

Usando distribuciones de referencia

Vemos que mediante el A-PISE que

$$h_0 = \left( \frac{\|K\|_2^2}{\|f''\|_2^2 (\mu_2(K))^2} \right)^{1/5}$$

con  $\mu_2(K) = \int U^2 K(U) dU$

En esta ecuación  $f''$  es desconocida pero el resto es conocido.

Podemos para realizar el cálculo suponer que  $f$  pertenece a una familia paramétrica y en ella intentar estimar  $\|f''\|_2^2$

Veamos un ejemplo, consideremos  $K$  el núcleo normal al cual notamos  $\phi$

Supongamos que  $f$  pertenece a la familia normal de media  $\mu$  y varianza  $\sigma^2$  desconocidos. Entonces

$$\|f''\|_2^2 = \sigma^{-5} \int (\phi''(x))^2 dx = \sigma^{-5} \underline{3} \approx 0,212 \sigma^{-4}$$

A partir de esto  $h_0 = \left( \frac{4}{3} \frac{\hat{\sigma}^2}{n} \right)^{1/5} \approx 1,06 \hat{\sigma} n^{-1/5}$

Otra manera es estimar  $f''$  mediante un método no paramétrico y luego ponerlo en la fórmula.

Validación cruzada

Hay 2 maneras a) V.C mediante máxima verosimilitud  
b) VC por mínimos cuadrados

a) Sea  $f_n(x)$  un estimador de  $f$  y consideremos la razón de verosimilitudes  $\frac{f(x)}{f_n(x)}$

Para una buena elección de  $h$  esta razón estará cerca de 1  
Podemos entonces decir que

$$E_* \left( \log \frac{f(x)}{f_n(x)} \right) = 0$$

Podemos definir la información de Kullback-Leibler mediante

mediante

$$d_{KL}(f, f_n) = \int \log\left(\frac{f}{f_n}\right)(x) f(x) dx$$

Entonces una buena idea es buscar  $h$  la cual minimiza  $d_{KL}(f, f_n)$ . No podemos calcularla pues no conocemos  $f$

Supongamos que son dadas un conjunto adicional de observaciones  $X_i$  independientes de las otras.

La verosimilitud de estas observaciones sería  $\prod_i f_n(x_i)$   
El valor de este estadístico para diferentes  $h$  puede indicar cual  $h$  es preferible dado que

$$d_{KL}(f, f_n) = \int \log f(x) f(x) dx - \int \log f_n(x) f(x) dx$$

• Si maximizando el log de la verosimilitud minimizamos  $d_{KL}$

Usualmente no agregamos observaciones adicionales  
Una forma de lidiar con esto es estimar  $f_n$  en el subconjunto  $\{X_j\}_{j \neq i}$  y calcular la verosimilitud para  $X_i$   
Notamos el estimador "leave-one-out" mediante

$$f_{n, i}(x_i) = \frac{1}{n-1} \sum_{j: j \neq i} K\left(\frac{x_i - x_j}{h}\right)$$

$$\prod_{i=1}^n f_{n,i}(x_i) = \frac{1}{(n-1)^n h^n} \prod_{i=1}^n \sum_{j \neq i} K\left(\frac{x_i - x_j}{h}\right)$$

Si tomamos el logaritmo y dividimos por  $n$  tenemos

$$\begin{aligned} CV_{KL}(h) &= n^{-1} \sum_{i=1}^n \log(\hat{f}_{n,i}(x_i)) = \\ &= n^{-1} \sum_{i=1}^n \log \left[ \sum_{j \neq i} K\left(\frac{x_i - x_j}{h}\right) \right] - \log[(n-1)h] \end{aligned}$$

y hallamos  $\hat{h}_{KL} = \underset{h}{\operatorname{argmax}} CV_{KL}(h)$

Si las  $X_i$  son i.i.d. entonces  $\log \hat{f}_{n,i}(x_i)$  son i.i.d. entonces

$$E(CV_{KL}(h)) = E(\log \hat{f}_{n,i}(x_i))$$

Sacando el efecto del "leave-one-out"

$$E(CV_{KL}(h)) \approx E\left(\int \log f_n(x) f(x) dx\right)$$

$$D \dots E(d_{\dots}(t, t_n)) = (d_{\dots}, d_{\dots}, \dots) E((0, 0, \dots, 0, 1, \dots))$$

$$\cdot \log f_n(x) - f(x) \cdot x$$

$$\text{o sea } E(CV_{KL}(h)) = -E(d_{KL}(f, f_n)) + \int \log f(x) f(x) dx$$

b) Definamos el error cuadrático integrado como

$$d_I(h) = \int (f_n - f)^2 dx = \underbrace{\int f_n^2(x) dx}_{\text{computable a partir de los datos}} - 2 \int (f_n f)(x) dx + \underbrace{\int f^2(x) dx}_{\text{no depende de } h}$$

entonces minimizar  $d_I(h)$  es equivalente a minimizar

$$\int f_n^2(x) dx - 2 \int f_n(x) f(x) dx$$

$$\text{Ahora } \int f(x) f(x) dx = E_x(f_n(x))$$

$$\text{Para estimar este término } E_x(\hat{f}_n(x)) = n^{-1} \sum_{i=1}^n f_{n,i}(x_i)$$

$$\text{Definimos } CV(h) = \int f_n^2(x) dx - \frac{2}{n} \sum_{i=1}^n f_{n,i}(x_i)$$

$$\hat{h}_{CV} = \underset{h}{\text{argmin}} CV(h)$$

Stone demostró en 1982 que si  $f$  es acotada  $\hat{h}_{CV}$  es

asintóticamente óptimo o sea

$$\frac{d_I(h_{CV})}{\inf_{h>0} d_I(h)} \xrightarrow{c.s} 1 \quad (n \rightarrow \infty)$$

Algoritmo

Para computar se muestra que

$$\int f_n^2(x) dx = n^{-2} h^{-1} \sum_{i=1}^n \sum_{j=1}^n K * K \left( \frac{x_j - x_i}{h} \right)$$

donde  $K * K(v)$  es la convolución del núcleo  $K$   
(dejar a cargo del lector)

$$CV(h) = n^{-2} h^{-1} \sum_{i=1}^n \sum_{j=1}^n \left( \frac{x_j - x_i}{h} \right) - \frac{2}{n} \sum_{i=1}^n f_{n,c}(x_i)$$

$$= \frac{2}{n^2 h} \left[ \frac{n}{2} K * K(0) + \sum_{i=1}^{n-1} \sum_{j=i+1}^n K * K \left( \frac{x_j - x_i}{h} \right) - \frac{2n}{n-1} K \left( \frac{x_j - x_i}{h} \right) \right]$$