



## Badania eksploatacyjne czterosensorowego detektora upadków

BARTŁOMIEJ WÓJTOWICZ, ANDRZEJ P. DOBROWOLSKI

Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Systemów Elektronicznych,  
00-908 Warszawa, ul. gen. S. Kaliskiego 2,  
BWOjtwicz@wat.edu.pl, ADobrowolski@wat.edu.pl

**Streszczenie.** Zaprezentowane w niniejszym artykule badania stanowią kontynuację dotychczasowych prac mających na celu opracowanie mobilnego detektora upadków. Przedstawiony algorytm opiera się na dyskretnej transformacji falkowej sygnałów z dostępnych w detektorze sensorów oraz pojedynczym klasyfikatorze w postaci sieci wektorów nośnych — SVM (ang. *Support Vector Machine*). Do procesu redukcji cech zastosowano miarę istotności Fishera. W wyniku zmniejszenia liczby cech zmniejszeniu uległa również liczba wektorów nośnych sieci SVM, mająca bezpośredni wpływ na górne oszacowanie błędu klasyfikacji. Na podstawie otrzymanych wyników wyznaczono parametry klasyfikatora pozwalające na zaprezentowanie opracowanej koncepcji w polu krzywych ROC (ang. *Receiver Operating Characteristics*) oraz porównanie ich z wynikami otrzymanymi dla pojedynczych sensorów detektora. Opracowana koncepcja daje zdecydowanie lepsze rezultaty niż każdy z sensorów działający niezależnie. Rezultaty przeprowadzonych badań dały bardzo dobre wyniki w porównaniu z dotychczasowymi wynikami, przy znacznej redukcji liczby wymaganych deskryptorów. Z uwagi na ścisłą zależność pomiędzy liczbą danych uczących oraz liczbą wektorów nośnych, które bezpośrednio wpływają na górne oszacowanie błędu klasyfikacji, dokonano redukcji deskryptorów. W rezultacie uzyskano zadowalające efekty przy redukcji liczby deskryptorów z 38 do zaledwie 6, zapewniając, że górne oszacowanie błędu klasyfikacji, w zbiorze nowych danych testowych nie przekracza 5,3%.

**Słowa kluczowe:** detekcja upadków, fuzja sensoryczna, dyskretna transformacja falkowa, sieć wektorów nośnych.

**DOI:** 10.5604/12345865.1157220

### 1. Wstęp

W związku z wydłużaniem się średniej długości życia zwiększa się odsetek ludzi starszych [1, 2]. Tzw. *proces starzenia się społeczeństwa* stał się powszechnym

problemem współczesnego świata i niesie z sobą szereg konsekwencji o charakterze m.in. społecznym, ekonomicznym, psychologicznym oraz politycznym [3].

Najbardziej narażoną na problemy zdrowotne grupą wiekową są osoby powyżej 65. roku życia [3, 4]. Wraz z wiekiem postępują zmiany w układzie nerwowym człowieka objawiające się zaburzeniami motoryki, równowagi oraz odruchów, co w rezultacie prowadzi do zwiększenia ryzyka upadków, a w efekcie spowodowanych nimi urazów [3]. Upadki dotyczą co trzecią osobę powyżej 65. roku życia, a ryzyko ich wystąpienia wzrasta wraz z wiekiem człowieka [4, 5]. Bardzo duży odsetek upadków ma miejsce w domu lub jego okolicach i dla grupy wiekowej 85-89 lat wynosi aż 80% [4]. Ponad połowa tych zdarzeń prowadzi do hospitalizacji i skutkuje ograniczeniem sprawności ruchowej, a w skrajnych przypadkach śmiercią [4, 6-8].

W celu zapobiegania negatywnym skutkom upadków kluczowym zagadnieniem staje się zminimalizowanie czasu niezbędnego do udzielenia poszkodowanemu fachowej pomocy, co istotnie redukuje możliwość wystąpienia niepożądanych powikłań pourazowych. Z tego względu autorzy podjęli próbę opracowania mobilnego detektora upadków bazującego na dyskretnej transformacji falkowej oraz sieci wektorów nośnych. Zaprezentowane prace są kontynuacją badań zapoczątkowanych w [9-11].

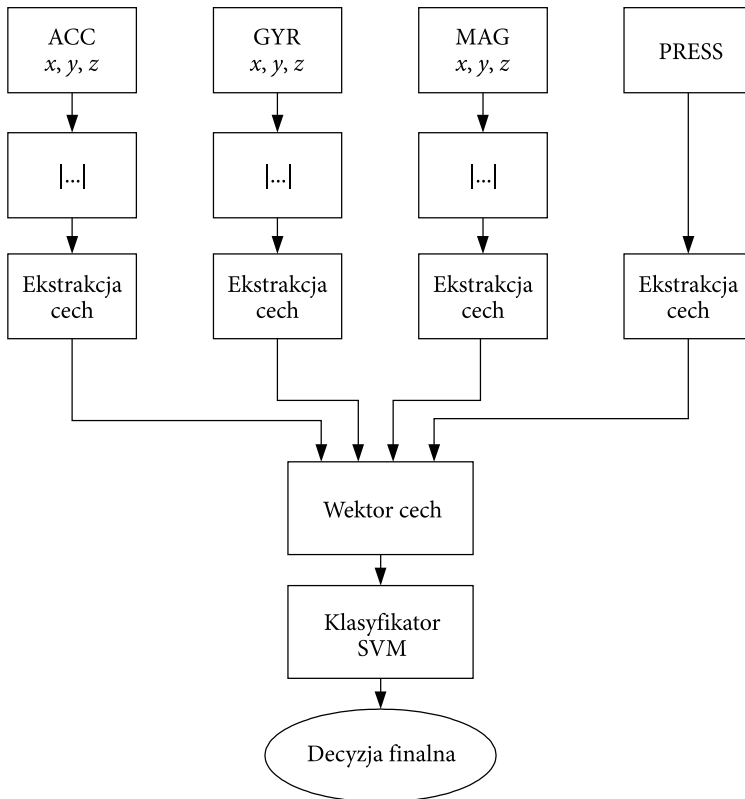
## 2. Algorytm detekcji upadków

Źródłem danych sensorycznych jest zaprojektowany specjalnie do tego celu detektor, który został szczegółowo opisany w [9, 10]. Urządzenie bazuje na danych pozyskiwanych z czterech niezależnych sensorów: akcelerometru, żyroskopu, magnetometru oraz sensora ciśnienia atmosferycznego. Jego pracą zarządza 32-bitowy mikrokontroler z rdzeniem *CortexM4*. Detektor komunikuje się z komputerem za pośrednictwem bezprzewodowej sieci Wi-Fi lub przy użyciu wirtualnego portu szeregowego. Urządzenie pozwala na zapis w czasie rzeczywistym kolekcjonowanych danych na karcie *microSD*. Zasilanie detektora zapewnia bateria o pojemności 950 mAh i napięciu 3,7 V, która może być doładowywana za pośrednictwem portu USB.


Opracowany i zaimplementowany algorytm detekcji upadków jest modyfikacją algorytmu zaprezentowanego w [11]. W odróżnieniu od poprzednich koncepcji fuzji danych sensorycznych, zdecydowano się na zastosowanie pojedynczego klasyfikatora, który zrealizowano przy użyciu liniowej sieci wektorów nośnych SVM (ang. *Support Vector Machine*). Uogólniony algorytm działania systemu zaprezentowano na rysunku 1.

Do procesu ekstrakcji cech zastosowano dyskretną transformację falkową DWT (ang. *Discrete Wavelet Transform*). Kolejne cechy zdefiniowano jako maksymalne wartości współczynników detali DWT. Liczba maksimum przypadająca na dany poziom, a także liczba poziomów dekompozycji oraz wybrana falka zostały

zdefiniowane w trakcie wielokrotnego procesu iteracyjnego dla każdego z sensorów detektora [11]. Schemat blokowy procesu ekstrakcji cech zaprezentowano na rysunku 2. Wyznaczone w ten sposób deskrytory numeryczne każdego z dostępnych sygnałów sensorycznych zostały połączone we wspólny wektor cech.



Rys. 1. Algorytm działania systemu detekcji upadków (symbol |...| oznacza moduł wypadkowego wektora będącego sumą geometryczną trzech ortogonalnych składowych)



Rys. 2. Schemat blokowy procesu ekstrakcji cech z pojedynczego sygnału sensorycznego

W tabeli 1 zaprezentowano konfigurację bloku ekstrakcji cech będącą wynikiem badań przedstawionych w [11].

TABELA 1

Wyznaczone parametry konfiguracyjne procesu ekstrakcji cech [11]  
( $p_i$  oznacza poziom dekompozycji)

Sensor	Falka	Liczba poziomów dekompozycji	Liczba maksimów wsp. detali na poziomach [ $p_1 p_2 p_3 p_4 p_5$ ]
ACC	coif3	5	[0 0 5 4 1]
GYR	sym2	5	[5 0 8 0 1]
MAG	db4	5	[0 2 4 0 1]
PRESS	db4	5	[0 4 1 1 1]

Na podstawie badań zaprezentowanych w [11] stwierdzono, że podanie na wejście klasyfikatora wartości bezwzględnych wyekstrahowanych cech daje znacznie lepsze rezultaty niż w przypadku uwzględniania ich znaków. Z tego powodu badania zaprezentowane w niniejszym artykule opierają się na mechanizmie ekstrakcji cech pomijającym znak.

### 3. Przeprowadzone badania

Przy użyciu elastycznego pasa na klatce piersiowej monitorowanej osoby zamocowano detektor. Urządzenie próbkowało sygnał źródłowy z każdego sensora z szybkością 25 próbek na sekundę. Kolekcjonowane dane przesyłane były do komputera w czasie rzeczywistym za pośrednictwem sieci Wi-Fi, a następnie przetwarzane w środowisku Matlab. Analizowana ramka miała długość 100 próbek, co odpowiadało 4 s rejestracji.

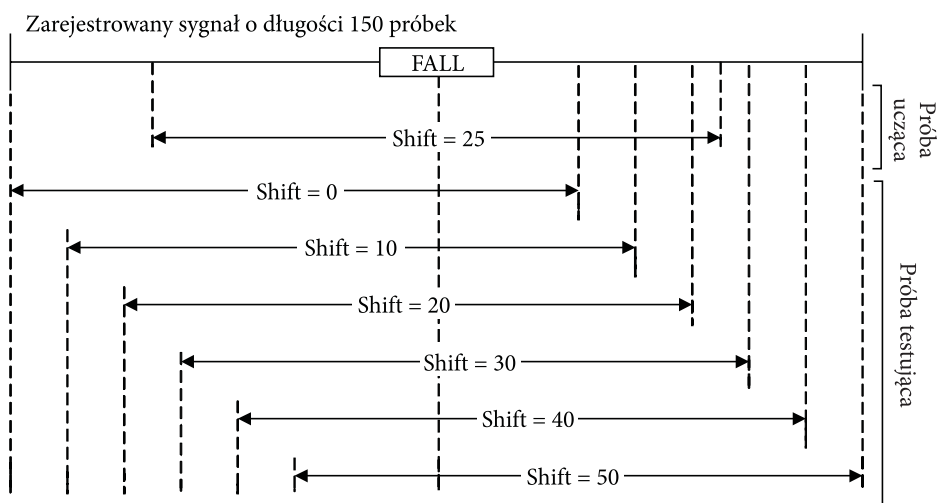
W pierwszym etapie badań sprawdzono działanie opracowanego algorytmu detekcji upadków. Próba ucząca składała się z 25 różnych upadków (ang. *Fall* — upadek) oraz 25 aktywności dnia codziennego (ang. ADL — *Activity Daily Living*). Weryfikacja działania zaproponowanego algorytmu odbyła się przy użyciu 25 rejestracji upadków i 40 rejestracji ADL. Na tym etapie badań w przypadku uczenia i testowania moment upadku występował w okolicy połowy analizowanej ramki o długości 100 próbek. Uzyskane w ten sposób rezultaty dały 100% poprawnie klasyfikowanych aktywności. Wyniki zaprezentowano w tabeli 2.

TABELA 2

## Rezultaty klasyfikacji

Dane	Fall/ADL	Poprawnie sklasyfikowanych		
Uczące	ADL	25/25	100%	100%
	Fall	25/25	100%	
Testujące	ADL	40/40	100%	100%
	Fall	25/25	100%	

W następnej kolejności przebadano wpływ umiejscowienia zdarzenia upadku w analizowanej ramce. Do tego celu zastosowano 115 sygnałów o długości 150 próbek, z których za pomocą ruchomego okna prostokątnego, przesuwanego z krokiem 10 próbek, wybierano fragmenty o długości 100 próbek, uzyskując w ten sposób sześć różnych pozycji zdarzenia upadku w analizowanej ramce. W rezultacie próba testująca składała się z 690 rejestracji (300 Fall; 390 ADL) i nie pokrywała się z próbą uczącą. Proces wyboru ramek zilustrowano na rysunku 3.



Rys. 3. Ilustracja wyboru ramek sygnału z różną lokalizacją zdarzenia upadku

Rezultaty klasyfikacji dla uzyskanych w ten sposób sygnałów zebrano w tabeli 3.

TABELA 3

Rezultaty klasyfikacji z uwzględnieniem różnego położenia upadku w analizowanej ramce

SHIFT	0	10	20	30	40	50
Liczba błędnych klasyfikacji upadku (Total = 50)	3	1	1	0	0	1
Liczba błędnych klasyfikacji ADL (Total = 65)	0	0	0	0	0	0

W celu oceny jakości klasyfikatora zastosowano trzy miary: czułość *SE* (ang. *Sensitivity*), specyficzność *SP* (ang. *Specificity*) oraz błąd całkowity *TE* (ang. *Total Error*).

Czułość określa stosunek liczby prawidłowo wykrytych upadków *TP* (ang. *True Positive*) do liczby wszystkich faktycznych upadków, tj. do sumy prawidłowo wykrytych upadków oraz liczby nierozpoznanych upadków *FN* (ang. *False Negative*)

$$SE = \frac{TP}{TP + FN} = \frac{294}{300} = 98\%. \quad (1)$$

Specyficzność określa stosunek liczby prawidłowo wykrytych aktywności niebędących upadkami *TN* (ang. *True Negative*) do sumy wszystkich zdarzeń ADL, czyli do sumy prawidłowo wykrytych aktywności dnia codziennego *TN* oraz tzw. fałszywych alarmów, tj. liczby aktywności niebędących upadkami błędnie sklasyfikowanych jako upadki *FP* (ang. *False Positive*).

$$SP = \frac{TN}{TN + FP} = \frac{390}{390} = 100\%. \quad (2)$$


Znajomość wartości specyficzności pozwala na wyznaczenie prawdopodobieństwa fałszywego alarmu  $PFA = 1 - SP$ , które na podstawie przeprowadzonych badań przyjmuje wartość  $PFA = 0$ .

Zdolność dyskryminacyjną klasyfikatora określa błąd całkowity (ang. *Total Error*) zdefiniowany jako stosunek liczby wszystkich błędnych klasyfikacji do wszystkich badanych przypadków.

$$TE = \frac{FP + FN}{TP + TN + FP + FN} = \frac{6}{690} = 0,9\%. \quad (3)$$

Na podstawie otrzymanych wyników można wyznaczyć parametry klasyfikatora pozwalające na zaprezentowanie opracowanych wariantów w polu krzywych ROC (ang. *Receiver Operating Characteristics*) oraz porównanie ich z wynikami otrzymanymi dla pojedynczych sensorów detektora (uzyskanymi w [11]), co zaprezentowano

na rysunku 4. Na podstawie tego wykresu można stwierdzić, że opracowana koncepcja daje zdecydowanie lepsze rezultaty niż każdy z sensorów działający niezależnie. Proces detekcji upadków jest tym skuteczniejszy, im punkty w polu krzywych ROC znajdują się bliżej lewego górnego narożnika [12].



Rys. 4. Położenie poszczególnych wariantów w polu krzywych ROC

## 4. Redukcja cech

Zaproponowane rozwiązanie wykorzystuje do uczenia oraz testowania aż 38 cech. Liczba ta jest sumą wszystkich deskryptorów wyznaczonych dla poszczególnych sensorów detektora. Uwzględniając wyjściowy zestaw zarejestrowanych zdarzeń, tj. 50 upadków oraz 65 przypadków ADL, stosunek liczby przypadków do liczby cech wynosi dla upadków 1,3 a dla ADL 1,7. By poprawić tę niekorzystną relację (liczba danych uczących przypadająca na pojedynczą cechę powinna być zdecydowanie większa), należy zminimalizować liczbę wykorzystywanych w procesie klasyfikacji deskryptorów.


W celu redukcji cech zastosowano metodę Fishera. Według [13] jest ona jedną z najbardziej intuicyjnych metod oceny pojedynczej cechy stosowanych w przypadku problemu klasyfikacji binarnej. Jeśli odległość między centrami obu klas reprezentujących upadki oraz ADL jest stosunkowo duża, przy jednoczesnym niewielkim

rozproszeniu wewnątrzklasowym, to wtedy dany deskryptor ma zdolność skutecznego rozróżniania pomiędzy klasami. Warunki te można opisać wzorem (4) definiującym tzw. współczynnik istotności Fishera:

$$S_{12}(f) = \frac{|c_{Fall} - c_{ADL}|}{\sigma_{Fall} + \sigma_{ADL}}, \quad (4)$$

gdzie:  $c_{Fall}$ ,  $c_{ADL}$  — średnia arytmetyczna wartości cechy dla klasy reprezentującej upadki oraz ADL;  
 $\sigma_{Fall}$ ,  $\sigma_{ADL}$  — odchylenie standardowe wartości cechy dla klasy reprezentującej upadki oraz ADL.

Wykres przedstawiony na rysunku 5 obrazuje współczynniki istotności Fishera obliczone dla poszczególnych cech. Różnymi kolorami oznaczono przynależność kolejnych cech do sensorów. Zastosowanie progu decyzyjnego  $TH_{FISHER}$  umożliwia pominięcie cech o podprogowych wartościach współczynnika istotności Fishera.

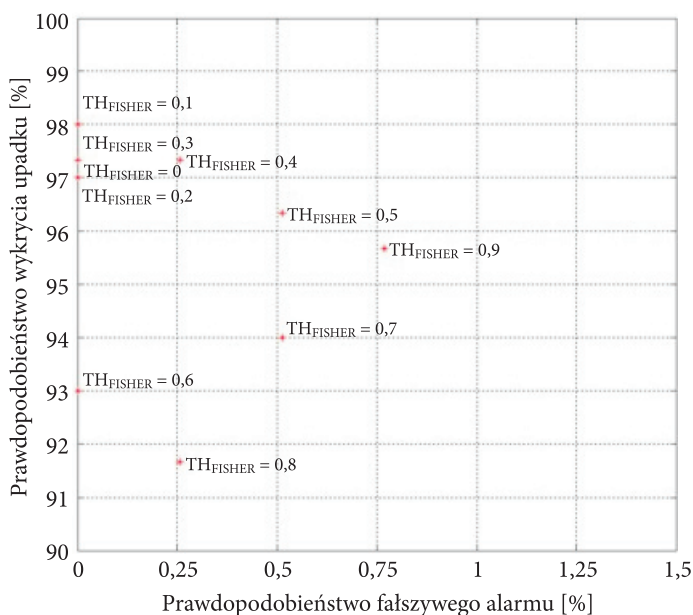


Rys. 5. Współczynniki istotności Fishera wyznaczone w oparciu o wyjściowy zestaw zarejestrowanych przypadków (50 upadków oraz 65 aktywności ADL)



Do badań przyjęto zakres zmienności progu w granicach od 0,1 do 0,9. Dalsze zwiększenie progu usuwałoby wpływ sensorów o mniejszej zdolności dyskryminacyjnej.

Najkorzystniejszy jest wybór progu istotności Fishera na poziomie 0,2 lub 0,9. Dla tych wartości liczba wektorów nośnych wynosi odpowiednio 9 i 6. Jak można zauważyć, redukując pięć cech (próg współczynnika istotności Fishera na poziomie 0,2), uzyskujemy czułość mniejszą zaledwie o 0,33% niż w przypadku zastosowania pełnego zestawu deskryptorów, przy wciąż zerowej liczbie fałszywych alarmów. Zastosowanie progu współczynnika istotności Fishera na poziomie 0,9 bardziej degradowuje czułość i specyficzność klasyfikatora, powoduje jednak znaczne zmniejszenie liczby wektorów nośnych, redukując ją do zaledwie sześciu. Na rysunku 6 zobrazowano wpływ wartości progu na parametry klasyfikatora w polu krzywych ROC.



Rys. 6. Parametry klasyfikatora w zależności od wartości progu w polu krzywych ROC

Z drugiej strony, zmniejszenie liczby wektorów nośnych zmniejsza górne oszacowanie błędu definiowane jako stosunek liczby wektorów nośnych do ogólnej liczby danych uczących pomniejszonej o jeden [14]:

$$P \leq \frac{N_{SV}}{p-1} = \frac{6}{50+65-1} = \frac{6}{114} \Rightarrow P \leq 5,3\%. \quad (5)$$

Z tego powodu, w celu poprawy generalizacji sieci SVM, należy dążyć do zmniejszania liczby wektorów nośnych nawet kosztem ograniczenia liczby prawidłowych klasyfikacji [14].

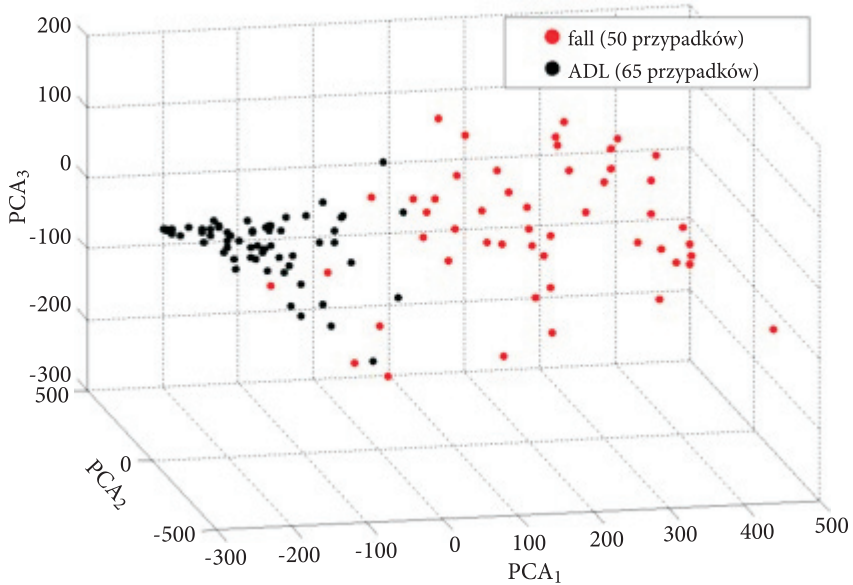

W tabela 4 zestawiono parametry klasyfikatora otrzymane dla różnych wartości progu współczynnika istotności Fishera. Wyniki te otrzymano dla pełnego zbioru przypadków z różnym umiejscowieniem zdarzenia upadku w analizowanej ramce, uzyskiwanych wg schematu przedstawionego na rysunku 3 (690 przypadków).

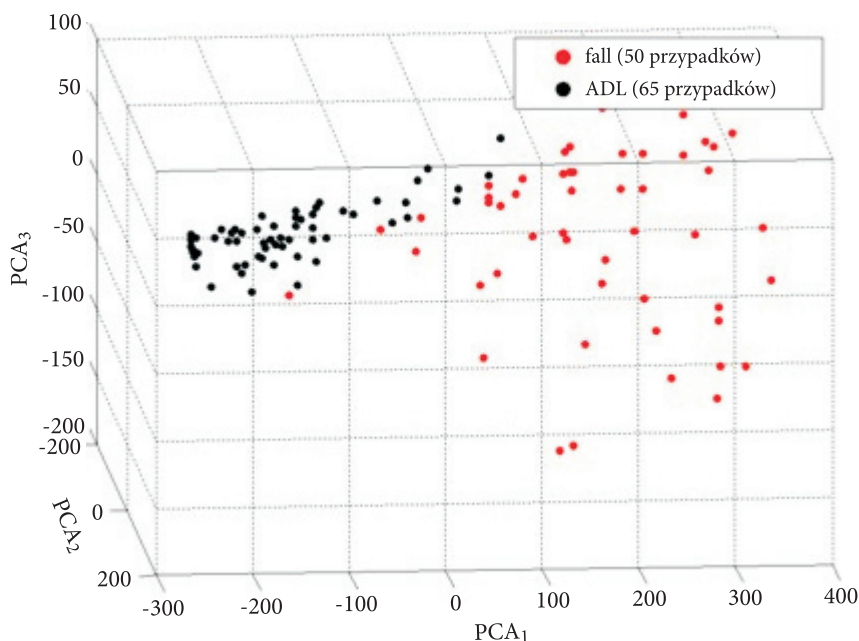
TABELA 4  
Parametry klasyfikatora w zależności od wartości progu współczynnika istotności Fishera

Próg istotności wsp. Fishera	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
Liczba wektorów nośnych	13	12	9	11	11	10	9	8	7	6
Liczba cech	38	36	33	32	29	23	16	14	9	6
SE [%]	97,3	98	97	97,3	97,3	96,3	93	94	91,7	95,7
PFA [%]	0	0	0	0	0,26	0,51	0	0,51	0,26	0,77
Górne oszacowanie błędu [%]	11,4	10,5	7,9	9,6	9,6	8,8	7,9	7,0	6,1	5,3

W celu szerszej oceny wpływu usunięcia cech o współczynniku istotności Fishera mniejszym od zadanego progu na separowalność klas reprezentujących upadki oraz ADL wykonano analizę PCA (ang. *Principal Component Analysis*). Na rysunkach 7-9 zaprezentowano rozkłady przypadków w przestrzeni ( $PCA_1$ ,  $PCA_2$ ,  $PCA_3$ ) przed redukcją cech oraz po redukcji cech — z zastosowaniem progu współczynnika istotności na poziomie 0,2 oraz 0,9.

W oparciu o analizę PCA można stwierdzić, że przyjęcie progu współczynnika istotności Fishera na poziomie 0,9 nie pogarsza separowalności klas reprezentujących upadki oraz ADL. W efekcie autorzy ostatecznie zdecydowali się na ustalenie progu współczynnika istotności Fishera na tym poziomie, co pozwoliło na znaczne obniżenie złożoności obliczeniowej, zapewniając jednocześnie minimalną wartość górnego oszacowania błędu klasyfikacji.

Rys. 7. Rozkład przypadków w przestrzeni (PCA1, PCA2, PCA3) bez redukcji cech ( $TH_{FISHER} = 0$ )Rys. 8. Rozkład przypadków w przestrzeni (PCA1, PCA2, PCA3) —  $TH_{FISHER} = 0,2$



Rys. 9. Rozkład przypadków w przestrzeni (PCA1, PCA2, PCA3) –  $TH_{FISHER} = 0,9$

## 5. Podsumowanie

Zaprezentowane badania są kontynuacją prac zapoczątkowanych w [9-11]. W artykule przedstawiono badania opracowanego algorytmu detekcji upadków bazującego na dekompozycji falkowej w roli generatora cech oraz sieci SVM w roli klasyfikatora. Przedstawiona koncepcja dała satysfakcjonujące wyniki, poprawiając skuteczność działania detektora w porównaniu z wariantami zastosowanymi w [11].

Z uwagi na ścisłą zależność pomiędzy liczbą danych uczących oraz liczbą wektorów nośnych, które bezpośrednio wpływają na górne oszacowanie błędu klasyfikacji, dokonano redukcji deskryptorów. Jako kryterium selekcji wykorzystano wartość współczynnika istotności Fishera. W rezultacie uzyskano zadowalające efekty przy redukcji liczby deskryptorów z 38 do zaledwie 6, zapewniając, że górne oszacowanie błędu klasyfikacji w zbiorze nowych danych testowych nie przekracza 5,3%.

Artykuł opracowany na podstawie referatu prezentowanego na XXVIII Międzynarodowej Konferencji Naukowo-Technicznej „Ekomilitaris 2014”, Zakopane 9-12.09.2014 r.



Artykuł wpłynął do redakcji 5.11.2014 r. Zweryfikowaną wersję po recenzji otrzymano 9.12.2014 r.

## LITERATURA

- [1] NYAN M.N., TAY F.E.H., KOH T.H., SITOY Y.Y., TAN K.L., *Location and sensitivity comparison of MEMS accelerometers in signal identification for ambulatory monitoring*, Electron. Components Technol., vol. 1, no. 1-4, Jun. 2004, 956-960.
- [2] GUANGYI S., CHEUNG S.C., WEN J.L., KWOK-SUI L., YUEXIAN Z., YUFENG J., *Mobile Human Airbag System for Fall Protection Using MEMS Sensors and Embedded SVM Classifier*, Ieee Sensors Journal, vol. 9, no. 5, May 2009.
- [3] SZPRINGER M., WYBRANIEC-LEWICKA B., CZERWIAK G., MICHALSKA M., KRAWCZYŃSKA J., *Upadki i urazy wieku geriatrycznego*, Studia Medyczne 2008.
- [4] EDBOM-KOLARZ A., MARCINKOWSKI J.T., *Upadki osób starszych — przyczyny, następstwa, profilaktyka*, Hygeia Public Health, 2011, 313-318.
- [5] BOURKE A.K., LYONS G.M., *A threshold-based fall-detection algorithm using a biaxial gyroscope sensor*, Biomedical Electronics Laboratory, Department of Electronic and Computer Engineering, University of Limerick, Limerick, Ireland, 2006.
- [6] RIGLER S.K., *Preventing falls in older adults*, Hospital Practice, 1999.
- [7] SIMPSON J.M., *Elderly people at risk of falling: the role of muscle weakness*, Physiother, 1993.
- [8] THORNBY M.A., *Balance and falls in the frail older person: a review of the literature*, Topics in Geriatric Rehabilitation, 1995.
- [9] WÓJTOWICZ B., DOBROWOLSKI A., *Projekt integratora danych sensorycznych do detekcji niekontrolowanych upadków*, Biul. WAT, 62, 4, Warszawa, 2013.
- [10] WÓJTOWICZ B., DOBROWOLSKI A., *Bezprzewodowy detektor upadków*, Elektronika: konstrukcje, technologie, zastosowania, vol. 55, nr 3, Warszawa, 2014, 72-75.
- [11] WÓJTOWICZ B., DOBROWOLSKI A., *Detektor upadków oparty na dyskretnej transformacie falkowej oraz niezależnych klasyfikatorach SVM*, Elektronika: konstrukcje, technologie, zastosowania, vol. 55, nr 3, Warszawa, 2014, 22-26.
- [12] SMITH S., *Cyfrowe przetwarzanie sygnałów. Praktyczny poradnik dla inżynierów i naukowców*, Wydawnictwo BTC, 2007.
- [13] OSOWSKI S., MARKIEWICZ T., KRUK M., KOZŁOWSKI W., *Metody sztucznej inteligencji do wspomaganiania diagnostyki patologii tkanek*, [w:] „Metrologia w medycynie — wybrane zagadnienia”, [red.] A. Michalski, WAT, Warszawa, 2011, 91-126.
- [14] OSOWSKI S., *Metody i narzędzia eksploracji danych*, Wydawnictwo BTC, Legionowo, 2013.

## B. WÓJTOWICZ, A.P. DOBROWOLSKI

**Inspection of four-sensor falls detector**

**Abstract.** The studies presented in this article are the continuation of previous work to develop a mobile fall detector. The algorithm is based on a discrete wavelet transform of the signals from the sensors available at the detector and a linear support vector machine as a classifier. Fisher score method is used for feature selection in the proposed algorithm. As a result of reducing the number of features, the number of support vectors has been also reduced — it has a direct impact on the upper estimate of the classification error. On the basis of the obtained results, the classifier parameters have been calculated. This allows presenting the developed concept in the field of ROC curves (Receiver Operating Characteristics) and their comparison with the results obtained for individual sensors. The developed

concept gives much better results than each of the sensors acting independently. The findings of this study have given very good results in comparison with the previous findings, with a significant reduction in the number of required features. Due to the close relationship between the number of training data and the number of support vectors which directly affect the upper estimate of the classification error, the number of features has been reduced. Finally, satisfactory results have been obtained with the reduction of the number of features from 38 to just six, ensuring that the upper estimation of the classification error in the set of the new test data does not exceed 5.3%.

**Keywords:** falls detection, data fusion, discrete wavelet transform, support vector machine