

## ***REGRESIÓN “FLEXIBLE”:***

- 1. Regresión polinómica***
- 2. Regresión polinómica “local”:  
Regresión spline***

***Carmen María Cadarso Suárez***

Dado el modelo de respuesta continua  $Y$ , y una sola covariable continua  $X$ :

$$E[Y / X] = \beta_0 + f(X)$$

donde  $f$  es una función “suave” desconocida. ¿Cómo obtener flexibilidad en la modelización?

**1. *Regresión polinómica.***

**2. *Regresión polinómica “local”.***

Splines de Regresión (regression splines)

- *B-splines* (bs)
- *Natural Splines* (ns)

# REGRESIÓN POLINÓMICA


Realizamos un ajuste mínimo-cuadrático a la función polinómica de grado  $p$

$$E[Y / X] = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_p X^p$$

- Grados de libertad del modelo:  $df = p+1$ .
- Cuanto mayor es la potencia  $p$  (i.e.,  $df$ ) mayor flexibilidad.

**Ejemplo:** Relación entre Ozono y Temperatura.

```
plot(airquality$Temp, airquality$Ozone, xlab="Temperature", ylab="Ozone",  
     main="Airquality")
```



## Ajuste cuadrático

$$E[Ozone / Temp] = \beta_0 + \beta_1 Temp + \beta_2 Temp^2$$

```
airquality$Temp2<- airquality$Temp*airquality$Temp
```

```
air.fit2<- lm(Ozone~Temp+Temp2,data=airquality)
summary(air.fit2)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	305.48577	122.12182	2.501	0.013800 *
Temp	-9.55060	3.20805	-2.977	0.003561 **
Temp2	0.07807	0.02086	3.743	0.000288 ***

---

Signif. codes: 0 ‘\*\*\*’ 0.001 ‘\*\*’ 0.01 ‘\*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 22.47 on 113 degrees of freedom  
Multiple R-squared: 0.5442, Adjusted R-squared: 0.5362  
F-statistic: 67.46 on 2 and 113 DF, p-value: < 2.2e-16

El modelo también se puede formular así:

```
air.fit22<- lm(Ozone~poly(Temp,2,raw=T), data=airquality)
summary(air.fit22)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	305.48577	122.12182	2.501	0.01380
poly(Temp, 2, raw = T)1	-9.55060	3.20805	-2.977	0.003561
poly(Temp, 2, raw = T)2	0.07807	0.02086	3.743	0.000288

Residual standard error: 22.47 on 113 degrees of freedom  
Multiple R-squared: 0.5442, Adjusted R-squared: 0.5362  
F-statistic: 67.46 on 2 and 113 DF, p-value: < 2.2e-16


## Ajuste lineal; ajuste cuadrático; ajuste cúbico

```
air.fit1<-lm(Ozone~Temp,data=airquality)
```

```
new <- data.frame(Temp =  
seq(min(airquality$Temp),max(airquality$Temp),1))  
plot(airquality$Temp,airquality$Ozone, xlab="Temperature",  
ylab="Ozone", main="Airquality")  
lines(new$Temp,predict(air.fit1,new),lty=1,col="black",lwd=3)
```

```
air.fit2<-lm(Ozone~poly(Temp,2,raw=T),data=airquality)  
lines(new$Temp,predict(air.fit2,new),lty=2,col="red",lwd=3)
```

```
air.fit3<-lm(Ozone~poly(Temp,3),data=airquality)  
lines(new$Temp,predict(air.fit3,new,raw=T),lty=3, col="blue",lwd=3)  
legend(60,120,c("p=1 (R2=0.48)", "p=2 (R2=0.53)", "p=3 (R2=0.54)"),  
col=c("black","red","blue"), lty=c(1,2,3),lwd=3)
```



## ANOVA

### a) Comparación lineal versus cuadrático

```
anova(air.fit1,air.fit2,test="Chi")
```

Analysis of Variance Table:

Model 1: Ozone ~ Temp;

Model 2: Ozone ~ poly(Temp, 2,raw=T)

	Res.Df	RSS	Df	Sum of Sq	P(> Chi )
1	114	64110			
2	113	57038	1	7072	<b>0.0001818</b>

### b) Comparación cuadrático versus cúbico

```
anova(air.fit2,air.fit3,test="Chi")
```

Analysis of Variance Table:

Model 1: Ozone ~ poly(Temp, 2,raw=T);

Model 2: Ozone ~ poly(Temp, 3,raw=T)

	Res.Df	RSS	Df	Sum of Sq	P(> Chi )
1	113	57038			
2	112	56440	1	598	<b>0.2759</b>


## VENTAJAS /DESVENTAJAS DE LA REGRESIÓN POLINÓMICA

### Ventajas:

- Los parámetros son fácilmente interpretables.
- Puede realizarse con cualquier paquete estadístico (con R, usando **lm** ó **glm**, pudiéndose aplicar a cualquier tipo de respuesta (continua, binaria, poisson).

### Desventajas:

- Es una regresión GLOBAL: los parámetros se ajustan utilizando TODOS los datos muestrales.
- Esto hace que, en ocasiones, no permita capturar relaciones con comportamientos locales diferenciados.



Los datos se basan en un modelo de regresión “simulado”

$$f(x_i) = \operatorname{sen}^3(2\pi x_i^3) + \varepsilon_i \quad , \quad i = 1, \dots, 400$$

$$x_i \sim U[0,1] \quad \text{y} \quad \varepsilon_i \sim N(0, 0.1)$$

```
set.seed(90)
```

```
eps<-rnorm(400,0,0.1); X<-runif(400,0,1)
```


```
X<-X[order(X)]
```

```
yteor<-(sin(2*3.141516*X**3))**3
```

```
yobs<-(sin(2*3.141516*X**3))**3+eps
```

```
plot(X,yobs,pch=1,ylab="Y")
```

Como posible solución, puede utilizarse la **regresión polinómica local:**



1. Elegimos  $K$  nodos (knots) interiores.
2. Dividimos el rango de la covariable  $X$ , en  $k+1$  regiones disjuntas.
3. Regresión polinómica (p.e. cúbica), en cada región.
4. **Restricción:** Los polinomios han de unirse “suavemente” en los nodos (asegurando que la función resultante sea continua).
5. El número de nodos,  $K$ , indica el grado de flexibilidad (a mayor  $K$ , mayor flexibilidad).

# **REGRESIÓN SPLINE**

- **B-Splines (bs)**
- **Natural Splines (ns)**

**(R library : splines)**

De Boor C. *A practical guide to splines*. Revised Edition. New York, NY: Springer Verlag, 1987.

De Boor C. *A practical guide to splines*. Revised Edition. New York, NY: Springer Verlag, 2001.

## Regresión B-spline (bs)

- Parte de una base de  $(K+p)$  polinomios B-splines (de Boor, 1978)

$$\{B_1(x), \dots, B_{p+K}(x)\}$$

donde

$K$  = número de nodos interiores.

$p$  = grado de los polinomios (p.e. cúbicos,  $p=3$ ).

- **Modelo de regresión B-spline:**

$$E[Y/X] = \beta_0 + \sum_{i=1}^{K+p} \beta_i B_i(x)$$

Con este modelo, se ha convertido el problema original en un problema de regresión lineal múltiple.


- **Grado de flexibilidad del modelo:**

$K$  = número de nodos interiores.


$df = K+p+1$  (ó  $K+p$  sin la constante).

En nuestro ejemplo, proponemos una regresión b-spline con 9 knots localizados en los siguientes valores de X:

$$(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)$$



Como resultado obtenemos la siguiente estimación B-spline:



## ¿Cómo se obtiene la base de B-splines en R?

```
library(splines)  
  
Bspline<-bs(x,knots=c(0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9))
```

Bspline es un objeto que guarda la evaluación de cada valor de x en la base de los 12 B-splines. Por ejemplo, para el valor x=0.1167016

```
x[40]  
[1] 0.1167016
```

Bspline[40,] nos ofrece la evaluación de la base en dicho valor:

```
Bspline[40,]  
  
 1          2          3          4          5  
0.1558194980 0.5964778668 0.2469261731 0.0007764621 0.0000000000  
 6          7          8          9         10  
0.0000000000 0.0000000000 0.0000000000 0.0000000000 0.0000000000  
 11         12  
0.0000000000 0.0000000000
```


La representación gráfica de la base se obtiene así:

```
matplot(x,Bspline,col="white", main="Base de B-splines")  
matlines(x,Bspline)
```

El objeto Bspline también guarda otras informaciones:

```
attr(,"degree")  
[1] 3  
attr(,"knots")  
[1] 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9  
attr(,"Boundary.knots")  
[1] 0.007405288 0.998299962  
attr(,"intercept")  
[1] FALSE  
attr(,"class")  
[1] "bs"      "basis"
```

a) Flexibilidad variando los gl (los knots los coloca en los cuantiles)




b) Flexibilidad fijando los knots.

Consideramos la siguiente secuencia de knots interiores ( $K=9$ )

$$(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)$$

Lo que nos lleva a un modelo b-spline con  $df=k+p+1 = 13$  grados de libertad.



## B-Spline Basis for Polynomial Splines

### Description

Generate the B-spline basis matrix for a polynomial spline.

### Usage

```
bs(x, df = NULL, knots = NULL, degree = 3, intercept = FALSE, Boundary.knots = range(x))
```

### Arguments

<b>x</b>	the predictor variable. Missing values are allowed.
<b>df</b>	degrees of freedom; one can specify df rather than knots; bs() then chooses df-degree-1 knots at suitable quantiles of x (which will ignore missing values).
<b>knots</b>	the <i>internal</i> breakpoints that define the spline. The default is NULL, which results in a basis for ordinary polynomial regression. Typical values are the mean or median for one knot, quantiles for more knots. See also Boundary.knots.
<b>degree</b>	degree of the piecewise polynomial—default is 3 for cubic splines.
<b>intercept</b>	if TRUE, an intercept is included in the basis; default is FALSE.
<b>Boundary.knots</b>	boundary points at which to anchor the B-spline basis (default the range of the data). If both knots and Boundary.knots are supplied, the basis parameters do not depend on x. Data can extend beyond Boundary.knots.

### Value

A matrix of dimension `length(x) * df`, where either `df` was supplied or if `knots` were supplied, `df = length(knots) + 3 + intercept`. Attributes are returned that correspond to the arguments to `bs`, and explicitly give the `knots`, `Boundary.knots` etc for use by `predict.bs()`.

### See Also

[ns](#), [poly](#), [smooth.spline](#), [predict.bs](#), [SafePrediction](#)

### Examples

```
require(stats); require(graphics)
bs(women$height, df = 5)
summary(fm1 <- lm(weight ~ bs(height, df = 5), data = women))
```

## Regresión natural-spline (ns)

- Parte de una base de  $(K+p-2)$  polinomios n-splines (de Boor, 1978)

$$\{N_1(x), \dots, N_{p+K-2}(x)\}$$

debido a la restricción de “**linealidad**” en las fronteras.

- **Modelo de regresión n-spline:**

$$E[Y / X] = \beta_0 + \sum_{i=1}^{K+p-2} \beta_i N_i(x)$$

- **Grado de flexibilidad:**

$K$  = número de nodos interiores.

$df = K+p-1$  (ó  $K+p-2$  sin la constante).

## Generate a Basis Matrix for Natural Cubic Splines

### Description

Generate the B-spline basis matrix for a natural cubic spline.

### Usage

```
ns(x, df = NULL, knots = NULL, intercept = FALSE, Boundary.knots = range(x))
```

### Arguments

- x** the predictor variable. Missing values are allowed.
- df** degrees of freedom. One can supply `df` rather than `knots`; `ns()` then chooses `df - 1 - intercept` knots at suitably chosen quantiles of `x` (which will ignore missing values).
- knots** breakpoints that define the spline. The default is no knots; together with the natural boundary conditions this results in a basis for linear regression on `x`. Typical values are the mean or median for one knot, quantiles for more knots. See also `Boundary.knots`.
- intercept** if `TRUE`, an intercept is included in the basis; default is `FALSE`.
- Boundary.knots** boundary points at which to impose the natural boundary conditions and anchor the B-spline basis (default the range of the data). If both `knots` and `Boundary.knots` are supplied, the basis parameters do not depend on `x`. Data can extend beyond `Boundary.knots`

### Value

A matrix of dimension `length(x) * df` where either `df` was supplied or if `knots` were supplied, `df = length(knots) + 1 + intercept`. Attributes are returned that correspond to the arguments to `ns`, and explicitly give the `knots`, `Boundary.knots` etc for use by `predict.ns()`.

### Examples

```
require(stats); require(graphics)
ns(women$height, df = 5)
summary(fm1 <- lm(weight ~ ns(height, df = 5), data = women))

## example of safe prediction
plot(women, xlab = "Height (in)", ylab = "Weight (lb)")
ht <- seq(57, 73, length.out = 200)
lines(ht, predict(fm1, data.frame(height=ht)))
```

## Comparativa: bs y ns

- Los splines naturales son menos flexibles en las fronteras (permiten reducir la varianza).
- Los splines naturales son más flexibles en el interior.  
Al poseer  $2gl$  menos que los B-splines, permiten introducir 2 knots interiores adicionales.

## Ejemplo: Ozono en función de la temperatura (airquality)

### B-SPLINE

- Realizamos una regresión b-spline con df=4.
- Esto significa que sólo se considera 1 knot (el percentil 50 de Temp).

```
air.bs<-lm(Ozone~bs(Temp,df=4),data=airquality)
```

```
summary(air.bs)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	3.243	15.623	0.208	0.836
bs(Temp, df = 4)1	31.004	28.336	1.094	0.276
bs(Temp, df = 4)2	-20.998	16.677	-1.259	0.211
bs(Temp, df = 4)3	110.104	23.107	4.765	5.76e-06 ***
bs(Temp, df = 4)4	79.535	19.452	4.089	8.24e-05 ***

Residual standard error: 21.91 on 111 degrees of freedom

Multiple R-squared: 0.574, Adjusted R-squared: 0.5587

F-statistic: 37.39 on 4 and 111 DF, p-value: < 2.2e-16

### Natural-SPLINE

- Realizamos una regresión n-spline con df=4.
- Esto significa que se consideran 3 knots (los percentiles 25,50 y 75 de Temp)

```
air.ns<-lm(Ozone~ns(Temp,df=4),data=airquality)
```

```
summary(air.ns)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	12.62	11.50	1.098	0.27469
ns(Temp, df = 4)1	13.04	11.44	1.141	0.25647
ns(Temp, df = 4)2	65.81	10.81	6.087	1.68e-08 ***
ns(Temp, df = 4)3	82.38	28.20	2.921	0.00423 **
ns(Temp, df = 4)4	79.33	12.73	6.231	8.55e-09 ***

Residual standard error: 22.14 on 111 degrees of freedom

(37 observations deleted due to missingness)

Multiple R-squared: 0.5651, Adjusted R-squared: 0.5495

F-statistic: 36.06 on 4 and 111 DF, p-value: < 2.2e-16

```

plot(airquality$Temp,airquality$Ozone, xlab="Temperature", ylab="Ozone",
main="Airquality")


new <- data.frame(Temp = seq(min(airquality$Temp),max(airquality$Temp),1))

lines(new$Temp,predict(air.bs,new),lty=1,col="red",lwd=3)

lines(new$Temp,predict(air.ns,new),lty=2,col="blue",lwd=3)

legend(60,120,c("bs (df=4)", "ns (df=4)"),col=c("red","blue"), lty=c(1,2),lwd=3)

```



## VENTAJAS /DESVENTAJAS DE LA REGRESIÓN SPLINE

### Ventajas:

- Es una regresión **paramétrica LOCAL**.
- Puede realizarse fácilmente con R, usando **lm** ó **glm**, pudiéndose aplicar a **cualquier tipo de respuesta** (continua, binaria, poisson,...).

### Desventajas:

- Debemos fijar de antemano:
  1. N<sup>º</sup> de knots **K** (ó equivalentemente los **df** del modelo).
  2. Localización de los knots.
- Todavía no existe un criterio automático totalmente óptimo para la selección y localización de los knots.
- Si el criterio es subjetivo, el investigador debe guiarse por el conocimiento del problema en cuestión.