

7.2 Analisi delle componenti principali (PCA): codifica ottimale dato il sottospazio

Sia $X \in \mathbb{R}^{m \times d}$ una matrice dati e si supponga di aver fissato (in qualche modo) un sottospazio \mathcal{S} di \mathbb{R}^d . Sia $K \leq d$ la dimensione di tale sottospazio e siano $c_1, \dots, c_K \in \mathbb{R}^d$ vettori che compongono una base di \mathcal{S} . Chiamiamo C la matrice $d \times K$ le cui colonne sono i vettori c_1, \dots, c_K .

Il sottospazio \mathcal{S} è tanto più rappresentativo dei dati quanto più la quantità

$$g(C) = \frac{1}{m} \sum_{i=1}^m \left\| CC^\top x^{(i)} - x^{(i)} \right\|^2$$

è piccola. Infatti l'operatore CC^\top è proprio l'operatore di proiezione sul sottospazio \mathcal{S} : è un operatore lineare, ed è idempotente perché

$$(CC^\top)(CC^\top) = C(C^\top C)C^\top = CC^\top,$$

dove la seconda uguaglianza segue dal fatto che $C^\top C$ è una matrice identità, visto che i vettori c_1, \dots, c_K formano una base ortonormale di \mathcal{S} . Infine, qualunque elemento $u \in \mathcal{S}$ è della forma $u = Cv$ per qualche $v \in \mathbb{R}^K$, e quindi

$$CC^\top u = CC^\top (Cv) = Cv = u,$$

quindi la proiezione lascia invariati tutti gli elementi di \mathcal{S} .

7.3 Analisi delle componenti principali (PCA): prima componente principale

Qual è una matrice a colonne ortogonali $C \in \mathbb{R}^{d \times K}$ (e quindi un sottospazio \mathcal{S}) che minimizza la distorsione $g(C)$? Dimostriamo qui che una scelta ottimale della prima colonna c_1 della matrice C è data dall'autovettore principale della *matrice di covarianza dei dati* $\Sigma = (1/m)X^\top X$.

Poiché CC^\top è un operatore idempotente,

$$\begin{aligned} \left\| CC^\top x^{(i)} - x^{(i)} \right\|^2 &= x^{(i)\top} CC^\top CC^\top x^{(i)} - 2x^{(i)\top} CC^\top x^{(i)} + x^{(i)\top} x^{(i)} \\ &= -x^{(i)\top} CC^\top x^{(i)} + x^{(i)\top} x^{(i)} \\ &= -\left\| C^\top x^{(i)} \right\|^2 + \left\| x^{(i)} \right\|^2. \end{aligned}$$

Visto che $\left\| x^{(i)} \right\|^2$ non dipende da C ,

$$\begin{aligned} \operatorname{argmin}_C g(C) &= \operatorname{argmin}_C \left(-\frac{1}{m} \sum_{i=1}^m \left\| C^\top x^{(i)} \right\|^2 \right) \\ &= \operatorname{argmax}_C \frac{1}{m} \sum_{i=1}^m \sum_{j=1}^K \langle c_j, x^{(i)} \rangle^2 \end{aligned}$$

$$= \operatorname{argmax}_C \frac{1}{m} \sum_{j=1}^K \sum_{i=1}^m \langle c_j, x^{(i)} \rangle^2,$$

dove si è usato il fatto che la j -esima componente di $C^\top x^{(i)}$ è $\langle c_j, x^{(i)} \rangle$.

Una delle colonne di C , ad esempio c_1 , può essere scelta indipendentemente dalle altre, e quindi può essere scelta in modo da massimizzare $(1/m) \sum_{i=1}^m \langle c_1, x^{(i)} \rangle^2$. Infine osserviamo che

$$\frac{1}{m} \sum_{i=1}^m \langle c_1, x^{(i)} \rangle^2 = c_1^\top \left(\frac{1}{m} X^\top X \right) c_1,$$

dove si è usato il fatto che

$$Xc_1 = \begin{pmatrix} \langle c_1, x^{(1)} \rangle \\ \langle c_1, x^{(2)} \rangle \\ \dots \\ \langle c_1, x^{(m)} \rangle \end{pmatrix}.$$

Quindi la scelta ottima di c_1 consiste nell'autovettore principale della matrice di covarianza Σ , in quanto il massimizzante della funzione $u \mapsto u^\top S u$ è l'autovettore principale della matrice S , qualunque sia la matrice semidefinita positiva S .

Si noti che una volta fissata la colonna c_1 , le altre colonne non possono più essere scelte liberamente, in quanto devono soddisfare la condizione di ortogonalità: c_2 dovrà essere ortogonale a c_1 , e in generale c_j dovrà essere ortogonale al sottospazio generato da c_1, \dots, c_{j-1} .