



本课件仅用于教学使用。未经许可，任何单位、组织和个人不得将课件用于该课程教学之外的用途(包括但不限于盈利等)，也不得上传至可公开访问的网络环境

1

数据科学导论

Introduction to Data Science

第三章 数据统计基础

黄振亚，陈恩红

Email: huangzhy@ustc.edu.cn, cheneh@ustc.edu.cn


课程主页:

<http://staff.ustc.edu.cn/~huangzhy/Course/DS2025.html>



回顾：数据统计

2





数据统计

3

- 数据分布
- 参数估计
- 假设检验
- 抽样方法



参数估计

4

- 参数(parameter)
 - 参数 是用来描述**总体数据特征**的度量
- 统计量(statistic)
 - 统计量 是用来描述**样本数据特征**的度量
 - 由试验计算得出，不依赖于任何其他未知的量（特别是不能依赖于总体分布中所包含的未知参数）
- 参数估计(parameter estimation)
 - 是统计推断的基本问题之一：用**样本统计量**估计总体的**参数**
 - 参数未知的真实
 - 统计量已知的估计
 - 例：掷骰子例子



参数估计

5

□ 参数估计

- **点估计：**用样本统计量 $\hat{\theta}$ 的某个取值直接作为总体参数 θ 的估计值
 - 简单来说，**直接以样本指标来估计总体指标**
 - 总体的某个特征值，如数学期望、方差和相关系数等
- **区间估计：**从总体中抽取的样本，根据一定的正确度与精确度的要求，构造出适当的区间，以作为总体的分布参数(或参数的函数)的真值所在范围的估计
 - 用数轴上的一段经历或一个数据区间，表示总体参数的可能范围。这一段距离或数据区间称为区间估计的置信区间



参数估计

6

□ 点估计(point estimate)

- 点估计是用样本统计量 $\hat{\theta}$ 的某个取值直接作为总体参数 θ 的估计值
 - 用样本均值 $\bar{x}$ 直接作为总体均值 μ 的估计值
 - 用样本方差 s^2 直接作为总体方差 σ^2 的估计值

□ 点估计的常用方法

- 矩估计
- 最小二乘估计
- 极大似然估计
- 最大后验概率
- 贝叶斯估计



参数估计—矩估计

7

□ 矩估计

□ 原理：大数定律：n趋近于无穷，样本矩趋近于总体矩

■ 矩估计是基于“替换”思想，即用样本矩估计总体矩

■ 均值，方差

□ 随机变量的矩

■ K阶原点矩： $E(X^k) = \frac{1}{n} \sum_{i=1}^n X_i^k$

■ K阶中心矩： $E([X - E(X)]^k) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$

■ 一阶原点矩表示期望

■ 二阶中心矩表示方差

■ 三阶中心矩表示偏度

■ 四阶中心矩表示峰度

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad \sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

$$SK = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{3}{2}}} \quad K = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^2}$$



参数估计—矩估计

8

□ 矩估计

□ 原理：大数定律：n趋近于无穷，样本矩趋近于总体矩

■ 矩估计是基于“替换”思想，即用样本矩估计总体矩

■ 均值，方差

□ 随机变量的矩

■ K阶原点矩： $E(X^k) = \frac{1}{n} \sum_{i=1}^n X_i^k$

■ K阶中心矩： $E([X - E(X)]^k) =$

■ 一阶原点矩表示期望

■ 二阶中心矩表示方差

■ 三阶中心矩表示偏度

■ 四阶中心矩表示峰度

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad \sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

$$SK = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{3}{2}}} \quad K = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^2}$$

课后练习：思考并推导矩估计与数据统计指标的关系



参数估计一

K阶原点矩: $E(X^k) = \frac{1}{n} \sum_{i=1}^n X_i^k$

K阶中心距: $E([X - E(X)]^k) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$

问 设总体 X 在 $[a, b]$ 上服从均匀分布, $X_1, \dots, X_n$ 是来自 X 的样本, 试求 a, b 的矩估计量

解

有两个未知量, 故我们需要列出 1 阶矩和 2 阶矩:

$$\begin{cases} \mu_1 = E(X) = (a+b)/2 \\ \mu_2 = E(X^2) = D(X) + [E(X)]^2 = \frac{(b-a)^2}{12} + \frac{(a+b)^2}{4} \end{cases}$$

解得

$$\begin{cases} a = \mu_1 - \sqrt{3(\mu_2 - \mu_1^2)} \\ b = \mu_1 + \sqrt{3(\mu_2 - \mu_1^2)} \end{cases}$$

由于样本 k 阶矩是 k 阶矩的无偏估计量, 故用 A_1, A_2 代替 μ_1, μ_2 得到 a, b 的矩估计量为:

$$\begin{cases} A_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X} \\ A_2 = \frac{1}{n} \sum_{i=1}^n X_i^2 \end{cases}$$

$$\begin{cases} a = \bar{X} - \sqrt{3\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2\right)} = \bar{X} - \sqrt{\frac{3}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \\ b = \bar{X} + \sqrt{3\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2\right)} = \bar{X} + \sqrt{\frac{3}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \end{cases}$$



参数估计—矩估计

10

□ 举例：黑白球（矩估计）

- 例：假如有一个罐子，里面有黑白两种颜色的球，数目多少不知，两种颜色的比例也不知。每次任意从已经摇匀的罐中拿1个球出来，记录球的颜色，然后把拿出来的球再放回罐中。假如在前面的100次重复记录中，有70次是白球。请问罐中白球所占的比例是多少？

解：用样本中白球比例的均值作为估计代替总体均值。

即估计结果为罐中白球所占的比例 $70\% = \frac{7}{10}$

符合直观

(独立同分布，无偏估计)





参数估计—最小二乘估计

11

□ 最小二乘估计(Least Square Estimate, LSE)

- 总体的模型：用样本数据拟合总体的参数估计量，即估计值与观测值之差的平方和最小
- 目标：最小化估计值 θ 与观测值 $\hat{\theta}$ 之差的平方和
- $\min L(\theta) = \sum_{i=1}^N (\theta - \hat{\theta}_i)^2$






参数估计—最小二乘估计

12

□ 最小二乘估计(LSE)

- 常用于线性回归分析做参数估计
- 给定数据 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, 假设模型 $f(X|\theta)$
- 例:在线性回归模型 $f(X|\theta) = \theta_0 + \theta_1 x + \theta_1 x^2 + \dots + \theta_n x^n = \theta^T X$
- 目标: $\min L(\theta) = \sum_{i=1}^N (f(X|\theta) - Y)^2$
- 求解: 一阶导数为0: $\frac{\partial L(\theta)}{\partial \theta_0} = 0, \frac{\partial L(\theta)}{\partial \theta_1} = 0, \dots, \frac{\partial L(\theta)}{\partial \theta_n} = 0$



课后学习: 最小二乘矩阵求解方法



参数估计—最小二乘估计

13

□ 最小二乘估计—建模案例

Question Difficulty Prediction for READING Problems in Standard Tests

$$\mathcal{J}(\Theta) = \sum_{Q_i} (P_i - \mathcal{M}(Q_i))^2 + \lambda_{\Theta} \|\Theta_{\mathcal{M}}\|^2, \quad (5)$$


ASGN: An Active Semi-supervised Graph Neural Network for Molecular Property Prediction

Traditionally, MPGNN is trained in a supervised manner where all the labels are given and we usually use mean square loss (MSE) between predictions and labels $\mathbf{y}_i$ (i.e. the labeled properties in $\mathcal{D}_l$) to guide the optimization of the model parameters:


$$\mathcal{L}_p = \sum_{i=1}^{N_l} \|\mathbf{y}_i - f_{\theta}(\mathbf{z}_{\mathcal{G}_i})\|^2. \quad (4)$$

(TD) Larry was on another of his underwater expeditions but this time, it was different. He decided to take his daughter along with him. She was only ten years old [...]. [A]lready, she looked like she was much heavier than had been then. This was the key to a successful underwater expedition.
(TQ) Q1: In what way was this expedition different for Larry?
(TT) A. His daughter had grown up.
(TT) B. He had become a famous diver.
(TT) C. His father would dive with him.
(TT) D. His daughter would dive with him.
(TQ) Q2: Why did Larry have to stay in a cage underwater sometimes?
(TT) A. To protect himself from danger.
(TT) B. To dive into the deep water.
(TT) C. To admire the underwater view.
(TT) D. To take photo more conveniently.

(a) A READING problem



(b) Difficulties in tests



- ✓ Zhenya Huang, Enhong Chen, Question Difficulty Prediction for READING Problems in Standard Tests, AAAI2017
- ✓ Zhongkai Hao, Zhenya Huang, Qi Liu, Enhong Chen, ASGN: An Active Semi-supervised Graph Neural Network for Molecular Property Prediction, KDD 2020



参数估计—最小二乘估计

14

□ 举例：黑白球（最小二乘估计）—课堂练习

- 问题：假如有一个罐子，里面有黑白两种颜色的球，数目多少不知，两种颜色的比例也不知。每次任意从已经摇匀的罐中拿1个球出来，记录球的颜色，然后把拿出来的球再放回罐中。假如在前面的100次重复记录中，有70次是白球。请问罐中白球所占的比例是多少？
- 请使用最小二乘估计方法，求解上述问题

假设：白球占比为 θ

目标：最小化估计值 θ 与观测值 $\hat{\theta}$ 之差的平方和

$$\min L(\theta) = \sum_{i=1}^N (\theta - \hat{\theta}_i)^2$$





参数估计

17

- 点估计
 - 用样本统计量 $\hat{\theta}$ 的某个取值直接作为总体参数 θ 的估计值
- 点估计的常用方法
 - 矩估计
 - 最小二乘估计 LSE
 - 极大似然估计 MLE
 - 最大后验估计 MAP
 - 贝叶斯估计



参数估计—极大似然估计

18

□ 极大似然估计(Maximum Likelihood Estimate, MLE)

□ 思想：利用已知的样本结果信息，反推最具有可能（最大概率）导致这些样本结果出现的模型参数值

□ 模型已定，参数未知

□ 目标：概率分布函数或者似然函数最大

■ 用似然函数取到最大值时的参数值作为估计值

□ 概率分布模型


■ 伯努利分布

■ 二项分布

■ 高斯分布

■ 泊松分布

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$





参数估计—极大似然估计

19

□ 极大似然估计(MLE)

- MLE目标：用似然函数取到最大值时的参数值作为估计值
- 设总体分布为 $f(X|\theta)$ ， $x_1, x_2, x_3, \dots, x_N$ 为样本。样本满足独立同分布，则他们的联合密度函数为：

$$L(x_1, x_2, \dots, x_n|\theta) = \prod_{i=1}^n f(x_i|\theta)$$

- 其中， θ 为未知参数。样本已经存在(观测)，即， $x_1, x_2, x_3, \dots, x_n$ 是固定的。 $L(X|\theta)$ 是关于 θ 的函数，称为似然函数
- 目标：求参数 θ ，使似然函数取极大值，称为极大似然估计
- 实践中，通常对似然函数取对数(log或ln)(连乘运算变为连加运算)，即对数似然函数。所以，极大似然估计问题可以写成

$$\ln L(x_1, x_2, \dots, x_n|\theta) = \sum_{i=1}^n \ln(f(x_i|\theta))$$



参数估计—极大似然估计


- 例子: 扔硬币, X 每次实验 X_i 服从伯努利分布
 - 参数为 θ , 假设为事件(正面向上)发生的概率



$$P(X_i | \theta) = \begin{cases} \theta, & X_i \text{ 为正面} \\ 1 - \theta, & X_i \text{ 为反面} \end{cases}$$

- n 次实验, 共 k 次正面向上, 采用MLE估计参数 θ :

样本观测



产生观测样本的概率不同



目标: 找到发生样本最大概率的参数

总体参数

	正	反
θ	0.5	0.5

	正	反
θ	0.2	0.8

	正	反
θ	0.9	0.1



参数估计—极大似然估计

21

- 例子: 扔硬币, X 每次实验 X_i 服从伯努利分布
 - 参数为 θ , 假设为事件(正面向上)发生的概率

$$P(X_i | \theta) = \begin{cases} \theta, & X_i \text{为正面} \\ 1 - \theta, & X_i \text{为反面} \end{cases}$$

- n 次实验, 共 k 次正面向上, 采用极大似然估计估计参数 θ :

- 似然函数: $L(x_1, x_2, \dots, x_n | \theta) = C_n^k \theta^k (1 - \theta)^{n-k}$
- 对数似然函数: $\ln L(X | \theta) = \ln C_n^k + k \ln \theta + (n - k) \ln(1 - \theta)$
- 求极值: $\frac{\partial L(\theta)}{\partial \theta} = 0$, 则: $\frac{k}{\theta} - \frac{n-k}{1-\theta} = 0$
- 参数 θ 的最大似然估计值: $\theta_{MLE} = \frac{k}{k+n-k} = \frac{k}{n}$

- ✓ 二项分布中每次事件发生的概率 θ = 做 N 次独立重复随机试验中事件发生的概率
- ✓ 例如: 如果做20次实验, 出现正面14次, 反面6次:
 - ✓ MLE得到参数值 p 为 $14/20 = 0.7$



参数估计—极大似然估计

22

□ 极大似然估计—高斯分布的参数

□ 例：给定 $x_1, x_2, x_3, \dots, x_N$ 为样本，已知样本来自于高斯分布 $N(\mu, \sigma)$ ，估计参数 μ, σ

解：

➤ 高斯分布的概率密度函数：
$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

➤ 带入样本，似然函数：
$$L(X) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x_i-\mu)^2}{2\sigma^2}\right)$$

➤ 对数似然：
$$\begin{aligned} \ln L(X) &= \sum_{i=1}^N \ln \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x_i-\mu)^2}{2\sigma^2}\right) \\ &= -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - \mu)^2 \end{aligned}$$

➤ 求偏导估计参数：
$$\mu = \frac{1}{n} \sum_i x_i \quad \sigma^2 = \frac{1}{n} \sum_i (x_i - \mu)^2$$

与矩估计结果相同。



参数估计—矩估计 vs LSE vs MLE

23

□ 举例：黑白球（极大似然估计）—课堂练习

- 例：假如有一个罐子，里面有黑白球，数目不知，两种颜色比例也不知。每次任意从摇匀的罐中拿1个球出来，记录颜色，然后把拿出来的球再放回罐中。假如在前面的100次重复记录中，有70次是白球。请问罐中白球所占的比例是多少？

解：假设：白球占比为 θ ，黑球占比为 $1-\theta$

已知100次观测量：出现白球70次，黑球概率30次

则，极大似然估计的目标为：

$$\max L(x_1, x_2, \dots, x_{100} | \theta) = C_{100}^{70} \theta^{70} (1 - \theta)^{30}$$

取对数为： $\ln(L(x_1, x_2, \dots, x_{100} | \theta)) = 70 \times \ln \theta + 30 \times \ln(1 - \theta)$

令： $\frac{\partial L(\theta)}{\partial \theta} = 0$

则： $\theta = \frac{7}{10}$

矩估计、LSE、MLE结果
均相同，但原理不同



参数估计—课后学习与思考

25

- 矩估计 vs LSE vs MLE—关联与区别
 - LSE可以通过高斯分布+MLE推算出来
 - LSE和MLE对应机器学习中的经验风险最小化
- MLE
 - 似然函数取对数后导数还是不好求：期望最大算法（EM）
 - 高斯混合模型
 - 机器学习中的交叉熵
 - 线性模型的极大似然估计方法
 - 逻辑斯蒂回归的极大似然估计方法



参数估计—最大后验估计

26

□ 回顾扔硬币的例子

- X 每次实验 X_i 服从伯努利分布
- 假设为事件(正面向上)发生的概率, 参数为 θ ,
- n 次实验, 共 k 次正面向上, 目标为估计参数 θ



□ MLE的思想

- $L(X|\theta)$ 似然函数取到最大值时的参数值作为估计值

样本观测

总体参数



k 次
5次

$N-k$ 次
5次

MLE



	正	反
θ	0.5	0.5

□ 频率学派


- 完全相信数据
- 世界是确定的
- 事件在多次重复实验中趋于稳定



参数估计—最大后验估计

27

- MLE是否有不足？—实验是否靠谱？
 - 实验对象(硬币)是否均匀？实验次数是否足够？
 - 实验环境是否有影响？。。。
- 最大后验估计(Maximum A Posteriori Estimation, MAP)
 - 目标：最大化在给定数据样本X的情况下模型参数的**后验概率**
 - 模型参数使得模型能够产生该数据样本的概率最大—**似然概率**
 - 但对于模型参数有了一个**假设**，加入了**先验知识**，即模型参数可能满足某种分布，即，估计不止依赖数据样本。



□ 贝叶斯学派

- 不能完全相信数据
- 世界是不确定的
- 数据量的增加，参数向数据靠拢—先验影响越小



参数估计—最大后验估计

28

□ 贝叶斯公式:

$$P(A, B) = P(B) * P(A|B) = P(A) * P(B|A)$$

$$P(A|B) = \frac{P(B|A)}{P(B)} * P(A)$$

$$= \frac{P(\mathbf{B}|\mathbf{A})P(\mathbf{A})}{P(\mathbf{B}|\mathbf{A})P(\mathbf{A}) + P(\mathbf{B}|\sim\mathbf{A})P(\sim\mathbf{A})}$$

$$\sum_{i=1}^n P(B|A_i)P(A_i)$$

□ 因果概率

$$P(\text{Cause} | \text{Effect}) = \frac{P(\text{Effect} | \text{Cause})P(\text{Effect})}{P(\text{Effect})}$$



Bayes, Thomas (1763) An essay towards solving a problem in the doctrine of chances. *Philosophical Transactions of the Royal Society of London*, 53:370-418



参数估计

29

□ 贝叶斯公式的理解—举例

□ 已知：

- 临床案例发现：患者得 meningitis(脑膜炎) 导致 stiff neck(颈部僵硬) 的概率为 50%
- 先验知识：患者得 meningitis 的概率为 1/50,000
- 先验知识：患者得 stiff neck 的概率为 1/20

□ 问：如果患者得 stiff neck, 那么他患有 meningitis 的概率为？

- 设 M 为患 meningitis（脑膜炎）的概率, S 为患 stiff neck 的概率：

$$P(M | S) = \frac{P(S | M)P(M)}{P(S)} = \frac{0.5 \times 1/50000}{1/20} = 0.0002$$

注：患有 meningitis 的后验概率 仍然非常小