

Exercise Detection Method by Using Heart Rate and Activity Intensity in Wrist-Worn Device

Sung Ji Hoon[†] · Choi Sun Tak^{**} · Lee Joo Young^{***} · We-Duke Cho^{****}

ABSTRACT

As interest in wellness grows, There is a lot of research about monitoring individual health using wearable devices. Accordingly, a variety of methods have been studied to distinguish exercise from daily activities using wearable devices. Most of these existing studies are machine learning methods. However, there are problems with over-fitting on individual person's learning, data discontinuously recognition by independent segmenting and fake activity. This paper suggests a detection method for exercise activity based on the physiological response principle of heart rate up and down during exercise. This proposed method calculates activity intensity and heart rate from triaxial and photoplethysmography sensor to determine a heart rate recovery, then detects exercise by estimating activity intensity or detecting a heart rate rising state. Experimental results show that our proposed algorithm has 98.64% of averaged accuracy, 98.05% of averaged precision and 98.62% of averaged recall.

Keywords : Wearable Device, Exercise Detection, Physiological Principal, Physiological Signal, Activity Recognition

손목형 웨어러블 디바이스에서 사람의 심박변화와 활동강도를 이용한 운동 검출 방법

성지훈[†] · 최선탉^{**} · 이주영^{***} · 조위덕^{****}

요약

웰니스에 대한 관심이 증대됨에 따라 개인의 건강상태를 웨어러블 디바이스로 모니터링하는 연구들이 늘어나고 있다. 이에 따라 웨어러블 디바이스에서 운동과 일상 활동을 구분하는 다양한 방법들이 연구되어 왔다. 이러한 기존 연구는 대부분 기계학습을 활용한 방식이다. 하지만 개인별 학습 데이터에 의존적인 과적합 문제와 연속적인 사건으로 구성되는 사람의 행동을 독립적으로 취급하여 인식 결과가 중간에 끊기고 오인행동이 생기는 문제가 있다. 이에 본 연구는 운동 시 심박이 오르내리는 생체반응 원리를 기반으로 한 운동 상태 검출 방법을 제안한다. 제안하는 방법은 3축 가속도 센서와 PPG 센서를 통해 활동강도 및 심박 수를 산출하여 심박 회복기를 판단한 후, 활동강도 검사 또는 심박 상승기 검사를 통해 운동 상태를 검출한다. 실험 결과에서 제안하는 알고리즘은 평균 정확도 98.64%, 정밀도 98.05%, 재현율 98.62%로 기존 알고리즘보다 개선된 모습을 보였다.

키워드 : 웨어러블 디바이스, 운동 검출, 생체원리, 생체신호, 행동 인식

1. 서론

의료 및 과학 기술의 발전과 생활수준의 향상으로 건강에 대한 관심이 높아지고, 이러한 변화는 웰니스(wellness)에 대한 관심으로 연결되었다[1]. 웰니스 산업의 발전은 IT 기술과

의 융합을 통하여 극대화되고 있으며, 특히 웨어러블 디바이스를 통해 개인의 건강 상태를 모니터링하기 위한 다양한 프로토타입 및 상용제품들이 생겨났다[2].

웨어러블 디바이스는 손목밴드, 안경, 신발, 벨트 등의 다양한 종류로 개발되었다. 그중에서 대부분 가속도센서를 탑재한 손목밴드 형태로 개발되어 사용자의 걸음 수, 신체활동 시간, 소비열량 등의 신체활동 정보를 측정한다. 특히 2014년 이후 광용적맥파(Photoplethysmography, PPG) 기술의 발전으로 웨어러블 디바이스에서 쉽고 간단한 맥박 측정이 가능해졌다[3]. 이를 통해 운동 중 사용자의 심박 수, 체지방률, 스트레스 수준 등의 생리변인을 측정하여 목표 운동량 대비 적절한 운동을 하고 있는지 실시간으로 피드백해주는 다양한 기기들이 개발되고 있다[4].

* 본 연구는 중소벤처기업부의 2018년도 산학연협력 기술개발사업 (킷걸움협력과제)의 지원에 의한 연구임[S2659493].

[†] 비회원: 아주대학교 전자공학과 공학석사

^{**} 준회원: 아주대학교 전자공학과 석·박사통합과정

^{***} 비회원: 아주대학교 전자공학과 공학사

^{****} 종신회원: 아주대학교 전자공학과 교수

Manuscript Received: August 27, 2018

First Revision: November 19, 2018

Second Revision: December 18, 2018

Accepted: December 21, 2018

* Corresponding Author: We-Duke Cho(wedukecho@gmail.com)

이에 따라 웨어러블 디바이스에서 운동과 일상 활동을 구분하는 다양한 방법들이 제안되어 왔다. 이러한 방법들은 주로 가속도 신호에서 특징을 추출하고 이를 분류기에 적용하여 행동을 인식하는 기계학습을 활용하였다[5-15]. 기계학습 방식은 움직임에 의한 관성 신호나 생리 신호를 나누어 다양한 산술적 통계값을 특징으로 산출하고, 모델을 학습하여 각 행동을 분류한다.

하지만 기계학습은 모델 학습에 사용된 데이터에 의존적인 과적합 문제(Over-fitting Problem)를 야기할 수 있다. 즉, 분류 모델을 확장하거나 개선하기 위해서는 학습 데이터를 추가해서 다시 반복 학습시킬 수밖에 없다. 예를 들어, 피실험자가 A, B, C 일 때, 피실험자 A와 B의 데이터로 모델을 학습할 경우, 학습된 모델로 피실험자 C의 행동을 분류하는 성능이 떨어진다면, 학습된 모델은 A와 B에 과적합 되어 있다고 할 수 있다. 특히, 심박 수를 분류기의 특징으로 사용한다면 심박의 기저가 개인마다 다르고 PPG 센서가 동잡음에 취약하기 때문에 신호 차원에서 통계적 특징으로 활용하는데에 한계가 있다.

또한, 사람의 행동은 연속적인 시간 단위 동작들로 구성되지만 기존의 기계학습 방법은 행동을 독립된 사건으로 처리한다. 행동의 연속성을 고려하지 못하므로 인식 결과가 중간에 끊기거나 오인행동이 생기는 등의 문제가 있다. 모델을 학습시키는 과정에서 생리적 원리를 활용하기보다는 학습 데이터에서 수학적으로 의미 있는 경계를 결정하는 데 중점을 두기 때문에 학습된 모델이 생리적 원리를 반영하지 못한다. 따라서 데이터에 의존적이지 않고, 연속성을 가지는 사람의 행동 특징을 고려하며, 운동 시 변화하는 신체적 상태에 대한 원리를 적용한 방법이 필요하다.

앞서 언급한 문제들을 해결하고자, 본 연구에서는 PPG 센서로 측정된 심박 수와 3축 가속도센서 신호를 통해 사람의 생리적 특징을 고려한 운동 검출 방법을 제안한다.

2. 관련 연구

운동과 일상 활동을 구분하기 위해 가속도 신호에서 평균, 표준편차, 모멘텀(Momentum), 상관성(Correlation) 등의 통계적 특징을 추출하고 이를 분류기에 적용하여 행동을 인식하는 기계학습을 활용하는 연구가 있다[5-16]. 그중 Instance Based Learning (IBL) 기법인 k-Nearest Neighbor (k-NN)를 사용한 행동인식 연구가 있다[5-8]. k-NN은 새로운 데이터가 주어질 때 기존 데이터 분포에서 가장 가까운 k개의 데이터 정보를 통해 분류하는 기법이다. 패턴 인식 기법 중에서 비교적 분류성능이 뛰어나다. 이와 유사하게 Decision Tree 기법들(ID3, C4.5 CART)은 연산 최적화의 효과가 크며 결과의 근거를 추적 가능한 설명력을 갖고 있어 행동인식 연구 분야에서 가장 빈번하게 사용된다[5,7-10]. Artificial Neural

Network 기법 중 하나인 Multi Layer Perceptron(MLP)를 적용한 연구들도 존재한다[9, 11, 12]. 이러한 기법들은 널리 쓰이며 인식률이 높지만, 결정 경계를 구하는 과정에서 마진(margin)을 고려하지 않으므로 데이터에 의존적인 과적합 문제를 일으킬 수 있다. 그리고 사람의 행동과 같은 연속적인 사건을 단위 시간에 따라 독립적으로 취급하기 때문에 분류시에 오류가 클 가능성이 있다. 또한 학습한 모델을 갱신해야 할 경우 수정이 불가능하며 모델을 다시 학습시켜야 하는 문제가 있다.

모든 특징값이 서로 독립임을 가정하여 확률 모델을 기반으로 한 Bayesian 기법은 범주형 데이터를 분류하는 데 효과적이다[5, 7-10]. 행동인식을 위해 두 범주를 가장 큰 마진으로 분리해내는 결정 경계를 찾는 알고리즘인 Support Vector Machine(SVM)을 사용한 연구도 있다[13-15]. 두 기법들은 앞선 기법들보다 과적합 정도가 덜하지만, 마찬가지로 행동을 독립된 사건으로 처리하며 모델을 갱신하기 힘들다. Bayesian 기법은 학습에 사용된 데이터의 확률분포만을, SVM은 범주 간 마진만을 고려하므로 학습데이터에 최적화된 결정경계를 산출하지만 학습에 사용되지 않은 분포의 데이터를 분류하는데에 한계가 있다.

기존 PPG 신호를 분류기의 특징으로 이용한 운동 검출 방식의 연구[18]가 있었으나, 신호 차원에서 통계적 특징만을 활용하기 때문에 과적합 문제가 있다.

본 연구에서는 관련 연구에서 공통으로 드러난 문제들을 해결하고자 사람의 생체반응 원리를 이용한 행동인식 방법을 제안한다. 운동 시에는 체내에 필요한 산소섭취량이 증가하며, 운동이 끝난 후에도 일정기간동안 안정 시 수준 이상의 산소를 소비한다[16]. 체내에서 소모되는 산소는 심장을 통해 각 혈관으로 전달된다. 그러므로 산소섭취량과 심박 수는 직선적 관계를 이룬다[17]. 즉, 심박이 오르내리는 구간을 통해 운동 검출이 가능하다. 이러한 생체반응 원리를 기반으로 웨어러블 디바이스 환경에서 PPG 신호를 사용하여 사용자의 운동 여부를 예측할 수 있다. 따라서 운동 시에 심박이 오르는 생체반응 원리를 기반으로 심박이 변화하는 시점을 감지하여 운동을 검출하고, 움직임이 크게 유지되는 시간 또는 그 시간 전후 심박이 오르내리는 구간을 통해 운동을 검출한다. 제안하는 방법을 통해 개인 데이터에 의존적인 과적합 문제와 인식 결과가 중간에 끊기거나 오인행동이 생기는 문제를 해결할 수 있을 것으로 기대한다.

3. 본 론

3.1 제안 알고리즘 개요

본 연구에서는 PPG 센서로 측정된 심박과 3축 가속도센서로 측정된 움직임의 크기를 통해 사람의 물리적, 생리적 특징을 상호 보완하여 운동을 검출하는 알고리즘을 제안한다. 제안하는 방법은 Fig. 1과 같다. 시스템은 크게 두 종류의 운동

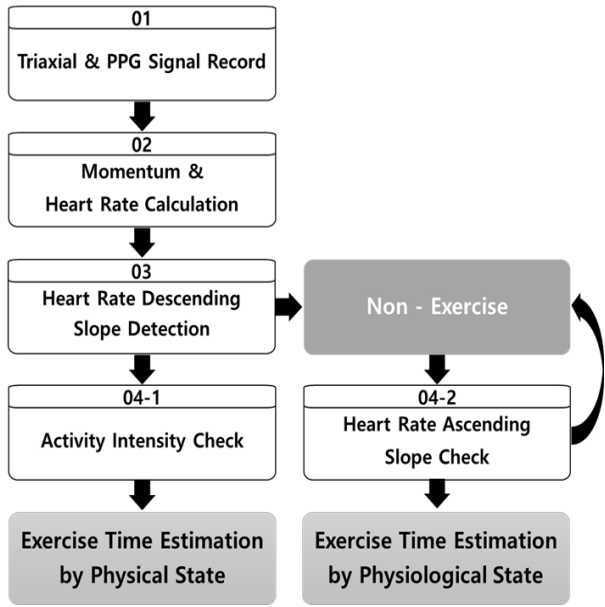


Fig. 1. Overview of Proposed Algorithm

을 구분하는데, 손목 움직임이 적은 운동과 손목 움직임이 큰 운동이다. 운동 검출을 위해 i) 먼저 3축 가속도 센서와 PPG 센서를 통해 활동강도와 심박 수를 계산한다. ii) 그 다음 심박 수가 감소하는 부분, 즉 심박 회복기가 검출되면 그 시점을 운동 직후 시점으로 결정한다. iii) 앞선 신호에서 활동강도가 일정 크기 이상일 경우 손목 움직임이 큰 운동으로 간주하여 가속도 신호 기반 운동 검출을 한다. 또는 일정 크기 이하인 신호가 검출되면 손목 움직임이 작은 운동이므로 심박 상승기를 검사하여 심박이 오르내리는 구간을 통해 운동을 검출한다.

사람의 생체반응 원인인 운동 시 심박 변화를 기반으로 한 알고리즘이기 때문에 모델 학습이 필요가 없고, 따라서 데이터에 의존적이지 않아 과적합 문제가 일어나지 않는다. 또한 연속적인 신체 상태의 변화, 즉 심박 변화를 정량적으로 반영하기 위해 영상신호처리에서 사용되는 모폴로지(Mathematical Morphology) 기법[20]을 활용하여 행동의 연속성을 모델링하였다.

3.2 가속도 및 광용적맥파 신호 측정 방법 및 실험

운동 실험은 그림과 같이 자체 제작한 디바이스를 사용하여 진행하였다. 디바이스는 손목밴드 형태로 STM LSM6DS3 6축 센서와 MAXIM MAX30102 PPG 센서가 탑재되어 있다. 실험자는 20대 남성 4명으로 디바이스를 손목에 착용한 뒤 손목움직임이 작은 운동인 사이클과 하체운동, 손목움직임이 큰 운동인 트레드밀 걷기/뛰기로 나누어 실험을 진행하였다. 운동은 한 종목당 10분 정도 진행하였고 운동이 끝난 후 심박이 기저심박에 가까워질 때 까지 휴식을 취한 뒤 디바이스를 종료하였다. 실험 데이터의 총 시간은 20,920초이다. 운동

시간 측정을 위해 실험 보조자가 운동을 시작과 종료 시점을 수기로 기록하여 알고리즘 성능 평가의 기준(Gold Standard) 설정하였다.




Fig. 2. The Device used in Experiments

3.3 활동강도 및 심박 수 산출

측정된 신호에서 잡음 성분을 제거하고 모멘텀과 심박 수를 정확하게 산출하기 위해 전처리를 통한 신호 보정을 한다. 손목 움직임이 큰 운동검출을 위해 3축 가속도 신호에서 Equation (1)을 이용해서 중력 모멘텀을 산출한다.

$$M = \sqrt{A_x^2 + A_y^2 + A_z^2} \tag{1}$$

M : 중력에 대한 모멘텀 신호
 A_x : x축 가속도 신호
 A_y : y축 가속도 신호
 A_z : z축 가속도 신호

PPG 센서 신호를 통해 심박 수를 얻기 위하여 두 번의 Moving Average Filter와 1차 미분을 통해 필터링 후, 신호의 피크(Peak)를 검출을 통해 HRV(Heart Rate Variability)의 시간 범위 분석을 한다. 특히 웨어러블 디바이스 환경에서의 PPG 신호는 동잡음에 민감하다[19]. 따라서 이상치(Outlier)에 강인하도록 10초 동안의 HRV 평균값(Mean)대신 중앙값(Median)을 사용해 심박 수를 산출한다. 또한 손목의 움직임이 매우 커서 신호 처리 기술로도 심박을 측정하기 힘든 경우의 PPG 신호는 본 논문에서 중력 모멘텀 기반 운동 검출을 하므로 무시해도 된다.

3.4 심박 회복기 검출

심박 회복기는 운동 직후 올라간 심박이 기저심박으로 다시 내려가는 시간이다. 심박 회복기를 통해 운동의 여부를 파악하기 위해서 심박이 감소하는 기울기를 검사한다. 물리적 특성을 고려하여 신호 단위를 샘플(sample)에서 평균값을 통해 초(sec)로 변환한다.

심박 회복기 검출에서 급격한 기울기 변화 또는 변화가 거의 없는 경우에는 신호의 잡음이거나 운동이 아닌 경우로 판단한다. 이러한 경우들을 분별하기 위해 심박 변화량의 추세

를 확인해야 한다. 심박은 운동 직후부터 1~2분 후까지 급격하게 떨어진 후 완만하게 감소하는 경향을 보인다[21]. 또한 심박은 최대심박의 40% 이상의 중강도 이상의 운동에서 회복률이 높다[22]. 따라서 본 논문에서는 중강도 이상의 운동을 한 직후의 심박이 급격하게 떨어지는 부분을 관찰한다. 그리고 20대 남성의 평균 회복속도를 고려하여 임계값의 상한값($Th_{HR,lower}$), 하한값($Th_{HR,upper}$)을 설정해 심박 회복 영역을 설정한다[23]. Equation (2)와 같이 심박 수 감소 상태를 검출하는 함수를 통해 심박 변화량이 특정 영역 내에 속하는 경우를 심박 회복기로 한다.

$$f_{descend}\left(\frac{\partial HR}{\partial t}\right) = \begin{cases} 1; & Th_{HR,lower} < \frac{\partial HR}{\partial t} < Th_{HR,upper} \\ 0; & otherwise \end{cases} \quad (2)$$

$\frac{\partial HR}{\partial t}$: 시간 당 심박 변화율
 $Th_{HR,lower}$: 심박 회복 영역의 하한값
 $Th_{HR,upper}$: 심박 회복 영역의 상한값

다음으로 검출된 특징의 연속성을 고려하여 심박의 변화를 심박 회복기 검출에 정량적으로 반영하기 위해 모폴로지 기법을 사용한다[20]. 모폴로지 기법은 2차원 영상처리 기법에서 사용하는 형태학적 분석 방법으로, 본 논문에서는 불림(Dilation)과 녹임(Erosion) 기법을 1차원으로 변형시킨 방법을 통해 심박 회복 영역을 보정한다. 사용된 방법은 Equation (3)과 (4)로 표현된다.

$$S_{dilation}[i] = \begin{cases} 1; & when \sum_{j=0}^{Th_{dilation}} S_{op}[i-j] \neq 0 \\ 0; & otherwise \end{cases} \quad (3)$$

$S_{op}[i]$: 후처리 과정 입력값
 $Th_{dilation}$: 시간 간격 임계값

$$S_{erosion}[i] = \begin{cases} 0; & when \prod_{j=0}^{Th_{erosion}} S_{op}[i-j] = 0 \\ 1; & otherwise \end{cases} \quad (4)$$

$S_{op}[i]$: 후처리 과정 입력값
 $Th_{erosion}$: 시간 간격 임계값

두 수식을 순차적으로 조합하여 Fig. 3과 같이 Opening 및 Closing 연산으로 심박 회복기를 검출한다. 녹임 후 불림 순서의 연산을 Opening 연산이라고 하며, 불림 후 녹임 순서의 연산을 Closing 연산이라 한다. Closing 연산을 통해 검출된 특징, 즉 심박 감소 변화량이 시간 간격 임계값 내에 다시 검출되면 특징은 연속되어 있다고 판단한다. 검출된 특징이 임계값 내로 유지되지 않는다면, 심박 회복기가 아닌 것으로 판단하여 Fig. 3의 c) Opening 연산처럼 무시하여 최종적으로 심박 회복기($HR_{Descending}$)를 검출한다.




Fig. 3. Heart Rate Descending Slope Detection

3.5 운동 상태 검출

심박 회복기가 검출이 된다면, 앞서 운동을 한 것으로 간주하기 때문에 활동강도 또는 심박 상승기를 살핀다.

1) 활동강도 검사

먼저 손목 움직임이 큰 운동을 하였을 경우, 중력 모멘텀 값을 통해 활동강도를 산출하여 운동 시간을 검출한다. 활동강도를 산출하기 위해 Equation (5)로 중력 모멘텀 신호의 바이어스를 제거하고, 절댓값을 취한 후에 Equation (6)로 표준편차를 구한다.

$$M_{avg}[i] = \frac{1}{N} \sum_{j=0}^N |M[i-j] - 1| \quad (5)$$

$M_{avg}[i]$: 중력 모멘텀 신호 평균값

$$I[i] = \sqrt{\frac{1}{N} \sum_{j=0}^N (|M[i-j] - 1| - M_{avg}[i])^2} \quad (6)$$

$I[i]$: 활동강도

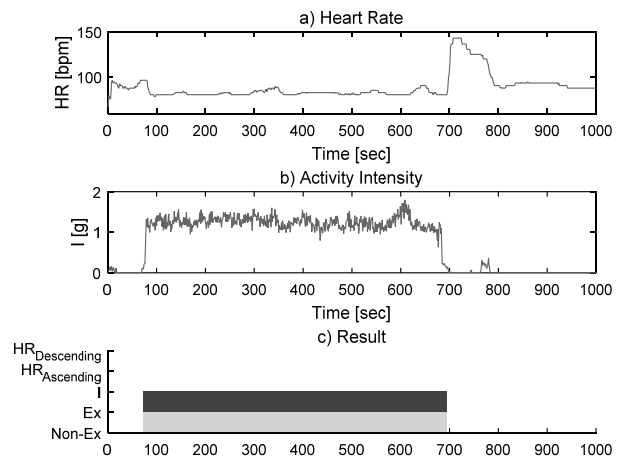


Fig. 4. Exercise Time Inference by Physical State

활동강도 또한 연속성을 고려하기 위해 모폴로지 기법으로 활동강도가 임계값 내에 다시 검출되면 두 특징은 연속되어 있다고 판단하고, 검출되지 않는다면 운동이 아닌 것으로 판단하여 무시한다. Fig. 4와 같이 손목 움직임이 큰 경우의 운동은 사람의 물리적 특징인 활동강도(I)를 통해 검출하고, c) Result와 같이 시작시간과 종료시간을 계산하여 운동(Ex)을 검출한다.

2) 심박 상승기 검사

손목 움직임이 적은 운동을 하였을 경우, 활동강도 검사로 운동 검출이 불가능하기 때문에 심박 상승기를 검사한다. 심박 회복기 검출과 같이 신호 단위를 샘플에서 평균값을 통해 초로 변환한다. 마찬가지로 임계값을 설정해 심박 상승 영역을 설정한다. 심박 상승기 검사에도 모폴로지 기법을 적용한다. Fig. 5의 c) Result와 같이 3.4에서 구한 심박 회복기를 운동 종료시간($HR_{Descending}$)으로, 심박 상승기를 운동 시작시간($HR_{Ascending}$)으로 계산하여 운동(Ex)을 검출한다.

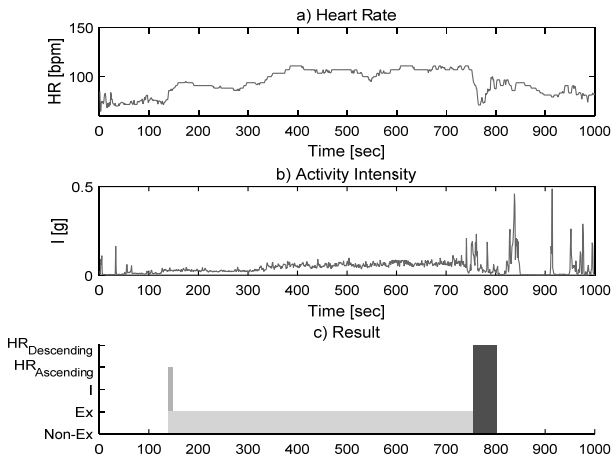


Fig. 5. Exercise Time Inference by Physiological State

4. 실험 결과

제안하는 방법과 기존 통계적 특징을 이용한 기계학습 방법들을 비교하기 위해 몸무게의 76.0 ± 3.0 kg, 안정 시 심박수 75.3 ± 5.5 bpm, 25.5 ± 1.3 세 남성 4명으로부터 3축 가속도 신호와 PPG 신호를 수집하였다. 실험은 손목움직임이 작은 운동인 사이클과 하체운동, 손목움직임이 큰 운동인 트레드밀 걷기/뛰기로 개인마다 네 가지 종목으로 나누어 총 16 번의 실험을 진행하였다. 실험자는 손목 디바이스를 착용한 뒤 한 종목당 10분 정도 운동을 진행하였고 운동이 끝난 후 심박이 기저심박에 가까워질 때 까지 휴식을 취한 뒤 디바이스를 종료하였다. 실험 데이터의 총 시간은 20,920초이다.

비교를 위한 기존 기계학습 방법은 관련 연구에서 언급한

Decision Tree(C4.5), k-Nearest Neighbor(k-NN), Naive Bayes Classification(NB), Support Vector Machine(SVM), Multi-layer Perceptron(MLP)을 사용하였다. k-NN 알고리즘의 k 값은 실험을 통해 경험적으로 가장 우수한 성능을 보이는 3으로 설정하였다.

Table 1. Test Case

Case	Training	Testing
1	S1	S2, S3, S4
2	S2	S1, S3, S4
3	S3	S1, S2, S4
4	S4	S2, S3, S4
5	S1, S2	S3, S4
6	S1, S3	S2, S4
7	S1, S4	S2, S3
8	S2, S3	S1, S4
9	S2, S4	S1, S3
10	S3, S4	S1, S2
11	S1, S2, S3	S4
12	S1, S2, S4	S3
13	S1, S3, S4	S2
14	S2, S3, S4	S1

S1~S4: 피실험자(Subject 1~4) 데이터

본 연구에서는 보다 정확한 비교를 위하여, 앞서 언급한 개인마다 다른 생체적 특성을 가지고 있는 점을 고려한 개인별 교차 검증(Cross Validation) 방식을 사용하였다. 교차 검증은 특정 데이터 셋에만 알고리즘이 잘 맞지 않도록 학습(Training) 및 테스트(Testing)에 사용되는 데이터를 다양화하여 검증하는 방법이다. 본 논문의 경우 Table 1과 같이 20,920초의 모든 실험데이터를 4명의 피실험자 별로 S1부터 S4까지 나누고, 개인별 실험데이터를 부분 집합으로 나누어 학습 및 테스트에 사용하는 총 14가지의 경우(Case)로 만들었다. 그리고 각 케이스의 학습 데이터로 모델을 학습시키고, 테스트 데이터로 모델을 평가하였다. 이로써 과적합 경우를 포함하는 보다 올바른 비교평가를 하였다.

앞서 언급한 기존 연구 5가지의 기계학습 방법으로 Table 1의 14가지의 경우에서 학습용 데이터를 통해 모델을 학습시킨 후 테스트 데이터로 운동인지 아닌지 분류한다. 제안하는 알고리즘은 모델 학습 과정이 없기 때문에 각 Case의 테스트 데이터만 사용하여 평가한다.

알고리즘의 성능을 평가하기 위해 Confusion Matrix를 사용하였다. Table 2~6의 기계학습, Table 7의 제안하는 알고리즘마다 진음성(TN: True Negative), 위양성(FP: False Positive), 위음성(FN: False Negative), 진양성(TP: True Positive)의 수를 나타내었고 정확도(Accuracy, ACC), 정밀도(Precision, Positive Predictive Value, PPV), 재현율(Recall, True Positive Rate, TPR)을 백분율로 나타내었다. TN의 경우 알고리즘이

운동이 아닌 경우로 예측하였고, 실제로도 운동이 아닌 경우이며 FP의 경우 운동으로 예측하였으나, 실제로는 운동이 아닌 경우이다. FN의 경우 알고리즘이 운동이 아니라고 예측하였으나, 실제로는 운동인 경우이며 TP의 경우 운동으로 예측하였고, 실제로도 운동인 경우이다. 즉, 알고리즘을 통한 운동시간은 TP로 계산하게 된다.

정확도는 전체 4가지 경우 중에서 올바르게 운동으로 예측한 비율이 얼마나 되는지를 나타낸다. Equation (7)로 계산한다. 정밀도는 알고리즘이 운동이라고 예측한 경우 중 실제로 운동인 경우의 비율을 뜻하며, 식으로 표현하면 Equation (8)과 같다. 재현율은 실제로 운동인 경우 중 알고리즘이 운동으로 예측한 경우의 비율을 뜻하며, 식으로 표현하면 Equation (9)와 같다.

$$ACC = \frac{TN+TP}{TN+FP+FN+TP} \tag{7}$$

ACC: 정확도

$$PPV = \frac{TP}{FP+TP} \tag{8}$$

PPV: 정밀도

$$TPR = \frac{TP}{FN+TP} \tag{9}$$

TPR: 재현율

Table 2. Confusion Matrix for C4,5

Case	TN	FP	FN	TP	ACC	PPV	TPR
1	588	29	262	286	75.02	90.79	52.19
2	792	64	307	365	75.72	85.08	54.32
3	1037	41	298	293	79.69	87.72	49.58
4	1067	105	422	296	72.12	73.82	41.23
5	213	19	162	215	70.28	91.88	57.03
6	429	25	169	127	74.13	83.55	42.91
7	498	50	116	307	82.90	85.99	72.58
8	649	44	180	240	79.87	84.51	57.14
9	734	53	249	298	77.36	84.90	54.48
10	970	39	239	227	81.15	85.34	48.71
11	64	5	43	82	75.26	94.25	65.60
12	152	11	69	183	80.72	94.33	72.62
13	371	14	103	68	78.96	82.93	39.77
14	594	30	144	151	81.07	83.43	51.19

Table 3. Confusion Matrix for k-NN

Case	TN	FP	FN	TP	ACC	PPV	TPR
1	479	138	467	81	48.07	36.99	14.78
2	606	250	520	152	49.61	37.81	22.62
3	601	477	377	214	48.83	30.97	36.21
4	252	920	236	482	38.84	34.38	67.13
5	182	50	314	63	40.23	55.75	16.71
6	330	124	227	69	53.20	35.75	23.31
7	403	145	298	125	54.38	46.30	29.55
8	414	279	266	154	51.03	35.57	36.67
9	502	285	350	197	52.40	40.87	36.01
10	442	567	218	248	46.78	30.43	53.22
11	40	29	81	44	43.30	60.27	35.20
12	127	36	164	88	51.81	70.97	34.92
13	277	108	122	49	58.63	31.21	28.65
14	332	292	182	113	48.42	27.90	38.31

Table 4. Confusion Matrix for NB

Case	TN	FP	FN	TP	ACC	PPV	TPR
1	610	7	312	236	72.62	97.12	43.07
2	742	114	220	452	78.14	79.86	67.26
3	1068	10	386	205	76.27	95.35	34.69
4	1127	45	347	371	79.26	89.18	51.67
5	223	9	191	186	67.16	95.38	49.34
6	450	4	177	119	75.87	96.75	40.20
7	545	3	236	187	75.39	98.42	44.21
8	668	25	243	177	75.92	87.62	42.14
9	721	66	174	373	82.01	84.97	68.19
10	1003	6	326	140	77.49	95.89	30.04
11	66	3	65	60	64.95	95.24	48.00
12	160	3	125	127	69.16	97.69	50.40
13	384	1	109	62	80.22	98.41	36.26
14	613	11	185	110	78.67	90.91	37.29

Table 5. Confusion Matrix for MLP

Case	TN	FP	FN	TP	ACC	PPV	TPR
1	269	279	36	581	72.96	67.56	94.17
2	147	525	47	809	62.57	60.64	94.51
3	224	367	69	1009	73.88	73.33	93.60
4	628	90	245	927	82.28	91.15	79.10
5	123	254	6	226	57.31	47.08	97.41
6	244	52	13	441	91.33	89.45	97.14
7	384	39	64	484	89.39	92.54	88.32
8	192	228	21	672	77.63	74.67	96.97
9	166	381	31	756	69.12	66.49	96.06
10	135	331	22	987	76.07	74.89	97.82
11	98	27	2	67	85.05	71.28	97.10
12	243	9	5	158	96.63	94.61	96.93
13	130	41	19	366	89.21	89.93	95.06
14	162	133	70	554	77.91	80.64	88.78

Table 6. Confusion Matrix for SVM

Case	TN	FP	FN	TP	ACC	PPV	TPR
1	542	75	42	506	89.96	87.09	92.34
2	749	107	131	541	84.42	83.49	80.51
3	1026	52	202	389	84.78	88.21	65.82
4	1062	110	245	473	81.22	81.13	65.88
5	195	37	3	374	93.43	91.00	99.20
6	427	27	41	255	90.93	90.43	86.15
7	484	64	22	401	91.14	86.24	94.80
8	615	78	129	291	81.40	78.86	69.29
9	690	94	178	369	79.56	79.70	67.46
10	939	70	138	328	85.90	82.41	70.39
11	61	8	2	123	94.85	93.89	98.40
12	140	23	3	249	93.73	91.54	98.81
13	364	21	19	152	92.81	87.86	88.89
14	560	64	129	166	79.00	72.17	56.27

Table 7. Confusion Matrix for Proposed

Case	TN	FP	FN	TP	ACC	PPV	TPR
1	609	11	6	539	98.54	98.00	98.90
2	854	7	11	656	98.82	98.94	98.35
3	1063	15	8	583	98.62	97.49	98.65
4	1158	15	10	707	98.68	97.92	98.61
5	231	2	5	371	98.85	99.46	98.67
6	445	10	3	292	98.27	96.69	98.98
7	539	10	5	417	98.46	97.66	98.82
8	690	6	7	410	98.83	98.56	98.32
9	786	6	9	533	98.88	98.89	98.34
10	997	14	7	457	98.58	97.03	98.49
11	68	1	2	123	98.45	99.19	98.40
12	166	1	3	245	99.04	99.59	98.79
13	375	9	1	171	98.20	95.00	99.42
14	621	5	6	287	98.80	98.29	97.95

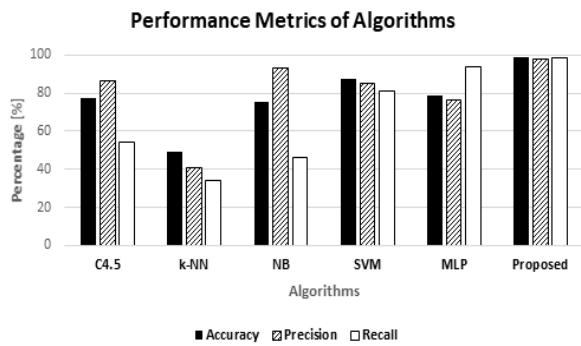


Fig. 6. Performance Metrics

Table 8. Performance Metrics

Performance Metrics	Algorithms					
	C4.5	k-NN	NB	SVM	MLP	Proposed
Accuracy	77.45	48.97	75.22	87.37	78.67	98.64
Precision	86.32	41.08	93.06	85.29	76.73	98.05
Recall	54.24	33.81	45.91	81.01	93.78	98.62

Table 8과 Fig. 6은 Table 2~7에서 알고리즘별로 14개의 케이스로 운동을 검출하였을 때 인식률의 정확도, 정밀도, 재현율을 평균값으로 나타낸다. 기존 알고리즘에서 평균 정확도는 k-NN이 48.87%로 가장 낮고, SVM이 87.37%로 가장 높았다. SVM은 범주형 데이터를 분류하는데 가장 큰 마진으로 결정 경계를 찾기 때문에 비교적 높은 인식률을 보이는 것으로 사료된다. SVM을 제외한 기존 알고리즘은 평균 정확도가 모두 80%에 미치지 못하였다. 제안하는 방법의 평균 정확도는 98.64%로 기존 알고리즘들보다 높은 수치를 보였다. 기존 알고리즘의 평균 정밀도와 재현율에서는 k-NN이 41.08%

의 정밀도, 33.81%의 재현율로 가장 낮았고, NB이 93.06%의 정밀도, MLP가 93.78%의 재현율로 가장 높았다. 제안하는 방법의 정밀도와 재현율은 98.05%와 98.62%로 정확도와 마찬가지로 기존 알고리즘들보다 높았다. 제안한 알고리즘의 TP 비율이 타 기계학습 알고리즘에 비해 높기 때문에 정확도와 정밀도, 재현율이 높았다. 따라서 제안한 방법으로 검출한 운동이 운동 기준(Gold Standard)에 가까운 결과를 나타내었다.

Table 9. Standard Deviation in Performance Metrics

Standard Deviation	Algorithms					
	C4.5	k-NN	NB	SVM	MLP	Proposed
Accuracy	3.63	5.22	4.85	5.47	10.80	0.23
Precision	5.15	12.31	5.49	5.76	13.38	1.20
Recall	9.97	13.27	10.77	14.30	5.00	0.35

Table 9는 Table 2~7에서의 알고리즘별 정확도, 정밀도, 재현율의 표준편차 값을 나타낸다. 제안하는 알고리즘의 정확도 편차가 0.23인 것에 비해 기존 알고리즘들은 평균 약 6%의 편차가 나타난다. 가장 높은 정확도를 가지는 SVM도 표준편차가 5.47이고 재현율도 14.3의 편차를 보였다. 이는 앞서 언급한 학습데이터에 의존적인 과적합 문제로, 심박의 기저가 개인마다 다르고 PPG 센서가 동잡음에 취약하기 때문에 심박 신호를 분류기의 특징으로 사용하기 어렵기 때문이다. 제안하는 알고리즘은 운동 시에 심박이 변화하는 생체반응 원리를 기반으로 운동을 검출하였기에 표준편차가 각각 0.23, 1.20, 0.35로 기존 알고리즘에 비해 데이터에 의존적이지 않은 수치를 보인다.

Fig. 7은 Case 1에 대한 SVM 알고리즘(b)과 제안하는 알고리즘의 운동시간 검출 결과(c)를 수기로 기록한 기준(a)과

비교하여 나타낸 그래프이다. SVM과 같은 기계학습으로 운동을 검출할 경우, 행동의 연속성을 고려하지 못하므로 b) 그래프와 같이 인식 결과가 중간에 끊기거나 오인행동이 생기게 된다. 반면 제안하는 알고리즘은 c) 그래프와 같이 운동의 시작시간과 종료시간을 계산하여 운동을 검출하기 때문에 정밀도나 재현율이 다른 알고리즘보다 더 높게 측정된다.

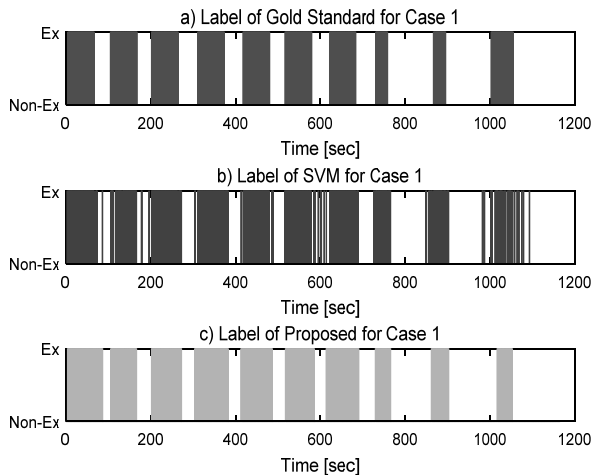


Fig. 7. Label Graph for Case 1

5. 결 론

본 논문에서 제안하는 운동 검출 방법은 사람의 생리적 특징을 고려하여 운동 시에 심박이 오르내리는 시점을 검출하고, 심박이나 움직임이 크게 유지되는 구간을 계산한 방법이다. 이러한 방법은 기존 기계학습으로 사람의 행동을 인식하는 방법이 모델 학습에 사용된 데이터에 의존적 문제와 사람 행동의 연속성을 고려하지 못하는 문제를 해소한다. 그러나 실험 시에 커피나 술 등의 약물에 의한 심박변화 요소를 통제하였다. 따라서 차후 연구에서는 약물이나 다른 심박변화 요소를 고려하여 심박을 기반으로 한 운동 검출 방법을 개선시킬 예정이다.

References

[1] Miller, James William. "Wellness: The history and development of a concept," *Spektrum Freizeit*, Vol.27, No.1, pp.84-106, 2005.

[2] Pantelopoulos, Alexandros, and Nikolaos G. Bourbakis, "A survey on wearable sensor-based systems for health monitoring and prognosis," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* Vol.40, No.1, pp.1-12, 2010.

[3] T. Tamura, Y. Maeda, M. Sekine, and M. Yoshida, "Wearable photoplethysmographic sensors—past and present," *Electronics*,

Vol.3, No.2, pp.282-302, 2014.

[4] Seung-Hun Park and Dae-Geun Jang, "IT Convergence Trends in Wellness," *Communications of the Korean Institute of Information Scientists and Engineers*, Vol.31, No.3, pp.61-72, Mar. 2013.

[5] Bao, Ling, and Stephen Intille, "Activity recognition from user-annotated acceleration data," *Pervasive Computing*, (2004): 1-17.

[6] J. Parkka, M. Ermes, P. Korpipaa, J. Mantyjarvi, J. Peltola, and I. Korhonen, "Activity classification using realistic data from wearable sensors," *IEEE Transactions on Information Technology in Biomedicine*, Vol.10, No.1, pp.119-128, 2006.

[7] U. Maurer, A. Smailagic, D. P. Siewiorek, and M. Deisher, "Activity recognition and monitoring using multiple sensors on different body positions," *Wearable and Implantable Body Sensor Networks, 2006. BSN 2006. International Workshop on*. IEEE, 2006.

[8] L. C. Jatoba, U. Grossmann, C. Kunze, J. Ottenbacher, and W. Stork, "Context-aware mobile health monitoring: Evaluation of different pattern recognition methods for classification of physical activity," *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*. IEEE, 2008.

[9] O. D. Lara, A. J. Perez, M. A. Labrador, and J. D. Posada, "Centinela: A human activity recognition system based on acceleration and vital sign data," *Pervasive and mobile computing* Vol.8, No.5, pp.717-729, 2012.

[10] E. M. Tapia, S. S. Intille, W. Haskell, K. Larson, J. Wright, A. King, and R. Friedman, "Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor," *Wearable Computers, 2007 11th IEEE International Symposium on*. IEEE, 2007.

[11] Altun, Kerem, and Billur Barshan, "Human activity recognition using inertial/magnetic sensor units," *International Workshop on Human Behavior Understanding*. Springer, Berlin, Heidelberg, 2010.

[12] A. M. Khan, Y. K. Lee, S. Y. Lee, and T. S. Kim, "A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer," *IEEE Transactions on Information Technology in Biomedicine*, Vol.14, No.5, pp.1166-1172, 2010.

[13] He, Zhen-Yu, and Lian-Wen Jin, "Activity recognition from acceleration data using AR model representation and SVM," *Machine Learning and Cybernetics, 2008 International Conference on*. Vol.4. IEEE, 2008.

[14] Z. He, Z. Liu, L. Jin, L. X. Zhen, and J. C. Huang, "Weightlessness feature: a novel feature for single tri-axial accelerometer based activity recognition," *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*. IEEE, 2008.

[15] He, Zhenyu, and Lianwen Jin, "Activity recognition from

acceleration data based on discrete cosine transform and SVM," *Systems, Man and Cybernetics, 2009. SMC 2009. IEEE International Conference on.* IEEE, 2009.

- [16] Fox, Edward L., Richard W. Bowers, and Merle L. Foss. The physiological basis for exercise and sport. No. Ed. 5. Brown & Benchmark, 1993.
- [17] Montoye, H. J., "Circulatory-respiratory fitness," *An Introduction to Measurement in Physical Education, Vol.4,* pp.41-87, 1970.
- [18] S. Mehrang, J. Pietila, J. Tolonen, E. Helander, H. Jimison, M. Pavel, and I. Korhonen, "Human Activity Recognition Using A Single Optical Heart Rate Monitoring Wristband Equipped with Triaxial Accelerometer," *EMBECE & NBC 2017.* Springer, Singapore, 2017, 587-590.
- [19] A. Kamišalić, I. Fister, M. Turkanović, and S. Karakatič, "Sensors and Functionalities of Non-Invasive Wrist-Wearable Devices: A Review," *Sensors, Vol.18, No.6,* pp.1714, 2018.
- [20] Serra, Jean, "Biomedical image analysis by mathematical morphology (author's transl)," *Pathologie-biologie, Vol.27,* No.4, pp.205-207, 1979.
- [21] Saltin, Bengt, and Loring B. Rowell, "Functional adaptations to physical activity and inactivity," *Federation proceedings, Vol.39. No.5,* pp.1506-1513, 1980.
- [22] Davies, C. T. M., A. V. Knibbs, and J. Musgrove, "The rate of lactic acid removal in relation to different baselines of recovery exercise," *Internationale Zeitschrift für Angewandte Physiologie Einschließlich Arbeitsphysiologie, Vol.28, No.3,* pp.155-161, 1970.
- [23] C. R. Cole, E. H. Blackstone, F. J. Pashkow, C. E. Snader, and M. S. Lauer, "Heart-rate recovery immediately after exercise as a predictor of mortality," *New England journal of medicine, Vol.341, No.18,* pp.1351-1357, 1999.



성 지 훈

<https://orcid.org/0000-0001-8712-541X>
 e-mail : shc1028@gmail.com
 2017년 아주대학교 전자공학과(공학사)
 2019년 아주대학교 전자공학과(공학석사)
 관심분야 : Machine Learning, Artificial Intelligence, Signal Processing, Deep Learning



최 선 탁

<https://orcid.org/0000-0003-2648-1757>
 e-mail : suntaag62@gmail.com
 2011년 아주대학교 전자공학과(공학사)
 2011년~현 재 아주대학교 전자공학과 석·박사통합과정
 관심분야 : Smart IoT Device, Mobile Context Aware Computing, Human Activity Sensing/Recognition



이 주 영

<https://orcid.org/0000-0001-6411-5788>
 e-mail : vvvic313@gmail.com
 2018년 아주대학교 전자공학과(공학사)
 관심분야 : Pattern Recognition, Deep Learning, Artificial Intelligence



조 위 덕

<https://orcid.org/0000-0002-2895-0791>
 e-mail : wedukecho@gmail.com
 1977년~1981년 서강대학교(공학사)
 1981년~1983년 한국과학기술원(공학석사)
 1983년~1987년 한국과학기술원(공학박사)
 1983년~1990년 금성전기(주), 기술연구소
 신호처리연구실장

1990년~1991년 KAITECH 수석연구원
 1990년~2003년 전자부품연구원 수석연구원, 시스템연구본부장
 1995년~1995년 UK TTP/Cambridge 연구원
 1995년~1996년 USA TCSI/Berkeley 연구원
 2003년~2013년 (재)유비쿼터스컴퓨팅사업단 사업단장
 2010년~2014년 Sonybrook Univ. Electrical Engineering
 겸임교수
 2004년~현 재 아주대학교 전자공학과 교수,
 라이프케어사이언스랩, 랩디렉터
 관심분야 : Smart IoT Device, Well-ness System/Index, Lifelog bio data, Healing Care Device/Service