

# ***Metodología y aplicaciones de la Estadística al control Medioambiental***

***Manuel Febrero Bande , Wenceslao González Manteiga y María Piñeiro Lamas***

06/02/2009  
Oviedo

*Congreso de la Real Sociedad Matemática 2009  
Sesión especial de transferencia Matemática*

# *Esquema*

---

- 1. Un problema medioambiental.*
- 2. Modelos de predicción.*
- 3. Nuevas aportaciones a la predicción medioambiental: el fenómeno de la cointegración.*

# *Un problema medioambiental*

- ❑ La Unidad de Producción Térmica (UPT) de As Pontes constituye uno de los centros productivos propiedad de Endesa Generación S.A., situado en el municipio de As Pontes, al noroeste de la provincia de A Coruña.





As Pontes de García Rodríguez

Image © 2009 DigitalGlobe  
© 2009 AND  
© 2009 Tele Atlas  
© 2009 Cnes/Spot Image  
elev. 264 m

© 2008 Google

43°27'29.86" N 7°53'14.95" O


12 Oct 2003

Alt. ojo 15.67 km


## Descripción general

- ❑ Inició su actividad en 1976 con la puesta en marcha de un grupo de generación de energía, disponiendo en la actualidad de cuatro.
- ❑ Fue diseñada para utilizar los lignitos extraídos de la mina a cielo abierto situada en sus proximidades con alto contenido de azufre.
- ❑ En el período 1993-1996 fue transformada con el objetivo de utilizar mezclas de lignito local con carbones subbituminosos de importación caracterizados por sus bajos contenidos en azufre.
- ❑ Actualmente ya se ha finalizado una nueva adaptación para consumir carbón subbituminoso de importación como combustible principal (período de transformación: 2005-2008).



# Sistema de Seguimiento y Control de la Calidad Atmosférica



# SIPEI 2008: Pantalla principal



# Sistema de Seguimiento y Control de la Calidad Atmosférica



# Problema

- ❑ Existe un foco emisor donde se monitoriza en continuo distintas medidas de calidad de aire en su entorno, e interesa predecir valores futuros de la calidad de aire. El principal interés inicial es la predicción de valores futuros de  $\text{SO}_2$ .
- ❑ Los modelos estadísticos de predicción son una herramienta eficaz para obtener estas predicciones y sugerir una línea de actuación para intentar evitar los episodios de calidad de aire.

## *Nueva problemática*

- ❑ Cercano al emplazamiento de la Central Térmica de As Pontes se ha construido una nueva Central de Ciclo Combinado de gas natural.



## *Descripción general*


- ❑ Consiste en un grupo generador de electricidad formado por dos turbinas de gas y una turbina de vapor (dos focos emisores).
- ❑ Está diseñado para utilizar gasóleo como combustible de emergencia.
- ❑ Como cualquier instalación de generación de energía por combustión debe disponer de un Sistema de Control de las Emisiones que ha sido integrado en el Sistema de Seguimiento y Control de la Calidad Atmosférica .

## Nuevos retos

En el período 2007-2008 las emisiones se han visto afectadas por dos actuaciones clave:

- ❑ La Central Térmica actual consume únicamente carbón de importación. → *Disminución de las emisiones de  $SO_2$  (alrededor del 95%)*
- ❑ La nueva Central de Ciclo Combinado entró en funcionamiento. → *Necesidad de predecir las emisiones de  $NO_x$*

# Resumen histórico




# Los datos

- ❑ Actualmente, se reciben datos con frecuencia minutal y pentaminutal en tiempo real.
- ❑ Se va a considerar la media horaria arrastrada, tanto de los valores de  $\text{SO}_2$  como de  $\text{NO}_x$ , para obtener las predicciones de valores futuros.
- ❑ La serie de valores medios horarios de  $\text{SO}_2$  tiene un comportamiento muy característico:
  - ❑ Toma valores próximos a cero durante largos períodos de tiempo.
  - ❑ En ocasiones crece de manera brusca y repentina (episodios).
  - ❑ Estos episodios están muy espaciados en el tiempo.
- ❑ La serie del  $\text{NO}_x$  tiene un comportamiento similar pero a menor escala.

# Los datos

## Valores de SO<sub>2</sub> y NO<sub>x</sub> .12/03/2007



# Modelos de predicción

# Modelo Semiparamétrico

- En los primeros años de desarrollo la frecuencia de envío de datos era pentaminutal y la legislación vigente establecía límites para las medias bihorarias.
- El modelo usa la serie temporal de medias bihorarias arrastradas

$$x_t = \frac{1}{24} \sum_{i=0}^{23} SO_2(t-i)$$

donde  $SO_2(t)$  representa la concentración de  $SO_2$  en el instante  $t$  (pentaminutal), medida en  $\mu\text{g}/\text{m}^3$ .

- El modelo semiparamétrico generaliza los modelos Box-Jenkins de la siguiente manera:

$$X_{t+k} = \varphi(X_t, X_{t-l}) + Z_{t+k}$$

# Modelo Semiparamétrico

- En cada instante  $t$  se estima la función de regresión

$E(X_{t+6} / X_t, X_{t-1})$  con el estimador tipo núcleo Nadaraya-Watson y la matriz histórica.

- Se calcula la serie de residuos  $\hat{Z}_{t-64}, \dots, \hat{Z}_t$  (6 últimas horas),

donde  $\hat{Z}_i := X_i - \hat{E}(X_i / X_{i-6}, X_{i-7})$  y se ajusta un modelo ARIMA adecuado.

- Se obtiene la predicción Box-Jenkins de  $\hat{Z}_{t+6}$ .

- La predicción final propuesta es:

$$\hat{X}_{t+6} = \hat{E}(X_{t+6} / X_t, X_{t-1}) + \hat{Z}_{t+6}$$

## Modelo Semiparamétrico

---

García-Jurado I., González-Manteiga W., Prada-Sánchez J.M., Febrero-Bande M. and Cao R. *Predicting using Box-Jenkins, Nonparametric and Bootstrap Techniques*. Technometrics 1995; 37: 303-310.

# Matrices Históricas

- ❑ La clave del buen funcionamiento de todos los modelos de predicción diseñados está en un **mecanismo de memoria** diseñado en los primeros años de desarrollo.
- ❑ La serie temporal de interés está formada en su mayor parte por valores próximos a cero y pocos valores de episodios de inmisión.
- ❑ Se estratifican los datos disponibles de  $\text{SO}_2$  según un rango de valores que representan razonablemente a los episodios pasados con objeto de mantener la **información interesante** de los episodios.
- ❑ A lo largo de los años este concepto se ha adaptado a las distintas técnicas estadísticas utilizadas.

# Matrices Históricas

~~□ Serie temporal~~

□ Matriz histórica:

□ Un número grande de registros.

□ Divididos en estratos.

□ Se asigna un rango de valores de

$X_{t+k}$  a cada clase.

□ Cada vector se asigna a la clase a la que pertenece  $X_{t+k}$ .

$$(X_{t-l}^1, X_t^1, X_{t+k}^1)$$

$$(X_{t-l}^i, X_t^i, X_{t+k}^i)$$

⋮

$$(X_{t-l}^M, X_t^M, X_{t+k}^M)$$

## Matrices Históricas

---

Prada-Sánchez, J.M. and Febrero-Bande M.  
*Parametric, Non-Parametric and Mixed  
approaches to prediction of sparsely  
distributed pollution incidents: a case study.*  
Journal of Chemometrics **1997**; 11: 13-32.

# Modelo Semiparamétrico (Matriz histórica)



# Modelos Parcialmente Lineales

- ❑ La información utilizada por los modelos semiparamétricos es el pasado de la propia serie.
- ❑ Se puede introducir información adicional: variables meteorológicas y variables de emisión.
- ❑ Los modelos parcialmente lineales utilizan estas variables y amplían el horizonte de predicción a una hora.
- ❑ Se consideran datos de la forma  $(V_l, Z_l, Y_l)$  donde  $V_l$  es un vector de variables exógenas,  $Z_l = (X_l, X_{l-3})$  e  $Y_l = X_{l-12}$ , siendo  $\{X_l\}$  la serie de medias bihorarias de  $\text{SO}_2$ .
- ❑ Se asume que se ajustan al modelo parcialmente lineal:

$$Y_l = V_l' \beta + \varphi(Z_l) + \varepsilon_l$$

## Modelos Parcialmente Lineales

Prada-Sánchez J.M., Febrero-Bande M., Cotos-Yáñez T., González-Manteiga W., Bermúdez-Cela J.L. and Lucas-Domínguez T. *Prediction of  $SO_2$  pollution incidents near a power station using partially linear models and a historical matrix of predictor-response vectors.* Environmetrics **2000**; 11: 209-225.

## Modelos de Predicción binaria

- El objetivo de estos modelos es estimar la probabilidad de que la serie de medias bihorarias de SO<sub>2</sub> supere un cierto nivel con una hora de antelación.
- Se pretende predecir:

$$p(Z_t) = p(X_{t+12} > r \mid Z_t)$$

donde

$$Z_t = (X_t, X_t - X_{t-3})$$

- Para ello se van a utilizar *modelos aditivos generalizados con función link desconocida (G-GAM)*


# Modelos de Predicción binaria

- Sea  $Y$  una variable con respuesta binaria, y  $Z=(1, Z_1, \dots, Z_p)$  el vector de covariables asociado.
- Se denota  $p(Z) = p(Y = 1 | Z)$  .
- El *modelo G-GAM* tiene la siguiente expresión:

$$p(Z) = H(\eta_z) = H\left(\beta_0 + \sum_{j=1}^p f_j(Z_j)\right)$$

donde  $f_j$  son funciones suaves desconocidas y la función link  $H$  es monótona creciente.

# Modelos de Predicción binaria



## Modelos de Predicción binaria

Roca-Pardiñas, J., González-Manteiga W., Febrero-Bande M., Prada-Sánchez J.M. and Cadarso-Suárez C. *Predicting binary time series of  $SO_2$  using generalized additive models with unknown link function*. Environmetrics **2004**; 15: 729-742.

# Modelos de Predicción binaria

- También se han considerado modelos GAM incluyendo términos de interacción de segundo orden

$$p(Z) = H(\eta_z) = H\left(\beta_0 + \sum_{j=1}^p f_j(Z_j) + \sum_{1 \leq j < k \leq p} f_{jk}(Z_j, Z_k)\right)$$

donde  $f_j$  son funciones unidimensionales desconocidas, las

$\{f_{jk}\}_{1 \leq j < k \leq p}$  son un conjunto de funciones bidimensionales

desconocidas y H es la función link monótona y conocida.

- Se ha visto que el GAM con interacciones detecta el inicio de los episodios con mayor antelación de lo que lo hace el GAM puro.

## *Modelos de Predicción binaria*

---

Roca-Pardiñas, J., Cadarso-Suárez C. and González-Manteiga W. *Testing for interactions in generalized additive models: Application to SO<sub>2</sub> pollution data.* Statistics and Computing **2005**; 15: 289-299.

# Modelos de Redes Neuronales

- ❑ La entrada en vigor de la Directiva Europea 1999/CE/30, provoca un cambio en la serie de interés, de medias bihorarias a medias horarias.


$$x_t = \frac{1}{12} \sum_{i=0}^{11} SO_2(t - i)$$

donde  $SO_2(t)$  representa la concentración de  $SO_2$  en el instante  $t$  (pentaminutal), medida en  $\mu\text{g}/\text{m}^3$ .

- ❑ Se adaptó el modelo semiparamétrico para trabajar con la nueva serie pero se observó un considerable aumento de la variabilidad.
- ❑ Para mejorar las predicciones se desarrollaron modelos de redes neuronales.

# Modelos de Redes Neuronales

- La topología de la red diseñada es la siguiente:



# Modelos de Redes Neuronales


- El predictor dado por la red neuronal tiene la siguiente expresión:

$$\hat{x}_{t+6} = o_1 = \sum_{j=1}^L \omega_1^o f_j^h \left( \theta_j^h + \omega_{j1}^h x_{t-3} + \omega_{j2}^h x_t \right)$$

donde

- $f_j^h(z) = \frac{1}{1 + e^{-z}}$  para todos los nodos  $j$  de la capa oculta.
- Los pesos  $\{\omega_{j1}^h, \omega_{j2}^h; j = 1, \dots, L\}$  y las tendencias  $\{\theta_j^h; j = 1, \dots, L\}$  serán determinados durante el proceso de entrenamiento.
- El número  $L$  de nodos de la capa oculta se determinará en el entrenamiento como el valor cuya red neuronal proporcione mejores resultados, tras haber entrenado redes idénticas con distintos valores de  $L$ .

# Modelos de Redes Neuronales




# Modelos de Redes Neuronales

Fernández de Castro B.M., Prada-Sánchez J.M., González-Manteiga W., Febrero-Bande M., Bermúdez-Cela J.L. and Hernández Fernández J.J. *Prediction of SO<sub>2</sub> levels using neural networks.* Journal of the Air and Waste Management Association **2003**; 53: 532-538.


# Modelos Funcionales

□ Idea central:




# Modelos Funcionales

- Idea central:



# Modelos Funcionales

- Idea central:



# Modelos Funcionales


- Se considera la serie de datos como observaciones de un proceso estocástico en tiempo continuo que modeliza los niveles medios horarios de  $\text{SO}_2$ .
- Se consideran porciones de dicho proceso estocástico que representan media hora.
- En consecuencia se consideran variables aleatorias que toman valores en

$$H = L^2([0, 6])$$

de la forma:

$$X_n(u) = x(6n + u)$$

# Modelos Funcionales




## Modelos Funcionales

---

Fernández de Castro B.M., Guillas S. and González-Manteiga W. *Functional Samples and Bootstrap for Predicting Sulfur Dioxide Levels.* Technometrics **2005**. 47: 212-222.

# Boosting



# Boosting

---

Fernández de Castro B.M. and González-Manteiga W.  
*Boosting for real and functional samples: an application to an environmental problem.*  
Stochastic Environmental Research and Risk Assessment  
2008. 22: 27-37.

# Nuevas aportaciones a la predicción: el fenómeno de la cointegración

- ❑ El nuevo objetivo de los modelos de predicción será modelizar el  $\text{NO}_x$ , para poder predecir sus valores con media hora de antelación, así como seguir obteniendo las predicciones del  $\text{SO}_2$ .
- ❑ La idea es generalizar el enfoque semiparamétrico unidimensional propuesto por García Jurado, *et al.* (1995), teniendo en cuenta la estructura de correlación entre las series que se pretenden predecir: las relaciones de cointegración.
- ❑ Se van a considerar dos posibles enfoques:
  - ❑ Cointegración lineal con respuesta multidimensional.
  - ❑ Cointegración no paramétrica unidimensional.

# Estructura de correlación: Cointegración

- Granger (1983) y Engle & Granger (1987) desarrollaron formalmente el concepto de procesos cointegrados.

- Sea  $Z_t = (z_{1t}, \dots, z_{nt})'$  un vector de  $n$  series de tiempo  $I(1)$ .

$Z_t$  está *cointegrada* si existe un vector  $\beta = (\beta_1, \dots, \beta_n)'$  tal que

$$\beta' Z_t = \beta_1 z_{1t} + \dots + \beta_n z_{nt} \sim I(0)$$

- $\beta$  recibe el nombre de *vector de cointegración*. Dicho vector no es único; se suele considerar la normalización  $\beta = (1, -\beta_2, \dots, -\beta_n)$  y así la relación de cointegración se puede expresar:

$$z_{1t} = \beta_2 z_{2t} + \dots + \beta_n z_{nt} + u_t$$

donde  $u_t \sim I(0)$ , se denomina *error de desequilibrio* o *residuo de cointegración*.

# Cointegración: Procedimiento de Johansen

- Se considera el modelo autorregresivo vectorial de orden  $p$  (VAR( $p$ )) para el vector de series temporales  $Z_t$

$$Z_t = \Phi D_t + \Pi_1 Z_{t-1} + \dots + \Pi_p Z_{t-p} + \varepsilon_t, t = 1, \dots, T$$

donde  $D_t$  contiene los términos determinísticos.

- Supóngase que  $Z_t$  es integrada de orden 1 ( $I(1)$ ) con posibilidad de estar cointegrada.
- La representación VAR no es la más adecuada para el análisis: las relaciones de cointegración no aparecen explícitamente.

# Cointegración: Procedimiento de Johansen

- Se transforma el VAR en un *modelo de corrección de errores vectorial (VECM)*

$$\Delta Z_t = \Phi D_t + \Pi Z_{t-1} + \Gamma_1 \Delta Z_{t-1} + \dots + \Gamma_{p-1} \Delta Z_{t-p+1} + \varepsilon_t$$

donde  $\Pi = \Pi_1 + \dots + \Pi_p - I_n$      $\Gamma_k = -\sum_{j=k+1}^p \Pi_j$ ,  $k = 1, \dots, p-1$

- El rango de la matriz singular  $\Pi$  proporciona la información del número de relaciones de cointegración existentes, es decir, el rango de cointegración.

# Modelo Semiparamétrico Multidimensional con Cointegración en los errores.

- Se considera el modelo

$$Z_t = \varphi(Y_t) + e_t$$

donde  $e_t$  tiene una estructura  $VECM(p)$  independiente de  $Y_t$ .

- La predicción se define por:

$$\hat{Z}_t = \hat{\varphi}(Y_t) + \hat{e}_t$$

donde  $\hat{\varphi}(Y_t)$  es un estimador no paramétrico y  $\hat{e}_t$  es la predicción dada por el  $VECM$  de la serie residual


$$\hat{e}_t = Z_t - \hat{\varphi}(Y_t)$$

## Aplicación al problema medioambiental


- Sea  $X_t$  la serie bidimensional formada por las series de valores medios horarios de  $\text{SO}_2$  y  $\text{NO}_x$  relativa a las últimas cuatro horas.
- Se pretende predecir  $X_{t+30}$  utilizando el modelo anterior:
  - Se supone que  $X_t = \varphi(X_{t-1}, X_{t-1} - X_{t-6}) + e_t$ .
  - En cada instante se estima  $\varphi(X_{t-1}, X_{t-1} - X_{t-6})$  con modelos aditivos, de forma independiente para cada componente.
  - Se construye la serie de residuos  $\hat{e}_{t-6}, \dots, \hat{e}_t$  donde  $\hat{e}_i := X_i - \hat{\varphi}(X_{i-1}, X_{i-1} - X_{i-6})$  y se ajusta un VECM adecuado.
  - Se obtiene la predicción  $\dot{e}_{t+30}$ .
  - La predicción final propuesta es:

$$\hat{X}_{t+30} = \hat{\varphi}(\hat{X}_{t+29}, \hat{X}_{t+29} - \hat{X}_{t+24}) + \dot{e}_{t+30}$$

# Aplicación al problema medioambiental



# Aplicación al problema medioambiental



## *Bibliografía adicional*

- ❑ Engle R.F. and Granger C.W.J. *Co-Integration and Error Correction: Representation, Estimation and Testing*. *Econometrica* 1987; 55: 251-276.
- ❑ Granger C.W.J. *Co-Integrated Variables and Error-Correcting Models*. Unpublished University of California, San Diego 1983; Discussion Paper: 83-13.
- ❑ Hastie T.J., Tibshirani R.J. and Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer-Verlag, New York 2001.
- ❑ Johansen S. *Statistical Analysis of Cointegration Vectors*. *Journal of Economic Dynamics and Control* 1988; 12: 231-254.

