

4讲、赋范线性空间与内积空间

一、赋范线性空间

二、特殊的线性空间 $R^{n \times n}$ (方阵空间)上的范数

三、内积空间：内积的定义与性质

四、内积的表示

一、赋范线性空间

定义2.1 设 V 是数域 P 上的线性空间，如果定义了从 V 到 R 的映射 N ，满足下列条件：

- (1) $N(\alpha) \geq 0$, $N(\alpha) = 0$ 当且仅当 $\alpha = 0$ (正定条件),
- (2) $N(k\alpha) = |k|N(\alpha)$, ($k \in P, \alpha \in V$) (非负齐次条件),
- (3) $N(\alpha + \beta) \leq N(\alpha) + N(\beta)$, ($\alpha, \beta \in V$) (三角不等式),

则称映射 $N(\alpha)$ 是 V 上的范数，定义了范数的线性空间称为赋范线性空间。

习惯上，记 $N(\alpha)$ 为 $\|\alpha\|$ 。

例 设 $x = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}^T \in C^n$, 规定 $\|x\| = \max_{1 \leq i \leq n} |x_i|$,

证明 $\|x\|$ 是 C^n 中的一个向量范数, 这个范数称为 x 的 ∞ - 范数, 作 $\|x\|_\infty$ 。

证明 (1) 显然 $\|x\| \geq 0$, 当 $x = 0 \Leftrightarrow \|x\| = 0$ 。

$$(2) \|kx\| = \max_{1 \leq i \leq n} |kx_i| = |k| \max_{1 \leq i \leq n} |x_i| = |k| \|x\| ,$$

$$(3) \|x + y\| = \max_{1 \leq i \leq n} |x_i + y_i| \leq \max_{1 \leq i \leq n} |x_i| + \max_{1 \leq i \leq n} |y_i| = \|x\| + \|y\|$$

因此 $\|x\|$ 是 C^n 中的一个向量范数。

同理可证：

- (1) $\|x\|_1 = \sum_{i=1}^n |x_i|$ 是 C^n 中的范数，这个范数称为 x 的 1 - 范数。
- (2) $\|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2}$ 是 C^n 中的范数，这个范数称为 x 的 2 - 范数。
- (3) $\|x\|_p = \sqrt[p]{\sum_{i=1}^n |x_i|^p}$ ($1 \leq p < \infty$) 是 C^n 中的范数，这个范数称为 x 的 p - 范数。

定义2.2 若 $||\alpha||$ 和 $||\alpha||_*$ 是线性空间 V 中的两个向量范数，若存在 $M > 0, m > 0$ ，使得对所有 $\alpha \in V$ ，都有 $m||\alpha|| \leq ||\alpha||_* \leq M||\alpha||$ ，则称范数 $||\alpha||$ 和 $||\alpha||_*$ 等价。

定理2.1 有限维线性空间中任意两个向量范数都等价。

定义2.3 若 $\{\alpha^{(k)}\}$ 是赋范线性空间 V 中的向量序列, 如果存在 $\alpha \in V$,
使得 $\lim_{k \rightarrow \infty} \|\alpha^{(k)} - \alpha\| = 0$, 则称序列 $\{\alpha^{(k)}\}$ 收敛于 α 。

定理2.2

(1) 在有限维线性空间中, 若向量序列 $\{\alpha^{(k)}\}$ 按某种范数收敛于 α ,
则 $\{\alpha^{(k)}\}$ 按任何范数都收敛于 α ;

(2) 设 $\alpha_1, \alpha_2, \dots, \alpha_n$ 是赋范线性空间 V 的基, $\alpha^{(k)}$ 在这组基下的坐标是
 $x^{(k)}$, α 在这组基下的坐标是 x , 则 $\{\alpha^{(k)}\}$ 按范数收敛于 α 与 $\{x^{(k)}\}$ 收敛于 x 等价。

证明: (1): 可证, (2)坐标收敛, 可推范数收敛. 反之亦然

二、特殊的线性空间 $R^{n \times n}$ (方阵空间)上的范数

定义2.4 如果从 $R^{n \times n}$ 到 R 的映射 N ， 并且 N 满足下列条件：

- (1) $N(A) \geq 0, N(A) = 0$ 当且仅当 $A = 0$ (正定条件),
- (2) $N(kA) = |k|N(A), (k \in R, A \in R^{n \times n})$ (非负齐次条件),
- (3) $N(A + B) \leq N(A) + N(B), (A, B \in R^{n \times n})$ (三角不等式),

则称映射 $N(A)$ 是 $R^{n \times n}$ 上的广义矩阵范数。

定义2.5 如果从 $R^{n \times n}$ 到 R 的映射 N , 并且 N 满足下列条件:

- (1) $N(A) \geq 0$, $N(A) = 0$ 当且仅当 $A = 0$ (正定条件),
- (2) $N(kA) = |k|N(A)$, ($k \in R, A \in R^{n \times n}$) (非负齐次条件),
- (3) $N(A + B) \leq N(A) + N(B)$, ($A, B \in R^{n \times n}$) (三角不等式),
- (4) $N(AB) \leq N(A)N(B)$, ($A, B \in R^{n \times n}$) (相容条件),

则称映射 $N(A)$ 是 $R^{n \times n}$ 上的矩阵范数。

习惯上, $R^{n \times n}$ 上的矩阵范数 $N(A)$ 记为 $\|A\|$ 。

定义2.6 对 $C^{n \times n}$ 中的矩阵范数 $\|A\|$, C^n 中的向量范数 $\|x\|_*$,

如果对任意 $A \in C^{n \times n}$, $x \in C^n$, 都有

$$\|Ax\|_* \leq \|A\| \cdot \|x\|_*$$

则称矩阵范数 $\|A\|$ 与向量范数 $\|x\|_*$ 相容。

例： 对 $A \in C^{n \times n}$, 定义 $\|A\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2}$ 。

证明：1) $\|A\|_F$ 是一个矩阵范数 (这个范数称为矩阵A的Frobenius 范数),

(2) $\|A\|_F$ 与 $\|x\|_2$ 相容。

证明：不要求，详细证明附后面。

例如： $A = \begin{pmatrix} -2 & 2 \\ 3 & -4 \end{pmatrix}$, 则 $\|A\|_F = \sqrt{4 + 4 + 9 + 16} = \sqrt{33}$.

由上面定义显然可得下面结论：

定理2.3 $\|A\|_F = \sqrt{A^H A \text{所有特征值之和}}$

证明：由矩阵特征值理论可知 $A^H A$ 所有特征值之和就是 $A^H A$ 对角元之和,

而 $A^H A$ 对角元之和刚好是 $\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2$ 。

例题的证明：矩阵 A 可以视为 C^{n^2} 中的向量，所以 $\|A\|_F$ 就是 C^{n^2} 中的向量的2—范数，因此 $\|A\|_F$ 满足正定条件、非负齐次条件和三角不等式。

$$\text{记 } A_i = (a_{i1}, a_{i2} \cdots a_{in}), x = (x_1, x_2 \cdots x_n)^T, \text{ 则 } Ax = \begin{pmatrix} A_1 \\ A_2 \\ \vdots \\ A_n \end{pmatrix} x = \begin{pmatrix} A_1 x \\ A_2 x \\ \vdots \\ A_n x \end{pmatrix},$$

由向量点乘 $a \cdot b = \|a\| \|b\| \cos \theta \Rightarrow |a \cdot b| \leq \|a\| \|b\|$ 可得

$$|A_i x|^2 = (a_{i1} x_1 + a_{i2} x_2 + \cdots + a_{in} x_n)^2 \leq (a_{i1}^2 + a_{i2}^2 + \cdots + a_{in}^2)(x_1^2 + x_2^2 + \cdots + x_n^2) = \|A_i\|_2^2 \|x\|_2^2,$$

$$\text{从而有 } \|Ax\|_2^2 = |A_1 x|^2 + \cdots + |A_n x|^2 \leq \|A_1\|_2^2 \|x\|_2^2 + \cdots + \|A_n\|_2^2 \|x\|_2^2$$

$$= (\|A_1\|_2^2 + \cdots + \|A_n\|_2^2) \|x\|_2^2 = \|A\|_F^2 \|x\|_2^2$$

对任意 $A, B \in C^{n \times n}$, $B = (b_1, b_2, \dots, b_n)$

$$\|AB\|_F^2 = \|A(b_1, b_2, \dots, b_n)\|_F^2$$

$$= \|(Ab_1, Ab_2, \dots, Ab_n)\|_F^2$$

$$= \|Ab_1\|_2^2 + \|Ab_2\|_2^2 + \dots + \|Ab_n\|_2^2$$

$$\leq \|A_F\|_2^2 \|b_1\|_2^2 + \|A_F\|_2^2 \|b_2\|_2^2 + \dots + \|A_F\|_2^2 \|b_n\|_2^2$$

$$= \|A\|_F^2 \|B\|_F^2$$

这就证明了: $\|A\|_F$ 是一个矩阵范数且 $\|A\|_F$ 与 $\|x\|_2$ 相容。

定理2.4 对 $C^{n \times n}$ 中的矩阵范数 $\|A\|$ ，则在 C^n 中一定存在与它相容的向量范数，即存在向量范数 $\|x\|_*$ ，使得 $\|Ax\|_* \leq \|A\| \cdot \|x\|_*$ 对任意 $A \in C^{n \times n}$ ， $x \in C^n$ 成立。

证明： $\forall x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ ，令 $\|x\|_* = \left\| \begin{pmatrix} x_1 & 0 & 0 \\ \dots & \dots & \dots \\ x_n & 0 & 0 \end{pmatrix} \right\|$ 。容易检验 $\|\cdot\|_*$ 是范数，且有

$$\|Ax\|_* = \left\| \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \dots & \dots & \dots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \right\|_* = \left\| \begin{pmatrix} a_{11}x_1 + \cdots + a_{1n}x_n \\ \dots \\ a_{n1}x_1 + \cdots + a_{nn}x_n \end{pmatrix} \right\|_* = \left\| \begin{pmatrix} a_{11}x_1 + \cdots + a_{1n}x_n, 0, \dots, 0 \\ \dots \\ a_{n1}x_1 + \cdots + a_{nn}x_n, 0, \dots, 0 \end{pmatrix} \right\|$$

$$= \left\| \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \dots & \dots & \dots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \begin{pmatrix} x_1 & 0 & 0 \\ \dots & \dots & \dots \\ x_n & 0 & 0 \end{pmatrix} \right\| \leq \left\| \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \dots & \dots & \dots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \right\| \left\| \begin{pmatrix} x_1 & 0 & 0 \\ \dots & \dots & \dots \\ x_n & 0 & 0 \end{pmatrix} \right\| = \|A\| \|x\|_*$$

下面考虑反向问题. 即对给定的向量范数, 能否找到矩阵范数, 使得该矩阵范数与已知的向量范数相容?

另一方面, 与向量范数类似, 同一矩阵它的各种范数有一定的差别, 如 $\|E\| > 1$, 将给理论分析与实际应用造成不便, 所以要找出一种矩阵范数 $\|A\|$, 使得 $\|E\| = 1$ 。

下面的定理给出了一种定义矩阵范数的方法, 使得该矩阵范数与已知的向量范数相容, 且单位矩阵的范数是1。

定理2.5 已知线性空间 C^n 上的范数 $\|x\|_*$ ，则

$\|A\| = \max_{x \neq 0} \frac{\|Ax\|_*}{\|x\|_*}$ 是矩阵范数.

证明：只需检验满足矩阵范数的4条要求.

如此定义的矩阵范数

称为向量范数的**诱导范数**

$$(1) \|A\| \geq 0, \|A\| = 0 \Leftrightarrow A = 0 \quad (2) \|kA\| = |k| \|A\|$$

$$(3) \|A + B\| \leq \|A\| + \|B\| \quad (4) \|AB\| \leq \|A\| \|B\|$$

注: 如上定义的矩阵范数显然与相应的向量范数相容.

事实上, 对任意非零 $x \in R^n$ 有 $\frac{\|Ax\|_*}{\|x\|_*} \leq \max_{x \neq 0} \frac{\|Ax\|_*}{\|x\|_*} = \|A\|$, $\Rightarrow \|Ax\|_* \leq \|A\| \|x\|_*$.

对应向量的1-范数, 2-范数, ∞ -范数, 就可以确定三个矩阵范

数 $\|A\|_1$, $\|A\|_2$ 和 $\|A\|_\infty$:

$$\|A\|_1 = \max_{x \neq 0} \frac{\|Ax\|_1}{\|x\|_1} \quad \|A\|_2 = \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} \quad \|A\|_\infty = \max_{x \neq 0} \frac{\|Ax\|_\infty}{\|x\|_\infty}$$

定理2.6 $A = (a_{ij}) \in R^{n \times n}$, 则

$$(1) \|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$$

(2) $\|A\|_2 = \sqrt{\lambda_1}$ (λ_1 是矩阵 $A^T A$ 的最大特征值。

$$(3) \|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|$$

分别称之为矩阵 A 的**行(和)范数**, **谱范数**与**列(和)范数**。

$$\|A\| = \max_{x \neq 0} \frac{\|Ax\|_*}{\|x\|_*}$$

例 计算矩阵 $A = \begin{pmatrix} 2 & -2 \\ 3 & 4 \end{pmatrix}$ 的1-范数、2-范数、无穷范数和Frobenius范数。

解: $\|A\|_1 = 6$; $\|A\|_\infty = 7$; $\|A\|_F = \sqrt{33}$;

计算 $A^T A = \begin{pmatrix} 13 & 8 \\ 8 & 20 \end{pmatrix}$, 求得其2个特征值 $\lambda_{1,2} = \frac{33 \pm \sqrt{305}}{2}$,

从而 $\|A\|_2 = \sqrt{\frac{33 + \sqrt{305}}{2}}$ 。

定理2.7 设 $A \in R^{n \times n}$, U, V 是 n 阶正交矩阵, 则

$$(1) \quad \|UAV\|_2 = \|UA\|_2 = \|AV\|_2 = \|A\|_2$$

$$(2) \quad \|UAV\|_F = \|UA\|_F = \|AV\|_F = \|A\|_F$$

定理2.8 设 $A \in R^{n \times n}$ 为对称矩阵, $\lambda_1, \lambda_2, \dots, \lambda_n$ 是它的 n 个特征值, 则

$$(1) \quad \|A\|_2 = \max \{|\lambda_1|, \dots, |\lambda_n|\},$$

$$(2) \quad \|A\|_F = \sqrt{\lambda_1^2 + \lambda_2^2 + \dots + \lambda_n^2}$$

$$\|A\|_F = \sqrt{(A^H A) \text{所有特征值之和}}$$

$$\|A\|_2 = \sqrt{(A^H A) \text{最大特征值}}$$

注: 定义 $\rho(A) = \max \{|\lambda_1|, \dots, |\lambda_n|\}$ 是矩阵 A 的谱半径, 其中 $\lambda_1, \dots, \lambda_n$ 是 A 的 n 个特征值

那么, 当 A 是实对称矩阵时, $\rho(A) = \|A\|_2$.

定理2.9 $A \in C^{n \times n}$, $\|A\|$ 是任意 矩阵范数, 则 $\rho(A) \leq \|A\|$

证明: 设 λ 是 A 的任一特征值, x 是相应的特征向量, 则有 $Ax = \lambda x$.

选取一个与矩阵范数 $\|A\|$ 相容的向量范数 $\|x\|$, 则有

$$|\lambda| \|x\| = \|\lambda x\| = \|Ax\| \leq \|A\| \|x\|$$

因此 A 的谱半径 $\rho(A) \leq \|A\|$ 。

事实上, $\rho(A) = \inf_{\| \cdot \|_\alpha \text{ 是矩阵范数}} \|A\|_\alpha$

定理2. 2. 9 A 的谱半径 $\rho(A)$ 是 A 的所有矩阵范数的下确界, 即对任意 $\varepsilon > 0$, 则一定存在某一矩阵范数 $\|A\|$, 使得

$$\|A\| \leq \rho(A) + \varepsilon$$

线性空间是解析几何中空间概念的推广。上一节中，定义了向量的范数，使线性空间成为赋范线性空间。

但是，在赋范线性空间中，还缺少欧几里德空间中的一些重要概念，即两向量之间的夹角。特别是两向量之间的正交概念。

我们知道，由于有了向量间的夹角和正交概念，也就有了向量的投影等一系列概念和结论，从而建立起一整套欧几里德空间的几何理论。我们也知道，向量的夹角和正交概念可以用“向量的内积”这个更本质的概念来描述。

我们先来回顾一下 R^3 中向量内积的概念，对 R^3 中任意两个向量 $\alpha = (x_1, x_2, x_3)^T$, $\beta = (y_1, y_2, y_3)^T$, α 与 β 的内积

$$\alpha \cdot \beta = x_1y_1 + x_2y_2 + x_3y_3,$$

有了内积的概念后， R^3 中任何一个向量 $||\alpha||$ 的长度就可以由式 $||\alpha|| = \sqrt{\alpha \cdot \alpha}$ 确定，同时两个向量 α 与 β 之间的夹角 θ 也可以由式

$$\cos \theta = \frac{\alpha \cdot \beta}{||\alpha|| \cdot ||\beta||}$$
确定。

当然不能直接将 R^3 中的内积公式推广到一般的线性空间，与定义线性空间类似，我们用公理来引入一般线性空间的内积。

三、内积的定义与性质

定义2.7 设 V 是实数域 R 上的线性空间, $\alpha, \beta, \gamma \in V, k \in R$ 。在 $V \times V$ 上定义了一个实函数 (α, β) , 它满足下列条件:

- (1) 对称性: $(\alpha, \beta) = (\beta, \alpha)$;
- (2) 线性性: $(\alpha + \gamma, \beta) = (\alpha, \beta) + (\gamma, \beta), (k\alpha, \beta) = k(\alpha, \beta)$;
- (3) 正定性: $(\alpha, \alpha) \geq 0$, 且 $(\alpha, \alpha) = 0$ 的充分必要条件是 $\alpha = 0$.

则称实数 (α, β) 为向量 α 与 β 的**内积**, 称定义了内积的线性空间 V 为**内积空间**。

向量的内积有以下性质：

$$(1) \quad (\alpha, k\beta) = k(\alpha, \beta);$$

$$(2) \quad (\alpha, 0) = (0, \beta) = 0;$$

$$(3) \quad \left(\sum_{i=1}^n x_i \alpha_i, \sum_{j=1}^n y_j \beta_j \right) = \sum_{i,j=1}^n x_i y_j (\alpha_i, \beta_j)$$

例: 在线性空间 R^n 中, 对任意 $x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \in R^n$,

定义 $(x, y) = x_1y_1 + x_2y_2 + \cdots + x_ny_n$, 容易检验其为内积。

例: 在线性空间 R^n 中, 对任意 $x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \in R^n$,

定义 $(x, y) = x_1y_1 + 2x_2y_2 + \cdots + nx_ny_n$, 容易检验其为内积。

由此可见, 对于同一个线性空间可以引入**不同的内积**, 从而构成**不同的内积空间**。

例 $\varepsilon_1, \dots, \varepsilon_n$ 是线性空间 V 的一组基. 对 V 中任意 α, β ,

$$\text{记 } \alpha = (\varepsilon_1, \dots, \varepsilon_n) \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = (\varepsilon_1, \dots, \varepsilon_n) X, \beta = (\varepsilon_1, \dots, \varepsilon_n) \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = (\varepsilon_1, \dots, \varepsilon_n) Y,$$

定义 $(\alpha, \beta) = X^T A Y$. 证明: (α, β) 是内积 $\Leftrightarrow A$ 是正定矩阵.

$$\text{证明“} \Rightarrow \text{” } (\alpha, \beta) = (\beta, \alpha) = Y^T A X \\ (\alpha, \beta)^T = (X^T A Y)^T = Y^T A^T X \Rightarrow Y^T (A - A^T) X = 0,$$

$$\text{取 } X_i = e_i, Y_j = e_j, i, j = 1, 2, \dots, n, \text{ 得 } \begin{pmatrix} e_1^T \\ \dots \\ e_n^T \end{pmatrix} (A - A^T) (e_1 \dots e_n) = 0, \text{ 即 } E (A - A^T) E = 0, \text{ 即 } A = A^T.$$

另一方面, 显然 $X^T A X = (\alpha, \alpha) \geq 0$; 若 $X^T A X = 0$, 即 $(\alpha, \alpha) = 0 \Leftrightarrow \alpha = 0 \Leftrightarrow X = 0$.
综上, A 是正定的.

“ \Leftarrow ”显然.

例 设 $t_0, t_1, t_2, \dots, t_m$ 两两互异。在实多项式空间 $P_n(t)$ 中定义二元实函数

$$(f(t), g(t)) = \sum_{i=0}^m f(t_i)g(t_i), \quad f(t), g(t) \in P_n(t)$$

- (1) 当 $m \geq n$ 时, 证明 $(f(t), g(t))$ 是 $P_n(t)$ 上的内积。
- (2) 当 $m < n$ 时 $(f(t), g(t))$ 是 $P_n(t)$ 上的内积吗? 给出你的结论, 并说明理由。

证 是否是内积只需检验正定性. 显然 $(f(t), f(t)) \geq 0$. 下证 $(f(t), f(t)) \geq 0 \Leftrightarrow f = 0$.

记 $f(t) = a_0 + a_1t + a_2t^2 + \dots + a_nt^n$. 显然 $(f(t), f(t)) = 0 \Leftrightarrow f(t_i) = 0, \quad i = 0, 1, 2, \dots, m$.

$$\Leftrightarrow \begin{pmatrix} 1 & t_0 & t_0^2 & \dots & t_0^n \\ 1 & t_1 & t_1^2 & \dots & t_1^n \\ \dots & \dots & \dots & \dots & \dots \\ 1 & t_m & t_m^2 & \dots & t_m^n \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix} = \mathbf{0} \Leftrightarrow A_{(m+1) \times (n+1)} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix} = \mathbf{0}.$$

(1) 当 $m \geq n$ 时, $r(A) = n + 1$, 因此

$$A_{(m+1) \times (n+1)} \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} = \mathbf{0} \text{ 只有零解, 因此 } A_{(m+1) \times (n+1)} \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} = \mathbf{0} \Leftrightarrow \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} = \mathbf{0} \Leftrightarrow f = \mathbf{0}.$$

从而 $(f(t), g(t))$ 是内积。

(2) 当 $m < n$ 时, $r(A) = m + 1$, 因此

$$A_{(m+1) \times (n+1)} \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} = \mathbf{0} \text{ 有非零解, 因此 } A_{(m+1) \times (n+1)} \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} = \mathbf{0} \xrightarrow{*} \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} = \mathbf{0}.$$

从而 $(f(t), g(t))$ 不是内积。

定义2.8 在内积空间 V 中, 非负实函数 $\|\alpha\| = \sqrt{(\alpha, \alpha)}$ 是 V 中向量 α 的范数, 称它为由内积导出的范数, 简称导出范数.

容易验证, 内积空间按导出范数成为赋范线性空间.

注: 显然, 内积空间按一定是赋范线性空间, 反之不然.

定理 2.10 (Cauchy – Schwarz 不等式) 对内积空间中的任意向量 α, β ,

$$(\alpha, \beta)^2 \leq (\alpha, \alpha)(\beta, \beta).$$

证明: 取任意 α, β , 考察 $(t\alpha + \beta)$, 其中 t 是任意量. 由内积定义知, 任意 t ,

$$((t\alpha + \beta), (t\alpha + \beta)) \geq 0 \Rightarrow t^2(\alpha, \alpha) + 2(\alpha, \beta)t + (\beta, \beta) \geq 0$$

$$\Rightarrow 4(\alpha, \beta)^2 - 4(\alpha, \alpha)(\beta, \beta) \leq 0 \Rightarrow (\alpha, \beta)^2 \leq (\alpha, \alpha)(\beta, \beta).$$

定义2.9 在内积空间中非零向量 α 与 β 之间的夹角 θ 由下式确定

$$\cos\theta = \frac{(\alpha, \beta)}{\|\alpha\|\|\beta\|}, \quad 0 \leq \theta \leq \pi$$

定义: 对内积空间中的2个向量 α, β , 若 $(\alpha, \beta) = 0$,

则称2向量垂直或正交, 记为 $\alpha \perp \beta$.

定理2.11 在内积空间中非零向量 α 与 β , 若 $\alpha \perp \beta$, 则

$$\|\alpha + \beta\|^2 = \|\alpha\|^2 + \|\beta\|^2.$$

证明: $\|\alpha + \beta\|^2 = (\alpha + \beta, \alpha + \beta) = (\alpha, \alpha) + (\alpha, \beta) + (\beta, \alpha) + (\beta, \beta) = \|\alpha\|^2 + \|\beta\|^2.$

二、内积的表示

在3维实内积空间 V 中，取基 e_1, e_2, e_3 ，对于 V 中的任意两个向量 α, β ，有

$$\alpha = x_1 e_1 + x_2 e_2 + x_3 e_3 \quad \beta = y_1 e_1 + y_2 e_2 + y_3 e_3$$

由内积的性质可知

$$\begin{aligned} (\alpha, \beta) &= (x_1 e_1 + x_2 e_2 + x_3 e_3, y_1 e_1 + y_2 e_2 + y_3 e_3) \\ &= x_1 y_1 (e_1, e_1) + x_1 y_2 (e_1, e_2) + x_1 y_3 (e_1, e_3) \\ &\quad + x_2 y_1 (e_2, e_1) + x_2 y_2 (e_2, e_2) + x_2 y_3 (e_2, e_3) \\ &\quad + x_3 y_1 (e_3, e_1) + x_3 y_2 (e_3, e_2) + x_3 y_3 (e_3, e_3) \end{aligned}$$

$$\begin{aligned}
(\alpha, \beta) &= x_1 (e_1, e_1) y_1 + x_1 (e_1, e_2) y_2 + x_1 (e_1, e_3) y_3 \\
&\quad + x_2 (e_2, e_1) y_1 + x_2 (e_2, e_2) y_2 + x_2 (e_2, e_3) y_3 \\
&\quad + x_3 (e_3, e_1) y_1 + x_3 (e_3, e_2) y_2 + x_3 (e_3, e_3) y_3
\end{aligned}$$

$$= (x_1, x_2, x_3) \begin{pmatrix} (e_1, e_1) & (e_1, e_2) & (e_1, e_3) \\ (e_2, e_1) & (e_2, e_2) & (e_2, e_3) \\ (e_3, e_1) & (e_3, e_2) & (e_3, e_3) \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$

在 n 维实内积空间 V 中, 取基 e_1, e_2, \dots, e_n , 对于 V 中的任意两个向量 α, β , 有

$$\alpha = x_1 e_1 + x_2 e_2 + \cdots + x_n e_n \quad \beta = y_1 e_1 + y_2 e_2 + \cdots + y_n e_n$$

则 $(\alpha, \beta) = (x_1 e_1 + x_2 e_2 + \cdots + x_n e_n, y_1 e_1 + y_2 e_2 + \cdots + y_n e_n)$

$$= \sum_{i=1}^n \sum_{j=1}^n x_i y_j (e_i, e_j) = (x_1, x_2, \dots, x_n) A \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \quad (\text{称为内积的表示式})$$

其中 $A = \begin{pmatrix} (e_1, e_1) & (e_1, e_2) & \cdots & (e_1, e_n) \\ (e_2, e_1) & (e_2, e_2) & \cdots & (e_2, e_n) \\ \vdots & \vdots & \ddots & \vdots \\ (e_n, e_1) & (e_n, e_2) & \cdots & (e_n, e_n) \end{pmatrix}$, 称做 V 在基 e_1, e_2, \dots, e_n 下的度量矩阵。

注 由前面例题可知 A 是对称正定阵。

例：如果内积空间在基 $\alpha_1, \alpha_2, \alpha_3$ 下的度量矩阵 $A = \begin{pmatrix} 10 & -3 & 4 \\ -3 & 20 & 1 \\ 4 & 1 & 30 \end{pmatrix}$

求向量 $\alpha = 3\alpha_1 + 2\alpha_2 - \alpha_3$ 的长度 $\|\alpha\|$ 以及它与 $\alpha_1 + 2\alpha_2$ 之间的夹角。

解： $\alpha = (\alpha_1, \alpha_2, \alpha_3) \begin{pmatrix} 3 \\ 2 \\ -1 \end{pmatrix}$. 由内积表示可知 $(\alpha, \alpha) = (3 \ 2 \ -1) A \begin{pmatrix} 3 \\ 2 \\ -1 \end{pmatrix} = 136$, 即 $\|\alpha\| = \sqrt{136}$.

$\alpha_1 + 2\alpha_2 = (\alpha_1, \alpha_2, \alpha_3) \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}$. 由内积表示可知 $(\alpha, \alpha_1 + 2\alpha_2) = (3 \ 2 \ -1) A \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix} = 80$,

而 $(\alpha_1 + 2\alpha_2, \alpha_1 + 2\alpha_2) = (1 \ 2 \ 0) A \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix} = 78$, 因此 $\cos \theta = \frac{80}{\sqrt{78} \sqrt{136}}$, 从而 $\theta = \arccos \frac{80}{\sqrt{78} \sqrt{136}}$.

例 设 $t_i = i, i = 0, 1, 2$ 。在实多项式空间 $P_2(t)$ 中定义二元实函数

$$(f(t), g(t)) = \sum_{i=0}^2 f(t_i)g(t_i) \quad \text{如果 } f(t) = 1 + 2t - t^2, g(t) = 2 - t + at^2$$

(1) 求 $f(t)$ 与 $g(t)$ 夹角。

(2) 当 a 为何值时, $f(t)$ 与 $g(t)$ 正交。

解: 由 $(f(t), g(t)) = f(0)g(0) + f(1)g(1) + f(2)g(2)$

得 $(f(t), f(t)) = f(0)f(0) + f(1)f(1) + f(2)f(2) = 6$

$$(g(t), g(t)) = g(0)g(0) + g(1)g(1) + g(2)g(2) = 5 + 2a + 17a^2 \Rightarrow \theta = \arccos \frac{4 + 6a}{\sqrt{6(5 + 2a + 17a^2)}}$$

$$(f(t), g(t)) = f(0)g(0) + f(1)g(1) + f(2)g(2) = 4 + 6a$$

显然当 $4 + 6a = 0$ 时, $f(t) \perp g(t)$.

定义2.10 称 $\alpha_1, \alpha_2, \dots, \alpha_n$ 是内积空间中的正交组(正交系) 是指

$$(\alpha_i, \alpha_j) = 0, \quad i \neq j, \quad i, j = 1, 2 \dots n.$$

定理2.3.5 若 $\alpha_1, \alpha_2, \dots, \alpha_k$ 是 n 维内积空间 V 中非零正交向量组, 即

$$(\alpha_i, \alpha_j) = 0, \quad i \neq j, \quad i, j = 1, 2 \dots n$$

则 $\alpha_1, \alpha_2, \dots, \alpha_k$ 必线性无关。

思考: $\alpha_1, \alpha_2, \dots, \alpha_n$ 是内积空间中的线性无关组, $\alpha_1, \alpha_2, \dots, \alpha_n$ 一定是非零正交组吗?

定义2.11 (1) 设 $\alpha_1, \alpha_2, \dots, \alpha_k$ 为 n 维内积空间 V 中一个正交系, 如果

$$\|\alpha_i\|=1, \quad (i = 1, 2, \dots, k)$$

则称 $\alpha_1, \alpha_2, \dots, \alpha_k$ 为 V 中一个**标准正交系**。

(2) n 维内积空间中的标准正交系 $\alpha_1, \alpha_2, \dots, \alpha_n$ 称为**标准正交基**。

思考: 在标准正交基下度量矩阵? 内积表示? (单位阵 E)

定理2.12 设 e_1, e_2, \dots, e_n 是内积空间 V 的标准正交基, 对任意

的向量 $\alpha \in V$, α 在基 e_1, e_2, \dots, e_n 下的坐标为 $x = (x_1, x_2, \dots, x_n)^T$, 则

$$x_i = (\alpha, e_i) \quad i = 1, 2, \dots, n$$

证明: 直接计算 $(\alpha, e_i) = (\sum_{j=1}^n x_j e_j, e_i) = \sum_{j=1}^n (x_j e_j, e_i) = \sum_{j=1}^n x_j (e_j, e_i) = x_i$.

定理2.13 在n维内积空间V中必存在标准正交基 $\alpha_1, \alpha_2, \dots, \alpha_n$.

证明：设 $\beta_1, \beta_2, \dots, \beta_n$ 是内积空间V中的一个基，令

$$e_1 = \beta_1$$

$$e_k = \beta_k - \sum_{i=1}^{k-1} \frac{(\beta_k, e_i)}{(e_i, e_i)} e_i \quad k = 2, 3, \dots, n$$

则 e_1, e_2, \dots, e_n 两两正交的非零向量组。

再令 $\alpha_i = \frac{e_i}{\|e_i\|}, i = 1, 2, \dots, n.$

则 $\alpha_1, \alpha_2, \dots, \alpha_n$ 就是V的标准正交基。

这一方法称为**施米特(Schmidt)正交化方法**。

例 在 $P_3(t)$ 中定义如下内积 $(f(t), g(t)) = \int_{-1}^1 f(t)g(t)dt$.

求内积空间 $P_3(t)$ 的一组标准正交基。

解：取定 $P_3(t)$ 中的一组基 $1, t, t^2, t^3$ 。下面利用 schmidt 正交化得到一组正交基

$$g_0(t) = 1; \quad g_1(t) = t - \frac{(t, g_0)}{(g_0, g_0)} g_0 = t; \quad g_2(t) = t^2 - \frac{(t^2, g_1)}{(g_1, g_1)} g_1 - \frac{(t^2, g_0)}{(g_0, g_0)} g_0 = t^2 - \frac{1}{3}$$

$$g_3(t) = t^3 - \frac{(t^3, g_2)}{(g_2, g_2)} g_2 - \frac{(t^3, g_1)}{(g_1, g_1)} g_1 - \frac{(t^3, g_0)}{(g_0, g_0)} g_0 = t^3 - \frac{3}{5}t$$

再将上述正交基单位化就得到一组标准正交基

$$\phi_0(t) = \frac{g_0(t)}{\|g_0(t)\|} = \frac{1}{\sqrt{2}}; \quad \phi_1(t) = \frac{g_1(t)}{\|g_1(t)\|} = \frac{\sqrt{6}}{2}t; \quad \phi_2(t) = \frac{g_2(t)}{\|g_2(t)\|} = \frac{\sqrt{10}}{4}(2t^2 - 1); \quad \phi_3(t) = \frac{g_3(t)}{\|g_3(t)\|} = \frac{\sqrt{14}}{4}(5t^3 - 3t)$$

例 设 W 是内积空间 V 的非平凡子空间，证明：

$$W^\perp = \{\alpha \mid \text{对所有的 } \beta \in W, \alpha \perp \beta\}$$

也是 V 的子空间. 称子空间 W^\perp 为 W 的正交补。

证明：显然， $0 \in W^\perp$ ，因此 W^\perp 不是空集。

设 $\alpha_1, \alpha_2 \in W^\perp$, 则对任意 $\beta \in W$,

$$(x\alpha_1 + y\alpha_2, \beta) = (x\alpha_1, \beta) + (y\alpha_2, \beta) = x(\alpha_1, \beta) + y(\alpha_2, \beta) = 0,$$

即 W^\perp 对加法和数乘封闭。因此 W^\perp 是 V 的子空间

例 如果 W 是线性空间 V 的子空间, 证明: $V = W \oplus W^\perp$.

证明: 取 W 的一组标准正交基 $\alpha_1, \alpha_2, \dots, \alpha_r$,

将其扩充成 V 的一组标准正交基 $\alpha_1, \alpha_2, \dots, \alpha_r, \dots, \alpha_n$.

下面证明 $W^\perp = \text{span}(\alpha_{r+1}, \dots, \alpha_n)$.

$\forall \alpha \in W^\perp$, 设 $\alpha = l_1\alpha_1 + \dots + l_{r+1}\alpha_{r+1} + \dots + l_n\alpha_n$. 对 $i = 1, 2, \dots, r$, 由 $(\alpha, \alpha_i) = 0$

即 $(l_1\alpha_1 + \dots + l_{r+1}\alpha_{r+1} + \dots + l_n\alpha_n, \alpha_i) = 0$ 得 $l_i = 0$ 因此 $\alpha = l_{r+1}\alpha_{r+1} + \dots + l_n\alpha_n \in \text{span}(\alpha_{r+1}, \dots, \alpha_n)$.

反之, 显然 $\text{span}(\alpha_{r+1}, \dots, \alpha_n) \subseteq W^\perp$.

综上, $V = W + W^\perp$. 而显然 $W + W^\perp = W \oplus W^\perp$.

例 内积空间 V 在基 $\alpha_1, \alpha_2, \alpha_3$ 下的度量矩阵 $A = \begin{pmatrix} 5 & 2 & -4 \\ 2 & 1 & -2 \\ -4 & -2 & 5 \end{pmatrix}$

向量 $\alpha = \alpha_1 + \alpha_2 - \alpha_3, \beta = 2\alpha_1 - \alpha_2 + 3\alpha_3, ,$

(1) 求 α 与 β 之间的夹角 (2) 求 $W = \text{Span}\{\alpha, \beta\}$ 的正交补。

解 (1) $(\alpha, \alpha) = (1, 1, -1)A \begin{pmatrix} 1 \\ 1 \\ -1 \end{pmatrix} = 23; \quad (\beta, \beta) = (2, -1, 3)A \begin{pmatrix} 2 \\ -1 \\ 3 \end{pmatrix} = 10;$

$$(\alpha, \beta) = (1, 1, -1)A \begin{pmatrix} 2 \\ -1 \\ 3 \end{pmatrix} = -4$$

因此 $\theta = \arccos \frac{-4}{\sqrt{230}}.$

例 内积空间 V 在基 $\alpha_1, \alpha_2, \alpha_3$ 下的度量矩阵 $A = \begin{pmatrix} 5 & 2 & -4 \\ 2 & 1 & -2 \\ -4 & -2 & 5 \end{pmatrix}$

向量 $\alpha = \alpha_1 + \alpha_2 - \alpha_3, \beta = 2\alpha_1 - \alpha_2 + 3\alpha_3, ,$

(1) 求 α 与 β 之间的夹角 (2) 求 $W = \text{Span}\{\alpha, \beta\}$ 的正交补。

解 (2) $\forall \gamma \in W^\perp$, 则 $\gamma \perp \alpha$ 且 $\gamma \perp \beta$ 。设 $\gamma = (\alpha_1, \alpha_2, \alpha_3) \begin{pmatrix} x \\ y \\ z \end{pmatrix}$,

则 $(\alpha, \gamma) = (1, 1, -1)A \begin{pmatrix} x \\ y \\ z \end{pmatrix} = 0; (\beta, \gamma) = (2, -1, 3)A \begin{pmatrix} x \\ y \\ z \end{pmatrix} = 0,$

即 $\begin{cases} 11x + 5y - 7z = 0 \\ -4x - 3y + 5z = 0 \end{cases}$ 得 $\begin{cases} x = -\frac{4}{13}c \\ y = \frac{27}{13}c \\ z = c \end{cases}$, c 任意常数。得 $\gamma = c \left(-\frac{4}{13}\alpha_1 + \frac{27}{13}\alpha_2 + \alpha_3 \right)$, c 任意常数。即 $W^\perp = \text{span} \left(-\frac{4}{13}\alpha_1 + \frac{27}{13}\alpha_2 + \alpha_3 \right)$.