

系统辨识三要素：
数据、模型类和准则

最小二乘法辨识

传递函数参数模型
↑
响应曲线非参数模型

古典辨识：脉冲响应法，阶跃响应法，频域响应法，

近代辨识：最小二乘法、极大似然法

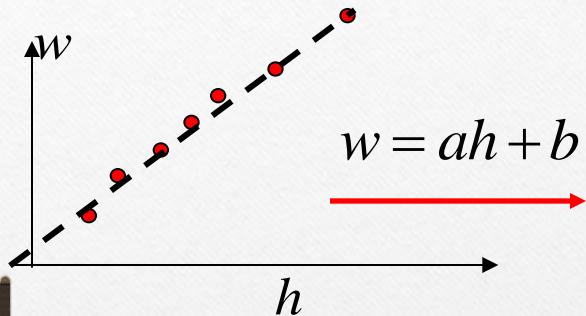
辨识对象：以单输入单输出系统差分方程为模型

辨识内容：系统模型参数

微分方程的离散化

例: 体重和身高 (假设: 线性)

最小二乘问题(Least-squares problems)



$$\begin{array}{l} ah_1 + b = w_1 \\ ah_2 + b = w_2 \\ \vdots \\ ah_k + b = w_k \end{array}$$

Matrix form

$$\begin{bmatrix} h_1 & 1 \\ h_2 & 1 \\ \vdots & \vdots \\ h_k & 1 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_k \end{bmatrix}$$

$$Ax = b$$

参数 $x = \begin{bmatrix} a \\ b \end{bmatrix}$

LS: $\text{minimize } \|Ax - b\|_2^2$

◆ 解析形式解: $x^\star = (A^T A)^{-1} A^T b$

基本的最小二乘估计

限定模型的种类

解决问题：在模型阶次n已知的情况下，根据系统的输入输出数据，估计出系统差分方程的各项系数。

1. 基于输入/输出数据的系统模型描述 $\left\{ \begin{array}{l} u(0), y(0), u(1), y(1), \dots, u(n), y(n), \\ u(n+1), y(n+1) \dots u(n+N), y(n+N) \dots \end{array} \right\}$
n+N个点

SISO系统的差分方程为

模型. 给定输入和输出序列, 待辨识的参数 a_i, b_j ,

$$\left\{ \begin{array}{l} x(k) + a_1x(k-1) + \dots + a_nx(k-n) = b_0u(k) + \dots + b_mu(k-m) \\ y(k) = x(k) + v(k) \end{array} \right.$$

式中， $x(k)$ 为理论输出值， $y(k)$ 为实际观测值， $v(k)$ 为观测噪声。则有：

系统内部状态无法观测 输出数据

$$x(k) = y(k) - v(k)$$

将 $x(k)$ 代入上式，可得输入输出数据方程为： 消去了中间变量 $x(k)$

$$y(k) + a_1 y(k-1) + \cdots + a_n y(k-n) = b_0 u(k) + b_1 u(k-1) + \cdots + b_n u(k-n) + \xi(k)$$

$$\xi(k) = v(k) + \sum_{i=1}^n a_i v(k-i)$$

则当前输出为：

$$y(k) = -a_1 y(k-1) - \cdots - a_n y(k-n) + b_0 u(k) + b_1 u(k-1) + \cdots + b_n u(k-n) + \xi(k)$$

设观测数据有 $(n+N)$ 个，令 k 分别等于 $\underline{n+1}, \dots, n+N$ ，则有：
↑任意一个大数
↑系统阶次
为了让差分方程启动 共 N 个方程

$$\begin{cases} k=n+1 & y(n+1) = -a_1 y(n) - \cdots - a_n y(1) + b_0 u(n+1) + \cdots + b_n u(1) + \xi(n+1) \\ k=n+2 & y(n+2) = -a_1 y(n+1) - \cdots - a_n y(2) + b_0 u(n+2) + \cdots + b_n u(2) + \xi(n+2) \\ & \vdots \\ & y(n+N) = -a_1 y(n+N-1) - \cdots - a_n y(N) + b_0 u(n+N) + \cdots + b_n u(N) + \xi(n+N) \end{cases}$$

上式写成向量形式为：

$$\begin{bmatrix} y(n+1) \\ y(n+2) \\ \vdots \\ y(n+N) \end{bmatrix} = \begin{bmatrix} -y(n) & \cdots & -y(1) & u(n+1) & \cdots & u(1) \\ -y(n+1) & \cdots & -y(2) & u(n+2) & \cdots & u(2) \\ \vdots & & \vdots & \vdots & & \vdots \\ -y(n+N-1) & \cdots & -y(N) & u(n+N) & \cdots & u(N) \end{bmatrix} \begin{bmatrix} a_1 \\ a_n \\ b_o \\ \vdots \\ b_n \end{bmatrix} + \begin{bmatrix} \xi(n+1) \\ \xi(n+2) \\ \vdots \\ \xi(n+N) \end{bmatrix}$$

记为：

$$\mathbf{Y}_{N \times 1} = \Phi_{N \times (2n+1)} \Theta_{(2n+1) \times 1} + \xi_{N \times 1}$$

↓ ↓ ↓ ↓ ↓

输出向量 测量矩阵 参数矩阵 噪声矩阵 数据长度

即

$$\mathbf{Y} = \Phi \boldsymbol{\theta} + \xi \quad (3.1)$$

若 $N = (2n+1)$ 且 $\xi = 0$, 则上式中的 Φ 阵为 $(2n+1) \times (2n+1)$ 的方阵。由此, 可解得 $\boldsymbol{\theta}$ 的唯一解为:

$$\underline{\boldsymbol{\theta} = \Phi^{-1} Y}$$

而在实际工程中, ξ 肯定不等于 0, 且 $N >> (2n+1)$, 即方程个数远大于未知数, 故而上述 $\boldsymbol{\theta}$ 的解不成立。

当前任务: 在存在噪声 ξ 和数据长度 $N >> (2n+1)$ 的情况下, 如何进行参数 $\boldsymbol{\theta}$ 的估计。

2. 基本的最小二乘法(LS)

辨识准则：残差平方和最小。

(1) 残差 e

$\mathbf{e} = \mathbf{Y} - \hat{\mathbf{Y}}$, $\hat{\mathbf{Y}}$ 为模型的计算值, 即 $\hat{\mathbf{Y}} = \Phi\hat{\theta}$

(2) 指标函数 J $\mathbf{e} = \mathbf{Y} - \Phi\hat{\theta}$

$$J = \sum_{k=n+1}^{n+N} e^2(k) = \mathbf{e}\mathbf{e}^T = (\mathbf{Y} - \Phi\hat{\theta})^T(\mathbf{Y} - \Phi\hat{\theta})$$

故而, 最小二乘法辨识就是使 J 最小的参数估计方法。

即有:

$$\hat{\theta} = \min_{\theta} J$$

下面我们推导 θ 估计值的计算方法。

J 取得最小值，也即 J 为极值，则有：

$$\frac{\partial J}{\partial \hat{\theta}} = \mathbf{0}$$

$$\Rightarrow \frac{\partial [(\mathbf{Y} - \Phi \hat{\theta})^T (\mathbf{Y} - \Phi \hat{\theta})]}{\partial \hat{\theta}} = \mathbf{0}$$

$$\Rightarrow -2\Phi^T (\mathbf{Y} - \Phi \hat{\theta}) = \mathbf{0}$$

$$\Rightarrow \Phi^T \Phi \hat{\theta} = \Phi^T \mathbf{Y}$$

其中， $(\Phi^T \Phi)$ 为 $(2n+1) \times (2n+1)$ 的方阵。

$$\begin{matrix} \Phi & N \times (2n+1) \\ \theta & (2n+1) \times 1 \end{matrix}$$

若其逆阵存在，则：

$$\hat{\theta} = \underline{(\Phi^T \Phi)^{-1} \Phi^T \mathbf{Y}} \quad (3.2)$$

上式即为最小二乘法的参数估计结果。

$$\mathbf{Y} = \Phi \theta + \xi$$

作业 1：已知某一单输入单输出线性系统的差分方程形式为

$$y(k) = -a_1 y(k-1) + b_0 u(k) + b_1 u(k-1) + \xi(k)$$

但其参数 a_1, b_0, b_1 为未知数，且 $\xi(k)$ 为不相关的随机序列。经过辨识试验，测得 5 组输入输出数据为

$$\begin{array}{lll} u(1) = 2.1 & u(2) = -2.7 & u(3) = 0.8 \\ u(4) = 1.5 & u(5) = -2.1 & \\ y(1) = 0.3 & y(2) = 0.5 & y(3) = -0.2 \\ y(4) = 0.6 & y(5) = 0.83 & \end{array}$$

试求出其最优参数估计。

解：由系统方程 $y(k) = -a_1 y(k-1) + b_0 u(k) + b_1 u(k-1) + \xi(k)$ ，

设：

$$Y = \begin{pmatrix} y(2) \\ y(3) \\ y(4) \\ y(5) \end{pmatrix} \quad \phi = \begin{pmatrix} -y(1) & u(2) & u(1) \\ -y(2) & u(3) & u(2) \\ -y(3) & u(4) & u(3) \\ -y(4) & u(5) & u(4) \end{pmatrix} \quad \theta = \begin{pmatrix} a_1 \\ b_0 \\ b_1 \end{pmatrix}$$

满足：

$$Y = \phi\theta + \xi$$

根据最小二乘法，其参数估计的结果为： $\hat{\theta} = (\phi^T \phi)^{-1} \phi^T Y$

代码：

```
1  yk = [0.3 0.5 -0.2 0.6 0.83];
2  u1 = [2.1 -2.7 0.8 1.5 -2.1];
3
4  Y = [yk(2); yk(3); yk(4); yk(5)];
5  X = [-yk(1), u1(2), u1(1);
6    | -yk(2), u1(3), u1(2);
7    | -yk(3), u1(4), u1(3);
8    | -yk(4), u1(5), u1(4)];
9  % 计算参数估计结果 theta_hat = inv(X' * X) * X' * Y
10 theta_hat = (X' * X) \ (X' * Y);
11 disp(theta_hat);
```

结果： $a_1 = -1.4862, b_0 = 0.3456, b_1 = 0.4569$

理论上，偏导为0只能说明J取得极值
使J为极小值的条件为： $\frac{\partial^2 J}{\partial \hat{\theta}^2} > 0$

3. 最小二乘法对输入信号的要求

主要讨论 $\Phi^T \Phi > 0$ 对输入信号 $u(k)$ 的要求。

$$\frac{\partial^2 J}{\partial \hat{\theta}^2} = 2\Phi^T \Phi \Rightarrow \Phi^T \Phi > 0$$

$$\Phi^T \Phi = \begin{bmatrix} -y(n) & -y(n+1) & \cdots & -y(n+N-1) \\ \vdots & \vdots & & \vdots \\ -y(1) & -y(2) & \cdots & -y(N) \\ u(n+1) & u(n+2) & \cdots & u(n+N) \\ \vdots & \vdots & & \vdots \\ u(1) & u(2) & \cdots & u(N) \end{bmatrix} \times \begin{bmatrix} -y(n) & \cdots & -y(1) & u(n+1) & \cdots & u(1) \\ -y(n+1) & \cdots & -y(2) & u(n+2) & \cdots & u(2) \\ \vdots & & \vdots & \vdots & & \vdots \\ -y(n+N-1) & \cdots & -y(N) & u(n+N) & \cdots & u(N) \end{bmatrix}$$

$$= \begin{bmatrix} \Phi_{yy} & \Phi_{yu} \\ \Phi_{uy} & \Phi_{uu} \end{bmatrix} \quad \begin{bmatrix} Y \\ U \end{bmatrix}_{2 \times 1} \times \begin{bmatrix} Y & U \end{bmatrix}_{1 \times 2} = \begin{bmatrix} \cdot & \cdot \end{bmatrix}_{2 \times 2}$$

其中， $\Phi_{yy} = \begin{bmatrix} \sum_{k=n}^{n+N-1} y^2(k) & \sum_{k=n}^{n+N-1} y(k)y(k-1) & \cdots & \sum_{k=n}^{n+N-1} y(k)y(k-n+1) \\ \sum_{k=n}^{n+N-1} y(k-1)y(k) & \sum_{k=n}^{n+N-1} y^2(k-1) & \cdots & \sum_{k=n}^{n+N-1} y(k-1)y(k-n+1) \\ \vdots & \vdots & \cdots & \vdots \\ \sum_{k=n}^{n+N-1} y(k-n+1)y(k) & \sum_{k=n}^{n+N-1} y(k-n+1)y(k-1) & \cdots & \sum_{k=n}^{n+N-1} y^2(k-n+1) \end{bmatrix}$

$$\Phi_{yu} = \begin{bmatrix} -\sum_{k=n}^{n+N-1} y(k)u(k+1) & -\sum_{k=n}^{n+N-1} y(k)u(k) & \cdots & -\sum_{k=n}^{n+N-1} y(k)u(k-n+1) \\ -\sum_{k=n}^{n+N-1} y(k-1)u(k+1) & -\sum_{k=n}^{n+N-1} y(k-1)u(k) & \cdots & -\sum_{k=n}^{n+N-1} y(k-1)u(k-n+1) \\ \vdots & \vdots & \vdots & \vdots \\ -\sum_{k=n}^{n+N-1} y(k-n+1)u(k+1) & -\sum_{k=n}^{n+N-1} y(k-n+1)u(k) & \cdots & -\sum_{k=n}^{n+N-1} y(k-n+1)u(k-n+1) \end{bmatrix}$$

$$\Phi_{uy} = \begin{bmatrix} -\sum_{k=n}^{n+N-1} y(k)u(k+1) & -\sum_{k=n}^{n+N-1} y(k-1)u(k+1) & \cdots & -\sum_{k=n}^{n+N-1} y(k-n+1)u(k+1) \\ -\sum_{k=n}^{n+N-1} y(k)u(k) & -y(k-1)u(k) & \cdots & -\sum_{k=n}^{n+N-1} y(k-n+1)u(k) \\ \vdots & \vdots & \vdots & \vdots \\ -\sum_{k=n}^{n+N-1} y(k)u(k-n+1) & -\sum_{k=n}^{n+N-1} y(k-1)u(k-n+1) & \cdots & -\sum_{k=n}^{n+N-1} y(k-n+1)u(k-n+1) \end{bmatrix}$$

$$\Phi_{uu} = \begin{bmatrix} \sum_{k=n}^{n+N-1} u^2(k+1) & \sum_{k=n}^{n+N-1} u(k+1)u(k) & \cdots & \sum_{k=n}^{n+N-1} u(k+1)u(k-n+1) \\ \sum_{k=n}^{n+N-1} u(k)u(k+1) & \sum_{k=n}^{n+N-1} u^2(k) & \cdots & \sum_{k=n}^{n+N-1} u(k)u(k-n+1) \\ \vdots & \vdots & \vdots & \vdots \\ \sum_{k=n}^{n+N-1} u(k-n+1)u(k+1) & \sum_{k=n}^{n+N-1} u(k-n+1)u(k) & \cdots & \sum_{k=n}^{n+N-1} u^2(k-n+1) \end{bmatrix}$$

则当N→∞时，有： 自相关函数

$$\lim_{N \rightarrow \infty} \frac{1}{N} \Phi^T \Phi = \begin{bmatrix} \mathbf{R}_y & \\ & \mathbf{R}_{yu} \\ \mathbf{R}_{uy} & \end{bmatrix} = \mathbf{R}$$

互相关函数

$$\mathbf{R}_y = \begin{bmatrix} R_y(0) & R_y(1) & \cdots & R_y(n-1) \\ R_y(1) & R_y(0) & \cdots & R_y(n-2) \\ \vdots & \vdots & & \vdots \\ R_y(n-1) & R_y(n-2) & \cdots & R_y(0) \end{bmatrix}$$

$$\mathbf{R}_{uy} = \begin{bmatrix} -R_{uy}(-1) & -R_{uy}(0) & \cdots & R_{uy}(n-1) \\ -R_{uy}(-2) & -R_{uy}(-1) & \cdots & R_{uy}(n-2) \\ \vdots & \vdots & & \vdots \\ -R_{uy}(-n) & -R_{uy}(-n+1) & \cdots & R_{uy}(0) \end{bmatrix} = \mathbf{R}_{yu}^T$$

$$\mathbf{R}_u = \begin{bmatrix} R_u(0) & R_u(1) & \cdots & R_u(n) \\ R_u(1) & R_u(0) & \cdots & R_u(n-1) \\ \vdots & \vdots & & \vdots \\ R_u(n) & R_u(n-1) & \cdots & R_u(0) \end{bmatrix}$$

$$\mathbf{R}_u = \begin{bmatrix} R_u(0) & R_u(1) & \cdots & R_u(n) \\ R_u(1) & R_u(0) & \cdots & R_u(n-1) \\ \vdots & \vdots & & \vdots \\ R_u(n) & R_u(n-1) & \cdots & R_u(0) \end{bmatrix}$$

于是有：

J取得极小值→ $\Phi^T \Phi$ 正定→ R 正定→ R_u 正定。

因此：

J取得极小值的必要条件为 R_u 为正定阵。

这就是最小二乘法对输入信号的要求。

定义：

如果序列{ $u(k)$ }的($n+1$)阶方阵 R_u 是正定的，则称序列{ $u(k)$ }为($n+1$)阶持续激励信号。

因此，最小二乘法对输入信号的要求为：

☆ { $u(k)$ }为($n+1$)阶持续激励信号

考查

$$\mathbf{R}_u = \begin{bmatrix} R_u(0) & R_u(1) & \cdots & R_u(n) \\ R_u(1) & R_u(0) & \cdots & R_u(n-1) \\ \vdots & \vdots & & \vdots \\ R_u(n) & R_u(n-1) & \cdots & R_u(0) \end{bmatrix}$$

若 \mathbf{R}_u 为强对角线占优矩阵，则 \mathbf{R}_u 正定。

哪些输入信号 $\{u(k)\}$ 的 \mathbf{R}_u 是强对角线占优矩阵？以下输入信号均能满足
 \mathbf{R}_u 正定的要求：



总结：白噪声 — 平稳随机过程 $w(t)$

- 均值为零，自相关函数为脉冲函数，功率谱密度为非零常数

$$M_w = E\{w(t)\} = 0 \quad R_{ww}(t) = \sigma^2 \delta(t) \quad S_{ww}(f) = \sigma^2 \quad (-\infty < f < \infty)$$

(1) 白噪声序列；

(2) 伪随机二位式噪声序列；

(3) 有色噪声随机信号序列。

⇒ 对角线上无穷大，其它元素均为0

即 M 序列

扫频信号

工程上常用“伪随机二位式噪声序列”、“有色噪声随机信号序列”作为输入信号。

4. 最小二乘估计的概率性质

$$\begin{cases} \mathbf{Y} = \boldsymbol{\Phi} \boldsymbol{\theta} + \boldsymbol{\xi} \\ \hat{\boldsymbol{\theta}} = (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{Y} \end{cases}$$

最小二乘估计的概率性质主要有以下四方面：

LS无偏估计的充分条件为：

(1) 估计的无偏性；

{ $\xi(k)$ }为零均值不相关随机序列，且与{ $u(k)$ }无关

(2) 估计的一致性；

一致性估计的充分条件为：

{ $\xi(k)$ }为零均值不相关随机序列，且与{ $u(k)$ }无关

(3) 估计的有效性；

eg 白噪声序列、M序列

(4) 估计的渐进正态性。

我们主要讨论前两项：无偏性和一致性。

即使在 $v(k)$ 为白噪声的条件下， $\{\xi(k)\}$ 为相关随机序列。故而 基本最小二乘估计是有偏估计，必须对基本最小二乘法进行改进。

最小二乘法的修正算法：广义最小二乘和辅助变量方法

~~(1)~~估计的无偏性

无偏性估计的定义：

若 $E\{\hat{\theta}\} = E\{\theta\} = \theta$ ，则称 $\hat{\theta}$ 是参数 θ 的无偏估计。

下面讨论无偏估计的条件。

$$\begin{cases} \mathbf{Y} = \boldsymbol{\Phi} \boldsymbol{\theta} + \boldsymbol{\xi} \\ \hat{\boldsymbol{\theta}} = (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{Y} \end{cases} \quad (3.3)$$

$$E[\hat{\boldsymbol{\theta}}] = E[(\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{Y}] = E[(\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T (\boldsymbol{\Phi} \boldsymbol{\theta} + \boldsymbol{\xi})]$$

$$\Rightarrow E[\hat{\boldsymbol{\theta}}] = E[\boldsymbol{\theta} + (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \boldsymbol{\xi}] = \boldsymbol{\theta} + E[(\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \boldsymbol{\xi}]$$

LS无偏估计的充要条件为：

$$E[(\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \boldsymbol{\xi}] = 0$$

下面讨论无偏估计的充分条件。

$$y(k) = -a_1 y(k-1) - \cdots - a_n y(k-n) + b_0 u(k) + b_1 u(k-1) + \cdots + b_n u(k-n) + \xi(k)$$

由上式可知：

$y(k)$ 只与 $\xi(k), \xi(k-1), \xi(k-2) \dots$ 相关，而与 $\xi(k+1), \xi(k+2), \xi(k+3) \dots$ 不相关。

考查充要条件 $E[(\Phi^T \Phi)^{-1} \Phi^T \xi] = 0$

$$\Phi^T \xi = \begin{bmatrix} -y(n) & -y(n+1) & \cdots & -y(n+N-1) \\ \vdots & \vdots & & \vdots \\ -y(1) & -y(2) & \cdots & -y(N) \\ u(n+1) & u(n+2) & \cdots & u(n+N) \\ \vdots & \vdots & & \vdots \\ u(1) & u(2) & \cdots & u(N) \end{bmatrix} \begin{bmatrix} \xi(n+1) \\ \xi(n+2) \\ \vdots \\ \xi(n+N) \end{bmatrix}$$

在每个时刻的数值是独立的 相关. eg. 阶跃信号、正弦信号

若 $\{\xi(k)\}$ 为零均值不相关随机序列，且与 $\{u(k)\}$ 无关。

则由上式可知， Φ^T 与 ξ 不相关。

则有：

$$E(x|y) \xrightarrow{x,y \text{不相关}} E(x)E(y)$$

$$\begin{aligned} E[\hat{\theta}] &= \theta + E[(\Phi^T \Phi)^{-1} \Phi^T \xi] \\ &= \theta + E[(\Phi^T \Phi)^{-1} \Phi^T] E[\xi] \\ &= \theta + 0 \\ &= \theta \end{aligned}$$

可见，在上述条件下我们得到了参数 θ 的无偏估计。

LS无偏估计的充分条件为：

{ $\xi(k)$ }为零均值不相关随机序列，且与{ $u(k)$ }无关。

(2) 一致性估计

一致性估计的定义：

若参数估计值以概率1收敛于真值 θ ，则称估计值具有一致性。

或采用下述定义：

若 $\lim_{N \rightarrow \infty} Var[\tilde{\theta}] = 0$ ，则称 $\hat{\theta}$ 是参数 θ 的一致性估计。

式中， $Var[\tilde{\theta}]$ 为估计误差 $\tilde{\theta}$ 的方差。

下面讨论一致性估计的充分条件。

$$\begin{aligned}\tilde{\theta} &= \theta - \hat{\theta} = \theta - (\Phi^T \Phi)^{-1} \Phi^T Y \\ &= \theta - (\Phi^T \Phi)^{-1} \Phi^T (\Phi \theta + \xi) \\ &= -(\Phi^T \Phi)^{-1} \Phi^T \xi\end{aligned}$$

估计误差的方差为：

$$Var\tilde{\boldsymbol{\theta}} = E[\tilde{\boldsymbol{\theta}}\tilde{\boldsymbol{\theta}}^T] = E[(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}\boldsymbol{\Phi}^T(\boldsymbol{\xi}\boldsymbol{\xi}^T)\boldsymbol{\Phi}(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}]$$

同样，假设 $\{\boldsymbol{\xi}(k)\}$ 为零均值不相关随机序列，且与 $\{u(k)\}$ 无关。则 $\boldsymbol{\Phi}^T$ 与 $\boldsymbol{\xi}$ 不相关，且有：

$$E\left\{\boldsymbol{\xi}\boldsymbol{\xi}^T\right\} = \sigma^2 \mathbf{I}_N$$

$$\begin{aligned} \Rightarrow Var\tilde{\boldsymbol{\theta}} &= E[(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}\boldsymbol{\Phi}^T\sigma^2\mathbf{I}_N\boldsymbol{\Phi}(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}] \\ &= E[\sigma^2(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}\boldsymbol{\Phi}^T\boldsymbol{\Phi}(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}] \\ &= \sigma^2 E[(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}] \end{aligned}$$

$$\Rightarrow \lim_{N \rightarrow \infty} Var\tilde{\boldsymbol{\theta}} = \lim_{N \rightarrow \infty} \sigma^2 E[(\boldsymbol{\Phi}^T\boldsymbol{\Phi})^{-1}] = \lim_{N \rightarrow \infty} \frac{\sigma^2}{N} E\left[\left(\frac{1}{N}\boldsymbol{\Phi}^T\boldsymbol{\Phi}\right)^{-1}\right] = \lim_{N \rightarrow \infty} \frac{\sigma^2}{N} \mathbf{R}^{-1} \xrightarrow{\text{自相关矩阵}} 0$$

一致性估计的充分条件为：

$\{\boldsymbol{\xi}(k)\}$ 为零均值不相关随机序列，且与 $\{u(k)\}$ 无关。

(3) 估计值的有效性

有效性的定义：若参数估计误差的方差达到最小值，则称该估计值是有效估计值。

LS有效估计值的充分条件： $\{\xi(k)\}$ 是零均值且服从正态分布的白噪声序列。

(4) 估计值的渐近正态性

渐近正态性的定义：若参数估计值服从正态分布，则称该估计值是渐近正态的。

LS渐近正态性的充分条件： $\{\xi(k)\}$ 是零均值且服从正态分布的白噪声序列。

(5) 基本最小二乘估计存在问题

$$\begin{cases} \mathbf{Y} = \Phi \boldsymbol{\theta} + \xi \\ \hat{\boldsymbol{\theta}} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{Y} \end{cases}$$

无偏性和一致性估计的充分条件均为： $\{\xi(k)\}$ 为零均值不相关随机序列，且与 $\{u(k)\}$ 无关。

考查

$$\begin{cases} \xi(k) = v(k) + \sum_{i=1}^n a_i v(k-i) \\ \xi(k+1) = v(k+1) + \sum_{i=1}^n a_i v(k+1-i) \end{cases} \Rightarrow \xi(k), \xi(k+1) \text{ 相关}$$

也就是说即使在 $v(k)$ 为白噪声的条件下， $\{\xi(k)\}$ 为相关随机序列。故而基本最小二乘估计是有偏估计，必须对基本最小二乘法进行改进。

最小二乘法的修正算法：广义最小二乘和辅助变量方法

递推最小二乘法

在线辨识方法

要会推导过程和公式

解决问题：(n+N)组观测数据时的参数估计值已知，现在又得到了一组新的观测值(u(n+N+1),y(n+N+1)), 如何采用最小二乘法进行在线估计新的估计值问题。

1. 递推算法推导

假设已获取了数据长度为N的I/O数据，则由LS估计有：

$$\begin{cases} \mathbf{Y}_N = \boldsymbol{\Phi}_N \boldsymbol{\theta} + \boldsymbol{\xi}_N \\ \hat{\boldsymbol{\theta}}_N = (\boldsymbol{\Phi}_N^T \boldsymbol{\Phi}_N)^{-1} \boldsymbol{\Phi}_N^T \mathbf{Y}_N \\ \tilde{\boldsymbol{\theta}}_N = \boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_N = -(\boldsymbol{\Phi}_N^T \boldsymbol{\Phi}_N)^{-1} \boldsymbol{\Phi}_N^T \boldsymbol{\xi}_N \\ \text{Var}\tilde{\boldsymbol{\theta}} = \sigma^2 (\boldsymbol{\Phi}_N^T \boldsymbol{\Phi}_N)^{-1} \end{cases}$$

记: $\mathbf{P}_N = (\Phi_N^T \Phi_N)^{-1}$, 则 $\hat{\theta}_N$ 可写成:

$$\text{已有的估计值} \hat{\theta}_N = \mathbf{P}_N \Phi_N^T \mathbf{Y}_N$$

现获得了一组新的I/O数据值: $u(n+N+1)$ 、 $y(n+N+1)$ 。需推导出 $\hat{\theta}_{N+1}$ 的计算公式, 即

$$\hat{\theta}_{N+1} = f(\hat{\theta}_N, u(n+N+1), y(n+N+1))$$

($n+N+1$)时刻的观测值 $y(n+N+1)$ 可表示为:

$$y(n+N+1) = [-y(n+N) \ \cdots \ -y(N+1) \ u(n+N+1) \ \cdots \ u(N+1)] \theta + \xi(n+N+1)$$
$$\downarrow \qquad \qquad \qquad \downarrow \qquad \qquad \qquad \downarrow$$
$$y_{N+1} \qquad \qquad \qquad \Psi_{N+1}^T \qquad \qquad \qquad \xi_{N+1}$$

则上式可写为:

$$\text{第} N+1 \text{个式子} \quad y_{N+1} = \Psi_{N+1}^T \theta + \xi_{N+1}$$

则输入输出方程可写成分块矩阵形式：

$$\begin{array}{l} \text{原有数据} \\ \text{新数据} \end{array} \left[\begin{array}{c} \mathbf{Y}_N \\ \dots \\ y_{N+1} \end{array} \right] = \left[\begin{array}{c} \Phi_N \\ \dots \\ \Psi_{N+1}^T \end{array} \right] \boldsymbol{\theta} + \left[\begin{array}{c} \xi_N \\ \dots \\ \zeta_{N+1} \end{array} \right] \quad \text{共 } N+1 \text{ 行} \quad (3.4)$$

则由最小二乘(LS)可得(n+N+1)时刻的参数估计值为：

$$\hat{\boldsymbol{\theta}}_{N+1} = \left\{ \left[\begin{array}{c} \Phi_N \\ \dots \\ \Psi_{N+1}^T \end{array} \right]^T \left[\begin{array}{c} \Phi_N \\ \dots \\ \Psi_{N+1}^T \end{array} \right] \right\}^{-1} \left[\begin{array}{c} \Phi_N \\ \dots \\ \Psi_{N+1}^T \end{array} \right]^T \left[\begin{array}{c} \mathbf{Y}_N \\ \dots \\ y_{N+1} \end{array} \right]$$

$$= (\Phi_N^T \Phi_N + \Psi_{N+1} \Psi_{N+1}^T)^{-1} (\Phi_N^T \mathbf{Y}_N + \Psi_{N+1} y_{N+1})$$

上式记为： 记： $\mathbf{P}_N = (\Phi_N^T \Phi_N)^{-1}$

$$\begin{cases} \hat{\boldsymbol{\theta}}_{N+1} = \mathbf{P}_{N+1} (\Phi_N^T \mathbf{Y}_N + \Psi_{N+1} y_{N+1}) \\ \mathbf{P}_{N+1} = (\mathbf{P}_N^{-1} + \Psi_{N+1} \Psi_{N+1}^T)^{-1} \end{cases}$$

现在的主要任务是求解矩阵的逆

矩阵求逆引理：若相应矩阵的逆均存在，则有

$$(\mathbf{A} + \mathbf{B}\mathbf{C}^T)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{B}(\mathbf{I} + \mathbf{C}^T\mathbf{A}^{-1}\mathbf{B})^{-1}\mathbf{C}^T\mathbf{A}^{-1}$$

对照 $\mathbf{P}_{N+1} = (\mathbf{P}_N^{-1} + \boldsymbol{\Psi}_{N+1}\boldsymbol{\Psi}_{N+1}^T)^{-1}$ ，令：

$$\mathbf{A} = \mathbf{P}_N^{-1}, \quad \mathbf{B} = \boldsymbol{\Psi}_{N+1}, \quad \mathbf{C}^T = \boldsymbol{\Psi}_{N+1}^T$$

则有

$$\mathbf{P}_{N+1} = \mathbf{P}_N - \mathbf{P}_N \boldsymbol{\Psi}_{N+1} (I + \boldsymbol{\Psi}_{N+1}^T \mathbf{P}_N \boldsymbol{\Psi}_{N+1})^{-1} \boldsymbol{\Psi}_{N+1}^T \mathbf{P}_N$$

↑实际上是数字！

考查矩阵 $\boldsymbol{\Psi}_{N+1}^T \mathbf{P}_N \boldsymbol{\Psi}_{N+1}$ 的维数：

$$[1 \times (2n+1)] \times [(2n+1) \times (2n+1)] \times [(2n+1) \times 1] = 1 \times 1$$

可见，矩阵求逆运算转化为求标量的倒数运算。

将 \mathbf{P}_{N+1} 代入 $\hat{\boldsymbol{\theta}}_{N+1}$ 的表达式 $\hat{\boldsymbol{\theta}}_{N+1} = \mathbf{P}_{N+1}(\boldsymbol{\Phi}_N^T \mathbf{Y}_N + \boldsymbol{\Psi}_{N+1} y_{N+1})$ ，经整理有：

$$\hat{\boldsymbol{\theta}}_{N+1} = \hat{\boldsymbol{\theta}}_N + \mathbf{P}_N \boldsymbol{\Psi}_{N+1} (I + \boldsymbol{\Psi}_{N+1}^T \mathbf{P}_N \boldsymbol{\Psi}_{N+1})^{-1} (y_{N+1} - \boldsymbol{\Psi}_{N+1}^T \hat{\boldsymbol{\theta}}_N)$$

↓标量
来新数据后的估计量的修正值

(3.5)

第 $N+1$ 个式 $y_{N+1} = \boldsymbol{\Psi}_{N+1}^T \boldsymbol{\theta} + \xi_{N+1}$

$$\text{解 将 } P_{N+1} = P_N - P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} \Psi_{N+1}^T P_N$$

$$\text{代入 } \hat{\Theta}_{N+1} = P_{N+1} (\bar{\Phi}_N^T Y_N + \Psi_{N+1} Y_{N+1}).$$

$$\text{有 } \hat{\Theta}_{N+1} = [P_N - P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} \Psi_{N+1}^T P_N] (\bar{\Phi}_N^T Y_N + \Psi_{N+1} Y_{N+1}).$$

$$= \underbrace{P_N \bar{\Phi}_N^T Y_N}_{\hat{\Theta}_N} + P_N \Psi_{N+1} Y_{N+1} - P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} \Psi_{N+1}^T P_N \bar{\Phi}_N^T Y_N \\ - P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} \Psi_{N+1}^T P_N \Psi_{N+1} Y_{N+1}$$

$$= \hat{\Theta}_N + P_N \Psi_{N+1} Y_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} (I + \Psi_{N+1}^T P_N \Psi_{N+1}) \\ - P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} \Psi_{N+1}^T P_N \bar{\Phi}_N^T Y_N \\ - P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} \Psi_{N+1}^T P_N \Psi_{N+1} Y_{N+1}$$

$$= \hat{\Theta}_N + P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} [Y_{N+1} + \underbrace{Y_{N+1} \Psi_{N+1}^T P_N \Psi_{N+1}}_{\hat{\Theta}_N} - \Psi_{N+1}^T P_N \bar{\Phi}_N^T Y_N - \Psi_{N+1}^T P_N \Psi_{N+1} Y_{N+1}]$$

$$= \hat{\Theta}_N + P_N \Psi_{N+1} (I + \Psi_{N+1}^T P_N \Psi_{N+1})^{-1} (Y_{N+1} - \Psi_{N+1}^T \hat{\Theta}_N)$$

修正值

由(3.5)式可得LS的递推算法：

$$\hat{\theta}_{N+1} = \hat{\theta}_N + \mathbf{P}_N \Psi_{N+1} (1 + \Psi_{N+1}^T \mathbf{P}_N \Psi_{N+1})^{-1} (y_{N+1} - \Psi_{N+1}^T \hat{\theta}_N)$$
$$\Rightarrow \begin{cases} \hat{\theta}_{N+1} = \hat{\theta}_N + \mathbf{K}_{N+1} (y_{N+1} - \Psi_{N+1}^T \hat{\theta}_N) \\ \mathbf{K}_{N+1} = \mathbf{P}_N \Psi_{N+1} (1 + \Psi_{N+1}^T \mathbf{P}_N \Psi_{N+1})^{-1} \\ \mathbf{P}_{N+1} = \mathbf{P}_N - \mathbf{P}_N \Psi_{N+1} (1 + \Psi_{N+1}^T \mathbf{P}_N \Psi_{N+1})^{-1} \Psi_{N+1}^T \mathbf{P}_N \end{cases} \quad (3.6)$$

上述递推算法的运行需获取两个初值： $\hat{\theta}_0$, \mathbf{P}_0

递推过程：

$$\hat{\theta}_0, \mathbf{P}_0 \rightarrow \mathbf{K}_1, \mathbf{P}_1, \hat{\theta}_1 \rightarrow \mathbf{K}_2, \mathbf{P}_2, \hat{\theta}_2 \rightarrow \mathbf{K}_3, \mathbf{P}_3, \hat{\theta}_3 \rightarrow \dots$$

初值获取方法：

- (1) 记录一组少量的 I/O 数据 ($N_0 > (2n+1)$), 采用 LS 方法估计出 $\hat{\theta}_0, \mathbf{P}_0$;
- (2) 直接取 $\hat{\theta}_0 = \mathbf{0}, \mathbf{P}_0 = c^2 \mathbf{I}_{(2n+1) \times (2n+1)}$, c 为充分大的数。⇒ 无需逆计算

证明：基本最小二乘离线算法与递推算法的结果完全一致.

$$\mathbf{P}_0 = c^2 \mathbf{I}, \quad \hat{\boldsymbol{\theta}}_0 = 0$$

$$\Rightarrow \mathbf{P}_1 = (\mathbf{P}_0^{-1} + \boldsymbol{\Psi}_1 \boldsymbol{\Psi}_1^T)^{-1}, \quad \hat{\boldsymbol{\theta}}_1 = \mathbf{P}_1 \boldsymbol{\Psi}_1 y_1$$

$$\Rightarrow \mathbf{P}_2 = (\mathbf{P}_1^{-1} + \boldsymbol{\Psi}_2 \boldsymbol{\Psi}_2^T)^{-1} = (\mathbf{P}_0^{-1} + \boldsymbol{\Psi}_1 \boldsymbol{\Psi}_1^T + \boldsymbol{\Psi}_2 \boldsymbol{\Psi}_2^T)^{-1}, \quad \hat{\boldsymbol{\theta}}_2 = \mathbf{P}_2 (\boldsymbol{\Psi}_1 y_1 + \boldsymbol{\Psi}_2 y_2)$$

$$\Rightarrow \mathbf{P}_3 = (\mathbf{P}_2^{-1} + \boldsymbol{\Psi}_3 \boldsymbol{\Psi}_3^T)^{-1} = (\mathbf{P}_0^{-1} + \boldsymbol{\Psi}_1 \boldsymbol{\Psi}_1^T + \boldsymbol{\Psi}_2 \boldsymbol{\Psi}_2^T + \boldsymbol{\Psi}_3 \boldsymbol{\Psi}_3^T)^{-1}, \quad \hat{\boldsymbol{\theta}}_3 = \mathbf{P}_3 (\boldsymbol{\Psi}_1 y_1 + \boldsymbol{\Psi}_2 y_2 + \boldsymbol{\Psi}_3 y_3)$$

⋮

$$\Rightarrow \mathbf{P}_N = (\mathbf{P}_0^{-1} + \boldsymbol{\Psi}_1 \boldsymbol{\Psi}_1^T + \cdots + \boldsymbol{\Psi}_N \boldsymbol{\Psi}_N^T)^{-1}, \quad \hat{\boldsymbol{\theta}}_N = \mathbf{P}_N (\boldsymbol{\Psi}_1 y_1 + \cdots + \boldsymbol{\Psi}_N y_N)$$

$$\begin{aligned} \lim_{c \rightarrow \infty} \mathbf{P}_N &= \lim_{c \rightarrow \infty} \left(\frac{\mathbf{I}}{c^2} + \boldsymbol{\Psi}_1 \boldsymbol{\Psi}_1^T + \boldsymbol{\Psi}_2 \boldsymbol{\Psi}_2^T + \cdots + \boldsymbol{\Psi}_N \boldsymbol{\Psi}_N^T \right)^{-1} \\ &= (\boldsymbol{\Psi}_1 \boldsymbol{\Psi}_1^T + \boldsymbol{\Psi}_2 \boldsymbol{\Psi}_2^T + \cdots + \boldsymbol{\Psi}_N \boldsymbol{\Psi}_N^T)^{-1} = (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \end{aligned}$$

$$\Rightarrow \hat{\boldsymbol{\theta}}_N = (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{Y}$$

注： $\begin{cases} \hat{\boldsymbol{\theta}}_{N+1} = \mathbf{P}_{N+1} (\boldsymbol{\Phi}_N^T \mathbf{Y}_N + \boldsymbol{\Psi}_{N+1} y_{N+1}) \\ \mathbf{P}_{N+1} = (\mathbf{P}_N^{-1} + \boldsymbol{\Psi}_{N+1} \boldsymbol{\Psi}_{N+1}^T)^{-1} \end{cases}$

$$\begin{aligned} \bar{\boldsymbol{\Phi}} &= \begin{bmatrix} \boldsymbol{\Psi}_1^T \\ \boldsymbol{\Psi}_2^T \\ \vdots \\ \boldsymbol{\Psi}_N^T \end{bmatrix} \\ \boldsymbol{\Phi}^T &= [\boldsymbol{\Psi}_1 \quad \boldsymbol{\Psi}_2 \quad \cdots \quad \boldsymbol{\Psi}_N] \end{aligned}$$