

司继春

¹ 上海对外经贸大学

2023年12月

- ① 假设检验的基本概念
- ② 假设检验的一般步骤
- ③ 评价检验的方法
- ④ 构造假设检验的一般方法

总体参数 θ 的参数估计问题

总体参数 θ 是多少的问题，
题，还要回答「是不是」的

城镇住户调查的数据中，男性
元，那么我们是不是可以推断
。还是仅仅因为抽样的巧合导
性收入高？

sis testing) 的方法回答此

- 总体参数 θ 的参数估计问题
- 总体参数 θ 是多少的问题，
题，还要回答「是不是」的
- 城镇住户调查的数据中，男性
元，那么我们是不是可以推断
。还是仅仅因为抽样的巧合导
性收入高？
- sis testing) 的方法回答此

一个命题。

想。由于总体参
们不能确切的知
对以上命题进行

数学命题中的
的假设是我们要
假设则是结论的

- ◀ ◻ ▶ ◀ ◻ ▶ ◀ ≡ ▶ ◀ ≡ ▶ ≡ ▶ ↺ 🔍 ↻

原假设 (null hypothesis)
(H_0)，分别用 H_0 和 H_1 来表
参数 $\theta \in \Theta$ ，而原假设
原假设的补集，即 $\theta \in \Theta_0^c$ 。
设是 $\theta = \theta_0$ ，那么备择假设就
备择假设就是 $\theta < \theta_0$ 。

- 假设检验中有两个互补的假设：原假设（null hypothesis）和备择假设（alternative hypothesis），分别用 H_0 和 H_1 来表示。
- 如果参数的范围为 Θ ，即总体参数 $\theta \in \Theta$ ，而原假设为 $\theta \in \Theta_0$ ，那么备择假设即为原假设的补集，即 $\theta \in \Theta_0^c$ 。
 - 比如，如果 $\Theta = \mathbb{R}$ ，若原假设是 $\theta = \theta_0$ ，那么备择假设就是 $\theta \neq \theta_0$ ；
 - 若原假设是 $\theta \geq \theta_0$ ，那么备择假设就是 $\theta < \theta_0$ 。
- 注意原假设一般包含等号。

H_0)”的说法与“不能拒绝原假设”的说法不同。
不能拒绝原假设，可能是由于原假设的确就是对的，因而正确。
想要搜集证据去推翻的结论放

- ◀ ◻ ▶ ◀ ◻ ▶ ◀ ≡ ▶ ◀ ≡ ▶ ≡ ▶ ↺ 🔍 ↻

两类假设的推断

- 由于统计方法总会存在误差，因而基于以上两类假设的推断也会存在犯错的可能性。在假设检验中，有两种错误可能会发生：
 - 第I类错误（type-I error）：原假设为真，但是拒绝原假设，即“弃真错误”；
 - 第II类错误（type-II error）：备择假设为真，但是接受原假设，即“取伪错误”。
- 比如：
 - 如果一个被告本来无罪，但是错误地判其有罪，那么就犯了第I类错误；
 - 而如果一个被告的确犯罪，但是却判其无罪，那么就犯了第II类错误。

◀ ◻ ▶ ◀ ◻ ▶ ◀ ≡ ▶ ◀ ≡ ▶ ≡ ▶ ↺ 🔍 ↻

- $$P_{\theta \in \Theta_0} (T(\mathbf{x}) \in R)$$

假设检验

正态总体假设检验

- $$P_{\theta=0}(\bar{x} \in R) = P_{\theta=0}(|\bar{x}| > 0.5)$$

$$\begin{aligned}
&= P_{\theta=0} \left(\left| \frac{\bar{x}}{\sqrt{\frac{1}{N}}} \right| > \frac{0.5}{\sqrt{\frac{1}{N}}} \right) \\
&= 2 \left(1 - \Phi \left(\frac{0.5}{\sqrt{\frac{1}{N}}} \right) \right)
\end{aligned}$$

- 如果令 $N = 16$, 那么

$$P_{\theta=0}(\bar{x} \in R) = 2(1 - \Phi(2)) \approx 4.56\%$$

- 以上概率是我们在原假设的假设上进行的计算的，这意味着，如果原假设成立，那么得到均值落在拒绝域，即 $\bar{x} \in R = (-\infty, -0.5) \cup (0.5, \infty)$ 的概率为4.56%。
- 在原假设成立的条件下，我们犯错的概率就是4.56%，即犯第I类错



外 經

$$- \Phi \left(\frac{0.5}{\sqrt{\frac{1}{N}}} \right)$$

- 率上界为
为2.28%。

$$\sup_{\theta \in \Theta_0} P_{\theta}(T(x) \in R) = 1 - \Phi\left(\frac{0.5 - 0}{\sqrt{\frac{1}{N}}}\right) = 1 - \Phi\left(\frac{0.5}{\sqrt{\frac{1}{N}}}\right)$$

- 当 $N = 16$ 时，上式为 $1 - \Phi(2) \approx 2.28\%$ ，即在原假设 $H_0: \mu \leq 0$ 的假设下，错误拒绝原假设的概率上界为2.28%，或者等价的，犯第I类错误的概率上界为2.28%。

- 在假设检验中，我们通常希望控制犯第I类错误的概率在某个水平以内，即给定一个 α ，找到一个拒绝域 R_α ，使得

$$\sup_{\theta \in \Theta_0} P_\theta (T(\mathbf{x}) \in R_\alpha) \leq \alpha$$

- 如此，我们便保证了使用拒绝域 R_α 进行假设检验，犯第I类错误的概率不超过 α 。
- 我们称 α 为显著性水平（level of significance）
 - 如果我们能够保证 $\sup_{\theta \in \Theta_0} P_\theta(T(\mathbf{x}) \in R_\alpha) = \alpha$ ，我们通常称这个检验的水准（size）为 α 。
 - 否则，如果只能保证 $\sup_{\theta \in \Theta_0} P_\theta(T(\mathbf{x}) \in R_\alpha) \leq \alpha$ ，我们称这个检验的水平（level）为 α 。
 - 一般不做明确区分，我们接下来统一成为显著性水平。

作为一个区间，区间的临界点

代表在不同的显著性水平下假设

，

显著，则标记一个“*”符号

显著，则标记两个“*”符号，即“**”

显著，则标记“***”符号。

更加不能容忍，因而我们会

区域也会越小。



此外，我们还可以定义 p 值。

- p 值指的是，给定检验统计量 $T(\boldsymbol{x}) = t$ ，在原假设的条件下，能够取到 t 或者比 t 更加极端的值的概率。
- 或者等价的， p 值可以被定义为能够拒绝原假设的最小的显著性水平，即给定 $T(\boldsymbol{x}) = t$ ：

$$p = \inf \{ \alpha \in (0, 1) : t \in R_\alpha \}$$

- 由于检验统计量 $T(\mathbf{x})$ 为随机变量，因而 $p(\mathbf{x}) = \inf \{ \alpha \in (0, 1) : T(\mathbf{x}) \in R_\alpha \}$ 也是一个随机变量。
- 当 $p \leq 0.01, 0.05, 0.1$ 时，可以在相应的显著性水平下拒绝原假设。
- 如下图所示，绿色区域面积即 p 值。
- 需要特别注意的是，对于双侧检验，需要同时计算两侧的绿色面积。

p 值



原假设成立时，重复了
拒绝原假设的次数
了10个 $x_i \sim N(0, 1)$ ，并
显著性水平下进行假设检验
否则为0。
重复了10000次
及，与我们5%的显著性

总体均值的检验（小样本正态总体）

- 在代码test_under_null.do中，我们在原假设成立时，重复了10000次以上的假设检验，并计算了拒绝原假设的次数
 - 在test_normal_mean程序中，生成了10个 $x_i \sim N(0, 1)$ ，并在 $H_0: \mu = 0$ 的原假设以及5%的显著性水平下进行假设检验
 - 如果拒绝原假设则返回rejected=1，否则为0。
 - 我们将以上步骤通过simulate命令重复了10000次
- 最终有5.1%的假设检验拒绝了原假设，与我们5%的显著性水平一致。

常见的假设检验

总体均值的检验（大样本）

- 在上例中，如果不假设样本的正态性，但是在大量样本条件下，有

$$z = \frac{\bar{x} - \mu_0}{\sqrt{\frac{s^2}{N}}} \stackrel{a}{\sim} N(0, 1)$$

- 因而在原假设： $H_0: \mu = \mu_0$ 的条件下，可知当 $|z| \geq 1.96$ 时，则在5%的显著性水平下是显著的。
- 由于 $\sqrt{\frac{s^2}{N}}$ 为 $\bar{x}$ 的标准误的估计，即 $s.e.(\bar{x})$ ，因而经验法则是当 $\bar{x} - \mu_0$ 超过 $1.96 \times s.e.$ 时，即可以在5%的显著性水平下拒绝原假设
- 不同学科中该标准可能存在差异，比如在物理学中，要求超过5个标准误才可以认定为证据，比一般社会科学的要求更加严格。

正态分布，因而在大样本条件下，
正态分布是完全可以的
区分小样本或大样本情况，而
为临界值（即都当做 t 检验来

- A set of small navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and other slide controls.

实践中的总体均值检验

CFPS中收入的检验

- 该检验的 p 值应为 $p = 1 - \Phi(10.41)$ ，即10.41右侧的面积。
- 如果原假设为 $H_0: \mu = 8000$ ，这是一个双侧检验，那么 p 值应为 $p = 2(1 - \Phi(10.41))$ 。
- 在Stata中，可以使用“ttest”命令进行该检验：

```
1 use datasets/cfps_adult.dta, clear
2 // 删掉不适用
3 drop if p_income < 0
4 // 进行检验 t
5 ttest p_income = 8000
```

A set of small navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and other slide controls.

- $$z = \frac{\bar{x} - p_0}{\sqrt{\frac{s^2}{N}}} = \frac{\hat{p} - p_0}{\sqrt{\frac{\hat{p}(1-\hat{p})}{N}}} \stackrel{a}{\sim} N(0, 1)$$

- $$z = \frac{\bar{x} - p_0}{\sqrt{\frac{\sigma^2}{N}}} = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{N}}} \stackrel{a}{\sim} N(0, 1)$$

- 由于检验统计量的分布是在原假设成立的条件下得到的，所以分母上使用 p_0 是完全可以的，结论仍然不变。

UNIVERSITY OF INTERNATIONAL BUSINESS

-

外科综合

ear

=3

- UNIVERSITY OF INTERNATIONAL BUS

- 根据以上的假设检验步骤，我们知道假设检验可以控制犯第I类错误的概率
- 然而对于假设检验而言，还有犯第II类错误的可能性，即当我们无法拒绝原假设的时候，备择假设可能是成立的。为
- 了研究第II类错误的概率，我们引入假设检验的势（power）的概念。

对于一个检验统计量 $T(\boldsymbol{x})$ 及其拒绝域 R , 检验的势函数 (power function) 即给定真实参数 θ 时, 拒绝原假设的概率, 即

$$\beta(\theta) = P_{\theta}(T(\mathbf{x}) \in R)$$

Θ_0 或者 $\theta \in \Theta_0^c$, 因而接近于0, 而

设定了在原假设成为显著性水平 α , 因该接近或者等于 α 。拒绝原假设的概率,

- 是，我们设定了在原假设成立的概率为显著性水平 α ，因此 $\beta(\theta)$ 应该接近或者等于 α 。
- 计，没有拒绝原假设的概率，
概率。

势函数

正态总体均值单侧检验的势函数

若样本 $x_i \sim N(\mu, \sigma^2)$ $i.i.d, i = 1, \dots, N$, 且 σ^2 已知, 设原假设为 $H_0: \mu \leq \mu_0$, 备择假设为 $H_1: \mu > \mu_0$, 那么可以构建检验统计量为

$$T(x) = \frac{\bar{x} - \mu_0}{\sqrt{\frac{\sigma^2}{N}}} \sim N(0, 1)$$

在原假设的条件下, 若给定 $\alpha = 0.05$, 那么 $R_{0.05} = (z_{0.05}, \infty) = (1.65, \infty)$ 。

势函数


正态总体均值单侧检验的势函数

因而, 给定 μ , 势函数为

$$\begin{aligned}\beta(\mu) &= P_{\mu}(T(x) \in R_{0.05}) \\ &= P_{\mu}\left(\frac{\bar{x} - \mu_0}{\sqrt{\frac{\sigma^2}{N}}} > z_{0.05}\right) \\ &= P_{\mu}\left(\frac{\bar{x} - \mu}{\sqrt{\frac{\sigma^2}{N}}} > z_{0.05} + \frac{\mu_0 - \mu}{\sqrt{\frac{\sigma^2}{N}}}\right) \\ &= 1 - \Phi\left(z_{0.05} + \frac{\mu_0 - \mu}{\sqrt{\frac{\sigma^2}{N}}}\right)\end{aligned}$$

The graph displays two probability density functions. The black curve, representing a normal distribution, is centered at 0 with a peak height of 0.4. The red curve, also a normal distribution, is centered at 3 with a peak height of 0.4. A vertical dashed line is drawn at $x = 1$. The area under the red curve to the right of $x = 1$ is shaded green, representing the probability $P(X > 1)$ for the red distribution.

势函数



此外还有

Page 10 of 10

量及其在原假

$$t = \frac{\bar{x}}{\sqrt{\frac{s^2}{N}}} \sim t(N-1)$$

模拟，
都重复进行
验中拒绝的比



拒绝原假设时，此时只有可能

因而我们可以有比较强的自信

我们只有可能犯第II类错误

依赖于样本量以及真实参数与原假设

而一般情况下我们并不知道犯第

一般情况下我们也不能说原假设

假设并不成立，仅仅是样本量不

的证据拒绝原假设而已。

- 当我们进行假设检验并且可以拒绝原假设时，此时只有可能犯第I类错误而非第II类错误
 - 而第I类错误的概率不超过 α ，因而我们可以有比较强的自信认为原假设的确不成立。
- 但是当我们不能拒绝原假设时，我们只有可能犯第II类错误而非第I类错误
 - 然而犯第II类错误的概率依赖于样本量以及真实参数与原假设之间差距的绝对大小，因而一般情况下我们并不知道犯第II类错误的概率
 - 因而如果不能拒绝原假设，一般情况下我们也不能说原假设就是对的，因为很有可能原假设并不成立，仅仅是样本量不足以使得我们收集到足够多的证据拒绝原假设而已。

无差异区域与样本量

- 介于此种情况，我们可以引入无差异区域（indifference region）
 - 即虽然备择假设为真，但是 θ 与 θ_0 的差异足够的小，我们认为在这个区域里面错误接受原假设也是可以接受的
 - 此时我们可以计算出一个为了能够在一定概率下区分出无差异区域以外的差异所需的样本量。

单个参数的检验

泊松分布参数估计的假设检验

- 若 $x_i \sim P(\lambda)$, 我们希望在5%显著性水平下, 对于原假设: $H_0: \lambda = 10$ 进行检验。
- 首先得到点估计, 其矩估计 (极大似然估计) 为: $\hat{\lambda} = \bar{x}$ 。
- 根据中心极限定理, 有

$$\sqrt{N}(\hat{\lambda} - \lambda) \overset{a}{\sim} N(0, \lambda)$$

因而

$$\frac{\sqrt{N}(\hat{\lambda} - 10)}{\sqrt{10}} \overset{a}{\sim} N(0, 1)$$

- 如果 $\left| \frac{\sqrt{N}(\hat{\lambda} - 10)}{\sqrt{10}} \right| > 1.96$, 则可以拒绝原假设。

Wald检验

- 如果对于 θ 的估计，我们已经有

$$\sqrt{N}(\hat{\theta} - \theta) \stackrel{a}{\sim} N(0, \Sigma)$$

，那么使用Delta方法：

$$C(\hat{\theta}) = C(\theta) + \ddot{C}(\hat{\theta} - \theta) + O(|\hat{\theta} - \theta|^2)$$

其中 $\ddot{C} = \frac{\partial^2 C(\theta)}{\partial \theta^2}$ 为在真值 θ 处的 $r \times k$ 的雅克比矩阵，且假设 $\text{rank}(\ddot{C}) = r$ ，那么在原假设 $H_0: C(\theta) = 0$ 的条件下，带入 $C(\theta) = 0$ ，得到：

$$\sqrt{N}C(\hat{\theta}) = \ddot{C}\sqrt{N}(\hat{\theta} - \theta_0) + o_p(1) \stackrel{a}{\sim} N(0, \ddot{C}\Sigma\ddot{C}')$$

- $\hat{\theta}_n(r) \stackrel{a}{\sim} \chi^2(r)$
- 进行假设检验。

$$C'(\hat{\theta}) \left[\frac{\ddot{C}\Sigma\ddot{C}'}{N} \right]^{-1} C(\hat{\theta}) \stackrel{a}{\sim} \chi^2(r)$$

可以使用以上检验统计量对原假设进行假设检验。

Wald检验

Wald检验示例

- 假设 $x_i \sim (\mu, \sigma^2)$ ，我们需要检验： $H_0 : \mu^2 = 1$ ，或者： $H_0 : \mu^2 - 1 = 0$ 。
 - 该原假设相当于同时检验了 $\mu = \pm 1$ 。
- 由于

$$\hat{\mu} = \bar{x} \overset{a}{\sim} N\left(\mu, \frac{\sigma^2}{N}\right)$$

从而使用Delta方法，有

$$\begin{aligned}\sqrt{N} [(\hat{\mu}^2 - 1) - (\mu^2 - 1)] &= 2\mu\sqrt{N} (\hat{\mu} - \mu) + o_p(1) \\ &\overset{a}{\sim} N(0, 4\mu^2\sigma^2)\end{aligned}$$

Wald检验

Wald检验示例

- 将原假设 $H_0 : \mu^2 - 1 = 0$ 带入，得到：

$$\left(\frac{4\mu^2\sigma^2}{N} \right)^{-1/2} (\hat{\mu}^2 - 1) \stackrel{a}{\sim} N(0, 1)$$

从而：

$$\frac{(\hat{\mu}^2 - 1)^2}{\frac{4\mu^2\sigma^2}{N}} \stackrel{a}{\sim} \chi^2(1)$$

Wald检验

Wald检验示例

- 由于分母中 μ, σ^2 未知，我们可以使用其一致估计代替，从而：

$$\frac{N(\hat{\mu}^2 - 1)^2}{4\hat{\mu}^2\hat{\sigma}^2} \underset{a}{\sim} \chi^2(1)$$

- 当原假设成立时，以上检验统计量应该趋向于0，因而拒绝域在 χ^2 分布的右侧，因而该检验应为右侧检验。
- 即，当

$$\frac{N(\hat{\mu}^2 - 1)^2}{4\hat{\mu}^2\hat{\sigma}^2} > \chi_{0.05}^2(1)$$

时，拒绝原假设。

Wald检验

Wald检验示例

- 我们使用simulation_wald_test.do对以上检验在原假设和备择假设下分别进行了模拟，结果如下图所示
- 其中：
 - (a)展示了原假设下模拟的检验统计量的直方图以及 $\chi^2(1)$ 的密度函数
 - 而(b)展示了原假设下模拟的检验统计量的直方图以及 $\chi^2(1)$ 的密度函数。
 - 可以发现，虽然样本量比较少，原假设下检验统计量的分布与 $\chi^2(1)$ 非常接近，而备择假设下两者有相当区别。
 - 原假设下检验统计量大于临界值的模拟次数大约占5.58%，与5%相差较小；而备择假设下大于临界值的模拟大约占99.74%。



成立，在 H_0 的约束

- $\max_{\theta} L(\theta|x)$

假设。

- 假设。

假设。

假设。

到的，而 $\hat{\theta}$ 是在无约束的条件 $\tilde{\theta}|x$ 。那么是否对极大似然不及施加很大影响，从而 $\tilde{\theta}$ 和 $\hat{\theta}$ 应该充分接近；约束就会起作用，从而得到而 $L(\hat{\theta}|x)$ 和 $L(\tilde{\theta}|x)$ 也应该有 $L(\hat{\theta}|x) \gg L(\tilde{\theta}|x)$ 成立，那么立的。

- 由于 $\tilde{\theta}$ 是在 H_0 的约束条件下得到的，而 $\hat{\theta}$ 是在无约束的条件下得到的，因而 $L(\hat{\theta}|x) \geq L(\tilde{\theta}|x)$ 。
- 如果原假设成立，即 $C(\theta) = 0$ ，那么是否对极大似然不及施加原假设并不会对参数估计造成很大影响，从而 $\tilde{\theta}$ 和 $\hat{\theta}$ 应该充分接近，因而 $L(\hat{\theta}|x)$ 和 $L(\tilde{\theta}|x)$ 也应该充分接近；
- 但是如果原假设不成立，那么约束就会起作用，从而得到的 $\tilde{\theta}$ 和 $\hat{\theta}$ 应该有相当的差距，因而 $L(\hat{\theta}|x)$ 和 $L(\tilde{\theta}|x)$ 也应该有足够大的差距。
- 根据此逻辑，反过来，如果 $L(\hat{\theta}|x) \gg L(\tilde{\theta}|x)$ 成立，那么我们可以认为 $C(\theta) = 0$ 是不成立的。

然函数值在取得最大时，
即

$$|x) \Big] \stackrel{a}{\sim} \chi^2(r)$$

$= 0$ 进行检验。

，而备择假设成立的条
是一个右侧检验。

(likelihood-ratio test) 。

- 注意原假设成立的条件下, $LR \approx 0$, 而备择假设成立的条件下, $LR > 0$, 所以以上检验同样是一个右侧检验。
- 以上检验我们通常成为似然比检验 (likelihood-ratio test)。

似然比检验

泊松分布的似然比检验

如果 $x_i \sim P(\lambda)$, $i = 1, \dots, N$, 如果原假设为 $H_0: \lambda = 1$

- 无约束时, $\hat{\lambda} = \bar{x}$,
- 有约束时, $\tilde{\lambda} = 1$ 。
- 其似然函数分别为:

$$L(\hat{\lambda}|x) = \sum_{i=1}^N [x_i \ln(\hat{\lambda}) - \ln(x_i!) - \hat{\lambda}] = \sum_{i=1}^N [x_i \ln(\bar{x}) - \ln(x_i!) - \bar{x}]$$

$$L(\tilde{\lambda}|x) = \sum_{i=1}^N [x_i \ln(\tilde{\lambda}) - \ln(x_i!) - \tilde{\lambda}] = \sum_{i=1}^N [x_i \ln(1) - \ln(x_i!) - 1]$$

泊松分布的似然比检验

- $$\begin{aligned} LR &= 2 \left[\sum_{i=1}^N [x_i \ln(\bar{x}) - \ln(x_i!) - \bar{x}] - \sum_{i=1}^N [x_i \ln(1) - \ln(x_i!) - 1] \right] \\ &= 2 \left[\sum_{i=1}^N [x_i \ln(\bar{x}) - \bar{x} + 1] \right] \\ &= 2N [\ln(\bar{x}) \bar{x} - \bar{x} + 1] \\ &\stackrel{a}{\sim} \chi^2(1) \end{aligned}$$

- 模拟: simulation_lr_test.do

MathStatsCode/combinatorics/modulationnbresesi

(b)

似然比检验

Beta分布的似然比检验

如果 $x_i \sim B(\alpha, \beta)$, 原假设为: $H_0: \alpha = 1, \beta = 1$ 此时我们需要同时检验两个假设, 我们仍然可以通过似然比检验对其进行检验。

- 如果 $(\hat{\alpha}, \hat{\beta})$ 为极大似然估计, 那么无约束时的似然函数为:

$$L(\hat{\alpha}, \hat{\beta}|x) = \sum_{i=1}^N \left[-\ln B(\hat{\alpha}, \hat{\beta}) + (\hat{\alpha} - 1) \ln x_i + (\hat{\beta} - 1) \ln(1 - x_i) \right]$$

- 而有约束时的似然函数:

$$L(\hat{\alpha}, \hat{\beta}|x) = L(1, 1|x) = -N \ln B(1, 1) = 0$$

- 从而似然比检验统计量为:

$$LR = 2 \sum_{i=1}^N \left[-\ln B(\hat{\alpha}, \hat{\beta}) + (\hat{\alpha} - 1) \ln x + (\hat{\beta} - 1) \ln(1 - x) \right] \stackrel{a}{\sim} \chi^2(2)$$

是其有一个缺点即需要估计两大似然估计和有约束的极大似然估计无约束的估计，且不仅问题比估计无约束的问题要简单，有约束的估计甚至不需要计算已经给出了答案，相比之下无约束的估计从而进行检验呢？

- 是其有一个缺点即需要估计两大似然估计和有约束的极大似然估计无约束的估计，且不仅问题比估计无约束的问题要简单，有约束的估计甚至不需要计算已经给出了答案，相比之下无约束的估计从而进行检验呢？

拉格朗日乘子检验

- 考虑有约束的极大似然估计问题，通常我们可以使用拉格朗日乘子法求解：

$$\mathcal{L}(\theta, \lambda) = L(\theta|x) - \lambda C(\theta)$$

从而一阶条件为

$$\begin{aligned}\frac{\partial \mathcal{L}(\theta, \lambda)}{\partial \theta} &= \frac{\partial L(\theta|x)}{\partial \theta} - \lambda \frac{\partial C(\theta)}{\partial \theta} = 0 \\ \frac{\partial \mathcal{L}(\theta, \lambda)}{\partial \lambda} &= -C(\theta) = 0\end{aligned}$$

从而解得 $\tilde{\theta}$ 。

拉格朗日乘子检验

- 考虑如果原假设成立，即对于真值 θ ，约束 $C(\theta) = 0$ 成立，那么此时 $\tilde{\theta}$ 应该同时可以最大化 $L(\theta|x)$ ，从而：

$$\frac{\partial L(\tilde{\theta}|x)}{\partial \theta} = \sum_{i=1}^N s_i(\tilde{\theta}) \approx 0$$

我们可以通过检验以上一阶条件是否成立来检验原假设是否成立。

- Rao (1948) 提出了如上检验，由于以上检验实际上等价于检验得分函数的期望 $\mathbb{E}s_i(\tilde{\theta}) = 0$ ，从而以上检验被称为得分检验 (score test)。
- 如果取原假设为 $H_0: \theta = \theta_0$ ，从而 $\ddot{C} = 1$ ，带入以上拉格朗日乘子法的一阶条件中，就可以得到 $\lambda = \sum_{i=1}^N s_i(\tilde{\theta})$ ，因而 Aitchison 和 Silvey (1958) 以及 Silvey (1959) 将称为拉格朗日乘子检验 (Lagrangian multiplier test, LM test)。

拉格朗日乘子检验

- 为了构造渐近分布，注意到在原假设的条件下， $\mathbb{E}\left(s_i\left(\tilde{\theta}\right)\right)=0$ ，从而其渐近分布为

$$\frac{1}{\sqrt{N}} \sum_{i=1}^N s_i(\tilde{\theta}) \stackrel{a}{\sim} N(0, \mathcal{I}_0)$$

从而可以使用

$$\frac{1}{N} \left[\sum_{i=1}^N s_i \left(\tilde{\theta} \right) \right]' \mathcal{I}_0^{-1} \left[\sum_{i=1}^N s_i \left(\tilde{\theta} \right) \right] \approx \chi^2(r)$$

进行假设检验。

- 由于 $\mathcal{I}_0$ 不可观测，实际使用时可以将有约束的极大似然估计带入，从而得到其估计 $\tilde{\mathcal{I}}$ ，带入上式即可。

拉格朗日乘子检验

Beta分布的LM检验

考虑使用得分检验对似然比检验中Beta分布检验的问题构造检验统计量。

- 极大似然函数为

$$L(\alpha, \beta | x) = \sum_{i=1}^N [-\ln B(\alpha, \beta) + (\alpha - 1) \ln x_i + (\beta - 1) \ln (1 - x_i)]$$

- 首先计算得分函数：

$$s_i(\alpha, \beta) = \frac{\partial L(\alpha, \beta | x_i)}{\partial \begin{pmatrix} \alpha \\ \beta \end{pmatrix}} = \begin{pmatrix} -\frac{\Gamma'(\alpha)}{\Gamma(\alpha)} + \frac{\Gamma'(\alpha+\beta)}{\Gamma(\alpha+\beta)} + \ln x_i \\ -\frac{\Gamma'(\beta)}{\Gamma(\beta)} + \frac{\Gamma'(\alpha+\beta)}{\Gamma(\alpha+\beta)} + \ln (1 - x_i) \end{pmatrix}$$

拉格朗日乘子检验

Beta分布的LM检验

- 记 $\psi_0(z) = \frac{\Gamma'(z)}{\Gamma(z)} = \frac{d}{dz} \ln \Gamma(z)$ 为多伽马函数 (polygamma function), 根据其性质: $\psi_0(z+1) = \psi_0(z) + \frac{1}{z}$
- 将原假设 $\alpha = \beta = 1$ (从而有约束的估计 $\tilde{\alpha} = \tilde{\beta} = 1$) 带入, 得到

$$s_i(\tilde{\alpha}, \tilde{\beta}) = \begin{pmatrix} 1 + \ln x_i \\ 1 + \ln(1 - x_i) \end{pmatrix}$$

继续求海塞矩阵有

$$H_i(\alpha, \beta) = \begin{bmatrix} -\psi_1(\alpha) + \psi_1(\alpha + \beta) & \psi_1(\alpha + \beta) \\ \psi_1(\alpha + \beta) & -\psi_1(\alpha) + \psi_1(\alpha + \beta) \end{bmatrix}$$

其中 $\psi_1(z) = \frac{d}{dz} \psi_0(z) = \frac{d^2}{dz^2} \ln \Gamma(z)$

此外还有

A set of small navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and other slide controls.

- 司继春

假设检验

从而检验统计量为

$$\frac{1}{N} \left[\sum_{i=1}^N \begin{pmatrix} 1 + \ln x_i \\ 1 + \ln(1 - x_i) \end{pmatrix} \right]' \tilde{\mathcal{I}}^{-1} \left[\sum_{i=1}^N \begin{pmatrix} 1 + \ln x_i \\ 1 + \ln(1 - x_i) \end{pmatrix} \right] \underset{(2)}{\sim} \chi^2$$

Beta分布的LM检验

- 其中 ψ_0, ψ_1 函数可以由计算机语言计算
 - 比如在Stata中，两个函数分别可以通过digamma(x)以及trigamma(x)两个函数计算。
- 以上检验过程甚至无需进行参数估计，只需要将原假设带入以上公式即可，是非常方便的办法。

- 以上拉格朗日乘子检验不仅可以应用在极大似然估计中，在其他检验中也可以类似应用。
- 比如，对于所有通过最大（小）化目标函数得到估计的估计量中，都可以计算无约束最优化的一阶条件，并将有约束估计量带入，检验一阶条件是否为0。
 - 比如我们前面提到，矩估计可以转化为广义矩估计，从而转化为一个求极值的问题，当然可以采用类似手段。

泊松分布的LM检验

- $$\frac{1}{\sqrt{N}} \sum_{i=1}^N (x_i - 10) \stackrel{a}{\sim} N(0, 10)$$

- $$\frac{1}{N \times 10} \left[\sum_{i=1}^N (x_i - 10) \right]^2 \stackrel{a}{\sim} \chi^2(1)$$

MathInstat0605/modatinnbmese/str

(b)

(a)

(b)

LM检验与模型设定检验

- 由于得分检验通常依赖于有约束的参数估计，而有约束的参数估计通常比较容易计算，所以在很多检验，特别是模型设定检验或者模型诊断中非常有用。
- 通常我们可以先计算一个简单的模型（带约束的），使用得分检验检验是否需要更复杂的模型
 - 如果该检验不显著，那么意味着使用复杂模型的必要性不足；
 - 否则如果检验显著，则意味着我们可能需要更复杂的模型。

- $$\mathbb{E}(y_i|x_i) = \alpha + \beta x_i$$

UNIVERSITY OF INTERNATIONAL BUSINESS

- 然而我们可能会猜测 x_i 对 y_i 没有均值上的预测能力，即 $\beta = 0$
- 如果该假设成立，那么以上问题就变成了一个简单的正态总体参数估计问题。

假设检验

Method: `StatsCode/modulationnames/si`

(b)

(a)

(b)

- 因而，如果我们需要检验是否需要更复杂的线性回归模型，只需要计算以上统计量
 - 如果以上检验拒绝了原假设，那么意味着线性回归统计量是比简单的均值计算更好的模型，或者 x 对 y 有预测能力，从而可以进行线性回归的建模；
 - 反之，则代表现有证据对使用线性回归的证据不足，或者 x 对 y 有预测能力的证据不足。

检验的方法：Wald检验、似
乘子（LM）检验。

的估计量；
估计量；
和不受约束的估计量。

（卡方分布）和自由度，实际
以上三种检验是渐近等价的。

- 的估计量；
估计量；
和不受约束的估计量。
- （卡方分布）和自由度，实际
以上三种检验是渐近等价的。



三种检验的关系

- 观察上图
 - Wald检验重在检验 θ_0 与 $\hat{\theta}$ 之间的距离；
 - LR检验重在检验似然函数 $L(\theta_0)$ 与 $L(\hat{\theta})$ 之间的距离；
 - LM检验则是检验 θ_0 处切线的斜率。
- 如果原假设成立，那么应该有 $\hat{\theta} \approx \theta_0$ ，从而 $L(\hat{\theta}) \approx L(\theta_0)$ ，而此时切线斜率应该为0（由于最大化）。
- 因此三者虽然形式不同，但是本质上相同的检验。