

Jacek ŁĘSKI

ZASTOSOWANIE NIELINIOWEJ FILTRACJI KALMANA DO TŁUMIENIA ZAKŁÓCEŃ SYGNAŁU EKG

Streszczenie. W pracy przedstawiono nową metodę tłumienia zakłóceń sygnału EKG, których widmo częstotliwościowe nakłada się na widmo sygnału dla szerokiego zakresu częstotliwości. Sygnał EKG modelowano procesem autoregresyjnym (AR). Jednoczesna estymacja wartości próbek sygnału i nieznanymi parametrów autoregresji prowadzi do problemu nieliniowego. Zagadnienie to zostało rozwiązane przez zastosowanie rozszerzonego filtra Kalmana i metody GPIA. Metoda może znaleźć zastosowanie w tłumieniu zakłóceń elektrokardiogramów wysiłkowych, EKG płodu i innych.

1. WSTĘP

Jednym z pierwszych etapów komputerowej analizy sygnału EKG jest tłumienie zakłóceń. Zakłócenia których widmo częstotliwościowe nie nakłada się, lub nakłada się na widmo sygnału EKG dla wąskiego zakresu częstotliwości mogą być tłumione za pomocą klasycznych filtrów częstotliwościowych [2,5,26]. Metoda tą nie można bez zniekształcania sygnału (utrata informacji diagnostycznej) tłumić zakłóceń, których widmo częstotliwościowe nakłada się na widmo sygnału dla szerokiego zakresu częstotliwości [25].

Do zakłóceń takich należą np.:

- zakłócenia mięśniowe podczas elektrokardiograficznych prób wysiłkowych [13, 16],
- zakłócenia powstające przy przesyłaniu sygnału EKG linią telefoniczną [6],
- zakłócenia EKG płodu podczas akcji porodowej [14],
- zakłócenia wysokorozdzielczych elektrokardiogramów [1,15].

Powszechnie stosowaną metodą tłumienia tych zakłóceń jest selektywne uśrednianie sygnału EKG z wielu ewolucji serca [13,25]. Metoda ta bazuje na dyskusyjnym założeniu idealnej powtarzalności kształtu sygnału w każdej ewolucji serca [12].

Stosując w praktyce tę metodę uzyskujemy uśredniony kształt sygnału. W pewnych zastosowaniach, np. analizie obniżenia odcinka ST podczas próby wysiłkowej nie stanowi to problemu. Jednak nie jest możliwe zastosowanie tej metody np. do analizy zmienności odcinka QT podczas tej próby.

W artykule przedstawiona jest metoda tłumienia zakłóceń sygnału EKG oparta na modelowaniu sygnału procesem autoregresyjnym [7] oraz jednoczesnej estymacji wartości próbek sygnału i nieznanych parametrów autoregresji. Jeżeli przedstawimy ten model w postaci równań zmiennych stanu, włączając nieznanne parametry do wektora stanu, to uzyskamy nieliniowy model względem wektora stanu/parametrów.

Klasycznymi metodami rozwiązania tego problemu są, np.:

- metoda porogramowania nieliniowego; estymacja parametrów metodą największą największej wiarygodności [4,21],
- estymacja adaptacyjna za pomocą przetwarzania równoległego [3],
- stosowanie rozszerzonego filtru Kalmana [9],
- stosowanie dyskretnej zasady maksimum lub dyskretnego równania Eulera-Lagrange'a [11].

W pracy zastosowano metodę GPIA (Generalized Partitioned Identification Algorithm) Lainiotisa [18,19]. Nieznane statystyki szumów estymowano metodą Mayersa [23].

2. METODA

Sygnał EKG modelujemy procesem autoregresyjnym rzędu p [17,22]:

$$x(k) = \sum_{i=1}^p a_i x(k-i) + w(k) \quad (1)$$

gdzie:

a_i - nieznanne parametry,

w - gaussowski szum biały spełniający założenia:

$$\forall_k E\{w(k)\} = 0 \quad (2)$$

$$\forall_{i,j} E\{w(i)w(j)\} = Q(i)\delta_{i,j}; \quad \delta - \text{delta Kroneckera.}$$

Zakłócony sygnał EKG otrzymujemy dodając gaussowski szum biały:

$$z(k) = x(k) + v(k) \quad (3)$$

Szum v spełnia założenia:

$$\forall_k E[v(k)] = 0 \quad (4)$$

$$\forall_{i,j} E[v(i)v(j)] = R(i)\delta_{i,j}$$

Równania (1), (3) możemy przedstawić w formie nieliniowego modelu zmiennych stanu:

$$x_a(k+1) = f[x_a(k)] + G_a w(k) \quad (5a)$$

$$z(k) = H_a x_a(k) + v(k) \quad (5b)$$

gdzie

$$x_a = \begin{bmatrix} x \\ \theta \end{bmatrix} = \begin{bmatrix} x_1 \\ \vdots \\ x_p \\ a_p \\ \vdots \\ a_1 \end{bmatrix} \quad - \text{wektor stanu/parametrów,} \quad (6)$$

$$f[x_a(k)] = \begin{bmatrix} x_p(k)x_{p+1}(k) \\ x_1(k)+x_p(k)x_{p+2}(k) \\ \vdots \\ x_{p-1}(k)+x_p(k)x_{2p}(k) \\ x_{p+1} \\ \vdots \\ x_{2p} \end{bmatrix} = \begin{bmatrix} f_x \\ f_\theta \end{bmatrix} \quad (7)$$

$$H_a = [0 \dots 0 \ 1; 0 \dots 0] = [H_x; H_\theta]; \quad G_a = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} G_x \\ G_\theta \end{bmatrix} \quad (8)$$

Zakładamy ponadto:

$$\forall_{i,j} E[v(i)w(j)] = 0$$

$$\forall_i E[v(i)x(j)] = 0 \quad (9)$$

$$\forall_i E[w(i)x(0)] = 0$$

gdzie:

$x(0)$ - stan początkowy.

Rozwijamy $f[x_a(k)]$ w szereg Taylora w otoczeniu $\hat{x}_a(k/k)$

$$f[x_a(k)] = f[\hat{x}_a(k/k)] + F_a(k)[x_a(k) - \hat{x}_a(k/k)] + \dots \quad (10)$$

Pomijając człony wyższego rzędu i zakładając znajomość $\hat{x}_a(k/k)$ otrzymujemy:

$$x_a(k+1) = F_a(k)x_a(k) + G_a w(k) + u(k) \quad (11a)$$

$$z(k) = H_a x_a(k) + v(k) \quad (11b)$$

gdzie:

$$u(k) = \hat{x}_a(k/k) - F_a(k)\hat{x}_a(k/k) \quad (12)$$

$$F_a(k) = \frac{\delta f}{\delta x_a} \bigg|_{\hat{x}_a(k/k)} = \left[\begin{array}{c|c} 0 & 0 \dots\dots 0 \ x_{p+1} \\ 0 & 1 \dots\dots 0 \ x_{p+2} \\ \vdots & \vdots \\ 0 & \dots\dots 1 \ x_{2p} \\ \hline & 0 \qquad \qquad \qquad I \end{array} \right] = \left[\begin{array}{c|c} F_x(k) & F_\theta(k) \\ \hline 0 & I \end{array} \right] \quad (13)$$

Stosując do estymacji x_a filtr Kalmana otrzymujemy [9,24]:

$$\hat{x}_a(i/i) = \hat{x}_a(i) + K_a(i) \bar{z}(i) \quad (14a)$$

$$\bar{x}_a(i) = f[\hat{x}_a(i-1/i-1)] \quad (14b)$$

$$\bar{z}(i) = z(i) - H_a \bar{x}_a(i) \quad (14c)$$

$$K_a(i) = M_a(i) H_a^T B_a^{-1}(i) \quad (14d)$$

$$B_a(i) = H_a M_a(i) H_a^T + R(i) \quad (14e)$$

$$M_a(i) = F_a(i-1) P_a(i-1) F_a(i-1)^T + G_a Q(i-1) G_a^T \quad (14f)$$

$$P_a(i) = [I - K_a(i) H_a] M_a(i) \quad (14g)$$

gdzie: $\hat{x}_a(i/i)$ - estymata wartości $x_a(i)$ na podstawie pierwszych i -pomiarów,
 $P_a(i) = E\{[\hat{x}_a(i/i) - x_a(i)]^T [\hat{x}_a(i/i) - x_a(i)]\}$ - macierz kowariancji błędu estymacji.

W dalszej części pracy zakładamy stacjonarność zakłóceń:

$$\forall_i Q(i)=Q \quad (14b)$$

$$\forall_i R(i)=R \quad (14i)$$

Zgodnie z koncepcją Lainiotisa zakładamy, że stan początkowy jest sumą dwóch niezależnych wektorów gaussowskich [18]:

$$x_a(0) = x_n(0) + x_r(0) = \begin{bmatrix} x(0) \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ \theta(0) \end{bmatrix} \quad (15)$$

gdzie:

$x_n(0)$ - nominalna część stanu początkowego,

$x_r(0)$ - pozostała część stanu początkowego.

Macierz kowariancji stanu początkowego ma postać:

$$P_a(0) = P_n(0) + P_r(0) = \begin{bmatrix} P_x(0) & 0 \\ 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 0 & P_{\theta\theta}(0) \end{bmatrix} \quad (16)$$

Na podstawie (14), (15), (16) widzimy, że wzmocnienie filtra Kalmana ma postać:

$$K_a(i) = \begin{bmatrix} K_x(i) \\ 0 \end{bmatrix} \quad (17)$$

Przy poczynionych założeniach filtr Kalmana jest jedynie estymatorem stanu i parametry pozostają niezmiennicze. Stąd równania (14a)-(14g) możemy przepisać w postaci wymagającej mniejszego nakładu obliczeniowego:

$$\hat{x}_x(i/i) = \bar{x}_x(i) + K_x(i) \tilde{z}(i) \quad (18a)$$

$$\bar{x}_x(i) = f_x[\hat{x}_x(i-1/i-1)] \quad (18b)$$

$$\tilde{z}(i) = z(i) - H_x \bar{x}_x(i) \quad (18c)$$

$$K_x(i) = M_x(i) H_x^T B_x^{-1}(i) \quad (18d)$$

$$B_x(i) = H_x M_x(i) H_x^T + R \quad (18e)$$

$$M_x(i) = F_x(i-1) P_x(i-1) F_x(i-1)^T + G_x Q G_x^T \quad (18f)$$

$$P_x(i) = [I - K_x(i) H_x] M_x(i) \quad (18g)$$

Za pomocą filtru Kalmana prowadzimy "w przód" estymację stanu, zakładając że θ jest znane. "W tył" estymujemy nieznanne parametry za pomocą wygładzania w stałym punkcie [10]:

$$\theta = \theta(0) + P_{\theta\theta}^{-1} M_{\theta}(N,) \quad (19)$$

$$P_{\theta\theta} = [0_{\theta\theta}(N, 0) + P_{\theta\theta}^{-1}(0)]^{-1} \quad (20)$$

gdzie:

$$M_n(N, 0) = \begin{bmatrix} M_x(N, 0) \\ M_{\theta}(N, 0) \end{bmatrix} = \sum_{i=1}^N Z_n^T(i-1) F_a^T(i-1) H_a^T B_x^{-1}(i) \tilde{z}(i) \quad (21)$$

$$0_n(N, 0) = \begin{bmatrix} 0_{xx}(N, 0) & 0_{x\theta}(N, 0) \\ 0_{x\theta}^T(N, 0) & 0_{\theta\theta}(N, 0) \end{bmatrix} = \sum_{i=1}^N Z_n^T(i-1) F_a^T(i-1) H_a^T B_x^{-1}(i) H_a F_a(i-1) Z_n(i-1) \quad (22)$$

gdzie:

N - liczba próbek sygnału.

$$Z_n(i) = [I - K_a(i) H_a] F_a(i-1) Z_n(i-1); \quad Z_n(0) = I \quad (23)$$

Nieznanne wariancje szumów estymujemy za Mayersem [23]:

$$\hat{R} = \frac{1}{i-N} \sum_{j=1}^N \left[\hat{v}(j)^2 - \left(\frac{N-1}{N} \right) H_x M_x(j) H_x^T \right] \quad (24)$$

$$\hat{v}(j) = z(j) - H_x \bar{x}(j) \quad (25)$$

$$\hat{Q} = \sum_{j=1}^N \left[\hat{w}(j)^2 - \left(\frac{N-1}{N} \right) G_x^T \left[F_x(j-1) P_x(j-1) F_x^T(j-1) - P_x(j) \right] G_x \right] \quad (26)$$

$$\hat{w}(j) = G_x^T [x(j/j) - F_x(j-1)x(j-1/j-1)] \quad (27)$$

Estymację parametrów prowadzimy iteracyjnie podstawiając:

$$\theta \longrightarrow \theta(0)$$

$$P_{\theta\theta} \longrightarrow P_{\theta\theta}(0) \quad (28)$$

$$\hat{R} \longrightarrow R$$

$$\hat{Q} \longrightarrow Q$$

Do inicjalizacji obliczeń używamy:

$$x_a^T(0) = [z(1), \dots, z(1)] \left[\frac{1}{p}, \dots, \frac{1}{p} \right] \quad (29)$$

$$P_x(0) = I \cdot R \quad (30)$$

$$P_{\theta\theta}^{-1}(0) = 0 \quad (31)$$

Zastosowano heurystyczną regułę mającą na celu uzyskanie zbieżności algorytmu: w kolejnych iteracjach estymowano na przemian statystyki szumów i parametry autoregresji. Estymaty statystyk szumów wyznaczano na podstawie równań (24)-(27), gdy spełniony był warunek:

$$\theta - \theta(0) < \epsilon_1, \quad \epsilon_1 - \text{parametr.} \quad (32)$$

Następnie znów estymowano parametry autoregresji. Iteracje przerywano gdy spełnione były warunki:

$$|R - R| < \epsilon_2 \wedge |Q - Q| < \epsilon_3; \quad \epsilon_2, \epsilon_3 - \text{parametry.} \quad (33)$$

Zbieżność algorytmu uzyskiwano w 9 do 10 iteracjach.

3. REZULTATY

Z prac Eisensteina, Vaccaro [8] oraz Lina, Changa [20] wynika, że zwiększenie rzędu autoregresji powyżej $p=2$ powoduje nieznaczne zmniejszenie błędów modelowania sygnału EKG. Powoduje to natomiast w przypadku stosowania algorytmu opisanego w artykule zwiększenie nakładu obliczeniowego proporcjonalnego do $(2p)^3$. Z tego względu do testowania opisanej metody stosowany był model autoregresyjny rzędu 2 AR(2). Do testowania używano przebiegów EKG próbkowanych z częstotliwością $f_p=500$ Hz i kwantowanych 12 bitowo ($1\mu\text{V}$ na kwant). Z bazy danych elektrokardiograficznych wybrano 20 odcinków po 200 próbek, zawierających istotne z diagnostycznego punktu widzenia fragmenty: załamki P, zespoły QRS, odcinki ST oraz załamki T.

Przeprowadzono następujące badania symulacyjne: oryginalny sygnał EKG zakłócano szumem białym, następnie tłumiono zakłócenia i porównywano ten sygnał z oryginalnym.

Stosunek sygnał-szum definiowano jako:

$$\text{SNR [dB]} := 10 \log \frac{P_{\text{QRS}}}{P_n} \quad (34)$$

gdzie:


P_{QRS} - moc sygnału EKG,

P_n - moc zakłóceń.

Testowano równolegle następujące metody tłumienia zakłóceń:

- "klasyczną" częstotliwościową filtrację cyfrową; filtr dolnoprzepustowy o częstotliwości granicznej 10 Hz,
- uśrednianie sygnału w dziedzinie czasu z 16 ewolucji serca,
- metodą opisaną w artykule.

Rysunek 1 przedstawia zależność wyjściowego stosunku sygnału do szumu (SNR_{out}) od wejściowego (SNR_{in}) dla testowanych metod. Są to wyniki uśrednione dla 20 odcinków sygnału EKG używanych do testowania i 10 realizacji szumu zakłócającego dla każdego odcinka sygnału. Przykładowe tłumienia zakłóceń opisanymi metodami przedstawiają rysunki od 2 do 4 (fragment sygnału EKG z załawkami P i początkiem zespołu QRS). Rysunki te przedstawiają w części a sygnał zakłóceniowy ($\text{SNR}=3$ dB), w części b sygnał po filtracji (linia przerywana) i oryginalny (linia ciągła).



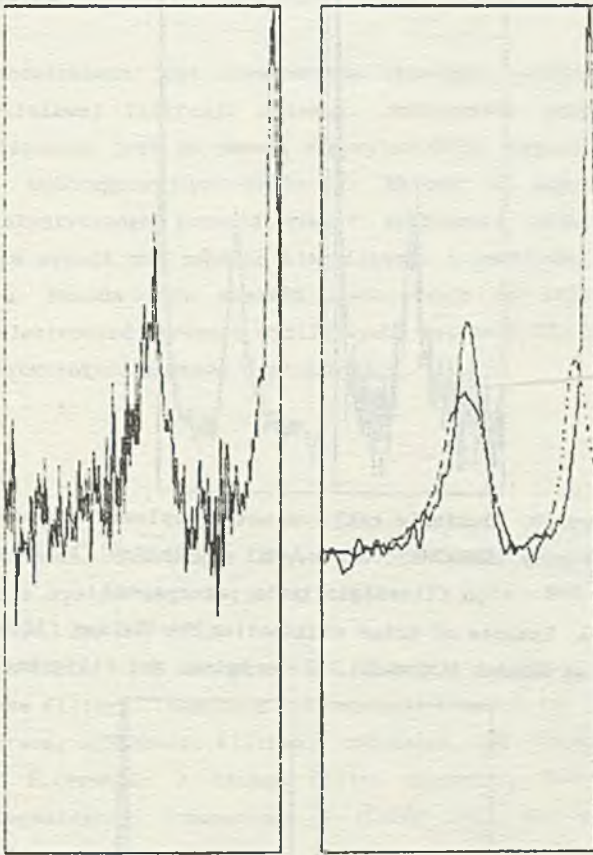
Rys. 1. Zależność stosunku sygnału do szumu sygnału po filtracji od stosunku sygnał-szum sygnału filtrowanego:

— uśrednianie statystyczne 16 okresów sygnału, - - metoda opisana w pracy,
 - - - filtracja cyfrowa

Fig. 1. Output signal to noise ratio as a function of input signal to noise ratio:


— statistical averaging (16 cycles), - - Kalman filtering, - - - low-pass digital filtering

Na podstawie rysunku 1 widzimy, że metoda opisana w pracy wykazuje zależność stopnia tłumienia zakłóceń od SNR sygnału wejściowego. Metoda uśredniania tłumí wariancję zakłóceń k -razy; gdzie k jest liczbą uśrednianych okresów sygnału. Jest to oszacowanie optymistyczne wymagające spełnienia następujących założeń: stacjonarności zakłóceń oraz idealnego centrowania uśrednianych okresów. Metoda opisana w pracy nie wymaga spełnienia powyższych założeń, gdyż estymuje wartości próbek na podstawie jednego okresu sygnału. "Klasyczna" częstotliwościowa filtracja cyfrowa powoduje niedopuszczalne zniekształcenia sygnału EKG (usuwanie częstotliwości zawartych w sygnale).



Rys. 2. Tłumienia zakłóceń metodą częstotliwościowej filtracji cyfrowej:
a - sygnał zakłócony (SNR=3dB), b - sygnał oryginalny (linia ciągła), sygnał
po filtracji (linia przerywana)

Fig. 2. Example of noise elimination for low-pass digital filtering:
a - noise signal (SNR=3dB), b - original and filtering signal




Rys. 3. Tłumienie zakłóceń metodą opisaną w pracy:

a - sygnał zakłócony (SNR=3dB), b - sygnał oryginalny (linia ciągła), sygnał po filtracji (linia przerywana)

Fig. 3. Example of noise elimination for Kalman filtering:

a - noise signal (SNR=3dB), b - original and filtering signal



Rys. 4. Tłumienie zakłóceń metodą uśredniania statystycznego:

a - sygnał zakłócony (SNR=3dB), b - sygnał oryginalny (linia ciągła), sygnał po filtracji (linia przerywana)

Fig. 4. Example of noise elimination for statistical averaging:

a - noise signal (SNR=3dB), b - original and filtering signal

4. PODSUMOWANIE

W pracy przedstawiona jest nowa metoda tłumienia zakłóceń sygnału EKG oparta na nieliniowej filtracji Kalmana. Jednoczesna estymacja stanu i parametrów realizowana jest za pomocą algorytmu GPIA. Sygnał EKG modelowany jest procesem autoregresyjnym rzędu 2. Metoda w przeciwieństwie do uśredniania statystycznego pozwala tłumić zakłócenia pojedynczego okresu sygnału EKG. Nie wymaga ona ponadto klasyfikacji i centrowania uśrednianych okresów sygnału. Metoda może znaleźć zastosowanie do tłumienia zakłóceń mięśniowych w elektrokardiogramach wysiłkowych, zakłóceń EKG płodu i wysoko-oddzielczych elektrokardiogramów oraz innych.

LITERATURA

- [1] H.A.M. Al-Nashash, S.W.Kelly, D.J.E.Taylor: Beat-to-beat detection of His-Purkinje system signals using adaptive filters, *Med & Biol.Eng. & Comput.*, 1988, 26, 117-125.
- [2] J.A.Alste, W.Eck, O.E.Herrmann: ECG baseline wander reduction using linear phase filters, *Computers & Biomedical Research* 19, 417-427, (1986)
- [3] B.D.O.Anderson, J.B.Moore: Filtracja optymalna, WNT, Warszawa 1984.
- [4] F.Bartoli, S.Cerutti: A Kalman filter procedure for processing of electroencephalogram, *Proceedings of ICASSP 1982, New York IEEE 1982*, pp. 721-724.
- [5] K.G.Beauchamp: Przetwarzanie sygnałów metodami analogowymi i cyfrowymi, WNT, Warszawa 1978.
- [6] A.S.Berson: Telephone transmission of electrocardiograms, *Proceedings of the 2nd IFIP TC-4 Working Conference on Computer Application on ECG & VCG analysis, Hannover, 11-14 October 1971*, pp. 83-97.
- [7] G.E.Box, G.M.Jenkins: Analiza szeregów czasowych - Prognozowanie i sterowanie, PWN, Warszawa 1983.
- [8] B.A.Eisenstein, R.J.Vaccaro: Feature extraction by system identification, *IEEE Trans.Sys.Men Cyb. SMC-12, No.1. Jan 1982*, 15-23.
- [9] T.E.Elbirt: Estimation and Control of Systems, Van Nostrand Reinhold Company Inc., New York 1984.
- [10] B.J.Eulrich, D.Andrisani, D.G.Lainiotis: Partitioning Identification Algorithms, *IEEE Trans. Automatic Control, Vol. AC-25, No.3, June 1980*.

- [11] P. Eykoff: Identyfikacja w układach dynamicznych, PWN, Warszawa 1980.
- [12] J. Groeben, R.S. Crow, A.D. Forbes: Some observations on ECG waveform variability, Proceedings of the 2nd IFIP TC-4 Working Conference on Computer Application on ECG & VCG analysis, Hannover, 11-14 October 1971.
- [13] P. Hsia et al: An automated system for ST segment and arrhythmia analysis in exercise radionuclide ventriculography, IEEE Trans. Biomed. Eng., BME-33, No. 6, June 1986, pp. 585-593.
- [14] W. Jarisch, J.S. Detwiler: Statistical modeling of fetal heart rate variability, IEEE Trans. Biomed. Eng., BME-27, No. 10, Oct. 1980, pp. 582-589.
- [15] S. Jesus, H. Rix: High resolution ECG analysis by an improved signal averaging method and comparison with a beat-to-beat approach, J. Biomed. Eng., Vol. 10, Jan., pp. 25-32.
- [16] N.B. Jones, et al: Spectral analysis and the interference EMG, IEEE Proc., Vol. 129, No. 9, Dec 1982, 987-992.
- [17] R.L. Kashyap: Optimal feature selection and decision rule in classification problem with time series, IEEE Trans. Inf. Theory 3, 281-307, (1978).
- [18] D.G. Lainiotis: Partitioning: A unifying framework for adaptive systems, I: Estimation, Proc. IEEE, Vol. 64, Aug. 1976.
- [19] D.G. Lainiotis: Partitioning: A unifying framework for adaptive systems, II: Control, Proc. IEEE, Vol. 64, Aug. 1976.
- [20] K.P. Lin, W.H. Chang: ECG signal analysis by linear predictive method IEEE Ninth Annual Conference of the Engineering in Medicine and Biological Society 1987, pp. 557-558.
- [21] K. Mańczak, Z. Nachorski: Komputerowa identyfikacja obiektów dynamicznych PWN, Warszawa 1983.
- [22] J.P. Marques de Sa, C. Abreu-Lima: A new ECG Classifier based on linear prediction techniques, Computers & Biomedical Research 19, 213-222 (1986).
- [23] R.A. Mayers, B.D. Tapley: Adaptive sequential estimation with unknown noise statistics, IEEE Trans. Automatic Control, Vol. AC-21, No. 4, 1980.
- [24] J.S. Meditch: Estymacja i sterowanie statystycznie optymalne w układach liniowych, WNT, Warszawa 1975.

- [25] O. Pahlm, L. Sörnmo: Data processing of exercise ECG's, IEEE Trans. Biomed. Eng., BME-34, No2, Feb. 1987, pp. 158-165.
- [26] A. Wojtkiewicz: Elementy syntezy filtrów cyfrowych, WNT, Warszawa 1984.

Recenzent: Prof. dr hab. inż. Ryszard Tadeusiewicz

Wpłynęło do Redakcji 30.03.1989 r.

ПРИМЕНЕНИЕ НЕЛИНЕЙНОЙ ФИЛЬТРАЦИИ ПО КАЛЬМАНУ ДЛЯ ПОДАВЛЕНИЯ ПОМЕХ СИГНАЛА ЭКГ

Р е з ю м е

В статье описано применение нелинейной фильтрации по Кальману для подавления помех сигнала ЭКГ. Помехи имеют спектр, который накладывается на спектр сигнала, несущего существенную с диагностической точки зрения информацию и не могут быть устранены классическими цифровыми фильтрами. Для идентификации модели сигнала применена авторегрессивная модель. Помехи моделированы белым гауссовым шумом. Одновременная оценка состояния параметров ведёт к нелинейной проблеме. Эта проблема решена при помощи применения расширенного фильтра Кальмана и метода GP1A. Представлено сравнение нового метода с классическим усреднением и нижнепропускной фильтрацией. Метод может найти применение, например, в исследованиях физического нагрязок, ЭКГ плода, и т.д.

APPLICATION OF NONLINEAR KALMAN FILTERING FOR ECG NOISE REDUCTION

Summary

In the paper a nonlinear Kalman filter procedure is applied for a reduction of the ECG noise. Such a noise has a bandwidth which overlaps the signal carrying the information useful from the clinical stand point and can not be removed by means of classical digital filtering. An autoregressive model is used for identification of the signal model. Noise is modeled by white gaussian sequence. Combined state and parameter estimation leads to a nonlinear problem. The nonlinear problem is solved by the extended Kalman filter and generalized partitioned identification algorithm. The paper presents a comparison of the new method with classical averaging and low-pass filtering methods. For example the method may be applied in the ECG exercise, fetal ECG and others.