

# 高级计量经济学

## Appendix 3: Review of Matrix and Linear Algebra

Hansen, B. (2022). *Econometrics*. Princeton University Press.

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

办公室 粤海校区汇文楼1510  
E-mail [huangjp@szu.edu.cn](mailto: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

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

↑  
第  $j$  列

← 第  $i$  行

$a_{ij}$  称为  $A$  的  $(i, j)$  要素  
 $A$  也可以简写成  $A = (a_{ij})_{k \times r}$  或  $A = (a_{ij})$

# 矩阵的表达方式

## Matrix notation

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

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

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

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  $A = A^\top$ , 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

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

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  $a^\top b = 0$ , 则称向量  $a$  与  $b$  正交
  - 正交矩阵: 如果  $A^\top B = O$ , 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

- $\text{tr}(cA) = c \text{tr}(A)$
- $\text{tr}(A^\top) = \text{tr}(A)$
- $\text{tr}(A + B) = \text{tr}(A) + \text{tr}(B)$
- $\text{tr}(I_k) = k$
- 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,

- $(A^\top)^{-1} = (A^{-1})^\top$
- $(AC)^{-1} = C^{-1}A^{-1}$

# 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  $\pi$  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  $2 \times 2$  和  $3 \times 3$  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：

$$\begin{aligned} \det(A) &= \det(A^{\top}), \quad \det(cA) = c^k \det(A), \quad \det(AB) = \det(BA) = \det(A) \det(B), \\ \det(A^{-1}) &= \det(A)^{-1}, \quad \det(A) \neq 0 \Leftrightarrow A \text{ 是非奇异矩阵}, \quad A \text{ 是三角矩阵} \Leftrightarrow \det(A) = \prod_{i=1}^k a_{ii} \end{aligned}$$

# 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)， $\lambda$  为对应的特征值 (eigenvalue)
- 方程  $A\mathbf{h} = \lambda\mathbf{h}$  可以改写为  $(A - \lambda\mathbf{I}_k)\mathbf{h} = \mathbf{0}$ ，此时存在非零解的充分必要条件是

$$\det(A - \lambda\mathbf{I}_k) = 0$$

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

- 令  $\lambda_i$  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  $\lambda_i$  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  $\lambda_i$  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,  $H = (\mathbf{h}_1 \ \cdots \ \mathbf{h}_k)$ ,  $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_k)$

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

**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  $\mathbf{c} \neq \mathbf{0}$  都有

$$\mathbf{c}^\top A \mathbf{c} > 0 \quad (\mathbf{c}^\top A \mathbf{c} \geq 0)$$

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

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

- $\mathbf{c}^\top A \mathbf{c} = \sum_{i=1}^k \sum_{j=1}^k c_i a_{ij} c_j = \sum_{i=1}^k a_{ii} c_i^2 + \sum_{i \neq j} a_{ij} c_i c_j$  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  $A = BB^\top$ 。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  $A = LL^\top$

- 例如对于  $3 \times 3$  矩阵，

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

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

- $\mathbf{x} = (x_1, x_2, \dots, x)^T$  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

$$\frac{\partial}{\partial \mathbf{x}} g(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} g(\mathbf{x}) \\ \frac{\partial}{\partial x_2} g(\mathbf{x}) \\ \vdots \\ \frac{\partial}{\partial x_k} g(\mathbf{x}) \end{pmatrix} \quad \text{和} \quad \frac{\partial}{\partial \mathbf{x}^\top} g(\mathbf{x}) = \left( \frac{\partial}{\partial x_1} g(\mathbf{x}) \quad \frac{\partial}{\partial x_2} g(\mathbf{x}) \quad \cdots \quad \frac{\partial}{\partial x_k} g(\mathbf{x}) \right)$$

为  $g$  的梯度 (gradient) 向量

- 称

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

为  $g$  的海赛 (Hessian) 矩阵

# 多变量函数求导

## Matrix calculus

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

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

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

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

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

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

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

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

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

# 多变量函数的极值和最值

## Extrema of functions of several variables

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



- 必要条件

$$x^* \text{ 是函数 } g \text{ 的} \underline{\text{最值点}} \Rightarrow \frac{\partial}{\partial x} g(x) \Big|_{x=x^*} = 0$$

- 充分条件

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

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