

# AJUSTE DE CURVAS

# Contenido

- 1 Preliminares
  - Definiciones
- 2 Métodos de Ajuste de Curvas
  - Rectas de Regresión en Mínimos Cuadrados
  - El Ajuste Potencial  $y = Ax^M$
  - El Ajuste Exponencial  $y = Ce^{Ax}$
  - Combinaciones Lineales en Mínimos Cuadrados

# Contenido

- 1 Preliminares
  - Definiciones
- 2 Métodos de Ajuste de Curvas
  - Rectas de Regresión en Mínimos Cuadrados
  - El Ajuste Potencial  $y = Ax^M$
  - El Ajuste Exponencial  $y = Ce^{Ax}$
  - Combinaciones Lineales en Mínimos Cuadrados

# Definiciones

- En ciencias e ingeniería es frecuente que un experimento produzca un conjunto de datos  $(x_1, y_1), \dots, (x_N, y_N)$ , siendo las abscisas  $\{x_k\}$  distintas entre sí.
- Uno de los objetivos del cálculo numérico es la determinación de una fórmula  $y = f(x)$  que relacione las variables (*ajustar una curva a datos experimentales*).
- Normalmente se dispone de una serie de fórmulas previamente establecidas, y lo que hay que hallar son los valores más adecuados de unos coeficientes o unos parámetros para estas fórmulas.

# Definiciones

- En ciencias e ingeniería es frecuente que un experimento produzca un conjunto de datos  $(x_1, y_1), \dots, (x_N, y_N)$ , siendo las abscisas  $\{x_k\}$  distintas entre sí.
- Uno de los objetivos del cálculo numérico es la determinación de una fórmula  $y = f(x)$  que relacione las variables (*ajustar una curva a datos experimentales*).
- Normalmente se dispone de una serie de fórmulas previamente establecidas, y lo que hay que hallar son los valores más adecuados de unos coeficientes o unos parámetros para estas fórmulas.

# Definiciones

- En ciencias e ingeniería es frecuente que un experimento produzca un conjunto de datos  $(x_1, y_1), \dots, (x_N, y_N)$ , siendo las abscisas  $\{x_k\}$  distintas entre sí.
- Uno de los objetivos del cálculo numérico es la determinación de una fórmula  $y = f(x)$  que relacione las variables (*ajustar una curva a datos experimentales*).
- Normalmente se dispone de una serie de fórmulas previamente establecidas, y lo que hay que hallar son los valores más adecuados de unos coeficientes o unos parámetros para estas fórmulas.

# Definiciones

## Definición

Se definen los *errores* o *desviaciones* o *residuos* así:

$$e_k = f(x_k) - y_k; 1 \leq k \leq N.$$

Se definen las siguientes normas que se pueden usar con los residuos para medir la distancia entre la curva  $y = f(x)$  y los datos:

*Error Máximo:*

$$E_{\infty}(f) = \max \{ |f(x_k) - y_k| : 1 \leq k \leq N \},$$

# Definiciones

*Error Medio:*

$$E_1(f) = \frac{1}{N} \sum_{k=1}^N |f(x_k) - y_k|,$$

*Error Cuadrático Medio:*

$$E_2(f) = \left( \frac{1}{N} \sum_{k=1}^N |f(x_k) - y_k|^2 \right)^{1/2}. \quad (1)$$



# Contenido

- 1 Preliminares
  - Definiciones
- 2 Métodos de Ajuste de Curvas
  - Rectas de Regresión en Mínimos Cuadrados
  - El Ajuste Potencial  $y = Ax^M$
  - El Ajuste Exponencial  $y = Ce^{Ax}$
  - Combinaciones Lineales en Mínimos Cuadrados

# Rectas de Regresión en Mínimos Cuadrados

## Definición

Sea  $\{(x_k, y_k)\}_{k=1}^N$  un conjunto de  $N$  puntos cuyas abcisas  $\{x_k\}$  son todas distintas. La *recta de regresión* o *recta óptima* en (el sentido de los) *mínimos cuadrados* es la recta de ecuación  $y = f(x) = Ax + B$  que minimiza el error cuadrático medio  $E_2(f)$ .

# Rectas de Regresión en Mínimos Cuadrados

De (1), notar que  $E_2(f)$  será mínima sii lo es

$$N(E_2(f))^2 = \sum_{k=1}^N (Ax_k + B - y_k)^2.$$

Geoméricamente es la suma de los cuadrados de las distancias verticales desde los puntos  $\{(x_k, y_k)\}$  hasta la recta  $y = Ax + B$ .

# Rectas de Regresión en Mínimos Cuadrados

## Teorema: Recta de Regresión en Mínimos Cuadrados

Sean  $\{(x_k, y_k)\}_{k=1}^N$   $N$  puntos cuyas abcisas  $\{x_k\}_{k=1}^N$  son distintas. Entonces, los coeficientes de la recta de regresión

$$y = Ax + B$$

son la solución del siguiente sistema lineal, conocido como las *ecuaciones normales de Gauss*:

$$\begin{aligned} \left( \sum_{k=1}^N x_k^2 \right) A + \left( \sum_{k=1}^N x_k \right) B &= \sum_{k=1}^N x_k y_k, \\ \left( \sum_{k=1}^N x_k \right) A + NB &= \sum_{k=1}^N y_k. \end{aligned}$$

# Contenido

- 1 Preliminares
  - Definiciones
- 2 Métodos de Ajuste de Curvas
  - Rectas de Regresión en Mínimos Cuadrados
  - El Ajuste Potencial  $y = Ax^M$
  - El Ajuste Exponencial  $y = Ce^{Ax}$
  - Combinaciones Lineales en Mínimos Cuadrados

# El Ajuste Potencial $y = Ax^M$

Algunas situaciones se modelan mediante una función del tipo  $f(x) = Ax^M$ , donde  $M$  es una constante conocida. En estos casos solo hay que determinar un parámetro.

# El Ajuste Potencial $y = Ax^M$

## Teorema: Ajuste Potencial

Supongamos que tenemos  $N$  puntos  $\{(x_k, y_k)\}_{k=1}^N$  cuyas abscisas son distintas. Entonces, el coeficiente  $A$  de la curva potencial óptima en mínimos cuadrados  $y = Ax^M$  viene dado por

$$A = \frac{\left(\sum_{k=1}^N x_k^M y_k\right)}{\left(\sum_{k=1}^N x_k^{2M}\right)}.$$

# Contenido

- 1 Preliminares
  - Definiciones
- 2 Métodos de Ajuste de Curvas
  - Rectas de Regresión en Mínimos Cuadrados
  - El Ajuste Potencial  $y = Ax^M$
  - El Ajuste Exponencial  $y = Ce^{Ax}$
  - Combinaciones Lineales en Mínimos Cuadrados



# El Ajuste Exponencial $y = Ce^{Ax}$

Se desea ajustar una curva exponencial de la forma

$$y = Ce^{Ax} \quad (2)$$

a un conjunto de puntos  $\{(x_k, y_k)\}_{k=1}^N$  dado de antemano.

## Opción 1: El método de linealización de los datos

Tomando logaritmos en (2):

$$\ln(y) = Ax + \ln(C).$$

Haciendo un cambio de variables (y de constante):

$$Y = \ln(y), X = x, B = \ln(C),$$

se obtiene una relación lineal entre las nuevas variables X y Y:

$$Y = AX + B. \tag{3}$$

## Opción 1: El método de linealización de los datos

Tomando logaritmos en (2):

$$\ln(y) = Ax + \ln(C).$$

Haciendo un cambio de variables (y de constante):

$$Y = \ln(y), X = x, B = \ln(C),$$

se obtiene una relación lineal entre las nuevas variables X y Y:

$$Y = AX + B. \tag{3}$$

## Opción 1: El método de linealización de los datos

Tomando logaritmos en (2):

$$\ln(y) = Ax + \ln(C).$$

Haciendo un cambio de variables (y de constante):

$$Y = \ln(y), X = x, B = \ln(C),$$

se obtiene una relación lineal entre las nuevas variables X y Y:

$$Y = AX + B. \quad (3)$$

## Opción 1: El método de linealización de los datos

Ahora se calcula la recta de regresión (3) para los puntos  $\{(X_k, Y_k)\}$ , para lo que planteamos las correspondientes ecuaciones normales de Gauss

$$\begin{aligned}\left(\sum_{k=1}^N X_k^2\right) A + \left(\sum_{k=1}^N X_k\right) B &= \sum_{k=1}^N X_k Y_k, \\ \left(\sum_{k=1}^N X_k\right) A + NB &= \sum_{k=1}^N Y_k,\end{aligned}$$

que constituyen un sistema de ecuaciones *lineales* para las incógnitas A y C. Una vez calculados A y B, hallamos el parámetro C de (2):  $C = e^B$ .

## Opción 2: El método no lineal de los mínimos cuadrados

Se debe hallar el mínimo de la función

$$E(A, C) = \sum_{k=1}^N \left( Ce^{Ax_k} - y_k \right)^2.$$

Para ello, hallamos las derivadas parciales

$$\frac{\partial E}{\partial A} = 2 \sum_{k=1}^N \left( Ce^{Ax_k} - y_k \right) Cx_k e^{Ax_k},$$

$$\frac{\partial E}{\partial C} = 2 \sum_{k=1}^N \left( Ce^{Ax_k} - y_k \right) e^{Ax_k}.$$

## Opción 2: El método no lineal de los mínimos cuadrados

Se debe hallar el mínimo de la función

$$E(A, C) = \sum_{k=1}^N \left( Ce^{Ax_k} - y_k \right)^2.$$

Para ello, hallamos las derivadas parciales

$$\frac{\partial E}{\partial A} = 2 \sum_{k=1}^N \left( Ce^{Ax_k} - y_k \right) Cx_k e^{Ax_k},$$

$$\frac{\partial E}{\partial C} = 2 \sum_{k=1}^N \left( Ce^{Ax_k} - y_k \right) e^{Ax_k}.$$

## Opción 2: El método no lineal de los mínimos cuadrados

Igualando a cero obtenemos las ecuaciones normales

$$C \sum_{k=1}^N x_k e^{2Ax_k} - \sum_{k=1}^N x_k y_k e^{Ax_k} = 0,$$
$$C \sum_{k=1}^N e^{2Ax_k} - \sum_{k=1}^N y_k e^{Ax_k} = 0,$$

que es un sistema de ecuaciones *no lineales* para las incógnitas A y C.



## Opción 2: El método no lineal de los mínimos cuadrados

- Se puede resolver este sistema con el método iterativo de Newton-Raphson.
- Se pueden utilizar métodos para minimizar funciones de varias variables, para hallar el mínimo de la función  $E(A, C)$  directamente. Por ejemplo, el de Nelder-Mead. En este caso, no se necesita calcular las derivadas parciales.

## Opción 2: El método no lineal de los mínimos cuadrados

- Se puede resolver este sistema con el método iterativo de Newton-Raphson.
- Se pueden utilizar métodos para minimizar funciones de varias variables, para hallar el mínimo de la función  $E(A, C)$  directamente. Por ejemplo, el de Nelder-Mead. En este caso, no se necesita calcular las derivadas parciales.

# Contenido

- 1 Preliminares
  - Definiciones
- 2 Métodos de Ajuste de Curvas
  - Rectas de Regresión en Mínimos Cuadrados
  - El Ajuste Potencial  $y = Ax^M$
  - El Ajuste Exponencial  $y = Ce^{Ax}$
  - Combinaciones Lineales en Mínimos Cuadrados

# Combinaciones Lineales en Mínimos Cuadrados

Este problema se formula así: Dados  $N$  puntos  $\{(x_k, y_k)\}$  y un conjunto de  $M$  funciones linealmente independientes  $\{f_j(x)\}$ , encontrar  $M$  coeficientes  $\{c_j\}$  tales que la función  $f(x)$  definida como la combinación lineal

$$f(x) = \sum_{j=1}^M c_j f_j(x)$$

minimice la suma de los cuadrados de los errores

$$E(c_1, c_2, \dots, c_M) = \sum_{k=1}^N (f(x_k) - y_k)^2 = \sum_{k=1}^N \left( \left( \sum_{j=1}^M c_j f_j(x_k) \right) - y_k \right)^2 .$$

# Combinaciones Lineales en Mínimos Cuadrados

Para que  $E$  alcance un mínimo en un punto,  $\{c_j\}$  debe ser la solución del sistema de ecuaciones lineales:

$$\begin{aligned} \frac{\partial E}{\partial C_i} &= \sum_{k=1}^N \left( \left( \sum_{j=1}^M c_j f_j(x_k) \right) - y_k \right) (f_i(x_k)) = 0; \quad i = 1, 2, \dots, M \\ \Rightarrow \sum_{j=1}^M \left( \sum_{k=1}^N f_i(x_k) f_j(x_k) \right) c_j &= \sum_{k=1}^N f_i(x_k) y_k; \quad i = 1, 2, \dots, M, \end{aligned} \quad (4)$$

llamadas *ecuaciones normales de Gauss*. Es un sistema de ecuaciones lineales de orden  $M \times M$ . Las incógnitas son los coeficientes  $\{c_j\}$ .

## Formulación Matricial

Si se define

$$\mathbf{F} = \begin{bmatrix} f_1(x_1) & f_2(x_1) & \dots & f_M(x_1) \\ f_1(x_2) & f_2(x_2) & \dots & f_M(x_2) \\ f_1(x_3) & f_2(x_3) & \dots & f_M(x_3) \\ \dots & \dots & \dots & \dots \\ f_1(x_N) & f_2(x_N) & \dots & f_M(x_N) \end{bmatrix}, \mathbf{F}' = \begin{bmatrix} f_1(x_1) & f_1(x_2) & f_1(x_3) & \dots & f_1(x_N) \\ f_2(x_1) & f_2(x_2) & f_2(x_3) & \dots & f_2(x_N) \\ \dots & \dots & \dots & \dots & \dots \\ f_M(x_1) & f_M(x_2) & f_M(x_3) & \dots & f_M(x_N) \end{bmatrix},$$

$$\mathbf{C} = \begin{bmatrix} c_1 \\ c_2 \\ \dots \\ c_M \end{bmatrix}, \mathbf{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_N \end{bmatrix},$$

entonces (4) se puede escribir como

$$\mathbf{F}'\mathbf{F}\mathbf{C} = \mathbf{F}'\mathbf{Y},$$

cuya incógnita es  $\mathbf{C}$ .

# Ajuste Polinomial

Cuando el método que se acaba de describir se aplica al caso en el que se tienen  $M+1$  funciones dadas por  $\{f_j(x) = x^{j-1}\}$ , la función  $f(x)$  será un polinomio de grado  $\leq M$ :

$$f(x) = c_1 + c_2x + c_3x^2 + \dots + c_{M+1}x^M.$$

# Ajuste Polinomial

## Teorema: Parábola óptima en mínimos cuadrados

Suponer que se tienen  $N$  puntos  $\{(x_k, y_k)\}_{k=1}^N$  cuyas abcisas son todas distintas. Los coeficientes de la parábola de ecuación

$$y = f(x) = Ax^2 + Bx + C$$

que mejor se ajusta a dichos puntos en el sentido de los mínimos cuadrados son las soluciones  $A$ ,  $B$  y  $C$  del sistema de ecuaciones lineales



# Ajuste Polinomial

$$\begin{aligned} \left( \sum_{k=1}^N x_k^4 \right) A + \left( \sum_{k=1}^N x_k^3 \right) B + \left( \sum_{k=1}^N x_k^2 \right) C &= \sum_{k=1}^N y_k x_k^2, \\ \left( \sum_{k=1}^N x_k^3 \right) A + \left( \sum_{k=1}^N x_k^2 \right) B + \left( \sum_{k=1}^N x_k \right) C &= \sum_{k=1}^N y_k x_k, \\ \left( \sum_{k=1}^N x_k^2 \right) A + \left( \sum_{k=1}^N x_k \right) B + NC &= \sum_{k=1}^N y_k. \end{aligned}$$

# Bibliografía

-  MATHEWS, John; KURTIS, Fink.  
*Métodos Numéricos con MATLAB.*  
Prentice Hall, 2000.