

Ireneusz BEMKE

POLITECHNIKA GDAŃSKA, WYDZIAŁ ELEKTRONIKI TELEKOMUNIKACJI I INFORMATYKI

Zastosowanie post-segmentacji do poprawy efektywności cech fazowych w detekcji zbita szyby z użyciem transformacji falkowej**mgr inż. Ireneusz BEMKE**

Doktorant Wydziału Elektroniki Telekomunikacji i Informatyki Politechniki Gdańskiej. Równolegle pracuje zawodowo w przemyśle elektronicznym na stanowisku konstruktor-programista. Specjalność naukowa: systemy kontroli, nadzoru i sterowania procesów przemysłowych.



e-mail: bemke@mercury.perfect.net.pl

Streszczenie

Przedmiotem badań prowadzonych przez autora są bezkontaktowe metody detekcji zbita szyby bazujące na analizie sygnałów akustycznych towarzyszących temu procesowi. Zagadnienie to ma zasadnicze znaczenie dla nowoczesnych systemów alarmowych, szczególnie w przypadkach dużych obiektów, gdzie indywidualne nadzorowanie każdej szyby byłoby nieekonomiczne. W toku badań opracowano metodę, bazującą na transformacji falkowej i identyfikacji wybranych cech sygnału, dającą efektywność detekcji >90%, a odporność na sygnały fałszywe >80%. W artykule przedstawiono metodę w wersji umożliwiającej jej implementację w systemie przetwarzającym dane on-line, koncentrując się na modyfikacji poprawiającej dystynktywność cech fazowych sygnałów. W części końcowej zaprezentowano uzyskane wyniki i porównano je do rezultatów przedstawionych w pracach [1] i [2].

Słowa kluczowe: systemy alarmowe, algorytm, transformacja falkowa

The use of post-segmentation for improvement of efficiency of phase features in glass breaks detection based on wavelet transformation

Abstract

The subject of research being made by author is a non-contact method of glass break detection, based on analysis of acoustic signals of the phenomena. Presented problem is very important for modern alarm systems, especially mounted in buildings with big amount of panes, where assembling of individual sensor for each pane is very expensive. In the progress of research author has developed the method of breaks detection based on Wavelet Transformation and identification of amplitude and phase features of the acoustic signal. Developed method achieves over 90% of detectability, and >80% of resistance for false signals. In the paper method adapted for embedded system with on-line processing is presented. Author focused on modifications which improves the identification of phase features of the signals. The last part of the article presents achieved results (detectability and resistance to false signals) in comparison to results of the method presented in [1] and [2].

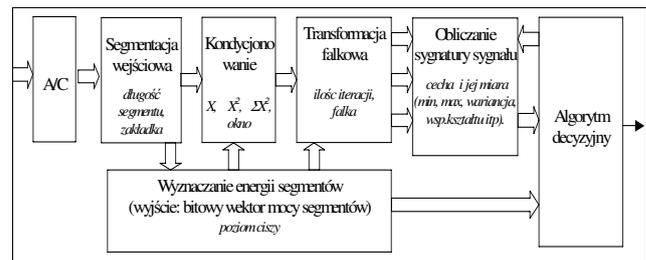
Keywords: alarm systems, algorithm, wavelet transformation

1. Wstęp

Podstawowymi problemami przy detekcji zbita szyby są: silnie stochastyczny charakter zjawiska oraz duża liczba nieokreślonych parametrów (odległość od nadzorowanego obiektu do detektora, wymiary szyby, sposób jej zamocowania, właściwości akustyczne pomieszczenia, natężenie i rodzaj sygnałów zakłócających itp.). Dlatego też najprostsze metody,

bazujące na progowej detekcji jednej lub kilku częstotliwości, mają zwykle albo niską efektywność detekcji albo generują wiele fałszywych alarmów. Parametry te są ściśle określone przez międzynarodowe normy, dla przykładu niemiecka norma VdS wymaga ponad 90% wykrywalności zbita i 100% odporności na sygnały fałszywe (definiowane przez tę normę) [3]. Istotną częścią tej normy jest ścisła definicja zbita szyby, określająca rodzaj i wymiary uszkodzenia szkła. Wymaganiom tym w zasadzie są w stanie sprostać tylko rozwiązania, które wykorzystują zaawansowane metody analizy czasowo-częstotliwościowej w kilku pasmach częstotliwości, w tym znane autorowi rozwiązanie oparte na analizie Hilberta [4].

Autor zaproponował inne podejście bazujące na JTFA (Join Time-Frequency Analysis), wykorzystujące transformatę falkową [5], [6] oraz analizę złożonych miar amplitudowych i fazowych sygnału [1]. Metoda ta pozwala uzyskać jednoczesny podział na kilka pasm częstotliwości i przetwarzanie sygnału wejściowego w dziedzinę czasowo-częstotliwościową, przy znacznej redukcji mocy obliczeniowej w porównaniu z krótkookresową szybką transformacją Fouriera [5], [6]. Jej schemat blokowy w wersji z przetwarzaniem w czasie rzeczywistym przedstawia rys. 1.



Rys. 1. Schemat blokowy algorytmu z przetwarzaniem on-line
Fig. 1. Block diagram of the on-line processing algorithm

Przeprowadzone przez autora analizy dowiodły skuteczności tej metody. Uzyskana efektywność detekcji dla identyfikacji pojedynczych cech przekracza wartość 60%, przy odporności na sygnały fałszywe rzędu 40-50%. Badania [2], [4] wykazały, iż dla prawidłowej i pewnej klasyfikacji sygnału niezbędna jest znajomość wartości przynajmniej kilku cech sygnału [4], czyli złożonej sygnatury sygnału. Ich wartości i moment występowania charakterystyczne są dla sygnałów prawdziwych (szyba zbita), jak też fałszywych (nie nastąpiło zbitie, ale pęknięcie lub tylko uderzenie), co pozwala odróżnić je od siebie. Dla przykładu cechy dystynktywne zależne od amplitudy to: wartość chwilowa części rzeczywistej, wartość chwilowa części urojonej oraz wartość chwilowa obwiedni sygnału, a cechy niezależne od amplitudy to faza chwilowa sygnału, częstotliwość chwilowa sygnału oraz współczynnik Q [1]. Grupa cech niezależnych od amplitudy jest bardzo istotna ze względu na ich niezmienność (lub niewielką zmienność) w funkcji odległości detektora od badanego obiektu. Niemniej ważne od samych cech są ich miary [2], w badaniach stosowano między innymi analizę wariancji i wartości skutecznej.

Wynikową łączną skuteczność detekcji kilku cech oszacowano na 90%, a odporność na sygnały fałszywe na 80%. Przy czym, zbiór decyzji prawidłowych określono jako sumę zbiorów sygnałów prawdziwych identyfikowanych prawidłowo przez poszczególne parametry, a zbiór decyzji odpornych jako dopełnienie iloczynu zbiorów sygnałów fałszywych klasyfikowanych przez dany parametr jako prawdziwe do zbioru wszystkich sygnałów fałszywych (1).

$$P = \bigcup_{i=1}^N P_i \quad O = F - \bigcap_{i=1}^N F_i \quad (1)$$

gdzie: P zbiór decyzji poprawnych, O zbiór decyzji odpornych, F zbiór wszystkich sygnałów fałszywych, a P_i i F_i zbiory decyzji poprawnych i błędnych dla poszczególnych cech.

2. Metodyka badań

2.1. Podstawowy algorytm on-line

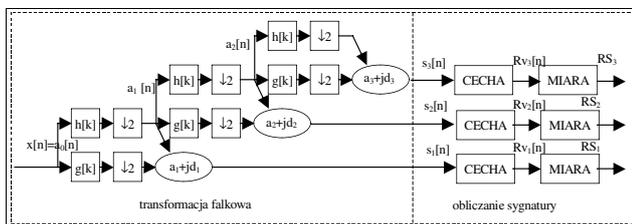
Zgodnie z algorytmem przedstawionym na rysunku 1 sygnał dzielony jest na segmenty o zadanej długości (64-512 próbek), przy zakładce umożliwiającej zachowanie w całości istotnych cech sygnału. Obliczając energię skumulowaną segmentów ocenia się czy jest to przedział ciszy, czy sygnał użyteczny [3]. Stosując takie podejście uzyskuje się ponad 50% redukcję niezbędnej mocy obliczeniowej, gdyż sygnały badane mają duże fragmenty o stosunkowo niewielkiej energii, a w warunkach rzeczywistych sygnał docierający do detektora to głównie cisza (szum, którego nie ma potrzeby analizować szczegółowo [7]). Segmenty niezerowe są kondycjonowane i okienkowane tworząc wektory danych $v[n]$ dla przetwarzania falkowego (2) za pomocą wybranej falki (filtru falkowego)

$$\begin{aligned} a_{j+1}[n] &= \downarrow_2 [a_j[n] * h[k]] = \sum a_j[2n-k] \cdot h[k] \\ d_{j+1}[n] &= \downarrow_2 [a_j[n] * g[k]] = \sum a_j[2n-k] \cdot g[k] \end{aligned} \quad (2)$$

przy czym $a_0[n] = v[n]$; $a_{j+1}[n]$ i $d_{j+1}[n]$ to detale i aproksymacje, natomiast $h[k]$ i $g[k]$ to jądra filtrów dolno i górno przepustowego odpowiednio. Zespolony sygnał analityczny $s[n]$, stanowiący podstawę do obliczania wartości wybranych cech sygnału tworzony jest zgodnie z formułą (3) dla każdej iteracji z osobna

$$s[n] = a_j[n] + id_j[n] \quad (3)$$

Zasadniczym etapem w procesie identyfikacji jest wyznaczenie sygnatury czasowej sygnału. Na jej podstawie algorytm decyzyjny klasyfikuje badany przebieg. Rysunek 2 przedstawia szczegółowo proces przetwarzania falkowego i obliczania sygnatury. Najpierw zespolony sygnał $s[n]$ przekształca się na wektor liczb rzeczywistych $Rv[n]$, przy czym odwzorowanie określone jest przez definicję wybranej cechy. Następnie liczona jest miara statystyczna RS z wektora $Rv[n]$ (np. wariancja). Miara ta za pomocą pojedynczej liczby rzeczywistej określa charakter wybranej cechy segmentu. Wartości miary, odpowiadające następującym po sobie segmentom, stanowią czasową sygnaturę sygnału, a zbiór sygnatur na kolejnych poziomach aproksymacji tworzy sygnaturę wielowymiarową.



Rys. 2. Struktura głównej części algorytmu przetwarzania
Fig. 2. Structure of the main part of the algorithm

W praktycznym rozwiązaniu stosowano sześć poziomów aproksymacji, co znacząco zwiększyło rozdzielczość w dziedzinie częstotliwości i wydobywanie cech dystynktywnych w dolnej części widma.

Tab. 1. Efektywność detekcji dla wybranych cech w metodach on-line i post-proces
Tab. 1. Detectability of selected features for on-line and post-process methods

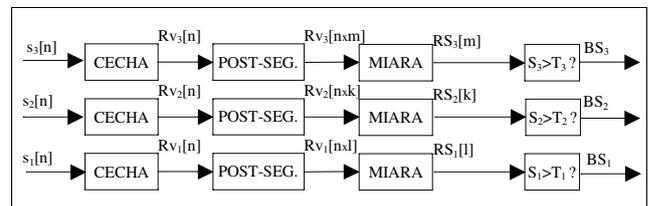
Cecha	post-process	on-line wersja I
Cześć urojona	<20%	>40%
Cześć rzeczywista	<20%	>40%
Obwiednia	<30%	>60%
Faza chwilowa	>70%	<10%
Współczynnik Q	>30%	<10%

Przedstawiony algorytm dokonuje znaczącej redukcji ilości danych. Dla przykładu: przy długości segmentu równej 256 próbek i sześciu poziomach aproksymacji falkowej otrzymuje się na wyjściu 6 liczb rzeczywistych, czyli kompresja wynosi 6/256 (około 42 razy). Proces ten jednak ogranicza rozdzielczość czasową sygnatur i pogarsza znacznie identyfikację cech o krótkich czasach trwania (głównie fazowych). Mimo to, jak pokazuje tabela 1, daje on dobre wyniki dla cech amplitudowych, których czasy trwania zbliżone są do długości segmentów.

2.2. Modyfikowany algorytm on-line

Niemal oczywistym sposobem poprawy zdolności detekcyjnej krótkookresowych cech sygnałów jest zwiększenie rozdzielczości czasowej sygnatur. Ze względu na właściwości transformacji falkowej [5], [6] i identyfikowanych cech sygnałów [2], nie jest możliwa realizacja tego zadania poprzez redukcję długości segmentów wejściowych. Autor zastosował podział pierwotnego segmentu na mniejsze odcinki (4-32 próbki), ale dopiero po operacji przetwarzania falkowego. Proces ten przedstawiono na rysunku 3 i nazwano post-segmentacją. Post-segmentacja pozwala zastąpić pojedynczą wartość miary segmentu wektorem wartości i uzyskać nawet 8-krotny (zależnie od długości segmentów) wzrost rozdzielczości czasowej na niskich poziomach aproksymacji falkowej. Ze względu na własności transformacji falkowej rozdzielczość maleje w kolejnych iteracjach [5], [6].

Negatywnym skutkiem post-segmentacji jest pogorszenie stopnia kompresji danych, oraz zróżnicowanie długości sygnatur na poszczególnych poziomach, co na rysunku 3 zaznaczono jako macierze sygnatur o elementach $n \times m$, $n \times k$, i $n \times l$ (na różnych poziomach aproksymacji falkowej, ale w obrębie pojedynczego segmentu). Może to prowadzić do nadmiernego skomplikowania algorytmu decyzyjnego i rozbudowy sygnatur wzorcowych.



Rys. 3. Zmodyfikowana struktura bloku obliczania sygnatur
Fig. 3. Modified structure of the signature calculation block

Rozwiązaniem problemu jest dalsza redukcja ilości danych poprzez uproszczenie sygnatury. Niezbędne jest jednak wybranie takiej metody, która pozwala zachować rozdzielczość czasową analizy. W tym celu można stosować redukcję długości słowa (np. do 2 bitów) lub nieliniową kwantyzację, która w rezultacie da dobry punkt wyjścia do zastosowania algorytmów decyzyjnych działających na logice rozmytej.

W przedstawionym rozwiązaniu zastosowano kwantyzację binarną sygnatury czasowej dla zadanego progu (rys. 3, dane wyjściowe oznaczono jako BS). Testy wykazały, że przy odpowiednio dobranym progu jest ona wystarczająca do prawidłowej identyfikacji cechy, a jej główną zaletą, w porównaniu z innymi, jest kompresja danych w stosunku 1:16 (słowo 16-bitowe zamieniane jest na pojedynczy bit), co łącznie z etapem obliczania sygnatury rzeczywistej kształtuje na poziomie 1:128 (1:16 x 32:256)

2.3. Metody klasyfikacji sygnałów

Klasyfikacja sygnału następuje w ostatnim bloku algorytmu przedstawionego na rys. 1. Podjęcie decyzji na podstawie wygenerowanej sygnatury nie jest zadaniem prostym i w omawianym rozwiązaniu wymaga jeszcze dopracowania.

W przedstawionych badaniach zastosowano metodę z detekcją pików, która zalicza wszystkie sygnatury niezerowe do klasy sygnałów prawdziwych (nastąpiło zbieżenie). Metoda ta pozwala

wykryć wąskie szpilki dużych wartości sygnatury rzeczywistej. Daje to pogląd na fakt czy jej wartość w ogóle przekracza przyjęty próg i ma zasadnicze znaczenie dla detekcji bardzo krótkich cech fazowych. Nie pozwala jednak ocenić jak szeroki jest przedział wartości niezerowych sygnatury. Podstawową zaletą tej metody jest prostota i szybkość działania.

Druga z opracowanych metod, to metoda wagowa. Pozwala ona określić jaka część sygnatury binarnej jest niezerowa, jednak jej wadą jest możliwość błędnej klasyfikacji sygnałów posiadających sygnaturę grzebieniową (0101...01), która może być wynikiem błędów obliczeniowych na krańcach segmentów. Metoda ta jest obecnie używana przez autora do oceny szerokości niezerowych przedziałów sygnatur, co stanowi podstawowy parametr wejściowy dla trzeciej opracowanej metody - złożonej metody korelacyjnej. Ta metoda łączy w sobie cechy obydwu wcześniejszych i polega ona na obliczaniu korelacji sygnatury sygnału z sygnaturą wzorcową, dając miarę podobieństwa z opracowanym wzorcem. Niestety jej zastosowanie będzie możliwe dopiero po opracowaniu wyników obecnie prowadzonych badań.

2.4. Agregaty i metody ich oceny

Dla uproszczenia określeniem „agregat” nazwano następujący zbiór parametrów algorytmu detekcji: długość segmentu, rodzaj okna, rodzaj falki, cecha i jej miara oraz długość post-segmentu.

Prowadzone badania miały na celu: sprawdzenie zdolności post-segmentacji do poprawy efektywności detekcji przez cechy o krótkich czasach trwania, określenie efektywności detekcji różnych agregatów, identyfikację agregatów dających najlepsze wyniki oraz określenie przedziałów niepewności (zakresów zmienności) progów, dla których efektywność detekcji oraz odporność na sygnały fałszywe jest w przybliżeniu stała i możliwie duża – to znaczy: algorytm osiąga najlepsze wyniki.

Aby zautomatyzować proces porównywania agregatów niezbędne jest określenie wartości ich normy. W badaniach zastosowano normę agregatu zdefiniowaną formułą (4)

$$H = \left| \frac{P_p}{L_p} - \frac{B_f}{L_f} \right| \cdot 100\% \quad (4)$$

gdzie: P_p liczba poprawnie zaklasyfikowanych sygnałów prawdziwych, B_f liczba błędnie zaklasyfikowanych sygnałów fałszywych, L_p i L_f liczby wszystkich sygnałów prawdziwych i fałszywych. Tak określona norma pozwala pokazać za pomocą pojedynczej wartości odsetek prawidłowych decyzji i odporność na sygnały fałszywe danego agregatu przy założonym progu kwantyzacji sygnatury binarnej.

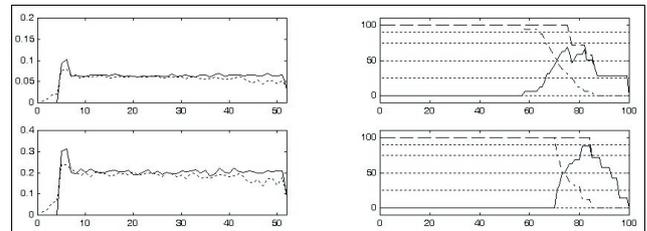
W celu zobrazowania wpływu wartości progów na efektywność detekcji poszczególnych agregatów i określenia przedziałów progów, dla których wartości normy są możliwe duże, należało przyjąć zakresy zmienności progów. W toku badań obliczane najpierw były macierze sygnatur dla wszystkich badanych sygnałów. Na tej podstawie określano maksima i minima ich wartości dla poszczególnych poziomów aproksymacji w zbiorze wszystkich sygnałów. W tak określonych przedziałach wyznaczano po 100 wartości pośrednich, które podstawiano jako wartości progów kwantyzacji binarnej w algorytmie z rys. 3.

Przyjęto, że agregat zostanie zakwalifikowany jako efektywny jeżeli wartość jego normy wyniesie ponad 50% w zakresie zmienności progów o szerokości co najmniej 10%. Pozwala to wyeliminować te agregaty, których normy mają duże wartości ale w bardzo wąskim przedziale.

3. Uzyskane wyniki

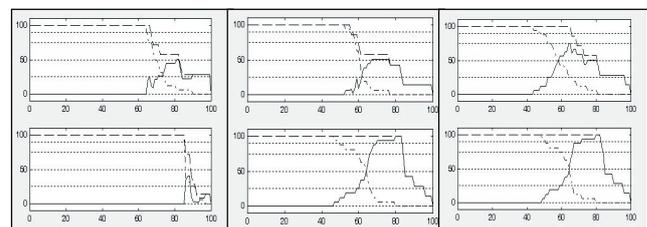
Rysunek 4 przedstawia przykładowy przebieg wartości parametrów agregatu „średnia z wartości bezwzględnej fazy chwilowej dla falki bior1.5” przy przetwarzaniu bez post-segmentacji. Z lewej strony rysunku widoczne są uśrednione

wartości sygnatury rzeczywistej na 2 pierwszych poziomach aproksymacji falkowej dla sygnałów prawdziwych (linia ciągła) i fałszywych (kropkowana). Z prawej strony widoczna jest wartość normy agregatu (linia ciągła) oraz odsetek decyzji prawidłowych dla sygnałów prawdziwych (linia kreskowa) i błędnych decyzji dla sygnałów fałszywych (kropka-kreska) w funkcji wartości progów. Jak widać na obu poziomach w miarę wzrostu wartości progów maleje liczba błędnych decyzji, przez co wartość normy rośnie by osiągnąć maksimum (dla poziomu pierwszego około 60%, a dla drugiego ponad 80%) w przedziale 70-85% zakresu zmienności progów.



Rys. 4. Przykładowy przebieg wartości parametrów agregatu bez post-segmentacji
Fig. 4. The example plots of aggregate performance without post-segmentation

Na rysunku 5 przedstawiono natomiast zależność wartości normy tego samego agregatu w funkcji długości post-segmentu. Jak widać dla 8 próbek w post-segmencie (lewe skrajne wykresy) wartość normy uległa znacznemu pogorszeniu w stosunku do przetwarzania bez post-segmentacji. Przy 16 próbkach natomiast zaobserwować można znaczący wzrost jej wartości (do około 95%) dla poziomu 2 (środkowy dolny), a w szczycie 100% (wszystkie decyzje poprawne). Podobnie dla długości post-segmentu 32 próbki, na poziomie 2 zaobserwować można szeroki przedział wartości ponad 90%, dodatkowo widoczny jest wzrost wartości normy na poziomie 1 (prawy górny wykres).



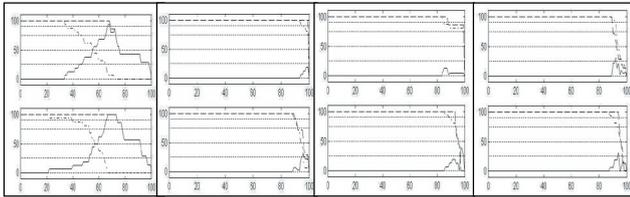
Rys. 5. Zależność parametrów agregatu z rysunku 4 od długości post-segmentu
Fig. 5. The performance of the aggregate from figure 4 versus post-segment length

Tabela 2 przedstawia efektywność detekcji wybranych agregatów fazowych (różne miary segmentów w funkcji długości post-segmentu) falki bior1.5 na sześciu poziomach aproksymacji. Można w niej znaleźć pozycje które dają dobre wyniki po zastosowaniu post-segmentacji, jak i bez niej.

Tab. 2. Uzyskane rezultaty wybranych agregatów fazowych falki bior1.5
Tab. 2. Obtained performance of phase aggregates of bior1.5 wavelet

MIARA	L	P1	P2	P3	P4	P5	P6
wart. skuteczna	-	>50; p70	>60; p75	<25; p25	<25; p25	<50; p50	<15
	8	45-50	<15	<25; p25	45-50	>65; p100	~25
	16	50-60	>95	<25; p25	>45	~25; p50	~25
	32	60-75	>95	<25; p25	<25; p25	~25; p50	-
średnia modułu	-	50-70	65-90	~25	~30	<50	<25
	8	<50; p50	<20; p35	<50	>40	60-80	<20
	16	~50	95-100	~25	40-50	~50	<20; p25
	32	50-75	95-100	~25	30-45	~50	-
wariancja	-	50-65	50-85	<20	50-70	<25; p25	<25; p25
	8	~30; p50	<15	>25; p50	>25; p50	75-100	<25; p25
	16	~50	75-95	~25	35-50	>25; p70	<25; p25
	32	65-75	~95	~25	35-50	~50; p55	-
odchylenie standardowe	-	50-70	50-75	<25; p25	~50	<70; p70	<25; p25
	8	~50	<15	<25; p25	>35; p50	75-90	25-35
	16	~50	75-95	<25; p25	>35; p50	40-65	<25; p25
	32	65-75	~95	<25; p25	<50; p50	<50; p50	-
minimum modułu / wart. skuteczną	-	-	<20	~20	~20	~25	~20; p25
	8	>40; p60	<25; p25	>25; p50	<25	<50; p50	~20; p25
	16	>40; p55	<25; p25	~20	>35; p50	~20; p25	-
	32	-	<35; p35	<20	-	-	-

Wśród otrzymanych rezultatów na uwagę zasługują także te, w których dobre wyniki uzyskane dla algorytmu bez post-segmentacji uległy pogorszeniu po jej zastosowaniu (rys. 6.). Lewy skrajny wykres przedstawia przebieg wartości normy agregatu bez post-segmentacji, a kolejne odpowiednio dla 8, 16 i 32 próbek w post-segmentach. Należy zauważyć, że agregat ten („współczynnik kształtu z fazy dla falki coiflet 2”) nie został wyszukany we wcześniejszych etapach badań ze względu na mało obliczające wyniki wstępne.



Rys. 6. Przykład spadku wartości normy agregatu po procesie post-segmentacji
Fig. 6. Example of aggregate performance decrease after use of post-segmentation

Jak wskazały badania tylko agregaty fazowe dają wyniki dobre (wartość normy powyżej 50%) lub bardzo dobre (wartość normy powyżej 75%). Dla pozostałych rodzajów agregatów zwykle nie przekraczały poziomu 30%, toteż pozostały nieopisane. Najlepsze (w sensie globalnym) miary to wariancja i odchylenie standardowe, także wartość średnia z modułu i wartość skuteczna dają dobre wyniki, jednak zwykle nie są tak efektywne. Tabela 3 przedstawia wartości wariancji fazy chwilowej w zależności od rodzaju falki (wybrano najlepsze falki). Potwierdza ona wyniki prezentowane w [1] i [2], które wykazują, że dominujące są krótkie i gładkie falki, w szczególności z rodziny biortogonalnych.

Tab. 3. Uzyskane rezultaty wybranych agregatów fazowych w zależności od falki
Tab. 3. Obtained performance of phase aggregate versus wavelet type

FALKA	L	P1	P2	P3	P4	P5	P6
db 1	-	>50; p75	>50; p75	>50; p90	>50; p75	<50; p50	~35
	8	~25	<30; p30	>25; p45	>50; p80	<50; p50	~25
	16	<25	>25; pp50	>50; p80	>50; p75	<25; p25	-
	32	>50; p75	>50-75	>50; p85	<50; p50	-	-
db 2	-	>55; p70	50-60	>55; p70	~55; p75	~25; p40	~25; p35
	8	~25	<25; p25	~30; pp60	>50; p65	~25; p30	<25; p25
	16	<25	>65; p90	>40; p55	~50; p65	~25; p40	-
	32	50-70	50-60	~60; p70	70-75	-	-
db 3	-	~50; p75	45-70	25-35	<25; p25	~25; p35	<20
	8	~25; p40	>55; p80	35	~25; p35	<20	<20
	16	~25; p40	>45; p70	35-50	~25; p35	~25; p35	<25; p25
	32	>50; p80	>45; p70	25-35	<25; p25	-	-
bior 1.3	-	>45; p55	>25; p50	~50; p55	~25; p25	<20	90-95
	8	<25; p25	~25	~30; p60	<25; p25	<20	90-95
	16	<25; p25	~25	~30; p60	<25; p25	<20	>85; p95
	32	~50	>25; p30	>50; p60	<25; p25	-	-
bior 1.5	-	50-65	50-85	<20	50-70	50-70	<25; p25
	8	~30; p50	<15	>25; p50	>25; p50	75 - 100	<25; p25
	16	~50	75-95	~25	35-50	>25; p70	<25; p25
	32	65-75	~95	~25	35-50	~50; p55	-
coiflet 2	-	>50; p80	50-75	>50; p85	>40; p80	~25; p35	~25; p40
	8	<25; pp25	<25; p35	~25; p40	<25; p30	<25	<25; pp30
	16	25-40	>60; p80	>40; p60	~50; p70	~35; p55	~25; pp45
	32	>50; p95	60-70	>50; p80	>45; p75	~25; pp35	-
coiflet 3	-	50-70;	40-55;	25-45;	25-50;	25-45;	<25; p25
	8	<25; p25	<25; p25	<25; p50	<20	<25; p25	<25; p30
	16	<25; p25	>40; p55	~30; p40	~40; p95	~30; p50	~25; p50
	32	~55; p75	~35; p50	<25; p25	25; pp55	~40; p50	<25; p25

Generalnie najlepsza falka to bior 1.5. Pozwala ona uzyskać wartości normy ponad 90% w szerokich przedziałach na co najmniej 2 poziomach aproksymacji równocześnie, dla kilku różnych miar (średniej z modułu, wariancji i odchylenia standardowego), i niemal niezależnie od długości post-segmentu (Tab.2). Również falka bior 1.3 daje bardzo dobre rezultaty (około 90%), jednak w zasadzie tylko na szóstym poziomie aproksymacji, co ogranicza znacznie jej wykorzystanie, dlatego autor nie przytacza tu odpowiedniej tabeli.

Wyniki badań wskazują także jednoznacznie, iż przyjęta szerokość przedziału zmienności progów, dla których agregat jest uznany za efektywny została w wielu przypadkach kilkukrotnie

przekroczona, przykładem jest tu rysunek 4. Rozwiewa to obawy co do możliwości opracowania prostego systemu ekspertowego dobierającego progi automatycznie, dostrajając algorytm do konkretnych warunków akustycznych pomieszczenia.

Jak można się spodziewać zmiana warunków akustycznych w pomieszczeniu, albo charakterystyki fazowej części analogowej detektora pociągnie za sobą zmiany skuteczności poszczególnych agregatów, dlatego celowe będzie przebadanie ich dla innego niż dotychczas stosowany zestawu sygnałów testowych, ale także o ściśle określonej zmienności warunków otoczenia.

4. Podsumowanie

Badania jednoznacznie dowiodły, że zastosowanie post-segmentacji pozytywnie wpłynęło na poprawę rozdzielczości czasowej omawianej metody przez co pozwoliło poprawić dystynktywność krótkookresowych cech sygnału (głównie fazy chwilowej).

W trakcie badań wskazano najlepsze zestawy: falka-cechamiara, oraz długości segmentów i post-segmentów, dające w wyniku jednoznacznie identyfikację sygnałów prawdziwych, przy dużej odporności na sygnały fałszywe. Uzyskana efektywność detekcji dla wybranych agregatów spełnia z powodzeniem wymagania tej części standardu VdS [3], niestety odporność na sygnały fałszywe jest jeszcze niedoskonała i wymaga dopracowania. Na podstawie literatury [4], [7] oraz obecnych rezultatów można sądzić, iż sprostanie temu wymaganiu nie powinno stanowić problemu, po odpowiednim dobraniu zestawu kilku agregatów i właściwej konstrukcji algorytmu wnioskującego.

Wyszukane także zostały agregaty, które nie wymagają post-segmentacji, a dają dobrą identyfikację wspomnianych cech. Ich zaletą jest zmniejszone zapotrzebowanie na moc obliczeniową, tak więc warte są głębszego rozpoznania.

Autor stwierdził, że zaproponowany sposób oceny agregatu nie jest w pełni jednoznaczny i nie pozwala precyzyjnie opisać jego zachowania w funkcji zmian progu kwantyzacji binarnej sygnatury (spodziewano się bardziej jednostajnego przebiegu). Dlatego zaproponował inny sposób oceny, bazujący na pomiarze pola zawartego pod krzywą wartości normy, lub pomiędzy krzywymi ilości decyzji poprawnych i błędnych.

W chwili obecnej autor opracowuje rezultaty przetwarzania przy zastosowaniu metody wagowej klasyfikacji sygnałów. Wstępne wyniki potwierdzają jej przydatność w detekcji cech o średnich i dużych czasach trwania, jednakże są to głównie cechy amplitudowe, obciążone wadami opisanymi w [1] i [2].

5. Literatura

- [1] Bemke I. Zielonko R.: Application of Rock Solid Attributes for robust identification of glass breaks acoustic signals via Wavelet Transformation. 10th IIMECO TC10 International Conference on Technical Diagnostics, 9-10 June, 2005, Budapest, Hungary
- [2] Bemke I.: Application of data segmentation and segregation in alarm dedicated glass breaks detection method, based on Wavelet Transformation. International Congress on Signals and Electronic Systems 2006, September 17-20, Łódź.
- [3] VdS Richtlinien für Einbruchmeldeanlagen: Glasbruchmelder – Anforderungen VdS Schadenverhütung im Gesamtverband der Deutschen Versicherungswirtschaft e.V., VdS 2332, Köln, 2002.
- [4] Tlaga J., Tlaga W.: Zdalna diagnostyka tafli szklanych z zastosowaniem elementów transformaty Hilberta. 3rd International Conference on Technical Diagnostics 2004, Poznań, Poland
- [5] Biafasiewicz J. T.: Falki i aproksymacje. WNT Warszawa 2000
- [6] Wojtaszczyk P.: Teoria falek. PWN, Warszawa 2000.
- [7] Chien-Chang L., Shi-Huang Ch.: Audio Classification and Categorization Based on Wavelets and Support Vector Machine. IEEE Transactions on Speech and Audio Processing vol. 13 No. 5. September 2005, pp. 644-651.