

## ROZPOZNAWANIE KATEGORII RUCHU LUDZKIEGO NA PODSTAWIE ANALIZY SYGNAŁÓW POCHODZĄCYCH Z TRÓJOSIOWYCH CZUJNIKÓW PRZYSPIESZENIA

Adam KUPRYJANOW<sup>1</sup>, Katarzyna KASZUBA<sup>2</sup>

### 1. Miejsce pracy:

Wydział Elektroniki, Telekomunikacji i Informatyki

Katedra Systemów Multimedialnych

tel:0-58-347-19-67 fax:0-58-347-11-14 e-mail: adamq@sound.eti.pg.gda.pl<sup>1</sup>, katkasz@sound.eti.pg.gda.pl<sup>2</sup>

**Streszczenie:** W artykule przedstawiono procedurę rejestracji sygnałów przyspieszenia pochodzących z czujników biomedycznych Shimmer, sposób ich rozmieszczenia na ciele oraz opisano klasyfikator pozwalający na rozpoznawanie wybranych kategorii ruchu ludzkiego. W części eksperymentalnej artykułu zbadano wpływ filtracji dolnoprzepustowej sygnałów na skuteczność rozpoznawania typu aktywności ruchowej.

**Słowa kluczowe:** rozpoznawanie aktywności ruchowych, klasyfikacja sygnałów, czujniki przyspieszenia.

### 1. WPROWADZENIE

Dzięki bardzo szybkiemu rozwojowi mikrokontrolerów możliwe stało się stworzenie urządzeń rejestrujących oraz transmitujących sygnały z czujników przyspieszenia w czasie rzeczywistym. Miniaturyzacja umożliwiła umieszczenie czujnika przyspieszenia (akcelerometrów), mikroprocesora oraz nadajnika Bluetooth w urządzeniu o rozmiarze pudełka zapalek. Badania prowadzone przez firmę Intel doprowadziły do powstania platformy sprzętowo softwarowej dedykowanej do celów tworzenia sieci czujników komunikujących się ze sobą poprzez łączność radiową. Urządzenie wytworzone w celu pracy na tej platformie nazwano Shimmer. Niewielkie rozmiary i waga urządzeń oraz niskie zużycie energii pozwala na zamontowanie go na ludzkim ciele w taki sposób, który nie jest uciążliwy w życiu codziennym [1].


Jak pokazały badania wielu grup badawczych [2-5], na podstawie analizy sygnałów pochodzących z trójosiowych czujników przyspieszenia możliwe jest rozróżnienie wielu kategorii ruchu ciała ludzkiego. W wielu dziedzinach nauki oraz medycyny istotne jest posiadanie informacji dotyczącej stanu aktywności osoby obserwowanej. Analiza przyspieszenia pozwala na automatyczne odróżnienie takich czynności jak: chodzenie, bieganie, wstawanie z krzesła (siadanie), kładzenie się na łóżko (wstawanie), podnoszenie przedmiotów oraz wykrywanie upadków pacjentów [2-5]. W tym artykule opisano klasyfikatory służące do rozpoznawania dwóch typów aktywności: chodzenie oraz podnoszenie przedmiotów. Opisany moduł rozpoznawania kategorii aktywności ruchowej jest częścią systemu nadzorowania osób chorych na chorobę Parkinsona. System

ten jest tworzony w ramach Europejskiego projektu PERFORM [6-7].

### 2. REJESTRACJA SYGNAŁÓW PRZYSPIESZENIA

Wykorzystane w procesie rejestracji sygnału urządzenia (Shimmer) były wyposażone w trójosiowe czujniki przyspieszenia. Urządzenia te umożliwiały rejestrację sygnałów poprzez transmisję Bluetooth oraz poprzez zapis sygnałów na kartach MicroSD [1]. Przeprowadzone badania pokazały, że rejestracja sygnału z wykorzystaniem łączności bezprzewodowej powoduje utratę fragmentów sygnału.

Podczas eksperymentów sygnału rejestrowane były z wykorzystaniem kart pamięci. Ten tryb pracy umożliwił rejestrację sygnału z częstotliwością 51,2 Hz, zakres dynamiki ruchu wynosił  $\pm 4$  g. Pozwalało to na prawidłową rejestrację typowych aktywności ruchowych. Synchronizacja czujników wykonywana była poprzez automatyczne zsynchronizowanie każdego urządzenia z zegarem komputera uruchamiającego proces rejestracji na karcie pamięci.



Rys. 1. Sposób rozmieszczenia czujników przyspieszenia.

Sposób rozmieszczenia czujników dobrano tak, aby wykorzystując jak najmniejszą liczbę urządzeń uzyskać jak najwyższą skuteczność rozpoznawania wymaganych kategorii ruchu [8]. W procesie rejestracji użyto pięciu urządzeń rozmieszczonych w następujący sposób: dwa akcelerometry umieszczone na nadgarstkach, dwa na kostkach i jeden na klatce piersiowej. Na rysunku 1 przedstawiono rozmieszczenie czujników przyspieszenia na ciele człowieka oraz zwrot trzech osi pomiaru wartości przyspieszenia.

Rejestracja sygnałów użytych do trenowania i testowania skuteczności klasyfikatorów została wykonana zgodnie z wcześniej ustalonym protokołem. Każda osoba biorąca udział w nagraniu miała za zadanie wykonać sekwencję określonych ruchów. Sekwencje zawierały następujące kategorie ruchu: siadanie i wstawanie z krzesła, chodzenie, bieganie, chodzenie po schodach, podnoszenie przedmiotu jedną lub obiema rękoma, kładzenie się na łóżku i wstawanie z łóżka. Wszystkie osoby musiały wykonać daną sekwencję ruchów trzykrotnie.

Na rysunku 2 przedstawiono schemat sekwencji ruchu dla dwóch kategorii ruchu (chód, ruch rąk). Można zaobserwować, że sekwencja ruchu wykonywana dla kategorii chód składała się z trzykrotnie powtórnego chodu rozdzielonego 10 s momentami stania bez ruchu. Taki podział sekwencji umożliwił jednoznaczne wycięcie z sygnału jednej kategorii ruchu oraz zwielokrotnienie ilości ruchu należącego do danej kategorii (jedna osoba wykonywała chód dziewięciokrotnie).



Rys. 2. Schemat sekwencji ruchu

Wszystkie sygnały zostały zarejestrowane na grupie zdrowych osób. Średnia wieku wyniosła  $25 \pm 2.9$  lat. Grupa testowa składała się z 16 osób (2 kobiety/14 mężczyzn). Każda z osób wykonywała aktywności zapisane w protokole przez około 20 minut. Co dało 320 minut nagrań.

### 3. ROZPOZNAWANIE KATEGORII RUCHU

Zarejestrowane sygnały zostały pocięte na kategorie zawierające wyłącznie ruch wykonywany w ramach jednej z kategorii np. wyłącznie chód. Sygnały te zostały wykorzystane do trenowania oraz testowania klasyfikatora rozpoznawania kategorii ruchu. Klasyfikator został stworzony w oparciu o Sztuczne Sieci Neuronowe.

Sygnały z akcelerometrów były dzielone na ramki czasowe o długości 64 próbek (~1,24 s) z zakładką o długości 32 próbek (~0,62 s). Dla każdej z ramek obliczano zestaw parametrów, które podawane były na wejście klasyfikatora. Obliczane parametry można podzielić na dwie grupy: parametry czasowe, parametry częstotliwościowe.

Parametry czasowe obliczane dla sygnału po stronie czasowej:

- wartość średnia
- odchylenie standardowe
- kurtoza
- stosunek wartości szczytowej do wartości RMS

- współczynnik korelacji pomiędzy osiami akcelerometru
- współczynnik korelacji pomiędzy tymi samymi osiami różnych akcelerometrów np. wsp. korelacji pomiędzy osią X akcelerometrów z lewej nogi i prawej ręki

Parametry częstotliwościowe obliczane dla sygnału po stronie widmowej:

- energia
- entropia

W wyniku obliczenia wszystkich parametrów dla jednej ramki czasowej sygnału otrzymywano zbiór 135 parametrów.

Zaprojektowano i wytrenowano dwa niezależne klasyfikatory kategorii ruchowych. Zadaniem pierwszego z klasyfikatorów było wykrywanie chodu. W przypadku tego klasyfikatora zbiór uczący zawierał dwie kategorie ruchu: chód, brak chodu. W kategorii brak chodu znajdowały się wszystkie sygnały poza chodem czyli: siadanie i wstawanie z krzesła, kładzenie się i wstawanie z krzesła, podnoszenie przedmiotu, stanie bez ruchu, leżenie na łóżku, siedzenie na krześle.

Drugi klasyfikator miał za zadanie wykrywanie ruchu rąk. Zbiór uczący tego klasyfikatora zawierał cztery kategorie: ruch lewej ręki, ruch prawej ręki, ruch obu rąk oraz brak aktywności rąk. Podział sygnałów w ramach danej kategorii był analogiczny jak w przypadku klasyfikatora chodu.

Oba klasyfikatory posiadały taką samą strukturę sieci neuronowej (V). Warstwa wejściowa sieci składała się z 135 neuronów i była determinowana ilością parametrów obliczanych dla jednej ramki czasowej. Ilość neuronów w warstwie ukrytej obliczana była zgodnie ze wzorem:

$$n_{ukr} = \text{floor} \left( \frac{n_{wej}}{2} + n_{wyj} \right) \quad (1)$$

gdzie:  $n_{ukr}$  - liczba neuronów w warstwie ukrytej,  $n_{wej}$  - liczba neuronów w warstwie wejściowej,  $n_{wyj}$  - liczba neuronów w warstwie wyjściowej,  $\text{floor}$  oznacza zaokrąglenie wyniku do najbliższej wartości całkowitej poprzez usunięcie z wyniku części ułamkowej.

Warstwa wyjściowa w zależności od typu klasyfikatora składała się z 2 lub 4 neuronów.

Wyjścia sieci kodowane były w ten sposób, że wartość jeden przyjmowana była przez wyjście reprezentujące daną kategorię ruchu w momencie rozpoznania tej kategorii, a pozostałe wyjścia przyjmowały wartości zero. Podczas klasyfikacji binaryzacja wyjść wykonywana była następująco: maksymalnej wartości z wszystkich wyjść sieci przepisywano wartość 1 a wszystkim pozostałym wartościom przypisywano wartości 0.

### 4. EKSPERYMENTY

W tym rozdziale przedstawiono skuteczność klasyfikacji kategorii ruchowych. Sprawdzone także wpływ filtracji sygnałów przyspieszenia za pomocą filtrów dolnoprzepustowych oraz pasmowo przepustowych na wynik rozpoznania kategorii ruchowych. Filtracja może okazać się konieczna w przypadku rozpoznawania sygnałów pochodzących od osób z chorobą Parkinsona. Pozwoli ona

na usunięcie niepożądanych ruchów oraz zakłóceń wynikających z drżenia kończyn.

Zastosowano dwa rodzaje filtrów dolnoprzepustowych. Pierwszy o częstotliwości odcięcia 6 Hz oraz drugi o częstotliwości odcięcia 3 Hz. Częstotliwości odcięcia zostały dobrane w ten sposób, że pierwsza z nich reprezentowała zakres częstotliwości ruchów wykonywanych podczas czynności dnia codziennego. Druga częstotliwość została dobrana tak, aby usunąć drzenie kończyn występujące u osób chorych na chorobę Parkinsona.

W zależności od typu klasyfikatora zastosowano także dwa filtry usuwające lub pozostawiające składową stałą sygnału. Podczas klasyfikacji chodu wykorzystano filtr pasmowo przepustowy o paśmie od 0,5 Hz do 3 Hz. Zakres ten usuwał drzenie występujące u osób chorych oraz składową stałą, która mogła okazać się zbędna. W przypadku rozpoznawania ruchu rąk zastosowano filtr dolnoprzepustowy o częstotliwości odcięcia 0,5 Hz. Filtr ten pozostawiał jedynie składową stałą sygnału. Miało to na celu sprawdzenie czy możliwe jest rozpoznanie ruchu rąk poprzez analizę jedynie pozycji akcelerometrów (analizę składowej stałej).

Wszystkie wykorzystane filtry zostały zaprojektowane w programie Matlab jako filtry IIR, a filtracja wykonywana była z wykorzystaniem funkcji `filter` filtrującej sygnał w dwóch kierunkach (do przodu i od tyłu) w celu eliminacji opóźnienia grupowego wprowadzanego przez filtrację.

W tabeli 1 umieszczono skuteczność rozpoznawania kategorii chodu w zależności od rodzaju filtracji. Wszystkie rodzaje filtracji sygnału przyspieszenia umożliwiły klasyfikację aktywności z bardzo wysoką skutecznością bliską 100 %. Najwyższą skuteczność rozpoznawania chodu uzyskano dla filtracji filtrem z częstotliwością odcięcia równą 3 Hz. Skuteczność rozpoznawania braku chodu nie była najwyższą uzyskaną skutecznością podczas testów jednak wartość 99,96 % jest bardzo dobrym wynikiem. Usunięcie składowej stałej powodowało znaczące pogorszenie rozpoznawania chodu oraz w niewielkim stopniu wpływało na jakość rozpoznawania braku aktywności.

Tablica 1. Skuteczność rozpoznawania kategorii chodu w zależności od rodzaju zastosowanej filtracji

	filtr 6Hz		filtr 3Hz		filtr 0.5÷3Hz	
%	brak	chód	brak	chód	brak	chód
brak	99,99	0,01	99,96	0,04	99,83	0,17
chód	0,45	99,55	0,2	99,8	1,21	98,79

Tablica 2. Skuteczność rozpoznawania ruchu rąk dla filtracji dolnoprzepustowej z częstotliwością odcięcia 6 Hz

%	obie	lewa	brak	prawa
obie	<b>84,35</b>	0,48	8,51	6,67
lewa	0	<b>99,55</b>	0,45	0
brak	0,64	0,01	<b>99,07</b>	0,28
prawa	1,52	0	2,92	<b>95,55</b>

W drugiej części eksperymentu zbadano jakość rozpoznawania ruchu rąk. W tabelach 2-4 umieszczono wyniki klasyfikacji dla filtracji dolnoprzepustowej. Klasyfikator ruchu rąk nie pozwala na uzyskanie tak wysokiej skuteczności klasyfikacji co klasyfikator chodu. Najśląbiej rozpoznawaną aktywnością okazał się ruch obu rąk. Ruch lewą ręką oraz brak ruchu rąk rozpoznawano z bardzo dobrą skutecznością bliską lub przekraczającą 99 %.

Zauważono, że jakość rozpoznawania ruchu prawej ręki była niższa od jakości rozpoznawania ruchu lewej ręki. Z takim problemem zmagano się także podczas prac wykonywanych przez L. Bao [2]. Filtracja dolnoprzepustowa z wykorzystaniem filtru o częstotliwości odcięcia 3 Hz pozwoliła na uzyskanie najwyższej skuteczności rozpoznania ruchu prawej ręki.

Tablica 3. Skuteczność rozpoznawania ruchu rąk dla filtracji dolnoprzepustowej z częstotliwością odcięcia 3 Hz

%	obie	lewa	brak	prawa
obie	<b>81,35</b>	6,98	10,76	0,9
lewa	0	<b>99,31</b>	0,69	0
brak	0,64	0,24	<b>98,91</b>	0,21
prawa	0	0	2,83	<b>97,17</b>

Tablica 4. Skuteczność rozpoznawania ruchu rąk dla filtracji dolnoprzepustowej z częstotliwością odcięcia 0,5 Hz

%	obie	lewa	brak	prawa
obie	<b>83,43</b>	1,72	8,44	6,41
lewa	0,2	<b>96,63</b>	2,89	0,28
brak	0,51	0,18	<b>98,17</b>	1,14
prawa	0,57	0	6,41	<b>93,02</b>

## 5. PODSUMOWANIE

Uzyskane wyniki eksperymentów pozwalają wnioskować iż możliwe jest dokonanie klasyfikacji sygnałów przyspieszenia u osób z chorobą Parkinsona, ponieważ odfiltrowanie częstotliwości powyżej 3 Hz nie powoduje spadku skuteczności rozpoznawania aktywności chodu oraz ruchu rąk.

Obecnie do klasyfikacji wszystkich aktywności zostały użyte sygnały pochodzące z 5 akcelerometrów w przyszłych badaniach należy sprawdzić jaki wpływ ma zmniejszenie liczby czujników na wyniki skuteczność rozpoznawania różnych kategorii ruchu.

## 6. PODZIĘKOWANIA

Badania prowadzące do uzyskania tych wyników zostały sfinansowane przez Europejski siódmy program ramowy (FP7/2007-2013) w ramach umowy N° 215952 nazwanej: "PERFORM".

## 7. BIBLIOGRAFIA

1. Shimmer: Sensing Health with Intelligence Modularity, Mobility and Experimental Reusability. RealTime Technologies Manual, September 2008.
2. L. Bao, S. S. Intille, Activity Recognition from User-Annotated Acceleration Data, PERSASIVE 2004, LNCS 3001, pp. 1–17, 2004.
3. N. Ravi, N. Dandekar, P. Mysore, M. Littman, Activity Recognition from Accelerometer Data, Proceedings of the Seventeenth Conference on Innovative Applications of Artificial Intelligence (IAAI-05), pp. 1541-1546, 2005.
4. C. Lombriser, N. Bharatula, G. Troste, D. Roggen, On-body activity recognition in a dynamic sensor network, Proceedings of the ICST 2nd International Conference

- on Body Area Networks, Article No. 17, Florence, Italy, 2007.
5. S. W. Lee, K. Mase, Activity and Location Recognitions Using Wearable Sensors, *Pervasive Computing* July-September, pp. 24-32, 2002.
  6. D. Baga, D. I. Fotiadis, S. Konitsiotis, P. Maziewski, R. Greenlaw, D. Chaloglou, M. T. Arrendondo, M. G. Robledo, M. A. Pastor, PERFORM: Personalised Disease Management for Chronic Neurodegenerative Diseases: The Parkinson's Disease and Amyotrophic lateral Sclerosis Cases, *eChallenges e-2009 Conference*, 21-23 October 2009, Istanbul, Turkey.
  7. P. Maziewski, P. Suchomski, B. Kostek, A. Czyżewski, An Intuitive Graphical User Interface for the Parkinson's Disease Patients, *Proceedings of the 4th International IEEE EMBS Conference on Neural Engineering*, April 29 - May 2, 2009, Antalya, Turkey.
  8. U. Maurer, A. Smailagic, D. Siewiorek, M. Deisher, Activity Recognition an Monitoring Using Multiple Sensors on Different Body Positions

## HUMAN ACTIVITY RECOGNITION USING THE ACCELEROMETERS DATA ANALYSIS

**Key-words:** human activity recognition, signal classification, accelerometers

In many scientific fields, especially medicine, information about human activity is crucial. The analysis of acceleration data coming from the sensors mounted on human's limbs and trunk allows automatic classification of patients' activities (e.g. sitting, walking, getting up, etc). In this paper, a neural network based motion activity classifier and the procedure for recording signals from accelerometers are described.

Owing to a very fast development of microcontrollers, it is now possible to create devices which enable real-time recording and transmission of signals from accelerometers. Today's miniaturization enables the integration of accelerometers, microcontrollers and Bluetooth transmitters into a single matchbox-size device. Research carried out by Intel resulted in highly integrated devices and software platforms designed for networks of sensors which communicate wirelessly. Small size and weight of such devices as well as low energy consumption make the montage of sensors on a human body technically possible and comfortable for patients.

The research proved that the localization of sensors on a human body has a great impact on the accuracy of motion type recognition. Many experiments addressing this subject were conducted, and finally an optimal sensors configuration was chosen. A group of 16 healthy people was observed. The acceleration signals were sampled with the frequency of 51,2 Hz whereas the G force was set within the range of 0 to 4. The 64 sample windows with the 32 samples overlap were used for the analysis. For each window, a set of parameters was extracted, which allowed the classification of signals.

The research showed that the motion classifier based on neural networks ensures satisfying efficiency of motion type classification. Activity recognition was performed off-line. The accuracy of detection depended on the type of activity and the way the activity was performed. It turned out that for a better network training and testing, a greater number of signals must be collected.