

GEOESTADISTICA

Parte 2: prediccion espacial

2019

Objetivos

$\{Z(s), s \in D \subset \mathbb{R}^d\}$ campo aleatorio

observamos $z(s_1), z(s_2), \dots, z(s_n)$ en los lugares s_1, s_2, \dots, s_n

Estimar (predecir) $g(Z(s)), s \in D$.

Por ejemplo :

$Z(s_0), s_0$ no observado,

$\frac{1}{|B|} \int_B Z(s) ds$ B region de D ,

$P(Z(s) > \zeta),$

...

Predictor optimo

Predecir $Z(s_0)$ dados $Z(s_1) = z(s_1), \dots, Z(s_n) = z(s_n)$

Predictor optimo :

$$p^{opt} = E(Z(s_0) | Z(s_1) = z(s_1), \dots, Z(s_n) = z(s_n))$$

minimiza el riesgo quadratico

$$E((Z(s_0) - \hat{Z}(s_0))^2)$$

Predictor lineal optimo (BLUP) :

$$p^* = \alpha + \sum_{i=1}^n \lambda_i Z(s_i)$$

Si Z gaussiano, $p^{opt} = p^*$

Solucion

$$\lambda = C^{-1}c \quad C_{i,j} = \text{cov}(Z(s_i), Z(s_j)) \quad c_i = \text{cov}(Z(s_0), Z(s_i))$$

$$\alpha = E(Z(s_0)) - \sum_{i=1}^n \lambda_i E(Z(s_i))$$

Kriging simple

C y $m(s)$ conocidas

$$\widehat{Z}(s_0) = {}^t c C^{-1} (Z - m) + m(s_0)$$

Varianza de kriging

$$\sigma_{SK}^2 = \sigma^2(s_0) - {}^t c C^{-1} c$$

Si $s_0 = s_i$, entonces

$$\widehat{Z}(s_i) = Z(s_i)$$

Necesita estimar C y $m(s)$.

Kriging Ordinario

Hypotesis : $Z(s) = \mu + \delta(s)$, con incrementos estacionarios.

$$\hat{Z}(s_0) = \sum_{i=1}^n \lambda_i Z(s_i) \text{ con}$$

$$E(\hat{Z}(s_0)) = E(Z(s_0)) \text{ y } E(\hat{Z}(s_0) - Z(s_0))^2 \text{ minimo}$$

variograma : $\gamma(h) = \frac{1}{2} \text{Var}(Z(s+h) - Z(s))$

$(\lambda_i)_{i=1,n}$ soluciones del sistema

$$\begin{pmatrix} 0 & \gamma(s_1 - s_2) & \dots & \gamma(s_1 - s_n) & 1 \\ \gamma(s_1 - s_2) & 0 & \dots & \gamma(s_2 - s_n) & 1 \\ \dots & \dots & \dots & \dots & \dots \\ \gamma(s_1 - s_n) & \gamma(s_1 - s_n) & \dots & 0 & 1 \\ 1 & 1 & \dots & 1 & 0 \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \lambda_n \\ \alpha \end{pmatrix} = \begin{pmatrix} \gamma(s_0 - s_1) \\ \gamma(s_0 - s_2) \\ \dots \\ \gamma(s_0 - s_n) \\ 1 \end{pmatrix}$$

Kriging Ordinario

Varianza de kriging

$$\sigma_K^2(s_0) = E((\widehat{Z}(s_0) - Z(s_0))^2) = \alpha + \sum_{i=1}^n \lambda_i \gamma(s_i - s_0)$$

Comentarios

- i) No es necesario que $0 \leq \lambda_i \leq 1$
- ii) si $s_0 = s_i \in \{s_1, \dots, s_n\}$ entonces $\lambda_i = 1$, $\lambda_j = 0$, $j \neq i$, y $\sigma_K^2(s_i) = 0$
- iii) los pesos de kriging λ_i dependen de la disposición de los lugares de los datos, de la localización del sitio de predicción, del número de datos y de la función variograma.

Pesos de kriging

Efecto pantalla

0.662



A



0.338



B

0.447



A



0.43



C



0.123



B


Pesos de kriging

Declustering natural



Pesos de kriging

Effet écran et pondérateurs négatifs



Influencia de los parametros del variograma

La pepita

- si el variograma es solo una pepita $\lambda_i = \frac{1}{n}$, la prediccion es constante (menos a los sitios de los datos) asi como la varianza de kriging.
- la presencia de una pepita en la funcion variograma alisa la prediccion.

La escala (el rango)

- si es alta, las observaciones influyen mas
- no se nota en los pesos (efecto pantalla)

El silo

- influye la varianza de kriging


Regularidad

- si la pepita $\tau = 0$ la regularidad del variograma en 0 da la regularidad del proceso


Influencia de los parametros del variograma

Forme du variogramme


Exponentiel




krigeage




Gaussien




krigeage



Sphérique




krigeage




Influencia de los parametros del variograma

Variogrammes puissance


Puissance $\alpha=0.5$




krigeage




Puissance $\alpha=1$




krigeage



Puissance $\alpha=1.5$




krigeage




Influencia de los parametros del variograma

Influence de la pépite


pepite = 0




variance




pepite=0.5




variance



pepite=1




variance




Influencia de los parametros del variograma

Influence de la portée


portée = 0.5




variance




portée = 1




variance



portée = 2



variance



Kriging de una media regional

V parte de D

$$Z_v = \frac{1}{|V|} \int_V Z(s) ds$$

$$\widehat{Z}_V = \sum_{i=1}^n \lambda_i Z(s_i)$$

$$\begin{pmatrix} \Lambda \\ \alpha \end{pmatrix} = \Gamma^{-1} \begin{pmatrix} \gamma(V, s_i) \\ 1 \end{pmatrix} \quad \sigma_{OK}^2(V) = \sum_i \lambda_i \gamma(V, s_i) + \alpha - \gamma(V, V)$$

$$\gamma(V, s_i) = \frac{1}{|V|} \int_V \gamma(s_i - s) ds$$

Kriging log-normal

Si los datos no siguen una distribución normal, la predicción dada por el kriging no es la del predictor óptimo.

$Z \sim$ log-normal si $Y = \log(Z) \sim \mathcal{N}(\mu, \sigma)$ y $E(Z) = \exp(\mu + \sigma^2/2)$.

Si $Y(s) = \log(Z(s))$ gaussiano con incrementos estacionarios

$$\hat{Y}(s_0) = \sum_{i=1}^n \lambda_i Y(s_i) = \sum_{i=1}^n \lambda_i \log(Z(s_i))$$

El kriging log-normal de Z es

$$\hat{Z}(s_0) = \exp(\hat{Y}(s_0) + \sigma_{Y,K}^2(s_0)/2 - \alpha_Y)$$

Kriging Universal

Si la media no es constante

$$Z(s) = \mu(s) + \delta(s) \quad \delta \text{ con incrementos estacionarios } E(\delta) = 0$$

Modelization de la tendencia $E(Z(s)) = \mu(s)$, $\mu(s) = \sum_{k=0}^p \beta_k f_k(s)$

$f_0(s) = 1, f_1(s) = x, f_2(s) = y, f_3(s) = xy, \dots, s = (x, y)$,
(β_j) desconocidos

Predictor lineal $\hat{Z}(s_0) = \sum_{i=1}^n \lambda_i Z(s_i)$

Restriccion insesgado (universalidad):

$$\sum_i \lambda_i f_k(s_i) = f_k(s_0), \quad k = 0, \dots, p$$

Kriging Universal

γ variograma de δ

$$\begin{pmatrix} 0 & \dots & \gamma(s_1 - s_n) & f_0(s_1) & \dots & f_p(s_1) \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \gamma(s_1 - s_n) & \dots & 0 & f_0(s_n) & \dots & f_p(s_n) \\ f_0(s_1) & \dots & f_0(s_n) & & & \\ \dots & \dots & \dots & & 0 & \\ f_p(s_1) & \dots & f_p(s_n) & & & \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \vdots \\ \lambda_n \\ \alpha_0 \\ \vdots \\ \alpha_p \end{pmatrix} = \begin{pmatrix} \gamma(s_0 - s_1) \\ \vdots \\ \gamma(s_0 - s_n) \\ f_0(s_0) \\ \vdots \\ f_p(s_0) \end{pmatrix}$$

varianza de kriging :

$$\sigma_{KU}^2(s_0) = \sum_{i=1}^n \lambda_i \gamma(s_0 - s_i) + \sum_{j=1}^{p+1} \alpha_{j-1} f_{j-1}(s_0)$$

Kriging Universal

Estimacion del variograma de δ

$$\frac{1}{2}(\delta(s_i) - \delta(s_j))^2 = \frac{1}{2}\left(Z(s_i) - Z(s_j) - \sum_{k=0}^p \beta_k (f_k(s_i) - f_k(s_j))\right)^2$$

Necesita estimar los β_i . Para estimar los β_i

$$\hat{\beta} = (X^t \Sigma^{-1} X)^{-1} X^t \Sigma^{-1} Z \quad \Sigma = \text{cov}(\delta)$$

Procedimiento iterativo :

- estimar β con minimos cuadrados ordinarios,
- ajustar el variograma con los residuos,
- estimar β con minimos cuadrados generalizados,
- ...

Maxima verosimilitud : se supone que los $Z(s)$ son gaussianos y se estima conjuntamente los parametros de la regresion y de la covarianza.

Kriging con una tendencia

Deriva externa

$$Z(s) = \beta_0 + \beta_1\varphi(s) + \delta(s)$$

$\varphi(s)$ conocida $\forall s \in D$

$$\hat{Z}(s_0) = \sum_{i=1}^n \lambda_i Z(s_i)$$

Kriging de los residuos

$$Z(s) = \beta X(s) + \delta(s)$$

$$\hat{\beta} = (X^t X)^{-1} X^t Z \quad , \quad \hat{\delta}(s_i) = Z(s_i) - \hat{\beta} X(s_i)$$

$$\hat{Z}(s_0) = \hat{\beta} X(s_0) + \sum_{i=1}^n \lambda_i \hat{\delta}(s_i)$$

Cokriging

2 procesos espaciales $Z_1(\cdot), Z_2(\cdot)$

$(s_{ik}, k = 1, n_i)$ lugares de datos observados del proceso Z_i .

caso isotopico $s_{1k} = s_{2k} = s_k$

caso heterotopico los lugares no coinciden en absoluto (total),
parcialmente (parcial)

Hipotesis de estacionaridad:

- $E(Z_i(s)) = \mu_i, \text{cov}(Z_i(s+h), Z_j(s)) = c_{ij}(h)$
- si Z isotropico $c_{ij}(h) = c_{ij}(\|h\|)$

Propiedades

- $c_{ij}(h) = c_{ji}(-h)$
- $|c_{ij}(h)| \leq \sqrt{c_{ii}(0)c_{jj}(0)}$

Cokriging

Estacionaridad junta de los incrementos

- $E(Z_j(s+h) - Z_j(s)) = 0$,
- $\text{cov}(Z_i(s+h) - Z_i(s), Z_j(s+h) - Z_j(s)) = 2\gamma_{ij}(h)$

Variograma cruzado

$\gamma_{ij}(h) = c_{ij}(0) - \frac{1}{2}(c_{ij}(h) + c_{ij}(-h))$ si es estacionario

Pseudo-variograma cruzado

$$\begin{aligned}\tilde{\gamma}_{ij}(h) &= \frac{1}{2}\text{Var}(Z_i(s+h) - Z_j(s)) \\ &= \frac{1}{2}(c_{ii}(0) + c_{jj}(0)) - c_{ij}(-h) \text{ si es estacionario}\end{aligned}$$

Cokriging

Predictor lineal

$$\widehat{Z}_1(s) = \sum_{k=1}^{n_1} \lambda_{1k}(Z_1(s_{1k})) + \sum_{k=1}^{n_2} \lambda_{2k}(Z_2(s_{2k}))$$

Minimizar $E(\widehat{Z}_1(s) - Z_1(s))^2$ sujeto a restricción
 $E(\widehat{Z}_1(s) - Z_1(s)) = 0$

$$\sum_{j=1}^2 \sum_{l=1}^{n_j} \lambda_{jl} \gamma_{ij}(s_{ik} - s_{jl}) + \alpha_i = \gamma_{1i}(s_{ik} - s) \quad i = 1, 2 \quad k = 1 \dots n_i$$

$$\sum_{k=1}^{n_1} \lambda_{1k} = 1 \quad \sum_{k=1}^{n_2} \lambda_{2k} = 0$$

Varianza de cokriging

$$\sigma_{CO}^2 = \sum_{i=1}^2 \sum_{k=1}^{n_i} \lambda_{ik} \gamma_{1i}(s_{ik} - s) + \alpha_1$$

Cokriging

Estimacion de los variogramas

$\gamma_{ij}(h)$ condicionalmente definidas negativas.

Modelos de coregionalizacion :

$$\gamma_{ij}(h) = \sum_{\ell=0}^L b_{ij}^{\ell} \gamma_{\ell}(h) \quad \Gamma(h) = \sum_{\ell=0}^L B_{\ell} \gamma_{\ell}(h)$$

cada B_{ℓ} ha de ser definida positiva, i.e.

$$b_{11}^{\ell} \geq 0 \quad ; \quad b_{22}^{\ell} \geq 0 \quad ; \quad |b_{12}^{\ell}| \leq \sqrt{b_{11}^{\ell} b_{22}^{\ell}}$$

Kriging multivariado

Z^1, Z^2, \dots, Z^p campos aleatorios correlacionados, predecir simultaneamente.

Funcion de correlacion cruzada

$$C_{ij}(s, s') = \text{cov}(Z^i(s), Z^j(s')) = C_{ij}(s - s')$$

Separable

$$C_{ij}(h) = a_{ij}C(h)$$

$A = [a_{ij}]_{i,j=1\dots p}$ matriz definida positiva

No separable (Gneiting)

$$C_{ij}(h) = \sigma_i \sigma_j r_{ij} C(h, \rho_{ij}, \nu_{ij})$$

$C(h, \rho, \nu)$ funcion de correlacion de Matern, escala ρ , orden ν

$\rho_{ij} = (\rho_i^2 + \rho_j^2)/2$, $\nu_{ij} = (\nu_i^2 + \nu_j^2)/2$

restricciones en r_{ij}

Kriging espacio-temporal

Proceso espacio-temporal : $Z(s, t), s \in D, t \in [0; T]$

Si Z es estacionario

$$\text{cov}(Z(s, t), Z(s', t')) = C(s - s', t - t')$$

Funciones de covarianza separables

$$C(h, u) = C_s(h)C_t(u)$$

admisibles si C_s y C_t son funciones de covarianza admisibles.

Funciones de covarianza no separables y admisibles

$$C(h, u) = \frac{\sigma^2}{\psi(|u|^2)^{d/2}} \varphi\left(\frac{\|h\|^2}{\psi(|u|^2)}\right)$$

$\varphi(t), t \geq 0$ completamente monótona, $\psi(t), t \geq 0$ positiva y con derivadas completamente monótonas.

Simulaciones condicionales

Principio Simular campos aleatorios segun una distribucion de tal manera que los valores simulados en los lugares de datos sean iguales a los observados.

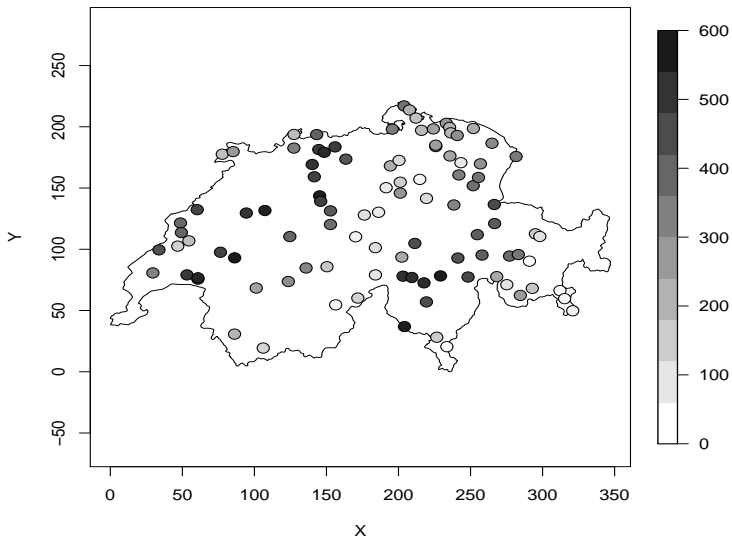
Interes Permite estimar funciones no lineales de Z .

Kriging condicional

- Estimar la funcion de covarianza del campo $C(h)$
- $\hat{Z} = \sum_i \lambda_i Z_i$ kriging con los datos observados
- simular un campo Y en el dominio D con funcion de covarianza $C(h)$
- $\hat{Y} = \sum_i \lambda_i Y_i$ kriging con los valores simulados en los lugares de datos.
- $\hat{Z} + Y - \hat{Y}$ es una simulacion condicional.


Lluvias suizas

Cumuls pluviométriques en Suisse
après le passage du nuage de Tchernobyl




Lluvias suizas

Altitude (m)



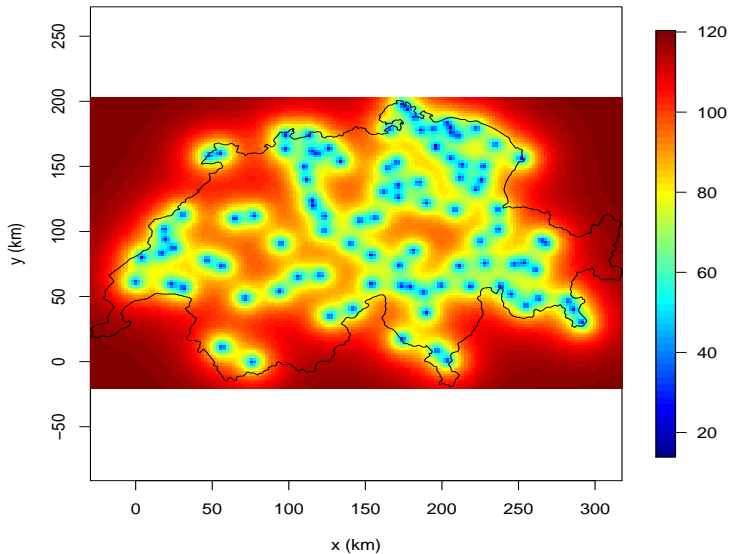
Lluvias suizas

Krigage avec un modele exponentiel




Lluvias suizas

Ecart-type de krigage




Lluvias suizas

Krigage avec un modele exponential anisotrope




Lluvias suizas

Krigiage avec un modele exponentiel avec l'altitude



Lluvias suizas

Simulation conditionnelle



Lluvias suizas

Proba($Y > 300$)

