

# 矩阵微分

## 目录

在实际计算过程中，按照定义求解矩阵梯度往往不现实。如果还要计算Hessian 矩阵就更复杂了。那么有没有简单的办法呢？有。矩阵微分为标量函数，向量函数和矩阵函数的梯度矩阵与Hessian矩阵的计算提供了便捷的算法。

矩阵微分是实函数微分对矩阵函数的推广。在微积分中，函数 $\phi(x)$ 的导数 $\phi'(x)$ 定义为：

$$\phi'(x) = \lim_{\Delta x \rightarrow 0} \frac{\phi(x + \Delta x) - \phi(x)}{\Delta x} \quad (1)$$

式(1)又可以写为：

$$\phi(x + \Delta x) = \phi(x) + \Delta x \phi'(x) + r_x(\Delta) \quad (2)$$

式(2)中 $r_x(\Delta x)$ 是 $\phi(x)$ 的留数，有 $\lim_{\Delta x \rightarrow 0} \frac{r_x(\Delta x)}{\Delta x} = 0$ 。 $\phi(x + \Delta x) - \phi(x)$ 由两部分构成：与导数成正比的分量 $\Delta x \phi'(x)$ 和误差分量。如果误差分量可以忽略不计则函数 $\phi(x + \Delta x) = \phi(x) + \Delta x \phi'(x)$

把上述定义推广到向量，即可得到向量函数的微分。令 $\mathbf{c}$ 和 $\mathbf{u}$ 是两个 $(n \times 1)$ 向量，其中 $\mathbf{c}$ 是 $m \times 1$ 向量函数 $\mathbf{f}(x)$ 的向量变元，而 $\mathbf{u}$ 是 $R^n$ 中的一个点，并且 $\|\mathbf{u}\|_2 < r$ 。若存在一个 $m \times n$ 的矩阵 $\mathbf{A}$ ，它与 $\mathbf{c}$ 有关，但与 $\mathbf{u}$ 无关，并且使得：

$$\mathbf{f}(\mathbf{c} + \mathbf{u}) = \mathbf{f}(\mathbf{c}) + \mathbf{A}(\mathbf{c})\mathbf{u} + r_c(\mathbf{u}) \quad (3)$$

对所有具有 $\|\mathbf{u}\|_2 < r$ 的 $n \times 1$ 实向量 $\mathbf{u}$ 恒成立，以及：

$$\lim_{\mathbf{u} \rightarrow \mathbf{0}} \frac{r_c(\mathbf{u})}{\|\mathbf{u}\|_2} = 0 \quad (4)$$

则称函数 $f$ 在向量点 $\mathbf{c}$ 是可微分的。称 $m \times n$ 矩阵 $\mathbf{A}(\mathbf{c})$ 是函数 $f$ 在 $\mathbf{c}$ 的一阶导数，并称 $m \times 1$ 向量

$$df(\mathbf{c}; \mathbf{u}) = \mathbf{A}(\mathbf{c})\mathbf{u} \quad (5)$$

是 $f$ 在 $\mathbf{c}$ 的一阶微分向量。

现在考虑另外一个向量点 $\mathbf{c} + t\mathbf{e}_j$ ，其中 $\mathbf{e}_j$ 是一个仅第 $j$ 个元素为1，其他元素为0的 $n \times 1$ 的基本向量。 $t$ 是非零标量。换句话说 $\mathbf{c}$ 与 $\mathbf{c} + t\mathbf{e}_j$ 只第 $j$ 个元素不同。当 $t$ 足够小时，极限：

$$D_j \mathbf{f}_i(\mathbf{c}) = \lim_{t \rightarrow 0} \frac{f_i(\mathbf{c} + t\mathbf{e}_j) - f_i(\mathbf{c})}{t} \quad (6)$$

称为向量函数 $\mathbf{f}$ 的第 $i$ 个元素相对于向量变元 $\mathbf{c}$ 的第 $j$ 个元素的偏导。

根据以上定义， $n$ 个偏导的排列 $[D_1 \mathbf{f}_i(\mathbf{c}), D_2 \mathbf{f}_i(\mathbf{c}), \dots, D_n \mathbf{f}_i(\mathbf{c})]$ 。定义了向量函数 $f(\mathbf{c})$ 的第 $i$ 个元素 $\mathbf{f}_i(\mathbf{c})$ 相对于 $1 \times n$ 行向量 $\mathbf{c}^T$ 的偏导向量，即有：

$$\frac{\partial \mathbf{f}_i(\mathbf{c})}{\partial \mathbf{c}^T} = [D_1 \mathbf{f}_i(\mathbf{c}), D_2 \mathbf{f}_i(\mathbf{c}), \dots, D_n \mathbf{f}_i(\mathbf{c})] \quad (7)$$

于是，列向量 $\mathbf{f}(\mathbf{c}) = [\mathbf{f}_1(\mathbf{c}), \mathbf{f}_2(\mathbf{c}), \dots, \mathbf{f}_m(\mathbf{c})]^T$ 相对于行向量 $\mathbf{c}^T = [c_1, c_2, \dots, c_n]$ 的偏导数矩阵为 $m \times n$ 矩阵。定义为：

$$D[\mathbf{f}(\mathbf{c})] = \begin{bmatrix} \frac{\partial \mathbf{f}_1(\mathbf{c})}{\partial \mathbf{c}^T} \\ \frac{\partial \mathbf{f}_2(\mathbf{c})}{\partial \mathbf{c}^T} \\ \vdots \\ \frac{\partial \mathbf{f}_m(\mathbf{c})}{\partial \mathbf{c}^T} \end{bmatrix} = \begin{bmatrix} D_1 \mathbf{f}_1(\mathbf{c}) & D_2 \mathbf{f}_1(\mathbf{c}) & \dots & D_n \mathbf{f}_1(\mathbf{c}) \\ D_1 \mathbf{f}_2(\mathbf{c}) & D_2 \mathbf{f}_2(\mathbf{c}) & \dots & D_n \mathbf{f}_2(\mathbf{c}) \\ \vdots & \vdots & \dots & \vdots \\ D_1 \mathbf{f}_m(\mathbf{c}) & D_2 \mathbf{f}_m(\mathbf{c}) & \dots & D_n \mathbf{f}_m(\mathbf{c}) \end{bmatrix} \quad (8)$$

矩阵微分有很多性质和单变量函数微分性质类似，此处不再一一列举。只待用到的时候再去查阅工具书。