

高级计量经济学

理论经济学博士课程

Lecture 2: Matrix and Linear Algebra

黄嘉平

工学博士 经济学博士
深圳大学中国经济特区研究中心 讲师

Office 粤海校区汇文楼1510
Email huangjp@szu.edu.cn
Website <https://huangjp.com>

矩阵和向量

矩阵的表达方式

Matrix notation

- 标量 (scalar) 是一个单独的数, 一般用标准体小写字母表达, 例如 a
- 向量 (vector) 是由 k 个数组成的清单, 用粗体小写字母表达, 例如

$$\mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_k \end{pmatrix} \quad \text{或} \quad \boldsymbol{\alpha} = (a_1 \ a_2 \ \cdots \ a_k) \quad \text{也可以写成 } \boldsymbol{\alpha} = (a_1, a_2, \cdots, a_k)$$

- 矩阵 (matrix) 是由 $k \times r$ 个数字组成二维排列, 一般用粗体大写字母表达, 例如

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1j} & \cdots & a_{1r} \\ a_{21} & a_{22} & \cdots & a_{2j} & \cdots & a_{2r} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{i1} & a_{i2} & \cdots & a_{ij} & \cdots & a_{ir} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{k1} & a_{k2} & \cdots & a_{kj} & \cdots & a_{kr} \end{pmatrix}$$

← 第 i 行

↑ 第 j 列

a_{ij} 称为 \mathbf{A} 的 (i, j) 要素

\mathbf{A} 也可以简写成 $\mathbf{A} = (a_{ij})_{k \times r}$ 或 $\mathbf{A} = (a_{ij})$

矩阵的表达方式

Matrix notation

- 矩阵的转置 (transpose) A^T 是将矩阵 A 以主对角线为轴翻转后获得的矩阵, 即

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1r} \\ \vdots & & \vdots \\ a_{k1} & \cdots & a_{kr} \end{pmatrix} \Leftrightarrow A^T = \begin{pmatrix} a_{11} & \cdots & a_{k1} \\ \vdots & & \vdots \\ a_{1r} & \cdots & a_{kr} \end{pmatrix}$$

$$\text{例: } \begin{pmatrix} 2 & 3 & 0 \\ -1 & 1 & 5 \end{pmatrix}^T = \begin{pmatrix} 2 & -1 \\ 3 & 1 \\ 0 & 5 \end{pmatrix}$$

也可以写作 A' 或 A^t

- 如果 A 的行数等于列数, 则称其为方阵 (square matrix)
- 方阵 A 满足 $A = A^T$, 即 $a_{ij} = a_{ji}$ 时, 称其为对称 (symmetric) 矩阵
- $k \times k$ 单位矩阵 (identity matrix) I_k 是主对角要素为 1, 其他要素为 0 的方阵, 即

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

- 主对角要素下面/上面的要素都为零的方阵称为上三角/下三角 (upper triangular/lower triangular) 矩阵, 两者统称三角矩阵
- 分块矩阵 (partitioned matrix) 是将一个大矩阵表达成几个小矩阵的矩阵, 例如 $A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$

矩阵计算

Matrix operations

- 矩阵的加法: $A + B = (a_{ij} + b_{ij})$
- 矩阵乘以标量: $cA = Ac = (c \times a_{ij})$
- 向量的内积 (inner product) : 两个列向量 \mathbf{a} 和 \mathbf{b} 的内积定义为

$$\mathbf{a} \cdot \mathbf{b} = \mathbf{a}^\top \mathbf{b} = a_1 b_1 + a_2 b_2 + \cdots + a_k b_k = \sum_{i=1}^k a_i b_i$$

- 矩阵的乘法: $k \times r$ 矩阵 A 和 $r \times s$ 矩阵 B 的积定义为

$$AB = \begin{pmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_k^\top \end{pmatrix} (\mathbf{b}_1 \quad \mathbf{b}_2 \quad \cdots \quad \mathbf{b}_s) = \begin{pmatrix} \mathbf{a}_1^\top \mathbf{b}_1 & \mathbf{a}_1^\top \mathbf{b}_2 & \cdots & \mathbf{a}_1^\top \mathbf{b}_s \\ \mathbf{a}_2^\top \mathbf{b}_1 & \mathbf{a}_2^\top \mathbf{b}_2 & \cdots & \mathbf{a}_2^\top \mathbf{b}_s \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_k^\top \mathbf{b}_1 & \mathbf{a}_k^\top \mathbf{b}_2 & \cdots & \mathbf{a}_k^\top \mathbf{b}_s \end{pmatrix}$$

也可以表达为 $C = AB \Leftrightarrow c_{ij} = \mathbf{a}_i^\top \mathbf{b}_j$, C 为 $k \times s$ 矩阵

矩阵计算的性质

Some properties of matrix operations

- 矩阵的加法满足交换律和结合律
 - 交换律: $A + B = B + A$
 - 结合律: $A + (B + C) = (A + B) + C$
- 矩阵的乘法满足结合律和分配律
 - 结合律: $A(BC) = (AB)C$
 - 分配律: $A(B + C) = AB + AC$
- 矩阵的乘法不满足交换律: $AB \neq BA$ 举例证明这条性质
- 与单位矩阵的积: $k \times r$ 矩阵 A 满足 $I_k A = A I_r = A$
- 正交 (orthogonal) 向量与矩阵
 - 正交向量: 如果 $a^T b = 0$, 则称向量 a 与 b 正交
 - 正交矩阵: 如果 $A^T B = O$, 则称矩阵 A 与 B 正交。这里 O 为零矩阵。 A 与 B 正交意味着 A 的任意列向量与 B 的任意列向量正交

方阵的迹

Trace

- $k \times k$ 方阵 A 的迹 (**trace**) 定义为其主对角要素之和, 即

$$\text{tr}(A) = \sum_{i=1}^k a_{ii}$$

- 一些显而易见的性质

- $\text{tr}(cA) = c \text{tr}(A)$

- $\text{tr}(A^T) = \text{tr}(A)$

- $\text{tr}(A + B) = \text{tr}(A) + \text{tr}(B)$

- $\text{tr}(I_k) = k$

- 对于 $k \times r$ 矩阵 A 和 $r \times k$ 矩阵 B , $\text{tr}(AB) = \text{tr}(BA)$

尝试证明这条性质

矩阵的秩与逆

Rank and inverse

- $k \times r$ 矩阵 $A = (a_1 \ a_2 \ \cdots \ a_r)$ 的秩 (**rank**) 是 A 的线性独立的列的最大个数, 记作 $\text{rank}(A)$
- $\text{rank}(A) \leq \min(k, r)$
- 如果 $\text{rank}(A) = \min(k, r)$, 则称 A **满秩 (has full rank)**
- 当 $r \leq k$ 时, $\text{rank}(A) = r$ 称为列满秩。列满秩代表所有的列都是线性独立的
- $k \times k$ 方阵 A 如果满足 $\text{rank}(A) = k$, 则称 A 为**非奇异矩阵 (non-singular matrix)**。这意味着不存在能使 $Ac = \mathbf{0}$ 的非零向量 c
- 如果 $k \times k$ 方阵 A 是非奇异矩阵, 则存在唯一的 $k \times k$ 方阵 B , 使

$$AB = BA = I_k$$

此时, 称 B 为 A 的**逆矩阵 (inverse matrix)**, 并写作 $A^{-1} = B$

- A 与 C 是非奇异矩阵时,
 - $(A^T)^{-1} = (A^{-1})^T$
 - $(AC)^{-1} = C^{-1}A^{-1}$

行列式

Determinant

- 行列式 (determinant) 是每个方阵对应的一个标量, 定义为


$$\det(A) = |A| = \sum_{\pi} \varepsilon_{\pi} a_{1j_1} a_{2j_2} \cdots a_{kj_k}$$

此式中 $\pi = (j_1, j_2, \dots, j_k)$ 是 $(1, 2, \dots, k)$ 的一个排列, 而每个 π 中较大数字排在较小数字之前的组合数为偶数时 $\varepsilon_{\pi} = 1$, 为奇数时 $\varepsilon_{\pi} = -1$


例如: $\varepsilon_{(3,2,1)} = -1$

- 行列式的定义比较复杂, 通常我们会直接记住常用的 2×2 和 3×3 方阵的行列式公式

$$\begin{vmatrix} a & b \\ c & d \end{vmatrix} = ad - bc,$$



$$\begin{vmatrix} a & b & c \\ d & e & f \\ g & h & i \end{vmatrix} = aei + bfg + cdh - ceg - afh - bdi,$$



- 行列式的一些性质:

$$\det(A) = \det(A^T), \quad \det(cA) = c^k \det(A), \quad \det(AB) = \det(BA) = \det(A) \det(B),$$

$$\det(A^{-1}) = \det(A)^{-1}, \quad \det(A) \neq 0 \Leftrightarrow A \text{ 是非奇异矩阵}, \quad A \text{ 是三角矩阵} \Leftrightarrow \det(A) = \prod_{i=1}^k a_{ii}$$

特征值

Eigenvalues

- 关于 $k \times k$ 矩阵 A 的方程 $A\mathbf{h} = \lambda\mathbf{h}$ 存在非零解 \mathbf{h} 时, 称 \mathbf{h} 为 A 的特征向量 (eigenvector), λ 为对应的特征值 (eigenvalue)
- 方程 $A\mathbf{h} = \lambda\mathbf{h}$ 可以改写为 $(A - \lambda I_k)\mathbf{h} = \mathbf{0}$, 此时存在非零解的充分必要条件是

$$\det(A - \lambda I_k) = 0$$

此方程称为特征方程 (characteristic equation), 其左边是关于 λ 的 k 次多项式, 因此称之为特征多项式 (characteristic polynomial), λ 为特征方程的解 (共有 k 个, 可重复, 可为实数或复数)

- 令 λ_i 和 $\mathbf{h}_i, i = 1, \dots, k$ 为 A 的特征值和特征向量, 则
 - $\det(A) = \prod_{i=1}^k \lambda_i$
 - $\text{tr}(A) = \sum_{i=1}^k \lambda_i$
 - A 为非奇异矩阵 \Leftrightarrow 所有的特征值 λ_i 都不为零
 - AB 和 BA 具有相同的非零特征值
 - 如果 B 是非奇异矩阵, 则 A 与 $B^{-1}AB$ 具有相同的特征值

谱分解

Spectral decomposition

- 令 λ_i 和 $\mathbf{h}_i, i = 1, \dots, k$ 为 A 的特征值和特征向量, 则方程 $A\mathbf{h} = \lambda\mathbf{h}$ 可以写为下面的矩阵形式

$$AH = H\Lambda$$

其中, $H = (\mathbf{h}_1 \quad \dots \quad \mathbf{h}_k), \Lambda = \text{diag}(\lambda_1, \dots, \lambda_k)$

$$\Lambda = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_k \end{pmatrix}$$

谱分解 (spectral decomposition) : 如果 A 是 $k \times k$ 的实对称矩阵, 则 $A = H\Lambda H^\top$ 。 A 的所有特征值都为实数, 且 H 满足 $H^\top H = I_k$

- 如果 A 是可逆实对称矩阵, 则 $A^{-1} = (H^\top)^{-1}\Lambda^{-1}H^{-1} = H\Lambda^{-1}H^\top$, 因此 A^{-1} 与 A 拥有相同的特征向量, 其特征值是 $\lambda_1^{-1}, \lambda_2^{-1}, \dots, \lambda_k^{-1}$

(半) 正定矩阵

Positive (semi)definite matrices

如果 $k \times k$ 的实对称矩阵 A ，对于任意非零向量 $c \neq 0$ 都有

$$c^T A c > 0 \quad (c^T A c \geq 0)$$

则称 A 为 **(半) 正定矩阵** (positive **(semi)definite matrix**)，并可记作 $A > 0$ ($A \geq 0$)

$$(c_1 \ c_2) \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} c_1 \\ c_2 \end{pmatrix} = c_1^2 - 2c_1c_2 + c_2^2 = (c_1 - c_2)^2 \geq 0, \text{ 因此 } \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix} \text{ 是半正定矩阵}$$

- $c^T A c = \sum_{i=1}^k \sum_{j=1}^k c_i a_{ij} c_j = \sum_{i=1}^k a_{ii} c_i^2 + \sum_{i \neq j} a_{ij} c_i c_j$ 是关于 c_i 的二次函数，因此称为**二次型 (quadratic form)**
- 如果 A 是正定矩阵，则 A 为非奇异矩阵 ($\det(A) > 0$)，且 A^{-1} 也是正定矩阵
- A 是 (半) 正定矩阵 $\Leftrightarrow A$ 的所有特征值都为正 (非负) 实数
- 如果 A 是半正定矩阵，则 $\text{rank}(A)$ 等于正特征值的个数

行列式与正定矩阵

Determinants and positive definite matrices

- 从 $k \times k$ 矩阵 A 中删除任意 $k - r$ 行和任意 $k - r$ 列后，剩下的 $r \times r$ 矩阵的行列式称为 A 的 r 阶余子式 (minor)
- 如果第 i 行被删除时第 i 列也被删除，则剩下的 $r \times r$ 矩阵的行列式称为 A 的 r 阶主子式 (principle minor)
- 由 A 的前 r 行和前 r 列组成的 $r \times r$ 矩阵的行列式称为 A 的 r 阶顺序主子式 (leading principle minor)

- A 是正定矩阵
 $\Leftrightarrow A$ 的所有顺序主子式都为正
- A 是半正定矩阵
 $\Leftrightarrow A$ 的所有主子式都为非负

$$\begin{pmatrix} a_{11} & a_{12} & a_{13} & \cdots & a_{1k} \\ a_{21} & a_{22} & a_{23} & \cdots & a_{2k} \\ a_{31} & a_{32} & a_{33} & \cdots & a_{3k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_{k1} & a_{k2} & a_{k3} & \cdots & a_{kk} \end{pmatrix}$$

例:

$$3 \times 3 \text{ 矩阵 } A = \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix}$$

有 7 个主子式:

a_{11} , a_{22} , a_{33} , $|A|$, 以及

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

其中, a_{11} , $\begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix}$, $|A|$ 是顺序主子式

Cholesky 分解

Cholesky decomposition

- 如果 $k \times k$ 实矩阵 A 是正定矩阵，则存在矩阵 B 使 $A = BB^T$ 。我们称 B 为 A 的矩阵平方根 (matrix square root) 并记作 $B = A^{\frac{1}{2}}$ 。矩阵平方根并不是唯一的

Cholesky 分解：如果 $k \times k$ 实矩阵 A 是正定矩阵，则存在唯一满秩的下三角矩阵 L 使 $A = LL^T$

- 例如对于 3×3 矩阵，

$$\begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{12} & a_{22} & a_{23} \\ a_{13} & a_{23} & a_{33} \end{pmatrix} = \begin{pmatrix} l_{11} & 0 & 0 \\ l_{21} & l_{22} & 0 \\ l_{31} & l_{32} & l_{33} \end{pmatrix} \begin{pmatrix} l_{11} & l_{21} & l_{31} \\ 0 & l_{22} & l_{32} \\ 0 & 0 & l_{33} \end{pmatrix} = \begin{pmatrix} l_{11}^2 & l_{11}l_{21} & l_{11}l_{31} \\ l_{21}l_{11} & l_{21}^2 + l_{22}^2 & l_{21}l_{31} + l_{22}l_{32} \\ l_{31}l_{11} & l_{31}l_{21} + l_{32}l_{22} & l_{31}^2 + l_{32}^2 + l_{33}^2 \end{pmatrix}$$

注意：A 是正定矩阵 \Rightarrow A 是对称矩阵

这里共有 6 个线性方程与 6 个未知量 (L 的要素)， A 是正定矩阵 (所有顺序主子式为正) 可以保证解的存在性和唯一性，并保证 L 的主对角要素为正

- L 是 A 的一个矩阵平方根

多变量函数求导

Matrix calculus

- $\mathbf{x} = (x_1, x_2, \dots, x_k)^\top$ 为 k 维实数向量, 令 $g(\mathbf{x}) = g(x_1, x_2, \dots, x_k) : \mathbb{R}^k \rightarrow \mathbb{R}$ 为 \mathbf{x} 的实数值函数

- 称

$$\frac{\partial}{\partial \mathbf{x}} g(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} g(\mathbf{x}) \\ \frac{\partial}{\partial x_1} g(\mathbf{x}) \\ \vdots \\ \frac{\partial}{\partial x_1} g(\mathbf{x}) \end{pmatrix} \quad \text{和} \quad \frac{\partial}{\partial \mathbf{x}^\top} g(\mathbf{x}) = \left(\frac{\partial}{\partial x_1} g(\mathbf{x}) \quad \frac{\partial}{\partial x_1} g(\mathbf{x}) \quad \dots \quad \frac{\partial}{\partial x_1} g(\mathbf{x}) \right)$$

为 g 的梯度 (gradient) 向量

- 称

$$\frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}^\top} g(\mathbf{x}) = \begin{pmatrix} \frac{\partial^2}{\partial x_1^2} g(\mathbf{x}) & \frac{\partial^2}{\partial x_1 \partial x_2} g(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_1 \partial x_k} g(\mathbf{x}) \\ \frac{\partial^2}{\partial x_2 \partial x_1} g(\mathbf{x}) & \frac{\partial^2}{\partial x_2^2} g(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_2 \partial x_k} g(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial x_k \partial x_1} g(\mathbf{x}) & \frac{\partial^2}{\partial x_k \partial x_2} g(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_k^2} g(\mathbf{x}) \end{pmatrix}$$

为 g 的海赛 (Hessian) 矩阵

多变量函数求导

Matrix calculus

- $\frac{\partial}{\partial \mathbf{x}}(\mathbf{a}^\top \mathbf{x}) = \frac{\partial}{\partial \mathbf{x}}(\mathbf{x}^\top \mathbf{a}) = \mathbf{a}$

$$\mathbf{a}^\top \mathbf{x} = \mathbf{x}^\top \mathbf{a} = \sum_{i=1}^k a_i x_i \Rightarrow \frac{\partial}{\partial x_i}(\mathbf{a}^\top \mathbf{x}) = \frac{\partial}{\partial x_i}(\mathbf{x}^\top \mathbf{a}) = a_i$$

- $\frac{\partial}{\partial \mathbf{x}}(\mathbf{x}^\top \mathbf{A}) = \mathbf{A}, \frac{\partial}{\partial \mathbf{x}^\top}(\mathbf{A} \mathbf{x}) = \mathbf{A}$

令 $\mathbf{A} = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_k)$, 则 $\mathbf{x}^\top \mathbf{A} = (\mathbf{x}^\top \mathbf{a}_1, \mathbf{x}^\top \mathbf{a}_2, \dots, \mathbf{x}^\top \mathbf{a}_k)$

$$\Rightarrow \frac{\partial}{\partial \mathbf{x}}(\mathbf{x}^\top \mathbf{A}) = \frac{\partial}{\partial \mathbf{x}}(\mathbf{x}^\top \mathbf{a}_1, \mathbf{x}^\top \mathbf{a}_2, \dots, \mathbf{x}^\top \mathbf{a}_k) = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_k) = \mathbf{A}$$

- $\frac{\partial}{\partial \mathbf{x}}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = (\mathbf{A} + \mathbf{A}^\top) \mathbf{x}, \frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}^\top}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = \mathbf{A} + \mathbf{A}^\top$

如果 \mathbf{A} 是对称矩阵, 则
 $\frac{\partial}{\partial \mathbf{x}}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = 2\mathbf{A} \mathbf{x}, \frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}^\top}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = 2\mathbf{A}$

$$\mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^k \sum_{j=1}^k a_{ij} x_i x_j$$

$$\Rightarrow \frac{\partial}{\partial x_i}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = a_{ij} x_j + a_{ji} x_j, \frac{\partial^2}{\partial x_i \partial x_j}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = a_{ij} + a_{ji}$$

多变量函数的极值和最值

Extrema of functions of several variables

\mathbf{x}^* 是函数 g 的驻点 (stationary point, 包括极大值点、极小值点和鞍点) $\Leftrightarrow \left. \frac{\partial}{\partial \mathbf{x}} g(\mathbf{x}) \right|_{\mathbf{x}=\mathbf{x}^*} = \mathbf{0}$


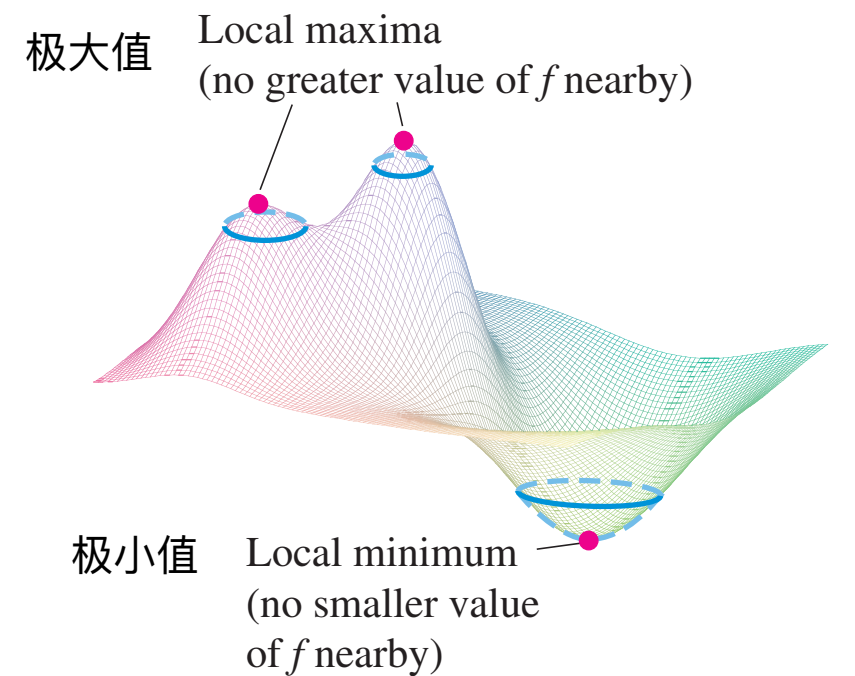
- 必要条件

\mathbf{x}^* 是函数 g 的最值点 $\Rightarrow \left. \frac{\partial}{\partial \mathbf{x}} g(\mathbf{x}) \right|_{\mathbf{x}=\mathbf{x}^*} = \mathbf{0}$

- 充分条件

令 $S \subseteq \mathbb{R}^k$ 为凸集合, 并假设 $\mathbf{x}^* \in S$ 是函数 g 的一个驻点, 则

- ▶ 海赛矩阵 $\left. \frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}^\top} g(\mathbf{x}) \right|_{\mathbf{x}=\mathbf{x}^*}$ 是正定矩阵 $\Rightarrow \mathbf{x}^*$ 是 g 的极小值点
- ▶ g 在 S 中是凸函数 (\Leftrightarrow 对于任意 $\mathbf{x} \in S$, 海赛矩阵 $\frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}^\top} g(\mathbf{x})$ 都是半正定矩阵) $\Rightarrow \mathbf{x}^*$ 是 g 在 S 中的最小值点



鞍点 (saddle point)

图出自 Thomas, Weir, & Hass.
Thomas' Calculus, 12e. Addison-Wesley