

## Modelowanie parametryczne

Modelowania parametryczne<sup>1</sup> polega na takim wyznaczeniu transmitacji filtra liniowego  $H(z)$ , który upodabnia w sensie średniokwadratowym sygnał fitrowany  $y[n]$  z dodanym białym szumem do sygnału modelowanego  $x[n]$ :

$$H(z) = \frac{\sum_{k=0}^q b_k \cdot z^{-k}}{1 + \sum_{k=1}^p a_k \cdot z^{-k}} = \frac{B(z)}{A(z)} \quad (1)$$

W zależności od budowy filtra  $H(z)$  wyróżniamy modele:

- autoregresywny (AR - ang. *autoregressive*), gdy występują tylko wielomian mianownika, a licznik równa się 1;
- ze średnią ruchomą (MA - ang. *moving average*), gdy występuje tylko wielomian licznika (mianownik równa się 1);
- ARMA - gdy licznik i mianownik jednocześnie jest różny od 1.

### 1 Modelowanie autoregresyjne AR

Model autoregresywny (AR - ang. *autoregressive*) służy głównie do modelowania sygnałów, których widmo jest prążkowe (np. suma sygnałów harmoniczných). Model ten można zapisać w postaci:

$$x[n] = c + \sum_{k=1}^p \varphi_k \cdot x[n - k] + \varepsilon[n] \quad (2)$$

gdzie:  $c$  - stała,  $\varphi$  - parametry modelu,  $\varepsilon$  - biały szum (o średniej 0 i wariancji  $\sigma^2$ )

Obliczenie wartości parametrów modelu sprowadza się do rozwiązania układu równań liniowych, zapisanych w postaci macierzowej (równanie Yule'a-Walkera):

$$\begin{bmatrix} R_{xx}(0) & R_{xx}(1) & \cdots & R_{xx}(p) \\ R_{xx}(1) & R_{xx}(0) & \cdots & R_{xx}(p-1) \\ R_{xx}(2) & R_{xx}(1) & \cdots & R_{xx}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ R_{xx}(p) & R_{xx}(p-1) & \cdots & R_{xx}(0) \end{bmatrix} \cdot \begin{bmatrix} 1 \\ \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_p \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3)$$

gdzie  $R_{xx}(m)$  wartość funkcji autokorelacji:

$$R_{xx}(m) = \sum_{n=0}^{N-1-|m|} x[n] \cdot x^*[n - m] \quad (4)$$

Równanie 3 można rozbić na dwie części (osobny pierwszy wiersz i reszta):

$$\begin{bmatrix} R_{xx}(0) & R_{xx}(1) & \cdots & R_{xx}(p-1) \\ R_{xx}(1) & R_{xx}(0) & \cdots & R_{xx}(p-2) \\ R_{xx}(2) & R_{xx}(1) & \cdots & R_{xx}(p-3) \\ \vdots & \vdots & \ddots & \vdots \\ R_{xx}(p-1) & R_{xx}(p-2) & \cdots & R_{xx}(0) \end{bmatrix} \cdot \begin{bmatrix} \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_p \end{bmatrix} = - \begin{bmatrix} R_{xx}(1) \\ R_{xx}(2) \\ R_{xx}(3) \\ \vdots \\ R_{xx}(p) \end{bmatrix} \Rightarrow \mathbf{R} \cdot \mathbf{a} = -\mathbf{r} \quad (5a)$$

$$R_{xx}(0) + \mathbf{a}^T \cdot \mathbf{r} = \sigma^2 \quad (5b)$$

<sup>1</sup>Rozdział na podstawie: T. Zieliński (2009) *Cyfrowe Przetwarzanie Sygnałów*, WKŁ, Warszawa

## 2 Modelowania ze średnią ruchomą MA

Modelowanie predykcyjne z wykorzystaniem średniej ruchomej stosowane jest głównie tam, gdzie widmo ma charakter gładki. Do wyznaczenia wartości współczynników  $b_k$  z równania 1 często stosuje się modelowanie AR, przy czym ilość współczynników  $q$  licznika MA powinna być minimum 4 razy większa od ilości współczynników  $p$  mianownika MA.

Po obliczeniu wartości współczynników  $a$ , tworzona jest macierz Toeplitza  $\mathbf{A}$  o rozmiarze  $(q+p) \times q$ , gdzie wierszami zapisane są wartości współczynników  $a$  poczynając od drugiego wiersza (dla przykładu:  $p=4$  i  $q=3$ ) oraz wektor  $\delta$ :

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 \\ a_1 & 1 & 0 \\ a_2 & a_1 & 1 \\ a_3 & a_2 & a_1 \\ a_4 & a_3 & a_2 \\ 0 & a_4 & a_3 \\ 0 & 0 & a_4 \end{bmatrix} \quad \delta = \begin{bmatrix} -a_1 \\ -a_2 \\ -a_3 \\ -a_4 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad b = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix} \quad (6)$$

$$b = (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \delta \quad (7)$$

## 3 ARMA

Model ten stanowi połączenie metod przedstawionych powyżej. Wartości współczynników  $a$  i  $b$  określane są w następujących krokach:

1. Wyznaczamy wartości współczynników  $a$  (dla  $M > p + q$  oraz  $m > q$ ) z równania  $\mathbf{R} \cdot a = r$ :

$$\begin{bmatrix} R_{xx}(q) & R_{xx}(q-1) & \cdots & R_{xx}(q-p+1) \\ R_{xx}(q+1) & R_{xx}(q) & \cdots & R_{xx}(q-p+2) \\ R_{xx}(q+2) & R_{xx}(q+1) & \cdots & R_{xx}(q-p+3) \\ \vdots & \vdots & \ddots & \vdots \\ R_{xx}(M-1) & R_{xx}(M-2) & \cdots & R_{xx}(M-p) \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} -R_{xx}(q+1) \\ -R_{xx}(q+2) \\ -R_{xx}(q+3) \\ \vdots \\ -R_{xx}(M) \end{bmatrix} \quad (8)$$

$$a = (\mathbf{R}^T \cdot \mathbf{R})^{-1} \cdot \mathbf{R}^T \cdot r \quad (9)$$

2. Filtracja sygnału  $x(t)$  filtrem o współczynnikach  $a$ .
3. Obliczenie współczynników  $b$  modelu MA dla przefiltrowanego sygnału.

## 4 Econometrics toolbox

Modelowania parametryczne AR, MA i ARMA są zawarte w Econometrics toolbox. Modelowanie AR (przewidywanie) odbywa się w kilku krokach z wykorzystaniem kolejnych funkcji:

1. Stworzenie odpowiedniego modelu: `model = arima(p, D, q)`, gdzie:
  - $p$ : ilość współczynników wielomianu autoregresji (dla  $AR > 0$ , dla  $MA = 0$ );

- D: stopień różniczkowania (zwykle 0, dla danych z liniowym trendem 1);
  - q: stopień wielomianu odpowiedzialnego za średnią ruchomą (dla AR=0, dla MA>0);
- wartości p, D, q muszą być nieujemnymi liczbami całkowitymi.
2. Estymacja : `est_mod = estimate(model, presample, 'Y0', estymacja)`, gdzie:
    - `presample` - dane przedwstępne: `presample = dane(1:model.P)`;
    - `'Y0'` - nazwa parametru danych przedwstępnych;
    - `estymacja` - dane służące do estymacji: `estymacja = dane((model.P+1):N)`, gdzie N - ilość próbek wektora
  3. Modelowanie: `predykcja = forecast(est_mod, N_p, dane_wej)`, gdzie
    - `N_p` - ile danych w przód chcemy przewidzieć
    - `dane_wej` - wektor zawierający minimum P ostatnich danych z wektor `estymacja`.

## 5 Zadania

1. Stwórz sygnały ( $t = 0 - 10s$ ,  $F_s = 100Hz$ )
  - $x_1(t)$  - suma sygnałów harmoniczných ( $A_1=1$ ,  $F_1=10Hz$ ;  $A_2=0.5$ ,  $F_2=3.75$ ;  $A_3=0.75$ ,  $F_3=18Hz$ ) oraz szumu gaussowskiego ( $\sigma=0.02$ );
  - $x_2(t)$  - sklejanie sygnałów harmoniczných z podpunktu 1 ( $f_1$  dla  $t=0-3s$ ,  $f_2$  dla  $t=3-6s$ ,  $f_3$  dla  $t=6-9s$ , sygnał zerowy dla  $t>9s$ ) + szum;
  - $x_3(t)$  - sygnał harmoniczny o liniowym wzroście częstotliwości  $f(0s)=0.5Hz$ ,  $f(10s)=5Hz$  i stałej amplitudzie  $A=1$ ;
  - $x_4(t)$  - sygnał harmoniczny o  $f=5Hz$  i  $A=1$  i wartości NaN dla  $t=4s$  i  $t=7s$ .

Dla każdego takiego sygnału (osobno), policz wartości współczynników dla  $t=<10, 10.5>s$  korzystając z metody AR (z i bez użycia funkcji `arma`) oraz MA i ARMA (korzystając z `arma`).
2. Pobierz dane odnośnie średniego kursu walut Narodowego Banku Polskiego (tabela A w formie XLS: [https://www.nbp.pl/home.aspx?f=/kursy/arch\\_a.html](https://www.nbp.pl/home.aspx?f=/kursy/arch_a.html) ). Korzystając z narzędzi AR, MA i ARMA spróbuj przewidzieć kurs euro i dolara w grudniu 2023 na podstawie danych od stycznia do listopada. Dane porównaj z rzeczywistymi kursami.