



# 人工智能基础与进阶

## 数学基础

周 越

上海交通大学

# 目录 content



第一节 向量与特征表达

第二节 行列式

第三节 矩阵及运算

第四节 导数与梯度

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

## 第一节 向量与特征表达



上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

# 向量的基本定义



在数学中，向量（也称为欧几里得向量、几何向量、矢量），指具有大小（magnitude）和方向的量。它可以形象化地表示为带箭头的线段。箭头所指：代表向量的方向；线段长度：代表向量的大小。与向量对应的量叫做数量（物理学中称标量），数量（或标量）只有大小，没有方向。

向量的记法：印刷体记作黑体（粗体）的字母（如 $\mathbf{a}$ 、 $\mathbf{b}$ 、 $\mathbf{u}$ 、 $\mathbf{v}$ ），书写时在字母顶上加一小箭头“ $\rightarrow$ ”。如： $\vec{a}$ ,  $\vec{b}$

如果给定向量的起点（A）和终点（B），可将向量记作 $\overrightarrow{AB}$ （并于顶上加 $\rightarrow$ ）。在空间直角坐标系中，也能把向量以数对形式表示，如XOY平面中(2, 3)是一向量。如： $\overrightarrow{AB}$ , (2,3)

# 向量的基本定义

常见的二维空间里的向量和三维空间中的向量：



N维空间里的向量？

# 向量的基本定义

把若干个数字并列放在一起，彼此之间用刻个分隔，再用括号围起来，这种样子的数组就可以称为向量。如果有n个数字，称为n维向量。

比如  $(2, 35, 72, 24)$  就是一个4维向量。

用行的方式排列的向量叫作行向量，用列的方式排列的向量叫作列向量。如果是行向量，加上一个上标符号T，T代表转置

$$\vec{a} = [a_1 \quad a_2 \quad \cdots \quad a_n], \quad \vec{a}^T = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix}$$

# 向量的基本定义

## 向量的模

向量的大小，也就是向量的长度（或称模）。向量 $\vec{a}$ 的模记作 $|\vec{a}|$ 。

向量的模是非负实数，向量的模是可以比较大小的。向量  $\vec{a} = (x, y)$ ，

$$\|\vec{a}\| = \sqrt{x^2 + y^2}$$

因为方向不能比较大小，所以向量也就不能比较大小。对于向量来说  
“大于”和“小于”的概念是没有意义的。例如:  $\overrightarrow{AB} > \overrightarrow{CD}$  是没有意义的。

若向量  $\vec{a} = (a_1, a_2, a_3, \dots, a_n)$ ，模为：

$$\|\vec{a}\| = \sqrt{a_1^2 + a_2^2 + a_3^2 + \dots + a_n^2}$$


# 向量的基本运算

## 向量的数乘

向量的数乘就是向量和一个数字相乘，等于向量的各个分量都乘以相同的系数。向量数乘的几何意义就是把向量拉伸了 $k$ 倍。

$$\begin{bmatrix} a_1 \\ a_2 \end{bmatrix} \times k = \begin{bmatrix} ka_1 \\ ka_2 \end{bmatrix}$$

$$\begin{bmatrix} 1 \\ 3 \\ 4 \end{bmatrix} \times 7 = \begin{bmatrix} 7 \\ 21 \\ 28 \end{bmatrix}$$



# 向量的基本运算

## 向量的线性组合




把向量的加法和数乘组合起来就得到了向量的线性组合，之所以叫线性是因为加法和乘法都是线性运算。

$$\vec{a} = \begin{bmatrix} 1 \\ 3 \\ 4 \end{bmatrix}, \vec{b} = \begin{bmatrix} 2 \\ 11 \\ 6 \end{bmatrix}$$

$$4\vec{a} - 6\vec{b} = \begin{bmatrix} 4 \times 1 - 6 \times 2 \\ 4 \times 3 - 6 \times 11 \\ 4 \times 7 - 6 \times 6 \end{bmatrix} = \begin{bmatrix} -8 \\ -54 \\ -8 \end{bmatrix}$$

$$\vec{a} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}, \vec{b} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix}$$

$$m\vec{a} + n\vec{b} = \begin{bmatrix} ma_1 + nb_1 \\ ma_2 + nb_2 \end{bmatrix}$$



# 向量的基本运算

## 向量的乘法（点积）

两个向量的乘法（点积）等于两个向量对应元素之积的和。点积运算的公式如下：

$$\vec{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix}, \quad \vec{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix}$$


$$\vec{a} \cdot \vec{b} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix} \cdot \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix} = a_1 b_1 + a_2 b_2 + \cdots + a_n b_n$$

两个向量的点积得到的是一个数字，在数值上等于两个向量的长度和夹角余弦之积。因此两个向量的夹角余弦可以用一下的公式计算：

$$\cos \theta = \frac{\vec{a} \cdot \vec{b}}{\|\vec{a}\| \|\vec{b}\|}$$

# 数据特征的向量化

数据分析中最难解决的问题是数据的向量化，比如人脸识别和自然语言处理中，如何将人脸图像数据和语音的时序数据用一个向量表示。



$$\vec{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix}$$



$$\vec{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix}$$

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

## 第二节 行列式



上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

# 行列式的基本知识

行列式是线性代数的一个重要组成部分. 它是研究矩阵、线性方程组、特征多项式的重要工具. 本章介绍了 $n$ 阶行列式的定义、性质及计算方法, 最后给出了它的一个简单应用

——克莱姆法则.

# 行列式的基本知识

记号：
$$\begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix}$$
 称其为二阶行列式.

它表示数： $a_{11}a_{22} - a_{12}a_{21}$

即 
$$\begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} = a_{11}a_{22} - a_{12}a_{21}$$

对任何行列式，横排称为行，竖排称为列

$a_{ij}$  中  $i$  称为行标， $j$  称为列标。 $a_{ij}$  表示第  $i$  行第  $j$  列的元素。

左上角到右下角表示主对角线

# 行列式的基本知识

上海交通大学人工  
智能创新教育实验室

例 1  $\begin{vmatrix} 5 & -1 \\ 3 & 2 \end{vmatrix} = 5 \times 2 - (-1) \times 3 = 13$

例 2 设  $D = \begin{vmatrix} \lambda^2 & \lambda \\ 3 & 1 \end{vmatrix}$ ,

(1) 当  $\lambda$  为何值时,  $D = 0$ ,

(2) 当  $\lambda$  为何值时,  $D \neq 0$ .

解  $\lambda^2 - 3\lambda = 0 \iff \lambda = 0, \text{ 或 } \lambda = 3$

$$D = \begin{vmatrix} \lambda^2 & \lambda \\ 3 & 1 \end{vmatrix} = \lambda^2$$

# 行列式的基本知识

记号

$$\begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix}$$

称为三阶行列式.

它表示数

$$a_{11}a_{22}a_{33} + a_{12}a_{23}a_{31} + a_{13}a_{21}a_{32}$$

$$- a_{13}a_{22}a_{31} - a_{12}a_{21}a_{33} - a_{11}a_{23}a_{32}$$

即


$$\begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix}$$

$$= a_{11}a_{22}a_{33} + a_{12}a_{23}a_{31} + a_{13}a_{21}a_{32}$$

$$- a_{13}a_{22}a_{31} - a_{12}a_{21}a_{33} - a_{11}a_{23}a_{32}$$

# 行列式的基本知识

可以用对角线法则来记忆如下.



$$D = \begin{vmatrix} 1 & 2 & -4 \\ -2 & 2 & 1 \\ -3 & 4 & -2 \end{vmatrix}$$

$$\begin{aligned} D &= 1 \times 2 \times (-2) + 2 \times 1 \times (-3) + (-4) \times (-2) \times 4 \\ &\quad - (-4) \times 2 \times (-3) - 2 \times (-2) \times (-2) - 1 \times 1 \times 4 \\ &= -4 - 6 + 32 - 24 - 8 - 4 \\ &= -14 \end{aligned}$$

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

## 第三节 矩阵



上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

# 矩阵的基本定义

矩阵就是 $n$ 行 $m$ 列的二维表格。如果行数和列数相等，即 $n=m$ ，这样的矩阵就是方阵，否则就是非方阵。一个 $n$ 行 $n$ 列的方阵习惯称之为 $n$ 阶方阵。

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nm} \end{pmatrix} \quad B = \begin{pmatrix} 2 & 5 & -3 \\ -1 & 7 & 14 \end{pmatrix} \quad C = \begin{pmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{pmatrix}$$

如果一个矩阵只有一行，则称之为行向量；只有一列元素的矩阵则称之为列向量。B可以看作是由三个 $2 \times 1$ 的列向量构成，也可以看作是由两个 $1 \times 3$ 的行向量构成。

# 矩阵的基本定义

对于方阵，有种特殊的形态：对角矩阵D、单位矩阵E、对称矩阵F。

$$D = \begin{pmatrix} a_{11} & 0 & \cdots & 0 \\ 0 & a_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & a_{mm} \end{pmatrix}$$

除了对角线之外的元素都是0

$$E = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{pmatrix}$$

对角线元素全为1，其他全为0；对角线元素为1的对焦矩阵

$$F = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nm} \end{pmatrix}$$

且  $a_{ij} = a_{ji}$ , 对称矩阵的特点是  $A = A^T$ 。

$$A_1 = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 3 & 0 \\ 0 & 0 & 0 & 4 \end{pmatrix}$$
$$A_2 = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$
$$A_3 = \begin{pmatrix} 10 & 8 & 16 & 64 \\ 8 & 20 & 32 & 128 \\ 16 & 32 & 30 & 256 \\ 64 & 128 & 256 & 40 \end{pmatrix}$$

# 矩阵的基本运算

## 矩阵加法与数乘

矩阵的加法与数乘运算是向量对应运算的延伸：

- 两个大小相同的矩阵的加法就是把其对应元素相加；
- 数字乘以矩阵就是把矩阵中的每一个元素与这个数字相乘。

## 矩阵乘法

矩阵之间定义的乘法是：如果矩阵A为 $m \times n$ 大小的矩阵，矩阵B为 $n \times p$ 大小的矩阵，那么矩阵AB为 $m \times p$ 大小矩阵，其元素为

$$(AB)_{ij} = \sum_{k=1}^n a_{ik} b_{kj} = a_{i1} b_{1j} + a_{i2} b_{2j} + \cdots + a_{in} b_{nj}$$

$$\begin{matrix} \square & \square & \square & \square \\ \blacksquare & \blacksquare & \blacksquare & \blacksquare \\ \square & \square & \square & \square \\ \blacksquare & \blacksquare & \blacksquare & \blacksquare \\ \square & \square & \square & \square \end{matrix} \times \begin{matrix} \square & \blacksquare & \square & \square \\ \blacksquare & \blacksquare & \square & \square \\ \square & \square & \square & \square \\ \blacksquare & \blacksquare & \square & \square \\ \square & \square & \square & \square \end{matrix} = \begin{matrix} \square & \blacksquare & \square & \square \\ \blacksquare & \blacksquare & \square & \square \\ \square & \square & \square & \square \\ \blacksquare & \blacksquare & \square & \square \\ \square & \square & \square & \square \end{matrix}$$

$$\begin{matrix} \square & \square & \square \\ \blacksquare & \blacksquare & \blacksquare \\ \square & \square & \square \end{matrix} \times \begin{matrix} \square & \blacksquare \\ \blacksquare & \blacksquare \\ \square & \square \end{matrix} = \begin{matrix} \square & \blacksquare \\ \blacksquare & \blacksquare \\ \square & \square \end{matrix}$$

# 矩阵的基本运算

矩阵乘法满足结合律

$$(AB)C = A(BC) = ABC$$

矩阵乘法-左右分配律

$$(A+B)C = AB + BC$$

$$C(A+B) = CA + CB$$

矩阵的乘法一般不满足交换律，即使AB和BA都有定义，通常

$$AB \neq BA$$

$$\begin{pmatrix} 1 & 4 \\ 2 & 3 \end{pmatrix} \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix} = \begin{pmatrix} 0 & 4 \\ 0 & 3 \end{pmatrix} \quad \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 1 & 4 \\ 2 & 3 \end{pmatrix} = \begin{pmatrix} 0 & 0 \\ 2 & 3 \end{pmatrix}$$

矩阵乘法中需要明确相乘的顺序，AB称为B右乘A，或A左乘B。

向量的点积可以用矩阵乘法表示，两个n维向量r和v的点积，可以看做是行向量 $r^T$ 与列向量v的矩阵乘法。

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

## 第四节 导数与梯度



上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

上海交通大学人工  
智能创新教育实验室

# 导数基本概念

## 平均变化率

如果两个不同的变量 $x_1$ 和 $x_2$ , 分别对应不同的因变量 $y_1$  $y_2$ , 要表示 $y = f(x)$ 在 $x_1$ 和 $x_2$ 之间变化的快慢, 只需将因变量的变化( $\Delta y = y_2 - y_1 = f(x_2) - f(x_1)$ )除以自变量的变化( $\Delta x = x_2 - x_1$ ), 即


$$\frac{\Delta y}{\Delta x} = \frac{y_2 - y_1}{x_2 - x_1} = \frac{f(x_2) - f(x_1)}{x_2 - x_1}$$

上式称为函数 $y = f(x)$ 从 $x_1$ 到 $x_2$ 的平均变化率, 也可以写成如下形式:

$$\frac{f(x_1 + \Delta x) - f(x_1)}{\Delta x}$$

# 导数基本概念

## 平均变化率



平均变化率在函数图像上的意义为 $x_1$ 和 $x_2$ 对应的 $P_1$ 和 $P_2$ 之间连线（函数的割线）的斜率。

对于一次线性函数：

$$y = f(x) = ax + b$$

计算它在  $x = x_0$  的平均变化率：

$$\frac{\Delta y}{\Delta x} = \frac{f(x_0 + \Delta x) - f(x_0)}{\Delta x}$$

$$= \frac{a(x_0 + \Delta x) + b - (ax_0 + b)}{\Delta x}$$
$$= \frac{a\Delta x}{\Delta x} = a$$

线性函数的平均变化率就是它的斜率

# 导数基本概念

## 瞬时变化率

平均变换率是在 $\Delta x$ 内对应函数 $y = f(x)$ 的变化速度。当 $\Delta x$ 越取越小，不断逼近0， $x_1$ 和 $x_2$ 也会越来越近，直至几乎变为同一个点。在这种情况下，原先定义的平均变化率也逐渐变为 $y = f(x)$ 在 $(x_1, y_2)$ 这一点处瞬间所具有的变化速度，称为瞬间变化率，记作：

$$\lim_{\Delta x \rightarrow 0} \frac{f(x_1 + \Delta x) - f(x_1)}{\Delta x}$$

极限符号 $\lim_{x \rightarrow c} f(x)$ 表示 $x$ 趋于 $c$ 时函数 $f(x)$ 的值。计算表明，在 $\Delta x$ 趋于0时，上式的值趋于一个定值，即为函数在这一点的导数。

# 导数基本概念

## 瞬时变化率

一个二次函数  $y = f(x) = x^2$  在  $x = 1$  附近的变化率，有

$$\frac{f(1 + \Delta x) - f(1)}{\Delta x} = \frac{(1 + \Delta x)^2 - 1^2}{\Delta x} = \frac{2\Delta x + (\Delta x)^2}{\Delta x} = 2 + \Delta x$$

而当  $\Delta x$  趋于 0 时，不难看出，这个式子的值趋于一个定值 2，即

$$\lim_{\Delta x \rightarrow 0} \frac{f(1 + \Delta x) - f(1)}{\Delta x} = 2$$

# 导数基本概念

## 导数的定义

假设函数 $y = f(x)$ 在某个区间上的导数存在，则在此区间上的某个点 $(x_1, f(x_1))$ 处的导数定义为：

$$f'(x_1) = \lim_{\Delta x \rightarrow 0} \frac{f(x_1 + \Delta x) - f(x_1)}{\Delta x}$$

此区间上所有点的导数构成以 $x$ 为自变量的函数，称为导函数（有时也简称为导数），记为 $f'(x)$ （或 $y'$ ,  $\frac{dy}{dx}$ ,  $\frac{df}{dx}$ ）。

寻找已知的函数在某点的导数或者其导函数的过程称之为求导。不难看出，当 $\Delta x$ 趋于0时，点 $x_1 + \Delta x$ 与 $x_1$ 无限接近，原本的割线变为函数图像的切线。因此导数的几何意义为函数 $y = f(x)$ 的图像在点 $(x_1, f(x_1))$ 处切线的斜率。

# 导数基本概念

## 导数的定义

常见的导数公式：

$$C' = 0 \quad (C \text{ 为常数});$$

$$(x^\mu)' = \mu x^{\mu-1};$$

$$(a^x)' = a^x \ln a;$$

$$(e^x)' = e^x;$$

$$(\log_a x)' = \frac{1}{x \ln a};$$

$$(\ln x)' = \frac{1}{x};$$

$$(\sin x)' = \cos x;$$

$$(\cos x)' = -\sin x;$$

导数计算的一些主要性质如下

两个函数的和差：

$$(u \pm v)' = u' \pm v';$$

两个函数的积

$$(uv)' = u'v + uv';$$

两个函数的商

$$\left(\frac{u}{v}\right)' = \frac{u'v + uv'}{v^2}$$

复合函数：

$$\{f[\varphi(x)]\}' = f'[\varphi(x)]\varphi'(x)$$

或  $\frac{df}{dx} = \frac{df}{d\varphi} \cdot \frac{d\varphi}{dx}$  (链式法则)

# 高阶导数和偏导数

导数 $f'(x)$ 本身也可以视作是自变量 $x$ 的函数，因此可以在导数的基础上再次求导，得到高阶导数。例如二阶导数： $y = f(x)$ 的一阶导数为

$y' = f'(x)$ ,  $f'(x)$ 的导数就是 $f(x)$ 的二阶导数，记作 $y''$ ，或者 $f''(x)$ ,  $\frac{d^2y}{dx^2}$ 。


上述讨论的函数默认为是一个自变量。若函数的自变量多于一个自变量，为一多元函数 $y = f(x_1, x_2, \dots)$ ，研究它的变化率也是一个有意义的问题，这里就引入偏导数的概念。

在数学中，一个多变量函数的偏导数，是它关于其中一个变量的导数，而保持其他变量不变。例如： $z = x^2 + 3xy + 2y^2$ ,  $x$ 和 $y$ 的偏导数：


$$\frac{\partial z}{\partial x} = 2x + 3y \quad \frac{\partial z}{\partial y} = 3x + 4y$$

# 导数与函数极值


$$f''(x_0) > 0$$



$$f''(x_0) < 0$$



$$f''(x_0) = 0$$



# 梯度

## 方向导数


方向导数是偏导数的概念的推广, 偏导数研究的是指定方向(坐标轴方向)的变化率。函数在某一点处的方向导数在其梯度方向上达到最大值, 此最大值即梯度的范数。

## 梯 度

函数在某一点处的方向导数在其梯度方向上达到最大值。

这就是说, 沿梯度方向, 函数值增加最快。同样可知, 方向导数的最小值在梯度的相反方向取得, 此最小值为最大值的相反数, 从而沿梯度相反方向函数值的减少最快。

# 梯度



梯度的本意是一个向量（矢量），表示某一函数在该点处的方向导数沿着该方向取得最大值，即函数在该点处沿着该方向（此梯度的方向）变化最快，变化率最大（为该梯度的模）。

比如在一个三维直角坐标系，该函数的梯度就可以表示为公式：

$$\nabla f = \left( \frac{\partial f}{\partial x}, \frac{\partial f}{\partial y}, \frac{\partial f}{\partial z} \right)$$