



Performance Evaluation of Person Classification Techniques Based on Human Activities Using Smartphones' Sensors

Young-In Kim*

Department of Applied Information Technology and Engineering, Pusan National University

ABSTRACT

To distinguish a smartphone user, some studies have been researched to analyze various human activities of natural daily life and classify users without using an additional step, such as using fingerprints or iris. However, it is not sufficient to analyze the diversity of human activities, the analysis per subject and the experiments using techniques that were better in previous related studies. In this paper, we propose a method that classifies users with various human activities by experimenting with a public data set of six activities data collected from thirty subjects using acceleration and gyroscope sensor in smartphone and with seven classification techniques that are better to existing research results. As a result of the comparison experiment with seven classification techniques, AdaBoost showed good results in the experiment in which the user classifies all of the six activities. Next, Adaboost showed the good results in laying, sitting and standing according to each activity by using the top four techniques which were better performance in classification of all activities. In walking, walking downstairs and walking upstairs, we could find out higher accuracy than the previous three activities, and SVM showed relatively excellent accuracy. Especially, the accuracy of user classification using walking upstairs is the highest. The results of this experiment are expected to become an important basis for the development of technologies that naturally and continuously classify users in everyday life.

© 2018 KKITS All rights reserved

KEYWORDS: Smartphone sensors, Accelerometer, Gyroscope, Human activity, User classification

ARTICLE INFO: Received 25 November 2018, Revised 11 December 2018, Accepted 11 December 2018.

*Corresponding author is with the Department of Applied IT & Engineering, Pusan National University, 1268-50, Samnangjin-ro, Samnangjin-eup, Miryang-si,

Gyeongsangnam-do, 50463, Rep. of KOREA. *E-mail address:* kimyi@pusan.ac.kr

1. 서론

사람은 신체의 행동적인 특성을 가지고 있으므로 이를 이용하여 사용자를 분류할 수 있다. 걷기, 앉기 등과 같은 행동, 고유한 필체 및 음성 등의 특징을 가지고 개인을 구분할 수 있다[1]. 이중 행동 특징은 기기를 소유한 사용자의 움직임에 가지고 개인을 식별할 수 있어 개인 인증이 필요한 응용에서 특정 인증 단계를 필요로 하지 않고 움직이 있는 동안 지속적으로 개인인증을 할 수 있는 기술로 최근 관심이 높아지고 있으며, 특히 스마트폰을 이용한 금융, 헬스케어 등 다양한 응용 분야에 스마트폰에 탑재된 센서로부터 수집된 데이터에 기계학습 기술을 적용하여 개인인증 기술을 개발하여 활용할 수 있다[2-4].

최근 스마트폰의 센서를 이용하여 사용자의 움직임을 인식하려는 HAR(Human Activity Recognition)에 대한 연구가 활발히 이루어져, 걷기, 눕기, 앉기, 서기, 계단오르기 등 다양한 동작을 비교적 정확한 수준으로 분류하고 있다[5]. 그러나 이러한 연구는 사용자 분류가 아닌 각 동작의 분류에 초점이 맞추어져 있어 활용하기에는 한계가 있다. 걸음걸이와 같은 사용자의 행동에 가속도와 자이로스코프 센서 등을 사용한 연구도 활발히 이루어지고 있으며 활용도가 높을 것으로 기대되고 있으나, 대부분 제한된 걷기 동작만을 사용하거나 앉기, 서기 등 다른 행동에 대한 일상생활의 다양한 행동에 대한 전반적인 비교 연구는 미흡한 실정이다[5,6]. 따라서 이러한 다양한 행동을 포함하며, 한 시점에서 사용자를 알아내는 것이 아닌 지속적인 일상생활속에서의 행동으로부터 사용자를 알아낼 수 있으며, 다른 사람이 짧은 시간에 따라 하기 힘든 개인 분류 기법에 대한 연구가 필요한 실정이다.

본 논문은 사용자의 다양한 행동 특징을 스마트

폰에 탑재된 가속도와 자이로스코프 센서로부터 데이터를 수집하여 이를 기계학습의 분류 기법으로 분류할 수 있는 성능을 비교 평가하여 우수한 기법을 제시하고자 한다. 이를 위하여 실험 데이터는 UCI(University of California, Irvine) Machine Learning Repository에 있는 19세에서 48세사이의 실험 참여자 30명으로부터 여섯 가지 동작에 대하여 수집하여 공개한 데이터를 이용한다[7]. 사용자 분류 모델은 기존 관련 연구에서 우수한 성능을 보인 기법을 기반으로 실험하여 개발한다.

본 논문의 전체적인 구성은 다음과 같다. 먼저 2장에서는 사람 행동 데이터를 가지고 수행한 기존 연구들을 살펴본다. 3장에서는 실험에 사용한 데이터의 특성과 특징 벡터 및 분류 기법에 대하여 다룬다. 4장에서는 각 행동을 이용한 분류 실험 과정과 결과를 제시한다. 마지막 5장에서는 논문의 결론과 향후 연구 방안을 논의한다.

2. 관련 연구

본 논문에서는 사람의 행동을 인식하여 사용자를 분류하는 연구이므로, 스마트폰 가속도와 자이로스코프 센서를 활용한 관련 연구에 대한 조사가 필요하다.

먼저 [8]은 사용자 식별을 위하여 삼성 갤럭시 J-1의 3축 가속도 센서로부터 10명의 사용자 걸음걸이 데이터를 수집하였다. 특징 벡터로는 평균, 중앙값, 교차 상관 등 30가지를 사용하였다. 분류 모델은 64개 트리로 구성된 랜덤 포레스트(random forest: RF)를 구축하였으며, 실험 결과로 의사결정 트리(Decision Tree: DT), 로지스틱 회귀분석(logistic regression: LR), SVM보다 우수한 0.9679의 정확도를 나타내었다.

[4]는 스마트폰을 25에서 30세의 남자 사용자 10명의 다섯 군데 신체 부위에 착용하고 걷기, 앉기,

서기, 뛰기 등 여섯 가지 행동을 하며 가속도, 자이로스코프, 지자기 센서를 이용하여 데이터를 수집하였다. 특징 추출은 5초 간격으로 최댓값, 최솟값, 평균 등 8가지 특징을 구하여 k-최근접이웃기법(k-nearest neighbor: kNN), 베이즈넷(bayes network: BN), 서포트벡터 머신(support vector machine: SVM)의 세가지 분류기법을 사용하여 실험하였다. 실험 결과, 허리에 부착했을 때 우수한 성능을 구할 수 있었으며 BN이 94.57%의 가장 좋은 정확도를 나타내었다. 본 연구는 비슷한 나이의 남성 10명만 참여하였으며, 학습 데이터와 검증 데이터는 30:70으로 나누어 실험하였다.

[9]은 UCI Machine Learning Repository에 공개된 두 가지 데이터셋을 가지고 사용자 행동을 이용한 AdaBoost(AB) 등 10가지의 사용자 식별 분류 기법의 성능을 비교하는 연구를 수행하였다. 행동을 정적인 자세와 자세 변화로 나누어 분류하였으며, 가속도와 자이로스코프 센서 데이터의 3축에 대한 평균, 표준편차 등 24가지 특징을 사용하였다. 실험 결과로 kNN이 100%의 분류 성능을 보였다. 그러나 학습 데이터와 검증 데이터를 70:30으로 실험하였으며, 분류 기법의 k 값 등 주요 파라미터 설정에 대한 설명이 미흡하였다.

이외에도 웨어러블 기기의 가속도 센서를 이용한 연구[10, 11]이 있었으나, 공통적으로 비교적 적은 피실험자 인원수, 한정된 행동 종류, 피실험자 개개인 수준의 성능비교, 학습과 검증 데이터 선정 비율을 70:30으로 고정하여 실험하여 이에 대한 보완이 연구가 필요하다고 판단된다. 본 논문에서는 이와 같은 기존 실험을 개선하기 위하여 UCI Machine Learning Repository의 비교적 많은 수인 30명 사용자의 6가지 행동 데이터에서 추출한 다양한 특징 벡터를 이용하여, 기존 연구에서 우수한 성능을 보였으며 스마트폰과 같은 서버에 비해 성능이 낮은 기기에서도 실행 가능한 7 가지

분류기법을 가지고 10겹 교차 검증 기법을 사용하여 피실험자 개개인의 성능도 구하여 비교하고자 한다.

3. 데이터 구성 및 분류 기법

본 논문에서 사용자 분류는 스마트폰 센서로부터 구해진 데이터 집합으로부터 사용자 행동 검출, 특징 벡터 추출, 사용자 행동 분류, 사용자 개인 분류를 수행하는 과정을 의미하며, 이를 위해 본 장에서는 사용자 행동 기반 분류 기법에 사용된 데이터 구성과 특징 벡터에 대해 설명한다. 또한 사용자 분류를 위해 사용된 7개의 분류 기법에 대해서도 설명한다.

3.1 데이터 구성

행동을 가지고 사용자를 분류하기 위해서는 다양한 사용자의 행동 데이터를 스마트폰의 움직임 감지 센서를 이용하여 데이터를 수집하여야 한다. 본 논문에서 사용한 데이터는 공개 데이터셋인 UCI Machine Learning Repository의 HAR 데이터셋을 사용하였다[7]. 이 데이터셋은 19세에서 48세의 30명의 피실험자들이 허리 부분과 다른 원하는 부분에 삼성 갤럭시 S2 스마트폰을 착용하고 여섯 가지 동작(걷기, 서기, 앉기, 눕기, 계단 오르기, 계단 내려오기)을 정한 순서와 시간으로 수행하면서, 3축 가속도와 자이로스코프 센서 신호를 50Hz로 샘플링하여 약 2.56초의 샘플 윈도우 단위를 50%씩 겹치게하여 10,299개의 데이터를 수집하였다. 이 데이터의 예로 3명의 피실험자 데이터를 보인 것은 <그림 1>과 <그림 2>와 같다. 이 그림은 x축을 기준으로 가속도와 자이로스코프 센서 데이터를 나타낸 것이다.




그림 1. 피실험자 U01, U11, U21의 x축 가속도센서 데이터
Figure 1. X axis accelerometer data from U01, U11 & U21 users




그림 2. 피실험자 U01, U11, U21의 x축 자이로스코프 데이터
Figure 2. X axis gyroscope data from U01, U11 & U21 users

표 1. 피실험자 데이터 요약
Table 1. Summary of data from subjects

	Total	Mean	Min (SID)	Max (SID)
Laying	1944	64.8	48 (U02)	90 (U21)
Sitting	1777	59.2	44 (U05)	85 (U21)
Standing	1906	63.5	44 (U10)	89 (U21)
Walking	1722	57.4	46 (U22)	95 (U01)
WalkingDown	1406	46.9	36 (U22)	62 (U30)
WalkingUp	1544	51.5	40 (U19)	65 (U25)

<표 1>은 각 행동별 피실험자 데이터의 정보를 요약한 것으로, Total과 Mean은 각 행동별 전체 데이터 개수와 평균 개수이며, Min(SID)는 제일 적은 개수를 가진 피실험자 식별자(SID)와 그 개수를 나타낸 것이고, Max(SID)는 제일 많은 개수를 가진 피실험자 식별자(SID)와 그 개수를 나타내고 있다.

가장 많은 데이터 개수를 가진 피실험자는 가장 적은 피실험자보다 약 2배 정도 데이터 개수가 많았다. 이 데이터셋에는 평균, 표준편차, 엔트로피, 최솟값, 최댓값, 가중평균 등 561가지의 특징 벡터도 추출하여 제공하고 있다[7]. 본 논문에서는 이 특징 벡터를 사용하여 실험하였다.

3.2 특징 벡터 및 분류 기법

피실험자 30명의 특징 벡터를 이용해 특정 사용자를 분류하도록 할 수 있도록, 본 논문에서는 이 특징 벡터를 사용하여 HAR 분야에서 우수했던 분류 기법에 파라미터 설정을 달리하여 성능이 개선되는지 알아보기 위해 AB, BN, DT, kNN, LR, RF, SVM의 7가지 기법을 가지고 실험하고자 한다. 사용한 분류 기법의 방법과 특징을 간단히 비교 설명하면 다음과 같다. 먼저 학습 속도가 상대적으로 빠른 편인 기법은 BN, DT, kNN, LR이며, 나머지는 상대적으로 느리다고 볼 수 있다. 분류 속도는 대부분 빠르나 kNN은 k값이 크면 느리지며, 분류 과정을 사용자가 이해 가능한 기법은 AB, DT, kNN, LR, RF이며, SVM은 어렵다고 볼 수 있다. 사용한 특징 벡터는 571가지로 가속도와 자이로스코프 데이터에서 추출할 수 있는 특징이 대부분 포함되어 있으므로 추가로 특징 벡터를 추출하지 않고 이 데이터를 가지고 분류 성능을 구하여 평가한다. 본 연구에서는 신경회로망과 딥 신경망 등 현재 스마트폰과 같은 저전력 CPU에서 구축하기에는 한계가 있는 기법들은 제외하였다[12].

4. 실험 평가 및 분석

본 장에서는 선정된 분류 기법으로 실험한 환경 및 실험 결과를 설명한다. kNN과 RF를 구성할 때 필요한 설정을 구하였으며, 7가지 분류기법을 사용

하여 정확도 등 성능을 구하여 제시하였다.

4.1 실험 환경 및 방법

실험에 사용할 분류 기법 중, kNN과 RF는 각각 성능이 우수한 k 값과 결정 트리 개수를 구하여야 한다. 이를 위해 이에 대한 실험을 먼저 수행하였다. 다음으로 사용자 분류에 우수한 기법을 알아내기 위하여 실험 데이터의 모든 행동 형태를 대상으로 7가지 분류 기법을 적용하여 성능 수치를 구하여 비교 분석하였다. 모든 실험은 Weka3.8.2[13]를 사용하여 수행하였으며, 성능 평가의 정확성을 높이기 위하여 10겹 교차 검증 방법을 사용하였다. 여기서 10겹 교차 검증은 전체 데이터셋을 10개로 분할하여, 돌아가며 9개는 학습에 사용하고 나머지 1개는 검증에 사용하는 방법이다. 이 방식으로 10가지 모델을 만들어 구한 성능의 평균을 구하는 방법으로, 보다 일반화된 성능을 구할 수 있다[14].

다음으로 앞선 실험 결과에서 구해진 성능으로부터 상위 4가지 분류 기법을 선택하여 각 행동별 사용자 분류 성능을 구하여 비교 분석하였다. 또한 각 피실험자의 분류 능력을 정확히 파악하는 것이 중요하므로 이에 대한 실험도 수행하였다. 실험에 사용한 컴퓨터의 CPU는 3.20GHz인 인텔 Core i5-3470이며, 메모리는 8GB이다.

4.2 실험 결과

먼저 kNN을 행동 데이터에 적용하기 위해서는 정확도가 높은 k값을 구해야 한다[15]. 따라서 본 연구에서는 k값을 1부터 11까지의 홀수를 사용하여 정확도를 구하였으며, 그 결과는 <그림 3>과 같다. 그림에서와 같이 k가 1일 때 정확도가 0.8167로 가장 우수하였으며, k값이 이보다 증가할수록 정확도가 저하되어 본 실험에서는 이 수치를 사용

하였다.

또한, RF도 성능이 우수한 결정 트리의 개수를 구하여야 한다[16]. 이를 위하여 결정 트리 개수를 2에서 128까지 사용하여 정확도와 AUC 값을 구하였으며, 그 결과는 <그림 4>와 같다. 결과와 같이, 트리를 124개 사용했을 때 정확도는 0.879794이며 AUC는 0.99로 성능이 우수하였으며, 이 이상 결정 트리의 개수를 증가시켜도 개선되는 성능 수치가 미미하여 본 연구에서는 트리의 개수를 124로 정하여 사용하였다.




그림 3. k 값에 따른 kNN 분류기의 성능 비교
Figure 3. Performance comparison of classifier due to k value

본 논문에서 사용한 각 기법의 주요 파라미터 설정은 다음과 같다. 먼저 RF는 최대 깊이는 무제한, 사용한 결정 트리 개수는 124로 하였다. DT는 신뢰도 계수는 0.25, 리프당 최소 수는 2로 하였으며, SVM에는 복잡도는 1.0, 입실론은 1.0E-12, 익스포넌트는 1.0 그리고 커널은 polynomial 커널을 사용하였다. 다음으로 AB는 기본 분류기로 C4.5 의사결정트리를 10개 사용하였으며, LR은 릿지 값으로 1.0E-8을 그리고 BN은 탐색 알고리즘으로 hill climbing으로 설정하여 실험하였다.




그림 4. 트리 개수에 따른 RF 분류기의 성능 비교
Figure 4. Comparison of performance of RF classifier due to the number of Trees

<그림 5>는 피실험자 30명의 행동 특징 벡터를 가지고 7가지 분류 기법을 이용하여 실험한 결과이다. 정확도는 AB가 평균 0.9414로 가장 높았다. 분류 기법의 평균 정확도는 AB, RF, SVM, LR, kNN, DT, BN 순으로 구해졌다. 효율적인 실험을 위하여 다음 실험에 사용할 성능 상위 4가지 분류기를 선정한 결과, AB, RF, SVM, kNN을 선택하였다. 여기서 LR은 정확도에서 kNN 보다 0.006384 높았으나, 최소, 최대, 표준편차에서 모두 kNN의 성능이 우수하여, 네 번째 분류기법은 kNN으로 하였다. 이번 실험에서 분류 정확도가 가장 높았던 기법은 SVM이었으며, 행동 종류는 계단오르기로 정확도 1.0을 보였다. 분류 정확도가 가장 낮았던 분류기법은 BN으로 서기에서 0.4가 구해졌다. 다양한 행동에 따른 성능의 편차가 가장 작았던 경우는 AB로 0.05465이었으며, 반대로 가장 큰 경우는 BN으로 0.255를 보였다. 그러므로 모든 행동을 함께 분류할 때는 AB가 가장 우수할 수 있으며, BN은 행동에 따른 성능 차이가 큰 것으로 나타났다. 다음으로 행동별 분류 정확도에 대한 평균값을 구

하여 이를 기반으로 분류가 잘 되는 우수한 행동 종류부터 나열하면 다음과 같다: 걷기, 계단오르기, 계단내려오기, 눕기, 서기, 앉기. 여기서 분류 정확도는 각각 0.9871, 0.9690, 0.9598, 0.8319, 0.7237, 0.7013을 구했으며, 걷기와 관련된 행동 분류 정확도가 높으며, 나머지 행동에서는 오류가 약 17~30% 정도 있음을 알 수 있었다.




그림 5. 7가지 분류기의 정확도 비교
Figure 5. Accuracy differences in the seven classifiers

다음으로 이전 모든 행동 분류 실험에서 우수한 성능을 보인 AB의 자세한 실험 결과로, 모든 피실험자 30명을 올바르게 분류한 것과 잘못 분류한 것에 대해 나타난 것은 <그림 6>과 같다. 그림에서 대각선 부분이 각 피실험자를 정확히 분류한 경우이다. 그림과 같이 가장 정확하게 분류된 피실험자는 U21로 정확도가 약 0.975이었으며, 반대로 가장 낮았던 피실험자는 U20으로 0.876이었으며, 그 다음으로 U06이 0.877이었다. 따라서 모든 피실험자에게서 87%이상의 분류 정확도를 구하였다. 여기서 측정된 데이터의 개수가 성능에 영향을 미치는지 검토하기 위하여 개수를 비교해 보았다. 성능이 좋았던 U21의 데이터 개수는 앉기가 85, 눕기는

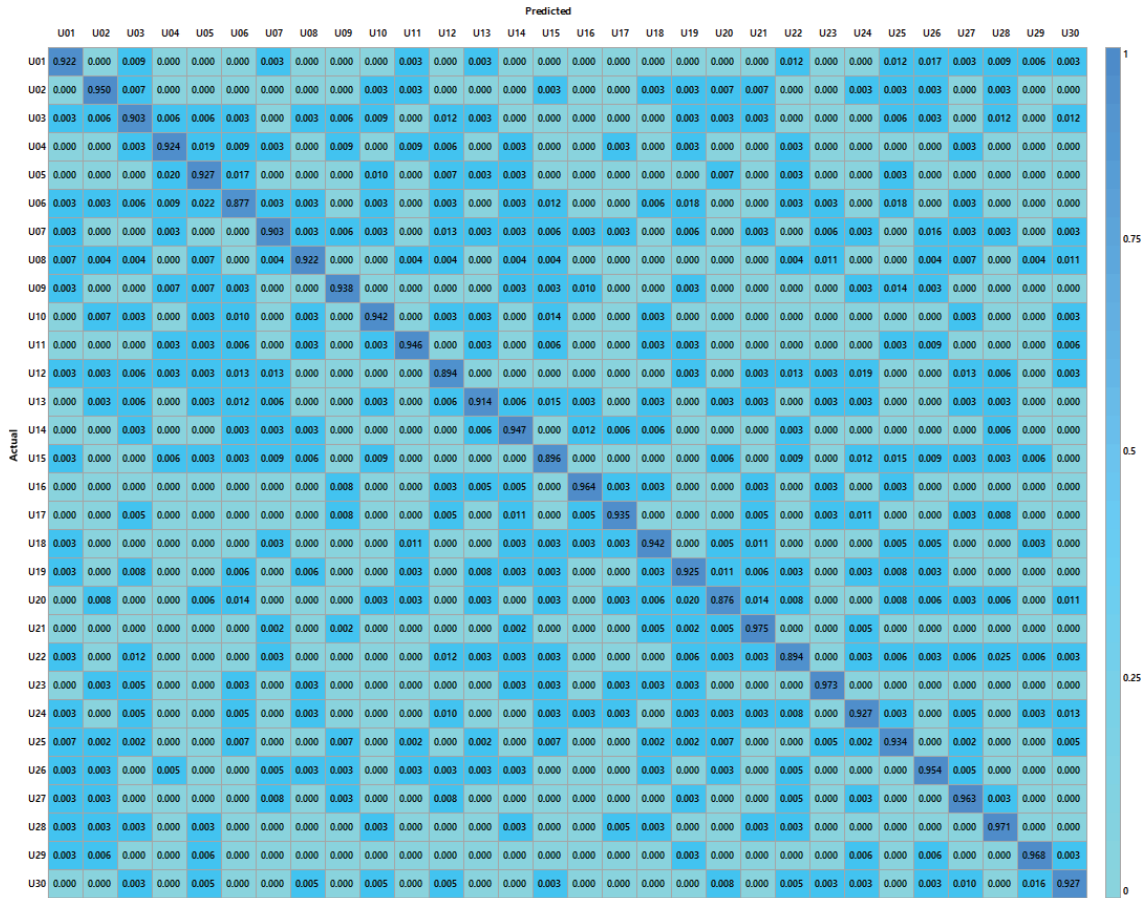


그림 6. AdaBoost를 이용한 분류 결과에 대한 정오분류표
Figure 6. Confusion matrix of Classification results using AdaBoost

90, 서기가 89, 걷기는 52, 계단내려오기는 45, 계단오르기는 47이었다. 상대적으로 성능이 저조했던 U20의 데이터 개수는 앉기 66, 눕기 68, 서기 73, 걷기 51, 계단내려가기 45이며 계단오르기는 51이었다, 이와 같이 피실험자들의 데이터 개수를 비교해본 결과, 개수 차이가 성능에 영향을 주지 않은 것으로 보였다.

다음으로 보다 자세한 성능 분석을 위하여, 앞선 실험에서 각 행동에 대하여 좋은 성능을 보인 4가지 분류기법인 AB, kNN, RF, SVM의 실험 결과로 정확도와 AUC 및 F1 점수를 비교한 것은 <표 2>

와 같다. 여기서 정확도는 정오분류표에서 피식별자가 정확히 분류된 정분류율을 나타내며, AUC(area under the curve)는 ROC 커브의 밑면적으로 분류기의 성능을 민감도와 특이도에 의해 비교할 때 사용하는 수치이고, F1 점수는 (2 * 정밀도 * 민감도)를 (정밀도 + 민감도)로 나눈 수치로, 여기서는 beta 값이 1인 경우로 두 측정치의 균형 정도를 나타낸다. 표에 나타난 것과 같이 행동에 따른 사용자 분류에 있어서 AB가 고르게 좋은 성능을 보였으며, 특히 눕기, 앉기, 서기에서 다른 분류기법보다 우수하였다. 걷기와 계단내려가기 및

계단오르기에서는 SVM의 성능이 좋았으며, 특히 계단오르기의 경우에는 분류 정확도가 1, 즉 100%로 가장 높았으며, 나머지 분류기법도 98%이상의 우수한 성능을 보였다.

마지막으로 <표 3>에는 피실험자 30명에 대하여 앞선 실험에서 성능이 우수하였던 분류기법으로 구한 정확도를 나타내었다. 피실험자 중 가장 분류 정확도가 높았던 경우는 U22로 0.98이었으며, 모든 사용자가 0.91 이상의 정확도를 보였다. 걷기, 계단 내려가기, 계단오르기에서 높은 성능을 보였으며, 계단오르기의 경우에는 모든 피실험자가 정확히 분류되었다. 그러나 나머지 행동에서는 상대적으로 낮은 성능을 보였으며, 앉기와 서기에서는 0.86과 0.87의 상대적으로 낮은 정확도를 보였다. 이 행동에서는 피실험자 U26과 U20은 분류가 비교적 잘 이루어졌으나, U10과 U17은 0.69와 0.679로 낮은 정확도를 보였으며, 이 피실험자들은 전체적으로 다른 피실험자에 비해 낮은 수준의 성능을 보였다. 본 논문의 실험 결과, 이전 논문과는 다르게 계단 오르기에서 더 나은 성능을 구하였으며, 걷는 동작이 아닌 눕기, 서기, 앉기에서도 87%이상의 성능을 구할 수 있음을 보였다. 그리고 비교적 정적인 행동인 서기, 눕기, 앉기에서는 AB 기법을 그리고 나머지 걷는 종류의 행동에서는 SVM을 사용하는 것이 좋을 수 있다. 또한 표에 나타나진 않았으나 kNN 등 다른 기법을 함께 사용하면 AB와 SVM에서 오분류하는 피실험자도 정확히 분류할 수 있는 경우도 있으므로, 실제 시스템에서는 한 가지 분류 기법을 사용하기 보다는 여러 기법을 함께 사용하면 분류율을 개선할 수 있다.

표 2. 높은 성능 분류기법의 정확도, AUC, F1 점수
Table 2. Accuracy, AUC and F1 scores in the higher-performance classifiers

	Classifier	Accuracy	AUC	F1 Score
Laying	AB	0.933128	0.976	0.933
	kNN	0.826132	0.902	0.826
	RF	0.882716	0.991	0.883
	SVM	0.891975	0.977	0.892
Sitting	AB	0.870568	0.956	0.871
	kNN	0.689927	0.835	0.691
	RF	0.753517	0.968	0.754
	SVM	0.691615	0.931	0.691
Standing	AB	0.882476	0.993	0.882
	kNN	0.690451	0.838	0.692
	RF	0.803778	0.982	0.801
	SVM	0.798006	0.979	0.798
Walking	AB	0.99187	1	0.992
	kNN	0.998839	0.999	0.999
	RF	0.997677	1	0.998
	SVM	0.998839	1	0.999
Walking downstairs	AB	0.985775	1	0.986
	kNN	0.985775	0.993	0.986
	RF	0.986486	1	0.986
	SVM	0.997866	1	0.998
Walking upstairs	AB	0.984456	0.999	0.984
	kNN	0.995466	0.998	0.995
	RF	0.993523	1	0.994
	SVM	1	1	1

5. 결 론

본 논문은 사용자의 다양한 행동 특징에 분류 기법을 적용하여 스마트폰 사용자를 분류하는 방법을 제안했다. 사용자 행동 데이터로는 공개 데이터셋을 사용하였다. 6가지 행동 데이터로부터 추출된 특징 벡터를 이용하였으며 기존 관련연구에서 우수한 성능을 보인 7가지 분류기법을 적용하여 사용자 식별의 가능성을 제시하였다. 또한 실험을 10겹 교차 검증으로 수행하여 이전 보다 정확한 성능을 구하도록 노력하였고, 모든 특징 벡터를 사용하여 실험하였다. 실험 결과, 계단오르기와 계단내려가기, 걷기 및 눕는 행동이 사용자 분류에 이용

표 3. 피실험자별 최우수 성능 분류기의 정확도
Figure 3. Accuracies of top ranked classifiers per subject

Activity	Laying	Sitting	Standing	Walking	Walking downstairs	Walking upstairs	Per-User Average
Classifier UserID	AdaBoost	AdaBoost	AdaBoost	SVM	SVM	SVM	
U01	0.82	0.7872	0.8868	1	1	1	0.9157
U02	0.988	0.9178	0.8904	1	1	1	0.966
U03	0.8889	0.78	0.875	0.9833	1	1	0.9212
U04	0.931	0.9074	0.9091	1	1	1	0.9579
U05	0.9667	0.8039	0.9344	1	1	1	0.9508
U06	0.8387	0.8367	0.9298	1	0.9787	1	0.9307
U07	0.9846	0.9474	0.8767	1	0.9818	1	0.9651
U08	0.8971	0.7879	0.8356	1	1	1	0.9201
U09	0.9861	0.9412	0.7826	1	1	1	0.9517
U10	0.9194	0.6923	0.8525	1	1	1	0.9107
U11	0.8846	0.8636	0.8393	1	1	1	0.9313
U12	0.8947	0.8727	0.7544	1	1	1	0.9203
U13	0.9231	0.875	0.8302	0.9825	1	1	0.9351
U14	0.9444	0.8043	0.8333	1	1	1	0.9303
U15	0.9825	0.9245	0.8723	1	1	1	0.9632
U16	0.902	0.7778	0.9667	1	1	1	0.9411
U17	0.9028	0.9153	0.6792	1	1	1	0.9162
U18	0.9571	0.8406	0.9359	1	1	1	0.9556
U19	0.9155	0.9219	0.9231	1	1	1	0.9601
U20	0.9889	0.8824	1	1	1	1	0.9786
U21	0.9167	0.8226	0.746	1	1	1	0.9142
U22	1	0.9265	0.9706	1	1	1	0.9829
U23	0.7945	0.8923	0.9324	1	1	1	0.9365
U24	0.9474	0.859	0.8378	1	1	1	0.9407
U25	0.973	0.9	0.925	1	0.9773	1	0.9626
U26	0.95	0.9722	0.9241	1	1	1	0.9741
U27	0.942	0.9167	0.9385	1	1	1	0.9662
U28	0.9571	0.871	0.8305	1	1	1	0.9431
U29	0.9375	0.8696	0.9444	1	1	1	0.9586
U30	0.98	0.88	0.8889	1	1	1	0.9582

가능함을 보였고, 모든 행동을 사용한 실험에서는 AdaBoost가 가장 성능이 우수함을 보였으며, 30명의 피실험자 각각의 분류 정도도 구하여 제시하였다. 다음으로 각 행동 종류마다 우수한 분류 기법이 무엇인지 제시하였으며, 기존 관련 연구 결과와 다르게 계단오르기로 사용자를 분류하는 것의 중요성도 제시하였다. 이러한 결과를 통해 본 논문에서 제안한 사용자 분류 기법들을 이용하면 다양한 행동을 가지고 사용자 분류 정확도를 높일 수 있

음을 보였다.

본 연구에서 6가지 행동으로 분류한 사용자 중 일부는 상대적으로 오분류율이 높게 나왔으므로, 이 부분을 보완하기 위하여 피실험자의 신체적 특성, 나이, 성별 등 자세한 정보를 감안한 분석이 향후 필요하다. 또한 일상에서 이루어지는 사용자들의 다양한 행동에 대한 데이터를 여러 위치에 스마트폰을 자연스럽게 배치하고 보다 많은 데이터를 수집하여 실험하는 일이 필요하며, 실시간으

로 사용자가 실제 환경에서 사용할 수 있는 수준으로 구현하고 다양한 분류 기법의 성능을 측정하여 비교하는 연구도 필요하다.

References

- [1] J-H. Kim, and K-S. Park, *Personal authentication technology and database construction using biosignals*, Journal of Telecommunication Technology Association, Vol. 165, pp. 41-46, 2016.
- [2] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, *Cell phone-based biometric identification*, IEEE International Conference on Biometrics: Theory Applications and Systems, pp. 1-7, 2010.
- [3] W. H. Lee, and R. Lee, *Implicit sensor-based authentication of smartphone users with smartwatch*, Proceedings of the Hardware and Architectural Support for Security and Privacy, pp. 1-8, 2016.
- [4] M. Ehatisham-ul-Haq, M. A. Azam, U. Naeem, S. ur Rehman, and A. Khalid, *Identifying smartphone users based on their activity patterns via mobile sensing*, Procedia Computer Science, Vol. 113, pp. 202-209, 2017.
- [5] S. R. Ramamurthy, and N. Roy, *Recent trends in machine learning for human activity recognition—A survey*, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, e1254, 2018.
- [6] M. Janidarmian, A. R. Fekr, K. Radecka, and Z. Zilic, *A comprehensive analysis on wearable acceleration sensors in human activity recognition*, Sensors 17, No. 3, 2017.
- [7] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, *A public domain dataset for human activity recognition using smartphones*, European Symposium on Artificial Neural Networks, pp. 437-442, 2013.
- [8] T. B. Singha, R. K. Nath, and A. V. Narsimhadhan, *Person recognition using smartphones' accelerometer data*, arXiv preprint arXiv:1711.04689, 2017.
- [9] C. Tang, and V. V. Phoha, *An empirical evaluation of activities and classifiers for user identification on smartphones*, IEEE 8th International Conference on Biometrics Theory, Applications and Systems, 2016.
- [10] P. Casale, O. Pujol, and P. Radeva, *Personalization and user verification in wearable systems using biometric walking patterns*, Personal and Ubiquitous Computing, Vol. 16, No. 5, pp. 563-580, 2012.
- [11] T. Hoang, D. Choi, and T. Nguyen, *On the instability of sensor orientation in gait verification on mobile phone*, IEEE 12th International Joint Conference on e-Business and Telecommunications, Vol. 4, pp. 148-159, 2015.
- [12] A. Ignatov, *Real-time human activity recognition from accelerometer data using Convolutional Neural Networks*, Applied Soft Computing, Vol. 62, pp. 915-922, 2018.
- [13] E. Frank, M. A. Hall, and I. H. Witten, *The WEKA workbench. Online appendix for data mining: Practical machine learning tools and techniques*, Morgan Kaufmann, Fourth Edition, 2016.
- [14] R. Kohavi, *A study of cross-validation*

and bootstrap for accuracy estimation and model selection, International Joint Conferences on Artificial Intelligence, Vol. 14, No. 2, pp. 1137-1145, 1995.

- [15] G. Shmueli, N. R. Patel, and P. C. Bruce, *Data mining for business intelligence: Concepts, techniques, and applications in Microsoft Office Excel with XLMiner*, John Wiley and Sons, 2011.

- [16] T. M. Oshiro, P. S. Perez, and J. A. Baranauskas, *How many trees in a random forest?*, International Workshop on Machine Learning and Data Mining in Pattern Recognition, pp. 154-168, 2012.

스마트폰 센서를 이용한 사용자 행위 기반 개인 분류 기법의 성능 평가

김영인

부산대학교 IT응용공학과 교수

요 약

스마트폰의 사용자를 알아내기 위하여 지문, 홍채 등을 사용하는 방법과 같이 별도의 단계를 사용하지 않고, 자연스러운 일상생활의 다양한 행동을 분석하여 사용자를 분류하는 연구가 활발히 이루어지고 있다. 그러나 사람 행동의 다양성과 피실험자 각각에 대한 분석 및 기존 연구의 기법들을 사용한 실험 및 분석은 미흡한 실정이다. 본 논문에서는 스마트폰의 가속도와 자이로스코프 센서를 이용하여 30명의 피실험자로부터 여섯 가지 행동 데이터를 수집하여 공개한 데이터셋을 가지고, 기존 연구 결과에서 우수한 성능을 보인 분류 기법을 가지고 실험하여, 다양한 사람 행동을 가지고 사용자를 분류할 수 있는 방법을 제안한다. 일곱 가지 분류 기법으로 여섯 가지 행동을 비교 실험한 결과,

AdaBoost가 우수한 결과를 보여줬다. 다음으로 모든 행동에 대한 분류 실험에서 우수한 결과를 보인 상위 4 가지 분류기법을 이용하여 각 행동별 사용자 분류 실험을 한 결과, 눕기, 앉기 및 서기에서는 AdaBoost가 가장 우수하였으며, 걷기, 계단내려가기 및 계단오르기에서는 SVM이 가장 좋은 정확도를 보였고, 앞선 세 가지 동작보다 높은 분류 정확도를 구할 수 있었다. 특히 계단오르기를 이용한 사용자 분류 정확도는 가장 높은 결과를 보였다. 이 실험 결과는 앞으로 지속적 사용자 분류 기술 개발에 중요한 기초가 될 것이라고 생각한다.

감사의 글

이 논문은 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음.



Young-In Kim the Ph.D. degree in the Department of Computer Engineering from MyongJi University in 1996. He was a visiting scholar at University of Missouri. He has been a professor in the Department of Applied IT & Engineering at Pusan National University since 2006. His current research interests include data mining and database systems. He is a life member of the KKITS.

E-mail address: yikim@pusan.ac.kr