Akademia Górniczo-Hutnicza im. Stanisława Staszica
Wydział Informatyki, Elektroniki i Telekomunikacji
Katedra Informatyki

Autoreferat rozprawy doktorskiej

DETEKCJA UPADKU I WYBRANYCH AKCJI NA SEKWENCJACH OBRAZÓW CYFROWYCH

mgr inż. Michał Kępski

Promotor: dr hab. inż. Bogdan Kwolek, prof. nadzw. AGH

Kraków 2016

Wstęp

W ostatnich latach obserwuje się duży wzrost zainteresowania tematyką rozpoznawania akcji wykonywanych przez człowieka, a także zagadnieniem detekcji wybranych akcji, takich jak upadek. Współczesne systemy detekcji upadku człowieka nie są pozbawione wad, przez co nie zostały w pełni zaakceptowane przez potencjalnych użytkowników. Trudności związane z ich wdrożeniem w środowisku seniorów związane się z niedoskonałością technologii: brakiem wystarczającej precyzji detekcji, dużą liczbą fałszywych alarmów, niewystarczającym poszanowaniem prywatności oraz z koniecznością noszenia sensorów przytwierdzonych do ciała bądź ubrania. Ponadto niewiele jest algorytmów zdolnych do detekcji upadku na platformach w architekturze ARM, które dzięki energooszczędności doprowadziłyby do szerszego upowszechnienia się systemów detekcji upadku.
Potrzeba usprawnienia systemów detekcji upadku zwróciła uwagę zespołów badawczych z całego świata. Opracowywane metody nie są pozbawione wad, w szczególności nie pozwalają one na nieprzerwane monitorowanie osoby. Mając na względzie powyższe, **tezy rozprawy doktorskiej** sformułowano w następujący sposób:

> **Zastosowanie obrazów głębi w systemach detekcji upadku prowadzi do znaczącego obniżenia liczby fałszywych alarmów**

oraz:

> **Dzięki wykorzystaniu cech pochodzących z obrazów głębi oraz uwzględnieniu kontekstu sytuacji następuje wzrost skuteczności detekcji upadku oraz zmniejszenie liczby fałszywych alarmów w porównaniu do systemów operujących na sekwencjach obrazów RGB lub pomiarach z akcelerometru/żyroskopu.**

W pracy opracowano i przebadano metody detekcji upadku człowieka na podstawie sekwencji map głębi oraz danych pochodzących z sensora inercyjnego. Szczególną uwagę poświęcono przebadaniu algorytmów, które umożliwiłyby efektywną detekcję upadku, przy zachowaniu niewielkiej liczby fałszywych alarmów. Celem lepszego dostosowania algorytmów wstępnego przetwarzania obrazów na potrzeby opracowywanego systemu zaproponowano szereg ich modyfikacji. **Do najważniejszych osiągnięć rozprawy można zaliczyć:**

- opracowanie oraz zaimplementowanie algorytmów detekcji upadku z wykorzystaniem algorytmów uczenia z nadzorem; metody te charakteryzują się wysoką czułością i małą liczbą fałszywych alarmów, a także pozwalają na implementację systemu na platformie obliczeniowej z procesorem ARM; w ramach prac przygotowano zestaw cech, zbiory uczące i testujące, a także przedstawiono wyniki klasyfikacji;
- opracowanie rozmytego systemu detekcji upadku będącego hierarchią trzech układów wnioskujących, charakteryzującego się wysoką czułością i specyficznością, a także

możliwością łatwej analizy bazy wiedzy przez eksperta; w ramach prac zaprojektowano zmienne lingwistyczne, bazę reguł, przebadano system i porównano wyniki z metodami opartymi o uczenie z nadzorem, a także inne pokrewne algorytmy detekcji upadku;

- opracowanie architektury systemu uwzględniającej możliwości obliczeniowe platformy z procesorem ARM; zaproponowanie rozwiązania z buforem cyklicznym oraz wstępną analizą danych, pozwalające na uniknięcie przetwarzania wszystkich obrazów *on-line*;
- przygotowanie zestawu algorytmów na potrzeby skutecznej detekcji upadku: algorytmów detekcji podłogi (metodami *v-disparity* i RANSAC), śledzenia postaci w oparciu o filtr cząsteczkowy, zmodyfikowanej metody rozrostu obszarów obrazu oraz metody budowy modelu tła;
- przygotowanie i udostępnienie w sieci web zbioru sekwencji UR Fall Detection Dataset, który posłużył ocenie skuteczności detekcji metod opracowanych w niniejszej pracy; zbiór ten jest jedynym publicznie dostępnym zbiorem łączącym sekwencje obrazów z danymi pochodzącymi z inercyjnego sensora ruchu;
- przygotowanie aktywnej głowicy obrotowej *pan/tilt* dedykowanej dla kamery *Microsoft Kinect* i opracowanie oprogramowania sterownika działającego na mikrokontrolerze Arduino.

Tematyka niniejszej rozprawy obejmuje zagadnienia z dwóch obszarów informatyki: uczenia maszynowego, a w szczególności jednej z jego dziedzin jaką jest rozpoznawanie akcji (w zakresie opracowania systemu wnioskującego i zastosowania metod klasyfikacji do detekcji upadku) oraz widzenia maszynowego (w zakresie komputerowego przetwarzania i analizy obrazów). Wpisuje się ona też w ogół badań w dziedzinie *Ambient Assisted Living*, dotyczącej projektowania systemów informatycznych i telekomunikacyjnych instalowanych w otoczeniu użytkownika.

1. Problematyka detekcji upadku

Jednym z poważniejszych zagrożeń dla zdrowia i życia ludzi starszych są upadki. Według danych WHO, od 28 do 35 procent ludzi w wieku powyżej 65. roku życia upada przynajmniej raz w roku, zaś dla segmentu populacji powyżej 80. roku życia liczba ta zwiększa się do 50%. Od 20 do 30 procent upadających ludzi odnosi obrażenia, które mieszczą się w grupie od średnich do poważnych (Heinrich et al., 2010), a upadki są przyczyną około 90% złamań biodra (Fuller, 2000). Badania dotyczące ryzyka odniesienia obrażeń przy upadkach wskazują także, że połowa osób, które upadły nie było w stanie podnieść się bez pomocy osoby trzeciej.

Problem detekcji upadku sprowadza się do ciągłej analizy danych pochodzących z sensorów noszonych przez osobę lub zewnętrznych urządzeń i odróżnieniu upadku od innych czynności życia codziennego (ang. *Activities of Daily Living – ADL*). Wraz z rozwojem badań w tej dziedzinie ukształtowały się wymagania (Igual et al., 2013; Yu, 2008) stawiane

opracowywanym technologiom. Klasyfikacja akcji wykonywanej przez człowieka powinna być na tyle wiarygodna, jak jest to tylko możliwe, szczególnie podczas pracy w naturalnym środowisku osoby starszej. Następną ważną cechą jest zdolność do nieprzerwanego monitoringu i podejmowania decyzji w jak najkrótszym czasie. Sukces w przystosowaniu technologii detekcji upadku do potrzeb użytkowników oraz późniejszym jej wdrożeniu możliwy jest po uwzględnieniu oczekiwań osób starszych (Brownsell et al., 2000). Docelowy system powinien działać w pełni automatycznie lub wymagać minimum obsługi przez użytkownika, który nie zawsze radzi sobie z nowoczesną technologią (Kurniawan, 2008). Ważnym wyzwaniem jest zapewnienie prywatności użytkownika, szczególnie w systemach opartych na kamerach RGB. Użytkownik systemu nie powinien mieć poczucia inwigilacji czy też ingerencji w jego prywatne środowisko. Istnieje ogólne przekonanie, że korzyści płynące z detekcji upadku nie powinny być uzyskiwane kosztem ingerencji w prywatność użytkownika.

W literaturze brakuje jednoznacznego podziału technologii detekcji upadku. Najczęściej stosowany jest podział zaprezentowany w pracy (Igual et al., 2013). Autorzy podzielili systemy detekcji upadku na dwie grupy: urządzenia noszone przez użytkownika (ang. *wearable devices*) oraz instalowane w jego otoczeniu (ang. *context aware systems*). Podział metod detekcji upadku według przyjętego kryterium przedstawia rysunek 1.1.

Systemy pasywne nie dokonują automatycznej detekcji upadku, zaś wystąpienie upadku zgłaszane jest przez użytkownika za pomocą niewielkiego urządzenia. Takie rozwiązania są niewystarczające ze względu na bezpieczeństwo użytkownika, gdyż statystyki pokazują, że duża część osób po upadku traci przytomność lub silny stres paraliżuje ich działania.

Większość proponowanych rozwiązań opiera się o analizę danych z sensorów inercyjnych noszonych przez człowieka. Decyzja o klasyfikacji akcji jako upadek podejmowana jest zazwyczaj w oparciu o predefiniowany próg lub polega na analizie pozycji po upadku (Bourke et al., 2007). Podstawową wadą tych metod jest trudność dopasowania progu wartości, przy którym wzbudzany jest alarm, czego konsekwencją jest wysoki odsetek fałszywych alarmów w środowisku poza laboratorium (Bagalà et al., 2012). Algorytm zaproponowany w pracy (Li et al., 2009) zakłada, że upadek zawsze kończy się w pozycji leżącej. Pozwala to na zniwelowanie części fałszywych alarmów, jednak może prowadzić do spadku skuteczności wykrywania upadków kończących się w pozycji siedzącej. Ponadto systemy działające jedynie w oparciu o sensory noszone przez osobę mogą być nieskuteczne, gdyż pewne czynności, takie jak przebieranie się czy kąpiel, wymagają zdjęcia tych urządzeń.

Kolejnym podejściem jest zastosowanie urządzeń monitorujących otoczenie, instalowanych w miejscach przebywania użytkownika. Pierwsza grupa metod zakłada wykorzystanie sensorów takich jak czujniki nacisku, wibracji (Zigel et al., 2009), pasywne

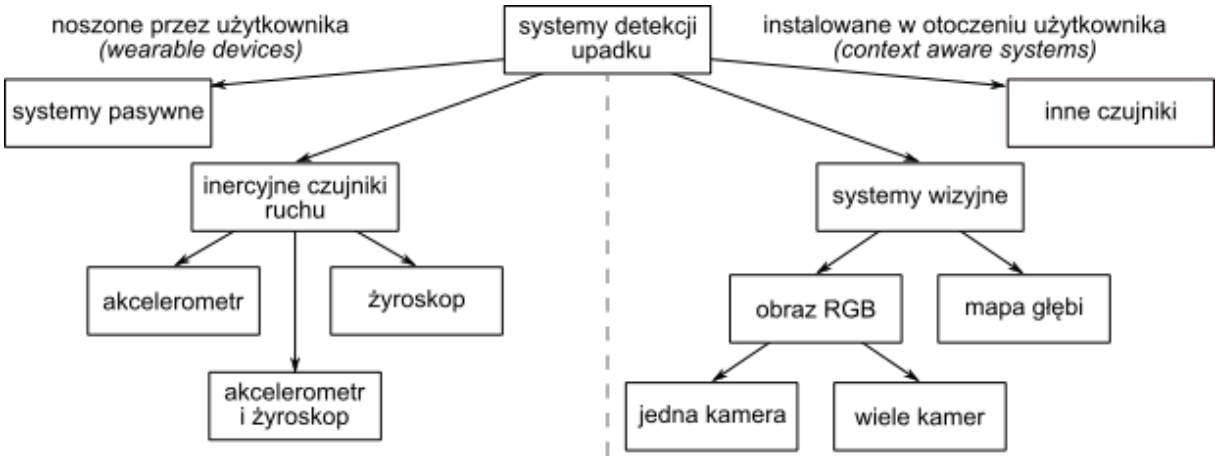

Rysunek 1.1. Podział systemów detekcji upadku ze względu na wykorzystaną technologię.

czujniki podczerwieni (A. Sixsmith et al., 2005), mikrofony (Y. Li et al., 2010) czy radary (Piorek & Winiecki, 2015). Zastosowanie tego typu technologii zwalnia osoby starsze z konieczności noszenia przy sobie urządzeń, lecz wymusza czasochłonną instalację oraz częściową ingerencję w miejsce zamieszkania, co może spotkać się z brakiem akceptacji przez użytkowników oraz ze znaczącymi kosztami użytkowania.

Druga grupa metod opiera się na wykorzystaniu technik widzenia komputerowego do śledzenia postaci i wykrywania upadku. Do tego celu wykorzystano systemy oparte na jednej kamerze CCD (Rougier et al., 2006), kilku kamerach (Cucchiara et al. 2007; Rougier et al. 2011), specjalnej kamerze dookólnej (Wang et al., 2006) lub kamerze głębi (Mastorakis & Makris, 2012; Kępski & Kwolek, 2012b; Kwolek & Kępski, 2013). Najprostszym podejściem jest analiza sylwetki lub jej prostokątnego obrysu. Jednak dokładność tych metod zależy w dużym stopniu od pozycji człowieka względem kamery, umiejscowienia kamery oraz występujących przysłonięć. Aby wyeliminować te trudności niektórzy autorzy (Lee & Mihailidis, 2005) proponują umiejscowienie kamery w centralnym punkcie sufitu pomieszczenia lub kamerę dookólną. Istnieje kilka systemów wielokamerowych, których skuteczność jest wyższa niż w przypadku użycia pojedynczej kamery (Cucchiara et al., 2007), jednak potrzebują one znaczących mocy obliczeniowych. Bardziej zaawansowane metody polegają na analizie konfiguracji modelu 3D reprezentującego pozę postaci. Ze względu na brak informacji o głębokości, precyzyjne dopasowanie modelu jest trudne do przeprowadzenia, szczególnie w podatnym na przysłonięcia środowisku. Główną wadą metod opartych na analizie obrazów RGB jest niemożliwość zapewnienia prywatności osobie, która jest monitorowana. Podłączenie systemu do sieci, np. w celu zdalnej weryfikacji upadku, może być krępujące, nie wspominając już o możliwości obserwacji czynności dnia codziennego takich jak mycie się czy przebieranie. Poza tym, systemy oparte na kamerach RGB wymagają odpowiedniego oświetlenia.

Wraz ze wzrostem popularności urządzeń do obrazowania 3D do detekcji upadku rozpoczęto wykorzystywać kamery udostępniające mapy głębokości (Rougier et al. 2011; Kępski & Kwolek, 2012a; Stone & Skubic 2013). Przetransformowanie mapy głębokości pozwala na uzyskanie trójwymiarowej reprezentacji sceny w postaci chmury punktów. Jest to

istotne w zagadnieniach detekcji upadku, gdyż dzięki mapom głębi możliwe jest określenie rzeczywistych rozmiarów i położenia ludzi oraz przedmiotów. Ponadto, akwizycja obrazów pozbawionych informacji o kolorze i teksturze obiektów nie prowadzi do znacznego naruszenia prywatności użytkownika i jest możliwa w różnych warunkach oświetleniowych. W pracy (Rougier et al. 2011) przedstawiono algorytm oparty na analizie odległości środka geometrycznego postaci od podłogi oraz prędkości środka ciężkości sylwetki. W pracy (Mastorakis & Makris, 2012) zaadaptowano metodę analizy prostokątnego obrysu sylwetki do danych 3D. Podjęto także kilka prób wykorzystania szkieletu 3D na potrzeby detekcji upadku (Parra-Dominguez et al., 2012; Planinc & Kampel, 2012).

Analizując rezultaty badań przedstawione w literaturze przedmiotu zauważyć można, że uzyskanie wysokiej czułości detekcji przy pomocy inercyjnych czujników ruchu wiąże się z wysokim odsetkiem wyników fałszywie pozytywnych. Najprostsze metody detekcji upadku poddane ciągłej, długotrwałej ewaluacji generują od 22 do 85 fałszywych alarmów na dobę (Bagalà et al., 2012), co jest nie do zaakceptowania przez potencjalnych użytkowników. Detekcja upadku w oparciu o obraz RGB charakteryzuje się mniejszą skutecznością niż w przypadku kamer głębi. Jednak opracowane dotychczas algorytmy nie są pozbawione wad i ich skuteczność maleje dla trudniejszych scenariuszy. Przykładowo w pracy (Stone & Skubic, 2014) uzyskano wysoką czułość dla upadków z pozycji stojącej, jednak detekcja zdarzeń rozpoczynających się z pozycji siedzącej okazała się być problematyczna.

1.1. Baza danych UR Fall Detection Dataset

W dziedzinie uczenia maszynowego ocena skuteczności algorytmów realizowana jest najczęściej w sposób empiryczny poprzez analizę miar jakości dla zestawu danych testowych. Problem ewaluacji algorytmów opracowywanych przez różne zespoły badawcze jest istotny ze względu na możliwość analizy porównawczej otrzymanych wyników. Rozwiązaniem tego problemu jest ewaluacja w oparciu o wspólne, ogólnodostępne dane, zgodnie z jednym protokołem postępowania. Opracowano stosunkowo niewiele zbiorów danych umożliwiających ewaluację algorytmów do detekcji upadku. Istniejące repozytoria zawierają głównie obrazy RGB (Auvinet et al., 2010; Anderson et al., 2009) lub mapy głębi.

Na potrzeby oceny skuteczności detekcji metod prezentowanych w niniejszej pracy został przygotowany i opublikowany zbiór sekwencji UR Fall Detection Dataset (Kępski & Kwolek, 2014b). Dane zostały zarejestrowane dwiema kamerami *Microsoft Kinect*, różniących się między sobą ustawieniem względem sceny oraz akcelerometrem x-IMU. Na wspomniany zbiór składa się 70 sekwencji prezentujących upadki (30 sekwencji) i czynności dnia codziennego (40 sekwencji) wykonywane przez 6 osób (5 w wieku 23-28 lat oraz jedna osoba w wieku 50+). Dane zostały zarejestrowane w pokoju biurowym oraz w trzech różnych pomieszczeniach w domu mieszkalnym (o typowej, niezmodyfikowanej na potrzeby nagrań scenerii). Przykładowe obrazy ze zbioru danych przedstawiono na rysunku 1.2. Część obrazów zawiera przysłonięcia, na niektórych fragmenty postaci są poza kadrem, co ma miejsce w percepcji sceny w typowych systemach monitoringu. Warto wspomnieć, że opracowany zbiór jest pierwszym i do tej pory

jedynym zbiorem, który zawiera zsynchronizowane obrazy RGBD oraz dane inercyjnego czujnika ruchu.

Rysunek 1.2. Przykładowe obrazy i mapy głębi ze zbioru UR Fall Detection Dataset.

Dla każdej z sekwencji przygotowano pliki: synchoronizacyjny – zawierający znaczniki czasowe dla obrazów i danych z akcelerometru, plik z danymi akcelerometrycznymi oraz plik z zestawami wartości deskryptorów wykorzystanych w procesie klasyfikacji.

1.2. Zaproponowane w pracy podejście do problemu

W ramach niniejszej pracy dokonano kilkugodzinnej akwizycji danych akcelerometrycznych dla pięciu starszych osób (kobiety i mężczyźni w wieku powyżej 65 lat, z czego jedna osoba w wieku powyżej 80 lat). Celem badań było określenie skuteczności prostych metod opartych o predefiniowany próg przyspieszenia oraz poznanie typowych wartości przyspieszenia i prędkości kątowej dla czynności dnia codziennego. Analizując zgromadzone w dłuższym horyzoncie czasowym dane, można zauważyć, że duża liczba wartości przyspieszenia przekracza typowe progi zaprezentowane w literaturze przedmiotu. Maksymalna liczba fałszywych alarmów uzyskana dla godzinnego okna czasowego wynosi odpowiednio 15 oraz 12. Rezultaty przeprowadzonych badań potwierdzają przedstawioną w pracy (Bagalà et al., 2012) tezę o niskiej specyficzności metod detekcji upadku działających w oparciu o próg wartości przyspieszenia. Część prac badawczych wykorzystuje założenie, że upadek kończy się w większości przypadków w pozycji leżącej (lub rzadziej siedzącej) i dokonuje detekcji w oparciu o orientację ciała człowieka (ang. *posture*). Często stosuje się metody polegające na połączeniu predefiniowanego progu, orientacji i innych cech, takich jak prędkość. Warto podkreślić, że tak naprawdę opisywana w pracach orientacja nie odnosi się stricte do ciała osoby, a jedynie położenia sensora inercyjnego. Ten zaś może w niekontrolowanym środowisku poza laboratorium ulec przesunięciu, w wyniku niepoprawnego czy też niedokładnego przymocowania do ciała lub ubioru. Dlatego też w niniejszej pracy, mając na względzie skuteczność dotychczas przedstawionych w literaturze przedmiotu metod opartych o sensory inercyjne, uznano za wartościowe opracowanie i przebadanie układu wykorzystującego **inercyjne sensory wraz z kamerą *Kinect,*** łączącego zalety obu rozwiązań.

Punktem wyjścia do badań nad detekcją upadku były metody oparte o klasyfikatory i zestawy deskryptorów opisujące akcje wykonywane przez człowieka. W momencie formułowania tezy (Kępski & Kwolek, 2012), liczba prac dotyczących detekcji upadku w oparciu o mapy głębi była niewielka, jednak ten kierunek badań z czasem uległ

upowszechnieniu. Wyniki opublikowane w pracy dyskutującej algorytmy oparte o dane akcelerometryczne (Bagalà et al., 2012) świadczą o niewystarczającej skuteczności w zastosowaniach poza laboratorium, przez co wskazują na nietrywialność postawionej w rozprawie tezy. Podejście zaprezentowane w pracy wpisuje się w główny kierunek badań prowadzonych w dziedzinie detekcji upadku(Mastorakis & Makris 2012; Planinc & Kampel 2012; Stone & Skubic 2014). Celem wykazania prawdziwości sformułowanej w niniejszej pracy tezy podjęto prace badawcze mające na celu wykorzystanie sensora głębi i inercyjnego czujnika ruchu, który dostarcza informacji o kontekście w jakim znajduje się osoba (Kępski & Kwolek, 2013). Te wstępne badania złożyły się na sformułowanie dodatkowych kryteriów, które są istotne w kontekście potencjalnych zastosowań. Mając na względzie powyższe czynniki, zdecydowano się na zaprojektowanie systemu wbudowanego o niskim zużyciu energii oraz niewymagającego kalibracji. Ze względu na ograniczoną moc obliczeniową platformy sprzętowej z procesorem o architekturze ARM zaproponowano hierarchiczną architekturę systemu, w której:

- wstępna hipoteza o wystąpieniu upadku jest podejmowana na podstawie analizy danych z inercyjnego sensora ruchu,
- obrazy przechowywane są w ciągle aktualizowanym buforze cyklicznym w celu weryfikacji hipotezy o upadku osoby lub dokonania aktualizacji modelu tła w wypadku zmian monitorowanego otoczenia.

Idea hierarchicznej architektury systemu została przedstawiona na rysunku 1.3. Dane pobierane z sensora głębi są przetwarzane jedynie wtedy, gdy wartość przyspieszenia przekracza pewien ustalony próg. W przeciwnym razie przechowywane są jedynie w buforze cyklicznym. Zaletą takiego podejścia jest brak konieczności ciągłego przetwarzania obrazów, szczególnie w sytuacjach dłuższej nieaktywności użytkownika. Okresy nieaktywności użytkownika, czyli takie, w których osoba pozostaje w bezruchu dłuższy czas, mogą zostać wykryte na podstawie analizy danych pochodzących z inercyjnego sensora ruchu. Mając na względzie przyjęte założenie, że docelowy system powinien nieustannie monitorować osobę, liczba obrazów, które można pominąć w fazie przetwarzania, jest znaczna. Warto wspomnieć, że takie podejście nie zostało do tej pory zaprezentowane przez inne zespoły badawcze.

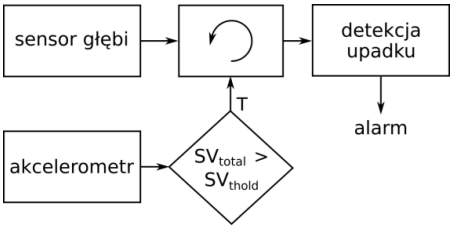

Rysunek 1.3. Schemat ideowy hierarchicznego systemu detekcji upadku.

Mając na uwadze parametry dostępnych na rynku sensorów głębi, w szczególności ich kąty widzenia oraz ich zasięg, które określają wielkość monitorowanego obszaru, zaproponowano i przebadano dwa scenariusze umieszczenia kamery: na wprost, w którym oś kamery jest równoległa do podłogi i scenariusz w którym kamera obserwuje scenę z góry (Kępski &

Kwolek, 2014a). Zbyt mała powierzchnia monitorowania, a także brak możliwości jej zwiększenia przez różnego rodzaju nakładki na obiektyw, doprowadziły do umieszczenia kamery na obrotowej głowicy *pan-tilt,* którą wykonano na potrzeby niniejszej pracy.

Przygotowano także zestaw algorytmów wstępnego przetwarzania obrazów, do którego zaliczyć można:

- algorytm detekcji podłogi – przedstawiono propozycję połączenia metody *v-disparity* i algorytmu RANSAC do estymacji parametrów modelu płaszczyzny reprezentującej podłogę monitorowanego pomieszczenia,
- algorytm budowy referencyjnego modelu tła – dokonano modyfikacji klasycznego algorytmu opartego o medianę obrazów w czasie, pozwalającą na aktualizację tła w obszarach sceny, które uległy zmianie,
- algorytm rozrostu obszarów – zaproponowano modyfikację klasycznego algorytmu, w której dokonywany jest rozrost pojedynczego obszaru reprezentującego postać, co w konsekwencji prowadzi do zmniejszonych wymagań obliczeniowych algorytmu,
- algorytm śledzenia postaci – zaproponowano algorytm śledzenia osoby w oparciu o filtr cząsteczkowy, w którym kształt jej głowy zamodelowano za pomocą elipsoidy,
- algorytm detekcji osoby – zaproponowano algorytm detekcji osoby w oparciu o histogramy gradientów map głębokości i klasyfikator oparty o maszynę wektorów wspierających (ang. *support vector machine,* SVM), w dalszej części nazwany HOG-SVM.

W ramach prac nad metodami wstępnego przetwarzania obrazów, dokonano kilku modyfikacji wyżej wymienionych algorytmów, a także przedstawiono scenariusze ich wykorzystania, mając na uwadze docelową platformę obliczeniową. Zastosowanie podejścia z buforem cyklicznym, wydajnej modyfikacji algorytmu rozrostu obszarów do segmentacji osoby oraz algorytmu HOG-SVM do weryfikacji poprawności segmentacji jedynie na fragmencie obrazu pozwala na uruchomienie systemu w czasie rzeczywistym na komputerze PandaBoard ES.

Efektem badań i wynikiem doświadczenia nabytego przy pracy nad metodami detekcji upadku była propozycja zastosowania w rozpatrywanym problemie rozmytego systemu wnioskującego (Kwolek & Kępski, 2016).

2. System do detekcji i śledzenia osób

Architektura systemu detekcji upadku została przedstawiona na rysunku 2.1. Na poziomie konceptualnym można ją przedstawić jako 4 warstwy: akwizycji, przetwarzania, komunikacji i klasyfikacji. Taki podział wprowadzono celem przedstawienia uproszczonego modelu systemu i zaprezentowanie etapów jego działania.

Warstwa akwizycji

Warstwa akwizycji danych prezentuje sposób pozyskania danych wejściowych z urządzenia *Kinect* oraz inercyjnego czujnika ruchu. Mapy głębi są pobierane z wykorzystaniem protokołu USB, natomiast dane akcelerometryczne pobierane są bezprzewodowo z akcelerometru przy wykorzystaniu protokołu Bluetooth. Do akwizycji danych wykorzystano bibliotekę OpenNI, skompilowaną dla architektury ARM na podstawie kodów źródłowych, natomiast dla czujnika IMU przygotowano oprogramowanie w oparciu o kody źródłowe dostarczone przez producenta.

Warstwa przetwarzania

Przed wydzieleniem postaci i jej cech, mapy głębi zostają poddane etapowi wstępnego przetwarzania by zredukować szum i obszary o nieznanej wartości pikseli. W celu usunięcia szumu zastosowano filtr medianowy o rozmiarze 5 na 5 pikseli. Usunięcie obszarów o nieznanej wartości pikseli jest dokonywane metodą filtracji medianowej w czasie, przy wykorzystaniu 3 ostatnich obrazów.

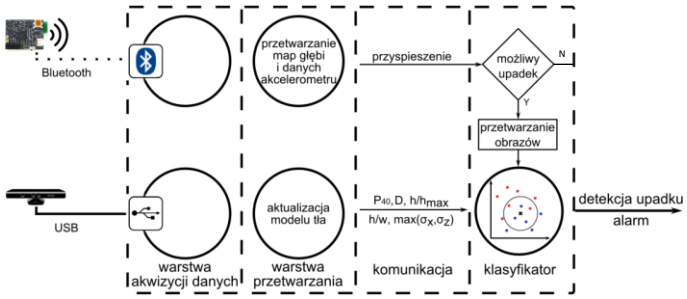

Rysunek 2.1. Schemat architektury systemu detekcji upadku

Inne metody, które można zaliczyć do warstwy przetwarzania także dotyczą przetwarzania map głębi i są to:

- budowa i aktualizacja modelu tła,
- wydzielenie pierwszego planu,
- detekcja postaci,
- śledzenie postaci,
- wydzielenie cech postaci.

Wydzielone w warstwie przetwarzania cechy, zostaną przedstawione w podrozdziale 2.2.

2.1. Algorytm detekcji upadku

Zgodnie z założeniami przyjętymi podczas projektowania systemu, opracowano algorytmy detekcji upadku dla dwóch różnych ustawień kamery: "na wprost" i "u góry". Pomimo cech wspólnych, obydwa rozwiązania dostosowano do specyfiki ustawienia kamery oraz danych wejściowych. Obraz sylwetki człowieka, czy też dowolnego przedmiotu o złożonym kształcie będzie zmieniał się w zależności od ustawienia kamery na scenie. W niniejszym podrozdziale

przedstawiono i omówiono obydwa algorytmy oraz cechy postaci wydzielane na potrzeby klasyfikacji. Do prezentacji algorytmów wykorzystano diagramy aktywności UML.

Diagram aktywności UML algorytmu detekcji upadku dla kamery umieszczonej "na wprost" przedstawiono na rysunku 2.2a. Pierwszym etapem jest akwizycja danych z kamery głębi i bezprzewodowego czujnika ruchu. Mapy głębi zostają poddane operacjom wstępnego przetwarzania (filtracji) i zostają zapisane do bufora cyklicznego. Przechowywanie map w buforze jest niezbędne do wykonania operacji budowy i aktualizacji modelu tła. W następnym kroku algorytmu wykonywana jest detekcja ruchu w oparciu o akcelerometr, co pozwala na dokonanie tej operacji niskim kosztem obliczeniowym. Gdy osoba pozostaje w bezruchu przez pewien zadany okres czasu, system przestaje dokonywać wydzielania postaci na obrazach i zapisując nowe dane do bufora czeka na ruch postaci. Pozwala to uniknąć przetwarzania każdej klatki obrazu dzięki wykryciu okresów, w których monitorowana osoba jest nieaktywna (przykładowo śpi lub odpoczywa). W przypadku braku danych akcelerometrycznych (osoba nie nosi akcelerometru lub utracono połączenie z urządzeniem) konieczne jest wydzielenie postaci.

Jeżeli osoba znajduje się w ruchu, zostaje wykonana operacja wydzielenia pierwszego planu i etykietowania połączonych komponentów. Przypadek pojawienia się więcej niż jednego połączonego komponentu na obrazie różnicy aktualnej mapy głębi i modelu tła traktowany jest jako zmiana elementów sceny (np. poprzez interakcję użytkownika z otoczeniem). Wówczas system rozpoczyna procedurę aktualizacji modelu tła. W sytuacji braku zmian otoczenia użytkownika realizowana jest procedura detekcji upadku, to znaczy w sytuacji gdy występuje podejrzenie o jego wystąpieniu. Wstępna hipoteza o upadku jest uzyskiwana w wyniku przekroczenia wartości przyspieszenia uzyskanego z czujnika ruchu. Potwierdzenie lub odrzucenie tej hipotezy jest realizowane poprzez wydzielenie cech sylwetki postaci na obrazach głębi oraz poddaniu ich klasyfikacji. Gdy wykryto upadek, system zgłasza alarm, w przeciwnym razie kontynuowane jest działanie algorytmu dla nowych danych. W przypadku gdy system działa na podstawie tylko obrazów, konieczna jest detekcja upadku dla każdego obrazu, gdyż nie ma możliwości określenia wstępnej hipotezy w oparciu o przyspieszenie.

Diagram aktywności UML algorytmu detekcji upadku dla kamery umieszczonej "u góry" przedstawiono na rysunku 2.2 b. Pierwszym etapem, podobnie jak dla ustawienia kamery "na wprost", jest realizowana akwizycja danych z kamery głębi i bezprzewodowego sensora ruchu oraz filtracja map głębi. Następnie za pomocą algorytmu rozrostu obszarów wydzielana jest osoba. Punkty startowe, od których rozpoczynana jest segmentacja są znane dzięki informacji o położeniu postaci na wcześniejszej klatce obrazu. Po segmentacji postaci i weryfikacji jej poprawności przy użyciu HOG dalsza analiza wydzielanego obszaru jest przeprowadzana w dwojakim celu: wyznaczenie środka postaci w celu obliczenia parametrów sterowania głowicy oraz klasyfikacja pozy leżącej postaci na potrzeby wyznaczenia wstępnej hipotezy o wystąpieniu upadku. W razie braku podejrzenia wystąpienia upadku, algorytm rozpoczyna pracę dla nowych danych, w przeciwnym wypadku konieczna jest dalsza analiza akcji wykonanej przez człowieka. Sam fakt stwierdzenia, że osoba znajduje się w pozycji leżącej jest niewystarczający do zapewnienia akceptowalnej liczby fałszywych alarmów, gdyż intencją

osoby mogło być znalezienie się w pozycji leżącej. Odróżnienie takiego zachowania od upadku jest możliwe dzięki analizie wartości przyspieszeń uzyskanych z akcelerometru oraz analizie zmian sylwetki postaci w czasie. Dla niniejszego systemu zaproponowano cechy opisujące akcje postaci pod względem dynamiki zmian sylwetki, nazwane *dynamic transitions* (Kępski & Kwolek, 2014b; Kępski & Kwolek, 2014a). Metoda ta pozwala odróżnić akcje wykonywane dynamicznie, charakteryzujące się szybką zmianą sylwetki (np. upadek) od typowych ADLs. Decyzja po analizie cech dynamicznych prowadzi do alarmu (w razie wystąpienia upadku) lub do kontynuacji pracy systemu dla nowych danych.

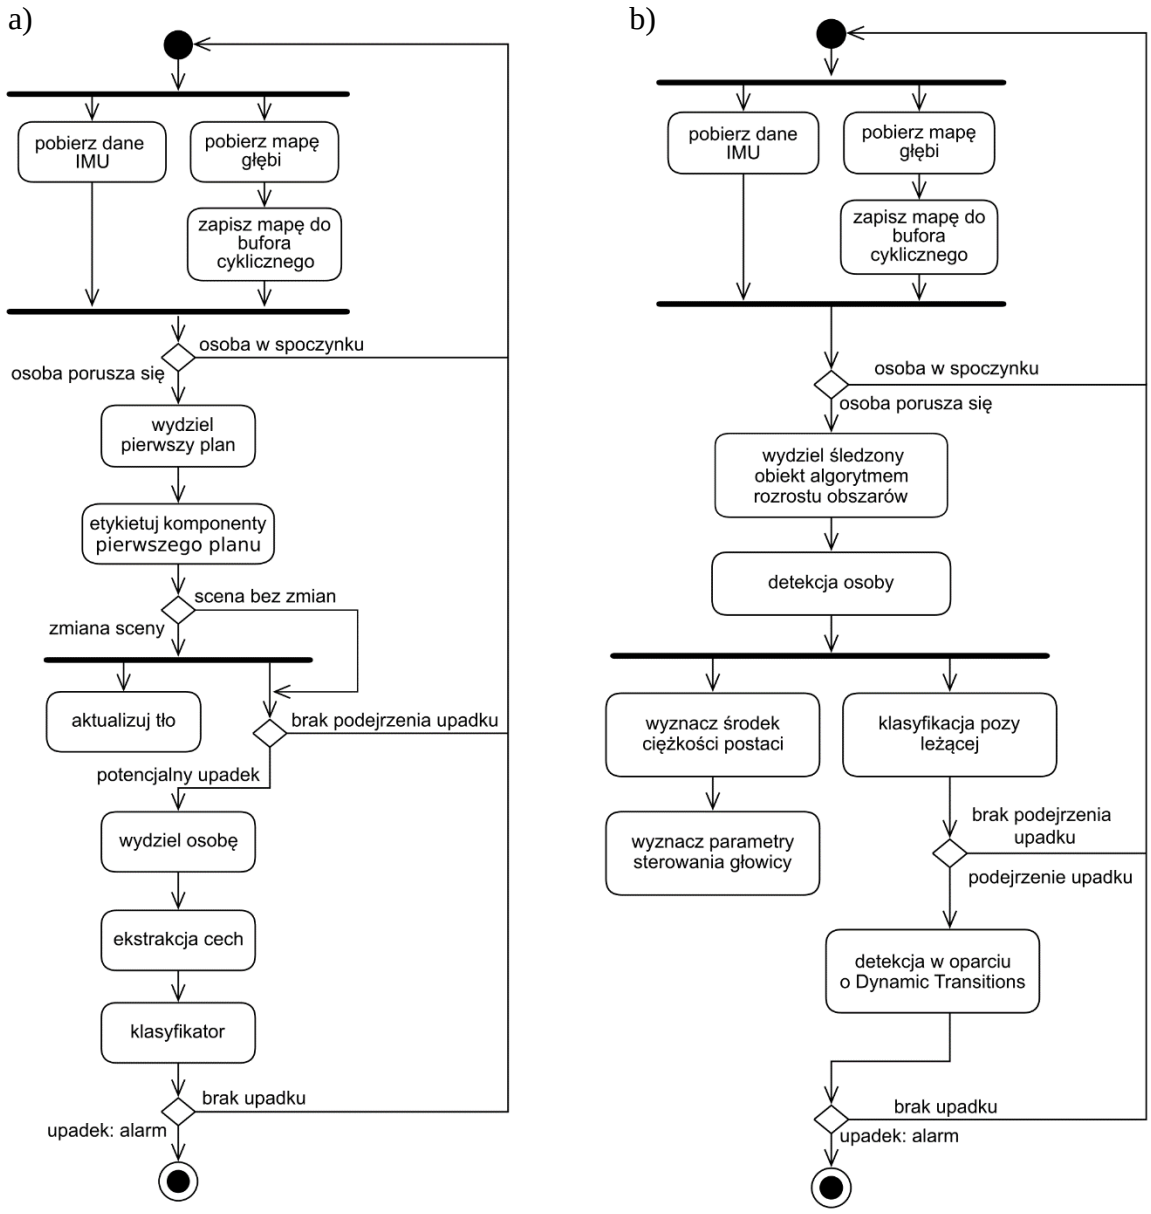

Rysunek 2.2 Diagramy UML

2.2. Zaproponowane wektory cech

Detekcję upadku można rozpatrywać jako problem klasyfikacji dwuklasowej. Wybór cech jest kluczowym problemem w dziedzinie widzenia i uczenia maszynowego i w dużym stopniu wpływa na skuteczność klasyfikacji oraz wynik działania systemu wizyjnego (Dollar et al., 2007).

Do opracowania cech wykorzystano zbiór danych URFD oraz sekwencje zarejestrowane na potrzeby prac (Kępski & Kwolek, 2013; Kwolek & Kępski, 2013). Ostatecznie ze zbioru cech, dla scenariusza z kamerą „na wprost" wybrano następujące deskryptory:

- H/W – stosunek wysokości do szerokości wydzielonej postaci, wyznaczony na podstawie map głębi (rysunek 2.3),
- H/H_{max} – stosunek wysokości wydzielonej postaci w danej klatce obrazu do jej rzeczywistej wysokości w postawie wyprostowanej, wyznaczony na podstawie chmury punktów,
- D – odległość środka ciężkości postaci od płaszczyzny podłogi wyrażona w milimetrach,
- $max(\sigma_x, \sigma_z)$ – maksymalne odchylenie standardowe wartości punktów należących do postaci od jej środka ciężkości, wzdłuż osi X i Z układu współrzędnych kamery *Kinect*,
- P_{40} – stosunek liczby punktów należących do postaci, leżących w prostopadłościanie o wysokości 40 cm, umieszczonym nad podłogą, do liczby wszystkich punktów należących do postaci (rysunek 2.4).

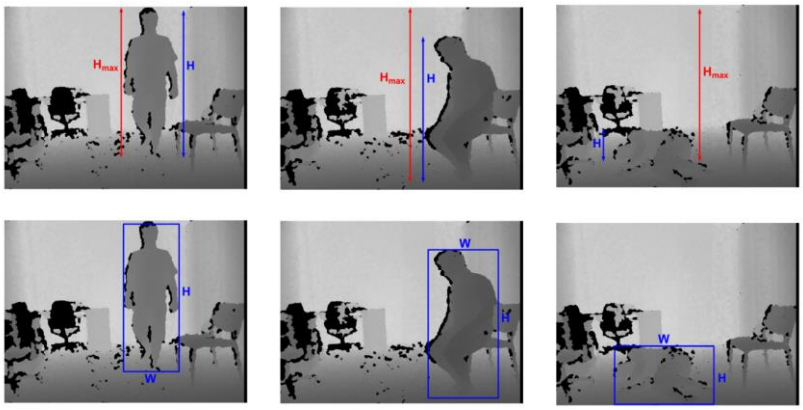

Rysunek 2.3. Cechy H/W oraz H/H_{max} przedstawione dla różnych sylwetek postaci: stojącej, siedzącej i leżącej.

Cechy $max(\sigma_x, \sigma_z)$ oraz P_{40}, nie były prezentowane uprzednio w żadnych pracach naukowych innych zespołów badawczych. Zostały one zaproponowane celem odróżnienia od upadku akcji, w których osoba schyla się po przedmiot, kuca lub wykonuje podobne czynności. Duże wartości odchylenia standardowego punktów należących do postaci względem osi x lub y, są charakterystyczne dla leżącej sylwetki. Istotne jest to, że odchylenie standardowe wyznaczane jest na podstawie chmury punktów zamiast mapy głębi. Dzięki temu można uniezależnić wartość omawianego atrybutu od orientacji leżącej osoby względem kamery. Cecha P_{40} ma za

zadanie odróżniać sytuację, w których postać znajduje się blisko podłogi, wydzielonej wcześniej algorytmami v-dysparycji i RANSAC (rysunek 3.7). W badaniach eksperymentalnych dowiedziono skuteczności omawianych cech w zagadnieniu detekcji upadku.

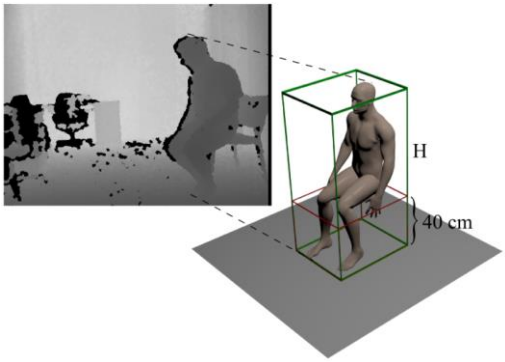

Rysunek 2.4 Cecha P_{40} przedstawiona na mapie głębi i odpowiadającym mu modelu postaci 3D.

Dla kamery umieszczonej na wprost detekcja pozy leżącej postaci została zrealizowana na podstawie zbioru następujących cech:

- H/H_{max} – stosunek wysokości postaci w danej klatce obrazu (odległości głowy od podłogi) do jej rzeczywistej wysokości,
- $area$ – wielkość obszaru reprezentującego postać na obrazie przeskalowana dla stałej odległości,
- l/w – stosunek długości osi wielkiej do długości osi małej obszaru reprezentującego postać na obrazie binarnym $I(x, y)$, powstałym w wyniku wydzielenia osoby na mapie głębi.

Aby odróżnić upadki od innych akcji, takich jak kładzenie się do łóżka, zaproponowano analizę zmian cech opisujących sylwetkę w czasie. Ponieważ upadki, mogą różnić się między sobą ułożeniem ciała, kierunkiem upadku, prędkością ciała (różnica występuje szczególnie pomiędzy upadkiem z pozycji nieruchomej, a podczas ruchu, np. chodzenia), a także ustawieniem postaci względem kamery, zaprezentowano cechy *dynamic transitions,* które są wspólne dla dużej liczby możliwych wzorców kinematycznych upadku (Kępski & Kwolek, 2015).

2.3. Wyniki badań eksperymentalnych

Wyniki detekcji upadku dla kamery umieszczonej "na wprost"

Badania zrealizowano na sekwencjach obrazów głębi ze zbioru danych UR Fall Dataset. Jak już wspomniano, przygotowane sekwencje zawierają upadki oraz typowe czynności dnia codziennego, które wykonane były przez 6 osób, zarówno w środowisku laboratoryjnym jak

i domowym. Definicje użytych miar jakości klasyfikacji znaleźć można w pracy (Sokolova & Lapalme, 2009).

Z przeglądu literatury wynika (Igual et al., 2013), że wiele systemów do detekcji upadku wykorzystuje jedynie informację o pozie leżącej. Celem przebadania użyteczności tego podejścia, w oparciu o przygotowany zestaw deskryptorów dokonano klasyfikacji pozy osoby. W tabeli 2.1 zebrano uzyskane wyniki klasyfikacji pozy osoby. Jak zaobserwować można, osiągnięto wysoką czułość i swoistość systemu, jednak wyniki klasyfikacji nie są pozbawione błędów. Co więcej, w praktycznym zastosowaniu, wspomniane błędy przełożyłyby się na wystąpienie fałszywych alarmów oraz pominięcie niektórych upadków.

Tabela 2.1. Macierz pomyłek dla klasyfikacji pozy osoby.

			Rzeczywiste pozy osoby		
			osoba w pozie leżącej	**osoba w pozie nieleżącej**	
Przewidywane pozy osoby	**k-NN(3)**	**osoba w pozie leżącej**	898	6	Dokładność = 99,55%
		osoba w pozie nieleżącej	5	1516	Precyzja = 99,34%
			Czułość = 99,45%	Swoistość = 99,61%	

Celem oceny wskaźników jakościowych opracowanych metod detekcji upadku zrealizowano badania eksperymentalne, których wyniki zestawiono w tabeli 2.2. W omawianej tabeli zamieszczono także wyniki uzyskane przez reprezentatywne i powszechnie przywoływane w literaturze metody. Jak można zauważyć, wykorzystanie danych pochodzących z noszonego przez osobę inercyjnego sensora umożliwia znaczne polepszenie jakości detekcji.

Tabela 2.2. Wyniki uzyskane w oparciu o opracowane metody detekcji upadku na zbiorze danych UR Fall Dataset dla kamery umieszczonej na wprost.

		***k*-NN + akcelerometr**	**SVM + akcelerometr**	***k*-NN**	***UFT* (Bourke et al., 2007)**	***LFT* (Bourke et al., 2007)**
Wyniki	**Dokładność**	95,71%	94,28%	90,00%	88,57%	78,57%
	Precyzja	90,90%	88,24%	81,08%	78,95%	68,29%
	Czułość	100,00%	100,00%	100%	100,00%	93,33%
	Swoistość	92,50%	90,00%	82,5%	80,00%	67,50%

Mając na względzie brak akceptacji istniejących rozwiązań przez seniorów, głównie ze względu na liczbę fałszywych alarmów przy wysokiej czułości urządzenia, które występują

podczas ciągłego monitoringu osoby, można stwierdzić, że jednoczesne wykorzystanie danych wizyjnych i akcelerometru jest racjonalne. W szczególności, dzięki użyciu deskryptorów opisujących ruch osoby i obrazów głębi możliwe jest zmniejszenie liczby fałszywych alarmów w porównaniu do systemów operujących na sekwencjach obrazów lub pomiarach z akcelerometru czy żyroskopu. Jak można zaobserwować, metody działające jedynie w oparciu o akcelerometr charakteryzują się dużą liczbą błędów pierwszego rodzaju, co przekłada się na niższą swoistość wspomnianych rozwiązań. Z kolei detekcja upadku jedynie w oparciu o klasyfikację pozy w jakiej znajduje się osoba (zob. wyniki uzyskiwane przez *k*-NN), prowadzi do niezadowalającej swoistości i precyzji metody, mając na względzie praktyczne zastosowania w systemach nieprzerwanego monitoringu osoby.

Wyniki detekcji upadku dla kamery umieszczonej "u góry"

Z przeglądu literatury dotyczącej detekcji upadku wynika, że większość zespołów badawczych nie rozpatruje scenariuszy, w których kamera umieszczona jest u góry pomieszczenia. Tym niemniej, w typowych systemach monitoringu w oparciu o kamery RGB, dość powszechnie wykorzystuje się kamery skierowane w dół i umieszczone na obrotowych głowicach. Liczba obrazów, na których realizowano badania eksperymentalne jest równa 525. Na wymieniony zbiór składa się 248 obrazów przedstawiających osoby w pozie leżącej oraz 277 obrazów przedstawiających osoby w pozostałych pozach. Jak można zaobserwować w tabeli 2.4, w oparciu o obrazy zarejestrowane przez kamerę umieszczoną u góry uzyskać można wyniki, które nie ustępują wynikom zaprezentowanym w tabeli 2.1.

Tabela 2.4. Wyniki detekcji pozy leżącej.

			Rzeczywiste pozy osoby		
			osoba w pozie leżącej	**osoba w pozie nieleżącej**	
Przewidywane pozy osoby	***k*-NN**	**osoba w pozie leżącej**	244	9	Dokładność = 97,52%
		osoba w pozie nieleżącej	4	268	
			Czułość = 98,39%	Swoistość = 96,75%	Precyzja = 96,44%
	SVM	**osoba w pozie leżącej**	244	10	Dokładność = 97,33%
		osoba w pozie nieleżącej	4	267	
			Czułość = 98,39%	Swoistość = 96,39%	Precyzja = 96,06%

W tabeli 2.6 znajdują się wyniki uzyskane w oparciu o algorytm, który może być wykorzystany do usprawnienia wydzielania osoby w razie zajścia wspomnianej sytuacji (Kępski & Kwolek, 2016).

Tabela 2.6. Wyniki detekcji postaci metodą HOG-SVM.

	Dokładność	Precyzja	Czułość	Swoistość
rotacja komponentu	99,45	98,21	100	99,22
brak rotacji komponentu	98,91	98,18	98,18	99,22

Omawiana metoda detekcji postaci została przebadana na zbiorze liczącym 892 obrazy, z których 60% wykorzystano do uczenia klasyfikatora. Przedstawione wyniki uzyskano na zbiorach rozłącznych. Jak można zaobserwować, dzięki transformacji komponentu reprezentującego sylwetkę postaci do orientacji kanonicznej, wyniki detekcji są lepsze mając na względzie czułość i dokładność.

Celem przebadania przydatności zaproponowanych cech *dynamic transitions*, zrealizowano eksperyment, w którym określono czułość i specyficzność dla $\Delta t \in (400ms, 800ms)$. W oparciu o uzyskane wyniki sporządzono wykres obrazujący przebieg krzywej ROC, który zaprezentowany jest na rysunku 2.5. Jak można zaobserwować, uzyskane pole powierzchni pod krzywą ROC jest znaczące.

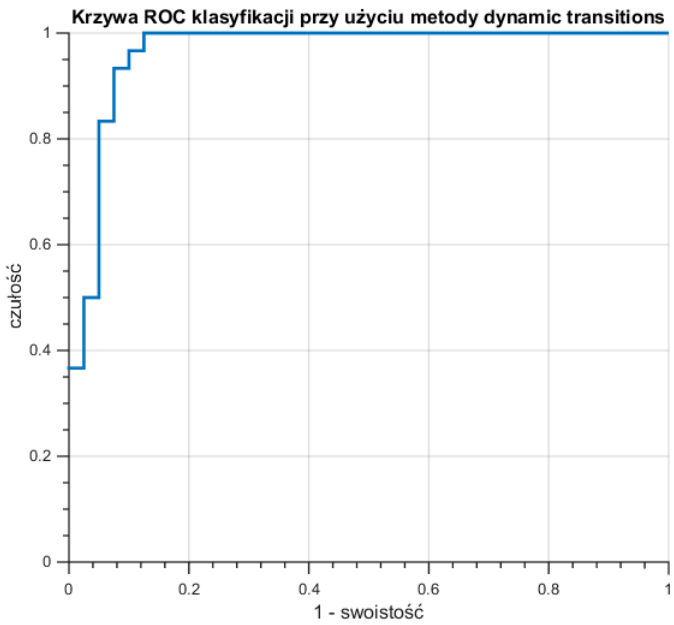

Rysunek 2.5. Krzywa ROC klasyfikacji upadku przy użyciu metody *dynamic transitions*.

Podsumowanie

Badania nad upadkami to szeroka dziedzina i nie ulega wątpliwości, że znaczące polepszenie funkcjonalności istniejących rozwiązań uzyskać będzie można w wyniku wprowadzenia nowych podejść. W pracy zwrócono uwagę na szereg trudności występujących w detekcji upadku, prowadzących do spadku skuteczności i występowania dużej liczby fałszywych alarmów, przez co współczesne technologie nie zostały jeszcze w pełni zaakceptowane przez użytkowników.

W ramach niniejszej rozprawy doktorskiej opracowano i przebadano metody detekcji upadku człowieka na podstawie sekwencji map głębi oraz danych pochodzących z sensora inercyjnego. W pracy zaproponowano szereg rozwiązań, do kluczowych osiągnięć zaliczyć można:

- przebadanie algorytmów, które umożliwiłyby efektywną detekcję upadku, przy zachowaniu wysokiej swoistości,
- zaprezentowanie i porównanie dwóch metod: metody opartej o uczenie z nadzorem oraz metody wykorzystującej wnioskowanie rozmyte.

Metody te pozwoliły uzyskać wskaźniki jakościowe świadczące o wysokiej czułości i swoistości detekcji upadku. Ponadto w pracy zaprezentowano podejście wykorzystujące bufor cykliczny do przechowywania obrazów w okresach nieaktywności użytkownika, mające za zadanie redukcję liczby obrazów poddanych analizie. Przygotowano i przebadano także zestaw algorytmów przetwarzania obrazów dla potrzeb efektywnej detekcji upadku.

Dalsze prace dotyczyć będą przygotowania prototypowych urządzeń i umieszczenia ich w pomieszczeniach domu opieki społecznej w celu akwizycji dużej liczby sekwencji z naturalnego środowiska osoby starszej.

Bibliografia

A. Sixsmith, N. Johnson & R. Whatmore (2005) Pyroelectric IR sensor arrays for fall detection in the older population. *J. Phys. IV France*, 128, pp. 153–160.

Anderson, D., Luke, R.H., Keller, J.M., Skubic, M., Rantz, M. & Aud, M. (2009) Linguistic Summarization of Video for Fall Detection Using Voxel Person and Fuzzy Logic. *Computer Vision and Image Understanding*, 113 (1), pp. 80–89.

Auvinet, E., Rougier, C., Meunier, J., St-Arnaud, A. & Rousseau, J. (2010) *Multiple cameras fall data set*. Montréal (Québec).

Bagalà, F., Becker, C., Cappello, A., Chiari, L., Aminian, K., Hausdorff, J.M., Zijlstra, W. & Klenk, J. (2012) Evaluation of accelerometer-based fall detection algorithms on real-world falls. *PloS ONE*, 7 (5), p.e37062.

Bourke, A.K., O'Brien, J. V & Lyons, G.M. (2007) Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm. *Gait & Posture*, 26 (2), pp. 194–9.

Brownsell, S.J., Bradley, D.A., Bragg, R., Catlin, P. & Carlier, J. (2000) Do community alarm users want telecare? *Journal of Telemedicine and Telecare*, 6 (4), pp. 199–204.

Cucchiara, R., Prati, A. & Vezzani, R. (2007) A multi-camera vision system for fall detection and alarm generation. *Expert Systems*, 24 (5), pp. 334–345.

Dalal, N. & Triggs, B. (2005) Histograms of Oriented Gradients for Human Detection. In: *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, pp. 886–893.

Dollar, P., Tu, Z., Tao, H. & Belongie, S. (2007) Feature Mining for Image Classification. In: *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, pp. 1–8.

Fuller, G.F. (2000) Falls in the elderly. *American Family Physician*, 61 (7), pp. 2159–68, 2173–4.

Igual, R., Medrano, C. & Plaza, I. (2013) Challenges, issues and trends in fall detection systems. *BioMedical Engineering OnLine*, 12, p.66.

Kępski, M. & Kwolek, B. (2014a) Detecting human falls with 3-axis accelerometer and depth sensor. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, pp. 770–773.

Kępski, M. & Kwolek, B. (2015) Embedded system for fall detection using body-worn accelerometer and depth sensor. In: *IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*. IEEE, pp. 755–759.

Kępski, M. & Kwolek, B. (2012a) Fall detection on embedded platform using kinect and wireless accelerometer. In: *Computers Helping People with Special Needs*. Lecture Notes in Computer Science. Springer Berlin Heidelberg, pp. 407–414.

Kępski, M. & Kwolek, B. (2016b) Fall Detection Using Body-worn Accelerometer and Depth Maps Acquired by Active Camera. In: *Hybrid Artificial Intelligence Systems*. Lecture Notes in Computer Science

Kępski, M. & Kwolek, B. (2014b) Fall Detection Using Ceiling-Mounted 3D Depth Camera. In: *International Conference on Computer Vision Theory and Applications*. pp. 640–647.

Kępski, M. & Kwolek, B. (2012b) Human fall detection by mean shift combined with depth connected components. In: *Computer Vision and Graphics*. Lecture Notes in Computer Science. Springer Berlin Heidelberg, pp. 457–464.

Kępski, M. & Kwolek, B. (2014c) Person Detection and Head Tracking to Detect Falls in Depth Maps. In: *Computer Vision and Graphics*. Lecture Notes in Computer Science. Springer International Publishing, pp. 324–331.

Kępski, M. & Kwolek, B. (2013) Unobtrusive Fall Detection at Home Using Kinect Sensor. In: *Computer Analysis of Images and Patterns*. Lecture Notes in Computer Science. Springer Berlin Heidelberg, pp. 457–464.

Kępski, M., Kwolek, B. & Austvoll, I. (2012) Fuzzy inference-based reliable fall detection using kinect and accelerometer. In: *Artificial Intelligence and Soft Computing*. Lecture Notes in Computer Science. Springer Berlin Heidelberg, pp. 266–273.

Kurniawan, S. (2008) Older people and mobile phones: A multi-method investigation. *International Journal of Human-Computer Studies*, 66 (12), pp. 889–901.

Kwolek, B. & Kępski, M. (2013) Fall Detection Using Kinect Sensor and Fall Energy Image. In: *Hybrid Artificial Intelligent Systems*. Lecture Notes in Computer Science. Springer Berlin Heidelberg, pp. 294–303.

Kwolek, B. & Kępski, M. (2016) Fuzzy inference-based fall detection using kinect and body-worn accelerometer. *Applied Soft Computing*, 40, pp. 305–318.

Kwolek, B. & Kępski, M. (2014) Human fall detection on embedded platform using depth maps and wireless accelerometer. *Computer Methods and Programs in Biomedicine*, 117 (3), pp. 489–501.

Kwolek, B. & Kępski, M. (2015) Improving fall detection by the use of depth sensor and accelerometer. *Neurocomputing*, 168, pp. 637–645.

Lee, T. & Mihailidis, A. (2005) An intelligent emergency response system: preliminary development and testing of automated fall detection. *Journal of Telemedicine and Telecare*, 11 (4), pp. 194–8.

Li, Q., Stankovic, J.A., Hanson, M.A., Barth, A.T., Lach, J. & Zhou, G. (2009) Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information. In: *International Workshop on Wearable and Implantable Body Sensor Networks*. IEEE, pp. 138–143.

Li, Y., Zeng, Z., Popescu, M. & Ho, K.C. (2010) Acoustic fall detection using a circular microphone array. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2010, pp. 2242–5.

Mastorakis, G. & Makris, D. (2012) Fall detection system using Kinect's infrared sensor. *Journal of Real-Time Image Processing*, 9 (4), pp. 635–646.

Parra-Dominguez, G.S., Taati, B. & Mihailidis, A. (2012) 3D Human Motion Analysis to Detect Abnormal Events on Stairs. In: *International Conference on 3D Imaging, Modeling, Processing, Visualization & Transmission*. IEEE, pp. 97–103.

Perry, J.T., Kellog, S., Vaidya, S.M., Youn, J.-H., Ali, H. & Sharif, H. (2009) Survey and evaluation of real-time fall detection approaches. In: *International Symposium on High Capacity Optical Networks and Enabling Technologies*. IEEE, pp. 158–164.

Piorek, M. & Winiecki, W. (2015) On calibration and parametrization of low power ultrawideband radar for close range detection of human body and bodily functions. In: *IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*. IEEE, pp. 639–645.

Planinc, R. & Kampel, M. (2012) Introducing the use of depth data for fall detection. *Personal and Ubiquitous Computing*, 17 (6), pp. 1063–1072.

Rougier, C., Auvinet, E., Rousseau, J., Mignotte, M. & Meunier, J. (2011) Fall detection from depth map video sequences. In: *Int. Conf. on Toward Useful Services for Elderly and People with Disabilities*. Springer-Verlag, pp. 121–128.

Rougier, C., Meunier, J., St-Arnaud, A. & Rousseau, J. (2006) Monocular 3D head tracking to detect falls of elderly people. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, pp. 6384–6387.

Rougier, C., Meunier, J., St-Arnaud, A. & Rousseau, J. (2011) Robust Video Surveillance for Fall Detection Based on Human Shape Deformation. *IEEE Transactions on Circuits and Systems for Video Technology*, 21 (5), pp. 611–622.

Sokolova, M. & Lapalme, G. (2009) A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45 (4), pp. 427–437.

Stone, E.E. & Skubic, M. (2014) Fall Detection in Homes of Older Adults Using the Microsoft Kinect. *IEEE Journal of Biomedical and Health Informatics*.

Stone, E.E. & Skubic, M. (2013) Unobtrusive, continuous, in-home gait measurement using the Microsoft Kinect. *IEEE Transactions on Biomedical Engineering*, 60 (10), pp. 2925 – 2932.

Wang, M., Huang, C. & Lin, H. (2006) An Intelligent Surveillance System Based on an Omnidirectional Vision Sensor. In: *IEEE Conference on Cybernetics and Intelligent Systems*. IEEE, pp. 1–6.

Yu, X. (2008) Approaches and principles of fall detection for elderly and patient. In: *International Conference on e-Health Networking, Applications and Services*. IEEE, pp. 42–47.

Zigel, Y., Litvak, D. & Gannot, I. (2009) A method for automatic fall detection of elderly people using floor vibrations and sound - proof of concept on human mimicking doll falls. *IEEE Transactions on Biomedical Engineering*, 56 (12), pp. 2858–67.