

Análisis en componentes principales es una técnica estadística que tiene por principal objetivo el de lograr reducir la dimensionalidad de los datos cuando nos encontramos frente a datos multivariados.

Más explícitamente, si tenemos un vector aleatorio que observa p variables que llamamos $X = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{pmatrix}$ intentamos construir r variables que llamaremos

Z_1, Z_2, \dots, Z_r con $r < p$ de modo que perdamos la menor cantidad de información posible al pasar de p variables a r variables.

A las Z_1, Z_2, \dots, Z_r les llamaremos las r componentes principales.

Le llamamos Σ a la matriz de varianzas y covarianzas de X y supondremos que X es un vector centrado, es decir que $\mathbb{E}(X_1) = \mathbb{E}(X_2) = \dots = \mathbb{E}(X_p) = 0$ (esto se debe a que algunos de los resultados teóricos que se utilizan en la teoría están basadas en subespacios vectoriales por lo que es necesario que los vectores estén centrados).

Es conveniente tener en cuenta las siguientes propiedades de toda matriz de varianzas y covarianzas.

1. Σ es una matriz simétrica por lo que (teorema mediante) todos sus valores propios son reales.
2. Cuando una matriz es simétrica, los vectores propios asociados a valores propios distintos son ortogonales (es decir que si A es simétrica $n \times n$ y $Au = \alpha u$, $Av = \beta v$ con $\alpha \neq \beta$ y u, v no nulos, entonces se cumple que $u \perp v$ o lo que es lo mismo $u^T v = 0$, o bien $\langle u, v \rangle = u_1 v_1 + u_2 v_2 + \dots + u_n v_n = 0$).
3. Σ es definida positiva o semidefinida positiva (teorema mediante), lo que significa que todos sus valores propios son ≥ 0 . Será importante ordenar los valores propios de la matriz Σ por lo que les llamaremos $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$.
4. $tr(\Sigma) = \mathbb{V}(X_1) + \mathbb{V}(X_2) + \dots + \mathbb{V}(X_p) = \lambda_1 + \lambda_2 + \dots + \lambda_p$ (la traza de una matriz es por definición la suma de los valores de la diagonal, la propiedad dice que la misma coincide con la suma de los valores propios de Σ).

El criterio para construir las variables Z_i se realiza en pasos (primero Z_1 , luego Z_2 y así sucesivamente).

Paso 1. Construcción de la primer componente principal.

$Z_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p$ donde el vector $a_1 = (a_{11}, a_{12}, \dots, a_{1p})$ se elige de forma que

$$a_1 = \arg \max_{\|a_1\|=1} \mathbb{V}(Z_1)$$

Por aplicación directa del teorema de la esfera unidad llegamos a que a_1 debe ser vector propio de la matriz Σ (matriz de varianzas y covarianzas del

vector X) de norma 1 correspondiente al mayor valor propio de \sum . Además, el teorema de la esfera unidad nos dice que esa máxima varianza es igual a λ_1 .

Paso 2. Construcción de la segunda componente principal.

$Z_2 = a_{21}X_1 + a_{22}X_2 + \dots + a_{2p}X_p$ donde el vector $a_2 = (a_{21}, a_{22}, \dots, a_{2p})$ se elige de forma que

$$a_2 = \arg \max_{\|a_2\|=1, a_2 \perp a_1} \mathbb{V}(Z_2).$$

Nuevamente, aplicando el teorema de la esfera unidad restringida al complemento ortogonal del subespacio propio asociado al valor propio λ_1 , se llega a que a_2 es vector propio de \sum asociado al siguiente valor propio más grande (le llamamos λ_2). Además la varianza máxima buscada es λ_2 .

Paso 3. Construcción de la tercer componente principal.

$Z_3 = a_{31}X_1 + a_{32}X_2 + \dots + a_{3p}X_p$ donde el vector $a_3 = (a_{31}, a_{32}, \dots, a_{3p})$ se elige de forma que

$$a_3 = \arg \max_{\|a_3\|=1, a_3 \perp a_1, a_3 \perp a_2} \mathbb{V}(Z_3)$$

a_3 es vector propio de \sum asociado al siguiente valor propio más grande (le llamamos λ_3) (por aplicación del teorema de la esfera unidad restringida al complemento ortogonal de la suma entre subespacio propio asociado al valor propio λ_1 y el subespacio propio asociado a λ_2 . Además la varianza máxima es igual a λ_3 .

Pasos 4 a r se siguen con la misma idea.

Sintetizando.

Primer componente principal es $Z_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p$ siendo $a_1 = (a_{11}, a_{12}, \dots, a_{1p})$ vector propio de \sum asociado al mayor valor propio λ_1 . Además $\mathbb{V}(Z_1) = \lambda_1$.

Segunda componente principal es $Z_2 = a_{21}X_1 + a_{22}X_2 + \dots + a_{2p}X_p$ siendo $a_2 = (a_{21}, a_{22}, \dots, a_{2p})$ vector propio de \sum asociado al segundo mayor valor propio λ_2 . Además $\mathbb{V}(Z_2) = \lambda_2$.

Así sucesivamente con Z_3, Z_4, \dots, Z_r .

Algunas observaciones y comentarios.

1. Las componentes principales son centradas e incorrelacionadas entre sí.
2. La restricción para maximizar las varianzas de $\|a\| = 1$ es necesaria para homogeneizar y además si no acotamos los valores de los coeficientes podemos lograr varianzas tan grandes como se desee.
3. Los coeficientes que definen las componentes principales no son únicos. Por ejemplo, dados los coeficientes que definen la primer componente principal $a_1 = (a_{11}, a_{12}, \dots, a_{1p})$, si les cambiamos de signo a los mismos, obtenemos la misma varianza para Z_1 y siguen teniendo norma 1. Incluso podría haber infinitos coeficientes que alcancen el máximo.

4. Si definimos la matriz $A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1p} \\ a_{21} & a_{22} & \cdots & a_{2p} \\ \vdots & \vdots & \cdots & \vdots \\ a_{r1} & a_{r2} & \cdots & a_{rp} \end{pmatrix}$ incluyendo los coe-

ficientes obtenidos que definen las componentes principales, se tiene que las filas de esta matriz tienen norma 1 y además son ortogonales entre sí. Estas condiciones equivalen a la igualdad $AA^T = I$.

5. Las igualdades que definen las componentes principales pueden ser escritas en forma matricial como $Z = AX$ siendo $X = (X_1, X_2, \dots, X_p)^T$ y $Z = (Z_1, Z_2, \dots, Z_r)^T$.

6. En el caso en que consideremos $r = p$ componentes principales, entonces la matriz A queda cuadrada y en ese caso, las filas tienen norma 1 y son ortogonales entre sí, pero también las columnas tienen norma 1 y son ortogonales entre sí. Eso equivale a que A es invertible y además $A^{-1} = A^T$ y por lo tanto $A^T A = AA^T = I$.

7. En el caso $r = p$, dado que A es invertible, se tiene que la igualdad $Z = AX$ equivale a $X = A^T Z$, lo que implica que, por un lado no reducimos la dimensionalidad ni perdemos información (porque dada Z podemos recuperar X) pero pasamos a variables incorrelacionadas y por otro lado tenemos una fórmula sencilla para recuperar las X_i ya que $X_i = \sum_{j=1}^p a_{ji} Z_j$.

Elección de un valor adecuado de r .

Cuando realmente necesitamos reducir dimensionalidad y trabajar con un $r < p$, el método más utilizado es el llamado método del "codo" que consiste en considerar la proporción de variabilidad de las r componentes principales con respecto a la variabilidad total que es $tr(\Sigma) = \mathbb{V}(X_1) + \mathbb{V}(X_2) + \dots + \mathbb{V}(X_p)$.

Es decir que consideramos los cocientes

$$\frac{\mathbb{V}(Z_1) + \mathbb{V}(Z_2) + \dots + \mathbb{V}(Z_r)}{\mathbb{V}(X_1) + \mathbb{V}(X_2) + \dots + \mathbb{V}(X_p)} = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_r}{\lambda_1 + \lambda_2 + \dots + \lambda_p}.$$

Si graficamos esta proporción en función de r tendremos una función que irá creciendo tomando valores entre 0 y 1. En algún momento suele visualizarse que a partir de determinado valor de r esta proporción queda cerca de 1 y crece demasiado lentamente (es donde se produce el "codo", elbow en inglés, en el gráfico). Si tomamos un valor de r que cumpla con esas condiciones, tendremos un valor de r (que muchas veces es notoriamente menor que p) y con el cual la proporción de la variabilidad explicada por las r componentes principales es aproximadamente el 100% de la variabilidad total. De esta forma muchas veces logramos reducir claramente la dimensionalidad de los datos perdiendo muy poca información.

Recordar que para aplicar este criterio es necesario que o bien todas las variables X_i sea comparables entre sí en magnitudes, de lo contrario es conveniente estandarizar los datos ya que si hay mucha variación en el valor de las varianzas, las componentes principales estarán gobernadas por aquellas variables que tienen las mayores varianzas.