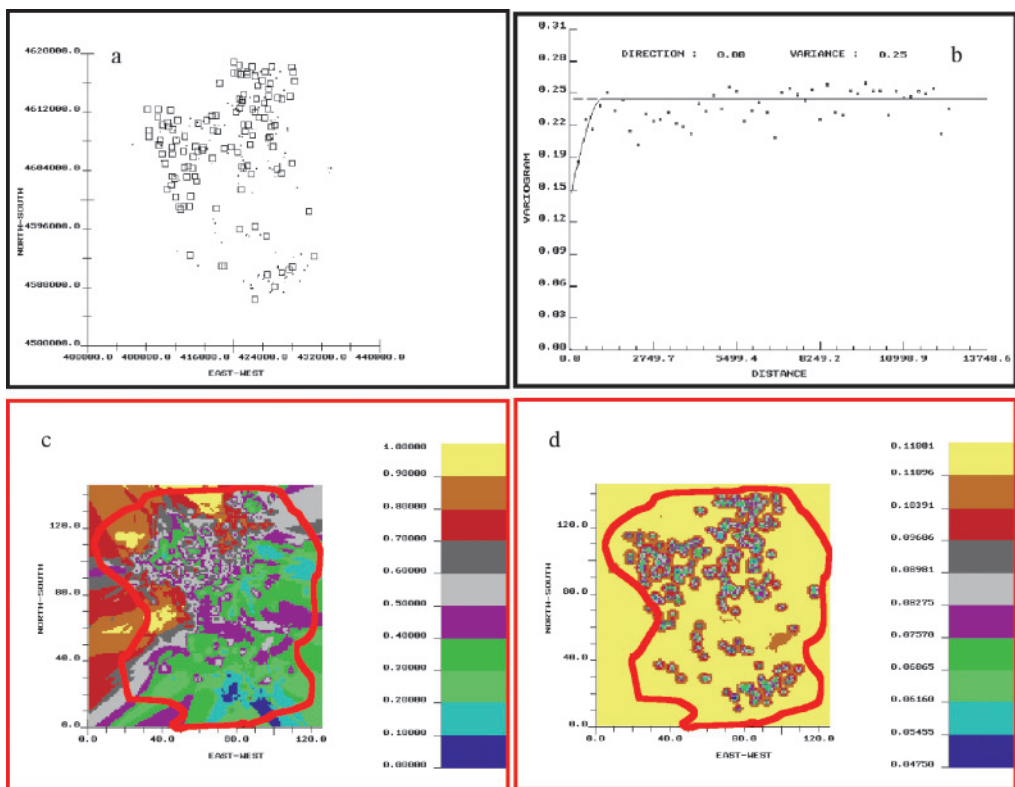


Figura 6 a-d. Distribución de datos experimentales de la variable “Área basal” (a); Variograma indicatriz correspondiente al corte  $z_c = 25$  (b); Mapa de isoprobabilidades correspondiente a “Área basal”  $\geq 25$  (c) y Mapa de errores de estimación (d)