


# 1. Przedmiot identyfikacji

## System



$$y = F^*(\mathbf{x}, z) = F(\mathbf{x}, z, \mathbf{a}^*), \text{ gdzie } \mathbf{x} = \begin{bmatrix} x^{(1)} \\ x^{(2)} \\ \vdots \\ x^{(s)} \end{bmatrix} - \text{mierzone, } \mathbf{a}^* = \begin{bmatrix} a_1^* \\ a_2^* \\ \vdots \\ a_s^* \end{bmatrix} - \text{zestaw współczynników konkretyzujących } F()$$

$F()$  – znane,  $\mathbf{a}^*$  – nieznane

## informacja aprioryczna

$$F^* \in \{F(\mathbf{x}, z, \mathbf{a}); \mathbf{a} \in R^s\}$$

istnieje dokładnie jedno  $\mathbf{a}^*$ , takie że  $F^*(\mathbf{x}, z) = F(\mathbf{x}, z, \mathbf{a}^*)$  dla każdej pary  $(\mathbf{x}, z)$  (**identyfikowalność**)

## informacja pomiarowa

$$\{\mathbf{x}_k, y_k\}_{k=1}^N$$

## cel

znaleźć przepis  $\Psi()$  (algorytm identyfikacji)

$$\Psi(\text{inf. aprioryczna, inf. pomiarowa}) = \mathbf{a}_N \sim \mathbf{a}^*$$

## założenia o zakłóceniach

$$\begin{aligned} \text{jest addytywne, tj. } y &= F(\mathbf{x}, \mathbf{a}^*) + z \\ \{z_k\}_{k=1}^N &\text{ - ciąg i.i.d.} \\ \mathbf{E}z &= 0 \\ \text{var}z &< \infty \\ z, \mathbf{x} &\text{ - niezależne} \end{aligned}$$

## natura procesów

$z$  – losowe,  $\mathbf{x}$  – deterministyczne lub losowe,  $y$  – losowe,  $\mathbf{a}_N$  – losowe

## własności $\mathbf{a}_N$

- praktyczne: wartości  $\mathbf{E}\mathbf{a}_N[i]$  i  $\text{var}\mathbf{a}_N[i]$
- asymptotyczne: fakt i typ zbieżności  $\mathbf{a}_N \rightarrow \mathbf{a}^*$

## 2. Metoda najmniejszych kwadratów (Gauss 1809)

wskaźnik teoretyczny oceniający jakość dopasowania

$$Q_J(\mathbf{a}) = \mathbf{E}\{y - F(\mathbf{x}, \mathbf{a})\}^2 \rightarrow \min_{\mathbf{a}}$$

$$\begin{aligned} Q_J(\mathbf{a}) &= \mathbf{E}\{F(\mathbf{x}, \mathbf{a}^*) + z - F(\mathbf{x}, \mathbf{a})\}^2 = \mathbf{E}\{[F(\mathbf{x}, \mathbf{a}^*) - F(\mathbf{x}, \mathbf{a})]^2 + 2[F(\mathbf{x}, \mathbf{a}^*) - F(\mathbf{x}, \mathbf{a})]z + z^2\} = \\ &= \mathbf{E}\{F(\mathbf{x}, \mathbf{a}^*) - F(\mathbf{x}, \mathbf{a})\}^2 + \text{var}z \end{aligned}$$

konkluzja

$$\mathbf{a}^* = \arg \min_{\mathbf{a}} Q_J(\mathbf{a})$$

w praktyce nie jest możliwe obliczenie  $Q_J(\mathbf{a})$  (brak znajomości odpowiednich rozkładów), proponuje się estymację wartości oczekiwanej za pomocą wartości średniej

$$\widehat{Q}_{J,N}(\mathbf{a}) = \frac{1}{N} \sum_{k=1}^N \{y_k - F(\mathbf{x}_k, \mathbf{a})\}^2 \rightarrow \min_{\mathbf{a}}$$

uśredniane składniki  $\{y_k - F(\mathbf{x}_k, \mathbf{a})\}^2$  tworzą ciąg i.i.d., zatem na podstawie *MPWL*

$$\widehat{Q}_{J,N}(\mathbf{a}) \xrightarrow{p.1} Q_J(\mathbf{a}), \text{ gdy } N \rightarrow \infty$$

**pytanie:** czy prawdziwe jest następujące wnioskowanie

$$\widehat{Q}_{J,N}(\mathbf{a}) \xrightarrow{p.1} Q_J(\mathbf{a}) \implies \arg \min_{\mathbf{a}} \widehat{Q}_{J,N}(\mathbf{a}) \xrightarrow{p.1} \arg \min_{\mathbf{a}} Q_J(\mathbf{a})$$

**odpowiedź:** tylko wtedy, gdy

$$\sup_{\mathbf{a}} (\widehat{Q}_{J,N}(\mathbf{a}) - Q_J(\mathbf{a})) \xrightarrow{p.1} 0$$

### 3. Liniowy system statyczny *MIMO*

$$\begin{aligned} y &= \mathbf{a}^{*T} \mathbf{x} + z = \mathbf{x}^T \mathbf{a}^* + z \\ y_k &= \mathbf{x}_k^T \mathbf{a}^* + z_k, \quad k = 1, 2, \dots, N \end{aligned}$$

opis macierzowo–wektorowy

$$X_N = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_N^T \end{bmatrix} = \begin{bmatrix} x_1^{(1)} & x_1^{(2)} & \dots & x_1^{(s)} \\ x_2^{(1)} & x_2^{(2)} & \dots & x_2^{(s)} \\ \dots & \dots & \dots & \dots \\ x_N^{(1)} & x_N^{(2)} & \dots & x_N^{(s)} \end{bmatrix}, \quad Y_N = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}, \quad Z_N = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix}$$

równanie pomiarów

$$Y_N = X_N \mathbf{a}^* + Z_N$$

wektor wyjść modelu

$$\bar{Y}_N = X_N \mathbf{a}$$

empiryczne kryterium jakości

$$\begin{aligned}\bar{Q}_{J,N}(\mathbf{a}) &= \sum_{k=1}^N \{y_k - \mathbf{x}_k^T \mathbf{a}\}^2 = (Y_N - X_N \mathbf{a})^T (Y_N - X_N \mathbf{a}) = \|Y_N - X_N \mathbf{a}\|_2^2 = \dots - \text{kwadrat normy euklidesowej} \\ \dots &= (Y_N^T - \mathbf{a}^T X_N^T)(Y_N - X_N \mathbf{a}) = Y_N^T Y_N - \mathbf{a}^T X_N^T Y_N - Y_N^T X_N \mathbf{a} + \mathbf{a}^T X_N^T X_N \mathbf{a} \rightarrow \min_{\mathbf{a}}\end{aligned}$$

gradient

$$\nabla_{\mathbf{a}} \bar{Q}_{J,N}(\mathbf{a}) = -2X_N^T Y_N + 2X_N^T X_N \mathbf{a} = 0$$

**równanie normalne**

$$X_N^T X_N \mathbf{a} = X_N^T Y_N$$

$$\dim X_N^T X_N = s \times s, \dim X_N^T Y_N = s \times 1, \dim \mathbf{a} = s \times 1$$

- kwestia istnienia rozwiązania

$$\text{lincol} X_N^T X_N = \text{lincol} X_N^T Y_N$$

- kwestia jednoznaczności rozwiązania

$$\begin{aligned}\det X_N^T X_N &> 0 \quad (\neq 0) \\ \text{inaczej } \text{rank} X_N^T X_N &= s \text{ (nieosobliwa)}\end{aligned}$$

Fakt:  $\text{rank} X_N^T X_N = \text{rank} X_N^T = \text{rank} X_N$ .

Warunek jednoznaczności:  $\text{rank} X_N = s$

1)  $N \geq s$  – dostatecznie dużo pomiarów (warunek konieczny, ale nie wystarczający)

2) wśród  $N$  pomiarów musi się znaleźć  $s$  niezależnych liniowo wektorów

Gdy  $\text{rank} X_N < s$ , wtedy rozwiązanie równania normalnego nie jest jednoznaczne.

- kwestia nazwy równania (normalność-prostopadłość)

$$X_N^T(Y_N - X_N \mathbf{a}) = 0$$


$$X_N^T(Y_N - \bar{Y}_N) = 0, \text{ gdzie } \bar{Y}_N - \text{wyjście modelu o parametrach } \mathbf{a}$$

$$X_N^T = [col_1x, col_2x, \dots, col_sx]$$

$$\bar{Y}_N = a_1 col_1x + a_2 col_2x + \dots + a_s col_sx - \text{liniowa kombinacja wektorów kolumnowych}$$

$$\text{wniosek : } \bar{Y}_N \in \text{lincol} X_N^T$$

$$\text{natomiast w ogólności : } Y_N \notin \text{lincol} X_N^T$$



$$X_N^T(Y_N - \bar{Y}_N) = 0 \Rightarrow (col_{xi})^T(Y_N - \bar{Y}_N) = 0 \text{ dla każdego } i = 1, 2, \dots, s$$

wniosek: wektor różnicy  $Y_N - \bar{Y}_N$  jest prostopadły do każdej z kolumn  $col_{xi}$  (rzut prostopadły jest "najkrótszy")

## 1. Identyfikacja liniowych systemów dynamicznych z czasem dyskretnym

$$x_k + \alpha_1 x_{k-1} + \dots + \alpha_n x_{k-n} = \beta_0 u_k + \beta_1 u_{k-1} + \dots + \beta_m u_{k-m}, \quad (1)$$

gdzie wartości rzędów  $n$  i  $m$  są znane.

Po wprowadzeniu operatora  $q = z^{-1}$  przesuującego wstecz (tzn.  $qx_k = x_{k-1}$ ,  $q^2 x_k = x_{k-2}$  itd.) oraz wielomianów

$$\begin{aligned} A(q) &= 1 + \alpha_1 q + \alpha_2 q^2 + \dots + \alpha_n q^n, \\ B(q) &= \beta_0 + \beta_1 q + \dots + \beta_m q^m, \end{aligned}$$

równanie (1) upraszcza się do postaci

$$A(q)x_k = B(q)u_k \quad \rightarrow \quad x_k = \frac{B(q)}{A(q)}u_k.$$

## 2. Identyfikacja w warunkach bez zakłóceń pomiarowych

$$\theta = (\alpha_1, \alpha_2, \dots, \alpha_n, \beta_0, \beta_1, \dots, \beta_m)^T$$

$$r_k = (-x_{k-1}, -x_{k-2}, \dots, -x_{k-n}, u_k, u_{k-1}, \dots, u_{k-m})^T,$$

$$x_k = r_k^T \theta.$$

Nieznane parametry zawarte w wektorze  $\theta$  identyfikuje się na podstawie par pomiarów  $(u_k, x_k)$ .

Zapiszmy

$$R_N = \begin{bmatrix} r_1^T \\ r_2^T \\ \vdots \\ r_N^T \end{bmatrix}, \quad X_N = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix}.$$

$$X_N = R_N \theta, \quad (2)$$

$$R_N^T X_N = R_N^T R_N \theta, \quad (\theta - \text{niewiadome}), \quad (3)$$

warunek jednoznaczności rozwiązania

$$\det R_N^T R_N \neq 0$$

$$\text{rank} R_N = \dim \theta.$$

warunek konieczny

$$N \geq \dim \theta. \quad (4)$$

$$\theta = (R_N^T R_N)^{-1} R_N^T X_N.$$

### 3. Identyfikacja w obecności zakłóceń pomiarowych

Cel: estymacja wektora parametrów  $\theta = (\alpha_1, \alpha_2, \dots, \alpha_n, \beta_0, \beta_1, \dots, \beta_m)^T$  na podstawie pomiarów we-wy  $\{(u_k, y_k)\}_{k=1}^N$ , gdzie  $y_k = x_k + \varepsilon_k$ . Do prawdziwego (nieдоступnego dla pomiarów) wyjścia obiektu  $x_k$  dodają się przypadkowe zakłócenia  $\varepsilon_k$

- o zerowej wartości oczekiwanej  $\mathbf{E}\varepsilon_k = 0$ ,
- skończonej wariancji  $\text{var}\varepsilon_k < \infty$ ,
- niezależne od procesu wejściowego  $u_k$

Zapisujemy

$$x_k = y_k - \varepsilon_k = \frac{B(q)}{A(q)} u_k \quad / \cdot A(q)$$

i otrzymujemy równanie różnicowe o zmiennych  $y$  i  $u$

$$A(q)y_k = B(q)u_k + z_k.$$

$$z_k = A(q)\varepsilon_k = \varepsilon_k + \alpha_1\varepsilon_{k-1} + \alpha_2\varepsilon_{k-2} + \dots + \alpha_n\varepsilon_{k-n},$$

$z_k$  nie jest szumem białym, gdyż jego autokorelacja dla  $|\tau| \leq n$  jest niezerowa

$$\mathbf{E}z_k z_{k-\tau} \neq 0.$$

Po wprowadzeniu rzeczywistego regresora (uogólnionego wektora wejść)

$$\phi_k = (-y_{k-1}, -y_{k-2}, \dots, -y_{k-n}, u_k, u_{k-1}, \dots, u_{k-m})^T$$

oraz macierzy uogólnionych wejść, wektora wyjść i zakłóceń

$$\Phi_N = \begin{bmatrix} \phi_1^T \\ \phi_2^T \\ \vdots \\ \phi_N^T \end{bmatrix}, \quad Y_N = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}, \quad Z_N = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix},$$

równanie pomiarów przyjmuje postać

$$Y_N = \Phi_N \theta + Z_N,$$

gdzie  $\theta$  jest niewiadomym wektorem stałych parametrów, a  $Z_N$  – nieznanym zakłóceniem losowym.

$$Y_N = \Phi_N \theta - \text{w ogólności sprzeczny}$$

**estymator metodą najmniejszych kwadratów**

$$\hat{\theta} = (\Phi_N^T \Phi_N)^{-1} \Phi_N^T Y_N,$$



## błąd estymacji

$$\begin{aligned}\Delta &= \hat{\theta} - \theta = (\Phi_N^T \Phi_N)^{-1} \Phi_N^T Y_N - \theta = \\ &= (\Phi_N^T \Phi_N)^{-1} \Phi_N^T \Phi_N \theta + (\Phi_N^T \Phi_N)^{-1} \Phi_N^T Z_N - \theta = \\ &= \left(\frac{1}{N} \Phi_N^T \Phi_N\right)^{-1} \frac{1}{N} \Phi_N^T Z_N.\end{aligned}$$

Ponieważ proces wyjściowy jest ergodyczny

$$\frac{1}{N} \Phi_N^T Z_N \rightarrow \mathbf{E} \phi_k z_k = \mathbf{E} \begin{bmatrix} -y_{k-1} \\ \vdots \\ -y_{k-n} \\ u_k \\ u_{k-1} \\ \vdots \\ u_{k-m} \end{bmatrix} z_k$$

z prawdopodobieństwem 1, gdy  $N \rightarrow \infty$ . Skorelowanie procesu  $\{z_k\}$  powoduje, że

$$\mathbf{E} \phi_k z_k = \begin{bmatrix} -\mathbf{E} y_{k-1} z_k \\ \vdots \\ -\mathbf{E} y_{k-n} z_k \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \neq 0$$

Zwiększanie liczby pomiarów nie doprowadzi nas do prawdziwych wartości parametrów. W celu pokonania tej trudności, stosuje się techniki oparte na filtracji zakłóceń lub tzw. metodę zmiennych instrumentalnych

9.

Wersja rekurencyjna algorytmu najmniejszych kwadratów

wersja off-line (standardowa)

$$a_N = (X_N^T X_N)^{-1} X_N^T Y_N$$

wersja on-line (rekurencyjna)

$$a_N = f(a_{N-1}, x_N, y_N) = a_{N-1} + \delta(a_{N-1}, x_N, y_N)$$

odwracana macierz (w wersji off-line)

$$X_N^T X_N = \sum_{k=1}^N x_k x_k^T = \sum_{k=1}^{N-1} x_k x_k^T + x_N x_N^T = X_{N-1}^T X_{N-1} + x_N x_N^T$$

oznaczmy

$$P_N = (X_N^T X_N)^{-1}$$

$$\text{cov}(a_N) = P_N \sigma_z^2$$

możemy zapisać

$$\begin{aligned} a_N &= P_N X_N^T Y_N \\ a_{N-1} &= P_{N-1} X_{N-1}^T Y_{N-1} \end{aligned}$$

$$P_N = (P_{N-1}^{-1} + x_N x_N^T)^{-1}, \text{ gdzie } P_{N-1}^{-1} = X_{N-1}^T X_{N-1}$$

**Lemat 1** (o odwracaniu macierzy)

$$(A + uu^T)^{-1} = A^{-1} - \frac{1}{1 + u^T A^{-1} u} A^{-1} u u^T A^{-1}$$

Przyjmując  $A = P_{N-1}^{-1}$  i  $u = x_N$  otrzymujemy

$$P_N = P_{N-1} - \frac{1}{1 + x_N^T P_{N-1} x_N} P_{N-1} x_N x_N^T P_{N-1} = P_{N-1} - \varkappa_N P_{N-1} x_N x_N^T P_{N-1}$$

$$\text{gdzie } \varkappa_N = \frac{1}{1 + x_N^T P_{N-1} x_N}$$

$$\begin{aligned} a_N &= (P_{N-1} - \varkappa_N P_{N-1} x_N x_N^T P_{N-1}) (X_{N-1}^T Y_{N-1} + x_N y_N) = \\ &= P_{N-1} X_{N-1}^T Y_{N-1} + P_{N-1} x_N y_N - [\varkappa_N P_{N-1} x_N] (x_N^T P_{N-1} X_{N-1}^T Y_{N-1} - x_N^T P_{N-1} x_N y_N) = \\ &= a_{N-1} + [\varkappa_N P_{N-1} x_N] \left\{ \frac{1}{\varkappa_N} y_N - x_N^T a_{N-1} - x_N^T P_{N-1} x_N y_N \right\} \end{aligned}$$

wstawiając

$$\frac{1}{\varkappa_N} = 1 + x_N^T P_{N-1} x_N$$

otrzymujemy

$$\{\dots\} = y_N + x_N^T P_{N-1} x_N y_N - x_N^T a_{N-1} - x_N^T P_{N-1} x_N y_N = y_N - x_N^T a_{N-1}$$

wniosek

$$\begin{aligned} a_N &= a_{N-1} + \varkappa_N P_{N-1} x_N (y_N - x_N^T a_{N-1}) \\ P_N &= P_{N-1} - \varkappa_N P_{N-1} x_N x_N^T P_{N-1} \quad / \cdot x_N \end{aligned} \tag{1}$$

$$P_N x_N = P_{N-1} x_N - \varkappa_N P_{N-1} x_N x_N^T P_{N-1} x_N = \varkappa_N P_{N-1} x_N \left\{ \frac{1}{\varkappa_N} - x_N^T P_{N-1} x_N \right\}$$

$$\{\dots\} = 1$$

$$P_N x_N = \varkappa_N P_{N-1} x_N$$

wstawiamy do (1)

$$\begin{aligned}a_N &= a_{N-1} + P_N x_N (y_N - x_N^T a_{N-1}) \\ P_N &= P_{N-1} - \frac{P_{N-1} x_N x_N^T P_{N-1}}{1 + x_N^T P_{N-1} x_N}\end{aligned}$$

warunki początkowe

$$a_0 = 0, P_0 = \text{diag}[10^3 \div 10^5]$$

**zaleta:** algorytm pracuje bez odwracania macierzy