

Análisis Estadístico de Datos Direccionales.

Aplicaciones Medioambientales.

Proyecto Fin de Máster - Máster en Técnicas Estadísticas

Alumna: María Leyenda Rodríguez
Tutor: Wenceslao González Manteiga

El presente documento recoge el Proyecto Fin de Máster para el Máster en Técnicas Estadísticas realizado por D^a. María Leyenda Rodríguez bajo el título **“Análisis Estadístico de Datos Direccionales. Aplicaciones Medioambientales”**.

D. Wenceslao González Manteiga catedrático del Departamento de Estadística e Investigación Operativa de la Universidad de Santiago de Compostela y profesores del citado Máster, autoriza y dirige el presente proyecto.

Este trabajo fue cofinanciado por la Dirección Xeral de Investigación, Desenvolvemento e Innovación de la Consellería de Innovación e Industria de la Xunta de Galicia (Código 10MDS207015PR).

Santiago de Compostela, 1 de julio de 2011

Fdo.: D^a. María Leyenda Rodríguez

Fdo.: D. Wenceslao González Manteiga

Índice general

1. Introducción	1
2. Resumen estadístico de datos direccionales	5
2.1. Medidas de localización	6
2.2. Medidas de concentración y dispersión	7
2.3. Distribuciones notables	7
2.3.1. Distribución uniforme	9
2.3.2. Distribución Cardioide	9
2.3.3. Distribución Normal proyectada	10
2.3.4. Distribución Wrapped	11
2.3.5. Distribución von Mises	12
3. Estimación de la densidad circular	17
3.1. Estimación tipo núcleo de la densidad circular	17
3.2. Selección del parámetro de suavizado.	19
3.2.1. Validación cruzada	20
3.2.2. Regla plug-in escala von Mises	21
4. Estimación de la regresión circular-lineal	23
4.1. Estimación no paramétrica tipo núcleo de la regresión circular-lineal	23
4.2. Selección del parámetro de suavizado	24
5. El modelo de Möbius de series de tiempo	27
5.1. El modelo Möbius de series de tiempo	27
5.2. Función de máxima verosimilitud	28
6. Análisis de Datos Medioambientales	31
6.1. Datos Perturbados	32
6.2. Análisis de los datos de dirección de viento	33
6.3. Estimación tipo núcleo de la función de densidad circular	36
6.4. Estimación del modelo de Möbius de series de tiempo	40

6.5.	Estimación tipo núcleo de la función de regresión circular-lineal . . .	46
6.5.1.	Estación B1	52
6.5.2.	Estación B2	53
6.5.3.	Estación C9	55
6.5.4.	Estación F2	56
6.5.5.	Estación G2	58
7.	Software	61
	Bibliografía	63

Capítulo 1

Introducción

Endesa Generación S.A. cuenta en el municipio de As Pontes de García Rodríguez, al noroeste de la provincia de A Coruña, con una importante Unidad de Producción Térmica (U.P.T. As Pontes) en la que se encuentran las Centrales Térmica y de Ciclo Combinado de As Pontes.

Las Centrales tienen implantado un Sistema de Control Suplementario de la Contaminación Atmosférica que incluye la adquisición de datos de calidad de aire en tiempo real, su tratamiento y la realización de operaciones específicas que nos ayuden a la reducción de emisiones. Esto es útil cuando las condiciones meteorológicas son adversas para la difusión del penacho emitido y/o se dan episodios significativos de alteración de calidad del aire en el entorno de éstas.

Los datos de calidad de aire en tiempo real se adquieren mediante una Red de Vigilancia de la Calidad Atmosférica constituida por 10 estaciones automáticas, distribuidas en un radio de aproximadamente 30 km alrededor de las centrales. Además, también se dispone de una estación meteorológica central llamada Estación de A Mourela. Estas estaciones, proporcionan medidas en continuo de diversos contaminantes y variables meteorológicas.

Debido al compromiso de Endesa Generación S.A. con el medio ambiente y su interés por mejorar este sistema de predicción, se estableció una fructífera relación entre la Sección de Medio Ambiente de la U.P.T. As Pontes y el Departamento de Estadística e Investigación Operativa de la Universidad de Santiago de Compostela.

De esta relación nace el Sistema de Predicción Estadística de Inmisión (SIPEI) que permite obtener predicciones de los valores de dióxido de azufre y de óxidos de nitrógeno, con media hora de antelación, usando modelos aditivos. Además, este

sistema también predice cuál es el origen del episodio de alteración de calidad de aire, ya que este puede ser causado por la Central Térmica, el Ciclo Combinado u otros posibles focos como por ejemplo el tráfico o las actividades agrícolas de la zona.

En este trabajo nos hemos propuesto analizar la dirección de viento medida en la estación meteorológica A Mourela a 80 metros, considerando la naturaleza angular de la dirección de viento. Realizaremos la estimación no paramétrica tipo núcleo de la densidad circular haciendo un especial hincapié en la selección del parámetro de suavizado. Notemos que estos datos de dirección de viento son minutales y recogidos a lo largo del año 2010 lo que nos llevó a estudiar el modelo de Möbius de series de tiempo.

Debido al interés por estudiar la relación entre las concentraciones de dióxido de azufre (SO_2) y la dirección de viento utilizaremos la estimación no paramétrica tipo núcleo de la función de regresión donde la selección del parámetro de suavizado también es de vital importancia. Hay que destacar que en este apartado se va a trabajar con la dirección de viento recogida en cinco de las estaciones de medida automáticas que también forman parte del Sistema de Control Suplementario de la Contaminación Atmosférica de la U.P.T de As Pontes; donde además de medir la dirección de viento, se registran las concentraciones de SO_2 lo que es crucial a la hora de estimar la función de regresión. Con el fin de que esto nos ayude a determinar si el episodio tiene como origen la central térmica o no; es decir, se quiere observar si la presencia de SO_2 es debida a las emisiones de la central y para ello vamos a considerar si el viento va en esa dirección o no.

Nos interesa tomar la dirección de viento en la estación meteorológica ya que si se obtuviese algún resultado interesante esta sería la única manera de extenderlo a todas las estaciones. En cambio, a la hora de realizar la estimación no paramétrica de la regresión fue imposible utilizar los datos de dirección de viento ya que en esta estación no se recogen las concentraciones de SO_2 . Por ello, nos hemos visto obligados a realizar dicha estimación en las estaciones de medida automáticas que recogen tanto la dirección de viento como las concentraciones de SO_2 .

En la Figura 1.1 representamos las 5 estaciones de medida automáticas que van a ser usadas la estimación tipo núcleo no paramétrica de la función de regresión. Se observa que la estación de medición B1 y F2 denominadas Magdalena y Fraga Redonda, respectivamente, se encuentran en el municipio de As Pontes, B2 denominada Louseiras se encuentra en el municipio de Muras, C9 denominada Mouranza se encuentra en el municipio de Vilalba y G2 denominada Vilanova se

encuentra en el municipio de San Sadurniño. En la Figura 1.1 también se observa que la estación meteorológica A Mourela está situada en el municipio de As Pontes.




Figura 1.1: Estaciones de medida automáticas (verde). Estación Meteorológica A Mourela (azul)

El documento se estructura de modo que en los cuatro primeros capítulos se introducen técnicas que van a ser utilizadas. En el Capítulo 1 se introducen los datos direccionales, en el Capítulo 2 se estudia la estimación no paramétrica tipo núcleo de la densidad circular haciendo un especial hincapié en la selección del parámetro de suavizado, en el Capítulo 3 se estudia la estimación no paramétrica tipo núcleo de la función de regresión circular-lineal donde la elección del parámetro de suavizado también será tratada y en el Capítulo 4 se estudia el modelo de Möbius de series de tiempo,. Finalmente en el Capítulo 5 se aplican las técnicas anteriores a los datos proporcionados por la Sección de Medio Ambiente de la U.P.T. As Pontes a quienes agradecemos su amabilidad.

Capítulo 2

Resumen estadístico de datos direccionales

En diversos campos surgen problemas estadísticos donde los datos son recogidos mediante medidas angulares dando la orientación o ángulos en el plano (datos circulares) o en el espacio (datos esféricos). Los datos circulares constituyen el caso más simple de esta categoría de datos llamada datos direccionales, donde la medida no es escalar, sino que es angular o direccional. La suposición estadística básica es que los datos son una muestra aleatoria de una población de direcciones. Para trabajar con datos de esta naturaleza es necesario construir nuevos estadísticos pues los estadísticos usuales empleados para datos lineales son inapropiados, ya que no tienen en cuenta la naturaleza periódica de esta clase de datos.

Los datos circulares se obtienen de diversas formas. Las dos principales corresponden a los instrumentos de medición circular clásicos: la brújula y el reloj. Entre las observaciones típicas medidas por la brújula se encuentran las direcciones de viento y las direcciones migratorias de los pájaros. Un ejemplo para el reloj son los tiempos de llegada de los pacientes a una unidad de urgencias de un hospital. Otros conjuntos de datos similares surgen al considerar las veces en un año (o veces en un mes) de un cierto evento.

En este capítulo, presentaremos la descriptiva de los datos circulares siguiendo Mardia y Jupp, 2000. Comenzaremos estudiando las medidas de localización, concentración y dispersión, Secciones 1.1., 1.2. y finalmente nos centraremos en las principales distribuciones circulares, Sección 1.3.

2.1. Medidas de localización

Las direcciones en el plano se pueden observar como vectores unitarios en el plano o como puntos en el círculo unidad. Aunque hay otras dos formas muy útiles de observar las direcciones- como ángulos y como números complejos- escogiendo una dirección y orientación inicial. Esto sería equivalente a escoger un sistema de coordenadas ortogonal en el plano. Por tanto, cada punto $\mathbf{x}$ en el círculo unidad puede ser representado por un ángulo θ o por un número complejo unitario z .

$$\begin{aligned}\mathbf{x} &= (\cos \theta, \sin \theta) \\ z &= e^{i\theta} = \cos \theta + i \sin \theta\end{aligned}$$

Sean $x_1, \dots, x_n$ cuyos ángulos correspondientes son θ_i , $i = 1, \dots, n$. La dirección media $\bar{\theta}$ de $\theta_1, \dots, \theta_n$ es la dirección de $x_1 + \dots + x_n$ que es el centro de masa $\bar{x}$ de $x_1, \dots, x_n$.

Por tanto, si las coordenadas cartesianas de x_j son $(\cos \theta_j, \sin \theta_j)$, entonces $(\bar{C}, \bar{S})$ son las coordenadas cartesianas del centro de masas.

$$\bar{C} = \frac{1}{n} \sum_{j=1}^n \cos \theta_j; \quad \bar{S} = \frac{1}{n} \sum_{j=1}^n \sin \theta_j$$

Supongamos que $x_1 + \dots + x_n$ es un vector no nulo, en cuyo caso, la longitud media resultante,

$$\bar{R} = \sqrt{\bar{C}^2 + \bar{S}^2}, \quad (2.1)$$

es mayor que cero, $\bar{\theta}$ es la solución de las siguientes ecuaciones

$$\bar{C} = \bar{R} \cos \bar{\theta}, \quad \bar{S} = \bar{R} \sin \bar{\theta}$$

y es la dirección de $x_1 + \dots + x_n$, denominada, dirección media.

Por otra parte, la mediana muestral de la dirección $\bar{\theta}$ de los ángulos $(\theta_1, \dots, \theta_n)$ es todo ángulo ϕ tal que la mitad de los puntos se encuentran en el arco $[\phi, \phi + \pi)$ y la mayoría de los puntos están más cerca de ϕ que de $\phi + \pi$.

- Cuando n es par, la mediana coincide con uno de ellos.
- Cuando n es impar, es conveniente tomar la mediana como el punto medio de dos puntos adyacentes adecuados.

2.2. Medidas de concentración y dispersión

La media de longitud resultante $\bar{R}$ introducida en (2.1) es la medida de dispersión más importante en datos direccionales. Sean $x_1, \dots, x_n$ vectores unitarios, entonces es claro que $0 \leq \bar{R} \leq 1$; de lo que se deduce que:

- Si las direcciones $\theta_1, \dots, \theta_n$ están estrechamente agrupadas luego $\bar{R} = 1$.
- Si $\theta_1, \dots, \theta_n$ están muy dispersas luego $\bar{R}$ será prácticamente 0.

Además esta medida de concentración tiene las siguientes propiedades

- $\bar{R}$ es invariante bajo rotaciones.
- La longitud resultante $\bar{R}$ es la longitud del vector resultante $x_1 + \dots + x_n$.

A veces emplearemos otras medidas de dispersión análogas a las de los datos en la recta real. La medida más simple es la varianza circular muestral,

$$V = 1 - \bar{R},$$

o la desviación circular estándar,

$$v = \sqrt{-2 \log \bar{R}}, \quad (2.2)$$

donde $\log$ es el logaritmo neperiano.

También podemos considerar la distancia entre dos ángulos θ y ξ

$$\min(\theta - \xi, 2\pi - (\theta - \xi)) = \pi - |\pi - |\theta - \xi||$$

y definir la medida de dispersión de los ángulos $\theta_1, \dots, \theta_n$ sobre un ángulo dado α

$$d_0(\alpha) = \frac{1}{n} \sum_{i=1}^n (\pi - |\pi - |\theta_i - \alpha||).$$

La función d_0 alcanza el mínimo en la mediana muestral $\tilde{\theta}$. La desviación circular media es $d_0(\tilde{\theta})$

2.3. Distribuciones notables

Una forma de especificar una distribución en el círculo unidad es por medio de su función de distribución. Suponemos que ha sido escogida una dirección y orientación inicial en el círculo unidad. Luego la distribución puede ser considerada

como la de un ángulo aleatorio θ y su función de distribución F es definida como la función en toda línea real dada por

$$F(x) = \mathbb{P}(0 < \Theta \leq x), \quad 0 \leq x \leq 2\pi$$

y

$$F(x + 2\pi) - F(x) = 1, \quad -\infty < x < \infty \quad (2.3)$$

La ecuación (2.3) solo afirma que todo arco en el círculo unidad de longitud 2π tiene probabilidad uno (este arco es la totalidad de la circunferencia en el círculo). Para $\alpha \leq \beta \leq \alpha + 2\pi$,

$$\mathbb{P}(\alpha < \Theta \leq \beta) = F(\beta) - F(\alpha) = \int_{\alpha}^{\beta} dF(x) \quad (2.4)$$

donde la integral es una integral de Lebesgue-Stieltjes. La función de distribución F es continua por la derecha y por definición

$$F(0) = 0, \quad F(2\pi) = 1$$

Notemos que aunque la función F dependa de la elección inicial, (2.4) muestra que $F(\beta) - F(\alpha)$ es independiente de esta elección, por tanto cambiar la dirección inicial es simplemente añadir una constante a F .

Si la función de distribución F es absolutamente continua tiene como función de densidad a f tal que

$$\int_{\alpha}^{\beta} f(x)dx = F(\beta) - F(\alpha), \quad -\infty < \alpha \leq \beta < \infty.$$

Una función f es la función de densidad de una distribución absolutamente continua si y sólo si

1. $f(\theta) \geq 0$ en casi todo $(-\infty, \infty)$.
2. $\int_0^{2\pi} f(\theta)d\theta = 1$.
3. $f(\theta) = f(\theta + 2\pi)$ en casi todo $(-\infty, \infty)$.

En definitiva, una distribución circular es una distribución de probabilidad la cual está concentrada en la circunferencia de círculo unidad. Las distribuciones circulares son de dos tipos:

1. Discretas: asignan masas de probabilidad solo a un número de direcciones.
2. Absolutamente continuas.

2.3.1. Distribución uniforme

Es la distribución más básica en el círculo y a menudo se utiliza como modelo nulo. Esta es la única distribución en el círculo que es invariante bajo rotación y reflexión. Su función de densidad es

$$f(\theta) = \frac{1}{2\pi} \quad (2.5)$$

Por tanto, para $\alpha \leq \beta \leq \alpha + 2\pi$,

$$\mathbb{P}(\alpha < \theta \leq \beta) = \frac{\beta - \alpha}{2\pi}$$

es decir, es proporcional a la longitud del arco.

2.3.2. Distribución Cardioide

La perturbación de la densidad uniforme por la función coseno da lugar a una distribución denominada Cardioide $C(\mu, \rho)$, cuya función de densidad es,

$$f(\theta) = \frac{1}{2\pi}(1 + 2\rho \cos(\theta - \mu)), \quad |\rho| < \frac{1}{2}. \quad (2.6)$$

- La media de longitud resultante es ρ .
- La media de la dirección es μ .
- La distribución es simétrica y unimodal en μ (si $\rho > 0$) (Figura 2.1).
- Si $\rho = 0$ la distribución se reduce a la distribución Uniforme (Figura 2.1).

Esta distribución se define para añadir flexibilidad a la distribución Uniforme. Además, la distribución Cardioide es utilizada, principalmente, como aproximaciones de poca concentración a las distribuciones von Mises.

Hay que destacar que el conjunto de distribuciones Cardioides es cerrado bajo convolución,

$$\theta_i \sim C(\mu_i, \rho_i) (i = 1, 2) \Rightarrow \theta_1 + \theta_2 \sim C(\mu_1 + \mu_2, \rho_1 \rho_2);$$

es decir, que si dos ángulos independientes siguen una distribución Cardioide de parámetros la suma de estos dos ángulos también seguirá una distribución Cardioide de parámetros la suma de los parámetros de las distribuciones Cardioide de cada uno de los ángulos.




Figura 2.1: Representación de la función de densidad cardiode $C(0, \rho)$, $\rho=0.1$ (verde), $\rho=0.2$ (azul), $\rho=0.3$ (naranja), $\rho=0.4$ (rojo), $\rho=0.5$ (negro)

2.3.3. Distribución Normal proyectada

Las distribuciones en el círculo pueden ser obtenidas mediante proyección radial de la distribución en el plano. Sea X un vector aleatorio bidimensional siguiendo una distribución normal bidimensional con media 0 y matriz de covarianzas Σ , $\mathbb{P}(x=0)=0$. Luego $\|x\|^{-1}x$ es un punto aleatorio sobre el círculo unidad.

$$p(\theta; \mu, \Sigma) = \frac{\phi(\theta; 0, \Sigma) + |\Sigma|^{-1/2} D(\theta) \phi(D(\theta)) \phi(|\Sigma|^{-1/2} (x^T \Sigma^{-1} x)^{-1/2} \mu \wedge x)}{x^T \Sigma^{-1} x}$$

donde $\phi(\cdot; 0, \Sigma)$ denota la función de densidad de $N_2(0, \Sigma)$, ϕ y Φ denotan la función densidad y la función de distribución de $N(0,1)$, $x = (\cos \theta, \sin \theta)^T$

$$D(\theta) = \frac{\mu^T \Sigma^{-1} x}{(x^T \Sigma^{-1} x)^{1/2}}$$

$$\mu \wedge x = \mu_1 \sin \theta - \mu_2 \cos \theta \quad \mu = (\mu_1, \mu_2)^T$$

2.3.4. Distribución Wrapped

Dada una distribución en la recta real, se puede envolver alrededor de la circunferencia del círculo de radio uno. Si X es una variable aleatoria en la línea, la variable aleatoria correspondiente X_w de la distribución wrapped viene dada por

$$X_w = X(\text{mod } 2\pi)$$

Si el círculo es identificado con el conjunto de números complejos de módulo la unidad, entonces los puntos de la línea envueltos en el círculo $x \rightarrow x_w$ pueden ser escritos como

$$x \rightarrow e^{2\pi i x}$$

Si x tiene como función de distribución F , se deduce que la función de distribución F_w de x_w viene dada por

$$F_w(\theta) = \sum_{\kappa=-\infty}^{\infty} \{F(\theta + 2\pi\kappa) - F(2\pi\kappa)\}$$

Si x tiene como función de masa de probabilidad f , entonces la función de densidad f_w de x_w es

$$f_w(\theta) = \sum_{\kappa=-\infty}^{\infty} f(\theta + 2\pi\kappa).$$

Hay diversos tipos de distribuciones wrapped. Uno de ellos es la distribución wrapped normal $WN(\mu, \rho)$ la cual se obtiene al envolver la distribución $N(\mu, \sigma^2)$ en el círculo, donde

$$\sigma^2 = -2 \log \rho, \quad \rho = e^{-\sigma^2/2}$$

Su función de densidad viene dada por

$$\phi_w(\theta; \mu, \rho) = \frac{1}{2\pi} \left\{ 1 + 2 \sum_{p=1}^{\infty} \rho^{p^2} \cos p(\theta - \mu) \right\} \quad (2.7)$$

2.3.5. Distribución von Mises

La distribución von Mises es la más utilizada en el círculo. La distribución von Mises $vM(\mu, \kappa)$ tiene como función de densidad

$$g(\theta; \mu, \kappa) = \frac{1}{2\pi I_0(\kappa)} e^{\kappa \cos(\theta - \mu)} \quad (2.8)$$

$$(2.9)$$

donde

- I_0 denota la función de Bessel modificada de primer tipo y orden 0,

$$I_0(\kappa) = \frac{1}{2\pi} \int_0^{2\pi} e^{\kappa \cos \theta} d\theta.$$

- El parámetro μ es la media de las direcciones.
- κ es el parámetro de concentración.

Dado la importancia de la distribución von Mises le reservamos la letra g para denotar su función de densidad.

Como se puede ver en la Figura 2.2 la distribución von Mises es unimodal y es simétrica sobre $\theta = \mu$. Además la moda se encuentra en $\theta = \mu$ y la antimoda en $\theta = \mu + \pi$. La relación de la moda de la densidad y la antimoda viene dada por $e^{2\kappa}$, así que cuanto mayor sea el valor de κ , mayor es el agrupamiento acerca de la moda. En esta Figura 2.2 también se observa el hecho de que cuanto más grande sea el parámetro κ su función de densidad estará más concentrada.

El parámetro κ es una medida de concentración en el caso de que nuestra muestra siga una von Mises. Así que, nos hemos planteado explicar la relación entre diferentes medidas de dispersión como son la media de longitud resultante (2.1), la desviación circular estándar (2.2), la varianza definida de forma análoga al caso lineal, que se definirá a continuación, y el parámetro de concentración de la distribución von Mises κ .

1. Generar una muestra $vM(\pi, \kappa)$ de tamaño 3000 para distintos valores del parámetro κ (75 valores).
2. Para cada una de las muestras calculamos:




Figura 2.2: Representación de la función de densidad von Mises $vM(0, \kappa)$, $\kappa=0.5$ (verde), $\kappa=1$ (azul), $\kappa=2$ (naranja), $\kappa=4$ (rojo).

- La varianza definida de forma análoga al caso lineal,

$$\min_{\theta} S_n^2(\theta) = \min_{\theta} \frac{1}{n} \sum_{i=1}^n d^2(\theta_i, \theta)$$

con respecto a la distancia euclídea y a la distancia definida por la longitud de arco (??),

$$d^2(\theta_i, \theta) = 2(1 - (\cos(\theta_i - \theta))),$$

y a la distancia definida por la longitud de arco,

$$d^2(\theta_i, \theta) = \pi - |\pi - |\theta_i - \theta||.$$

- El parámetro de concentración $\bar{R} = \sqrt{\bar{C}^2 + \bar{S}^2}$ y
- La desviación circular estándar $\sqrt{-2 \log(\bar{R})}$.

3. Representar el estimador local-lineal para estudiar las relaciones de estas medidas de concentración y dispersión, frente a diferentes valores de κ .

En la Figura 2.3 se puede observar que v , S_n^2 (obtenida mediante cualquiera de las distancias) se comportan de forma similar: disminuyen casi de forma exponencial a




Figura 2.3: Relación entre $\bar{R}$ (azul), v (verde), S_n^2 distancia arco (negro), S_n^2 distancia euclídea (rosa) y $1/\kappa$ (rojo)

medida que κ aumenta. Mientras que $\bar{R}$ se comporta de modo diferente: aumenta a medida que lo hace κ .

La distribución von Mises juega un papel crucial en el campo de los datos direccionales. De hecho, juega el mismo papel que la distribución gaussiana en los datos lineales. Debido a esto nos va a interesar tanto aproximar como relacionar la distribución von Mises con otras distribuciones. Así pues,

- Si $\kappa = 0$, entonces $vM(\mu, \kappa)$ es la distribución uniforme (2.5). Además para x próximos a 0 la aproximación $\exp(x) \cong 1 + x$, muestra que para κ pequeños $vM(\mu, \kappa) \cong C(\mu, \kappa/2)$, donde $C(\mu, \kappa/2)$ denota una distribución Cardioide (2.6). Por tanto, una distribución von Mises con parámetro de concentración pequeño puede ser aproximada por una distribución Cardioide con la misma dirección media y mismo parámetro de concentración dividido por 2.
- Cuando $\kappa \rightarrow \infty$ la distribución $vM(\mu, \kappa)$ está concentrada en el punto $\theta = \mu$.
- Si κ es grande, sea $\theta \sim vM(\mu, \kappa)$ (2.8) y sea $\xi = \kappa^{1/2}(\theta - \mu)$. Luego, de (2.8) se deduce que la función de distribución de ξ es ‘proporcional a

$$\exp \left\{ -\kappa [1 - \cos(\kappa^{-1/2} \xi)] \right\}. \quad (2.10)$$

Para κ grande,

$$1 - \cos(\kappa^{-1/2}\xi) = \frac{1}{2}\kappa^{-1}\xi^2 + O(\kappa^{-2})$$

así pues, de (2.10), $\xi \sim N(0, 1)$. Entonces para grandes valores de κ ,

$$\theta \sim vM(\mu, \kappa) \Rightarrow \kappa^{-1/2}(\theta - \mu) \sim N(0, 1), \quad \kappa \rightarrow \infty. \quad (2.11)$$

- De foma más general, cualquier von Mises puede ser aproximada por una distribución wrapped normal (2.7)

$$vM(\mu, \kappa) \cong WN(\mu, A(\kappa)), \quad \kappa \rightarrow \infty$$

$$A_\kappa = I_1(\kappa)/I_0(\kappa).$$

Respecto a la convolución, notemos que la convolución de dos von Mises no es una distribución von Mises. En cambio, la convolución de dos distribuciones wrapped normal, $WN(\mu_1, A(\kappa_1))$ y $WN(\mu_2, A(\kappa_2))$ es la distribución wrapped normal $WN(\mu_1 + \mu_2, A(\kappa_1)A(\kappa_2))$. La cual puede ser aproximada por $vM(\mu_1 + \mu_2, A^{-1}(A(\kappa_1)A(\kappa_2)))$.

$$\theta_1 + \theta_2 \sim vM(\mu_1 + \mu_2, A^{-1}(A(\kappa_1)A(\kappa_2))).$$

Capítulo 3

Estimación de la densidad circular

En la Sección 2.1., describiremos la estimación no paramétrica tipo núcleo de la densidad circular (sección 2.1). Al igual que en el caso lineal, la selección del parámetro de suavizado será crucial. Se estudiarán tres métodos de selección: un método usando la técnica plug-in y dos mediante validación cruzada que surgen de minimizar la función de pérdida dada por minimizar el error cuadrático medio (L2) o minimizar la función de pérdida dada por Kullback-Leibler (ver Hall, Watson y Cabrera, 1987)

3.1. Estimación no paramétrica tipo núcleo de la densidad circular

En el caso lineal, si partimos de una muestra aleatoria simple $X_1, \dots, X_n$, el estimador natural de la probabilidad en cada uno de los intervalos $[x_m, x_{m+1})$, con $x_m = x_0 + hm$, $m \in \mathbb{Z}$, es el histograma (3.1)

$$\hat{f}_{n,H}(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}(X_i \in [x_m, x_{m+1})) \quad (3.1)$$

donde $\mathbb{I}$ denota a la función indicadora.

La estimación no paramétrica de la función de densidad dada por el histograma tiene el problema de que se ve muy influenciada por la elección del punto inicial, x_0 . Para solucionar este problema modificaremos esta estimación de manera que para cada punto x se construye un intervalo de la forma $(x - h, x + h)$; lo que da lugar a otra estimación no paramétrica de la densidad denominada histograma móvil.

Teniendo en cuenta que la función de densidad de una variable aleatoria X en un punto x viene dada por

$$f(x) = \lim_{h \rightarrow 0} \frac{1}{2h} \sum_{i=1}^n \mathbb{P}(x-h < X < x+h) \quad (3.2)$$

Podemos definir de manera natural un estimador de tipo núcleo, denominado Estimador Naive, mediante:

$$\hat{f}_{n,N}(x) = \frac{1}{2nh} \sum_{i=1}^n \mathbb{I}(X_i \in (x-h, x+h)) = \frac{1}{2nh} \sum_{i=1}^n \mathbb{I}(x \in (X_i-h, X_i+h)) \quad (3.3)$$

Luego, el Estimador Naive (3.3) se puede escribir como:

$$\hat{f}_{n,N}(x) = \frac{1}{nh} \sum_{i=1}^n \omega\left(\frac{x-X_i}{h}\right) \quad (3.4)$$

donde, ω es la densidad de la distribución uniforme en $(-1, 1)$. Por tanto la aportación de un dato X_i al Estimador Naive en el punto x viene determinado por el valor de

$$\omega\left(\frac{x-X_i}{h}\right)$$

que vale $\frac{1}{2}$ para todos los puntos en $(x-h, x+h)$ independientemente de su proximidad a x .

Si se reemplaza ω por una densidad K (denominada núcleo) con una única moda en cero y simétrica se obtiene el estimador tipo núcleo; también denominado como el estimador de Parzen-Rosemblat que viene dado por

$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x-X_i}{h}\right) \quad (3.5)$$

donde

- h es el parámetro de suavizado o ventana.
- Usualmente se supone que la función núcleo es una función de masa de probabilidad simétrica, por ejemplo, la densidad Gausiana.

Este estimador no paramétrico tipo núcleo de la densidad generaliza al histograma móvil, al promediar pesos variables que penalizan la distancia de los datos al punto

x .

La estimación de la densidad tipo núcleo en el caso lineal (3.5) se extiende fácilmente a datos circulares, aunque se debe tener cuidado en la selección de la función núcleo.

Cuando usamos datos en el círculo, la distancia entre dos puntos en el círculo viene dada por

$$d_i = \|x - X_i\|^2 = 2(1 - x^T X_i) = 2(1 - \cos(\theta - \Theta_i))$$

donde $x^T = (\cos \theta, \sin \theta)$ y $X_i = (\cos \Theta_i, \sin \Theta_i)^T$.

La ecuación (3.5) permite una representación alternativa de la estimación no paramétrica tipo núcleo de la densidad,

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{1 - x^T X_i}{h}\right)$$

Dada una muestra aleatoria de ángulos $\Theta_1, \dots, \Theta_n \in [0, 2\pi]$. Si consideraremos que el estimador no paramétrico tipo núcleo de la densidad con función núcleo la distribución von Mises (2.8), viene dado por

$$\hat{f}(\theta, \nu) = \frac{1}{2\pi I_0(\nu)n} \sum_{i=1}^n \exp(\nu \cos(\theta - \Theta_i)). \quad (3.6)$$

El parámetro de concentración ν ha asumido el papel de la inversa del parámetro de suavizado. Por tanto, controla el grado de suavidad en estimación no paramétrica tipo núcleo de la densidad circular y es análogo al parámetro de suavizado excepto que valores altos de ν proporcionan menos suavidad y pequeños valores de ν conducen a mayor suavidad.

3.2. Selección del parámetro de suavizado.

A continuación, nos centramos en la elección del parámetro de suavizado. Existen varios métodos para seleccionar el parámetro de suavizado como pueden ser el método de validación cruzada o la regla plug-in con densidad de referencia von Mises (2.8).

3.2.1. Validación cruzada

A continuación obtendremos las funciones de validación cruzada para minimizar la función pérdida dada por el error cuadrático medio y la dada por Kullback-Leibler. Ambas dadas por Hall, Watson y Cabrera, (1987).

$$L_2(\nu) = \int_0^{2\pi} \mathbb{E} \left(\hat{f}(\theta, \nu) - f(\theta) \right)^2 d\theta \quad (3.7)$$

$$L_{KL}(\nu) = \int_0^{2\pi} f(\theta) \mathbb{E} \left[\log \left\{ f(\theta) / \hat{f}(\theta, \nu) \right\} \right] d\theta \quad (3.8)$$

Comenzamos obteniendo la función de validación cruzada para la función pérdida dada por el error cuadrático medio (3.8). Para ello comenzamos obteniendo el Error Cuadrático Integrado (ISE). En este caso, se define como

$$ISE_2(\nu) = \int_0^{2\pi} \left(\hat{f}(\theta, \nu) - f(\theta) \right)^2 d\theta$$

y se puede escribir como

$$ISE_2(\nu) = \int_0^{2\pi} \hat{f}^2(\theta, \nu) d\theta - 2 \int_0^{2\pi} \hat{f}(\theta, \nu) f(\theta) d\theta + \int_0^{2\pi} f^2(\theta) d\theta \quad (3.9)$$

Luego podemos buscar el parámetro de suavizado que haga al ISE más pequeño posible. Minimizar la ecuación (3.9) es equivalente a minimizar

$$CV_2(\nu) = \int_0^{2\pi} \hat{f}^2(\theta, \nu) d\theta - 2 \int_0^{2\pi} \hat{f}(\theta, \nu) f(\theta) d\theta$$

Estimamos esta expresión mediante

$$CV_2(\nu) = \int_0^{2\pi} \hat{f}^2(\theta, \nu) d\theta - 2n^{-1} \sum_{i=1}^n \hat{f}_i(\Theta_i, \nu)$$

donde, $\hat{f}_j(\cdot)$ la estimación no paramétrica tipo núcleo de la densidad construída dejando fuera el valor Θ_j de la muestra y viene dada por

$$\hat{f}_j(\theta, \nu) = \frac{1}{2\pi I_0(\nu)n} \sum_{i \neq j} \exp(\nu \cos(\theta - \Theta_i)) \quad (3.10)$$

$$(3.11)$$

se toma como parámetro de suavizado

$$v_2 = \arg \min_{\nu \geq 0} CV_2(\nu) \quad (3.12)$$

$$(3.13)$$

Análogamente se procede con la función de pérdida dada por Kullback-Leibler y se obtiene que otra posible elección para el parámetro de suavizado del siguiente modo

$$v_{KL} = \arg \min_{\nu \geq 0} -CV_{KL}(\nu) \quad (3.14)$$

siendo

$$CV_{KL}(\nu) = n^{-1} \sum_{i=1}^n \log \left\{ \hat{f}_i(\Theta_i, \nu) \right\}$$

donde la expresión $\hat{f}_i(\cdot)$ viene dada por la ecuación (3.11)

3.2.2. Regla plug-in escala von Mises

Si suponemos que $f(\cdot)$ es von Mises con concentración ν y $\mu = 0$. Taylor minimiza el Error Cuadrático Medio Integrado (MISE) para obtener un parámetro de suavizado en vez de minimizar el ISE, puesto que el MISE no depende de la muestra (ver Taylor, 2008). Además obtuvo el Error Cuadrático Medio Integrado Asintótico (AMISE), lo cual no es más que el MISE para muestras grandes. El AMISE obtenido viene dado por

$$AMISE(\nu) = 3\kappa^2 I_2(2\kappa) / \{32\pi\nu^2 I_0(\kappa)^2\} + \nu^{1/2} / (2n\pi^{1/2}) \quad (3.15)$$

donde el primer sumando es la expresión asintótica del sesgo cuadrático integrado y el segundo la expresión asintótica de la varianza cuadrática integrada.

Por tanto, AMISE es de la forma $a\kappa^{-2} + b\kappa^{1/2}$ la cual puede ser minimizada diferenciando respecto de ν e igualando a cero. Esto permite desarrollar la regla plug-in con densidad de referencia von Mises para el parámetro de suavizado ν basado en la estimación de κ mediante máxima verosimilitud (ver Taylor, 2008):

$$\nu = [3n\hat{\kappa}^2 I_2(2\hat{\kappa}) \{4\pi^{1/2} I_0(\hat{\kappa})^2\}^{-1}]^{2/5}. \quad (3.16)$$

Por tanto el parámetro de suavizado, así estimado, tiene una expresión de la forma $\nu = Cn^{2/5}$ donde

$$C = [3\hat{\kappa}^2 I_2(2\hat{\kappa}) \{4\pi^{1/2} I_0(\hat{\kappa})^2\}^{-1}]^{2/5}.$$

A continuación mostramos un ejemplo en el que se observa que los parámetros de suavizado dados por validación cruzada son mejores que el dado por esta técnica plug-in. Pues, los resultados de simulación de Taylor (ver Taylor, 2008) muestran que la regla plug-in se comporta bien cuando la distribución que genera los datos es una von Mises. Sin embargo, estos resultados no son tan satisfactorios cuando esta hipótesis no es cierta. Por ejemplo, si consideramos una mixtura de von Mises de parámetros $\mu_1 = \pi/2$, $\kappa_1 = 15$, $\mu_2 = 3\pi/2$ y $\kappa_2 = 15$ con $\rho = 0,5$; cuya función de densidad viene dada por

$$f(\theta) = \rho f_1(\theta, \mu_1, \kappa_1) + (1 - \rho) f_2(\theta, \mu_2, \kappa_2), \quad 0 < \rho < 1$$

y la comparamos con las tres estimaciones no paramétricas tipo núcleo de la densidad obtenidas tras seleccionar diferentes parámetros de suavizado (3.16, 3.12, 3.14). Se observa (Figura (3.1)) como las estimaciones no paramétricas tipo núcleo de la densidad (3.6) obtenidas tras estimar el parámetro mediante validación cruzada (3.12, 3.14) son mejores que la dada por el parámetro de suavizado obtenido mediante plug-in (3.16). Pues ambas estimaciones se parecen notablemente a la teórica.




Figura 3.1: Representación de la densidad teórica de una mixtura de von Mises $vM(\pi/2, 15), vM(3\pi/2, 15)$ (negra) y la estimación no paramétrica de la densidad seleccionando el parámetro de suavizado mediante las técnicas estudiadas. L2 (azul), Kullback-Leibler (verde), plug-in (violeta)

Capítulo 4

Estimación de la regresión circular-lineal

En la Sección 3.1. describiremos la estimación no paramétrica tipo núcleo de la regresión circular-lineal que se puede utilizar para investigar la relación entre una variable explicativa direccional y una variable respuesta lineal. Mediante validación cruzada obtendremos diferentes parámetros de suavizado mediante los métodos de validación cruzada y plug-in (ver Sección 3.2.).

La estimación no paramétrica tipo núcleo de la función de regresión es comunmente usada como una forma de resumir la relación entre dos variables sin requerir el supuesto de una forma paramétrica para describir dicha relación.

4.1. Estimación no paramétrica tipo núcleo de la regresión circular-lineal

Dadas n observaciones de una variable direccional explicativa $\Theta_1, \dots, \Theta_n$ y una variable respuesta lineal $Y_1, \dots, Y_n$, suponemos que $Y_i = m(\Theta_i) + \epsilon_i$, donde ϵ_i son variables con media cero, independientes e idénticamente distribuidas. Luego, la estimación no paramétrica tipo núcleo de la regresión circular-lineal, $m(\theta)$, viene dada por (ver Haiyong y Schoenberg)

$$\hat{m}(\theta; \nu) = \frac{\sum_{i=1}^n Y_i g(\theta - \Theta_i, 0, \nu)}{\sum_{i=1}^n g(\theta - \Theta_i, 0, \nu)} \quad (4.1)$$

donde función núcleo g denota la función de densidad von Mises (2.8).

Dicha estimación (4.1) es análoga al estimador propuesto por Nadaraya-Watson en 1964 para el caso lineal.

4.2. Selección del parámetro de suavizado

Así como para la estimación no paramétrica tipo núcleo de la densidad, la elección del parámetro de suavizado es crucial para la estimación no paramétrica tipo núcleo de la regresión. Existen varios métodos para seleccionar el parámetro de suavizado automáticamente y pueden ser extendidos al caso de la estimación no paramétrica tipo núcleo de la regresión. Nos centraremos en el método plug-in y en el método de validación cruzada (ver Haiyong y Schoenberg).

Por ejemplo, cuando el núcleo de suavizado evaluado sobre datos lineales es un núcleo Gausiano, Silverman recomienda un parámetro de suavizado de $0,9\hat{\sigma}n^{-1/5}$ y el valor $h_s = 1,06\hat{\sigma}n^{-1/5}$ es sugerido por Scott. (En ambos casos $\hat{\sigma}$ es dado por el mínimo de la desviación típica muestral $x_1, \dots, x_n$ y el rango intercuartílico dividido por 1.34).

Como se vió anteriormente, ambas pueden estar conectadas con el parámetro κ de la distribución de von Mises usando que si θ es distribuída de acuerdo con la distribución von Mises centrada en μ y con parámetro κ , entonces

$$\kappa^{-1/2}(\theta - \mu) \rightarrow_D N(0, 1) \quad \kappa \rightarrow \infty$$

Esto sugiere la elección del parámetro de concentración ν mediante

$$\nu = \frac{1}{h_s^2} \quad (4.2)$$

Otra opción es seleccionar ν por validación cruzada de mínimos cuadrados (LCV). Como en el caso lineal, escogemos ν de modo

$$\nu_{opt} = \arg \min_{\nu \geq 0} CV(\nu) \quad (4.3)$$

$$(4.4)$$

donde

$$CV(\nu) = n^{-1} \sum_{j=1}^n [Y_j - \hat{m}^{-j}(\Theta_j; \nu)]^2$$

donde

$$\hat{m}^{-j}(\theta_j; \nu) = \frac{\sum_{i \neq j}^n Y_i g(\theta_j - \theta_i, 0, \nu)}{\sum_{i \neq j}^n g(\theta_j - \theta_i, 0, \nu)}$$

son las estimaciones sin el dato j -ésimo.

La estimación no paramétrica tipo núcleo seleccionando el parámetro de suavizado mediante LCV puede ser inconsistente bajo una variedad de circunstancias. En particular, para datos discretos con múltiples valores repetidos, validación cruzada tiende a sugerir parámetros de suavizado que infrasuavizan, es decir, ν tiende a ser muy grande. Por tanto valores de ν escogidos de acuerdo (4.2) serán preferidos en este caso.

Capítulo 5

El modelo de Möbius de series de tiempo

En este capítulo se adapta un modelo de regresión circular propuesto en Mardia y Downs (2002) al contexto de series de tiempo siguiendo la metodología propuesta en Hughes (2007) (ver Sección 4.1.). La distribución de θ_t dado θ_{t-1} es modelada usando una distribución von Mises particular. La función de máxima verosimilitud (condicionada a la primera observación) es obtenida en la Sección 4.2., así como la estimación de los parámetros.

5.1. El modelo Möbius de series de tiempo

La componente determinística del modelo de regresión estudiado por Downs y Mardia (2002) une a la variable angular dependiente v con la variable angular independiente u mediante la siguiente expresión

$$\tan \frac{1}{2}(v - \beta) = \omega \tan \frac{1}{2}(u - \alpha) \quad (5.1)$$

dónde $\omega \in [-1, 1]$ es el parámetro que determina la pendiente y $-\pi \leq \alpha, \beta < \pi$ son parámetros que determinan la localización angular. La ecuación (5.1) nos conduce a

$$v = \beta + 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(u - \alpha) \right\} \quad (5.2)$$

Por lo que podemos decir que hemos definido una relación uno a uno entre u y v siempre que ω sea distinto de cero (5.2). El lugar de los puntos (u, v) satisfaciendo (5.1) es una curva cerrada y continua que da una sola vuelta alrededor de una superficie toroidal.

Por tanto, aplicaremos la ecuación (5.2) a las series de datos temporales, reemplazando el ángulo v por θ_t y el ángulo u por θ_{t-1} , $t = 2, \dots, n$. Esta sustitución nos sugiere la existencia de un único parámetro de localización, $\alpha = \beta$, obteniendo así

$$\tan \frac{1}{2}(\theta_t - \alpha) = \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \quad (5.3)$$

y

$$\theta_t = \alpha + 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\} \quad (5.4)$$

ecuaciones análogas a (5.1) y (5.2).

Para el modelo de serie de tiempo dado en (5.4) se asume que $\theta_t|\theta_{t-1}$ sigue una distribución von Mises

$$\theta_t|\theta_{t-1} \sim vM \left(\alpha + 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\}, \kappa \right) \quad (5.5)$$

Por tanto, el modelo de series de tiempo se convierte en

$$\theta_t = \alpha + 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\} + \epsilon_t \quad (5.6)$$

dónde $\epsilon_t \sim vM(0, \kappa)$. Nos referiremos a la distribución condicionada de la media direccional de θ_t dado θ_{t-1} como μ_t . Es decir,

$$\mu_t = \alpha + 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\} \quad (5.7)$$

Notemos que valor de ω se restringe al intervalo $[-1, 1]$ así que α es único.

5.2. Función de máxima verosimilitud

Como

$$\theta_t|\theta_{t-1} \sim vM(\alpha + 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\}, \kappa)$$

se obtiene que

$$f(\theta_t|\theta_{t-1}) = 2\pi I_0(\kappa)^{-1} \exp \{ \kappa \cos(\theta_t - \mu_t) \}$$

dónde μ_t es dada por (5.7). Por tanto, la función de masa de probabilidad de $\theta_2, \dots, \theta_n$ dado θ_1 es

$$\begin{aligned} f(\theta_2, \dots, \theta_n | \theta_1) &= f(\theta_2 | \theta_1) f(\theta_3, \dots, \theta_n | \theta_1, \theta_2) \\ &= f(\theta_2 | \theta_1) f(\theta_3 | \theta_1, \theta_2) f(\theta_4, \dots, \theta_n | \theta_1, \theta_2, \theta_3) \\ &= \dots = f(\theta_2 | \theta_1) f(\theta_3 | \theta_1, \theta_2) f(\theta_4 | \theta_1, \theta_2, \theta_3) \cdots f(\theta_n | \theta_1, \dots, \theta_{n-1}) \end{aligned}$$

Pero en la ecuación (5.5) el valor de θ_t depende solo del valor θ_{t-1} . Además,

$$f(\theta_t | \theta_1, \dots, \theta_{t-1}) = f(\theta_t | \theta_{t-1}), \quad \forall t = 2, \dots, n.$$

La función de verosimilitud condicionada es

$$L_C(\alpha, \omega, \kappa) = \{2\pi I_0(\kappa)\}^{-(n-1)} \exp \left\{ \kappa \sum_{t=2}^n \cos \left[\theta_t - \alpha - 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\} \right] \right\}$$

dando el logaritmo de la verosimilitud condicionada

$$l_C(\alpha, \omega, \kappa) = \text{const.} - (n-1) \log I_0(\kappa) + \kappa \sum_{t=2}^n \cos \left[\theta_t - \alpha - 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\} \right].$$

La cual es maximizada respecto los parámetros α y ω desconocidos

$$l_C(\alpha, \omega) = \sum_{t=2}^n \cos \left[\theta_t - \alpha - 2 \tan^{-1} \left\{ \omega \tan \frac{1}{2}(\theta_{t-1} - \alpha) \right\} \right]. \quad (5.8)$$

La maximización de (5.8) la haremos usando la función *nlm* de R. Esta función utiliza un algoritmo tipo Newton para minimizar una función dada. Por tanto hemos minimizado la función $-l_C(\alpha, \omega)$. Una vez que $l_C(\alpha, \omega)$ ha sido maximizada con respecto a α y ω , se obtiene una estimación de κ maximizando

$$l_C(\hat{\alpha}, \hat{\omega}, \kappa) = \text{const.} - (n-1) \log I_0(\kappa) + \kappa l_C(\hat{\alpha}, \hat{\omega}) \quad (5.9)$$

respecto de κ . Diferenciando (5.9) respecto de κ obtenemos

$$\frac{\partial}{\partial \kappa} [l_C(\hat{\alpha}, \hat{\omega}, \kappa)] = -(n-1) \frac{I_1(\kappa)}{I_0(\kappa)} + l_C(\hat{\alpha}, \hat{\omega}),$$

donde

$$I_1(\hat{\kappa}) = \frac{1}{2\pi} \int_0^{2\pi} e^{-i(n\theta - \hat{\kappa} \sin(\theta))} d\theta.$$

así que κ es la solución de

$$\frac{I_1(\hat{\kappa})}{I_0(\hat{\kappa})} = \frac{l_C(\hat{\alpha}, \hat{\omega})}{n-1}.$$

Capítulo 6

Análisis de Datos Medioambientales

[Análisis de Datos Medioambientales] En este capítulo, realizaremos un análisis exploratorio de la dirección de viento tomada en la estación meteorológica A Mourela durante el año 2010. Para ello realizaremos un análisis descriptivo de esta variable (ver Sección 5.2.) así como realizaremos una estimación no paramétrica tipo núcleo de la densidad (ver Sección 5.3.) y estimaremos el modelo de Möbius de series de tiempo (ver Sección 5.4.).

En la Sección 5.5 estudiaremos qué tipo de relación hay entre el SO_2 y la dirección de viento en las estaciones de medida automáticas B1, B2, C9, F2 Y G2, construyendo un modelo de regresión circular-lineal.

Cabe mencionar que tanto la estación meteorológica A Mourela como las estaciones de medida automáticas pertenecen al Sistema de Control Suplementario de la Contaminación Atmosférica de la U.P.T. de As Pontes propiedad de Endesa Generación S.A.

Por otra parte, notemos que para llevar a cabo este capítulo fue necesaria realizar una perturbación en los datos, descrita en la Sección 5.1. Por tanto, en este capítulo no vamos a trabajar con los datos minutales recogidos en la estación meteorológica y en las estaciones de medida automáticas B1, B2, C9, F2, G2; sino que vamos a trabajar con los datos horarios perturbados.

6.1. Datos Perturbados

Al analizar los datos obtenidos por los dispositivos de dirección se observó que había valores repetidos tanto en la dirección de viento como en las concentraciones de SO_2 . Esto puede ser debido a que estos dispositivos no son lo suficientemente precisos. La aparición de medidas repetidas va a ser un problema a la hora de implementar ciertas técnicas, como la validación-cruzada a la hora de seleccionar el parámetro de suavizado.

Con el fin de solucionar dicho problema, haremos una perturbación en ambas variables. La perturbación en el caso lineal, motivada por [1], nos lleva a una perturbación en las concentraciones de SO_2 dada por:

$$\tilde{X}_i = X_i + b\epsilon_i,$$

donde X_i denota los valores observados de SO_2 , $b = 1,03\hat{\sigma}n^{-1/3}$ y $\epsilon_i, i = 1, \dots, n$ son variables aleatorias independientes e idénticamente distribuidas siguiendo el núcleo de Epanechnikov en $(-\sqrt{5}, \sqrt{5})$; $\hat{\sigma}$ es un estimador robusto de la varianza, el cual puede ser obtenido usando el rango intercuartílico estandarizado. [1] muestra que esta elección de b para los datos perturbados permite una estimación consistente de la función de distribución, obteniendo un error cuadrático medio con la misma magnitud que el de la función empírica de distribución acumulada.

En el caso circular, la perturbación se realiza de forma similar al caso lineal. La muestra artificial de la dirección del viento es

$$\tilde{\theta}_i = \theta_i + d\epsilon_i,$$

donde θ_i denota los valores observados de la dirección de viento y $\epsilon_i, i = 1, \dots, n$ son variables aleatorias independientes generadas de la distribución von Mises con $\mu = 0$ y $\kappa = 1$. García-Portugués, Crujeiras y González-Manteiga (2011) escogieron $d = n^{-1/5}$ basándose en los resultados de Liu y Yang (2008) para la estimación tipo núcleo de la distribución multivariante. Esta perturbación resuelve el problema de los valores repetidos y no afecta a la estimación de la función de distribución subyacente.

6.2. Análisis de los datos de dirección de viento en A Mourela

En esta sección vamos a analizar los datos de viento recogidos durante el año 2010 por la estación meteorológica A Mourela situada en As Pontes (Figura 1.1), que van a ser usados en todo el capítulo excepto en la sección 5.4.

Esta estación recoge datos minutales pero trabajaremos con las medias horarias para reducir la gran cantidad de datos, aunque ésta sigue siendo elevada (8360). Con el objetivo de que los resultados sean más fáciles de visualizar, hemos dividido el año 2010 en cuatro periodos de 2090 datos (Tabla 6.1). Estos periodos son de tres meses el primero corresponde a los meses de enero, febrero, marzo; el segundo a los meses de abril, mayo, junio; el tercero a los meses de julio, agosto, septiembre y el cuarto a los meses de octubre, noviembre, diciembre.

En lo que se refiera a notación hay que decir que la dirección de viento va a tomar valores entre $[0, 2\pi)$ y cada valor representa el ángulo que forma respecto al Este. Por tanto, vamos a usar la siguiente codificación $0, \frac{\pi}{2}, \pi, \frac{3\pi}{2}$ representan las direcciones Este, Norte, Oeste y Sur, respectivamente.

En este análisis exploratorio de los datos, observamos que en el primer y el cuarto periodo del año 2010 la dirección media es la de Sureste y que la dirección media del segundo y tercer periodo del año 2010 es la de Noreste (Tabla 6.1).

	n	Media direccional	Medida de dispersión
Primer periodo	2090	5.3634	0.2177
Segundo periodo	2090	0.6446	0.2850
Tercer periodo	2090	0.2134	0.1750
Cuarto periodo	2090	5.7374	0.2952

Cuadro 6.1: Estudio de los datos de dirección de viento 2010 mediante una medida de localización (media direccional) y una medida de dispersión ($\bar{R}$)

Se observa que los datos están muy dispersos (Figuras 6.1, 6.2, 6.3, 6.4) lo que ya se podía deducir de la Tabla 6.1 donde se muestra que $\bar{R}$ es próxima a 0 en los cuatro periodos en los que hemos dividido el año.

Además, a la vista de los diagramas de rosa (Figura 6.5) podemos decir que la distribución de la dirección de viento en los 4 periodos en los que hemos dividido el año 2010 es prácticamente uniforme. Aunque, al realizar el test de uniformidad de Rao para las medias horarias de la dirección de viento en cada uno de los periodos; se obtiene que en ningún periodo las direcciones de viento siguen una distribución uniforme.




Figura 6.1: Gráfico de dispersión de las medias horarias de la dirección de viento correspondientes al primer periodo de 2010.




Figura 6.2: Gráfico de dispersión de las medias horarias de la dirección de viento correspondientes al segundo periodo de 2010.




Figura 6.3: Gráfico de dispersión de las medias horarias de la dirección de viento correspondientes al tercer periodo de 2010.




Figura 6.4: Gráfico de dispersión de las medias horarias de la dirección de viento correspondientes al cuarto periodo de 2010.




Figura 6.5: Diagrama de rosa de las medias horarias de la dirección de viento.

6.3. Estimación tipo núcleo de la función de densidad circular

En esta sección obtendremos la estimación no paramétrica tipo núcleo de la densidad circular (3.6) para cada uno de los cuatro periodos en los que hemos dividido el año 2010. Para ello hemos implementado tres diferentes elecciones del parámetro de suavizado; mediante el método plug-in (3.16), mediante el método de validación cruzada dada por la función de pérdida L2 (3.12) y mediante el método de validación cruzada dada por la función de pérdida Kullback-Leibler (3.14) para la correspondiente estimación no paramétrica tipo núcleo de la densidad circular en cada uno de los periodos en los que hemos dividido el año 2010.

Los parámetros de suavizado obtenidos (ver Tabla 6.2) mediante validación cruzada (3.12,3.14) toman valores del mismo orden pero más altos que los obtenidos mediante el método plug-in (3.16) en todos los periodos. En las estimaciones no paramétricas tipo núcleo de la densidad obtenidas seleccionando el parámetro de suavizado mediante la técnica plug-in van a ser más suaves que las dadas al seleccionar el parámetro de suavizado mediante validación cruzada.

	plug-in	L2	Kullback-Leibler
Primer periodo	3.10	28.56	26.20
Segundo periodo	4.87	63.57	77.17
Tercer periodo	2.17	41.44	36.17
Cuarto periodo	5.16	35.56	34.31

Cuadro 6.2: Estimaciones del parámetro de suavizado para la estimación no paramétrica tipo núcleo de la función de densidad circular.

En primer lugar, al representar las estimaciones no paramétricas tipo núcleo de la densidad circular seleccionando el parámetro de suavizado mediante plug-in en los cuatro periodos; se observa que estamos ante una situación de sobresuavizado (Figuras 6.6, 6.7, 6.8, 6.9) como ya apuntaban los valores obtenidos en la Tabla 6.2.

A continuación, estudiamos la estimación de la densidad circular seleccionando el parámetro de suavizado mediante validación cruzada. En todos los cuatro periodos del año de 2010 se obtuvo que tanto la validación cruzada para minimizar la función pérdida dada por error cuadrático medio (L2) como la dada por la función de pérdida de Kullback-Leibler (KL) alcanzan un mínimo en valores muy próximos (3.12, 3.14).

Observamos que estimando la función de densidad seleccionando el parámetro de suavizado mediante validación cruzada con cualquiera de las dos funciones de pérdida, anteriormente definidas, obtenemos prácticamente la misma estimación a lo largo de los cuatro periodos en los que hemos dividido el año 2010. En cambio, la estimación de la densidad seleccionando el parámetro de suavizado mediante plug-in, se obtiene una estimación sobresuavizada de la densidad circular (Figuras 6.6, 6.7, 6.8, 6.9).

En definitiva, para cada uno de los periodos nos quedamos con cualquiera de las dos estimaciones de la densidad circular obteniendo el parámetro de suavizado mediante la función de validación cruzada para minimizar la función pérdida dada por error cuadrático medio o la dada por la función de pérdida dada por Kullback-Leibler.




Figura 6.6: Estimación no paramétrica tipo núcleo de la función de densidad circular de las medias horarias de la dirección de viento correspondientes al primer periodo de 2010. Parámetro de suavizado obtenido mediante plug-in (violeta), mediante validación cruzada dada por la función de pérdida L2 (azul) y por la función de pérdida Kullback-Leibler (verde).




Figura 6.7: Estimación no paramétrica tipo núcleo de la función de densidad circular de las medias horarias de la dirección de viento correspondientes al segundo periodo de 2010. Parámetro de suavizado obtenido mediante plug-in (violeta), mediante validación cruzada dada por la función de pérdida L2 (azul) y por la función de pérdida Kullback-Leibler (verde).




Figura 6.8: Estimación no paramétrica tipo núcleo de la función de densidad circular de las medias horarias de la dirección de viento correspondientes al tercer periodo de 2010. Parámetro de suavizado obtenido mediante plug-in (violeta), mediante validación cruzada dada por la función de pérdida L2 (azul) y por la función de pérdida Kullback-Leibler (verde).




Figura 6.9: Estimación no paramétrica tipo núcleo de la función de densidad circular de las medias horarias de la dirección de viento correspondientes al cuarto periodo de 2010. Parámetro de suavizado obtenido mediante plug-in (violeta), mediante validación cruzada dada por la función de pérdida L2 (azul) y por la función de pérdida Kullback-Leibler (verde).

6.4. Estimación del modelo de Möbius de series de tiempo

En esta sección realizaremos la estimación del modelo de Möbius de series de tiempo (5.6) para los datos horarios perturbados de la dirección de viento recogida en la estación meteorológica A Mourela. Comenzamos esta sección realizando un estudio de la dependencia en los datos de dirección de viento. Para ello estudiamos el coeficiente de autocorrelación basado en la estimación de la correlación circular entre dos variables aleatorias Θ, Φ introducido por Fisher y Lee (1983).

$$\rho_T = \frac{\mathbf{E} [\sin(\Theta_1 - \Theta_2) \sin(\Phi_1 - \Phi_2)]}{\{\mathbf{E} [\sin^2(\Theta_1 - \Theta_2)] \mathbf{E} [\sin^2(\Phi_1 - \Phi_2)]\}^{1/2}}$$

En este caso, (Θ_1, Φ_1) y (Θ_2, Φ_2) son independientes e uniformemente distribuidas como (Θ, Φ) . El estimador de ρ_T que vamos a utilizar es

$$\hat{\rho}_T = \frac{\sum_{1 \leq i < j \leq n} \sin(\theta_i - \theta_j) \sin(\phi_i - \phi_j)}{\left[\sum_{1 \leq i < j \leq n} \sin^2(\theta_i - \theta_j) \sum_{1 \leq i < j \leq n} \sin^2(\phi_i - \phi_j) \right]^{1/2}}$$

y constituye la base para el cálculo del coeficiente de autocorrelación circular. Por conveniencia tomamos $\phi_i = \theta_{i+k}$, $i = 1, \dots, n-k$ luego tenemos $(n-k)$ pares

$$(\phi_1, \theta_1), (\phi_2, \theta_2), \dots, (\phi_{n-k}, \theta_{n-k})$$

Por tanto, podemos calcular la autocorrelación circular k-lag $\hat{\rho}_T^k$ como

$$\hat{\rho}_T^k = \frac{\sum_{1 \leq i < j \leq n-k} \sin(\theta_i - \theta_j) \sin(\phi_i - \phi_j)}{\left[\sum_{1 \leq i < j \leq n-k} \sin^2(\theta_i - \theta_j) \sum_{1 \leq i < j \leq n-k} \sin^2(\phi_i - \phi_j) \right]^{1/2}}$$

lo que es equivalente a

$$\hat{\rho}_T^k = \frac{\sum_{1 \leq i < j \leq n-k} \sin(\theta_i - \theta_j) \sin(\theta_{i+k} - \theta_{j+k})}{\left[\sum_{1 \leq i < j \leq n} \sin^2(\theta_i - \theta_j) \sum_{1 \leq i < j \leq n-k} \sin^2(\theta_{i+k} - \theta_{j+k}) \right]^{1/2}} \quad (6.1)$$

Por tanto, si representamos $\hat{\rho}_T^k$ frente a k obtendremos (Figuras 6.10, 6.12, 6.14, 6.16). En estos gráficos se observa que las medias horarias de las direcciones de viento correspondientes primer, segundo y cuarto periodo son muy dependientes, respectivamente. En cambio las medias horarias de las direcciones de viento en el tercer periodo presentan una dependencia no tan destacada.

Al construir el modelo de Möbius de series de tiempo (5.4) hemos tenido que estimar los parámetros α , ω , κ (Tabla 6.3) donde $\omega \in [-1, 1]$ y $-\pi < \alpha < \pi$. El modelo de series de tiempo obtenido en cada uno de los periodos modela bien nuestros datos de dirección de viento (Figuras 6.11, 6.13, 6.15, 6.4). De hecho si calculamos, el Error Cuadrático Medio mediante la distancia longitud de arco, que viene dado por

$$\frac{1}{n} \sum_{i=1}^n d(\theta_i, \hat{\theta}_i)^2 = \frac{1}{n} \sum_{i=1}^n (\pi - |\pi - |\theta_i - \hat{\theta}_i||)^2$$

donde

- θ_i , $i = 1, \dots, n$ corresponden a las medias horarias de la dirección de viento del periodo correspondiente.
- $\hat{\theta}_i$, $i = 1, \dots, n$ corresponden a las estimaciones dadas por modelo de Möbius de series de tiempo de las medias horarias de la dirección de viento del periodo correspondiente.
- d es la distancia entre dos ángulos definida por la longitud de arco.

Se obtiene el Error Cuadrático Medio en cada uno de los periodos es 0.237, 0.249, 0.252 y 0.247. Luego, las medias horarias de la dirección de viento difieren de las estimaciones dadas por modelo de Möbius de series de tiempo 0.25 radianes. Con el fin de entender mejor este resultado convertimos los errores cuadráticos medios en ángulos; 13.579, 14.317, 14.439 y 14.157. Por lo que podemos decir que las medias horarias de la dirección de viento distan de las estimaciones dadas por modelo de Möbius de series de tiempo 14 grados; lo que no es muy elevado.

Se debe tener en cuenta que las fuertes subidas y bajadas que presenta el modelo de Möbius de series de tiempo, en los cuatro periodos, son debidas a cuando pasamos de valores entorno al cero a valores entorno a 2π . Obviamente, en el entorno de datos circulares, ambos valores representan a la misma observación.

	α	ω	κ
Primer periodo	-0.7492	0.9634	4.12
Segundo periodo	0.5133	0.9296	4.09
Tercer periodo	-0.1431	0.9644	4.11
Cuarto periodo	-1.3190	0.9382	4.11

Cuadro 6.3: Estimaciones de los parámetros que están involucrados en la otención del modelo de Möbius de series de tiempo




Figura 6.10: Autocorrelaciones circulares de las medias horarias de la dirección de viento correspondientes al primer periodo de 2010.




Figura 6.11: Modelo de Möbius de series de tiempo de las medias horarias de la dirección de viento correspondientes al primer periodo de 2010.




Figura 6.12: Autocorrelaciones circulares de las medias horarias de la dirección de viento correspondientes al segundo periodo de 2010.




Figura 6.13: Modelo de Möbius de series de tiempo de las medias horarias de la dirección de viento correspondientes al segundo periodo de 2010.




Figura 6.14: Autocorrelaciones circulares de las medias horarias de la dirección de viento correspondientes al tercer periodo de 2010.




Figura 6.15: Modelo de Möbius de series de tiempo de las medias horarias de la dirección de viento correspondientes al tercer periodo de 2010.




Figura 6.16: Autocorrelaciones circulares de las medias horarias de la dirección de viento correspondientes al cuarto periodo de 2010.




Figura 6.17: Modelo de Möbius de series de tiempo de las medias horarias de la dirección de viento correspondientes al cuarto periodo de 2010

6.5. Estimación tipo núcleo de la función de regresión circular-lineal

En esta sección vamos a realizar la estimación de la regresión de las media horarias transformadas mediante la función logaritmo de las concentraciones de SO_2 frente a las direcciones horarias de viento en las 5 estaciones de medición automática, B1, B2, C9, F2 y G2. Estas cinco estaciones que pertenecen a la Red de Vigilancia y Control de la Calidad Atmosférica la cual forma parte del Sistema de Control Suplementario de la Contaminación Atmosférica propiedad de la U.P.T. de As Pontes.

En todas ellas se mide tanto la dirección de viento como las concentraciones de SO_2 , las utilizaremos para estudiar la relación entre las concentraciones de SO_2 y la dirección de viento mediante la estimación no paramétrica tipo núcleo de la función de regresión. Pues para realizar esta estimación necesitamos que tanto los datos de SO_2 y dirección de viento estén recogidos por la misma estación.

Comencemos analizando los valores que hemos obtenido para el parámetro de suavizado en la estimación de la función de regresión circular. En primer lugar, empleando validación cruzada de mínimos cuadrados (4.3) se han obtenido, en general, unos parámetros de suavizado razonables (Tabla 6.4).

	B1	B2	C9	F2	G2
Primer periodo	3.33	2.87	30.28	37.69	26.42
Segundo periodo	13.07	8.83	7.07	10.73	20.13
Tercer periodo	6.61	25.56	2.33	11.97	18.43
Cuarto periodo	0.00	22.63	4.87	11.24	17.74

Cuadro 6.4: Estimaciones del parámetro de suavizado obtenidas mediante validación cruzada

Por otra parte, hemos obtenido el parámetro de suavizado mediante la expresión dada por (4.2). En este caso los parámetros de suavizado obtenidos son muy variados (ver Tabla 6.5); es decir, obtenemos parámetros pequeños como el obtenido en el segundo periodo en la estación F2 y demasiado grandes como el obtenido durante el cuarto periodo en B1. De hecho, en el cuarto periodo en la estación B1 no somos capaces de obtener la estimación no paramétrica tipo núcleo de la densidad circular con un parámetro de suavizado tan grande (Figuras 6.24, 6.27, 6.30, 6.33, 6.36). Lo que parece que escoger el parámetro de suavizado mediante el método plug-in dado por (4.2), no es una buena elección.

	B1	B2	C9	F2	G2
Primer periodo	592.52	1.04	16.48	1329.96	0.76
Segundo periodo	28.55108	108.28	7.32	0.50	71.05
Tercer periodo	44.07	331.62	7.15	0.51	83.39
Cuarto periodo	48020.99	1.21	11.38	0.51	0.72

Cuadro 6.5: Estimaciones del parámetro de suavizado obtenidas mediante la expresión $\kappa = 1/h_s^2$

Observamos que las medias horarias de SO_2 transformadas mediante la función logaritmo están muy concentrados entorno al uno, es decir, que las medias horarias de SO_2 originales están concentradas entorno al 3 lo que se observa en las siguientes gráficas (Figuras 6.18, 6.19, 6.20, 6.21, 6.22).




Figura 6.18: Estimación no paramétrica tipo núcleo de la función de densidad de las medias horarias de las concentraciones de SO₂ correspondientes a la estación B1.




Figura 6.19: Estimación no paramétrica tipo núcleo de la función de densidad de las medias horarias de las concentraciones de SO₂ correspondientes a la estación B2.

6.5 ESTIMACIÓN TIPO NÚCLEO DE LA FUNCIÓN DE REGRESIÓN CIRCULAR-LINEAL49




Figura 6.20: Estimación no paramétrica tipo núcleo de la función de densidad de las medias horarias de las concentraciones de SO_2 correspondientes a la estación C9.




Figura 6.21: Estimación no paramétrica tipo núcleo de la función de densidad de las medias horarias de las concentraciones de SO_2 correspondientes a la estación F2.




Figura 6.22: Estimación no paramétrica tipo núcleo de la función de densidad de las medias horarias de las concentraciones de SO_2 correspondientes a la G2.

A continuación, presentamos la estimación no paramétrica tipo núcleo de la función regresión en cada una de las estaciones de medición automáticas.

En todos los casos, se observa que en todas las estaciones las estimaciones no dependen de la elección del parámetro de suavizado, es decir, las estimaciones dadas con el parámetro de suavizado obtenido mediante validación cruzada son mejores a las obtenidas seleccionando el parámetro de suavizado mediante la técnica plugin; pues describen mejor a los datos y la estimación dada por el parámetro obtenido mediante validación cruzada siempre existe mientras que la dada por el parámetro de suavizado obtenido mediante el método plug-in no (Figuras 6.24, 6.27, 6.30, 6.33, 6.36).

De todos modos, apuntemos que las estimaciones se ven muy afectadas debido a la gran cantidad de datos de SO_2 concentrados entorno al 3. Al ser las medias horarias transformadas de SO_2 tan bajas y tan concentradas la estimación no paramétrica tipo núcleo de la función de regresión no es capaz de seguir a los datos ya que estas observaciones tienen más peso que las demás. Por ello, no se puede apreciar si hay realmente relación entre la dirección de viento y las concentraciones de SO_2 .

Sin embargo, en la estación G2 durante el primer periodo del año 2010 (Figura 6.36) se observa que cuando el viento sopla del suroeste las concentraciones de SO_2 son más elevadas. Por lo que, en este caso, existe relación entre las medias horarias de las concentraciones de SO_2 y las medias horarias de la dirección de viento. Además podemos decir que las concentraciones de SO_2 pueden ser debidas a una fabrica de tableros DF que está situada al suroeste de G2.

Notemos que en este periodo las medias horarias de las concentraciones de SO_2 no están tan concentrados (Figura 6.22); las concentraciones las medias horarias transformadas de SO_2 toman valores entre 0.5 y 3.5. Luego las concentraciones las medias horarias de SO_2 toman valores entre 1 y 33, aproximadamente.

6.5.1. Estación B1




Figura 6.23: Validación cruzada en la estación B1.




Figura 6.24: Estimación de la función de regresión circular-lineal en B1. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

6.5 ESTIMACIÓN TIPO NÚCLEO DE LA FUNCIÓN DE REGRESIÓN CIRCULAR-LINEAL53




Figura 6.25: Estimación de la función de regresión circular-lineal en B1. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

6.5.2. Estación B2




Figura 6.26: Validación cruzada en la estación B2.




Figura 6.27: Estimación de la función de regresión circular-lineal en B2. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)




Figura 6.28: Estimación de la función de regresión circular-lineal en B2. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

6.5.3. Estación C9





Figura 6.29: Validación cruzada en la estación C9.

Figura 6.30: Estimación de la función de regresión circular-lineal en C9. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)




Figura 6.31: Estimación de la función de regresión circular-lineal en C9. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

6.5.4. Estación F2




Figura 6.32: Validación cruzada en la estación F2.

6.5 ESTIMACIÓN TIPO NÚCLEO DE LA FUNCIÓN DE REGRESIÓN CIRCULAR-LINEAL57




Figura 6.33: Estimación de la función de regresión circular-lineal en F2. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)




Figura 6.34: Estimación de la función de regresión circular-lineal en F2. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

6.5.5. Estación G2




Figura 6.35: Validación cruzada en la estación G2.




Figura 6.36: Estimación de la función de regresión circular-lineal en G2. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

6.5 ESTIMACIÓN TIPO NÚCLEO DE LA FUNCIÓN DE REGRESIÓN CIRCULAR-LINEAL59




Figura 6.37: Estimación de la función de regresión circular-lineal en G2. Elección del parámetro de suavizado mediante $1/h_s^2$ (violeta). Elección del parámetro de suavizado mediante validación cruzada (azul)

Capítulo 7

Software

- En este trabajo se han utilizado las siguientes librerías del software libre R:
 - circular
 - CircStats
 - MASS
 - rgl
- De lo estudiado en el Capítulo 2 se ha implementado:
 - El estimador no paramétrico tipo núcleo de la densidad circular (3.6).
 - Estimaciones del parámetro de suavizado mediante el método de validación cruzada dado por la función de pérdida dada por el error cuadrático medio (3.12) y el dado por función de pérdida dada por Kullback-Leibler (3.14).
 - Estimación del parámetro de suavizado mediante la regla plug-in con densidad de referencia von Mises (3.16).
- De lo estudiado en el Capítulo 3 se ha implementado:
 - El estimador no paramétrico tipo núcleo de la función de regresión circular-lineal (4.1).
 - Estimaciones del parámetro de suavizado mediante el método de validación cruzada (4.3).
 - Estimaciones del parámetro de suavizado mediante el método plug-in (4.2).

- De lo estudiado en el Capítulo 4 se ha implementado:
 - La estimación del modelo de Möbius de series de tiempo 5.6.
 - La estimación de los parámetros mediante máxima verosimilitud (5.8).

Además se ha implementado la estimación de la autocorrelación circular k-lag (6.1).

Bibliografía

- [1] A. Azzalini. A note on the estimation of a distribution function and quantiles by a kernel method. *Biometrika*, 68:326–328, 1981.
- [2] Panzera A. Di Marzio, M. and C.C. Taylor. Local polynomial regression for circular predictors. *Statistics and Probability Letters*, 79:2066–2075, 2009.
- [3] T. D. Downs and K. V. Mardia. Circular regression. *Biometrika*, 89:683–698, 2002.
- [4] N. Fisher and A. Lee. A correlation coefficient for circular data. *Biometrika*, 70:327–332, 1983.
- [5] Crujeiras R.M. González Manteiga W. García Portugués, E. Exploring with direction and so₂ concentration by circular-linear density estimation. Technical report, Universidade de Santiago de Compostela, Departamento de Estatística e Investigación Operativa., 2011.
- [6] X. Haiyong and F. P. Schoenberg. Kernel regression of directional data with application to wind and wildfire data in los angeles country, california. Department of Statistics, University of California, Los Angeles, CA 90095-1554, USA.
- [7] Watson G.S. Hall, P. and J. Cabrera. Kernel density estimation whith spherical data. *Biometrika*, 74:751–762, 1987.
- [8] G. Hughes. *Multivariate and Times Series Models for Circular Data with Applications to Protein Conformational Angles*. PhD thesis, The University of Leeds, Department of Statistics., 2007.
- [9] R. Liu and L. Yang. Kernel estimation of multivariate cumulative distribution function. *Journal of Nonparametric Statistics*, 20:661–667, 2008.
- [10] K.V. Mardia and P.E Jupp. *Directional Statistics*. Wiley; New York, 2000.
- [11] C.C. Taylor. Automatic bandwidth selection for circular density estimation. *Computational Statistics and Data Analysis*, 52:3493–3500, 2008.