

为了保证式 (3.4.2) 和式 (3.4.5) 所示的分解相等, 令

$$\frac{N(z)}{A(z)} = \frac{\sum_{i=0}^p n_i z^{-i}}{\sum_{i=0}^p a_i z^{-i}} = \sum_{k=0}^{\infty} \rho(k) z^{-k} \quad (3.4.7)$$

然后用  $\sum_{i=0}^p a_i z^{-i}$  同乘式 (3.4.7) 两边, 并比较相同幂次项的系数, 即得到

$$n_k = \sum_{i=0}^p a_i \rho(k-i), \quad k = 0, 1, \dots, p \quad (3.4.8)$$

综上所述, Cadzow 谱估计子的关键是确定 AR 阶数  $p$  和估计 AR 参数, 因为系数  $n_k$  可以利用式 (3.4.8) 直接计算。这种方法避免了 MA 阶数的确定、MA 参数和激励白噪声方差的估计。

## 2. Kaveh 谱估计子

ARMA 功率谱密度表示式 (3.4.1) 也可以改写为

$$P_x(z) = \sigma^2 \frac{B(z)B(z^{-1})}{A(z)A(z^{-1})} = \frac{\sum_{k=-q}^q c_k z^{-k}}{A(z)A(z^{-1})} = \sum_{l=-\infty}^{\infty} C_x(l) z^{-l} \quad (3.4.9)$$

为了保证第二个等号成立, 系数  $c_k$  与 MA 参数之间应该满足关系式

$$\sigma^2 B(z)B(z^{-1}) = \sum_{k=-q}^q c_k z^{-k} \quad (3.4.10)$$

由此可以看出, 系数  $c_k$  具有对称性, 即  $c_{-k} = c_k$ 。

从式 (3.4.9) 的第三个等式, 又可以得到

$$\sum_{k=-q}^q c_k(k) z^{-k} = A(z)A(z^{-1}) \sum_{l=-\infty}^{\infty} C_x(l) z^{-l} \quad (3.4.11)$$

注意到  $A(z)A(z^{-1}) = \sum_{i=0}^p \sum_{j=0}^p a_i a_j^* z^{-i+j}$ , 并比较式 (3.4.11) 两边同幂次项的系数, 可

得系数  $c_k$  的计算公式:

$$c_k = \sum_{i=0}^p \sum_{j=0}^p a_i a_j^* C_x(k - i + j), \quad k = 0, 1, \dots, q \quad (3.4.12)$$

Kaveh 提出的 ARMA 谱估计子为

$$P_x(\omega) = \left| \frac{\sum_{k=-q}^q c_k z^{-k}}{1 + \sum_{i=1}^p a_i z^{-i}} \right|^2 \Big|_{z=e^{j\omega}} \quad (3.4.13)$$

显然, Kaveh 谱估计子也不需要白噪声方差  $\sigma^2$  和 MA 参数  $b_i$ , 但需要已知 MA 阶数。

### 3.4.2 修正 Yule-Walker 方程

在 Cadzow 谱估计子和 Kaveh 谱估计子中, 都需要已知 AR 阶数和 AR 参数。在实际场合, 它们可以根据观测数据进行估计。为此, 需要推导 AR 参数所服从的线性方程组。

根据定理 3.2.3 知, 因果 ARMA 过程  $\{x(n)\}$  具有唯一的平稳解

$$x(n) = \sum_{i=0}^{\infty} h(i)e(n-i) \quad (3.4.14)$$

其相关函数为

$$\begin{aligned} R_x(\tau) &= E\{x(n)x(n+\tau)\} \\ &= E\left\{\left[\sum_{i=0}^{\infty} h(i)e(n-i)\right]\left[\sum_{k=0}^{\infty} h(k)e(n+\tau-k)\right]\right\} \\ &= \sum_{i=0}^{\infty} \sum_{k=0}^{\infty} h(i)h(k)E\{e(n-i)e(n+\tau-k)\} \end{aligned} \quad (3.4.15)$$

由于  $e(n)$  是白噪声, 故

$$E\{e(n-i)e(n+\tau-k)\} = \begin{cases} \sigma^2, & k = \tau + i \\ 0, & \text{其他} \end{cases}$$

将此结果代入式 (3.4.15), 即可得到

$$R_x(\tau) = \sigma^2 \sum_{i=0}^{\infty} h(i)h(i+\tau) \quad (3.4.16)$$

这一描述相关函数与冲激响应之间关系的公式是重要的, 它在后面将经常用到。

我们知道, 线性系统的冲激响应  $h(n)$  就是用冲激信号  $\delta(n)$  激励该系统时的输出响应, 故由 ARMA 过程的定义式, 直接有

$$\sum_{i=0}^p a_i h(n-i) = \sum_{k=0}^q b_k \delta(n-k) = b_n \quad (3.4.17)$$

于是, 利用公式 (3.4.16) 和式 (3.4.17), 立即得到

$$\begin{aligned} \sum_{i=0}^p a_i R_x(l-i) &= \sigma^2 \sum_{k=0}^{\infty} h(k) \cdot \sum_{i=0}^p a_i h(k+l-i) \\ &= \sigma^2 \sum_{k=0}^{\infty} h(k) b_{k+l} \end{aligned} \quad (3.4.18)$$

注意, 对于一个  $\text{ARMA}(p,q)$  过程而言, 其 MA 参数  $b_i = 0, i > q$ , 故当  $l > q$  时, 式 (3.4.18) 恒等于零, 即有

$$R_x(l) + \sum_{i=1}^p a_i R_x(l-i) = 0, \quad \forall l > q \quad (3.4.19)$$

这一法方程就是著名的修正 Yule-Walker 方程, 有时简称 MYW 方程。

特别地, 对于一个  $\text{AR}(p)$  过程, 式 (3.4.19) 简化为

$$R_x(l) + \sum_{i=1}^p a_i R_x(l-i) = 0, \quad \forall l > 0 \quad (3.4.20)$$

这一法方程称为 Yule-Walker 方程, 有时简称 YW 方程。

既然修正 Yule-Walker 方程对所有  $l > q$  均成立, 那么是不是需要求解无穷多个方程才能确定 AR 参数  $a_1, \dots, a_p$  呢? 这个问题就是第 2 章中提到的参数惟一可辨识性问题。下面的定理给出了这一问题的答案, 它是 Gersch<sup>[72]</sup> 于 1970 年解决的。

**定理 3.4.1 (AR 参数的可辨识性)** 若  $\text{ARMA}(p,q)$  模型的多项式  $A(z)$  和  $B(z)$  无可对消的公共因子, 且  $a_p \neq 0$ , 则该模型的 AR 参数  $a_1, \dots, a_p$  可由  $p$  个修正 Yule-Walker 方程

$$\sum_{i=1}^p a_i R_x(l-i) = -R_x(l), \quad l = q+1, \dots, q+p \quad (3.4.21)$$

惟一确定或辨识。

**证明** 令  $R$  是一个  $p \times p$  维 Hankel 矩阵, 即

$$R = \begin{bmatrix} R_x(q+1-p) & R_x(q+2-p) & \cdots & R_x(q) \\ R_x(q+2-p) & R_x(q+3-p) & \cdots & R_x(q+1) \\ \vdots & \vdots & \vdots & \vdots \\ R_x(q) & R_x(q+1) & \cdots & R_x(q+p-1) \end{bmatrix} \quad (3.4.22a)$$

并定义  $p \times 1$  向量

$$\mathbf{a} = [a_p, \dots, a_1]^T \quad (3.4.22b)$$

$$\mathbf{r} = [R_x(q+1), \dots, R_x(q+p)]^T \quad (3.4.22c)$$

则修正 Yule-Walker 方程可以矩阵形式写成

$$R\mathbf{a} = -\mathbf{r} \quad (3.4.23)$$

于是, 本定理的证明等价于证明矩阵  $R$  非奇异。为此, 我们考虑矩阵

$$R_\infty = \begin{bmatrix} R_x(q+1-p) & R_x(q+2-p) & \cdots & R_x(q) \\ R_x(q+2-p) & R_x(q+3-p) & \cdots & R_x(q+1) \\ \vdots & \vdots & \vdots & \vdots \\ R_x(q) & R_x(q+1) & \cdots & R_x(q+p-1) \\ R_x(q+1) & R_x(q+2) & \cdots & R_x(q+p) \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix}$$

首先, 由修正 Yule-Walker 方程知

$$\mathbf{r}_{p+1} = -a_1 \mathbf{r}_p - a_2 \mathbf{r}_{p-1} - \cdots - a_p \mathbf{r}_1$$

$$\mathbf{r}_{p+2} = -a_1 \mathbf{r}_{p+1} - a_2 \mathbf{r}_p - \cdots - a_p \mathbf{r}_2$$

⋮

式中  $\mathbf{r}_i$  代表矩阵  $R_\infty$  的第  $i$  行向量。上式表明, 矩阵  $R_\infty$  的第  $p+1$  行是第一行到第  $p$  行的线性组合, 第  $p+2$  行是第二行到第  $p+1$  行的线性组合, 依此类推。换言之, 矩阵  $R_\infty$  的非奇异性仅决定于最上面的  $p$  行。用反证法可以证明这  $p$  行不可能线性相关。假定行向量  $\mathbf{r}_1, \dots, \mathbf{r}_p$  线性相关。由于业已证明  $\mathbf{r}_{p+1}$  与  $\mathbf{r}_1, \dots, \mathbf{r}_p$  线性相关, 而  $\mathbf{r}_{p+2}$  与  $\mathbf{r}_2, \dots, \mathbf{r}_{p+1}$  线性相关等, 所以在这种情况下, 矩阵  $R_\infty$  只有前面

$p-1$  行线性独立。这意味着可以找到一个  $(p-1) \times 1$  维参数向量  $\mathbf{u} = [u_1, \dots, u_{p-1}]^T$  使得法方程

$$\sum_{i=1}^{p-1} u_i R_x(l-i) = -R_x(l), \quad l = q+1, q+2, \dots$$

成立。这就导致了  $a_p = 0$  的结论，与假设条件相矛盾。这说明矩阵  $\mathbf{R}$  的前面  $p$  行必然是线性独立的。又因为矩阵  $\mathbf{R}$  是对称矩阵，所以它的  $p$  列也是线性独立的。综上所述，矩阵  $\mathbf{R}$  是个非奇异矩阵。这就完成了本定理的证明。■

定理 3.4.1 告诉我们，当 ARMA( $p, q$ ) 过程  $\{x(n)\}$  的真实 AR 阶数  $p$  和自相关函数  $R_x(\tau)$  已知时，只需要求解  $p$  个修正 Yule-Walker 方程，便可辨识出 AR 参数。然而，在实际应用中，AR 阶数和自相关函数都是未知的。我们该如何解决这个问题呢？

不妨仍然假定自相关函数  $R_x(\tau)$  已知，但 AR 阶数  $p$  未知。在这种情况下，我们将原 ARMA( $p, q$ ) 过程  $\{x(n)\}$  视为一具有扩展 AR 阶数  $p_e > p$  的 ARMA( $p_e, q$ ) 过程，则在  $p$  被  $p_e$  代替，并且取  $l > q_e$ （其中  $q_e > q$ ）后，修正 Yule-Walker 方程式 (3.4.19) 仍然成立。不妨将它写成

$$\mathbf{R}_e \mathbf{a}_e = \mathbf{0} \quad (3.4.24)$$

式中

$$\mathbf{R}_e = \begin{bmatrix} R_x(q_e + 1) & R_x(q_e) & \cdots & R_x(q_e + 1 - p_e) \\ R_x(q_e + 2) & R_x(q_e + 1) & \cdots & R_x(q_e + 2 - p_e) \\ \vdots & \vdots & \vdots & \vdots \\ R_x(q_e + M) & R_x(q_e + M - 1) & \cdots & R_x(q_e + M - p_e) \end{bmatrix} \quad (3.4.25a)$$

$$\mathbf{a}_e = [1, a_1, \dots, a_p, a_{p+1}, \dots, a_{p_e}]^T \quad (3.4.25b)$$

这里， $M \gg p$ 。因此，式 (3.4.24) 是一超定方程组。现在的问题是矩阵  $\mathbf{R}_e$  的秩是否仍然等于  $p$ ？下面的命题给出了这个问题的答案。

**命题 3.4.1<sup>[31]</sup>** 若  $M > p_e, p_e > p, q_e > q$ ，且  $q_e - p_e > q - p$ ，则  $\text{rank}(\mathbf{R}_e) = p$ 。

这一命题表明，若真实自相关函数  $R_x(\tau)$  已知，则矩阵  $\mathbf{R}_e$  的  $p_e + 1$  个奇异值，只有  $p$  个不等于零，其余皆为零。因此，利用矩阵  $\mathbf{R}_e$  的奇异值分解，即可确定 AR 阶数  $p$ 。

然而，在实际应用中，不仅 AR 阶数未知，而且真实自相关函数也未知，只有  $N$  个观测数据  $x(1), \dots, x(N)$  可以利用。因此，需要先计算出样本自相关函数  $\hat{R}_x(\tau)$ ，然后用它代替矩阵  $\mathbf{R}_e$  中的元素  $R_x(\tau)$ 。一个自然会问的问题是：一个时间平均的样

本自相关函数  $\hat{R}_x(\tau)$  能否用以代替真实的总体自相关函数  $R_x(\tau) = E\{x(n)x^*(n-\tau)\}$  呢？下面的二阶均方遍历定理肯定地回答了这个问题。

**定理 3.4.2** (二阶均方遍历定理) 令  $\{x(n)\}$  是一个零均值的高斯(广义)平稳的复过程。若真实或总体自相关是平方可求和的，即

$$\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} |R_x(k)|^2 = 0 \quad (3.4.26)$$

则对于任一固定的  $\tau = 0, \pm 1, \pm 2, \dots$ ，均有

$$\lim_{N \rightarrow \infty} E\{[\hat{R}_x(\tau) - R_x(\tau)]^2\} = 0 \quad (3.4.27)$$

式中， $\hat{R}_x(\tau)$  是样本自相关函数，由

$$\hat{R}_x(\tau) = \frac{1}{N} \sum_{n=1}^N x(n)x^*(n-\tau) \quad (3.4.28)$$

估计。

**证明** 参见文献 [98]。

### 3.4.3 AR 阶数确定的奇异值分解方法

确定一个 ARMA 模型阶数的方法可以分成两类：信息量准则法和线性代数法。

在信息量准则法中最著名的是最终预测误差(FPE)法<sup>[1]</sup>和 AIC 准则法<sup>[2]</sup>，它们是日本数理统计学家赤池分别于 1969 和 1974 年提出的。

FPE 准则选择使信息量

$$FPE(p, q) \stackrel{\text{def}}{=} \hat{\sigma}_{wp}^2 \left( \frac{N + p + q + 1}{N - p - q - 1} \right) \quad (3.4.29)$$

最小的  $(p, q)$  作为 ARMA 模型的阶数，其中  $\hat{\sigma}_{wp}^2$  是线性预测误差的方差，可按公式

$$\hat{\sigma}_{wp}^2 = \sum_{i=0}^p \hat{a}_i \hat{R}_x(q+i) \quad (3.4.30)$$

计算。

在 AIC 准则里，ARMA 模型阶数  $(p, q)$  的选择准则是使信息量

$$AIC(p, q) \stackrel{\text{def}}{=} \ln \hat{\sigma}_{wp}^2 + 2(p + q)/N \quad (3.4.31)$$

最小，式中  $N$  为数据长度(也叫样本容量)。显然，不论是使用 FPE 准则还是采用 AIC 准则，都需要事先用最小二乘方法拟合各种可能阶数的 ARMA 模型，然后根

据“吝啬原则”，确定一个尽可能小的阶数组合  $(p, q)$  作为 ARMA 模型阶数。当样本容量  $N$  趋于无穷大时，信息量  $\text{FPE}(p, q)$  和  $\text{AIC}(p, q)$  等价。Kashyap<sup>[99]</sup> 证明了，当  $N \rightarrow \infty$  时，AIC 准则选择正确阶数的错误概率并不趋于零。从这个意义上讲，AIC 准则是统计非一致估计。

AIC 准则的改进形式叫做 BIC 准则，它选择  $(p, q)$  的原则是使信息量

$$\text{BIC}(p, q) \stackrel{\text{def}}{=} \ln \hat{\sigma}_{wp}^2 + (p + q) \frac{\ln N}{N} \quad (3.4.32)$$

最小。

由 Rissanen<sup>[157]</sup> 提出的另一种信息量准则是用最小描述长度 (MDL) 来选择 ARMA 模型阶数  $(p, q)$ ，其中信息量定义为

$$\text{MDL}(p, q) \stackrel{\text{def}}{=} N \ln \hat{\sigma}_{wp}^2 + (p + q) \ln N \quad (3.4.33)$$

还有一种常用的信息量准则，简称 CAT(准则自回归传递) 函数准则，它是由 Parzen 于 1974 年提出的<sup>[145]</sup>。CAT 函数定义为

$$\text{CAT}(p, q) \stackrel{\text{def}}{=} \left( \frac{1}{N} \sum_{k=1}^p \frac{1}{\hat{\sigma}_{k,q}^2} \right) - \frac{1}{\hat{\sigma}_{p,q}^2} \quad (3.4.34)$$

式中

$$\hat{\sigma}_{k,q}^2 = \frac{N}{N-k} \hat{\sigma}_{k,q}^2 \quad (3.4.35)$$

阶数  $(p, q)$  的选择应使  $\text{CAT}(p, q)$  最小。

MDL 信息量准则是统计一致的。实验结果显示，对一个短的数据长度，AR 阶数应选择在  $N/3 \sim N/2$  范围内才会有好的结果。Ulrych 与 Clayton<sup>[192]</sup> 证明了，对于一个短的数据段，FPE, AIC 和 CAT 中没有一个工作得好。

典型的线性代数定阶法有行列式检验算法<sup>[45]</sup>、Gram-Schmidt 正交法<sup>[40]</sup>和奇异值分解法。这里介绍奇异值分解方法。

奇异值分解 (SVD) 主要用于求解线性方程组。与该方程组相关联的矩阵不仅表征所期望的解的特征，而且还常常传达动态性能的信息。因此，有必要研究此特征矩阵的特性。下述定理中概括的矩阵的奇异值分解能够出色地起到这一作用。

**定理 3.4.3** 令  $\mathbf{A}$  是一个  $m \times n$  的复数矩阵，则存在一个  $m \times m$ 酉矩阵  $\mathbf{U}$  和  $n \times n$  酉矩阵  $\mathbf{V}$ ，使得  $\mathbf{A}$  可以分解为

$$\mathbf{A} = \mathbf{U} \Sigma \mathbf{V}^H \quad (3.4.36)$$

式中, 上标  $H$  表示复数矩阵的共轭转置,  $\Sigma$  是一个  $m \times n$  维对角阵, 其主对角线上的元素是非负的, 并按下列顺序排列:

$$\sigma_{11} > \sigma_{22} > \cdots > \sigma_{hh} > 0 \quad (3.4.37)$$

式中

$$h = \min(m, n)$$

上述定理的证明可以在很多线性代数或矩阵论的著作中找到, 例如参考文献 [90]、[79] 和 [228] 等。

一个复数矩阵  $B$  称为酉矩阵, 若  $B^{-1} = B^H$ 。特别地, 一个实的酉矩阵称为正交矩阵, 即有  $B^{-1} = B^T$ 。对角矩阵  $\Sigma$  的主对角线上的元素  $\sigma_{kk}$  称为矩阵  $A$  的奇异值, 酉矩阵  $U$  和  $V$  分别叫做矩阵  $A$  的左奇异矩阵和右奇异矩阵, 而  $U = [u_1, \dots, u_m]^T$  和  $V = [v_1, \dots, v_n]^T$  的列向量  $u_i$  和  $v_j$  分别称作矩阵  $A$  的左奇异向量和右奇异向量。

奇异值  $\sigma_{kk}$  包含了有关矩阵  $A$  的秩的特性的有用信息。在实际应用中, 常常需要求  $m \times n$  矩阵  $A$  在 Frobenius 范数意义下的最佳逼近  $\hat{A}$ 。

保留  $\Sigma$  的前  $k$  个奇异值不变, 同时将其他奇异值置零, 并将这一矩阵记为  $\Sigma_k$ , 则  $\Sigma_k$  称为  $\Sigma$  的秩  $k$  的逼近。现在, 即可用

$$A^{(k)} = U \Sigma_k V^H \quad (3.4.38)$$

逼近矩阵  $A$ 。这一逼近的质量用矩阵差  $A - A^{(k)}$  的 Frobenius 范数

$$\|A - A^{(k)}\|_F = \|U \Sigma V^H - U \Sigma_k V^H\|_F \quad (3.4.39)$$

衡量。利用范数的运算及注意到对于  $m \times m$  酉矩阵  $U$  和  $n \times n$  酉矩阵  $V$ , 它们的范数  $\|U\|_F = \sqrt{m}$  和  $\|V\|_F = \sqrt{n}$ , 故式 (3.4.39) 可简化为

$$\begin{aligned} \|A - A^{(k)}\|_F &= \|U\|_F \cdot \|\Sigma - \Sigma_k\|_F \cdot \|V^H\|_F \\ &= \sqrt{mn} \|\Sigma - \Sigma_k\|_F \\ &= \sqrt{mn} \left[ \sum_{i=k+1}^{\min(m,n)} \sigma_{ii}^2 \right]^{1/2} \end{aligned} \quad (3.4.40)$$

这表明, 矩阵  $A^{(k)}$  逼近  $A$  的精确度取决于被置零的那些奇异值的平方和。显然, 若  $k$  越大, 则  $\|A - A^{(k)}\|_F$  越小, 并在  $k = h = \min(m, n)$  时最终等于零。很自然地, 我们希望当  $k$  取某个合适值  $p$  时, 逼近误差向量  $A - A^{(k)}$  的 Frobenius 范数

已足够小，并且当  $k > p$  时，该范数不再明显减小。这一  $p$  值称为矩阵  $A$  的“有效秩”。确定矩阵  $A$  有效秩的这一方法可以用下列方法实现。定义归一化比值

$$\nu(k) = \frac{\|A^{(k)}\|_F}{\|A\|_F} = \left[ \frac{\sigma_{11}^2 + \cdots + \sigma_{kk}^2}{\sigma_{11}^2 + \cdots + \sigma_{hh}^2} \right]^{1/2}, \quad 1 \leq k \leq h \quad (3.4.41)$$

并预先确定一个非常接近于 1 的阈值（例如 0.995）。于是，当  $p$  是  $\nu(k)$  大于或等于该阈值的最小整数时，就可以认为前面  $p$  个奇异值是“主要的”（称为主奇异值），而后面的所有奇异值则是“次要的”（称为次奇异值），从而将  $p$  确定为矩阵  $A$  的有效秩。

除了使用归一化比值  $\nu(k)$  外，也可以利用归一化奇异值确定一个矩阵的有效秩。归一化的奇异值定义为

$$\bar{\sigma}_{kk} \stackrel{\text{def}}{=} \sigma_{kk}/\sigma_{11}, \quad 1 \leq k \leq h \quad (3.4.42)$$

显然  $\bar{\sigma}_{11} = 1$ ，与使用归一化比值  $\nu(k)$  的情况相反，利用归一化奇异值确定有效秩时，选择一个接近于零的正数作阈值（例如 0.05 等），并把  $\bar{\sigma}_{kk}$  大于此阈值的最大整数  $k$  取为矩阵  $A$  的有效秩  $p$ 。

在式 (3.4.25a) 中用样本相关函数  $\hat{R}_x(\tau)$  代替总体相关函数  $R_x(\tau)$ ，得到

$$\mathbf{R}_e = \begin{bmatrix} \hat{R}_x(q_e + 1) & \hat{R}_x(q_e) & \cdots & \hat{R}_x(q_e + 1 - p_e) \\ \hat{R}_x(q_e + 2) & \hat{R}_x(q_e + 1) & \cdots & \hat{R}_x(q_e + 2 - p_e) \\ \vdots & \vdots & \vdots & \vdots \\ \hat{R}_x(q_e + M) & \hat{R}_x(q_e + M - 1) & \cdots & \hat{R}_x(q_e + M - p_e) \end{bmatrix} \quad (3.4.43)$$

利用归一化比值  $\nu(k)$  或归一化奇异值  $\bar{\sigma}_{kk}$  确定上述矩阵的有效秩，即可得到 ARMA 模型的 AR 阶数的估计。

#### 3.4.4 AR 参数估计的总体最小二乘法

一旦 AR 阶数  $p$  确定，如何求出  $p$  个 AR 参数的估计值呢？直观的想法是利用最小二乘方法，但这会带来两个问题：其一，必须重新列出法方程组，使它只包含  $p$  个未知数；其二，求解  $Ax = b$  的最小二乘方法只认为  $b$  含有误差，但实际上系数矩阵  $A$ （这里为样本相关矩阵）也含有误差。因此，一种比最小二乘法更合理的处理方法应该同时考虑  $A$  和  $b$  二者的误差或扰动。不妨令  $m \times n$  矩阵  $A$  的误差矩阵为  $E$ ，向量  $b$  的误差向量为  $e$ ，即考虑矩阵方程

$$(A + E)x = b + e \quad (3.4.44)$$

的最小二乘解。由于考虑了总体的误差，所以这种最小二乘方法称为总体最小二乘（total least squares, TLS）方法。

式(3.4.44)可等价写作

$$\left([-b + A] + [-e + E]\right) \begin{bmatrix} 1 \\ \vdots \\ x \end{bmatrix} = 0 \quad (3.4.45a)$$

或

$$(B + D)z = 0 \quad (3.4.45b)$$

式中

$$B = [-b + A], \quad D = [-e + E], \quad z = \begin{bmatrix} 1 \\ \vdots \\ x \end{bmatrix}$$

这样一来,求解方程组(3.4.44)的TLS方法可以表述为:求解向量 $z$ 使得

$$\|D\|_F = \min \quad (3.4.46)$$

式中

$$\|D\|_F = \left( \sum_{i=1}^m \sum_{j=1}^n d_{ij}^2 \right)^{1/2} \quad (3.4.47)$$

为扰动矩阵 $D$ 的Frobenius范数。这里考虑超定方程的求解,即假定 $m > n + 1$ 。

TLS方法的基本思想是使来自 $A$ 和 $b$ 的噪声扰动影响最小,具体步骤是:求一具有最小范数的扰动矩阵 $D \in R^{m \times (n+1)}$ 使得 $B + D$ 是非满秩的(如果满秩,则只有平凡解 $z = 0$ )。奇异值分解可用于实现这一目的。令

$$B = U \Sigma V^H \quad (3.4.48)$$

且奇异值仍按递减次序排列:

$$\sigma_{11} > \sigma_{22} > \cdots > \sigma_{n+1,n+1} > 0$$

令 $m \times (n+1)$ 矩阵 $\hat{B}$ 是 $B$ 的最佳逼近,并且矩阵 $B$ 的有效秩为 $p$ ,则由前面的讨论知,最佳逼近 $\hat{B}$ 为

$$\hat{B} = U \Sigma_p V^H \quad (3.4.49)$$

其中 $\Sigma_p$ 的前 $p$ 个奇异值与矩阵 $B$ 的前 $p$ 个奇异值相同,而其他奇异值为零。

令 $m \times (p+1)$ 维矩阵 $\hat{B}(j, p+j)$ 是 $m \times (n+1)$ 维最佳逼近矩阵 $\hat{B}$ 中的一个子矩阵,定义为

$$\hat{B}(j, p+j) \stackrel{\text{def}}{=} \text{由 } \hat{B} \text{ 的第 } j \text{ 列到第 } p+j \text{ 列组成的子矩阵} \quad (3.4.50)$$