



上海师范大学
Shanghai Normal University

《线性代数》

15-奇异值分解 (Singular Value Decomposition)

杨启哲

上海师范大学信机学院计算机系

2024 年 5 月 23 日

- › SVD 基础
- › 用线来拟合数据
- › 用 k 维子空间拟合数据
- › 再看 $Ax = b$ 的近似解

► SVD 基础

对图片的存储

假设一张图片被如下的矩阵表示:

$$A = \begin{bmatrix} a & a & b & b & c & c \\ a & a & b & b & c & c \\ a & a & b & b & c & c \\ a & a & b & b & c & c \\ a & a & b & b & c & c \\ a & a & b & b & c & c \end{bmatrix}$$

直接存储需要 $6 \times 6 = 36$ 个数。注意到该矩阵的秩 $\text{rank}(A) = 1$, 从而:

$$A = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \begin{bmatrix} a & a & b & b & c & c \end{bmatrix}$$

从而我们只需要存储 12 个数。

注意到实对称矩阵可以对角化，即：

定理 1.

令 S 是一个实对称矩阵， $\lambda_1, \dots, \lambda_n \in \mathbb{R}$ 是其特征值 (可能重复)。从而存在 n 个正交的向量 $v_1, \dots, v_n \in \mathbb{R}^n$ ，使得：

$$S = \begin{bmatrix} v_1 & \cdots & v_n \end{bmatrix} \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix} \begin{bmatrix} v_1^T \\ \vdots \\ v_n^T \end{bmatrix} = \lambda_1 v_1 v_1^T + \cdots + \lambda_n v_n v_n^T$$

从而：

引理 2.

令 S 是一个 $n \times n$ 的实对称矩阵， S 恰好有 $\text{rank}(S)$ 个非零的特征值 (计算代数重数)。从而 S 可以被 $(n + 1)\text{rank}(S)$ 个数字表示。

引理的证明. 注意到 S 是实对称的, 从而存在正交矩阵 Q 使得:

$$Q^T S Q = \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix}$$

因此有:

$$\text{rank}(S) = \text{rank}(\Lambda) = |\{i \in [n] \mid \lambda_i \neq 0\}|$$

令 $s = \text{rank}(S)$, 即存在 s 个正交的向量 $v_1, \dots, v_s \in \mathbb{R}^n$ 使得:

$$S = \lambda_1 v_1 v_1^T + \dots + \lambda_s v_s v_s^T$$

即存储 S 需要 s 个特征值和 s 个特征向量, 共 $(n+1)\text{rank}(S)$ 个数字。 □

奇异值分解 (Singular Value Decomposition)(I)

实对称矩阵可以完成谱分解, 那么对于任意的矩阵 $A \in \mathbb{R}^{m \times n}$, 是否存在类似的分解呢?

答案就是**奇异值分解 (Singular Value Decomposition, SVD)**.

定理 3.

令 A 是一个 $m \times n$ 的矩阵, $\text{rank}(A) = r$, 定义下列 $m \times n$ 的矩阵 Σ :

$$\Sigma = \begin{bmatrix} D & O_{r \times (n-r)} \\ O_{(m-r) \times r} & O_{(m-r) \times (n-r)} \end{bmatrix}, \text{ 其中 } D = \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{bmatrix}$$

这里, $\sigma_1 \geq \dots \geq \sigma_r$ 是 A 的**奇异值**. 则存在 $m \times m$ 的正交矩阵 U 和 $n \times n$ 的正交矩阵 V , 使得:

$$A = U\Sigma V^T$$

特别的, 存在 $u_1, \dots, u_r \in \mathbb{R}^m$ 和 $v_1, \dots, v_r \in \mathbb{R}^n$ 使得:

$$A = \sigma_1 u_1 v_1^T + \dots + \sigma_r u_r v_r^T$$

给定一个任意的矩阵 A , 我们有:

$$(AA^T)^T = AA^T, (A^T A)^T = A^T A$$

即其都是对称矩阵, 同时我们有:

引理 4.

$$\text{rank}(AA^T) = \text{rank}(A^T A) = \text{rank}(A)$$

证明. 我们只需证明:

$$\text{rank}(A^T A) = \text{rank}(A)$$

因为:

$$\text{rank}(AA^T) = \text{rank}((A^T)^T A^T) = \text{rank}(A^T) = \text{rank}(A) = \text{rank}(A^T A)$$

rank($A^T A$) = rank(A) 的证明

由 Rank-Nullity 定理, 我们有:

$$\text{rank}(A^T A) + \dim(N(A^T A)) = n = \text{rank}(A) + \dim(N(A))$$

从而我们只需证明:

$$\dim(N(A^T A)) = \dim(N(A))$$

- 任取 $x \in N(A)$, 即 $Ax = 0$, 从而有:

$$A^T Ax = A^T 0 = 0$$

即 $N(A) \subseteq N(A^T A)$ 。

- 任取 $x \in N(A^T A)$, 即 $A^T Ax = 0$, 从而有:

$$x^T A^T Ax = 0 \implies \|Ax\|^2 = 0 \implies Ax = 0$$

即 $N(A^T A) \subseteq N(A)$ 。

□

现在我们来关注一下 $A^T A$ 和 AA^T 的特征值的性质。

引理 5.

1. $A^T A$ 和 AA^T 的特征值都是非负的。
2. $A^T A$ 和 AA^T 是半正定矩阵。

证明. 这里只证明 $A^T A$ 的特征值是非负的。令 λ 是 $A^T A$ 的一个特征值， v 是对应的特征向量，即：

$$A^T A v = \lambda v$$

从而有：

$$\lambda \|v\|^2 = \lambda v^T v = v^T (\lambda v) = v^T A^T A v = (A v)^T (A v) = \|A v\|^2 \geq 0$$

即：

$$\lambda \geq 0$$

□

引理 6.

令 $\text{rank}(A) = r$, 则 $A^T A$ 和 AA^T 有相同的 r 个非零特征值 (计算重数)。

证明. 由前面的引理可知:

$$\text{rank}(A^T A) = \text{rank}(A) = \text{rank}(AA^T) = r$$

令 $A^T A$ 有如下 n 个特征值:

$$\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n \geq 0$$

其对应的一组标准正交的特征向量为 v_1, \cdots, v_n 。从而:

1. $\lambda_1, \cdots, \lambda_r > 0$ 。
2. $\lambda_{r+1} = \cdots = \lambda_n = 0$ 。
3. 对任意的 $i \in [n]$ 有 $A^T A v_i = \lambda_i v_i$ 且 $\|v_i\| = 1$ 。
4. 对任意的 $1 \leq i < j \leq n$ 有 $v_i \cdot v_j = v_i^T v_j = 0$ 。

$A^T A$ 和 AA^T 的特征值 (III)

考察如下的一组向量 \bar{v} :

$$\bar{v} := \frac{1}{\sqrt{\lambda_1}} A v_1, \dots, \frac{1}{\sqrt{\lambda_r}} v_r$$

我们接下来证明:

1. \bar{v} 是标准正交的。
2. \bar{v} 是 AA^T 的特征值 $\lambda_1, \dots, \lambda_r$ 的特征向量。
3. AA^T 和 $A^T A$ 的特征值的代数重数相同。

从而最终得到:

$A^T A$ 和 AA^T 由相同的 r 个非零特征值 (计算重数)。

我们先证明:

$$\frac{1}{\sqrt{\lambda_1}}Av_1, \dots, \frac{1}{\sqrt{\lambda_r}}v_r$$

是标准正交的。

- 对于 $i \in [r]$. 有:

$$\left\| \frac{1}{\sqrt{\lambda_i}}Av_i \right\|^2 = \left(\frac{1}{\sqrt{\lambda_i}}Av_i \right)^T \frac{1}{\sqrt{\lambda_i}}Av_i = \frac{1}{\lambda_i}v_i^T A^T Av_i = \frac{1}{\lambda_i}v_i^T \lambda_i v_i = \|v_i\|^2 = 1$$

- 对于 $1 \leq i < j \leq r$. 有:

$$\begin{aligned} \left(\frac{1}{\sqrt{\lambda_i}}Av_i \right) \cdot \left(\frac{1}{\sqrt{\lambda_j}}Av_j \right) &= \left(\frac{1}{\sqrt{\lambda_i}}Av_i \right)^T \frac{1}{\sqrt{\lambda_j}}Av_j \\ &= \frac{1}{\sqrt{\lambda_i \lambda_j}}v_i^T A^T Av_j = \frac{1}{\sqrt{\lambda_i \lambda_j}}v_i^T \lambda_j v_j = \sqrt{\frac{\lambda_j}{\lambda_i}}v_i \cdot v_j = 0 \end{aligned}$$

► \bar{v} 是 AA^T 的特征值 $\lambda_1, \dots, \lambda_r$ 的特征向量

我们再证明, 对任意的 $i \in [r]$ 有:

$$AA^T \left(\frac{1}{\sqrt{\lambda_i}} Av_i \right) = \lambda_i \left(\frac{1}{\sqrt{\lambda_i}} Av_i \right)$$

事实上,

$$\begin{aligned} AA^T \left(\frac{1}{\sqrt{\lambda_i}} Av_i \right) &= \frac{1}{\sqrt{\lambda_i}} A(A^T Av_i) \\ &= \frac{1}{\sqrt{\lambda_i}} A(\lambda_i v_i) \\ &= \lambda_i \left(\frac{1}{\sqrt{\lambda_i}} Av_i \right) \end{aligned}$$

从而对 $A^T A$ 任意的非零特征值 λ_i , λ_i 也是 AA^T 的特征值, $\frac{1}{\sqrt{\lambda_i}} Av_i$ 是对应的特征向量。

AA^T 和 $A^T A$ 的特征值的代数重数 (I)

现在令 $\lambda_{i_1}, \dots, \lambda_{i_t}$ 是 $A^T A$ 的**两两不同**的非零特征值, 其中:

$$1 = i_1 < i_2 < \dots < i_t \leq r$$

注意到其也是 AA^T 的特征值, 定义:

1. α_i 是 $A^T A$ 的特征值 λ_i 的代数重数, α'_i 是 AA^T 的特征值 λ_i 的代数重数。
2. g_i 是 $A^T A$ 的特征值 λ_i 的几何重数, g'_i 是 AA^T 的特征值 λ_i 的几何重数。

并且我们有:

$$\sum_{i \in [t]} \alpha_i = r, \quad \sum_{i \in [t]} \alpha'_i \leq r$$

AA^T 和 $A^T A$ 的特征值的代数重数 (II)

注意到 v_1, \dots, v_r 是一组标准正交的向量, 也是 $A^T A$ 的特征值 $\lambda_1, \dots, \lambda_r$ 的特征向量。从而我们对任意的 $i \in [t]$ 有:

$$g_i \leq g'_i$$

从而由代数重数和几何重数的关系我们有:

$$a_i = g_i \leq g'_i \leq a'_i \implies \sum_{i \in [t]} a'_i \geq \sum_{i \in [t]} a_i = r$$

从而 $\sum_{i \in [t]} a'_i = r$, 即对所有的 $i \in [t]$:

$$a_i = a'_i$$

从而 $A^T A$ 和 AA^T 有相同的 r 个非零特征值 (计算重数)。 □

现在我们来直观的理解一下一般矩阵的分解。令 A 是一个 $m \times n$ 的矩阵，则 $A^T A$ 是一个对称阵，从而存在一个 $n \times n$ 的正交矩阵 Q 使得：

$$A^T A = Q \Lambda Q^T$$

这里 $\Lambda = \begin{bmatrix} D & O \\ O & O \end{bmatrix}$ ，其中 $D = \text{diag}\{\lambda_1, \dots, \lambda_r\}$ 是一个对角阵， $r = \text{rank}(A)$ 。另一方面，在定理3中我们有：

$$A = U \Sigma V^T$$

从而：

$$A^T A = V \Sigma^T U^T U \Sigma V^T = V \Sigma^T \Sigma V^T$$

我们可以看到：

$$\Lambda = \Sigma^T \Sigma = \begin{bmatrix} D & O_{(m-r) \times r} \\ O_{r \times (n-r)} & O_{(n-r) \times (m-r)} \end{bmatrix} \begin{bmatrix} D & O_{r \times (n-r)} \\ O_{(m-r) \times r} & O_{(m-r) \times (n-r)} \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & & \\ & \ddots & \\ & & \sigma_r^2 \end{bmatrix}$$

从而我们有, 对任意的 $i \in [r]$ 有:

$$\lambda_i = \sigma_i^2$$

我们称其为**奇异值 (Singular Value)**。

定义 7.

令 A 是一个 $m \times n$ 的矩阵, $\lambda_1, \dots, \lambda_r$ 是对称矩阵 $A^T A$ 的非零特征值, 从而其都是非负的。对任意的 $i \in [r]$, 定义:

$$\sigma_i = \sqrt{\lambda_i}$$

我们将 $\sigma_1, \dots, \sigma_r$ 称为矩阵 A 的**奇异值 (Singular Value)**。

我们现在开始证明定理3。再次回顾一下定理的内容：

定理 3.

令 A 是一个 $m \times n$ 的矩阵, $\text{rank}(A) = r$, 定义下列 $m \times n$ 的矩阵 Σ :

$$\Sigma = \begin{bmatrix} D & O_{r \times (n-r)} \\ O_{(m-r) \times r} & O_{(m-r) \times (n-r)} \end{bmatrix}, \text{ 其中 } D = \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{bmatrix}$$

这里, $\sigma_1, \dots, \sigma_r$ 是 A 的奇异值。则存在 $m \times m$ 的正交矩阵 U 和 $n \times n$ 的正交矩阵 V , 使得:

$$A = U\Sigma V^T$$

特别的, 存在 $u_1, \dots, u_r \in \mathbb{R}^m$ 和 $v_1, \dots, v_r \in \mathbb{R}^n$ 使得:

$$A = \sigma_1 u_1 v_1^T + \dots + \sigma_r u_r v_r^T$$

令

$$\lambda_1, \dots, \lambda_r, \lambda_{r+1}, \dots, \lambda_n$$

是 $A^T A$ 的特征值，并且我们有：

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > 0 = \lambda_{r+1} = \dots = \lambda_n$$

并且令 v_1, \dots, v_n 是其相应的标准正交的特征向量，从而矩阵：

$$V = \begin{bmatrix} v_1 & \dots & v_n \end{bmatrix}$$

是一个 $n \times n$ 的正交矩阵。

现在对于任意的 $i \in [r]$, 定义:

$$u_i = \frac{1}{\sqrt{\lambda_i}} A v_i \in \mathbb{R}^m$$

则由之前的引理:

$$u_1, \dots, u_r$$

是 AA^T 的标准正交的特征向量。利用 Gram-Schmidts 正交化将其扩展成一组标准正交基:

$$u_1, \dots, u_r, u_{r+1}, \dots, u_m$$

从而矩阵 $U = \begin{bmatrix} u_1 & \dots & u_m \end{bmatrix}$ 是 $m \times m$ 的正交矩阵。

让我们再来关注一下奇异值究竟想表示的内容，注意到：

$$A = U\Sigma V^T, \text{ 即: } AV = U\Sigma$$

则对于 $i \in [n]$ 有：

$$Av_i = \sigma_i u_i = \sqrt{\lambda_i} u_i$$

- u_i 是 \mathbb{R}^m 的一组标准正交基。
- v_i 是 \mathbb{R}^n 的一组标准正交基。
- $AV = U\Sigma$ 与再方阵中 $AX = X\Lambda$ 类似，表达的是不改变方向的变换，只是对一般矩阵而言，其对应的是 \mathbb{R}^n 到 \mathbb{R}^m 的线性变换，而不是 \mathbb{R}^n 到 \mathbb{R}^n 。

由对称性我们只需要证明 $C(A)$ 和 $N(A)$ 的性质。

- 注意到 $\dim(C(A)) = \text{rank}(A)$ ，我们只要证明：

$$C(A) \subseteq \text{span}\{u_1, \dots, u_r\}$$

而由 $A = \sigma_1 u_1 v_1^T + \dots + \sigma_r u_r v_r^T$ 可知， A 的每一列都是 u_1, \dots, u_r 的线性组合。

- 注意到 $\dim(N(A)) = n - \text{rank}(A) = n - r$ ，我们只要证明对任意的 $r + 1 \leq i \leq n$ 有：

$$A v_i = \mathbf{0}$$

而此时有：

$$\begin{aligned} A v_i &= (\sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_r u_r v_r^T) v_i \\ &= \sigma_1 u_1 v_1^T v_i + \sigma_2 u_2 v_2^T v_i + \dots + \sigma_r u_r v_r^T v_i \\ &= \sigma_1 u_1 (v_1 \cdot v_i) + \sigma_2 u_2 (v_2 \cdot v_i) + \dots + \sigma_r u_r (v_r \cdot v_i) \\ &= \mathbf{0} \end{aligned}$$

□

- 矩阵的低秩分解-更少的存储方式。
- 矩阵的奇异值分解 (SVD)、奇异值的概念。
- 奇异值分解的证明。


► 用线来拟合数据

用线来拟合数据 (I)

假设我们现在在 \mathbb{R}^2 中有 m 个数据:

$$(x_1, y_1), \dots, (x_m, y_m)$$

我们希望找到一条直线: $y = cx$ ($c \in \mathbb{R}$) 使得每个数据点到直线的距离尽可能的小。




这等价于找到一个单位向量 $w = \begin{bmatrix} \frac{1}{\sqrt{1+c^2}} \\ \frac{c}{\sqrt{1+c^2}} \end{bmatrix}$ 使得:

$$d_1^2 + \dots + d_m^2 \text{ 最小}$$

用线来拟合数据 (II)



对于每个数据点 $a_i(x_i, y_i) \in \mathbb{R}^2$, 我们希望寻找到一个单位向量 $w \in \mathbb{R}^2$:



最小化:

$$\sum_{i=1}^m d_i^2 = \sum_{i=1}^m (\|a_i\|^2 - p_i^2) = \sum_{i=1}^m \|a_i\|^2 - \sum_{i=1}^m p_i^2$$

即最大化:

$$\sum_{i=1}^m p_i^2 = \sum_{i=1}^m (\|a_i\| \cos \theta_i)^2 = \sum_{i=1}^m \left(\|a_i\| \frac{w \cdot a_i}{\|w\| \|a_i\|} \right)^2 = \sum_{i=1}^m (w \cdot a_i)^2$$

假设现在数据有 n 个特征，即：

$$a_1, \dots, a_m \in \mathbb{R}^n$$

我们依旧是希望找到一个单位向量 $w \in \mathbb{R}^n$ 最小化：

$$\sum_{i=1}^m w \text{ 和 } a_i \text{ 的距离}$$

即最大化：

$$\sum_{i=1}^m (w \cdot a_i)^2$$

定义 $m \times n$ 的矩阵:

$$A = \begin{bmatrix} a_1^\top \\ \vdots \\ a_m^\top \end{bmatrix}$$

则我们目标是找到一个单位向量 $w \in \mathbb{R}^n$ 使得:

$$\sum_{i=1}^m (w \cdot a_i)^2 = \sum_{i=1}^m (a_i^\top w)^2 = \|Aw\|^2 \text{ 最大}$$

由矩阵的奇异值分解可知, 事实上这就是矩阵 A 最大的奇异值的平方。

定理 10.

令 A 是 $m \times n$ 的矩阵, σ_1 是其最大的奇异值, 则:

$$\max_{w \in \mathbb{R}^n, \|w\|=1} \|Aw\|^2 = \sigma_1^2$$

特比的, 该值取到最大的时候恰好是 A 的 SVD 分解中 V 对应 σ_1 的向量, 即:

$$A = U\Sigma V^T = U\Sigma \begin{bmatrix} v_1^T \\ v_2^T \\ \vdots \\ v_n^T \end{bmatrix}$$

在证明这个定理之前, 我们先讨论回顾一下基于标准正交基表示的向量的长度。

考虑 \mathbb{R}^n 上的一组标准正交基 v_1, \dots, v_n 。则任何一个 $w \in \mathbb{R}^n$ 都可以被其线性表示:

$$w = c_1 v_1 + \dots + c_n v_n$$

即 w 关于基 v_1, \dots, v_n 的坐标为 $(c_1, \dots, c_n) \in \mathbb{R}^n$ 。注意到对所有的 $i \in [n]$:

$$v_i \cdot w = v_i \cdot (c_1 v_1 + \dots + c_n v_n) = c_i (v_i \cdot v_i) = c_i$$

从而我们有:

$$\begin{aligned} w &= (v_1 \cdot w)v_1 + \dots + (v_n \cdot w)v_n = v_1 v_1^T w + \dots + v_n v_n^T w \\ &= \begin{bmatrix} v_1 & \dots & v_n \end{bmatrix} \begin{bmatrix} v_1^T w \\ \vdots \\ v_n^T w \end{bmatrix} = \begin{bmatrix} v_1 & \dots & v_n \end{bmatrix} \begin{bmatrix} v_1^T \\ \vdots \\ v_n^T \end{bmatrix} w = Q Q^T w \end{aligned}$$

这其实就是:

$$Qx = b \text{ 的最小二乘解就是 } \hat{x} = Q^T b$$

令 $q_1, \dots, q_n \in \mathbb{R}^n$ 是标准正交的，并且：

$$Q = [q_1 \quad \cdots \quad q_n]$$

显然 Q 是一个正交矩阵。从而 $Qx = b$ 的最小二乘解为： $\hat{x} = Q^T b$ ，对应的投影矩阵为 $QQ^T = I$ ，从而：

$$b = QQ^T b = [q_1 \quad \cdots \quad q_n] \begin{bmatrix} q_1^T b \\ \vdots \\ q_n^T b \end{bmatrix} = q_1 q_1^T b + \cdots + q_n q_n^T b$$

也就是：

p 是 b 分别到每条线 $\text{span}(\{q_i\})$ 上的投影的和。

考虑向量空间 $V = \mathbb{R}^n$ 和其两组基:

$$\bar{e} = e_1, \dots, e_n \text{ 和 } \bar{v} = v_1, \dots, v_n$$

从而 \bar{e} 到 \bar{v} 的基变换矩阵 M 满足:

$$\begin{bmatrix} v_1 & \cdots & v_n \end{bmatrix} = \begin{bmatrix} e_1 & \cdots & e_n \end{bmatrix} M$$

并且可以得出:

$$M = \begin{bmatrix} v_1 & \cdots & v_n \end{bmatrix}$$

即: 对于任意的 $w = (w_1, \dots, w_n) \in V$, 其在基 \bar{e} 下的坐标就是其自己 w 。

回顾坐标变换公式:

定理 11.

令 \bar{v}_n 和 \bar{v}' 是 V 的两组基, 则对于任意的 $u \in V$, 我们有:

$$T_{\bar{v}}(u) = MT_{\bar{v}'}(u)$$

从而 w 在基 \bar{v} 下的坐标为:

$$M^{-1}w$$

如果基 \bar{v} 是标准正交的, 即:

$$M = \begin{bmatrix} v_1 & \cdots & v_n \end{bmatrix} \text{ 是正交矩阵}$$

则我们有:

$$M^{-1}w = M^T w, \quad \text{即: } w = MM^T w = v_1 v_1^T w + \cdots + v_n v_n^T w$$

注意到:

定理 12.

令 Q 是 $n \times n$ 的正交矩阵, 并且 $x, y \in \mathbb{R}^n$, 则:

1. $\|Qx\| = \|x\|$, 特别的 $\|Q^T x\| = \|x\|$ 。
2. $Qx \cdot Qy = x \cdot y$, 从而 $Q^T x \cdot Q^T y = x \cdot y$ 。

从而考虑任意的 $w \in \mathbb{R}^n$, 我们有:

1. 其在标准正交基 v_1, \dots, v_n 下的坐标为 $Q^T w$, 这里 $Q = [v_1 \ \dots \ v_n]$, 即:

$$(v_1^T w, \dots, v_n^T w)$$

2. 对应坐标的长度和 w 的长度是相同的, 即:

$$\|w\| = \|Q^T w\| = \sqrt{(v_1^T w)^2 + \dots + (v_n^T w)^2}$$

考虑 \mathbb{R}^n 的一个单位向量 w , 存在 c_1, \dots, c_n 使得 $w = c_1 v_1 + \dots + c_n v_n$, 并且由前面的讨论:

$$c_1^2 + \dots + c_n^2 = \|w\|^2 = 1$$

从而:

$$\begin{aligned} Aw &= (\sigma_1 u_1 v_1^T + \dots + \sigma_r u_r v_r^T)(c_1 v_1 + \dots + c_n v_n) \\ &= \sum_{i \in [r], j \in [n]} \sigma_i c_j u_i v_j^T v_j = \sum_{i \in [r]} \sigma_i c_i u_i \end{aligned}$$

从而 Aw 在标准正交基 $u_1, \dots, u_r, u_{r+1}, \dots, u_m$ 下的坐标为 $(\sigma_1 c_1, \dots, \sigma_r c_r, 0, \dots, 0)$, 因此我们有:

$$\|Aw\| = \sigma_1^2 c_1^2 + \dots + \sigma_r^2 c_r^2 \leq \sigma_1^2 \sum_{i \in [r]} c_i^2 \leq \sigma_1^2 \sum_{i \in [n]} c_i^2 = \sigma_1^2$$

当 $w = v_1$ 时取到上述不等式等号。

□

► 用 k 维子空间拟合数据

固定一个 $k \geq 1$ 。

$$a_1, \dots, a_m \in \mathbb{R}^n$$

我们希望找到一个 k 维的子空间 $W \subseteq \mathbb{R}^n$ 最小化:

$$\sum_{i \in [m]} (a_i \text{ 到 } W \text{ 的距离})^2$$

我们可以选取 W 中的一组标准正交基 $w_1, \dots, w_k \in W$, 从而 a_i 到 W 的距离是:

a_i 和 a_i 到 W 的投影 p_i 的距离。

1. 我们的目标是计算 b 到下列空间:

$$V = \text{span}(\{a_1, \dots, a_n\})$$

的投影 p , 其中 a_1, \dots, a_n 是线性无关的, $p \in V$.

2. 我们令 $p \in V$ 是满足其误差 $e = b - p$ 与 V 垂直的向量。我们证明了, 对于任意的 $v \in V$:

$$\|b - v\| = \min_{u \in V} \|b - u\| \iff v = p$$

3. 我们得到了相应的投影矩阵 $P = A(A^T A)^{-1} A^T$, 即:

$$p = A\hat{x} = A(A^T A)^{-1} A^T b$$

并且我们证明了当 $\text{rank}(A) = n$ 时 $(A^T A)^{-1}$ 是存在的, 这也说明了 p 的**唯一性**。

我们利用如下的标准正交的向量来表示 W :

$$w_1, \dots, w_k \in \mathbb{R}^n$$

特别的, 令

$$Q = [w_1 \quad \dots \quad w_k]$$

则:

$$Q^T Q = \begin{bmatrix} w_1^T \\ \vdots \\ w_k^T \end{bmatrix} [w_1 \quad \dots \quad w_k] = \begin{bmatrix} w_1^T w_1 & \dots & w_1^T w_k \\ \vdots & \ddots & \vdots \\ w_k^T w_1 & \dots & w_k^T w_k \end{bmatrix} = I_{k \times k}$$

$$Q Q^T = [w_1 \quad \dots \quad w_k] \begin{bmatrix} w_1^T \\ \vdots \\ w_k^T \end{bmatrix} = w_1 w_1^T + \dots + w_k w_k^T$$

则 a_i 到 $W(= \text{span}(\{w_1, \dots, w_k\})) = C(Q)$ 的投影为:

$$\begin{aligned} p_i &= Q(Q^T Q)Q^T a_i \\ &= QQ^T a_i \\ &= w_1 w_1^T a_i + \dots + w_k w_k^T a_i \\ &= (w_1 \cdot a_i)w_1 + \dots + (w_k \cdot a_i)w_k \\ &= \sum_{j \in [k]} (w_j \cdot a_i)w_j \end{aligned}$$

即:

a_i 到 W 的投影 = a_i 到直线 $\text{span}(\{w_1\}), \dots, \text{span}(\{w_k\})$ 的投影之和

另一方面，注意到 a_i 到 W 的距离可以表示为：

$$d_i^2 = \|a_i - p_i\|^2 = \|a_i\|^2 - \|p_i\|^2 = \|a_i\|^2 - \sum_{j \in [k]} (w_j \cdot a_i) w_j$$

从而最小化 $d_1^2 + \dots + d_m^2$ 等价于最大化：

$$\sum_{i \in [m]} \|p_i\|^2 = \sum_{i \in [m]} \left\| \sum_{j \in [k]} (w_j \cdot a_i) w_j \right\|^2 = \sum_{i \in [m]} \sum_{i \in [k]} (w_j \cdot a_i)^2$$

注意到之前用线去拟合的情况就是该例中 $k = 1$, $w_1 = w$ 的特殊情况。

我们依旧用一个矩阵来表示这 m 个数据:

$$A = \begin{bmatrix} \mathbf{a}_1^\top \\ \vdots \\ \mathbf{a}_m^\top \end{bmatrix} \in \mathbb{R}^{m \times n}$$

从而我们的目标是寻找到一组标准正交的向量 $w_1, \dots, w_k \in \mathbb{R}^n$ 最大化:

$$\sum_{i \in [m]} \sum_{j \in [k]} (w_j \cdot \mathbf{a}_i)^2 = \sum_{j \in [k]} \sum_{i \in [m]} (w_j \cdot \mathbf{a}_i)^2 = \sum_{j \in [k]} \|A w_j\|^2$$

由定理10, 我们知道存在 $w_1 \in \mathbb{R}^n$, 使得对于任意的 $w \in \mathbb{R}^n$:

$$\|Aw\|^2 \leq \|Aw_1\|^2 = \sigma_1^2$$

从而 w_2 的选取应当满足 $w_2 \perp w_1$, 之后的情况可以类似归纳。为此我们先证明两个引理。

引理 14.

令 $k \in [r]$, 并且 $w \in \mathbb{R}^n$ 是一个单位向量, 并且满足对任意的 $i \in [k-1]$ 有 $w \perp v_i$, 则我们有:

$$\|Aw\|^2 \leq \|Av_k\|^2 = \sigma_k^2$$

引理 15.

令 $2 \leq k \leq n$, $W \subseteq \mathbb{R}^n$ 是一个 k 维的子空间, 则存在一个单位向量 $w \in \mathbb{R}^n$, 使得: 对任意的 $i \in [k-1]$ 有 $w \perp v_i$

引理 14.

令 $k \in [r]$, 并且 $w \in \mathbb{R}^n$ 是一个单位向量, 并且满足对任意的 $i \in [k-1]$ 有 $w \perp v_i$, 则我们有:

$$\|Aw\|^2 \leq \|Av_k\|^2 = \sigma_k^2$$

证明. 令 $w = c_1 v_1 + \cdots + c_n v_n$, 则由题目假设我们有:

1. $c_1 = c_2 = \cdots = c_{k-1} = 0$
2. $c_k^2 + \cdots + c_n^2 = 1$

从而:

$$Aw = (\sigma_1 u_1 v_1^T + \cdots + \sigma_r u_r v_r^T)(c_1 v_1 + \cdots + c_n v_n) = \sigma_k c_k u_k + \cdots + \sigma_r c_r u_r$$

因此:

$$\|Aw\|^2 = \|(0, \cdots, \sigma_k c_k, \cdots, \sigma_r c_r, 0, \cdots, 0)\|^2 = \sum_{k \leq j \leq r} \sigma_j^2 c_j^2 \leq \sigma_k^2 \sum_{k \leq j \leq r} c_j^2 \leq \sigma_k^2 \sum_{j \in [n]} c_j^2 = \sigma_k^2$$

引理 16.

令 $2 \leq k \leq n$, $W \subseteq \mathbb{R}^n$ 是一个 k 维的子空间, 则存在一个单位向量 $w \in \mathbb{R}^n$, 使得: 对任意的 $i \in [k-1]$ 有 $w \perp v_i$

证明. 对任意的 $i \in [k-1]$, 定义 v'_i 是 v_i 到 W 的投影, 显然我们有 $(v_i - v'_i) \perp W$ 。注意到:

$$W_0 = \text{span}(\{v'_1, \dots, v'_{k-1}\}) \subseteq W \text{ (由于 } \dim(W_0) \leq k-1 \text{)}$$

令 $\dim(W_0) = l$, 则我们可以构造出一组 W 的标准正交基:

$$w_1, \dots, w_l, \dots, w_{k-1}, w_k$$

使得 w_1, \dots, w_l 是 W 中的一组标准正交基, 定义 $w = w_k$, 则:

- $\|w\| = \|w_k\| = 1$ 。
- $w \perp W_0$, 从而对任意的 $i \in [k-1]$ 有:

$$w \cdot v = w^T v_i = w^T v'_i + w^T (v_i - v'_i) = 0 + 0 = 0$$



定理 13.

假设 $k \leq r$, 则对任意的标准正交的 $w_1, \dots, w_k \in \mathbb{R}^n$ 有:

$$\sum_{j \in [k]} \|Aw_j\|^2 \leq \sum_{j \in [k]} \sigma_j^2$$

当 $w_1 = v_1, \dots, w_k = v_k$ 时等号成立。

证明. 定义:

$$\mathbb{V}_k = \text{span}(\{v_1, \dots, v_k\})$$

从而:

$$\begin{aligned} \sum_{i \in [m]} (a_i \text{ 到 } \mathbb{V}_k \text{ 的投影})^2 &= \sum_{j \in [k]} \|Av_j\|^2 \\ &= \sum_{j \in [k]} \left\| (\sigma_1 u_1 v_1^T + \dots + \sigma_r u_r v_r^T) v_j \right\|^2 \\ &= \sum_{j \in [k]} \|\sigma_j u_j\|^2 = \sum_{j \in [k]} \sigma_j^2 \end{aligned}$$

下面我们对 k 作归纳, 证明对任意的 k 维子空间 \mathbb{W} , 我们有:

$$\sum_{i \in [m]} (a_i \text{ 到 } \mathbb{W} \text{ 的投影})^2 \leq \sum_{i \in [m]} (a_i \text{ 到 } \mathbb{V}_k \text{ 的投影})^2 = \sum_{j \in [k]} \sigma_j^2$$

即 \mathbb{V}_k 是最佳的 k 维子空间。

$k = 1$ 的时候就是定理 10, 即对任意的 $w \in \mathbb{R}^n$ 且 $\|w\| = 1$, 我们有:

$$\|Aw\|^2 \leq \|Av_1\|^2 = \sigma_1^2$$

当 $k \geq 2$ 的时候, 令 $W \subseteq \mathbb{R}^n$, 且 $\dim(W) = k$ 。由引理15存在一个单位向量 $w \in W$, 使得对任意的 $i \in [k-1]$ 有 $w \perp v_i$ 。利用 Gram-Schmidts 正交化, 我们可以获得 W 的一组标准正交基:

$$w_1, \dots, w_{k-1}, w_k = w$$

从而由归纳假设我们有:

$$\sum_{j \in [k-1]} \|Aw_j\|^2 \leq \sum_{j \in [k-1]} \sigma_j^2$$

利用引理14我们有: $\|Aw\|^2 \leq \sigma_k^2$, 从而:

$$\sum_{j \in [k]} \|Aw_j\|^2 = \|Aw\|^2 + \sum_{j \in [k-1]} \|Aw_j\|^2 \leq \sigma_k^2 + \sum_{j \in [k-1]} \sigma_j^2 = \sum_{j \in [k]} \sigma_j^2$$

□

▶ 再看 $Ax = b$ 的近似解

令 A 是 $m \times n$ 的矩阵, $b \in \mathbb{R}^m$, 考虑方程组:

$$Ax = b$$

可能有无数解, 也可能没有任何解。

- $Ax = b$ 当且仅当:

$$\text{rank}(A) = \text{rank}\left(\begin{bmatrix} A & b \end{bmatrix}\right)$$

- 其最小二乘解 \hat{x} 满足:

$$\|b - A\hat{x}\| = \min_{x \in \mathbb{R}^n} \|b - Ax\|$$

1. 我们知道如果 $\hat{x} \in \mathbb{R}$ 满足:

$$A^T(A\hat{x} - b) = \mathbf{0} \quad \text{即} \quad A^T A \hat{x} = A^T b$$

则 $A\hat{x} - b$ 与 $C(A)$ 正交。

2. 我们可以得到 \hat{x} 的表达式:

$$\hat{x} = (A^T A)^{-1} A^T b$$

并且我们知道 \hat{x} 是唯一的。

3. 我们称 \hat{x} 就是**最小二乘解 (least square solution)** , 因为其误差的长度 $\|e\|$

$$e = b - A\hat{x}$$

是所有 $b - Ax$ 中最小的。

最小二乘解- $\text{rank}(A) < n$

1. 选择 $C(A)$ 的一组基 $\{a_{i_1}, \dots, a_{i_r}\}$, 其中 $r = \text{rank}(A)$ 。
2. 定义 $m \times r$ 的矩阵:

$$A' = \begin{bmatrix} a_{i_1} & \cdots & a_{i_r} \end{bmatrix}$$

显然我们有: $C(A) = C(A')$

3. $\text{rank}(A')$ 是列满秩的, 所以我们可以利用前面的方法来找到 $A'x' = b$ 的最优近似解, 即:

$$\hat{x}' = (A'^T A')^{-1} A'^T b \in \mathbb{R}^n$$

显然其误差 $e = b - A'\hat{x}'$ 是所有 $b - Ax$ 中长度最小的, 即:

$$\|e\| = \min_{x \in \mathbb{R}^n} \|b - Ax\| = \min\{\|b - v\| \mid v \in C(A')\} = \min\{\|b - v\| \mid v \in C(A)\}$$

4. 我们需要的 $\hat{x} \in \mathbb{R}^n$ 只要满足:

$$A\hat{x} = A'\hat{x}'$$

注意此时 \hat{x} 并不是唯一的。

定义:

$$x^+ = A^+b$$

我们说明 x^+ 就是 $Ax = b$ 的最小二乘解。

定理 20.

x^+ 是 $Ax = b$ 的最小二乘解, 即:

$$\|b - Ax^+\| = \min_{x \in \mathbb{R}^n} \|b - Ax\|$$

特别的, 对于该方程的每个最小二乘解 $x \neq x^+$, 即:

$$\|b - Ax^+\| < \|b - Ax\|$$

我们有:

$$\|x^+\| < \|x\|$$

注意到 u_1, \dots, u_r 是标准正交的, 从而:

$Ax^+ = b$ 到 $\text{span}(\{u_1, \dots, u_r\})$ 的投影

由推论61:

正交向量组	作为正交基的对应的向量空间
u_1, \dots, u_r	$C(A)$
u_{r+1}, \dots, u_m	$N(A^T)$
v_1, \dots, v_r	$C(A^T)$
v_{r+1}, \dots, v_n	$N(A)$

Ax^+ 是 b 到 $C(A)$ 上的投影, 即 x^+ 是 $Ax = b$ 的最小二乘解。

现在考虑 $Ax = b$ 的另一个最小二乘解 $x (\neq x^+)$, 即:

$$\|b - Ax\| = \|b - Ax^+\|$$

我们有:

$$Ax = Ax^+ \implies A(x - x^+) = \mathbf{0}, \text{ 即 } x - x^+ \in N(A)$$

从而

$$x^+ = \sigma_1^{-1} v_1 u_1^T b + \cdots + \sigma_r^{-1} v_r u_r^T b \in \text{span}(\{v_1, \dots, v_r\}) = C(A^T)$$
$$x - x^+ \in N(A) = \text{span}(\{v_{r+1}, \dots, v_n\})$$

从而 $x^+ \perp (x - x^+)$, 并且:

$$\|x\|^2 = \|x^+\|^2 + \|x - x^+\|^2 > \|x^+\|^2$$

最后一个严格大于号是由于 $x - x^+ \neq \mathbf{0}$.

□

矩阵 A 的奇异值分解并不是唯一的，即：

$$A = U_1 \Sigma_1 V_1^T, \quad A = U_2 \Sigma_2 V_2^T$$

则从定义上来讲，其可能存在两个广义逆：

$$A_1^+ = V_1 \Sigma_1^+ U_1^+, \quad A_2^+ = V_2 \Sigma_2^+ U_2^+$$

但我们可以证明，这两个是相等的，即 A 的广义逆是唯一的。

定理 21.

$$A_1^+ = A_2^+$$

由定理20, 对于该方程的每个最小二乘解 $x \neq x^+$, 即:

$$\|b - Ax^+\| = \|b - Ax\|$$

我们有:

$$\|x^+\| < \|x\|$$

从而对任意的 $b \in \mathbb{R}^m$, 我们有:

$$A_1^+ b = A_2^+ b$$

考察所有的 $b = e_i$, 则有:

$$A_1^+ = A_2^+$$

□

我们介绍了 SVD 的一些应用，以及其几何意义。

- 利用 k 维子空间拟合数据-SVD 的最大 k 个奇异值是最好的结果。
- 矩阵的广义逆，最小的二乘解。