

# **Estimación no-paramétrica**

**Máximo Camacho Alonso**

**Universidad de Murcia**

**[www.um.es/econometria/tecpre](http://www.um.es/econometria/tecpre)**

**[mcamacho@um.es](mailto:mcamacho@um.es)**

# Contenido del tema

- **Introducción: ventajas e inconvenientes**
- **Estimación función de densidad**
  - **Algunos tipos de estimación**
  - **Propiedades asintóticas**
  - **El papel del kernel**
  - **El papel de la ventana**
- **Estimación de funciones**
  - **Nadaraya-Watson**
  - **Predicción**

# 1. Introducción

- Estimación paramétrica
- Estimación no-paramétrica
- Ventajas
- Inconvenientes

# 1. Introducción

- Supongamos que
  - Disponemos de  $n$  observaciones de  $y$ ,  $x$ .
  - Pensamos

$$y_t = m(x_t) + e_t$$

- Deseamos estimar
  - Función de densidad de  $y$
  - La función  $m$

# 1. Introducción

## 1.1. Estimación paramétrica

- Supuesto 1:  $m$  es lineal  $y_t = a + bx_t + e_t$
- Supuesto 2:  $e \approx N(0, \sigma^2)$ 
  - Implica  $y_t / x_t \approx N(a + bx_t, \sigma^2)$
- Estimamos  $a, b, \sigma$

$$\hat{y}_t / x_t \approx N(\hat{a} + \hat{b}x_t, \sigma^2)$$

# 1. Introducción

## 1.2. Estimación no-paramétrica

- No exigimos a priori que
  - la densidad de  $y$
  - la función  $m$pertenezcan a una familia paramétrica
- Trataremos de estimarlas dejando que los datos “hablen por sí mismos”

# 1. Introducción

## 1.3. Ventajas

- Principio de parquedad
- Método flexible
  - ¿Qué método paramétrico?
- Fácil de implementar
- Evitamos el error al elegir
  - funciones de densidad erróneas
  - $m$  errónea

# 1. Introducción

## 1.4. Inconvenientes

- Muestras grandes
- Existen varios no-paramétricos
  - ¿Qué método usar?
- Resultados menos intuitivos
- Inferencia

## 2. Funciones de densidad

- Introducción
- Tipos de estimación no-paramétrica
  - Histograma
  - Kernel
  - Kernel adaptativa
  - “Vecino más cercano”
- Estimación kernel
  - Propiedades
  - Datos multivariantes

## 2. Estimación funciones densidad

### 2.1. Introducción

- Densidad univariante
- Ejemplo
  - Copas y Fryer (1980)
  - $y_t$  duración 86 pacientes tras suicidio
  - Nótese:
    - $y > 0$
    - $y$  suele ser pequeña

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

- Histograma
- Kernel: Rosenblatt (1956)
- Vecino más cercano: Loftsgaarcen y Quesenberry (1965)
- Kernel variable: Breiman, Meisel y Purcell (1977)

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 1. Histograma

- Sean:
  - Un punto de partida  $y_0$
  - Un radio  $h$
- Para cada natural  $m$  se define
  - La bola  $[ y_0+mh, y_0+(m+1)h )$ ,  $m = 0,1,2,\dots$


$$\hat{f}(y_i) = \frac{\#B_i}{nh}$$

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 1. Histograma

- $y_0 = -50$
- $h = 30$



## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 1. Histograma

- **Ventajas**
  - Fácil aplicación
- **Inconvenientes**
  - Depende de  $y_0$
  - Discontinuidades:  
no derivadas
  - Múltiples  
explicativas

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: definiciones

- Una función de densidad  $f(y)$  satisface:

1. 
$$\int_{-\infty}^{\infty} f(y) dy = 1$$

2.  $f(y) \geq 0$

- Una función kernel  $K(y)$  sólo satisface 1

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: estimador

- Definimos estimador kernel:

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


- Simplificamos: K es la normal estandarizada

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: intuición

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




## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: el papel de h

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



## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: kernel a examen

- **Ventajas: ciertos K**

- $\hat{f}(y)$  función densidad
- $\hat{f}(y)$  continua
- $\hat{f}(y)$  diferenciable

- **Inconvenientes**


- Elección de K, h
- h fija: problemas en distribuciones asimétricas

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: kernel a examen


$h=15$



## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 2. Estimación kernel: kernel a examen



## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

### 3. Estimación kernel adaptativa

- Definimos


$$\hat{f}(y) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h\lambda_i} K\left(\frac{y - y_i}{h\lambda_i}\right)$$

- $\lambda_i$  adapta la ventana a cada observación: resta peso a observaciones “aisladas”

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

### 3. Estimación kernel adaptativa



## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 4. Estimación “vecino más cercano”

- Consideremos:  $d(x,y) = |x - y|$
- Ordenamos:  $d_1(y) \leq d_2(y) \leq \dots \leq d_n(y)$   
 $d_n(y) =$  distancia entre ( observación más lejana a  $y$ ,  $y$  )


- Definimos 
$$\hat{f}(y) = \frac{1}{nd_k(y)} \sum_{i=1}^n K\left(\frac{y-y_i}{d_k(y)}\right) \quad k \sim n^{1/2}$$

- Ventana grande (curva suave) en obs. atípicas

## 2. Estimación funciones densidad

### 2.2. Tipos de estimación no-paramétrica

#### 4. Estimación “vecino más cercano”



## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 1. Supuestos adicionales

- $K$  simétrica

$$\int K(t) dt = 1$$

$$\int tK(t) dt = 0$$

$$\int t^2 K(t) dt = k_2 \neq 0$$

- $f$  derivadas continuas de cualquier orden

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 2. Error Cuadrático Medio: definición

$$\begin{aligned} \text{ECM} &= \int E \left( f(y) - \hat{f}(y) \right)^2 dy \\ &= \int \left\{ f(y) - E\hat{f}(y) \right\}^2 dy && \int (\text{sesgo})^2 dy \\ &+ \int E \left\{ \hat{f}(y) - E\hat{f}(y) \right\}^2 dy && \int (\text{varianza}) dy \end{aligned}$$

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 2. Error Cuadrático Medio: sesgo

$$\int (\text{sesgo})^2 dy$$

Aplicar propiedades de K  
Expansión de Taylor

$$\cong \frac{1}{4} h^4 (k_2)^2 \int f''(y)^2 dy$$

**(Aumenta con h)**

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 2. Error Cuadrático Medio: varianza

$\int$  varianza  $dy$

Aplicar propiedades de K  
Expansión de Taylor

$$\cong \frac{1}{nh} \int K(y)^2 dy$$

**(Disminuye con h)**

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

### 3. El papel de la ventana

- $h$ : aumenta sesgo y disminuye varianza
- $h_{\text{opt}} = (k_2)^{-2/5} \left( \int K(y)^2 dt \right)^{1/5} \left( \int f''(y)^2 dy \right)^{-1/5} n^{-1/5}$ 
  - minimiza el ECM
  - pequeña para
    - $n$  grande
    - densidades fluctuación rápida
- $h_{\text{Nopt}} = 1.06 \sigma n^{-1/5}$

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 4. El papel del Kernel

$$ECM_{opt} = g(n, f'', \int K(y)^2 dy)$$

- Es mínimo para Epanechnikov (Ke)
- Compararemos ECM de otras Kernel con Ke para analizar eficiencia relativa

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 4. El papel del Kernel

Kernel	K(t)	Eficiencia
Epanechnikov	$\begin{cases} \frac{3}{4} \left( 1 - \frac{1}{5} y^2 \right) / \sqrt{5} &  y  < \sqrt{5} \\ 0 & \text{resto} \end{cases}$	1
Gausiana	$1 / \sqrt{2\pi} \exp((1/2)y^2)$	0.95
Rectangular	$1/2 \text{ para }  y  < 1, \text{ y } 0 \text{ resto}$	0.93

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 4. Elección de $h$

- Validación cruzada máximo verosímil
- $h$  tal que maximiza

$$VCMV(h) = \frac{1}{n} \sum_{i=1}^n \log \hat{f}_{-i}(y_i)$$

- Buscando entre  $(1/4 h_{\text{Nopt}}, 3/2 h_{\text{Nopt}})$

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 5. Propiedades asintóticas

- Consistencia puntual. Bajo  $f$  continua y:

$$- \int |K(y)| dy < \infty, \int K(y)dy = 1$$

$$- |y K(y)| \rightarrow 0 \quad \text{si } |y| \rightarrow \infty$$

$$- h_n \rightarrow 0 \quad \text{y} \quad nh_n \rightarrow \infty \quad \text{si } n \rightarrow \infty$$

entonces

$$\hat{f}(y) \xrightarrow{p} f(y)$$

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

### 5. Propiedades asintóticas

- Consistencia funcional.
  - Bajo los supuestos anteriores
  - K no negativa

entonces, con probabilidad 1:

$$\int |\hat{f}(y) - f(y)| dy \rightarrow 0$$

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 6. Datos multivariantes

- Suponemos  $Y_i$  vector d-dimensional

- Definición

$$\hat{f}(Y) = \frac{1}{nh^d} \sum_{i=1}^n \underline{K}\left(\frac{1}{h}(Y - Y_i)\right)$$

- Ejemplo: si el Kernel es gaussiano

$$\underline{K}(Y) = (2\pi)^{-d/2} \exp(-1/2Y'Y)$$

## 2. Estimación funciones densidad

### 2.3. Estimación Kernel

#### 6. Datos multivariantes: consideraciones

- Gran importancia de las colas
- $n$  grande. Ej.: para asegurar  $ECM(y = 0) < 0.1$ 
  - $d = 3 \dots n > 67$
  - $d = 5 \dots n > 770$
  - $d = 10 \dots n > 850.000$

# 3. Estimación de funciones

- **Introducción**
- **Nadaraya-Watson**
  - Estimación
  - Propiedades asintóticas
- **“Vecino más cercano”**
- **Muchas variables explicativas**
- **Predicción**

# 3. Estimación de funciones

## 3.1. Introducción

- Disponemos  $\{y_t, x_t\} \quad i=1, \dots, n$
- Suponemos  $y_t = m(x_t) + e_t$
- Tratamos de estimar  $m(x)$  sin hacer ningún supuesto previo sobre la naturaleza de  $m$

## 3. Estimación de funciones

### 3.2. Nadaraya-Watson : estimador

- Si  $E(e / x) = 0$
- $m(x) = E(y / x) = \int y f(y / x) dy$   
 $= \int y f(y, x) / f(x) dy$
- El estimador natural de
  - $f(x)$  es  $K(x)$
  - $f(y, x) = \underline{K}(y, x)$

# 3. Estimación de funciones

## 3. 2. Nadaraya-Watson: estimador

- Bajo los supuestos  $\underline{K}$ 
  - Media 0:  $\int y \underline{K}(y, x) dy = 0$
  - Marginalizable:  $\int \underline{K}(y, x) dy = K(x)$
- Nadaraya y Watson (1964)

$$\hat{m}(x) = \frac{\sum K\left(\frac{x - x_i}{h}\right) y_i}{\sum K\left(\frac{x - x_i}{h}\right)} = \sum w(x_i) y_i$$

# 3. Estimación de funciones

## 3. 2. Nadaraya-Watson: propiedades asintóticas

- Si  $K$  satiface
  - $\int |K(u)| du < \infty$
  - $\lim_{|u| \rightarrow \infty} u K(u) = 0$ , cuando  $|u| \rightarrow \infty$
- $m(x)$ ,  $f(x)$ ,  $\sigma^2(x)$  continuas en  $x$
- $f(x) > 0$

entonces

$$\hat{m}(x) \xrightarrow{p} m(x)$$

si

$$h \rightarrow 0$$

$$nh \xrightarrow{n \rightarrow \infty} \infty$$

### 3. Estimación de funciones

#### 3. 2. Nadaraya-Watson: ECM

$$\begin{aligned} \text{ECM} &= \int E(m(x) - \hat{m}(x))^2 dy \\ &= \int (\text{sesgo})^2 dy + \int \text{varianza} dy \\ &= h^4 B^2(x) + n^{-1} h^{-1} V(x) \end{aligned}$$


donde  $B^2(x)$  y  $V(x)$  dependen de:

$m$ ,  $f$  y  $\text{var}(x)$

# 3. Estimación de funciones

## 3. 2. Nadaraya-Watson: papel de h

Serie: tasa crecimiento US GDP 1947.2-2000.3



$h = 0.01$


— Serie real

— Serie estimada

# 3. Estimación de funciones

## 3. 2. Nadaraya-Watson: papel de h

Serie: tasa crecimiento US GDP 1947.2-2000.3



$h = 2$

— Serie real

— Serie estimada

# 3. Estimación de funciones

## 3. 2. Nadaraya-Watson: elección de h

- Härdle y Vieu (1990)
- Para series temporales: validación cruzada
- h que minimiza

$$CV(h) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{m}_i(x_i))^2$$

$$\text{con } \hat{m}_i(x_i) = \frac{1}{n-1} \sum_{j \neq i} y_j w(x_j)$$

## 3. Estimación de funciones

### 3.3. Estimación vecino más cercano

$$\hat{m}(x) = n^{-1} \sum w_{ki}(x) y_i$$

donde  $w_{ki}(x) = n / k$  si  $x_i$  es una de las  $k$  observaciones más cercanas a  $x$  (0 en otro caso)

- Efectos de  $k$ 
  - $k \geq n \Rightarrow$  serie estimada = media de  $y$
  - $k = 1 \Rightarrow$  serie estimada = serie real

## 3. Estimación de funciones

### 3.3. Estimación vecino más cercano

- Ejemplo. Queremos  $m(4)$  con  $k = 3$  en:

x	1	2	3	4	5
y	2	4	5	5	6
w	0	0	1/3	1/3	1/3

- $m(4) = (5+5+6)/3$

# 3. Estimación funciones

## 3.4. Datos multivariantes

- $\uparrow$  variables explicativas  $\Rightarrow \uparrow \uparrow n$
- Reducción de la dimensión  $d \rightarrow d' \leq 5$ 
  - Projection Pursuit  
(eliminar las que más disminuyan la varianza)
  - Análisis de componentes informativos  
(eliminar las que menos aumentan el sesgo)

# 3. Estimación funciones

## 3.5. Predicción

- Ver comentarios de predicción en STAR
- Sólo a título orientativo, supongamos

- $Y_1, Y_2, \dots, Y_n$

- $y_t = m(y_{t-1}) + e_t$

- Para predecir:

- Estimamos  $m$  con información hasta  $n$

- Predecimos :  $\hat{y}_{n+1} = \hat{m}(y_n)$

- $\hat{y}_{n+2} = \hat{m}(\hat{y}_{n+1})$

- $\hat{y}_{n+3} = \hat{m}(\hat{y}_{n+2}) \dots$