

试验数据处理措施

第三部分：统计学措施

第十二章 最大似然法 (Maximum Likelihood method)

第十二章 最大似然法

(Maximum Likelihood Method)

点估计的措施之一，是参数估计中常用的措施，具有下列的特点：

1. 在一定的条件下，ML估计式满足一致性、无偏性、有效性等要求；
2. 当样本容量 $n \rightarrow \infty$ 时，ML估计式满足正态分布 \rightarrow 方差轻易计算；
3. 用ML措施可较轻易地得到参数的估计式；

本章内容：

1. 最大似然原理；
2. 用ML措施求解参数估计问题的环节；
3. ML估计式的特征；
4. 怎样计算ML估计值的方差；
5. 利用似然函数进行区间估计

第十二章 最大似然法

(Maximum Likelihood Method)

12.1 最大似然原理

12.1 最大似然原理

(一) 似然函数的定义

p.d.f: $f(\underline{x}|\theta)$

测量量: $\underline{x} = \{x_1, x_2, \dots, x_n\}$

$$L(\underline{x}|\theta) = \prod_{i=1}^n f(x_i|\theta)$$

$$\int_{\Omega} L(\underline{x}|\theta) d\underline{x} = 1$$

(二) 最大似然原理

未知参数 θ 的最佳估计值 $\hat{\theta}$ 应满足如下的条件:

- i. $\hat{\theta}$ 位于 θ 的允许取值范围;
- ii. 对于给定的一组测量值, $\hat{\theta}$ 使L取极大值:

$$L(\underline{x}|\hat{\theta}) \geq L(\underline{x}|\theta)$$

12.1 最大似然原理

(三)估计值 $\hat{\theta}$ 的求法

似然方程:
$$\frac{\partial L(\underline{x}|\theta)}{\partial \theta} = \frac{\partial}{\partial \theta} \prod_{i=1}^n f(x_i, \theta) = 0$$

极大值条件:
$$\left. \frac{\partial^2 L(\underline{x}|\theta)}{\partial \theta^2} \right|_{\theta=\hat{\theta}} < 0$$

因为 $\ln L$ 是 L 的单调上升函数, $\ln L$ 和 L 具有相同的极大值点, 所以, $L \rightarrow \ln L$, 求和运算比乘积运算轻易处理

似然方程:
$$\frac{\partial \ln L(\underline{x}|\theta)}{\partial \theta} = \frac{\partial}{\partial \theta} \sum_{i=1}^n \ln f(x_i, \theta) = 0$$

极大值条件:
$$\left. \frac{\partial^2 \ln L(\underline{x}|\theta)}{\partial \theta^2} \right|_{\theta=\hat{\theta}} < 0$$

假如有 k 个位置参数, $\underline{\theta} = \{\theta_1, \theta_2, \dots, \theta_k\}$

→ k 阶似然方程

$$\frac{\partial \ln L(\underline{x}|\theta)}{\partial \theta_j} = \frac{\partial}{\partial \theta_j} \sum_{i=1}^n \ln f(x_i, \theta) = 0 \quad j=1, 2, \dots, k$$

估计值:
$$\underline{\hat{\theta}} = \{\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k\}$$

12.1 最大似然原理

极大值条件：二次矩阵 $U(\hat{\theta})$ 是负定的(Negative definite)

$$U_{ij}(\hat{\theta}) = \frac{\partial^2 \ln L(\underline{x} | \underline{\theta})}{\partial \theta_i \partial \theta_j} \Big|_{\underline{\theta} = \hat{\theta}}$$

第十二章 最大似然法

(Maximum Likelihood Method)

12.2 用ML措施进行参数估计的环节

12.2 用ML措施进行参数估计的环节

- 1) 构造概率密度函数；
- 2) 构造似然函数；
- 3) 求似然函数的极大值。

12.2 用ML措施进行参数估计的环节

(一) 构造概率密度函数

物理系统的特征：某些量的理论概率分布函数

试验的条件：辨别率、探测效率

例：不变质量谱分析： $e^+e^- \rightarrow J/\psi \rightarrow \gamma K^+ K^-$

- 经过测量 K^+K^- 的动量，可得到 K^+K^- 的不变质量分布，对该分布进行统计分析，可得到衰变过程中产生的共振态的信息；
- 描述不变质量 m 的分布的p.d.f应包括对该分布有贡献的物理过程

12.2 用ML措施进行参数估计的环节

1. 信号事例:

$$J/\psi \rightarrow \gamma X$$

\downarrow
 $\rightarrow K^+ K^-$

在不变质量为 m_0 处出现共振态 X 的弹性散射振幅可用Breit-Wigner公式描述:

$$BW = \frac{\sqrt{\Gamma}}{m - m_0 + i\Gamma/2}$$

Γ : X 的宽度, m_0 : X 的静质量, m : K^+K^- 的不变质量

(1) 假如 Γ 较小

$$|BW| = \frac{\Gamma^2}{(m - m_0)^2 + \Gamma^2/4}$$

试验成果包括质量辨别率 σ 和探测效率的影响, $\Gamma \sim \sigma$, 故必须对理论公式进行修正

$$|BW|^2 \rightarrow \int |BW|^2 \eta(m) R(m, m') dm'$$

12.2 用ML措施进行参数估计的环节

其中:

$\eta(m)$: 效率函数, 因 $\eta(m)$ 随 m 的变化较小, 故 $\eta(m) \sim$ 常数

$R(m, m')$: 辨别率函数, 真值为 m 时, 取得测量值 m' 的概率

$$R(m, m') = \frac{1}{\sqrt{2\pi}\sigma} \exp[-\frac{1}{2}(m - m')^2 / \sigma^2]$$

σ : 质量辨别率

所以, 窄共振峰的p.d.f为

$$\int |BW|^2 R(m, m') dm' = \frac{1}{\sqrt{2\pi}\sigma} \text{Re}(w(z))$$

$$w(z) = e^{-z^2} \text{erfc}(-iz)$$

$$z = \frac{m - m_0}{\sqrt{2}\sigma} + i \frac{\Gamma}{2\sqrt{2}\sigma}$$

12.2 用ML措施进行参数估计的环节

(1) 假如 Γ 较大, 宽共振峰

因为 $\Gamma \gg \sigma$, 所以 $R(m, m') \sim \delta(m - m')$

假如在衰变过程中存在着多种宽共振, 则可能存在仙湖干涉的现象, 设有 N_{amp} 个相干的共振峰, 则描述这些共振峰的

p.d.f为

$$\sim \left| BW_1 + \sum_{k=2}^{N_{\text{amp}}} \sqrt{\delta_{k-1}} e^{-\varphi_{k-1}} BW_k \right|^2$$
$$BW_k = \frac{\sqrt{\Gamma_k}}{m - m_{0k} + i\Gamma/2}$$

φ_{k-1} : 相位差

δ_{k-1} : 第 k 个相干的共振峰事例数/第一种相干的共振峰的事例数

12.2 用ML措施进行参数估计的环节

2. 本底事例：相空间本底、粒子误判本底、其他衰变道本底等

$$f_{back}(m, \theta) \sim f_{ps}(m, \theta) \frac{1}{m_{\max} - m_{\min}} \left[1 + \sum_{i=1}^{N_b} b_i P^i(x) \right]$$

$f_{ps}(m, \theta)$: 相空间函数

$P^i(x)$: i 阶Legendre多项式

$$x = -1 + \frac{m - m_{\min}}{m_{\max} - m_{\min}}$$

b_i : 未知参数

12.2 用ML措施进行参数估计的环节

假如衰变过程中： N_{BW} 个窄共振峰、 N_{amp} 个相干共振峰，则m的pdf

$$f(m|\theta) = \sum_{k=1}^{N_{bw}} \alpha_m \cdot \frac{1}{\sqrt{2\pi\sigma_m}} \text{Re}(W(z)) / C_{BW}$$
$$+ \beta \cdot \left| BW_1 + \sum_{k=2}^{N_{amp}} \sqrt{\delta_{k-1}} e^{-i\phi_{k-1}} BW_k \right| / C_{amp}^2$$
$$+ (1 - \sum_{k=1}^{N_{BW}} \alpha_k - \beta) f_{back} / C_{back}$$

其中： C_{BW} 、 C_{amp} 、 C_{back} 为归一化常数，确保 $\int f(m|\theta) dm = 1$

α_k : 第k个窄共振峰事例数/总事例数

β : N_{amp} 个相干共振峰事例数/总事例数



(二) 构造似然函数

12.2 用ML措施进行参数估计的环节

设对某物理系统进行了n次测量， $x_1、x_2、\dots、x_n$

$$\ln L(\underline{x}|\underline{\theta}) = \sum_{i=1}^n \ln f(x_i|\underline{\theta})$$

根据需要可对 $L(\underline{x}|\underline{\theta})$ 进行变化：

1. 广义似然函数（Generalized Likelihood Function）

总事例数n也是随机变量，服从平均值为v的泊松分布：

- 在试验条件一定的条件下，事例的产生率为常数，
- 在时间t内取得n个事例的概率为泊松分布。

观察到n个事例，且测量量为 $x_1、x_2、\dots、x_n$ 的联合概率为

$$L(n, \underline{x}|\underline{\theta}) = \frac{v^n e^{-v}}{n!} L(\underline{x}|\underline{\theta}) = \frac{v^n e^{-v}}{n!} \prod_{i=1}^n f(x_i|\underline{\theta})$$

→ 广义似然函数， $v = v(\underline{\theta})$

优点：n对 θ 增长了附加的限制

条件：v必须能够精确拟定

12.2 用ML措施进行参数估计的环节

2. 数据分类情况下的似然函数

对试验数据进行分间隔处理，（如作成直方图）然后用ML措施对分类后的数据进行处理。

优点：减小了数据量，使得对 L 的计算速度加紧

缺陷：因为将原 L 简化为少许的几种“平均” pdf的乘积，使得参数估计的精度下降。

设将 x 的变化范围提成了 N 个间隔

n_i : 第 i 个间隔内的事例数

$$\sum_{i=1}^N n_i = n$$

p_i : 某事例落入第 i 个间隔的概率

N 个事例分布于 N 个间隔内，每个间隔内的事例数为 n_1 、 n_2 、 \dots 、 n_N

的概率满足多项式分布：

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/116052215125010224>