

粒子物理与核物理实验中的 数据分析

陈少敏
清华大学

第九讲：最小二乘法

本讲要点

- 最小二乘法与最大似然法的关系
- 线性情况下的最小二乘估计
- 非线性情况下的最小二乘估计
- 约束情况下的最小二乘法
- 检验最小二乘法的拟合优度
- 应用最小二乘法处理分区数据
- 不等精度关联实验结果的并合问题

最小二乘法与最大似然法

假设有高斯随机变量: $y_i, i=1, \dots, N$, 其平均值为

$$E[y_i] = \lambda_i = \lambda(x_i; \vec{\theta})$$

这里, x_1, \dots, x_N 与 $V[y_i] = \sigma_i^2$ 已知。


为了估计参数 $\vec{\theta}$, 可以用曲线拟合所有的测量点(见右图)。

对于独立的高斯变量 y_i , 联合概率密度函数为

$$g(\vec{y}; \vec{\lambda}, \vec{\sigma}^2) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left(-\frac{(y_i - \lambda_i)^2}{2\sigma_i^2}\right)$$

对应的对数似然函数(去掉与 θ 无关的项)为

$$\log L(\vec{\theta}) = -\frac{1}{2} \sum_{i=1}^N \frac{[y_i - \lambda(x_i; \vec{\theta})]^2}{\sigma_i^2} \rightarrow \chi^2(\vec{\theta}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i; \vec{\theta})]^2}{\sigma_i^2}$$



求 $\log L(\vec{\theta})$ 的最大值等效于求 χ^2 的最小值。

最小二乘估计量的定义

如果 y_i 是一多维高斯变量，协方差矩阵为 V ，满足

$$g(\vec{y}; \vec{\lambda}, V) = \frac{1}{(2\pi)^{N/2} |V|^{1/2}} \exp\left[-\frac{1}{2} (\vec{y} - \vec{\lambda})^T V^{-1} (\vec{y} - \vec{\lambda})\right]$$

那么其对数似然函数为

$$\log L(\vec{\theta}) = -\frac{1}{2} \sum_{i=1}^N [y_i - \lambda(x_i; \vec{\theta})] (V^{-1})_{ij} [y_j - \lambda(x_j; \vec{\theta})]$$

也就是说，我们应求下式的最小值

$$\chi^2(\vec{\theta}) = \sum_{i,j=1}^N [y_i - \lambda(x_i; \vec{\theta})] (V^{-1})_{ij} [y_j - \lambda(x_j; \vec{\theta})]$$

它的最小值定义了最小二乘法的估计量 θ ，即使 y_i 不是高斯变量，该定义依然适用。(实际上， y_i 通常是高斯的，因为中心极限定理会导出测量误差也是高斯的。)

线性最小二乘法估计

如果 $\lambda(x; \vec{\theta})$ 是 $\vec{\theta}$ 的线性函数，最小二乘法有一些简单的特殊性质，

$$\lambda(x; \vec{\theta}) = \sum_{j=1}^m a_j(x) \theta_j$$



$\hat{\vec{\theta}}$ 没有偏置，而且得到的方差最小(高斯-马尔可夫定理)。

这里 $a_j(x)$ 是 x 的任意线性独立函数。

用矩阵来表示时，令 $A_{ij}=a_j(x_i)$ ，有

$$\chi^2(\vec{\theta}) = (\vec{y} - \vec{\lambda})^T V^{-1} (\vec{y} - \vec{\lambda}) = (\vec{y} - A\vec{\theta})^T V^{-1} (\vec{y} - A\vec{\theta})$$

对 θ_i 求偏微分，并令结果等于零，有

$$\nabla \chi^2 = -2(A^T V^{-1} \vec{y} - A^T V^{-1} A \vec{\theta}) = 0$$

解方程得到最小二乘法的估计量

$$\vec{\hat{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \vec{y} \equiv B \vec{y}$$



估计量 $\hat{\theta}_i$ 是测量量 y_i 的线性函数。

非线性最小二乘法估计

如果 $\lambda(x; \vec{\theta})$ 是 $\vec{\theta}$ 的非线性函数，最小二乘法不能给出参数的严格解，需要通过迭代法求 $\vec{\theta}$ 的近似解，使得下式最小

$$\chi^2(\vec{\theta}) = (\vec{y} - \vec{\lambda})^T V^{-1} (\vec{y} - \vec{\lambda})$$

如果采用牛顿法求上式的最小值，第 $n+1$ 次迭代公式可采用

$$\vec{\hat{\theta}}^{(n+1)} = \vec{\hat{\theta}}^{(n)} - G^{-1}(\vec{\hat{\theta}}^{(n)}) \cdot g(\vec{\hat{\theta}}^{(n)})$$

$$g_i = \left. \frac{\partial \chi^2}{\partial \theta_i} \right|_{\vec{\theta} = \vec{\hat{\theta}}^{(n)}}, \quad G_{ij} = \left. \frac{\partial^2 \chi^2}{\partial \theta_i \partial \theta_j} \right|_{\vec{\theta} = \vec{\hat{\theta}}^{(n)}}$$

迭代终止判据：

$$\Rightarrow \left\| \vec{\hat{\theta}}^{(n+1)} - \vec{\hat{\theta}}^{(n)} \right\| = \left[\sum_{i=1} (\hat{\theta}_i^{(n+1)} - \hat{\theta}_i^{(n)})^2 \right]^{1/2} < \varepsilon \Rightarrow \vec{\hat{\theta}} = \vec{\hat{\theta}}^{(n+1)}$$

ε 是一个给定的小数。

最小二乘估计量的方差

协方差矩阵元 $U_{ij} = \text{cov}[\hat{\theta}_i, \hat{\theta}_j]$ 在线性情况下的误差传递可以写为

$$\vec{\hat{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \vec{y} \equiv B \vec{y} \quad U = B V B^T = (A^T V^{-1} A)^{-1}$$

等效地，可以利用下式来计算

$$(U^{-1})_{ij} = \frac{1}{2} \left[\frac{\partial^2 \chi^2}{\partial \theta_i \partial \theta_j} \right]_{\vec{\theta} = \vec{\hat{\theta}}} = \sum_{k,l}^N a_i(x_k) (V^{-1})_{kl} a_j(x_l)$$



如果 y_i 是高斯变量时，
其与RCF边界一致。

最小二乘估计量的方差(续)

对于 $\lambda(x; \vec{\theta})$ 是参数的线性函数情况下, $\chi^2(\vec{\theta})$ 是二次型的

$$\chi^2(\vec{\theta}) = \chi^2(\vec{\hat{\theta}}) + \frac{1}{2} \sum_{i,j=1}^m \left[\frac{\partial^2 \chi^2}{\partial \theta_i \partial \theta_j} \right]_{\vec{\theta}=\vec{\hat{\theta}}} (\theta_i - \hat{\theta}_i)(\theta_j - \hat{\theta}_j)$$



方差从正切平面到椭圆

$$\chi^2(\vec{\theta}) = \chi^2(\vec{\hat{\theta}}) + 1 = \chi_{\min}^2 + 1$$

如果 $\lambda(x; \vec{\theta})$ 不是 $\vec{\theta}$ 的线性函数, 上述式子会有偏差, 但仍不失为较好的近似。可以把区间 $\chi^2(\vec{\theta}) \leq \chi_{\min}^2 + 1$ 看作“置信区间”, 给出了包含真值 $\vec{\theta}$ 的可能性。

注意: 上式并不依赖于 y_i 是否为高斯变量, 但无论何种情况, 都要计算协方差矩阵 $V_{ij} = \text{cov}[y_i, y_j]$ 。

多项式的最小二乘法拟合

用一个多项式来拟合右图

$$\lambda(x; \theta_0, \dots, \theta_m) = \sum_{j=0}^m \theta_j x^j$$

例如:

第 0 阶(一个参数)

第 1 阶(两个参数)



第 4 阶(五个参数)

➤ 对于单参数拟合情况(例如上图的横线):

$$\hat{\theta}_0 = 2.66 \pm 0.13$$

$$\chi_{\min}^2 = 45.5$$

标准误差 $\sigma_{\hat{\theta}_0}$ 是根据 $\chi^2(\hat{\theta}_0 \pm \sigma_{\hat{\theta}_0}) = \chi_{\min}^2 + 1$ 来确定的。



多项式的最小二乘法拟合(续)

➤ 对于双参数拟合的情形(有非零斜率的直线)

$$\begin{aligned}\hat{\theta}_0 &= 0.93 \pm 0.30; \quad \hat{\theta}_1 = 0.68 \pm 0.10; \\ \widehat{\text{cov}}[\hat{\theta}_0, \hat{\theta}_1] &= -0.028; \quad r = \hat{\rho} = -0.90; \\ \chi^2 &= 3.99.\end{aligned}$$

切线给出 $\sigma_{\hat{\theta}_0}, \sigma_{\hat{\theta}_1}$ 。

椭圆的倾角给出相关系数(与最大似然法相同)。

虽然表面上可以通过变换 $(\hat{\theta}_0, \hat{\theta}_1) \rightarrow (\hat{\eta}_0, \hat{\eta}_1)$ 使得 $\text{cov}(\hat{\eta}_0, \hat{\eta}_1) = 0$, 从而得到不关联的估计值, 但是对新参数的理解也许并不容易。

➤ 对于五个参量拟合的情形(有非零斜率的直线)


✓ 曲线通过所有点;

✓ $\chi^2_{\min} = 0$, 参数的数目 = 数据点的数目。

χ^2_{\min} 值的大小反映了数据与假设之间的符合程度。



可以用来检验拟合优度。



约束情况下的最小二乘法

在处理实际问题中，常常会遇到测量量本身要受到某些物理定律的约束。例如，能动量守恒，衰变顶点约束等等。无参数的最小二乘问题变为

$$\chi^2(\vec{x}) = (\vec{x}' - \vec{x})^T V^{-1} (\vec{x}' - \vec{x}) = \text{最小}$$

$$\psi_i(\vec{x}) = 0, \quad i = 1, \dots, l \quad (\text{共 } l \text{ 个约束条件})$$

$$\vec{x} = (x_1, \dots, x_m) = \text{真值}$$

$$\vec{x}' = (x'_1, \dots, x'_m) = \text{观测值}$$

求解可以采用拉格朗日乘子法，对每一个约束引入修正因子 α_i ，有

$$\chi^2(\vec{x}, \alpha) = (\vec{x} - \vec{x}')^T V^{-1} (\vec{x} - \vec{x}') + 2\alpha^T \psi(\vec{x}) = \text{最小}$$

可以证明，在经过 n 次迭代以后，第 $n+1$ 次的值为

$$\alpha^{(n+1)} = \left[F_x(\vec{x}^{(n)}) V F_x^T(\vec{x}^{(n)}) \right]^{-1} \left[\psi(\vec{x}^{(n)}) + F_x(\vec{x}^{(n)}) (\vec{x}' - \vec{x}^{(n)}) \right]$$

$$\vec{x}^{(n+1)} = \vec{x}' - V F_x^T(\vec{x}^{(n)}) \alpha^{(n+1)}, \quad \text{其中 } F_x = \frac{\partial \psi}{\partial x} = l \times m \text{ 矩阵}$$

约束情况下的最小二乘法(续)

当经过 $n+1$ 次迭代以后, 满足下式时即可终止

$$\left| \frac{\chi^2(\vec{x}^{(n+1)}, \alpha^{(n+1)}) - \chi^2(\vec{x}^{(n)}, \alpha^{(n)})}{\chi^2(\vec{x}^{(n+1)}, \alpha^{(n+1)})} \right| < \varepsilon_1$$

$$|f(\vec{x}^{(n+1)})| < \varepsilon_2, \text{ 这里 } \varepsilon_1 \text{ 与 } \varepsilon_2 \text{ 均为小量。}$$

在粒子与核物理实验中, 为了提高测量精度而采用的四动量拟合(4-C fit)或顶点拟合(1-C fit), 大都采用该方式来进行。




$$\chi_{\min}^2 \sim \chi^2(l)$$

例如, 实验观测衰变

$$\rho^\pm \rightarrow \pi^\pm \pi^0, \pi^0 \rightarrow \gamma\gamma$$

对光子的能量测量通常较差, 从而影响到 ρ^\pm 的重建。可以利用 π^0 质量约束, 进行1-C拟合, 改善对光子的测量精度。



检验最小二乘法的拟合优度

如果 $y_i, i = 1, \dots, N$ 是高斯量 (V_{ij} 已知), 而且假设 $\lambda(x; \vec{\theta})$ 是 θ_i 的线性函数, 函数形式正确。

那么 χ^2_{\min} 服从在 $N-m$ 自由度下的最小二乘概率密度函数分布。

据此来计算P-值 $P = \int_{\chi^2_{\min}}^{\infty} f(z; n_d) dz$


例如考虑在前面双参数拟合的情况

$$\chi^2_{\min} = 3.99, N - m = 3 \rightarrow P = 0.263$$

也就是说, 重复实验多次, 有26.3% 的值将大于 χ^2_{\min} 。

而对于水平线拟合, 有

$$\chi^2_{\min} = 45.5, N - m = 4 \rightarrow P = 3.1 \times 10^{-9}$$



拟合优度与误差的最小值

小的统计误差并不意味着是一个好的拟合(反之亦然)

- χ^2 曲线在其最小值附近变化给出统计误差;
- χ^2_{\min} 的曲率大小给出拟合的优度。

在水平线拟合中，可以人为改变数据点纵向的位置，但保持误差不变，使得

$$\hat{\theta}_0 = 2.66 \pm 0.13$$

$$\chi^2_{\min} = 45.5$$



$$\hat{\theta}_0 = 2.84 \pm 0.13$$


$$\chi^2_{\min} = 4.48$$



方差与改变前一样，
但 χ^2_{\min} 变“好”了。



$\chi^2(\theta_0)$ 曲线只是向下平移，表明与数据符合更好。但曲线形状并没有发生变化，即误差并没有改变。



拟合优度与误差的最小值(续)

➤估计量的方差告诉我们:

- 如果实验重复多次, 估计量 θ 分布有多宽。
- 但是, 它并不告诉我们假设是否正确。

➤P-值告诉我们:

- 如果假设正确, 并且实验重复了多次, 实验与假设按照统计的 χ^2_{\min} 完全符合或符合得更差的比率是多少。
- P-值太低, 则假设可能有误, 即存在系统误差。

最小二乘法处理分区数据

在有 N 个区间，填入 n 次的直方图中，假设概率密度函数为 $f(x; \vec{\theta})$ ，有

y_i = 第 i 个区间的频数

$$\lambda_i(\vec{\theta}) = n \int_{x_i^{\min}}^{x_i^{\max}} f(x_i; \vec{\theta}) dx = np_i(\vec{\theta})$$


最小二乘法拟合使得下式有最小值

$$\chi^2(\vec{\theta}) = \sum_{i=1}^N \frac{(y_i - \lambda_i(\vec{\theta}))^2}{\sigma_i^2} \quad \sigma_i^2 = V[y_i] \text{ 为先验未知量。}$$

把 y_i 看做泊松分布的随机变量，方差为

$$\sigma_i^2 = \lambda_i(\vec{\theta}) \quad (\text{最小二乘法})$$

$$\sigma_i^2 = y_i \quad (\text{改进后的最小二乘法})$$



改进的最小二乘法虽方便了计算，但对于有些区间频数太少时 χ^2_{\min} 不再服从最小二乘的概率密度分布函数(或无定义)。

最小二乘法的归一化问题

尽量避免拟合归一化常数。例如，引入可调参数 ν ，并与 $\vec{\theta}$ 一起拟合。


$$\lambda_i(\vec{\theta}, \nu) = \nu \int_{x_i^{\min}}^{x_i^{\max}} f(x; \vec{\theta}) dx = \nu p_i(\vec{\theta})$$

$\hat{\nu}$ 对 n 而言是一个不好的估计量。



$$\hat{\nu}_{LS} = n + \frac{\chi_{\min}^2}{2}$$
$$\hat{\nu}_{MLS} = n - \chi_{\min}^2$$

例如 $n = 400$ 次， $N = 20$ 个区间



会出现当 N 大 n 小时， $\hat{\nu}$ 的相对误差会变大。

解决的方法是从数据中直接得到 n ，或者最好是用最大似然法定 n 。

在PAW上的最小二乘拟合

```
HISTOGRAM/FIT id func [ chopt np par step pmin pmax errpar ]
```

Only the parameters, which are of more general use, are described in detail. For an up to date description of this command have a look in the online help or in the reference manual.

ID A histogram identifier (1-dim or 2-dim)
A bin range may be specified, e.g. Histo/Fit 10(25:56) ...

FUNC Name of a function to be fitted to the histogram.
This function can be of various forms:

- 1 The name of a file which contains the user defined function to be minimized. Function name and file name must be the same. For example file FUNC.FOR is:

```
FUNCTION FUNC(X) or FUNC(X,Y) for a 2-Dim histogram
COMMON/PAWPAR/PAR(2)
FUNC=PAR(1)*X +PAR(2)*EXP(-X)
END
```

- 2 One of the keywords below (1-dim histograms only), which will use the parameterization described at the right for the fit.


G Func=par(1)*exp(-0.5*((x-par(2))/par(3))**2)

E Func=exp(par(1)+par(2)*x)

Pn Func=par(1)+par(2)*x+par(3)*x**2...+par(n+1)*x**n, 0<n<20

例如: PAW>ve/cr par(3) r 100 0 1;h/fit 100 g ! 3 par (拟合高斯分布)

在ROOT上的最小二乘拟合



在图形显示屏幕中右击鼠标键，
可以出现拟合菜单，选择所需
的函数对直方图进行拟合。

或者采取如下方式：

```
root> hist->Fit("gaus");  
root> hist->Fit("landau");  
root> hist->Fit("exp0");  
root> hist->Fit("pol1");
```

...

详见root用户手册

用最小二乘法并合各实验结果

用最小二乘法得到 λ 的 N 个测量的权重平均值

y_i = 第 i 个测量结果, $i = 1, \dots, N$

$\sigma_i^2 = V[y_i]$, 假设已知

λ = 真值

在各测量量不相关的情况下,
并合方法与最大似然法一样。

如果各测量量之间相关, $\text{cov}[y_i, y_j] = V_{ij}$, 通过求下式的最小值

$$\chi^2(\lambda) = \sum_{i,j=1}^N (y_i - \lambda)(V^{-1})_{ij}(y_i - \lambda)$$



$$\hat{\lambda} = \sum_{i=1}^N w_i y_i, \quad w_i = \frac{\sum_{j=1}^N (V^{-1})_{ij}}{\sum_{k,l=1}^N (V^{-1})_{kl}}$$

$$V[\hat{\lambda}] = \sum_{i,j=1}^N w_i V_{ij} w_j$$

最小二乘法得到的 $\hat{\lambda}$ 是
无偏的, 而且方差最小
(高斯-马科夫定理)。

未知关联矩阵的并合问题

$\chi^2(\lambda) > N - 1$ 的情形

定义标度因子



$$f = \chi^2 / (N - 1)$$

并合后的误差为



$$\sigma_{\hat{\lambda}} \Rightarrow f \sigma_{\hat{\lambda}}$$

粒子数据组PDG
建议的处理方法。
结果比较保守。

$\chi^2(\lambda) < N - 1$ 的情形

对应于多次测量之间存在正关联的情况，得到的误差比真实结果要小。

可以考虑建立等效协方差矩阵(Schmelling M. Phys. Scripta, 1995(51):676)

$$V_{ii} = \sigma_i^2, \quad V_{ij} = f \sigma_i \sigma_j, \quad i \neq j, \quad i, j = 1, \dots, N$$

解方程

$$\chi^2(f) = \sum_{i,j=1}^N (y_i - \hat{\lambda})(V^{-1})_{ij}(y_i - \hat{\lambda}) = N - 1 \quad \Rightarrow \quad f \quad \Rightarrow \quad \text{新的 } V[\hat{\lambda}]$$

对两个相关实验求平均的例子

假设有两相关测量量 y_1, y_2 ，且

$$V = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix} \quad \longrightarrow$$

$$\hat{\lambda} = wy_1 + (1-w)y_2, \quad w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2}$$
$$V[\hat{\lambda}] = \frac{(1-\rho^2)\sigma_1^2\sigma_2^2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} = \sigma$$

如果因第二个测量导致方差倒数的增加为

$$\frac{1}{\sigma^2} - \frac{1}{\sigma_1^2} = \frac{1}{1-\rho} \left(\frac{\rho}{\sigma_1} - \frac{1}{\sigma_2} \right)^2 > 0 \quad \longrightarrow \quad \text{第二个测量结果对平均值有帮助。}$$

如果 $\rho > \sigma_1 / \sigma_2 \rightarrow w < 0$ ，那么

\longrightarrow 加权平均的结果将不在 y_1 和 y_2 之间。

如果相关是由于使用相同数据的话，上述情况不可能发生，但有却可能来自共同的随机效应；此时的平均值很不可信，例如 ρ, σ_1, σ_2 不正确。

小结

1. 与最大似然法的联系

对于高斯分布量 y_i ，两者相同

2. 线性的最小二乘法估计

估计是通过求矩阵的逆来完成，估计量是测量量 y_i 的线性函数

3. 非线性的最小二乘法估计

估计是通过迭代来完成，方差可采用线性的情况 $\chi^2 = \chi^2_{\min} + 1$ 来近似

4. 用最小二乘法检验拟合优度

用 χ^2_{\min} 做拟合优度统计，满足 $N-m$ 自由度下的 χ^2 概率密度函数分布

5. 用最小二乘法处理分区数据

把 y_i 当作泊松量，得到误差估计 λ_i ，或 y_i (推广最小二乘法)

6. 不等精度关联实验结果的并合问题

对关联情况的处理，误差的修正

习题

习题9.1 考虑用最小二乘法拟合直方图。假定直方图分为 N 个区，以 y_i 表示第 i 个区的频数，预期值为

$$\lambda_i(\vec{\theta}) = n \int_{x_i^{\min}}^{x_i^{\max}} f(x; \vec{\theta}) dx$$

这里 $f(x; \vec{\theta})$ 取决于未知参数 $\vec{\theta}$ 。如果用参数来代替总数 n ，同时在对下式进行最小时给出

$$\chi^2(\vec{\theta}, \nu) = \sum_{i=1}^N \frac{[y_i - \lambda_i(\vec{\theta}, \nu)]^2}{\sigma_i^2}$$

a) 证明取 $\sigma_i^2 = \lambda_i$ ，会导致对总数估计量为

$$\hat{\nu}_{LS} = n + \frac{\chi_{\min}^2}{2}$$

b) 并证明若 $\sigma_i^2 = y_i$ ，即改进的最小二乘法，会得到

$$\hat{\nu}_{MLS} = n - \chi_{\min}^2$$

习题(续一)

习题9.2 考虑用最小二乘法拟合直方图。假定直方图分为 N 个区，以 y_i 表示第 i 个区的频数，预期值为 $\lambda_i(\bar{\theta})$ 。假设总数 n 可以视为常数，从而 y_i 满足多项式分布。

- a) 协方差矩阵 $V_{ij}=\text{cov}[y_i,y_j]$ 为何？为什么该矩阵的逆不存在？
- b) 考虑只拟合头 $N-1$ 个区的情况。找出协方差矩阵的逆，并证明这等效于在不考虑相关情况下，拟合所有的 N 个区。

习题9.3 假设一样本容量为 n 的数据样本，每个事例包含了 N 个测量量 y_1,\dots,y_N ，该数据样本将用于拟合一些未知参数。如果测量量之间是相关的，在构造 χ^2 量时，需要知道相关矩阵的逆 V^{-1} 。通常这可以通过首先测定相关系数 $\rho_{ij}=V_{ij}/\sigma_i\sigma_j$ 来得到，例如，采用蒙特卡罗方法来计算。

- a) 在RCF边界中，已知有效参数估计量协方差矩阵的逆正比于样本容量 n 。证明如果这样的话，相关系数与样本容量无关。

习题(续二)

b) 证明协方差矩阵的逆为

$$(V^{-1})_{ij} = \frac{(\rho^{-1})_{ij}}{\sigma_i \sigma_j}$$

(提示: 可根据 $\delta_{ij} = \sum_k (V^{-1})_{ik} V_{kj} = \sum_k (V^{-1})_{ik} \rho_{kj} \sigma_k \sigma_j$, 两边同乘以 ρ^{-1} , 求和而得到。)

习题9.4 考虑随机变量为 x 的两个部分重叠样本, 分别具有 n 次与 m 次观测, 两者重叠部分为 c 。假设 x 的方差 $V[x]=\sigma^2$ 已知, 考虑样本平均值为 $y_1 = \frac{1}{n} \sum_{i=1}^n x_i$, $y_2 = \frac{1}{m} \sum_{i=1}^m x_i$

a) 证明协方差为 $\text{cov}[y_1, y_2] = \frac{c\sigma^2}{nm}$

b) 求出 y_1 与 y_2 加权平均值和对应的方差或标准误差。