

Recap PCA

Objectif: Passer d'un espace de dimension p des features à un espace de dimension $k < p$.

Cela peut-être à des fins de visualisation ($k=2$ ou 3), computationnelles (complexité) ou encore pour éviter l'overfitting (mais ce n'est pas "une bonne pratique": mieux vaut régulariser).

+ Utilisation annexe importante: avoir des nouvelles features décorrélées.

Principe: On va projeter nos données $x_1, \dots, x_n \in \mathbb{R}^p$ dans un espace de dimension $k < p$ telle que la "variance totale" résultante est maximisée.

On écrit $X \in \mathbb{R}^{n \times p}$, n le nombre de données, p le nombre features:

$$X = \begin{pmatrix} x_1^T \\ \vdots \\ x_n^T \end{pmatrix} = (X_1 | \dots | X_p)$$

↳ En pratique: on centre et réduit nos données au préalable.

$$x \rightarrow \frac{x - \bar{x}}{\sigma}$$

Rappel de Mathu préliminaires

I | SVD: Singular Value Decomposition

• Pour $X \in \mathbb{R}^{n \times p}$, on peut écrire

$$X = UDV^T \quad U \in O_n(\mathbb{R}) \text{ (i.e. orthogonale)},$$

$$V \in O_p(\mathbb{R}), \quad D = \begin{pmatrix} D_{11} & & 0 \\ & \dots & \\ 0 & & D_{mm} \end{pmatrix}, \quad m = \min(n, p)$$

$$\text{et } D_{11} \geq \dots \geq D_{mm} \geq 0.$$

⊕ Si $n > p$: on peut réécrire cela comme

$$X = UDV^T, \quad U \in \mathbb{R}^{n \times p}, \quad D \in \mathbb{R}^{p \times p}, \quad V \in O_p(\mathbb{R})$$

$$\text{où } U = (U_1 | \dots | U_n) \xrightarrow{\text{devenir}} (U_1 | \dots | U_p).$$

(On supprime les dernières colonnes de U) ⊕ D diagonal

En effet:

$$UDV^T = (U_1 | \dots | U_n) \begin{pmatrix} D_{11} & & 0 \\ & \dots & \\ 0 & & D_{pp} \end{pmatrix} \begin{pmatrix} v_1^T \\ \vdots \\ v_p^T \end{pmatrix}$$

$$= (U_1 | \dots | U_n) \begin{pmatrix} D_{11} v_1^T \\ \vdots \\ D_{pp} v_p^T \\ 0 \\ \vdots \end{pmatrix} = \sum_{i=1}^p U_i D_{ii} v_i^T$$

on peut donc supprimer les dernières colonnes

⊕ Si $n < p$: on réécrit $X = UDV^T$,
 $V^T = \begin{pmatrix} v_1^T \\ \vdots \\ v_n^T \end{pmatrix}$, $U \in O_n(\mathbb{R})$, $D \in \mathbb{R}^{n \times n}$.

↳ Cette réécriture s'appelle thin SVD (en anglais)

On a alors: $X^T X = (UDV^T)^T (UDV^T)$



$$X^T X = V D^T D V^T$$

$$\boxed{X^T X = V \Lambda V^T}, \Lambda = D^T D, \\ V \in \mathcal{O}_p(\mathbb{R})$$

$\Lambda \rightarrow$ contient les valeurs propres de $X^T X$ (valeurs singulières) qui sont réelles ≥ 0 .

$V \rightarrow$ contient les vecteurs propres qui forment une base orthonormée de \mathbb{R}^p (v_1, \dots, v_p) .

II / Produit scalaire et projection en \mathbb{R}^2



$$\cos(\alpha) = \frac{pu(x)}{\|x\|_2} \leftarrow \text{projection orthogonale de } x \text{ sur la droite avec vecteur directeur } u$$

Donc $\langle x, u \rangle = \|x\|_2 \cdot \|u\|_2 \cdot \cos(\alpha) = \|u\|_2 \cdot pu(x)$

Si $\|u\|_2 = 1 \rightarrow \langle x, u \rangle = pu(x)$

III / Caractérisation projection orthogonale sur un plan dans $\mathbb{R}^n, n \geq 3$

Rappel: $\boxed{\pi_P(x) = \operatorname{argmin}_{y \in P} \|y - x\|_2}$ pour P un plan. \rightarrow projection orthogonale de x sur P .

Prenez une base orthonormée de P (v_1, v_2) .

$$\forall y \in P, y = \lambda_1 v_1 + \lambda_2 v_2$$

$$\|x - y\|_2^2 = \|x\|_2^2 - 2\langle x, y \rangle + \|y\|_2^2.$$

$$\boxed{\|x - y\|_2^2 = \|x\|_2^2 + \lambda_1^2 + \lambda_2^2 - 2\lambda_1 \langle x, v_1 \rangle - 2\lambda_2 \langle x, v_2 \rangle}$$

Posons $\varphi(\lambda_1, \lambda_2) = -2\lambda_1 \langle x, v_1 \rangle - 2\lambda_2 \langle x, v_2 \rangle + \lambda_1^2 + \lambda_2^2$

$$\begin{cases} \frac{\partial \varphi}{\partial \lambda_i} = -2\langle x, v_i \rangle + 2\lambda_i, \quad i=1,2 \\ \frac{\partial^2 \varphi}{\partial \lambda_i^2} = 2, \quad i=1,2 \\ \frac{\partial^2 \varphi}{\partial \lambda_1 \partial \lambda_2} = 0 \end{cases}$$

$\hookrightarrow \frac{\partial^2 \varphi}{\partial x^2} > 0$ positive définie (Jacobienne)

donc la fonction est convexe (strictement)

\Rightarrow Minimum atteint pour $\frac{\partial \varphi}{\partial x} = 0$ ie

$$\boxed{\lambda_i = \langle x, v_i \rangle, \quad i=1,2}$$

$$\hookrightarrow \boxed{y = \langle x, v_1 \rangle v_1 + \langle x, v_2 \rangle v_2 = \pi_P(x)}$$

On généralise facilement à un espace de dimension k en prenant (v_1, \dots, v_k) une base orthonormée de E_k :

On obtient
$$\pi_{E_k}(x) = \sum_{i=1}^k \langle x, v_i \rangle v_i$$

$$\pi_{E_k}(x) = \sum_{i=1}^k (x \cdot \bar{v}_i) v_i$$

PCA - Introduction

La "variance totale" est définie

comme : $\frac{1}{n} \sum_{i=1}^n \|x_i - \bar{x}\|_2^2 \Leftrightarrow \frac{1}{n} \sum_{i=1}^n \|x_i\|_2^2$

données centrées

$$= \frac{1}{n} \sum_{i=1}^n \|x_i\|_2^2$$

(le facteur $\frac{1}{n}$ n'est pas important pour la suite).


On cherche donc un espace de dimension k tq la projection des x_i sur cet espace donne des données (et nouvelles features anciennes) qui gardent le maximum de variance totale possible.

ie : on aura une nouvelle matrice

$$Y = \begin{pmatrix} y_1^T \\ \vdots \\ y_n^T \end{pmatrix}, y_i \in \mathbb{R}^k \text{ telle que}$$

$\sum \|y_i\|_2^2$ est "maximale" dans le sens défini ci-dessus.

Exemple : $2D \rightarrow 1D$ (ou $PD \rightarrow 1D$)



Nouvelle feature z

On veut garder une "dispersion" maximale

Bon choix de projection

Nouvelle feature z



— Bon choix de projection
— Mauvais choix

Mauvais choix de projection
Les nouvelles données sont très rapprochées

Données originales

Prends le cas où on a des données avec 2 features qu'on veut "compresser" en une seule. On cherche \tilde{x} ($\|u\|_2=1$) tq les données projetées sur \tilde{x} ($x_i^T u, \forall i=1, \dots, n$) gardent une variance maximale.

ie $Xu = \begin{pmatrix} x_1^T u \\ \vdots \\ x_n^T u \end{pmatrix}$ et on a vu que

$x_i^T u = \text{pu}(x_i)$ pour u de norme 1.

On cherche $u \in \mathbb{R}^2$ tq : $u = \underset{\substack{v \in \mathbb{R}^2 \\ \|v\|_2=1}}{\text{argmax}} \|Xu\|_2^2$

ou, plus généralement : $u = \underset{\substack{v \in \mathbb{R}^p \\ \|v\|_2=1}}{\text{argmax}} \|Xv\|_2^2$

Si on part de $\mathbb{R}^p, p \geq 2$

On a : $\|Xv\|_2^2 = v^T X^T X v = v^T V D^T D V^T v$ (avec $\|v\|_2=1$)

Écrivons $a = V^T v, \|a\|_2 = \|v\|_2 = 1, \|Xv\|_2^2 = a^T D D a$


$$\|Xv\|_2^2 = \sum_{i=1}^m a_i^2 D_i^2 \leq D_1^2 \sum a_i^2 = D_1^2$$

Donc $a = \begin{pmatrix} 1 \\ 0 \\ \vdots \end{pmatrix}$ maximise $\|Xv\|_2^2$ ie $v = Va = V_1$


La direction qui maximise $\|Xv\|_2^2$ est V_1 , vecteur propre associé à D_1^2 : $\|XV_1\|_2^2 = \|D_1 V_1\|_2^2 = D_1^2$

Remarque: les données projetées $x_i \cdot v$ sont centrées ($\sum x_i \cdot v = \sum (x_i \cdot v) = 0$), donc la variance totale est bien $\sum_{i=1}^n (x_i \cdot v)^2 = \|Xv\|_2^2$ (#facteur $\frac{1}{n}$ pas important pour trouver le maximum)

• Ne pas confondre PCA et regression linéaire.



PCA



Regression linéaire

↳ les "traits rouge" (ce qu'on cherche à minimiser) sont différents.

Formulation du problème

Notre problème peut se résumer à :

$$\operatorname{argmax}_{\substack{U \in \mathbb{R}^k \\ (U_1, \dots, U_k) \in (\mathbb{R}^p)^k}} \sum_{i=1}^k \|XU_i\|_2^2 \quad \text{tels que} \quad U_i \cdot U_j = \delta_{i,j}$$

En effet, on a, pour un espace E_n de dimension k et une base orthonormée (v_1, \dots, v_k) :

$$\Pi_{E_n}(x_i) = \sum_{l=1}^k (x_i \cdot v_l) \cdot v_l \quad (\text{projection orthogonale sur } E_n)$$

N.B. $\sum_{i=1}^n \|\Pi_{E_n}(x_i)\|_2^2 = \sum_{i=1}^n \sum_{l=1}^k (x_i \cdot v_l)^2$

Dans ce nouvel espace, on peut retrouver les coordonnées des x_i projetées dans la base orthonormée :

$$Y = \begin{pmatrix} y_{11} \\ \vdots \\ y_{n1} \end{pmatrix} = \begin{pmatrix} x_{11} \cdot v_1 & x_{12} \cdot v_2 & \dots & x_{1k} \cdot v_k \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} \cdot v_1 & x_{n2} \cdot v_2 & \dots & x_{nk} \cdot v_k \end{pmatrix} = (Xv_1 \dots Xv_k) = (Y_1 \dots Y_k)$$

La variance totale est :

$$\sum_{i=1}^n \sum_{l=1}^k x_{il} \cdot v_l = \sum_{l=1}^k \|Xv_l\|_2^2$$

Résolution

On peut commencer par v_1 pour la 1^{ère} feature puis chercher u tq $\|Xu\|_2^2$ est maximale et $\|u\|_2 = 1$ et $u^T v_1 = 0$ (observable).

On peut montrer facilement que $u = v_2$.
Récursivement, on obtient (v_1, \dots, v_k) les vecteurs propres de $X^T X$ associés aux valeurs propres $D_{v_1}^2 \geq D_{v_2}^2 \geq \dots \geq D_{v_k}^2 \geq 0$.

on a alors : $Y = (Y_1 \dots Y_k) = (Xv_1 \dots Xv_k)$
 $Y = (D_{v_1} Y_1) \dots (D_{v_k} Y_k)$

↳ la variance totale est alors : $\sum_{l=1}^k \|D_{v_l} Y_l\|_2^2 = \sum_{l=1}^k D_{v_l}^2$

A noter que la variance totale avant projection est : $\sum_{l=1}^m D_{v_l}^2$

Une façon de choisir k (dimension de l'espace sur lequel on projette) :

$$\min \left\{ k \mid \frac{\sum_{l=1}^k D_{v_l}^2}{\sum_{l=1}^m D_{v_l}^2} \geq 0.95 \right\}$$

↳ ou autre : 0.99, 0.90, 0.80, ...

Remarques :

◦ les données sont centrées

$$XV_1 = \begin{pmatrix} x_{11}^T V_1 \\ \vdots \\ x_{n1}^T V_1 \end{pmatrix} \rightarrow (\sum x_{i1}^T V_1) = (\sum x_{i1}) V_1 = 0$$

◦ les features créées sont décorréllées :

$$i \neq j, (XV_i)^T (XV_j) = V_i^T X^T X V_j = V_i^T V V^T V_j \\ \underbrace{= 0}$$

⇒ D'ailleurs, on utilise cette méthode pour "décorréller des features" (ie avoir de nouvelles features décorréllées)

◦ les features créées perdent en interprétabilité/expliquabilité

Ideé générale : garder le plus de "dispersion" possible entre les données.