

附录 A 线性代数

A.1 向量与矩阵

对于两个集合 A, B , 我们记 $A \times B = \{(a, b), \forall a \in A, b \in B\}$, 即 \times 运算定义了一个二元组 (pair) 的集合, 我们称 \times 为笛卡尔乘积 (**Cartesian product**)。比如, 如果我们选取 $A = \{\heartsuit, \spadesuit, \clubsuit, \diamond\}, B = \{2, \dots, 10, J, Q, K, A\}$, 那么我们就得到了一副扑克牌共 52 张牌的集合。而如果选取 $A = \mathbb{R}, B = \mathbb{R}$, 那么 $\mathbb{R}^2 = \mathbb{R} \times \mathbb{R}$ 为二维平面。

更一般的, 我们可以记

$$\begin{aligned}\Omega_1 \times \Omega_2 \times \cdots \times \Omega_d &= \times_{i=1}^n \Omega_i \\ &= \{(\omega_1, \omega_2, \dots, \omega_n), \omega_i \in \Omega_i, i = 1, \dots, n\}\end{aligned}$$

既得到了一个 n 元组 (n -tuple) 的集合。特别的, $\mathbb{R}^n = \mathbb{R} \times \mathbb{R} \times \cdots \times \mathbb{R}$ 为 n 维的欧几里得空间 (**Euclidean space**), 其中 $\omega = (\omega_1, \dots, \omega_n) \in \mathbb{R}^n$ 为向量 (**vectors**)。向量可以按照行或者列排列, 分别称为行向量 (row vector) 或者列向量 (column vector)。不失一般性, 我们下面提到的向量都默认为列向量。行向量和列向量之间可以通过转置 (transpose) 得到, 即对于一个列向量 ω , 其转置记为 ω' , 为行向量。特别的, 我们记 0 为所有元素都等于 0 的向量, 即零向量, 而记 $\iota = [1, 1, \dots, 1]'$ 为所有元素都为 1 的列向量:

$$0 = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \iota = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

令 $\alpha \in \mathbb{R}$ 为标量, $\omega, \eta \in \mathbb{R}^n$ 为 n 维向量, 我们定义向量加法运算的数乘运算:

$$\omega + \eta = \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_n \end{bmatrix} + \begin{bmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_n \end{bmatrix} = \begin{bmatrix} \omega_1 + \eta_1 \\ \omega_2 + \eta_2 \\ \vdots \\ \omega_n + \eta_n \end{bmatrix}, \alpha\omega = \begin{bmatrix} \alpha\omega_1 \\ \alpha\omega_2 \\ \vdots \\ \alpha\omega_n \end{bmatrix}$$

即对向量的每个元素相加, 或者都乘以这个标量。

如果 $x \in \mathbb{R}^n, y \in \mathbb{R}^n$ 我们可以定义内积 (**inner product**) 或者点乘积 (**dot product**) 为

$$\langle x, y \rangle = x \cdot y = \sum_{i=1}^n x_i y_i$$

如果 $\langle x, y \rangle = 0$, 我们称两个向量正交 (**orthogonal**)。在几何上, 正交意味着两个向量是垂直的。

有了内积之后, 可以使用内积定义长度的概念, 即所谓的 (欧几里得或者 L^2) 范数 (**norm**):

$$\|x\|_2 = \sqrt{\langle x, x \rangle} = \sqrt{x'x} = \sqrt{\sum_{i=1}^n x_i^2}$$

以及两个向量间的距离:

$$d(x, y) = \|x - y\|_2 = \sqrt{\langle x - y, x - y \rangle} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

以上范数是通过内积定义出来的, 实际上我们还可以定义其他范数, 比如 L^1 范数:

$$\|x\|_1 = \sum_{i=1}^n |x_i|$$

以及更广义的 L^p ($p \geq 1$) 范数:

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

使用这些范数都可以相应定义距离为 $\|x - y\|_p$ 。

如果我们把 k 个 n 维向量按列摆放在一起, 我们得到了一个 $n \times k$ 维的矩阵 (**matrix**) $A_{n \times k} = [a_1, \dots, a_k]$, 其中 a_i 为 n 维列向量。我们也可以把列向量看成是一个 $n \times 1$ 维的矩阵。特别的, 如果 $k = n$, 即一个行数与列数相等的矩阵, 我们称之为方阵 (**square matrix**)。

对于矩阵, 我们同样可以类似定义加法和数乘运算

$$A + B = \begin{bmatrix} a_1 & \cdots & a_k \end{bmatrix} + \begin{bmatrix} b_1 & \cdots & b_k \end{bmatrix} = \begin{bmatrix} a_1 + b_1 & \cdots & a_k + b_k \end{bmatrix}$$

$$\alpha A = \begin{bmatrix} \alpha a_1 & \cdots & \alpha a_k \end{bmatrix}$$

其中 a_i, b_i 为 $n \times 1$ 维的列向量。自然的, 我们也可以定义矩阵的转置为

$$A' = \begin{bmatrix} a'_1 \\ \vdots \\ a'_k \end{bmatrix}$$

如果 A 为 $n \times k$ 的矩阵, 那么其转置 A' 为 $k \times n$ 的矩阵。矩阵的数乘、加法、转置等满足一些良好的性质, 比如:

- $(A + B) + C = A + (B + C)$
- $(\alpha + \beta)A = \alpha A + \beta A$
- $\alpha(A + B) = \alpha A + \alpha B$
- $\alpha(\beta A) = (\alpha\beta)A$

- $(A')' = A$
- $(A + B)' = A' + B'$

矩阵与向量之间的乘法运算可以定义为矩阵列向量的线性组合 (**linear combination**), 即对于矩阵 $A_{n \times k} = [a_1, \dots, a_k]$ 以及 k 维向量 $x = [x_1, \dots, x_k]'$, 可以定义矩阵与向量的乘法为

$$Ax = x_1 a_1 + \dots + x_k a_k = \sum_{j=1}^k x_j a_j$$

即 a_j 的一个线性组合。注意以上乘法的定义要求矩阵 A 的列数必须与向量 x 的维数一致。

如果存在一个非零向量 x , 使得 $Ax = 0$, 那么我们称向量 a_1, \dots, a_k 是线性相依的 (**linearly dependent**)。线性相依意味着其中的某个向量一定可以被其他向量线性表示出。比如, 不妨假设 $Ax^* = 0$, 且 $x_1^* \neq 0$, 那么必然有

$$a_1 = -\frac{x_2^*}{x_1^*} a_2 - \dots - \frac{x_k^*}{x_1^*} a_k$$

即 a_1 可以通过其他几个向量线性表示出。而如果只有当 $x = 0$ 时, 才有 $Ax = 0$, 那么我们称向量 a_1, \dots, a_k 是线性无关或者线性独立的 (**linearly independent**)。比如矩阵

$$I = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

其任何一个列向量都不可以被其他两个列向量线性表示出。

使用矩阵与向量的乘法我们可以定义两个矩阵之间的乘法, 对于矩阵 $A_{n \times k} = [a_1, \dots, a_k]$ 以及 $B_{k \times m} = [b_1, \dots, b_m]$, 其乘法定义为

$$AB = A[b_1, \dots, b_m] = [Ab_1, \dots, Ab_m]_{n \times m}$$

即一个 $n \times k$ 的矩阵与一个 $k \times m$ 的矩阵相乘, 得到了一个 $n \times m$ 的矩阵。对于矩阵相乘而言, 即使乘积都存在, 交换律也并不成立, 即 $AB \neq BA$, 而其转置满足: $(AB)' = B'A'$ 。

对于一个矩阵 $A_{n \times k} = [a_1, \dots, a_k]$, 其列向量的所有子集即可以是线性相关的, 也可以是线性无关的。在矩阵列向量的所有子集中线性无关向量组所包含向量个数的最大值, 我们称之为秩 (**rank**)。比如对于矩阵

$$A = \begin{bmatrix} 1 & 1 & 2 & 0 \\ 0 & 2 & 3 & 5 \end{bmatrix}$$

其所有四个向量是线性相依的, 任意三个列向量也都是线性相依的, 而前两个列向量是线性无关的, 因而其矩阵的秩为 2, 我们记为 $\text{rank}(A) = 2$ 。矩阵的秩有如下的性质:

1. $\text{rank}(A_{n \times k}) \leq \min(n, k)$
2. $\text{rank}(A) = \text{rank}(A') = \text{rank}(A'A) = \text{rank}(AA')$
3. 若 A 为 $n \times k$ 的矩阵, 而 B 为 $k \times k$ 的矩阵, 且 $\text{rank}(B) = k$, 那么 $\text{rank}(AB) = \text{rank}(A)$

$$4. \operatorname{rank}(A+B) \leq \operatorname{rank}(A) + \operatorname{rank}(B)$$

对于方阵，如果其秩等于行（列）数，那么我们称其为满秩（**full rank**）矩阵。如果方阵 A 满足 $A = A'$ ，那么我们称其为对称矩阵（**symmetric matrix**）。如果一个方阵其非对角线元素都为 0，那么我们称其为对角矩阵。我们接下来会使用 $\operatorname{diag}()$ 符号将向量转化为对角阵，比如

$$\operatorname{diag}([1, 2, 3]) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 3 \end{bmatrix}$$

特别的，我们令 $I = \operatorname{diag}(1)$ 为对角线元素都为 1 的对角阵，称为单位阵（**identity matrix**）。

此外，如果一个方阵 A 满足 $AA' = A'A = I$ ，那么我们称 A 为正交矩阵（**orthogonal matrix**）。实际上，如果将矩阵 A 看成是列向量的组合， $A = [a_1, \dots, a_n]$ ，那么

$$A'A = \begin{bmatrix} a'_1 \\ \vdots \\ a'_n \end{bmatrix} [a_1, \dots, a_n] = \begin{bmatrix} a'_1 a_1 & \cdots & a'_1 a_n \\ \vdots & \ddots & \vdots \\ a'_n a_1 & \cdots & a'_n a_n \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

意味着 A 的列向量其范数都等于 1，且两两正交。显然，单位阵满足上述条件，为正交矩阵。

对于方阵 $A_{n \times n}$ ，我们可以定义其行列式（**determinant**）：

$$|A| = \sum (-1)^{\phi(j_1, \dots, j_n)} \prod_{i=1}^n a_{ij_i}$$

其中 (j_1, \dots, j_n) 为 $(1, \dots, n)$ 的排列（permutations），而 $\phi(j_1, \dots, j_n)$ 为 $(1, \dots, n)$ 变换到 (j_1, \dots, j_n) 所需要交换的次数。实际上，矩阵的行列式与面积、体积紧密相关，比如，对于一个 2×2 的矩阵：

$$A = \begin{bmatrix} 1 & 3 \\ 2 & 1 \end{bmatrix}$$

其行列式的绝对值等于以 $(0, 0), (1, 2), (3, 1)$ 为顶点的矩形的面积（或者三角形面积的两倍）。如果方阵为不满秩，即矩阵的某一列可以被其他列向量表示出，那么其「体积」等于 0，因而其行列式等于 0。对于此类矩阵，我们称之为奇异阵（**singular matrix**）。行列式有以下性质：

- $|AB| = |A||B|$
- $|A'| = |A|$
- $|\alpha A| = \alpha^n |A|$

此外，对于方阵，我们还可以定义迹（**trace**），即对角线元素的和：

$$\operatorname{tr}(A) = \sum_{i=1}^n a_{ii}$$

矩阵的迹有如下结论：

- $\operatorname{tr}(A+B) = \operatorname{tr}(A) + \operatorname{tr}(B)$

- $\text{tr}(\lambda A) = \lambda \text{tr}(A)$
- $\text{tr}(A') = \text{tr}(A)$
- $\text{tr}(AB) = \text{tr}(BA)$

此外, 显然对于一个标量 (1×1), 其迹的值就等于他本身。我们可以使用迹的概念定义一个矩阵的 L^2 范数

$$\|A\|_2 = \sqrt{\text{tr}(A'A)} = \sqrt{\sum_{i=1}^n \sum_{j=1}^n a_{ij}^2}$$

如果 $\|A - B\|_2 = 0$ 那么 $A = B$ 。

最后, 对于方阵, 如果其行列式不等于 0, 即非奇异矩阵, 那么可以定义其逆矩阵 (**inverse matrix**)。对于一个 $n \times n$ 的非奇异矩阵, 如果矩阵 B 满足:

$$AB = BA = I$$

那么我们称矩阵 B 为矩阵 A 的逆矩阵, 记为 $B = A^{-1}$ 。对于逆矩阵, 有

- $(A^{-1})' = (A')^{-1}$
- $(AB)^{-1} = B^{-1}A^{-1}$
- $|A^{-1}| = |A|^{-1}$
- 若 A 为 $n \times n$ 的非奇异矩阵, 且

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}$$

其中 A_{11} 为 $r \times r$ 的非奇异矩阵, A_{22} 为 $k \times k$ 的方阵, A_{12} 为 $r \times k$ 的矩阵, 令 $D = A_{22} - A_{21}A_{11}^{-1}A_{12}$, 且 D 也是非奇异矩阵, 那么:

$$A^{-1} = \begin{bmatrix} A_{11}^{-1} + A_{11}^{-1}A_{12}D^{-1}A_{21}A_{11}^{-1} & -A_{11}^{-1}A_{12}D^{-1} \\ -D^{-1}A_{21}A_{11}^{-1} & D^{-1} \end{bmatrix}$$

或者令 $E = A_{11} - A_{12}A_{22}^{-1}A_{21}$, 且 E 也是非奇异矩阵, 那么:

$$A^{-1} = \begin{bmatrix} E^{-1} & -E^{-1}A_{12}A_{22}^{-1} \\ -A_{22}^{-1}A_{21}E^{-1} & A_{22}^{-1} + A_{22}^{-1}A_{21}E^{-1}A_{12}A_{22}^{-1} \end{bmatrix}$$

对于任意两个矩阵 $A_{m \times n}$ 和 $B_{p \times q}$, 我们还可以定义其 **Kronecker** 乘积:

$$A \otimes B = \begin{bmatrix} a_{11}B & a_{12}B & \cdots & a_{1n}B \\ a_{21}B & a_{22}B & \cdots & a_{2n}B \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1}B & a_{m2}B & \cdots & a_{mn}B \end{bmatrix}$$

即得到了一个 $mp \times nq$ 的矩阵。此外，我们还可以定义 $\text{vec}(\cdot)$ 操作符。对于一个 $n \times k$ 矩阵 $A = [a_1, \dots, a_k]$ ，那么

$$\text{vec}(A) = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_k \end{bmatrix}$$

即得到了一个 $nk \times 1$ 的向量。Kronecker 乘积和 $\text{vec}(\cdot)$ 操作符有如下性质：

- $A \otimes B \otimes C = (A \otimes B) \otimes C = A \otimes (B \otimes C)$
- $(A + B) \otimes (C + D) = A \otimes C + A \otimes D + B \otimes C + B \otimes D$
- $(A \otimes B) \otimes (C \otimes D) = AC \otimes BD$ 如果 AC 、 BD 存在
- $\alpha \otimes A = \alpha A = A \otimes \alpha$
- 对于两个向量 a, b ， $a' \otimes b = ba' = b \otimes a'$
- $(A \otimes B)' = A' \otimes B'$
- $\text{tr}(A \otimes B) = \text{tr}(A) \text{tr}(B)$
- $(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}$
- $\text{rank}(A \otimes B) = \text{rank}(A) \text{rank}(B)$
- 对于向量 a ， $\text{vec}(a') = \text{vec}(a) = a$
- 对于两个向量 a, b ， $\text{vec}(ab') = b \otimes a$
- $\text{vec}(A)' \text{vec}(B) = \text{tr}(A'B)$
- $\text{vec}(ABC) = (C' \otimes A) \text{vec}(B)$
- $\text{tr}(ABCD) = (\text{vec}(D'))' (C' \otimes A) \text{vec}(B) = (\text{vec}(D'))' (A \otimes C') \text{vec}(B')$

A.2 线性空间与线性变换

以上我们介绍了实数域 \mathbb{R} 中的向量和矩阵，我们可以进一步将其拓展（如拓展到复数域 \mathbb{C} ），并引入线性空间的概念。

定义 A.1. 对于一个数域 \mathbb{F} （其中的元素称为标量），以及一个带有加法和标量乘法的集合 V （如 \mathbb{F}^n ），如果对于 $a, b \in \mathbb{F}$ 以及 $x, y, z \in V$ ，满足：

1. 交换律： $x + y = y + x$
2. 结合律： $(x + y) + z = x + (y + z)$ ， $(ab)x = a(bx)$
3. 加法单位元：存在 $0 \in V$ 使得对于所有 $x \in V$ ，有 $0 + x = x$
4. 加法逆元：对于每个 $x \in V$ ，存在 $y \in V$ 使得 $x + y = 0$

5. 数乘单位元: $1x = x$

6. 分配律: $a(x + y) = ax + ay$, $(a + b)x = ax + bx$

我们称 V 为 \mathbb{F} 上的向量空间 (**vector space**) (或者线性空间, **linear space**), 向量空间中的元素称为向量或者点 (point)。

比如, 可以验证, 对于实数域 \mathbb{R} , \mathbb{R}^n 为 \mathbb{R} 上的线性空间, 而对于实数域 \mathbb{C} , \mathbb{C}^n 为 \mathbb{C} 上的线性空间。

如果一个集合 U 为 \mathbb{F} 上的线性空间 V 的子集, 且本身也是 \mathbb{F} 上的线性空间, 那么我们称 U 是 V 的子空间 (**subspace**), 或者线性子空间。比如, \mathbb{R}^3 为 \mathbb{R} 上的线性空间, 令 x, y 为 \mathbb{R}^3 中任意两个向量, 定义:

$$U = \{ax + by | a, b \in \mathbb{R}\}$$

可以验证 U 是一个线性空间, 且 $U \subset \mathbb{R}^3$, 故 U 是 \mathbb{R}^3 的子空间。比如如果取 $x = (1, 0, 0)$, $y = (0, 1, 0)$, 那么 U 就是 $x - y$ 平面; 如果取 $x = (1, 0, 0)$, $y = (1, 1, 0)$, 则 U 就是一个经过 x 轴且与 y, z 轴成 45° 角的平面; 如果取 $x = (1, 1, 0)$, $y = (-1, -1, 0)$, 则 U 是一条经过原点在 $x - y$ 平面上的一条直线。

有了线性空间后, 我们可以定义线性空间中的线性函数, 或者线性映射 (**linear mapping**)。

定义 **A.2.** 对于 \mathbb{F} 上的线性空间 V, W , 如果映射 $T: V \rightarrow W$ 满足:

1. 加性: 对于 $x, y \in V$, $T(x + y) = T(x) + T(y)$

2. 对于 $a \in \mathbb{F}, x \in V$, $T(ax) = aT(x)$

那么称 T 为 V 到 W 的线性映射。

线性映射与矩阵乘法关系密切, 我们可以将矩阵乘法使用线性映射的概念加以理解。如果我们将 $k \times n$ 维矩阵 A 左乘一个 n 维向量 x , 那么 $y = Ax$ 为一个 k 维向量, 由此我们可以定义一个映射 $A: \mathbb{R}^n \rightarrow \mathbb{R}^k$, $y = A(x) = Ax$, 易知:

1. $A(x_1 + x_2) = Ax_1 + Ax_2$,

2. $A(ax) = aAx$

从而矩阵与向量之间的乘积是一种线性映射。特别的, 当 $k = n$, 即 A 为 $n \times n$ 维方阵时, 线性映射 A 将 \mathbb{R}^n 上的一个向量 x 映射到 \mathbb{R}^n 上的另外一个向量 y , 此时我们称 A 为线性变换 (**linear transformation**)。

例 **A.1.** 变换:

$$A = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix}$$

将一个二维空间 \mathbb{R}^2 上的向量逆时针旋转 θ 度。取 $\theta = \frac{\pi}{2}$, 那么:

$$A = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$$

取 $x = [1, 0]'$, 那么 $y = Ax = [0, 1]'$, 逆时针旋转了 90 度。

使用分块矩阵, 如果令 $x = [x_1, x_2, \dots, x_n]' \in \mathbb{R}^n$, $A_{k \times n} = [a_1, \dots, a_n]$, 其中 a_i 为 k 维列向量, 那么:

$$y = Ax = [a_1, \dots, a_n] \cdot \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} = \sum_{i=1}^n x_i a_i$$

也就是说线性映射的结果 y 实际上是矩阵 A 的列向量 a_i 的一个线性组合。因而矩阵 A 的列向量的极大线性无关组, 也就是所有 $\{y = Ax | x \in \mathbb{R}^n\}$ 的极大线性无关组, 从而秩 $\text{rank}(A)$ 也就是 $\{y = Ax, \forall x \in \mathbb{R}^n\}$ 这个线性空间的维数。

A.3 线性型与二次型

对于任何一个向量 $x \in \mathbb{R}^n$, 线性型 (**linear form**) 即一个关于 x 的线性函数 $f(x) : \mathbb{R}^n \rightarrow \mathbb{R}$:

$$f(x) = a_1 x_1 + \dots + a_n x_n = a'x$$

其中:

$$a = \begin{bmatrix} a_1 \\ \vdots \\ a_n \end{bmatrix}$$

而二次型 (**quadratic form**) 则是一个关于 x 的二次函数 $g(x) : \mathbb{R}^n \rightarrow \mathbb{R}$:

$$\begin{aligned} g(x) &= a_{11}x_1^2 + a_{12}x_1x_2 + \dots + a_{1n}x_1x_n + a_{21}x_2x_1 + \dots + a_{nn}x_n^2 \\ &= \sum_{i=1}^n \sum_{j=1}^n a_{ij}x_i x_j \\ &= x'Ax \end{aligned}$$

其中:

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}$$

不失一般性, 我们一般将以上二次型写成一个对称矩阵的形式, 即假定 A 为一个实对称矩阵。

对于一个方阵 $A_{n \times n}$, 如果一个向量 $v \in \mathbb{R}^n$ 满足

$$Av = \lambda v$$

那么我们称 v 为 A 的一个特征向量 (**eigenvector**), 而 λ 则称为一个特征值 (**eigenvalue**)。如果我们将矩阵 A 看做是一个线性变换, 那么特征向量即经过 A 的变换以后, 保持方向不变的向量。实际上, 如果 v 是 A 的一个特征向量, 那么将其乘以一个常数 c , cv 也满足: $Acv = cAv = c\lambda v = \lambda cv$, 因而 cv 也是矩阵 A 的一个特征向量。

如果矩阵 $A_{n \times n}$ 有 n 个线性独立的特征向量: $\{v^1, \dots, v^n\}$, 其对应的特征值为: $\{\lambda_1, \dots, \lambda_n\}$,

记矩阵:

$$\Gamma = \begin{bmatrix} v^1 & \cdots & v^n \end{bmatrix}^{-1}$$

那么矩阵 A 可以被分解为

$$A = \Gamma^{-1} \text{diag}([\lambda_1, \dots, \lambda_n]) \Gamma \triangleq \Gamma^{-1} \Lambda \Gamma$$

以上分解我们称之为特征分解 (**eigendecomposition**)。根据行列式的性质, 我们有:

$$|A| = |\Gamma^{-1} \Lambda \Gamma| = |\Gamma^{-1}| |\Lambda| |\Gamma| = |\Lambda| = \prod_{i=1}^n \lambda_i$$

而根据迹的性质, 有

$$\text{tr}(A) = \text{tr}(\Gamma^{-1} \Lambda \Gamma) = \text{tr}(\Lambda \Gamma \Gamma^{-1}) = \text{tr}(\Lambda) = \sum_{i=1}^n \lambda_i$$

如果矩阵 A 可以被特征分解为 $A = \Gamma^{-1} \Lambda \Gamma$, 那么我们可以矩阵的 p 次方为

$$A^p = \Gamma^{-1} \Lambda^p \Gamma = \Gamma^{-1} \text{diag}([\lambda_1^p, \dots, \lambda_n^p]) \Gamma$$

比如, 逆矩阵 $A^{-1} = \Gamma^{-1} \Lambda^{-1} \Gamma$, 从而 $AA^{-1} = \Gamma^{-1} \Lambda \Gamma \Gamma^{-1} \Lambda^{-1} \Gamma = I$ 。使用这一定义可以方便地定义分数次方, 比如定义

$$A^{\frac{1}{2}} = \Gamma^{-1} \text{diag} \left(\left[\lambda_1^{\frac{1}{2}}, \dots, \lambda_n^{\frac{1}{2}} \right] \right) \Gamma$$

$$A^{-\frac{1}{2}} = \Gamma^{-1} \text{diag} \left(\left[\lambda_1^{-\frac{1}{2}}, \dots, \lambda_n^{-\frac{1}{2}} \right] \right) \Gamma$$

可以验证 (习题A.3)

$$A^{\frac{1}{2}} A^{-\frac{1}{2}} = A^{-\frac{1}{2}} A^{\frac{1}{2}} = I$$

$$A^{-\frac{1}{2}} A A^{-\frac{1}{2}} = A^{\frac{1}{2}} A^{-1} A^{\frac{1}{2}} = I$$

等等, 与实数的幂次方运算法则类似。

注意并非任何一个方阵 A 都可以进行特征分解, 不过有一类特殊的矩阵, 即实对称矩阵, 必然可以被特征分解, 且矩阵 Γ 可以变换为一个正交矩阵。由于正交矩阵的逆矩阵等于其对称矩阵, 因而实对称矩阵 A 总是可以被分解为如下形式:

$$A = \Gamma' \Lambda \Gamma$$

其中 Γ 为正交矩阵。

由于正交矩阵 $\Gamma' \Gamma = I$, 因而矩阵 Γ 的列向量 (特征向量, **eigenvector**) 是两两正交的, 且每个列向量的范数为 1。比如矩阵:

$$\Gamma = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix}$$

为正交矩阵, 其每个列向量都是正交的且范数为 1。这类矩阵对应着等距变换 (isometry), 即两个点经过正交矩阵 Γ 的变换之后, $d(\Gamma x, \Gamma y) = \sqrt{x' \Gamma' \Gamma y} = \sqrt{x' y} = d(x, y)$ 。正交矩阵对应着旋转、翻转等变换; 而相应的, 对角矩阵 Λ 则对应着在不同的方向上的拉伸变换。因而实对称矩阵的特征值分解将一个线性变换 A 分解为了一个等距变换 Γ 和一个放缩变换 Λ 。

如果对于任何一个向量 $x \in \mathbb{R}^n$, 二次型 $x' A x > 0$, 我们称矩阵 A 为正定矩阵 (**Positive-definite matrix**); 如果满足 $x' A x \geq 0$, 则成为半正定矩阵 (**Positive semi-definite matrix**); 负定矩阵和半负定矩阵可以类似定义。

对于一个实对称矩阵 A , 其二次型:

$$x' A x = x' \Gamma' \Lambda \Gamma x = (\Gamma x)' \Lambda (\Gamma x)$$

注意由于 $y = \Gamma x$ 为一个 n 维向量, 因而上式可以写为:

$$x' A x = y' \Lambda y = \sum_{i=1}^n \lambda_i y_i^2 > 0 (\geq 0)$$

因而如果实对称矩阵 A 的所有特征值都 > 0 (≥ 0), 那么这个矩阵为正定矩阵 (半正定矩阵)。

对于 $n \times n$ 的实对称矩阵 A, B , 如果 $A - B$ 是一个正定矩阵, 我们可以简记为 $A \succ B$, 如果是半正定矩阵, 记为 $A \succeq B$, \prec, \preceq 符号类似定义。从而, 如果 $A \succ (\succeq) 0$ 也就意味着矩阵 A 为 (半) 正定矩阵。对于矩阵的比较符号, 我们有如下性质:

1. $A \succeq B$ 且 $B \succeq A \Leftrightarrow A = B$
2. D 为 $m \times n$ 的矩阵, $A \succeq B \Rightarrow D' A D \succeq D' B D$;
3. D 为 $m \times n$ 的矩阵, 如果 $\text{rank}(D) = m$, 那么 $A \succ B \Rightarrow D' A D \succ D' B D$;
4. $A \succ 0, B \succ 0$, 那么 $A \succeq B \Leftrightarrow B^{-1} \succeq A^{-1}$;
5. $A \succ 0, B \succeq 0$, 那么 $A \succeq B \Rightarrow A^{1/2} \succeq B^{1/2}$;
6. $A \succeq B \Rightarrow \lambda_i(A) \geq \lambda_i(B), i = 1, \dots, n$, 其中 $\lambda_i(A)$ 为矩阵 A 的第 i 小的特征值;
7. $A \succeq B \Rightarrow \text{tr}(A) \geq \text{tr}(B)$, 当且仅当 $A = B$ 时等号成立;
8. $A \succeq B \succeq 0 \Rightarrow \det(A) \geq \det(B) \geq 0$ 。

A.4 投影与幂等矩阵

在实对称矩阵中, 有一类矩阵是我们接下来非常频繁使用的, 即幂等矩阵 (**idempotent matrix**)。如果一个方阵 P 满足 $P^2 = P$, 那么我们称矩阵 P 为幂等矩阵。例如, 矩阵:

$$P = \frac{1}{4} \cdot \begin{bmatrix} -4 & 6 & 2 \\ -12 & 13 & 3 \\ 20 & -15 & -1 \end{bmatrix}$$

为幂等矩阵, 可以验证 $P^2 = P$ 。

特别的, 当 P 为实对称矩阵时, 我们称其为投影矩阵 (**projection matrix**)。由于所有实对称矩阵都可以被对角化, 所以对于任意的投影矩阵, 都可以写为:

$$P = \Gamma' \Lambda \Gamma$$

而由于 $P^2 = \Gamma' \underbrace{\Lambda \Gamma \Gamma' \Lambda}_{I} \Gamma = \Gamma' \Lambda^2 \Gamma = \Gamma' \Lambda \Gamma$, 且 Γ 为可逆矩阵, 所以 $\Lambda^2 = \Lambda$ 。由于 Λ 为对角阵, 所以 Λ 的对角元必为 0 或者 1。因而 $\text{rank}(P) = \text{rank}(\Lambda) = \text{tr}(\Lambda)$, 且 $P \succeq 0$ 。

投影矩阵顾名思义, 与投影 (**projection**) 的概念密不可分。如果把投影矩阵 P 视为线性变换, 幂等矩阵的定义意味着一个向量经过 P 的变换以后, 再次经过 P 的变换仍然保持不变, 即 $P(Px) = P^2x = Px$ 。比如矩阵:

$$P = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

即把一个 $x - y - z$ 三维坐标系中的一个向量 $x = [x_1, x_2, x_3]'$ 映射到 $x - y$ 二维平面上的点 Px , 而一个本身就在 $x - y$ 二维平面的点, 如 Px , 再次经过 P 的映射, 还是在 $x - y$ 二维平面上, 且就是其本身。可以验证, $P^2 = P$ 。类似的, 矩阵:

$$P = \begin{bmatrix} 0.5 & 0.5 & 0 \\ 0.5 & 0.5 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

则把一个三维向量 $x = [x_1, x_2, x_3]'$ 映射到 $y = x$ 这条直线上, 同样有 $P^2 = P$ 。

如果定义 $M = I - P$, 那么 $M^2 = (I - P)(I - P) = I - P - P + P^2 = I - P = M$, 即 $M = I - P$ 也为投影矩阵。注意 $(Mx)' Px = x'(I - P)Px = x'(P - P^2)x = 0$, 因而 Px 与 Mx 是正交的。也就是说, 幂等矩阵把一个向量 x 分解成了正交的两个部分: Px 和 Mx , $x = Px + Mx$ 且 $\langle Mx, Px \rangle = 0$ 。

例 A.2. 令 $\iota \in \mathbb{R}^n, \iota = [1, 1, \dots, 1]'$, 那么矩阵 $P_0 = \frac{1}{n} \iota \iota'$ 为投影矩阵, 即 $P_0' = P_0$, 且 $P_0^2 = \frac{1}{n^2} \underbrace{\iota \iota' \iota}_{n} \iota' = \frac{1}{n} \iota \iota' = P_0$ 。对于一个向量 x ,

$$P_0 x = \frac{1}{n} \iota \iota' x = \frac{1}{n} \iota \cdot \sum_{i=1}^n x_i = \iota \cdot \bar{x} = \begin{pmatrix} \bar{x} \\ \vdots \\ \bar{x} \end{pmatrix}$$

即 P_0 将一个向量投影变换为其均值向量。易知 $\text{rank}(P_0) = \text{tr}(P_0) = \text{tr}(\frac{1}{n} \iota \iota') = \frac{1}{n} \text{tr}(\iota \iota') = 1$ 。如果令 $M_0 = I - P_0$, 根据上述结论, 易知 M_0 也是幂等矩阵, 且 $\text{rank}(M_0) = \text{tr}(M_0) = \text{tr}(I - P_0) = \text{tr}(I) - \text{tr}(P_0) = n - 1$, 且:

$$M_0 x = x - \frac{1}{n} \iota \iota' x = \begin{pmatrix} x_1 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{pmatrix}$$

那么:

$$\sum_{i=1}^n (x_i - \bar{x})^2 = (M_0 x)' M_0 x = x' M_0 x$$

为一个二次型的形式。

此外, 根据幂等矩阵的性质, 我们可以证明如下结论:

定理 **A.1**. 对于一个 $n \times n$ 的实对称矩阵 W 以及一个 $n \times m$ 的矩阵 A , $m \leq n$, 有

$$W \succeq A (A' W^{-1} A)^{-1} A'$$

证明. 以上结论等价于 $W - A (A' W^{-1} A)^{-1} A' \succeq 0$, 不妨令 $W = \Gamma' \Lambda \Gamma$, 由于

$$\begin{aligned} W - A (A' W^{-1} A)^{-1} A' &= \Gamma' \Lambda \Gamma - A (A' \Gamma' \Lambda^{-1} \Gamma A)^{-1} A' \\ &= \Gamma' \Lambda \Gamma - \Gamma' \Gamma A (A' \Gamma' \Lambda^{-1} \Gamma A)^{-1} A' \Gamma' \\ &= \Gamma' \left(\Lambda - \Gamma A (A' \Gamma' \Lambda^{-1} \Gamma A)^{-1} A' \Gamma \right)' \Gamma \end{aligned}$$

从而以上结论等价于证明 $\Lambda - \Gamma A (A' \Gamma' \Lambda^{-1} \Gamma A)^{-1} A' \Gamma \succeq 0$. 继续将两边乘以 $\Lambda^{-1/2}$, 上式变为得到

$$I - \Lambda^{-1/2} \Gamma A (A' \Gamma' \Lambda^{-1} \Gamma A)^{-1} A' \Gamma \Lambda^{-1/2} \succeq 0$$

令 $D = \Lambda^{-1/2} \Gamma A$, 上式变为

$$I - D (D' D)^{-1} D' \succeq 0$$

注意到

$$D (D' D)^{-1} D' D (D' D)^{-1} D' = D (D' D)^{-1} D'$$

为幂等矩阵, 从而 $I - D (D' D)^{-1} D'$ 也是幂等矩阵, 从而 $I - D (D' D)^{-1} D' \succeq 0$ 必然成立, 原命题得证. \square

A.5 矩阵微积分

对于一个向量 $\theta = [\theta_1, \theta_2, \dots, \theta_n]'$, 其实值函数: $f(\theta) : \mathbb{R}^n \rightarrow \mathbb{R}$, 我们可以定义函数 $f(\cdot)$ 对向量 θ 的导数为:

$$\nabla_{\theta} f = \frac{\partial f(\theta)}{\partial \theta} = \begin{bmatrix} \frac{\partial f}{\partial \theta_1} \\ \frac{\partial f}{\partial \theta_2} \\ \vdots \\ \frac{\partial f}{\partial \theta_n} \end{bmatrix}$$

同时定义其二阶导:

$$\nabla_{\theta}^2 f = \frac{\partial^2 f(\theta)}{\partial \theta \partial \theta'} = \begin{bmatrix} \frac{\partial^2 f}{\partial \theta_1^2} & \frac{\partial^2 f}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 f}{\partial \theta_1 \partial \theta_n} \\ \frac{\partial^2 f}{\partial \theta_2 \partial \theta_1} & \frac{\partial^2 f}{\partial \theta_2^2} & \cdots & \frac{\partial^2 f}{\partial \theta_2 \partial \theta_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial \theta_n \partial \theta_1} & \frac{\partial^2 f}{\partial \theta_n \partial \theta_2} & \cdots & \frac{\partial^2 f}{\partial \theta_n^2} \end{bmatrix}$$

其中 $\nabla_{\theta} f$ 为梯度 (gradient) 的记法, 而 $\frac{\partial f(\theta)}{\partial \theta}$ 为导数的记法。在导数的记法中, 我们约定如果对 θ 列向量求导, 那么求出来应该是列向量; 而如果对 θ' 这一行向量求导, 那么求出来应该是行向量, 从而

$$\frac{\partial f(\theta)}{\partial \theta'} = \left[\frac{\partial f}{\partial \theta_1} \quad \frac{\partial f}{\partial \theta_2} \quad \dots \quad \frac{\partial f}{\partial \theta_n} \right]$$

从而二阶导 $\frac{\partial^2 f(\theta)}{\partial \theta \partial \theta'}$ 可以看做是对 $\frac{\partial f(\theta)}{\partial \theta}$ 的每一个分量再对 θ' 求导数的结果。我们知道对于一个实值函数, $\frac{\partial^2 f}{\partial \theta_i \partial \theta_j} = \frac{\partial^2 f}{\partial \theta_j \partial \theta_i}$, 因而 $\nabla_{\theta}^2 f$ 是一个实对称矩阵。我们称 $\nabla_{\theta}^2 f$ 为海塞矩阵 (Hessian matrix)。我们将混合使用这两种不同的记法。

例 A.3. 如果 $f(\theta) = \frac{\mu^2}{2\sigma^2} + \ln(\sigma)$, $\theta = (\mu, \sigma)'$ 那么:

$$\frac{\partial f(\theta)}{\partial \theta} = \left[\begin{array}{c} \frac{\mu}{\sigma^2} \\ \frac{1}{\sigma} - \frac{\mu^2}{\sigma^3} \end{array} \right]$$

$$\frac{\partial^2 f(\theta)}{\partial \theta \partial \theta'} = \left[\begin{array}{cc} \frac{1}{\sigma^2} & -\frac{2\mu}{\sigma^3} \\ -\frac{2\mu}{\sigma^3} & \frac{3\mu^2}{\sigma^4} - \frac{1}{\sigma^2} \end{array} \right]$$

回忆极值原理, 如果函数 f 可微, 那么函数 f 在 θ_0 处为极值点的必要条件是 $\nabla_{\theta} f = 0$, 如果 $\nabla_{\theta}^2 f$ 为正定矩阵 ($f(\theta)$ 的所有特征值为正), 那么 f 在 θ_0 处为极小值点, 否则如果 $\nabla_{\theta}^2 f$ 为负定矩阵 ($f(\theta)$ 的所有特征值为负), 那么 f 在 θ_0 处为极大值点, 如果 $\nabla_{\theta}^2 f$ 的特征值既有正值又有负值, 那么 f 在 θ_0 处为鞍点 (saddle point)。

例 A.4. 记向量 $x = (x_1, x_2)'$, 效用函数为 $f(x) = \ln x_1 + \ln x_2$ 。为了求解如下效用最大化问题:

$$\begin{aligned} & \max_x f(x) \\ & \text{s.t. } p'x = I \end{aligned}$$

其中 $p = (p_1, p_2)'$ 为价格, I 为收入, 可以构造拉格朗日函数:

$$\mathcal{L}(x, \lambda; p, I) = \ln x_1 + \ln x_2 + \lambda(I - p'x)$$

其一阶条件为:

$$\frac{\partial \mathcal{L}(x, \lambda; p, I)}{\partial x} = \begin{pmatrix} \frac{1}{x_1} \\ \frac{1}{x_2} \end{pmatrix} - \lambda \begin{pmatrix} p_1 \\ p_2 \end{pmatrix} = 0$$

解得:

$$x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} \frac{I}{2p_1} \\ \frac{I}{2p_2} \end{pmatrix}$$

在所有向量的实值函数中, 有两类函数是非常常用的, 即线性型以及二次型。对于线性型: $f(\theta) = \alpha'\theta$, 其一阶导数为:

$$\frac{\partial(\alpha'\theta)}{\partial \theta} = \alpha$$

而二次型 $g(\theta) = \theta' A \theta$ 的一阶导数为:

$$\frac{\partial(\theta' A \theta)}{\partial \theta} = A\theta + A'\theta = (A + A')\theta$$

而其二阶导为:

$$\frac{\partial^2 (\theta' A \theta)}{\partial \theta \partial \theta'} = A' + A$$

特别的, 如果 A 为对称矩阵, 那么

$$\begin{aligned} \frac{\partial (\theta' A \theta)}{\partial \theta} &= 2A\theta \\ \frac{\partial^2 (\theta' A \theta)}{\partial \theta \partial \theta'} &= 2A \end{aligned}$$

例 A.5. 如果存在 n 个有价证券, 其期望收益率向量为 $r = [r_1, \dots, r_n]'$, 而其收益率的协方差矩阵为 Σ 。现在给定一个权重向量 x , 满足 $x' \iota = 1$, 即所有权重相加等于 1, 那么根据权重向量配置 n 个有价证券, 我们就得到了一个资产组合, 该资产组合的期望收益率为 $x'r$, 而资产组合收益率的方差为 $x'\Sigma x$ 。在所有的资产组合中, 有一个资产组合其方差最小, 为了求出这个使得方差最小的资产组合权重, 我们可以解如下问题:

$$\begin{aligned} \min_x & x'\Sigma x \\ \text{s.t.} & x'\iota = 1 \end{aligned}$$

构建拉格朗日函数¹:

$$\mathcal{L}(x, \lambda; r, \Sigma) = x'\Sigma x + 2\lambda(1 - x'\iota)$$

其一阶条件为:

$$\frac{\partial \mathcal{L}(x, \lambda; p, I)}{\partial x} = 2\Sigma x - 2\lambda \iota = 0$$

解得:

$$x = \lambda \Sigma^{-1} \iota$$

将其带入约束中, 得到:

$$\lambda \iota' \Sigma^{-1} \iota = 1$$

从而:

$$\lambda = \frac{1}{\iota' \Sigma^{-1} \iota}$$

最终我们得到权重向量:

$$x = \frac{\Sigma^{-1} \iota}{\iota' \Sigma^{-1} \iota}$$

习题

练习 A.1. 证明:

1. $Ax = 0 \iff A'Ax = 0$
2. $AB = 0 \iff A'AB = 0$
3. $A'AB = A'AC \iff AB = AC$

练习 A.2. 证明: V 的子集 U 是 V 的子空间的充要条件是:

¹为了方便起见, 我们令拉格朗日乘子为 2λ 。

1. $0 \in U$
2. $x, y \in U$ 则 $x + y \in U$
3. 若 $a \in \mathbb{F}, x \in U$ 则 $ax \in U$

练习 **A.3.** 对于矩阵 A , 如果可以进行特征分解, 验证 $A^p A^q = A^{p+q}$ 。

练习 **A.4.** 在例A.5中, 如果投资者的效用函数为:

$$U(x; r, \Sigma) = x'r - \gamma x'\Sigma x$$

其中 $\gamma \geq 0$ 为一个标量, 度量了投资者的风险厌恶程度, 请求出使得效用最大化的投资组合权重 x 。

练习 **A.5.** 同样在例A.5中, 请计算给定投资组合期望收益 $x'r = r^*$ 的条件下, 方差最小的投资组合权重 x 。