

Contenidos

- ▶ 5.1: Diagnóstico: Análisis de los residuos
- ▶ 5.2: La descomposición ANOVA (ANalysis Of VAriance)
- ▶ 5.3: Relaciones no lineales y transformaciones para linealización
- ▶ 5.4: El modelo de regresión lineal en forma matricial
- ▶ 5.5: Introducción a la regresión lineal múltiple



Bibliografía

- ▶ Newbold, P. Estadística para los Negocios y la Economía (1997).
 - ▶ Capítulos 12, 13 y 14
- ▶ Peña, D. Regresión y Diseño de Experimentos (2002).
 - ▶ Capítulos 5 y 6



5.1. Diagnóstico en regresión

- ▶ **Supuestos teóricos** del modelo de regresión lineal simple de una var. respuesta y sobre una var. explicativa x :
 - Linealidad: $y_i = \beta_0 + \beta_1 x_i + u_i$, para $i = 1, \dots, n$
 - Homogeneidad: $E[u_i] = 0$, para $i = 1, \dots, n$
 - Homocedasticidad: $\text{Var}[u_i] = \sigma^2$, para $i = 1, \dots, n$
 - Independencia: u_i y u_j son independientes para $i \neq j$
 - Normalidad: $u_i \sim \text{Normal}(0, \sigma^2)$, para $i = 1, \dots, n$
- ▶ Los **métodos de diagnóstico** se utilizan para contrastar si tales supuestos son adecuados para los datos disponibles (x_i, y_i) ; se basan en el **análisis de los residuos** $e_i = y_i - \hat{y}_i$



5.1. Diagnóstico: diagrama de puntos

- ▶ El método más sencillo consiste en la observación visual del **diagrama de puntos** (x_i, y_i)
- ▶ A menudo, este sencillo pero potente método revela pautas que sugieren si el modelo teórico es o no adecuado
- ▶ Ilustraremos su uso con un ejemplo clásico. Consideremos los cuatro conjuntos de datos siguientes



5.1. Diagnóstico: diagrama de puntos

TABLE 3-10
Four Data Sets

| DATA SET 1 | | DATA SET 2 | |
|------------|-------|------------|------|
| X | Y | X | Y |
| 10.0 | 8.04 | 10.0 | 9.14 |
| 8.0 | 6.95 | 8.0 | 8.14 |
| 13.0 | 7.58 | 13.0 | 8.74 |
| 9.0 | 8.81 | 9.0 | 8.77 |
| 11.0 | 8.33 | 11.0 | 9.26 |
| 14.0 | 9.96 | 14.0 | 8.10 |
| 6.0 | 7.24 | 6.0 | 6.13 |
| 4.0 | 4.26 | 4.0 | 3.10 |
| 12.0 | 10.84 | 12.0 | 9.13 |
| 7.0 | 4.82 | 7.0 | 7.26 |
| 5.0 | 5.68 | 5.0 | 4.74 |

| DATA SET 3 | | DATA SET 4 | |
|------------|-------|------------|-------|
| X | Y | X | Y |
| 10.0 | 7.46 | 8.0 | 6.58 |
| 8.0 | 6.77 | 8.0 | 5.76 |
| 13.0 | 12.74 | 8.0 | 7.71 |
| 9.0 | 7.11 | 8.0 | 8.84 |
| 11.0 | 7.81 | 8.0 | 8.47 |
| 14.0 | 8.84 | 8.0 | 7.04 |
| 6.0 | 6.08 | 8.0 | 5.25 |
| 4.0 | 5.39 | 19.0 | 12.50 |
| 12.0 | 8.15 | 8.0 | 5.56 |
| 7.0 | 6.42 | 8.0 | 7.91 |
| 5.0 | 5.73 | 8.0 | 6.89 |

SOURCE: F. J. Anscombe, *op. cit.*



5.1. Diagnóstico: diagrama de puntos

- ▶ Para cada uno de los cuatro conjuntos de datos anteriores, se obtiene el mismo modelo estimado de regresión lineal:
- ▶ $\hat{y}_i = 3.0 + 0.5x_i$
- ▶ $n = 11$, $\bar{x} = 9.0$, $\bar{y} = 7.5$, $r_{x,y} = 0.817$
- ▶ El **error estándar** estimado del estimador $\hat{\beta}_1$,

$$\sqrt{\frac{s_R^2}{(n-1)s_x^2}},$$

toma el valor 0.118. El estadístico T correspondiente toma el valor $T = 0.5/0.118 = 4.237$

- ▶ Sin embargo, los diagramas de puntos correspondientes revelan que los cuatro conjuntos de datos son cualitativamente muy diferentes: ¿Qué conclusiones podemos extraer de estos diagramas?



5.1. Diagnóstico: diagrama de puntos




FIGURE 3-29 Scatterplots for the four data sets of Table 3-10
SOURCE: F. J. Anscombe, *op cit.*

5.1: análisis de los residuos

- ▶ Si la observación del diagrama de puntos no basta para descartar el modelo, se utilizan métodos de diagnóstico basados en el **análisis de los residuos** $e_i = y_i - \hat{y}_i$
- ▶ El análisis comienza **tipificando** los residuos (dividiéndolos por la cuasi-desviación típica residual): Las cantidades resultantes se denominan **residuos tipificados**:


$$\frac{e_i}{S_R}$$

- ▶ Bajo los supuestos del modelo de regresión lineal, los residuos tipificados son aproximadamente variables aleatorias normales estándar independientes
- ▶ Un gráfico de los residuos tipificados no debería mostrar ninguna pauta clara


5.1: Diagramas de residuos

- ▶ Hay varios tipos de diagramas de residuos. Los más comunes son:
 - Diagrama de los residuos vs. x
 - Diagrama de los residuos vs. \hat{y}
- ▶ Las desviaciones de los supuestos del modelo dan lugar a pautas, que se pueden identificar visualmente

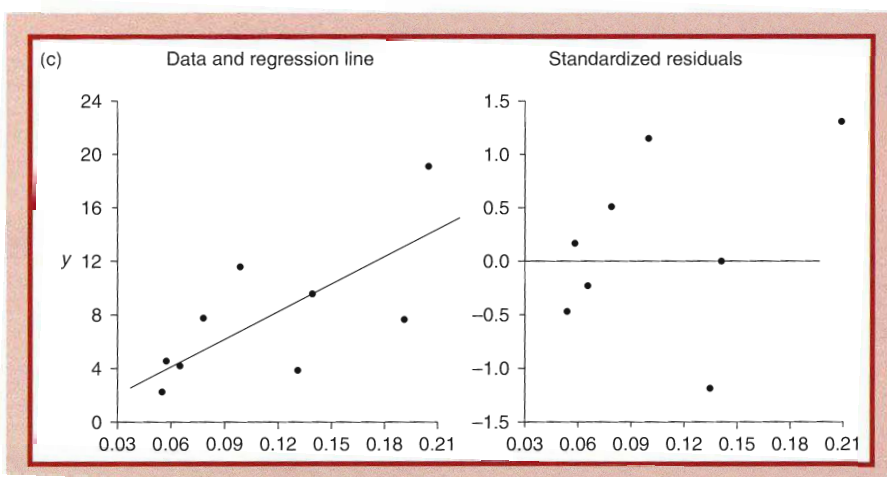
5.1: Ej: consistencia con el modelo teórico



5.1: Ej: No linealidad



5.1: Ej: Heterocedasticidad



5.1: Datos atípicos

- ▶ A partir del gráfico de la recta de regresión podemos observar **datos atípicos**, que presentan desviaciones sustanciales de la recta de regresión
- ▶ Los estimadores $\hat{\beta}_0$ y $\hat{\beta}_1$ de los parámetros de la recta de regresión son muy sensibles a tales datos atípicos
- ▶ Por ello, es importante identificar tales datos y comprobar si son válidos



5.1: Normalidad de los errores

- ▶ Recordemos que uno de los supuestos teóricos del modelo de regresión lineal es que los errores tienen una distribución normal
- ▶ Podemos comprobar este supuesto visualmente a partir de la observación y análisis de los residuos e_j , empleando varios métodos:
 - ▶ Observación del histograma de frecuencias de los residuos
 - ▶ Observación de un “*Normal Probability Plot*” para los residuos (desviaciones importantes de los datos de la línea recta en este gráfico indican desviaciones sustanciales del supuesto de normalidad)



5.2: La descomposición ANOVA

- ▶ ANOVA: *ANalysis Of VAriance*
- ▶ Al ajustar un modelo de regresión lineal $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ a un conjunto de datos (x_i, y_i) , para $i = 1, \dots, n$, podemos distinguir tres **fuentes de variación** en las respuestas:
 - **variación debida al modelo**: $SCM = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$, donde las siglas “SC” se refieren a “suma de cuadrados”, y la “M” se refiere al “Modelo”
 - **variación residual**: $SCR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n e_i^2$
 - **variación total**: $SCT = \sum_{i=1}^n (y_i - \bar{y})^2$
- ▶ La descomposición ANOVA indica que $SCT = SCM + SCR$



5.2: El coeficiente de determinación R^2

- ▶ La descomposición ANOVA indica que $SCT = SCM + SCR$
- ▶ Notemos que: $y_i - \bar{y} = (y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})$
- ▶ $SCM = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ mide la variación de las respuestas debida a la regresión (explicada por los valores predichos \hat{y})
- ▶ Por lo tanto, el cociente SCR/SCT es la proporción de variación de la respuesta no explicada por la regresión
- ▶ El cociente $R^2 = SCM/SCT = 1 - SCR/SCT$ es la proporción de variación de las respuestas explicada por la regresión; se conoce como **coeficiente de determinación**
- ▶ Resultado: $R^2 = r_{xy}^2$ (coef. de correlación al cuadrado)
- ▶ Ej: si $R^2 = 0.85$, la variable x explica un 85% de la variación de la variable y



5.2: Tabla ANOVA

| Fuente de variación | SC | G.L. | Media | Cociente F |
|---------------------|-----|---------|------------------------|--------------|
| Modelo | SCM | 1 | SCM/1 | SCM/ s_R^2 |
| Residuos/Errores | SCR | $n - 2$ | SCR/ $(n - 2) = s_R^2$ | |
| Total | SCT | $n - 1$ | | |



5.2: Contraste de hipótesis ANOVA

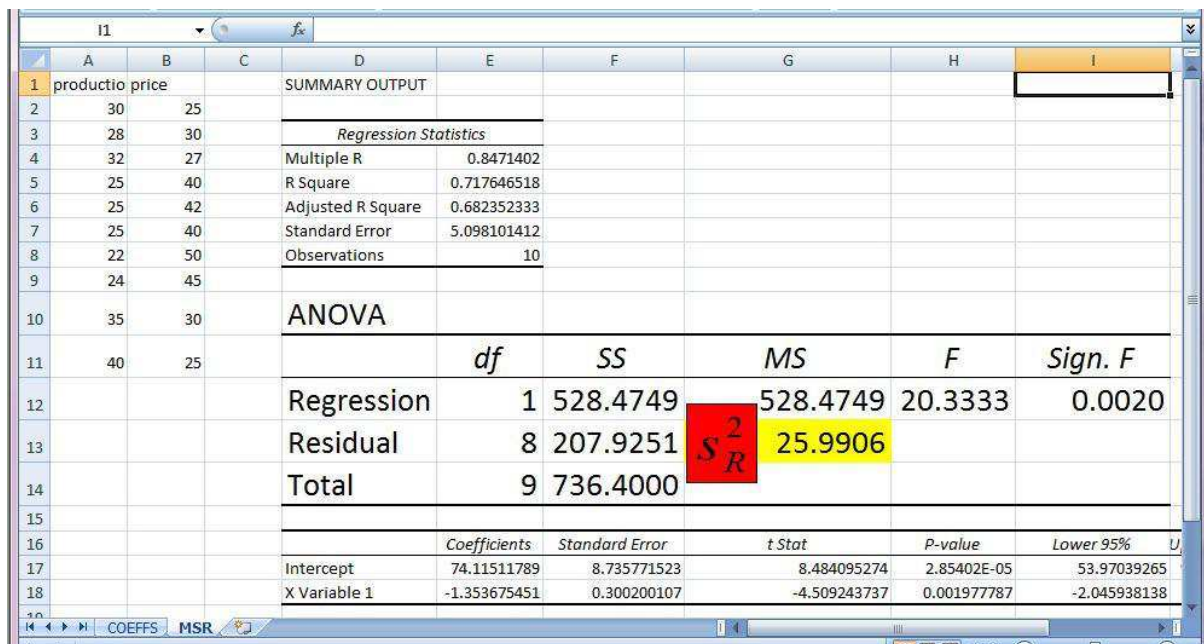
- ▶ Contraste de hipótesis $H_0: \beta_1 = 0$ vs. $H_1: \beta_1 \neq 0$
- ▶ Consideremos el cociente

$$F = \frac{\text{SCM}/1}{\text{SCR}/(n-2)} = \frac{\text{SCM}}{s_R^2}$$

- ▶ Bajo H_0 , F sigue una distribución $F_{1, n-2}$
- ▶ Contraste a nivel α : rechazar H_0 si $F > F_{1, n-2; \alpha}$
- ▶ ¿Cuál es la relación con el contraste basado en la t de Student que vimos en el Tema 4? **Son equivalentes**



5.2: Ej. ANOVA



| Regression Statistics | |
|-----------------------|-------------|
| Multiple R | 0.8471402 |
| R Square | 0.717646518 |
| Adjusted R Square | 0.682352333 |
| Standard Error | 5.098101412 |
| Observations | 10 |

| ANOVA | | | | | |
|------------|----|----------|----------|---------|---------|
| | df | SS | MS | F | Sign. F |
| Regression | 1 | 528.4749 | 528.4749 | 20.3333 | 0.0020 |
| Residual | 8 | 207.9251 | 25.9906 | | |
| Total | 9 | 736.4000 | | | |

| | Coefficients | Standard Error | t Stat | P-value | Lower 95% |
|--------------|--------------|----------------|--------------|-------------|--------------|
| Intercept | 74.11511789 | 8.735771523 | 8.484095274 | 2.85402E-05 | 53.97039265 |
| X Variable 1 | -1.353675451 | 0.300200107 | -4.509243737 | 0.001977787 | -2.045938138 |

5.3: Relaciones no lineales y linealización

- ▶ Supongamos que la parte determinista $f(x_i; a, b)$ de la respuesta en el modelo

$$y_i = f(x_i; a, b) + u_i, \quad i = 1, \dots, n$$

es una **función no lineal** de x que depende de dos parámetros a y b (ej: $f(x; a, b) = ab^x$)

- ▶ En algunos casos podemos aplicar **transformaciones** a los datos para **linearizarlos**, y así poder aplicar los métodos de regresión lineal
- ▶ A partir de los datos (x_i, y_i) originales, obtenemos los datos transformados (x'_i, y'_i)
- ▶ Los parámetros β_0 y β_1 de la relación lineal entre las x'_i y las y'_i se obtienen como transformaciones de los parámetros a y b

5.3: Transformaciones para linealización

- ▶ Ejemplos de transformaciones para linealización:
 - ▶ Si $y = f(x; a, b) = ax^b$ entonces $\log y = \log a + b \log x$: tomamos $y' = \log y$, $x' = \log x$, $\beta_0 = \log a$, $\beta_1 = b$
 - ▶ Si $y = f(x; a, b) = ab^x$ entonces $\log y = \log a + (\log b)x$: tomamos $y' = \log y$, $x' = x$, $\beta_0 = \log a$, $\beta_1 = \log b$
 - ▶ Si $y = f(x; a, b) = 1/(a + bx)$ entonces $1/y = a + bx$: tomamos $y' = 1/y$, $x' = x$, $\beta_0 = a$, $\beta_1 = b$
 - ▶ Si $y = f(x; a, b) = \ln(ax^b)$ entonces $y = \ln a + b \ln x$: tomamos $y' = y$, $x' = \ln x$, $\beta_0 = \ln a$, $\beta_1 = b$



5.4: Regresión lineal en forma matricial

- ▶ Recordemos el modelo de regresión lineal simple:

$$y_i = \beta_0 + \beta_1 x_i + u_i, \quad i = 1, \dots, n$$

- ▶ Escribiendo una ecuación para cada observación obtenemos

$$y_1 = \beta_0 + \beta_1 x_1 + u_1$$

$$y_2 = \beta_0 + \beta_1 x_2 + u_2$$

⋮

$$y_n = \beta_0 + \beta_1 x_n + u_n$$



5.4: Regresión lineal en forma matricial

- ▶ En forma matricial, podemos escribir

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 x_1 \\ \beta_0 + \beta_1 x_2 \\ \vdots \\ \beta_0 + \beta_1 x_n \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix},$$

o, separando los parámetros β_j de las x_i ,

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix},$$



5.4: Regresión lineal en forma matricial

- ▶ Escribimos la relación matricial

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix},$$

como

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

- ▶ \mathbf{y} : vector de respuestas; \mathbf{X} : matriz de variables explicativas (o del diseño experimental); $\boldsymbol{\beta}$: vector de parámetros; \mathbf{u} : vector de errores



5.4: La matriz de covarianzas de los errores

- ▶ Denotamos por $\text{Cov}(\mathbf{u})$ la matriz $n \times n$ de covarianzas de los errores; su elemento (i, j) es

$$\text{cov}(u_i, u_j) = \begin{cases} 0 & \text{si } i \neq j \\ \text{Var}[u_i] = \sigma^2 & \text{si } i = j \end{cases}$$

- ▶ $\text{Cov}(\mathbf{u})$ es la matriz identidad $\mathbf{I}_{n \times n}$ multiplicada por σ^2 :

$$\text{Cov}(\mathbf{u}) = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \mathbf{I}$$



5.4: Estimación de mínimos cuadrados

- ▶ El vector estimado $\hat{\beta}$ de mínimos cuadrados es la solución única de la ecuación matricial 2×2 (comprueba las dimensiones)

$$(\mathbf{X}^T \mathbf{X}) \hat{\beta} = \mathbf{X}^T \mathbf{y},$$

es decir,

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

- ▶ El vector $\hat{\mathbf{y}} = (\hat{y}_i)$ de respuestas estimadas es

$$\hat{\mathbf{y}} = \mathbf{X} \hat{\beta}$$

y el vector de residuos es $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}}$



5.5: El modelo de regresión lineal múltiple

- ▶ Modelo de regresión lineal simple: predecir una respuesta y a partir de una variable explicativa x
- ▶ En numerosas aplicaciones, buscamos predecir la respuesta y a partir de múltiples variables explicativas x_1, \dots, x_k
- ▶ Ej: predecir el precio de una casa en función de su superficie, localización, planta, y número de baños
- ▶ Ej: predecir el tamaño de un parlamento en función de la población, su tasa de crecimiento, el número de partidos políticos con representación, etc.



5.5: El modelo de regresión lineal múltiple

- ▶ Modelo de regresión lineal múltiple: predecir una respuesta y a partir de múltiples variables explicativas x_1, \dots, x_k
- ▶ Tenemos n observaciones: para $i = 1, \dots, n$,

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i$$

- ▶ Suponemos que las u_i son v.a. independientes con distribución Normal($0, \sigma^2$)



5.5: Ajuste de mínimos cuadrados

- ▶ Tenemos n observaciones: para $i = 1, \dots, n$,

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i$$

- ▶ Buscamos ajustar a los datos $(x_{i1}, x_{i2}, \dots, x_{ik}, y_i)$ un hiperplano de la forma

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik}$$

- ▶ El **residuo** para la observación i es: $e_i = y_i - \hat{y}_i$
- ▶ Utilizamos la estimación de los parámetros $\hat{\beta}_j$ que minimiza la suma de los cuadrados de los residuos



5.5: Modelo en forma matricial

- ▶ Escribimos la relación matricial

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix},$$

como

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

- ▶ \mathbf{y} : vector de respuestas; \mathbf{X} : matriz de variables explicativas (o del diseño experimental); $\boldsymbol{\beta}$: vector de parámetros; \mathbf{u} : vector de errores



5.5: Estimación de mínimos cuadrados de β

- ▶ El vector estimado $\hat{\beta}$ de mínimos cuadrados es la solución única de la ecuación matricial $(k + 1) \times (k + 1)$ (comprueba las dimensiones)

$$(\mathbf{X}^T \mathbf{X}) \hat{\beta} = \mathbf{X}^T \mathbf{y},$$

como en el caso $k = 1$ visto anteriormente, es decir,

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

- ▶ El vector $\hat{\mathbf{y}} = (\hat{y}_i)$ de respuestas estimadas es

$$\hat{\mathbf{y}} = \mathbf{X} \hat{\beta}$$

y el vector de residuos es $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}}$



5.5: Estimación de la varianza σ^2

- ▶ Para el modelo de regresión lineal múltiple, estimamos la varianza σ^2 mediante la cuasi-varianza residual,

$$s_R^2 = \frac{\sum_{i=1}^n e_i^2}{n - k - 1},$$

que es un estimador insesgado (nótese que para regresión lineal simple el denominador vale $n - 2$)



5.5: Distribución muestral de $\hat{\beta}$

- ▶ Bajo los supuestos del modelo, el estimador de mínimos cuadrados $\hat{\beta}$ del vector de parámetros β sigue una distribución **normal multivariante**
- ▶ $E[\hat{\beta}] = \beta$ (i.e., es un estimador insesgado)
- ▶ La matriz de covarianzas de $\hat{\beta}$ es $\text{Cov}(\hat{\beta}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}$
- ▶ Estimamos $\text{Cov}(\hat{\beta})$ por $s_R^2 (\mathbf{X}^T \mathbf{X})^{-1}$
- ▶ La estimación de $\text{Cov}(\hat{\beta})$ nos da estimaciones $s^2(\hat{\beta}_j)$ de la varianza $\text{Var}(\hat{\beta}_j)$; $s(\hat{\beta}_j)$ es el **error estándar** del estimador $\hat{\beta}_j$
- ▶ Al tipificar $\hat{\beta}_j$ obtenemos: $\frac{\hat{\beta}_j - \beta_j}{s(\hat{\beta}_j)} \sim t_{n-k-1}$ (*t* de Student)



5.5: Inferencia sobre los parámetros $\hat{\beta}_j$

- ▶ Intervalo de confianza a nivel $1 - \alpha$ para β_j :

$$\hat{\beta}_j \pm t_{n-k-1; \alpha/2} s(\hat{\beta}_j)$$

- ▶ Contraste de hipótesis a nivel α para $H_0: \beta_j = 0$ vs. $H_1: \beta_j \neq 0$
- ▶ Rechazar H_0 si $|T| > t_{n-k-1; \alpha/2}$, donde $T = \hat{\beta}_j / s(\hat{\beta}_j)$ es el estadístico de contraste



5.5: La descomposición ANOVA

- ▶ ANOVA: *ANalysis Of VAriance*
- ▶ Al ajustar un modelo de regresión lineal múltiple

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \cdots + \hat{\beta}_k x_{ik}$$

a un conjunto de datos $(x_{i1}, \dots, x_{ik}, y_i)$, para $i = 1, \dots, n$, podemos distinguir tres **fuentes de variación** en las respuestas:

- **variación debida a la regresión:** $\text{SCM} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$, donde las siglas "SC" se refieren a "suma de cuadrados", y la "M" se refiere al "Modelo"
 - **variación residual:** $\text{SCR} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n e_i^2$
 - **variación total:** $\text{SCT} = \sum_{i=1}^n (y_i - \bar{y})^2$
- ▶ La descomposición ANOVA indica que $\text{SCT} = \text{SCM} + \text{SCR}$



5.5: El coeficiente de determinación R^2

- ▶ La descomposición ANOVA indica que $\text{SCT} = \text{SCM} + \text{SCR}$
- ▶ Notemos que: $y_i - \bar{y} = (y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})$
- ▶ $\text{SCM} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ mide la variación de las respuestas debida a la regresión (explicada por los valores predichos \hat{y}_i)
- ▶ Por lo tanto, el cociente SCR/SCT es la proporción de variación de la respuesta no explicada por la regresión
- ▶ El cociente $R^2 = \text{SCM}/\text{SCT} = 1 - \text{SCR}/\text{SCT}$ es la proporción de variación de las respuestas explicada por las variables explicativas; se conoce como **coeficiente de determinación múltiple**
- ▶ Resultado: $R^2 = r_{\hat{y}y}^2$ (coef. de correlación al cuadrado)
- ▶ Ej: si $R^2 = 0.85$, las variables x_1, \dots, x_k explican un 85% de la variación de la variable y



5.5: Tabla ANOVA

| Fuente de variación | SC | G.L. | Media | Cociente F |
|---------------------|-----|-------------|-----------------------------|-----------------|
| Modelo | SCM | k | SCM/k | $(SCM/k)/s_R^2$ |
| Residuos/Errores | SCR | $n - k - 1$ | $\frac{SCR}{n-k-1} = s_R^2$ | |
| Total | SCT | $n - 1$ | | |



5.5: Contraste de hipótesis ANOVA

- ▶ Consideremos el contraste de hipótesis $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$ vs. $H_1: \beta_j \neq 0$ para algún $j = 1, \dots, k$
- ▶ H_0 : la respuesta no depende de las x_j
- ▶ Consideremos el cociente

$$F = \frac{SCM/k}{SCR/(n-k-1)} = \frac{SCM/k}{s_R^2}$$

- ▶ Bajo H_0 , F sigue una distribución $F_{k, n-k-1}$
- ▶ Contraste a nivel α : rechazar H_0 si $F > F_{k, n-k-1; \alpha}$

