

Introducción a Identificación de Sistemas Dinámicos: métodos subespacio

Antonio Sala Piqueras

Notas de clase sobre control de sistemas multivariables/complejos

Dept. Ing. Sistemas y Automatica (DISA)
Universitat Politècnica de València (UPV)

Vídeo presentación en:
<http://personales.upv.es/asala/YT/V/lsmatr.html>

Subsección 1

Mínimos cuadrados matriciales

Video-presentación disponible en:

personales.upv.es/asala/videos/lsmatr.html

Mínimos cuadrados versión matricial

- Identificar matriz Θ en $y_{m \times 1} = \Theta_{m \times n} x_{n \times 1}$ se plantea como m problemas **separados** de mínimos cuadrados (uno por cada **fila** de Θ) *-No cambia nada desde pto. de vista teórico-*.

- Formando, con núm. de muestras (vectoriales) $N \geq n$

$$\Xi_y := \begin{pmatrix} y_1(1) & \dots & y_1(N) \\ \vdots & & \vdots \\ y_m(1) & \dots & y_m(N) \end{pmatrix}_{m \times N} \quad \Xi_x := \begin{pmatrix} x_1(1) & \dots & x_1(N) \\ \vdots & & \vdots \\ x_n(1) & \dots & x_n(N) \end{pmatrix}_{n \times N}$$

el problema es

$$\hat{\Theta} := \min_{\Theta} \left\| \underbrace{\Xi_y}_{m \times N} - \underbrace{\Theta}_{m \times n} \underbrace{\Xi_x}_{n \times N} \right\|_F$$

se tiene:

$$\hat{\Theta} = \Xi_y \cdot \text{pinv}(\Xi_x) = \Xi_y \cdot \Xi_x^T (\Xi_x \Xi_x^T)^{-1}$$

- Norma Frobenius de una matriz $\|\cdot\|_F$ es la suma de los cuadrados de todos los elementos... o sea, que minimizar $\|E\|_F$ es minimizar el índice mínimo-cuadrático $\sum_{k=1}^N \sum_{i=1}^m e_i(k)^2$.

Mínimos cuadrados versión matricial

- Identificar matriz Θ en $y_{m \times 1} = \Theta_{m \times n} x_{n \times 1}$ se plantea como m problemas **separados** de mínimos cuadrados (uno por cada **fila** de Θ) *-No cambia nada desde pto. de vista teórico-*.

- Formando, con núm. de muestras (vectoriales) $N \geq n$

$$\Xi_y := \begin{pmatrix} y_1(1) & \dots & y_1(N) \\ \vdots & & \vdots \\ y_m(1) & \dots & y_m(N) \end{pmatrix}_{m \times N} \quad \Xi_x := \begin{pmatrix} x_1(1) & \dots & x_1(N) \\ \vdots & & \vdots \\ x_n(1) & \dots & x_n(N) \end{pmatrix}_{n \times N}$$

el problema es

$$\hat{\Theta} := \min_{\Theta} \left\| \underbrace{\Xi_y}_{m \times N} - \underbrace{\Theta}_{m \times n} \underbrace{\Xi_x}_{n \times N} \right\|_F$$

se tiene:

$$\hat{\Theta} = \Xi_y \cdot \text{pinv}(\Xi_x) = \Xi_y \cdot \Xi_x^T (\Xi_x \Xi_x^T)^{-1}$$

- Norma Frobenius de una matriz $\|\cdot\|_F$ es la suma de los cuadrados de todos los elementos... o sea, que minimizar $\|E\|_F$ es minimizar el índice mínimo-cuadrático $\sum_{k=1}^N \sum_{i=1}^m e_i(k)^2$.

Interpretación estadística

Como en el caso θ vector, se mantienen conceptos de ML, mejor predicción lineal, de un modelo $y = \Theta x + \mathcal{E}$ siendo \mathcal{E} un vector de variables de varianza identidad:

- la solución es la mejor predicción lineal del vector 'y' dado el vector 'x', esto es:

$$\hat{\Theta} = \Sigma_{yx} \Sigma_x^{-1}$$

donde Σ_{yx} es matriz $m \times n$, Σ_x es matriz $n \times n$ dadas por:

$$\Sigma_{yx} = E(yx^T) = \Xi_y \Xi_x^T / (N - 1), \quad \Sigma_x = E(xx^T) = \Xi_x \Xi_x^T / (N - 1)$$

Subsección 2

Algoritmo subespacio

Video-presentación disponible en:

personales.upv.es/asala/videos/subsp.html

Identificación subespacio de modelos espacio de estado

Concepto de estado: información pasada que sirve para predecir el futuro.
En una ec. en diferencias discreta como:

$$y_{k+1} = -a_1 y_k - a_2 y_{k-1} + b_1 u_k + b_2 u_{k-1}$$

El “estado” podría ser $x_k := \begin{pmatrix} y_{k-1} \\ y_k \\ u_{k-1} \end{pmatrix}$

$$\begin{pmatrix} y_k \\ y_{k+1} \\ u_k \end{pmatrix} = x_{k+1} = \begin{pmatrix} 0 & 1 & 0 \\ -a_2 & -a_1 & b_2 \\ 0 & 0 & 0 \end{pmatrix} x_k + \begin{pmatrix} 0 \\ b_1 \\ 1 \end{pmatrix} u_k$$

$$y_k = (0 \ 1 \ 0) x_k + 0 u_k$$

* La repr. es correcta, pero no **mínima**: hay 1 estado **no** observable; existe repr. interna de orden 2.

```
A=[0 1 0;-1.5 .3 -2;0 0 0]; B=[0 0.1 1]'; C=[0 1 0]; svd(ctrb(A,B))
svd(observ(A,C)) null(observ(A,C))
```

Generalización de la idea

En proceso lineal, determinista, orden n , combinaciones lineales de entradas y salidas pasadas permiten predecir con exactitud presente y futuro (junto con entradas presentes y futuras). Eligiendo horizontes de predicción h_1 , y de memoria pasada h_2 , h_3 (mayores de n):

$$\underbrace{\begin{pmatrix} y_k \\ y_{k+1} \\ \vdots \\ y_{k+h_1} \end{pmatrix}}_{Y_{fut,k}} = \bar{M}_1 \underbrace{\begin{pmatrix} y_{k-h_2} \\ \vdots \\ y_k \\ u_{k-h_3} \\ \vdots \\ u_{k-1} \end{pmatrix}}_{W_{past,k}} + M_2 \underbrace{\begin{pmatrix} u_k \\ u_{k+1} \\ \vdots \\ u_{k+h_1} \end{pmatrix}}_{U_{fut,k}}$$

* Como $h_1 > n$, $\text{rango}(M_1) = n$ – sólo se necesitan n combinaciones de variables pasadas para predecir el futuro –.

En caso no determinista (datos con ruido) el estimado \bar{M}_1 que mejor ajusta por mínimos cuadrados los datos no tiene rango n igual al del sistema que los genera, debido al ruido... la idea es hacer SVD y suponer cero los valores más pequeños, detalles a continuación.

Generalización de la idea

En proceso lineal, determinista, orden n , combinaciones lineales de entradas y salidas pasadas permiten predecir con exactitud presente y futuro (junto con entradas presentes y futuras). Eligiendo horizontes de predicción h_1 , y de memoria pasada h_2, h_3 (mayores de n):

$$\underbrace{\begin{pmatrix} y_k \\ y_{k+1} \\ \vdots \\ y_{k+h_1} \end{pmatrix}}_{Y_{fut,k}} = \bar{M}_1 \underbrace{\begin{pmatrix} y_{k-h_2} \\ \vdots \\ y_k \\ u_{k-h_3} \\ \vdots \\ u_{k-1} \end{pmatrix}}_{W_{past,k}} + M_2 \underbrace{\begin{pmatrix} u_k \\ u_{k+1} \\ \vdots \\ u_{k+h_1} \end{pmatrix}}_{U_{fut,k}}$$

* Como $h_1 > n$, $\text{rango}(M_1) = n$ – sólo se necesitan n combinaciones de variables pasadas para predecir el futuro –.

En caso no determinista (datos con ruido) el estimado \bar{M}_1 que mejor ajusta por mínimos cuadrados los datos no tiene rango n igual al del sistema que los genera, debido al ruido... la idea es hacer SVD y suponer cero los valores más pequeños, detalles a continuación.

Modelo de regresión

Si planteamos la ecuación para múltiples datos de las muestras entrada-salida tomadas del proceso, debemos identificar M_1 y M_2 por mínimos cuadrados matriciales:

$$\underbrace{\begin{pmatrix} y_k & y_{k+1} & \dots \\ y_{k+1} & y_{k+2} & \dots \\ \vdots & \vdots & \vdots \\ y_{k+h_1} & y_{k+h_1+1} & \dots \end{pmatrix}}_{Y_{fut} \text{ } [(h_1+1) \times \nu]} \approx M_1 \underbrace{\begin{pmatrix} y_{k-h_2} & y_{k-h_2+1} & \dots \\ \vdots & \vdots & \vdots \\ y_k & y_{k+1} & \dots \\ u_{k-h_3} & u_{k-h_3+1} & \dots \\ \vdots & \vdots & \vdots \\ u_{k-1} & u_k & \dots \end{pmatrix}}_{W_{past} \text{ } [(h_2+h_3+1) \times \nu]} + M_2 \underbrace{\begin{pmatrix} u_k & u_{k+1} & \dots \\ u_{k+1} & u_{k+2} & \dots \\ \vdots & \vdots & \vdots \\ u_{k+h_1} & u_{k+h_1+1} & \dots \end{pmatrix}}_{U_{fut} \text{ } [(h_1+1) \times \nu]}$$

$$Y_{fut} \approx (M_1 \ M_2) \cdot \begin{pmatrix} W_{past} \\ U_{fut} \end{pmatrix}$$

* si M_1 tiene rango n , $n \leq (h_2 + h_3 + 1)$, el SVD de M_1 nos permitirá establecer un predictor con

menos variables. Detalles a continuación.

Identificación subespacio

[1.] Normalización y preblanqueado: Dividir el pasado en componentes “independientes” no correlados

- para que “tener” o “no tener” unos no influya en la mejor predicción dados los otros*, que será usado en la estimación del orden del sistema o para obtener “*el mejor modelo de un orden prefijado*”).

$$W_{past}^{white} = \left(\sqrt{\Sigma_{W_{past}}} \right)^{\dagger} \cdot W_{past}$$

*Dada una matriz $\Sigma \geq 0$, entenderemos $(\sqrt{\Sigma})^{\dagger} = V \cdot pinv(\sqrt{D}) \cdot V^T$, siendo Σ diagonalizada como $\Sigma = VDV^T$, y $pinv(\sqrt{D})$ la inversa de la raíz cuadrada de los elementos diagonales, o cero en los elementos diagonales de D que sean cero.

*detalles en regresión PLS, <http://personales.upv.es/asala/videos/pcareg.html>

Identificación subespacio (cont.)

[2.] Identificamos M_1 y M_2 por mínimos cuadrados matriciales a partir de series de datos experimentales entrada-salida (ARX multivariable), después de preblanqueado de la matriz verde (paso 1):

$$\underbrace{\begin{pmatrix} y_k & y_{k+1} & \dots \\ y_{k+1} & y_{k+2} & \dots \\ \vdots & \vdots & \ddots \\ y_{k+h_1} & y_{k+h_1+1} & \dots \end{pmatrix}}_{Y_{fut} \text{ } [(h_1+1) \times \nu]} \approx M_1 \underbrace{\begin{pmatrix} y_{k-h_2} & y_{k-h_2+1} & \dots \\ \vdots & \vdots & \ddots \\ y_k & y_{k+1} & \dots \\ u_{k-h_3} & u_{k-h_3+1} & \dots \\ \vdots & \vdots & \ddots \\ u_{k-1} & u_k & \dots \end{pmatrix}}_{W_{past}^{white} \text{ } [(h_2+h_3+1) \times \nu]} + M_2 \underbrace{\begin{pmatrix} u_k & u_{k+1} & \dots \\ u_{k+1} & u_{k+2} & \dots \\ \vdots & \vdots & \ddots \\ u_{k+h_1} & u_{k+h_1+1} & \dots \end{pmatrix}}_{U_{fut} \text{ } [(h_1+1) \times \nu]}$$

$$Y_{fut} \approx (M_1 \ M_2) \cdot \begin{pmatrix} W_{past}^{white} \\ U_{fut} \end{pmatrix}, \quad M_1 \text{ es } [(h_1 + 1) \times (h_2 + h_3 + 1)]$$

Identificación subespacio: selección de orden

[3.] Hacemos SVD de $M_1 = USV^T$. **Orden estimado** n del sistema: núm. de elementos de S “significativamente más grandes que el resto” (no nulos, si los datos fueran sin ruido, lo que nunca ocurre).

$$Y_{fut} = USV^T W_{past}^{white} + M_2 U_{fut}$$

$$S \approx [\bar{S}_{(h_1+1) \times n} \ 0]$$

*Estamos determinando cuántas combinaciones lineales de los elementos de W_{past}^{white} (incorrelados entre sí) tienen un efecto significativo para predecir Y_{fut} .

Identificación subespacio: generación de estado

Continuamos de pág. anterior, por comodidad:

$$Y_{fut} = USV^T W_{past}^{white} + M_2 U_{fut}$$

$$S \approx [\bar{S}_{(h_1+1) \times n} \ 0]$$

[4.] Seleccionando las columnas de V asociadas a los valores singulares “no nulos”, $\tilde{V}_x = V(:, 1 : n)$, tenemos las combinaciones de entradas y salidas pasadas que influyen en el futuro: hemos encontrado **estados de la realización**.

$$Y_{fut} = U \bar{S} \tilde{V}_x^T W_{past}^{white} + M_2 U_{fut}$$

Hacemos el cambio $\Psi_x = \tilde{V}_x^T W_{past}$; Ψ_x tiene n filas. Las columnas de Ψ_x pueden asimilarse a los valores estimados $\hat{x}_k, \hat{x}_{k+1}, \dots$

$$Y_{fut} = U \underbrace{\bar{S} \Psi_x}_{n \times \nu} + M_2 U_{fut}$$

*Por “equilibrar” numéricamente, el cambio en el ejemplo del video de Matlab será $\Psi_x = \sqrt{\bar{S}} \tilde{V}_x^T W_{past}^{white}$.

Identificación subespacio: generación de estado

Continuamos de pág. anterior, por comodidad:

$$Y_{fut} = USV^T W_{past}^{white} + M_2 U_{fut}$$

$$S \approx [\bar{S}_{(h_1+1) \times n} \ 0]$$

[4.] Seleccionando las columnas de V asociadas a los valores singulares “no nulos”, $\tilde{V}_x = V(:, 1 : n)$, tenemos las combinaciones de entradas y salidas pasadas que influyen en el futuro: hemos encontrado **estados de la realización**.

$$Y_{fut} = U \bar{S} \tilde{V}_x^T W_{past}^{white} + M_2 U_{fut}$$

Hacemos el cambio $\Psi_x = \tilde{V}_x^T W_{past}$; Ψ_x tiene n filas. Las columnas de Ψ_x pueden asimilarse a los valores estimados $\hat{x}_k, \hat{x}_{k+1}, \dots$

$$Y_{fut} = U \underbrace{\bar{S} \Psi_x}_{n \times l} + M_2 U_{fut}$$

*Por “equilibrar” numéricamente, el cambio en el ejemplo del video de Matlab será $\Psi_x = \sqrt{\bar{S}} \tilde{V}_x^T W_{past}^{white}$.

Identificación subespacio: Matrices A, B, C, D.

[5.] Las matrices del sistema se generan obteniendo \hat{A} , \hat{B} con mínimos cuadrados matriciales, siendo \hat{x}_k la columna k de Ψ_x , tamaño $n \times 1$, en

$$\underbrace{\begin{pmatrix} \hat{x}_{k+1} & \hat{x}_{k+2} & \dots \end{pmatrix}}_{\Psi_{x+}} \approx \hat{A} \cdot \underbrace{\begin{pmatrix} \hat{x}_k & \hat{x}_{k+1} & \dots \end{pmatrix}}_{\Psi_x} + \hat{B} \cdot \begin{pmatrix} u_k & u_{k+1} & \dots \end{pmatrix}$$

$$\underbrace{\begin{pmatrix} \hat{x}_{k+1} & \hat{x}_{k+2} & \dots \end{pmatrix}}_{\Psi_{x+}} \approx \begin{bmatrix} \hat{A} & \hat{B} \end{bmatrix} \cdot \underbrace{\begin{pmatrix} \hat{x}_k & \hat{x}_{k+1} & \dots \\ u_k & u_{k+1} & \dots \end{pmatrix}}_{\Xi}$$

obteniendo: $\begin{bmatrix} \hat{A} & \hat{B} \end{bmatrix} = \Psi_{x+} \cdot \text{pinv}(\Xi)$. Luego, resolviendo \hat{C} , \hat{D} de forma análoga en:

$$\begin{pmatrix} y_k & y_{k+1} & \dots \end{pmatrix} \approx \hat{C} \cdot \begin{pmatrix} \hat{x}_k & \hat{x}_{k+1} & \dots \end{pmatrix} + \hat{D} \cdot \begin{pmatrix} u_k & u_{k+1} & \dots \end{pmatrix}$$

[FIN DEL ALGORITMO]

Conclusiones/Discusión

El algoritmo **subespacio** permite obtener matrices A , B , C , D a partir de series de datos entrada-salida (multivariables: u_k , y_k pueden ser vectores) usando **mínimos cuadrados** (matriciales) y **SVD** (para determinar el orden de la realización).

*Existen variaciones en la literatura, con pesos W_1 , W_2 en salidas y regresores (detalles omitidos por brevedad).

Matlab System ID Toolbox: `n4sid`.

Identificación del observador óptimo (Kalman Filter)

Como resultado adicional de gran interés, resolviendo por mínimos cuadrados matriciales:

$$\begin{aligned} (\hat{x}_{k+1} \quad \hat{x}_{k+2} \quad \dots) &\approx \hat{A}_{KF} \cdot (\hat{x}_k \quad \hat{x}_{k+1} \quad \dots) \\ &\quad + \hat{B}_{KF} \cdot (u_k \quad u_{k+1} \quad \dots) + \hat{L} \cdot (y_{k+1} \quad y_{k+2} \quad \dots) \end{aligned}$$

se obtienen **directamente de datos** las aproximaciones de las matrices del filtro de

Kalman (observ. adelantado, dlqe) cuyo valor exacto dado un modelo sería:

$$\hat{x}_{k+1} = A\hat{x}_k + Bu_k + L(y_{k+1} - C(A\hat{x}_k + Bu_k)) = \bar{A}_{KF}\hat{x} + \bar{B}_{KF}u + Ly_{k+1}$$

siendo $\bar{A}_{KF} = (I - LC)A$, $\bar{B}_{KF} = (I - LC)B$.

*Se identifican **directamente observadores**. No necesario estimar matrices de varianza de ruido de proceso/medida Q, R en $dlqe(A, C, G, Q, R)$. Los detalles teóricos de cómo se obtiene el observador dado un modelo aparecen en la video-presentación <http://personales.upv.es/asala/videos/est2k.html>.

Ejemplo Matlab

A partir de datos entrada-salida, se identifican estados, representación A, B, C, D, y matrices del filtro de Kalman según el algoritmo presentado en:

personales.upv.es/asala/videos/subspml.html