


Tomasz PANDER

INSTYTUT ELEKTRONIKI, POLITECHNIKA ŚLĄSKA W GLIWICACH

Modelowanie zakłóceń impulsowych w przetwarzaniu sygnałów biomedycznych**Dr inż. Tomasz PANDER**

Autor jest adiunktem w Instytucie Elektroniki Politechniki Śląskiej w Gliwicach. Od 1999 roku jest doktorem nauk technicznych. Jest członkiem PTETiS, PTiB. Zainteresowania zawodowe koncentrują się na cyfrowym przetwarzaniu sygnałów biomedycznych, miernictwie wielkości biologicznych i medycznych, sztucznej inteligencji. Jest autorem ok. 30 prac naukowych.

e-mail: Tomasz.Pander@polsl.pl**Streszczenie**

Literatura cyfrowego przetwarzania sygnałów jest zdominowana przez założenie o gaussowskim charakterze zakłóceń. Jednak w rzeczywistych warunkach zakłócenia charakteryzują się rozkładami innymi niż gaussowskie rozkładami. Często zakłócenia mają charakter impulsowy. Z uwagi na dużą liczbę sygnałów elektrofizjologicznych, do badań został wybrany sygnał EKG. Podczas przeprowadzania prób wysiłkowych zakłócenia mięśniowe wykazują charakter impulsowy. Celem pracy jest przedstawienie różnych modeli zakłóceń impulsowych stosowanych do zakłócania sygnałów biomedycznych. W pracy zostaną przedstawione następujące modele zakłóceń: Gaussa-Bernoulliego, Gaussa-Laplace'a, Gaussa-Cauchy'ego oraz model wykorzystujący symetryczne rozkłady α -stabilne. Symulowane zakłócenia są dodawane do sygnału o zadanej wartości SNR. Następnie wykorzystując filtrację liniową oraz nieliniową zostaną zmierzone zniekształcenia resztowe w sygnale po filtracji.

Słowa kluczowe: zakłócenia impulsowe, filtr miriadowy, filtr medianowy, rozkłady α -stabilne, metody odporne

Impulsive noise modeling in biomedical signal processing**Abstract**

A literature of digital signal processing is dominated by the assumption of Gaussian distribution of disturbances. But in a real world of signals such statement is too optimistic. Some noises distributions differ from the idealistic Gaussian model. Noises are often impulsive in their nature. There exists many different electrophysiological signals, but for the purpose of this work the electrocardiogram (ECG signal) was chosen. This signal is almost always disturbed by a noise. A noise that appears in ECG signals during the stress test (mainly a muscle noise) has an impulsive nature. The main aim of this work is to present different models of an impulsive noise. In this paper the following models of impulsive disturbances are introduced: a Gaussian-Bernoulli, a Gaussian-Laplace, a Gaussian-Cauchy and a symmetric α -stable model. Simulated noise is added to signal with known values of SNR. Then the linear and nonlinear filtering methods are applied and the rest distortions in a filtered signal are measured.

Keywords: impulsive noise, myriad filter, median filter, $S\alpha S$ distribution, robust methods

1. Wprowadzenie

Rozkład gaussowski odgrywa znaczącą rolę w dziedzinie cyfrowego przetwarzania sygnałów. Jest szeroko używany w modelowaniu zakłóceń. W wielu przypadkach, użycie idealnego modelu gaussowskiego jest celowe i ma swoje uzasadnienie w Centralnym Twierdzeniu Granicznym. Dodatkowo takie

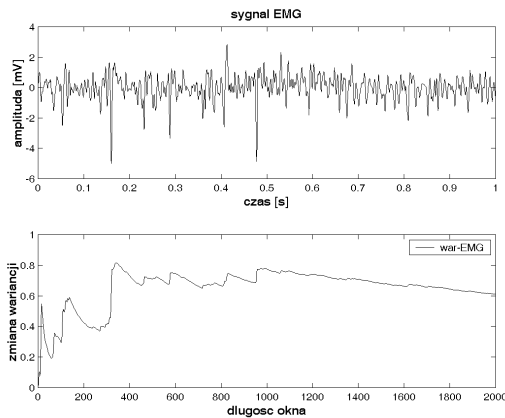
założenie często prowadzi do otrzymania rozwiązania danego problemu w postaci analitycznej. Założenie o rozkładzie gaussowskim prowadzi do estymacji metodą najmniejszych kwadratów, która jest metodą największej wiarygodności (prawdopodobieństwa) dla danych o rozkładzie gaussowskim [10].

W rzeczywistości wiele zjawisk mając charakter nie-gaussowski wykazuje charakter impulsowy. W takich sygnałach istnieje większe prawdopodobieństwo występowania próbek o wartościach amplitud próbek dużo większych niż w sygnałach o charakterystyce gaussowskiej. W rezultacie funkcja gęstości prawdopodobieństwa opada mniej gwałtownie w „ogonie” rozkładu niż funkcja gęstości prawdopodobieństwa rozkładu gaussowskiego. Inny niż gaussowski charakter sygnałów prowadzi często do znacznego pogorszenia działania systemów, które zostały zoptymalizowane przy założeniu gaussowskiej charakterystyki zakłóceń [10].

Tłumienie zakłóceń powinno być pierwszym krokiem każdego systemu przetwarzającego sygnały biomedyczne. Dokładność kolejnych etapów przetwarzania sygnału takich jak detekcja, pomiary czy klasyfikacja zależą od jakości algorytmów redukcji zakłóceń [5]. Sygnały biomedyczne są zwykle rejestrowane w obecności zakłóceń. Źródłami tych zakłóceń może być pacjent, układ pomiarowy lub środowisko elektromagnetyczne otaczające pacjenta i system pomiarowy. Własności tych zakłóceń są bardzo zróżnicowane. Począwszy od zakłóceń stałych, wolnozmiennych, przez zakłócenia sieciowe (50/60 Hz) aż do zakłóceń wysokoczęstotliwościowych. W celu tłumienia zakłóceń stosuje się odpowiednie metody cyfrowego przetwarzania sygnałów. Filtracja sygnału biomedycznego powinna być przeprowadzona w taki sposób, aby poprawić wartość stosunku sygnał-szum oraz nie wprowadzić zniekształceń sygnału. Ponieważ większość metod (systemów) cyfrowego przetwarzania sygnałów jest projektowana pod kątem obecności zakłóceń o charakterze gaussowskim, pojawienie się zakłóceń impulsowych prowadzi do znacznego pogorszenia działania takich metod. Dlatego istotne jest, aby system cyfrowego przetwarzania sygnałów był testowany także dla innych rozkładów zakłóceń.

Pomiary elektrofizjologiczne są od wielu lat wykorzystywane w diagnostyce medycznej [6]. Rejestracja sygnałów elektrofizjologicznych odbywa się jednak w obecności zakłóceń obniżających wartość stosunku sygnał-szum. Przykładem takiego sygnału jest sygnał EKG, przedstawiający odtworzone na powierzchni ciała sumaryczne napięcia pochodzące od pobudzonych komórek mięśnia sercowego. Czasowe i przestrzenne rozkłady pobudzeń na powierzchni serca są odwzorowane w otaczającym przewodzącym ośrodku jako wypadkowe pole prądów elektrycznych, które pomiędzy wybranymi punktami na powierzchni ciała, objawia się w postaci charakterystycznego przebiegu elektrokardiograficznego [6]. Sygnał EKG jest bardzo podatny na zakłócenia (np. w warunkach ambulatoryjnych lub podczas prób wysiłkowych). Zakłócenia mięśniowe, które są rejestrowane z sygnałem EKG są najtrudniejsze do tłumienia, gdyż widmo częstotliwościowe zakłóceń mięśniowych pokrywa się w szerokim zakresie częstotliwości z widmem częstotliwościowych sygnału EKG. Charakter zakłóceń mięśniowych jest bardzo często impulsowy szczególnie podczas wykonywania prób wysiłkowych. Zakłócenia mięśniowe w sygnale EKG mogą zniekształcać niski-amplitudowe składniki sygnału użytecznego i prowadzą do pogorszenia działania zautomatyzowanych systemów pomiarowych [3, 5]. Na rysunku 1 przedstawiono przykład

realizacji zakłóceń mięśniowych (rysunek górny), natomiast dolny rysunek przedstawia zmianę wariancji liczoną dla okna o zmiennej długości. Pojawiające się skoki wariancji są prostym dowodem świadczącym o charakterze impulsowym zakłóceń mięśniowych [10].



Rys. 1. Przykład realizacji zakłóceń mięśniowych (rysunek górny) i zmiany wariancji sygnału w funkcji długości okna (dolny rysunek).

Fig. 1. The example of real muscle noise (upper plot) and changes of signal's variance in the function of window length.

Celem pracy jest zbadanie możliwości stosowania innych niż gaussowski modeli zakłóceń mięśniowych. Zaproponowane modele są następujące: model Gaussa-Bernoulliego, Gaussa-Laplace'a, Gaussa-Cauchy'ego oraz model wykorzystujący rozkłady α -stabilne. Oceniana będzie jakość filtracji zakłóconego sygnału w stosunku do rzeczywistych zakłóceń mięśniowych. Filtrami referencyjnymi są filtry: ruchomej średniej, Savitzky'ego-Golaya, medianowy oraz miriadowy. Aby ocenić skuteczność doboru modelu zakłóceń oraz jakości filtracji jest wprowadzony wskaźnik zniekształceń resztowych w sygnale po filtracji w stosunku do sygnału bez zakłóceń.

2. Modele zakłóceń impulsowych

W rzeczywistym świecie istnieje wiele sygnałów i zakłóceń, które nie wykazują charakteru gaussowskiego i bardzo często mają charakter impulsowy [10, 11]. W przypadku wykonywania pomiarów elektrofizjologicznych zakłócenia impulsowe mogą powstać w skutek przełączania źródeł zasilania, podczas zmiany trybu pracy urządzeń i in.. W takich sytuacjach istnieje większe prawdopodobieństwo występowania impulsów o wartościach amplitud próbek dużo większych niż w sygnałach i zakłóceniach mających charakter gaussowski. W rezultacie funkcja gęstości prawdopodobieństwa opada mniej gwałtownie w „ogonie” rozkładu niż funkcja gęstości prawdopodobieństwa rozkładu gaussowskiego.

Niech $s(n)$ będzie sygnałem, który jest zakłócony addytywnymi zakłóceniami $v(n)$, stąd sygnał obserwowany dany jest następującą zależnością:

$$x(n) = s(n) + v(n). \quad (1)$$

Celem filtracji jest estymacja sygnału $s(n)$ na podstawie sygnału otrzymanego w wyniku filtracji, tj. $y(n) = F(x(n))$, gdzie $F(\cdot)$ jest operatorem filtru.

2.1. Model Gaussa-Bernoulliego

Składowa zakłócająca $v(n)$ z równania (1) w modelu Gaussa-Bernoulliego, który jest przedstawiona w następujący sposób:

$$x(n) = s(n) + z(n)v(n), \quad n = 1, 2, \dots \quad (2)$$

gdzie: $x(n)$ – zaobserwowany, zakłócony sygnał, $s(n)$ – sygnał deterministyczny, $z(n)$ – jest zmienną dwumianową określającą, czy sygnał $x(n)$ jest zakłócony sygnałem $v(n)$ w przypadku, gdy $z(n)=1$, a dla $z(n)=0$ sygnał $x(n)$ nie jest zakłócony sygnałem $v(n)$. Sygnał $v(n)$ jest zakłóceniem gaussowskim. Zmienna $z(n)$ jest związana funkcją gęstości prawdopodobieństwa rozkładu Bernoulliego wyrażoną w postaci:

$$p_z(z) = \begin{cases} 1 - \lambda, & z = 0, \\ \lambda, & z = 1. \end{cases} \quad (3)$$

W pracy przyjęto $\lambda = 0.2$ [5].

2.2. Model wykorzystujący symetryczne rozkłady α -stabilne ($S\alpha S$)

Innym sposobem modelowania składowej szumowej $v(n)$ jest zastosowanie symetrycznych rozkładów α -stabilnych, które są opisane funkcją charakterystyczną o następującej postaci:

$$\varphi(t) = \exp(j\mu t - \gamma|t|^\alpha) \quad (4)$$

gdzie α jest parametrem spełniającym warunek $0 < \alpha \leq 2$, μ jest parametrem odpowiadającym za przesunięcie rozkładu i $\mu \in \mathfrak{R}$ (parametr ten odpowiada wartości średniej dla $1 < \alpha \leq 2$, oraz medianie dla $0 < \alpha \leq 1$), γ jest parametrem skali lub dyspersją (zachowuje się w analogiczny sposób jak wariancja rozkładu gaussowskiego, jest miarą rozrzutu wokół wartości średniej). Parametr α opisuje impulsowość procesu losowego. Gdy α jest małe, wówczas ogon rozkładu funkcji gęstości prawdopodobieństwa jest „ciężki”, co świadczy o dużej impulsowości. Gdy $\alpha \rightarrow 2$, to rozkład zmiennej losowej zbliża się do rozkładu normalnego. Znaczną niedogodnością rozkładów α -stabilnych jest brak analitycznej postaci funkcji gęstości prawdopodobieństwa dla konkretnej wartości α , choć istnieją przypadki szczególne. Dla $\alpha=1$ otrzymuje się funkcję gęstości prawdopodobieństwa rozkładu Cauchy'ego, a dla $\alpha=2$ rozkładu gaussowskiego. Algorytm generowania zakłóceń o rozkładzie α -stabilnym jest przedstawiony w [12]. Więcej informacji na temat rozkładów α -stabilnych można znaleźć w [10, 11].

Jak zostało pokazane w pracy [8] dla rzeczywistych zakłóceń mięśniowych $\alpha \in (1.7, 1.8)$. W pracy przyjęto, że $\alpha = 1.8$.

2.3. Model wykorzystujący rozkłady Gaussa-Laplace'a

Niech składowa zakłócająca $v(n)$ będzie opisana rozkładem prawdopodobieństwa należącym do rodziny rozkładów P_ε ε -skazonych rozkładów normalnych danych następującym wzorem [4]:

$$P_\varepsilon = \{(1 - \varepsilon)\Phi + \varepsilon H : H \in S\} \quad (5)$$

gdzie: Φ jest rozkładem normalnym, S jest zbiorem wszystkich rozkładów prawdopodobieństwa spełniających warunek

$$H(-x) = 1 - H(x) \quad (6)$$

oraz $\varepsilon \in [0, 1]$ nazwane frakcją „skażenia”. Obecność próbek o wartościach amplitud bardzo dużych (impulsowych) jest modelowana za pomocą rozkładu prawdopodobieństwa H charakteryzującego się tzw. „ciężkim” ogonem rozkładu. W pracy przyjęto, że rozkład H jest rozkładem Laplace'a $L(0, \sigma_L^2)$ o wariancji σ_L^2 . Dzięki temu zmienna losowa $v(n)$ charakteryzuje się rozkładem, który ma charakter gaussowski

w centrum i tzw. ciężkim ogonem na obrzeżach rozkładu. W pracy przyjęto następujące wartości $\sigma_L^2 = 4$ oraz $\varepsilon = 0.4$ [1].

2.4. Model wykorzystujący rozkład Gaussa-Cauchy'ego

Niech zmienna zakłócająca $v(n)$ z równania (1) będzie zmienną losową, która będzie opisana rozkładem opisany równaniem (5), w którym Φ jest rozkładem normalnym natomiast rozkład H jest rozkładem Cauchy'ego. Do wygenerowania zmiennej losowej o rozkładzie Cauchy'ego zostanie wykorzystany rozkład α -stabilny dla przypadku $\alpha = 1$. W pracy przyjęto wartość $\varepsilon = 0.05$.

3. Filtracja zakłóceń

Głównym zadaniem filtru cyfrowego jest poprawa jakości filtrowanego sygnału. Wygładzanie, a także zachowanie kształtu sygnału w sytuacji, w której pojawiają się zakłócenia impulsowe sprawia, że alternatywą dla filtracji liniowej są tzw. metody „odporne” (ang. robust). Metody te są reprezentowane przez grupę filtrów należących do klasy tzw. M-filtrów, tj. estymatorów największej wiarygodności parametru położenia. Przykładami takich filtrów są filtry medianowe oraz miriadowe.

Rozważając zbiór próbek sygnału $\{x_i\}_{i=1}^N$ w ruchomym oknie o długości N , estymator największej wiarygodności parametru położenia wyrażony jest następującym wzorem [2]:

$$\hat{\beta} \triangleq \arg \min_{\beta} \sum_{i=1}^N \rho(x_i - \beta) \quad (7)$$

gdzie $\rho(\cdot)$ jest nazywana funkcją kosztu, β parametr położenia, N długość filtru. Używając funkcji gęstości prawdopodobieństwa rozkładu gaussowskiego, Laplace'a oraz Cauchy'ego otrzymuje się funkcje kosztu dla:

- wartości średniej w postaci funkcji kwadratowej: $\rho(x) = x^2$,
- mediany w postaci wartości bezwzględnej: $\rho(x) = |x|$,
- prostej miriady wyrażonej następująco $\rho(x) = \log(K^2 + x^2)$, gdzie K jest parametrem liniowości, kontrolującym odporność na zakłócenia impulsowe [2].

Własności filtru miriadowego zależą od wartości parametru K . Dla małych wartości K wartość wyjściowa filtru jest w przybliżeniu taka jak najbardziej liczne skupisko próbek sygnału wyjściowego. Gdy K dąży do nieskończoności i $\alpha = 2$, wyjście filtru miriadowego zachowuje się jak wyjście filtru ruchomej średniej. W pracy przyjęto $K = 1$. Więcej informacji o filtrach miriadowych można znaleźć w [2].

Równania filtrów są następujące:

- filtr ruchomej średniej:

$$x_{\text{ave}}(n) = \arg \min_{\beta} \sum_{i=n-k}^{n+k} (x(n+i) - \beta)^2 = \sum_{i=1}^N x_i / N \quad (8)$$

- filtr medianowy:

$$x_{\text{med}}(n) = \arg \min_{\beta} \sum_{i=n-k}^{n+k} |x(n+i) - \beta| = \text{mediana}(x_1, x_2, \dots, x_N) \quad (9)$$

- filtr miriadowy:

$$x_{\text{myr}}(n) = \arg \min_{\beta} \sum_{i=1}^N \log[K^2 + (x_i - \beta)^2] = \text{miriada}(x_1, x_2, \dots, x_N, K) \quad (10)$$

Ostatnim użytym filtrem jest wygładzający filtr wielomianowy Savitzky'ego-Golaya stopnia III [9].


4. Eksperyment numeryczny i wyniki

Warunkiem poprawnego działania filtru w zastosowaniach biomedycznych jest nie wprowadzanie zniekształceń do przefiltrowanego sygnału. Warunek ten jest prosty do spełnienia dla filtrów liniowych (warunek liniowości fazy), ale może być trudny do uzyskania w klasie filtrów nieliniowych, do której należą filtry miriadowe i medianowe. W celu ułatwienia oceny jakości sygnału po filtracji wprowadzono wskaźnik *NMSE* (ang. Normalized Mean Square Error) będący miarą zniekształceń resztowych w sygnale po filtracji zdefiniowany jako:

$$NMSE = \left(\frac{\sum_{i=1}^L [y(i) - s(i)]^2}{\sum_{i=1}^L [s(i)]^2} \right) \cdot 100\% \quad (11)$$

gdzie: $y(i)$ – sygnał po filtracji, $s(i)$ – sygnał deterministyczny, niezakłócony, L – długość sygnału.

Do badań porównawczych zostało losowo wybranych 5 różnych okresów sygnału EKG ($f_p = 2$ kHz), a następnie zamodelowanych w sposób przedstawiony w [7]. Przykładowy okres sygnału przedstawiono na rysunku 2 (2000 próbek).



Rys. 2. Przykład okresu sygnału EKG zakłóconego rzeczywistymi zakłóceniami mięśniowymi (linia ciągła – sygnał zakłócony, linia przerywana – sygnał EKG bez zakłóceń).

Fig. 2. The example of noisy ECG cycle disturbed with real muscle noise (solid line – noisy signal, dotted line – the ECG signal without noise).

Kolejnym krokiem jest dodanie zakłóceń do sygnału deterministycznego dla następujących wartości SNR: -5 dB, 0 dB, 5 dB, 10 dB, 20 dB. Dla każdego poziomu SNR wartość wskaźnika *NMSE* była obliczana 200 razy, dzięki czemu uzyskano różne realizacje zakłóceń. Następnie obliczono wartość średnią *NMSE*, którą umieszczono w tabelach. Wszystkie obliczenia przeprowadzono dla stałej długości okna filtru wynoszącej $N = 31$. Rzeczywisty sygnał EMG został zarejestrowany z przedramienia ($f_p = 2$ kHz). Dodatkowo przeprowadzono badania, w których zakłócenia są modelowane rozkładem gaussowskim.

Wyniki badań modeli zakłóceń mięśniowych są przedstawione w tabelach 1, 2, 3 i 4. Rozkłady α -stabilne oznaczone są w tabelach jako $S\alpha S$.

5. Dyskusja i wnioski

W pracy przebadano różne modele zakłóceń mięśniowych. Modele te wykorzystują mieszane rozkłady prawdopodobieństwa, począwszy od połączenia rozkładu Gaussa-Bernoulliego, Gaussa-Laplace'a, Gaussa-Cauchy'ego oraz rozkładów α -stabilnych.

Filtracja rzeczywistych zakłóceń mięśniowych w zakresie niskich wartości SNR (-5 dB, 0 dB) prowadzi do uzyskania bardzo zbliżonych wartości współczynnika *NMSE* przez wszystkie filtry. Również dla wartości SNR ≥ 5 dB, uzyskane wyniki filtracji są zbliżone.

Wyniki filtracji uzyskane dla szumu gaussowskiego prowadzą do uzyskania mniejszych wartości wskaźnika *NMSE* niż dla rzeczywistych zakłóceń mięśniowych. Oznacza to, że wartość resztowa zniekształceń w sygnale po filtracji jest mniejsza niż w przypadku rzeczywistych zakłóceń mięśniowych.

Tab. 1. Wartości *NMSE*[%] dla filtru miriadowego.
Tab. 1. *NMSE*[%] values obtained for myriad filter.

SNR [dB]	EMG	Gauss	$S\alpha S$, $\alpha=1.8$	Gauss-Bernoulli, $\lambda=0.2$	Gauss-Laplace, $\varepsilon=0.4$, $\sigma^2=4$	Gauss-Cauchy, $\varepsilon=0.05$
-5	32,9085	7,9331	5,5891	7,5707	7,4814	3,2519
0	11,0860	2,7929	2,1780	2,7172	2,8734	1,6032
5	3,4311	1,1922	1,0889	1,1836	1,2207	0,9110
10	1,3506	0,6916	0,6819	0,7085	0,7094	0,7128
20	0,5758	0,5169	0,4913	0,5225	0,5114	0,5259

Tab. 2. Wartości *NMSE*[%] dla filtru medianowego.
Tab. 2. *NMSE*[%] values obtained for median filter.

SNR [dB]	EMG	Gauss	$S\alpha S$, $\alpha=1.8$	Gauss-Bernoulli, $\lambda=0.2$	Gauss-Laplace, $\varepsilon=0.4$, $\sigma^2=4$	Gauss-Cauchy, $\varepsilon=0.05$
-5	40,478	11,913	6,3636	9,3954	6,8206	3,8614
0	13,529	4,0935	2,1794	3,2165	2,5905	1,5106
5	4,1624	1,5302	0,8892	1,2226	0,9958	0,6162
10	1,4804	0,622	0,3898	0,5294	0,4493	0,3163
20	0,2855	0,1801	0,1462	0,1746	0,1688	0,1356

Tab. 3. Wartości *NMSE*[%] dla filtru ruchomej średniej.
Tab. 3. *NMSE*[%] values obtained for moving average filter.

SNR [dB]	EMG	Gauss	$S\alpha S$, $\alpha=1.8$	Gauss-Bernoulli, $\lambda=0.2$	Gauss-Laplace, $\varepsilon=0.4$, $\sigma^2=4$	Gauss-Cauchy, $\varepsilon=0.05$
-5	30,4013	7,8619	7,6613	7,6734	7,7533	7,8405
0	10,3768	3,1139	3,0274	3,0638	3,2129	3,0585
5	3,3430	1,6090	1,6121	1,6322	1,6761	1,6486
10	1,4574	1,1400	1,2077	1,2043	1,2106	1,2314
20	0,7730	1,0464	0,973	1,0240	1,0239	1,0162

Tab. 4. Wartości *NMSE*[%] dla filtru Savitzky'ego-Golaya.
Tab. 4. *NMSE*[%] values obtained for Savitzky-Golay filter.

SNR [dB]	EMG	Gauss	$S\alpha S$, $\alpha=1.8$	Gauss-Bernoulli, $\lambda=0.2$	Gauss-Laplace, $\varepsilon=0.4$, $\sigma^2=4$	Gauss-Cauchy, $\varepsilon=0.05$
-5	37,8866	8,6976	8,4394	8,5238	8,5077	8,5863
0	12,4492	2,7802	2,7142	2,7554	2,9583	2,7862
5	3,6208	0,9880	0,9860	0,9513	1,0094	0,9712
10	1,2263	0,4026	0,3942	0,4113	0,4073	0,4430
20	0,2684	0,1749	0,1625	0,1752	0,172	0,1773

Dla zakłóceń modelowanych rozkładami α -stabilnymi uzyskano podobne wyniki jak dla rozkładu gaussowskiego, ale dla niskich wartości SNR (-5 dB, 0 dB) zastosowanie filtracji nieliniowej (filtr miriadowy i medianowy) prowadzi do uzyskania

mniejszych wartości współczynnika *NMSE* niż w przypadku filtracji liniowej (filtr ruchomej średniej i Savitzky'ego-Golaya). Podobne rezultaty uzyskano dla zakłóceń modelowanych połączeniem rozkładów Gaussa i Cauchy'ego.

Wyniki uzyskane dla połączonych rozkładów Bernoulliego-Gaussa oraz Gaussa-Laplace'a są podobne dla wszystkich rodzajów filtracji.

Porównując natomiast odmiany filtracji, to w przypadku zakłóceń modelowanych rozkładami α -stabilnymi oraz zakłóceń modelowanych mieszanymi rozkładami Gaussa-Cauchy'ego, do mniejszych błędów prowadzi zastosowanie filtrów nieliniowych (filtr medianowy i miriadowy). Natomiast w przypadku filtrów liniowych lepsze rezultaty filtracji można osiągnąć stosując filtr Savitzky'ego-Golaya.

Model Bernoulliego-Gaussa jednak jest zbyt idealny, dlatego że w rzeczywistych, obserwowanych przypadkach impulsy rzadko składają się z pojedynczych próbek. Sygnał najczęściej jest zakłócony szumem ciągłym, który w pewnych momentach może wybuchać (ma bardzo impulsowy charakter), natomiast w innych momentach ma małą, lecz niezerową amplitudę.

Model Gaussa-Cauchy'ego wykazuje zbyt duży poziom impulsowości (dobre działania filtru medianowego), natomiast model Gaussa-Laplace'a ma zbliżone wyniki do wyników otrzymanych dla rozkładów α -stabilnych. Najbardziej przydatnym rozkładem jest rodzina rozkładów α -stabilnych, dzięki możliwości kontrolowania poziomu impulsowości przez zmianę wartości parametru α .

Złożoność rzeczywistych zakłóceń mięśniowych powoduje, że bardzo trudno dobrać model dla tego zakłócenia sygnałów biomedycznych. Z przeprowadzonych w pracy badań wynika, że rodzina rozkładów α -stabilnych może spełniać rolę takiego modelu.

6. Literatura

- [1] Aysal T.C.; Barner K.E., Robust frequency-selective filtering using weighted sum-median filters, in Proceedings of the 40th Annual Conference on Information Sciences and Systems (CISS2006), (Princeton, NJ), Mar. 2006.
- [2] Gonzalez J.G., Arce G.R.: Optimality of the myriad filter in practical impulsive-noise environments, IEEE Trans. on Signal Processing, vol. 49, nr 2, February 2001, str. 438-441.
- [3] Hu X., Nenov V.: A single-lead ECG enhancement algorithm using a regularized data-driven filter, IEEE Transactions on Biomedical Engineering, vol. 53, nr 2, str.347-351, 2006.
- [4] Huber P.: Robust Statistics, John Wiley & Sons, Inc., 1981.
- [5] Łęski J.: Robust Weighted Averaging, IEEE Transactions on Biomedical Engineering, vol. 49, No. 8, str. 796-804, 2002.
- [6] Nałęcz M., Biopomiary, Biocybetyka i Inżynieria Biomedyczna 2000, Warszawa, Akademicka Oficyna Wydawnicza Exit 2001.
- [7] Pander T.: Użycie algorytmu genetycznego do modelowania okresów sygnału EKG metodą przesuwanych w dziedzinie czasu „paczek” funkcji Hermite'a, XI Konferencja Naukowa „Biocybetyka i Inżynieria Biomedyczna, Warszawa, 1999 r., str. 812-816.
- [8] Pander T.: An application of a weighted myriad filter to suppression an impulsive type of noise in biomedical signals, TASK Quarterly, 2004, str. 199-216.
- [9] Savitzky A., Golay M. J. E.: Smoothing and Differentiation of Data by Simplified Least Squares Procedures, Analytical Chemistry, vol. 36, 1964, str. 1627-1639.
- [10] Shao M., Nikias Ch.L.: Signal processing with fractional lower order moments: stable processes and their applications, Proceedings of IEEE, 1993, vol. 81, str. 986-1009.
- [11] Tshirintzis G.A., Shao M., Nikias Ch.L.: Recent results in applications and processing of α -stable-distributed time series, J.Franklin Inst., Vol. 333(B), nr 4, str. 467-497, 1996.
- [12] Wiczorkowski R., Zieliński R.: Komputerowe generatory liczb losowych, WNT, Warszawa 1997.