

**Bartłomiej WÓJTOWICZ, Andrzej P. DOBROWOLSKI**  
 WYDZIAŁ ELEKTRONIKI WOJSKOWEJ AKADEMII TECHNICZNEJ W WARSZAWIE

## Multisensoryczny detektor upadków wykorzystujący dyskretną dekompozycję falkową oraz klasyfikator SVM

Mgr inż. Bartłomiej WÓJTOWICZ

Jest absolwentem Wydziału Elektroniki (mgr inż. elektroniki i telekomunikacji) oraz Wydziału Cybernetyki (mgr inż. informatyk) Wojskowej Akademii Technicznej w Warszawie. Działalność naukowa autora obejmuje w głównej mierze obszary cyfrowego przetwarzania sygnałów, ze szczególnym uwzględnieniem procesu ekstrakcji deskryptorów przy użyciu dyskretnej dekompozycji falkowej oraz klasyfikacji przy użyciu sieci wektorów podtrzymujących. Prowadzone badania mają na celu opracowanie mobilnego detektora upadków.



e-mail: bwojtowicz@wat.edu.pl

Dr hab. inż. Andrzej P. DOBROWOLSKI

Pełni funkcje prodziekana ds. naukowych Wydziału Elektroniki Wojskowej Akademii Technicznej oraz Kierownika Studiów Doktoranckich, jest wykładowcą przedmiotów Technika obliczeniowa i symulacyjna oraz Układy analogowe. Jego zainteresowania naukowe koncentrują się na cyfrowym przetwarzaniu sygnałów biomedycznych oraz identyfikacji osób w oparciu o biometryczne cechy sygnału mowy. Jest autorem i współautorem wielu artykułów naukowych oraz podręczników i skryptów akademickich.



e-mail: adobrowolski@wat.edu.pl

### Streszczenie

W artykule zaprezentowano wyniki badań opracowanego mechanizmu detekcji upadków. Wysoką niezawodność oraz niski poziom fałszywych alarmów uzyskano w wyniku zastosowania czterech niezależnych sensorów różnych wielkości fizycznych oraz wyrafinowanych metod przetwarzania sygnałów i eksploracji danych. Przeprowadzone badania pozwalają na stwierdzenie, że pominięcie znaku deskryptorów znacznie poprawia skuteczność prawidłowej klasyfikacji upadków. Z tego powodu w dalszych pracach zostanie przyjęty algorytm wykorzystujący wartości bezwzględne wyznaczonych cech. W trakcie badań zaobserwowano, że zwiększanie liczby cech użytych w procesie uczenia oraz testowania nie prowadzi do zwiększenia jakości klasyfikacji. Wynika stąd potrzeba dobrania optymalnej liczby deskryptorów. Dlatego istotnym warunkiem poprawy skuteczności systemu jest przeprowadzenie właściwej selekcji cech, co jest głównym celem kolejnego etapu badań.

**Słowa kluczowe:** detekcja upadków, fuzja sensoryczna, sieć wektorów podtrzymujących.

### A multisensor fall detector using the discrete wavelet decomposition and SVM classifier

#### Abstract

The paper presents the results of research on a fall detection algorithm. The high reliability and a low level of false alarms were obtained by the use of four independent sensors of various physical quantities as well as sophisticated methods of signal processing and data mining. The algorithm was implemented and tested in Matlab. It was based on the discrete wavelet transform and a support vectors machine. The source of the data was processed by the detector presented in [5, 6]. The device integrates four MEMS sensors. It includes an atmospheric pressure sensor and three triaxial sensors, such as an accelerometer, a gyroscope and a magnetometer. The signal from each of the available sensors was sampled at a frequency of 25 Hz. The processed and analyzed frame had the length of 100 samples, which equaled four-second registration. The scheme of the measurement system is shown in Figure 3. The obtained findings were the basis for the presentation of each sensor in the field of ROC curves in two variants (taking into account an extracted feature with the sign and with its omission). Definitely, better results were obtained using the absolute values of the descriptors in the process of learning/testing. The best results of fall detection were received for a gyroscope and an accelerometer, followed by a magnetometer and a barometric pressure sensor. From the studies one can draw a conclusion that the omission of the sign descriptors significantly improves the correct classification of falls. For this reason, in further work there will be adopted an algorithm using the absolute values of extracted features. During the study it was observed that the increase in the number of features used in learning and testing did not lead to the increase in the quality of classification. This calls for the selection of the optimum number of descriptors. Therefore, an important prerequisite to improve the efficiency of the system is a proper feature selection, which is the main objective of the next stage of investigations. In further research, we plan to implement the data fusion algorithm in order to increase the effectiveness of the mechanisms developed.

**Keywords:** fall detection, data fusion, support vector machine.

### 1. Wstęp

Starzenie się społeczeństw jest powszechnym problemem współczesnego świata. W Polsce w 2000 roku osoby w wieku powyżej 65 lat stanowiły 12,3% populacji, ale już w 2010 roku grupa w wieku poprodukcyjnym stanowiła 17% populacji. Wg danych GUS z roku 2010, średnia długość życia Polaków wynosiła 72,1 lat dla mężczyzn i 80,6 lat dla kobiet, ale prognozy demograficzne wskazują, że do 2035 r. przeciętna długość życia wzrośnie o ok. 8 lat dla mężczyzn oraz o 3 lata dla kobiet [1]. Według statystyk Światowej Organizacji Zdrowia wskaźniki niesprawności wykazują znaczną korelację z wiekiem. Problemy z samodzielnością, codzienną egzystencją stwierdza się u ponad 30% osób w wieku powyżej 75 lat i aż u 70% osób w wieku powyżej 85 lat [2].

Innym niebezpiecznym zjawiskiem jest singularyzacja czyli coraz częstsze samotne zamieszkiwanie osób starszych, spowodowane głównie śmiercią współmałżonka. W 2030 roku 53% gospodarstw będzie prowadzonych przez samotne osoby w wieku co najmniej 65 lat, w tym 17% przez osoby w wieku powyżej 80 lat [1]. Singularyzacja oraz częste występowanie chorób sercowo-naczyniowych, kostno-stawowych oraz zaburzeń funkcji poznawczych wśród osób w wieku podeszłym stwarzają ryzyko istotnego opóźnienia w rozpoczęciu procedur terapeutycznych w przypadku wystąpienia stanu zagrożenia życia w warunkach pozaszpitalnych. Jest to spowodowane niewystarczającą komunikacją między osobami starszymi a rodziną, opiekunami lub placówkami medycznymi oraz zbyt późnym wszczęciem procedur alarmowych i ratunkowych. Zbyt późne rozpoczęcie leczenia prowadzi do istotnie mniejszej efektywności terapeutycznej i większego ryzyka zgonu spowodowanego urazami, do których dochodzi wskutek upadków.

Co trzecia osoba po 65 roku życia jest narażona na upadek przynajmniej raz w roku, i – co może zaskakiwać – aż pięć razy więcej pacjentów trafia do szpitali po upadkach niż po wypadkach drogowych. Do większości upadków dochodzi w domu lub koło domu (80% w grupie wiekowej 85-89 lat) [3].

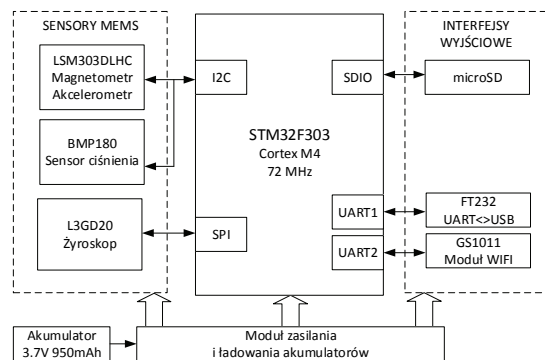
Upadki mogą być spowodowane wieloma przyczynami, najczęściej są to: czynniki zewnętrzne (31%), zaburzenia chodu i równowagi, zasłabnięcie lub napady padaczkowe (25%), zawroty głowy (13%) [4]. Samotne zamieszkiwanie w naturalnym środowisku, poprzednie epizody upadków, niesprawność psychofizyczna, choroby przewlekłe, efekty uboczne farmakoterapii, to kolejne istotne czynniki w upadkach geriatrycznych. Zmiany wzorca chodu (niepewny drobny krok bez odrywania podeszwy od podłoża), stan układu sercowo-naczyniowego i oddechowego, labilny mechanizm kompensacyjny podczas przemieszczania się w środowisku naturalnym stanowią kolejne czynniki zagrożenia upadkiem. Hipotonia ortostatyczna (objawowy spadek ciśnienia tętniczego) związana ze zmianą pozycji ciała, powodująca gwałtowny spadek ciśnienia o 20 mm Hg, prowadzi do zasłabnięcia lub zaburzeń równowagi i w efekcie niekontrolowany upadek podczas

dynamicznej zmiany pozycji ciała. Badania wskazują, że taka sytuacja dotyczy około 17-20% pacjentów poddanych hospitalizacji i około 33% osób mieszkających samotnie w środowisku naturalnym. Głównym następstwem upadku jest uraz czaszkowo-mózgowy lub złamanie w obrębie dużych stawów i kości długich. Odsetek zgonów będących następstwem upadków wzrasta wykładniczo z wiekiem niezależnie od płci. W grupie osób powyżej 75 roku życia stanowi 70% zgonów. Badania wskazują, że osoby, które doznały upadku z urazem w domu i nie otrzymały pomocy medycznej w ciągu pierwszej godziny umierają zwykle w ciągu kolejnych sześciu miesięcy.

Przedstawione przesłanki zmotywowały autorów do opracowania ergonomicznego i niezawodnego detektora upadków z zaimplementowaną funkcją alarmowania wybranego centrum pomocy medycznej, rodziny, znajomych bądź sąsiadów. W celu zapewnienia wysokiej niezawodności oraz niskiego poziomu fałszywych alarmów zastosowano niezależne sensory czterech różnych wielkości fizycznych oraz wyrafinowane metody przetwarzania sygnałów i eksploracji danych, opisane w kolejnych rozdziałach.

## 2. Detektor upadków

Źródłem przetwarzanych danych jest specjalnie do tego celu zaprojektowany detektor zaprezentowany w [5, 6]. Urządzenie integruje w sobie cztery sensory MEMS, w skład których wchodzi czujnik ciśnienia atmosferycznego oraz trzy sensory trójosiowe, tj. akcelerometr, żyroskop i magnetometr. Zbudowany detektor jest praktyczną realizacją sensora o dziesięciu stopniach swobody, tzw. 10 DOF (ang. *Degrees Of Freedom*). Schemat blokowy urządzenia zaprezentowano na rys. 1.



Rys. 1. Schemat blokowy sensora  
Fig. 1. Block diagram of the sensor

Podstawowym elementem układu jest 32-bitowy mikrokontroler STM32F303 z rdzeniem CortexM4, taktowany zegarem o częstotliwości 72 MHz. Komunikacja pomiędzy sensorami MEMS a mikrokontrolerem odbywa się za pośrednictwem szeregowych magistrali SPI oraz I2C. Układ L3GD20 (żyroskop) komunikuje się z mikrokontrolerem za pośrednictwem magistrali SPI. Pozostałe sensory, LSM303DLHC (zintegrowany akcelerometr i magnetometr) oraz BMP180 (sensor ciśnienia atmosferycznego) wykorzystują do tego celu magistralę I2C.


Urządzenie posiada możliwość rejestrowania danych z dostępnych sensorów na karcie pamięci microSD bądź przesyłania ich w czasie rzeczywistym za pośrednictwem sieci WIFI lub przy pomocy portu USB, pracującego w trybie wirtualnego portu szeregowego.

Detektor zasilany jest przy użyciu akumulatora o pojemności 950 mAh i napięciu 3,7 V. Dodatkowo urządzenie posiada zintegrowany moduł ładowania akumulatora za pośrednictwem portu USB.

## 3. Przeprowadzone badania

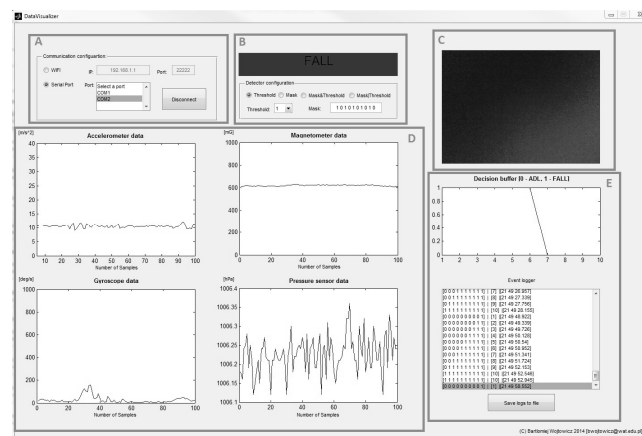
Przy pomocy elastycznego pasa, na klatce piersiowej monitorowanej osoby umieszczono detektor. Komunikacja pomiędzy urządzeniem a komputerem odbywała się za pośrednictwem sieci WIFI. Kolekcjonowane dane dla różnych aktywności (upadków

oraz czynności życia codziennego) przetwarzano następnie w środowisku Matlab. Sygnał z każdego z dostępnych sensorów próbkowano z częstotliwością 25 Hz. Przetwarzana i analizowana ramka miała długość 100 próbek, co odpowiada czterem sekundom rejestracji. Schemat systemu pomiarowego zaprezentowano na rys. 2.



Rys. 2. Schemat systemu pomiarowego  
Fig. 2. Scheme of the measurement system

Na potrzeby analizy i wizualizacji danych pochodzących z sensorów detektora, powstała aplikacja, której widok zaprezentowano na rys. 3.



Rys. 3. Aplikacja do akwizycji danych zbudowanego detektora  
Fig. 3. Application for data acquisition from the designed detector

Aplikacja powstała w środowisku Matlab. Można w niej wyróżnić 5 podstawowych elementów oznaczonych na rys. 3 literami A, B, C, D i E. Literą A oznaczono fragment okna odpowiedzialnego za wybór sposobu połączenia z detektorem: za pomocą sieci bezprzewodowej WIFI lub za pośrednictwem połączenia przez port szeregowy. Obszar oznaczony literą B prezentuje wynik procesu klasyfikacji rejestrowanego zdarzenia oraz konfigurację algorytmu detekcji upadków: ustalanie wartości progowej wystąpienia określonej liczby upadków w buforze decyzyjnym i/lub ustawienie maski bufora klasyfikacji. Dodatkowo aplikacja prezentuje w trybie online widok z dołączonej do komputera kamery (C) oraz pozwala na wizualizację danych z poszczególnych sensorów detektora (D). Sekcja oznaczona literą E prezentuje aktualny stan bufora klasyfikacji oraz listuje zdarzenia zaklasyfikowane, jako upadek, pozwalając na zapis tych danych do pliku.

Pierwszy etap badań polegał na rejestracji 50 ramek stanowiących zbiór sygnałów uczących, spośród których połowa stanowiła rejestrację różnorodnych upadków (ang. *Fall* – upadek), a pozostałe odpowiadały aktywnościom dnia codziennego *ADL* (ang. *Activity Daily Living*). Działanie opracowanych mechanizmów detekcji upadków zweryfikowano przy użyciu 25 rejestracji upadków i 40 rejestracji *ADL*.

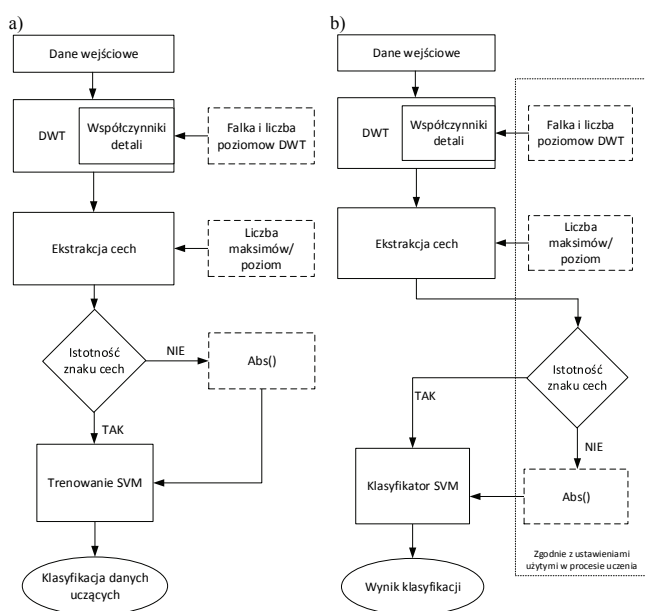
## 4. Ekstrakcja cech oraz detekcja upadków

Opracowany mechanizm ekstrakcji deskryptorów (rys. 4) opiera się na dyskretnej transformacji falkowej DWT (ang. *Discrete Wavelet Transform*). W wielokrotnym procesie iteracyjnym dobrano rodzaj

falki, liczbę poziomów dekompozycji oraz wymaganą liczbę deskryptorów przypadającą na każdy z poziomów DWT. Operację tę wykonano osobno dla każdego dostępnego w detektorze sensora MEMS. Współrzędne wektora cech zdefiniowano jako maksymalne wartości współczynników detali DWT, przy czym ich liczba została wyznaczona indywidualnie dla każdego z poziomów transformacji.

W roli klasyfikatora zastosowano liniową sieć wektorów podtrzymujących SVM (ang. *Support Vector Machine*). Na rys. 4a zaprezentowano schemat blokowy procesu ekstrakcji cech oraz uczenia sieci SVM. W ramach przeprowadzonych badań założono dwa scenariusze: sieć trenowana i testowana przy użyciu wektorów cech z uwzględnieniem znaku oraz bez jego uwzględniania.

Algorytm detekcji upadków, przedstawiony na rys. 4b, jest odzwierciedleniem konfiguracji zastosowanej w przypadku uczenia sieci SVM. Wyznaczone w sposób analogiczny deskryptory trafiają do wytrenowanej sieci wektorów podtrzymujących, która odpowiada za prawidłową klasyfikację danej aktywności.



Rys. 4. Proces ekstrakcji deskryptorów i uczenia sieci SVM (a) oraz schemat blokowy procesu detekcji upadków (b)

Fig. 4. SVM training process and feature extraction (a) as well as the block diagram of uncontrolled fall detection (b)

## 5. Rezultaty

W tab. 1 zaprezentowano wyznaczone w iteracyjnym procesie optymalizacji parametry konfiguracyjne procesu ekstrakcji cech, dla każdego z dostępnych sensorów. Stanowią one najlepsze rezultaty uzyskane poprzez manipulację typami standardowych falek oraz liczbą maksymalnych współczynników detali DWT. Zbiór sygnałów uczących i testujących stanowiły rejestracje o długości 100 próbek, a zdarzenie upadku występowało w połowie analizowanych ramek. Sensory oznaczono kolejno skrótami: ACC – akcelerometr, GYR – żyroskop, MAG – magnetometr, PRESS – czujnik ciśnienia atmosferycznego.

Tab. 1. Wyznaczone parametry konfiguracyjne procesu ekstrakcji cech  
Tab. 1. Determined configuration parameters of the feature extraction process

Sensor	Falka	Liczba poziomów dekompozycji	Liczba maksimów wsp. detali/poziom [p <sub>1</sub> p <sub>2</sub> p <sub>3</sub> p <sub>4</sub> p <sub>5</sub> ]
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]

W tab. 2 zaprezentowano rezultaty klasyfikacji opracowanych mechanizmów dla danych z poszczególnych sensorów. Przeprowadzono

badania w dwóch wariantach: uwzględniające znak cech oraz operujące na wartościach bezwzględnych deskryptorów.

Tab. 2. Rezultat klasyfikacji na podstawie danych z dostępnych sensorów  
Tab. 2. The result of the classification based on the data from available sensors

Istotność znaku cech	Dane	FALL/ADL	Poprawnie klasyfikowanych			
			ACC	ACC	ACC	ACC
TAK (ORG)	Uczące	ADL	21/25	21/25	21/25	21/25
		FALL	21/25	21/25	21/25	21/25
	Testujące	ADL	33/40	33/40	33/40	33/40
		FALL	17/25	17/25	17/25	17/25
NIE (ABS)	Uczące	ADL	25/25	25/25	25/25	25/25
		FALL	25/25	25/25	25/25	25/25
	Testujące	ADL	40/40	40/40	40/40	40/40
		FALL	25/25	25/25	25/25	25/25

Kolejnym etapem badań było określenie wpływu umiejscowienia zdarzenia upadku w analizowanej ramce na skuteczność procesu klasyfikacji. Do tego celu użyto wszystkie zarejestrowane sygnały trenujące oraz testujące, tj. 115 sygnałów (50 FALL, 65 ADL) o długości 150 próbek, gdzie upadek występował w połowie ramki. Następnie w wyniku zastosowania prostokątnego ruchomego okna o długości 100 próbek, przesuwanego z krokiem 10 próbek (SHIFT), uzyskano 690 (300 FALL, 390 ADL) rejestracji z różną lokalizacją zdarzenia upadku w analizowanej ramce. Rezultaty tych badań zaprezentowano w tab. 3.

Tab. 3. Rezultaty klasyfikacji uwzględniające różne położenie upadku w analizowanej ramce

Tab. 3. The results of the classification taking into account the different fall position in the analyzed frame

Sensor	Istotność znaku cech	NIE (ABS)					
		Shift					
		0	10	20	30	40	50
Akcelerometr	Błędnych klasyfikacji upadku (Total=50)	3	7	0	0	0	5
	Błędnych klasyfikacji ADL (Total=65)	0	2	0	1	1	0
Żyroskop	Błędnych klasyfikacji upadku (Total=50)	4	1	2	1	1	1
	Błędnych klasyfikacji ADL (Total=65)	0	1	0	2	1	2
Magnetometr	Błędnych klasyfikacji upadku (Total=50)	16	16	17	16	16	17
	Błędnych klasyfikacji ADL (Total=65)	2	5	4	2	3	3
Sensor ciśnienia	Błędnych klasyfikacji upadku (Total=50)	43	45	35	12	3	11
	Błędnych klasyfikacji ADL (Total=65)	2	7	6	5	8	7

Sensor	Istotność znaku cech	TAK (ORG)					
		Shift					
		0	10	20	30	40	50
Akcelerometr	Błędnych klasyfikacji upadku (Total=50)	19	21	10	28	33	27
	Błędnych klasyfikacji ADL (Total=65)	11	12	10	13	10	11
Żyroskop	Błędnych klasyfikacji upadku (Total=50)	15	40	20	12	40	30
	Błędnych klasyfikacji ADL (Total=65)	4	9	8	8	7	10
Magnetometr	Błędnych klasyfikacji upadku (Total=50)	39	32	32	39	37	32
	Błędnych klasyfikacji ADL (Total=65)	4	6	3	7	3	3
Sensor ciśnienia	Błędnych klasyfikacji upadku (Total=50)	26	24	26	24	37	30
	Błędnych klasyfikacji ADL (Total=65)	17	31	27	24	29	28

Uzyskane wyniki pozwalają na stwierdzenie, że pominięcie znaku deskryptorów, zarówno w procesie uczenia jak i testowania, znacznie lepsza skuteczność detekcji upadków. Należy zauważyć również,

że opracowany algorytm jest niewrażliwy na umiejscowienie upadku w analizowanej ramce dla akcelerometru, żyroskopu i magnetometru.

Do oceny jakości klasyfikatora zastosowano 3 podstawowe miary:

- a) Czułość (ang. *Sensitivity* – *SE*) – określa stosunek liczby prawidłowo wykrytych upadków *TP* (ang. *True Positive*) do liczby wszystkich upadków, czyli sumy prawidłowo wykrytych upadków *TP* i niewykrytych upadków *FN* (ang. *False Negative*)

$$SE = \frac{TP}{TP + FN} \quad (1)$$

- b) Specyficzność (ang. *Specificity* – *SP*) – określa stosunek liczby prawidłowo wykrytych aktywności dnia codziennego *TN* (ang. *True Negative*) do liczby wszystkich aktywności dnia codziennego, czyli do sumy prawidłowo wykrytych aktywności dnia codziennego *TN* i fałszywych alarmów (aktywności nie będących upadkami zaklasyfikowanych fałszywie jako upadki) *FP* (ang. *False Positive*)

$$SP = \frac{TN}{TN + FP} \quad (2)$$

Na podstawie znajomości specyficzności można wyznaczyć prawdopodobieństwo fałszywego alarmu  $PFA = 1 - SP$ .


- c) Błąd całkowity (ang. *Total Error* – *TE*) – określa tzw. zdolność dyskryminacyjną klasyfikatora i definiuje się go, jako stosunek liczby błędnych klasyfikacji do wszystkich badanych przypadków

$$TE = \frac{FP + FN}{TP + TN + FP + FN} \quad (3)$$

Znajomość wartości *TE* pozwala na obliczenie prawdopodobieństwa poprawnej klasyfikacji zdarzeń z obu klas i określa się wzorem  $PPA = 1 - TE$ .

Tab. 4. Miary oceny jakości klasyfikatorów  
Tab. 4. Measures of quality assessment of classifiers

Istotność znaku cech	Sensor	SE	SP	TE
TAK (ORG)	Akcelerometr	0,540	0,828	0,297
	Żyroskop	0,477	0,882	0,294
	Magnetometr	0,297	0,938	0,341
	Sensor ciśnienia	0,443	0,600	0,468
NIE (ABS)	Akcelerometr	0,950	0,990	0,028
	Żyroskop	0,967	0,985	0,023
	Magnetometr	0,673	0,951	0,170
	Sensor ciśnienia	0,503	0,910	0,267



Rys. 5. Położenie poszczególnych czujników w polu krzywych ROC  
Fig. 5. Location of particular sensors in the field of ROC curves

Obliczone miary oceny jakości klasyfikatorów wynikające bezpośrednio z danych zawartych w tab. 3, zaprezentowano w tab. 4.

Otrzymane wyniki stały się podstawą do przedstawienia każdego z sensorów w polu krzywych *ROC* (ang. *Receiver Operating Characteristics*) w dwóch wariantach (uwzględnienie znaku cech oraz jego pominięcie) [7], co zobrazowano na rys. 5. Należy zauważyć, iż im bliżej lewego narożnika znajduje się punkt reprezentujący dany sensor, tym proces wykrywania upadków jest skuteczniejszy.

lepiej rezultaty uzyskano stosując wartości bezwzględne deskryptorów w procesie uczenia/testowania. Najlepsze właściwości detekcyjne posiadają kolejno: żyroskop, akcelerometr, a następnie magnetometr i sensor ciśnienia atmosferycznego, pozwalający na wyznaczenie zmiany wysokości sensora.

## 6. Podsumowanie

Na podstawie przeprowadzonych badań można stwierdzić, że pominięcie znaku deskryptorów znacznie poprawia skuteczność prawidłowej klasyfikacji upadków. Z tego powodu w dalszych pracach zostanie przyjęty algorytm wykorzystujący wartości bezwzględne wyznaczanych cech.

Dla opracowanego algorytmu najlepsze właściwości detekcyjne posiada żyroskop oraz akcelerometr, a w dalszej kolejności magnetometr i sensor ciśnienia atmosferycznego. W dalszych badaniach autorzy planują dokonać fuzji danych sensorycznych w celu zwiększenia skuteczności opracowanych mechanizmów.

W trakcie badań zaobserwowano, że zwiększanie liczby cech użytych w procesie uczenia oraz testowania nie prowadzi do zwiększenia jakości klasyfikacji. Wynika stąd potrzeba dobrania optymalnej liczby deskryptorów. Spowodowane jest to między innymi faktem, że w zbiorze wyznaczonych cech mogą znajdować się cechy mające postać szumu pomiarowego [8, 9]. Dlatego istotnym warunkiem poprawy skuteczności systemu jest przeprowadzenie właściwej selekcji cech, co jest głównym celem kolejnego etapu badań.

## 7. Literatura

- [1] Rządowy program na rzecz aktywności społecznej osób starszych na lata 2012-2013, Załącznik do uchwały nr 137 Rady Ministrów z dnia 24.08.2012 r.
- [2] Kachaniuk H.: Opieka nad zdrowiem osób starszych, rozdział w monografii „Zdrowie Publiczne” pod red. T. Kulik i M. Latalskiego, Lublin, 2002; s. 293-309.
- [3] Edbom-Kolarz A., Marcinkowski J.T.: Upadki osób starszych – przyczyny, następstwa, profilaktyka, *Hygeia Public Health*, v. 46 (3), 2011, s. 313-318.
- [4] Rubenstein L. Z., Josephson K. R.: Fall risk assessment: step-by-step, rozdział w monografii „Gait disorders: evaluation and management” pod red. J. M. Hausdorffa i N. B. Alexandra, Taylor & Francis, 2005; s. 169-184.
- [5] Wójtowicz B., Dobrowolski A.: Projekt integratora danych sensorycznych do detekcji niekontrolowanych upadków, *Biuletyn WAT*, Vol. LXII, Nr 4, Warszawa 2013.
- [6] Wójtowicz B., Dobrowolski A.: Bezprzewodowy detektor upadków, *Elektronika: konstrukcje, technologie, zastosowania*, Vol. LV, Nr 3/2014, Warszawa, s. 72-75.
- [7] Smith S.: Cyfrowe przetwarzanie sygnałów. Praktyczny poradnik dla inżynierów i naukowców, Wydawnictwo BTC, 2007.
- [8] Osowski S., Markiewicz T., Kruk M., Kozłowski W.: Metody sztucznej inteligencji do wspomagania diagnostyki patologii tkanek, rozdział w monografii „Metrologia w medycynie – wybrane zagadnienia” pod red. A. Michalskiego, Redakcja Wydawnictw WAT, Warszawa, 2011, s. 91-126.
- [9] Osowski S.: Metody i narzędzia eksploracji danych. Wydawnictwo BTC, 2013.

otrzymano / received: 12.06.2014

przyjęto do druku / accepted: 01.08.2014

artykuł recenzowany / revised paper