

线性代数基础

机器学习版

VCG

数据的表示：向量与空间

向量

- 在机器学习中，向量 $\mathbf{v} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n]^T$
 - 作为数据点 (Data Point)
 - n 维特征空间中的一个位置
 - 静态的视角
 - 作为空间矢量 (Geometric Vector)
 - 从原点出发，具有方向和长度的箭头
 - 定义了空间中的一个“运动”或“位移”
 - 动态的视角

向量的线性无关

【线性组合】给定 $\mathbb{R}^n$ 中向量 $\mathbf{v}_1, \dots, \mathbf{v}_p$ 和标量 $c_1, \dots, c_p$, 向量

$$\mathbf{y} = c_1 \mathbf{v}_1 + \dots + c_p \mathbf{v}_p$$

称为向量 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p$ 以 $c_1, c_2, \dots, c_p$ 为权的线性组合【数乘和加法】

【Span】若 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p$ 是 $\mathbb{R}^n$ 中的向量, $\text{Span}\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p\}$ 称为由 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p$ 所生成(张成)的 $\mathbb{R}^n$ 的子集,即,

$$\text{Span}\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p\} = \{c_1 \mathbf{v}_1 + \dots + c_p \mathbf{v}_p | c_1, c_2, \dots, c_p \text{ 为标量}\}$$

向量空间

【向量空间】

一个向量空间是由向量构成的非空集合 V 。且定义了运算：加法和标量乘法。

对 V 中所有向量 $\mathbf{u}$, $\mathbf{v}$, $\mathbf{w}$ 及所有标量 c 和 d , 满足

- $\mathbf{u}$, $\mathbf{v}$ 之和(表示为 $\mathbf{u} + \mathbf{v}$)属于 V
- $\mathbf{u} + \mathbf{v} = \mathbf{v} + \mathbf{u}$
- $(\mathbf{u} + \mathbf{v}) + \mathbf{w} = \mathbf{u} + (\mathbf{v} + \mathbf{w})$
- V 中存在一个零向量 $\mathbf{0}$, 使得 $\mathbf{u} + \mathbf{0} = \mathbf{u}$
- 对 V 中每个向量 $\mathbf{u}$, 存在 V 中一个向量 $-\mathbf{u}$, 使得 $\mathbf{u} + (-\mathbf{u}) = \mathbf{0}$
- $\mathbf{u}$ 与标量 c 的标量乘法(记为 $c\mathbf{u}$)属于 V
- $c(\mathbf{u} + \mathbf{v}) = c\mathbf{u} + c\mathbf{v}$
- $(c + d)\mathbf{u} = c\mathbf{u} + d\mathbf{u}$
- $c(d\mathbf{u}) = (cd)\mathbf{u}$
- $1\mathbf{u} = \mathbf{u}$

子空间

【子空间】 向量空间 V 的子集 H ，如果 H 满足以下三个性质，则成 H 为 V 的子空间:

V 中的零向量在 H 中

H 对向量加法封闭，即对 H 中任意向量 u ， v ，和 $u + v$ 仍在 H 中

H 对标量乘法封闭，即对 H 中任意向量 u 和任意标量 c ，向量 cu 仍在 H 中

子空间的基：线性无关集；标准基

【基】 $\mathbb{R}^n$ 中子空间 H 的一组基是 H 中一个线性无关集，它生成 H

可逆 $n \times n$ 矩阵的各列构成 $\mathbb{R}^n$ 的一组基，因为它们线性无关，而且生成 $\mathbb{R}^n$

【标准基 $\mathcal{E}$ 】 $n \times n$ 单位矩阵，它的各列用 $\mathbf{e}_1, \dots, \mathbf{e}_n$:

$$\mathbf{e}_1 = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \quad \mathbf{e}_2 = \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix}, \quad \dots, \quad \mathbf{e}_n = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix}$$

$\{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ 称为 $\mathbb{R}^n$ 的标准基 $\mathcal{E}$




图 2-27 $\mathbb{R}^3$ 的标准基

数据的操作：矩阵与线性变换

矩阵：数据集合 vs. 空间变换

➤ 一个矩阵 A 有两种核心视角

➤ 数据集合 (Container of Data)

- 每一行或每一列是一个数据样本或特征

- 例如：一个用户-物品评分矩阵

- 静态的视角

➤ 线性变换 (Linear Transformation)

- 一个函数，将一个输入向量 x 映射到一个输出向量 $y = Ax$

- 描述空间运动：将整个输入空间进行旋转、缩放、切变等操作，变成一个新的输出空间

- 动态的，也是线性代数最核心的视角

矩阵向量乘法的本质：基向量的“着陆点”

【矩阵与向量乘法】 $m \times n$ 矩阵 $\mathbf{A} = [\mathbf{a}_1 \quad \mathbf{a}_2 \quad \cdots \quad \mathbf{a}_n]$ 。 $\mathbf{x} \in \mathbb{R}^n$ ，则 $\mathbf{A}$ 与 $\mathbf{x}$ 的积(记为 $A\mathbf{x}$)

$$A\mathbf{x} = [\mathbf{a}_1 \quad \mathbf{a}_2 \quad \cdots \quad \mathbf{a}_n] \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_n \end{bmatrix} = \mathbf{x}_1 \mathbf{a}_1 + \mathbf{x}_2 \mathbf{a}_2 + \cdots + \mathbf{x}_n \mathbf{a}_n$$

通常把矩阵 $\mathbf{A}$ 当作一种对象，它通过乘法“作用”于向量 $\mathbf{x}$ ，产生的新向量称为 $A\mathbf{x}$ 。

解方程 $A\mathbf{x} = \mathbf{b}$ ，就是要求出所有经过乘以 $\mathbf{A}$ 的“作用”后变为 $\mathbf{b}$ 的向量 $\mathbf{x}$

线性变换 T 的标准矩阵

$A\mathbf{x}$ 可以看作是 A 代表的 $\text{span}\{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ 空间中， $\mathbf{x}$ 作为权重生成的变量

【矩阵变换定理】设 $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$ 为线性变换，则存在唯一的矩阵 A ，使得对 $\mathbb{R}^n$ 中一切 $\mathbf{x}$ ，

$$T(\mathbf{x}) = A\mathbf{x}$$

事实上， A 是 $m \times n$ 矩阵，它的第 j 列是向量 $T(\mathbf{e}_j)$ ，其中 $\mathbf{e}_j$ 是 $\mathbb{R}^n$ 中单位矩阵 I_n 的第 j 列：

$$A = [T(\mathbf{e}_1) \cdots T(\mathbf{e}_n)]$$


矩阵 A 称为线性变换 T 的标准矩阵。

矩阵乘法

【矩阵乘法】矩阵 $\mathbf{B}$ 乘以向量 $\mathbf{x}$ （将 $\mathbf{x}$ 变换 $\mathbf{Bx}$ ），向量 $\mathbf{Bx}$ 再乘以矩阵 $\mathbf{A}$ ，得 $\mathbf{A(Bx)}$ 。于是， $\mathbf{x}$ 经复合映射（对应矩阵 $\mathbf{AB}$ ）变换得到 $\mathbf{A(Bx)}$ ：

$$\mathbf{A(Bx)} = (\mathbf{AB})\mathbf{x}$$

【矩阵的组合预算】



矩阵的逆，可逆矩阵，奇异矩阵

【可逆矩阵】一个 $n \times n$ 矩阵 A 是可逆的，若存在一个 $n \times n$ 矩阵 C 使

$$CA = I, AC = I$$

其中 $I = I_n$ 是 $n \times n$ 单位矩阵。这时称 C 是 A 的逆

若 A 可逆，它的逆是唯一的，记为 A^{-1} ，于是

$$A^{-1}A = I, \text{ 且 } AA^{-1} = I$$

不可逆矩阵有时称为奇异矩阵，而可逆矩阵也称为非奇异矩阵

坐标系，坐标，线性变换

线性变换

【线性变换】线性变换 T 将向量空间 V 中的 x 映射成向量空间 W 中唯一向量 $T(x)$ ，且：

$T(u + v) = T(u) + T(v)$ ，对 V 中所有 u, v 均成立

$T(cu) = cT(u)$ ，对 V 中所有 u 及所有数 c 均成立

线性无关集

【线性无关集】 V 中向量的一个指标集 $\{\mathbf{v}_1, \dots, \mathbf{v}_p\}$ 称为线性无关，如果向量方程

$$c_1\mathbf{v}_1 + c_2\mathbf{v}_2 + \dots + c_p\mathbf{v}_p = \mathbf{0}$$

只有平凡解（即 $c_1 = 0, \dots, c_p = 0$ ）

集合 $\{\mathbf{v}_1, \dots, \mathbf{v}_p\}$ 称为线性相关，如果方程有一个非平凡的解

基和标准基


【基】 H 是向量空间 V 的子空间。 V 中一组向量 $\mathcal{B} = \{\mathbf{b}_1, \dots, \mathbf{b}_p\}$ 称为 H 的一个基，如果

- $\mathcal{B}$ 是一线性无关集。
- 由 $\mathcal{B}$ 生成的子空间与 H 相同，即 $H = \text{Span}\{\mathbf{b}_1, \dots, \mathbf{b}_p\}$

基是：最小的生成集(再小生成不了 H)； 最大线性无关集(再多一个就不是线性无关)

【标准基】单位矩阵 $\mathbf{I}_n = [\mathbf{e}_1 \cdots \mathbf{e}_n]$ ， $\mathcal{E} = \{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ 是 $\mathbb{R}^n$ 中的标准基

基 $\mathcal{B}$ 引导了一个新的坐标系， $\{\mathbf{b}_1, \dots, \mathbf{b}_p\}$ 为基（坐标轴）为在标准坐标系下的表达



坐标系与坐标

对一个向量空间 V ，指定一个基 $\mathcal{B}$ ：在 V 上加上一个“坐标系”，给 V 以一个新的“视角”。

【坐标】 $\mathcal{B} = \{b_1, \dots, b_n\}$ 是 V 的一个基, 记 $P_{\mathcal{B}} = [b_1 \cdots b_n]$, $[x]_{\mathcal{B}} = \begin{bmatrix} c_1 \\ \vdots \\ c_n \end{bmatrix}$ 。如

$$x = c_1 b_1 + \cdots + c_n b_n, \text{ 即 } x = P_{\mathcal{B}}[x]_{\mathcal{B}}$$

则，称向量 $[x]_{\mathcal{B}}$ 为 x (相对于基 $\mathcal{B}$)的坐标向量（或， x 的 $\mathcal{B}$ -坐标向量）


称 $P_{\mathcal{B}}$ 为从 $\mathcal{B}$ 到标准基 $\mathcal{E}$ 的坐标变换矩阵 $P_{\mathcal{B}}^{\mathcal{E} \leftarrow \mathcal{B}}$ 。【 $\mathcal{B}$ 中的向量，乘以 $P_{\mathcal{B}}$ ，变换到 $\mathcal{E}$ 】

【坐标映射】 (由 $\mathcal{B}$ 确定的)坐标映射 $x \mapsto [x]_{\mathcal{B}}$:

$$[x]_{\mathcal{B}} = P_{\mathcal{B}}^{-1}x$$

$$b_1 = [b_1]_{\mathcal{E}}$$

【坐标变换矩阵和坐标映射矩阵是逆变换】



基的变换（坐标系变换）

【定理】 向量空间 V 的基 $\mathcal{B} = \{\mathbf{b}_1, \dots, \mathbf{b}_n\}$ 和 $\mathcal{C} = \{\mathbf{c}_1, \dots, \mathbf{c}_n\}$, 称为由 $\mathcal{B}$ 到 $\mathcal{C}$ 的坐标变换矩阵 $\mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}}$, 将 $\mathcal{B}$ -坐标向量 转成 $\mathcal{C}$ -坐标向量, 即

$$[\mathbf{x}]_{\mathcal{C}} = \mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}} [\mathbf{x}]_{\mathcal{B}}$$

那么

$$\mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}} = [[\mathbf{b}_1]_{\mathcal{C}} \quad [\mathbf{b}_2]_{\mathcal{C}} \quad \dots \quad [\mathbf{b}_n]_{\mathcal{C}}] = \mathbf{P}_{\mathcal{C}}^{-1} \mathbf{P}_{\mathcal{B}}$$

【计算过程】

$$[[\mathbf{x}]_{\mathcal{C}}]_{\mathbb{R}^n} = \mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}} [\mathbf{x}]_{\mathcal{B}}, \text{ 两边同时乘以 } \mathbf{P}_{\mathcal{C}}$$

$$\mathbf{P}_{\mathcal{C}} [[\mathbf{x}]_{\mathcal{C}}]_{\mathbb{R}^n} = \mathbf{P}_{\mathcal{C}} \mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}} [\mathbf{x}]_{\mathcal{B}}, \text{ 又 } \mathbf{P}_{\mathcal{C}} [[\mathbf{x}]_{\mathcal{C}}]_{\mathbb{R}^n} = [\mathbf{x}]_{\mathcal{B}}, \text{ 所以}$$

$$\mathbf{P}_{\mathcal{B}} [[\mathbf{x}]_{\mathcal{B}}]_{\mathbb{R}^n} = \mathbf{P}_{\mathcal{C}} \mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}} [\mathbf{x}]_{\mathcal{B}}, \text{ 于是 } \mathbf{P}_{\mathcal{C} \leftarrow \mathcal{B}} = \mathbf{P}_{\mathcal{C}}^{-1} \mathbf{P}_{\mathcal{B}}$$

相当于, $\mathcal{B}$ -坐标到标准坐标, 再映射到 $\mathcal{C}$ -坐标





FIGURE 2 Two coordinate systems for V .

特征值与特征向量


矩阵特征向量和特征值：线性变换内在结构的描述

- 特征向量和特征值：描述线性变换核心的，不随观察坐标系改变的性质
 - 变换的主轴
 - 特征向量定义了线性变换的“主运动方向”。 $Ax = \lambda x$
 - 空间形变的骨架与自然坐标系 (Natural Coordinate System)
 - 标准形状（单位圆）线性变换后变成椭圆，特征向量（不一定正交）为变换骨架
 - 变换矩阵A在特征向量组成的“自然”坐标系（变换P）下，变成沿坐标轴缩放的对角矩阵D

同一个变换 T，在不同坐标系下的观察



变换 T 表现为复杂的剪切和旋转



变换 T 简化为纯粹的沿轴缩放

$$Ax = (PDP^{-1})x$$

➤ $P^{-1}x$:

- 把头歪过来，让视线和物体的主轴对齐，变换到自然坐标系

➤ $DP^{-1}x$:

- 在自然坐标系下，沿着坐标轴缩放

➤ $(PDP^{-1})x$

- 把头摆正，回到原来的观察角度


矩阵特征值与特征向量

【特征值与特征向量】 A 为 $n \times n$ 矩阵， $\mathbf{x}$ 为非零向量，若存在数 λ 使

$$A\mathbf{x} = \lambda\mathbf{x}$$

有非平凡解 $\mathbf{x}$ ，则称 λ 为 A 的特征值， $\mathbf{x}$ 称为对应于 λ 的特征向量

1. 矩阵与向量相乘是一种线性变换
2. 特征向量经过矩阵变换后，方向与原方向保持一致（缩放系数为特征值）



可逆矩阵，正交矩阵

可逆矩阵 (Invertible Matrix)

- 方阵 $A_{n \times n}$ 被称为可逆的 (Invertible) 或非奇异的 (Non-singular)
 - 存在方阵 $B_{n \times n}$ ，使得 $AB = BA = I$ 。其中 $I_{n \times n}$ 是单位矩阵。矩阵 $B = A^{-1}$ 是 A 的逆矩阵 (Inverse Matrix)
- 【可逆矩阵代表了一种“良好”的、不丢失信息的、可以撤销的线性变换】
- 变换 T 是双射
 - 单射：不同的输入向量 x 必然映射到不同的输出向量 y
 - 满射：整个目标空间中的每一个点 y 都能在输入空间中找到一个对应的点 x
 - 可逆：存在一个逆变换 $T^{-1}(x) = A^{-1}x$ ，可以将变换后的结果完美地还原回去
- 变换 T 不会“压扁”空间 ($\det(A) \neq 0$)
 - 将 n 维空间映射到 n 维空间，而不是降维到一条线或一个平面。变换后图形的体积不为零

正交矩阵

- 正交矩阵 $\mathbf{P}$ 满足 $\mathbf{P}^{-1} = \mathbf{P}^T$ 。显然，正交矩阵是可逆矩阵
- 【正交矩阵所代表的线性变换只有旋转或者反射，没有缩放，剪切或形变】
- 行向量和列向量是标准正交基
 - 任意不同的列向量（或行向量）的点积为 0（互相垂直）；列向量（或行向量）模长为 1
- 行列式的值为 +1 或 -1
 - 1，变换保向，代表旋转；-1，变换反向，代表反射或旋转加反射；体积没有变化
- 特征值的模长为 1
 - 变换不会在任何特征向量方向上进行缩放，与 " 保持长度 " 的几何特性一致
- 保持内积 / 点积
 - $\mathbf{Q}\mathbf{x} \cdot \mathbf{Q}\mathbf{y} = \mathbf{x} \cdot \mathbf{y}$
 - 保持向量间的夹角：向量之间的夹角，变换前后不变，没有发生剪切或形变
 - 保持向量长度：向量在经过正交变换后不会被拉伸或压缩

相似矩阵，对角化

相似性

【矩阵相似】假如 $\mathbf{A}$ 和 $\mathbf{B}$ 是 $n \times n$ 矩阵，如果存在可逆矩阵 $\mathbf{P}$ ，使得

$$\mathbf{P}^{-1}\mathbf{A}\mathbf{P} = \mathbf{B}$$

则称 $\mathbf{A}$ 相似于 $\mathbf{B}$ 。(那么 $\mathbf{B}$ 也相似于 $\mathbf{A}$ ， $\mathbf{A} = \mathbf{P}\mathbf{B}\mathbf{P}^{-1}$)

称 $\mathbf{A}$ 和 $\mathbf{B}$ 是相似的，把 $\mathbf{A}$ 变成 $\mathbf{P}^{-1}\mathbf{A}\mathbf{P}$ 的变换称为相似变换

【定理】若 $n \times n$ 矩阵 $\mathbf{A}$ 和 $\mathbf{B}$ 是相似的，那么它们有相同的特征多项式，从而有相同的特征值(和相同的重数)

【注】

即使有相同的特征值也可能不相似

相似性与行等价不一样。(假如 $\mathbf{B}$ 行等价于 $\mathbf{A}$ ，则存在可逆矩阵 $\mathbf{E}$ ，使得 $\mathbf{B} = \mathbf{E}\mathbf{A}$ 。)对矩阵作行变换通常会改变矩阵的特征值

相似矩阵的几何意义


若 A 相似于 C ，即 $A = PCP^{-1}$

记 $P = [b_1 \cdots b_n]$ ， $\mathcal{B} = \{b_1, \cdots, b_n\}$ ，则 P 是坐标变换矩阵 $P_{\mathcal{B}}$ ，其中

$$x = P[x]_{\mathcal{B}}, \quad [x]_{\mathcal{B}} = P^{-1}x$$

则 C 是变换 $x \mapsto Ax$ 的 $\mathcal{B}$ -矩阵【 C 代表变换在 $\mathcal{B}$ 坐标系下的矩阵】

即， $A = PCP^{-1}$



【几何意义】

相似矩阵为线性变换在不同坐标系下的，不同的矩阵表达形式

对向量的变换，可以看作：转换到 $\mathcal{B}$ 坐标系（ P^{-1} ），变换（ C ），再回原来坐标系（ P ）

相似矩阵的不变量：特征值

- 所有相似的矩阵都具有相同的

- 特征值（特征多项式）

- 最重要的不变量！

- 特征值代表了变换在特征向量上的缩放因子。这些“固有”的缩放方向和比例是变换本身的“特征”

- 行列式

- 变换对空间体积的缩放比例

- 矩阵相似性的最终应用和目标，就是对角化

- 希望找到一个“最理想的视角”（由特征向量组成的基），在这个视角下，线性变换的表达形式变得极其简单(一个对角矩阵)

对角矩阵与对角化

【对角矩阵】对角矩阵(diagonal matrix)是一个主对角线之外的元素皆为0的矩阵。

$$\text{记作 } \mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n) = \begin{pmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{pmatrix}$$

在很多情况下，从分解式 $\mathbf{A} = \mathbf{P}\mathbf{D}\mathbf{P}^{-1}$ (其中， $\mathbf{D}$ 是对角矩阵)，能够了解到有关矩阵 $\mathbf{A}$ 的特征值和特征向量的信息

【对角化】如果方阵 $\mathbf{A}$ 相似于对角矩阵，即存在可逆矩阵 $\mathbf{P}$ 和对角矩阵 $\mathbf{D}$ ，使得

$$\mathbf{A} = \mathbf{P}\mathbf{D}\mathbf{P}^{-1}$$

则称 $\mathbf{A}$ 可对角化

对角化矩阵

【对角化】 $A_{n \times n}$ 有 n 个线性无关的特征向量，则 A 可对角化
假设 A 的 n 个线性无关的特征向量为 $\mathbf{v}_1, \mathbf{v}_2 \cdots \mathbf{v}_n$ （对应特征值 $\lambda_1, \dots, \lambda_n$ ）

令 $\mathbf{P} = [\mathbf{v}_1 \quad \mathbf{v}_2 \quad \cdots \quad \mathbf{v}_n]$ 为特征向量基变换矩阵，对角阵 $\mathbf{D} = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{bmatrix}$

那么， $\mathbf{AP} = [\mathbf{Av}_1 \quad \mathbf{Av}_2 \quad \cdots \quad \mathbf{Av}_n]$ ， $\mathbf{PD} = [\lambda_1 \mathbf{v}_1 \quad \lambda_2 \mathbf{v}_2 \quad \cdots \quad \lambda_n \mathbf{v}_n]$
 λ_i 和 $\mathbf{v}_i$ 分别为特征值和特征向量， $\mathbf{Av}_i = \lambda_i \mathbf{v}_i$ ，则 $\mathbf{AP} = \mathbf{PD}$

从而 $\mathbf{A} = \mathbf{PDP}^{-1}$ ，于是 A 对角化矩阵为 $\mathbf{D} = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & \lambda_n \end{bmatrix}$

【重要结论】

如果一个 n 阶方阵 A 有 n 个互不相同的特征值，那么它一定可以被对角化
任何一个实对称矩阵 ($A = A^T$) 都一定可以被对角化