

SVD 奇异值分解. singular value decomposition

$$A \in M_{m \times n}(\mathbb{R})$$

$$(SVD) \quad A = Q D P^T.$$

$$Q \in O(m) \quad P \in O(n)$$

$$D = \begin{bmatrix} \sigma_1 & & & & \\ & \sigma_2 & & & \\ & & \dots & & \\ & & & \sigma_m & \\ \hline & & & & 0 \end{bmatrix} \quad m \geq n$$

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_m \geq 0$$

$A^T A$ 半正定, 对称, 正交对角化

eigen vectors $v_1, v_2, \dots, v_n \in \mathbb{R}^n$.

eigen values $\lambda_1, \lambda_2, \dots, \lambda_n \in \mathbb{R}$
 ≥ 0

$$\lambda_i = (\sigma_i)^2$$

$$P = (v_1 \ v_2 \ \dots \ v_n)$$

$$\begin{aligned} \underline{A^T A} &= (Q D P^T)^T \cdot (Q D P^T) \\ &= P \cdot D^T \cdot Q^T \cdot Q D P^T \end{aligned}$$

$$= P \cdot \underline{(D^T D)} P^T.$$

$$(A^T A) \cdot (v_1 \cdots v_n) = \underline{(v_1 \cdots v_n)} \cdot \begin{pmatrix} | & & | \\ | & & | \\ | & & | \end{pmatrix}$$

$$\underline{(A^T A)} P = P \cdot \begin{pmatrix} (r_1)^2 & & & \\ & (r_2)^2 & & \\ & & \ddots & \\ & & & (r_n)^2 \end{pmatrix}$$

同样有 $Q = (w_1 w_2 \cdots w_m)$

w_i 是 $A \cdot A^T$ 的特征向量.

特征值是 $(r_i)^2$, 或者 0
($i \geq n+1$).

(事实. A $m \times n$. AB . BA .
 B $n \times m$, 除 0 以外的特征
值相同.)

$(m \geq n)$ AB 比 BA 多 $m-n$ 个
0 特征值. (代数重数)

$$m=n. |\lambda I - AB| = |\lambda I - BA|$$

$$P = (v_1 \dots v_n), \quad Q = (w_1 \dots w_m)$$

$$A = \frac{(w_1 \dots w_m)}{\quad} \cdot \begin{pmatrix} \sigma_1 & \dots & \sigma_n \\ & & 0 \end{pmatrix} \begin{pmatrix} v_1^T \\ \vdots \\ v_n^T \end{pmatrix}$$

$$= \sum_{i=1}^{\min(m,n)} \sigma_i \cdot (w_i) \cdot v_i^T$$

A 来源

有 n 个变量, $1, 2, \dots, n$

(每一种组件的浓度)

(温度, 气压, 风速)

A

$(x_{11}, x_{12}, \dots, x_{1n})$

一次试验的结果

(一位用户的数据)

(一个点, 一个时刻的天气)

$(x_{21}, x_{22}, \dots, x_{2n})$

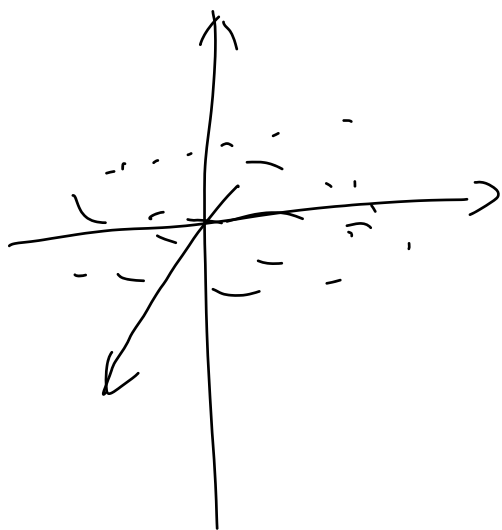
\vdots

$(x_{m1}, x_{m2}, \dots, x_{mn})$

$\leftarrow m$ 次试验.

A 行向量是每一次的数据

$$A = \begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_m \end{pmatrix}$$



0 维.

$$P^T = \begin{pmatrix} v_1^T \\ \vdots \\ v_n^T \end{pmatrix}$$

标准正交基.

$$A = \underline{(QD)} \cdot P^T$$

P^T 是一组新的基. C

QD 的第 i 行 是 α_i^T 在 C 下的坐标.

直观下, $\underline{v_1^T, \dots, v_n^T}$ 方向的重要性
由 v_1, \dots, v_n 来刻画.

秩逼近

定义: $A_r = Q \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_r & & \\ & & & & & 0 \end{bmatrix} P^T$

$\text{rk } A_r \leq r$

$$= \sum_{i=1}^r \sigma_i w_i v_i^T$$



Q 的前 r 列



P^T 的
前 r 行


定理: $\|A - A_r\|_F \leq \|A - B\|_F$ $\forall B, \text{rk } B \leq r$

(Eckart-Young, Schmidt)

$$\langle A, B \rangle_F = \text{Tr}(A^T B)$$

$$A = (a_{ij}), B = (b_{ij}) \quad \langle A, B \rangle_F = \sum_i \sum_j a_{ij} b_{ij}$$

低秩逼近的几何



$$A_r = Q \cdot \begin{pmatrix} \sigma_1 & & & \\ & \dots & & \\ & & \sigma_r & \\ & & & \dots \end{pmatrix} \begin{pmatrix} v_1^T \\ \vdots \\ v_r^T \\ 0 \end{pmatrix}$$

A_r 的第 i 行是 α_i 在 W 上的投影

$Q \cdot \begin{pmatrix} \sigma_1 & & & \\ & \dots & & \\ & & \sigma_r & \\ & & & \dots \end{pmatrix}$ 第 i 行是该投影在 $v_1^T \dots v_r^T$ 下的坐标.

Frobenius norm $\|\cdot\|_F$.

3/理1. $C \in \mathcal{O}(m)$. A, B $m \times n$.

$$\langle C \cdot A, C \cdot B \rangle_F = \langle A, B \rangle_F$$

1'. $C \in \mathcal{O}(n)$. A, B $m \times n$

$$\langle A \cdot C, B \cdot C \rangle_F = \langle A, B \rangle_F$$

Min-Max property for singular value.

3/理2. $\sigma_1 = \max_{\substack{v \in \mathbb{R}^n \\ v \neq 0}} \frac{|A \cdot v|}{|v|} \in \mathbb{R}$ quotient.

pf: $\lambda_1(A^T A) = \max_{\substack{v \in \mathbb{R}^n \\ v \neq 0}} \frac{\langle v, A^T A v \rangle}{\langle v, v \rangle}$

$$= \max_{\substack{v \in \mathbb{R}^n \\ v \neq 0}} \frac{\langle A v, A v \rangle}{\langle v, v \rangle}$$

$$\sigma_1 = \sqrt{\lambda_1}$$

引理 3.

$$\sigma_k(A - A_r) = \sigma_{k+r}(A)$$

$$A - A_r = Q \begin{pmatrix} 0 & \dots & 0 & \sigma_{r+1} & \sigma_{r+2} & \dots & 0 \\ \hline & & & & & & 0 \end{pmatrix} P^T$$

$A - A_r$ 的 SVD.

$$= \sum_{k=1}^{\min(m,n)-r} \sigma_{r+k} \cdot W_{r+k} \cdot V_{r+k}^T$$

推论: $\langle A, A \rangle_F = \|A\|_F^2$

$$= \sum_{i=1}^{\min(m,n)} (\sigma_i)^2$$

$$\|A - A_r\|_F^2 = \sum_{i=r+1}^{\min(m,n)} (\sigma_i)^2$$



$k \in r$

不是线性条件.

引理 4: B $m \times n$. $\text{rk } B \leq r$

$$\sigma_1(A-B) \geq \sigma_{r+1}(A)$$

$$(\text{特别 } \sigma_1(A-A_r) = \sigma_{r+1}(A))$$

证: 取 $v \in \text{span}(v_1, \dots, v_{r+1}) = W$
 $\dim = r+1$.

P 的前 $r+1$ 列

$\text{rk } B \leq r \Rightarrow$ 存在 $v \in W, v \neq 0$
 $B \cdot v = 0$

$$\sigma_1(A-B) \geq \frac{|(A-B) \cdot v|}{|v|}$$

$$= \frac{|A \cdot v|}{|v|} = \sqrt{\frac{\langle v, A^T A v \rangle}{\langle v, v \rangle}}$$

$$v = \sum_{i=1}^{r+1} a_i v_i$$

$$= \sqrt{\frac{\sum_{i=1}^{r+1} (\lambda_i) \cdot a_i^2}{\sum_{i=1}^{r+1} a_i^2}} \geq \sqrt{\lambda_{r+1}} = \sigma_{r+1}$$

3) 证: $\sigma_k(A-B) \geq \sigma_{k+r}(A)$
 $r_k B \leq r$

Pf: $\sigma_k(A-B) = \sigma_1((A-B) - (A-B)_{k-1})$
 $= \sigma_1(A - (B + (A-B)_{k-1}))$

$\left\{ \begin{array}{l} r_k B \leq r \\ r_k (A-B)_{k-1} \leq k-1 \end{array} \right.$

$r_k (B + (A-B)_{k-1}) \leq r + k - 1$

(3) 证 4) $\geq \sigma_{r+k}(A)$

定理的证明:

$\|A-B\|_F^2$

$= \sum_{i=1}^n (\sigma_i(A-B))^2$

$\geq \sum_{i=1}^n (\sigma_{i+r}(A-B))^2$

$\geq \|A-A_r\|_F^2$

图像压缩. 2D 灰度图 像素 $m \times n$.

$$A = (a_{ij})$$

$r \ll \min(m, n)$. $A_r = \begin{pmatrix} \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \end{pmatrix} \begin{pmatrix} \sigma_1 & \dots & \sigma_r \end{pmatrix} \cdot \begin{pmatrix} \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \end{pmatrix}$

$r \times j$ r 行


$m \gg n$ m 次试验. 采样.
 n 维数据


定理:

$$W_r = \text{span}(v_1, \dots, v_r)$$

W_r minimize among r -dim subspaces of \mathbb{R}^n

$$\sum_{i=1}^m (\text{distance}(x_i, W))^2$$





人脸识别

PCA

principal component analysis

(消除平均值的影"响)

m 次采样 取平均 $\frac{1}{m} \left(\sum_{i=1}^m x_i^T \right) = \mu$

$$\bar{\mu} = \begin{pmatrix} \vdots \\ \vdots \end{pmatrix} \cdot \mu$$

$$\underline{B = (A - \bar{\mu})}$$

B 的每一列平均值为 0


$$\underline{(A - \bar{\mu})_r + \bar{\mu}} \quad \underline{PCA}$$

取 B 对应的 SVD

$$B = \underline{Q U P^T}$$

$$B_r = Q \cdot \begin{pmatrix} v_1 \dots v_r \end{pmatrix}$$

$$\begin{pmatrix} v_1^T \\ \vdots \\ v_r^T \end{pmatrix}$$



沿 μ 作平移的
2 维平面

逼近性质:

$$\mu + \text{span}(v_1, \dots, v_r)$$

r 维的平面 (不一定经过原点)
仿射

与 x_1, \dots, x_m 的距离平方和最小的

(与 SVD, $\dim = r$ 逼近好
不比 $r+1$ 好)