


第九讲 欧氏空间中的投影

2023.11.17



主要内容

□ 向量空间

- 函数空间: 欧氏 R^n , 实函数 L^2 , 随机变量 $L^2(\mathcal{F})$

□ 内积向量空间的投影

□ 欧氏空间: 矩阵预备知识

- 四个基本空间: 列空间、行空间、核空间
- 常用线性变换方阵
- 奇异值分解 (SVD)、广义逆 A^-

□ 欧氏空间的投影

上次课

欧氏空间：矩阵预备知识

Recap: 列空间与行空间

矩阵 $A_{n \times m}$ 的列空间

$$C(A) = \{A\mathbf{x} \mid \mathbf{x} \in R^m\} = \left\{ \sum_{i=1}^m \mathbf{a}_i x_i \mid x_1, \dots, x_m \in R \right\}$$

$A_{n \times m}$ 的行空间即 A^T 的列空间:

$$C(A^T) = \{A^T \mathbf{y} \mid \mathbf{y} \in R^n\}$$

定理3: 对任一实数矩阵 A , $\text{rank}(A^T) = \dim(C(A^T)) = \dim(C(A)) = \text{rank}(A)$.

定理4. $C(A) = C(AA^T)$, $C(A^T) = C(A^T A)$,
特别地, $\text{rank}(AA^T) = \text{rank}(A)$


定理5. $C(A^T) \oplus N(A) = R^m$, $C(A) \oplus N(A^T) = R^n$
 $\text{rank}(A_{n \times m}) = m - \text{nullity}(A) = n - \text{nullity}(A^T)$

常用线性变换方阵：拉伸、旋转、镜像、投影

参见Gilbert Strang: Linear algebra and its applications (p146)

理解矩阵变换 - 观察矩阵将标准坐标轴变换到什么向量：
记 $A_{n \times m} = (\mathbf{a}_1, \dots, \mathbf{a}_m) : R^m \rightarrow R^n$ ，矩阵 A 的列向量为 $\mathbf{a}_1, \dots, \mathbf{a}_m \in R^n$
 R^m 中，记 $\mathbf{e}_k =$ 第 k 个坐标轴 = I_m 的第 k 列 = $(0, \dots, 1, \dots, 0)^T$ ，则
 $A\mathbf{e}_k = \mathbf{a}_k, k = 1, \dots, m$ ，即 $AI_m = A(\mathbf{e}_1, \dots, \mathbf{e}_m) = A = (\mathbf{a}_1, \dots, \mathbf{a}_m)$

例如 $A = \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}$ ，它将标准正交基 $\mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ 变换为 $\mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ ，
将 $\mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ 变换为 $-\mathbf{e}_1 = \begin{pmatrix} -1 \\ 0 \end{pmatrix}$ ， A 是逆时针 90° 旋转变换。



下面考虑常用的几个2阶变换方阵

$\begin{pmatrix} 1 & 0 \\ 0 & 2 \end{pmatrix}$	$\begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}$	$\begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$	$\begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$
拉伸	90° 逆时旋转	x 轴投影	45° 反射

拉伸
↔数乘

$$S = \begin{pmatrix} c_1 & 0 \\ 0 & c_2 \end{pmatrix}; S \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} c_1 x_1 \\ c_2 x_2 \end{pmatrix}$$

矩阵的数乘 cA ^{定义为} $= (ca_{ij})$, 应理解为拉伸: $diag(c)A = \begin{pmatrix} c & & \\ & \ddots & \\ & & c \end{pmatrix} A$

注1: cA 定义是明确的, 但不符合矩阵乘积的要求, 有时会引起混乱。

比如若 $c = \mathbf{x}^T \mathbf{x} \in R$, \mathbf{x} 是向量, 则 $cA = \mathbf{x}^T \mathbf{x} A$ 是三个矩阵/向量的乘积, 按照结合律 $cA = \mathbf{x}^T \mathbf{x} A = \mathbf{x}^T (\mathbf{x} A)$, 括号中出现了问题。

注2: 向量 $\mathbf{a} \in R^n$ 与实数 $c \in R$ 的数乘, 最好写成 $\mathbf{a}c$, 而不是 $\mathbf{c}\mathbf{a}$ 。

这是因为 $\mathbf{a}c$ 是 $n \times 1$ 向量与 1×1 的数的乘积, 符合矩阵向量乘积法则, 而 $\mathbf{c}\mathbf{a}$ 为 1×1 的数与 $n \times 1$ 向量的乘积, 不符合乘积法则。

比如若 $c = \mathbf{x}^T \mathbf{x} \in R$, 则常数在前的写法 $\mathbf{c}\mathbf{a} = \mathbf{x}^T \mathbf{x} \mathbf{a} = \mathbf{x}^T (\mathbf{x} \mathbf{a})$ 出现了矛盾。

旋转
↔ $e^{i\theta}$


$$O = \begin{pmatrix} c & -s \\ s & c \end{pmatrix} = \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix}, \quad c^2 + s^2 = 1,$$

对应

$$O \leftrightarrow e^{i\theta} = \cos(\theta) + i\sin(\theta)$$

对应


$$OO^T = I \leftrightarrow e^{i\theta}(e^{i\theta})^{-1} = 1$$



矩阵 O 和复数 $e^{i\theta}$ 都实现了平面上的旋转，但后者只需初等代数运算

特别：当 $\theta = 90^\circ$ 时(90°逆时针旋转)，

$$\Omega = \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix} \text{ 对应 } \leftrightarrow i:$$




	共轭	模长平方	平方	形式记号	变换
Ω	$\Omega^T = -\Omega$	$\Omega\Omega^T = I_2$	$\Omega^2 = -I_2$	$\Omega = (-I_2)^{1/2}$	$\Omega \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} -b \\ a \end{pmatrix}$
i	$\bar{i} = -i$	$i\bar{i} = 1$	$i^2 = -1$	$i = \sqrt{-1}$	$i(a + bi) = ia - b$

投影 $P^2 = P$
 $P \leftrightarrow 0$ or 1

对任何 $\mathbf{v} = \begin{pmatrix} c \\ s \end{pmatrix} = \begin{pmatrix} \cos(\theta) \\ \sin(\theta) \end{pmatrix}$, 投影阵 $P = \mathbf{v}\mathbf{v}^\top = \begin{pmatrix} c^2 & cs \\ cs & s^2 \end{pmatrix}$,

$$P\mathbf{e}_1 = \begin{pmatrix} c^2 \\ cs \end{pmatrix} = c\mathbf{v}, \quad P\mathbf{e}_2 = \begin{pmatrix} cs \\ s^2 \end{pmatrix} = s\mathbf{v}$$



$\theta = 0$ 时, $P = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$, 向横轴投影: $P \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ 0 \end{pmatrix}$

- 一般 $n \times n$ 投影矩阵 (对称幂等): $P^\top = P, P^2 = P$.
- P 特征根为 0 或 1, 存在正交矩阵 O , 使得

$$P = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top, r = \text{rank}(P)$$

- 二次型可简化为平方和:

$$\mathbf{x}^\top P \mathbf{x} = \|P\mathbf{x}\|^2 = \mathbf{x}^\top O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top \mathbf{x} = \mathbf{y}^\top \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} \mathbf{y} = y_1^2 + \dots + y_r^2$$


其中 $\mathbf{y} = O^\top \mathbf{x}$ 。

反射 $R^2 = I_n$
 $R \leftrightarrow \pm 1$

$$\mathbf{v} = \begin{pmatrix} c \\ s \end{pmatrix} = \begin{pmatrix} \cos(\theta) \\ \sin(\theta) \end{pmatrix}, \text{ 反射变换 (reflection)}$$


$$R = 2\mathbf{v}\mathbf{v}^T - I_n = \begin{pmatrix} 2c^2 - 1 & 2cs \\ 2cs & 2s^2 - 1 \end{pmatrix} = \begin{pmatrix} \cos(2\theta) & \sin(2\theta) \\ \sin(2\theta) & -\cos(2\theta) \end{pmatrix},$$

$$R\mathbf{e}_1 = \begin{pmatrix} \cos(2\theta) \\ \sin(2\theta) \end{pmatrix}, R\mathbf{e}_2 = \begin{pmatrix} \sin(2\theta) \\ \cos(2\theta) \end{pmatrix}.$$




$\theta = 45^\circ$ 反射

$$R = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$



$\theta = 90^\circ$ 反射

$$R = \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix}$$



反射变换矩阵 R : $R = I_n - 2P$ 或 $2P - I_n$, 其中 P 为投影矩阵.
 $R^2 = I_n$, 我们可称之为“平方根”矩阵。

正交矩阵
 $O^T O = I_n$

若 n 阶方阵 O 满足 $O^T O = I_n$ (不必要求 $OO^T = I_n$), 称为正交矩阵.
正交 = 旋转 + 反射

命题: 若 O 是 n 阶方阵满足 $O^T O = I_n$, 则 $OO^T = I_n$.

证明: $O^T O = I_n$, 两边同时左乘 O , 得

$$OO^T O = O, \quad (OO^T) O = O$$

记 O 的各列为 $O = (\omega_1, \dots, \omega_n)$, 上式说明

$$(OO^T)(\omega_1, \dots, \omega_n) = (\omega_1, \dots, \omega_n), \quad \text{即 } OO^T \omega_i = \omega_i, \quad i = 1, \dots, n,$$

即标准正交基 $\{\omega_i, i = 1, \dots, n\}$ 在线性变换 OO^T 下保持不变,

所以 OO^T 必定是单位变换, 验证如下:

任何 \mathbf{x} 可用正交基 $\{\omega_i, i = 1, \dots, n\}$ 表示: $\mathbf{x} = O\mathbf{a} = \sum \omega_i a_i$

$$\Rightarrow OO^T \mathbf{x} = OO^T O\mathbf{a} = O(O^T O)\mathbf{a} = O\mathbf{a} = \mathbf{x} \Rightarrow OO^T = I_n.$$

行列空间的特征刻画

特征根特征向量

定义：对于 $n \times n$ 方阵 A ，若存在数 λ 和向量 \mathbf{v} , $\mathbf{v} \neq \mathbf{0}$, 使得

$$A\mathbf{v} = \mathbf{v}\lambda,$$

则 \mathbf{v} 和 λ 分别称为 A 的特征根和特征向量(注意不限制 λ 是实数以及 $\mathbf{v} \in R^n$)。

特征向量：线性变换的不变量，列空间的刻画。

对任何方阵 A ，假设所有特征根和特征向量为 $\lambda_i, \mathbf{x}_i, i = 1, \dots, n$,

记 $V = (\mathbf{x}_1, \dots, \mathbf{x}_n)$ 为所有特征向量，则特征方程 $A\mathbf{x}_i = \mathbf{x}_i\lambda_i, 1 \leq i \leq n \Leftrightarrow$

$$A(\mathbf{x}_1, \dots, \mathbf{x}_n) = (\mathbf{x}_1, \dots, \mathbf{x}_n) \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} \Leftrightarrow AV = V\Lambda \Rightarrow A = V\Lambda V^{-1}$$

若 A 是对称矩阵，则所有特征根为实数，且所有特征向量可取为正交的：

对称矩阵的谱分解

定理6. 任一 $n \times n$ 对称阵 A 可表示为

$$A = V\Lambda V^T$$

其中 $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$, $V = (\mathbf{v}_1, \dots, \mathbf{v}_n)$ 是正交矩阵, $V^T V = V V^T = I_n$,

其中 λ_i 是 A 的特征根， \mathbf{v}_i 是对应的模为1的特征向量。

当特征根、特征向量 \mathbf{v} 为实数时， $A\mathbf{v}$ 与 \mathbf{v} 方向重合。复特征根情形，如何理解复特征向量？

复特征根

假设 $A_{n \times n}$ 是一个实矩阵，则下述事实等价(其中 $a, b \in R, \mathbf{u}, \mathbf{v} \in R^n$):

(1) $A(\mathbf{u} + \mathbf{v}i) = (\mathbf{u} + \mathbf{v}i)(a + bi)$, 即 $a + bi$ 是 A 的复特征根, 特征向量 $\mathbf{u} + \mathbf{v}i$;

(2) $A(\mathbf{u} - \mathbf{v}i) = (\mathbf{u} - \mathbf{v}i)(a - bi)$, 即 $a - bi$ 是 A 的特征根, 特征向量 $\mathbf{u} - \mathbf{v}i$;

(3) $A(\mathbf{u}, \mathbf{v}) = (\mathbf{u}, \mathbf{v}) \begin{pmatrix} a & b \\ -b & a \end{pmatrix}$.

证明: $A\mathbf{x} = \mathbf{x}\lambda \Leftrightarrow A(\mathbf{u} + \mathbf{v}i) = (\mathbf{u} + \mathbf{v}i)(a + bi) = a\mathbf{u} - b\mathbf{v} + (b\mathbf{u} + a\mathbf{v})i$

$\Leftrightarrow A\mathbf{u} = a\mathbf{u} - b\mathbf{v}, A\mathbf{v} = b\mathbf{u} + a\mathbf{v}$

$\Leftrightarrow A(\mathbf{u} - \mathbf{v}i) = a\mathbf{u} - b\mathbf{v} - (b\mathbf{u} + a\mathbf{v})i = (\mathbf{u} - \mathbf{v}i)(a - bi)$, 即 $A\bar{\mathbf{x}} = \bar{\mathbf{x}}\bar{\lambda}$.

注: $C(\mathbf{u}, \mathbf{v})$ 是 A 变换的2维不变子空间: 对任何 $\mathbf{w} \in C(\mathbf{u}, \mathbf{v})$, 设其坐标为 x_1, x_2 ,

即 $\mathbf{w} = \mathbf{u}x_1 + \mathbf{v}x_2 = (\mathbf{u}, \mathbf{v}) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$, 则 $A\mathbf{w} = A(\mathbf{u}, \mathbf{v}) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = (\mathbf{u}, \mathbf{v}) \begin{pmatrix} a & b \\ -b & a \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$,

其坐标为 $\begin{pmatrix} a & b \\ -b & a \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \propto \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$ 的正交旋转。

例5. $\Omega = \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}$ 是平面上的反转（逆时针） 90° 的变换矩阵:

$$R \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} -x_2 \\ x_1 \end{pmatrix}, \quad R^2 \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} -x_1 \\ -x_2 \end{pmatrix}$$

Ω 的特征根为 $i, -i$, 特征向量 $\begin{pmatrix} i \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ i \end{pmatrix}$, 特征方程

$$\begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} i \\ 1 \end{pmatrix} = i \begin{pmatrix} i \\ 1 \end{pmatrix}, \quad \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} 1 \\ i \end{pmatrix} = -i \begin{pmatrix} 1 \\ i \end{pmatrix}$$

$$\mathbf{u} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \mathbf{v} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, B = \begin{pmatrix} a & b \\ -b & a \end{pmatrix} = \begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix}$$

特征方程 \Leftrightarrow 实数空间中 $\Omega \mathbf{u} = -\mathbf{v}, \Omega \mathbf{v} = \mathbf{u} \Leftrightarrow \Omega(\mathbf{u}, \mathbf{v}) = (\mathbf{u}, \mathbf{v})B = (-\mathbf{v}, \mathbf{u})$,

$$\Rightarrow \Omega = (-\mathbf{v}, \mathbf{u})(\mathbf{u}, \mathbf{v})^{-1} = (-\mathbf{v}, \mathbf{u})(\mathbf{u}, \mathbf{v})$$

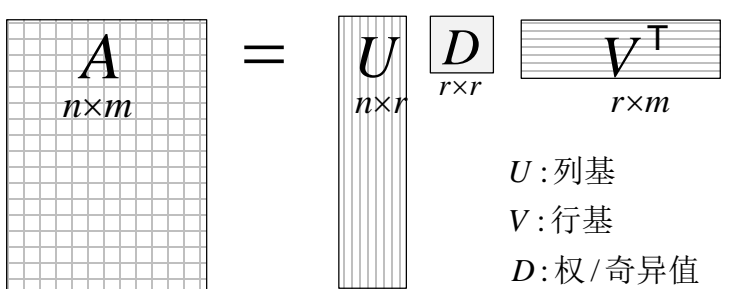
$$\text{即 } \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix} = \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix},$$

反转 90° 90° 反射 45° 反射

SVD: 非方阵的特征

任一不是方阵的 $n \times m$ 矩阵 A 没有特征根和特征向量，其行和列如何用类似于特征向量的不变量进行刻画？

奇异值分解 (SVD: singular value decomposition):

$$SVD: A = UDV^T$$


A
 $n \times m$

U
 $n \times r$

D
 $r \times r$

V^T
 $r \times m$

U : 列基
 V : 行基
 D : 权/奇异值

key: $C(A) = C(AA^T)$, $C(A^T) = C(A^T A)$

利用对称方阵 AA^T 以及 $A^T A$ 的特征向量分别刻画 A 和 A^T 的列。

奇异值 分解SVD

定理7(SVD). 任一秩为 r 的 $n \times m$ 矩阵 A 可表示为

$$A = U_{n \times r} D_{r \times r} V_{r \times m}^T$$

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 $A^T A$ 或 AA^T 的 r 个正特征根, $U_{n \times r} = (\mathbf{u}_1, \dots, \mathbf{u}_r)$ 的第 i 列 \mathbf{u}_i 为 AA^T 的对应于特征根 λ_i 的特征向量, $V_{m \times r} = (\mathbf{v}_1, \dots, \mathbf{v}_r)$ 的第 i 列 \mathbf{v}_i 为 $A^T A$ 的对应于特征根 λ_i 的特征向量。

SVD的发现本质上利用了简单事实:

若 \mathbf{v} 是 $A^T A$ 的特征向量, 则 $A\mathbf{v}$ 是 AA^T 的特征向量:

$$A^T A \mathbf{v} = \mathbf{v} \lambda \quad \text{左乘} A \Rightarrow AA^T (A\mathbf{v}) = (A\mathbf{v}) \lambda$$

证明: $\lambda_1 \geq \dots \geq \lambda_r > 0$ 为 $A^T A$ 或 AA^T 的 r 个正特征根.

由 $A^T A$ 的谱分解定理, 我们可选择单位正交特征向量 $\mathbf{v}_1, \dots, \mathbf{v}_r$, 满足特征方程:

$$A^T A \mathbf{v}_j = \mathbf{v}_j \lambda_j, \quad j = 1, \dots, r, \Leftrightarrow A^T A V = V D^2, \quad V = (\mathbf{v}_1, \dots, \mathbf{v}_r)$$

两边同时左乘 $A \Rightarrow AA^T (AV) = (AV) D^2$, 所以 $Y = AV$ 各列是 AA^T 的特征向量。

$Y^T Y = V^T A^T A V = V^T V D^2 = D^2$, 所以 Y 的各列相互正交, 但不是单位长度, 只需令 $U = YD^{-1} = AVD^{-1}$, 则 $U^T U = D^{-1} V^T A^T A V D^{-1} = I_r$, 即 U 的各列是 AA^T 的单位长且相互正交的特征向量。

由 $U = AVD^{-1} \Rightarrow AV = UD \Rightarrow AVV^T = UDV^T$
只需说明 $A = AVV^T$ 。

注意: V 是 $m \times r$ 矩阵,
 $V^T V = I_r$ 并不蕴含 $VV^T = I_m$,
事实上, VV^T 的秩为 $r \leq m$

因为 V 是 $C(A^T A)$, 也是 $C(A^T)$ 的一组正交基 \Rightarrow 存在 B 使得 $A^T = VB$,
由 $V^T V = I_r \Rightarrow AVV^T = B^T V^T V V^T = B^T V^T = A$, 所以 $A = UDV^T$ 。

$A^T = (\mathbf{a}_1, \dots, \mathbf{a}_n)$, 因为 V 的各列是 $C(A^T)$ 的一组基, 存在 $r \times 1$ 系数 \mathbf{b}_i 使得 $\mathbf{a}_i = V\mathbf{b}_i$
 $\Rightarrow A^T = (V\mathbf{b}_1, \dots, V\mathbf{b}_n) = V(\mathbf{b}_1, \dots, \mathbf{b}_n) = VB$

事实上, $VV^T = V(V^T V)^{-1} V^T$ 是 A 行空间的投影矩阵

定理7*(SVD). 有时为了数学上的方便, 将 U, V 扩展成正交方阵,

$$\tilde{U} = (U, *), \tilde{V} = (V, *), \tilde{U}^T \tilde{U} = \tilde{U} \tilde{U}^T = I_n, \tilde{V}^T \tilde{V} = \tilde{V} \tilde{V}^T = I_m.$$

奇异值分解也表述为



$$A_{n \times m} = \tilde{U}_{n \times n} \begin{pmatrix} D_{r \times r} & 0 \\ 0 & 0 \end{pmatrix}_{n \times m} \tilde{V}^T_{m \times m}.$$

总结SVD: $A = UDV^T$



- 行特征(V 是行空间 $C(A^T)$ 的正交基): $A^T A V = V D^2$, $C(V) = C(A^T)$;
- 列特征(U 是列空间 $C(A)$ 的正交基): $A A^T U = U D^2$, $C(U) = C(A)$;
- 对偶:
$$\begin{cases} A V = U D \\ A^T U = V D \end{cases}, \begin{cases} A \mathbf{v}_j = \mathbf{u}_j \sqrt{\lambda_j} \\ A^T \mathbf{u}_j = \mathbf{v}_j \sqrt{\lambda_j} \end{cases}, j = 1, \dots, r$$
- 若 A 各列是中心化的, 则 UD 的各列称为主成分(第 j 列称为第 j 主成分, 重要性或方差贡献为 λ_j)。 V 各列称为主成分方向。
- $A = UDV^T = \sum_{j=1}^r \sqrt{\lambda_j} \mathbf{u}_j \mathbf{v}_j^T$, 前 k 项 $\sum_{j=1}^k \sqrt{\lambda_j} \mathbf{u}_j \mathbf{v}_j^T$ 是 A 的 k 阶(秩 k)最佳逼近。

1955年，英国数学家Roger Penrose (彭罗斯，1931-) 发现, 通过使用广义逆可以将线性方程组通解简单地表示出来。2020年因其在黑洞，奇点的研究获得诺贝尔物理学奖。在娱乐数学方面，彭罗斯推广和发明了若干不可能图形，发现了除正三、四、六边形之外的其它形状地砖铺满地面但不重复的铺法。

不可能的形状：
彭罗斯三角和
彭罗斯阶梯



彭罗斯地砖
(几种图形填
满地面，直线
上永不重复)



我们知道，若 $A\mathbf{x} = \mathbf{b}$ 有唯一解，解 $\mathbf{x} = A^{-1}\mathbf{b}$;

若 $A\mathbf{x} = \mathbf{b}$ 解不唯一，甚至 A 不是方阵，能否将所有解表示为 $\mathbf{x} = A^{inv}\mathbf{b}$?
 A^{inv} 是一类 A 的“逆”矩阵.

若 $A\mathbf{x} = \mathbf{b}$ 有解，即 $\mathbf{b} \in C(A) \Rightarrow$ 存在 $\mathbf{t} \in R^m, \mathbf{b} = A\mathbf{t}$.

若 $\mathbf{x} = A^{inv}\mathbf{b}$ 是 $A\mathbf{x} = \mathbf{b}$ 的解, 则 $A\mathbf{t} = \mathbf{b} = A(A^{inv}\mathbf{b}) = A(A^{inv}A\mathbf{t}) = AA^{inv}A\mathbf{t}$,
所以 A^{inv} 需要满足条件: $AA^{inv}A = A$, 因此有下述定义:

广义逆 A^-

定义: 任何 $A_{n \times m}$, 若 $X_{m \times n}$ 满足 $AXA = A$, X 称为 A 的广义逆, 记为 A^-

存在性:

设 $A_{n \times m} = U_{n \times r} D_{r \times r} (V_{m \times r})^T$ 是 A 的奇异值分解, 则 $VD^{-1}U^T$ 是一个广义逆.

验证: 因为 $V^T V = U^T U = I_r$, 所以 $A(VD^{-1}U^T)A = UDV^T VD^{-1}U^T UDV^T = UDV^T = A$.

A^- 的一般表达

命题7. 当 A 是满秩方阵的时候广义逆唯一, $A^- = A^{-1}$, 否则不唯一, 具体如下:

当 $r = \text{rank}(A) < \max(m, n)$ 时, 若 A 有奇异值分解 $A = \tilde{U} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \tilde{V}^T$,

其中 $\tilde{U}^T \tilde{U} = \tilde{U} \tilde{U}^T = I_n, \tilde{V}^T \tilde{V} = \tilde{V} \tilde{V}^T = I_m$, 则任何广义逆具有形式:

$$A^- = \tilde{V} \begin{pmatrix} D^{-1} & * \\ * & * \end{pmatrix} \tilde{U}^T \quad (*\text{表示任意}).$$

证: 设 X 是任一广义逆, 则

$$AXA = A$$

$$\Leftrightarrow \tilde{U} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \tilde{V}^T X \tilde{U} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \tilde{V}^T = \tilde{U} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \tilde{V}^T$$

$$\Leftrightarrow \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} Y_{11} & Y_{12} \\ Y_{21} & Y_{22} \end{pmatrix} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}, \text{其中 } Y = \tilde{V}^T X \tilde{U} = \begin{pmatrix} Y_{11} & Y_{12} \\ Y_{21} & Y_{22} \end{pmatrix}$$

则 $Y_{11} = D^{-1}$, 其它任意, 所以 $X = \tilde{V} Y \tilde{U}^T = \tilde{V} \begin{pmatrix} D^{-1} & * \\ * & * \end{pmatrix} \tilde{U}^T$.

Moore-Penrose 广义逆

任何 $A_{n \times m}$, 若 $X_{m \times n}$ 满足

$$AXA = A, \quad XAX = X, \quad (AX)^\top = AX, \quad (XA)^\top = XA$$

X 称为 A 的 Moore - Penrose 广义逆, 记为 A^+ .

命题8(A^+ 存在唯一). 若 A 有 SVD 分解 $A_{n \times m} = U_{n \times r} D_{r \times r} (V_{m \times r})^\top$, 其中 U, V 为列正交方阵: $U^\top U = I_r, V^\top V = I_r$, 则 $A^+ = VD^{-1}U^\top$.

证明: 容易验证上述定义的 A^+ 满足 MP 广义逆的四个条件。

A^+ 的唯一性证明如下:

若 X, Y 都是 MP 广义逆, 下面证明 $X = Y$.

$$\begin{aligned} X &= XAX = X(AX)^\top = XX^\top A^\top = XX^\top (AYA)^\top = XX^\top A^\top Y^\top A^\top \\ &= X(AX)^\top (AY)^\top = X(AX)(AY) = X(AXA)Y = XAY, \end{aligned}$$

至此, 我们把 $X = XAX$ 中的第三项由 X 换作了 Y 。

类似的操作可把 $XAX = XAY$ 中的第一项也换成 Y :

$$\begin{aligned} X &= XAY = (XA)^\top (YAY) = A^\top X^\top YAY = A^\top X^\top A^\top Y^\top Y = A^\top Y^\top Y \\ &= (YA)^\top Y = YAY = Y. \end{aligned}$$

线性方程解的一般形式

定理8. 若方程 $A\mathbf{x} = \mathbf{b}$ 有解($\mathbf{b} \neq \mathbf{0}$), 则任何一个解都具有形式 $\mathbf{x} = A^-\mathbf{b}$.

证明: 假设 \mathbf{x} 是 $A\mathbf{x} = \mathbf{b}$ 的任一解。对任何一个 A 的广义逆 B , $\mathbf{x}_0 = B\mathbf{b}$ 是 $A\mathbf{x} = \mathbf{b}$ 的解, 所以 $A(\mathbf{x} - \mathbf{x}_0) = \mathbf{0}$, $\mathbf{v} = \mathbf{x} - \mathbf{x}_0 \in N(A)$,

$$\mathbf{x} = \mathbf{x}_0 + \mathbf{v} = B\mathbf{b} + \frac{\mathbf{v}\mathbf{b}^\top}{\|\mathbf{b}\|^2} \mathbf{b} = \left(B + \frac{\mathbf{v}\mathbf{b}^\top}{\|\mathbf{b}\|^2} \right) \mathbf{b} = C\mathbf{b}$$

其中 $C = B + \frac{\mathbf{v}\mathbf{b}^\top}{\|\mathbf{b}\|^2}$, 容易验证 $ACA = ABA + A \frac{\mathbf{v}\mathbf{b}^\top}{\|\mathbf{b}\|^2} A = ABA = A$.

所以 $C = B + \frac{\mathbf{v}\mathbf{b}^\top}{\|\mathbf{b}\|^2}$ 是 A 的广义逆。

线性方程解的最优解

命题9. 若方程 $A\mathbf{x} = \mathbf{b}$ 有解($\mathbf{b} \neq \mathbf{0}$), 则 $\mathbf{x} = A^+\mathbf{b}$ 是所有解中长度最小的解。

证: 设 \mathbf{x} 是 $A\mathbf{x} = \mathbf{b}$ 的解, 则 \mathbf{x} 可表示为 $\mathbf{x} = A^+\mathbf{b} + \mathbf{v}$,

其中 $A\mathbf{v} = \mathbf{0}$, 设 A 的SVD为 $A = UDV^\top$, $\Rightarrow UDV^\top \mathbf{v} = \mathbf{0} \Rightarrow V^\top \mathbf{v}$

由 $A^+ = VD^{-1}U^\top \Rightarrow A^+ \mathbf{v} = \mathbf{0} \Rightarrow \|\mathbf{x}\|^2 = \|A^+\mathbf{b}\|^2 + \|\mathbf{v}\|^2 \geq \|A^+\mathbf{b}\|^2$.

欧氏空间中的正交投影

内积: $\mathbf{u}, \mathbf{v} \in R^n, \langle \mathbf{u}, \mathbf{v} \rangle = \mathbf{u}^T \mathbf{v} = \sum u_i v_i$

模长: $\|\mathbf{u}\| = \sqrt{\langle \mathbf{u}, \mathbf{u} \rangle} = \sqrt{\sum u_i^2}$


其它形式内积也可以, 比如, $\langle \mathbf{u}, \mathbf{v} \rangle = \mathbf{u}^T G \mathbf{v}, G > 0$

投影

设 $\mathbf{y} \neq \mathbf{0} \in R^n, \mathbf{y}$ 在线性子空间 $V \subset R^n$ 空间上的正交投影 $\hat{\mathbf{y}}$ 满足:

(1) $\hat{\mathbf{y}} \in V$

(2) $\mathbf{y} - \hat{\mathbf{y}} \perp V$, 即对 $\forall \mathbf{x} \in V, \langle \mathbf{x}, \mathbf{y} - \hat{\mathbf{y}} \rangle = 0 \Leftrightarrow \langle \mathbf{x}, \mathbf{y} \rangle = \langle \mathbf{x}, \hat{\mathbf{y}} \rangle$.



记 $\mathbf{y}^\perp = \mathbf{y} - \hat{\mathbf{y}}$,

正交分解: $\mathbf{y} = \hat{\mathbf{y}} + \mathbf{y}^\perp, \hat{\mathbf{y}} \perp \mathbf{y}^\perp$;

平方和分解: $\|\mathbf{y}\|^2 = \|\hat{\mathbf{y}}\|^2 + \|\mathbf{y}^\perp\|^2$


投影参考: James H Stapleton (1995) Linear statistical models. Wiley
(下载: /books/5.pdf)

投影的最优性：
最小二乘

定理2(最小二乘,欧氏情形) : $\mathbf{y} \in R^n$, 记 $\hat{\mathbf{y}} = P(\mathbf{y} | V)$ 为 \mathbf{y} 在子空间 $V \subset R^n$ 上的投影, 则 $\|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \min_{\mathbf{u} \in V} \|\mathbf{y} - \mathbf{u}\|^2$

证: 对任何 $\mathbf{u} \in V$, 因为 $\hat{\mathbf{y}} - \mathbf{u} \in V$, 故 $\mathbf{y} - \hat{\mathbf{y}} \perp \hat{\mathbf{y}} - \mathbf{u}$.

所以 $\|\mathbf{y} - \mathbf{u}\|^2 = \|\mathbf{y} - \hat{\mathbf{y}} + \hat{\mathbf{y}} - \mathbf{u}\|^2 = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 + \|\hat{\mathbf{y}} - \mathbf{u}\|^2 \geq \|\mathbf{y} - \hat{\mathbf{y}}\|^2$.



投影矩阵

命题10. 设 $V = C(A_{n \times m}) \subset R^n$, $\mathbf{y} \in R^n$, 则 \mathbf{y} 在 V 上的投影为

$$\hat{\mathbf{y}} = P_A \mathbf{y} = A(A^T A)^{-1} A^T \mathbf{y},$$

其中 A 对应的投影矩阵为 $P_A = A(A^T A)^{-1} A^T$ (n 阶方阵).

证明1: 因为 $\mathbf{y}^\perp = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - A\boldsymbol{\beta} \perp C(A)$, 所以对任何 $\mathbf{t} \in R^m$, $\mathbf{u} = A\mathbf{t} \in C(A)$,

$$0 = \langle \mathbf{u}, \mathbf{y}^\perp \rangle = \langle A\mathbf{t}, \mathbf{y}^\perp \rangle \stackrel{\text{adjoint}}{=} \langle \mathbf{t}, A^T \mathbf{y}^\perp \rangle$$

即 $A^T \mathbf{y}^\perp \in R^m$ 与任何 $\mathbf{t} \in R^m$ 都正交, 所以 $A^T \mathbf{y}^\perp = \mathbf{0}$, 即正则方程:

$$A^T \mathbf{y} = A^T A \boldsymbol{\beta}$$

因为 $A^T \mathbf{y} \in C(A^T) = C(A^T A)$, 方程有解, 所有解 $\hat{\boldsymbol{\beta}} = (A^T A)^{-1} A^T \mathbf{y}$


$\Rightarrow \hat{\mathbf{y}} = A\hat{\boldsymbol{\beta}} = A(A^T A)^{-1} A^T \mathbf{y}$, 所以 $P_A = A(A^T A)^{-1} A^T$.

证明2: 因为 $\hat{\mathbf{y}} \in V$, 存在 $\boldsymbol{\beta}_{m \times 1}$, 使得 $\hat{\mathbf{y}} = A\boldsymbol{\beta}$.

因为 $\mathbf{y}^\perp = \mathbf{y} - \hat{\mathbf{y}} \perp C(A)$, 特别地, \mathbf{y}^\perp 与 A 的每列都正交

$$\Rightarrow A^T (\mathbf{y} - \hat{\mathbf{y}}) = A^T (\mathbf{y} - A\boldsymbol{\beta}) = \mathbf{0} \Leftrightarrow A^T A \boldsymbol{\beta} = A^T \mathbf{y}$$

$$\Rightarrow \hat{\boldsymbol{\beta}} = (A^T A)^{-1} A^T \mathbf{y} \Rightarrow \hat{\mathbf{y}} = A(A^T A)^{-1} A^T \mathbf{y}, P_A = A(A^T A)^{-1} A^T$$



$$R^n \text{ 中解近似方程 } \mathbf{y} \approx A\hat{\beta} \xrightarrow{A^T} R^m \text{ 中解方程 } A^T \mathbf{y} = A^T A\hat{\beta}$$

(求解 \mathbf{y} 的最佳逼近 $\mathbf{y} = A\hat{\beta}$)

$$A^T \mathbf{y}^\perp = A^T (\mathbf{y} - \hat{\mathbf{y}}) = \mathbf{0}:$$

蓝线 $\mathbf{y} + C(A)^\perp$ 上的点在 $C(A)$ 上的投影都相同

$\Leftrightarrow A^T$ 将它们映射为 R^m 中的同一点 $A^T \hat{\mathbf{y}}$ 。

例6. 设 $\mathbf{x} \neq \mathbf{0} \in R^n$, \mathbf{x} 张成的空间 $U = C(\mathbf{x}) = \{\mathbf{x}c \mid c \in R\}$, 投影矩阵

$$P_{\mathbf{x}} = \mathbf{x}(\mathbf{x}^T \mathbf{x})^{-1} \mathbf{x}^T$$


$\mathbf{y} \in R^n$ 在 U 上的投影 $\hat{\mathbf{y}} = P_{\mathbf{x}} \mathbf{y} = \mathbf{x}(\mathbf{x}^T \mathbf{x})^{-1} \mathbf{x}^T \mathbf{y} = \mathbf{x}\lambda$, $\lambda = \mathbf{x}^T \mathbf{y} / \mathbf{x}^T \mathbf{x}$ 。

特别地, 如果 $\mathbf{x} = \mathbf{1} = (1, \dots, 1)^T \in R^n$, $P_1 = \mathbf{1}(\mathbf{1}^T \mathbf{1})^{-1} \mathbf{1}^T = \frac{1}{n} \mathbf{1}\mathbf{1}^T$,

$$\hat{\mathbf{y}} = P_1 \mathbf{y} = \frac{1}{n} \mathbf{1}\mathbf{1}^T \mathbf{y} = \mathbf{1}\bar{y},$$

$$\mathbf{y}^\perp = \mathbf{y} - P_1 \mathbf{y} = \mathbf{y} - \mathbf{1}\bar{y} = (y_1 - \bar{y}, \dots, y_n - \bar{y})^T,$$

\mathbf{y}^\perp 称为 \mathbf{y} 的中心化向量。



中心化向量

$\mathbf{y}^\perp = (I_n - P_1)\mathbf{y} = P_{\mathbf{1}^\perp} \mathbf{y}$
为 \mathbf{y} 在 $\mathbf{1}$ 的正交补空间上的投影

投影矩阵的性质

命题11. 设 A 是 $n \times m$ 矩阵, 则

(1) $P_A = A(AA^\top)^- A^\top$ 唯一, 与广义逆 $(AA^\top)^-$ 的具体选择无关。

(2) 投影矩阵等价于对称幂等阵: $P_A = A(A^\top A)^- A^\top$ 是对称幂等矩阵, 反之, 任一对称幂等阵是投影阵。

(3) 任一投影矩阵 $P_{n \times n}$ 有谱分解 $P = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top$, 其中 $r = \text{rank}(P)$,

$$OO^\top = O^\top O = I_n,$$

(4) $P_A A = A$.

(5) P_A 是 $C(A)$ 对应的投影阵, $I_n - P_A$ 是 $C(A)^\perp$ 对应的投影阵, 两者正交:

$$P_A(I_n - P_A) = 0$$

(6) 线性子空间 V 对应的投影矩阵与空间的基的选取无关。

(7) 若 $A = (\mathbf{a}_1, \dots, \mathbf{a}_m)$, 即 $A^\top A$ 为对角阵, 则 $P_A = \sum_{k=1}^m P_{\mathbf{a}_k}$.

(8) 按列划分 $A = (A_1, A_2)$, 若 $A_1^\top A_2 = 0$, 则 $P_A = P_{A_1} + P_{A_2}$.

多数结论是第8讲命题6的重述

证明:(1) 这是命题6的特殊情形, 因为投影唯一, 投影阵 P_A 必定唯一, 与广义逆 $(A^T A)^-$ 的选择无关。但这里用矩阵方法再次证明:

因为 $C(A^T) = C(A^T A)$, 所以存在 B 使得 $A^T = A^T A B$,

所以 $P_A = A(A^T A)^- A^T = B^T A^T A(A^T A)^- A^T A B = B^T A^T A B$ 与 $(A^T A)^-$ 无关, 且 $P_A = B^T A^T A B$ 是对称的。

$$\begin{aligned} (2) \quad A^T = A^T A B &\Rightarrow P_A^2 = A(A^T A)^- A^T A(A^T A)^- A^T \\ &= A(A^T A)^- A^T A(A^T A)^- A^T A B = A(A^T A)^- A^T A B = A(A^T A)^- A^T = P_A. \end{aligned}$$

反之, 设 P 是 $n \times n$ 对称幂等矩阵, $r = \text{rank}(P)$, 则有谱分解 $P = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^T$,

其中 $OO^T = O^T O = I_n$, 划分 $O = (O_1, O_2)$, 则 $O_1^T O_1 = I_r$, $P = O_1 O_1^T = O_1 (O_1^T O_1)^{-1} O_1^T$, 所以 P 具有投影矩阵的形式, 所以任何对称幂等矩阵是投影阵。

(3)–(7)略。

命题12. 若 $A_{n \times m}$ 有奇异值分解 $A = U_{n \times r} D_{r \times r} (V_{m \times r})^\top$, 其中 $U^\top U = V^\top V = I_r$,
则 $P_A = A(A^\top A)^- A^\top = UU^\top$.

证明: $C(U) = C(A)$, 所以 $P_A = P_U = U(U^\top U)^{-1}U^\top = UU^\top$.

注: 命题12提供了投影阵更容易理解的形式:

设 U 的各列为 $U = (\mathbf{u}_1, \dots, \mathbf{u}_r)$, 则任何 $\mathbf{y} \in R^n$ 在 $C(A)$ 上的投影

$$P_A \mathbf{y} = UU^\top \mathbf{y} = \mathbf{u}_1(\mathbf{u}_1^\top \mathbf{y}) + \dots + \mathbf{u}_r(\mathbf{u}_r^\top \mathbf{y})$$

正是我们对正交投影的理解方式: $\mathbf{u}_1, \dots, \mathbf{u}_r$ 为基(坐标轴),

$\mathbf{u}_1^\top \mathbf{y}, \dots, \mathbf{u}_r^\top \mathbf{y}$ 为 \mathbf{y} 在这些坐标轴上的投影坐标。