
REORGANIZACIÓN DE LA INFORMACIÓN EN MATRICES

29 de marzo de 2006

1. Matrices de rango uno

Una matriz genérica de rango uno se puede escribir en la forma

$$\begin{bmatrix} a_1 \\ \vdots \\ a_n \end{bmatrix} [b_1 \ \dots \ b_m] = \begin{bmatrix} a_1 b_1 & \dots & a_1 b_m \\ \vdots & & \vdots \\ a_n b_1 & \dots & a_n b_m \end{bmatrix},$$

es decir, las matrices de rango uno son aquéllas de la forma $(a_i b_j)$ donde los vectores $\mathbf{a} = (a_1, \dots, a_n)^\top$ y $\mathbf{b} = (b_1, \dots, b_m)^\top$ son no nulos, es decir, con el convenio de que los vectores son columnas, tenemos la matriz,

$$\mathbf{a} \mathbf{b}^\top.$$

El producto por una matriz de rango uno es muy simple

$$\mathbf{a} \mathbf{b}^\top \mathbf{x} = (\mathbf{b}, \mathbf{x}) \mathbf{a}, \quad (\mathbf{b}, \mathbf{x}) = \mathbf{b} \cdot \mathbf{x} = \mathbf{b}^\top \mathbf{x} = \sum_{j=1}^m b_j x_j.$$

De aquí se deduce trivialmente que

$$\mathcal{N}(\mathbf{a} \mathbf{b}^\top) = \{ \mathbf{x} \in \mathbb{R}^m \mid (\mathbf{b}, \mathbf{x}) = 0 \}$$

La descomposición de un vector en una base ortogonal es un ejemplo de empleo de matrices de rango uno. Si tenemos $\mathbf{p}_1, \dots, \mathbf{p}_n$ una base ortonormal de \mathbb{R}^n , entonces

$$\mathbf{x} = \sum_{j=1}^n (\mathbf{p}_j, \mathbf{x}) \mathbf{p}_j = \sum_{j=1}^n \mathbf{p}_j \mathbf{p}_j^\top \mathbf{x}.$$

Esta operación se puede ver empleando una matriz que agrupe a los vectores de la base ortonormal

$$P = \left[\begin{array}{c|c|c} \mathbf{p}_1 & \dots & \mathbf{p}_n \end{array} \right].$$

Que la matriz P sea ortogonal significa que sus columnas son ortonormales, esto es, $P^\top P = I$. Por ser cuadrada (la ortogonalidad de matrices también se admite para matrices rectangulares cuyas columnas sean ortonormales), $P^\top = P^{-1}$ y por tanto, también tenemos que $P P^\top = I$, esto es, las filas de una matriz cuadrada ortogonal forman otra base ortonormal de \mathbb{R}^n .

El hecho de que $P P^\top = I$ es el mismo que nos permite escribir que para todo \mathbf{x} ,

$$\mathbf{x} = P(P^\top \mathbf{x}) = \left[\begin{array}{c|c|c} \mathbf{p}_1 & \dots & \mathbf{p}_n \end{array} \right] \left[\begin{array}{c} (\mathbf{p}_1, \mathbf{x}) \\ \vdots \\ (\mathbf{p}_n, \mathbf{x}) \end{array} \right] = \sum_{j=1}^n (\mathbf{p}_j, \mathbf{x}) \mathbf{p}_j.$$

En la expresión anterior hemos empleado las dos interpretaciones del producto matriz por vector, que en determinados contextos del mundo de la ingeniería se llaman *input-output* y *output-input*. Las expresiones anteriores también permiten escribir la siguiente descomposición de la matriz identidad como suma de matrices de rango uno

$$I = \sum_{j=1}^n \mathbf{p}_j \mathbf{p}_j^\top.$$

Regresemos momentáneamente a las matrices de rango uno. Si una matriz de rango uno cuadrada ($a_i b_j$) es simétrica, entonces

$$\mathbf{b} \mathbf{a}^\top = \mathbf{a} \mathbf{b}^\top,$$

luego $\mathbf{b} = \lambda \mathbf{a}$ (basta multiplicar a derecha por \mathbf{a}), y la matriz se puede escribir como

$$\lambda \mathbf{a} \mathbf{a}^\top.$$

Obviamente,

$$(\lambda \mathbf{a} \mathbf{a}^\top \mathbf{x}, \mathbf{x}) = \lambda (\mathbf{a}^\top \mathbf{x})^\top \mathbf{a}^\top \mathbf{x} = \lambda |(\mathbf{a}, \mathbf{x})|^2.$$

Si $\lambda > 0$, entonces, la matriz es semidefinida positiva y si $\lambda < 0$, es semidefinida negativa. Como la matriz tiene rango uno, no puede ser indefinida, ya que solo tiene un valor propio no nulo.

Tomemos ahora números $\lambda_j \in \mathbb{R}$ y una base ortonormal de \mathbb{R}^n : $\{\mathbf{p}_1, \dots, \mathbf{p}_n\}$. Consideremos entonces una matriz simétrica (es suma de matrices simétricas):

$$A := \sum_{j=1}^n \lambda_j \mathbf{p}_j \mathbf{p}_j^\top.$$

Multiplicar por esta matriz es simple,

$$A\mathbf{x} = \sum_{j=1}^n \lambda_j (\mathbf{p}_j, \mathbf{x}) \mathbf{p}_j.$$

Notemos que, en particular,

$$A\mathbf{p}_i = \lambda_i \mathbf{p}_i$$

y que

$$A = P\Lambda P^\top, \quad \Lambda = \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix}, \quad P = \begin{bmatrix} | & & | \\ \mathbf{p}_1 & \dots & \mathbf{p}_n \\ | & & | \end{bmatrix}.$$

Así pues, $P^\top A P = \Lambda$ no es más que la diagonalización ortogonal de una matriz simétrica y las matrices

$$\sum_{j=1}^n \lambda_j \mathbf{p}_j \mathbf{p}_j^\top$$

cubren todo el conjunto de las matrices simétricas.

2. Compresión de información

Vamos a restringirnos en esta sección a matrices simétricas definidas positivas. Tomamos números

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n > 0$$

y una base ortonormal de \mathbb{R}^n , $\{\mathbf{p}_1, \dots, \mathbf{p}_n\}$, de manera que la diagonalización ortogonal de A es equivalente a la descomposición

$$A = \sum_{j=1}^n \lambda_j \mathbf{p}_j \mathbf{p}_j^\top.$$

Notemos también que si

$$|\mathbf{x}| := \sqrt{(\mathbf{x}, \mathbf{x})} = \sqrt{\sum_{j=1}^n |x_j|^2},$$

entonces

$$P^\top \mathbf{x} = \begin{bmatrix} (\mathbf{p}_1, \mathbf{x}) \\ \vdots \\ (\mathbf{p}_n, \mathbf{x}) \end{bmatrix}$$

y

$$\sum_{j=1}^n |(\mathbf{p}_j, \mathbf{x})|^2 = |P^\top \mathbf{x}|^2 = (P^\top \mathbf{x})^\top (P^\top \mathbf{x}) = \mathbf{x}^\top P P^\top \mathbf{x} = \mathbf{x}^\top \mathbf{x} = |\mathbf{x}|^2.$$

De forma similar, se ve que

$$|A\mathbf{x}|^2 = \sum_{j=1}^n \lambda_j^2 |(\mathbf{p}_j, \mathbf{x})|^2.$$

Consideremos ahora las matrices

$$A_k := \sum_{j=0}^k \lambda_j \mathbf{p}_j \mathbf{p}_j^\top.$$

Las matrices A_k son simétricas y semidefinidas positivas. Su rango es k , ya que

$$A_k \mathbf{x} \in \{\alpha_1 \mathbf{p}_1 + \dots + \alpha_k \mathbf{p}_k \mid \alpha_j \in \mathbb{R}\},$$

a la vez que

$$A_k \mathbf{p}_j = \lambda_j \mathbf{p}_j, \quad j = 1, \dots, k.$$

El espacio nulo de A_k es

$$\mathcal{N}(A_k) = \{\alpha_{k+1} \mathbf{p}_{k+1} + \dots + \alpha_n \mathbf{p}_n \mid \alpha_j \in \mathbb{R}\}.$$

Además,

$$A \mathbf{x} - A_k \mathbf{x} = \sum_{j=k+1}^n \lambda_j (\mathbf{p}_j, \mathbf{x}) \mathbf{p}_j$$

luego

$$|A \mathbf{x} - A_k \mathbf{x}|^2 = \sum_{j=k+1}^n \lambda_j^2 |(\mathbf{p}_j, \mathbf{x})|^2 \leq \lambda_{k+1}^2 \sum_{j=k+1}^n |(\mathbf{p}_j, \mathbf{x})|^2 \leq \lambda_{k+1}^2 \sum_{j=1}^n |(\mathbf{p}_j, \mathbf{x})|^2 = \lambda_{k+1}^2 |\mathbf{x}|^2.$$

Merece la pena observar que en la inversa, el orden de los valores propios es el contrario

$$A^{-1} = \sum_{j=1}^n (1/\lambda_j) \mathbf{p}_j \mathbf{p}_j^\top.$$

Este resultado se deduce del hecho de que si $A = P \Lambda P^\top$, entonces $A^{-1} = P \Lambda^{-1} P^\top$. Al número

$$\text{cond}(A) := \frac{\lambda_1}{\lambda_n}$$

(producto de los mayores valores propios de A y A^{-1}) se le llama condicionamiento espectral de A .

El mismo argumento se puede usar para cualquier tipo de matriz simétrica, ordenando los valores λ_j por módulo. Si ninguno de ellos es cero, se puede invertir la matriz y repetir los comentarios sobre la inversa.

3. Matrices no simétricas

Consideremos una matriz B cualquiera con n filas y m columnas. La matriz $B^\top B$ es $m \times m$, simétrica y semidefinida positiva. Así

$$B^\top B = \sum_{j=1}^r \sigma_j^2 \mathbf{p}_j \mathbf{p}_j^\top,$$

donde

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0,$$

y los vectores $\mathbf{p}_1, \dots, \mathbf{p}_r \in \mathbb{R}^m$ son ortonormales. El número r es el rango de $B^\top B$. Ahora bien, también es el rango de B . ¿Por qué? Para verlo, notemos primero que

$$B\mathbf{x} = \mathbf{0} \quad \Longleftrightarrow \quad B^\top B\mathbf{x} = \mathbf{0}.$$

Así, aprovechando que el número de columnas de B y de $B^\top B$ es el mismo, tenemos que

$$r = \text{rango}(B^\top B) = m - \dim \mathcal{N}(B^\top B) = m - \dim \mathcal{N}(B) = \text{rango}(B).$$

Definimos seguidamente los vectores

$$\mathbf{q}_j := (1/\sigma_j)B\mathbf{p}_j \in \mathbb{R}^n, \quad j = 1, \dots, r.$$

Notemos que

$$B^\top \mathbf{q}_j = (1/\sigma_j)B^\top B\mathbf{p}_j = \sigma_j \mathbf{p}_j, \quad j = 1, \dots, r.$$

Además estos vectores cumplen

$$(\mathbf{q}_i, \mathbf{q}_j) = \frac{1}{\sigma_i \sigma_j} (B\mathbf{p}_i, B\mathbf{p}_j) = \frac{1}{\sigma_i \sigma_j} \mathbf{p}_i^\top B^\top B\mathbf{p}_j = \frac{\sigma_j}{\sigma_i} \mathbf{p}_i^\top \mathbf{p}_j = \frac{\sigma_j}{\sigma_i} (\mathbf{p}_i, \mathbf{p}_j) = \delta_{ij},$$

luego son ortonormales. Así, como $\dim \mathcal{R}(B) = r$ y los vectores \mathbf{q}_j son ortogonales y están en $\mathcal{R}(B)$ (por su definición), entonces

$$\mathcal{R}(B) = \{\beta_1 \mathbf{q}_1 + \dots + \beta_r \mathbf{q}_r \mid \beta_j \in \mathbb{R}\}.$$

Por tanto, para cualquier $\mathbf{x} \in \mathbb{R}^m$

$$B\mathbf{x} = \sum_{j=1}^r \xi_j \mathbf{q}_j, \quad \xi_j \in \mathbb{R}$$

y se tiene que

$$\sum_{j=1}^r \sigma_j^2 (\mathbf{p}_j, \mathbf{x}) \mathbf{p}_j = B^\top B\mathbf{x} = \sum_{j=1}^r \xi_j B^\top \mathbf{q}_j = \sum_{j=1}^r \xi_j \sigma_j \mathbf{p}_j,$$

luego, por independencia lineal,

$$\xi_j = \sigma_j (\mathbf{p}_j, \mathbf{x}), \quad j = 1, \dots, r$$

y tenemos que

$$B\mathbf{x} = \sum_{j=1}^r \sigma_j (\mathbf{p}_j, \mathbf{x}) \mathbf{q}_j = \sum_{j=1}^r \mathbf{q}_j \mathbf{p}_j^\top \mathbf{x}, \quad \forall \mathbf{x} \in \mathbb{R}^m.$$

Esto equivale a que

$$B = \sum_{j=1}^r \sigma_j \mathbf{q}_j \mathbf{p}_j^\top,$$

esto es, hemos descompuesto B como una suma de matrices de rango unidad. Empaquetando la información en matrices

$$P := \left[\begin{array}{c|c|c} & & \\ \mathbf{p}_1 & \dots & \mathbf{p}_r \\ & & \end{array} \right], \quad P^\top P = I_r$$

$$Q := \left[\begin{array}{c|c|c} & & \\ \mathbf{q}_1 & \dots & \mathbf{q}_r \\ & & \end{array} \right], \quad Q^\top Q = I_r$$

(P es $m \times r$, mientras que Q es $n \times r$) y

$$\Sigma = \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{bmatrix}$$

hemos factorizado B en la forma

$$B = Q\Sigma P^\top.$$

A esta factorización de B se le llama **descomposición en valores singulares**. Se suele abreviar con el nombre inglés SVD.

Hay una serie de resultados que se obtienen inmediatamente: para la matriz B^\top se tiene inmediatamente

$$B^\top = \sum_{j=1}^r \sigma_j \mathbf{p}_j \mathbf{q}_j^\top = P\Sigma Q^\top,$$

y para BB^\top

$$BB^\top = \sum_{j=1}^r \sigma_j^2 \mathbf{q}_j \mathbf{q}_j^\top.$$

Hay una matriz interesante, que es

$$B^\dagger := \sum_{j=1}^n (1/\sigma_j) \mathbf{p}_j \mathbf{q}_j^\top = P\Sigma^{-1}Q^\top.$$

Esta matriz se denomina **pseudoinversa** de B .

La compresión de información de B se realiza recortando la descomposición en valores singulares

$$B_k := \sum_{j=1}^k \sigma_j \mathbf{q}_j \mathbf{p}_j^\top.$$

Notemos que

$$|B\mathbf{x}|^2 = \sum_{j=1}^r \sigma_j^2 |(\mathbf{p}_j, \mathbf{x})|^2$$

y que entonces

$$|B\mathbf{x} - B_k\mathbf{x}|^2 = \sum_{j=k+1}^r \sigma_j^2 |(\mathbf{p}_j, \mathbf{x})|^2 \leq \sigma_{k+1}^2 |\mathbf{x}|^2.$$

Hay otra versión de la descomposición en valores singulares, donde Σ tiene el mismo tamaño que B (en la esquina superior derecha de Σ se pone la matriz diagonal anterior) y P y Q son cuadradas (cada una de un tamaño). Las r primeras columnas de P y Q son como las dadas antes. Las restantes, se obtienen completando hasta una base ortonormal del espacio correspondiente.

Temas relacionados:

- problemas mal condicionados
- regularización
- filtros de Wiener
- análisis de componentes principales

by F.-J. Sayas
Mathematics, Ho!, March, 2006

Mathematics, Ho! is a personal project for individual and comunal achievement in higher Maths among Mathematicians, with a bias to Applied Mathematics. It is a collection of class notes and small courses. I do not claim entire originality in these, since they have been much influenced by what I report as references. **Conditions of use.** You are allowed to use these pages and to share this material. This is by no means aimed to be given to undergraduate students, since the style is often too dry. Anyway you are requested to quote this as a source whenever you make extensive use of it. Note also that this is permanently work in progress.