

스마트 워치를 사용한 일상생활 인간 행동 인지

권민철*, 최선웅°

Daily Life Human Activity Recognition Using Smart Watch

Min-Cheol Kwon*, Sunwoong Choi°

요약

최근, 스마트 폰, 웨어러블 기기와 기계학습을 융합하여 인간 행동을 인지하는 기술이 활발하게 연구되고 있다. 그러나 대부분의 인간 행동 인지 기술은 걷기, 달리기 같은 활동성이 큰 행동만을 고려하고 있다. 본 논문에서는 스마트 워치를 활용하여 활동성이 큰 행동 뿐 만 아니라, 휴식, 사무업무, 독서와 같은 일상생활 속의 활동성이 작은 행동 또한 분류하는 방법을 제안한다. 스마트 워치를 통해 데이터를 수집하여, 기계 학습 알고리즘을 사용하여 학습 및 분류를 수행한다. 실험 결과는 제안된 기계 학습 모델이 최고 93%의 예측률을 가짐을 보여준다.

Key Words : Machine Learning, Human Activity Recognition, Classifier, Smart Watch, Smart Phone

ABSTRACT

Recently, human activity recognition has been actively studied with smart phone and wearable devices using machine learning. Most human activity recognition techniques, however, consider active activities only such as walking and running. Using smart watch, this paper proposes a new human activity recognition technique which can recognize in-active activities in daily life such as relaxation, office work, and reading, as well as active activities. An experiment was performed to collect realistic smart watch data from a range of activities of daily life. The experimental results showed that the proposed machine learning model can achieve the maximum prediction rate of 93%.

1. 서론

요즘, 다양한 기술들이 하루가 다르게 발전되고 연구되고 있다. 그 중에서도 특히 사물 인터넷과 기계학습, 이 두 기술은 최근에 더욱 각광받고 있다. 사물 인터넷 기술은 IoT(Internet of Things)라고 불리며, 사물에 통신기능을 추가하는 기술이다¹⁾. 이 기술은 센서의 소형화 기술과 무선 통신의 발전만큼 빠르게 성장하고 있다. 사물인터넷은 일상생활에서 사람들의 편의성을 제공하는데 많은 도움을 주고 있으며, 스마트 홈, 스마트 오피스와 같은 새로운 서비스 플랫폼을 창

출하였다. 그 외에도 착용식 기기(wearable device)라는 새 제품을 개발하는데 핵심 기술이 되어, 많은 기능을 내장한 착용식 기기를 개발하는데 있어 그 근본이 되고 있다.

기계학습은 사실 연구, 개발 된지 매우 오래되었다. 그러나 소프트웨어, 하드웨어적인 한계로 사용성과 발전성에 한계를 보인다, 최근 발전된 하드웨어와 소프트웨어 기술로 다시 주목받고 있다. 기계학습은 무수히 많은 데이터로부터 원하는 결과를 얻기 위해 어떻게 데이터로부터 결과를 얻을 수 있는지 그 과정을 컴퓨터에게 학습 시키는 것을 의미한다. 개발자는 어떤

※ 이 논문은 2016년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No.2016R1A5A1012966).

• First Author : Kookmin University, Department of Secured Smart Electric Vehicle, kys4543@kookmin.ac.kr, 학생회원

° Corresponding Author : Kookmin University, School of Electrical Engineering, schoi@kookmin.ac.kr, 종신회원

논문번호 : KICS2017-09-272, Received October 12, 2017; Revised October 26, 2017; Accepted November 14, 2017

식으로 학습하면 결론 판단에 도움이 될지 판별하여 그 방향성만 학습 모델에 부여하고, 실제로 학습과정 전체는 컴퓨터에게 맡긴다. 비록 학습과정이 컴퓨터에게 달려있어, 어떻게 학습하였는지 정확히 알기 힘들기 때문에 제대로 된 근거를 가지고 판단하는 것인지 알기 힘들다. 이런 특성 때문에 기계학습 모델은 블랙 박스에 비유되기도 한다. 어떻게 학습하는지 정확히 알기 힘들기 때문에 잘못된 도출된 결론이나 예기치 못한 변수에 대한 우려의 목소리도 높다. 이런 우려에도 불구하고, 알파고, 음성 인식, 사진 자동 분류 등 기계학습을 사용한 서비스들은 날이 갈수록 더 발전되고, 많이 사용되고 있다.

인간의 행동을 인지하는 Human Activity Recognition(HAR) 분야는 위 두 가지 기술의 발전에 따라 많은 연구가 진행되고 있다^[2]. 주로 헬스케어와 의료 분야에서 많은 연구와 실사용이 이루어진다^[3]. 그러나 지금까지는 상대적으로 활동성이 큰 행동을 분류하는 것에 초점이 맞춰져 있다. 예를 들어, 사용자가 걷는지, 뛰는지, 계단을 오르는지, 계단을 내려오는지, 앉아있는지, 누워있는지 등을 구분하여 칼로리를 계산하거나 움직임을 파악하는 연구를 하거나^[4,6], 근력 운동 시 자세가 올바른지 자세교정을 하는 연구^[7,8], 추가적으로 다양한 운동 종류를 학습하여 어떤 운동을 현재 하고 있는지 구분하는 등 비교적 활동성이 큰 행동에 관한 분류 연구를 진행해왔다.

그러나 진정한 인간 행동 인지 기술을 완성하려면, 일상생활에서의 활동성이 작은 행동을 연구하는 것도 필요하다. 여기서 활동성이 작은 행동은 몸 전체가 움직이지 않고 하는 행동들, 앉아서 또는 서서 손과 팔의 움직임만 조금씩 변화하는 행동들과 같은 비교적 동작이 크지 않은 행동들을 의미한다. 또한 근력운동과 같이 비교적 정해진 자세와 정해진 동작이 있어서 반복하는 형식의 행동들이 아닌, 필기, 사무업무와 같은 정해진 패턴이 없는 움직임을 예측하기 힘든, 개개인마다 특성이 다를 수 있는 행동들을 의미한다. 지금까지 많은 연구들은 이러한 행동들에 대해 고려하지 않았다. 활동성이 작은 행동들을 인지하는 것은 헬스케어와 의료분야에서 더욱 정확한 판단을 내릴 수 있도록 도와줄 수 있을 뿐만 아니라, 스마트 홈, 스마트 오피스와 같은 다른 분야에서도 새로운 서비스를 제공할 수 있는 확장성과 활용성을 가질 것이다. 활동성이 큰 행동과 활동성이 작은 행동 모두 고려하여 연구되어야 한다.

본 논문은 다음과 같이 구성되어있다. 2장에서는 문제 접근 방법에 대하여 설명한다. 3장에서는 제안하

는 시스템에 설계에 대해 보여주고, 4장에서는 설계된 시스템의 성능을 평가한다. 마지막으로 5장에서는 결론을 논의한다.

II. 문제 접근법

우리는 활동성이 작은 행동과 활동성이 큰 행동 모두 고려하여 일상생활 속 사람의 다양한 행동을 분류하고자 한다. 분류를 위해 이번 연구에서는 착용식 기기의 일종인 스마트워치와 기계학습 알고리즘을 사용한다. 일반 사람들이 즐겨 차는 장신구인 손목시계를 기반으로 개발된 스마트 워치는 착용식 기기들 중 사용자들에게 가장 친근한 기기이다^[9]. 스마트 워치 내부에는 시계를 포함하여 심박센서, 가속도 센서 등 정보를 얻기 좋은 센서와 기능들이 내장되어 있다. 또한, 손목에 착용하여 사용하기 때문에 몸 전체의 움직임이나 팔의 움직임을 추적하기 적합하다. 고성능의 스마트 워치는 단순히 정해진 기능 및 동작만 하지 않고 운영체제가 적용되어 원하는 기능 및 동작을 어플리케이션으로 개발하여 사용할 수도 있다. 대부분의 스마트 워치는 데이터 통신을 위해 블루투스를 지원하고 몇몇 스마트워치는 LTE나 WiFi를 지원한다. 기본적으로 스마트 폰과 연동되어 동작하기 때문에 고성능의 처리능력을 사용할 수 도 있다. 이러한 이유로 스마트 워치는 사람의 행동 분류를 위해 정보를 얻기에 가장 적합한 기기라고 판단된다. 손목에 착용하면, 내장된 다양한 센서로부터 실시간으로 사용자의 움직임에 대한 정보를 얻을 수 있고 즉각적으로 전송 및 처리가 가능하기 때문이다. 그림 1은 실제 사용자가 스마트 워치를 착용하고 작업하는 모습이다. 오른손잡이인 사용자가 오른손에 스마트 워치를 착용하고 여러 가지 일을 수행함으로써, 행동 인지를 위한 정보를



그림 1. 스마트 워치를 착용한 모습
Fig. 1. Wearing the smart watch

언을 수 있다. 뇌파 감지기기와 같이 부가적인 장비들이 필요한 기기나, 다른 연구에서와 같이 스마트 폰을 몸에 부착하고 사용하는 것에 비해, 사람들이 많이 착용하는 손목시계와 같은 형태인 스마트 위치를 사용하면 거부감이나 불편함을 최소화 할 수 있다.

기계학습에는 일반적으로 지도 학습(supervised learning), 자율 학습(unsupervised learning), 강화 학습(reinforcement learning) 3가지 방법이 존재한다. 본 논문에서는 학습을 위해 지도 학습 방법을 사용한다. 지도 학습은 각각의 학습 데이터가 여러 가지 특징을 하나의 벡터 형식으로 가지고 있으며 해당 데이터의 결과 또한 표시되어 있는 것을 의미한다. 지도 학습은 학습된 모델에서 예측하는 결과가 연속적인 값으로 출력되는 회귀 분석과 어떤 종류인지 구분하는 분류 분석으로 나뉜다. 우리는 두 가지 방법 중 분류 분석 방법을 사용한다.

본 논문에서는 일상생활에서 사람들이 많이 하는 행동 11가지를 선별하여 정의하였다. 표 1은 11가지 행동이 일어나는 클래스, 행동 종류를 나타냈다. 기존 연구와 다르게 활동성이 작은 행동을 선별하였고, 기존 연구에서 많이 다루는 걷기, 달리기와 같은 활동성이 큰 행동도 다룬다. 각 행동 별 상세 동작은 다음과 같다. 사무업무는 이메일을 작성하거나, 코드를 작성하거나, 문서를 작성하는 등 일반적인 사무 업무를 의미한다. 필기는 글을 쓰거나, 노트를 작성하는 등 펜, 연필을 사용하여 글을 작성하는 행동을 의미한다. 휴식은 의자 또는 소파에서 특별한 행동 없이 쉬는 행동이다. 대중교통 이용은 버스 또는 지하철을 이용하는 것을 의미한다. 이 경우 손잡이를 잡거나 그냥 서서 이용하거나 앉아서 이용하는 등 여러 자세가 포함되

표 1. 분류 행동 종류
Table 1. The types of behavior for classifying

클래스	행동 종류
B1	사무업무
B2	독서
B3	필기
B4	휴식
B5	컴퓨터 게임
B6	식사
B7	요리
B8	설거지
B9	걷기
B10	달리기
B11	대중교통 이용

어 있다. 모든 행동 데이터에는 그 행동을 행할 때 자연스럽게 일어나는 모든 동작, 자세를 포함한다.

III. 사용자 행동 분류 시스템 설계

본 논문에서 제안하는 사용자 행동 분류 시스템은 크게 정보 수집, 특징 추출, 학습 및 분류 세 단계로 이루어진다. 그림 2는 제안된 시스템의 구조이다. 정보 수집은 스마트 위치와 스마트폰에서 이루어지고, 특징 추출 및 학습 및 분류는 서버에서 이루어진다. 단계 별 상세 동작은 다음과 같다.

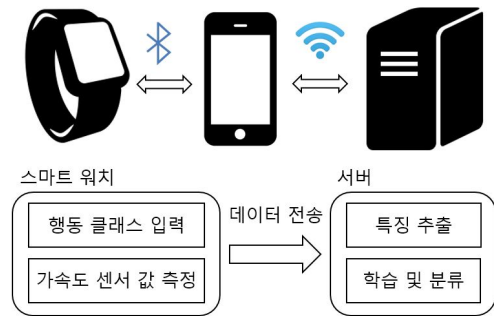


그림 2. 시스템 구조
Fig. 2. System structure

3.1 정보 수집 단계

정보 수집 단계는 기계학습 모델의 학습 및 검증을 위한 정보를 수집한다. 정보 수집을 위한 스마트 위치로는 애플 워치 Series 2^[10]를 사용한다. 사용자는 스마트 위치를 주-사용 손목(왼손잡이는 왼쪽 손목, 오른손잡이는 오른쪽 손목)에 착용한다.

스마트 위치에서는 행동 분류를 위한 데이터로 가속도 센서의 값을 측정한다. 가속도 센서의 값은 1초에 10번, 10Hz로 샘플링된다. 데이터로는 선택한 행동 클래스와 가속도 센서의 x, y, z값이 저장되고 측정 즉시 전송 형식으로 변환하여 실시간으로 스마트 위치와 연결된 스마트폰으로 전송한다. 이 때 통신방식으로는 BLE(Bluetooth Low Energy)를 사용한다. 스마트폰에서는 스마트 위치에서 전송된 데이터를 TCP 소켓 통신을 활용하여 그대로 서버로 전송한다. 스마트폰은 서버와 스마트워치의 매개체 역할만 수행한다. 서버에서는 전송된 데이터들을 저장된다.

3.2 특징 추출 단계

수집된 데이터로부터 기계학습 모델에 사용할 특징을 추출하는 특징 추출 단계는 서버에서 수행되며 다

음과 같다. 사람의 행동은 연속적인 동작을 가지므로 같은 행동 내 순차적인 데이터를 10초, 즉 100개씩 그룹화 하여 특징을 추출한다. 그룹화 시, 이전 데이터와 90% 구간을 공유하는 중첩(overlap) 방식을 사용한다. 이 논문에서 사용하는 특징들은 가속도 센서 x축 값의 평균, 가속도 센서 y축 값의 평균, 가속도 센서 z축 값의 평균, 가속도 센서 x축 값의 표준편차, 가속도 센서 y축 값의 표준편차, 가속도 센서 z축 값의 표준편차이다. 분류기에서는 이 특징들을 사용하여 학습한다.

3.3 학습 및 분류 단계

학습 및 분류 단계는 앞선 단계에서 만든 데이터 세트를 활용하여 기계학습 알고리즘을 사용하여 만든 분류기를 학습시키고 테스트 해보는 과정이다.

우리는 분류기에 지도학습 기반의 3종류의 기계학습 알고리즘을 사용한다. 먼저 결정 트리(Decision Tree) 알고리즘은 결정 트리를 사용하여 측정값을 가지고 목표 값을 얻기 위한 학습을 한다. 목표 값이 유한한 분류 트리과 목표 값이 연속적인 값을 가지는 회기 트리 두 종류로 나뉜다. 이 방법은 일반화에 적합하지 않고, 각 단계가 계층적으로 구성되어 있기 때문에 중간에 에러가 발생한다면 다음 단계로 계속 에러가 전파되는 단점을 갖고 있다.

두 번째 알고리즘은 랜덤 포레스트(Random Forest) 알고리즘이다. 이 알고리즘은 앙상블 학습 방법의 일종으로, 결정 트리보다 조금 발전 된 방법이다. 가장 핵심 특징은 임의성에 의해 서로 조금씩 다른 특성을 갖는 트리들로 구성하여 각 트리의 예측이 서로 영향을 미치는 것을 최소화 하여 좀 더 일반화시킬 수 있도록 한다. 이 학습 방법 역시 분류와 회기 분석 모두 사용할 수 있다.

마지막 알고리즘은 서포트 벡터 머신(Support Vector Machine)이다. 서포트 벡터 머신은 특정 목표 값을 갖는 데이터의 집합을 바탕으로, 새로운 데이터를 어느 목표 값으로 예측할 것인지 판단하는 모델이다. 이 예측 근거는 서로 다른 목표 값을 가진 데이터 간의 경계를 표시하여 구분하는데, 각기 다른 목표 값을 지닌 데이터와 이 경계간의 폭을 가장 크게 만드는 것이 이 알고리즘의 핵심 목표이다. 선형 분류 외의 비-선형 분류에도 사용할 수 있는데 이 경우 커널 트릭을 사용한다.

우리는 위 3가지 알고리즘을 사용한 기계학습 모델을 설계하여 분류기를 제작한다. 분류기를 제작하기 위해 python 기반의 scikit-learn 라이브러리^[11]를 사용

하였다.

IV. 성능 평가

이 장에서는 앞서 설계한 사용자 행동 분류 시스템을 평가한다. 먼저 사용자 행동 분류 시스템에 사용된 두 종류의 데이터 세트를 설명하고, 전체적인 결과와 세부 사항을 살펴본다.

4.1 실험 데이터의 구성

성능 평가를 위한 실험 데이터는 2명이 일상생활 속에서 해당 행동을 할 때마다 지속적으로 임의의 시간동안 데이터를 수집하였다. 표 2는 2명에게서 수집된 데이터로부터 특징 추출한 데이터 세트이다. 각 행동 별 데이터의 개수가 나타나 있다. 우리는 실험 및 검증을 위해 2개의 데이터 세트의 데이터를 9:1로 나누어 3가지 모델들에 대해 각각 학습 및 검증을 시행하였다.

표 2. 실험 데이터의 개수
Table 2. The number of experimental data

클래스	데이터 세트 #1	데이터 세트 #2
B1	52445	10067
B2	26577	10201
B3	16221	11258
B4	15433	15634
B5	33758	17950
B6	38503	7454
B7	7415	2950
B8	5901	4613
B9	13655	11918
B10	1720	4534
B11	21674	6611
Total	233302	103191

4.2 성능 비교

본 섹션에서는 2가지 데이터 세트에 대해 각 모델별로 학습 및 평가한 종합적인 결과를 평가하고자 한다.

4.2.1 평가 지표

기계학습 분야는 특성상 특징한 한 가지 지표가 설계된 기계학습 모델에 대하여 객관적으로, 포괄적으로 모든 성능을 평가하기 어렵다. 특별한 절대 지표가 없는 만큼, 본 논문에서는 사용자 행동 분류에 대해 보다 객관적으로 평가하기 위해 기계학습 모델 평가 시

가장 많이 사용하는 Accuracy, Precision, Recall, F1-Score 4가지 평가 지표를 사용한다. 4가지 지표는 많은 기계학습 관련 연구에서 평가 지표로 많이 사용되며, 표 3을 기반으로 하여 다음과 같은 식으로 얻어진다.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

$$Precision = \frac{(TP)}{(TP + FP)} \quad (2)$$

$$Recall = \frac{(TP)}{(TP + FN)} \quad (3)$$

$$F1-Score = 2 \times \frac{(recall \times precision)}{(recall + precision)} \quad (4)$$

표 3. 분류 문제에 대한 컨퓨전 매트릭스
Table 3. Confusion matrix for classification problem

		실제 결과	
		Positive	Negative
예측 결과	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

4.2.2 성능 평가

그림 3 그림 4 그림 5 그림 6은 데이터 세트 #1과 데이터 세트 #2를 사용하여 기계학습 분류 모델을 학습 및 검증한 결과를 나타낸 그래프이다. 각 그래프는 순서대로 Accuracy, Precision, Recall, F1-Score를 표시하였다. 그래프는 총 3종류의 모델에 대해 테스트한 결과를 나타내고 있고, 각 모델 별 첫 번째 항목은 데이터 세트 #1의 수치, 두 번째 항목은 데이터 세트 #2의 수치, 세 번째 항목은 데이터 세트 #1과 데이터 세트 #2의 평균 수치이다.

모델 별 특징으로는 결정 트리(DT)기반의 모델이 가장 예측 성능이 떨어지는 것을 확인할 수 있다. 모든 평가 지표가 85%이하로 상대적으로 매우 낮은 것을 확인할 수 있다. 다른 모델에 비해 사용자 행동 분류에는 부적합 하다고 판단된다. 평균적으로 최고 80%, 최소 76%의 성능을 갖는다.

반면, 랜덤 포레스트(RF)기반 모델과 서포트 벡터 머신(SVM)기반 모델은 4가지 지표가 모두 충분히 높은 수치를 나타내었다. 랜덤 포레스트 모델은 모든 데이터, 모든 항목에서 90% 이상의 성능을 갖는다. 이




그림 3. Accuracy
Fig. 3. Accuracy




그림 4. Precision
Fig. 4. Precision




그림 5. Recall
Fig. 5. Recall




그림 6. F1-Score
Fig. 6. F1-Score

는 충분히 높은 예측 성능을 가진다고 평가할 수 있다. 랜덤 포레스트 모델이 세 가지 기계학습 모델 중에서는 가장 뛰어난 성능을 갖는다. 평균적으로 최소 91.5%, 최고 92%의 성능을 갖는다.

서포트 벡터 머신은 랜덤 포레스트 모델보다는 조금 뒤처지는 성능을 보였으나 충분히 좋은 결과를 보여준다. 데이터 세트 #1의 경우 F1-Score를 제외한 지표들은 1%, F1-Score는 2%밖에 차이를 보이지 않는다. 평균적으로 최고 89.5%, 최소 88.5%의 성능을 갖는다.

대부분의 평가 지표는 데이터 세트 #1의 결과가 데이터 세트 #2의 결과보다 좋게 나왔다. 이는 데이터 세트 #1의 학습 데이터양이 데이터 세트 #2의 학습 데이터양보다 거의 2배가량 많기 때문에 학습 데이터가 많을수록 예측률이 올라가는 기계학습 알고리즘의 특성 때문에 나온 결과인 것 같다. 이는 더 많은 학습 데이터가 있다면 예측률 역시 더욱 올라갈 것으로 기대할 수 있다.

4.3 컨퓨전 매트릭스를 활용한 상세 결과

다음은 각각의 모델별 예측 결과를 컨퓨전 매트릭스(confusion matrix)로 상세하게 나타내어 분석한 결과이다. 그림 7, 그림 8, 그림 9는 데이터 세트 #1의 결정 트리, 랜덤 포레스트, 서포트 벡터 머신 모델의 결과이고, 그림 10, 그림 11, 그림 12는 데이터 세트 #2의 결정 트리, 랜덤 포레스트, 서포트 벡터 머신 모델의 결과이다.

데이터 세트 #1 으로 학습한 결과부터 자세히 살펴본다. 먼저 그림 7의 결정트리의 결과 중 가장 눈에 띄는 점은 B7, B8, B10을 전혀 예측하지 못한다는 점이다. 그 외에도 B5, B11의 예측률 또한 낮다는 점을 확인할 수 있다. 이런 상세한 결과로 결정 트리는 일상생활 행동 분석에는 부적합함을 확인할 수 있다.

그림 9의 랜덤 포레스트 결과와 그림 10의 서포트 벡터머신의 결과는 비슷한 양상을 보이므로 동시에 평가하겠다. 우선 전반적으로 모든 행동들이 꽤 많은 예측률을 보임을 알 수 있다. 공통적으로 B1을 B2, B4, B5로 B2를 B6로 B3을 B11로 B4를 B1로 B5를 B1로 B6을 B1, B2, B11로 B7을 B6, B8로 B11을 B1, B5, B6, B7로 혼동함을 알 수 있다. 서로 다른 행동들이지만 각 행동 내에는 비슷한 동작, 비슷한 특징들이 존재하여 서로 혼동의 여지를 주는 것으로 판단된다. 그럼에도 불구하고 대부분 높은 확률로 맞음을 알 수 있다. 다만 B11에 대한 예측률이 두 모델 모두 상대적으로 낮으므로 이 부분에 대해서는 새로운 특

징이나 다른 판단 근거를 찾아 추가하여야 할 필요성이 있다. 그 외에도 랜덤 포레스트모델의 B7의 예측률이 상대적으로 낮아 이 부분 역시 랜덤 포레스트 모델을 사용할 때에는 고려해야 할 부분이다.

다음은 데이터 세트 #2로 학습한 결과이다. 데이터 세트 #2는 데이터 세트 #1에 비해 데이터의 개수가 절반 수준으로 적다. 기계학습에서의 데이터의 양은 학습률에 영향을 미치기 때문에 매우 중요한데, 이 부분을 감안하여 모델의 결과가 평균적으로 낮은 점을

		Predicted Class										
		B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11
Actual Class	B1	0.973	0.013	0.00	0.012	0.001	0.00	0.00	0.00	0.00	0.00	0.00
	B2	0.00	0.910	0.00	0.00	0.00	0.090	0.00	0.00	0.00	0.00	0.00
	B3	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B4	0.018	0.00	0.00	0.982	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B5	0.029	0.309	0.00	0.00	0.662	0.00	0.00	0.00	0.00	0.00	0.00
	B6	0.016	0.020	0.00	0.00	0.005	0.839	0.00	0.00	0.113	0.00	0.008
	B7	0.00	0.00	0.00	0.00	0.00	0.022	0.00	0.00	0.978	0.00	0.00
	B8	0.00	0.00	0.042	0.00	0.00	0.00	0.00	0.00	0.958	0.00	0.00
	B9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
	B10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
	B11	0.614	0.00	0.00	0.00	0.007	0.061	0.00	0.00	0.021	0.00	0.297

그림 7. 데이터 세트 #1의 결정 트리 모델 결과
Fig. 7. DT result of dataset #1

		Predicted Class										
		B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11
Actual Class	B1	0.951	0.017	0.00	0.016	0.012	0.00	0.00	0.00	0.00	0.00	0.00
	B2	0.00	0.949	0.00	0.00	0.00	0.051	0.00	0.00	0.00	0.00	0.00
	B3	0.00	0.00	0.988	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.012
	B4	0.020	0.00	0.00	0.980	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B5	0.021	0.00	0.00	0.00	0.977	0.00	0.00	0.00	0.00	0.00	0.002
	B6	0.009	0.00	0.00	0.00	0.00	0.989	0.00	0.00	0.00	0.00	0.002
	B7	0.00	0.00	0.00	0.00	0.00	0.075	0.587	0.331	0.007	0.00	0.00
	B8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.00
	B9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
	B10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
	B11	0.204	0.00	0.00	0.00	0.045	0.101	0.017	0.00	0.00	0.00	0.633

그림 8. 데이터 세트 #1의 랜덤 포레스트 모델 결과
Fig. 8. RF result of dataset #1

		Predicted Class										
		B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11
Actual Class	B1	0.970	0.016	0.00	0.002	0.011	0.00	0.00	0.00	0.00	0.00	0.00
	B2	0.00	0.990	0.00	0.00	0.00	0.010	0.00	0.00	0.00	0.00	0.00
	B3	0.00	0.00	0.976	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.024
	B4	0.050	0.00	0.00	0.950	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B5	0.026	0.003	0.00	0.00	0.971	0.00	0.00	0.00	0.00	0.00	0.00
	B6	0.009	0.002	0.00	0.00	0.00	0.983	0.00	0.00	0.00	0.00	0.006
	B7	0.00	0.00	0.00	0.00	0.00	0.083	0.711	0.206	0.00	0.00	0.00
	B8	0.00	0.00	0.00	0.00	0.00	0.00	0.150	0.850	0.00	0.00	0.00
	B9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
	B10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
	B11	0.316	0.00	0.00	0.00	0.110	0.092	0.015	0.00	0.00	0.00	0.466

그림 9. 데이터 세트 #1의 서포트 벡터 머신 모델 결과
Fig. 9. SVM result of dataset #1

		Predicted Class										
		B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11
Actual Class	B1	0.902	0.00	0.00	0.00	0.098	0.00	0.00	0.00	0.00	0.00	0.00
	B2	0.00	0.908	0.00	0.00	0.00	0.092	0.00	0.00	0.00	0.00	0.00
	B3	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B4	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B5	0.006	0.00	0.00	0.00	0.982	0.00	0.00	0.00	0.00	0.00	0.012
	B6	0.009	0.252	0.013	0.00	0.00	0.664	0.00	0.00	0.00	0.061	0.00
	B7	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
	B8	0.00	0.00	0.324	0.00	0.00	0.00	0.00	0.00	0.00	0.676	0.00
	B9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
	B10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
	B11	0.00	0.519	0.410	0.00	0.00	0.00	0.00	0.00	0.00	0.070	0.00

그림 10. 데이터 세트 #2의 결정 트리 모델 결과
Fig. 10. DT result of dataset #2

		Predicted Class										
		B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11
Actual Class	B1	0.929	0.00	0.00	0.00	0.071	0.00	0.00	0.00	0.00	0.00	0.00
	B2	0.00	0.918	0.00	0.00	0.00	0.08	0.00	0.00	0.00	0.00	0.00
	B3	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B4	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B5	0.036	0.00	0.00	0.00	0.895	0.00	0.00	0.00	0.00	0.00	0.069
	B6	0.009	0.00	0.00	0.00	0.00	0.987	0.002	0.001	0.00	0.00	0.00
	B7	0.00	0.00	0.00	0.00	0.00	0.00	0.980	0.020	0.00	0.00	0.00
	B8	0.00	0.00	0.00	0.00	0.00	0.00	0.251	0.749	0.00	0.00	0.00
	B9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00
	B10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
	B11	0.00	0.184	0.193	0.009	0.00	0.029	0.00	0.259	0.00	0.00	0.327

그림 11. 데이터 세트 #2의 랜덤 포레스트 모델 결과
Fig. 11. RF result of dataset #2

		Predicted Class										
		B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11
Actual Class	B1	0.857	0.00	0.00	0.00	0.143	0.00	0.00	0.00	0.00	0.00	0.00
	B2	0.00	0.898	0.00	0.00	0.00	0.101	0.00	0.00	0.00	0.00	0.00
	B3	0.00	0.00	1.000	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B4	0.00	0.00	0.00	1.000	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	B5	0.006	0.00	0.00	0.00	0.931	0.00	0.00	0.00	0.00	0.00	0.062
	B6	0.00	0.027	0.00	0.00	0.00	0.939	0.006	0.00	0.00	0.00	0.028
	B7	0.00	0.00	0.00	0.00	0.00	0.00	1.000	0.00	0.00	0.00	0.00
	B8	0.00	0.00	0.00	0.00	0.00	0.00	0.586	0.310	0.10	0.00	0.00
	B9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.000	0.00	0.00
	B10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.000	0.00
	B11	0.00	0.333	0.299	0.00	0.00	0.00	0.00	0.254	0.00	0.00	0.114

그림 12. 데이터 세트 #2의 서포트 벡터 머신 모델 결과
Fig. 12. SVM result of dataset #2

인지하고 평가한다.

또한 이전 연구들에서 분류한 특정 운동 자세 감지와 같은 운동 관련 행동들은 대부분의 행동들의 동작이 정해져있다. 운동의 경우에는 모범적인 자세가 있어, 대부분의 사람들이 비슷한 자세와 비슷한 동작을 취하며 행동을 수행한다. 그러나 일상생활 행동들은 같은 행동 내에서도 사람마다 다른 동작, 다른 구성을 취할 수 있다. 이 부분을 고려하여 같은 모델을 사용한 결과 내에서도 행동 별로 예측률에 차이가 있을 수

있다는 점을 확인하고자 한다.

먼저 그림 10의 결정 트리의 결과를 살펴보면 데이터 세트 #1과 마찬가지로 B7, B8에 대한 예측이 전혀 이루어지지 않고 있다. 데이터 세트 #1과 비교하여 B5, B6, B10, B11의 예측률이 눈에 띄게 차이는 점을 알 수 있다. 그러나 전혀 예측하지 못하는 행동도 있고 전반적으로 낮은 예측률을 보이므로 분석이 의미가 갖기는 힘들다. 두 번의 결과로 결정 트리는 다른 모델에 비하여 행동 데이터 분류에 부적합하다고 판단된다.

데이터 세트 #2의 랜덤 포레스트 모델의 결과와 서포트 벡터 머신의 결과도 데이터 세트 #1의 결과와 비슷한 양상을 보인다. 따라서 데이터 세트 #1과의 차이점을 좀 더 세부적으로 분석해보도록 한다. 그림 11은 랜덤 포레스트 모델의 결과이다. 데이터 세트 #2의 결과는 데이터 세트 #1과 비교하여 B7행동을 좀 더 잘 예측하고, B8과 B11행동을 더욱 혼동하는 것을 확인할 수 있다. 특히 B7의 경우 데이터 세트 #1의 예측률은 58.7%, B11의 경우 데이터 세트 #2의 예측률은 32.7%로 많이 저조한 것을 확인할 수 있는데, 이는 모델 보다 두 사람의 행동의 특징 문제인 것으로 판단된다.

마지막으로 그림 12는 서포트 벡터 머신의 결과이다. 데이터 세트 #1의 결과와 비교하여 데이터 세트 #2의 경우, B8, B11을 특히 잘 예측하지 못한다. 두 행동 모두 50%도 못 미치는 인지율을 가지고 있다. 반면 B3과 B4는 100%로 완벽하게 예측함을 확인할 수 있다.

4.4 성능 평가 논의

사람의 행동 데이터는 같은 행동이라도 자세, 구분 동작이 매우 다를 수 있어 일반화가 어려우며, 다른 행동 일지라도 자세, 구분 동작이 비슷하여 인식에 혼동을 줄 여지가 있으나, 대부분의 경우 높은 확률로 인지가 가능한 것을 확인할 수 있다.

주로 혼동되는 특정 행동들의 경우, 추가적인 판단 근거를 만들어 줄 필요가 있다. 먼저 위치 정보를 특징 중 하나의 요소로 처리하는 것이 아니라, 위치 정보로 1차 분류를 하는 방법이 있다. 각 위치 별 행동 분류 모델을 분리하여 설계함으로써, 서로 다른 위치에서 일어나는 행동들끼리의 혼동을 줄일 수 있다. 특별히 혼동되는 행동들끼리는 추가 데이터를 활용하여 해결 가능할 것으로 보인다. B7과 B8은 분류 모델에서 특히 혼동이 많이 되는 행동데이터인데, 이 부분은 카메라를 통해 고무장갑을 사용하는 것을 인지하거나,

위치 감지 센서를 통해 싱크대에만 있으면 B7, 가스 레인지, 싱크대, 도마 등 위치가 수시로 변할 시에는 B8로 판단할 수 있을 것이다.

또한 다양한 기계학습 알고리즘 중 랜덤 포레스트 알고리즘이나 서포트 벡터 머신 알고리즘을 사용한다면 더욱 높은 예측률을 기대할 수 있을 것이다. 반면 결정 트리 알고리즘은 사용자 행동 데이터 분석에는 적합하지 않다고 평가된다.

종합적으로 성능 평가를 통해 제안된 사용자 행동 분류 시스템이 충분히 동작 가능하며, 일상생활 속의 활동성이 작은 행동들 역시 높은 정확도로 구분이 가능한 것을 확인할 수 있다.

V. 결 론

인간 행동 인지 기술에 대해서 관심이 많아짐과 동시에 해당 기술에 대해 많은 연구가 이루어지며, 사용하기 편리한 기기들이 많이 개발되었다. 지금까지의 많은 연구들은 해당 분야에서 사용하기 위해 주로 인간의 활동성이 큰 행동만 분류하였다. 그러나 점점 더 인간의 편의성을 증진시키는 다양한 기기가 연구, 개발되고, 실제 사용량이 많이 늘어나는 만큼 특정 분야 내에서만이 아닌 사람의 모든 행동을 분류하고자 하는 노력이 필요하다.


본 논문에서는 기존의 활동성이 큰 행동과 더불어 새로운 일상생활 속의 활동성이 작은 행동들을 정의하고 분류하였다. 이러한 연구는 스마트 홈, 스마트 오피스, 사물인터넷 기기 연구와 새로운 서비스를 제공하기 위해 필수적인 요소가 될 것이다. 현재는 11가지의 행동을 구분하고 있지만, 점점 더 다양해지는 서비스에 활용하기 위해 영역을 확장하여 좀 더 많은 공간과 많은 행동들을 구분하는 연구가 필요할 것이다.

또한, 분류되는 행동들의 개수가 늘어나는 만큼, 행동들 서로 혼동하는 경우가 발생할 수 있다. 추가 연구에서는 이런 부분을 고려하여, 평균, 표준 편차 외 새로운 특징들을 추가하고, 자이로센서, 심박센서 등 스마트 워치에 내장되어 있는 다양한 센서들로부터 데이터들을 수집하고, 실내의 경우 IP카메라, 적외선 센서 등 스마트 홈, 스마트 오피스에 구현된 센서들을 활용하여 행동 인지를 위한 판단 근거를 늘리는 방법을 통해 혼동을 줄일 수 있다.

References

- [1] Q. Sun, et al., "Internet of things: summarize on concepts, architecture and key technology problem," *J. Beijing University of Posts and Telecommun.*, vol. 33, no. 3, pp. 1-9, 2010.
- [2] O. D. Lara, and M. A. Labrador, "A survey on human activity recognition using wearable sensors," *IEEE Commun. Surveys and Tuts.*, vol. 15, no. 3, pp. 1192-1209, 2013.
- [3] Y. Kwon, K. Kang, and C. Bae, "Unsupervised learning for human activity recognition using smartphone sensors," *Expert Syst. with Appl.*, vol. 41, no. 14, pp. 6067-6074, 2014.
- [4] X. Yin, et al., "Human activity detection based on multiple smart phone sensors and machine learning algorithms," *IEEE CSCWD*, pp. 582-587, 2015.
- [5] M. A. Case, et al., "Accuracy of smartphone applications and wearable devices for tracking physical activity data," *Jama*, vol. 313, no. 6, pp. 625-626, Feb. 2015.
- [6] A. Wang, et al., "A comparative study on human activity recognition using inertial sensors in a smartphone," *IEEE Sensors J.*, vol. 16, no. 11, pp. 4566-4578, 2016.
- [7] T. T. Um, V. Babakeshizadeh, and D. Kulic, "Exercise motion classification from large-scale wearable sensor data using convolutional neural networks," arXiv preprint arXiv: 1610.07031v3, Jul. 2017.
- [8] F. Foerster, M. Smeja, and J. Fahrenberg, "Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring," *Computers in Human Behavior*, vol. 15, no. 5, pp. 571-583, 1999.
- [9] R. Rawassizadeh, B. A. Price, and M. Petre, "Wearables: has the age of smartwatches finally arrived?," *Commun. ACM*, vol. 58, no. 1, pp. 45-47, 2015.
- [10] <https://www.apple.com/watch/>
- [11] F. Pedregosa, et al. "Scikit-learn: machine learning in python," *J. Machine Learning Res.*, vol. 12, pp. 2825-2830, Oct. 2011.

권민철 (Min-Cheol Kwon)



2016년 2월 : 국민대학교 전자
공학과 졸업

2016년 3월~현재 : 국민대학교
보안-스마트 전기자동차공학
석사과정

<관심분야> 기계학습, 임베디
드 시스템, 사물 인터넷

최선웅 (Sunwoong Choi)



1998년 2월 : 서울대학교 전산
과학과 졸업

2000년 2월 : 서울대학교 전산
과학과 석사

2005년 8월 : 서울대학교 전기,
컴퓨터공학부 박사

2007년 3월~현재 : 국민대학교
전자공학부 부교수

<관심분야> 유무선 네트워크, 기계학습, 사물 인터
넷