

矩阵梯度

张朝龙

目录

1 简介	1
2 实值函数相对于实向量的梯度	1
3 实值函数的梯度矩阵	6
4 迹函数的梯度矩阵	8
5 Hessian矩阵	9
6 尾声	11

1 简介

在信息论或者机器学习的论文中，有很多黑体矢量的微分或者积分，再加上梯度函数，简直让人眼花缭乱。于是下定决心把这些黑体的矩阵语言仔细学习一下。出来混迟早是要还的，记得在大学的时候这个矩阵语言属于三不管：数学分析和线性代数都不管，其他课程就更不管了。今天属于还债日。

2 实值函数相对于实向量的梯度

相对于 $n \times 1$ 向量 \mathbf{x} 的梯度算子记作 $\nabla_{\mathbf{x}}$,定义为:

$$\nabla_{\mathbf{x}} = \left[\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n} \right]^T = \frac{\partial}{\partial \mathbf{x}} \quad (2.1)$$



因此, $n \times 1$ 实向量 \mathbf{x} 为变元的实标量函数 $f(\mathbf{x})$ 相对于 \mathbf{x} 的梯度为一 $n \times 1$ 的列向量, 定义为:

$$\nabla_{\mathbf{x}} f(\mathbf{x}) = \left[\frac{\partial f(\mathbf{x})}{\partial x_1}, \frac{\partial f(\mathbf{x})}{\partial x_2}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right]^T = \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} \quad (2.2)$$

梯度方向的负方向成为变元 \mathbf{x} 的梯度流 (gradient flow), 记为:

$$\dot{\mathbf{x}} = -\nabla_{\mathbf{x}} f(\mathbf{x}) \quad (2.3)$$

从梯度的定义式可以看出:

1. 一个以向量为变元的变量函数的梯度为一向量。
2. 梯度的每个分量给出了变量函数在该分量方向上的变化率

梯度向量最重要的性质之一是, 它指出了当变元增大时函数 f 的最大增大率。相反, 梯度的负值 (负梯度) 指出了当变元增大时函数 f 的最大减小率。根据这样一种性质, 即可设计出求一函数极小值的迭代算法。

类似地, 实值函数 $f(\mathbf{x})$ 相对于 $1 \times n$ 行向量 \mathbf{x}^T 的梯度为 $1 \times n$ 行向量, 定义为:

$$\nabla_{\mathbf{x}^T} f(\mathbf{x}) = \left[\frac{\partial f(\mathbf{x})}{\partial x_1}, \frac{\partial f(\mathbf{x})}{\partial x_2}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right] = \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}^T} \quad (2.4)$$

m 维行向量函数 $f(\mathbf{x}) = [f_1(\mathbf{x}), \dots, f_m(\mathbf{x})]$ 相对于 n 维实向量 x 的梯度为一 $n \times m$ 矩阵定义为:

$$\frac{\partial \mathbf{f}(\mathbf{x})}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \frac{\partial f_2(\mathbf{x})}{\partial x_1} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_1} \\ \frac{\partial f_1(\mathbf{x})}{\partial x_2} & \frac{\partial f_2(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_2} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial f_1(\mathbf{x})}{\partial x_n} & \frac{\partial f_2(\mathbf{x})}{\partial x_n} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_n} \end{bmatrix} = \nabla_{\mathbf{x}} \mathbf{f}(\mathbf{x}) \quad (2.5)$$

若 $m \times 1$ 向量函数 $\mathbf{f}(\mathbf{x}) = \mathbf{y} = [y_1, \dots, y_m]^T$, 其中 y_1, y_2, \dots, y_m 是向量的标量函数, 一阶梯度:

$$\frac{\partial \mathbf{y}}{\partial \mathbf{x}^T} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_1}{\partial x_2} & \dots & \frac{\partial y_1}{\partial x_n} \\ \frac{\partial y_2}{\partial x_1} & \frac{\partial y_2}{\partial x_2} & \dots & \frac{\partial y_2}{\partial x_n} \\ \vdots & \vdots & \dots & \vdots \end{bmatrix} \quad (2.6)$$

$\frac{\partial \mathbf{y}}{\partial \mathbf{x}^T}$ 是一个 $m \times n$ 的矩阵, 称为向量函数 $\mathbf{y} = [y_1, y_2, \dots, y_m]^T$ 的 Jacobi 矩阵。

若 $\mathbf{f}(\mathbf{x}) = [x_1, x_2, \dots, x_n]$, 则:

$$\frac{\partial \mathbf{x}^T}{\partial \mathbf{x}} = \mathbf{I} \quad (2.7)$$



这是一个非常有用的结论，将帮助我们导出更多非常有用的结论。

例 2.1

若 \mathbf{A} 和 \mathbf{y} 均和 \mathbf{x} 无关，则：

$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{y}}{\partial \mathbf{x}} = \frac{\partial \mathbf{x}^T}{\partial \mathbf{x}} \mathbf{A} \mathbf{y} = \mathbf{A} \mathbf{y} \quad (2.8)$$

例 2.2

因为 $\mathbf{y}^T \mathbf{A} \mathbf{x} = \langle \mathbf{A}^T \mathbf{y}, \mathbf{x} \rangle = \langle \mathbf{x}, \mathbf{A}^T \mathbf{y} \rangle = \mathbf{x}^T \mathbf{A}^T \mathbf{y}$ ，则：

$$\frac{\partial \mathbf{y}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}} = \mathbf{A}^T \mathbf{y} \quad (2.9)$$

例 2.3

由于：

$$\mathbf{x}^T \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j \quad (2.10)$$

所以梯度 $\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}}$ 的第 k 个分量为：

$$\left[\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}} \right]_k = \frac{\partial}{\partial x_k} \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j = \sum_{i=1}^n A_{ik} x_i + \sum_{j=1}^n A_{kj} x_j \quad (2.11)$$

即有：

$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}} = \mathbf{A} \mathbf{x} + \mathbf{A}^T \mathbf{x} \quad (2.12)$$

特别的如果 \mathbf{A} 为对称矩阵则有：

$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}} = 2 \mathbf{A} \mathbf{x} \quad (2.13)$$

归纳以上三个例子的结果以及其他结果，便得到实值函数 $f(\mathbf{x})$ 相对于列向量 \mathbf{x} 的一下几个常用的梯度公式。

例 2.4

若 $f(\mathbf{x}) = c$ 为常数，则梯度 $\frac{\partial c}{\partial \mathbf{x}} = 0$

**例 2.5**

线性法则：若 $f(\mathbf{x})$ 和 $g(\mathbf{x})$ 分别是向量 \mathbf{x} 的实值函数， c_1 和 c_2 为实常数，则：

$$\frac{\partial [c_1 f(\mathbf{x}) + c_2 g(\mathbf{x})]}{\partial \mathbf{x}} = c_1 \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} + c_2 \frac{\partial g(\mathbf{x})}{\partial \mathbf{x}} \quad (2.14)$$

例 2.6

乘法法则：若 $f(\mathbf{x})$ 和 $g(\mathbf{x})$ 都是向量 \mathbf{x} 的实值函数，则：

$$\frac{\partial (f(\mathbf{x})g(\mathbf{x}))}{\partial \mathbf{x}} = g(\mathbf{x}) \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} + f(\mathbf{x}) \frac{\partial g(\mathbf{x})}{\partial \mathbf{x}} \quad (2.15)$$

例 2.7

商法则：若 $g(\mathbf{x}) \neq 0$ ，则：

$$\frac{\partial (f(\mathbf{x})/g(\mathbf{x}))}{\partial \mathbf{x}} = \frac{1}{g^2(\mathbf{x})} \left[g(\mathbf{x}) \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} - f(\mathbf{x}) \frac{\partial g(\mathbf{x})}{\partial \mathbf{x}} \right] \quad (2.16)$$

例 2.8

链式法则：若 $\mathbf{y}(\mathbf{x})$ 是 \mathbf{x} 的向量值函数，则：

$$\frac{\partial f(\mathbf{y}(\mathbf{x}))}{\partial \mathbf{x}} = \frac{\partial \mathbf{y}^T(\mathbf{x})}{\partial \mathbf{x}} \frac{\partial f(\mathbf{y})}{\partial \mathbf{y}} \quad (2.17)$$

式中 $\frac{\partial \mathbf{y}^T(\mathbf{x})}{\partial \mathbf{x}}$ 为 $n \times n$ 矩阵。

例 2.9

若 $n \times 1$ 向量 \mathbf{a} 与 \mathbf{x} 是无关的常数向量，则：

$$\frac{\partial \mathbf{a}^T \mathbf{x}}{\partial \mathbf{x}} = \mathbf{a} \quad \frac{\partial \mathbf{x}^T \mathbf{a}}{\partial \mathbf{x}} = \mathbf{a} \quad (2.18)$$

**例 2.10**

若 $n \times 1$ 向量 \mathbf{a} 与 \mathbf{x} 是无关的常数向量, 则:

$$\frac{\partial \mathbf{a}^T \mathbf{y}(\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial \mathbf{y}^T(\mathbf{x})}{\partial \mathbf{x}} \mathbf{a} \quad \frac{\partial \mathbf{y}^T(\mathbf{x}) \mathbf{a}}{\partial \mathbf{x}} = \frac{\partial \mathbf{y}^T(\mathbf{x})}{\partial \mathbf{x}} \mathbf{a} \quad (2.19)$$

例 2.11

若 \mathbf{A} 和 \mathbf{y} 均与 \mathbf{x} 无关, 则:

$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{y}}{\partial \mathbf{x}} = \mathbf{A} \mathbf{y} \quad \frac{\partial \mathbf{y}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}} = \mathbf{A}^T \mathbf{y} \quad (2.20)$$

例 2.12

若 \mathbf{A} 是与 \mathbf{x} 无关, 而 $\mathbf{y}(\mathbf{x})$ 与向量 \mathbf{x} 的元素有关, 则:

$$\frac{\partial [\mathbf{y}(\mathbf{x})]^T \mathbf{A} \mathbf{y}(\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial [\mathbf{y}(\mathbf{x})]^T}{\partial \mathbf{x}} (\mathbf{A} + \mathbf{A}^T) \mathbf{y}(\mathbf{x}) \quad (2.21)$$

例 2.13

若 \mathbf{A} 是一个与向量 \mathbf{x} 无关的矩阵, 而 $\mathbf{y}(\mathbf{x})$ 和 $\mathbf{z}(\mathbf{x})$ 是与向量 \mathbf{x} 的元素有关的列向量, 则:

$$\frac{\partial [\mathbf{y}(\mathbf{x})]^T \mathbf{A} \mathbf{z}(\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial [\mathbf{y}(\mathbf{x})]^T}{\partial \mathbf{x}} \mathbf{A} \mathbf{z}(\mathbf{x}) + \frac{\partial [\mathbf{z}(\mathbf{x})]^T}{\partial \mathbf{x}} \mathbf{A}^T \mathbf{y}(\mathbf{x}) \quad (2.22)$$

例 2.14

令 \mathbf{x} 为 $n \times 1$ 向量, \mathbf{a} 为 $m \times 1$ 常数向量, \mathbf{A} 和 \mathbf{B} 分别为 $m \times n$ 和 $m \times m$ 常数矩阵, 且 \mathbf{B} 为对称矩阵, 则:

$$\frac{\partial (\mathbf{a} - \mathbf{A} \mathbf{x})^T \mathbf{B} (\mathbf{a} - \mathbf{A} \mathbf{x})}{\partial \mathbf{x}} = -2 \mathbf{A}^T \mathbf{B} (\mathbf{a} - \mathbf{A} \mathbf{x}) \quad (2.23)$$



3 实值函数的梯度矩阵

在最优化问题中，需要最优化的对象可能是某个加权矩阵。因此，有必要分析实值函数相对于矩阵变元的梯度。

实值函数 $f(\mathbf{A})$ 相对于 $m \times n$ 是矩阵 \mathbf{A} 的梯度为一 $m \times n$ 矩阵，简称梯度矩阵，定义为：

$$\frac{\partial f(\mathbf{A})}{\partial \mathbf{A}} = \begin{bmatrix} \frac{\partial f(\mathbf{A})}{\partial A_{11}} & \frac{\partial f(\mathbf{A})}{\partial A_{12}} & \cdots & \frac{\partial f(\mathbf{A})}{\partial A_{1n}} \\ \frac{\partial f(\mathbf{A})}{\partial A_{21}} & \frac{\partial f(\mathbf{A})}{\partial A_{22}} & \cdots & \frac{\partial f(\mathbf{A})}{\partial A_{2n}} \\ \vdots & \vdots & \cdots & \vdots \\ \frac{\partial f(\mathbf{A})}{\partial A_{m1}} & \frac{\partial f(\mathbf{A})}{\partial A_{m2}} & \cdots & \frac{\partial f(\mathbf{A})}{\partial A_{mn}} \end{bmatrix} \quad (3.1)$$

式中 A_{ij} 是 \mathbf{A} 的元素。

实值函数相对于矩阵变元的梯度具有以下性质：

例 3.1

若 $f(\mathbf{A}) = c$ 是常数，其中 \mathbf{A} 为 $m \times n$ 矩阵，则梯度 $\frac{\partial c}{\partial \mathbf{A}} = \mathbf{O}_{m \times n}$

例 3.2

线性法则：若 $f(\mathbf{A})$ 和 $g(\mathbf{A})$ 分别是矩阵 \mathbf{A} 的实值函数， c_1, c_2 均为实常数，则：

$$\frac{\partial [c_1 f(\mathbf{A}) + c_2 g(\mathbf{A})]}{\partial \mathbf{A}} = c_1 \frac{\partial f(\mathbf{A})}{\partial \mathbf{A}} + c_2 \frac{\partial g(\mathbf{A})}{\partial \mathbf{A}} \quad (3.2)$$

例 3.3

乘积法则：若 $f(\mathbf{A}), g(\mathbf{A})$ 都是矩阵 \mathbf{A} 的实值函数，则：

$$\frac{\partial f(\mathbf{A})g(\mathbf{A})}{\partial \mathbf{A}} = f(\mathbf{A}) \frac{\partial g(\mathbf{A})}{\partial \mathbf{A}} + g(\mathbf{A}) \frac{\partial f(\mathbf{A})}{\partial \mathbf{A}} \quad (3.3)$$

例 3.4

商法则：若 $g(\mathbf{A}) \neq 0$ ，则：

$$\frac{\partial f(\mathbf{A})/g(\mathbf{A})}{\partial \mathbf{A}} = \frac{1}{[g(\mathbf{A})]^2} \left[g(\mathbf{A}) \frac{\partial f(\mathbf{A})}{\partial \mathbf{A}} - f(\mathbf{A}) \frac{\partial g(\mathbf{A})}{\partial \mathbf{A}} \right] \quad (3.4)$$

**例 3.5**

链式法则：令 \mathbf{A} 为 $m \times n$ 的矩阵，且 $y = f(\mathbf{A})$ 和 $g(y)$ 分别是以矩阵 \mathbf{A} 和标量 y 为变元的实值函数，则：

$$\frac{\partial g(f(\mathbf{A}))}{\partial \mathbf{A}} = \frac{dg(y)}{dy} \frac{\partial f(\mathbf{A})}{\partial \mathbf{A}} \quad (3.5)$$

例 3.6

若 $\mathbf{A} \in R^{m \times n}, \mathbf{x} \in R^{m \times 1}, \mathbf{y} \in R^{n \times 1}$ ，则：

$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{y}}{\partial \mathbf{A}} = \mathbf{x} \mathbf{y}^T \quad (3.6)$$

例 3.7

若 $\mathbf{A} \in R^{n \times n}$ 非奇异， $\mathbf{x} \in R^{n \times 1}, \mathbf{y} \in R^{n \times 1}$ ，则：

$$\frac{\partial \mathbf{x}^T \mathbf{A}^{-1} \mathbf{y}}{\partial \mathbf{A}} = -\mathbf{A}^{-T} \mathbf{x} \mathbf{y}^T \mathbf{A}^{-T} \quad (3.7)$$

例 3.8

若 $\mathbf{A} \in R^{m \times n}, \mathbf{x} \in R^{n \times 1}, \mathbf{y} \in R^{n \times 1}$ ，则：

$$\frac{\partial \mathbf{x}^T \mathbf{A}^T \mathbf{A} \mathbf{y}}{\partial \mathbf{A}} = \mathbf{A}(\mathbf{x} \mathbf{y}^T + \mathbf{y} \mathbf{x}^T) \quad (3.8)$$

例 3.9

若 $\mathbf{A} \in R^{m \times n}, \mathbf{x}, \mathbf{y} \in R^{m \times 1}$ ，则：

$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{A}^T \mathbf{y}}{\partial \mathbf{A}} = (\mathbf{x} \mathbf{y}^T + \mathbf{y} \mathbf{x}^T) \mathbf{A} \quad (3.9)$$

**例 3.10**

指数函数的梯度:

$$\frac{\partial \exp(\mathbf{x}^T \mathbf{A} \mathbf{y})}{\partial \mathbf{A}} = \mathbf{xy}^T \exp(\mathbf{x}^T \mathbf{A} \mathbf{y}) \quad (3.10)$$

4 迹函数的梯度矩阵

有时候, 二次型目标函数可以利用矩阵的迹加以重写。因为一标量可以视为 1×1 的矩阵, 所以二次型目标函数的迹直接等同于函数本身, 即 $f(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x} = \text{tr}(\mathbf{x}^T \mathbf{A} \mathbf{x})$ 利用迹的性质, 又可以将目标函数进一步表示为:

$$f(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x} = \text{tr}(\mathbf{x}^T \mathbf{A} \mathbf{x}) = \text{tr}(\mathbf{A} \mathbf{x} \mathbf{x}^T) \quad (4.1)$$

因此, 二次型目标函数 $\mathbf{x}^T \mathbf{A} \mathbf{x}$ 等于核矩阵 \mathbf{A} 和向量外积 $\mathbf{x} \mathbf{x}^T$ 的乘积的迹 $\text{tr}(\mathbf{A} \mathbf{x} \mathbf{x}^T)$

例 4.1

对于 $n \times n$ 矩阵 \mathbf{A} , 由于 $\text{tr}(\mathbf{A}) = \sum_{i=1}^n A_{ii}$, 故梯度 $\frac{\partial \text{tr}(\mathbf{A})}{\partial \mathbf{A}}$ 的 (i, j) 元素为:

$$\left[\frac{\partial \text{tr}(\mathbf{A})}{\partial \mathbf{A}} \right]_{ij} = \frac{\partial}{\partial A_{ij}} \sum_{k=1}^n A_{kk} = \begin{cases} 1 & j = i \\ 0 & j \neq i \end{cases} \quad (4.2)$$

所以有 $\frac{\partial \text{tr}(\mathbf{A})}{\partial \mathbf{A}} = \mathbf{I}$

**例 4.2**

考察目标函数 $f(\mathbf{A}) = \text{tr}(\mathbf{AB})$ ，其中 \mathbf{A} 和 \mathbf{B} 分别为 $m \times n$ 和 $n \times m$ 实矩阵。首先，矩阵乘积的元素为 $[\mathbf{AB}]_{ij} = \sum_{l=1}^n A_{il}B_{lj}$ ，故矩阵乘积的迹 $\text{tr}(\mathbf{AB}) = \sum_{p=1}^m \sum_{l=1}^n A_{pl}B_{lp}$ ，于是，梯度 $\frac{\partial \text{tr}(\mathbf{AB})}{\partial \mathbf{A}}$ 是一个 $m \times n$ 矩阵，其元素为：

$$\left[\frac{\partial \text{tr}(\mathbf{AB})}{\partial \mathbf{A}} \right]_{ij} = \frac{\partial}{\partial A_{ij}} \left(\sum_{p=1}^m \sum_{l=1}^n A_{pl}B_{lp} \right) = B_{ji} \quad (4.3)$$

所以有：

$$\frac{\partial \text{tr}(\mathbf{AB})}{\partial \mathbf{A}} = \nabla_{\mathbf{A}} \text{tr}(\mathbf{AB}) = \mathbf{B}^T \quad (4.4)$$

由于 $\text{tr}(\mathbf{BA}) = \text{tr}(\mathbf{AB})$ 所以：

$$\frac{\partial \text{tr}(\mathbf{AB})}{\partial \mathbf{A}} = \frac{\partial \text{tr}(\mathbf{BA})}{\partial \mathbf{A}} = \mathbf{B}^T \quad (4.5)$$

同理，由于 $\text{tr}(\mathbf{xy}^T) = \text{tr}(\mathbf{yx}^T) = \mathbf{x}^T \mathbf{y}$ ，所以有：

$$\frac{\partial \text{tr}(\mathbf{xy}^T)}{\partial \mathbf{x}} = \frac{\partial \text{tr}(\mathbf{yx}^T)}{\partial \mathbf{x}} = \mathbf{y} \quad (4.6)$$

5 Hessian矩阵

实值函数 $f(\mathbf{x})$ 相对于 $m \times 1$ 实向量 \mathbf{x} 的二阶偏导是一个由 m^2 个二阶偏导组成的矩阵，称为Hessian矩阵，定义为：

$$\frac{\partial^2 f(\mathbf{x})}{\partial \mathbf{x} \partial \mathbf{x}^T} = \frac{\partial}{\partial \mathbf{x}^T} \left[\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} \right] \quad (5.1)$$

或者简写为梯度的梯度：

$$\nabla_{\mathbf{x}}^2 f(\mathbf{x}) = \nabla_{\mathbf{x}} (\nabla_{\mathbf{x}} f(\mathbf{x})) \quad (5.2)$$

根据定义，Hessian矩阵的第 j 列是梯度 $\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = \nabla_{\mathbf{x}} f(\mathbf{x})$ 第 j 个分量的梯度，即：

$$\left[\frac{\partial^2 f(\mathbf{x})}{\partial \mathbf{x} \partial \mathbf{x}^T} \right]_{i,j} = \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} \quad (5.3)$$



或者可以写作:

$$\frac{\partial^2 f(\mathbf{x})}{\partial \mathbf{x} \partial \mathbf{x}^T} = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n \partial x_n} \end{bmatrix}$$

(5.4)

因此, Hessian矩阵可以通过两个步骤计算得出:

1. 求实值函数 $f(\mathbf{x})$ 关于向量变元 \mathbf{x} 的偏导数, 得到实值函数的梯度 $\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}}$
2. 再求梯度 $\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}}$ 相对于 $1 \times n$ 行向量 \mathbf{x}^T 的偏导数, 得到梯度的梯度即Hessian矩阵

根据以上步骤, 得到Hessian矩阵的下列公式。

例 5.1

对于 $n \times 1$ 的常数向量 \mathbf{a}^T , 有:

$$\frac{\partial^2 \mathbf{a}^T \mathbf{x}}{\partial \mathbf{x} \partial \mathbf{x}^T} = \mathbf{O}_{n \times n} \quad (5.5)$$

例 5.2

若 \mathbf{A} 是 $n \times n$ 矩阵, 则:

$$\frac{\partial^2 \mathbf{x}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x} \partial \mathbf{x}^T} = \mathbf{A} + \mathbf{A}^T \quad (5.6)$$

例 5.3

令 \mathbf{x} 为 $n \times 1$ 向量, \mathbf{a} 为 $m \times 1$ 常数向量, \mathbf{A} 和 \mathbf{B} 分别为 $m \times n$ 和 $m \times m$ 常数矩阵, 且 \mathbf{B} 为对称矩阵, 则:

$$\frac{\partial^2 (\mathbf{a} - \mathbf{A} \mathbf{x})^T \mathbf{B} (\mathbf{a} - \mathbf{A} \mathbf{x})}{\partial \mathbf{x} \partial \mathbf{x}^T} = 2 \mathbf{A}^T \mathbf{B} \mathbf{A} \quad (5.7)$$



6 尾声

矩阵的语言非常的丰富，如果再加上随机矩阵，则又会有更多的结论。这些仅在一篇博文中恐怕难以详述。本文只大概的给出一些经常用到的结论。在实际应用中，还要多多查阅相关书籍。