

## Design of an Activity Recognition System using Smartphone Accelerometer

Joo-Hee Kim<sup>†</sup> · Sang-Ha Nam<sup>††</sup> · Se-Kyeong Heo<sup>†</sup> · In-Cheol Kim<sup>†††</sup>

### ABSTRACT

Activity recognition using smartphone accelerometer suffers from the user dependency problem that acceleration patterns of one user differ from those of others for the same activity. Moreover, it also suffers from the position dependency problem since a smartphone may be placed in any pockets or hands. In order to overcome these problems, this paper proposes an effective activity recognition method which is less dependent with both specific users and specific positions of the smartphone. Based on the proposed method, we implement a real-time activity recognition system working on an Android smartphone. Throughout some experiments with 6642 examples collected from different users and different positions, we investigate the performance of our activity recognition system.

**Keywords :** Activity Recognition, Smartphone, Accelerometer, SVM

## 스마트폰 가속도 센서를 이용한 행위 인식 시스템의 설계

김주희<sup>†</sup> · 남상하<sup>††</sup> · 허세경<sup>†</sup> · 김인철<sup>†††</sup>

### 요 약

스마트폰 가속도 센서를 이용한 사용자 행위 인식은 동일한 행위를 수행하더라도 사용자마다 가속도 데이터 패턴이 서로 달라지는 사용자 의존성 문제를 가지고 있다. 그뿐만 아니라 스마트폰은 사용자의 어느 주머니나 손에도 놓일 수 있기 때문에 위치 의존성 문제도 지니고 있다. 본 논문에서는 특정 사용자나 특정 폰 위치에 대한 의존성이 적은 효과적인 행위 인식 방법을 제안한다. 제안한 방법을 기초로 안드로이드 스마트폰에서 동작하는 실시간 행위 인식 시스템을 구현하였다. 서로 다른 사용자와 서로 다른 폰 위치로부터 수집한 총 6642개의 샘플들을 이용한 실험을 통해, 본 논문에서 제안한 행위 인식 시스템의 성능을 분석하였다.

**키워드 :** 행위 인식, 스마트폰, 가속도 센서, SVM

### 1. 서 론

일상생활 속에서 사람이 어떤 행위를 하고 있는지 시스템이 정확히 인식할 수 있는 능력은 유비쿼터스 컴퓨팅 및 모바일 컴퓨팅 환경에서 인간 중심의 다양한 편의 서비스를 제공하기 위해 필수적인 요소이다. 인간의 행위와 신체활동을 자동으로 인식할 수 있는 기능은 다방면으로 활용될 수 있다. 예컨대, 매일 매일 사용자의 신체활동을 자동으로 체크하여 의사나 가족들에게 전송해주는 응용 프로그램은 환자의

의료관리나 노약자의 건강관리에 큰 도움을 줄 수 있을 것이다[1, 2]. 사람의 행위를 인식하기 위해 이용할 수 있는 다양한 센서들이 존재하지만[3, 4], 최근에는 시간과 장소에 제약을 받지 않고 늘 휴대 가능한 스마트폰 내장형 가속도 센서를 이용한 연구가 매우 활발하다. 스마트폰 보급이 지금처럼 일반에 널리 보급되기 이전의 많은 행위 인식 연구들에서는 센서를 몸의 특정 부위에 부착하거나 착용하는 방식을 주로 사용하였다. 이러한 부착형 혹은 착용형 센서들은 신체에 강하게 밀착됨으로써 비교적 잡음이 적은 양질의 행위 인식 데이터를 얻을 수 있다는 장점이 있는 반면에, 착용의 불편함 때문에 일상생활에서 장시간 사용자의 행위를 모니터링하는 목적으로 활용되기는 어렵다는 단점이 있다[5, 6]. 최근에 보급되는 거의 모든 스마트폰에는 가속도 센서를 포함해 다양한 센서들을 기본 내장하고 있어 스마트폰 사용자의 행위 인식을 위해서는 별도의 부가 센서들이 필요치 않고, 대부분의 현대인들이 어디를 가든 자신의 스마트폰을 항상 몸에 소지함으로써 일상생활의 자연스런 분위기 속에서 다양한 행위

\* 본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음.

\*\* 이 논문은 한국정보처리학회 제38회 추계학술발표대회에서 '스마트폰 내장형 가속도 센서를 이용한 사용자 행위 인식'의 제목으로 발표된 논문을 확장한 것임.

† 준 회 원: 경기대학교 컴퓨터과학과 학사과정

†† 준 회 원: 경기대학교 컴퓨터과학과 석사과정

††† 종신회원: 경기대학교 컴퓨터과학과 교수

논문접수: 2012년 12월 24일

수정일: 1차 2013년 1월 4일

심사완료: 2013년 1월 4일

\* Corresponding Author: In-Cheol Kim(kic@kyonggi.ac.kr)

데이터를 수집할 수 있다는 장점이 있다. 하지만 스마트폰 내장 가속도 센서를 이용한 행위 인식도 다른 센서나 장비를 이용하는 경우와 마찬가지로 동일한 행위를 수행하더라도 사용자에게 따라 서로 다른 데이터 패턴을 나타내는, 소위 사용자 의존성 문제(user dependency problem)를 여전히 내포하고 있다. 그 뿐만 아니라, 동일한 행위를 수행하더라도 스마트폰을 사용자의 어느 주머니 혹은 어느 손에 휴대하느냐에 따라 서로 다른 데이터 패턴이 다르게 나타나는 폰 위치 의존성 문제(position dependency problem)도 포함하고 있다[7]. 이러한 사용자 의존성 및 폰 위치 의존성 문제는 스마트폰 내장 가속도 센서를 이용한 행위 인식의 성능과 응용 범위를 제한하는 큰 걸림돌이 되고 있다.

본 논문에서는 특정 사용자나 특정 폰 위치에 대한 의존성이 적은 효과적인 행위 인식 방법을 제안하고, 이를 기초로 안드로이드 스마트폰 기반의 실시간 행위 인식 시스템을 구현하였다. 본 연구에서는 3명의 서로 다른 스마트폰 사용자들이 3가지 서로 다른 위치 {손, 바지앞주머니, 바지뒷주머니}에 스마트폰을 소지하고 수행한 6가지 행위 {정지, 걷기, 뛰기, 계단올라가기, 계단내려가기, 점프}들에 관한 대용량의 데이터를 수집하였다. 이렇게 수집된 총 6642개의 데이터 집합을 이용하여, 본 논문에서 제안한 행위 인식 시스템의 사용자 의존성과 폰 위치 의존성 등 다양한 성능 분석 실험을 수행하고, 그 결과를 소개한다.

본 논문은 다음과 같은 내용으로 구성된다. 먼저 2장에서는 본 연구와 관련 있는 기존 연구들을 소개하고, 3장에서는 데이터 수집과 전처리, 특징 추출, 분류기 학습과 인식 등 본 논문에서 제안하는 행위 인식 시스템의 세부 설계사항들을 설명한다. 이어서 4장에서는 실시간 행위 인식 시스템의 구현과 이를 이용한 성능 분석 실험 결과들을 소개하고, 마지막으로 5장에서는 결론과 향후 연구에 대해 설명한다.

## 2. 관련 연구

[8]의 연구에서는 나이키+아이팟 스포츠 키트와 아이폰을 이용하여 행위 인식을 하였다. 인식 대상 행위들은 {걷기, 달리기, 자전거타기, 앉기} 총 4개로 8명의 실험자가 참여하여 각 행위별로 16회씩 데이터를 수집하였다. 이 연구에서는 폰의 위치를 특별히 제한하지 않았고, 분류에 사용한 특징(feature)들은 나이키+아이팟 패킷 페이로드(Packet Payload)와 가속도 크기, 가속도 주파수 등 크게 3가지 종류이다. 훈련 데이터 집합과 테스트 데이터 집합이 동일한 경우는 인식률이 99.48%, 다를 경우 97.4%의 성능을 보였다.

[9]의 연구에서는 스마트폰의 위치, 방향 등에 제한 없이 자연스러운 상태에서 신체 활동을 인식함으로써, 스마트폰 사용자의 하루 소비 열량을 추정하였다. 이 연구에서는 {서기, 걷기, 달리기, 자전거타기, 계단 오르기, 계단 내려오기, 드라이브} 총 7 가지 종류의 행위들을 인식 대상으로 삼았다. 또, 폰 위치와 방향이 달라도 견고한 인식 성능을 얻기 위해, {바지 좌측 앞주머니, 바지 우측 앞주머니, 바지 좌측 뒷주머니, 바지 우측 뒷주머니, 재킷 좌측 주머니, 재킷 좌측

주머니} 등 총 6 가지의 다른 폰 위치와 {폰의 위아래가 정방향 혹은 역방향으로 놓였는지, 액정화면이 위로 혹은 아래로 향하는지}에 따라 총 4 가지의 다른 폰 방향에서 다양한 훈련 데이터를 수집하였다. 이 연구에서는 3축 가속도의 평균(mean), 분산(variance), 에너지(energy), 주파수 영역 엔트로피(frequency-domain entropy)뿐만 아니라 3축 가속도들 사이의 상관관계수(correlation)들도 포함하여 총 22개의 특징들을 원시 가속도 데이터로부터 추출하였다. 이 연구에서는 SVM 알고리즘을 적용하여 행위 분류기를 학습하였고, 7명의 실험 참가자에 대해 평균 93%의 인식률을 보였다.







[10]의 연구에서는 특정 사용자보다 임의의 사용자에게 적용 가능한 모델을 얻기 위하여, 29명의 다양한 스마트폰 사용자들로 행위 인식 연구를 진행하였다. 인식 대상 행위들은 {걷기, 달리기, 계단 올라가기, 계단 내려가기, 앉기, 서기} 등 총 6개이며, 다른 연구들과는 달리 정지를 앉기와 서기로 구분하였다. 이 연구에서는 실험자의 스마트폰 위치를 특정 주머니로 통일하였다. 1초에 20개의 입력 데이터를 수집하여, 3축 가속도의 평균(average), 표준편차(standard deviation), 평균 절대 차(average absolute difference) 등 총 43개의 특징들을 추출하였다. 행위 분류기 학습을 위해서는 결정트리(Decision Tree), 신경망(Neural Network) 등의 알고리즘을 적용하였다. 결정트리의 평균 인식률은 85.1%, 신경망의 경우는 91.7%를 보였다.

## 3. 사용자 행위 인식

### 3.1 시스템 개요

본 논문에서는 스마트폰 내장 3축 가속도 센서를 이용하여 특정 사용자나 특정 폰 위치에 대한 의존성이 적은 스마트폰 사용자 행위 인식 방식을 제안한다. 본 연구의 인식 대상 행위들은 Table 1에 나타난 바와 같이 실내 환경에서 흔히 이루어지는 기본적인 이동 행위들로서, {정지, 걷기, 뛰기, 계단 내려가기, 계단 올라가기, 제자리 점프} 등 총 6 가지이다.

Table 1. Activities to be recognized

					
Still	Walking	Running	Down-stair	Up-stair	Jump

스마트폰 사용자가 각각의 행위를 수행하였을 때, 일반적으로 Table 2와 같이 서로 다른 가속도 센서값(X,Y,Z)의 변화 패턴을 보여준다.

스마트폰 사용자의 행위 인식은 크게 Fig. 1과 같은 과정을 거쳐 수행된다. 먼저, 훈련 단계(training phase)에서는 스마트폰 내장 3축 가속도 센서를 이용하여 각 행위별로 변화하는 가속도 시퀀스 데이터를 수집하고, 각 행위의 이전과 이후에 기록된 불필요한 가속도 데이터를 삭제하는 전처리(preprocessing) 과정을 거친다. 수집된 행위별 가속도 데

Table 2. Acceleration patterns for activities

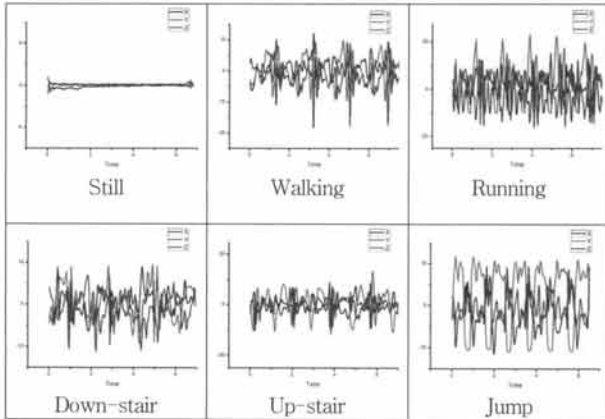


Table 3. Different positions of a smartphone

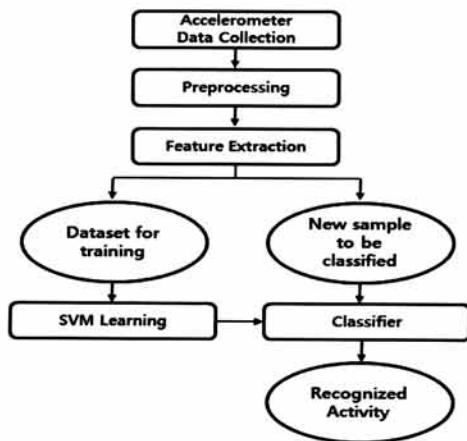



Fig. 1. Overall process for activity recognition

이터로부터 각 행위들을 자동 분류하기에 효과적인 특징들을 추출하여 특징 벡터(feature vector)를 생성한다. 다수의 특징 벡터들로 이루어진 입력 파일에 SVM 학습 알고리즘(learning algorithm)을 적용함으로써 행위 분류기(classifier)를 생성한다. 행위 인식 단계(recognition phase)에서는 사용자의 행위에 따라 실시간으로 입력되는 테스트 데이터(test data)에 행위 분류기를 적용함으로써 현재 수행중인 사용자의 행위를 자동 판별하게 된다.

3.2 데이터 수집 및 전처리

본 논문에서는 각 행위별로 약 100Hz의 속도로 {X, Y, Z} 3축 가속도 센서 데이터를 수집한다고 가정한다. 이 원시 가속도 데이터를 기초로 약 1초 단위로 66개의 특징들로 구성된 하나의 특징 벡터를 만들어낸다. 각 특징 벡터는 해당 행위별로, 또 행위 수행자인 사용자별로, 또 Table 3과 같이 {손, 바지 뒷주머니, 바지 앞주머니} 등 총 3가지의 스마트폰 위치별로 구분되어 저장된다. 본 연구에서는 3명의 서로 다른 스마트폰 사용자들이 3가지 서로 다른 위치에 스마트폰을 소지하고 수행한 6가지 행위 {정지, 걷기, 뛰기, 계단 올라가기, 계단 내려가기, 점프}들에 관한 총 6642개의 특징 벡터들로 이루어진 데이터 집합을 수집하였다.

데이터 수집 단계에서 각 행위를 위한 특징 벡터들 중 해당 행위와 직접 관련이 없는 (예컨대, 스마트폰을 주머니에 넣는 동작이나 스마트폰을 주머니에서 꺼내는 동작으로 인한) 불필요한 데이터를 제거하기 위한 작업이 필요하다고 판단되어, 데이터 수집 후 전처리(preprocessing) 작업을 시행하였다. 본 연구에서는 전처리 작업을 통해, 각 행위 수행 이전 및 이후의 약 5초가량의 데이터를 삭제하였다.

3.3 특징 추출

Table 2와 같은 각 행위별 원시 가속도 데이터로부터 Fig. 2와 같은 특징 추출 과정을 거쳐 초당 한 개의 특징 벡터를 생성한다. 일반적으로 행위 인식물은 입력 데이터를 어떤 특징(feature)들로 표현하느냐에 가장 크게 영향을 받는다. 가속도 데이터를 이용하는 기존의 행위 인식 연구들에서는 크게 4 가지 범주의 특징들을 이용해왔다. 첫째는 크기(magnitude) 기반의 특징들이고, 둘째는 주파수(frequency) 기반의 특징들, 셋째는 상관계수(correlation) 기반의 특징들, 마지막은 기타 특징들로 분류할 수 있다[11]. 본 논문에서 다루는 인식 대상 행위들은 Fig. 2의 전형적인 가속도 변화 곡선에서 보듯이 크기(magnitude)와 주파수(frequency)면에서 비교적 뚜렷이 차이가 난다. 따라서 이 두 가지 범주의 특징들을 고루 포함하는 것이 자동 분류에 도움을 줄 것으로 판단한다. 하지만, 본 논문에서는 스마트폰이 놓인 위치와 방향에 관한 의존성을 줄이는 것이 중요한 연구 목적의 하나이므로, X, Y, Z 3축 방향의 가속도, 평균, 표준편차, 최대, 최소 등을 그대로 특징으로 쓰지 않고, 대신 가속도 크기  $\sqrt{x^2+y^2+z^2}$ 를 중심으로 특징을 추출하였다. 먼저, 특징 벡터를 구성하는 65개의 특징들 중 64개의 특징은 가속도 크기  $\sqrt{x^2+y^2+z^2}$ 에 대한 DFT(Discrete Fourier Transform) 계수들이다. 본 연구에서는 DFT의 고속화 방식인 FFT(Fast Fourier Transform)의 여러 알고리즘들 중 DIT(Decimation - In - Time) Radix-2 FFT 방법을 적용하여 64개의 특징값을 계산한다. DIT Radix-2 FFT는 Equation (1)과 같이 길이 N의 시퀀스를 보다 작은 길이의 시퀀스들로 연속해서 분해함으로써 DFT 계산 양을 줄이는 방식이다. 그리고 마지막 65번째 특징은 1초 동안 변화한 가속도 크기  $\sqrt{x^2+y^2+z^2}$ 의 최대값(maximum)로 나타낸다. 각 특징 벡터의 부류 라벨(class label)은 해당 행위(activity) 뿐만 아니라 행위 수행자인 사용자(user), 그리고 스마트폰이 놓인 위치(position) 정보도 함께 포함한다.

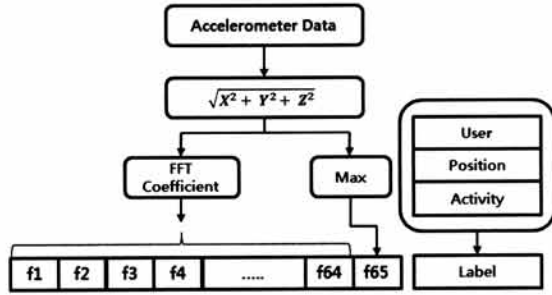


Fig. 2. Feature extraction

$$X(k) = DFT_N \left[ \frac{x(0) + x(2) + \dots + x(N-2)}{2} \right] + W_N^k DFT_N \left[ \frac{x(1) + x(3) + \dots + x(N-1)}{2} \right] \quad (1)$$

3.4 분류기 학습 및 인식

본 연구에서는 스마트폰의 내장형 3축 가속도 센서를 이용하여 행위 데이터를 수집하였고 불필요한 데이터 부분을 삭제하는 전처리 과정을 거쳐 특징 벡터 파일을 만들었다. 이와 같은 훈련 데이터 파일은 특정 사용자가 아닌 다수의 임의의 사용자에게 적용 가능하고, 스마트폰을 임의의 위치에 소지하여도 안정적인 인식률을 보장하는 행위 분류기를 학습하는데 이용하였다.

학습 알고리즘으로는 SVM(Support Vector Machine) 알고리즘을 채택하였다. SVM 알고리즘은 분류 문제를 해결하기 위해 여백(margin)을 최대화할 수 있는 최적의 분류 경계면을 찾아주는 학습 알고리즘으로서, 인공 신경망과 같은 다른 학습 알고리즘들에 대해 일반화(generalization) 능력이 매우 뛰어난 알고리즘이다. 또한, SVM은 커널 트릭(kernel trick) 기법을 이용해 비선형 데이터들에 대한 복잡한 분류 경계면도 매우 효율적으로 찾아줄 수 있는 장점을 가지고 있다. 본 연구에서는 서로 다른 사용자와 서로 다른 폰 위치에서 수집한 행위 데이터들을 서로 혼합한 훈련 데이터 집합에 분류 성능이 뛰어난 SVM 학습 알고리즘을 적용함으로써, 다양한 사용자와 다양한 폰 위치에도 불구하고 높은 행위 인식률을 보이는 행위 분류기를 학습하였다. 즉, 혼합 훈련 데이터 집합을 학습에 이용함으로써 행위 분류기의 사용자의

존성과 폰 위치 의존성을 크게 줄였다. 그리고 이렇게 학습된 행위 분류기를 실시간 행위 인식 시스템에 내장함으로써, 임의의 스마트폰 사용자가 일상생활 속에서 자유롭게 수행하는 행위들을 실시간으로 자동 인식할 수 있게 하였다.

4. 구현 및 평가

본 연구에서는 앞서 제시한 스마트폰 내장 가속도 센서를 이용한 행위 인식 방법의 효과와 성능을 분석하기 위해, 안드로이드 스마트폰 환경에서 동작하는 행위 인식 시스템을 구현하였다. 이 시스템은 크게 데이터 수집기와 학습기, 실시간 행위 인식기로 구성된다. Fig. 3의 (a)는 구현된 행위 인식 시스템의 데이터 수집기(data collector) 실행 화면을 보여준다. 수집하고자 하는 행위를 선택하고 시작버튼을 누르면 행위를 나타내는 가속도 데이터 수집이 시작되고, 동일 버튼을 한 번 더 누르면 데이터 수집을 종료한다. 또한, 삭제버튼으로 전체 데이터를 삭제할 수도 있다. Fig. 3의 (b)는 실시간 행위 인식기(real-time activity recognizer)의 실행화면을 보여준다. 행위인식 시작버튼을 누르고 스마트폰 사용자가 특정 행위를 수행하면, 현재 수행중인 행위를 자동으로 인식하여 행위 이름을 화면에 출력한다.

행위 인식 시스템의 핵심부인 학습기(learner)는 훈련 데이터 집합으로부터 행위 분류기(activity classifier)를 생성하고, 실시간 테스트 데이터에 학습된 분류기를 적용하여 사용자의 행위를 자동 인식하는 역할을 수행한다. 본 연구에서는 앞서 설명한대로 일반화 능력이 우수한 SVM 알고리즘을 학습에 적용하였다. SVM 학습 알고리즘을 제공하는 다양한 구현 코드들이 있으나, SVM 외에 비교 가능한 다양한 학습 알고리즘들을 함께 제공하는 Java 기반의 종합 기계 학습 도구(machine learning tool)인 Weka를 행위 인식 시스템의 학습기 구현에 사용하였다. Weka에서는 사용자가 선택한 하나의 학습 알고리즘에 따라 훈련 데이터 파일로부터 하나의 분류기 객체를 생성한 다음, Java 소스 코드 형태로도 제공함으로써 다른 Java 응용 프로그램에서 쉽게 학습된 분류기를 이용할 수 있는 기능을 제공한다. 본 연구에서는 Weka의 이러한 기능을 이용하여 SVM 알고리즘 기반의 행위 분류기 코드를 생성한 다음, 이것을 실시간 행위 인식기와 연동할 수 있도록 구현하였다.

본 논문에서 제안한 행위 인식 시스템의 성능을 분석하기 위해 아래와 같은 실험들을 수행하였다. 첫 번째 실험에서는 행위 인식 시스템의 사용자 의존성을 분석해보기 위해, 사용자 의존 성능(user-dependent performance)과 사용자 혼합 성능(user-mixed performance)을 서로 비교해 보았다. 사용자 의존 성능 측정을 위해서는 3명의 실험자별로 동일 사용자의 데이터를 각각 훈련 데이터 집합과 테스트 데이터 집합으로 나누어 실험하고, 3명의 평균 인식률을 구하였다. 사용자 혼합 성능 측정을 위해서는 3명의 실험자 데이터를 사용자 구분 없이 혼합한 뒤, 이 혼합 데이터 집합을 훈련용과 테스트용으로 나누어 학습한 뒤 인식률을 측정하였다.

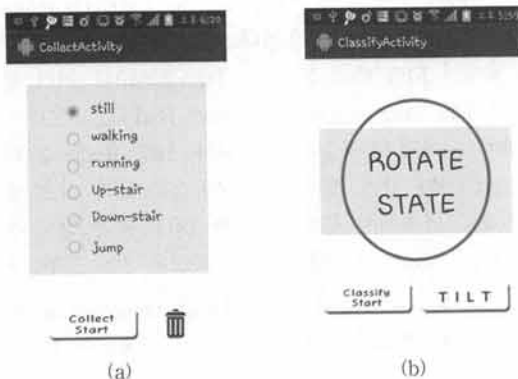


Fig. 3. Screenshots of the running implementation

성능 검증 방식은 데이터를 모두 혼합한 후 k개로 분할하여 테스트에 사용하는 k-분할 검증(k-fold validation)을 사용하였고, 이 후의 모든 실험에 대한 검증 역시 같은 방식을 사용하였다. 실험 결과는 Fig. 4의 그래프와 같다. 사용자 의존 성능은 각 위치별로 평균 84~91%(표준편차 2~7)의 높은 인식률을 보였고, 사용자 혼합 성능도 이보다는 5~6%정도 낮지만 여전히 79 ~ 85%의 높은 인식률을 보였다. 이 실험을 통해 본 논문에서 제안한 행위 인식 방식이 행위 수행자인 스마트폰 사용자간의 차이에도 불구하고 높은 행위 인식 성능을 보인다는 것을 확인할 수 있었다.

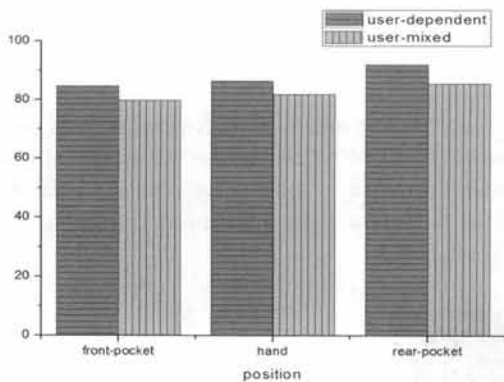


Fig. 4. Experimental results: user dependency




Fig. 5. Experimental results: position dependency

두 번째 실험에서는 스마트폰 위치에 따른 행위 인식 시스템의 성능 의존성을 분석하기 위해, 위치 의존 성능(position-dependent performance)와 위치 혼합 성능(position-mixed performance)를 서로 비교해 보았다. 위치 의존 성능 측정을 위해서는 3 가지 서로 다른 스마트폰 위치별로 동일 위치에서 수집된 훈련 데이터와 테스트 데이터를 이용한 실험의 평균 인식률을 구하였다. 반면에, 위치 혼합 성능 측정을 위해서는 폰의 위치를 구분하지 않고 혼합된 훈련 데이터와 테스트 데이터로 실험하여 인식률을 구하였다. 실험 결과는 Fig. 5의 그래프와 같다. 스마트폰 위치 의존 성능은 평균 82~91%(표준편차 1~6)의 인식률을 보였으며, 위치 혼합 성능도 이보다 4~8%는 낮지만 76~87%의 높은 인식률

을 보였다. 본 논문에서 제안한 행위 인식을 위한 특징들과 학습방법이 스마트폰 위치에 따른 차이에도 불구하고 비교적 높은 인식 성능을 보장할 수 있음을 확인할 수 있었다.

마지막 실험에서는 행위 인식에 사용되는 학습 알고리즘별 성능을 분석하기 위해, 본 연구에서 채택한 SVM 외에 나이브 베이즈(Naive Bayes), 결정 트리(C4.5), 인공 신경망 학습 알고리즘들의 인식 성능을 비교해 보았다. 실험결과 학습 알고리즘별 인식 성능은 Fig. 6과 같다. SVM 학습 알고리즘의 인식률은 77~87%로서 다른 학습 알고리즘들에 비해 가장 좋은 인식 성능을 보였다. 반면에, 나이브 베이즈 학습 알고리즘은 59~80%의 인식률로 가장 낮은 성능을 보였고, 인공 신경망 학습 알고리즘은 76~86%의 인식률로 SVM과 비슷한 성능을 보였다. 일반화 능력이 더 우수한 SVM 알고리즘이 인공 신경망에 비해 더 높은 인식 성능을 보일 것으로 기대하였으나, 본 실험에서는 인공 신경망과의 인식 성능의 차이가 크게 나타나지는 않았다.

Fig. 6에 는 사용자와 스마트폰 위치 모두를 구분하지 않고 훈련 및 테스트 데이터에 혼합하여 사용한 실험도 포함되었다. 이와 같이 사용자와 폰 위치에 모두 독립적인 경우의 평균 인식률은 77%로서, 사용자와 폰 위치에 모두 의존적인 평균 인식률 87%보다는 10% 가량 낮다 하지만, 이것은 어떤 임의의 사용자가 스마트폰을 어느 위치에 소지하여도 수행 행위를 인식할 수 있는 기대 성능이라는 의미에서 매우 고무적인 실험 결과로 판단된다.

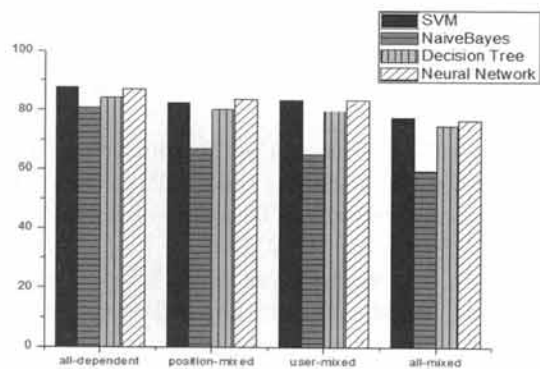


Fig. 6. Experimental results: learning algorithms

한편, 지금까지 설명한 행위 인식 성능 실험들 모두 계단 올라가기와 계단 내려가기 행위를 포함하고 있다. 두 행위의 가속도 패턴은 Table 2에서 보듯이 다른 행위들에 비해 주파수나 크기가 유사하기 때문에, 이들을 정확히 분류하기는 쉽지 않다. 따라서 이 두 행위들을 포함한 실험들에서 평균 인식률을 감소시키는 요인이 되었다. 실험들에서 이 두 행위를 배제하면, 어떤 경우든 평균 인식률은 90~96%까지 개선될 수 있음을 확인할 수 있었다.

### 5. 결 론

본 논문에서는 특정 사용자나 특정 폰 위치에 대한 의존

성이 적은 효과적인 행위 인식 방법을 제안하고, 이를 기초로 안드로이드 스마트폰 기반의 실시간 행위 인식 시스템을 구현하였다. 본 연구에서는 3명의 서로 다른 스마트폰 사용자들이 3가지 서로 다른 위치 (손, 바지앞주머니, 바지뒷주머니)에 스마트폰을 소지하고 수행한 6가지 행위 (정지, 걷기, 뛰기, 계단올라가기, 계단내려가기, 점프)들에 관한 대용량의 데이터를 수집하였다. 이렇게 수집된 총 6642개의 데이터 집합을 이용하여, 본 논문에서 제안한 행위 인식 시스템의 사용자 의존성과 폰 위치 의존성 분석 실험을 수행하였다 그리고 평균 77% 이상의 높은 사용자 및 스마트폰 위치 혼합 성능을 통해, 본 연구에서 제안한 행위 인식 시스템의 사용자 및 폰 위치 독립성을 확인할 수 있었다. 특히, 계단 올라가기와 내려가기 행위를 제외할 경우는 약 90~96%의 높은 인식률을 보였다.

현재 이용하고 있는 특징 벡터(feature vector)들은 스마트폰의 위치와 방향에 관한 의존성을 줄이기 위해, 특별히 x, y, z축 방향 중 특정 방향의 가속도 변화만을 고려하지 않고, 종합적인 가속도 크기(magnitude)  $\sqrt{x^2+y^2+z^2}$ 의 변화만을 고려하고 있다. 계단 올라가기, 계단 내려가기와 같이 상하 방향성이 중요한 행위에 대한 분류 성능을 개선하기 위해, 향후 연구에서는 특별히 상하 방향성을 고려한 특징들을 추가해볼 계획이다.

**참 고 문 헌**

[1] O. W. H. Wu, A. a T. Bui, M. a Batalin, L. K. Au, J. D. Binney, and W. J. Kaiser, "MEDIC: Medical Embedded Device for Individualized Care", Artificial intelligence in Medicine, Vol.42, No.2, pp.137-52, Feb., 2008.

[2] Y. Chiang, Y. Tsao, and J. Hsu, "A Framework for Activity Recognition in a Smart Home", Proceedings of the International Conference on Technologies and Applications of Artificial Intelligence (TAAI). 2010.

[3] G. Bieber, A. Luthardt, C. Peter, and B. Urban, "The Hearing Trousers Pocket: Activity Recognition by Alternative Sensors", Proceedings of the 4th International Conference on Pervasive Technologies Related to Assistive Environments (PETRA), 2011.

[4] C. Qin and X. Bao, "TagSense: A Smartphone-based Approach to Automatic Image Tagging", Proceedings of the 9th International Conference on Mobile Systems, Applications, and Sevcies(MobiSys), pp.1-14, 2011.

[5] X. Long, B. Yin, and R. M. Aarts, "Single-Accelerometer-Based Daily Physical Activity Classification", Conference Proceeding of IEEE Engineering in Medicine and Biology Society, pp.6107-6110, 2009.

[6] L. Bao and S. S. Intille, "Activity Recognition from User-Annotated Acceleration Data", Proceedings of the International Conference on Pervasive Computing, Lecture Notes in Computer Science, Vol.3001, pp.1-17, 2004.

[7] A. M. Khan, Y. K. Lee, S. Y. Lee, T. S. Kim, "Human Activity Recognition via An Accelerometer-Enabled-Smartphone Using Kernel Discriminant Analysis", Proceedings of the 5th

International Conference on Future Information Technology (FutureTech), pp.1-6, 2010.

[8] T. S. Saponas, J. Lester, J. Froehlich, J. Fogarty, J. Landay, "iLearn on the iPhone: Real-Time Human Activity Classification on Commodity Mobile Phones", University of Washington CSE Technical Report UW-CSE-08-04-02, 2008.

[9] L. Sun, D. Zhang, B. Li, B. Guo, and S. Li, "Activity Recognition on an Accelerometer Embedded Mobile Phone with Varying Positions and Orientations", Proceedings of the International Conference on Ubiquitous Intelligence and Computing, Lecture Notes in Computer Science, Vol.6406, pp.548-562, 2010.

[10] J. R. Kwapisz, G. M. Weiss, S. A. Moore, "Activity Recognition using Cell Phone Accelerometers", ACM SIGKDD Explorations Newsletter, Vol.12, No.2, pp.74-82, 2010.

[11] M. F. A. bin Abdullah, A. F. P. Negara, M. S. Sayeed, D. Choi, K. S. Muthu, "Classification Algorithms in Human Activity Recognition using Smartphones", International Journal of Computer and Information Engineering, Vol.6, pp.77-84, 2012.



**김 주 희**

e-mail : chilang@kyonggi.ac.kr  
 2003년~현 재 경기대학교 컴퓨터과학과  
 학사과정  
 관심분야: 인공지능, 기계학습,  
 모바일컴퓨팅



**남 상 하**

e-mail : namsh@kyonggi.ac.kr  
 2013년 경기대학교 컴퓨터과학과(학사)  
 2013년~현 재 경기대학교 컴퓨터과학과  
 석사과정  
 관심분야: 인공지능, 기계학습, 지능로봇



**허 세 경**

e-mail : tprudzzang@kyonggi.ac.kr  
 2008년~현 재 경기대학교 컴퓨터과학과  
 학사과정  
 관심분야: 인공지능, 기계학습,  
 모바일컴퓨팅



**김 인 철**

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, 지능형시스템