

# Design and Implementation of a Two-Phase Activity Recognition System Using Smartphone's Accelerometers

Jong-Hwan Kim<sup>†</sup> · In-Cheol Kim<sup>\*\*</sup>

## ABSTRACT

In this paper, we present a two-phase activity recognition system using smartphone's accelerometers. To consider the unique temporal pattern of accelerometer data for each activity, our system executes the decision-tree(DT) learning in the first phase, and then, in the second phase, executes the hidden Markov model(HMM) learning based on the sequences of classification results of the first phase classifier. Moreover, to build a robust recognizer for each activity, we trained our system using a large amount of data collected from different users, different positions and orientations of smartphone. Through experiments using 6720 examples collected for 6 different indoor activities, our system showed high performance based on its novel design.

Keywords : Activity Recognition, Smartphone, Accelerometer, Two-Phase Classification, Decision Tree, Hidden Markov Model

## 스마트폰 내장 가속도 센서를 이용한 2단계 행위 인식 시스템의 설계 및 구현

김 종 환<sup>†</sup> · 김 인 철<sup>\*\*</sup>

## 요 약

본 논문에서는 스마트폰 내장 가속도 센서를 이용한 2단계 행위 인식 시스템을 제안한다. 제안하는 행위 인식 시스템에서는 각 행위 별 가속도 데이터의 시간적 변화 패턴을 충분히 반영하기 위해, 1단계에서는 결정트리(DT) 학습을 수행하고, 2단계에서는 1단계 분류 결과들의 시퀀스를 이용하여 은닉 마코프 모델(HMM) 학습을 수행한다. 또한, 견고한 행위 인식을 얻기 위해, 동일한 행위에 대해 서로 사용자와 서로 다른 스마트폰 위치와 방향으로부터 수집한 다양한 대용량 데이터를 이용하여 본 시스템을 훈련하였다. 6가지 실내 행위들에 대해 수집한 6720개의 가속도 센서 데이터를 이용한 실험을 통해, 본 시스템은 앞서 설명한 설계 방식을 기초로 높은 인식 성능을 보여주었다.

키워드 : 행위 인식, 스마트폰, 가속도 센서, 2단계 분류, 결정 트리, 은닉 마코프 모델

## 1. 서 론

스마트폰 보급률이 높아지고 모바일 센서 기술이 발전함에 따라 스마트폰을 이용한 사용자 행위 인식에 관한 연구들이 활발히 진행되고 있다[1, 2, 3]. 특히 가속도 센서는 다른 센서에 비해 에너지 소모가 적고, 조명이나 소음과 같은 환경에 영향을 적게 받으므로 지속적으로 사용자의 움직임을 감지할 수 있다. 가속도 센서를 이용한 사용자 행위 인

식 기술은 다양한 분야에 활용될 수 있다. 예를 들면 매일 사용자의 일상을 체크하여 건강한 생활패턴을 유지하는 데 도움을 줄 수 있으며[4, 5], 노약자의 경우 낙상과 같은 긴급 상황을 가족에게 알려 줄 수 있다[6].

스마트폰 가속도 센서를 이용하여 사용자의 행위를 인식할 경우, 스마트폰의 위치와 방향에 따라 행위 인식의 결과가 달라질 수 있는 문제점이 있다. 이러한 문제점을 해결하고자 많은 선행 연구들에서는 3축 가속도 센서 측정치의 크기(magnitude)만을 이용하는 방법[7], 3축 가속도 센서 측정치를 스마트폰의 방향과 관계없이 상, 하, 좌, 우 움직임에 대한 가속도 크기를 이용하는 방법[8] 등을 시도하였다. 하지만 이들 방법은 가속도의 크기뿐만 아니라 방향 정보도 필요한 계단 올라가기, 계단 내려가기와 같은 행위를 구별하기 힘들다는 문제점이 있다. 또한 많은 선행 연구들에서

※ 본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음.  
※ 이 논문은 제40회 한국정보처리학회 추계학술발표대회에서 '스마트폰 가속도 센서를 이용한 2단계 행위 인식 시스템의 설계'의 제목으로 발표된 논문을 확장한 것임.  
† 준 회 원 : 경기대학교 컴퓨터과학과 석사과정  
\*\* 종신회원 : 경기대학교 컴퓨터과학과 교수  
논문접수 : 2013년 12월 9일  
심사완료 : 2014년 1월 3일  
\* Corresponding Author : In-Cheol Kim(kic@kyonggi.ac.kr)

는 결정트리(Decision Tree), 신경망(Neural Network), SVM (Support Vector Machine) 등의 알고리즘 사용하여 행위 모델 학습과 분류를 수행하였다. 하지만 이러한 학습 알고리즘은 시간에 따른 가속도 센서 데이터의 변화 패턴을 충분히 반영하지 못한다는 한계점을 지니고 있다.

본 논문에서는 스마트폰 3축 가속도 센서를 이용한 효과적인 사용자 행위 인식 시스템을 제안한다. 제안하는 시스템에서는 행위별 가속도 센서 데이터의 변화 패턴을 충분히 반영하기 위해, 1단계 분류에서는 결정트리 모델 학습과 분류를 수행하고, 2단계 분류에서는 1단계 분류 결과들의 시퀀스를 이용하여 HMM(Hidden Markov Model) 모델 학습과 분류를 수행한다. 또한, 본 논문에서 제안하는 행위 인식 시스템에서는 특정 사용자나 스마트폰의 특정 위치, 방향 변화에서도 견고한 행위 인식을 위해, 동일한 행위에 대해 사용자와 스마트폰의 위치, 방향을 변경하면서 다양한 훈련 데이터를 수집하였다.

본 논문에서 제안하는 행위 인식 시스템의 분류 성능을 분석하기 위해 사용자, 위치, 방향 등이 서로 다른 스마트폰으로부터 수집한 총 6720개의 가속도 센서 데이터들을 이용하여, 총 6가지 실내 행위들을 인식하기 위한 실험들을 수행하고 그 결과를 소개한다.

## 2. 관련 연구

[7]의 연구에서는 스마트폰의 서로 다른 위치, 방향을 고려한 행위 인식 방법을 제안하였다. 인식 대상 행위는 {정지, 걷기, 뛰기, 계단 올라가기, 계단 내려가기, 운전하기} 총 6가지이며, 이를 위해 {상의 왼쪽 앞주머니, 상의 오른쪽 앞주머니, 바지 왼쪽 앞주머니, 바지 오른쪽 앞주머니, 바지 왼쪽 뒷주머니, 바지 오른쪽 뒷주머니} 총 6가지 서로 다른 스마트폰 위치와 {액정이 안쪽방향/바깥쪽 방향, 위아래가 정방향/역방향} 등 총 4가지 서로 다른 스마트폰 방향에 따른 영향을 완화시키기 위해 3축 가속도 센서 측정치의 크기를 특징에 포함시켰다. 이 연구에서는 SVM을 이용하여 모델 학습 및 분류를 수행하였다.

[8]의 연구에서는 스마트폰의 서로 다른 위치를 고려한 행위 인식 방법을 제안하였다. 이 연구에서는 {정지, 걷기, 뛰기, 자전거타기, 자동차타기} 등 총 5가지 행위를 인식 대상으로 삼았다. 그리고 3축 가속도 센서 측정치를 변환하여 스마트폰의 방향과 관계없이 상, 하, 좌, 우 움직임의 대한 가속도 크기를 이용해 특징을 추출하였다. 또 이 연구에서는 결정트리를 이용하여 행위 모델을 학습하고 분류하였다.

## 3. 시스템 설계

### 3.1 시스템 개요

본 논문에서는 스마트폰 내장 가속도 센서를 이용한 효과적인 사용자 행위 인식 시스템을 제안한다. 인식 대상 행위

들은 Fig. 1에서 보는 바와 같이 {서기, 앉기, 걷기, 뛰기, 계단 올라가기, 계단 내려가기}로 총 6가지이다.



Fig. 1. Indoor physical activities

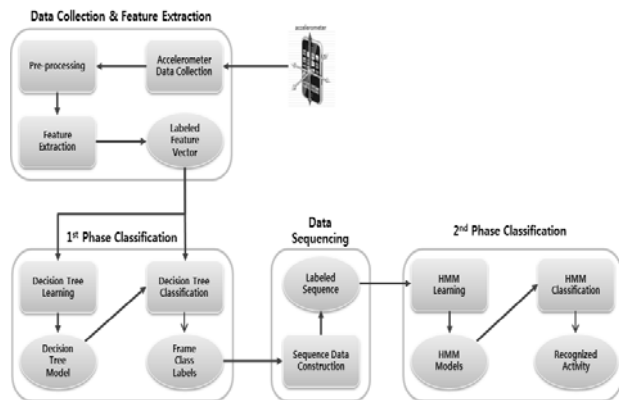


Fig. 2. Overall system structure

스마트폰 사용자의 6가지 행위 인식은 Fig. 2와 같은 과정을 거쳐 수행한다. 데이터 수집 및 특징 추출 단계(data collection & feature extraction)에서는 스마트폰 3축 가속도 센서를 통해 각 행위 별 데이터를 수집하고, 불필요한 데이터를 제거하는 전처리(pre-processing)과정을 거친다. 이어서 수집한 가속도 센서 데이터를 변환하여 그 변환된 값으로부터 총 84개의 특징을 추출(feature extraction)한다. 1단계 분류(1<sup>st</sup> phase classification)에서는 위 단계를 통해 만들어진 특징 벡터(feature vector)에 결정트리 알고리즘을 적용하여 모델 학습 및 분류를 수행한다. 하지만 걷기, 계단 올라가기, 계단 내려가기 등은 시간에 따른 복잡한 패턴 변화를 보이기 때문에 결정트리만을 이용했을 경우 행위를 인식하는데 한계가 있다. 따라서 데이터 순차화 단계(data sequencing)를 통해 1단계 분류 결과들을 일정한 길이만큼 모아서 시퀀스 데이터로 만든다. 2단계 분류(2<sup>nd</sup> phase classification)에서는 앞서 생성한 시퀀스 데이터를 기초로 시계열 학습 알고리즘인 HMM 적용한 모델 학습 및 분류를 수행한다. 이와 같은 과정을 통해 행위 인식 결과(recognized activity)를 얻는다.

### 3.2 데이터 수집 및 전처리

각 행위별 가속도 센서 데이터를 수집하기 위해 안드로이드 기반의 스마트폰을 사용하였다. 가속도 센서 데이터는 1초에 100개 정도 수집한다. 스마트폰 가속도 센서를 이용한 사용자 행위 인식은 사용자 마다 행위 패턴이 모두 달라 사용자에게 따른 의존성이 크다. 또한 스마트폰의 위치나 방향

이 일정하게 고정되어 있지 않아 가속도 센서 데이터를 토대로 서로 다른 행위들을 정확히 분류하는데 어려움이 있다. 따라서 본 논문에서는 특정 사용자나 스마트폰의 특정 위치, 방향 변화에 견고한 행위 인식을 위하여, 동일한 행위에 대해 사용자와 스마트폰의 위치, 방향을 변경하면서 다양한 훈련 데이터를 수집한다. 스마트폰의 위치는 Fig. 3과 같은 {손, 바지 앞주머니, 바지 뒷주머니} 등 3가지로 가정한다.



Fig. 3. Different positions of a smartphone

스마트폰의 방향은 스마트폰을 손에 쥐고 있는 경우에는 {스마트 폰 액정 보기/팔 흔들기} 등 2가지이며, 바지 주머니 속에 있는 경우에는 {액정이 안쪽방향/바깥쪽 방향, 위아래가 정방향/역방향} 등 4가지로 가정한다.

수집된 가속도 데이터 중에서는 각 행위와 관련이 없는 데이터 부분들이 포함될 수 있다. 예를 들어 수집을 시작하면서 스마트폰을 주머니에 넣는 행위 또는 수집을 종료하기 위해 스마트폰을 주머니에서 꺼내는 행위 등이 있을 수 있다. 이러한 데이터 부분들은 모델 학습과 분류에 영향을 주기 때문에 전처리 과정을 통해 제거한다.

### 3.3 특징 추출

안드로이드 기반의 스마트폰으로 수집한 가속도 센서 데이터를 변환하여 그 변환된 값으로부터 총 84개의 특징들로 이루어진 특징 벡터를 만든다. 특징 추출 과정은 Fig. 4와 같다.

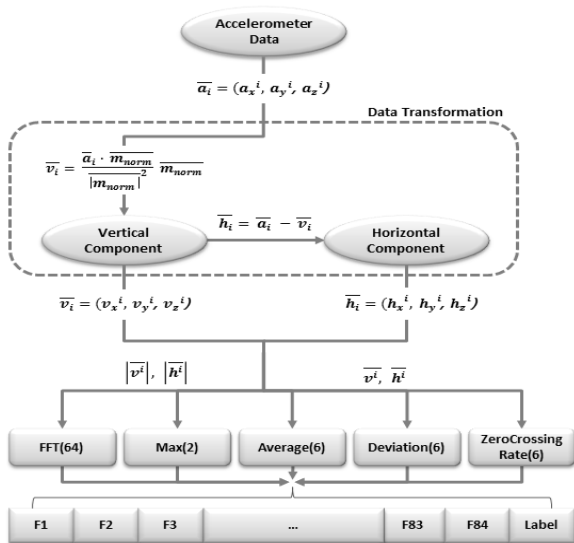


Fig. 4. Feature extraction process

스마트폰 가속도 센서는 동일한 행위에 따라 다른 측정치를 보인다. 대부분 선행 연구들에서는 이를 극복하기 위해 3축 가속도 센서 측정치의 크기를 이용한다. 하지만 이러한 방법은 스마트폰 상, 하, 좌, 우 움직임의 대한 정보 손실로 인해 행위 인식에 한계점이 나타난다. 이러한 한계점을 극복하기 위해 가속도 센서 측정치를 수직, 수평 성분으로 변환하여 특징 추출에 이용한다. 수직(vertical component), 수평 성분(horizontal component)은 스마트폰 방향의 관계없이 스마트폰에 상, 하, 좌, 우 움직임을 알 수 있다. 가속도 센서 측정치를 수직, 수평 성분으로 바꾸기 위해서는 (식 1)과 같이  $i$  번째 3축 가속도 센서 측정치  $\bar{a}_i$ 를 32개씩 모아 각 축(x, y, z)의 평균  $\bar{m}$ 을 구하고, (식 2)와 같이  $\bar{m}$ 의 단위 벡터  $\overline{m_{norm}}$ 을 구한다.

$$\bar{m} = \left( \left( \frac{\sum_{i=1}^{n+32} a_x^i}{32} \right), \left( \frac{\sum_{i=1}^{n+32} a_y^i}{32} \right), \left( \frac{\sum_{i=1}^{n+32} a_z^i}{32} \right) \right) \quad (1)$$

$$\overline{m_{norm}} = \left( \frac{m_x}{\sqrt{m_x^2 + m_y^2 + m_z^2}}, \frac{m_y}{\sqrt{m_x^2 + m_y^2 + m_z^2}}, \frac{m_z}{\sqrt{m_x^2 + m_y^2 + m_z^2}} \right) \quad (2)$$

이어서 (식 3)과 같이  $\overline{m_{norm}}$ 에  $\bar{a}_i$ 를 투영(projection)하면 수직 성분(vertical component)  $\bar{v}_i$ 을 구할 수 있다.

$$\bar{v}_i = \frac{\bar{a}_i \cdot \overline{m_{norm}}}{|\overline{m_{norm}}|} \overline{m_{norm}} \quad (3)$$

수평성분(horizontal component)  $\bar{h}_i$ 은 (식 4)와 같이  $\bar{a}_i$ 와 수직 성분  $\bar{v}_i$ 의 차(difference)로 계산할 수 있다.

$$\bar{h}_i = \bar{a}_i - \bar{v}_i \quad (4)$$

이와 같은 데이터 변환 과정으로 얻어진 수직, 수평 성분의 크기(magnitude) ( $|\bar{v}_i|, |\bar{h}_i|$ ) 각각으로부터 최대값 Max(2)과 FFT(Fast Fourier Transform) 계수 FFT(64) 등의 특징들을 추출한다. 이는 Fig. 5와 같은 각 행위별 가속도 수직, 수평 성분 크기의 패턴 변화를 파악하는 데 유용하다.

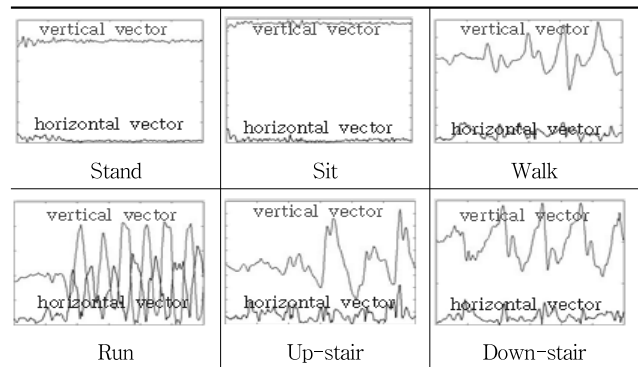


Fig. 5. Acceleration patterns of individual activities

하지만 수직, 수평 성분의 크기만으로는 Fig. 5 {걷기, 계단 올라가기, 계단 내려가기}와 같이 방향 정보도 필요한 행위들을 분류하는데 한계가 있다. 따라서 본 논문에서는 방향 정보를 가지는 수직, 수평 성분  $(\overline{v_i}, \overline{h_i})$  각각으로부터 평균 Average(6), 표준편차 Deviation(6), 영교차율 ZeroCrossingRate(6) 등의 특징들을 추가적으로 추출하여 총 84개의 특징으로 이루어진 특징 벡터를 구성한다.

3.4 모델 학습 및 분류

특징 추출 단계에서 얻어진 특징 벡터를 이용하여 1단계 결정트리(Decision Tree) 모델 학습 및 분류를 수행한다. 1단계 분류에서 결정트리를 사용하는 이유는 다른 학습 알고리즘에 비해 비교적 높은 인식률과 속도를 보이고, Weka에서 제공하는 라이브러리를 이용해 쉽게 구현할 수 있다. 그러나 시간 변화에 따라 여러 하위 동작들의 반복으로 이루어진 행위를 결정트리만으로 구분하는 데 한계가 있다. 따라서 본 논문에서는 시간에 따른 가속도 센서 데이터의 변화 패턴을 충분히 반영할 수 있는 시계열 학습 알고리즘인 HMM(Hidden Markov Model)을 이용한 2단계 행위 인식 시스템을 제안한다.

2단계 행위 인식 시스템은 결정트리를 이용한 1단계 분류를 통해 그 결과를 HMM 입력으로 사용하므로, 단순히 HMM만을 사용하는 경우 보다 특징 벡터의 차원 축소 효과가 있어 계산량이 감소하는 장점이 있다.



Fig. 6. Sequence data format

본 시스템에서 Fig. 6과 같은 훈련 시퀀스 데이터를 이용해, 인식하고자 하는 행위 별로 HMM 모델을 학습한다. 시퀀스 데이터는 결정트리 모델을 통해 분류된 결과를 10개씩 고정 길이로 모으고, 해당 행위 라벨을 부착한다.

HMM 모델 학습을 위해 필요한 요소로는 상태(state) 수와 관측(observation)수, 그리고 모델의 구조(structure) 등이 있다. 상태 개수는 실험을 통해 서기와 계단 올라가기 3개, 나머지 행위는 2개로 결정하였다. 관측 개수는 동일하게 각 행위 모델 별로 6개로 정하였다. 또한 모델 구조는 여러 하위 동작들의 반복으로 이루어진 행위를 표현하기에 적합한 Fig. 7과 같은 HMM 어고딕(ergodic)모델을 사용하였다.

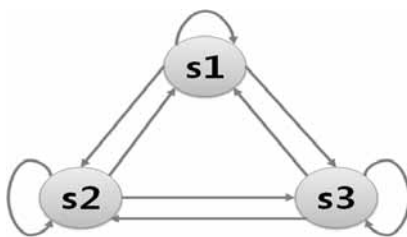


Fig. 7. Ergodic HMM

HMM 모델 학습을 위해서는 Baum-Welch 학습 알고리즘을 적용하였다. 이와 같은 방법으로 각 행위(서기, 앉기, 걷기, 뛰기, 계단 올라가기, 계단 내려가기)마다 HMM 모델을 각각 생성하였다.

분류 단계에서는 행위별 HMM 모델이 있을 때 (식 5)를 이용하여 입력된 테스트 데이터 X가 나타날 확률이 가장 큰 HMM 모델의 행위로 분류한다. 이때  $\lambda_a$ 는 행위 a를 나타내는 HMM 모델을 의미한다.

$$\underset{a \in A}{\operatorname{argmax}} (P(X|\lambda_a)) \tag{5}$$

4. 실험 및 평가

본 논문에서 제안하는 가속도 센서를 이용한 행위 인식 시스템의 성능을 분석하기 위한 실험을 수행하였다. 실험을 위한 데이터는 안드로이드 스마트폰을 이용하여 세 명의 실험자로부터 6가지 행위 각각에 대해 1120개씩 실험 데이터를 수집하여 총 6720개 데이터 집합을 구축하였다. 훈련용으로 1680개, 테스트용으로 5040개의 데이터를 사용하였다.

실험은 크게 네 가지로 진행하였다. 첫 번째 실험은 본 논문에서 제안하는 2단계 분류 방법의 각 행위별 HMM 모델의 최적의 상태 수를 찾는 목적으로 수행하였다. 이 실험을 위해 각 행위별로 상태 수가 다른 HMM 모델 학습을 하였고, 테스트 데이터에 평균 로그 우도를 비교하였다. Table 1은 각 행위 별로 상태 수에 따른 HMM 모델의 평균 로그 우도 값이다. 서기와 계단 올라가기는 상태 수가 3개일 때, 나머지 행위들은 2개일 때 가장 높은 평균 로그 우도 값을 나타낸다. 위 결과를 통해 각각 행위에 대한 HMM 모델의 상태 개수를 정하였다.

두 번째 실험은 결정트리만을 이용한 1단계 분류 방법과 HMM을 함께 적용한 2단계 분류 방법의 성능을 비교하기 위한 목적으로 수행하였다. Fig. 8은 각 행위별 분류 정확도를 측정된 결과이다. 결정트리만을 이용한 1단계 분류 방법은 평균 68%의 성능을 보였고, HMM을 함께 적용한 2단계 분류 방법은 1단계 분류 방법보다 13.8% 향상된 81.8%의 성능을 보였다. 계단 내려가기를 제외한 나머지 행위에선 10% 이상의 성능 향상을 보였고, 뛰기에 경우 소폭 상승한 모습이 보였다. 계단 내려가기의 경우 성능이 낮은 이유는 수직, 수평 성분 각축의 평균, 표준편차, 영교차율 등의 특징들로는 걷기, 계단 올라가기, 계단 내려가기와 같은 행위를 구분하는데 부족함이 있어 분류 정확도가 낮게 나온 것으로 추정된다.

세 번째 실험은 본 논문에서 제안하는 2단계 분류 방법의 사용자 의존성을 알아보기 위한 목적으로 수행하였다. 이

Table 1. Average log likelihoods of HMM models

HMM Models \ Number of State	Stand	Sit	Walk	Run	Up-Stair	Down-Stair
2	-7.7942	-6.7303	-10.2339	-4.0309	-9.1054	-8.304
3	-7.3823	-6.739	-10.5200	-6.3392	-8.9584	-9.0867
5	-7.4448	-6.7349	-10.8086	-8.1010	-9.3705	-8.5267
7	-7.6867	-6.733	-10.8423	-5.7276	-9.6023	-8.8924
10	-8.0503	-6.731	-11.2147	-10.2379	-10.4774	-8.9836

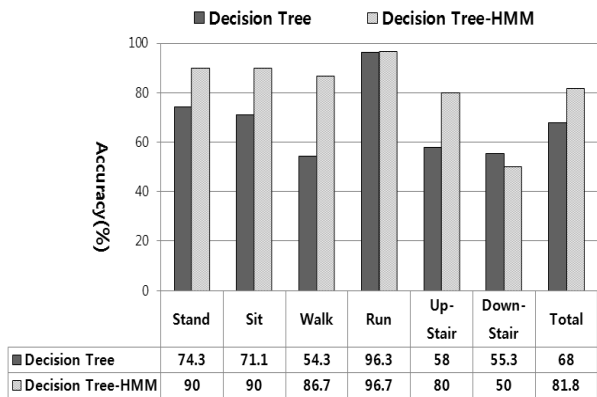


Fig. 8. Classification accuracy: DT vs DT-HMM

실험을 위해 사용자별(Individual Users) 분류성과 혼합 사용자(Mixed Users) 성능을 비교하였다. 사용자별 분류 성능은 동일한 사용자의 데이터 집합을 훈련용과 테스트용으로 나누어 학습하고 분류 성능을 측정하였다. 반면에 혼합 사용자 분류성은 3명의 실험자 데이터를 사용자 구분 없이 혼합한 후, 훈련용과 테스트용으로 나누어 적용하고 분류 성능을 측정하였다. 결과는 Fig. 9와 같이 각 위치별로 평균 88.3~95%이고, 사용자를 혼합하였을 경우 약 2~3%로 낮은 84.8~93.2%의 정확도를 보인다. 이를 통해 제안한 분류 방법이 다양한 여러 사용자에게도 여전히 높은 성능을 보인다는 것을 알 수 있다.

마지막 실험은 2단계 행위 인식 방법의 스마트폰 위치의 존성을 알아보기 위한 목적으로 수행하였다. 이 실험을 위해 위치별(Individual Locations) 분류 성과와 혼합 위치(Mixed Locations) 분류 성과를 비교하였다. 위치별 분류 성과는 동일한 스마트폰 위치의 데이터 집합을 훈련용과 테스트용으로 나누어 각각 학습하고 분류성을 측정하였다. 반면에 혼합 위치 분류 성과는 3곳에 스마트폰 위치의 데이터를 위치 구분 없이 혼합한 후, 훈련용과 테스트용으로 나누어 학습하고 분류 성과를 측정하였다. 결과는 Fig. 10과 같이 각 스마트폰 사용자 별로 정확도는 평균 90.6~94.1%이고, 위치를 모두 혼합하였을 경우 약 2% 정도 낮은 90.3~92.6%의 평균 정확도를 보인다. 이를 통해 제안한 분류 방법이 다양한 여러 위치에서도 여전히 높은 성능을 보임을 알 수 있다.

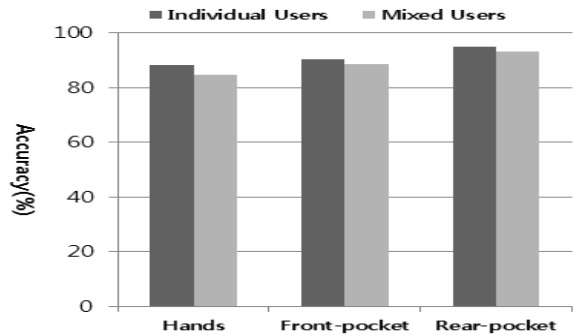


Fig. 9. User dependency: Individual vs Mixed

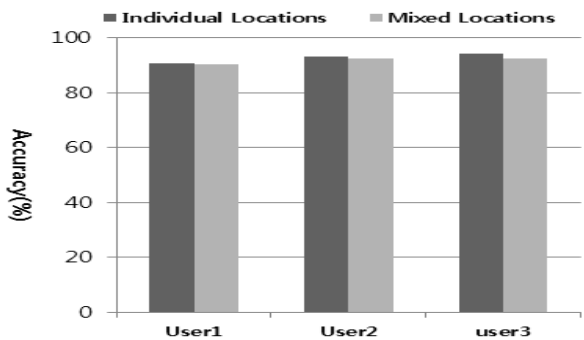


Fig. 10. Position dependency: Individual vs Mixed

### 5. 결론

본 논문에서는 스마트폰 3축 가속도 센서를 이용한 2단계 행위 인식 시스템을 제안하였다. 제안한 시스템은 결정트리 알고리즘을 이용하여 1단계 모델 학습 및 분류를 수행하고, 2단계 분류에서는 1단계 분류 결과들의 시퀀스를 이용하여 HMM모델 학습 및 분류를 수행하였다. 6가지 행위들에 대해 수집한 총 6,720개의 데이터 집합을 이용한 실험을 통해, 본 논문에서 제안하는 2단계 행위 인식 시스템의 높은 성능을 확인할 수 있었다. 최근에는 스마트폰의 기울기 및 방향에 따른 가속도 센서 데이터의 변화를 보완하기 위한 다양한 기술들이 제안되고 있다[9]. 향후 연구에서는 본 논문에서 제안한 행위 인식 시스템에 이러한 기술들을 추가함으로써 보다 안정적인 인식 성능을 얻을 수 있도록 시스템 확장을 시도해볼 계획이다.

### 참고 문헌

[1] N. Gyorbiro, A. Fabian, and G. Homanyi, "An Activity Recognition System for Mobile Phones", Mobile Networks and Applications, Vol.14, No.1, pp.82-91, 2008.  
 [2] J. R. Kwapisz, G. M. Weiss and S. A. Moore, "Activity Recognition Using Cell Phone Accelerometers", ACM SIGKDD Explorations Newsletter, Vol.12, No.2, pp.74-82, 2010.

[3] E. Miluzzo, N. Lane, K. Peterson, et al., "Sensing Meets Mobile Social Networks: The Design, Implementation and Evaluation of the CenceMe Application", Proc. of ACM Conf. on Embedded Networked Sensor Systems, pp.337-350, 2008.

[4] J. Yang, "Toward Physical Activity Diary: Motion Recognition Using Simple Acceleration Features with Mobile Phones", Proc. of Int. Workshop on Interactive Multimedia for Consumer Electronics, 2009.

[5] T. Scott, J. Lester, J. E. Froehlich, et al., "iLearn on the iPhone: Real-Time Human Activity Classification on Commodity Mobile Phones", CSE Technical Report, University of Washington, 2008.

[6] B. Najafi, K. Aminian, A. Paraschiv, et al., "Ambulatory System for Human Motion Analysis Using a Kinematic Sensor: Monitoring of Daily Physical Activity in the Elderly", IEEE Trans. on Biomedical Engineering, Vol.50, No.6, 2003.

[7] L. Sun, D. Zhang, B. Lin, B. Guo and S. Li, "Activity Recognition on an Accelerometer Embedded Mobile Phone with Varying Positions and Orientations", Lecture Notes in Computer Science Vol.6406, pp.548-562, 2010.

[8] H. Lu, J. Yang, Z. Liu, N. D. Lane, T. Choudhury and A. T. Campbell, "The Jigsaw Continuous Sensing Engine for Mobile Phone Applications", Proc. of SenSys-10, pp.71-84, 2010.

[9] M. D. Tundo, E. Lemaire, N. Baddour, "Correcting Smartphone Orientation for Accelerometer-Based Analysis", IEEE Int. Symposium on Medical Measurements and Applications(MeMeA), 2013.



### 김종환

e-mail : click7254@kyonggi.ac.kr

2014년 경기대학교 컴퓨터과학과(학사)

2014년~현 재 경기대학교 컴퓨터과학과  
석사과정

관심분야: 인공지능, 기계학습, 모바일 센싱



### 김인철

e-mail : kic@kyonggi.ac.kr

1985년 서울대학교 수학과(학사)

1987년 서울대학교 전산과학과(이학석사)

1995년 서울대학교 전산과학과(이학박사)

1996년~현 재 경기대학교 컴퓨터과학과  
교수

관심분야: 인공지능, 기계학습, 지능시스템