

第十五讲 奇异值分解

2024.4.29

上半学期: normal多元正态
下半学期: singular奇异值分解

奇异值分解(SVD)

列空间

对任一 $n \times p$ 矩阵 X , 其列向量张成的空间 (简称列空间) 记作
 $C(X) = \{X\mathbf{t}: \mathbf{t} \in R^p\}$

引理1. (1) 列空间 $C(X) = C(XX^T)$; 行空间 $C(X^T) = C(X^T X)$.

(2) $X^T X$ 与 XX^T 有相同的非0特征根, 特征向量相互关联。特别地, 若 \mathbf{a} 是 $X^T X$ 的特征向量, 则 $\mathbf{b} = X\mathbf{a}$ 是 XX^T 的特征向量; 若 \mathbf{b} 是 XX^T 的特征向量, 则 $\mathbf{a} = X^T \mathbf{b}$ 是 $X^T X$ 的特征向量。

证: (1) $C(XX^T) = \{XX^T \mathbf{t}: \mathbf{t} \in R^p\} = \{X\mathbf{s}: \mathbf{s} = X^T \mathbf{t} \in R^p\} \subset C(X)$

若 $\mathbf{x} \in C(XX^T)^\perp$, $XX^T \mathbf{x} = 0 \Rightarrow \mathbf{x}^T XX^T \mathbf{x} = 0 \Rightarrow X^T \mathbf{x} = 0 \Rightarrow \mathbf{x} \in C(X)^\perp$
 $\Rightarrow C(XX^T)^\perp \subset C(X)^\perp, C(X) \subset C(XX^T)$.

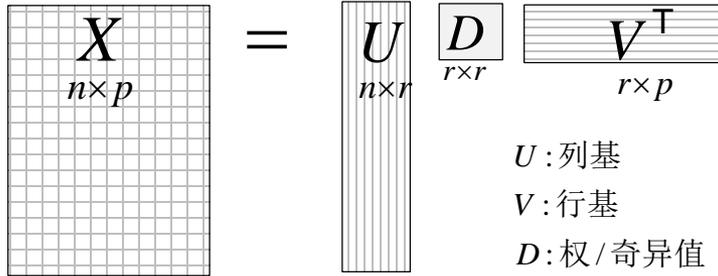
(2). $X^T \mathbf{b} = X^T X \mathbf{a} = \mathbf{a} \lambda \Rightarrow XX^T (X\mathbf{a}) = (X\mathbf{a}) \lambda$.

引理1蕴含了奇异值分解 (SVD, singular value decomposition)。特别地, 为了刻画矩阵 X 的列空间特征, 我们可以考虑 XX^T 的列空间特征 (特征向量)。对 X 的行也是如此。

SVD

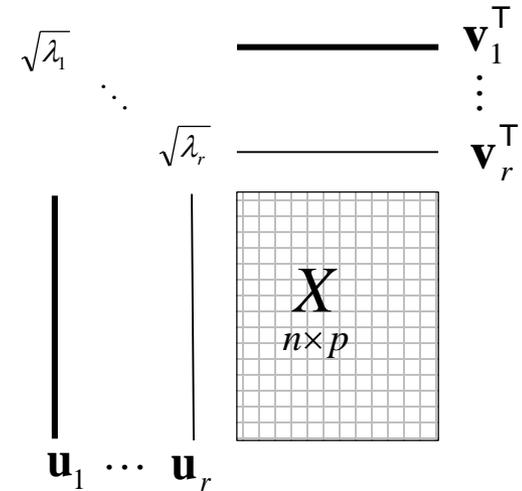
$$X = UDV^T$$

$$X = UDV^T$$



$$X_{n \times p} = U_{n \times r} D_{r \times r} V^T_{r \times p}$$

U : 列基
 V : 行基
 D : 权/奇异值



$$X_{n \times p} = U_{n \times r} D_{r \times r} V^T_{r \times p}$$

$u_1 \dots u_r$
 $v_1^T \dots v_r^T$

定理1(SVD). 任一秩为 r 的 $n \times p$ 矩阵 X 可表示为

$$X = U_{n \times r} D_{r \times r} V^T_{r \times p} = \sqrt{\lambda_1} \mathbf{u}_1 \mathbf{v}_1^T + \sqrt{\lambda_2} \mathbf{u}_2 \mathbf{v}_2^T + \dots + \sqrt{\lambda_r} \mathbf{u}_r \mathbf{v}_r^T$$

其中 $U^T U = V^T V = I_r$, $D = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_r})$ 的对角元称为奇异值, 其中 $\lambda_1 \geq \dots \geq \lambda_r > 0$ 为 $X^T X$ 或 XX^T 的 r 个正特征根, $U = (\mathbf{u}_1, \dots, \mathbf{u}_r)$, $V = (\mathbf{v}_1, \dots, \mathbf{v}_r)$ 的各列分别是 XX^T , $X^T X$ 的特征向量。

注：当 X 是中心化的数据矩阵， $Y = XV = UD$ 是主成分矩阵（第 k 列是第 k 主成分）。

证明: $X^T X$ 的非0特征根的特征方程:

$$X^T X \mathbf{v}_i = \mathbf{v}_i \lambda_i, i = 1, \dots, r \Leftrightarrow X^T X V = V D^2,$$

其中 $D^2 = \text{diag}(\lambda_1, \dots, \lambda_r)$

↓ 令 $Y = X V$

$$X X^T X V = X V D^2 \Leftrightarrow X X^T Y = Y D^2, Y^T Y = V^T X^T X V = D^2$$

Y 的列是 $X X^T$ 的正交特征向量, 模长分别为 $\sqrt{\lambda_1}, \dots, \sqrt{\lambda_r}$

↓ 令 $U = Y D^{-1}$ (Y 单位化)

$U^T U = I_r$, U 的列是 $X X^T$ 的单位正交特征向量

综上 $Y = X V = U D$, 左乘 $V^T \Rightarrow X V V^T = U D V^T$

因为 $C(V) = C(X^T X) = C(X^T)$, $V V^T = P_V = P_{X^T}$, 所以

$$U D V^T = X V V^T = X P_V = X P_{X^T} = X.$$

若 X 已经中心化, 则 $X^T X = (n-1)S$

若 X 已经中心化, 则 Y 是主成分矩阵。

SVD的一些评注

□ 若 X 已经中心化, 则 $\text{SVD} \Leftrightarrow \text{PCA}$

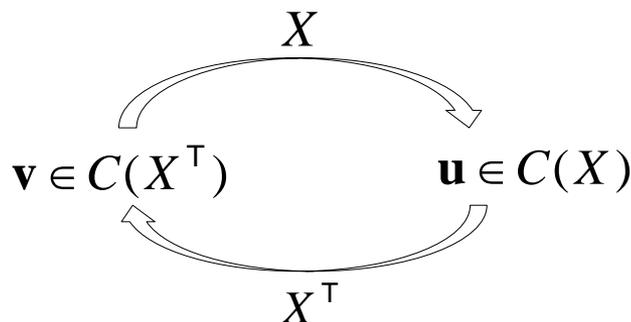
$X^T X = (n - 1)S$, $Y = X V = U D$ 是所有非0奇异值对应的主成分。

□ 正交展开: $X = U D V^T = \sqrt{\lambda_1} \mathbf{u}_1 \mathbf{v}_1^T + \dots + \sqrt{\lambda_r} \mathbf{u}_r \mathbf{v}_r^T$.

□ V 、 U 分别是 X 的行、列特征: $X X^T U = U D^2$, $X^T X V = V D^2$

□ 对偶方程: $X V = U D$, $X^T U = V D$

对 U , V 的特定一列 \mathbf{u} , \mathbf{v} (对应的特征根 λ): $X \mathbf{v} = \mathbf{u} \sqrt{\lambda}$, $X^T \mathbf{u} = \mathbf{v} \sqrt{\lambda}$



虽然 X 不是方阵, 没有特征向量, 但 $\{\mathbf{v}, \mathbf{u}\}$ 可看作是 X 及其伴随 X^T 的不变量

例1.

$$X = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 3 \\ 0 & 0 & 0 & 0 \end{pmatrix}, \quad XX^T = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 \\ 0 & 0 & 9 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}, \quad X^T X = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 4 & 0 \\ 0 & 0 & 0 & 9 \end{pmatrix},$$



XX^T 的特征根: $\lambda_1 = 9$, $\lambda_2 = 4$, $\lambda_3 = 1$ 。 X 的奇异值: 3,2,1

$$X = UDV^T$$

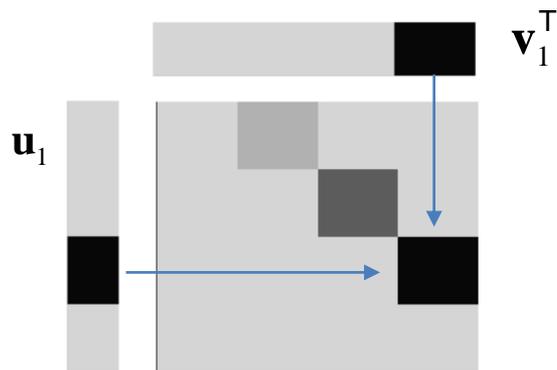
$$\text{其中 } U = \begin{pmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}, \quad V = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{pmatrix}, \quad D = \text{diag}(3,2,1)$$

XX^T 或 $X^T X$ 的最大特征根 $\lambda_1 = 9$ 对应的特征向量

• $\mathbf{u}_1 = (0,0,1,0)^T$: X 的第3行最重要, $(XX^T)_{33}$ 最大

• $\mathbf{v}_1 = (0,0,0,1)^T$: X 的第4列最重要, $(X^T X)_{44}$ 最大

如下图, $\mathbf{u}_1 \mathbf{v}_1^T$ 定位矩阵 X 的最重要的位置: (3,4)



类似地, 第二大特征值4对应的 $\mathbf{u}_2 = (0,1,0,0)^T$, $\mathbf{v}_2 = (0,0,1,0)^T$,

$\mathbf{u}_2 \mathbf{v}_2^T$ 定位矩阵 A 的 (2,3) 位置, $\mathbf{u}_3 \mathbf{v}_3^T$ 定位矩阵 A 的 (1,2)

$$\text{1阶逼近: } 3\mathbf{u}_1\mathbf{v}_1^T = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 3 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

$$\text{2阶逼近: } 3\mathbf{u}_1\mathbf{v}_1^T + 2\mathbf{u}_2\mathbf{v}_2^T = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 3 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

$$\text{3阶即为原数据: } 3\mathbf{u}_1\mathbf{v}_1^T + 2\mathbf{u}_2\mathbf{v}_2^T + \mathbf{u}_3\mathbf{v}_3^T = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 3 \\ 0 & 0 & 0 & 0 \end{pmatrix} = X$$

矩阵分解和低秩逼近

矩阵的低秩逼近(low rank approximation)或矩阵分解逼近(matrix factorization)可以将数据矩阵在低维(低秩)空间上表示, 利于发现数据结构或压缩数据。

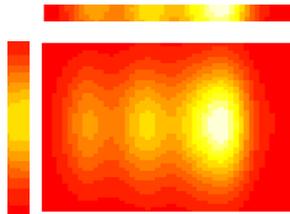
$$\boxed{\begin{matrix} X \\ n \times p \end{matrix}} \approx \boxed{\begin{matrix} C \\ n \times k \end{matrix}} \times \boxed{\begin{matrix} R^T \\ k \times p \end{matrix}}$$

$$k < r = \text{rank}(X)$$

矩阵分解不唯一, 我们感兴趣的是低秩(小 k)逼近或者对 C , R 有额外的限制的情形。我们将看到, 在平方误差意义下, 最优的秩 k 逼近是奇异值分解的前 k 项, 这说明了奇异值分解的优良性

首先注意到，任意一个秩为1的矩阵 $X_{n \times p}$ 可以表示为两个向量的外积：

$$X = \mathbf{c} \mathbf{r}^T,$$

$\begin{matrix} & \mathbf{r}^T \\ \mathbf{c} & \end{matrix}$


• 对任何矩阵 $X = (x_{ij})$ ，我们以秩1矩阵逼近 X ：

$$X = \mathbf{c} \mathbf{r}^T + E, \quad E = (\varepsilon_{ij}) \text{ 误差}$$

$\begin{matrix} X & \mathbf{c} & \mathbf{r}^T & E \\ n \times p & n \times 1 & 1 \times m & n \times m \end{matrix}$

$$\Leftrightarrow \text{乘积模型: } x_{ij} = c_i r_j + \varepsilon_{ij}$$

• 我们也可以应用方差分析中的“可加模型”

$$x_{ij} = c_i + r_j + \varepsilon_{ij} \Leftrightarrow X = \mathbf{c} \mathbf{1}^T + \mathbf{1} \mathbf{r}^T + E$$

$\begin{matrix} X & \mathbf{c} & \mathbf{1}^T & \mathbf{1} & \mathbf{r}^T & E \\ n \times p & n \times 1 & 1 \times m & n \times 1 & 1 \times m & n \times m \end{matrix}$

近似逼近矩阵 X ，其中 \mathbf{r} ， \mathbf{c} 未知，可称为行效应和列效应。

可加模型不易推广到更高秩情形。

矩阵分解

引理2. 任一秩 k 矩阵 $X_{n \times p}$ 可表示为矩阵分解形式 $X = CR^T$, 其中 C, R 分别是 $n \times k, p \times k$ 列满秩矩阵。

证: 取 $\mathbf{t}_1, \dots, \mathbf{t}_k$ 为行空间 $C(X^T)$ 的一组基, $R = (\mathbf{t}_1, \dots, \mathbf{t}_k)$, 记 X 的第 i 行为 \mathbf{x}_i^T , 存在 \mathbf{s}_i , 使得 $\mathbf{x}_i = R\mathbf{s}_i, i = 1, \dots, n$, 所以 $X = (\mathbf{x}_1, \dots, \mathbf{x}_n)^T = (R\mathbf{s}_1, \dots, R\mathbf{s}_n)^T = CR^T$ 。

$$C_{n \times k} = (\mathbf{c}_1, \dots, \mathbf{c}_k) = (\mathbf{s}_1, \dots, \mathbf{s}_n)^T,$$
$$R_{p \times k} = (\mathbf{r}_1, \dots, \mathbf{r}_k) = (\mathbf{t}_1, \dots, \mathbf{t}_n)^T$$

两种理解

- 正交展开: $X = CR^T = \mathbf{c}_1\mathbf{r}_1^T + \dots + \mathbf{c}_k\mathbf{r}_k^T$
 C 的列向量 $\{\mathbf{c}_i, i = 1, \dots, k\}$ 是 X 的列空间的基;
 R 的列向量 $\{\mathbf{r}_i, i = 1, \dots, k\}$ 是 X 的行空间的基。

- 行列关系: $X = CR^T = (\mathbf{s}_i^T \mathbf{t}_j)$: $x_{ij} = \mathbf{s}_i^T \mathbf{t}_j$
 $\{\mathbf{s}_i, i = 1, \dots, n\}$ 是 X 的各行(样本)的某种feature;
 $\{\mathbf{t}_j, j = 1, \dots, p\}$ 是 X 的各列(变量)的某种feature.
(参见例2)

列基

$$X = C R^T$$

行基

当 \mathbf{s}_i 与 \mathbf{t}_j 相似,
 $x_{ij} = \mathbf{s}_i^T \mathbf{t}_j$ 较大

例2(推荐系统的矩阵分解算法). 2006年*Netflix*推荐数据比赛优胜者使用了矩阵分解算法。用户 U_1, U_2, \dots 给电影 M_1, M_2, \dots 打分(1-5分), 假设用户个数 n , 电影个数 p , 用户 i 给电影 j 的打分为 x_{ij} , $X_{n \times p} = (x_{ij})$ 。每个观众只看过少数电影, 所以该矩阵大部分元素为空。我们的任务是填充上这些空格, 进行推荐。

	M1	M2	M3	M4
U1	5	3	-	1
U2	4	-	-	1
U3	1	1	-	5
U4	1	-	-	4
U5	-	1	5	4

来源: <http://www.albertauyeung.com/post/python-matrix-factorization/>

经典算法： 协同过滤

协同过滤算法 (collaborative filtering) 假设对某些电影评价类似/相反的用户对其它电影也应有类似/相反的评价，是推荐系统中最常见的假设。

	M1	M2	M3	M4
U1	5	3	?	1
U2	4	?		1
U3	1	1		5
U4	1			4
U5		1	5	4

U2对M2的评价？

U1, U2都评价了M1和M4，打分类似。U1对M2的评价为3，我们推测U2对M2的评价大概为3

U1对M3的评价？

U1似乎与U3, 4, 5相反，U5的评价为5，故推测U1对M3的评价较小，比如1.

	M1	M2	M3	M4
U1	5	3	1	1
U2	4	2	1	1
U3	1	1	5	5
U4	1	1	4	4
U5	1	1	5	4

Netflix算法： 矩阵分解

假设一个人对某个电影评价高，是因为该电影具有的某些特征恰好是该观众/用户喜欢的类型。假设电影的特征(潜变量)有 k 个，比如题材、导演等等。这些特征在电影和用户上的体现：

- $\mathbf{s}_i = (s_{i1}, \dots, s_{ik})^\top$, s_{if} = 用户 i 的对特征 f 的喜好。
- $\mathbf{t}_j = (t_{j1}, \dots, t_{jk})^\top$, t_{jf} = 电影 j 的特征 f 刻画。

假设模型： \mathbf{s}_i 和 \mathbf{t}_j 的相似程度决定了用户 i 给电影 j 的打分：

$$\begin{aligned} \text{用户 } i \text{ 给电影 } j \text{ 的打分: } x_{ij} &\approx \mathbf{s}_i^\top \mathbf{t}_j = \sum_{f=1}^k s_{if} t_{jf} \\ &= \sum_{f=1}^k (\text{用户 } i \text{ 对特征 } f \text{ 的喜好程度}) \times (\text{电影 } j \text{ 含有特征 } f \text{ 的程度}) \end{aligned}$$

现假设有 n 个用户， p 个电影，用户 i 给电影 j 的打分为 x_{ij} 。

求解 $\{\mathbf{s}_i, \mathbf{t}_j, 1 \leq i \leq n, 1 \leq j \leq p\}$ ，最小化误差平方和

$$J = \sum_{i,j} (x_{ij} - \mathbf{s}_i^\top \mathbf{t}_j)^2 = \|X - CR^\top\|_F^2.$$

- 如果X没有空值，我们将会看到，最优解为SVD的前k阶展开；
- Netflix:如果有空值，误差平方和只对非空格子求和，使用梯度下降法求解；
- 如果有空值，也可先使用协同过滤填充，再使用SVD重写拟合，调整填充内容。

Netflix矩阵分解推荐算法(matrix factorization, Stochastic gradient descent)

目标：假设 $J(\theta)$ 可写为 $\sum J_k(\theta_k)$ ，最小化 $J(\theta)$

梯度(Gradient): $\nabla J_k(\theta_k) = \frac{\partial J_k(\theta_k)}{\partial \theta_k}$

算法: $\theta_k^{(\text{update})} \leftarrow \theta_k^{(0)} - \eta \nabla J(\theta_k^{(0)})$

SVD及矩阵的最佳低秩逼近

低秩逼近问题

给定 $n \times p$ 矩阵 X , 求解秩为 k 的 $n \times p$ 矩阵 A , 使得误差平方和最小:

$$\min_{\text{rank}(A)=k} \|X - A\|_F^2 = \min_{\substack{C_{n \times k}, R_{k \times p} \\ \text{列满秩}}} \|X - CR^T\|_F^2$$

其中矩阵的Frobenius 模定义为 $\|A\|_F = \sqrt{\sum_{i,j} a_{ij}^2} = \sqrt{\text{tr}(A^T A)}$.

- 上述低秩逼近的最优解是 k -阶SVD（下页定理2）
- 对特定的问题，矩阵分解施加一些限制将会得到不同于SVD的其它方法。例如
 - ❖ 如果限制 R 的元素为0, 1, 代表 k 个类别的哑变量表示，得到的解将会把数据点聚集为 k 类（聚类分析）。
 - ❖ 若 X 元素非负，要求 C, R 元素也是非负，那么得到非负矩阵分解（non-negative matrix factorization, NMF），该方法因为容易解释且具有聚类效果而颇为流行。

SVD的最优性

定理2(Eckart - Young - Mirsky).

若 $X_{n \times p}$ 的奇异值分解为 $X = UDV^T = \sum_{i=1}^r \sqrt{\lambda_i} \mathbf{u}_i \mathbf{v}_i^T$, $r = \text{rank}(X)$, 则对任何 $k \leq r$,

$$\min_{\substack{A \in \mathbb{R}^{n \times p} \\ \text{rank}(A)=k}} \|X - A\|_F^2 = \|X - \sum_{i=1}^k \sqrt{\lambda_i} \mathbf{u}_i \mathbf{v}_i^T\|_F^2 = \sum_{i=k+1}^r \lambda_i$$

即 X 的最优秩 k 逼近为 $A_{\text{opt}} = \sum_{i=1}^k \sqrt{\lambda_i} \mathbf{u}_i \mathbf{v}_i^T = U_k D_k V_k^T$, 其中 $U_k = (\mathbf{u}_1, \dots, \mathbf{u}_k)$,

$V_k = (\mathbf{v}_1, \dots, \mathbf{v}_k)$, $D_k = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_k})$ 。

证明：首先,对任何给定的 $p \times k$ 矩阵 R ,不妨假设 R 是列正交且单位化的, 即 $R^T R = I_k$, 则必定有

$$\min_{C \in \mathbb{R}^{n \times k}} \|X - CR^T\|_F^2 = \|X - XRR^T\|_F^2 \quad (*)$$

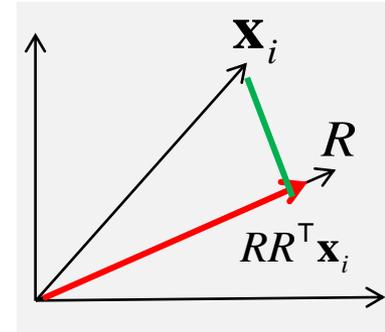
如果 R 不是列正交的, 那么我们可以把 R 的列向量Schmidt正交化: $R = \tilde{R}T$, $\tilde{R}^T \tilde{R} = I_k$, T 是上三角, 则 $CR^T = CT^T \tilde{R}^T \stackrel{\Delta}{=} \tilde{C} \tilde{R}^T$

这是因为对于给定的 R , $\|X - CR^T\|_F^2 = \sum_{i=1}^n \|\mathbf{x}_i - R\mathbf{c}_i\|^2$, 其中

$X = (\mathbf{x}_1, \dots, \mathbf{x}_n)^T$, $C = (\mathbf{c}_1, \dots, \mathbf{c}_n)^T$ 。

由最小二乘性质，每一项 $\|\mathbf{x}_i - R\mathbf{c}_i\|^2$ 在 $R\mathbf{c}_i = P_R\mathbf{x}_i$
 $= R(R^T R)^{-1} R^T \mathbf{x}_i = RR^T \mathbf{x}_i$ ，即 $\mathbf{c}_i = R^T \mathbf{x}_i$ ， $C = XR$ 时达到最小。

$$\Rightarrow \min \sum_{i=1}^n \|\mathbf{x}_i - R\mathbf{c}_i\|^2 = \sum_{i=1}^n \|\mathbf{x}_i - RR^T \mathbf{x}_i\|^2 = \|X - XRR^T\|_F^2。$$



其次，注意到：

$$\begin{aligned} \|X - XRR^T\|_F^2 &= \text{tr}(X - XRR^T)^T (X - XRR^T) \\ &= \text{tr}(X^T X - X^T XRR^T - RR^T X^T X + RR^T X^T XRR^T) \\ &= \text{tr}(X^T X) - \text{tr}(R^T X^T XR) = \|X\|_F^2 - \|XR\|_F^2 \end{aligned}$$

因此，

$$\min \|X - XRR^T\|_F^2 \Leftrightarrow \max \|XRR^T\|_F^2 = \max \|XR\|_F^2 = \max \text{tr}(R^T X^T XR)$$

记 R 的各列 $R = (\mathbf{r}_1, \dots, \mathbf{r}_k)$, 则 $R^T X^T X R = (\mathbf{r}_i^T X^T X \mathbf{r}_j^T, 1 \leq i, j \leq k)$, 所以

$$\|XR\|_F^2 = \text{tr}(R^T X^T X R) = \mathbf{r}_1^T X^T X \mathbf{r}_1 + \dots + \mathbf{r}_k^T X^T X \mathbf{r}_k$$

因为 $R^T R = I_k$, $\mathbf{r}_1, \dots, \mathbf{r}_k$ 是相互正交的单位长向量。

我们只需极大化各个加项(R 的各个方向上的投影长度):

$$\max_{\|\mathbf{r}_1\|=1} \mathbf{r}_1^T X^T X \mathbf{r}_1, \dots, \max_{\|\mathbf{r}_k\|=1, \mathbf{r}_k \perp \mathbf{r}_1, \dots, \mathbf{r}_{k-1}} \mathbf{r}_k^T X^T X \mathbf{r}_k \quad (**)$$

注意如果 X 已经中心化,
 $X^T X = (n-1)S$,
 (***) 是PCA的极大化问题。

上述各项的最大值分别为 $\lambda_1, \dots, \lambda_k$, 最大值在 $X^T X$ 的前 k 个特征向量 $\mathbf{v}_1, \dots, \mathbf{v}_k$ 达到, 即最优 $\hat{R} = V_k = (\mathbf{v}_1, \dots, \mathbf{v}_k)$. 所以

$$\max \|X\hat{R}\|_F^2 = \|XV_k\|_F^2 = \lambda_1 + \dots + \lambda_k.$$

$$\min \|X - XRR^T\|_F^2 = \|X - XV_k V_k^T\|_F^2 = \text{tr}(X^T X) - \|XV_k\|_F^2 = \lambda_{k+1} + \dots + \lambda_r$$

因为 $XV_k = U_k D_k$, 所以 X 的最佳逼近为

$$X\hat{R}\hat{R}^T = XV_k V_k^T = U_k D_k V_k^T = \sqrt{\lambda_1} \mathbf{u}_1 \mathbf{v}_1^T + \dots + \sqrt{\lambda_k} \mathbf{u}_k \mathbf{v}_k^T.$$

中心化矩阵的SVD等价于PCA

如果 X 已经中心化，我们在第1-2页已经看到PCA与SVD的等价性。从优化的角度来看，从定理2的证明过程，求解低秩逼近等价于极大化方差：

$$\begin{aligned} & \text{低秩逼近 } \min \| X - XRR^T \|_F^2 \Leftrightarrow \max \| XR \|_F^2 \\ & \Leftrightarrow \max_{\mathbf{r}_1, \dots, \mathbf{r}_k \text{ 正交, 模长1}} \left(\mathbf{r}_1^T X^T X \mathbf{r}_1 + \dots + \mathbf{r}_k^T X^T X \mathbf{r}_k \right) \\ & \Leftrightarrow \text{极大化加和中的每一项:} \\ & \max_{\|\mathbf{r}_1\|=1} \left(\mathbf{r}_1^T X^T X \mathbf{r}_1 \right), \max_{\mathbf{r}_2 \perp \mathbf{r}_1, \|\mathbf{r}_2\|=1} \left(\mathbf{r}_2^T X^T X \mathbf{r}_2 \right), \dots, \max_{\mathbf{r}_k \perp (\mathbf{r}_1, \dots, \mathbf{r}_{k-1}), \|\mathbf{r}_k\|=1} \left(\mathbf{r}_k^T X^T X \mathbf{r}_k \right) \end{aligned}$$

这是PCA极大化投影方差问题。

总之，中心化 X 的SVD等价于PCA，若

$$X = UDV^T$$

则 V 的各列是主成分方向， $Y = XV = UD$ 的第 k 列是第 k 主成分。

SVD应用1: 图像压缩

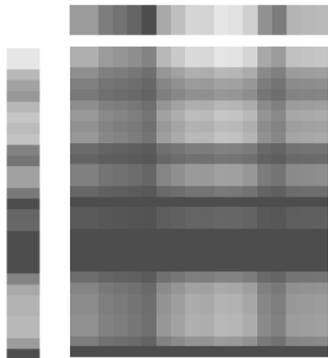
图像压缩中很少采用SVD逼近方法，我们这里采用SVD压缩图像数据知识为了演示目的。

例3. 下表 29×18 矩阵是头像数据，元素为0-1，1: 白，0: 黑。

```
11111111111111111111
11111111111111111111
111110000001110111
111100000000011111
111000000000001111
110000000111001111
110000001111100111
00000001111100111
00000001111100111
00000000010000011
00000000010000001
000000011011100000
000000011011100000
000000001001000000
000000000000000000
000000000001000000
000000000010000000
000000000000000000
000000000000000000
000000000000000000
000000000000000000
000000000000000000
000000000000000000
000000100110000000
000000111111000000
000000111111000000
000000111111000000
000000111111000000
000000111111000000
000000111110000000
000000000000000000
```



$$1: \sqrt{\lambda_1} \mathbf{u}_1 \mathbf{v}_1^T$$



轮廓

$$2: \sqrt{\lambda_2} \mathbf{u}_2 \mathbf{v}_2^T$$



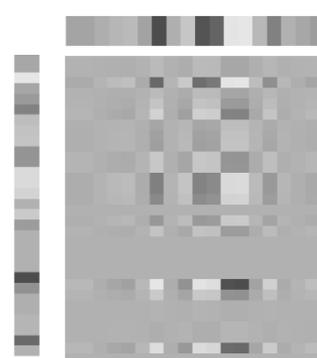
脸部水平特征：
头发,眼睛,嘴巴。
竖直方向边际

$$3: \sqrt{\lambda_3} \mathbf{u}_3 \mathbf{v}_3^T$$



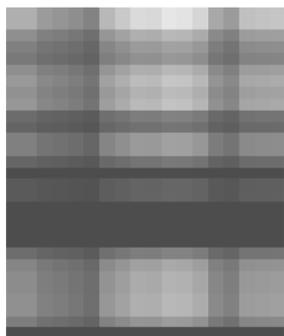
脸部垂直轮廓

$$4: \sqrt{\lambda_4} \mathbf{u}_4 \mathbf{v}_4^T$$

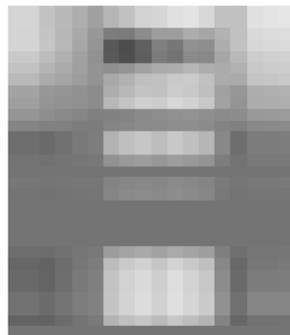


鼻子

1



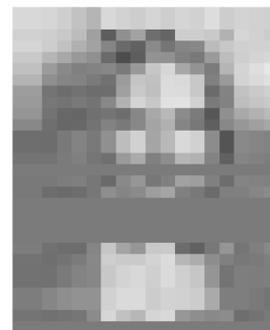
1+2



1+2+3



1+2+3+4



SVD应用2：网页搜索排序

来源：Gilbert Strang (2016) **Introduction to Linear Algebra**, 5th ed

网页排序算法HITS与谷歌的PageRank都出现在1998-1999年，方法也有类似之处，都与SVD有关。

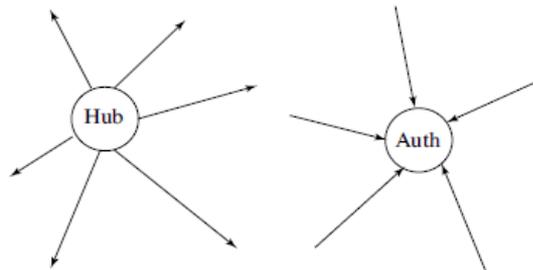
邻接矩阵

网页之间以超链接建立联系。定义邻接矩阵(adjacency matrix)

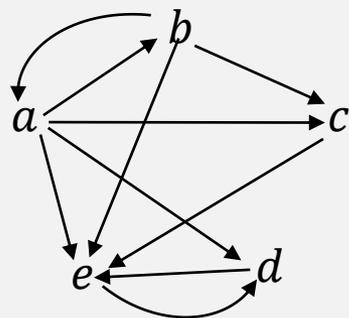
$$A = (a_{ij}), \quad a_{ij} = \begin{cases} 1 & \text{若 } i \text{ 链接到 } j \text{ (记作 } i \rightarrow j \text{)} \\ 0 & \text{否则} \end{cases}.$$

Hub, Authority

链入(in-link): 一个网页被多个网页链入，则其权威性Authority较大。
链出(out-link): 一个网页如果连接到多个其它网页，则其hub较大。



例4. 5个网页链接情况如图。网页*a*指向其它所有4个网页，是链出最多的网页；网页*e*被4个网页链接，是链入最多的网页。



		link-in					合计
		<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>	<i>e</i>	
Link-out $A =$	<i>a</i>	0	1	1	1	1	4
	<i>b</i>	1	0	1	0	1	3
	<i>c</i>	0	0	0	0	1	1
	<i>d</i>	0	0	0	0	1	1
	<i>e</i>	0	0	0	1	0	1
合计		1	1	2	2	4	

如果以网页链入个数（矩阵的列和）作为authority重要性度量，则在这种度量下，*e*最受欢迎（4分）。网页*c*和*d*的得分都是2，但网页*d*被权威性较高的*e*链入，故*d*的authority应该大于*c*。

所以在计算一个网页的权威性计分的时候，不但要考虑链入个数，也要考虑链入网页的权威性。

HITS算法的基本思想：一个权威性网页应该有重要的hub网页链接指向它,一个重要的hub网页应该链接指向一些权威网页。

假设所有网页的权威性计分为向量 \mathbf{v} , hub重要性计分为向量 \mathbf{u} 。
假设网页之间的邻接矩阵为 A （行为 \mathbf{a}_i , 列为 $\boldsymbol{\alpha}_j$ ）。

假设网页 j 的权威性 v_j 与指向它的网页的 hub 计分总值成正比：

$$v_j = c \sum_{k \rightarrow j} u_k = c \boldsymbol{\alpha}_j^T \mathbf{u}, \quad j=1,2,\dots,n \Leftrightarrow \mathbf{v} = cA^T \mathbf{u}.$$

网页 i 的 hub 计分 u_i 依赖于它指向的网页的权威性总分：

$$u_i = d \sum_{i \rightarrow j} v_j = c \mathbf{a}_i^T \mathbf{v}, \quad i=1,2,\dots,n \Leftrightarrow \mathbf{u} = dA \mathbf{v}.$$

注意 $\mathbf{u} = cA \mathbf{v}$ 和 $\mathbf{v} = dA^T \mathbf{u}$ 正是SVD的对偶方程。

$$\Rightarrow \mathbf{u} = cA \mathbf{v} = cdAA^T \mathbf{u}, \quad \mathbf{v} = dA^T \mathbf{u} = cdA^T A \mathbf{v}$$

\mathbf{u} 是 AA^T 的特征向量, \mathbf{v} 是 $A^T A$ 的特征向量, 考虑到逼近最优性,

\mathbf{u} , \mathbf{v} 是SVD: $A = UDV^T$ 中 U, V 的第一列。

例4(续)

> svd(A)

```
$U  [,1] [,2] [,3] [,4] [,5]
[1,] 0.71 -0.53 0.00 -0.45 0.00
[2,] 0.56 0.53 -0.58 0.26 0.00
[3,] 0.28 0.27 0.58 0.13 -0.71
[4,] 0.28 0.27 0.58 0.13 0.71
[5,] 0.13 -0.53 0.00 0.84 0.00
```

网页hub排序(U的第一列):

$a > b > c = d > e$

```
$D
[1] 2.56 1.41 1 0.68 0
```

最大奇异值

```
$V
  [,1] [,2] [,3] [,4] [,5]
[1,] 0.22 0.38 -0.58 0.38 -0.58
[2,] 0.28 -0.38 0.00 -0.67 -0.58
[3,] 0.50 0.00 -0.58 -0.29 0.58
[4,] 0.33 -0.76 0.00 0.57 0.00
[5,] 0.72 0.38 0.58 0.09 0.00
```

网页权威性排序 (V的第一列):

$e > c > d > b > a$

HITS算法的缺点是将一个网页的Authority重要性只与到访网页的hub重要性关联，而没有与到访网页的Authority重要性直接关联。谷歌的PageRank算法也是只使用链接情况而不使用网页内容对网页排序，但不区分auth, hub。

邻接矩阵A将所有网页之间的链接/关联性等同看待，但事实上某个网页 w 被一个对外有很多链接的网页(即hub)链接并不一定说明 w 重要，也即一个网页对外链接越多 (hub性质越强), 它对提升被链接的网页的重要性的作用反而越弱。考虑到这一点，Page and Brin (1998) 把每一个链出网页的重要性平均分配到它链接的网页中。

PageRank的基本思想是：

重要的网页应该链接重要的网页, 而且被对外链接较少的重要网页链接。这样一个自循环的描述其实就是特征向量在变换下的不变性。

PageRank 算法

假设网页 i 的重要性为 x_i , $\mathbf{x} = (x_1, \dots, x_n)^\top$, PageRank假设:

$$x_i = \sum_{k:k \rightarrow i} \frac{x_k}{d_k}, \quad (*)$$

网页 i 的 x_i 等于与之链接的所有网页的重要性 x_k 的加权和, 权重为 $1/d_k$,
 d_k = 网页 k 链出个数, 即邻接矩阵 A 的第 k 行的行和。

设 A 为邻接矩阵, 令各个网站对外链接的个数为 $\mathbf{d} = (d_1, \dots, d_n)^\top$,
即 $\mathbf{d} = A\mathbf{1}_n$ (A 的行和), 令 $D = \text{diag}(\mathbf{d})$, 则假设 (*) 为

$$\mathbf{x} = A^\top D^{-1} \mathbf{x} \quad (**)$$

\mathbf{x} 是 $A^\top D^{-1}$ 的特征根1对应的特征向量。

~~练习: 证明 $H = D^{-1}A$ 的特征根为实数;
证明1是 H 的特征根, 且是最大特征根。~~

~~A对称时该结论才成立。
这里的A不对称。~~

PageRank算法:

邻接矩阵为 A , $D = \text{diag}(A\mathbf{1}_n)$, $H = D^{-1}A$,

记 x_i 为网页 i 的重要性得分(score), PageRank 假设模型: $\mathbf{x} = H^T \mathbf{x}$

迭代求解 \mathbf{x} : $\mathbf{x}^{(k+1)} = H^T \mathbf{x}^{(k)}$, $k = 0, 1, 2, \dots$

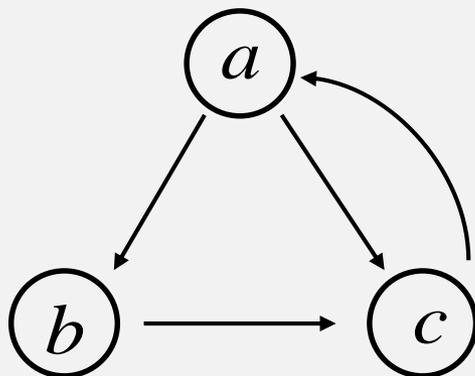
收敛到最大特征根的特征向量。

注1. PageRank对 H 做了修正:

$$\text{Google matrix } G = \alpha H + (1 - \alpha) \mathbf{1}_n \mathbf{1}_n^T / n$$

注2. 鉴于网页数目巨大, 一般的求解特征向量的方法都不适用。
Google使用的幂次迭代计算方法。

例5. 假设如下三个网页



		链入		
		<i>a</i>	<i>b</i>	<i>c</i>
链出	<i>a</i>	0	1	1
	<i>b</i>	0	0	1
	<i>c</i>	1	0	0

$A =$

1. HITS算法

单位化的 $\mathbf{v} = (0, 0.53, 0.85)$, 所以HITS权威性排序: $c > b > a$

2. PageRank算法

a, b, c 的重要性得分, 排序为

$$x_a = x_c = 0.4 > x_b = 0.2,$$

即 a, c 同等重要, 比HITS的排序更合理。