

Alina MOMOT

Politechnika Śląska, Instytut Informatyki

Michał MOMOT, Roman SEREDYŃSKI, Arkadiusz STANKIEWICZ

Instytut Techniki i Aparatury Medycznej ITAM

WYKRYWANIE NAGŁYCH ZMIAN POŁOŻENIA CIAŁA LUDZKIEGO W SYSTEMACH NADZORU I OPIEKI TELEMEDYCZNEJ

Streszczenie. Artykuł przedstawia nową metodę wykrywania zmian w położeniu ludzkiego ciała, w szczególności upadków, na podstawie sygnałów odczytywanych z czujników umieszczonych na monitorowanej osobie. Przekształcenie sekwencji danych zebranych z czujników pozwala odróżnić upadek od normalnego ruchu. Opracowana metoda może być stosowana w domowych systemach nadzoru i opieki telemedycznej.

Słowa kluczowe: wykrywanie upadku, dane próbkowane nieregularnie, numeryczne różniczkowanie

DETECTION OF ABRUPT CHANGES OF HUMAN BODY POSITIONS WITH APPLICATION TO TELEMEDIC HOME CARE SYSTEMS

Summary. This paper presents new method to detect abrupt changes in the position of the human body, in particular falling, based on the signals acquired from sensors placed on the monitored person. The transformation of data sequence collected from sensors allows to distinguish between fall and normal movement. The method can be used in domestic telemedic systems.

Keywords: fall detection, irregular sampled data, numerical differentiation

1. Wprowadzenie

Telemedycyna, zwana również medycyną na odległość, jest pojęciem, które łączy w sposób harmonijny elementy telekomunikacji, informatyki oraz medycyny. Polega ona na wymianie informacji i danych, takich jak obrazy USG, MRI, sygnał EKG, pomiędzy różnymi „obiektami”, jakimi są pacjent, lekarz, klinika, szpital itp. Wykorzystanie nowoczesnych technologii, a także szybkich procesorów oraz algorytmów kompresji umożliwia przesyłanie obrazów o wysokiej rozdzielczości oraz prowadzenie interaktywnych transmisji audiowizualnych w czasie rzeczywistym.

Domowe systemy opieki telemedycznej są najszybciej rozwijającą się drogą nadzorowania lub monitorowania stanu zdrowia pacjenta, a także pomagają kontrolować postępy w rehabilitacji. Skutkuje to tworzeniem systemów wymiany danych (rozumianych jako transfer wyników badań) „od pacjenta do lekarza” w celu postawienia diagnozy, która jest również realizowana na odległość. Telemedycyna jest zatem bardzo ważna zarówno dla lekarza, jak i pacjenta. Z jednej strony, lekarz jest w stanie dostarczyć różne informacje na temat leczenia pacjenta nawet przy bardzo dużych odległościach fizycznych. Z drugiej strony, pacjent może wykonywać wszystkie potrzebne badania sam w domu i natychmiast przesłać je specjalistycznymi urządzeniami telemedycznymi do lekarza. Zatem ze stosowania tego systemu jest również zadowolony pacjent, który ze względu na stan zdrowia nie jest w stanie odbywać częstych wizyt u lekarza. Ponieważ telemedycyna staje się tak ważna i potrzebna, osoby projektujące systemy nadzoru i opieki telemedycznej starają się wprowadzić jak najwięcej nowych technologii, które są następnie wykorzystywane do poprawy leczenia. Powstają przy tej okazji również bazy danych gromadzące historię chorób, wyniki badań analitycznych, obrazowych, konsultacji oraz, w warunkach polskich, dane administracyjne związane z koniecznością rozliczeń świadczonych usług z Narodowym Funduszem Zdrowia [3].

Jako przykłady obszarów zastosowania technik telemedycznych można wskazać monitorowanie kobiet w ciąży [4] oraz opiekę domową nad osobami starszymi [1]. Ta ostatnia kwestia jest częścią obszaru zwanego życiem wspieranym (ang. *assisted living*). Zawiera on między innymi nadzór czynności życia codziennego, wysyłając sygnały alarmujące w przypadku pogorszenia zdrowia nadzorowanej osoby lub koordynacji opieki zdrowotnej. Wśród czynników, które mogą być monitorowane, znajdują się informacje na temat czynności związanych z poruszaniem się nadzorowanej osoby, w szczególności ważne jest wykrywanie sytuacji, które niosą podejrzenie upadku lub urazu.

Ilość informacji z działalności akwizycji danych nadzorowanych osób jest znaczna, co stwarza potrzebę opracowania metod do automatycznego wykrywania takich sytuacji. Przykładem mogą tu być metody wykorzystujące sieci bayesowskie [6] lub inne – bazujące na uczeniu maszynowym [7]. Typowe metody pozyskiwania danych dla tego typu algorytmów

to: monitoring wideo lub odczyt informacji o położeniu człowieka z czujników znajdujących się na jego ciele [12]. To drugie rozwiązanie, łącznie z wykorzystaniem transmisji bezprzewodowej, zapewnia uzyskanie dokładnej informacji o położeniu i pozycji ciała monitorowanej osoby.

W artykule przedstawiono propozycję przekształcenia sygnałów odczytanych z czujników położenia, aby jak najlepiej wydobyć informacje na temat możliwego upadku człowieka. Metoda ta opiera się na analizie przyspieszenia, które jest otrzymywane jako druga pochodna współrzędnych położenia. Nacisk położono tu na trudności związane z nierównym rozstawieniem czasów odczytów z poszczególnych czujników. W celu zmniejszenia negatywnych skutków tego zjawiska zaproponowano metodę numerycznego różniczkowania, która jest oparta na wielomianie aproksymacyjnym.

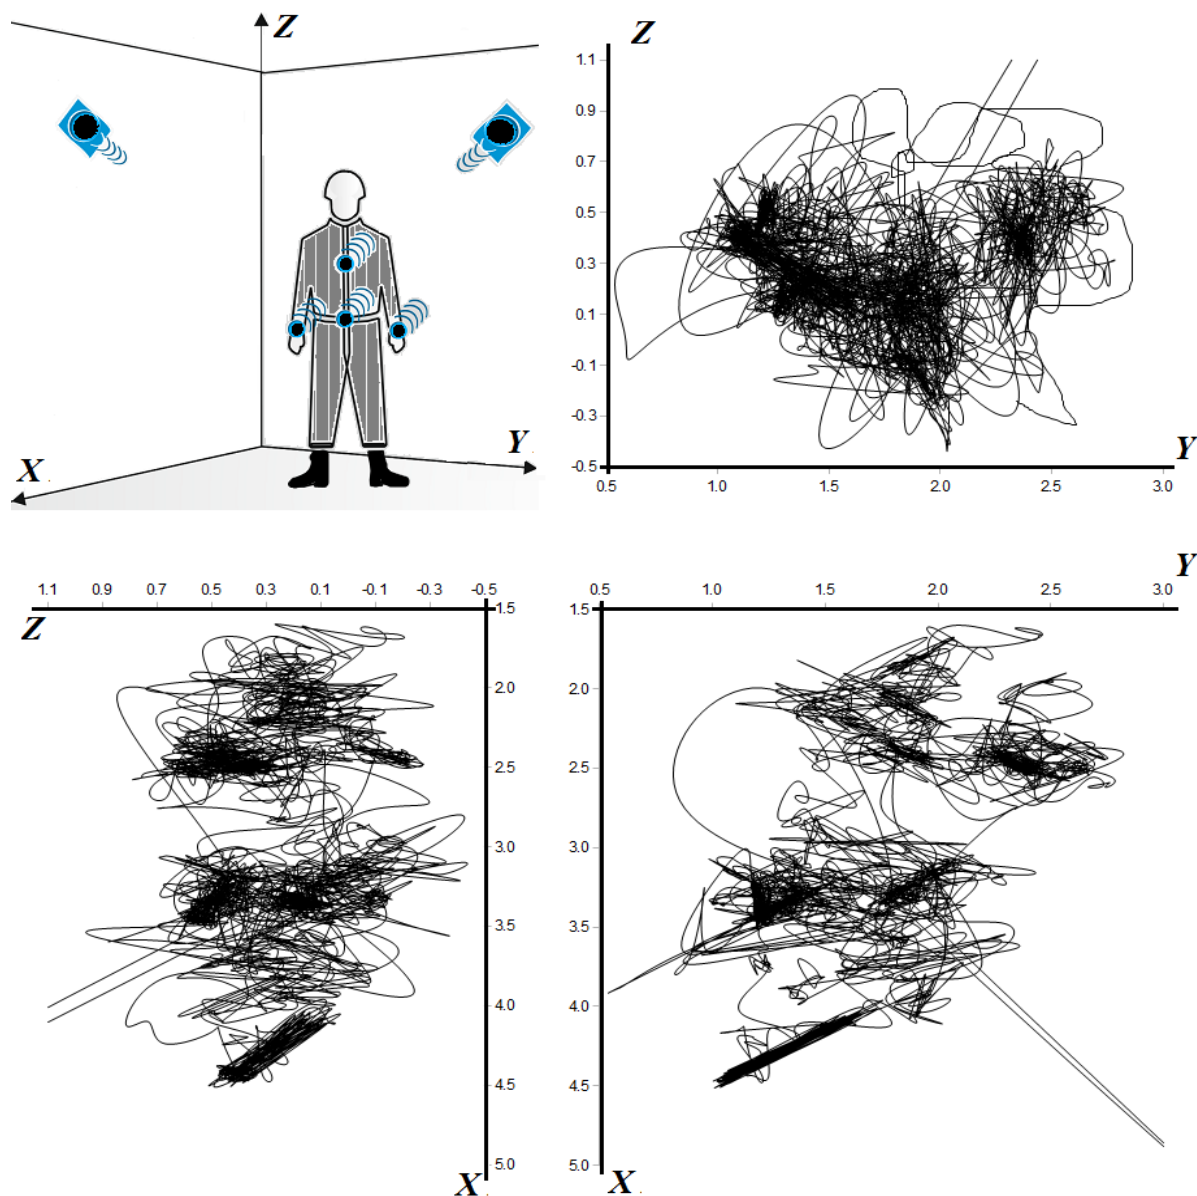
2. Metodologia

2.1. System monitorujący

Przykład typowego systemu monitorującego zmiany położenia ciała, wykorzystującego sygnały pochodzące z bezprzewodowych sensorów umieszczonych na monitorowanej osobie, przedstawia rysunek 1. Sensory mogą być umieszczone na różnych częściach ciała, typowe położenie sensorów to tułów, kończyny lub głowa. Zalecane jest jednak, aby położenie sensorów dobrać w taki sposób, aby jak najmniej ograniczyć codzienne czynności monitorowanej osoby. Artykuł [5] przedstawia system monitorowania ruchu składający się z czterech czujników o niewielkich rozmiarach, umieszczonych na nadgarstkach, klatce piersiowej i talii. Wykorzystano tu system lokalizacyjny Ubisense [9], który zapewnia dokładność pomiaru położenia czujnika rzędu 15 cm w 95% odczytów. W artykule tym opisano także wpływ eksperymentu obejmującego monitorowanie przemieszczania się pięciu wybranych osób w sztucznym środowisku zapewniającym warunki podobne do tych, w których starsza osoba mieszka na co dzień. Całkowita powierzchnia pomieszczenia, w którym dokonywany był eksperyment, wynosiła około 25 m². Sygnały z czujników były dostarczane w sposób bezprzewodowy do odbiorników umieszczonych na ścianach pomieszczeń. Średnia częstotliwość próbkowania wynosiła 10 Hz, ale odczyty były nierównomiernie rozmieszczone w czasie. Ponadto, zakłócenia, które wystąpiły pomiędzy czujnikami i stacją odbiorczą, spowodowały, że część danych z niektórych czujników zaginęła.

Rysunek 1 przedstawia uproszczony obraz monitorowanej osoby wraz z czujnikami, które przekazują dane do odbiorników umieszczonych w ich pobliżu. Dane te są wyrażone w postaci współrzędnych kartezjańskich względem stałego punktu odniesienia. Rysunek ten przedstawia

również przykład trajektorii ruchu zebranej z jednego z czujników w wybranym czasie. Tory te są przedstawione jako odpowiednie rzuty na płaszczyzny utworzone przez pary osi współrzędnych, tj. OX i OY, OX i OZ oraz OY i OZ.



Rys. 1. Schemat systemu monitorującego położenie ciała (u góry po lewej) oraz rzuty przykładowego sygnału pochodzącego z pojedynczego sensora na płaszczyzny utworzone przez pary osi współrzędnych

Fig. 1. Scheme of movement monitoring system (upper left) and projections of exemplary signal from single sensor on planes formed by pairs of axes

Metody wykrywania gwałtownych zmian położenia ciała, a zwłaszcza upadków, często opierają się nie tylko na wartościach położenia pobieranych z czujników, lecz także analizują szybkość zmian tych wartości. Szybkość zmian ma naturalną interpretację jako pochodna odbieranego sygnału. Ponadto, możliwe jest poszukiwanie reguł decyzyjnych na podstawie pochodnej drugiego rzędu interpretowanej jako przyspieszenie, czyli jest miarą dynamiki zmian położenia.

Z tego powodu metoda opisana poniżej, która rozwiązuje problem nierównomiernego rozłożenia w czasie zebranych próbek, bazuje na numerycznym wyznaczaniu pochodnych sygnałów odbieranych przez stacje odbiorcze z czujników umieszczonych na monitorowanej osobie. Postulowane własności tej metody są najbardziej dokładnym odzwierciedleniem nieznannej wartości pochodnej sygnału w wybranych momentach. Metoda ta wykazuje również odporność na występowanie próbek o znacznie różniących się wartościach w stosunku do ich rzeczywistego położenia w przestrzeni.

2.2. Wyrównywanie próbek w czasie

W określonym czasie każdy czujnik wysyła informacje na temat swojego położenia w postaci trzech współrzędnych kartezjańskich. Jednakże sygnały z różnych czujników mogą nadchodzić do stacji odbiorczej w różnych momentach. Zazwyczaj są one przekazywane w pewnych sekwencjach czasowych, ale w nierównych odstępach. Ponadto, możliwe jest, że niektóre informacje z czujnika ulegają zgubieniu lub z innego powodu są ignorowane. Stwarza to potrzebę przekształcenia oryginalnego zestawu próbek w sekwencję danych o jednakowych odstępach w czasie.


Istnieją różne podejścia do problemu nierównomiernie rozłożonych próbek danych, na przykład w artykule [2] jest opisana metoda bazująca na inteligencji obliczeniowej (ang. *computational intelligence*). Inne metody obejmują między innymi grupowanie danych, a także nieliniowe i adaptacyjne filtrowanie [8]. Ta sekcja przedstawia inną metodę rozwiązania powyżej opisanego problemu. Umożliwia ona znalezienie przekształcenia oryginalnych danych w celu uzyskania jako wyniku wartości pochodnej nierównomiernie pobranego sygnału w wybranych węzłach.

Założmy, że wektor zawierający wszystkie trzy współrzędne położenia jest opisany symbolem:

$$\mathbf{v}(t) = [x(t), y(t), z(t)]. \quad (1)$$

Ogólna idea zbioru próbek wyrównywanych w czasie jest schematycznie przedstawiona na rysunku 2. Szczegółowa konstrukcja tego zbioru jest przedstawiona poniżej dla pierwszej współrzędnej kartezjańskiej, czyli x . Dla pozostałych współrzędnych metoda działa analogicznie. Wyrównane czasowo próbki są zlokalizowane w chwilach oznaczanych przez t_n . Próbkę tę są podstawą numerycznego wyznaczania pochodnych położenia czujników w przestrzeni, zatem niezbędne jest określenie wektora odległości czasów pomiarów dla poszczególnych próbek od czasu t_n :

$$\mathbf{s}^{x,n} = [s_{-N}^{x,n}, \dots, s_{-1}^{x,n}, s_0^{x,n}, s_1^{x,n}, \dots, s_{N-1}^{x,n}]. \quad (2)$$



Rys. 2. Schemat konstrukcji zbioru próbek wyrównanych czasowo
 Fig. 2. Schematic construction of a set of time-aligned samples

Liczba N determinuje promień otoczenia sąsiedztwa wartości danej o czasie t_n , mierzony w liczbie próbek. Zakłada się przy tym, że wektor $\mathbf{s}^{x,n}$ zawiera parzystą liczbę składowych, a element o indeksie 0 jest położony w czasie nie wcześniejszym niż t_n :

$$s_{-N}^{x,n} < \dots < s_{-1}^{x,n} < 0 \leq s_0^{x,n} < s_1^{x,n} < \dots < s_{N-1}^{x,n}. \quad (3)$$


Powyższą zależność można wyrazić, wprowadzając indeks zdefiniowany jako najwcześniejsza próbka o czasie równym lub przekraczającym t :

$$I^x(t) = \min \{i : t_i^x \geq t\}. \quad (4)$$

Zatem odległości czasowe będące składowymi wektora $\mathbf{s}^{x,n}$ są opisane wzorem:

$$s_k^{x,n} = t_{I^x(t_n)+k}^x - t_n. \quad (5)$$

Interpretacja tych zależności czasowych jest zilustrowana na rysunku 3.



Rys. 3. Interpretacja indeksu I oraz odległości s
 Fig. 3. Interpretation of index I and distance s

Zbiór danych będących podstawą algorytmu różniczkowania obejmuje również wektor współrzędnych położen odczytywanych z czujnika:

$$\mathbf{x}^n = [\tilde{x}_{-N}^n, \dots, \tilde{x}_{-1}^n, \tilde{x}_0^n, \tilde{x}_1^n, \dots, \tilde{x}_{N-1}^n], \quad (6)$$

którego składowe wyrażają się następująco:

$$\tilde{x}_k^n = x_{I^x(t_n)+k}. \quad (7)$$

2.3. Numeryczne różniczkowanie

Ogólna idea numerycznego różniczkowania zbioru danych opisanego w poprzedniej sekcji opiera się na wyznaczeniu wielomianu o ustalonym stopniu D , który to wielomian aproksymuje wartości współrzędnych w równo odległych węzłach t_n . Natomiast wartości odczytywane z czujników są zlokalizowane w potencjalnie różnych odległościach reprezentowanych przez wektor $\mathbf{s}^{x,n}$. Dla otrzymanego w ten sposób wielomianu można już wyznaczyć pochodną w sposób symboliczny, co prowadzi do numerycznej oceny pochodnej rzeczywistego sygnału w danym węźle:

$$x = \sum_{i=0}^D a_i t^i, \quad \frac{dx}{dt} = \sum_{i=1}^D i a_i t^{i-1}. \quad (8)$$

Kryterium doboru współczynników wielomianu opiera się na minimalizacji odległości średniokwadratowej zdefiniowanej następująco:

$$G_N = \sum_{j=-N}^{N-1} \left(\tilde{x}_j - \sum_{i=0}^D a_i (s_j)^i \right)^2. \quad (9)$$

Minimalizacja odbywa się ze względu na współczynniki wielomianu. Funkcja kryterium jest funkcją wypukłą, zatem w celu znalezienia jej minimum wystarczające jest wyznaczenie jej punktu stacjonarnego. Prowadzi to do następującego układu równań:

$$\begin{aligned} \frac{\partial G_N}{\partial a_m} = -2 \sum_{j=-N}^{N-1} (s_j)^m \left(\tilde{x}_j - \sum_{i=0}^D a_i (s_j)^i \right) &= 0, \\ \sum_{i=0}^D a_i \left(\sum_{j=-N}^{N-1} (s_j)^{m+i} \right) &= \sum_{j=-N}^{N-1} (s_j)^m \tilde{x}_j. \end{aligned} \quad (10)$$

Równania te po prostych przekształceniach mogą być zapisane w postaci macierzowej:

$$\mathbf{J}\mathbf{a} = \mathbf{H}\mathbf{x}. \quad (11)$$

Macierze w nich występujące są zdefiniowane poniżej:

$$\mathbf{J} = \begin{bmatrix} \ddots & & & \\ & \ddots & & \\ & & \sum_{j=-N}^{N-1} (s_j)^{m+k} & \\ & & & \ddots \end{bmatrix} \leftarrow m. \quad (12)$$

$$\mathbf{a} = [a_0, a_1, \dots, a_D]^T, \quad \tilde{\mathbf{x}} = [\tilde{x}_{-N}, \dots, \tilde{x}_0, \dots, \tilde{x}_{N-1}]^T. \quad (13)$$

$$\mathbf{H} = \begin{bmatrix} 1 & \dots & 1 & \dots & 1 \\ s_{-N} & \dots & s_0 & \dots & s_{N-1} \\ \vdots & & \vdots & & \vdots \\ (s_{-N})^D & \dots & (s_0)^D & \dots & (s_{N-1})^D \end{bmatrix}. \quad (14)$$

Warto zauważyć, że obliczenie oceny pochodnej w wybranym węźle nie wymaga jawnego wyznaczania wszystkich współczynników wielomianu aproksymującego. Wprowadzenie pomocniczego wektora $\mathbf{d} = [0, 1, 0, \dots, 1]^T$ oraz rozwiązanie układu równań (11) pozwala na zapisanie wyniku w poniższej, zwartej postaci:

$$\left. \frac{dx}{dt} \right|_{x=0} = a_1 = \mathbf{d}^T \mathbf{J}^{-1} \mathbf{H} \mathbf{x}. \quad (15)$$


Opisana metoda może być stosowana iteracyjnie w celu numerycznego wyznaczania pochodnych wyższych rzędów. Oczywiście sekwencja czasowa otrzymana w wyniku jej jednokrotnego zastosowania składa się już z próbek o równomiernych odstępach. Nie stanowi to jednak przeszkody dla kolejnego stosowania tej metody ze względu na jej ogólny charakter.

2.4. Wstępne wyniki

Zastosowanie opisanej uprzednio procedury rozwiązuje problem wstępnego przekształcania nierównomiernie rozłożonych danych odczytywanych z czujników położenia umieszczonych na monitorowanej osobie. W procedurze tej skupiono się na wyznaczeniu numerycznym pochodnych rzędu pierwszego oraz drugiego. Rysunek 4 ilustruje charakter przebiegu czasowego uzyskanego w wyniku przetworzenia wejściowego zbioru danych. Przedstawiono na nim fragment uzyskany przez wyznaczenie ciągu wartości normy euklidesowej dla wektora przyspieszeń. Jako dane wykorzystano przykład opisany w artykule [5]. Wartości te zostały wyznaczone za pomocą następującego przekształcenia:

$$S(n) = \left(\sum_{i=0}^M (x''(t_n))^2 + (y''(t_n))^2 + (z''(t_n))^2 \right)^{\frac{1}{2}}. \quad (16)$$

Wartość $M = 4$ określa liczbę czujników. W przykładzie tym jako parametry procedury numerycznego wyznaczania pochodnej przyjęto $N = 3$ i $D = 3$. Rysunek 4 przedstawia również wykres wygładzony z użyciem ruchomej średniej arytmetycznej, oznaczony jako $\bar{S}(n)$. Promień uśredniania wynosił 5, co przekłada się na średnią kolejnych 11 próbek. Wygładzona wersja uwypukla lokalne maksima. Mogą być one traktowane jako kryterium wyboru wstępnych przedziałów czasowych, w których podejrzewa się upadek lub inne zagrożenia. Zmiany w amplitudzie norm tego wektora stanowią podstawę rozwoju metod wykrywania gwałtownych zmian położenia ciała monitorowanej osoby.



Rys. 4. Kwadraty norm wektora przyspieszeń (u góry) oraz ich wygładzona wersja (u dołu)
 Fig. 4. Squared norm of second derivatives vector (above) and its smoothed version (below)

Jednak ponieważ zmiany amplitudy mogą również wystąpić w przedziałach czasowych obejmujących normalną aktywność, konieczne będzie włączenie w proces detekcji dodatkowych kryteriów, bazujących na poszczególnych składnikach sygnałów pochodzących z pojedynczych czujników. Zostało to uwzględnione na rysunku 4 – jedynie w opisanych punktach (upadek, powstanie z pozycji leżącej) nastąpiły incydenty nagłej zmiany położenia, zaś pozostałe maksima lokalne były związane z normalną aktywnością. Opisane punkty zostały odpowiednio oznaczone w bazie danych udostępnianej przez autorów artykułu [5].

Planuje się dalszy rozwój systemu umożliwiającego monitorowanie i wykrywanie przedziałów czasowych, w których następuje nagły ruch, przy zastosowaniu podejścia zaproponowanego tutaj do wstępnego przekształcania nieregularnych próbek zebranych z czujników. Ponieważ szereg czasowy reprezentujący normy euklidesowe wektora pochodnych nie zawiera pełnej informacji, która pozwoliłaby odróżnić poszczególne typy niebezpiecznych zdarzeń, stanowi on tylko podstawę do ich wstępnej selekcji. Dlatego też rozwój kompletnego

modułu klasyfikacji wykrywania będzie wymagał analizy ruchu ciała na podstawie położenia czujników względem siebie.

Sekwencje pierwszych i drugich pochodnych, które są wyznaczane na podstawie sygnałów położenia czujników, tworzą wielowymiarowy szereg czasowy. Kolejne etapy rozwoju metody powinny obejmować analizę wartości w otoczeniu przedziałów czasowych podejrzanych o zdarzenia związane z upadkami lub powstawaniem z pozycji leżącej. Planuje się skoncentrować badania na rozwoju algorytmów klasyfikacji, w tym najprostszej metody najbliższych sąsiadów, a także metod opartych na wnioskowaniu bayesowskim oraz ich rozszerzeń w formie rozmytych systemów decyzyjnych. Obecnie trwają prace obejmujące rozmyte grupowanie wielowymiarowych sygnałów pochodzących z czujników i uczenie systemów rozmytych Takagi-Sugeno-Kanga [10,11].

Praca wykonywana częściowo w ramach projektu rozwojowego finansowanego przez Narodowe Centrum Badań i Rozwoju.

BIBLIOGRAFIA

1. Botia J. A., Villa A., Palma J.: Ambient Assisted Living system for in-home monitoring of healthy independent elders. *Expert Systems with Applications*, Vol. 39, No. 9, Murcia, Spain 2012, s. 8136÷8148.
2. Cismondi F., Fialho A. S., Vieira S. M. et al.: Computational intelligence methods for processing misaligned, unevenly sampled time series containing missing data. *Proc. IEEE Symp. on Computational Intelligence and Data Mining*, Paris 2011, s. 224÷231.
3. Frączkowski K.: Bazy danych w e-zdrowiu i telemedycynie – standardy informatyczne w regulacjach UE, [w:] Kozielski S., Małysiak B., Kasprowski P., Mrozek D. (red.): *Bazy danych: struktury, algorytmy, metody*. WKŁ, Warszawa 2006, s. 455÷469.
4. Jezewski J., Wrobel J., Horoba K. et. al.: Computerized perinatal database for retrospective qualitative assessment of cardiotocographic traces, [in:] Richards B. (ed.): *Current Perspectives in Healthcare Computing*. BJHC Limited, Great Britain 1996, s. 187÷196.
5. Kaluza B., Mirchevska V., Dovgan E. et al.: An agent-based approach to care in independent living. *Proc. 1st Int. Joint Conf. on Ambient intelligence*, Malaga 2010, s. 177÷186.
6. Liao Y. T., Huang C.-L., Hsu S.-C.: Slip and fall event detection using Bayesian Belief Network. *Pattern Recognition*, Vol. 45, No. 1, 2012, s. 24÷32.

7. Olivieri D. N., Conde I. G., Sobrino X. A. V.: Eigenspace-based fall detection and activity recognition from motion templates and machine learning. *Expert Systems with Applications*, Vol. 39, No. 5, 2012, s. 5935÷5945.
8. Przybyła T., Jezewski J., Wrobel J.: Robust Fuzzy Clustering using Adaptive Fuzzy Meridians, [in:] Nguyen N. T., Le M. T., Swiatek J. (eds.): *Intelligent Information and Database Systems. LNAI 5990/Lecture Notes in Computer Science*, Springer-Verlag, Berlin-Heidelberg 2010, s. 200÷209.
9. Steggles P., Gschwind S.: *Ubisense – a smart space platform. Raport techniczny, Ubisense*, 2005.
10. Sugeno M., Kang G. T.: Structure identification of fuzzy model. *Fuzzy Sets and Systems*, Vol. 28, 1988, s. 15÷33.
11. Takagi T., Sugeno M.: Fuzzy idnetification of systems and its application to modeling and control. *IEEE Trans. on System, Man and Cybernetics*, Vol. 15, No. 1, 1985, s. 116÷132.
12. Wang L., Gu T., Tao X. et al.: A hierarchical approach to real-time activity recognition in body sensor networks. *Pervasive and Mobile Computing*, Vol. 8, No. 1, 2012, s. 115÷130.

Wpłynęło do Redakcji 16 stycznia 2013 r.

Abstract

Telemedicine combines in a harmonious manner the elements of telecommunication, computing and medicine. It involves the exchange of information and data between patient, physician, hospital, etc.. Home care telemedicine systems are the fastest growing way to supervise or monitor the patient's health status, and progress in rehabilitation. The system often results in data exchange "from the patient to the doctor" to make the diagnosis, which also comes from a distance, thus telemedicine is very important for both doctor and patient.

Examples of application areas of telemedicine techniques include home care of the elderly which is part of the area known as assisted living. It incorporates supervision of daily living activities, alarming in case of deterioration of health of supervised person and coordination of health care services. Among the factors to be monitored there is information about a person's movement activities, in particular the detection of situations that raise suspicion of a fall or injury.

This paper presents a new method for detection of changes in alignment of the human body, particularly the fall, on the basis of signals acquired from the position sensors placed on the body of the monitored person. The sensors are located on the cuffs, waist and chest. Transformation of data sequence collected from sensors is proposed in order to best distinguish between the collapse from the normal movement. It is based on nonlinear combination of the first two derivatives of the signals being read. Because data from the sensors is sent asynchronously, a numerical algorithm for unevenly sampled data differentiation is proposed. Derivative values are calculated in equidistant nodes through differentiation of a polynomial, which is adjusted by minimizing the mean square error. The developed method can be used in home care telemedicine systems, where it is necessary to long term monitor of multiple vital parameters of people under care.

Adresy

Alina MOMOT: Politechnika Śląska, Instytut Informatyki, ul. Akademicka 16,
44-101 Gliwice, Polska, alina.momot@polsl.pl.

Michał MOMOT: Instytut Techniki i Aparatury Medycznej, ul. Roosevelta 118,
41-800 Zabrze, Polska, michal.momot@itam.zabrze.pl.

Roman SEREDYŃSKI: Instytut Techniki i Aparatury Medycznej, ul. Roosevelta 118,
41-800 Zabrze, Polska, roman.seredynski@itam.zabrze.pl.

Arkadiusz STANKIEWICZ: Instytut Techniki i Aparatury Medycznej, ul. Roosevelta 118,
41-800 Zabrze, Polska, arkadiusz.stankiewicz@itam.zabrze.pl.