

# Métodos no paramétricos en Stata

Eduardo García Echeverri

Webinar de Stata, 2023

# Agenda

- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

## ¿Qué es un método no paramétrico?

Método de estimación que no presupone:

- **Densidad de probabilidad** para el outcome y los regresores.
- **Forma funcional** relacionando el outcome y los regresores.

Un **método paramétrico**, requiere de estos dos supuestos.

## Ejemplo

¿Cuál es el efecto de **fumar durante el embarazo** (msmoke) en el **peso del bebé** al nacer (bweight)?

- **Paramétrico:**

$$\text{bweight} = \beta_0 + \beta_1 \text{msmoke} + \gamma \text{Controles} + \varepsilon$$

$$\varepsilon \sim N(0, \sigma^2)$$

- **No Paramétrico:**

$$\text{bweight} = g(\text{msmoke}, \text{Controles}) + \varepsilon$$

$$\mathbb{E}[\varepsilon | \text{msmoke}, \text{Controles}] = 0$$

# El Atractivo de los Métodos No Paramétricos

## Ventajas:

1. Evitan problemas causados por **mala especificación**.
2. Mejoran predicciones.
3. Conocer la forma funcional no es necesario para responder nuestras preguntas de investigación.
4. Fáciles de implementar en Stata.

## Desventajas:

1. Intensivos en datos (esp. con muchos regresores)
2. Computacionalmente costosos.

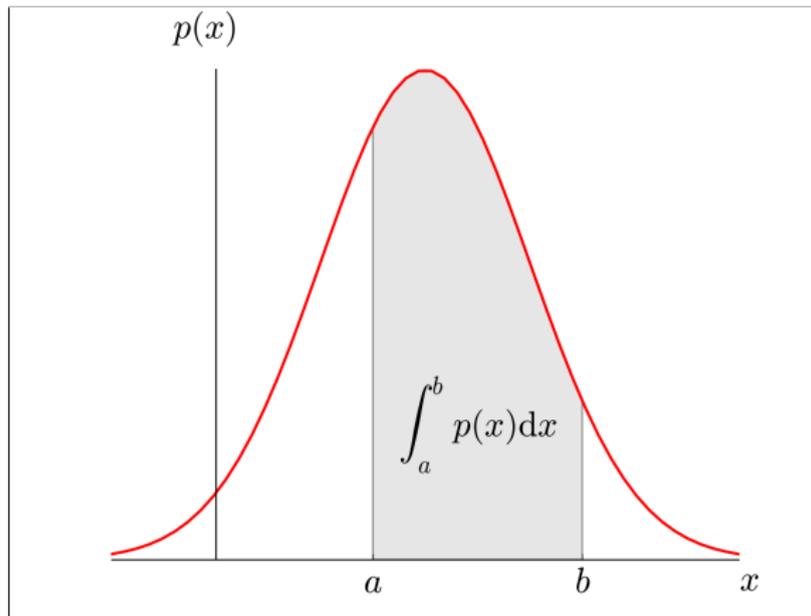
- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

# Agenda

- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

# ¿Qué es una densidad de probabilidad?

Nos muestra la **distribución de una variable aleatoria**.



## ¿Por qué son útiles?

La **densidad de probabilidad** nos muestra:

1. Qué valores son **probables/improbables**.
2. La **moda(s)** de la distribución (**picos** de la densidad)
3. El **rango** de valores que toma la variable
4. Probabilidad de **eventos extremos** (colas de la distribución)

## Estimación paramétrica de densidades

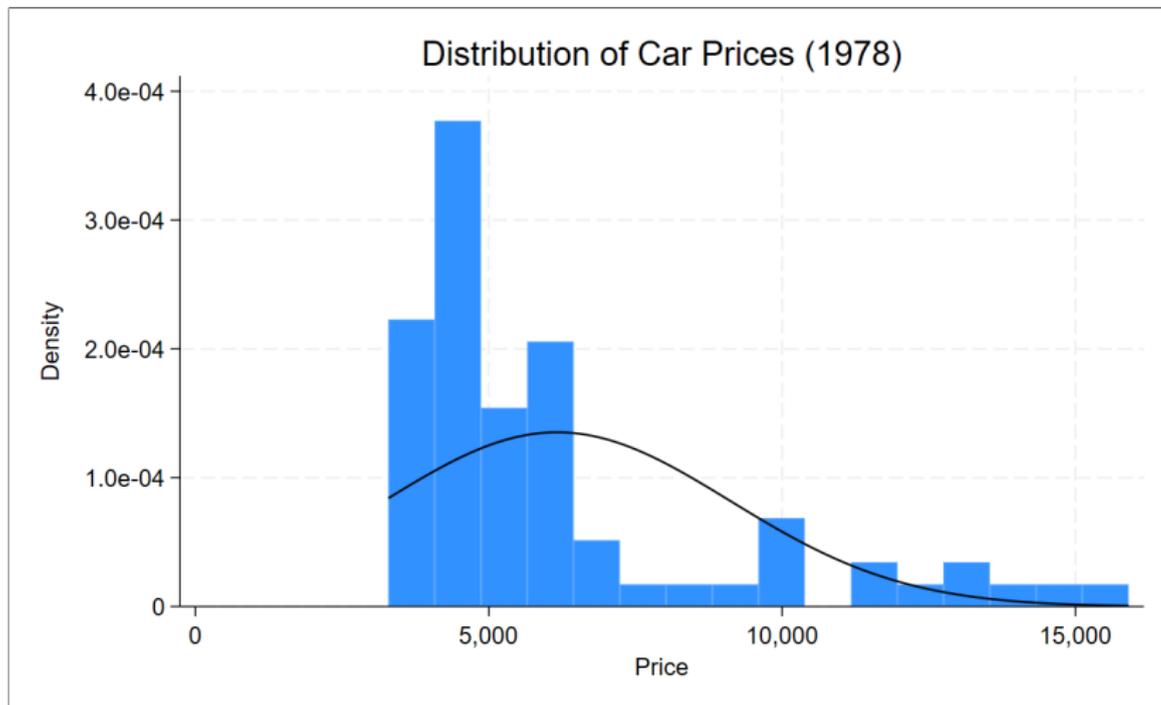
Primero, se especifica un tipo de densidad de probabilidad:

1. **Normal** (más común)
2. Log-normal
3. ...

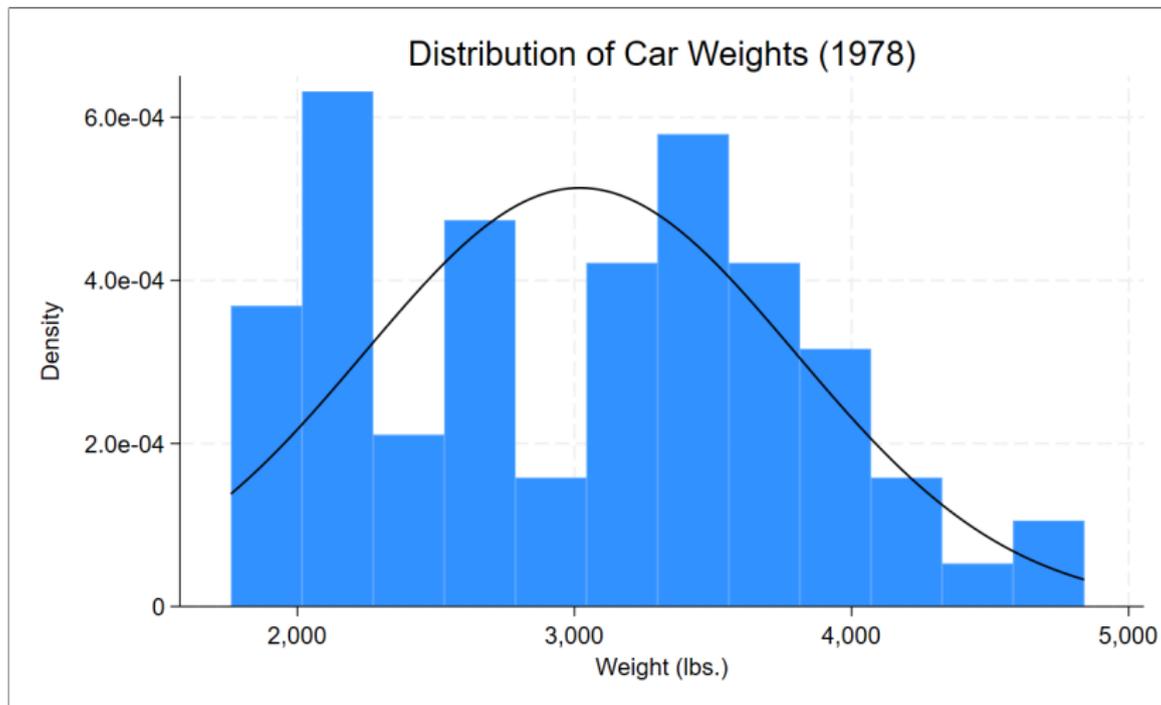
Segundo, basados en la **media y varianza muestral**, se **estima** la densidad que **mejor encaje en los datos**.

**Problema:** mala especificación. La normal puede ser una mala aproximación.

# Normalidad puede no cumplirse – larga cola derecha



# Normalidad puede no cumplirse – múltiples modas



## Estimadores Kernel para densidades

Estos estimadores **no presuponen un tipo de distribución**.

Para estimar la **densidad** en el punto  $x$ :

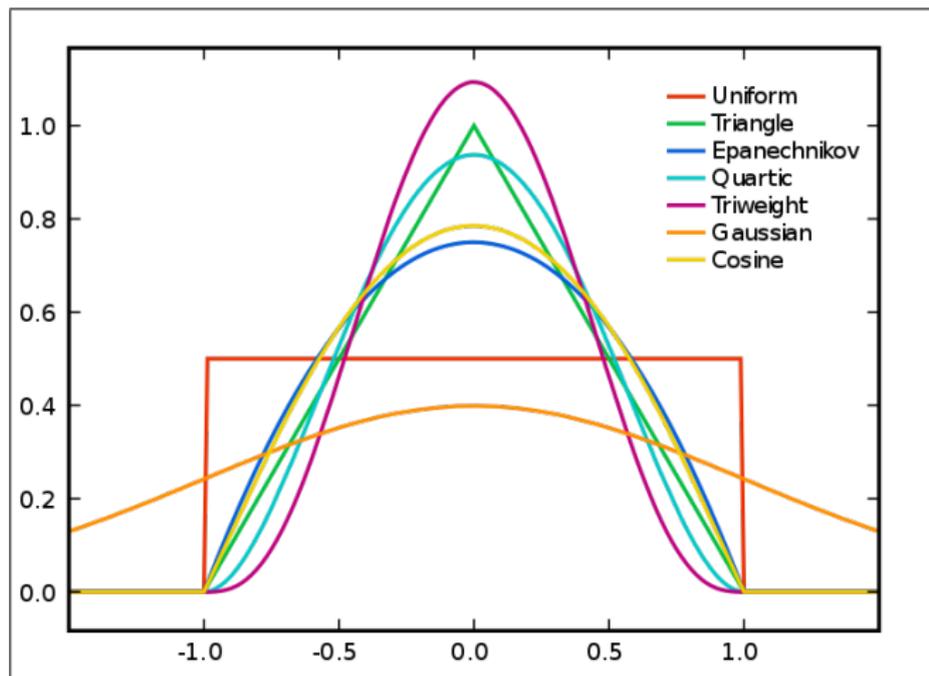
- **“Contamos”** cuántas observaciones son cercanas a  $x$ ,

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

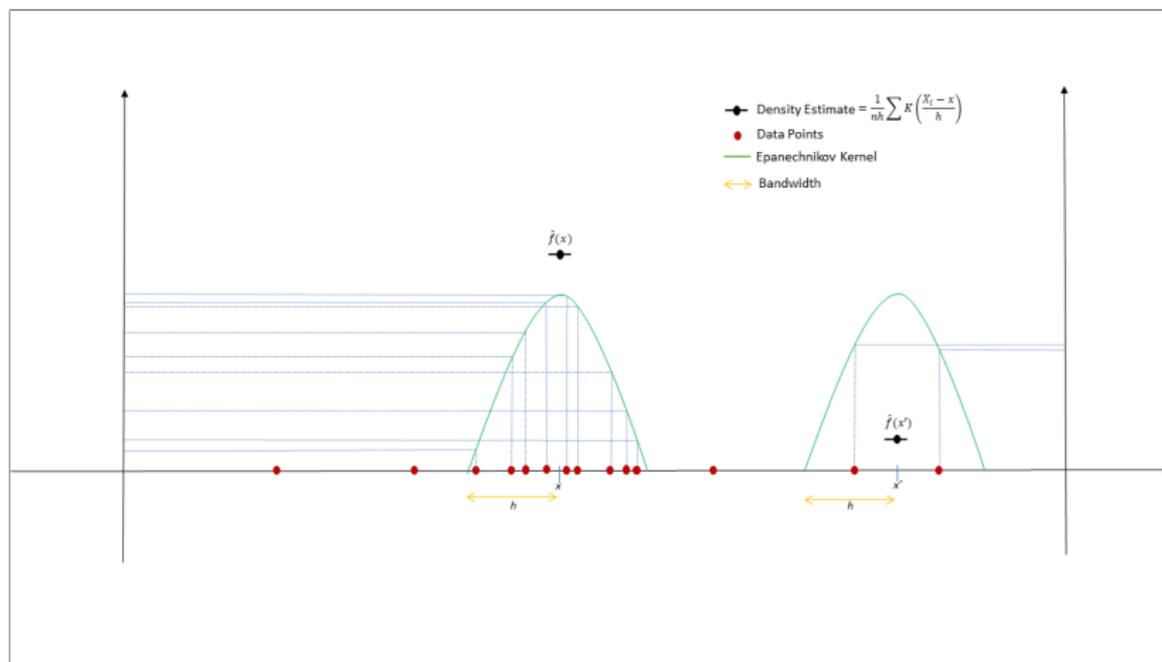
$h$ : **Bandwidth** – número positivo (muy importante)

$K(\cdot)$ : **Kernel** – una función ( $K : \mathbb{R} \rightarrow \mathbb{R}$ )

# Tipos de kernel



## Ilustración



# Implementación en Stata

```
kdensity varname [if] [in] [weight] [, options]
```

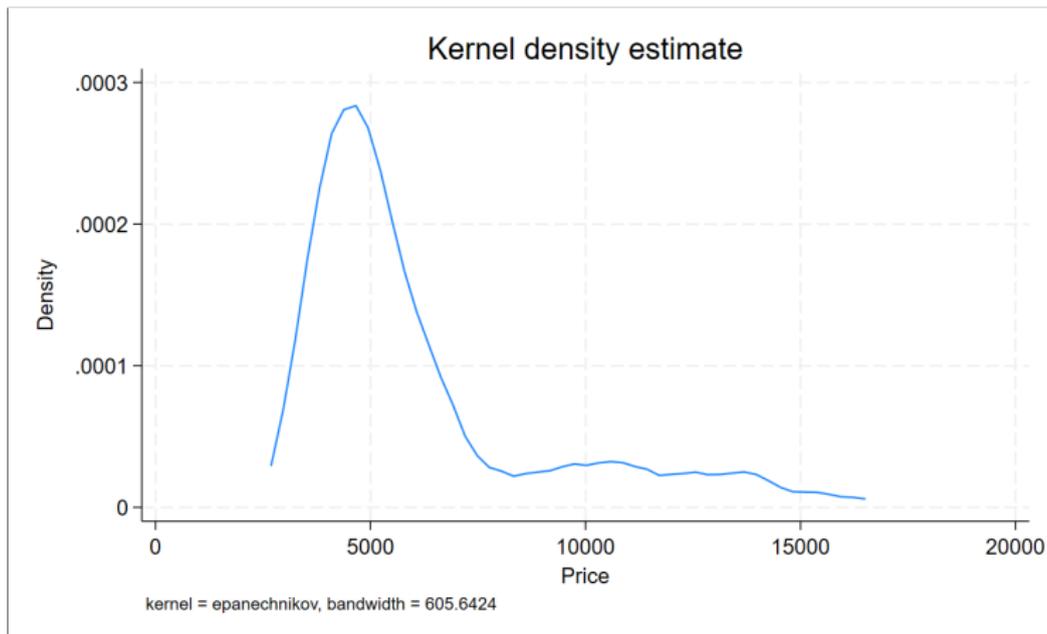
## Quick Start:

Graficar la densidad de la variable  $x_1$  usando **estimadores kernel**

- `kdensity x1`

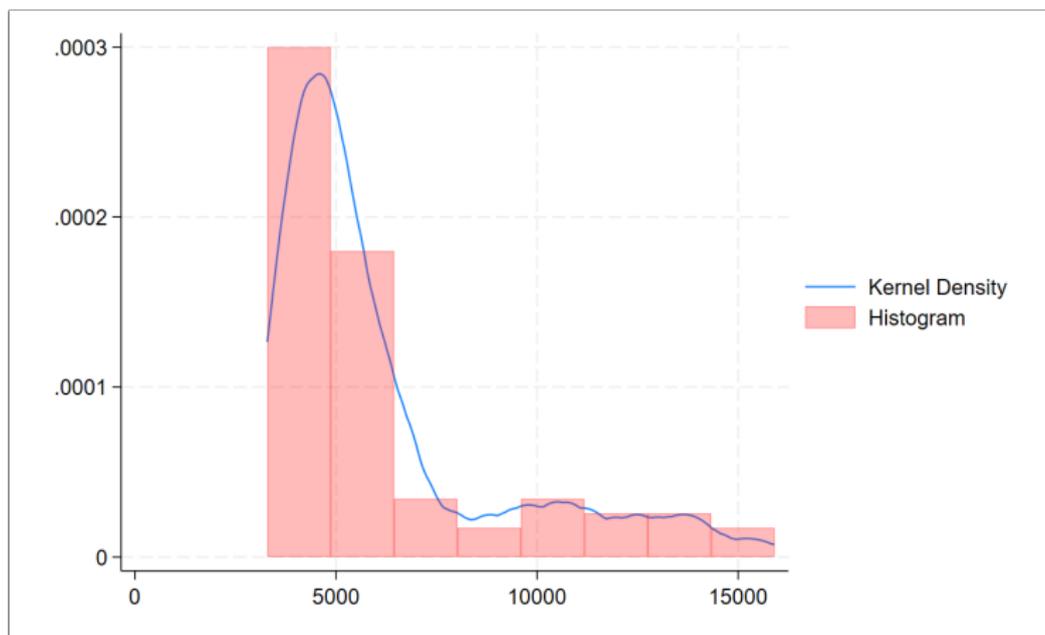
## Ejemplo 1: Graficando una densidad de probabilidad

- `sysuse auto, clear`
- `kdensity price`



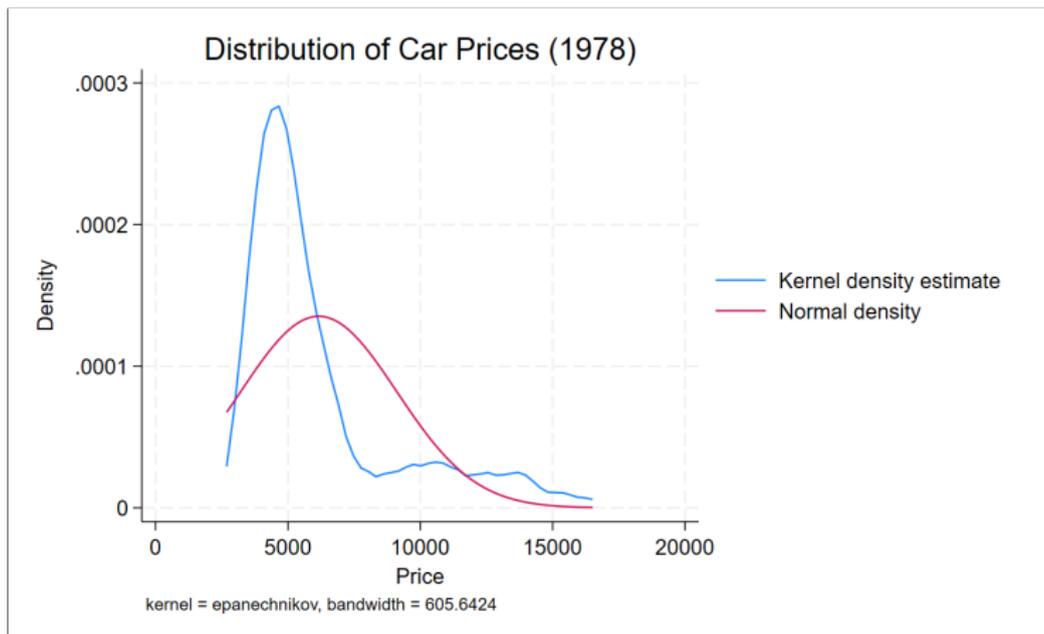
# Ejemplo 1: Un mejor ajuste a los datos de precios

- `twoway kdensity price || histogram price, legend(order(1 "Kernel Density" 2 "Histogram")) color(red%30)`



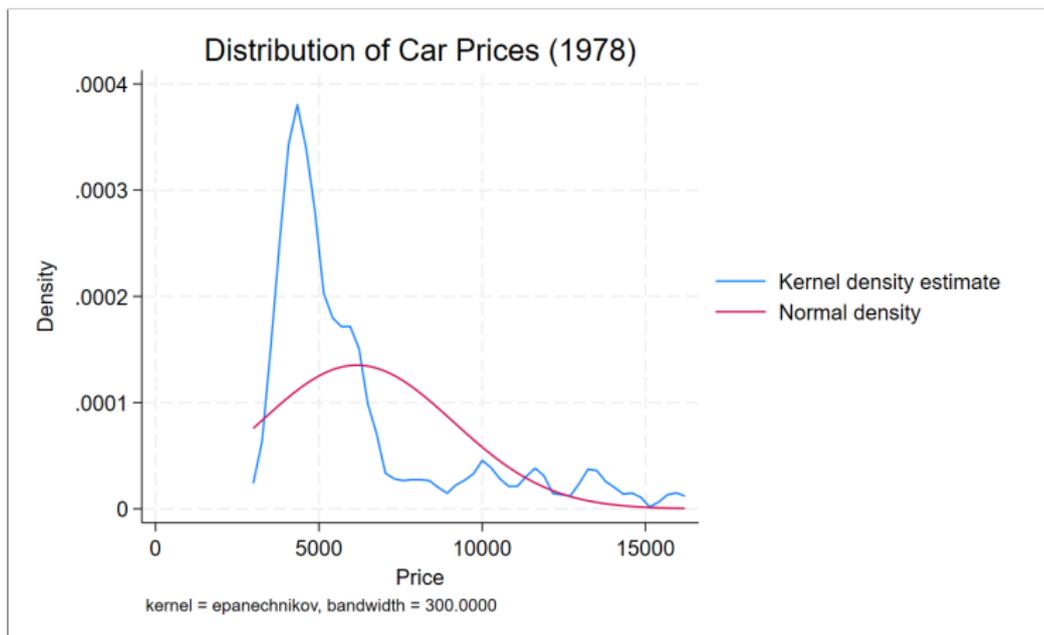
## Ejemplo 2: Comparando con la distribución normal

- `kdensity price, normal title("Distribution of Car Prices")`



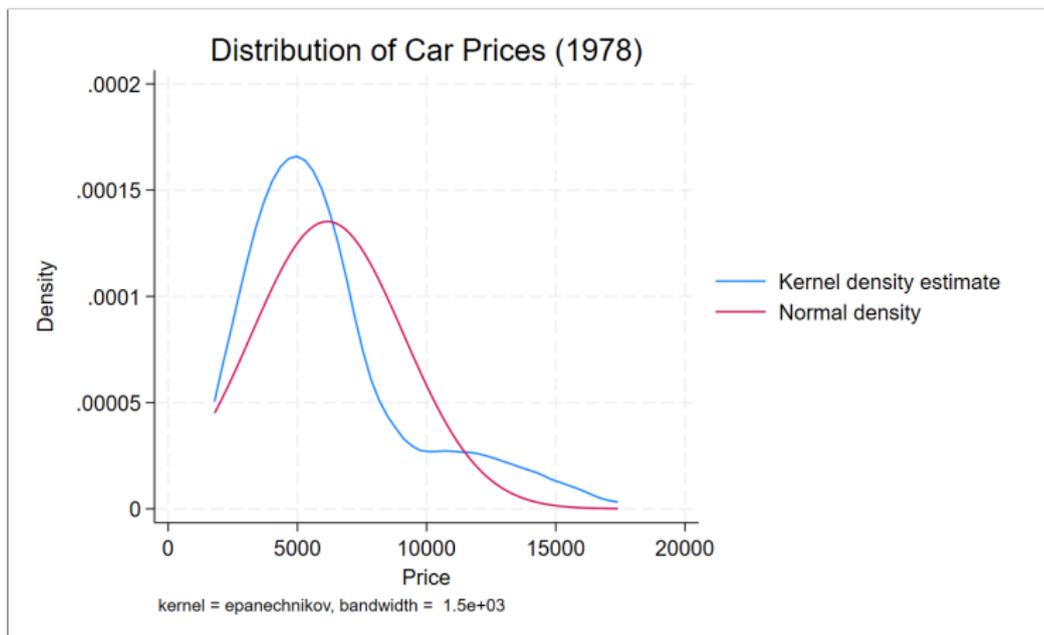
## Ejemplo 3: Un bandwidth más pequeño (overfitting)

- `kdensity price, normal bwidth(300) title("Distribution of Car Weights")`



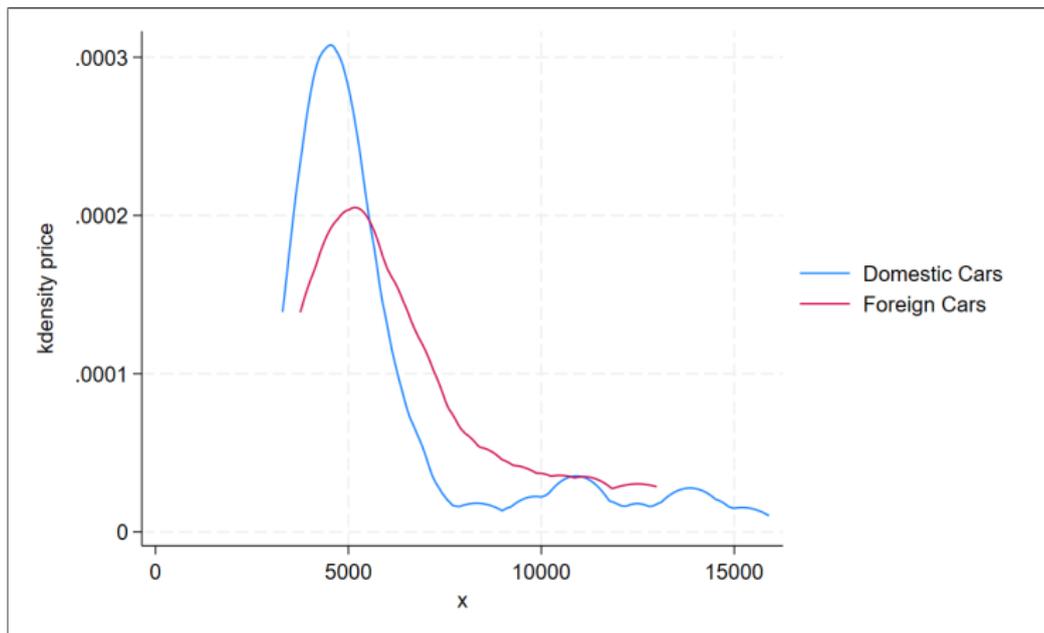
## Ejemplo 4: Un bandwidth más grande (oversmoothing)

- `kdensity price, normal bwidth(1500) title("Distribution of Car Prices")`



## Ejemplo 5: Comparando distribuciones de precios

- `twoway kdensity price if foreign==0 || kdensity price if foreign==1`



## Opciones útiles

`kernel`: Especificar la función Kernel:

- `epanechnikov`; por defecto
- `gaussian`
- `triangle...`

`generate(newvar1, newvar2)`: guardar los valores estimados en `newvar1` y sus respectivas densidades en `newvar2`

`nograph`: Suprimir la gráfica.

# Opción generate

- `kdensity price, generate(pricepoint density) nograph`
- `browse pricepoint density`

The screenshot shows the Stata Data Editor interface. The main window displays a grid with two columns: `density` and `pricepoint`. The `density` column contains values ranging from 0.00002919 to 0.0002250, and the `pricepoint` column contains values ranging from 2685.3578 to 11714.768. The right-hand side of the window shows the `Variables` panel, which lists the variables in the dataset. The `make` variable is selected, and its properties are displayed: Name: `make`, Label: `Make and model`, Type: `str18`, Format: `%-18s`. The `Data` panel shows the file name `1978 automobile.dta` and the number of observations (74).

density	pricepoint
0.00002919	2685.3578
0.0000687	2967.5267
0.00011843	3249.6956
0.00017546	3531.8648
0.00022515	3814.0339
0.00028398	4096.203
0.00034302	4378.3721
0.00040263	4660.5412
0.00046279	4942.7102
0.00052355	5224.8793
0.00058479	5507.0484
0.00064667	5789.2175
0.00070928	6071.3865
0.00077272	6353.5556
0.00083691	6635.7247
0.00090191	6917.8938
0.00096788	7200.0628
0.00103481	7482.2319
0.00110271	7764.401
0.00117156	8046.5701
0.00124137	8328.7392
0.00131214	8610.9082
0.00138387	8893.0773
0.00145657	9175.2464
0.00153024	9457.4155
0.00160488	9739.5845
0.00168049	10021.754
0.00175707	10303.923
0.00183462	10586.092
0.00191314	10868.261
0.00199264	11150.43
0.00207312	11432.599
0.00215458	11714.768

# Agenda

- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

## Esperanza condicional – Función de regresión

### Objetivo:

Estimar la **esperanza condicional**/función de regresión  $g(\cdot)$ :

$$y = g(X) + \varepsilon$$

$$\mathbb{E}[\varepsilon|X] = 0$$

### Enfoques paramétricos:

- Regresión lineal:  $g(X) = x\beta$
- Probit:  $g(X) = \Phi(x\beta)$
- Poisson:  $g(X) = \exp(x\beta)$

### Problemas por mala especificación.

**Regresión kernel** y **aproximación con series** no presuponen una forma funcional para  $g(\cdot)$

# Agenda

- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

## Regresión kernel – Local linear

Para estimar la **función de regresión** en el punto  $x$ :

- **“Regresión ponderada”** de  $y$  en  $X$  usando obs. cerca a  $x$ ,

$$\min_{\gamma_0, \gamma_1} \sum_{i=1}^n \left( y_i - \gamma_0 - \gamma_1(x_i - x) \right)^2 \cdot K\left(\frac{x - X_i}{h}\right)$$

$\gamma_0$  : **Función de regresión** estimada  $\hat{g}(x)$

$\gamma_1$ : **Derivada** de  $g(\cdot)$  estimada en el punto  $x$ .

$h$ : **Bandwidth** – número positivo (muy importante!)

$K(\cdot)$ : **Kernel** – una función ( $K : \mathbb{R} \rightarrow \mathbb{R}$ )

## Regresión kernel – Local constant

Para estimar la **función de regresión** en el punto  $x$ :

- “**Media ponderada**” de  $y$  usando puntos cerca de  $x$ ,

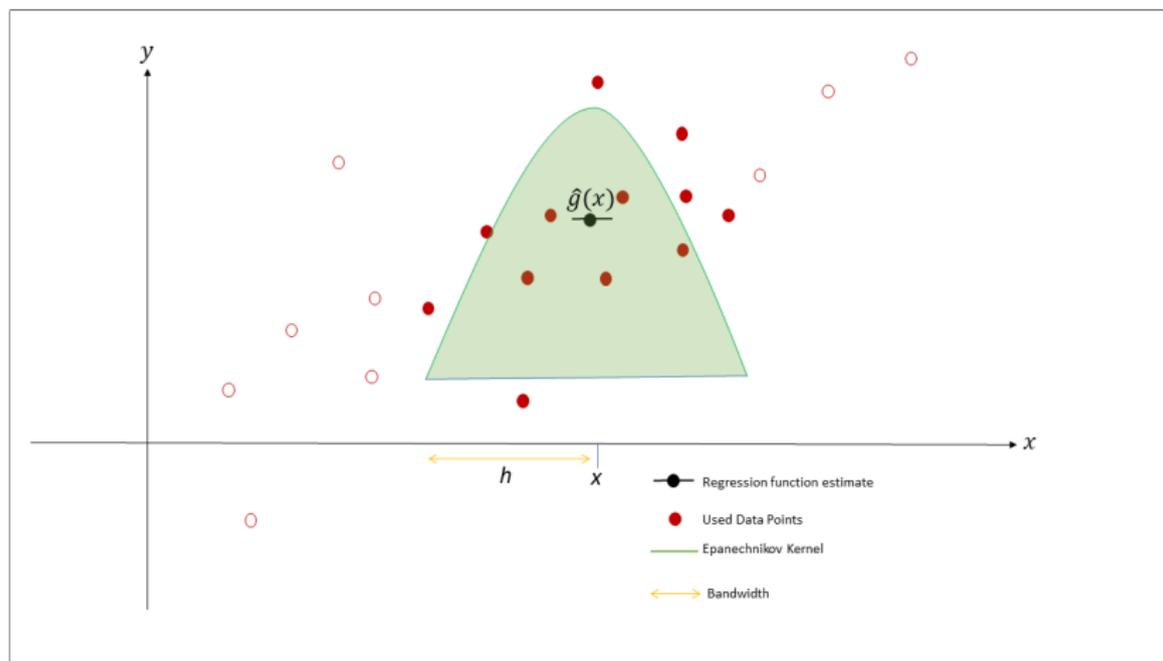
$$\min_{\gamma_0, \gamma_1} \sum_{i=1}^n \left( y_i - \gamma_0 \right)^2 \cdot K \left( \frac{x - X_i}{h} \right)$$

$\gamma_0$  : **Función de regresión** estimada  $\hat{g}(x)$

$h$  : **Bandwidth** – número positivo (muy importante!)

$K(\cdot)$  : **Kernel** – una función ( $K : \mathbb{R} \rightarrow \mathbb{R}$ )

# Ilustración – Local Constant



# Implementación en Stata

```
npregress kernel depvar indepvars [if] [in] [, options]
```

## Quick Start:

Regresión kernel local-linear de  $y$  con  $x$  y la variable discreta  $a$ :

- `npregress kernel y x i.a`

Regresión kernel local-const. de  $y$  con  $x$  y la variable discreta  $a$ :

- `npregress kernel y x i.a, estimator(constant)  
noderivatives`

## Ejemplo 7: El efecto de fumar sobre el peso de los bebés

### Base de datos:

- `lbwsim2.dta`: Extracto de Cattaneo (2010) *Journal of Econometrics*

### Outcome:

- `bweight`: **Peso del bebé** en gramos.

### Treatment:

- `msmoke`: **Cigarrillos** fumados durante el embarazo

### Controls:

- `mage`: Edad de la madre.
- `medu`: Años de educación de la madre.
- `alcohol`: 1 si se consumió alcohol durante el embarazo.
- `prenatal`: trimestre de la primera visita prenatal.

## Ejemplo 7: Regresión kernel Local-Linear

```
. nppregress kernel bweight mage medu i.msmove i.alcohol i.prenatal, nolog
```

Bandwidth

	Mean	Effect
mage	2.178108	3.09538
medu	.9284651	1.319472
msmove	.5	.5
alcohol	.5	.5
prenatal	.5	.5

Local-linear regression

Continuous kernel : epanechnikov

Discrete kernel : liracine

Bandwidth : cross-validation

Number of obs = 4,605

E(Kernel obs) = 4,605

R-squared = 0.0893

	bweight	Estimate
<b>Mean</b>	bweight	3357.97
<b>Effect</b>	mage	9.550276
	medu	4.95285
	msmove	
	(1-5 daily vs 0 daily)	-114.3037
	(6-10 daily vs 0 daily)	-214.6567
	(11+ daily vs 0 daily)	-306.8657
	alcohol	
	(1 vs 0)	-45.48752
	prenatal	
	(1 vs 0)	31.2373
	(2 vs 0)	10.41102
	(3 vs 0)	-30.41237

Note: Effect estimates are averages of derivatives for continuous covariates and averages of contrasts for factor covariates.

Note: You may compute standard errors using vce(bootstrap) or reps().

## Ejemplo 7: Predicciones generadas

2 - Data Editor (Browse) - [lbw\_sim2]

File Edit View Data Tools

bweight[1] 3459

	bweight	alcohol	mage	medu	msmoke	prenatal	_Mean_bw...
1	3459	0	24	14 0 daly		1	3432.9464
2	3260	0	20	10 0 daly		1	3371.1014
3	3572	0	22	9 0 daly		1	3454.9649
4	2948	0	26	12 0 daly		1	3431.5499
5	2410	0	20	12 0 daly		1	3335.7757
6	3147	0	27	12 0 daly		1	3427.7775
7	3799	0	27	12 0 daly		1	3427.7775
8	3629	0	24	12 0 daly		1	3428.6979
9	2835	0	21	12 0 daly		1	3370.4283
10	3880	0	30	15 0 daly		1	3498.2042
11	3090	0	26	12 11+ daly		1	3063.5346
12	3345	0	20	12 0 daly		1	3335.7757
13	4013	0	34	14 0 daly		1	3496.9393
14	3771	0	21	8 0 daly		1	3399.5816
15	662	0	23	12 0 daly		2	3378.9015
16	3657	0	22	12 0 daly		1	3397.0289
17	3572	0	26	12 0 daly		1	3431.5499
18	3430	0	40	16 0 daly		1	3375.6734
19	4479	0	34	12 0 daly		1	3454.5931
20	3186	0	27	12 6-10 daly		2	3188.7895
21	4253	0	33	12 0 daly		1	3442.9508
22	4054	0	27	14 0 daly		1	3457.9927
23	3160	0	25	12 0 daly		1	3434.6629
24	2466	0	22	12 0 daly		1	3397.0289
25	3147	0	19	10 11+ daly		2	3093.1773
26	3232	0	33	14 0 daly		1	3491.6733
27	3005	0	19	12 0 daly		1	3290.9059
28	1899	0	36	17 0 daly		1	3470.78
29	4026	0	33	14 0 daly		1	3491.6733
30	3969	0	26	12 0 daly		2	3411.2734
31	4167	0	19	9 0 daly		1	3320.6182
32	4054	1	32	16 0 daly		1	3491.0059
33	3660	0	28	15 0 daly		1	3481.2317

Variables

Filter variables here

<input checked="" type="checkbox"/>	Name	Label	Type	Format	Value L
<input checked="" type="checkbox"/>	bweight	Infant birthweight (gra...	int	%9.0g	
<input type="checkbox"/>	mmarried	1 if mother married	byte	%11.0g	mmarried
<input type="checkbox"/>	mhispanic	1 if mother hispanic	byte	%9.0g	
<input type="checkbox"/>	fhispanic	1 if father hispanic	byte	%9.0g	
<input type="checkbox"/>	foreign	1 if mother born abroad	byte	%9.0g	
<input checked="" type="checkbox"/>	alcohol	1 if alcohol consumed d...	byte	%9.0g	
<input type="checkbox"/>	deadkids	Previous births where n...	byte	%9.0g	
<input checked="" type="checkbox"/>	mage	Mother's age	byte	%9.0g	
<input checked="" type="checkbox"/>	medu	Mother's education attal...	byte	%9.0g	

Variables Snapshots

Properties

Variables

Name	bweight
Label	Infant birthweight (grams)
Type	int
Format	%9.0g
Value label	
Notes	

Data

Frame	default
Filename	lbw_sim2.dta
Label	Excerpt from Cattaneo (2010) Journal
Notes	
Variables	34
Observations	4,605
Size	512.67K

Ready

Vars: 7 of 34 Order: Dataset Obs: 4,605 Filter: Off Mode: Browse CAP: NIJ

## Ejemplo 8: Errores estándar usando un Bootstrap

```
npregress kernel bweight mage medu i.smoke i.alcohol i.prenatal, nolog vce(bootstrap, reps(40))
```

```
Bootstrap replications (40): .....10.....20.....30.....40 done
```

Bandwidth		
	Mean	Effect
mage	2.178108	3.09538
medu	.9284651	1.319472
msmoke	.5	.5
alcohol	.5	.5
prenatal	.5	.5

Local-linear regression	Number of obs	=	4,605
Continuous kernel : epanechnikov	E(Kernel obs)	=	4,605
Discrete kernel : liracine	R-squared	=	0.0893
Bandwidth : cross-validation			

	bweight	Observed estimate	Bootstrap std. err.	z	P> z	Percentile [95% conf. interval]	
<b>Mean</b>	bweight	3357.97	10.23615	328.05	0.000	3341.884	3379.431
<b>Effect</b>	mage	9.550276	1.77653	5.38	0.000	6.437531	12.45403
	medu	4.95285	7.087289	0.70	0.485	-9.00919	15.87284
	msmoke						
	(1-5 daily vs 0 daily)	-114.3037	10.67519	-10.71	0.000	-135.9948	-95.59864
	(6-10 daily vs 0 daily)	-214.6567	19.9158	-10.78	0.000	-257.2621	-179.2783
	(11+ daily vs 0 daily)	-306.8657	29.30562	-10.47	0.000	-367.6013	-261.8348
	alcohol						
	(1 vs 0)	-45.48752	42.34277	-1.07	0.283	-119.0151	39.6552
	prenatal						
	(1 vs 0)	31.2373	23.23159	1.34	0.179	-16.08415	73.16318
	(2 vs 0)	10.41102	41.17059	0.25	0.800	-79.54673	84.2395
	(3 vs 0)	-30.41237	61.28031	-0.50	0.620	-158.3454	86.92535

Note: Effect estimates are averages of derivatives for continuous covariates and averages of contrasts for factor covariates.

## Ejemplo 9: Presentar los resultados gráficamente

```
. npregress kernel bweight mage, nolog
```

```
Bandwidth
```

	Mean	Effect
mage	5.795516	3.695218

```
Local-linear regression      Number of obs      =      4,605
Kernel : epanechnikov      E(Kernel obs)     =      4,605
Bandwidth: cross-validation R-squared          =      0.0132
```

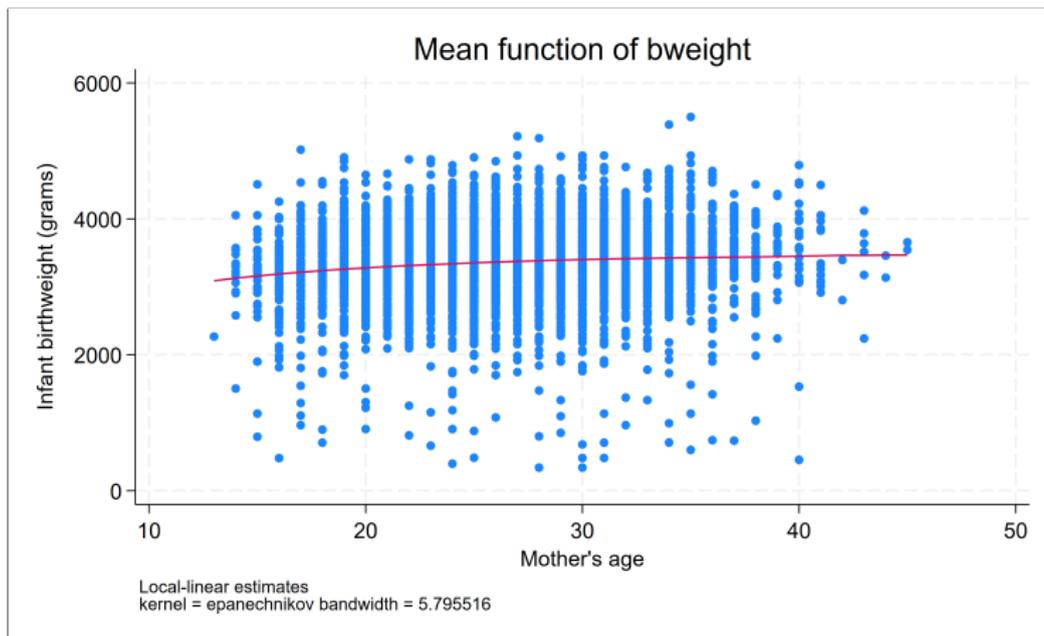
bweight	Estimate
<b>Mean</b>	
bweight	3354.357
<b>Effect</b>	
mage	11.41642

```
Note: Effect estimates are averages of derivatives.
```

```
Note: You may compute standard errors using vce(bootstrap) or reps().
```

```
.
. ngraph
```

## Ejemplo 9: Presentar los resultados gráficamente



# Agenda

- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

## Aproximación con series

Podemos **aproximar la función**  $g(\cdot)$  **usando series**. Por ejemplo, podríamos usar una **expansión de Taylor**:

$$g(x) = g(0) + \frac{g'(0)}{1!} \cdot x + \frac{g''(0)}{2!} \cdot x^2 + \frac{g^{(3)}(0)}{3!} \cdot x^3 + \text{Residuo}$$

Así, podemos **estimar la función**  $g(\cdot)$  como:

$$\hat{g}(x_i) = z(x_i)\hat{\beta}$$

Donde  $z(x_i) = (1, x_i, x_i^2, x_i^3)$  y  $\hat{\beta} = (Z^T Z)^{-1} Z^T y$ .

## Bases disponibles en Stata

### **Polynomial basis:**

La función  $g(\cdot)$  se aproxima con un polinomio.

### **Piecewise polynomial spline basis:**

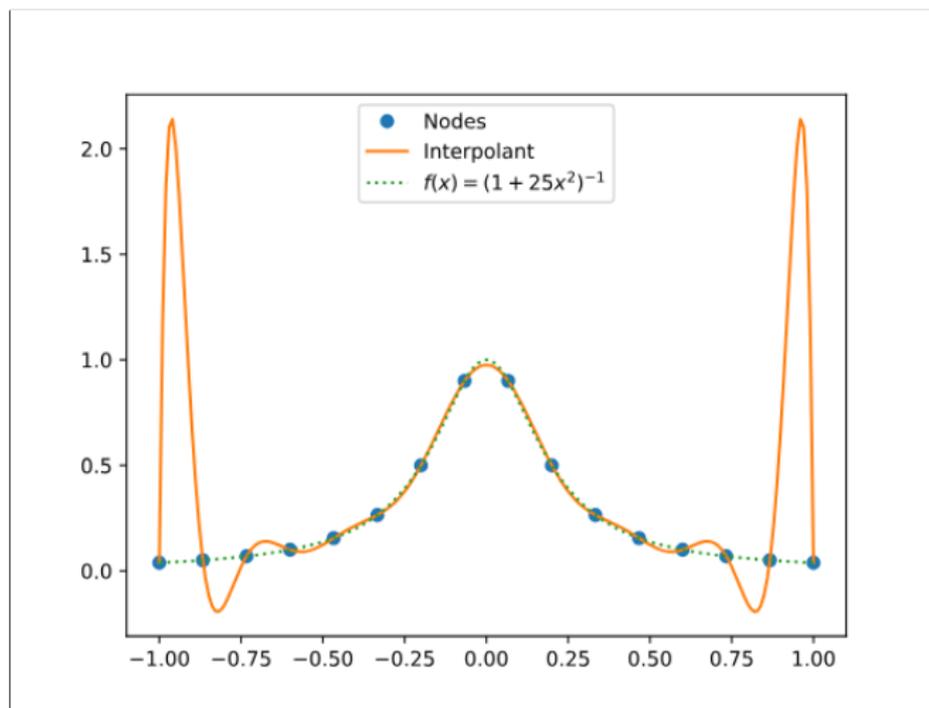
La función  $g(\cdot)$  se aproxima con un polinomio por partes.

### **B-Spline basis (default):**

La función  $g(\cdot)$  se aproxima con una función spline. Una función spline es un polinomio por partes “suavizado”.

Los polinomios por partes y las splines **mitigan el fenómeno de Runge**.

# Fenómeno de Runge



# Implementación en Stata

```
npregress series depvar indepvars [if] [in] [weight] [, options]
```

## Quick Start:

Regresión no paramétrica de  $y$  con  $x$  y la variable discreta  $a$  (usando una base B-spline):

- `npregress series y x i.a`

Igual que arriba pero usando una base polinomial:

- `npregress series y x i.a, polynomial`

# Ejemplo 10: Efecto de las multas en las citaciones de DUI

## Base de datos:

- <https://www.stata-press.com/data/r18/dui> (fictional data)

## Outcome:

- `citations`: **Citaciones por DUI anuales** en un condado.

## Tratamiento:

- `finer`: **Multa** por manejar bajo los efectos del alcohol en un condado

## Controles:

- `csize`: Tamaño del condado (3 categorías)
- `college`: 1 si hay un campus universitario en el condado.

# Regresión no paramétrica en Stata usando series

```
. npregress series citations fines i.csize i.college
```

```
Computing approximating function
```

```
Minimizing cross-validation criterion
```

```
Iteration 0: Cross-validation criterion = 30.26251
```

```
Computing average derivatives
```

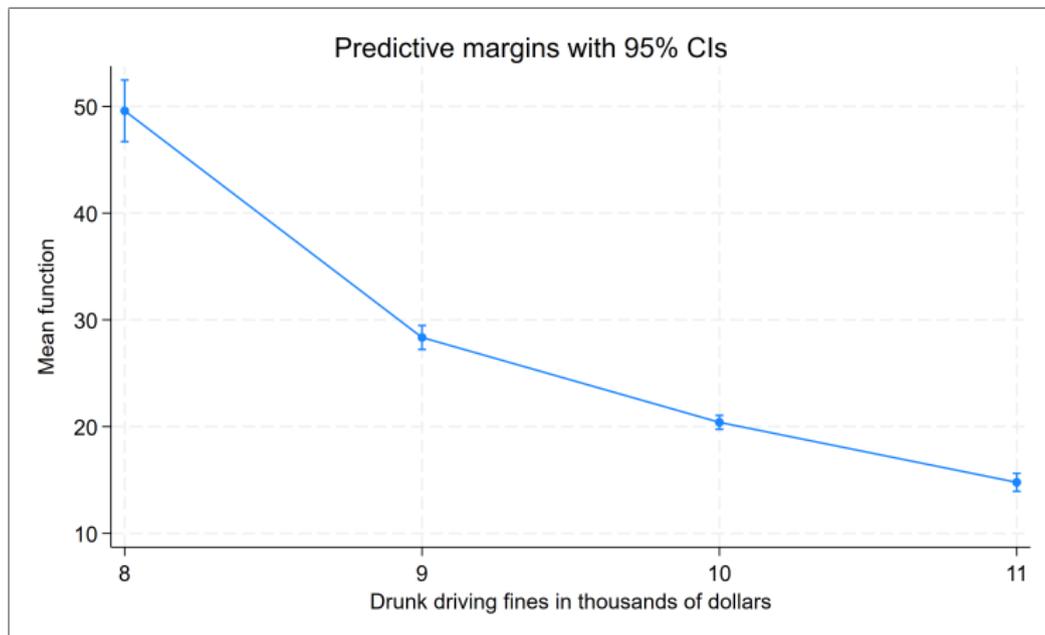
```
Cubic B-spline estimation      Number of obs   =      500
Criterion: cross-validation    Number of knots =       1
```

	Effect	Robust std. err.	z	P> z	[95% conf. interval]	
citations						
fines	-7.787386	.2917941	-26.69	0.000	-8.359292	-7.215481
csize						
(Medium vs Small)	4.732592	.5087968	9.30	0.000	3.735368	5.729815
(Large vs Small)	10.91757	.5350892	20.40	0.000	9.868813	11.96632
college						
(College vs Not college)	6.514286	.5958949	10.93	0.000	5.346353	7.682218

Note: Effect estimates are averages of derivatives for continuous covariates and averages of contrasts for factor covariates.

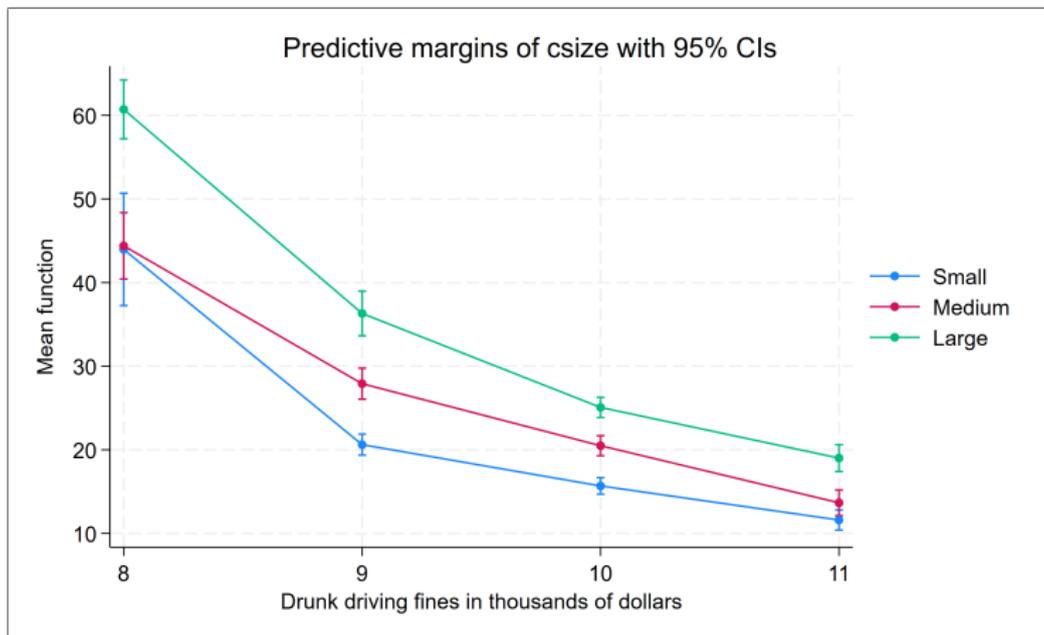
# Citaciones predichas para distintos niveles de multas

```
margins, at(fines=(8 9 10 11))
```



# El efecto de las multas según tamaño del condado

```
margins csize, at(fines=(8 9 10 11))
```



# makespline

Genera un conjunto de variables que constituyen una **base predeterminada**.

- Piecewise polynomial spline
- B-spline

Puedes usar estas variables **directamente en tus regresiones**.  
Útil para implementar **métodos semiparamétricos**.

## Quick Start:

Generar una base B-spline de tercer order a partir de las variables  $x_1$  y  $x_2$ , con nodos en las medianas de cada variable

```
makespline bspline x1 x2
```

## Ejemplo 11: Creando una base B-spline

```
sysuse auto
makespline bspline price
```

The screenshot shows the Stata Data Editor interface. The main window displays a data table with the following columns: price, \_bsp\_1\_1, \_bsp\_1\_2, \_bsp\_1\_3, \_bsp\_1\_4, and \_bsp\_1\_5. The data is sorted by price in descending order. The right-hand pane shows the 'Variables' list with checkboxes for each variable and their properties.

price	_bsp_1_1	_bsp_1_2	_bsp_1_3	_bsp_1_4	_bsp_1_5
4,000	11965163	79122659	89844835	00267342	0
4,749	00273345	78369636	20053231	01303788	0
3,799	28186433	67399465	04339465	00063636	0
4,816	00110678	77169007	21247004	01428311	0
7,627	0	30298968	48527033	2153732	0167404
5,768	0	58089873	35420268	6567073	0003561
4,453	02714761	81877214	14707026	00709069	0
5,189	0	89837284	27445574	02716889	4.535e-06
9,372	0	09033557	36298345	42255667	11524391
4,082	1285926	78721528	08375201	00253011	0
11,385	0	054977	28255657	46849891	19361652
14,500	0	00197027	04340015	31626842	63836116
15,906	0	1100e-06	00033303	03359915	96060672
3,289	79700403	20078032	00220713	7.919e-06	0
5,705	0	80234039	34442968	05197568	00025427
4,504	0203136	81555988	15625071	007878	0
5,104	0	71492566	26116447	02390917	6.915e-07
3,667	38477501	58661932	0281904	00041526	0
3,955	18612578	74775617	06450017	00161788	0
3,964	17114675	75830252	06874809	00180264	0
4,010	15842022	76980583	07263415	00197979	0
5,886	0	5721696	3647883	06253453	00060757
6,342	0	48843849	40702036	06276302	00177713
4,389	03789551	82064232	13564596	0080182	0
4,187	08811006	80759439	10079316	00350237	0
11,497	0	05109706	27309748	47189037	2039961
13,594	0	00793967	10055921	41901854	47248459
13,466	0	00925893	10993251	42914032	45167024
3,829	26137344	8042026	04720754	00099076	0
3,379	0	68230481	30233127	03332968	00003056
6,185	0	52625488	38212022	08045865	00116006
4,516	01889277	81458971	15841788	00080863	0
6,303	0	50448196	40389889	06999241	00162594

The right-hand pane shows the 'Variables' list with the following variables and their properties:

Name	Label	Type	Format	Value L
<input checked="" type="checkbox"/> price	Price	int	%8.0gc	
<input checked="" type="checkbox"/> _bsp_1_1	B-spline basis term 1 fo...	double	%10.0g	
<input checked="" type="checkbox"/> _bsp_1_2	B-spline basis term 2 fo...	double	%10.0g	
<input checked="" type="checkbox"/> _bsp_1_3	B-spline basis term 3 fo...	double	%10.0g	
<input checked="" type="checkbox"/> _bsp_1_4	B-spline basis term 4 fo...	double	%10.0g	
<input checked="" type="checkbox"/> _bsp_1_5	B-spline basis term 5 fo...	double	%10.0g	
<input type="checkbox"/> make	Make and model	str18	%-18s	
<input type="checkbox"/> mpg	Mileage (mpg)	int	%8.0g	
<input type="checkbox"/> rep78	Repair record 1978	int	%8.0g	

The 'Properties' pane shows the following properties for the selected variable:

Name	Value
Name	price
Label	Price
Type	int
Format	%8.0gc
Value label	
Notes	
Frame	default
Filename	auto.dta
Label	1978 automobile data
Notes	
Variables	17
Observations	74
Size	6.07K

At the bottom of the window, the status bar shows: Vars: 6 of 17 Order Modified Obs: 74 Filter: Off Mode: Browse CAP: NUM

## Métodos semiparamétricos usando `makespline`

Usaremos **datos simulados** para este ejemplo:

$$y = 3x_1 + 3 \sin(3(x_2 - x_3)) + \varepsilon$$

Como investigadores, **no conocemos** la forma funcional específica. No obstante, suponemos un **modelo semiparamétrico**:

$$y = \beta_1 x_1 + g(x_2, x_3) + \varepsilon$$

Nuestro **parámetro de interés** es  $\beta_1$ . Aquí,  $g(\cdot)$  es un **parámetro secundario**.

# Paso 1: Crear la base B-Spline

- use <https://www.stata-press.com/data/r18/splines>
- `makespline bspline x2 x3, knots(8)`

The screenshot shows the Stata Data Editor interface. The main window displays a dataset with the following variables: x1, x2, x3, gr, e, and nine B-spline basis terms (bsp\_1\_1 to bsp\_1\_9). The right-hand pane shows the variable list with checkboxes for each variable and their properties.

Name	Label	Type	Format	Value l
<input checked="" type="checkbox"/>	x1	float	%9.0g	
<input checked="" type="checkbox"/>	x2	float	%9.0g	
<input checked="" type="checkbox"/>	x3	float	%9.0g	
<input checked="" type="checkbox"/>	gr	float	%9.0g	
<input checked="" type="checkbox"/>	e	float	%9.0g	
<input checked="" type="checkbox"/>	y	float	%9.0g	
<input checked="" type="checkbox"/>	bsp_1_1	B-spline basis term 1 fo...	double	%10.0g
<input checked="" type="checkbox"/>	bsp_1_2	B-spline basis term 2 fo...	double	%10.0g
<input checked="" type="checkbox"/>	bsp_1_3	B-spline basis term 3 fo...	double	%10.0g

Los elementos de la base se guardan en r(regressors)

## Paso 2: Usar LASSO para escoger los elementos de la base

Con todas las interacciones tendríamos **168 regresores**. Usamos `poregress` para seleccionar de entre estos usando **LASSO**.

- `poregress y x1, controls(`r(regressors)`)`

```
. poregress y x1, controls(`r(regressors)')

Estimating lasso for y using plugin
Estimating lasso for x1 using plugin

Partialing-out linear model      Number of obs      =      5,000
                                Number of controls =      168
                                Number of selected controls =      19
                                Wald chi2(1)              =     3535.78
                                Prob > chi2                =      0.0000
```

		Robust				
y	Coefficient	std. err.	z	P> z	[95% conf. interval]	
x1	2.951242	.049632	59.46	0.000	2.853965	3.048519

Note: Chi-squared test is a Wald test of the coefficients of the variables of interest jointly equal to zero. Lassos `select controls` for model estimation. Type `lassoinfo` to see number of selected variables in each lasso.

# Agenda

- 1 El atractivo de los métodos no paramétricos
- 2 Estimando densidades de probabilidad
- 3 Estimando esperanzas condicionales / funciones de regresión
  - Regresión kernel
  - Aproximación con series
- 4 Ventajas y desventajas de los métodos no paramétricos

## Limitaciones de regresión kernel y aproximación con series

**1. Costo computacional:** Tiempo CPU incrementa rápidamente con  $n$  y  $k$ . Problema es más agudo en aproximación con series.

- Regresión kernel
- Opción `nointeract`.

**2. ‘Maldición de la dimensionalidad’:** Cuando  $k$  es grande,  $n$  debe ser muy grande para que los IC sean informativos.

- Intentar tener bastantes observaciones por regresor.
- Métodos semiparamétricos.

## Conclusión: Métodos no paramétricos en Stata

1. Herramienta poderosa para explorar las **relaciones entre variables**.
  - No requieren **supuestos de forma funcional**.
  - No hay riesgo de **mala especificación**.
2. Fáciles de implementar en Stata
  - `npregress`: Estimar  $g(\cdot)$ , efectos, y hacer predicciones.
  - `margins`: explorar  $\hat{g}(\cdot)$  y responder preguntas interesantes.
3. Cuidado con las limitaciones:
  - **Costo computacional**.
  - **'Maldición de la dimensionalidad'**.

## ¿Dónde aprender más?

1. Documentación de Stata:  
<https://www.stata.com/features/documentation/>
2. Canal de YouTube: <https://www.youtube.com/user/statacorp>
3. Envía un correo a nuestro soporte técnico:  
[tech-support@stata.com](mailto:tech-support@stata.com).
4. El comando `help`.

¡Gracias!