

---

## 유비쿼터스 컴퓨팅환경에서의 Multimodal Sensor 기반의

### Health care를 위한 사용자 행동 자동인식 시스템

- Multi-Sensor를 이용한 ADL(activities of daily living) 지수 자동 측정 시스템

↓

#### Design and Implementation of a User Activity Auto-recognition System based on Multimodal Sensor in Ubiquitous Computing Environment

↓

변성호, Byun Sung-Ho\*, 정유석 Jung Yu-Suk\*\*, 김태수 Kim Tae-Su\*\*  
김현우 Hyun-Woo Kim\*\*, 이승환 Seung Hwan Lee\*\*, 조위덕, We-Duke Cho\*\*\*

---

↓

요약 : 유비쿼터스 컴퓨팅 환경의 급속한 발전은 Multi-Sensor를 이용하여 자동으로 사용자의 행동인식을 가능한 환경을 만들어주었다. 따라서 이 논문에서는 사용자가 일상생활을 하는데 있어서 기본적으로 필요한 행동인 ADL(activities of daily living)의 수행능력을 분석하고 진단할 수 있는 Multi-Sensor기반의 ADL 자동 진단 시스템을 구축하였다. 두 개의 가속도 센서를 허벅지와 손목에 부착하여 사용자의 행동 정보를 수집하고 이를 Decision-Tree를 통하여 분석하여 사용자의 행동 정보를 수집하였다. 또한 Zigbee 센서를 이용하여 개별 물체의 Object ID를 이용하여 사용자의 위치정보와 주변의 물체의 정보를 수집하여 사용자의 상태 정보를 수집하였다. 이렇게 수집된 행동 정보와 상태 정보들을 통하여 일상생활에 필요한 약 20여 가지의 행동을 인식하였고 평균적으로 96%이상의 정확도를 나타내었으며 이를 통하여 ADL 지수를 자동으로 측정하였다.

↓

Abstract : A sensor system capable of automatically recognize activities would allow many potential Ubiquitous applications. This paper presents a new system for recognizing the activities of daily living(ADL) like walking, running, standing, sitting, lying etc. The system based on the state-dependent motion analysis using Tri-Accelerometer and Zigbee tag. Two accelerometers are used for the classification of body and hand activities. Classification of the environment and instrumental activities is performed based on the hand interaction with an object ID using.

↓

**핵심어:** *Activity Recognition, ADL INDEX, Multi sensor*

---

This research is supported by Foundation of ubiquitous computing and networking (UCN) Project, the Ministry of Knowledge Economy(MKE) 21st Century Frontier R&D Program in Korea and a result of subproject UCN 08B3-S3-10M

\* 주 저자 : 아주대학교 전자공학과 변성호 e-mail: Byun,Sungho@gmail.com

\*\* 공동저자 : 아주대학교 전자공학과 정유석 e-mail: j8508@ajou.ac.kr

\*\* 공동저자 : 아주대학교 전자공학과 김태수 e-mail: ts.kim84@gmail.com

\*\* 공동저자 : 아주대학교 전자공학과 김현우 e-mail : luckyguy@ajou.ac.kr

\*\* 공동저자 : 아주대학교 전자공학과 이승환 e-mail : shwan\_ee@gmail.com

\*\*\* 교신저자 : 아주대학교 전자공학과 조위덕; e-mail: wdukecho@gmail.com

## 1. 서론

유비쿼터스 컴퓨팅은 유, 무선 네트워크 접속기능을 갖춘 컴퓨터 뿐 아니라 네트워크와의 교신 능력을 가진 초소형 칩을 TV, 냉장고 전자레인지 등 가전기기, 자동차 등 모든 기기에 내장해 각종 정보를 손쉽게 송, 수신할 수 있도록 하여 생활을 보다 편리하게 해주는 것을 의미한다. 이러한 유비쿼터스 컴퓨팅 시대에 새로운 주목 받는 요소 기기인 웨어러블 컴퓨터(Wearable Computer)는 과거의 PC와는 차별적인 인간 중심의 지능형 디지털 컨버전스 정보 기기이다. 이러한 기술의 발달은 영상, 스포츠, 의료 등과 같은 다양한 분야에서 활용되고 있다. 이러한 정보기기의 발전은 사용자가 장시간 소형 웨어러블 센서를 장착하고 이를 통하여 자동적으로 데이터를 수집하고 모니터링 할 수 있는 환경을 조성하였다. 따라서 어린이나 노약자등의 사회적 약자에 대한 관찰이 중요한 분야로 대두되고 있는 상황에서 소형 웨어러블 센서를 이용하여 사용자를 모니터링하고 다양한 서비스를 제공하기 위한 연구가 활발히 진행 중이다. 본 논문에서는 노인과 장애인에 대한 맞춤형 서비스를 제공하기 위한 사회적 요구를 충족시키기 위하여 일상생활을 정상적으로 유지하기위한 기본적인 행동인 ADL(Activity of Daily Living)[1] 지수를 자동적으로 진단 할 수 있는 방법을 제안 한다.

ADL은 사용자의 일상 생활의 기능적인 활동 능력을 표현하는 지표로서, ADL을 정확히 인식하는 것은 어린이, 노약자 혹은 환자와 같이 보호를 필요로 하는 사람들을 관찰하고 연구하는데 있어서 매우 중요한 문제이다. ADL은 두 가지 항목으로 구성되어 있다. bathing, dressing, toileting, transferring, continence, feeding 와 같이 기본적인 활동 능력을 측정하는 요소인 Activities of Daily Living (ADL) 과 using telephone, shopping, food preparation, housekeeping, doing laundry, transportation, taking medications, handling finances 등과 같이 비교적 높은 수준의 행동인 주변 사회와 물리적인 상호작용을 나타내는 Instrumental Activities of Daily Living (IADL)으로 구성된다. 기존의 ADL 지수는 환자와 의사의 1:1 인터뷰와 질의응답을 통하여 평가되어왔다. 이러한 방식은 많은 시간을 필요로 하고 또한 사용자의 상태에 따라서 오류가 발생할 확률이 높아 정확한 판단을 내리는데 어려움이 많이 있었다. 따라서 자동으로 ADL 지수를 평가할 수 있는 시스템을 개발하려는 연구가 다방면에서 활발히 진행 중이다. 그 중에서, 대표적인 방법으로는 Fixed Thresholding 분류법을 이용한 방법, 패턴 매칭을 통한 분류 방법 그리고 신경망 학습 방법에 기반을 둔 분류 방법 등이 있다. Kiani 는 선택 트리(Decision Tree) 방법을 이용하여 보다 시스템적으로 접근이 가능하게 하였다. Bao와 Intille는 가속 센서 값으로부터 평균, 에너지 및 엔트로피 값을 특징 벡터로 하여 다양한 분

류기(classifier)에 대해서 성능을 평가하였다. 평가 대상이 된 분류기는 다음과 같다. Decision Table, IBL, Decision Tree(DT)와 Na ve Bayes 방법 등이 그것이다. 이 방법들 중에서 DT 방법이 가장 좋은 성능을 나타낸다는 것을 기존의 실험 결과로 나타났다. 성능이 가장 나은 것으로 평가된 DT 방법을 사용했음에도 불구하고, 그들이 보여준 결과는 일상생활에서 일어 날 수 있는 다양한 행동들에 대해서 약 80% 정도의 인식률을 보이는데 그쳤다. 이 인식률은 실험실 환경이 아닌 일반 환경에서 사용하기에는 다소 만족스럽지 못한 인식률이라고 할 수 있다. 이 논문에서는 가속도 센서와 Zigbee노드를 이용하여 ADL지수를 판단한다. 가속도 센서는 움직임에 따른 가속도 값과 중력에 의한 가속도 값에 대해서 동시에 반응하기 때문에 사용자의 몸에 부착하여 사용자의 자세 정보 및 사용자의 몸의 움직임을 측정하고 분석하기에 적합한 센서이다. 또한 Zigbee는 작은 크기와 저전력 설계를 통한 지속성의 확보를 통하여 사용자와 주변의 물체를 인식하고 무선 통신 이용하여 실시간 정보를 서버로 전송하여 사용자의 행동을 모니터링 할 수 있고 또한 궁극적으로는 ADL 지수를 판단할 수 있게 하였다.

## 2. 센서를 통한 행동인식 과정

수집된 센서 데이터들로부터 행동 인지를 수행 하기 위해서는 4가지의 단계가 필요하다.




그림 [1] 센서를 통한 행동인식 과정

- Signal processing
- Signal or data segmentation
- Feature computation
- Classification

Signal processing는 무선의 센서 데이터의 경우에는 일반적으로 신호 안에 포함되어 있는 잡음 신호를 제거하기 위해서 Band-pass filter를 통과 하는 부분과 사용하는 센서들에 따라서 신호 처리 과정에서 하드웨어 차이를 통해 발생하는 출력 값의 차이를 보정하기 위한 부분을 포함하고 있어서 신호의 무선 전송 과정 중에 발생될 수 있는 신호의 손실을 최소화 한다.

Signal or data segmentation는 일정시간 동안 수집된 데이터를 처리하는 과정이다. 센서 데이터를 통한 행동인지를 위해서는 하나의 센서 데이터 값이 아닌 특정 시간 동안에 수집되는 센서 데이터들을 연속적으로 분석하여야 하기

때문에 필요한 과정이다. Signal or data segmentation는 Sliding windows 방식과 Overlapping sliding windows로 구분된다.[3]

Sliding windows 방식은 시간 데이터가 겹쳐지지 않도록 하여 특정한 길이의 윈도우 크기로 센서의 데이터를 축적하여 모은다. 이에 비하여 Overlapping sliding windows는 일부의 시간 데이터가 겹쳐지도록 윈도우 크기를 설정한다. 따라서 연속되어 있는 데이터의 끊어짐을 최소화 한다. 따라서 달리기와 같이 주기적인 패턴을 나타내는 행동의 신호를 분석하기 위한 유용한 방식으로 주로 사용되어져 왔다.[4] Signal or data segmentation 과정 중에 고려해야 할 점은 윈도우의 길이의 설정이다. 윈도우의 크기가 길어질수록 행동인식의 정확도는 높아지지만 실시간으로 인식할 수 있는 시간의 차이가 발생한다. 이를 위해서 사용되는 방식이 Signal spotting 이다.[5] 예를 들면 서로 상관성이 없는 신호나 움직임의 스트리밍으로부터 발생하는 움직임의 시작과 끝을 구별하기 위한 것을 목표로 한다. Signal spotting의 가장 단순한 방식은 주어진 윈도우 시간 동안에 정해진 threshold 값을 넘는 시점을 표시한다. 이러한 방식은 신호 데이터의 덩어리에서 적합한 윈도우의 길이를 결정하게 된다. 이렇게 구분된 데이터를 이용하여 행동 인식을 위해 필요한 Feature computation을 거치게 된다. 행동 인식을 위하여 중요한 특징과 관계를 추출할 수 있다. 이러한 특징들이 사용자의 행동 분석을 위하여 적용될 알고리즘의 기본 요소로 사용된다. 예를 들면 시간과 주파수 영역의 특징, 분산, 평균, 상관관계나, 에너지, 엔트로피와 FFT계수 등은 매우 중요한 특징 요소이다.[6,7] 특징 요소들이 모아지고 난 후에 분석 알고리즘이 적용된다.

분석 알고리즘은 매우 다양한 종류의 알고리즘이 존재하고 각각의 알고리즘은 인식하려는 행동의 종류에 따라서 정확도가 달라진다. 분석 알고리즘은 크게 Discriminative classifiers와 Generative classifiers로 나눌 수 있는데 Discriminative classifiers는 주어진 기준들을 기본으로 하여 수학적 함수와 인식하려는 행동의 Decision boundary를 만들어 분석하고 Generative classifiers는 각각의 행동들이 일반적으로 적용될 수 있는 수학적 함수로 기술되기 전에 어떠한 과정을 거쳐서 생성되어졌는지를 나타내는 모델을 만들고 이러한 모델을 기준으로 하여 알고리즘이 적용된다.


Generative classifiers의 예로는 Bayesian 알고리즘이 있고 [8] Discriminative classifier에는 HMM 이 대표적이다.[9]

### 3. 실험환경

지금까지의 ADL 지수 항목의 행동을 인식하는 연구들은 비교적 간단한 행동들을 대상으로 제한된 환경 안에서 행동의 인식률을 구하는 것에 만족하였다. 그러나 이 실험에서는 그러한 제한된 환경의 ADL 항목이 아니라 다양하고 복잡한 ADL 행동을 인식하고 이를 통하여 자동으로 지수를 구하고


진단하는 시스템을 구현하는 것을 목표로 하여 실험을 진행했다. 이번 실험에서는 사람의 기본적인 Mobility (걷기, 앉기, 뛰기, 눕기, 계단 오르내리기) 등의 기본적인 움직임과 복잡한 행동인, Communication (전화하기, 교통수단이용, 대화하기, 쇼핑하기, 인터넷 이용), Self-care (목욕, 옷 갈아입기, 빗질하기), Sexual expression (화장하기, 잠자리 준비), Management of environmental hardware (청소하기, 식탁 차리기, 설거지, 공구 다루기) 등의 네 가지 항목을 기준으로 하여 총 다섯 가지의 항목과 각각의 항목에 속한 세부 항목 행동을 대상으로 하였다. 그림[2]처럼 평범한 가정의 모습처럼 실험실 환경을 설정하고 6명 (남자4, 여자2)을 대상으로 하여 일주일간 실험을 진행하였다. 또한 보다 정확한 행동 분류를 위하여 모든 실험실에서 진행한 모든 행동은 카메라로 기록하여 향후 수집된 데이터와 비교하였다. 실험에 사용된 센서들은 그림[3]와 같이 크기 5cm 이내, 무게 500g이내의 초소형 센서를 사용하여 사용자의 불편함을 최소화 하였다. 가속도 센서의 스펙은 X, Y, Z 축에 대하여 가속도 측정이 가능한 Tri-accelerometer를 사용하였다. 이 센서는 0.6mA이하의 전력을 소모하고 Resoulution은 60Hz 이다.

Zigbee 노드의 스펙은 MCU는 MSP430 micro controller 를 사용하였고, 16bit RISC, Ultra Low Current Consumption flash 48KB의 외부 메모리와, RAM 10KB의 내부 메모리를 갖는다. 가속도 센서는 손목과 허벅지에 부착하였다. 손목에 부착된 가속도 센서는 사용자의 손의 움직임을 판단하고 허벅지에 부착된 가속도 센서는 사람의 전체적인 움직임과 자세 판단하기 위하여 사용되었다. Zigbee 센서를 이용하여서는 사용자 주변의 환경 정보와 물체와의 상호 관계를 판단하기 위하여 사용되었다.



그림[2] Smart Home 구조도

본 논문에서 구성하려는 시스템은 그림[4]과 같이 크게 세 가지 부분으로 나누어진다. 첫 번째 부분은 Sensing Infrastructure part는 가속도 센서와 Zigbee Tag가 행동 인식을 위하여 필요한 Instrumental, Activity, Environment 등의 세 가지 요소 정보를 수집한다. 이렇게 수집된 데이터들은 Zigbee 통신을 이용하여 Context Widget으로 전달된다.



그림[3] 가속도 센서와 Zigbee 센서

수집된 정보를 기반으로 하여 Inference Engine에서 추론 알고리즘을 이용하여 각각의 수집된 데이터로부터 특징 요소들을 추출하여 행동을 인식한다. 인식된 행동을 바탕으로 하여 Service Invoker에서는 응급상황 알람, 사용자 개인에 대한 주기적인 Health Care 서비스, 실내에서나 원격지에서 모니터링이 적합한 서비스를 찾아서 호출 한다.

Inference Engine에서 ADL index 행동을 인식하기 위해서는 각각의 수집된 정보들을 개별적으로 이용하지 않고 그림[5]와 처럼 수집되어진 다른 정보들과 함께 이용되어 판단된다. 예를 들어 전화하기의 행동을 인식하려고 한다면 사용자의 장소 정보를 담고 있는 환경 정보와 사용자의 Body states는 중요하게 고려될 요소가 아니고 사용자 주변의 Object 정보와 사용자의 Hand states가 중요 요소로 고려되어야 정확한 사용자의 행동을 인식할 수 있다. 이처럼 각각의 행동을 하는데 있어서 필수적으로 고려되어야 할 중요 요소를 판단하고 이를 기반으로 하여 Decision-Tree 알고리즘을 적용하여 사용자의 행동을 판단한다.

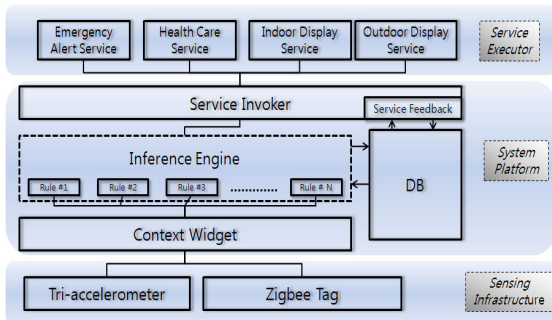


그림 [4] ADL자동 지수 측정 시스템 구조도

이러한 과정을 통하여 사용자 행동을 인식하고 미리 정의된 다섯 가지 항목 (Mobility, Communication, Self-care, Sexual expression, Management of environmental hardware) 별로 세부 항목의 행동 수행 능력을 평가하여 각각의 항목의 지수를 나타내고 이를 통하여 전체적인 ADL 항목의 수행능력을 평가한다.

#### IV. 실험 결과

이 연구의 중요 목적은 Zigbee와 가속도 센서를 사용하여

사용자의 행동을 인식하고 ADL지수를 결정하는 것이다. 따라서 사용자의 행동을 인식하는데 영향을 미치는 두 가지 파라미터인 Zigbee와 가속도 센서 분리한 실험과 두 가지 파라미터를 모두 고려한 실험으로 나누어 실험을 진행하였고 각각의 실험의 인식률을 구하여 두 가지 결과를 비교 하였다.





그림 [5] Inference Engine 행동인식과정

각각의 행동에 대한 인식률을 표[1]로 정리 하였고, 표[2]는 사용자의 하루 동안의 인식된 움직임의 비율을 표로 나타내었다. 사용자의 움직임은 Zigbee Tag만을 이용하였을 경우 정확한 판단할 수 없어서 인식률을 구하지 못하였다. 하지만 가속도 센서와 같이 사용되어 인식률을 고려하였을 경우에는 사용자의 움직임을 판단할 수 있는 하나의 파라미터로 판단되어 사용자의 행동인식률을 높이는데 기여하는 요소가 되었다. 반대로 나머지 항목의 행동을 인식하는 과정에서는 가속도 센서만으로는 정확한 행동을 인식하지 못하였지만, Zigbee Tag와 같이 사용한 경우의 실험에서는 행동인식률을 높일 수 있는 요소로 작용하였다.

실험 결과 두가지 파라미터를 모두 고려한 실험에서의 평균적인 인식률은 약 96%로 결과가 나왔다. 실험 대상자들이 행동을 수행하는 과정중의 개인적인 특성을 고려한다면 매우 정확한 실험 결과라고 할 수 있다.



그림[6] 가속도 센서 데이터 값

그림[6]는 가속도 센서를 통하여 수집된 정보를 FFT 변환을 통하여 구한 결과 값이다. 그래프의 X축은 시간을 Y축은 행동에 따른 값의 변화를 나타낸다. 각각의 그래프는 X, Y, Z를 나타낸다.

그림[7]은 사용자가 원격으로 떨어진 곳에서 사용자의 행동에 대한 5가지 항목의 ADL 지수와 변화추이를 모니터링 할 수 있는 어플리케이션이다. 사용자 행동의 수행 결과에



따라서 지수를 나타내고 이를 통하여 전체적인 ADL지수를 구하게 된다. 또한 일정 기간 동안의 지수의 변화를 그래프로 나타내고 이에 대한 의사 코멘트와 적합한 서비스를 자동으로 추천하여 주는 시스템을 구축하여 사용자와 병원간의 간편한 진료와 환자의 모니터링이 가능한 환경을 구축할 수 있도록 하였다.



그림 [7] ADL 지수 진단 UI

Activities	ACCURATION(%)			
	Zigbee Only	Tri-Acceleration Only	Tri-Acceleration + Zigbee	
Mobility	Walking	-	97.85	100
	Sitting	-	96.74	100
	Running	-	92.17	97.88
	Lying	-	97.58	100
	Up stair	-	91.63	100
	Down stair	-	89.45	96.56
Communication	Using Phone	88.74	-	96.54
	Talking	86.45	-	91.63
	shopping	92.45	-	96.01
	Going-out	93.54	-	100
	Using PC	87.54	-	100
Watching TV	85.21	-	100	
Self-care	Bath	87.63	-	97.45
	change clothes	90.63	-	96.99
	combing	95.55	-	98.52
	Cooking	97.52	-	97.03
	Reading	91.85	-	96.45
	brushing	90.78	-	99.52
Sexual expression	Cosmetic	89.85	-	96.85
	Setting bed	80.85	-	97.04
Management of environmental hardware	Cleaning	89.85	-	98.56
	dishwashing	87.85	-	100
	Using tools	92.52	-	100
	Using washing machine	94.85	-	100

표 [1] Accuracy Table(%)

## V. 결론

본 논문에서 구현한 ADL 지수 자동 측정 시스템은 소형의 웨어러블 멀티 센서를 이용하여 사용자의 행동 정보와 상황 정보를 수집하고 DT알고리즘을 통하여 사용자의 행동을 인식하여 이를 통하여 ADL지수를 구하고 이를 모니터링 할 수 있는 시스템이다.

기존에 제안된 시스템들은 실생활에 적용되기에는 많이 제약이 있기 때문에 효과적인 모니터링 하기에는 많은 어려움이 있었다. 본 논문에서 제안한 시스템은 원거리에서 사용자의 정보 수집과 지수 계산이 가능하고 비교적 자유로운 환경에 적용 될 수 있도록 실험 환경을 설정하였고 이를 통하여 만족할 만한 결과를 얻을 수 있었다. 이번 실험의 결과를

통하여 실질적인 사용자의 행동을 인식할 수 있는 적용 기반을 확보할 수 있다. 좀 더 효율적인 관리를 위해서는 Zigbee 센서 노드의 전원 문제와 사용자 인터페이스 기능의 강화 연구가 추가적으로 진행되어 사용자의 정보를 수집하는 과정에서의 사용자의 불편함을 최소화하고 궁극적으로는 무구속의 상태에서 사용자의 행동을 인식할 수 있는 기술이 필요하다. 또한 센서를 이용하여 수집된 다양한 행동 인식 데이터 분석을 위한 효율적인 알고리즘과 자유로운 환경에 적용할 될 수 있도록 사용자를 위한 인터페이스가 추가적으로 필요하다.




표 [2] Daily Mobility(%)

## References

- [1] S. Katz, "Assessing Self-Maintenance: Activities of Daily Living, Mobility, and Instrumental Activities of Daily Living," "Journal of the American Geriatrics Society, vol. 31, no. 12, pp. 721-726, 1983.
- [2] S. Rasoul Safavian and David Landgrebe "A Survey of Decision Tree Classifier Methodology" Institute of Electrical and Electronics Engineers, Reprinted from IEEE Transactions on Systems
- [3] Jonathan Lester<sup>1</sup>, Tanzeem Choudhury<sup>2</sup>, Nicky Kern<sup>3</sup>, Gaetano Borriello<sup>2,4</sup> and Blake Hannaford<sup>1</sup> University of Washington, Seattle "A Hybrid Discriminative/Generative Approach for Modeling Human Activities"
- [4] Ling Bao and Stephen S. Intille "Activity Recognition from User-Annotated Acceleration Data" Springer - Verlag Berlin Heidelberg 2004
- [5] H. Junker, P. Lukowicz, and G. Troster, "Continuous Recognition of Arm Activities with Body-Worn Inertial Sensors," Proceedings of the 8th IEEE International Symposium on Wearable Computers (ISWC '04), pp. 188-189, 2004.
- [6] O. Amft, H. Junker, and G. Troster, "Detection of Eating and Drinking Arm Gestures Using Inertial Body-Worn Sensors," in Proceedings of The Ninth IEEE International Symposium on Wearable Computers (ISWC '05), Osaka, Japan: IEEE Computer Society, 2005, pp. 160-163.
- [6] J. Lester, T. Choudhury, G. Borriello, S. Consolvo, J. Landay, K. Everitt, and I. Smith, "Sensing and

- Modeling Activities to Support Physical Fitness," in Workshop Proceedings of Ubicomp(Workshop: Monitoring, Measuring and Motivating Exercise: Ubiquitous Computing to Support Fitness). Tokyo, Japan, 2005.
- [8] R. Duda, P. Hart, and D. Stork, in Pattern Classification, 2nd ed: John Wiley & Sons, 2000.
- [9] J. Mantyjarvi, J. Himberg, and T. Seppanen, "Recognizing Human Motion with Multiple Acceleration Sensors," in Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics, vol. 2: IEEE Press, 2001, pp. 747-752
- [9] L. R. Rabiner and B.-H. Juang, "A Theory and Implementation of Hidden Markov Models," in Fundamentals of Speech Recognition: Prentice Hall, 1993, pp. 321-389.
- [10] D. Wilson, S. Consolvo, K. Fishkin, and M. Philipose, "In-Home Assessment of the Activities of Daily Living of the Elderly," in CHI 2005: Workshops - HCI Challenges in Health Assessment, April 2005.
- [11] M. Philipose, K. Fishkin, M. Perkowitz, D. Patterson, D. Fox, and H. Kautz, "Inferring Activities from Interactions with Objects," IEEE Pervasive Computing, vol. 3, no. 4, pp. 50-57, October 2004.
- Korhonen,
- [12] J. Lester, T. Choudhury, and G. Borriello, "A Practical Approach to Recognizing Physical Activities," in Proc. Pervasive, May 2006.