

# 第三章 度量与投影

## 第 7 讲 正交性与投影

黄定江

DaSE @ ECNU


djhuang@dase.ecnu.edu.cn

- 1 7.1 四个基本子空间
- 2 7.2 四个子空间的正交关系
- 3 7.3 正交投影
- 4 7.4 正交基与 Gram-Schmit

- 1 7.1 四个基本子空间
- 2 7.2 四个子空间的正交关系
- 3 7.3 正交投影
- 4 7.4 正交基与 Gram-Schmit

## 引入

在数据科学的许多工程应用（如信号降噪滤波、数据降维、主成分分析、时间序列分析）中，许多问题的最优求解都可归结为数据在某个子空间的投影问题。本讲我们讲解投影这一在数据分析中极为重要的数学工具。



### 7.1.1 四个基本子空间

为了更好的理解子空间与投影，我们先讨论四个基本子空间：

1. 列空间:  $\text{Col}(\mathbf{A})$
2. 行空间:  $\text{Row}(\mathbf{A}) = \text{Col}(\mathbf{A}^T)$
3. 零空间:  $\text{Null}(\mathbf{A})$
4. 左零空间:  $\text{Null}(\mathbf{A}^T)$

四个基本子空间也是线性代数中非常重要的概念。

### 7.1.1 四个基本子空间

#### 约定

为方便叙述，对于矩阵  $\mathbf{A} \in \mathbb{R}^{m \times n}$ ，其  $m$  个行向量、 $n$  个列向量分别记作

$$\begin{aligned} \mathbf{r}_1 &= [a_{11}, a_{12}, \dots, a_{1n}]^T \\ \mathbf{r}_2 &= [a_{21}, a_{22}, \dots, a_{2n}]^T \\ &\dots \\ \mathbf{r}_m &= [a_{m1}, a_{m2}, \dots, a_{mn}]^T \end{aligned} \quad \mathbf{a}_1 = \begin{pmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{m1} \end{pmatrix}, \mathbf{a}_2 = \begin{pmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{m2} \end{pmatrix}, \dots, \mathbf{a}_n = \begin{pmatrix} a_{1n} \\ a_{2n} \\ \vdots \\ a_{mn} \end{pmatrix}$$

$$\text{即 } \mathbf{A} = (\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_m)^T = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n)$$

设矩阵  $\mathbf{A} \in \mathbb{R}^{m \times n}$ , 则它引出下面四个基本子空间:

### 定义 1

列空间是其列向量  $\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n\}$  的所有线性组合的集合, 它是  $\mathbb{R}^m$  的一个子空间, 用符号  $Col(\mathbf{A})$  表示, 即有

$$Col(\mathbf{A}) = \left\{ \mathbf{y} \in \mathbb{R}^m \mid \mathbf{y} = \sum_{j=1}^n \alpha_j \mathbf{a}_j, \alpha_j \in \mathbb{R} \right\} = \text{span}\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n\} \quad (1)$$

### 定义 2

行空间是其行向量  $\{\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_m\}$  的所有线性组合的集合, 它是  $\mathbb{R}^n$  的一个子空间, 用符号  $Row(\mathbf{A})$  表示, 也可以用  $Col(\mathbf{A}^T)$  表示, 有

$$Row(\mathbf{A}) = Col(\mathbf{A}^T) = \left\{ \mathbf{y} \in \mathbb{R}^n \mid \mathbf{y} = \sum_{i=1}^m \beta_i \mathbf{r}_i, \beta_i \in \mathbb{R} \right\} = \text{span}\{\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_m\} \quad (2)$$

### 定义 3

零空间是所有满足齐次线性方程组  $\mathbf{Ax} = \mathbf{0}$  的解向量集合，它是  $\mathbb{R}^n$  的一个子空间，用符号  $\text{Null}(\mathbf{A})$  表示，即有

$$\text{Null}(\mathbf{A}) = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{0}\} \quad (3)$$

### 定义 4

左零空间是所有满足齐次线性方程组  $\mathbf{A}^T \mathbf{y} = \mathbf{0}$  的解向量集合，它是  $\mathbb{R}^m$  的一个子空间，用符号  $\text{Null}(\mathbf{A}^T)$  表示，即有

$$\text{Null}(\mathbf{A}^T) = \{\mathbf{y} \in \mathbb{R}^m \mid \mathbf{A}^T \mathbf{y} = \mathbf{0}\} \quad (4)$$

给定一个矩阵，为了获得其四个基本子空间，我们需要用到以下结论：

### 定理 1

1. 一系列初等行变换不改变矩阵的行空间。
2. 一系列初等行变换不改变矩阵的零空间。
3. 一系列初等列变换不改变矩阵的列空间。
4. 一系列初等列变换不改变矩阵的左零空间。

证明.

[2] 令  $E_i$  是对应于矩阵  $A$  的第  $i$  次初等行变换的初等矩阵。由初等行变换可逆。于是，

$$Bx = (E_k E_{k-1} \cdots E_1 A)x = 0 \Leftrightarrow Ax = 0$$

即齐次线性方程  $Bx = 0$  与  $Ax = 0$  具有相同的解向量，从而  $A$  经过若干次初等行变换后得到的矩阵  $B$  与  $A$  具有相同的零空间。 □

## 例 1

求  $3 \times 3$  矩阵

$$\mathbf{A} = \begin{pmatrix} 1 & 2 & 1 \\ -1 & -1 & 1 \\ 1 & 4 & 5 \end{pmatrix}$$

的行空间、列空间、零空间和左零空间。

## 解

依次进行初等列变换，得到列简约阶梯型矩阵：

$$\begin{pmatrix} 1 & 2 & 1 \\ -1 & -1 & 1 \\ 1 & 4 & 5 \end{pmatrix} \xrightarrow[\begin{smallmatrix} C_2-2C_1 \\ C_3-C_1 \end{smallmatrix}]{\quad} \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 2 \\ 1 & 2 & 4 \end{pmatrix} \xrightarrow[\begin{smallmatrix} C_1+C_2 \\ C_3-2C_2 \end{smallmatrix}]{\quad} \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 3 & 2 & 0 \end{pmatrix}$$

最后的变换结果为:

$$\mathbf{A}_C = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 3 & 2 & 0 \end{pmatrix}$$

由此得到两个线性无关的列向量  $\mathbf{c}_1 = (1, 0, 3)^T$ ,  $\mathbf{c}_2 = (0, 1, 2)^T$ , 它们是列空间  $\text{Col}(\mathbf{A})$  的基

$$\text{Col}(\mathbf{A}) = \text{span}\{(1, 0, 3)^T, (0, 1, 2)^T\}$$

由于一系列初等列变换不改变左零空间, 根据  $\mathbf{A}_C$ , 知  $-3\mathbf{r}_1 - 2\mathbf{r}_2 + \mathbf{r}_3 = 0$ 。

那么我们就可以根据  $\mathbf{A}_C$  的主元位置, 矩阵  $\mathbf{A}$  的主元行是第 1 行和第 2 行, 即行空间  $\text{Col}(\mathbf{A}^T)$  可以写作

$$\text{Col}(\mathbf{A}^T) = \text{span}\{(1, 2, 1)^T, (-1, -1, 1)^T\}$$

对  $\mathbf{A}$  进行行初等变换

$$\begin{pmatrix} 1 & 2 & 1 \\ -1 & -1 & 1 \\ 1 & 4 & 5 \end{pmatrix} \xrightarrow[\begin{smallmatrix} R_2+R_1 \\ R_3-R_1 \end{smallmatrix}]{R_3-R_1} \begin{pmatrix} 1 & 2 & 1 \\ 0 & 1 & 2 \\ 0 & 2 & 4 \end{pmatrix} \xrightarrow[\begin{smallmatrix} R_1-2R_2 \\ R_3-2R_2 \end{smallmatrix}]{R_3-2R_2} \mathbf{A}_R = \begin{pmatrix} 1 & 0 & -3 \\ 0 & 1 & 2 \\ 0 & 0 & 0 \end{pmatrix}$$

$\mathbf{A}$  的秩为 2。解方程组  $\mathbf{A}_R \mathbf{x} = \mathbf{0}$  得到  $\mathbf{x} = k(3, -2, 1)^T$

$$\text{Null}(\mathbf{A}) = \text{span}\{(3, -2, 1)\}^T$$

所以零空间维数为 1。

类似地，我们求解  $\mathbf{A}_C^T \mathbf{x} = \mathbf{0}$  得到  $\mathbf{x} = k(3, 2, -1)^T$  所以

$$\text{Null}(\mathbf{A}^T) = \text{span}\{(3, 2, -1)\}^T$$

左零空间的维数也是 1。

## 7.1.2 四个基本子空间的基

我们接下来的目标是: 求四个基本子空间的基和维数。

线性代数的课程中我们学习过矩阵的行秩等于列秩。因此

### 定理 2

设  $\mathbf{A} \in \mathbb{R}^{m \times n}$ , 则  $\dim(\text{Col}(\mathbf{A})) = \dim(\text{Row}(\mathbf{A})) = \text{rank}(\mathbf{A})$

### 定理 3

设  $\mathbf{A} \in \mathbb{R}^{m \times n}$  则

$$\dim(\text{Null}(\mathbf{A})) = n - \text{rank}(\mathbf{A})$$

证明.

我们令  $r = \text{rank}(\mathbf{A})$ , 根据定义  $\text{Null}(\mathbf{A}) = \{\mathbf{x} \in \mathbb{R}^n | \mathbf{A}\mathbf{x} = \mathbf{0}\}$  我们对  $\mathbf{A}$  做行初等变换和列变换, 将  $\mathbf{A}$  可以变换为

$$\mathbf{A}' = \begin{pmatrix} \mathbf{I} & \mathbf{B} \\ \mathbf{O} & \mathbf{O} \end{pmatrix} = \begin{pmatrix} 1 & & & b_{11} & b_{12} & \dots & b_{1,n-r} \\ & 1 & & b_{21} & b_{22} & \dots & b_{2,n-r} \\ & & \ddots & \vdots & \vdots & & \vdots \\ & & & 1 & b_{r1} & b_{r2} & \dots & b_{r,n-r} \\ 0 & 0 & 0 & 0 & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & \dots & 0 \end{pmatrix}$$

□

显然  $\mathbf{A}'\mathbf{x} = \mathbf{0}$  有以下  $n - r$  个解

$$\mathbf{x}^{(1)} = \begin{pmatrix} b_{11} \\ \vdots \\ b_{r1} \\ -1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \quad \mathbf{x}^{(2)} = \begin{pmatrix} b_{12} \\ \vdots \\ b_{r2} \\ 0 \\ -1 \\ \vdots \\ 0 \end{pmatrix} \quad \dots \quad \mathbf{x}^{(n-r)} = \begin{pmatrix} b_{1,n-r} \\ \vdots \\ b_{r,n-r} \\ 0 \\ 0 \\ \vdots \\ -1 \end{pmatrix}$$

并且容易看出向量组  $(\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n-r)})$  是一个极大线性无关组。

再注意到，如果  $\mathbf{x}$  是方程  $\mathbf{A}'\mathbf{x} = \mathbf{0}$  的解，那么当  $x_{r+1}, x_{r+2}, \dots, x_n$  取定时，可以唯一确定  $\mathbf{x}$ 。换句话说  $\{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}'\mathbf{x} = \mathbf{0}\}$  的维数最大为  $n - r$ 。

综上  $\mathbf{A}'\mathbf{x} = \mathbf{0}$  解空间的维数为  $n - r$ ，即  $\mathbf{Ax} = \mathbf{0}$  解空间的维数为  $n - r$ ，即

$$\dim(\text{Null}(\mathbf{A})) = n - r$$

上述的证明过程实际上也就是我们刚刚求解矩阵  $\mathbf{A}$  零空间  $\text{Null}(\mathbf{A})$  基底和维数的过程。由此得到秩定理，描述了矩阵的秩与其零空间维数之间的关系。

#### 定理 4

矩阵  $\mathbf{A}_{m \times n}$  的列空间和行空间的维数相等。这个共同的维数就是矩阵  $\mathbf{A}$  的秩  $\text{rank}(\mathbf{A})$ ，它与零空间维数之间有下列关系：

$$\dim(\text{Col}(\mathbf{A})) + \dim[\text{Null}(\mathbf{A})] = n \quad (5)$$

利用上述定理我们立刻可以得到以下推论

#### 推论 1

设  $\mathbf{A} \in \mathbb{R}^{m \times n}$  则

$$\dim(\text{Null}(\mathbf{A}^T)) = m - \text{rank}(\mathbf{A})$$

- 1 7.1 四个基本子空间
- 2 7.2 四个子空间的正交关系
- 3 7.3 正交投影
- 4 7.4 正交基与 Gram-Schmit

## 7.2 四个子空间的正交关系

我们将继续讨论四个基本子空间之间的关系。

设  $\mathbf{A} \in \mathbb{R}^{m \times n}$ ,  $\mathbf{A}$  的四个基本子空间中,  $\text{Col}(\mathbf{A}), \text{Null}(\mathbf{A}^T)$  都是  $\mathbb{R}^m$  的子空间, 它们是否有交集?  $\text{Col}(\mathbf{A}^T), \text{Null}(\mathbf{A})$  都是  $\mathbb{R}^n$  的子空间, 它们是否有交集?

### 定理 5

设  $\mathbf{A} \in \mathbb{R}^{m \times n}$ ,

$$\text{Col}(\mathbf{A}) \cap \text{Null}(\mathbf{A}^T) = \{\mathbf{0}\}$$

$$\text{Col}(\mathbf{A}^T) \cap \text{Null}(\mathbf{A}) = \{\mathbf{0}\}$$

证明.

设  $\boldsymbol{v} \in \text{Col}(\boldsymbol{A}^T) \cap \text{Null}(\boldsymbol{A})$ , 即  $\boldsymbol{v}$  在  $\boldsymbol{A} = (\boldsymbol{r}_1, \boldsymbol{r}_2, \dots, \boldsymbol{r}_m)^T$  的行空间中且  $\boldsymbol{A}\boldsymbol{v} = \mathbf{0}$ 。

设  $\boldsymbol{v} = a_1\boldsymbol{r}_1 + a_2\boldsymbol{r}_2 + \dots + a_m\boldsymbol{r}_m$ , 则

$$\boldsymbol{A}\boldsymbol{v} = \mathbf{0} \implies \boldsymbol{r}_1^T\boldsymbol{v} = 0, \dots, \boldsymbol{r}_m^T\boldsymbol{v} = 0 \implies \boldsymbol{v}^T\boldsymbol{v} = 0 \implies \boldsymbol{v} = \mathbf{0}$$

即

$$\text{Col}(\boldsymbol{A}^T) \cap \text{Null}(\boldsymbol{A}) = \{\mathbf{0}\}.$$

同理  $\text{Col}(\boldsymbol{A}) \cap \text{Null}(\boldsymbol{A}^T) = \{\mathbf{0}\}$ 。



## 定义 5

设  $S$  和  $T$  是  $\mathbb{R}^n$  的两个子空间。如果

$$S \cap T = \{\mathbf{0}\}$$

我们称  $S$  和  $T$  无交连。

列空间和左零空间是无交连的，行空间和零空间是无交连的。

## 定义 6

设  $S$  和  $T$  是  $\mathbb{R}^n$  的两个子空间。如果对于  $\forall \mathbf{v} \in S, \forall \mathbf{w} \in T$ ，均有

$$\mathbf{v}^T \mathbf{w} = 0$$

我们说  $S$  垂直于  $T$ ， $T$  垂直于  $S$ ，记做  $S \perp T, T \perp S$ 。

或者说，子空间  $S$  和子空间  $T$  是正交的。

## 定理 6

正交的两个子空间必定是无交连的。

证明.

假设  $\mathbb{R}^n$  中的两个子空间  $S, T$  不是无交连的  
则

$$\exists v \neq \mathbf{0}, v \in S \cap T$$

而

$$v^T v \neq 0$$

因而  $S$  和  $T$  不正交。从而正交的两个子空间必是无交连的。 □

显然，无交连的子空间不一定是正交的。如  $\text{span}\{(1, 1)^T\}$  和  $\text{span}\{(1, 0)^T\}$ 。  
那么列空间和左零空间，行空间和零空间是正交的么？

## 例 2

设  $\mathbf{A}$  是  $m \times n$  阶阵, 则  $\text{Col}(\mathbf{A})$  和  $\text{Null}(\mathbf{A}^T)$  正交,  $\text{Col}(\mathbf{A}^T)$  和  $\text{Null}(\mathbf{A})$  正交。

证明.

对  $\forall \mathbf{v} \in \text{Null}(\mathbf{A}^T)$ , 则

$$\mathbf{v}^T \mathbf{A} = \mathbf{0} \implies \mathbf{v}^T \mathbf{a}_1 = 0, \mathbf{v}^T \mathbf{a}_2 = 0, \dots, \mathbf{v}^T \mathbf{a}_n = 0$$

对  $\forall \mathbf{w} \in \text{Col}(\mathbf{A})$ , 有  $\mathbf{w} = \alpha_1 \mathbf{a}_1 + \alpha_2 \mathbf{a}_2 + \dots + \alpha_n \mathbf{a}_n$ :

$$\mathbf{v}^T \mathbf{w} = \alpha_1 \mathbf{v}^T \mathbf{a}_1 + \alpha_2 \mathbf{v}^T \mathbf{a}_2 + \dots + \alpha_n \mathbf{v}^T \mathbf{a}_n = 0$$

因此,  $\text{Null}(\mathbf{A}^T) \perp \text{Col}(\mathbf{A})$ ,  $\text{Col}(\mathbf{A})$  和  $\text{Null}(\mathbf{A}^T)$  正交。

将  $\mathbf{A}$  换成  $\mathbf{A}^T$ , 我们得到  $\text{Col}(\mathbf{A}^T) \perp \text{Null}(\mathbf{A})$ ,  $\text{Col}(\mathbf{A}^T)$  和  $\text{Null}(\mathbf{A})$  正交。 □

相对于正交，正交补是两个子空间更强的一种关系。

### 定义 7

设  $\mathbb{V} \subset \mathbb{R}^n$  是一个子空间,  $\mathbb{V}$  在  $\mathbb{R}^n$  中的正交补定义为集合

$$\{\boldsymbol{w} \in \mathbb{R}^n \mid \boldsymbol{v}^T \boldsymbol{w} = 0, \forall \boldsymbol{v} \in \mathbb{V}\}$$

记作  $\mathbb{V}^\perp$ 。

也就是说  $\mathbb{V}$  的正交补空间是  $\mathbb{R}^n$  中所有和  $\mathbb{V}$  正交的向量构成的集合。

显然一个空间和它的正交补空间是正交的，即  $\mathbb{V} \perp \mathbb{V}^\perp$ 。

显然  $\mathbb{V}$  与  $\mathbb{V}^\perp$  的和是直和，因此，对于  $\mathbb{R}^n$  中的任意向量  $\boldsymbol{x}$  可以唯一的分解成如下形式：

$$\boldsymbol{x} = \boldsymbol{x}_1 + \boldsymbol{x}_2$$

其中  $\boldsymbol{x}_1 \in \mathbb{V}$ ,  $\boldsymbol{x}_2 \in \mathbb{V}^\perp$  并且  $\boldsymbol{x}_1^T \boldsymbol{x}_2 = 0$ 。这种分解形式叫做向量的正交分解。

## 例 3

证明:  $\text{Col}(\mathbf{A}^T)^\perp = \text{Null}(\mathbf{A})$ ,  $\text{Col}(\mathbf{A})^\perp = \text{Null}(\mathbf{A}^T)$ 。

我们已经知道,  $\text{Col}(\mathbf{A}^T)$  和  $\text{Null}(\mathbf{A})$  是正交的, 也就是说

$$\text{Null}(\mathbf{A}) \subseteq \text{Col}(\mathbf{A}^T)^\perp$$

对  $\forall \mathbf{x} \in \text{Col}(\mathbf{A}^T)^\perp$ ,  $\mathbf{x}$  和  $\text{Col}(\mathbf{A}^T)$  中的任意向量正交, 那么:

$$\mathbf{x}^T \mathbf{r}_1 = 0, \mathbf{x}^T \mathbf{r}_2 = 0, \dots, \mathbf{x}^T \mathbf{r}_m = 0$$

即  $\mathbf{A}\mathbf{x} = \mathbf{0}$ 。说明  $\mathbf{x} \in \text{Null}(\mathbf{A})$ 。也即

$$\text{Col}(\mathbf{A}^T)^\perp \subseteq \text{Null}(\mathbf{A})$$

因此  $\text{Col}(\mathbf{A}^T)^\perp = \text{Null}(\mathbf{A})$ 。同样可以证明  $\text{Col}(\mathbf{A})^\perp = \text{Null}(\mathbf{A}^T)$ 。

顾名思义，子空间  $\mathbb{V}$  在向量空间  $\mathbb{R}^n$  的正交补空间  $\mathbb{V}^\perp$  含有正交和补充双重含义：

1. 子空间  $\mathbb{V}^\perp$  与  $\mathbb{V}$  正交：
2. 向量空间  $\mathbb{R}^n$  是子空间  $\mathbb{V}$  与  $\mathbb{V}^\perp$  的直和，即  $\mathbb{R}^n = \mathbb{V} \oplus \mathbb{V}^\perp$ 。这表明，向量空间  $\mathbb{R}^n$  是由子空间  $\mathbb{V}$  补充  $\mathbb{V}^\perp$  而成。

正交补空间是一个比正交子空间更严格的概念：当向量空间  $\mathbb{R}^n$  和子空间  $\mathbb{V}$  给定之后，和  $\mathbb{V}$  正交的空间不一定是唯一的，但是  $\mathbb{V}$  的正交补  $\mathbb{V}^\perp$  是唯一的。

## 线性代数基本定理

我们将本节内容总结成线性代数基本定理：

## 定理 7

(线性代数基本定理) 若  $\mathbf{A}$  是  $m \times n$  矩阵,

- 1 [正交角度]  $\text{Col}(\mathbf{A}^T) \perp \text{Null}(\mathbf{A})$ ,  $\text{Col}(\mathbf{A}) \perp \text{Null}(\mathbf{A}^T)$ ,
- 2 [扩张角度]  $\text{Col}(\mathbf{A}^T) \oplus \text{Null}(\mathbf{A}) = \mathbb{R}^n$ ,  $\text{Col}(\mathbf{A}) \oplus \text{Null}(\mathbf{A}^T) = \mathbb{R}^m$ ,
- 3 [维数角度]  $\dim \text{Col}(\mathbf{A}^T) + \dim \text{Null}(\mathbf{A}) = n$ ,  $\dim \text{Col}(\mathbf{A}) + \dim \text{Null}(\mathbf{A}^T) = m$ .

## 线性代数基本定理

$$\text{Col}(\mathbf{A}^T)^\perp = \text{Null}(\mathbf{A})$$

$$\text{Col}(\mathbf{A})^\perp = \text{Null}(\mathbf{A}^T)$$




图 1: 四个子空间

- ① 7.1 四个基本子空间
- ② 7.2 四个子空间的正交关系
- ③ 7.3 正交投影
- ④ 7.4 正交基与 Gram-Schmit

### 7.3.1 引言

- 投影是一类重要的线性变换。
- 投影在图形学，编码理论，统计和机器学习中起着重要作用。
- 在机器学习中，我们经常处理高维数据。高维数据通常很难分析或可视化。
- 但是，高维数据通常具有以下属性：只有少数维包含大多数信息，而其它大多数维对于描述数据的关键属性也不是必需的。当我们压缩或可视化高维数据时，我们将丢失信息。
- 为了最大程度地减少这种压缩损失，我们理想地希望在数据中找到最有用的信息维度。然后，我们可以将原始的高维数据投影到低维特征空间上，并在此低维空间中进行操作，以了解有关数据集的更多信息并提取模式。
- 例如机器学习中主成分分析（PCA）、深度学习中深度自动编码器大量采用了降维的想法。
- 下面，我们将专注于正交投影。

## 投影

## 定义 8

设  $V$  是一向量空间,  $W \subseteq V$  是  $V$  的一个子空间。如果线性映射  $\pi: V \rightarrow W$  满足

$$\pi^2 = \pi \circ \pi = \pi$$

则称  $\pi$  为投影。

设  $\pi$  对应的矩阵  $P_\pi$ , 显然  $P_\pi$  满足  $P_\pi^2 = P_\pi$ , 称  $P_\pi$  为投影矩阵。

## 投影

## 正交投影

本节所讲的投影指正交投影，即给定定义了标准内积和欧氏距离的向量空间  $\mathbb{R}^m$  中的向量  $\mathbf{x}$ ， $\mathbb{S}$  是  $\mathbb{R}^m$  的子空间，求  $\mathbf{y} \in \mathbb{S}$ ，使得  $\|\mathbf{y} - \mathbf{x}\|$  最小，即

$$\pi_{\mathbb{S}}(\mathbf{x}) = \arg \min_{\mathbf{y} \in \mathbb{S}} \|\mathbf{y} - \mathbf{x}\|,$$

称向量  $\mathbf{y}$  为向量  $\mathbf{x}$  在子空间  $\mathbb{S}$  的正交投影。

因为可以对  $\mathbf{x}$  进行分解， $\mathbf{x} = \mathbf{x}_1 + \mathbf{x}_2$ ，其中  $\mathbf{x}_1 \in \mathbb{S}$ ， $\mathbf{x}_2 \in \mathbb{S}^\perp$ 。所以


$$\|\mathbf{y} - \mathbf{x}\|^2 = \|\mathbf{y} - (\mathbf{x}_1 + \mathbf{x}_2)\|^2 = \|(\mathbf{x}_1 - \mathbf{y}) + \mathbf{x}_2\|^2.$$

而  $\mathbf{x}_1 - \mathbf{y} \in \mathbb{S}$ ， $\mathbf{x}_2 \in \mathbb{S}^\perp$ ，所以  $\|(\mathbf{x}_1 - \mathbf{y}) + \mathbf{x}_2\|^2 = \|\mathbf{x}_1 - \mathbf{y}\|^2 + \|\mathbf{x}_2\|^2$ 。


所以我们只需令  $\mathbf{y} = \mathbf{x}_1$  即可，那么  $\mathbf{x}_2 = \mathbf{x} - \mathbf{y} \in \mathbb{S}^\perp$ 。

### 7.3.2 投影到 1 维子空间

接下来，我们看一下如何寻找一个投影矩阵  $P_\pi$  使得向量投影到某个 1 维子空间上。



(a) Original dataset.



(b) Original data (blue) and their corresponding orthogonal projections (orange) onto a lower-dimensional subspace (straight line).

将 2 维空间的点投影到 1 维子空间上。

## 7.3.2 投影到 1 维子空间

### 投影到一维子空间

设基底矩阵  $\mathbf{B} = [\mathbf{b}]$ , 也就是这组基中仅有一个向量。

设  $\mathbb{R}^n$  的子空间  $\mathbb{W} = \text{Col}(\mathbf{B})$ , 我们想寻找一个点  $\pi_{\mathbb{W}}(\mathbf{x}) \in \mathbb{W}$  最接近  $\mathbf{x}$ 。

因为  $\pi_{\mathbb{W}}(\mathbf{x}) \in \mathbb{W}$ , 又  $\mathbb{W} = \text{Col}(\mathbf{B}) = \text{span}\{\mathbf{b}\}$ 。

所以  $\pi_{\mathbb{W}}(\mathbf{x}) = \lambda \mathbf{b}, \lambda \in \mathbb{R}$ 。

接下来, 我们将逐步确定  $\lambda$ ,  $\pi_{\mathbb{W}}(\mathbf{x})$  和投影矩阵  $\mathbf{P}_{\pi}$

### 1. 确定 $\lambda$

因为  $\pi_{\mathbb{W}}(\mathbf{x}) \in \text{Col}(\mathbf{B})$  是  $\mathbf{x}$  的投影, 所以  $\mathbf{x} - \pi_{\mathbb{W}}(\mathbf{x}) \in \text{Null}(\mathbf{B}^T)$ , 有

$$\mathbf{b}^T(\mathbf{x} - \pi_{\mathbb{W}}) = 0 \iff \mathbf{b}^T \mathbf{x} - \lambda \mathbf{b}^T \mathbf{b} = 0$$

从而

$$\lambda = \frac{\mathbf{b}^T \mathbf{x}}{\mathbf{b}^T \mathbf{b}}$$

或者利用内积表示可得

$$\langle \mathbf{x}, \mathbf{b} \rangle - \lambda \langle \mathbf{b}, \mathbf{b} \rangle = 0 \iff \lambda = \frac{\langle \mathbf{x}, \mathbf{b} \rangle}{\langle \mathbf{b}, \mathbf{b} \rangle} = \frac{\langle \mathbf{x}, \mathbf{b} \rangle}{\|\mathbf{b}\|^2}.$$

## 7.3.2 投影到 1 维子空间

### 2. 确定 $\pi_{\mathbb{W}}(\mathbf{x})$

因为  $\pi_{\mathbb{W}}(\mathbf{x}) = \lambda \mathbf{b}$ , 由上面的结论可得:

$$\pi_{\mathbb{W}}(\mathbf{x}) = \frac{\langle \mathbf{x}, \mathbf{b} \rangle}{\|\mathbf{b}\|^2} \mathbf{b} = \frac{\mathbf{b}^T \mathbf{x}}{\|\mathbf{b}\|^2} \mathbf{b}$$

我们可以给出  $\pi_{\mathbb{W}}(\mathbf{x})$  的长度

$$\begin{aligned} \|\pi_{\mathbb{W}}(\mathbf{x})\| &= \|\lambda \mathbf{b}\| = |\lambda| \|\mathbf{b}\| \\ &= |\cos \omega| \|\mathbf{x}\| \|\mathbf{b}\| \frac{\|\mathbf{b}\|}{\|\mathbf{b}\|^2} = |\cos \omega| \|\mathbf{x}\| \end{aligned}$$

其中  $\omega$  是  $\mathbf{x}$  和  $\mathbf{b}$  之间的夹角,  $\cos \omega = \frac{\mathbf{b}^T \mathbf{x}}{\|\mathbf{b}\| \|\mathbf{x}\|}$ 。

## 7.3.2 投影到 1 维子空间

### 3. 确定投影矩阵 $P_\pi$

投影矩阵  $P_\pi$  是投影  $\pi_{\mathbb{W}}(\mathbf{x})$  对应的变换矩阵, 那么就有  $\pi_{\mathbb{W}}(\mathbf{x}) = P_\pi \mathbf{x}$ , 则有

$$\pi_{\mathbb{W}}(\mathbf{x}) = \lambda \mathbf{b} = \mathbf{b} \lambda = \mathbf{b} \frac{\mathbf{b}^T \mathbf{x}}{\|\mathbf{b}\|^2} = \frac{\mathbf{b} \mathbf{b}^T}{\|\mathbf{b}\|^2} \mathbf{x}$$

我们立刻可以看出

$$P_\pi = \frac{\mathbf{b} \mathbf{b}^T}{\|\mathbf{b}\|^2}$$

注:

$\mathbf{b} \mathbf{b}^T$  是一个对称矩阵, 而  $\mathbf{b}^T \mathbf{b}$  则是一个标量。

## 例 4

确定投影到  $\mathbb{R}^3$  的子空间  $\text{span}\{\mathbf{b}\}$  上的投影矩阵  $\mathbf{P}_\pi$ 。其中  $\mathbf{b} = (1, 2, 2)^\text{T}$   
由上面的结论可得

$$\mathbf{P}_\pi = \frac{\mathbf{b}\mathbf{b}^\text{T}}{\mathbf{b}^\text{T}\mathbf{b}} = \frac{1}{9} \begin{pmatrix} 1 \\ 2 \\ 2 \end{pmatrix} (1 \ 2 \ 2) = \frac{1}{9} \begin{pmatrix} 1 & 2 & 2 \\ 2 & 4 & 4 \\ 2 & 4 & 4 \end{pmatrix}$$

给定向量  $\mathbf{x} = (1, 1, 1)^\text{T}$  其投影为

$$\pi_{\mathbb{W}}(\mathbf{x}) = \mathbf{P}_\pi(\mathbf{x}) = \frac{1}{9} \begin{pmatrix} 1 & 2 & 2 \\ 2 & 4 & 4 \\ 2 & 4 & 4 \end{pmatrix} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = \frac{1}{9} \begin{pmatrix} 5 \\ 10 \\ 10 \end{pmatrix} \in \text{Col} \left( \begin{pmatrix} 1 \\ 2 \\ 2 \end{pmatrix} \right)$$

### 7.3.3 投影到一般子空间

接下来，我们考虑更一般的情况。

我们将  $\mathbb{R}^m$  中的向量  $\mathbf{x}$  投影到更高维的子空间中。

#### 投影到一般的子空间中

设  $\mathbf{B} = (\mathbf{b}_1, \dots, \mathbf{b}_n)$  是子空间  $\mathbb{U}$  的一个有序基底。任何  $\mathbb{U}$  上的投影  $\pi_{\mathbb{U}}(\mathbf{x})$  必须是  $\mathbb{U}$  中的一个元素。故有

$$\pi_{\mathbb{U}}(\mathbf{x}) = \sum_{i=1}^n \lambda_i \mathbf{b}_i$$

和一维情况一样，我们将逐步确定  $\lambda_1, \dots, \lambda_n$ ， $\pi_{\mathbb{W}}(\mathbf{x})$  和投影矩阵  $\mathbf{P}_{\pi}$

1. 确定  $\lambda_1, \dots, \lambda_n$ 

设

$$\pi_U(\mathbf{x}) = \sum_{i=1}^n \lambda_i \mathbf{b}_i = B\boldsymbol{\lambda}$$

其中  $B = [\mathbf{b}_1, \dots, \mathbf{b}_n] \in \mathbb{R}^{m \times n}$ ,  $\boldsymbol{\lambda} = [\lambda_1, \dots, \lambda_n]^T \in \mathbb{R}^n$ 。因为  $\pi_U(\mathbf{x})$  是  $\mathbf{x}$  的投影, 所以  $\mathbf{x} - \pi_U(\mathbf{x}) \in \text{Null}(B^T)$ 

$$\mathbf{b}_1^T(\mathbf{x} - \pi_U(\mathbf{x})) = \langle \mathbf{b}_1, \mathbf{x} - \pi_U(\mathbf{x}) \rangle = 0$$

$$\mathbf{b}_2^T(\mathbf{x} - \pi_U(\mathbf{x})) = \langle \mathbf{b}_2, \mathbf{x} - \pi_U(\mathbf{x}) \rangle = 0$$

$$\vdots$$

$$\mathbf{b}_n^T(\mathbf{x} - \pi_U(\mathbf{x})) = \langle \mathbf{b}_n, \mathbf{x} - \pi_U(\mathbf{x}) \rangle = 0$$

使用矩阵可以将上式改写成

$$\mathbf{b}_1^T(\mathbf{x} - B\boldsymbol{\lambda}) = 0$$

$$\vdots$$

$$\mathbf{b}_n^T(\mathbf{x} - B\boldsymbol{\lambda}) = 0$$

故有

$$\begin{pmatrix} \mathbf{b}_1^T \\ \vdots \\ \mathbf{b}_n^T \end{pmatrix} (\mathbf{x} - B\boldsymbol{\lambda}) = \mathbf{0} \iff B^T(\mathbf{x} - B\boldsymbol{\lambda}) = \mathbf{0} \iff B^T B\boldsymbol{\lambda} = B^T \mathbf{x}$$

最终的方程我们称之为正规方程。因为  $\mathbf{b}_1, \dots, \mathbf{b}_n$  是  $\mathbb{U}$  的基。因此  $B^T B$  是可逆的 ( $B^T B\mathbf{y} = \mathbf{0} \implies \mathbf{y}^T B^T B\mathbf{y} = 0 \implies B\mathbf{y} = \mathbf{0}$ )。也就是说

$$\boldsymbol{\lambda} = (B^T B)^{-1} B^T \mathbf{x}$$

## 2. 确定 $\pi_{\mathbb{U}}(\mathbf{x})$

$$\boldsymbol{\lambda} = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{x}$$

$\boldsymbol{\lambda}$  也就是  $\pi_{\mathbb{U}}(\mathbf{x})$  在有序基底  $\mathbf{B}$  下的坐标。

$$\pi_{\mathbb{U}}(\mathbf{x}) = \mathbf{B}\boldsymbol{\lambda} = \mathbf{B}(\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{x}$$

## 3. 确定 $P_{\pi}$

由上面的讨论容易看出

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

## 例 5

已知  $\mathbb{R}^3$  中的子空间  $U = \text{span} \left\{ \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ 2 \end{pmatrix} \right\}$  和向量  $\boldsymbol{x} = \begin{pmatrix} 6 \\ 0 \\ 0 \end{pmatrix}$ ,

确定  $\boldsymbol{x}$  投影到  $U$  上的坐标  $\boldsymbol{\lambda}$  和投影点  $\pi_U(\boldsymbol{x})$  和投影矩阵  $\boldsymbol{P}_\pi$

解

首先确定  $\boldsymbol{B} = \begin{pmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \end{pmatrix}$

其次计算

$$\boldsymbol{B}^T \boldsymbol{B} = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 1 & 2 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \end{pmatrix} = \begin{pmatrix} 3 & 3 \\ 3 & 5 \end{pmatrix}, \quad \boldsymbol{B}^T \boldsymbol{x} = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 1 & 2 \end{pmatrix} \begin{pmatrix} 6 \\ 0 \\ 0 \end{pmatrix} = \begin{pmatrix} 6 \\ 0 \end{pmatrix}$$

然后只需要解方程  $B^T B \boldsymbol{\lambda} = B^T \boldsymbol{x}$  得到  $\boldsymbol{\lambda}$ ,

$$\begin{pmatrix} 3 & 3 \\ 3 & 5 \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \lambda_2 \end{pmatrix} = \begin{pmatrix} 6 \\ 0 \end{pmatrix} \iff \boldsymbol{\lambda} = \begin{pmatrix} 5 \\ -3 \end{pmatrix}$$

故投影点  $\pi_{\mathbb{W}}(\boldsymbol{x}) = B\boldsymbol{\lambda} = \begin{pmatrix} 5 \\ 2 \\ -1 \end{pmatrix}$  最后

$$P_{\pi} = B(B^T B)^{-1} B^T = \frac{1}{6} \begin{pmatrix} 5 & 2 & -1 \\ 2 & 2 & 2 \\ -1 & 2 & 5 \end{pmatrix}$$


我们还可以验证  $P_{\pi}^2 = P_{\pi}$

- 投影使我们可以研究线性系统  $\mathbf{Ax} = \mathbf{b}$  没有解的情况。
- 回想一下，这意味着  $\mathbf{b}$  不在  $\mathbf{A}$  的范围内，即向量  $\mathbf{b}$  不在  $\mathbf{A}$  的列张成的子空间中。
- 鉴于线性方程无法精确求解，我们可以找到一个近似解。
- 想法是在最接近  $\mathbf{b}$  的  $\mathbf{A}$  列张成的子空间中找到向量，即，我们计算  $\mathbf{b}$  到  $\mathbf{A}$  列张成的子空间上的正交投影。
- 此问题在实践中经常出现，并且解被称为超定系统的最小二乘解。
- 这将在后面进一步讨论。

## 7.3.4 投影到仿射子空间

到目前为止，我们讨论了如何将向量投影到低维子空间  $U$  上。

下面，我们将讨论如何将向量投影到仿射子空间上。



(a) Setting.



(b) Reduce problem to projection  $\pi_U$  onto vector subspace.(c) Add support point back in to get affine projection  $\pi_L$ .

图 2: 投影到仿射空间


考虑图 (a)。给定一个仿射空间  $\mathbb{L} = \mathbf{x}_0 + \mathbb{U}$ ，其中  $\mathbf{b}_1, \mathbf{b}_2$  是  $\mathbb{U}$  的基向量。为了确定  $\mathbf{x}$  在  $\mathbb{L}$  上的正交投影  $\pi_{\mathbb{L}}(\mathbf{x})$ 。

我们将问题转化为我们知道如何解决的问题：投影到向量子空间上。为此，我们从  $\mathbf{x}$  和  $\mathbb{L}$  中减去支撑点  $\mathbf{x}_0$ ，所以  $\mathbb{L} - \mathbf{x}_0 = \mathbb{U}$  恰好是向量子空间  $\mathbb{U}$ 。



现在，我们前面讨论过的在子空间上的投影，获得投影  $\pi_{\mathbb{U}}(\mathbf{x} - \mathbf{x}_0)$ ，如图 (b) 所示。

最后我们通过添加  $\mathbf{x}_0$  将该投影转换回  $\mathbb{L}$ ，这样我们就可以得出仿射空间  $\mathbb{L}$  上的正交投影为

$$\pi_{\mathbb{L}}(\mathbf{x}) = \mathbf{x}_0 + \pi_{\mathbb{U}}(\mathbf{x} - \mathbf{x}_0)$$



(a) Setting.

(b) Reduce problem to projection  $\pi_{\mathbb{U}}$  onto vector subspace.(c) Add support point back in to get affine projection  $\pi_{\mathbb{L}}$ .

- 1 7.1 四个基本子空间
- 2 7.2 四个子空间的正交关系
- 3 7.3 正交投影
- 4 7.4 正交基与 Gram-Schmit**

### 7.4.1 标准正交基

线性代数中已经学过，线性空间中的向量可以由该空间的一组基表示。

[回忆：标准正交基]

设  $n$  维向量  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_r$  是向量空间  $\mathbb{V} (\mathbb{V} \subset \mathbb{R}^n)$  的一个基，如果  $\mathbf{e}_1, \dots, \mathbf{e}_r$  两两正交，且都是单位向量，即对于  $\forall i, j = 1, \dots, r$ ，有

$$\langle \mathbf{e}_i, \mathbf{e}_j \rangle = \begin{cases} 0, i \neq j \\ 1, i = j \end{cases}$$

则称  $\mathbf{e}_1, \dots, \mathbf{e}_r$  是  $\mathbb{V}$  的一个规范 (标准) 正交基，有时也简称做正交基。

为什么需要标准正交基的概念？用标准正交基表示向量有什么好处呢？

### 7.4.1 标准正交基

若  $\mathbf{e}_1, \dots, \mathbf{e}_r$  是  $\mathbb{V}$  的一个规范正交基, 那么  $\mathbb{V}$  中任意向量  $\mathbf{a}$  可以由  $\mathbf{e}_1, \dots, \mathbf{e}_r$  线性表示, 设表示为

$$\mathbf{a} = \lambda_1 \mathbf{e}_1 + \lambda_2 \mathbf{e}_2 + \dots + \lambda_r \mathbf{e}_r,$$

为求其中的系数  $\lambda_i (i = 1, \dots, r)$ , 可以计算  $\mathbf{e}_i$  与  $\mathbf{a}$  的内积, 有

$$\langle \mathbf{e}_i, \mathbf{a} \rangle = \langle \mathbf{e}_i, \lambda_1 \mathbf{e}_1 + \lambda_2 \mathbf{e}_2 + \dots + \lambda_r \mathbf{e}_r \rangle = \lambda_1 \langle \mathbf{e}_i, \mathbf{e}_1 \rangle + \lambda_2 \langle \mathbf{e}_i, \mathbf{e}_2 \rangle + \dots + \lambda_r \langle \mathbf{e}_i, \mathbf{e}_r \rangle = \lambda_i$$

即

$$\lambda_i = \langle \mathbf{a}, \mathbf{e}_i \rangle$$

利用这个公式能方便地求得向量的坐标。

因此, 我们给向量空间取基时常常取标准正交基。

本讲最后一节应用投影的思想, 确定  $\text{Col}(\mathbf{A})$  中的一组标准正交基。

## 投影与基的正交化

设  $\mathbf{a}_1, \dots, \mathbf{a}_r$  是向量空间  $\mathcal{V}$  的一个基: 我们的目的是找到一组正交基  $\mathbf{e}_1, \dots, \mathbf{e}_r$  使得

$$\text{span}\{\mathbf{e}_1, \dots, \mathbf{e}_r\} = \text{span}\{\mathbf{a}_1, \dots, \mathbf{a}_r\}$$

我们可以这样做, 我们先取  $\mathbf{a}_1$  作为一个基。那么  $\mathbf{a}_2$  可以正交分解

$$\mathbf{a}_2 = \mathbf{a}_2^{(1)} + \mathbf{a}_2^{(2)},$$

其中  $\mathbf{a}_2^{(1)} \in \text{Col}((\mathbf{a}_1))$ ,  $\mathbf{a}_2^{(2)} \in \text{Null}((\mathbf{a}_1)^T)$ 。利用投影公式:

$$\mathbf{a}_2^{(1)} = \frac{\langle \mathbf{b}_1, \mathbf{a}_2 \rangle}{\langle \mathbf{b}_1, \mathbf{b}_1 \rangle} \mathbf{b}_1$$

$$\mathbf{a}_2^{(2)} = \mathbf{a}_2 - \frac{\langle \mathbf{b}_1, \mathbf{a}_2 \rangle}{\langle \mathbf{b}_1, \mathbf{b}_1 \rangle} \mathbf{b}_1$$

我们记  $\mathbf{a}_2^{(2)}$  为  $\mathbf{b}_2$ 。并把  $\mathbf{b}_2$  添加到正交基中,  $\text{span}\{\mathbf{a}_1, \mathbf{a}_2\} = \text{span}\{\mathbf{b}_1, \mathbf{b}_2\}$ 。注意这里  $\mathbf{b}_1, \mathbf{b}_2$  还不是标准正交基。

假设我们已经有了了一组有序正交基底  $\mathbf{B}_k = (\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_k)$ , 那么  $\mathbf{a}_{k+1}$  可以正交分解

$$\mathbf{a}_{k+1} = \mathbf{a}_{k+1}^{(1)} + \mathbf{a}_{k+1}^{(2)},$$

其中  $\mathbf{a}_{k+1}^{(1)} \in \text{Col}(\mathbf{B}_k)$ ,  $\mathbf{a}_{k+1}^{(2)} \in \text{Null}(\mathbf{B}_k^\top)$ 。利用投影公式:

$$\begin{aligned} \mathbf{a}_{k+1}^{(1)} &= \pi_{\text{Col}(\mathbf{B}_k)}(\mathbf{a}_{k+1}) = \mathbf{B}_k(\mathbf{B}_k^\top \mathbf{B}_k)^{-1} \mathbf{B}_k^\top \mathbf{a}_{k+1} \\ &= (\mathbf{b}_1, \dots, \mathbf{b}_k) \begin{pmatrix} \langle \mathbf{b}_1, \mathbf{b}_1 \rangle & \cdots & \langle \mathbf{b}_1, \mathbf{b}_k \rangle \\ \cdots & \ddots & \cdots \\ \langle \mathbf{b}_k, \mathbf{b}_1 \rangle & \cdots & \langle \mathbf{b}_k, \mathbf{b}_k \rangle \end{pmatrix}^{-1} \begin{pmatrix} \langle \mathbf{b}_1, \mathbf{a}_{k+1} \rangle \\ \vdots \\ \langle \mathbf{b}_k, \mathbf{a}_{k+1} \rangle \end{pmatrix} \end{aligned}$$

而  $\{\mathbf{b}_1, \dots, \mathbf{b}_k\}$  是相互正交的。也就是说若  $i \neq j$ ,  $\langle \mathbf{b}_i, \mathbf{b}_j \rangle = 0$ 。

所以

$$\begin{aligned} \mathbf{a}_{k+1}^{(1)} &= (\mathbf{b}_1, \dots, \mathbf{b}_k) \begin{pmatrix} \langle \mathbf{b}_1, \mathbf{b}_1 \rangle & & \\ & \ddots & \\ & & \langle \mathbf{b}_k, \mathbf{b}_k \rangle \end{pmatrix}^{-1} \begin{pmatrix} \langle \mathbf{b}_1, \mathbf{a}_{k+1} \rangle \\ \vdots \\ \langle \mathbf{b}_k, \mathbf{a}_{k+1} \rangle \end{pmatrix} \\ &= \frac{\langle \mathbf{b}_1, \mathbf{a}_{k+1} \rangle}{\langle \mathbf{b}_1, \mathbf{b}_1 \rangle} \mathbf{b}_1 + \frac{\langle \mathbf{b}_2, \mathbf{a}_{k+1} \rangle}{\langle \mathbf{b}_2, \mathbf{b}_2 \rangle} \mathbf{b}_2 + \dots + \frac{\langle \mathbf{b}_k, \mathbf{a}_{k+1} \rangle}{\langle \mathbf{b}_k, \mathbf{b}_k \rangle} \mathbf{b}_k \end{aligned}$$

而  $\mathbf{a}_{k+1}^{(2)} = \mathbf{a}_{k+1} - \mathbf{a}_{k+1}^{(1)}$ , 我们记  $\mathbf{a}_{k+1}^{(2)}$  为  $\mathbf{b}_{k+1}$ , 并把  $\mathbf{b}_{k+1}$  添加到正交基中,

$\text{span}\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_{k+1}\} = \text{span}\{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_{k+1}\}$ 。

以此类推, 我们可以得到  $\{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_r\}$  使得

$$\text{span}\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_r\} = \text{span}\{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_r\}.$$

只需要再把这组基单位化即可。

## 7.4.2 Gram-Schmidt 正交化

总结之前的过程，可以通过以下方法求得  $\mathbb{V}$  的一个规范正交基  $\mathbf{e}_1, \dots, \mathbf{e}_r$ 。

这种方法称为 Gram-Schmidt 正交化。

取

$$\mathbf{b}_1 = \mathbf{a}_1;$$

$$\mathbf{b}_2 = \mathbf{a}_2 - \frac{\langle \mathbf{b}_1, \mathbf{a}_2 \rangle}{\langle \mathbf{b}_1, \mathbf{b}_1 \rangle} \mathbf{b}_1;$$

.....

$$\mathbf{b}_r = \mathbf{a}_r - \frac{\langle \mathbf{b}_1, \mathbf{a}_r \rangle}{\langle \mathbf{b}_1, \mathbf{b}_1 \rangle} \mathbf{b}_1 - \frac{\langle \mathbf{b}_2, \mathbf{a}_r \rangle}{\langle \mathbf{b}_2, \mathbf{b}_2 \rangle} \mathbf{b}_2 - \dots - \frac{\langle \mathbf{b}_{r-1}, \mathbf{a}_r \rangle}{\langle \mathbf{b}_{r-1}, \mathbf{b}_{r-1} \rangle} \mathbf{b}_{r-1}$$

然后把它们单位化，取

$$\mathbf{e}_1 = \frac{1}{\|\mathbf{b}_1\|} \mathbf{b}_1, \mathbf{e}_2 = \frac{1}{\|\mathbf{b}_2\|} \mathbf{b}_2, \dots, \mathbf{e}_r = \frac{1}{\|\mathbf{b}_r\|} \mathbf{b}_r$$

就是  $\mathbb{V}$  的一个规范正交基。

## 例 6

求向量组  $\mathbf{a}_1 = (3, 1, 1)^T$ ,  $\mathbf{a}_2 = (2, 2, 0)^T$  的生成子空间的标准正交基。

取

$$\mathbf{b}_1 = (3, 1, 1)^T$$

$$\mathbf{b}_2 = \mathbf{a}_2 - \frac{\mathbf{b}_1^T \mathbf{a}_2}{\mathbf{b}_1^T \mathbf{b}_1} \mathbf{b}_1 = (2, 2, 0)^T - \frac{8}{11} (3, 1, 1)^T = \frac{-2}{11} (1, -7, 4)^T$$

$$\mathbf{e}_1 = \frac{1}{\sqrt{11}} (3, 1, 1)^T$$

$$\mathbf{e}_2 = \frac{1}{\sqrt{66}} (1, -7, 4)^T$$

故标准正交基为  $\mathbf{e}_1, \mathbf{e}_2$ : 即,

$$\frac{1}{\sqrt{11}} (3, 1, 1)^T, \frac{1}{\sqrt{66}} (1, -7, 4)^T$$