

矩阵分析笔记

1 矩阵的基本概念

- Hermitian 矩阵: $\mathbf{A}^H = \mathbf{A}$ 。幂等矩阵: $\mathbf{A}^2 = \mathbf{A}$ 。
- 内积: $\langle \mathbf{x}, \mathbf{y} \rangle = \mathbf{x}^H \mathbf{y}$, $\langle \mathbf{x}(t), \mathbf{y}(t) \rangle = \int \mathbf{x}^H \mathbf{y} dt$, $\langle \mathbf{x}(\xi), \mathbf{y}(\xi) \rangle = E\{\mathbf{x}^H \mathbf{y}\}$
- L_p 范数: $\|\mathbf{x}\|_p = (\sum |x_i|^p)^{1/p}$, 距离 $d(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|$ 。
- 范数性质 (P27)
- 向量夹角: $\cos\theta = \frac{\langle \mathbf{x}, \mathbf{y} \rangle}{\|\mathbf{x}\| \|\mathbf{y}\|}$ 。常数向量、函数向量正交充要条件是内积为零, 随机向量正交条件是外积为零。
- 均值向量 $\boldsymbol{\mu}_x = E\{\mathbf{x}(\xi)\}$, 自相关矩阵 $\mathbf{R}_x = E\{\mathbf{x}(\xi)\mathbf{x}^H(\xi)\}$, 自协方差矩阵 $\mathbf{C}_x = E\{[\mathbf{x}(\xi) - \boldsymbol{\mu}_x][\mathbf{x}(\xi) - \boldsymbol{\mu}_x]^H\} = \mathbf{R}_x - \boldsymbol{\mu}_x \boldsymbol{\mu}_x^H$ 。互相关矩阵 $\mathbf{R}_{xy} = E\{\mathbf{x}(\xi)\mathbf{y}^H(\xi)\}$, 互协方差矩阵 $\mathbf{C}_{xy} = E\{[\mathbf{x}(\xi) - \boldsymbol{\mu}_x][\mathbf{y}(\xi) - \boldsymbol{\mu}_y]^H\} = \mathbf{R}_{xy} - \boldsymbol{\mu}_x \boldsymbol{\mu}_y^H$ 。相关系数 $\rho_{xy} = \frac{c_{xy}}{\sigma_x \sigma_y}$ 。统计不相关充要条件为互协方差矩阵为零, 正交充要条件为互相关矩阵为零。
- $\mathbf{x}(\xi) \sim \mathcal{N}(\boldsymbol{\mu}_x, \mathbf{C}_x)$, 若 x_i 独立同分布, $f(\mathbf{x}) = \frac{1}{(2\pi)^{n/2} |\mathbf{C}_x|^{1/2}} \exp(-\frac{1}{2}(\mathbf{x}(\xi) - \boldsymbol{\mu}_x)^T \mathbf{C}_x^{-1}(\mathbf{x}(\xi) - \boldsymbol{\mu}_x))$ 。
- 欧氏距离: $D_E(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|_2$; 马氏距离: $D_M(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T \mathbf{C}_x^{-1}(\mathbf{x} - \mathbf{y})}$ 。
- 矩阵的 L_p 范数: $\|\mathbf{A}\|_p = (\sum_{ij} |a_{ij}|^p)^{1/p}$ 。
- 矩阵范数性质 (P33), 内积与范数关系 (P35)
- 矩阵的行列式: $\det(\mathbf{A}) = \sum_j a_{ij} (-1)^{i+j} \det(\mathbf{A}_{ij})$ 。
- 行列式性质、特征值及性质、迹及性质、秩及性质、逆及性质 (P47~P55)
- 矩阵和的求逆公式: $(\mathbf{A} + \mathbf{UBV})^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1} \mathbf{U}(\mathbf{I} + \mathbf{BVA}^{-1} \mathbf{U})^{-1} \mathbf{BVA}^{-1}$ 。
- 分块矩阵的逆 (P57), Hermitian 矩阵求逆引理 (P58~59)
- 左逆矩阵: $\mathbf{LA} = \mathbf{I}, m \geq n$; 右逆矩阵: $\mathbf{AR} = \mathbf{I}, m \leq n$ 。若 $\text{rank}(\mathbf{A}) = n$, 左伪

逆矩阵 $L = (A^H A)^{-1} A^H$, 若 $\text{rank}(A) = m$, 右伪逆矩阵 $R = A^H (A A^H)^{-1}$, 伪逆矩阵唯一确定。

- 广义逆矩阵 Moore-Penrose 条件: $AGA = A, GAG = G, AG$ 和 GA 为 Hermitian 矩阵。

- M-P 矩阵计算 (P64~P67)

- Kronecker 积: $A \otimes B = [a_{ij} B], [A \otimes B]_{left} = [A b_{ij}]$

- 直和: $A \oplus B = \begin{bmatrix} A & \\ & B \end{bmatrix}$

- Hadamard 积: $[A * B]_{ij} = a_{ij} b_{ij}$, 若 A, B 正定 (半正定), 则 $A * B$ 正定 (半正定)

- 直和与 Hadamard 积性质 (P67~P70)

2 特殊矩阵

- 基本矩阵 $E_{mn} = e_m e_n^T$ 。

- 基本矩阵性质 (P101)

- I 型基本矩阵 $E_{(p,q)}$, II 型基本矩阵 $E_{\alpha(p)}$, III 型基本矩阵 $E_{(p)+\alpha(q)}$, 对矩阵左乘表示行操作, 右乘表示列操作。

- 置换矩阵: 各行列有且仅有一个非零元素 1。移位矩阵 $P = (e_2, \dots, e_n, e_1)^T$ 。互换矩阵 $J = (e_n, \dots, e_1)^T$ 。选择矩阵 $P_{(M-1) \times M} = [I_{M-1}, 0]$ 。交换矩阵 $K_{mn} \text{vec}(A) = \text{vec}(A^T)$ 。广义置换矩阵: 各行列有且仅有一个非零元素。

- 酉矩阵: $UU^H = U^H U = I$ 。仿酉矩阵: 只满足 $UU^H = I$ 或 $U^H U = I$ 。正交矩阵与半正交矩阵定义与之类似。

- 酉矩阵性质 (P111)

- 正规矩阵: $AA^H = A^H A$ 。

- 求和向量 $\mathbf{1}_n = [1, \dots, 1]^T, J_{p \times q} = \mathbf{1}_p \mathbf{1}_q^T$, 中心化矩阵 $C_n = I_n - \frac{1}{n} J_n, \sum (x_i - \bar{x})^2 =$

$\mathbf{x}^T \mathbf{C} \mathbf{x}$ 。

• $\mathbf{B} \sim \mathbf{A}$: $\mathbf{B} = \mathbf{S}^{-1} \mathbf{A} \mathbf{S}$, \mathbf{S} 非奇异。

• 相似矩阵性质 (P117~P118)

• 相合矩阵: $\mathbf{B} = \mathbf{C}^H \mathbf{A} \mathbf{C}$, \mathbf{C} 非奇异。相合矩阵的二次型相同。

• 三角矩阵性质 (P114)

• Vandermonde 矩阵 $\mathbf{A} = \begin{bmatrix} a_1^0 & \cdots & a_N^0 \\ \vdots & \ddots & \vdots \\ a_1^{N-1} & \cdots & a_N^{N-1} \end{bmatrix}$, $\det(\mathbf{A}) = \prod_{i>j} (a_i - a_j)$

• Fourier 矩阵 $\mathbf{F}_{ik} = \omega^{(i-1)(k-1)}$, $\omega = e^{-j2\pi/N}$

• Fourier 矩阵性质 (P124)

• Hadamard 矩阵: 所有元素取 ± 1 , 且 $\mathbf{H}_n \mathbf{H}_n^T = \mathbf{H}_n^T \mathbf{H}_n = n \mathbf{I}_n$ 。

• Hadamard 矩阵性质 (P129~P130)

• Toeplitz 矩阵 $\mathbf{A}_{mn} = a_{m-n}$ 。对称 Toeplitz 矩阵: $a_{-i} = a_i$ 。Hermitian Toeplitz 矩阵: $a_{-i} = a_i^*$ 。

3 矩阵微分

• 根据函数 $f(z)$ 在 $z = 0$ 点的幂级数构造矩阵函数 $f(\mathbf{A}) = \sum_k c_k \mathbf{A}^k$ 。

• 若 $\mathbf{A}\mathbf{B} = \mathbf{B}\mathbf{A}$, 则 $e^{\mathbf{A}} e^{\mathbf{B}} = e^{\mathbf{B}} e^{\mathbf{A}} = e^{\mathbf{A}+\mathbf{B}}$ 。

• 若 $\mathbf{A}\mathbf{B} = \mathbf{B}\mathbf{A}$, 则 $\cos(\mathbf{A} + \mathbf{B}) = \cos \mathbf{A} \cos \mathbf{B} - \sin \mathbf{A} \sin \mathbf{B}$, $\sin(\mathbf{A} + \mathbf{B}) = \sin \mathbf{A} \cos \mathbf{B} + \cos \mathbf{A} \sin \mathbf{B}$ 。

• 设 $\mathbf{P}^{-1} \mathbf{A} \mathbf{P} = \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix}$, 则 $f(\mathbf{A}) = \mathbf{P} \begin{bmatrix} f(\lambda_1) & & \\ & \ddots & \\ & & f(\lambda_n) \end{bmatrix} \mathbf{P}^{-1}$ 。

• 偏导算子 $D_{\mathbf{x}} = \frac{\partial}{\partial \mathbf{x}^T}$, $D_{\text{vec}(\mathbf{X})} = \frac{\partial}{\partial \text{vec}^T(\mathbf{X})}$, $D_{\mathbf{X}} = \frac{\partial}{\partial \mathbf{X}^T}$, 梯度算子 $\nabla_{\mathbf{x}} = \frac{\partial}{\partial \mathbf{x}}$, $\nabla_{\text{vec}(\mathbf{X})} = \frac{\partial}{\partial \text{vec}(\mathbf{X})}$, $\text{rvec}(D_{\mathbf{X}}) = D_{\text{vec}(\mathbf{X})}$, $\nabla_{\mathbf{x}} = D_{\mathbf{x}}^T$ 。

• $[D_{\mathbf{x}} \mathbf{f}(\mathbf{x})]_{ij} = \frac{\partial f_i(\mathbf{x})}{\partial x_j}$, $D_{\mathbf{X}} \mathbf{F}(\mathbf{X}) = \frac{\partial \text{vec}(\mathbf{F}(\mathbf{X}))}{\partial \text{vec}^T(\mathbf{X})}$

- $df(\mathbf{x}) = \text{tr}(\mathbf{A}d\mathbf{x}), \mathbf{A} = D_{\mathbf{x}}f(\mathbf{x}); df(\mathbf{X}) = \text{tr}(\mathbf{A}d\mathbf{X}), \mathbf{A} = D_{\mathbf{X}}f(\mathbf{X})$
- 矩阵微分的性质和常用公式 (P152~P153, P158, P160)
- $d(\text{vec}\mathbf{F}(\mathbf{X})) = \mathbf{A}d(\text{vec}\mathbf{X}) + \mathbf{B}d(\text{vec}\mathbf{X}^T) = (\mathbf{A} + \mathbf{B}\mathbf{K}_{mn})d(\text{vec}\mathbf{X}), D_{\mathbf{X}}\mathbf{F}(\mathbf{X}) = \mathbf{A} + \mathbf{B}\mathbf{K}_{mn}; d\mathbf{F}(\mathbf{X}) = \mathbf{A}(d\mathbf{X})\mathbf{B} + \mathbf{C}(d\mathbf{X}^T)\mathbf{D}, D_{\mathbf{X}}\mathbf{F}(\mathbf{X}) = (\mathbf{B}^T \otimes \mathbf{A}) + (\mathbf{D}^T \otimes \mathbf{C})\mathbf{K}_{mn}。$
- $\mathbf{H}[f(\mathbf{x})] = \nabla_{\mathbf{x}}^2 f(\mathbf{x}) = \nabla_{\mathbf{x}}(D_{\mathbf{x}}f(\mathbf{x})), \mathbf{H}^T[f(\mathbf{x})] = \mathbf{H}[f(\mathbf{x})]$
- $d^2 f(\mathbf{x}) = (d\mathbf{x})^T \mathbf{B}d\mathbf{x}, \mathbf{H}[f(\mathbf{x})] = \frac{1}{2}(\mathbf{B}^T + \mathbf{B}); d^2 f(\mathbf{X}) = (d(\text{vec}(\mathbf{X})))^T \mathbf{B}d(\text{vec}\mathbf{X}), \mathbf{H}[f(\mathbf{x})] = \frac{1}{2}(\mathbf{B}^T + \mathbf{B})$
- $\frac{\partial}{\partial z} = \frac{1}{2}(\frac{\partial}{\partial x} - j\frac{\partial}{\partial y}), \frac{\partial}{\partial z^*} = \frac{1}{2}(\frac{\partial}{\partial x} + j\frac{\partial}{\partial y})$
- 复变函数偏导的常用公式、法则 (P173~P174)
- 协梯度算子 $D_{\mathbf{z}} = \frac{\partial}{\partial \mathbf{z}^T}$, 共轭协梯度算子 $D_{\mathbf{z}^*} = \frac{\partial}{\partial \mathbf{z}^H}$, 梯度算子 $\nabla_{\mathbf{z}} = \frac{\partial}{\partial \mathbf{z}}$, 共轭梯度算子 $\nabla_{\mathbf{z}^*} = \frac{\partial}{\partial \mathbf{z}^*}$
- 复偏导算子重要结果 (P177)
- 梯度矩阵运算法则 (P179)
- $df(\mathbf{Z}, \mathbf{Z}^*) = \text{tr}(\mathbf{A}d\mathbf{Z} + \mathbf{B}d\mathbf{Z}^*), \nabla_{\mathbf{z}} f(\mathbf{Z}, \mathbf{Z}^*) = \mathbf{A}^T, \nabla_{\mathbf{z}^*} f(\mathbf{Z}, \mathbf{Z}^*) = \mathbf{B}^T$
- 几种迹函数、行列式函数的复矩阵微分 (P183~P184)

4 无约束优化和凸优化基础

- $f(\mathbf{x})$ 局部极小点: $\nabla_{\mathbf{x}} f(\mathbf{x}) = 0, \nabla_{\mathbf{x}}^2 f(\mathbf{x}) \succcurlyeq 0$ 。 $f(\mathbf{z})$ 局部极小点: $\nabla_{\mathbf{z}^*} f(\mathbf{z}, \mathbf{z}^*) = 0, \mathbf{H}f(\mathbf{z}, \mathbf{z}^*) \succcurlyeq 0$ 。凸函数的局部极小点即为全局极小点。
- 凸函数、强凸函数、拟凸函数定义 (P213~P214)
- 一般优化问题: $\min_{\mathbf{x} \in \mathcal{D}} f_0(\mathbf{x}) \text{ s.t. } f_i(\mathbf{x}) \leq b_i, i = 1, \dots, m$ 。如果目标函数和约束函数都是凸函数, 则为凸优化问题。
- 凸集定义与运算性质 (P211~P212)

- 函数 $f(\mathbf{x})$ 为凸函数的充要条件是 $g(t) = f(\mathbf{x} + t\mathbf{v})$ 对任意 \mathbf{x}, \mathbf{v} 都是凸函数。
- 函数 $f(\mathbf{x})$ 为凸函数的充要条件是 $f(\mathbf{y}) \geq f(\mathbf{x}) + \nabla f^T(\mathbf{x})(\mathbf{y} - \mathbf{x})$ 。
- 设凸优化问题最优解 p^* ，记 $L(\mathbf{x}, \boldsymbol{\lambda}, \mathbf{v}) = f_0(\mathbf{x}) + \sum \lambda_i f_i(\mathbf{x}) + \sum v_i h_i(\mathbf{x})$ ，拉格朗日对偶函数 $g(\boldsymbol{\lambda}, \mathbf{v}) = \inf_{\mathbf{x}} L(\mathbf{x}, \boldsymbol{\lambda}, \mathbf{v})$ 是凹函数。对偶问题： $\max_{\boldsymbol{\lambda} \geq 0, \mathbf{v}} J_D(\boldsymbol{\lambda}, \mathbf{v})$ ，其最优解 $d^* \leq p^*$ 。

• 拉格朗日对偶无约束优化问题 KKT 条件：

$$\begin{cases} f_i(\mathbf{x}) \leq 0 \\ h_i(\mathbf{x}) = 0 \\ \boldsymbol{\lambda} \geq 0 \\ \lambda_i f_i(\mathbf{x}) = 0 \\ \nabla L(\mathbf{x}, \boldsymbol{\lambda}, \mathbf{v}) = 0 \end{cases} .$$

- 凸优化与拉格朗日对偶无约束优化强对偶。非凸优化，解在可行域内域则强对偶（Slater 定理），否则弱对偶。

5 奇异值分解

- 条件数（P287）
- 对矩阵 \mathbf{A} ，存在酉矩阵 \mathbf{U}, \mathbf{V} ，使得 $\mathbf{A} = \mathbf{U}\boldsymbol{\Sigma}\mathbf{V}^H$ ， $\boldsymbol{\Sigma} = \begin{bmatrix} \boldsymbol{\Sigma}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$ ，其中 $\boldsymbol{\Sigma}_1 = \text{diag}(\sigma_1, \dots, \sigma_r)$ ， $\sigma_1 \geq \dots \geq \sigma_r > 0$ ， $r = \text{rank}(\mathbf{A})$ 。 $\sigma_1, \dots, \sigma_r$ 以及 $\sigma_{r+1} = \dots = \sigma_n = 0$ 称为 \mathbf{A} 的奇异值。
- 奇异值的分解形式（P289~P290）
- 对优化问题 $\min_{\text{rank}(\mathbf{B})=k < \text{rank}(\mathbf{A})} \|\mathbf{A} - \mathbf{B}\|_F^2$ ，解为 $\mathbf{A}_k = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^H$ ，且 $\|\mathbf{A} - \mathbf{A}_k\|_F^2 = \sum_{i=k+1}^r \sigma_i^2$ 。
- 奇异值分解的唯一性（P291~P292）
- 奇异值的性质（P292~P295）
- 奇异值分解的应用（P301~P304）
- 乘积奇异值分解（P298~P299）
- 广义奇异值分解（P304~P306）

6 最小二乘

- 最小二乘问题: $\min_x \|Ax - b\|_p$ 。 $p = 1$ 时称为最小绝对偏差问题, $p = 2$ 称为线性最小二乘问题, $p = \infty$ 称为最小最大问题。
- Gauss-Markov 定理: 对于 $Ax = b + e$, 当且仅当 A 列满秩时, 存在最优无偏解, 它由最小二乘解 $\hat{x}_{SL} = (A^H A)^{-1} A^H b$ 给出, 具有最小方差。
- Tikhonov 正则化: 对秩亏损情况, $\hat{x}_{Tik} = (A^H A + \lambda I)^{-1} A^H b$ 。
- 普通最小二乘 (b 有误差), 解: $\hat{x}_{SL} = (A^H A)^{-1} A^H b$
- 数据最小二乘 (A 有误差), 解: $\hat{x}_{DLS} = \min_x \frac{(Ax - b)^H (Ax - b)}{x^H x}$ 。
- 总体最小二乘解: $\min_x \frac{(Ax - b)^H (Ax - b)}{1 + x^T x}$ 。(P337~P348)

7 特征分析

- 代数多重度、几何多重度 (P402)
- 特征值和特征向量性质 (P408~P410)
- 奇异值分解和特征值分解的区别 (P403)
- 若实矩阵 A 具有 n 个线性无关的特征向量 (或 n 个不同的特征值), 则其可对角化。
- Cayley-Hamilton 定理: 特征多项式 $p(x) = \det(A - xI)$ 是使方阵 A 零化的多项式。
- 逆矩阵的计算 (P417)
- 矩阵幂的计算 (P419)
- 迷向圆变换 $y = \sum_x^{-1/2} U_x^H (x - m_x)$, 其中 x 为随机向量, 协方差矩阵 $C_x = U_x \Sigma_x U_x^H$ 。
 y 的所有分量都是零均值、具有单位方差的统计不相关随机变量。
- 离散 Karhunen-Loeve 变换 (P428~P430)
- 满足 $Au = \lambda Bu$ 的标量 λ 和非零向量 u 称为矩阵束 (A, B) 的广义特征值和广义特

征向量, $\lambda(\mathbf{A}, \mathbf{B}) = \{z: \det(\mathbf{A} - z\mathbf{B}) = 0\}$ 。

- 广义特征值性质 (P434)
- $(\mathbf{XAY}, \mathbf{XBY})$ 是 (\mathbf{A}, \mathbf{B}) 的等价矩阵束, \mathbf{X}, \mathbf{Y} 非奇异。
- 广义特征值分解的总体最小二乘方法 (P437)
- Hermitian 矩阵 \mathbf{A} Rayleigh 商: $R(\mathbf{x}) = \frac{\mathbf{x}^H \mathbf{A} \mathbf{x}}{\mathbf{x}^H \mathbf{x}}$, \mathbf{x} 可限定于单位球使得 $R(\mathbf{x})$ 取最值。
- Rayleigh 商的性质 (P443)
- 广义 Rayleigh 商 (P447~P448)
- 复矩阵 \mathbf{A} 酉相似于对角矩阵的充要条件是 \mathbf{A} 为正规矩阵
- 复矩阵 \mathbf{A} 相似于对角矩阵的充要条件是 \mathbf{A} 有 n 个线性无关的特征向量
- 存在可逆矩阵 \mathbf{P} , 使任意矩阵 \mathbf{A} 相似于块对角矩阵, $J_i(\lambda_i) = \begin{pmatrix} \lambda_i & 1 & & \\ & \ddots & \ddots & \\ & & \lambda_i & 1 \\ & & & \ddots & \ddots \\ & & & & \lambda_i \end{pmatrix}$

8 子空间

• 线性空间要求加法满足结合律、交换律、零元素、存在负元素, 乘法满足数因子分配律、分配律、结合律、单位元。

• 线性空间 \mathcal{V} 中线性无关向量组所含向量的最大个数称为 \mathcal{V} 的维数, 记作 $\dim \mathcal{V} = n$ 。

• 若向量集 $S = \{\mathbf{u}_1, \dots, \mathbf{u}_m\}$ 是向量空间的子集, 则 $\mathcal{W} = \text{Span}\{\mathbf{u}_1, \dots, \mathbf{u}_m\} = \{\mathbf{u}: \mathbf{u} = a_1 \mathbf{u}_1 + \dots + a_m \mathbf{u}_m\}$ 称为由 $\mathbf{u}_1, \dots, \mathbf{u}_m$ 张成的子空间。 $\mathbf{u}_1, \dots, \mathbf{u}_m$ 称为 \mathcal{W} 的生成元, S 称为 \mathcal{W} 的张成集。

• 张成集定理: (1) 若 S 中某向量是其他向量的线性组合, 删除后仍张成 \mathcal{W} ; (2) 若 \mathcal{W} 非平凡, 则在 S 中存在某线性无关向量的子集合, 它张成 \mathcal{W} 。

• \mathcal{W} 的子集合 $\{\mathbf{u}_1, \dots, \mathbf{u}_p\}$ 称为 \mathcal{W} 的一组基, 如果 $\mathcal{W} = \text{Span}\{\mathbf{u}_1, \dots, \mathbf{u}_p\}$, $\mathbf{u}_1, \dots, \mathbf{u}_p$ 线性无关。

• 基表示定理：令 $S = \{\mathbf{u}_1, \dots, \mathbf{u}_m\}$ 是 \mathcal{W} 的一组基，则 \mathcal{W} 中任意向量都可以表示为 $\mathbf{u}_1, \dots, \mathbf{u}_m$ 的线性组合。

• 若 U 和 V 是 \mathcal{W} 的两组不同的基，若基变换 $V = UC$ ，称 C 为 U 到 V 的过渡矩阵。

• 设 $\mathbf{x} \in \mathcal{W}$ 在 U 和 V 下坐标为 $\boldsymbol{\xi}, \boldsymbol{\eta}$ ，那么 $\boldsymbol{\xi} = C^{-1}\boldsymbol{\eta}$ 。

• 子空间 $S = S_1 \cap \dots \cap S_n$ 表示 S_1, \dots, S_n 共同向量的集合。若 $S = \{\mathbf{0}\}$ ，则称 S_1, \dots, S_n 无交连。

• $S = S_1 + \dots + S_n = \{\mathbf{x} | \mathbf{x} = \mathbf{x}_1 + \dots + \mathbf{x}_n, \mathbf{x}_i \in S_i\}$ 称为 S_1, \dots, S_n 的和（并）。无交连子空间的和称为子空间的直和，记作 $S = S_1 \oplus \dots \oplus S_n$ ，此时 S 中的向量具有唯一分解 $\mathbf{x} = \mathbf{x}_1 + \dots + \mathbf{x}_n, \mathbf{x}_i \in S_i$ 。

• 维数公式： $\dim(S_1 + S_2) = \dim S_1 + \dim S_2 - \dim(S_1 \cap S_2)$ 。

• 称子空间 S_1, \dots, S_n 为正交子空间，记作 $S_i \perp S_j$ ，若 $\forall \mathbf{x}_i \in S_i, \mathbf{x}_j \in S_j$ ，有 $\mathbf{x}_i \perp \mathbf{x}_j$ 。

• 与 S 正交的所有向量组成向量子空间 S^\perp ，称为正交补。 $\dim(S + S^\perp) = \dim \mathcal{V}, \mathcal{V} = S \oplus S^\perp$ ， \mathcal{V} 中任一向量都可以分解为 S 和 S^\perp 的向量和，称为正交分解。

• 若 $\forall \mathbf{x} \in S, \mathbf{Ax} \in S$ ，则称 S 相对于 \mathbf{A} 不变。由 \mathbf{A} 的特征向量张成的子空间是相对于 \mathbf{A} 不变的。零空间 $\text{Null}(\mathbf{A} - \lambda \mathbf{I})$ 是相对于 \mathbf{A} 不变的，称之为 \mathbf{A} 与特征值 λ 对应的特征空间。

• 子空间 \mathcal{H} 和 S 的夹角 $\theta(\mathcal{H}, S) = \min_{\mathbf{x} \in \mathcal{H}, \mathbf{y} \in S} \theta(\mathbf{x}, \mathbf{y})$ 。

• 令 \mathbf{P} 是到子空间 S 的正交投影算子，则对于任一复向量 \mathbf{x} ，有 $\min_{\mathbf{y} \in S} \|\mathbf{x} - \mathbf{y}\|_2 = \|\mathbf{x} - \mathbf{Px}\|_2$ ，或 $\theta(\mathbf{x}, S) = \theta(\mathbf{x}, \mathbf{Px})$ 。

• 正交强迫一致问题： $\min_Q \|\mathbf{A} - \mathbf{BQ}\|_F, s.t. \mathbf{Q}^T \mathbf{Q} = \mathbf{I}$ 。若有奇异值分解 $\mathbf{B}^T \mathbf{A} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T$ ，则解为 $\mathbf{Q} = \mathbf{UV}^T$ ，称为 $\mathbf{B}^T \mathbf{A}$ 的正交极因子。若 $\mathbf{B} = \mathbf{I}$ ，易知若 $\mathbf{A} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T$ ，则与 \mathbf{A} 最接近的正交矩阵为 \mathbf{UV}^T 。

• 矩阵 \mathbf{A} 的列空间记为 $Col(\mathbf{A}) = Span\{\mathbf{a}_1, \dots, \mathbf{a}_n\}$, 行空间 $Row(\mathbf{A}) = Col(\mathbf{A}^H) = Span\{\mathbf{r}_1^*, \dots, \mathbf{r}_n^*\}$ 。值域 $Range(\mathbf{A}) = \{\mathbf{Ax}\}$, 零空间 (核) $Null(\mathbf{A}) = Ker(\mathbf{A}) = \{\mathbf{x} | \mathbf{Ax} = \mathbf{0}\}$, 零空间的维数称为 \mathbf{A} 的零化维或零度 $nullity(\mathbf{A}) = dim[Null(\mathbf{A})]$ 。

• $Range(\mathbf{A}) = Col(\mathbf{A})$ 。

• $(Row(\mathbf{A}))^\perp = Null(\mathbf{A}), (Col(\mathbf{A}))^\perp = Null(\mathbf{A}^H)$ 。

• $dim(Col(\mathbf{A})) = dim(Row(\mathbf{A})) = rank(\mathbf{A})$, 且 $rank(\mathbf{A}) + dim(Null(\mathbf{A})) = n$ 。

• 初等行变换不改变 $Row(\mathbf{A})$ 和 $Null(\mathbf{A})$, 初等列变换不改变 $Col(\mathbf{A})$ 和 $Null(\mathbf{A}^H)$ 。

• 子空间基的构造: 初等变换法 (P496)、奇异值分解法 (P501)

• 两个零空间交的标准正交基: 平凡方法、奇异值分解法 (P502)

8 投影分析

• 投影定理: 令 H 是向量空间, 而 M 是 H 内 n 维子空间, 若对于 H 中的向量 \mathbf{x} , 在子空间 M 内有一个向量 $\hat{\mathbf{x}}$, 使得 $\mathbf{x} - \hat{\mathbf{x}}$ 与 M 中任一向量 \mathbf{y} 都满足正交条件, 则 $\|\mathbf{x} - \hat{\mathbf{x}}\| \leq \|\mathbf{x} - \mathbf{y}\|$ 对于所有 $\mathbf{y} \in M$, 当且仅当 $\mathbf{y} = \hat{\mathbf{x}}$ 时成立。

• 向量 \mathbf{x} 到子空间 M 的正交补 M^\perp 上的投影则称为正交投影, 记为 $\mathbf{P}_M^\perp \mathbf{x}$ 。 $\mathbf{P}_M \mathbf{P}_M^\perp = \mathbf{P}_M \mathbf{P}_M^\perp = \mathbf{0}$, 投影矩阵和正交投影矩阵均奇异。

• 投影的性质 (P529)

• 幂 n 矩阵及幂等矩阵性质 (P532)

• 考虑 $\mathbb{C}^n = S \oplus H$, 若 \mathbf{x} 有唯一分解 $\mathbf{x} = \mathbf{x}_1 + \mathbf{x}_2, \mathbf{x}_1 = \mathbf{P}\mathbf{x}$, 则称 \mathbf{P} 是沿着 H 方向到 S 的投影算子, 简记为 $\mathbf{P}_{S|H}$ 。

• 复向量 \mathbf{x} 可以唯一分解为 $\mathbf{x} = \mathbf{P}\mathbf{x} + (\mathbf{I} - \mathbf{P})\mathbf{x}$, 若 $\mathbf{P} \perp (\mathbf{I} - \mathbf{P})$, 则称分解为正交分解, \mathbf{P} 为正交投影算子。若不满足 $\mathbf{P} \perp (\mathbf{I} - \mathbf{P})$, 则称 \mathbf{P} 为斜投影算子。

• 线性齐次算子 \mathbf{P} 是投影算子, 当且仅当 \mathbf{P} 是幂等矩阵。

- 齐次线性算子 \mathbf{P} 是正交投影算子，当且仅当 \mathbf{P} 是 Hermitian 幂等矩阵。
- 到矩阵 \mathbf{A} 的列空间的投影矩阵 $\mathbf{P}_A = \mathbf{A}(\mathbf{A}^H\mathbf{A})^+ \mathbf{A}^H$ 。