

Apuntes de modelos lineales

Clases Nos. 1 al 3

Ernesto Ponsot Balaguer

Dr. en Estadística, MSc. en Estadística Aplicada, Ing. de Sistemas

<http://webdelprofesor.ula.ve/economia/ernesto>

E-mail: ernesto@ula.ve

Departamento de Estadística. Universidad de Los Andes. Mérida, Venezuela

Abril de 2012

- 1 **Introducción**
- 2 **Repaso matemático**
- 3 **El ejercicio 1.8 de Graybill**
- 4 **Continúa el repaso matemático**
- 5 **Postulados añadidos después**

Características del curso

- El curso comprende básicamente tres temas: el modelo lineal general, el modelo de regresión y el modelo de diseño de experimentos.
- La teoría será expuesta en clases, así como algunos ejemplos que contribuyan a su comprensión. Cuando sea pertinente, se empleará el procesador estadístico R para la solución de problemas numéricos.
- Algunos ejercicios selectos se dejarán al alumno para ser resueltos como tarea y algunas de sus soluciones deberán entregarse para ser evaluadas.
- Los textos del curso son: Graybill, Franklin A. (1976) "Theory and Application of The Linear Model". Duxbury Press, Ma, EEUU y Faraway, Julian J. (2009) "Linear models with R". Chapman & Hall/CRC, Fl, EEUU.

Evaluación

Tabla : Evaluación del curso

Concepto	Tema	Aporte
1° Examen	Modelo lineal general	25 %
2° Examen	Modelo de regresión	25 %
3° Examen	Modelo de diseño	25 %
Ejercicios	Todos los temas	25 %
Total		100 %

Matrices

- 1 La matriz \mathbf{A} con n filas y m columnas, se denota $\mathbf{A}_{n \times m}$. Sus elementos son $[a_{ij}]$ para $i = 1, 2, \dots, n$ y $j = 1, 2, \dots, m$.
- 2 \mathbf{I} se reserva para denominar a la matriz identidad (\mathbf{I}_n o $\mathbf{I}_{n \times n}$ para señalar su dimensión). Se trata de una matriz cuadrada, con unos en la diagonal y ceros en el resto, esto es, $[i_{kj}] = 1$ si $k = j$ e $[i_{kj}] = 0$ si $k \neq j$.
- 3 Para dos matrices cualesquiera $\mathbf{A}_{n \times m_1}$ y $\mathbf{B}_{m_2 \times p}$, el producto (escalar) $\mathbf{AB} = \mathbf{C}$ está definido sí y sólo sí $m_1 = m_2 = m$.
 $\mathbf{C}_{n \times p} = [c_{ij}] : c_{ij} = \sum_{k=1}^m a_{ik} b_{kj}$, para $i = 1, \dots, n$ y $j = 1, \dots, p$.
- 4 $\mathbf{IA} = \mathbf{A}$ y $\mathbf{AI} = \mathbf{A}$, para matrices \mathbf{A} e \mathbf{I} de dimensiones apropiadas.
- 5 Como en general el producto de matrices no es conmutativo, en la operación \mathbf{AB} se dice que \mathbf{A} pre-multiplica a \mathbf{B} , o equivalentemente, \mathbf{B} post-multiplica a \mathbf{A} .

Matrices

- 6 Si $\mathbf{A}_{n \times m} = [a_{ij}]$ entonces $\mathbf{A}' = \mathbf{A}^T = [a_{ji}]$ para $i = 1, \dots, n$, $j = 1, \dots, m$. $\mathbf{A}'_{m \times n}$ se denomina la matriz traspuesta (o transpuesta) de \mathbf{A} .
- 7 La matriz \mathbf{A} se dice simétrica si $\mathbf{A} = \mathbf{A}'$, esto es, si $[a_{ij}] = [a_{ji}]$, para todos los i, j . Obviamente, la simetría sólo puede establecerse en matrices cuadradas.
- 8 $\mathbf{A}'\mathbf{A}$ y $\mathbf{A}\mathbf{A}'$ son matrices simétricas.
- 9 $(\mathbf{A}\mathbf{B})' = \mathbf{B}'\mathbf{A}'$.
- 10 El determinante de la matriz \mathbf{A} se señala como $|\mathbf{A}|$. Sólo se aplica a matrices cuadradas y se dice que \mathbf{A} es una matriz singular sí y sólo sí $|\mathbf{A}| = 0$.

Matrices

- 11 Dado un conjunto de vectores $\{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_k\}$ con $\mathbf{y}_i \in \mathbb{R}^n$ para todo i , se dice que dicho conjunto es linealmente independiente (LI) si para $\lambda_i \in \mathbb{R} \forall i$, se verifica que $\sum_{i=1}^k \lambda_i \mathbf{y}_i = \mathbf{0} \Leftrightarrow \lambda_i = 0 \forall i$. En palabras, esto es que ninguno de los \mathbf{y} 's, puede ser escrito como combinación lineal de los restantes, excepto de forma trivial. En caso contrario (al menos uno de los $\lambda_i \neq 0$), el conjunto se denomina linealmente dependiente (LD). Todo conjunto de vectores que incluya al vector $\mathbf{0}$ se considera LD.
- 12 El rango de la matriz $\mathbf{A}_{n \times p}$ se señala como $r(\mathbf{A})$ y se define como el número de columnas (o filas) linealmente independientes de \mathbf{A} . Si $n \geq p \Rightarrow r(\mathbf{A}) \leq p$, o bien, si $n \leq p \Rightarrow r(\mathbf{A}) \leq n$. Si $r(\mathbf{A}) = p$ se dice que \mathbf{A} es de rango completo por columnas. De igual forma, si $r(\mathbf{A}) = n$ se dice que \mathbf{A} es de rango completo por filas.

Matrices

- 13 Si $\mathbf{A}_{n \times n}$ es tal que $r(\mathbf{A}) = n$ entonces \mathbf{A} es no singular, en caso contrario ($r(\mathbf{A}) < n$), \mathbf{A} es singular. Si $\mathbf{A}_{n \times p}$ es de rango completo por columnas, entonces $\mathbf{A}'\mathbf{A} = \mathbf{B}_{p \times p}$ es no singular.
- 14 Si \mathbf{A} es una matriz cuadrada no singular, entonces existe (y es única) \mathbf{A}^{-1} tal que $\mathbf{A}^{-1}\mathbf{A} = \mathbf{I}$. \mathbf{A}^{-1} se llama la matriz inversa de \mathbf{A} . Una matriz singular no tiene inversa y sobre una matriz que no sea cuadrada no está definida.
- 15 Si \mathbf{A} y \mathbf{B} son matrices equidimensionales que tienen inversa, entonces $(\mathbf{AB})^{-1} = \mathbf{B}^{-1}\mathbf{A}^{-1}$.
- 16 Una matriz simétrica $\mathbf{A}_{n \times n}$ es semidefinida positiva si $\mathbf{y}'\mathbf{A}\mathbf{y} \geq 0$, para todo $\mathbf{y} \in \mathbb{R}^n$ y $\mathbf{y}'\mathbf{A}\mathbf{y} = 0$, para al menos un $\mathbf{y} \in \mathbb{R}^n$. Se verifica que:
- $r(\mathbf{A}) < n$.
 - $a_{ii} \geq 0 \forall i$.

Matrices

- 17 Una matriz simétrica $\mathbf{A}_{n \times n}$ es definida positiva si $\mathbf{y}'\mathbf{A}\mathbf{y} > 0$, para todo $\mathbf{y} \in \mathbb{R}^n$. Se verifica que:
- a) $r(\mathbf{A}) = n$.
 - b) $a_{ii} > 0 \forall i$.
- 18 Una matriz simétrica \mathbf{A} es definida nonegativa si es definida positiva o semidefinida positiva.
- 19 Una matriz \mathbf{P} se dice ortogonal, si $\mathbf{P}^{-1} = \mathbf{P}'$.
- 20 Dos vectores \mathbf{x} e \mathbf{y} son ortogonales, sí y sólo sí, $\mathbf{x}'\mathbf{y} = 0$

Tarea 01

Luego de repasar los conceptos de espacio vectorial, valores y vectores propios, espacio de columnas de una matriz, entre otros, resuelva los ejercicios 1.7, 1.8 y 1.9 de Graybill (p.50-51).

Matrices

- 21 **Inversa generalizada** (de Moore-Penrose, o g-inversa): debido a las condiciones que impone, la inversa de una matriz no siempre existe (la matriz puede no ser cuadrada, o serlo, pero de rango incompleto y por tanto singular). Un tipo de inversa que aporta en la solución de problemas del álgebra lineal es la siguiente: sea $\mathbf{A}_{m \times n}$ una matriz cualquiera. La matriz $\mathbf{A}_{n \times m}^-$ (única) se denomina la inversa generalizada de \mathbf{A} (g-inversa de \mathbf{A}), si satisface:
- $\mathbf{A}\mathbf{A}^-$ es simétrica.
 - $\mathbf{A}^-\mathbf{A}$ es simétrica.
 - $\mathbf{A}\mathbf{A}^-\mathbf{A} = \mathbf{A}$.
 - $\mathbf{A}^-\mathbf{A}\mathbf{A}^- = \mathbf{A}^-$.
- 22 Se le denomina “generalizada” ya que si \mathbf{A} es no singular, $\mathbf{A}^- = \mathbf{A}^{-1}$.

Matrices

- 23 $(\mathbf{A}')^{-} = (\mathbf{A}^{-})'$.
- 24 $(\mathbf{A}^{-})^{-} = \mathbf{A}$.
- 25 $r(\mathbf{A}^{-}) = r(\mathbf{A})$.
- 26 Si $\mathbf{A} = \mathbf{A}'$ entonces $\mathbf{A}^{-} = (\mathbf{A}^{-})'$.
- 27 Si $\mathbf{A} = \mathbf{A}'$ (simetría) y $\mathbf{A} = \mathbf{A}^2$ (idempotencia) entonces $\mathbf{A}^{-} = \mathbf{A}$.
- 28 Si $\mathbf{B}_{m \times r}$ y $\mathbf{C}_{r \times m}$ son tales que $r(\mathbf{B}) = r(\mathbf{C}) = r > 0$, entonces $(\mathbf{BC})^{-} = \mathbf{C}^{-}\mathbf{B}^{-}$.
- 29 $(\mathbf{A}'\mathbf{A})^{-} = \mathbf{A}^{-}(\mathbf{A}')^{-}$.
- 30 $(\mathbf{AA}^{-})^{-} = \mathbf{AA}^{-}$ y $(\mathbf{A}^{-}\mathbf{A})^{-} = \mathbf{A}^{-}\mathbf{A}$.
- 31 Una matriz \mathbf{A}^c tal que $\mathbf{AA}^c\mathbf{A} = \mathbf{A}$ se denomina **inversa condicional** de \mathbf{A} . \mathbf{A}^c no es única para \mathbf{A} y cuando se adopta la convención de llamar \mathbf{A}^+ a la inversa generalizada de M-P, se le denomina \mathbf{A}^{-} a la inversa condicional, o simplemente inversa generalizada (sin el apelativo M-P).

Matrices

- 32 La **traza** de una matriz $\mathbf{A}_{n \times n} = [a_{ij}]$ se define como

$$\text{tr}(\mathbf{A}) = \sum_{i=1}^n a_{ii}.$$

33 $\text{tr}(\mathbf{AB}) = \text{tr}(\mathbf{BA})$.

34 $\text{tr}(a\mathbf{A} + b\mathbf{B}) = a \text{tr}(\mathbf{A}) + b \text{tr}(\mathbf{B})$.

35 Si $\mathbf{A}^2 = m\mathbf{A}$ entonces $\text{tr}(\mathbf{A}) = m r(\mathbf{A})$.

36 Para $\mathbf{A}_{m \times n} = [a_{ij}]$, $\text{tr}(\mathbf{A}'\mathbf{A}) = \text{tr}(\mathbf{AA}')$ $= \sum_{i=1}^n \sum_{j=1}^m a_{ij}^2$.

37 $\text{tr}(\mathbf{A}') = \text{tr}(\mathbf{A})$.

38 $\text{tr}(\mathbf{A}^c\mathbf{A}) = \text{tr}(\mathbf{AA}^c) = \text{tr}(\mathbf{A}^- \mathbf{A}) = \text{tr}(\mathbf{AA}^-) = r(\mathbf{A})$.

Matrices

- 39 Sean \mathbf{x} y \mathbf{A} un vector (columna) y una matriz de números reales, respectivamente. La función $\mathbf{x}'\mathbf{A}\mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n x_i a_{ij} x_j$ se denomina una **forma cuadrática** y a menos que se diga otra cosa, se asumirá que la matriz \mathbf{A} es simétrica.
- 40 **Derivada vectorial:** sea $\mathbf{x} = [x_1, x_2, \dots, x_n]'$, entonces si $f(\mathbf{x}) = f(x_1, x_2, \dots, x_n)$:

$$\frac{\partial f}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix}$$

Matrices

41

$$\frac{\partial(\mathbf{a}'\mathbf{x})}{\partial\mathbf{x}} = \frac{\partial(\mathbf{x}'\mathbf{a})}{\partial\mathbf{x}} = \mathbf{a}$$

42 Sea $q(\mathbf{x}) = \mathbf{x}'\mathbf{A}\mathbf{x}$ una forma cuadrática, entonces

$$\frac{\partial q(\mathbf{x})}{\partial\mathbf{x}} = 2\mathbf{A}\mathbf{x}$$

43 Sea $\mathbf{W} = [W_{ij}]$ una matriz aleatoria, esto es, una matriz cuyos elementos son variables aleatorias (o funciones de variables aleatorias), entonces $E[\mathbf{W}] = [E[W_{ij}]]$.

Matrices

- 44 Sean \mathbf{A} , \mathbf{B} dos matrices reales apropiadas y \mathbf{V} , \mathbf{W} dos matrices aleatorias, también apropiadas, entonces:
- $E[\mathbf{A}] = \mathbf{A}$.
 - $E[\mathbf{AV}] = \mathbf{AE}[\mathbf{V}]$.
 - $E[\mathbf{VB}] = E[\mathbf{V}]\mathbf{B}$.
 - $E[\mathbf{AVB}] = \mathbf{AE}[\mathbf{V}]\mathbf{B}$.
 - $E[\mathbf{V} + \mathbf{W}] = E[\mathbf{V}] + E[\mathbf{W}]$.
- 45 Sean \mathbf{Y}_m y \mathbf{Z}_n dos vectores aleatorios con vectores de medias $\boldsymbol{\mu}$ y $\boldsymbol{\psi}$ respectivamente. Entonces:
- $$\text{Cov}[\mathbf{Y}, \mathbf{Z}] = E[(\mathbf{Y} - \boldsymbol{\mu})(\mathbf{Z} - \boldsymbol{\psi})'] = \boldsymbol{\Sigma}_{m \times n} = [\sigma_{ij}], \text{ con}$$
- $$\sigma_{ij} = \text{Cov}(Y_i, Z_j) \text{ para todos los } i, j.$$

Matrices

46 En particular,

$$V[\mathbf{Y}] = \text{Cov}[\mathbf{Y}, \mathbf{Y}] = E[(\mathbf{Y} - \boldsymbol{\mu})(\mathbf{Y} - \boldsymbol{\mu})'] = \boldsymbol{\Sigma}_{m \times m} = [\sigma_{ij}],$$

con

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{bmatrix}$$

Con $\sigma_{ii} = \sigma_i^2 = V[Y_i] \quad \forall i$, $\sigma_{ij} = \sigma_{ji} \quad \forall i, j$ y $\boldsymbol{\Sigma}$ es una matriz definida no negativa.

Matrices

- 47 Si \mathbf{A} y \mathbf{B} son matrices reales, \mathbf{b} un vector de escalares, y \mathbf{Y} , \mathbf{Z} dos vectores aleatorios, entonces:
- $\text{Cov}[\mathbf{A}\mathbf{Y} + \mathbf{b}] = \mathbf{A} \text{Cov}[\mathbf{Y}] \mathbf{A}' = \mathbf{A}\Sigma\mathbf{A}'$.
 - $\text{Cov}[\mathbf{A}\mathbf{Y}, \mathbf{B}\mathbf{Z}] = \mathbf{A} \text{Cov}[\mathbf{Y}, \mathbf{Z}] \mathbf{B}'$.
 - $\text{Cov}[\mathbf{A}\mathbf{Y} + \mathbf{B}\mathbf{Z}] = \mathbf{A} \text{V}[\mathbf{Y}] \mathbf{A}' + \mathbf{B} \text{V}[\mathbf{Z}] \mathbf{B}' + \mathbf{A} \text{Cov}[\mathbf{Y}, \mathbf{Z}] \mathbf{B}' + \mathbf{B} \text{Cov}[\mathbf{Z}, \mathbf{Y}] \mathbf{A}'$.

El ejercicio...

Para $\mathbf{A} = \begin{bmatrix} 4 & 1 \\ 1 & 2 \end{bmatrix}$, encuentre $\mathbf{P}_{2 \times 2} : \mathbf{P}'\mathbf{A}\mathbf{P} = \mathbf{I}$.

Solución:

Encontrando las raíces del polinomio característico de la matriz \mathbf{A} ($|\mathbf{A} - \lambda\mathbf{I}| = 0$) es fácil ver que $\lambda_1 = 3 + \sqrt{2}$ y $\lambda_2 = 3 - \sqrt{2}$ son los valores propios de \mathbf{A} .

Ahora bien, como $\mathbf{A} = \mathbf{A}'$, el teorema 1.2.50 de Graybill (p. 17) asegura que existe $\mathbf{B} : \mathbf{B}'\mathbf{A}\mathbf{B} = \mathbf{D} = \text{Diag}(\lambda_i)$. Ahora, sea $\mathbf{R} = \text{Diag}[(\sqrt{\lambda_i})^{-1}]$, entonces:

$$\begin{aligned} \mathbf{B}'\mathbf{A}\mathbf{B} &= \mathbf{D} \\ \mathbf{R}'\mathbf{B}'\mathbf{A}\mathbf{B} &= \mathbf{R}'\mathbf{D} \\ \mathbf{R}'\mathbf{B}'\mathbf{A}\mathbf{B}\mathbf{R} &= \mathbf{R}'\mathbf{D}\mathbf{R} \\ (\mathbf{B}\mathbf{R})'\mathbf{A}\mathbf{B}\mathbf{R} &= \mathbf{I} \\ \therefore \mathbf{P} &= \mathbf{B}\mathbf{R} \end{aligned}$$

El ejercicio...

Por supuesto, ahora el problema es ¿quién es \mathbf{B} ? Pues bien, \mathbf{B} es la matriz cuyas columnas forman una **base ortonormal** a partir de los vectores propios de \mathbf{A} . Recuérdese que dos vectores son ortogonales si su producto escalar es nulo, y un vector es normal si el producto consigo mismo es unitario. Entonces una matriz apropiada \mathbf{Z} forma una base ortonormal si $\mathbf{Z}'\mathbf{Z} = \mathbf{I}$. Encontrar esta base ortonormal es algebraicamente laborioso (y tedioso): deben calcularse los vectores propios y emplear el teorema de Gram-Schmidt para su ortonormalización, por lo tanto, el ejercicio continúa con R (ver programa anexo)...

Repaso...

- 48 Sea Y una variable aleatoria (VA) con f.d.p. dada por:

$$f(y; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(y-\mu)^2}{2\sigma^2}}, \quad \infty < y < \infty$$

Entonces decimos que $Y \sim N(\mu, \sigma^2)$.

- 49 $Z = (Y - \mu)/\sigma \sim N(0, 1)$, que se denomina **normal estándar**.
- 50 Sean Z_1, \dots, Z_n VA's independientes tales que $Z_i \sim N(0, 1) \forall i$, entonces:

$$X^2 = \sum_{i=1}^n Z_i^2 \sim \chi_n^2,$$

- 51 Sean Y_1, \dots, Y_n VA's independientes tales que $Y_i \sim N(\mu, \sigma^2) \forall i$, entonces:

$$X^2 = \sum_{i=1}^n \left(\frac{Y_i - \bar{Y}}{\sigma} \right)^2 \sim \chi_{n-1}^2,$$

Repaso...

- 52 Sean $Z \sim N(0, 1)$ y $U \sim \chi_n^2$ dos VA's independientes, entonces $T = Z/\sqrt{U/n} \sim t_n$, que se denomina **t-Student**.
- 53 Sean Y_1, \dots, Y_n VA's independientes tales que $Y_i \sim N(\mu, \sigma^2) \forall i$, entonces:

$$T = \frac{\bar{Y} - \mu}{(\hat{\sigma}/\sqrt{n})} \sim t_{n-1}, \text{ donde}$$
$$\hat{\sigma} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-1}.$$

- 54 Sean $Z \sim N(0, 1)$ y $U \sim \chi_\nu^2$ dos VA's independientes, y δ una constante, entonces $T = (Z + \delta)/\sqrt{U/\nu} \sim t_{\nu, \delta}$ denominada la **densidad t no central**.
- 55 Sean $U_1 \sim \chi_{n_1}^2$ y $U_2 \sim \chi_{n_2}^2$ dos VA's independientes, entonces $F = (U_1/n_1)/(U_2/n_2) \sim F_{n_1, n_2}$, que se denomina **F-Snedecor**, o simplemente la distribución F.

Repaso...

- 56 Sean $U_1 \sim \chi_{n_1, \lambda}^2$ y $U_2 \sim \chi_{n_2}^2$, dos VA's independientes, entonces $W = (U_1/n_1)/(U_2/n_2) \sim F_{n_1, n_2, \lambda}$ denominada la **densidad F no central**.
- 57 Sea $\mathbf{Z} = [Z_1 \quad Z_2 \quad \cdots \quad Z_n]'$ un vector de VA's independientes, tales que $Z_i \sim N(0, 1) \forall i$, entonces $\mathbf{Z} \sim N(\mathbf{0}, \mathbf{I})$ y su f.d.p. es:

$$N(\mathbf{z}; \mathbf{0}, \mathbf{I}) = \frac{1}{(2\pi)^{n/2}} e^{-(1/2)\mathbf{z}'\mathbf{z}}, \quad \mathbf{z} \in \mathbb{R}^n$$

- 58 Sean $\mathbf{Z} \sim N(\mathbf{0}, \mathbf{I})$, $\boldsymbol{\gamma} = [\gamma_1 \quad \gamma_2 \quad \cdots \quad \gamma_n]'$ un vector de constantes y γ_0 un escalar, entonces $X = \boldsymbol{\gamma}'\mathbf{Z} + \gamma_0 \sim N(x; \gamma_0, \boldsymbol{\gamma}'\boldsymbol{\gamma})$.

Repaso...

99 Sean:

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}, \quad \boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{bmatrix}, \quad \boldsymbol{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{bmatrix}$$

donde \mathbf{Y} es un vector aleatorio, $\boldsymbol{\mu}$ es su vector de medias y $\boldsymbol{\Sigma}$ su matriz de varianzas y covarianzas, tal que $r(\boldsymbol{\Sigma}) = n$, entonces $\mathbf{Y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ si su f.d.p. es:

$$N(\mathbf{y}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{n/2} |\boldsymbol{\Sigma}|^{1/2}} e^{-\frac{1}{2}(\mathbf{y}-\boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1}(\mathbf{y}-\boldsymbol{\mu})}, \quad \mathbf{y} \in \mathbb{R}^n$$

Repaso...

- 00 Sean $\mathbf{Y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, \mathbf{B} una matriz de constantes y \mathbf{b} un vector también de constantes, entonces
$$\mathbf{W} = \mathbf{B}\mathbf{Y} + \mathbf{b} \sim N(\mathbf{B}\boldsymbol{\mu} + \mathbf{b}, \mathbf{B}\boldsymbol{\Sigma}\mathbf{B}').$$
- 01 Sea $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ y \mathbf{Y}_m^* un vector aleatorio con sólo algunos de los elementos de \mathbf{Y} ($m < n$), entonces tomando los elementos correspondientes de $\boldsymbol{\mu}$ para formar $\boldsymbol{\mu}^*$, y los elementos de filas y columnas correspondientes de $\boldsymbol{\Sigma}$ para formar $\boldsymbol{\Sigma}^*$, se tiene que $\mathbf{Y}_m^* \sim N(\boldsymbol{\mu}^*, \boldsymbol{\Sigma}^*)$.
- 02 En particular, si $\mathbf{Y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ entonces $Y_i \sim N(\mu_i, \sigma_{ii} = \sigma_i^2)$, para todo i .
- 03 $\mathbf{Y}_n \sim N(\mathbf{0}, \mathbf{I}) \Rightarrow \mathbf{Y}'\mathbf{Y} \sim \chi_n^2$.
- 04 $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \mathbf{I}) \Rightarrow \mathbf{Y}'\mathbf{Y} \sim \chi_{n,\lambda}^2$. Esta distribución se llama χ^2 **no central** y $\lambda = (1/2)\boldsymbol{\mu}'\boldsymbol{\mu}$ es el parámetro de no centralidad.

Repaso...

- 65 $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma}), r(\boldsymbol{\Sigma}) = n \Rightarrow \mathbf{Y}'\boldsymbol{\Sigma}^{-1}\mathbf{Y} \sim \chi_{n,\lambda}^2$, con $\lambda = (1/2)\boldsymbol{\mu}'\boldsymbol{\Sigma}^{-1}\boldsymbol{\mu}$ es el parámetro de no centralidad.
- 66 $\mathbf{Y}_n \sim N(\mathbf{0}, \mathbf{I}) \Rightarrow \mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi_k^2 \Leftrightarrow \mathbf{A}' = \mathbf{A}, \mathbf{A}^2 = \mathbf{A}, r(\mathbf{A}) = k$.
- 67 $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \mathbf{I}) \Rightarrow \mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi_{k,\lambda}^2$ con $\lambda = (1/2)\boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu} \Leftrightarrow \mathbf{A}^2 = \mathbf{A}, r(\mathbf{A}) = k$.
- 68 $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ con $r(\boldsymbol{\Sigma}) = n$, entonces $\mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi_{k,\lambda}^2$ con $\lambda = (1/2)\boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu}$ sí y sólo sí cualquiera de las siguientes condiciones se satisface:
- $\mathbf{A}\boldsymbol{\Sigma}$ es idempotente de rango k .
 - $\boldsymbol{\Sigma}\mathbf{A}$ es idempotente de rango k .
 - $\boldsymbol{\Sigma}$ es una c-inversa de \mathbf{A} , con $r(\mathbf{A}) = k$.
- 69 Si \mathbf{Y} es un vector aleatorio con $E[\mathbf{Y}] = \boldsymbol{\mu}$ y $V[\mathbf{Y}] = \boldsymbol{\Sigma}$, entonces $E[\mathbf{Y}'\mathbf{A}\mathbf{Y}] = \text{tr}(\mathbf{A}\boldsymbol{\Sigma}) + \boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu}$.

Después del repaso...

- 70 (Teorema 1.5.12) Si $\mathbf{A}_{m \times n} : r(\mathbf{A}) = m \Rightarrow \mathbf{A}^- = \mathbf{A}'(\mathbf{A}\mathbf{A}')^{-1}$, $\mathbf{A}\mathbf{A}^- = \mathbf{I}$ y si $r(\mathbf{A}) = n \Rightarrow \mathbf{A}^- = (\mathbf{A}'\mathbf{A})^{-1}\mathbf{A}'$, $\mathbf{A}^-\mathbf{A} = \mathbf{I}$.
- 71 (Teorema 4.5.2) Dado $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ con $r(\boldsymbol{\Sigma}) = n$, si $\mathbf{B}\boldsymbol{\Sigma}\mathbf{A} = \mathbf{0}$ entonces $\mathbf{Y}'\mathbf{A}\mathbf{Y}$ es independiente de $\mathbf{B}\mathbf{Y}$.
- 72 (Teorema 1.2.13) $r(\mathbf{A}\mathbf{B}) \leq r(\mathbf{A})$ y $r(\mathbf{A}\mathbf{B}) \leq r(\mathbf{B})$. Dicho en otros términos, $r(\mathbf{A}\mathbf{B}) \leq \text{Mín}[r(\mathbf{A}), r(\mathbf{B})]$.
- 73 (Ejercicio 1.20) Si $\mathbf{A}_{m \times n}$, $\mathbf{B}_{m \times n}$, $\mathbf{A}\mathbf{B}' = \mathbf{0}$ y $\mathbf{B}'\mathbf{A} = \mathbf{0}$, entonces: $\mathbf{A}^-\mathbf{B} = \mathbf{0}$, $\mathbf{B}^-\mathbf{A} = \mathbf{0}$, $\mathbf{A}\mathbf{B}^- = \mathbf{0}$, $\mathbf{B}\mathbf{A}^- = \mathbf{0}$, $(\mathbf{B}')^-\mathbf{A}^- = \mathbf{0}$ y $(\mathbf{A}')^-\mathbf{B}^- = \mathbf{0}$.

Después del repaso...

- 74 **Espacio vectorial (EV)**: es cualquier conjunto de vectores que incluya al $\mathbf{0}$, cerrado frente a la suma y multiplicación vectoriales, y frente a la multiplicación por un escalar.
- 75 El **espacio de columnas** generado por la matriz \mathbf{M} , es el espacio vectorial que producen las columnas de \mathbf{M} consideradas como vectores. Se simboliza como $\mathcal{C}(\mathbf{M})$. La definición del **espacio de filas** de una matriz $\mathcal{R}(\mathbf{M})$ es completamente análoga.
- 76 El **rango** de $\mathcal{C}(\mathbf{M})$ es el número de columnas linealmente independientes de \mathbf{M} , y por lo tanto $r[\mathcal{C}(\mathbf{M})] = r(\mathbf{M})$.
- 77 Si \mathcal{M}, \mathcal{N} son dos EV's tales que $\mathcal{M} \subseteq \mathcal{N}$ entonces se dice que \mathcal{M} es un **subespacio** (vectorial) de \mathcal{N} .
- 78 Sean \mathcal{M} un EV y \mathbf{x} un vector cualquiera. Se dice que \mathbf{x} es **ortogonal** a \mathcal{M} ($\mathbf{x} \perp \mathcal{M}$) si para todo $\mathbf{y} \in \mathcal{M}$, $\mathbf{x}'\mathbf{y} = 0$.

Después del repaso...

- 79 Si $\mathcal{M} \subseteq \mathcal{N}$ son dos EV's, $\mathcal{M}_{\mathcal{N}}^{\perp} = \{\mathbf{x} \in \mathcal{N} : \mathbf{x} \perp \mathcal{M}\}$. $\mathcal{M}_{\mathcal{N}}^{\perp}$ se denomina el **complemento ortogonal de \mathcal{M} respecto a \mathcal{N}** . Si $\mathcal{N} \equiv \mathbb{R}^n$ entonces $\mathcal{M}_{\mathcal{N}}^{\perp} = \mathcal{M}^{\perp}$ y se denomina simplemente el **complemento ortogonal de \mathcal{M}** .
- 80 Sea \mathcal{N} un EV y \mathcal{M} un subespacio de \mathcal{N} , entonces $\mathcal{M}_{\mathcal{N}}^{\perp}$ es un subespacio de \mathcal{N} . Si $\mathbf{x} \in \mathcal{N}$ entonces $\mathbf{x} = \mathbf{x}_1 + \mathbf{x}_2$, donde $\mathbf{x}_1 \in \mathcal{M}$ y $\mathbf{x}_2 \in \mathcal{M}_{\mathcal{N}}^{\perp}$. Además, $r(\mathcal{N}) = r(\mathcal{M}) + r(\mathcal{M}_{\mathcal{N}}^{\perp})$.
- 81 Si \mathcal{M}, \mathcal{N} son dos EV's entonces $\mathcal{M} + \mathcal{N}$ es un EV y $\mathcal{M} + \mathcal{N} = \{\mathbf{x} = \mathbf{x}_1 + \mathbf{x}_2 : \mathbf{x}_1 \in \mathcal{M}, \mathbf{x}_2 \in \mathcal{N}\}$.
- 82 $\mathcal{C}(A, B) = \mathcal{C}(A) + \mathcal{C}(B)$.
- 83 El conjunto de todos los \mathbf{x} tales que $\mathbf{A}\mathbf{x} = \mathbf{0}$ se denomina el **espacio nulo de \mathbf{A}** y se simboliza como $\mathcal{N}(\mathbf{A})$.
- 84 Si $r(\mathbf{A}_{n \times n}) = r \Rightarrow r[\mathcal{N}(\mathbf{A})] = n - r$.

Después del repaso...

- 85 (Teorema 4.5.3) Dado $\mathbf{Y}_n \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ con $r(\boldsymbol{\Sigma}) = n$, si $\mathbf{A}\boldsymbol{\Sigma}\mathbf{B} = 0$ entonces las dos formas cuadráticas $\mathbf{Y}'\mathbf{A}\mathbf{Y}$ y $\mathbf{Y}'\mathbf{B}\mathbf{Y}$ son independientes.
- 86 (Teorema 1.5.13) Las matrices $\mathbf{A}\mathbf{A}^-$, $\mathbf{A}^-\mathbf{A}$, $\mathbf{I} - \mathbf{A}\mathbf{A}^-$ e $\mathbf{I} - \mathbf{A}^-\mathbf{A}$ son todas simétricas e idempotentes.
- 87 (Corolario 1.4.2) Si $\mathbf{B}_{p \times n}$ de rango r entonces: $\mathbf{B}'\mathbf{B}$ y $\mathbf{B}\mathbf{B}'$ son matrices no negativas, $\mathbf{B}'\mathbf{B}$ es semidefinida positiva si $r < n$ y $\mathbf{B}'\mathbf{B}$ es definida positiva si $r = n$.