

Curso intensivo de Kriging

- Es un método de Interpolación
- Lo hemos citado y lo citaremos en:
 - Imputación de ausencias (obvio...)
 - Detección de errores
 - Estimación de sensibilidad de modelos
- Base estadística
- Incorporado en algunos GIS (¿malamente? ¿parcialmente?...)

¿Qué es la Geoestadística?

- Def.: Aplicación de la teoría de las variables regionalizadas a la estimación de procesos en el espacio
- Si $z(x)$ es el valor de z en el punto x , $z(x)$ es una variable regionalizada
 - Concepto no probabilístico
 - Quizá función continua
- Usualmente $z(x)$ está compuesta de
 - Componentes aleatorios y
 - Componentes estructurados
 - No luce "suave"
- ➔ Conviene considerar a $z(x)$ como una función aleatoria

Algunas consecuencias...

- La realidad es simplemente una realización o instancia de un experimento aleatorio
- Sólo tenemos una realidad; hay que hacer inferencia estadística sólo con ello
 - En general no sería posible
 - Requerirá hipótesis adicionales
 - Ej.: homogeneidad espacial
- Las funciones aleatorias son sólo un modelo posible de la realidad

Definiciones...

Momentos de la distribución

- 1er. orden: Esperanza $E(Z(x))=m(x)$
 - $m(x)$ es llamada "deriva" o "tendencia"
- 2do. orden:
 - Varianza $Var(Z(x))=E((Z(x)-m(x))^2)$
 - Covarianza $C(x_i, x_j)$
 - $C(x_i, x_j) = E((Z(x_i)-m(x_i)) \cdot [Z(x_j)-m(x_j)])$
 - Semivariograma $\gamma(x_i, x_j)$
 - $\gamma(x_i, x_j) = 0.5 \cdot E((Z(x_i)-Z(x_j))^2)$
- $Var(Z(x)) \geq 0$; $\gamma(x_i, x_j) \geq 0$ pero $C(x_i, x_j)$ no se sabe


Más definiciones

- Def.: $Z(x)$ estacionaria de segundo orden si
 - $E(Z(x))$ existe y no depende de x
 - $C(x+h, x)=C(h)$ (sólo depende de la separación)
- Implica
 - $Var(Z(x))=C(0)$
 - $\gamma(x+h, x)=\gamma(h)=0.5 \cdot E((Z(x+h)-Z(x))^2)$
- h es en general un vector; suele asumirse isotropía, por lo que $\gamma(h)=\gamma(|h|)$
- $\gamma(h)=var(Z)-C(h)$ sólo si la media es estrictamente constante; en otro caso, usar $\gamma(h)$ es más conveniente que usar $C(h)$

Más sobre variogramas...

Def.: $\gamma(h)=0.5 \cdot E((Z(x+h)-Z(x))^2)$

- $\gamma(0)=0$; $\gamma(h) \geq 0$



Rango (Range):

Distancia a la cual el variograma se estabiliza

Meseta (Sill):

Valor constante que toma el variograma en distancias mayores al rango

Fórmula del Variograma

- El variograma debe cumplir algunas condiciones matemáticas restrictivas
- Salen de imponer que $Var(Y) \geq 0$, siendo $Y = \sum \lambda_i Z(x_i)$, λ_i y x_i conjunto arbitrario
- Hay algunos modelos de variogramas que se ajustan a los datos
 - Esférico, Exponencial, Gaussiano, Pepita, etc.
 - Hay otros menos populares
- Todos dependen de la meseta S y el rango a , excepto el denominado Pepita (nugget)

Estimación del Variograma

- Un tópico en sí mismo
- "Left to the user..."
- Métodos:
 - A sentimiento (!)
 - Mínimos cuadrados
 - Jackknife
 - Máxima Verosimilitud
 - Validación Cruzada
 - Validación Cruzada de Máxima Verosimilitud
 - ...
- Sin variograma...



Kriging

- Del geólogo sudafricano D. G. Krige
- Hay muchas variantes y casos particulares
- Caso Puntual: se modela el estimador con

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

eligiéndose los pesos $\lambda_i(x)$ para que sea insesgado

$$E(Z^*(x)) = m = E(Z(x))$$

y de varianza mínima $var[Z(x) - Z^*(x)]$

Algunos detalles

- Se asume m constante; hay variantes para otro caso

- Los pesos son función del punto

$$\begin{bmatrix} 0 & \gamma_{12} & \gamma_{13} & \dots & \gamma_{1n} & 1 \\ \gamma_{21} & 0 & \gamma_{23} & \dots & \gamma_{2n} & 1 \\ \gamma_{31} & \gamma_{32} & 0 & \dots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \gamma_{n1} & \gamma_{n2} & \gamma_{n3} & \dots & 0 & 1 \\ 1 & 1 & 1 & \dots & 1 & 0 \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_n \\ 1 \end{bmatrix}$$

Algunos detalles⁽²⁾

- Donde $\gamma_{ij} = \gamma(x_i - x_j)$; $\gamma_i = \gamma(x_i - x)$

- Nótese que:

- El variograma depende de los datos
- Los coeficientes λ_i dependen del variograma, pero no de los datos mismos
- Idem con la varianza, mediante la expresión

$$\text{Var}(Z^* - Z) = \sum_i \lambda_i \gamma(x_i - x) + \mu$$

- La matriz del sistema es constante; puede usarse LU
- El resultado es perfectamente determinista; lo estocástico reside en los datos mismos

Algunos detalles⁽³⁾



- El de Krigado es un estimador BLUE
 - Sólo si el variograma es "exacto"
 - Sólo si la función aleatoria es normal
 - En ese caso, es el *Best* incluso comparando con los no lineales
 - Difícil de verificar la normalidad en la práctica (por lo multivariado...)
- El Krigado es interpolante
 - Sólo si se asumen datos sin error
- Bajo ciertas hipótesis
 - error $\sim N(0, \sigma^2)$; N nro. de puntos y d dimensión del espacio (típicamente 2)
 - ¡Incluso con el variograma erróneo!
 - Pero en este caso la varianza no es consistente

Algunos detalles⁽³⁾

- Si los datos *tienen un error* cuya varianza es ϵ^2 el sistema cambia levemente

$$\begin{bmatrix} \epsilon^2 & \gamma_{12} & \gamma_{13} & \dots & \gamma_{1n} & 1 \\ \gamma_{21} & \epsilon^2 & \gamma_{23} & \dots & \gamma_{2n} & 1 \\ \gamma_{31} & \gamma_{32} & \epsilon^2 & \dots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \gamma_{n1} & \gamma_{n2} & \gamma_{n3} & \dots & \epsilon^2 & 1 \\ 1 & 1 & 1 & \dots & 1 & 0 \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_n \\ 1 \end{bmatrix}$$

Simulación

- Def.:

- No condicionada: Consiste en generar realizaciones con igual media y varianza que la disponible
- Condicionada: Idem, pero obligando a que además adopte valores específicos en ciertos puntos

- Tres tipos de métodos

- Espectrales, Bandas Rotantes y Matricial
- Sólo presentaremos el Matricial



Método Matricial de Simulación

- No es el más eficaz si se necesitan muchos puntos
 - Matricial $O(n^3)$
 - Bandas rotantes $O(n^{1.75})$
- Implicitamente se asume normalidad
- La fórmula para Z_S es:

$$Z_S = Z^* + \mathbf{M}\mathbf{u}; \mathbf{M}\mathbf{M}^T = \mathbf{C}; \mathbf{u}_i \sim N(0,1)$$

- La simulación se logra generando diversos \mathbf{u}
 - Problema estándar
 - Muchas librerías disponibles

¿Para qué se usa la Simulación?

- Generar realizaciones
 - Compatibles con las medidas disponibles
 - Compatibles con el variograma asumido
- Ejemplo: un MDE
 - Generar N realizaciones del raster basado
 - Delinear zona de visibilidad a un mástil
 - Calcular área A_i de esa zona
 - Calcular valor esperado, promedio, máximos, etc. del conjunto A_i y sus niveles de confianza
- Se comentarán más casos luego

Literatura & Software

- Digital:
 - Rudolf Dutter, Vienna Inst. of Technology
 - CD del curso: http://www.statistik.tuwien.ac.at/publib/datt/vorles/geom_03/geom.html
 - Denis Marcotte, Ecole Polytechnique de Montréal
 - CD del curso: <http://geo.polytechnique.ca/~marcotte/glslib/geo.html>
 - Oscar Rondón, Venezuela
 - CD del curso
- Papel:
 - Samper, F.J. y Carrera, J. 1990. Geostatística: Aplicaciones a la hidrología subterránea. CIMNE, ISBN 84-404-6045-7
- Biblioteca GSLIB
- Matlab+EasyKrig
 - http://globec.whoi.edu/pub/software/kriging/V2.1/easy_krig2.1