

# Estimación de función de densidad

Gabriel Montes-Rojas

# Histogramas

- Supongamos  $\{x_i\}_{i=1}^n$  una muestra aleatoria de la variable aleatoria  $X$  con dominio en  $\mathcal{X}$ .
- Si  $X$  es una variable aleatoria **discreta**<sup>1</sup> la densidad o probabilidad se puede estimar como

$$\hat{f}(x) = \frac{\sum_i 1\{x_i = x\}}{n},$$

para todo  $x$  en  $\mathcal{X}$ . Esto es un estimador de frecuencias o proporción tal que  $\sum_{x \in \mathcal{X}} \hat{f}(x) = 1$ .

- Se puede probar que  $\hat{f}(x) \xrightarrow{P} f(x)$  y  $\sqrt{n}(\hat{f}(x) - f(x)) \xrightarrow{d} \text{Normal}(0, f(x)(1 - f(x)))$  cuando  $n \rightarrow \infty$ .

---

<sup>1</sup>Una variable aleatoria es discreta si su dominio es un conjunto contable, finita o infinita.

# Histogramas

- Si  $X$  es una variable aleatoria **continua** con dominio en  $\mathcal{X}$  entonces debemos considerar intervalos que cubran el dominio de  $\mathcal{X}$ , que por ahora lo asumimos acotado. Sea  $M$  el número de intervalos (bins), indexado por  $m$ , cada uno con el mismo **ancho de banda** (bandwidth)  $h$ . Entonces tenemos intervalos de forma

$$[x_m - h/2, x_m + h/2), \quad m = 1, 2, \dots, M$$


$$x_1 < x_2 < \dots < x_m < \dots < x_M, \quad x_m + h/2 = x_{m+1} - h/2$$

Definimos entonces el estimador de histograma,

$$\hat{f}(x) = \frac{\sum_{i=1}^n \mathbf{1}[x_i \text{ en intervalo que contiene } x]}{nh}.$$

# Histogramas

- Notar que  $h \times \hat{f}(x) \xrightarrow{P} P[x - h/2 \leq X < x + h/2]$ , cuando  $n \rightarrow \infty$ . También  $P[x - h/2 \leq X < x + h/2] = \int_{x-h/2}^{x+h/2} f(z) dz$  que es la probabilidad del intervalo.
- Entonces  $\hat{f}(x) \approx \frac{1}{h} \int_{x-h/2}^{x+h/2} f(z) dz \approx f(x)$  es un estimador de la densidad promedio en el intervalo, que es igual a  $f(x)$  cuando  $h \rightarrow 0$ .
- ¿Cómo elegir  $h$  óptimamente?
- Si  $h \rightarrow 0$ ,  $\hat{f}(x)$  es la proporción de observaciones con  $x$ . El resultado va a tener muchos saltos y ceros.
- Si  $h \rightarrow \infty$ ,  $\hat{f}(x) = 1, \forall x$ . Demasiada suavización.

Histogramas  $h_2 < h_1$ 

# Kernel

Un kernel  $K$  es una función simétrica tal que:

- 1  $\int K(\psi)d\psi = 1;$
- 2  $\int \psi K(\psi)d\psi = 0;$
- 3  $\int \psi^2 K(\psi)d\psi = \mu_2 < \infty.$

Nota 1: A menos que se especifique lo contrario (ej. si el dominio de  $\mathcal{X}$  es acotado con bordes conocidos), los límites de la integración son  $(-\infty, \infty)$ .

Nota 2: En general  $K(\psi) \geq 0, \forall \psi$ , con lo que se puede asociar a una función de densidad (ej. normal). Sin embargo se pueden considerar kernels de orden alto donde puede haber valores negativos.

# Estimación de densidad por kernel

Sea  $h$  el ancho de banda (bandwidth). Sea  $x$  un valor particular donde queremos estimar  $f(x)$ .

El estimador de densidad de kernel es  $\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x_i - x}{h}\right)$ .

Nota 1: Si  $\phi(x)$  es la función de densidad de una normal  $\psi \sim N(0, 1)$ , entonces  $\psi \sim N(\mu, \sigma^2)$  tiene función de densidad  $\frac{1}{\sigma} \phi\left(\frac{x - \mu}{\sigma}\right)$ . Así  $h$  se asocia al desvío estándar. Notar que aplica también a los histogramas.

Nota 2:  $\hat{f}_h(x) = \frac{1}{n} \sum_{i=1}^n w_i$  donde  $w_i = \frac{1}{h} K\left(\frac{x_i - x}{h}\right)$ .

- En la práctica, estimamos la densidad de  $x$  para todo el dominio,  $\mathcal{X}$ .
- Consideremos una grilla  $X = [x_1, x_2, \dots, x_M]$ , donde  $\#X = M$  puntos en los cuales vamos a estimar la densidad.
- Entonces, una estimación de la densidad es el gráfico  $\{\hat{f}_h(x(m)), x(m)\}_{m=1}^M$ .
- Podríamos tener anchos de banda diferentes  $h(x(m))$ . En general deberíamos tener más ancho de banda para regiones con menor densidad.

## Kernels

Kernel	Formula	
Biweight	$K[z] = \begin{cases} \frac{15}{16}(1 - z^2)^2 \\ 0 \end{cases}$	if $ z  < 1$ otherwise
Cosine	$K[z] = \begin{cases} 1 + \cos(2\pi z) \\ 0 \end{cases}$	if $ z  < 1/2$ otherwise
Epanechnikov	$K[z] = \begin{cases} \frac{3}{4}(1 - \frac{1}{5}z^2)/\sqrt{5} \\ 0 \end{cases}$	if $ z  < \sqrt{5}$ otherwise
Epan2	$K[z] = \begin{cases} \frac{3}{4}(1 - z^2) \\ 0 \end{cases}$	if $ z  < 1$ otherwise
Gaussian	$K[z] = \frac{1}{\sqrt{2\pi}}e^{-z^2/2}$	
Parzen	$K[z] = \begin{cases} \frac{4}{3} - 8z^2 + 8 z ^3 \\ 8(1 -  z )^3/3 \\ 0 \end{cases}$	if $ z  \leq 1/2$ if $1/2 <  z  \leq 1$ otherwise
Rectangular	$K[z] = \begin{cases} 1/2 \\ 0 \end{cases}$	if $ z  < 1$ otherwise
Triangular	$K[z] = \begin{cases} 1 -  z  \\ 0 \end{cases}$	if $ z  < 1$ otherwise



# Supuestos

- A1. Las observaciones  $x_1, x_2, \dots, x_n$  son iid.
- A2. El kernel  $K$  cumple con las propiedades de arriba.
- A3. Las derivadas de segundo orden de  $f$  son continuas y acotadas en un vecindario de  $x$ .
- A4.  $h = h_n \rightarrow 0$  cuando  $n \rightarrow \infty$ .
- A5.  $nh_n \rightarrow \infty$  cuando  $n \rightarrow \infty$ .

## Propiedades asintóticas

- Definamos el error cuadrático medio (mean squared error, MSE):

$$MSE(x) = E[(\hat{f}_h(x) - f(x))^2] = \text{Var}(\hat{f}_h(x)) + (\text{Sesgo}(\hat{f}_h(x)))^2,$$

donde  $\text{Sesgo}(\hat{f}_h(x)) = E[\hat{f}_h(x) - f(x)]$ .

- Siguiendo a Pagan&Ullah pp.23-24:

$$\text{Sesgo}(\hat{f}_h(x)) \approx \frac{h^2}{2} f''(x) \mu_2$$

$$\text{Var}(\hat{f}_h(x)) \approx \frac{f(x)}{nh} \int K(\psi)^2 d\psi$$

- Notar que para un estimador consistente de  $f(x)$  se debe cumplir  $MSE \rightarrow 0$  cuando  $n \rightarrow \infty$ , y tenemos un trade-off entre sesgo y varianza:
  - $h \rightarrow 0$  cuando  $n \rightarrow \infty$  para reducir el sesgo.
  - Pero necesitamos que  $nh \rightarrow \infty$ , o sea,  $n$  debe crecer más rápido que  $h$  reducirse para eliminar la varianza.

# Propiedades asintóticas

## Pruebas del sesgo y varianza

- Notar que con los supuestos,  $w_i = \frac{1}{h}K\left(\frac{x_i-x}{h}\right)$  también forma una muestra aleatoria iid con  $E(w_i) = E(w_1)$ ,  $V(w_i) = V(w_1)$ ,  $Cov(w_i, w_j) = 0$ ,  $i \neq j$ .
- Sesgo.  $E\hat{f} = \frac{1}{n} \sum_{i=1}^n Ew_i = Ew_1$   
 $= h^{-1}E\left[K\left(\frac{x_1-x}{h}\right)\right] = h^{-1} \int K\left(\frac{x_1-x}{h}\right) f(x_1)dx_1$ . Ahora haciendo cambio de variables  $= \int K(\psi)f(h\psi + x)d\psi$ . Entonces el sesgo es  $E\hat{f} - f = \int K(\psi)(f(h\psi + x) - f(x))d\psi$ .
- Ahora tomemos la siguiente expansión de Taylor  $f(h\psi + x) = f(x) + h\psi f'(x) + \frac{h^2\psi^2}{2} f''(x) + \dots$
- Si lo aplicamos al sesgo, obtenemos  $Sesgo(\hat{f}_h(x)) = \frac{h^2}{2} f''(x)\mu_2 + o(h^2)$ .
- Ahora calculemos la varianza.  $V\hat{f} = n^{-1}Vw_1 = n^{-1}Ew_1^2 - n^{-1}(Ew_1)^2$ . Por un lado  $E\hat{f}^2 = n^{-1}Ew_1^2 = (nh^2)^{-1}EK(\psi)^2 =$   
 $(nh)^{-1} \int K(\psi)^2 \left\{ f(x) + h\psi f'(x) + \frac{h^2\psi^2}{2} f''(x) + \dots \right\} d\psi =$   
 $(nh)^{-1}f(x) \int K(\psi)^2 d\psi + o((nh)^{-1})$ . Entonces,  
 $V\hat{f} = (nh)^{-1}f(x) \int K(\psi)^2 d\psi + o((nh)^{-1}) + o(n^{-1})$ .  
 Notar que necesitamos que  $E[w_1^2] < \infty$  lo que implica  $E[w_1] < \infty$ .

# Propiedades asintóticas

## MISE

- Dado que nos interesa la densidad en todo el dominio  $\mathcal{X}$ , debemos considerar el MSE integrado (mean integrated squared error, MISE):

$$MISE = \int_{\mathcal{X}} MSE(x) dx = \frac{1}{nh} \int K(\psi)^2 d\psi + \mu_2^2 \frac{h^4}{4} \int_{\mathcal{X}} (f''(x))^2 dx$$

- Tomemos derivadas con respecto a  $h$ , para obtener

$$h_{opt} = \left( \int K(\psi)^2 d\psi \right)^{1/5} \mu_2^{-2/5} \left( \int_{\mathcal{X}} (f''(x))^2 dx \right)^{-1/5} n^{-1/5}$$

Esto es,  $h$  debería ir a 0 a tasa  $-1/5$  con respecto a  $n$ . Así debemos considerar  $h_n$ , como una función de  $n$ .

- Esto significa que la **tasa de convergencia** es  $O_p(n^{-2/5})$  lo que nos da una tasa más *lenta* que la estimación paramétrica de  $f(x)$ ,  $O_p(n^{-1/2})$ , o sea  $\sqrt{n}$ -consistencia. Para obtener esto tenemos que calcular  $\frac{1}{\sqrt{nh}}$  que es la tasa que se aplica a la sumatoria para estandarizar la varianza.
- Por otro lado  $MISE = \max((nh)^{-1}, h^4) = O(n^{-4/5})$ .

# Estimación de densidad por kernel

- La parte más importante de los estimadores no paramétricos es seleccionar  $h$ .
- Si  $h \rightarrow 0$ , entonces **no hay suavización**. La densidad va a tener muchos saltos y ceros.
- Si  $h \rightarrow \infty$ , entonces **hay demasiado suavizamiento**.
- Notar que para  $h_{opt}$  necesitamos
  - $\int K(\psi)^2 d\psi$ . Depende del kernel.
  - $\mu_2 = \int \psi^2 K(\psi) d\psi$ . Depende del kernel.
  - $\int_{\mathcal{X}} f''(x) dx$ . Depende de  $f$  que no es conocida.

## Selección de ancho de banda

- **Rule-of-thumb:** Usar la distribución normal estándar  $\int_{\mathcal{X}} (f''(x))^2 dx = \frac{3}{8\sqrt{\pi}\sigma^5}$ . Por otro lado, supongamos también que  $K$  es el kernel gaussiano. Entonces,

$$\hat{h}_{opt} = 1.059\hat{\sigma}n^{-1/5}, \text{ con } \hat{\sigma} = \sqrt{\frac{1}{n} \sum_i (x_i - \bar{x})^2}$$

- Silverman (1986) propone  $h = 0.79Rn^{-1/5}$  y  $h = 0.9An^{-1/5}$  donde  $R$  es el rango intercuartiles y  $A = \min(\sigma, R/1.34)$ . Esto es lo que usa STATA.
- **Plug-in:** Usar un estimador de  $f$ , luego computar  $f''$  y re-estimar.
- **Cross-validation:** Ver Pagan&Ullah pp.50-52.
- Usar la intuición! **La econometría no paramétrica es un arte.**

# Otras propiedades asintóticas

## Normalidad asintótica

- Si a los supuestos A1-A5 le agregamos A15.  $(nh)^{1/2}h^2 \rightarrow 0$  cuando  $n \rightarrow \infty$ , entonces

$$(nh)^{1/2}(\hat{f} - f) \xrightarrow{d} \text{Normal} \left( 0, f \int K^2(\psi) d\psi \right).$$

- Para armar los intervalos de confianza al nivel de significatividad  $1 - \alpha$ :

$$\hat{f} \pm Z_{1-\alpha/2}(nh)^{-1/2} \left[ \hat{f} \int K^2(\psi) d\psi \right]^{1/2},$$

donde  $\Phi(Z_{1-\alpha/2}) = 1 - \alpha/2$ .

# STATA

- Histogramas `hist`:  
[www.stata.com/manuals13/rhistogram.pdf](http://www.stata.com/manuals13/rhistogram.pdf)
- Kernel `kdensity`:  
[www.stata.com/manuals13/rkdensity.pdf](http://www.stata.com/manuals13/rkdensity.pdf)



# Referencias

- Pagan, A. and Ullah, A. (1999), *Nonparametric Econometrics*. Cambridge: Cambridge University Press.
- Racine, J. (2008), "Nonparametric Econometrics: A Primer", *Foundations and Trends in Econometrics*, 3(1), 1-88.