

# 웨어러블 동작센서와 인공지능 학습모델 기반에서 행동인지의 개선

안정욱<sup>†</sup>, 강운구<sup>\*\*</sup>, 이영호<sup>\*\*\*</sup>, 이병문<sup>\*\*\*\*</sup>

## Improvement of Activity Recognition Based on Learning Model of AI and Wearable Motion Sensors

Junguk Ahn<sup>†</sup>, Un Gu Kang<sup>\*\*</sup>, Young Ho Lee<sup>\*\*\*</sup>, Byung Mun Lee<sup>\*\*\*\*</sup>

### ABSTRACT

In recent years, many wearable devices and mobile apps related to life care have been developed, and a service for measuring the movement during walking and showing the amount of exercise has been provided. However, they do not measure walking in detail, so there may be errors in the total calorie consumption. If the user's behavior is measured by a multi-axis sensor and learned by a machine learning algorithm to recognize the kind of behavior, the detailed operation of walking can be autonomously distinguished and the total calorie consumption can be calculated more than the conventional method. In order to verify this, we measured activities and created a model using a machine learning algorithm. As a result of the comparison experiment, it was confirmed that the average accuracy was 12.5% or more higher than that of the conventional method. Also, in the measurement of the momentum, the calorie consumption accuracy is more than 49.53% than that of the conventional method. If the activity recognition is performed using the wearable device and the machine learning algorithm, the accuracy can be improved and the energy consumption calculation accuracy can be improved.

**Key words:** Motion Sensor, Activity Recognition, Machine Learning Model, Smart Lifecare

### 1. 서 론

최근 IT기기를 이용하여 일상생활에서 건강관리를 제공하고 보조하는 기술과 제품이 개발되고 있다 [1]. 그 중에는 운동을 보조하는 웨어러블 기기도 있는데, 하루 동안의 총 보행 수를 측정하여 이동 거리를 보여준다. 일부 기술에서는 이동속력을 측정하여 걷기와 달리기를 구분하기도 하고 사용자의 설정으

로 걷기와 달리기를 구분하여 그것을 기준으로 산정한 운동량을 보여주는 기능도 제공한다[2-4].

일반적으로 보행을 인지할 때에는 보행하는 과정에서 지면에 발이 닿을 때에 그 충격파를 이용한다 [5-6]. 충격파가 다리를 거쳐 골반, 허리까지 도달하므로, 허리에 가속도 센서를 밀착하여 부착한 후 측정한다. 만보계는 이러한 원리를 이용하여 보행 수를 측정할 수 있다. 측정된 보행 수로 활동 대사량 계산

※ Corresponding Author : Byung Mun Lee, Address: 1342 Seongnamdae-ro, Sujeong-gu, Seongnam-si, Gyeonggi-do, Korea, TEL : +82-31-750-4756, FAX : +82-31-750-4756, E-mail : bmlee@gachon.ac.kr

Receipt date : Jun. 25, 2018, Approval date : Jul. 16, 2018

<sup>†</sup> Dept. of Computer Engineering, Gachon University  
(E-mail : WoodenCatty@gmail.com)

<sup>\*\*</sup> Dept. of Computer Engineering, Gachon University  
(E-mail : ugkang@gachon.ac.kr)

<sup>\*\*\*</sup> Dept. of Computer Engineering, Gachon University  
(E-mail : lee.brain69@gmail.com)

<sup>\*\*\*\*</sup> Dept. of Computer Engineering, Gachon University  
※ This work was supported by the Technology development Program(Grants No.S2593303) funded by the Ministry of SMEs and Startups(MSS, Korea) in 2018.

공식을 적용하여 행동에 대한 운동 소모량을 계산하고, 하루의 총 운동량을 보여준다.

하지만 이렇게 보행을 인지할 때 보행유형을 알 수 없고, 보행 수에 대한 정확도가 떨어진다. 예를 들어 같은 보행 수라 할지라도 사용자가 평지를 걷는지, 계단을 오르는지, 계단을 내려가는지에 대한 세부 유형을 알 수 없다. 각 보행유형별로 소모 활동 대사량이 다른데, 이를 구분할 수 없다면 정확한 운동량을 산출할 수 없는 문제가 발생한다.

또한 단순히 층격과만을 측정하여 보행 수를 측정하므로 기기를 손에 쥐고 흔들는 것도 보행이라 잘못 인지하게 된다. 이와 같은 이유로 보행 수를 이용하여 칼로리나 운동량을 계산하면 오차가 생겨 정확한 이동 거리를 측정할 수 없다.

측정의 정확도를 높이려면 움직임뿐만 아니라 진행방향도 알아야 한다. 이것은 9축 가속도 센서를 이용하고 머신러닝 기법을 도입한다면 보다 정확한 행동을 인지할 수 있다. 본 연구에서는 머신러닝 기법을 도입하기 위해 측정 데이터를 머신러닝 알고리즘에 적용하여 새로운 학습모델을 생성한다. 이를 통해 걷기는 물론 행동의 세부 유형까지 인지할 수 있다.

본 논문에서는 이를 확인하기 위해 센서를 이용하여 행동인지를 할 때에 어느 부위에서 측정을 하여야 가장 정확도가 높은지, 몇 축의 가속도 센서를 이용하여야 정확도가 높은지 실험을 진행하고자 한다. 실험에서 걷기, 달리기, 계단 오르기, 계단 내려가기를 반복적으로 수행하여 데이터를 추출하고, 추출한 데이터를 머신러닝 알고리즘에 적용한 보다 정확한 학습모델을 생성한다. 이 학습모델을 이용하여 같은 행동에 대해 인지정확도를 측정하고, 기존의 방식과 비교한다.

인지한 세부 행동 유형은 일일 에너지 소비량 추공식을 이용하여 행동에 대한 운동 소모량을 계산하는데 이용한다. 기존의 방식보다 정확하게 에너지 소비량을 산출해낼 수 있고, 더 나아가 사용자의 하루 평균 소모 칼로리와 운동량을 계산, 행동 패턴을 분석하여 운동을 조절할 수 있도록 한다.

2. 관련 연구

2.1 가속도 센서를 활용한 행동인지 연구

2.1.1 스마트폰 기반 운동량 측정 및 모니터링 시스템

첫 번째 관련 연구사례는 스마트폰의 가속도 센서와 함께 GPS 센서를 동시에 이용하여 소모 칼로리를 인지하는 사례가 있다[7]. 이 사례는 운동 유형에 따른 대사당량(METs, Metabolic Equivalents)[8]를 측정한 후, 그 값을 이용하여 칼로리 소모량으로 변환하는 시스템이다.

Fig. 1과 같이 서있기, 걷기, 조깅(달리기)에 대해 스마트폰의 센서를 이용하여 GPS데이터값과 3축 가속도값을 측정하고, 측정된 데이터를 분석하여 특징을 추출한다. 이후 모델 분류기를 이용하여 운동 유형의 특징을 구분하여 행동을 인지한 사례이다[9]. 각 운동의 속도에 따라 구체적으로 대사량을 정의하여 소모 칼로리량을 계산한다.

그러나 GPS 센서는 실내에서 측정이 어려워 정확한 이동거리를 산출할 수 없을 뿐만 아니라 실내 계단 운동에 대해 측정이 불가능하다는 한계가 있다.

2.1.2 스마트폰과 머신러닝을 활용한 행동인지 연구

두 번째로 살펴본 사례는 스마트폰의 3축 가속도 센서로 걷기, 달리기, 계단 오르기를 사용자의 움직임으로 측정하고, 이를 머신러닝 알고리즘에 적용시킨 것이다[10].

이 사례는 Fig. 2와 같이 바지 주머니에 스마트폰




Fig. 1. Activity measurement and monitoring system.




Fig. 2. Measuring acceleration on Smartphone.

Table 1. Accuracy by classifier

Classifier	Accuracy
J48	85.1%
Logistic Regression	78.1%
Multilayer Perceptron	91.7%

을 넣고 측정을 진행하며, 3축 가속도 값을 측정한다. 가속도값의 평균, 표준편차, 평균 변화량, 평균 순간 가속도, 최고점 간의 시간 차, 누적분포 값을 데이터로 이용하여[11], Java 기반의 머신러닝 라이브러리인 Weka[12]에서 J48[13], Logistic Regression[14], Multilayer Perceptron[15] 분류기를 통해 각 행동을 분류하였다. 분류 결과를 살펴보면 Table 1과 같이 최소 85.1%에서 최고 91.7%의 정확도를 보인다.

Weka 라이브러리에 포함된 각 분류기는 각기 다른 알고리즘에 따라 측정 데이터를 학습한 후, 데이터를 분류할 수 있는 모델을 제작하여 행동을 인지한다. 머신러닝을 활용할 경우 행동인지의 정확도를 높이는 동시에, 더 다양한 행동을 인지할 수 있다.

2.1.3 웨어러블 기기를 활용한 행동인지 연구

세 번째 사례에서는 허리춤에 가속도 센서를 부착한 후 걷기, 달리기, 계단 오르기의 행동을 측정하고 분석하여, 보정한 데이터를 머신러닝 알고리즘에서 행동을 구체적으로 인지하는 과정을 도입한 예이다[16].

사용자가 골반에 3축 가속도 센서를 착용한 후, Fig. 3과 같이 측정한 데이터를 이용하여 사용자의 움직임을 측정한다. 측정한 데이터는 머신러닝 어플

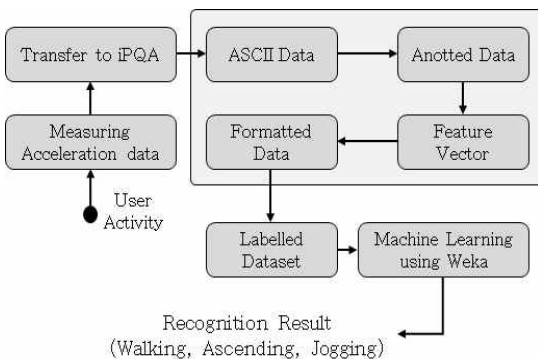


Fig. 3. Activity recognition algorithm based on machine learning.

리케이션을 탑재한 모바일기기(iPQA)로 전송하여 데이터를 가공하고, 데이터셋을 제작하여 행동 분류를 한다. 이와 같이 행동을 여러 가지 형태로 분류하려는 이유는 에너지 소비량을 산출할 때 각 행동에 따라 소모되는 에너지 기본량이 다르기 때문이다. 다음에서 보다 구체적인 에너지 소비량 산출에 대해 살펴보자.

2.2 가속도 센서를 활용한 행동인지 연구

하루 동안 수행한 행동들을 인지하고, 각 인지한 행동의 소모 칼로리량을 적용하면 하루의 총 에너지 소비량을 계산할 수 있다. 총 에너지 소비량의 90%는 기초대사량과 활동대사량이다. 나머지 10%는 체온유지, 소화애 소모되는 에너지로써 분류하는 적응대사량이지만 적은 양이므로 일반적으로 무시된다[17].

기초대사량은 Harris-Benedict 공식에 의해 계산이 가능하며 공식의 각 계수는 통계적으로 조사한 결과를 바탕으로 추론한 내용이다[18]. 일반적인 남성의 기초대사량 공식은 식 1과 같으며, 여성의 기초대사량 공식은 식 2와 같다.

$$66.5 + [13.7 \times W] + [5.0 \times H] - (6.8 \times A) \tag{1}$$

$$655.1 + [9.65 \times W] + [1.85 \times H] - (4.7 \times A) \tag{2}$$

예를 들어, 키(H)가 185 cm이고, 체중(W)이 85 kg이며 나이(A)가 22세인 남성의 기초대사량을 구한다면 2006.4 Kcal이다. 활동대사량은 활동할 때 근육에 의해 소비되는 에너지를 말한다. 식 3과 같이 계산하며, 각 활동에 소모되는 에너지 소모량은 Table 2와 같이 나타낼 수 있다[19].

$$A \times W \times T \tag{3}$$

예를 들어 체중(W)이 85 kg의 성인남성이 4 km/h로 한시간(T)동안 걷기(A)를 할 시 3.48(A)×85(W)×1(T)의 계산 결과로 295.8kcal의 활동 대사량을 소비한다. 그러므로 운동뿐만 아니라 인간의 활동종류에

Table 2. Energy expenditure for activities

Activity	Kcal/h/kg (A)
Standing	1.26
Walking (4 km/h)	3.48
Ascending	7.0
Running (8 km/h)	7.98

따라 소비되는 에너지가 다르게 적용되어야 하기 때문에 보다 정확한 행동인지가 필요하다. 그래서 본 논문에서는 인공지능 학습모델기반의 행동인지 기법을 제안한다.

### 3. 학습모델기반의 행동인지

#### 3.1 행동인지 학습모델

##### 3.1.1 학습 알고리즘

본 논문에서 제안하는 학습모델 기반의 행동인지에서는 인간의 모션을 센싱하기 위해서 Fig. 4와 같이 9축센서를 이용한다. 이 센서는 모션센서로써 가속도(A) 3축데이터, 자이로(G) 3축데이터 그리고 지자기(M) 3축데이터를 각각 측정하며 사용자의 허벅다리 부분에 부착 후 총 9개의 데이터(X, Y, Z)값을 획득한다. 측정된 데이터로 데이터 셋을 구성한 후 학습모델에 이용하면 각 보행유형에 대한 특징 점을 추출할 수 있다. 이를 학습 알고리즘에서 사용하기 적합한 포맷으로 가공하여야 하는데 그 과정에서 센서 오류 값을 제거하고, 각 측정 값에 해당하는 보행유형을 라벨로 정의한다. 라벨은 각 데이터가 어떤 행동을 의미하는지 명시하여 학습에 사용하기 위함이다.

학습모델 생성에 사용하는 머신러닝 알고리즘은 C4.5[12]을 기반으로 한 Weka 3.8의 J48알고리즘을 사용한다. 이는 분류기 머신러닝 알고리즘으로써 의사 결정트리에 기반을 두고 있다. 생성한 학습모델은

보행의 유형을 추정하는데 사용한다. 새로 측정된 가속도 데이터에 대해 학습시와 동일하게 특징점을 추출하고 머신러닝 알고리즘에 사용하기 적합한 형태로 가공한다. 가공한 데이터를 생성된 학습모델을 이용하여 최종적으로 보행유형이 무엇인지를 예측하고, 예측결과를 토대로 인지정확도를 평가한다.

인지정확도는 생성된 학습모델이 실제 보행유형을 추정하는데 얼마만큼 정확한지에 따라 그 결과가 달라진다. 그러므로 학습모델을 정확히 생성하는 것은 매우 중요하다.

##### 3.1.2 생성된 학습모델을 이용한 행동인지

생성된 학습모델은 이진트리의 형태를 띠며, 특징 값을 기준으로 각 행의 데이터 값을 비교하며 최종적으로 행동을 유추해내는 과정을 거친다. Fig. 5는 생성된 학습모델을 이용하여 보행유형중 '걷기'를 유추해 내는 과정이다. 그림 하단의 표는 측정된 9축 데이터를 의미하며, Ax, Ay, Az는 가속도를, Gx, Gy, Gz는 자이로를, Mx, My, Mz는 지자기를 의미한다.

Fig. 5의 예에서 살펴보면, 제시된 표에 기술된 것처럼 특징시점에 측정된 9개의 데이터 중에서 My의 값이 24.11213 이다. 이 값으로 결정트리의 루트노드부터 값을 비교하면 왼쪽방향으로 판단된다. 다음으로 비교할 대상 데이터는 Mx이다. 측정 값이 13.2206 이므로 -0.13371 보다 크다. 이와 같이 연속적으로 판단을 진행하여 최종 말단 노드인 'Walk'에 도달하

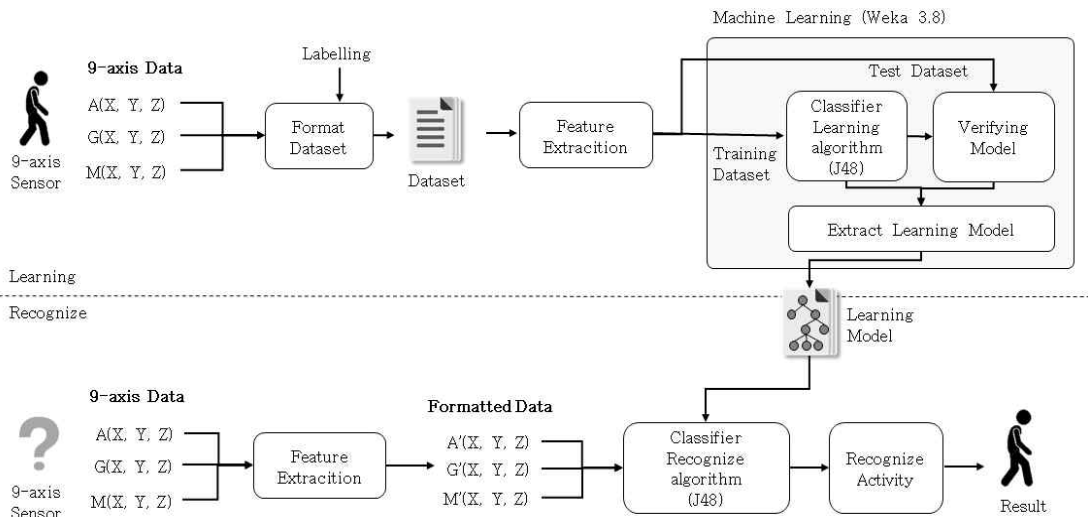


Fig. 4. Learning algorithm for an activity recognition based on the model.

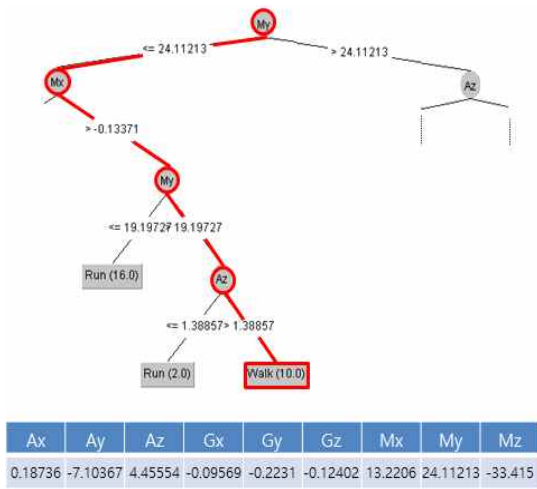


Fig. 5. Decision tree for an activity recognition.

게 된다. 이는 걷기를 의미하며, 오른쪽의 (10, 0)은 데이터 셋 중 이에 해당하는 값의 개수를 의미한다.

인지정확도는 라벨을 붙이지 않은 데이터를 위의 과정을 통해 보행유형을 인지한 후, 실제 데이터를 측정할 당시의 보행유형과 비교하여 맞았을 경우를 비율로 나타낸다.

### 3.2 인지정확도 측정실험

본 실험에서는 인지 정확도를 측정하기 위해서 9축 가속도센서 데이터와 함께 머신러닝 학습 알고리즘을 이용할 경우의 정확도를 확인하기 위해 사용자의 몸에 9축 가속도센서를 부착하여 실시하였다.

#### 3.2.1 실험조건

실험에 앞서 측정할 보행유형을 다음 Table 3과 같이 구분하였다. 서있기, 걷기, 계단 올라가기, 계단 내려가기, 달리기를 인지대상으로 설정하였으며, 걷기와 계단보행의 경우 4 km/h, 달리기의 경우 8 km/h의 일정한 속도로 이동하며 측정하였다.

Table 3. Sort of Activity

Activity	Speed	Number of data
Standing	0km/h	1000
Walking	4km/h	1000
Ascending	4km/h	1000
Descending	4km/h	1000
Running	8km/h	1000

걷기와 달리기의 경우 경사가 없는 평평한 바닥에서 수행하였으며, 한 방향으로 일정한 속도로 이동하도록 하였다. 계단 올라가기와 계단 내려가기는 45°의 경사를 가진 20개의 계단을 오르내리며 측정하였다. 계단의 경우 달리기와 걷기보다 길이가 짧으므로 별도로 추가 실험을 진행하였다.

각 행동 당 1,000개의 데이터를 포함하여 총 5,000개의 데이터를 측정하였다. 각 데이터는 보행유형을 식별하기 위해 라벨과 함께 실수형태의 9축 데이터 값으로 구성한다. 머신러닝을 수행할 때에는 순서를 임의로 섞어서 학습모델을 생성하여 편파적인 인지 결과가 나오지 않도록 하였다.

#### 3.2.2 실험환경

실험을 위해 사용자의 움직임을 측정할 때에, 측정 데이터량이 많으므로 높은 컴퓨팅 파워를 요구한다. 또한 9축 모션센서를 장착하여 모션데이터를 측정해야 하기 때문에 GPIO 단자와 고성능의 컴퓨팅 파워를 제공하는 Raspberry Pi Zero W를 이용하여 웨어러블 기기를 자체 제작하였다. 여기에 9축 모션센서는 LSM9DS0 센서를 사용하였으며 전반적인 규격과 성능은 Table 4와 같다.

Fig. 6과 같이 기기를 헤어밴드를 이용하여 오른쪽 허벅다리에 고정시키고, 무선 통신을 통해 노트북과 연결하여 측정 데이터를 저장하는 동시에 저장하였다. 노트북을 이용하여 웨어러블 기기에 콘솔로 접속한 후, 각 구간마다 다른 보행유형을 설정하였다.

#### 3.2.3 실험시나리오

실험은 Fig. 7과 같이 실험 시나리오 환경 하에서 진행하였다. 모션 데이터는 웨어러블 기기를 이용하여 측정했으며, 측정하는 동시에 각 라벨을 구분하여 저장하였다.

보행 경로는 Fig. 7과 같다. 라벨을 '걷기'로 설정한



Fig. 6. Experiment environment.

Table 4. LSM9DS0 Specification

Item	Specification
Model	FLORA 9-DOF
Sensor	LSM9DS0
Size	16 mm × 0.8 mm
Active Voltage Range	3.3v or Higher
Acceleration Measuring Range	±2/±4/±6/±8/±16 g linear acceleration full scale
Gyroscope Measuring Range	±2/±4/±8/±12 gauss magnetic full scale
Magnitude Measuring Range	±245/±500/±2000 dps angular rate full scale




Fig. 7. Experiment scenario.

후 (A)에서부터 (B)의 계단을 향하여 4 km/h의 속도로 걷는다. 걷기의 거리는 약 50 m이며, (B)의 위치에서는 라벨을 ‘계단 오르기’로 전환한 후 데이터를 측정한다. 계단을 모두 오른 후에는 (C)위치에서부터 반대편 계단이 위치한 (D)의 위치까지 8 km/h의 속도로 달려간다. 이 때 라벨을 ‘달리기’로 설정한다. (D)에 도착한 후 계단의 끝인 (A)까지는 ‘계단 내려가기’로 라벨을 설정한 후 계단을 내려간다. 이후 (A) 위치부터 위의 내용을 반복 수행한다.

3.3 실험결과

실험 시나리오에 따라 자체 제작한 웨어러블 기기를 이용하여 각 보행유형에 대한 데이터를 측정하였고, Weka 라이브러리의 J48 알고리즘을 사용하여 머신러닝을 수행하였다. 수행결과 평균적으로 97.3%의 인지정확도를 보였으며, 각각의 행동들 역시 최소

94%이상의 정확도를 보였다.

Fig. 8의 (a)는 인지 과정에서 보행유형을 올바르게 인지한 경우와 다르게 인지한 경우에 대한 혼동행렬이다. 맨 위의 알파벳들은 데이터를 토대로 인지한 보행유형을 의미한다. 또한 맨 오른쪽의 알파벳들은 실제로 데이터를 측정할 때의 보행유형을 의미한다. 왼쪽 위부터 오른쪽 아래까지의 대각선은 모두 정확하게 행동을 맞춘 경우를 의미한다. 예를 들면, 1,000개의 데이터 중에서 걷기는 980개, 달리기는 986개, 서있기는 988개, 계단 올라가기는 949개, 계단 내려가기는 960개를 맞춘 것이다.

좀 더 자세하게 계단 내려가기를 예로 설명을 하자면, 1,000개의 데이터 중 960개는 계단 내려가기로, 30개는 계단 올라가기로, 10개는 걷기로, 3개는 달리기로, 1개는 서있기로 판단한 결과다. (b)는 혼동행렬의 결과를 토대로 인지정확도(TP, True Positive)와 인지오류 비율(FP, False Positive)을 나타낸 것이다. 내려가기에서 96%, 올라가기에서 94.9%, 걷기에서 98%, 달리기에서 98.6%, 서있기에서 98.8%의 정확도를 기록하였으며, 평균 97.3%의 정확도를 기록했다.

4. 평가 및 분석

9축 모션센서와 머신러닝 알고리즘을 활용할 때, 행동인지 정확도가 향상되었는가를 확인하기 위해

(a)

	a	b	c	d	e	<-- classified as
	960	25	13	1	1	a = Descending
	30	949	7	8	6	b = Ascending
	10	9	980	0	1	c = Walking
	3	10	0	986	1	d = Running
	1	6	3	2	988	e = Standing

(b)

	TP Rate	FP Rate	Class
	0.960	0.011	Descending
	0.949	0.013	Ascending
	0.980	0.006	Walking
	0.986	0.003	Running
	0.988	0.002	Standing
Weighted Avg.	0.973	0.007	

Fig. 8. Activity recognition results.

관련연구에서 기술한 기존 연구방식과의 정확도 비교를 수행하였다. 스마트폰의 3축 가속도 센서를 이용한 경우[6]와 웨어러블 기기의 3축 가속도 센서를 이용한 경우[15] 두 가지를 비교 대상으로 설정하였다. 두 개의 논문에서는 서있기, 걷기, 달리기, 계단오르기, 계단 내려가기와 같은 보행유형을 구분하였다.

비교결과 인지정확도의 경우에는 스마트폰을 활용한 논문과는 5.15% 만큼 향상된 결과로 평가되었으며 웨어러블 기기를 활용한 논문과는 12.5%만큼 향상된 결과를 얻을 수 있었다. 본 논문의 경우 가속도 센서의 착용위치가 허벅다리에 가깝다. 반면에 기존 방식의 가속도센서 착용위치는 허리이므로 비교적 행동인지 정확도가 낮은 것으로 보인다. 착용위치에 따라서도 행동인지의 정확도가 차이를 보인다는 것을 알 수 있었다.

또한 각 행동에 있어서도 평균 18.6% 만큼 향상을

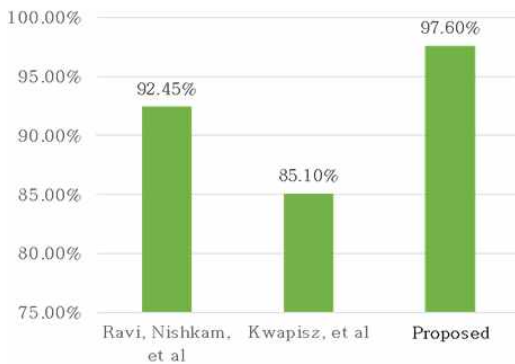


Fig. 9. Comparing recognition accuracy.

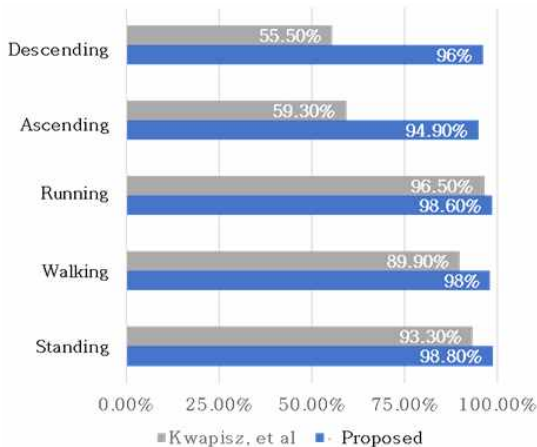


Fig. 10. Comparing Activity recognition accuracy.

보였다. 기존 방식에서는 3축 가속도 센서값만을 사용했지만, 본 논문에서는 가속도 센서 값과 함께 자이로 센서, 지자기 센서 값을 포함한 9축 가속도 센서를 사용하였다. 머신러닝 수행 시 더 다양한 데이터를 학습에 활용할 수 있으므로 더 높은 정확도를 달성할 수 있는 것으로 평가하였다.

인지실험 결과를 이용하여 총 에너지 소비량을 산출했을 경우, 제안한 방식으로 얻는 에너지 소비량과 기존방식으로 얻은 에너지 소비량의 차이는 Fig. 11에서처럼 49.53%로 확인되었다. 85 kg 성인 남성을 기준(K)으로 서있기(S), 걷기(W), 달리기(R), 계단 올라가기(A), 계단 내려가기(D)를 수행했을 경우, 총 에너지 소모량(E)을 식 4에 따라 산출할 수 있다. 계산 결과 85 kg의 성인 남자가 각각 한 시간 동안 서있기, 걷기, 달리기, 계단 오르기, 계단 내려가기를 수행했을 경우 1,972 kcal를 소모한다.

$$(1.21(S) \times 85(K)) + (3.48(W) \times 85(K)) + (7.98(R) \times 85(K)) + (7(A) \times 85(K)) + (3.48(D) \times 85(K)) = 1972kcal(E) \quad (4)$$

기존방식과 같이 단순히 걷음만을 측정했을 때에는 서서 멈춰있는 경우와 걷는 경우 두 가지에 대해서만 인식을 하므로 걷기, 달리기, 계단올라가기, 계단내려가기와 같은 행동은 모두 걷기로만 인식한다. 그러므로 총 에너지 소모량을 계산할 때에 세부적으로 동작을 구분하여 계산하지 않고 서 있기 1시간을 제외한 다른 행동은 모두 걷기로 통합하여 걷기 4시간으로 치환하여 식 5와 같이 계산한다. 계산 결과 1,286.05 kcal로 실제 총 에너지 소모량인 1,972 kcal과 685.95 kcal만큼 오차가 발생했다.

$$(1.21(S) \times 85(K)) + (3.48(W) \times 85(K)) \times 4 = 1286.05kcal \quad (5)$$




Fig. 11. Total energy expenditure.



개선된 방식의 경우 각각의 행동을 모두 개별적으로 인식할 수 있으므로 서있기, 걷기, 달리기, 계단 올라가기, 계단 내려가기 각 행동에 대해 각각 한 시간의 분량으로 계산한다. 이 때, Fig. 8에서 획득한 각 유형별 인식정확도를 식 4의 결과에 반영한 후 식 6와 같이 계산하면 1,971.22 kcal로 산출된다.

$$\begin{aligned}
 & (1.21(S) \times 85(K) \times 0.998(Acc)) + \\
 & (3.48(W) \times 85(K) \times 1.003(Acc)) + \\
 & (7.98(R) \times 85(K) \times 0.997(Acc)) + \\
 & (7(A) \times 85(K) \times 0.999(Acc)) + \\
 & (3.48(D) \times 85(K) \times 1.004(Acc)) = 1971.22kcal(E)
 \end{aligned} \tag{6}$$

이와 같이 기존 방식과 개선 방식을 이용하여 계산한 에너지 소모량을 실제 에너지 소모량으로 나누어 퍼센트 비율로 표현할 경우, 기존 방식은 50.43%를 기록한 반면 개선 방식은 99.96%를 기록하여 크게 향상됨을 알 수 있다.

### 5. 결 론

본 논문에서는 모션센서를 이용하여 사용자의 보행유형을 측정하고, 데이터 셋을 구성하였다. 이를 사용하여 머신러닝 알고리즘으로 학습하고, 학습 결과인 학습모델을 이용하여 보행유형을 인지하는 실험을 진행하였다.

기존의 3축 가속도를 활용한 방식보다 머신러닝 향상 기법을 도입한 경우 최대 12.5% 이상의 정확도를 달성하였고, 각 보행유형을 인지함에 있어서도 평균 18.6%의 정확도 향상을 달성할 수 있었다.

이를 이용한다면 사용자의 하루동안의 행동을 추적할 수 있고, 측정된 행동의 칼로리를 계산하여 일일 에너지 소비량을 계산해낼 수 있다. 또한 사용자의 생활 패턴을 분석하여 하루 운동이 부족한지 알 수 있다. 특히 요일별로 분석을 한다면 활동 대사량이 적은날에 사용자에게 운동을 권하는 서비스를 제공할 수 있다.

### REFERENCE

[ 1 ] H.J. Park and H.S. Kim, "Case Studies and Development on Wearable Healthcare Design -Mainly with Diverse Types of User Perspectives," *Journal of Digital Design*, Vol. 14, No. 3, pp. 135-144, 2014.

[ 2 ] Runtastic, Android Application, <http://play.google.com/store> (accessed May, 1, 2018).

[ 3 ] Endomondo, Android Application, <http://play.google.com/store> (accessed May, 1, 2018).

[ 4 ] Nike+Fuelband, "Nike+SportWatch" for NIKE, <http://www.nike.com/cdp/fuelband/> (accessed May, 1, 2018).

[ 5 ] K.H. An, E.T. Kim, U.J. Ryu, and Y.S. Chang, "Implementation on SVM Based Step Detection Analyzer," *Journal of Korea Multimedia Society*, Vol. 16, No. 10, pp. 1147-1155, 2013.

[ 6 ] B.M. Lee, "Adaptation of Customized Measurement of Stride Length in Smart Device," *Journal of the Korea Contents Association*, Vol. 13, No. 4, pp. 35-43, 2013.

[ 7 ] W. Lee, H. Lee, and S. Lee, "Calorie Consumption Measurement Platform using GPS and Activity Recognition Based on Accelerometer in Smartphone," *Proceeding of the Spring Conference of the Korean Institute of Information Scientists and Engineers*, pp. 342-344, 2013.

[ 8 ] J.H. Wilmore and D.L. Costill, *Physiology of Sport and Exercise* 3rd Edition, Human Kinetics Publishers, Illinois, 2006.

[ 9 ] C.M. Jung, J.H. Bang, K.H. Han, H.N. Yeom, and S.Y. Lee, "Smartphone Based Activity Recognition for Real Environment," *Proceeding of Korean Institute of Information and Engineers, Proceedings of Korea Computer*, pp. 460-462, 2013.

[ 10 ] 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, 2011.

[ 11 ] L. Bao, and S.I. Stephen, "Activity Recognition from User-Annotated Acceleration Data," *Proceeding of International Conference on Pervasive Computing*, Springer, pp. 1-17, 2004.

[ 12 ] G. Holmes, A. Donkin, and I.H. Witten, "Weka: A Machine Learning Workbench," *Proceedings of the 1994 Second Australian and New*



*Zealand Conference, Intelligent Information Systems*, pp. 357-361, 1994.

- [13] S.L. Salzberg, "C4. 5: Programs for Machine Learning," *Machine Learning*, Vol. 16, No. 3, pp. 235-240, 1994.
- [14] D.R. Cox, "The Regression Analysis of Binary Sequences," *Journal of the Royal Statistical Society*, pp. 215-242, 1958.
- [15] D.E. Rumelhart, E.H. Geoffrey, and J.W. Ronald, *Learning Internal Representations by Error Propagation*, California Univ San Diego La Jolla Inst for Cognitive Science, 1985.
- [16] N. Ravi, N. Dandekar, P. Mysore, and M.L. Littman, "Activity Recognition from Accelerometer Data," *Association for the Advancement of Artificial Intelligence*, Vol. 5, No. 2005, pp. 1541- 1546, 2005.
- [17] S.H. Kim, O.H. Lee, H.S. Lee, and J.Y. Joe, *Nutrition and Exercise*, Powerbook, Goyang, 2007.
- [18] J.A. Harris and G.B. Francis, "A Biometric Study of Human Basal Metabolism," *Proceedings of the National Academy of Sciences*, Vol 4, No. 12, pp. 370-373, 1918.
- [19] J.H. Yoon and I.K. Jung, *Human Performance & Exercise Physiology*, DKBooks, Seoul, 2011.



**안 정 옥**

2013년 ~ 현재 가천대학교 IT대학 컴퓨터공학과  
 관심분야: 스마트헬스, 사물인터넷(IoT), 센서네트워크, 지능형서비스, 엣지컴퓨팅



**강 운 구**

2001년 2월 인하대학교 전자계산공학과(공학박사)  
 2002년~2006년 뉴미디어연구소장  
 2007년~현재 유-헬스케어연구소장  
 1994년~현재 가천대학교 컴퓨터공학과 교수

관심분야: 의료IT융합, 유헬스, 의료정보, 소프트웨어공학



**이 영 호**

2005년 8월 아주대학교 의과대학 의료정보 학과(이학박사)  
 1999년~2002년 IBM Korea BI & CRM EM  
 2002년~현재 가천대학교 IT대학 컴퓨터공학과 교수

2013년~현재 대한의료정보학회 이사  
 2017년~현재 가천대학교 전산정보원장  
 관심분야: 데이터마이닝, 메디컬인포메틱스, 정밀의학



**이 병 문**

1988년 2월 동국대학교 전자계산학과 학사  
 1990년 2월 서강대학교 전자계산학과 석사  
 2008년 2월 인천대학교 컴퓨터공학과 박사

1990년~1997년 LG전자 중앙연구소 네트워크 연구실 선임연구원  
 1998년 3월~현재 가천대학교 IT대학 컴퓨터공학과 교수  
 관심분야: 스마트헬스, 사물인터넷(IoT), 센서네트워크, 지능형서비스, 엣지컴퓨팅 스마트서비스