


# Regresión y modelos lineales




Mike Wiper

Departamento de Estadística

Universidad Carlos III de Madrid

Grado en Estadística y Empresa

# Objetivo



Introducir el enfoque bayesiano a los modelos lineales.

# Modelos lineales

Un modelo lineal tiene forma:

$$y = X\beta + \epsilon$$

donde  $y = (y_1, \dots, y_n)^T$  es un vector de “outputs”,  $X$  es un  $n \times k$  matriz de diseño,  $\beta$  es un vector de  $k$  parámetros y  $\epsilon \sim \text{Normal}(0, \sigma^2 I_n)$  es un vector de errores aleatorios.

▶ MVN

Muchos modelos estándares son modelos lineales:

# Modelos lineales

Un modelo lineal tiene forma:

$$y = X\beta + \epsilon$$

donde  $y = (y_1, \dots, y_n)^T$  es un vector de "outputs",  $X$  es un  $n \times k$  matriz de diseño,  $\beta$  es un vector de  $k$  parámetros y  $\epsilon \sim \text{Normal}(0, \sigma^2 I_n)$  es un vector de errores aleatorios.

▶ MVN

Muchos modelos estándares son modelos lineales:

- Regresión lineal simple:  $y_i = \beta_0 + \beta_1 x_i + \epsilon_i$

$$X = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} \quad \beta = (\beta_0, \beta_1)^T$$

# Modelos lineales

Un modelo lineal tiene forma:

$$y = X\beta + \epsilon$$

donde  $y = (y_1, \dots, y_n)^T$  es un vector de "outputs",  $X$  es un  $n \times k$  matriz de diseño,  $\beta = (\beta_1, \dots, \beta_k)^T$  es un vector de parámetros y  $\epsilon \sim \text{Normal}(0, \sigma^2 I_n)$  es un vector de errores aleatorios.

Muchos modelos estándares son modelos lineales:

- Regresión múltiple:  $y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_{k-1} x_{i,k-1} + \epsilon_i$ .

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1,k-1} \\ 1 & x_{21} & x_{22} & \cdots & x_{2,k-1} \\ \vdots & \vdots & & & \\ 1 & x_{n1} & x_{n2} & \cdots & x_{n,k-1} \end{pmatrix} \quad \beta = (\beta_0, \beta_1, \dots, \beta_{k-1})^T$$

# Modelos lineales

Un modelo lineal tiene forma:

$$y = X\beta + \epsilon$$

donde  $y = (y_1, \dots, y_n)^T$  es un vector de “outputs”,  $X$  es un  $n \times k$  matriz de diseño,  $\beta = (\beta_1, \dots, \beta_k)^T$  es un vector de parámetros y  $\epsilon \sim \text{Normal}(0, \sigma^2 I_n)$  es un vector de errores aleatorios.

Muchos modelos estándares son modelos lineales:

- Análisis de varianza:  $y_{ij} = \mu + \tau_j + \epsilon_{ij}$  for  $i = 1, \dots, n_j$ ,  $j = 1, \dots, g$ .
- Análisis de covarianza:  $y = Z\alpha + X\beta + \epsilon$  donde  $Z$  es una matriz de 0s y 1s como en análisis de varianza y  $X$  es un matriz de diseño como en regresión.
- Modelos lineales mezclados, modelos autoregresivos, ...

# La función de verosimilitud para un modelo lineal

La verosimilitud es:

$$\begin{aligned}l(\boldsymbol{\mu}, \sigma^2 | \mathbf{y}) &= \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} \exp\left(-\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})\right) \\&\propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} \left[\mathbf{y}^T \mathbf{y} - 2\boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y} + \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{X} \boldsymbol{\beta}\right]\right) \\&\propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} \left[\mathbf{y}^T \mathbf{y} - 2\boldsymbol{\beta}^T (\mathbf{X}^T \mathbf{X}) (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} + \boldsymbol{\beta}^T (\mathbf{X}^T \mathbf{X}) \boldsymbol{\beta}\right]\right) \\&\propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} \left[\mathbf{y}^T \mathbf{y} - 2\boldsymbol{\beta}^T (\mathbf{X}^T \mathbf{X}) \hat{\boldsymbol{\beta}} + \boldsymbol{\beta}^T (\mathbf{X}^T \mathbf{X}) \boldsymbol{\beta}\right]\right)\end{aligned}$$

donde  $\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ . Luego, completando la forma cuadrática, tenemos:

$$\begin{aligned}l(\boldsymbol{\mu}, \sigma^2 | \mathbf{y}) &\propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} \left[\mathbf{y}^T \mathbf{y} - \hat{\boldsymbol{\beta}}^T (\mathbf{X}^T \mathbf{X}) \hat{\boldsymbol{\beta}} + (\boldsymbol{\beta} - \hat{\boldsymbol{\beta}})^T (\mathbf{X}^T \mathbf{X}) (\boldsymbol{\beta} - \hat{\boldsymbol{\beta}})\right]\right) \\&\propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} \left[(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) + (\boldsymbol{\beta} - \hat{\boldsymbol{\beta}})^T (\mathbf{X}^T \mathbf{X}) (\boldsymbol{\beta} - \hat{\boldsymbol{\beta}})\right]\right)\end{aligned}$$

# Inferencia frecuentista

El EMV de  $\beta$  es el estimador de mínimos cuadrados:

$$\hat{\beta} = (X^T X)^{-1} X^T y.$$

Típicamente se estima  $\sigma^2$  con el estimador insesgado:

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\text{suma de errores al cuadrado}}{n - \text{número de parámetros}} = \frac{1}{n - k} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\ &= \frac{1}{n - k} (y - X\hat{\beta})^T (y - X\hat{\beta})\end{aligned}$$

## Ejemplo: regresión lineal simple

En este caso:

$$X^T X = \begin{pmatrix} n & n\bar{x} \\ n\bar{x} & \sum_{i=1}^n x_i^2 \end{pmatrix}, \quad (X^T X)^{-1} = \frac{1}{(n-1)s_x^2} \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n x_i^2 & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}.$$


También,  $X^T y = \begin{pmatrix} n\bar{y} \\ \sum_{i=1}^n x_i y_i \end{pmatrix}$  y entonces, el EMV de  $\beta = (\beta_0, \beta_1)^T$  es

$$\hat{\beta}_1 = \frac{s_{xy}}{s_x^2}, \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}.$$

## Ejemplo: velocidades y tiempo necesario para parar de unos coches

```
help(cars)
data(cars)
plot(cars)
cor(cars$speed, cars$dist)
modelolineal <- lm(dist ~ speed, data=cars)
print(modelolineal)
abline(modelolineal, col='red', lwd=2)
anova(modelolineal)
xnuevo <- data.frame(20)
names(xnuevo) <- "speed"
predict(modelolineal, xnuevo, interval="confidence")
predict(modelolineal, xnuevo, interval="prediction")
```

# Ejemplo: velocidades y tiempo necesario para parar de unos coches



Coefficients:

(Intercept)	speed
-17.579	3.932

fit	lwr	upr
61.06908	55.24729	66.89088
61.06908	29.60309	92.53507

# Problemas

- Se necesitan más datos que parámetros.
- Dificultades con colinealidad.
- Se requiere que la matriz  $X^T X$  sea invertible.

Para mitigar los problemas, típicamente se utiliza penalización:

- Regresión de arista o regresión de Tíjonov

$$\text{minimizar : } \sum_i \left( y_i - \sum_j \beta_j x_{ij} \right)^2 + \lambda \sum_j \beta_j^2$$

- Lasso

$$\text{minimizar : } \sum_i \left( y_i - \sum_j \beta_j x_{ij} \right)^2 + \lambda \sum_j |\beta_j|.$$

# El enfoque bayesiano

Para el modelo bayesiano, es necesario definir distribuciones a priori para los parámetros,  $\beta$ , y la varianza del modelo,  $\sigma^2$

Existen varias posibilidades:

- A priori conjugada
- A priori “no informativa”
- A priori semi-conjugada o no conjugada.

# Una distribución a priori conjugada: la distribución normal-multivariante gamma

Sea  $\phi = \frac{1}{\sigma^2}$  y definimos una distribución normal-multivariante gamma para  $\beta, \phi$ :

$$\begin{aligned}\beta|\phi &\sim \text{Normal}\left(m, \frac{1}{\phi}V\right) \\ \phi &\sim \text{Gamma}\left(\frac{a}{2}, \frac{b}{2}\right)\end{aligned}$$

La distribución conjunta es

$$f(\beta, \phi) = \frac{\left(\frac{b}{2}\right)^{\frac{a}{2}}}{(2\pi)^{\frac{k}{2}} |V|^{\frac{1}{2}} \Gamma\left(\frac{a}{2}\right)} \phi^{\frac{a+k}{2}-1} \exp\left(-\frac{\phi}{2} [b + (\beta - m)^T V^{-1} (\beta - m)]\right)$$

# La distribución marginal de $\beta$

Integrando con respecto a  $\phi$ , tenemos:

$$\begin{aligned} f(\beta) &\propto (b + (\beta - m)^T V^{-1} (\beta - m))^{-\frac{a+k}{2}} \\ &\propto \left( 1 + \frac{1}{a} (\beta - m)^T \left( \frac{b}{a} V \right)^{-1} (\beta - m) \right)^{-\frac{a+k}{2}} \end{aligned}$$

que es una distribución t de Student multivariante escalada y no centrada.

La distribución t es bastante difícil de manejar pero observamos que es muy fácil simular de ello a través del Monte Carlo.

# La distribución a posteriori

Dada la muestra, se puede demostrar que la distribución a posteriori es normal-multivariante gamma con parámetros:

$$m^* = (V^{-1} + X^T X)^{-1} (V^{-1} m + X^T y)$$

$$V^* = (V^{-1} + X^T X)^{-1}$$

$$a^* = a + n$$

$$b^* = b + m^T V^{-1} m + y^T y - m^{*T} V^{*-1} m^*$$

# La distribución a posteriori

Dada la muestra, se puede demostrar que la distribución a posteriori es normal-multivariante gamma con parámetros:

$$\begin{aligned}m^* &= (V^{-1} + X^T X)^{-1} (V^{-1} m + X^T y) \\V^* &= (V^{-1} + X^T X)^{-1} \\a^* &= a + n \\b^* &= b + m^T V^{-1} m + y^T y - m^{*T} V^{*-1} m^*\end{aligned}$$

- Observamos que cuando el EMV existe, la media a posteriori es una media ponderada de la media a priori y el EMV:

$$E[\beta|y] = (V^{-1} + X^T X)^{-1} (V^{-1} m + (X^T X) \hat{\beta}).$$

- Cuando el EMV no existe, todavía se puede calcular la media a posteriori. De hecho, coincide con el estimador de regresión arista en el caso  $V = \frac{1}{\lambda} I$ .

# Predicción

Supongamos que queremos predecir una nueva observación  $\tilde{Y} = \sum_{i=1}^k \beta_i \tilde{x}_i + \tilde{\epsilon}$ .

Lo más sencillo es generar una muestra de la distribución a posteriori de  $\beta, \phi$  y después generar valores de  $\epsilon$  de una distribución normal con precisiones iguales a los  $\phi$  generados. Luego calculamos una muestra de  $\tilde{Y}$  directamente.

# Ejemplo

```
m <- c(0,1)
V <- 1000*diag(2)
Vinv <- solve(V)
a <- 1
b <- 1
X <- cars[,1]
n <- length(X)
X <- matrix(c(rep(1,n),X),nrow=n)
XTX <- t(X)%*%X
Vpost <- solve(XTX+Vinv)
y <- cars$dist
mpost <- Vpost%*%(Vinv%*%m+t(X)%*%y)
apost <- a+n
bpost <- b+t(m)%*%Vinv%*%m+t(y)%*%y-t(mpost)%*%solve(Vpost)%*%mpost
simuls <- 10000
library(MASS)
phi <- rgamma(simuls, apost/2, bpost/2)
beta <- matrix(rep(NA, simuls*2),nrow=simuls)
for (i in 1:simuls){
  beta[i,] <- mvrnorm(n = 1, mpost, Vpost/phi[i])
}
apply(beta, 2, mean)
apply(beta, 2, quantile, probs=c(0.025,0.975))
```

# Ejemplo

Estimaciones de los parámetros y intervalos de credibilidad:

-17.434286    3.925996

[,1]    [,2]

2.5%    -30.485629    3.113157

97.5%    -4.313447    4.733982

Predicciones de la media y de una nueva observación:

61.08564

2.5%    97.5%

55.40086    66.80101

2.5%    97.5%

30.48484    92.18414

# A priori no informativa

Como anteriormente, supongamos que  $f(\boldsymbol{\mu}, \phi) \propto \frac{1}{\phi}$ . Luego la distribución a posteriori es una normal multivariante gamma con parámetros:

$$\mathbf{m}^* = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = \hat{\boldsymbol{\beta}}$$

$$\mathbf{V}^* = (\mathbf{X}^T \mathbf{X})^{-1}$$

$$\mathbf{a}^* = \mathbf{a} + n - k$$

$$\mathbf{b}^* = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})$$

En este caso, si la matriz  $\mathbf{X}^T \mathbf{X}$  tiene inverso, la media a posteriori de  $\boldsymbol{\beta}$  coincide con el EMV. Si no tiene inverso, (cuando  $n \leq k$  o  $\mathbf{X}^T \mathbf{X}$  no es invertible) la distribución a posteriori es impropia.

## Ejemplo

Simulando de la a posteriori, tenemos estimaciones de los parámetros iguales (hasta el error de la simulación) a los EMV.

-17.574671    3.930448

[,1]    [,2]

2.5%   -30.780914   3.116529

97.5%   -4.501304   4.750646

Los intervalos predictivos son muy similares a las clásicas también.

61.03428

2.5%    97.5%

55.39266   66.65916

2.5%    97.5%

30.43020   91.23413

## A priori semi conjugada

En problemas modernos, típicamente se suponen a priori independientes para  $\beta$ ,  $\phi$ , por ejemplo  $\beta \sim \text{Normal}(m, V)$ .  $\phi \sim \text{Gamma}(\frac{a}{2}, \frac{b}{2})$ .

En este caso, usamos el muestreo de Gibbs para implementar la inferencia.

```
m <- c(0,1)
V <- 1000*diag(2)
a <- 1
b <- 1
library(MCMCpack)
cc <- MCMCregress(dist ~ speed, data=cars, burnin = 1000,
                  mcmc = 10000, thin = 1,
                  beta.start = modelolineal$coefficients,
                  marginal.likelihood = c("none"))
summary(cc)
```

# Ejemplo


1. Empirical mean and standard deviation for each variable, plus standard error of the mean:

	Mean	SD	Naive SE	Time-series SE
(Intercept)	-17.516	6.9119	0.069119	0.069119
speed	3.928	0.4265	0.004265	0.004265
sigma2	247.470	53.2858	0.532858	0.555348

2. Quantiles for each variable:

	2.5%	25%	50%	75%	97.5%
(Intercept)	-31.089	-22.041	-17.421	-12.954	-4.087
speed	3.085	3.648	3.926	4.202	4.766
sigma2	164.940	209.887	240.105	277.494	371.629

# Ejemplo: distribución predictiva de una nueva observación



# Resumen y siguiente sesión

En esta sesión, hemos ilustrado el enfoque bayesiano a modelos lineales y regresión.

$$P(Y = y|\lambda) = \frac{\lambda^y e^{-\lambda}}{y!}$$
$$\log \lambda = \sum_{i=1}^k x_i \beta_i$$

En la siguiente sesión, miraremos modelos lineales generalizados.

# Apéndice: La distribución normal multivariante

Una variable multivariante  $Y = (Y_1, \dots, Y_k)^T$  tiene una distribución normal multivariante con parámetros  $\boldsymbol{\mu} \in \mathbb{R}^k$  y  $\boldsymbol{\Sigma}$  una  $(k \times k)$  matriz positiva semi definida si

$$f(\mathbf{y}) = \frac{1}{(2\pi)^{\frac{k}{2}} |\boldsymbol{\Sigma}|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu})\right) \quad \forall \mathbf{y} \in \mathbb{R}^k$$

La media es  $E[Y] = \boldsymbol{\mu}$  y la matriz de covarianzas es  $V[Y] = \boldsymbol{\Sigma}$ .