




# Minicurso: Estadística para datos Espacio-temporales

Dra. Carolina Euán

<https://www.cimat.mx/~caroe/>


# Cómo son los Datos Espacio-temporales

- ▶ Características: Datos con dependencia temporal y espacial




**Fig. 1.** The spatial and temporal components of the spatio-temporal emergency alarm call data. The left panel shows the spatial locations of the calls while the right panel presents the call counts over the study region as a function of time. The scales of measurements for the spatial locations and the temporal count data are meter (scaled by 1000) and day, respectively. The numbers in the right panel plot indicate the smoothed seasons-of-a-year, which are Fall (1), Spring (2), Summer (3), and Winter (4), of the emergency alarm calls; the first time point corresponds to January 1, 2014.

# Eventos de Sequía en Guanajuato



# Temperatura en EU

Temperatura máxima diaria en el este de EU durante Mayo-Septiembre 1993



# Contenido

Definiciones básicas

El caso espacial

Variograma

Predicción

Datos Espacio-temporales

Visualización

Media y Covarianza

Modelos Estadísticos

## Notación Inicial

**Referencia:** Wikle, C. K., Zammit-Mangion, A., and Cressie, N. (2019), Spatio-Temporal Statistics with R, Boca Raton, FL: Chapman & Hall/CRC

s - ubic esp

- ▶  $Z(s)$  denota un proceso espacial.
  - ▶  $Z(t, s)$  denota un proceso espacio-temporal.
- Comenzaremos estudiando datos espaciales y en la ultima sesión lo expandiremos a datos espacio temporales.

## Cómo son nuestros Datos?

- ▶  $m$  ubicaciones,  $\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_m$ .
- ▶  $T$  tiempos,  $t_1, \dots, t_T$ .
- ▶ Muestra (datos espaciales):  $\{Z(\mathbf{s}_1), Z(\mathbf{s}_2), \dots, Z(\mathbf{s}_m)\}$




# Datos del Rio Mosa

16

El Río Mosa es un importante río Europeo

```
> library(sp)  
> data(meuse)  
> data(meuse.riv)
```

En este caso:  $m = 155$  y  $Z(s_i)$  es la concentración de Zinc.



# Contenido

Definiciones básicas

El caso espacial

Variograma

Predicción

Datos Espacio-temporales

Visualización

Media y Covarianza

Modelos Estadísticos

# Midiendo Dependencia Espacial


Sea  $Z(s)$  un proceso espacial definimos su función de covarianza como

$$\text{Cov}(s_1, s_2) = \text{Cov}(Z(s_1), Z(s_2)) = \mathbb{E}[\{Z(s_1) - \mu\}\{Z(s_2) - \mu\}]$$

donde  $\mu = \mathbb{E}(Z(s))$ .

Lo más común es tener una muestra de tamaño 1. Entonces necesitamos ciertos supuestos:

1. Isotropia:  $\text{Cov}(s_1, s_2) = \text{Cov}(|s_1 - s_2|)$ ,  $|\cdot|$  denota norma euclídea.




$$\begin{aligned} & \text{Cov}(Z(s_1), Z(s_2)) \\ &= \text{Cov}(Z(s_1), Z(s_3)) \\ & \text{si } |s_1 - s_2| = |s_1 - s_3| \end{aligned}$$

# Datos del Rio Mosa

```
> hscat(log(zinc) ~ 1, meuse, (0:6) * 100)
```

lagged scatterplots



$$(z(s_i), z(s_j)) \\ s_i \quad |s_i - s_j| = h$$

# Variograma


- La estrategia es transformar los datos
- Definimos  $h = |\mathbf{s}_1 - \mathbf{s}_2|$ , luego

$$V(x) = E[x^2] - (E[x])^2$$

$$\gamma_Z(h) = 1/2 \mathbb{E}(Z(\mathbf{s}_1) - Z(\mathbf{s}_2))^2$$

$$\begin{aligned} \mathbb{E}(Z(s_1) - Z(s_2))^2 &= \text{Var}(Z(s_1) - Z(s_2)) \\ &= \text{Var}(Z(s_1)) + \text{Var}(Z(s_2)) - 2 \text{Cov}(Z(s_1), Z(s_2)) \\ \text{Var}(Z(s_1)) &= 2\sigma_z^2 - 2 \text{Cov}(Z(s_1), Z(s_2)) \\ &= \text{Var}(Z(s_2)) = \sigma_z^2 \end{aligned}$$

$$\Rightarrow \gamma_Z(h) = \sigma_z^2 - \text{Cov}(s_1, s_2)$$



## Variograma


- ▶ Entonces,  $\gamma_Z(h) = \sigma^2 - \text{Cov}(\mathbf{s}_1, \mathbf{s}_2)$ , donde  $\sigma^2 = \text{Var}(Z(\mathbf{s}))$
- ▶ Ahora tenemos mas valores muestra de  $Z(\mathbf{s}_1) - Z(\mathbf{s}_2)$ .
- ▶ Asi el estimador muestral del variograma es

$$\hat{\gamma}_Z(h) = \frac{1}{2 * N_h} \sum_{i=1}^{N_h} (Z(\mathbf{s}_i) - Z(\mathbf{s}_i + h))^2$$


# Datos del Rio Mosa

```
> plot(variogram(log(zinc) ~ 1, meuse, cloud = TRUE),  
+       xlab="Distancia",ylab="",  
+       main="Variograma Muestral (1)")  
> plot(variogram(log(zinc) ~ 1, meuse),  
+       xlab="Distancia",ylab="",  
+       main="Variograma Muestral")
```

Variograma Muestral (1)



Variograma Muestral (1)




## Variograma

- ▶ Entonces,  $\gamma_Z(h) = \sigma^2 - \text{Cov}(\mathbf{s}_1, \mathbf{s}_2)$ , donde  $\sigma^2 = \text{Var}(Z(\mathbf{s}))$
- ▶ Así el estimador muestral del variograma es


$$\hat{\gamma}_Z(h) = \frac{1}{2 * N_h} \sum_{i=1}^{N_h} (Z(\mathbf{s}_i) - Z(\mathbf{s}_i + h))^2$$

- ▶ NOTA - Necesitamos que la función de covarianza estimada sea no-negativa definida. Para ello, una versión muestral del variograma no es suficiente!



# Datos del Rio Mosa

```
> v<-variogram(log(zinc) ~ 1, meuse)
> model<-fit.variogram(v, vgm(1, "Exp", 500, 0))
> plot(v, model=model, pch=20, lwd=2, xlab="Distancia (h)",
+       ylab="", main="Variograma - Modelo Exponencial")
```



$$\gamma_2(h) = \sigma^2 + Cn(h)$$

$$a \exp\{-|s_1 - s_2|/b\} = Cn(s_1, s_2; a, b)$$
$$\rightarrow \sum_h (\hat{\gamma}_2(h) - \gamma_2(h; a, b))^2$$

$\hat{a}, \hat{b}$  LS .

# Contenido

Definiciones básicas

El caso espacial

Variograma

Predicción

Datos Espacio-temporales

Visualización

Media y Covarianza


Modelos Estadísticos

# Predictión

- ▶ En el estudio de datos espaciales, un objetivo es poder **predecir** en **ubicaciones** donde no observamos datos.
- ▶ El objetivo es construir un predictor lineal que use la información observada.

$$Z(\mathbf{s}_0) = \lambda_0 + \sum_{i=1}^m \lambda_i Z(\mathbf{s}_i)$$

- ▶ Se necesita conocer la covarianza entre  $Z(\mathbf{s}_0)$  y cada  $Z(\mathbf{s}_i)$ .



Mejor predictor lineal

→ Menor error  $\mathbb{E} (z(s_0) - \hat{z}(s_0))^2 \rightarrow \text{minimo.}$

$$z = \begin{pmatrix} z(s_1) \\ \vdots \\ z(s_m) \end{pmatrix}$$

$$\mathbb{E} (z(s_0) - \lambda_0 - \gamma^T z)^2$$

$$\lambda = \begin{pmatrix} \lambda_1 \\ \vdots \\ \lambda_m \end{pmatrix}$$

$$= C_{0,1} (z(s_0) - \lambda_0 - \gamma^T z, z(s_0) - \lambda_0 - \gamma^T z)$$

$$+ [\mathbb{E} (z(s_0) - \lambda_0 - \gamma^T z)]^2, \quad \mathbb{E}(z(s)) = \mu(s)$$

$$= (\mu(s_0) - \lambda_0 - \gamma^T \mu)^2 + k_0 - 2 \gamma^T k + \gamma^T K \gamma$$

$$\lambda = K^{-1} k \quad \} \checkmark$$

$$\rightarrow K^{-1} \checkmark \Rightarrow \lambda_0 = (s_0) - k^T K^{-1} \mu \quad \} \checkmark$$

$$K = C_{0,1}(z, z), \quad k = C_{0,1}(z(s_0), z)$$

## Mejor predictor lineal -Kriging

$$z(s) = \underbrace{X(s)^T \beta}_{M(s)} + \varepsilon(s)$$

$\hat{\varepsilon}_{\text{media}} = 0$

$$\beta_0 = \mu$$

$$\rightarrow E(\lambda_0 + \gamma^T \bar{x}) = E(z(s_0))$$

$$\Leftrightarrow \lambda_0 + \gamma^T \bar{x} \beta = X(s_0)^T \beta$$

Se encuentra  $\lambda - \gamma$   $\in$  BLUP

$$\gamma^T z = k^T k^{-1} (z - \bar{x} \hat{\beta}) + X(s_0)^T \hat{\beta}$$


## Mejor predictor lineal -Kriging

$$\hat{\beta} \text{ GLS , } (\mathbf{M}^T \mathbf{k}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{k}^T \mathbf{z}$$
$$\mathbf{M} = \underline{\mathbf{X}} .$$

## Kriging Ordinario - Rio Mosa

El Río Mosa es un importante río Europeo

```
> krige(log(zinc) ~ 1,  
+ meuse, meuse.grid, model)
```



# Contenido


Definiciones básicas

El caso espacial  
Variograma  
Predicción


Datos Espacio-temporales  
Visualización  
Media y Covarianza  
Modelos Estadísticos

# Temperatura en EU - Espacial


```
> data("NOAA_df_1990", package = "STRbook")
```




## Temperatura en EU - Temporal



# Temperatura en EU - Efecto de Latitud



# Temperatura en EU - Efecto de Longitud



# Contenido

Definiciones básicas


El caso espacial  
Variograma  
Predicción

Datos Espacio-temporales  
Visualización  
Media y Covarianza  
Modelos Estadísticos

# Media Espacial

La media espacial muestral se calcula promediando en el tiempo


$$\hat{\mu}_z(\mathbf{s}_i) = \frac{1}{T} \sum_{j=1}^T Z(\mathbf{s}_i, t_j)$$



```
> library("dplyr")
> TmaxMean <- Tmax %>% group_by(id, lat, lon) %>%
+   summarise(z = mean(z))
```

# Serie de Tiempo de Promedios


$$\hat{\mu}_z(t_j) = \frac{1}{m} \sum_{i=1}^m Z(\mathbf{s}_i, t_j)$$



```
> TmaxMeanTS <- Tmax %>% group_by(date) %>%  
+   summarise(z = mean(z))
```

## Covarianza

La covarianza resulta,



$$\text{Cov}_Z(Z(\mathbf{s}_1, t_1), Z(\mathbf{s}_2, t_2)) = \mathbb{E}[\{Z(\mathbf{s}_1, t_1) - \mu(\mathbf{s}_1, t_1)\}\{Z(\mathbf{s}_2, t_2) - \mu(\mathbf{s}_2, t_2)\}]$$

y el variograma,

$$\gamma_Z(\mathbf{s}_1, \mathbf{s}_2, t_1, t_2) = \frac{1}{2} \text{var}(Z(\mathbf{s}_1, t_1) - Z(\mathbf{s}_2, t_2))$$

Si asumimos isotropia y estacionariedad:

$$\gamma_Z(h, \tau) = \text{Cov}_Z(0, 0) - \text{Cov}_Z(h, \tau).$$

# Media Espacial

El estimador muestral resulta ser


$$\hat{\gamma}_Z(h, \tau) = \frac{1}{\#N_h} \frac{1}{\#N_\tau} \sum_{\mathbf{s}_i, \mathbf{s}_k \in N_h} \sum_{t_i, t_l \in N_\tau} (Z(\mathbf{s}_i, t_j) - Z(\mathbf{s}_k, t_l))^2$$

En R...

```
> data("STObj3", package = "STRbook")
> STObj4 <- STObj3[, "1993-07-01::1993-07-31"]
> VTmax<-variogram(object = z~1 +lat,
+                     data = STObj4, # Julio 93
+                     width = 80, # spatial bin (80 km)
+                     cutoff = 1000, # pts < 1000 km
+                     tlags = 0.01:6.01)
```

L  
C

### Variograma para Temperaturas Max



# Contenido

Definiciones básicas

El caso espacial  
Variograma  
Predicción

Datos Espacio-temporales  
Visualización  
Media y Covarianza  
Modelos Estadísticos

# Modelos Estadísticos para datos Espacio-temporales

- ▶ Es este caso tendremos tres posibles objetivos:
- ▶ 1- Predicción de un valor desconocido en una nueva ubicación pero en el mismo periodo de observación.
- ▶ 2- Inferencia del efecto de Covariables
- ▶ 3- Prediction de un valor futuro.

## Predicción lineal determinística (Interpolación)

- ▶ Muestra  $\{Z(\mathbf{s}_1, t_1), \dots, Z(\mathbf{s}_m, t_1), Z(\mathbf{s}_1, t_2), \dots, Z(\mathbf{s}_m, t_2), \dots, Z(\mathbf{s}_1, t_T), \dots, Z(\mathbf{s}_m, t_T)\}$
- ▶ Estimador pesado con kernel



$$\hat{Z}(\mathbf{s}_0, t_0) = \sum_{j=1}^T \sum_{i=1}^m \omega_{ij}(\mathbf{s}_0, t_0) Z(\mathbf{s}_i, t_j),$$

donde los pesos  $\omega_{ij}(\mathbf{s}_0, t_0)$  es usualmente determinado por un kernel. Por ejemplo, el kernel Gaussiano radial,

$$\kappa_{ij}(\mathbf{s}_0, t_0; \theta) = \exp\left(-\frac{1}{\theta} |(\mathbf{s}_i, t_j) - (\mathbf{s}_0, t_0)|^2\right),$$

$$\text{con } \omega_{ij}(\mathbf{s}_0, t_0) = \frac{\kappa_{ij}(\mathbf{s}_0, t_0; \theta)}{\sum_{j=1}^T \sum_{i=1}^m \kappa_{ij}(\mathbf{s}_0, t_0; \theta)}$$

# Predicción lineal determinística (Interpolación)



## Predicción usando Regresión

$$Y = X\beta + \varepsilon$$

Consideramos un modelo lineal con  $p$  covariables:

$$Z(s_i, t_j) = \beta_0 + \beta_1 X_1(s_i, t_j) + \dots + \beta_p X_p(s_i, t_j) + \varepsilon(s_i, t_j).$$

En un primer análisis asumimos que  $\varepsilon(s_i, t_j)$  son errores independientes con varianza  $\sigma_\varepsilon^2$ .

## Predicción usando Regresión

Consideramos un modelo lineal con las siguientes covariables:

- ▶ Media constante en  $s$  and  $t$ . ✓
- ▶ Covariables en longitud ( $s_{1,i}$ ), latitud ( $s_{2,i}$ ). ✓
- ▶ Tendencia lineal en tiempo,  $t_j$ . ✓
- ▶ Y posibles interacciones tiempo-espacio ✓

El modelo resultante es de la forma:

$$Z(s_i, t_j) = \beta_0 + \beta_1 s_{1,i} + \beta_2 s_{2,i} + \beta_3 t_j + \beta_4 s_{1,i} s_{2,i} + \beta_5 s_{1,i} t_j + \beta_6 s_{2,i} t_j + \varepsilon(s_i, t_j).$$

# Predicción usando Regresión

En R...

```
> ModLin<- lm(z ~ (lon + lat + day)^2,      # model  
+                  data = select(TmaxJ, -id))
```

**Nota:** En realidad es un poco más complicado que un simple modelo de regresión.

## Predicción usando Kriging y Procesos Gaussianos

Aquí tambien consideraremos que podemos tener error de medicón.

- ▶  $Z(\mathbf{s}_i, t_j) = Y(\mathbf{s}_i, t_j) + \epsilon(\mathbf{s}_i, t_j)$ , donde  $\epsilon$  son iid.
- ▶  $Y(\mathbf{s}_i, t_j) = \mu(\mathbf{s}_i, t_j) + \eta(\mathbf{s}_i, t_j)$ ,  $\mu$  representa la media que puede depender del tiempo y espacio y  $\eta(\mathbf{s}_i, t_j)$  es un proceso Gaussiano espacio temporal con media zero.

## S-T Predictor usando Kriging

Usando Notación Matricial

$$\rightarrow Z = Y + \varepsilon \quad \text{donde} \quad \varepsilon \sim \mathcal{N}(0, \sigma_\varepsilon^2)$$

Si asumimos  $Y(s, t)$  es un proceso Gaussiano

$$\rightarrow Y = M + \eta$$

$$\begin{pmatrix} Y(s_0, t_0) \\ Z \end{pmatrix} \sim N\left(\begin{pmatrix} x(s_0, t_0)' \\ X \end{pmatrix}\beta, \begin{bmatrix} C_{00} & C_0 \\ C_0 & C_z \end{bmatrix}\right)$$

Donde  
 $\rightarrow C_{00} = \text{cov}(Y(s_0, t_0), Z) \rightarrow C_{00} = \text{Var}(Y(s_0, t_0))$

$$\rightarrow C_z = \text{Cov}(Z) = C_y + C_\varepsilon$$

Bajo el supuesto distribucional el mejor predictor lineal resulta ser  $\mathbb{E}(Y(s_0, t_0) | Z)$



## S-T Predictor usando Kriging

Entonces,



$$\hat{y}(s_0, t_0) = x(s_0, t_0)' \beta + c' C^{-1} (z - X\beta)$$

$$y - \hat{y} = c_{00} - c' C^{-1} c_0$$

# S-T Predictor usando Kriging



# Comparación



# Referencia

- ▶ Wikle, C. K., Zammit-Mangion, A., and Cressie, N. (2019), Spatio-Temporal Statistics with R, Boca Raton, FL: Chapman & Hall/CRC
- ▶ Stein, M. (1999) Interpolation of Spatial Data - Some Theory for Kriging. Springer.

Carolina Euán

[caroe@cimat.mx](mailto:caroe@cimat.mx)

<https://www.cimat.mx/~caroe/>



[Home](#)

TIES-GRASPA 2021 CONFERENCE

<https://sites.google.com/view/tiesgraspa2021/home>

Unirse a TIES: <https://www.isi-web.org/component/rsform/form/70-ties-membership-form-2020>

## WORKSHOP 1




01-02 July 2021, 12-4pm

*Bayesian spatial and spatio-temporal modeling with R-NIMBLE*

by [Tullia Padellini](#) and [Garyfallos Konstantinoudis](#), Imperial College London.

*Registrations will open soon*

## WORKSHOP 2



13-14 September 2021, 12-4pm

*Spatio-temporal modeling and visualisation of small-area data in R*


by [Duncan Lee](#), University of Glasgow.

See [here](#) for the description of the workshop.

*Registrations will open soon*

# Drought Data Analysis

- ▶ We fit the Ber VAR model with the spatial model with  $\exp(\lambda||s_i - s_j||)$  as the correlation function.
- ▶ Under the Ber VAR model,  $X_{i,t} = Y_{i,t}X_{i,t-1} + Z_{i,t}(1 - X_{i,t-1})$ . Then,  $Y_t$  models the dynamics of the dry events and  $Z_t$  models the dynamics of the rain.
- ▶ Correlation function of the latent processes:



- ▶ Confident bands are computed by the asymptotic variance of the MLE estimators and the  $MSE = 0.125$ .

# Drought Data Analysis

## Cross correlation plots of $X_t$ .

