

# ADAPTACYJNE PRZETWARZANIE SYGNAŁÓW LABORATORIUM

## Ćwiczenie 1

### Modelowanie i analiza widmowa dyskretnych sygnałów losowych

#### 1. CEL ĆWICZENIA

Celem ćwiczenia jest zapoznanie studentów z wybranymi algorytmami filtracji adaptacyjnej stosowanymi do estymacji parametrów sygnałów modelowanych procesami ARMA oraz przedstawienie nowoczesnych metod analizy widmowej opartych na liniowym modelowaniu dyskretnych procesów losowych.

#### 2. ZAKRES BADAŃ

W pierwszej części ćwiczenia badane są dwa algorytmy adaptacyjnej identyfikacji modeli ARMA sygnału losowego:

- blokowy transwersalny algorytm typu LS w wersji Kay'a;
- rekursywny transwersalny algorytm oparty na kryterium największej wiarygodności (tzw. algorytm Friedlandera).

W drugiej części ćwiczenia badane są natomiast metody analizy widmowej oparte na autoregresyjnym modelu dyskretnego procesu losowego. Badania szerokiej klasy algorytmów modelowania AR zaimplementowanych w pakiecie AFRICA przeprowadzone są dla różnych typów sygnałów syntetycznych i rzeczywistych (sygnał EEG). W szczególności badane są adaptacyjne właściwości algorytmów na przykładzie sygnałów niestacjonarnych (sygnał sinusoidalny o liniowo narastającej częstotliwości (*chirp*) oraz sygnał EEG).

#### 3. PODSTAWY TEORETYCZNE

##### 3.1 Model ARMA dyskretnego procesu losowego

Losowy proces autoregresji z ruchomą średnią ARMA (*AutoRegressive Moving Average*) opisany jest następującym równaniem różnicowym:

$$X(n) = \sum_{i=1}^p a_i X(n-i) + W(n) + \sum_{j=1}^q b_j W(n-j), \quad (1)$$

gdzie  $W(n)$  jest szumem białym, a liczby  $p$  i  $q$  określają rząd modelu – ozn. ARMA( $p, q$ ). Innymi słowy jest to proces otrzymywany na wyjściu filtru liniowego o transmitancji  $H(z)$ , pobudzanego szumem  $W(n)$ . Transmitancja  $H(z)$  ma przy tym postać:

$$H(z) = \frac{B(z)}{A(z)} = \frac{1 + b_1 z^{-1} + \dots + b_q z^{-q}}{1 - a_1 z^{-1} - \dots - a_p z^{-p}}. \quad (2)$$

Filtr o transmitancji  $H(z)$  nazywany jest filtrem modelującym. Jeśli filtr ten spełnia warunek minimalnofazowości, to wówczas sensownym staje zagadnienie filtru odwrotnego, rozumianego jako filtr o transmitancji  $G(z) = 1/H(z) = A(z)/B(z)$ . Jeśli na wejściu takiego filtru podamy sygnał  $X(n)$ , to na jego wyjściu otrzymamy szum biały. Mamy wtedy do czynienia z problemem wybielania sygnałów, który sprowadza się do znalezienia transmitancji filtru odwrotnego. Jeśli transmitancja  $H(z)$  filtru modelującego jest znana lub inaczej znany jest model sygnału  $X(n)$ , to tak postawione zadanie jest trywialne. W praktyce jednak model sygnału  $X(n)$  nie jest znany. Co więcej nie ma żadnej pewności, że obserwowany sygnał spełnia równanie modelu ARMA (1). W takiej sytuacji problem wybielania sygnału wiąże się nierozdzielnie z problemem modelowania, tzn. znalezienia takiego filtru liniowego o transmitancji  $\hat{B}(z)/\hat{A}(z)$ , którego wyjście przy pobudzeniu szumem białym na wejściu jest w jakimś sensie przybliżeniem obserwowanego sygnału  $X(n)$ . Filtr wybielający ma wówczas transmitancję  $\hat{G}(z) = \hat{A}(z)/\hat{B}(z)$ .

Przedstawiony powyżej schemat rozwiązania problemu wybielania poprzez uprzednie modelowanie ma znaczenie czysto teoretyczne i wyłącznie pogładowe. W praktyce bowiem zdecydowana większość algorytmów znajdowania modelu ARMA dla obserwowanego sygnału pracuje w odwróconej kolejności. Model znajdujący się poprzez uprzednie wybielanie sygnału, którego obserwowane próbki przetwarzane są przez filtr adaptacyjny w taki sposób, aby na wyjściu tego filtru pojawił się sygnał błędu o właściwościach możliwie najbardziej zbliżonych do szumu białego. Filtr modelujący uzyskuje się wtedy poprzez odpowiednie odwrócenie filtru wybielającego. Dowodzi to, że z praktycznego punktu widzenia problemy wybielania i modelowania sygnałów są ze sobą nierozdzielnie związane i należy je traktować łącznie.

### 3.2 Adaptacyjne algorytmy modelowania procesów losowych ARMA

W ćwiczeniu badane są dwa algorytmy modelowania ARMA. Pierwszym z nich jest blokowy algorytm transwersalny oparty na kryterium LS. Istotą tego algorytmu jest połączenie rozwiązania nadokreślonego układu zmodyfikowanych równań Yula-Walkera (estymacja parametrów AR) z metodą Kay'a estymacji parametrów MA w modelu ARMA. Algorytm ten jest opisany szczegółowo w [1, 2].

Drugim algorytmem jest rekursywny algorytm oparty na kryterium największej wiarygodności [3]. Ze względu na duże znaczenie praktyczne w klasie algorytmów estymacji parametrów procesów ARMA zostanie on omówiony dokładniej.

Przyjmujemy następujące oznaczenia:

$\boldsymbol{\theta} = [-a_1, \dots, -a_p, b_1, \dots, b_q]^T$  - wektor parametrów modelu,

$\hat{\boldsymbol{\theta}}_n = [-\hat{a}_1(n), \dots, -\hat{a}_p(n), \hat{b}_1(n), \dots, \hat{b}_q(n)]^T$  - wektor estymat parametrów modelu,

$\boldsymbol{\nu}_n = [x(n-1), \dots, x(n-p), e(n-1), \dots, e(n-q)]^T$  - wektor danych (obserwacji),

$\tilde{\boldsymbol{\nu}}_n = [\tilde{x}(n-1), \dots, \tilde{x}(n-p), \tilde{e}(n-1), \dots, \tilde{e}(n-q)]^T$  - wektor danych po filtracji.

Zakładając, że znamy już wektor estymat parametrów  $\hat{\boldsymbol{\theta}}_{n-1}$  wyznaczony dla poprzednich obserwacji możemy, zgodnie z ogólną zasadą algorytmów rekursywnych, wyznaczyć wektor estymat  $\hat{\boldsymbol{\theta}}_n$  po zarejestrowaniu obserwacji  $x(n)$ . Bezpośrednio przed zarejestrowaniem obserwacji  $x(n)$  dostępne są następujące wielkości:  $\hat{\boldsymbol{\theta}}_{n-1}$ ,  $\boldsymbol{\nu}_n$ ,  $\tilde{\boldsymbol{\nu}}_n$  oraz macierz

$$\mathbf{Q}_{n-1} = E[(\hat{\boldsymbol{\theta}}_{n-1} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}}_{n-1} - \boldsymbol{\theta})^T], \quad (3)$$

będąca macierzą kowariancji błędu.

Po zarejestrowaniu próbki  $x(n)$  możemy zatem wyznaczyć błąd predykcji:

$$\varepsilon(n) = x(n) - \boldsymbol{\nu}_n^T \hat{\boldsymbol{\theta}}_{n-1} \quad (4)$$

oraz macierz kowariancji błędu w chwili  $n$ :

$$\mathbf{Q}_n = \frac{1}{\lambda_n} \cdot \frac{\mathbf{Q}_{n-1} - \mathbf{Q}_{n-1} \tilde{\boldsymbol{\nu}}_n \tilde{\boldsymbol{\nu}}_n^T \mathbf{Q}_{n-1}}{\lambda_n + \tilde{\boldsymbol{\nu}}_{n-1}^T \mathbf{Q}_{n-1} \tilde{\boldsymbol{\nu}}_{n-1}}. \quad (5)$$

Rola parametru  $\lambda_n$  zostanie wyjaśniona niżej.

Główna rekursja na parametry modelu przyjmuje postać:

$$\hat{\boldsymbol{\theta}}_n = \hat{\boldsymbol{\theta}}_{n-1} + \mathbf{Q}_n \tilde{\boldsymbol{\nu}}_n \varepsilon(n). \quad (6)$$

Po wyznaczeniu bieżącej wartości wektora estymat  $\hat{\boldsymbol{\theta}}_n$  możemy wyznaczyć błąd resztkowy:

$$e(n) = x(n) - \boldsymbol{\nu}_n^T \hat{\boldsymbol{\theta}}_n, \quad (7)$$

który występuje w wektorze obserwacji  $\boldsymbol{\nu}_{n+1}$ . Mając z kolei wektor  $\boldsymbol{\nu}_{n+1}$  możemy wyznaczyć wektor danych po filtracji  $\tilde{\boldsymbol{\nu}}_{n+1}$  do następnej iteracji. W tym celu należy dokonać następującej operacji filtracji:

$$\tilde{x}_n(z) = \frac{1}{\hat{B}_n(kz^{-1})} x_n(z), \quad \tilde{e}_n(z) = \frac{1}{\hat{B}_n(kz^{-1})} e_n(z), \quad (8)$$

gdzie

$$\hat{B}_n(kz^{-1}) = 1 + k\hat{b}_1(n)z^{-1} + k^2\hat{b}_2(n)z^{-2} + \dots + k^q\hat{b}_q(n)z^{-q}. \quad (9)$$

Rolą stałej  $k$  jest zapewnienie stabilności filtru. W wersji algorytmu zaimplementowanej w pakiecie AFRICA wartość tej stałej jest dobierana automatycznie.

Występujący wcześniej parametr  $\lambda_n$  jest pewnym parametrem wagowym nazywanym również wykładniczym współczynnikiem zapominania. Często przyjmuje się, że  $\lambda_n = \text{const}$ . W wersji algorytmu badanej w ćwiczeniu przyjęto jednak, że  $\lambda_n = (1 - \beta)\lambda_{n-1} + \beta$ , gdzie  $\lambda_0 = 0,95$ ,  $\beta$  zaś jest stałą dodatnią o małej wartości ( $\beta < 1$ ), która ma jednakże istotny wpływ na szybkość zbieżności algorytmu.

### 3.3 Analiza widmowa oparta na modelowaniu autoregresyjnym

Proces autoregresyjny AR jest szczególnym przypadkiem procesu ARMA rozważanego w punkcie 3.1. Losowy dyskretny proces autoregresji opisany jest następującym równaniem:

$$X(n) = \sum_{i=1}^p a_i X(n-i) + W(n). \quad (10)$$

Podobnie jak dla procesu ARMA, proces AR otrzymywany jest na wyjściu filtru liniowego o transmitancji  $H(z)$  pobudzanego szumem  $W(n)$  z tą różnicą, że tym razem transmitancja ta ma postać:

$$H(z) = \frac{1}{A(z)} = \frac{1}{1 - a_1 z^{-1} - \dots - a_p z^{-p}}. \quad (11)$$

Zgodnie z właściwościami transmisyjnymi układów liniowych widmowa gęstość mocy sygnału na wyjściu filtru, a więc procesu autoregresyjnego jest dana zależnością:

$$S_{XX}(e^{j\theta}) = \sigma_W^2 \cdot \frac{1}{|1 - a_1 e^{-j\theta} - \dots - a_p e^{-jp\theta}|^2}. \quad (12)$$

Oczywiście podaną zależność widmową można bez trudu uogólnić na przypadek procesu ARMA. Wówczas otrzymujemy

$$S_{XX}(e^{j\theta}) = \sigma_W^2 \cdot \left| \frac{1 + b_1 e^{-j\theta} + \dots + b_q e^{-jq\theta}}{1 - a_1 e^{-j\theta} - \dots - a_p e^{-jp\theta}} \right|^2. \quad (13)$$

Przedstawione zależności widmowe stanowią podstawę analizowanych w ćwiczeniu nowoczesnych metod estymacji widma opartych na modelowaniu procesów losowych. Zgodnie z zależnościami (12) i (13), znając parametry modelu, możemy bez trudu wyznaczyć widmową gęstość mocy obserwowanego procesu. Oczywiście w praktyce parametry modelu nie są znane i należy je estymować na podstawie próbek pojedynczej realizacji obserwowanego sygnału losowego.

W tym miejscu należy podkreślić, że w porównaniu z klasycznymi metodami estymacji widma takimi jak metoda periodogramów, metody oparte na modelowaniu sygnałów charakteryzują się znacznie lepszą rozdzielczością, a także lepszymi właściwościami statystycznymi estymatora, takimi jak obciążenie czy wariancja. Cena jaką trzeba zapłacić za taką poprawę to znaczne zwiększenie złożoności obliczeniowej algorytmów estymacji widma mocy.

## 4. BADANIA EKSPERYMENTALNE

### 4.1 Badanie algorytmów estymacji parametrów procesu ARMA

Wygenerować 500 próbek sygnału ARMA(2, 2) o współczynnikach  $\mathbf{b} = [1 \ -1,7150 \ 0,9810]^T$  oraz  $\mathbf{a} = [1 \ -0,9500 \ 0,9025]^T$ , wykorzystując do tego celu następującą sekwencję instrukcji:

```
rand('normal');
x = rand(1,500);
y = filter(b,a,x);
```

1. Wyestymować widmo sygnału za pomocą blokowego algorytmu Kay'a BLK i porównać je na jednym wykresie logarytmicznym z charakterystyką amplitudową filtru modelującego. Skorzystać z funkcji `freqz`. Skomentować wyniki.
2. Wybielić sygnał za pomocą estymowanego i idealnego filtru odwrotnego. Porównać i skomentować wyniki na podstawie oceny widma mocy i funkcji autokorelacji wybielonych sygnałów.
3. Wygenerowany sygnał ARMA(2, 2) poddać filtracji za pomocą rekursywnego algorytmu Friedlandera RML dla kilku wartości stałej  $\beta$  ( $\beta = 0,3; 0,1; 0,05; 0,01; 0$ ), badając jednocześnie wpływ tej stałej na jakość estymacji widma oraz dokładność estymacji współczynników.
4. Porównać jakość wybielania sygnału dla trzech wybranych wartości stałej  $\beta$ .

### 4.2 Estymacja widma zaszumionych sygnałów sinusoidalnych

1. Wygenerować sygnał o długości 500 próbek będący sumą dwóch składowych harmonicznych o jednostkowych amplitudach oraz częstotliwościach unormowanych 0,20 i 0,30 zakłóconych addytywnym szumem białym. Wyestymować widmo takiego sygnału za pomocą algorytmu BLK, zakładając jednocześnie, że sygnał ten jest dobrze

modelowany procesem ARMA(4, 4). Zbadać jakość estymacji widma w zależności od wariancji szumu zakłócającego.

2. Powtórzyć badania z punktu 1 zbliżając do siebie częstotliwości unormowane składowych sinusoidalnych (przyjąć wartości 0,20 i 0,21).

### 4.3 Estymacja widma sygnału zespolonego za pomocą modelowania AR

Ten punkt ćwiczenia został zrealizowany w pakiecie AFRICA jako program `demo 6`. Sygnał zespolony, którego widmo będzie estymowane za pomocą różnych algorytmów AR dostępnych w pakiecie AFRICA jest krótkim 64 punktowym ciągiem danych. Zawiera on w swoim widmie dwie silne blisko siebie położone sinusoidy zespolone o częstotliwościach unormowanych 0,20 i 0,21, a także dwie słabsze o 20 dB sinusoidy o częstotliwościach -0,15 i 0,10. Sygnał użyteczny składający się z tych czterech zespolonych sinusoid zakłócony jest szumem kolorowym występującym w pasmach częstotliwości od -0,50 do -0,20 oraz od 0,20 do 0,50.

Widma będą estymowane kolejno za pomocą następujących algorytmów: BLT, BLL, GAT, GAL, LST. Rząd modelu AR ustalono na 15. Oglądając kolejno estymowane widma porównać i skomentować rezultaty pod kątem rozdzielania dwóch bliskich składowych sinusoidalnych, skuteczności wychwycenia składowych o mniejszych amplitudach oraz obecności ewentualnych artefaktów.

### 4.4 Zastosowanie algorytmów rekursywnych do estymacji charakterystyk procesu niestacjonarnego

Wygenerować 100 próbek sygnału sinusoidalnego o liniowo narastającej częstotliwości unormowanej w zakresie od 0,16 do 0,32 zakłócanego szumem białym o odchyleniu standardowym  $\sigma_W = 0,1$  (program demonstracyjny `demo 4`).

1. Wyznaczyć widmo takiego sygnału metodą FFT oraz blokowym algorytmem AR wysokiego rzędu (np. 32). Skomentować wyniki.
2. Do estymacji widma zastosować rekursywny algorytm rzędu 4 (np. LST). Za pomocą odpowiednich procedur wizualizacji wyników dostępnych w pakiecie AFRICA zbadać możliwość śledzenia widma chwilowego sygnału niestacjonarnego przez algorytm rekursywny. Sformułować wnioski ogólne.

### 4.5 Zastosowanie algorytmów rekursywnych do estymacji widma chwilowego sygnału EEG

Rekursywna estymacja widma chwilowego sygnału EEG została zaimplementowana jako program demonstracyjny pakietu AFRICA o nazwie `demo 5`. Sygnał EEG wykorzystany w tym pokazowym programie jest fragmentem sygnału rzeczywistego nagranych podczas całonocnego badania pacjenta w szpitalu. Podobnie jak w poprzednim punkcie jest to sygnał niestacjonarny. Analiza widmowa tego sygnału służy do rozpoznawania faz snu, a w szczególności tzw. wrzecion sennych, które stanowią istotną informację diagnostyczną dla lekarzy. Szczegóły dotyczące analizowanego przebiegu EEG podane zostaną jako komentarze w trakcie kolejnych kroków wykonywania się programu `demo 5`.

## 4.6 Zastosowanie algorytmów AR do estymacji widma procesów ARMA

Wygenerować sygnał ARMA(2, 2) o dowolnych (ale sensownych) wymyślonych przez ćwiczących parametrach. Dokonać estymacji widma tego sygnału za pomocą kilku wybranych algorytmów AR. Zbadać wpływ rzędu algorytmu AR na jakość estymacji.

### LITERATURA

- [1] M. L. Hönl and D. G. Messerschmitt, *Adaptive Filters*. Kluwer Academic Publishers, 1984.
- [2] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*. Englewood Cliffs: Prentice-Hall, 1985.
- [3] B. Friedlander, "Recursive Maximum Likelihood Algorithm for ARMA Spectral Estimation," *IEEE Trans. on Information Theory*, July 1982.
- [4] P. M. Clarkson, *Optimal and Adaptive Signal Processing*. CRC Press, 1993.