

스마트폰과 웨어러블 가속도 센서를 혼합 처리한 실시간 행위 및 자세인지 기법 (Real-time Activity and Posture Recognition with Combined Acceleration Sensor Data from Smartphone and Wearable Device)

이 호 성 [†] 이 승 룡 ^{**}
(Hosung Lee) (Sungyoung Lee)

요 약 최근 고성능 센서가 집적된 스마트폰과 웨어러블 디바이스 기술이 부각됨에 따라 이와 같은 플랫폼을 활용한 차세대 모바일 컴퓨팅 기술이 크게 주목받고 있다. 기존 행위인지는 지속적인 움직임에 따른 고유 패턴을 포착하는 반면, 자세인지는 급격한 순간 변화나 신체 방향의 변화를 포착하는 방법으로 접근되어 왔다. 그러나 이 두 가지의 패턴을 함께 고려하고 실제 활용 가능한 수준의 성능 확보와 그 시스템에 대한 연구는 다소 부족한 실정이다. 이에 본 논문에서는 최근 부각되는 스마트폰과 웨어러블 디바이스의 센서 데이터를 함께 고려하고 각각이 갖는 장점을 혼합한 사용자 행위 및 자세인지 기법과 스마트폰 플랫폼을 기반으로 실제 환경에서의 그 활용 방법을 제안한다. 스마트폰과 웨어러블 센서 데이터를 함께 운용하기 위한 전처리 방법을 설계하고 고유 진동 패턴과 수직, 수평 방향 패턴 특징을 혼합적으로 활용하여 인지 모델을 구축하였다. 이 과정에서 자전거 타기와 빠르게, 천천히 걷기, 뛰기와 같이 보다 다양한 행위와 서기, 앉기, 누워있기와 같은 자세 패턴을 고려하였다. 실험 결과 제안하는 기법의 성능과 타당성을 입증하였고 실제 환경에서의 적용을 통해 그 활용 가능성을 보였다.

키워드: 행위인지, 자세인지, 스마트폰, 웨어러블 센서

Abstract The next generation mobile computing technology is recently attracting attention that smartphone and wearable device imbedded with various sensors are being deployed in the world. Existing activity and posture recognition research can be divided into two different ways considering feature of one's movement. While activity recognition focuses on catching distinct pattern according to continuous movement, posture recognition focuses on sudden change of posture and body orientation. There is a lack of research constructing a system mixing two separate patterns which could be applied in real world. In this paper, we propose a method to use both smartphone and wearable device to recognize activity and posture in the same time. To use smartphone and wearable sensor data together, we designed a pre-processing method and constructed recognition model mixing signal vector magnitude and orientation pattern features of vertical and horizontal. We considered cycling, fast/slow walking and running activities, and postures such as standing, sitting, and laying down. We confirmed the performance and validity by experiment, and proved the feasibility in real world.

Keywords: activity recognition, posture recognition, smartphone, wearable sensor

· This research was supported by the MSIP(Ministry of Science, ICT&Future Planning). Korea, under IT/SW Creative research program supervised by the NIPA(National IT Industry Promotion Agency) (NIPA-2013-(H0502-13-1083)

[†] 학생회원 : 경희대학교 컴퓨터공학과
hslee@oslab.khu.ac.kr

^{**} 종신회원 : 경희대학교 컴퓨터공학과 교수
sylee@oslab.khu.ac.kr
(Corresponding author임)

논문접수 : 2013년 12월 17일
(Received 17 December 2013)

논문수정 : 2014년 5월 22일
(Revised 22 May 2014)
심사완료 : 2014년 5월 23일
(Accepted 23 May 2014)

Copyright©2014 한국정보과학회 : 개인 목적이거나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.
정보과학회논문지 : 소프트웨어 및 응용 제41권 제8호(2014.8)

1. 서 론

사용자의 신체활동으로 인한 움직임을 포착하는 행위 인지와 자세인지 연구는 기계학습(Machine Learning)과 데이터마이닝(Data mining), 영상처리(Image Processing), 인공지능(Artificial Intelligence)과 같은 컴퓨터 공학의 핵심 분야에서 오랜 시간에 걸쳐 연구가 이루어져 왔다. 특히 최근 고성능의 센서들이 집적된 스마트폰과 웨어러블 디바이스와 같은 모바일 컴퓨팅 기술의 획기적인 발전으로 인하여 이러한 모바일 플랫폼을 대상으로 하는 행위 및 자세인지 연구가 활발히 진행되고 있다. 또한 이와 같은 플랫폼에서의 인지 기술들은 차세대 유비쿼터스 컴퓨팅 및 U-헬스케어 분야의 핵심 요소 기술로 각광받는 추세이다.

행위나 자세를 인지하기 위한 일반적인 방법은 사용자가 휴대한 모바일 기기의 가속도, 자이로스코프 혹은 GPS와 같은 센서들의 데이터를 수집, 분석하여 신체 움직임에 따라 변화하는 고유의 특징과 패턴들을 포착하는 것이다. 과거 선행 연구자들은 이러한 방법론에 따라 신체의 곳곳에 고정식 센서를 부착하여 보다 높은 성능으로 많은 신체 움직임을 포착 가능한 최적의 인지 방법을 찾아내거나[1,2], 최근에는 스마트폰과 같은 비고정식 센서를 이용하여 신체 움직임에 따른 진동 패턴을 포착하는 연구들을 시도하였다[3-5]. 이러한 선행 연구들을 분석해 본 결과, 신체 고정식과 비고정식 센서들은 서로 두드러진 장단점과 특징을 가지고 있으며 또한 이를 각각에 적합한 상황에 적용할 때 최적의 인지 성능을 보이는 것으로 분석된다. 지속적인 움직임 패턴을 가진 행위인지와 이에 반해 급격한 움직임 변화를 포착하는 자세인지 연구는 서로 다른 동작 특성에 따라 각각에 적합한 기법을 차용하여 개별적으로 연구되거나, 행위와 자세인지를 통합한 모델에서는 다소 낮은 성능을 보이는 한계를 드러내고 있다[2,6]. 따라서 본 논문에서는 스마트폰과 웨어러블 센서 데이터를 기반으로 사용자의 행위와 자세를 동시에 고려하며 또한 실시간으로 이를 인지 가능한 기법을 제안한다. 제안하는 기법은 최근 폭발적으로 성장하는 스마트폰과 웨어러블 디바이스를 기반으로 하는 차세대 U-헬스케어 서비스 핵심 요소 기술로의 활용을 기대할 수 있으며 뿐만 아니라 기존의 행위 및 자세인지 기법 보다 한층 개선된 통합 인지 방법론을 제시할 수 있을 것으로 예상된다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 과거 선행된 행위인지와 자세인지 연구들에 대하여 서술하고 이를 분석하여 각각의 강점과 한계점을 도출한다. 또한 최근 실용화된 행위 및 자세인지 기술들과 서비스에 대해 소개하고 이를 분석한다. 3장에서는 제안하는 스마트

폰과 웨어러블 센서 데이터를 혼합한 행위 및 자세인지 기법에 대하여 상세히 기술하며, 4장에서 제안하는 인지 기법의 성능을 평가하고 실제 환경에서의 적용 방법을 보이며 마지막으로 5장에서 본 논문의 결론을 맺는다.

2. 관련 연구

행위 및 자세인지 연구는 1980년 대 부터 HCI, 의학 분야 등을 중심으로 개인화 서비스 제공을 위한 핵심 기술로 주목받아 왔으며 현재까지 컴퓨터 과학 분야에서 지속적으로 연구가 진행되고 있다. 또한 최근에는 차세대 유비쿼터스, U-헬스케어, 사용자 라이프로그 서비스와 같은 분야의 기반 기술로 자리 잡고 있으며 특히 스마트폰과 같이 다양한 센서가 집적된 저 전력의 첨단 모바일 디바이스를 중심으로 인간의 물리적 활동을 인지하는 연구가 주를 이루고 있다. 이러한 센서 데이터 기반의 행위 및 자세인지 연구는 정형화된 방법론이 정의되어 있으며 사용자의 물리적 활동 패턴을 인지하기 위하여 크게 데이터 수집 및 특징 추출, 모델링 및 학습, 인지 단계로 구분되어 진다[7].

2.1 스마트폰 기반의 행위 및 자세인지

최근 스마트폰의 보급이 대중화됨에 따라 누구나 항상 소지하고 있으며 다양한 센서를 내장하고 있는 스마트폰 플랫폼을 기반으로 사용자의 행위 및 자세와 같은 일상 패턴에 대한 라이프로그를 수집하고자 하는 여러 연구들이 선행되었다. Yang은 스마트폰의 3축 가속도 센서를 이용하여 사용자의 걷기, 뛰기, 자전거 타기, 운전하기와 같은 행위와 앉기, 서있기와 같은 자세를 동시에 인지하는 연구를 수행하였다[5]. Yang의 연구에서는 사용자의 주머니 속 스마트폰 휴대방법에 따라 뒤섞이는 센서 방향의 문제를 해결하고자 Mizell[8]이 제안한 가속도 센서 데이터로부터의 방향 성분 검출 방법을 적용하고 이를 기반으로 인지 모델을 구축하였다. 실험 결과 평균 90.6% 정확도를 도출하였으나 높은 분류 성능을 보인 걷기, 뛰기와는 달리 앉기, 서기, 운전하기, 자전거 타기의 경우 평균 정확도에 비하여 상대적으로 낮은 분류 성능을 보였다. 이는 걷기와 같이 지속적인 활동 패턴과 달리 그 외 상대적으로 정적인 동작 패턴에 대하여 동일한 방법을 적용했을 때 이를 포괄적으로 인지하기에 부적합한 것으로 분석된다. Raquel은 스마트폰의 3축 가속도를 이용하여 사용자의 걷기, 계단 오르기, 계단 내려가기, 앉기, 서기, 눕기와 같은 행위 및 자세인지 연구를 수행하였다[9]. 본 연구에서는 급격한 신체 자세 변화를 포착하기 위하여 Signal Vector Magnitude기반의 Threshold-based 접근 방법과 3축 가속도 센서 기반의 방향 정보를 획득하였다. 또한 걷기, 계단 오르내리기와 같은 지속적 행위를 포착하기 위

하여 신체 활동에 따라 변화하는 중력 데이터와 고속 푸리에 변환(Fast Fourier Transform, FFT)을 사용하였고 실험 결과 평균 86%로 높은 수준의 인지 정확도를 얻었으나 행위와 자세 각 그룹 내에서 분류 오차가 높은 문제를 보였다. 특히 앉기와 서기의 경우 가장 높은 분류 오차 빈도를 나타내었다.

2.2 웨어러블 센서 기반의 행위 및 자세인지

스마트폰 기술의 발전과 대중화에 이어 최근 차세대 모바일 컴퓨팅 기술로 웨어러블 디바이스가 주목받고 있다. 웨어러블 컴퓨팅 기술은 이미 스마트폰 보다 훨씬 앞선 1966년부터 유비쿼터스 컴퓨팅 기술의 출발점으로 각인되어져 있다. 이미 세계 유수의 글로벌 기업들뿐만 아니라 스포츠용품 기업들까지 U-헬스케어, 웰니스, 피트니스, 메디컬, 엔터테인먼트 등의 다양한 영역에서 혁신적인 제품과 서비스를 출시하고 있다.

Bao와 Intille의 연구[1]는 걷기, 뛰기, 자전거 타기, 앉기, 서기, 눕기 외, 계단 오르내리기 등 20개의 사용자의 일상적인 활동 패턴을 인지하기 위하여 손목, 허벅지, 발목 등 신체 곳곳에 센서를 부착하여 각각의 성능을 도출하였고 평균 84%의 정확도를 보였다. 본 연구에서는 센서의 신체 부착 위치에 따른 활동 패턴 성능을 도출하였으며 다수의 활동 패턴을 인지하는데 있어 평균적으로 좋은 성능을 보였다. 하지만 2축 가속도 센서를 사용한 점과 특정 행위에서 다소 낮은 정확도를 보이며 데이터를 수집한 피험자에 의존한 인지 성능을 보이는 한계를 드러내었다. Quwaider와 Biswas는 신체 곳곳에 부착한 웨어러블 디바이스의 센서 네트워크를 이용하여 걷기, 뛰기, 앉기, 서기 네 가지의 동작을 인지하는 연구를 수행하였다[6]. 이는 걷기, 뛰기와 달리 앉기, 서기 그룹의 경우 가속도 센서 데이터만으로 두드러지게 분류 가능한 특징을 찾아낼 수 없었기 때문으로

분석된다. 이런 이유로 앉기, 서기 분류를 위하여 센서 네트워크를 통해 각 웨어러블 디바이스의 RSSI(Radio Signal Strength Indication)를 이용한 센서 간 근접 정도를 특징으로 활용하였다. HMM 분류기를 적용하여 최대 88%의 정확도를 얻어냈으나 모든 데이터 처리가 오프라인에서 이루어진 점과 다수의 장치를 신체 곳곳에 부착해야하는 점은 실제 환경에서의 적용에 어려움이 있음을 나타낸다.

3. 스마트폰과 웨어러블 가속도 센서 혼합 처리 및 인지 방법

본 연구에서 제안하는 스마트폰과 웨어러블 디바이스 센서 데이터를 혼합한 행위, 자세인지 기법의 전체 구조는 그림 1과 같다. 정의된 사용자의 행위, 자세와 같은 움직임의 변화에 따라 스마트폰과 웨어러블 디바이스로부터 획득되는 스트림 데이터에 대하여 샘플링 구간(Sampling Interval, Windowing)을 정하고 데이터의 동기를 취한다(Synchronization). 이 과정에서 혼란 데이터의 집합을 얻어 낸 후 혼합 데이터 처리 알고리즘을 통해 특징 추출과 선택, 훈련과 검증을 통하여 인지 모델을 결정한다. 획득한 인지 모델을 분류기에 적용 후 실시간 획득 데이터에 대하여 사용자의 행위와 자세에 대한 분류 결과를 도출한다.

웨어러블 디바이스는 블루투스 통신을 이용하여 스마트폰 플랫폼으로 센서 데이터 스트림을 송신한다. 두 기기로부터의 실시간으로 혼합된 데이터 처리와 특징 추출을 위해서는 먼저 적절한 방법의 스마트폰과 웨어러블 센서 데이터 동기화 과정이 요구된다. 그림 2와 같이 각 기기의 가속도 센서의 샘플링 주기(Sampling rate)를 50Hz로 일치시키고 3초, 150개의 샘플링 구간을 취하여 매 구간별로 데이터를 획득한다.




그림 1 스마트폰과 웨어러블을 혼합한 행위 및 자세인지 구조

Fig. 1 Activity and Posture recognition structure with combined smartphone and wearable




그림 2 스마트폰과 웨어러블 디바이스 센서 데이터 스트림의 윈도우잉 방법

Fig. 2 Windowing technique for Smartphone and Wearable sensor data stream




그림 3 스마트폰과 웨어러블 센서 데이터의 혼합 처리 개념도

Fig. 3 Conceptual diagram of combined sensor data processing from Smartphone and Wearable

비고정식 스마트폰과 고정식 웨어러블 디바이스의 가속도 센서 데이터 혼합 처리 개념은 그림 3과 같다. 비고정식, 고정식 방식에서의 각 장점을 혼합하여 행위와 자세인지를 위한 최적의 특징들을 추출하는 것이다. 본 연구에서는 행위인지를 위하여 비고정식 스마트폰의 고유 진동 패턴과 고정식 웨어러블 센서로부터 수직, 수평 신호에 대한 진동 패턴을 혼합하여 활용한다[8]. 또한 자세인지를 위하여 스마트폰과 웨어러블 센서의 수직, 수평 신호 패턴의 상관관계와 축 간 상관관계 특징을 활용한다. 다음 3.1절에서는 행위인지를 위한 보편적인 방법과 그 과정에서 발생하는 한계점에 대하여 기술하며 3.2절에서는 한계점 극복을 위한 혼합 데이터 처리 방법을 제시한다. 이어 3.3절에서는 자세인지를 위한 기

존 방법의 한계점과 이를 극복하기 위한 혼합된 데이터 기반의 자세인지 방법을 제안한다.

3.1 보편적인 행위인지 방법에서의 혼합 문제

기존의 보편적인 행위인지 방법은 3축 가속도 센서에 대하여 다음의 식 (1)을 적용한 후 변환된 신호에 대한 특징을 추출하는 것이다. Signal Vector Magnitude는 중력에 대한 3축 가속도 신호의 방향 성분을 상쇄하고 신호 벡터의 크기를 얻어내는 방법이다. 이는 스마트폰과 같이 휴대방법에 따라 뒤섞이는 센서의 축 방향 손실과 무관하게 패턴 정보를 획득 가능한 방법 중 하나이다. N 은 샘플링 구간을 의미한다.

$$SVM_i = \sqrt{x_i^2 + y_i^2 + z_i^2}, (i = 1, 2, \dots, N) \quad (1)$$

일반적인 정지, 걷기, 뛰기 행위에 대하여 중력 가속




그림 4 일반적인 정지, 걷기, 뛰기의 Signal Vector Magnitude 신호

Fig. 4 Signal Vector Magnitude Signal of general stay, walking, running




그림 6 걷기, 뛰기, 자전거 타기에 따른 스마트폰 가속도 센서의 패턴 혼잡 문제

Fig. 6 Signal pattern confusion problem of smartphone acceleration sensor data according to each activity




그림 5 걷기, 뛰기 강도에 따른 스마트폰 가속도 센서의 패턴 혼잡 문제

Fig. 5 Signal pattern confusion problem of smartphone acceleration sensor data according to activity intensity

도를 필터링한 스마트폰의 3축 가속도 센서 신호에 수식 (1)을 적용한 Signal Vector Magnitude 신호를 그림 4에서 나타내었다. 결과와 같이 Signal Vector Magnitude를 이용하여 행위별 고유 진동 패턴과 크기를 이용할 경우 일반적인 정지, 걷기, 뛰기 행위에 대하여 높은 분류 성능을 보였다[2,9,11]. 그러나 걷기, 뛰기의 경우에서 사용자 개개인의 동작 특성과 행위의 강도를 달리 할 경우 분류 결과가 혼동되는 문제가 있다. 그림 5는 각각 빠르게 걷기, 천천히 걷기, 빠르게 뛰기, 천천히 뛰기에 대한 Signal Vector Magnitude 신호 패턴

을 나타낸 것이다. 빠르게 뛰기의 경우에는 다소 두드러진 특징을 보인 반면 다른 세 가지의 행위 결과는 서로 유사한 신호의 영역과 패턴을 보이는 문제를 나타내었다.

정지, 걷기, 뛰기와 함께 더 다양한 행위를 인지하기 위하여 자전거 타기를 추가적으로 고려하였다. 그러나 자전거 주행에 따른 진동 패턴을 획득한 결과 그림 6과 같이 걷기, 뛰기 행위의 패턴들과 상호간에 혼잡한 결과를 보였다. 결과적으로 단순히 진동 패턴을 고려한 보편적 행위인지 방법은 각 행위를 상호간에 혼동된 인지 결과를 초래하며 또한, 보다 다양한 행위 패턴을 고려하기에 부적합한 한계를 보인다.

3.2 혼합 센서 데이터 기반의 행위인지 방법

본 절에서는 앞서 기술한 보편적인 행위인지에서 발생하는 한계점을 극복하기 위하여 기존 스마트폰에 손목형 웨어러블 디바이스의 가속도 센서 데이터를 함께 고려한 혼합된 인지 방법을 제안한다. 그림 7은 본 연구에서 활용되는 웨어러블 디바이스인 Shimmer 가속도 센서¹⁾이며 그림의 좌측에서와 같이 사용자의 손목에 위치시킨다.

기존 여러 선행 연구들은 최적의 성능을 보이는 신체 부착 위치와 센서의 개수를 도출하고 적용했지만 본 연구에서는 최근 등장하는 손목 밴드형, 시계형 웨어러블 기기의 트렌드에 중점을 두고, 현실적으로 활용 가능성이 가장 높은 손목을 최적의 위치로 결정하였다. 웨어러블 센서를 함께 고려할 경우 센서의 축 방향에 대한 패턴을 획득할 수 있으며 이를 스마트폰의 진동 패턴과 함께 활용함으로써 앞서 기술한 동작의 강도에 따른 인지 혼동 문제를 해결할 수 있다. 축 방향 패턴은 3축 가

1) Shimmer - Wearable Device (<http://www.shimmersensing.com>)




그림 7 손목형 웨어러블 디바이스 - Shimmer
Fig. 7 Wrist type wearable device - Shimmer

속도 센서로부터 수직, 수평 방향 성분을 추출하는 방법을 사용한다[8]. 연속적인 가속도 센서 데이터의 3차원 벡터 a_i 를 다음의 (2)와 같이 표현한다. 또한 각 샘플링 구간별 평균 벡터 v 를 다음과 같이 얻어낸다.

$$a_i = (x_i, y_i, z_i), (i=1,2,\dots,N)$$

$$v = (m_x, m_y, m_z)$$

$$d_i = a_i - v,$$

$$d_i = (x_i - m_x, y_i - m_y, z_i - m_z),$$

$$p_i = \left(\frac{d_i \cdot v}{v \cdot v} \right) v,$$

$$h_i = d_i - p_i$$

식 (3)과 같이 동일한 샘플링 구간 내의 각 가속도 벡터 a_i 에서 구간 평균 벡터 v 을 뺀 d_i 를 도출한 후, 벡터의 내적(vector dot product)을 이용하여 수직(Vertical) 성분인 p_i 를 얻어낸다. 또한 d_i 와의 벡터 뺄셈(vector subtraction)을 통해 수평(Horizontal) 성분 h_i 를 얻어낸다.

결과적으로 걷기, 뛰기 동작 강도에 따른 신호의 혼잡 문제 해결을 위하여 동일한 샘플링 구간에서 비고정식 스마트폰의 진동 패턴과 고정식 웨어러블 센서의 방향 성분 패턴을 함께 고려한다. 스마트폰과 웨어러블 센서를 함께 고려했을 때 다음의 그림 8과 같은 신호 패턴 결과를 보였다. 이것은 행위를 수행할 때 사용자의 팔 움직임에 대한 수직, 수평 방향 패턴을 함께 이용한 것이다. 결과적으로 이를 스마트폰의 진동 패턴과 함께 활용함으로써 행위의 강도에 따른 신호 혼잡 문제 해결이 가능하며 보다 효과적으로 행위 간에 구분이 가능한 특징을 획득할 수 있다.

또한, 스마트폰의 진동 패턴을 이용한 자전거 타기 행위를 인지할 때 발생하는 신호 혼잡 문제 해결을 위하여 걷기, 뛰기 강도 구분과 동일한 방법론을 적용한다. 그림 9와 같이 기본 of 스마트폰의 진동 패턴만을 활용한 결과에 비하여 웨어러블 센서를 통해 보다 두드러진 패턴을 발견할 수 있다. 이는 자전거 주행 시 사용자의 동작 특성을 이용한 것으로, 핸들을 잡고 있는 자세에 기인하여 손목에 위치한 센서로부터 수직, 수평 방향 성분을 내포한 패턴을 얻어내는 것이다. 그러나 이 과정에서 스마트폰으로부터의 고유 진동 패턴을 배제하고 웨어러블 센서 패턴만을 활용할 경우 또 다른 일상 행위 패턴과 혼동되는 문제를 야기할 수 있다. 그러므로 제안하는 기법은 어느 한 가지의 특정 패턴에 의존하지 않고 고정식과 비고정식으로 부터의 패턴 정보를 혼합하여 보다 신뢰 가능한 행위 결과를 도출하는 것이다.




그림 8 혼합 데이터를 이용한 행위 강도에 따른 신호 혼잡 문제 해결 방법

Fig. 8 The method for solving the problem of signal pattern confusion according to activity intensity




그림 9 혼합 데이터를 이용한 걷기, 뛰기, 자전거 신호의 혼잡 문제 해결 방법

Fig. 9 The method for solving the problem of signal pattern confusion according to each activity

3.3 혼합 센서 데이터 기반의 자세인지 방법

본 절에서는 기존의 자세인지를 위한 방법에서의 한계점과 이를 해결하기 위한 혼합 데이터 기반의 인지 방법을 제안한다. 사용자의 자세를 인지하기 위한 연구에서는 몇 개의 센서를 이용할 것이며 신체 어느 부위에 부착할 것인지가 가장 큰 이슈이다. 이는 세 가지 이상의 자세 변화를 검출하기 위해서는 최소 두 개의 방향 정보를 획득 가능한 센서를 이용해야만 하기 때문이다. 예컨대, 서기와 앉기를 구분하기 위해서는 하체에 센서를 위치해야 하며, 앉기와 눕기(혹은 엎드리기) 구분을 위해서는 상체에 센서를 위치해야만 한다[2,10]. 그러나 이와 같은 방법은 복수의 센서 활용에 따른 비효율성과 불편함으로 인하여 실생활에 적용이 어렵다는 문제가 있다. 이에 본 연구에서는 손목형 웨어러블 디바이스와 스마트폰의 센서 데이터 상관관계를 이용하여 서기, 앉기, 눕기 세 가지의 자세를 인지 가능한 방법을 제안한다. 본 방법은 순간적 동작의 변화를 검출하는 것이 아닌 각 자세를 유지할 때의 특정 방향 패턴의 영역과 그 상관관계를 이용하는 것이다. 웨어러블과 비교정식 스마트폰으로 하여금 손실되는 가속도 센서 방향 정보를 수직, 수평 방향으로 한정하여 각 자세에 대한 특정 패턴을 취득하는 것이다.

그림 10은 동일한 실험자를 대상으로 서기, 앉기, 눕기에 대한 스마트폰과 웨어러블 센서의 수직, 수평 방향 패턴 영역을 혼합하여 나타낸 것이다. 그림의 좌측은 각 자세에 대한 스마트폰, 웨어러블 센서의 수직 방향에 대한 패턴을 나타내며 우측은 수평 방향에 대한 패턴 영역을 나타낸다.

혼합된 수직, 수평 방향 패턴에 대한 측 간 상관관계

(Correlation between each axis)는 다음의 식 (4)를 통해 도출할 수 있다. V , H 는 각각 수직, 수평 속성이며 α , β 는 각각 스마트폰과 웨어러블 디바이스를 의미한다.

$$\begin{aligned} Corr(V_{\alpha}, V_{\beta}) &= \frac{Cov(V_{\alpha}, V_{\beta})}{\delta_{V_{\alpha}} \delta_{V_{\beta}}} \\ Corr(H_{\alpha}, H_{\beta}) &= \frac{Cov(H_{\alpha}, H_{\beta})}{\delta_{H_{\alpha}} \delta_{H_{\beta}}} \end{aligned} \quad (4)$$




그림 10 혼합 데이터를 이용한 서기, 앉기, 눕기 자세 구분
Fig. 10 The method for classifying posture using combined data

식 (4)의 상관관계 도출을 위한 하위 수식은 다음의 식 (5-7)과 같다.

공분산(covariance),

$$\begin{aligned} Cov(V_{\alpha_i}, V_{\beta_i}) &= \frac{1}{N} \sum_{i=1}^N (m_{V_{\alpha}} - V_{\alpha_i})(m_{V_{\beta}} - V_{\beta_i}) \\ Cov(H_{\alpha_i}, H_{\beta_i}) &= \frac{1}{N} \sum_{i=1}^N (m_{H_{\alpha}} - H_{\alpha_i})(m_{H_{\beta}} - H_{\beta_i}) \end{aligned} \quad (5)$$

표준편차(Standard deviation),

$$\begin{aligned} \delta_V &= \sqrt{\frac{1}{N} \sum_{i=1}^N (V_i - m_V)^2} \\ \delta_H &= \sqrt{\frac{1}{N} \sum_{i=1}^N (H_i - m_H)^2} \end{aligned} \quad (6)$$

평균값(mean),

$$m_V = \frac{1}{N} \sum_{i=1}^N V_i, \quad m_H = \frac{1}{N} \sum_{i=1}^N H_i \quad (7)$$

본 논문에서는 행위 및 자세뿐만 아니라 사용자의 교통수단 탑승 여부를 검출하기 위한 연구를 시도하였다. 여기서 대상 교통수단은 버스와 자가용이며 지하철은 고려하지 않았다. 사용자의 탑승 데이터 분석 과정에서 차량의 진동 패턴과 서기, 앉기에 대한 일상적인 신체 움직임 패턴이 서로 혼동됨을 발견하였고, 이를 해결하기 위해 각 샘플링 구간별 FFT를 적용하여 주파수 도메인에서의 패턴을 얻어내었다. 다음의 그림 11은 교통수단과 각 서기, 앉기 자세에 대한 스마트폰의 진동 패턴과 FFT를 적용한 결과이다. 이로 인하여 차량 운행 시 발생하는 고유의 주파수 패턴을 검출하였으며 5~20Hz 사이의 두드러진 빈발 패턴을 특징으로 이용하였다.

4. 성능 평가

본 장에서는 제안하는 스마트폰과 웨어러블 센서 데이터를 혼합 처리한 행위 및 자세인지 기법의 성능 평가를 위해 데이터 수집 방법과 실험 환경을 기술하고 동일한 샘플 데이터를 이용하여 기존의 보편적인 행위 인지 기법을 차용한 대표적인 선행 연구와 제안하는 기법을 적용한 분류 모델에 각각 적용 후, 결과에 대한 비교 및 그 성능을 분석한다. 또한 실제 환경에서의 적용을 통해 제안하는 실시간 행위 및 자세인지 기법의 타당성을 입증한다.

4.1 실험 환경

본 절에서는 성능 평가를 위해 실제 사용된 단말과 데이터 수집 방법 등의 실험 환경을 소개한다. 삼성전자의 갤럭시 S3 스마트폰과 Shimmer 웨어러블 디바이스의 3축 가속도 센서를 각각 사용했으며 상호 간 데이터 송수신을 위하여 블루투스 통신을 활용하였다. 각 기기에 대한 상세 사양은 표 1과 같다.

표 1 실험에 사용된 스마트폰과 웨어러블 디바이스 스펙
Table 1 Technical Specifications of smartphone and wearable device used in the experiment

	Smartphone	Wearable Device
Model	Samsung Galaxy S3	Shimmer Wireless Sensor
OS	Android 4.1.2 (Jelly bean)	TinyOS
CPU (MCU)	Samsung Exynos 4412 Quad Core A9	MSP430 Microcontroller
Memory	1GB DDR2	10KB
Using sensor	LSM330DLC (3D Accelerometer)	MMA7361 (3D Accelerometer)




그림 11 교통수단과 자세별 스마트폰 가속도 센서의 신호 혼잡 문제(좌) 및 FFT를 이용한 해결 방법(우)

Fig. 11 Signal pattern confusion problem of smartphone acceleration sensor data according to each posture and vehicle(Left) and The method for solving the problems



그림 12 본 연구의 샘플 데이터 수집을 위한 애플리케이션
Fig. 12 Application for sample data collection

본 연구에서의 데이터 수집과 실제 성능평가에서 웨어러블 디바이스는 좌측 손목에 착용하고 스마트폰은 좌우 바지 주머니(자전거 타기의 경우 상의 재킷의 주머니)에 위치시킨다. 이때, 웨어러블 디바이스는 3장의 그림 7과 같이 최초 결정한 방향과 일치하도록 장착해야하며 스마트폰은 그 방향에 관계없이 주머니 속에 자유롭게 위치시켰다. 각 센서의 샘플링 주기는 50Hz이며 매 3초 간 150개의 샘플링 구간을 취하여 구간별 샘플 데이터를 수집하였다. 실험은 20대 중후반의 남녀 9명(남자 8, 여자 1)으로 구성된 모집단을 대상으로 수행되었으며 피험자별로 약 5~10분 동안 각 행위와 자세를 지속하는 방법으로 데이터를 수집하였다. 걷기, 뛰기, 자전거 타기 데이터 수집은 경희대학교 국제캠퍼스 내에서 이루어졌으며 언덕이나 내리막길을 제외한 평탄한 장소에서 임의적으로 이루어졌다. 샘플 데이터 수집을 위하여 그림 12의 안드로이드 스마트폰 애플리케이션을 구현하였고 이를 활용하였다.

그림 12에서 우측의 화면과 같이 최초 스마트폰과 웨어러블 디바이스를 블루투스 연결 한 후 데이터 로깅을 시작한다. 본 연구에 대상이 되는 행위는 빠르게 걷기(5~6km/h), 천천히 걷기(4~5km/h), 빠르게 뛰기(12~14km/h), 천천히 뛰기(8~10km/h), 자전거 타기(10~12km/h)이며 자세는 서기, 앉기, 눕기 그리고 교통수단 탑승으로 총 9개의 행위와 자세를 인지한다. 모집단에 의해 수집된 각 행위 및 자세별 샘플 데이터 결과는 표 2와 같다.

4.2 성능 평가 방법

성능 평가를 위하여 기존의 대표적 연구에서의 방법론과 본 연구에서 제안하는 기법에 대하여 각각 동일한 샘플 데이터를 적용한 후 그 인지 성능을 도출하고 분

표 2 실험을 위한 행위, 자세별 수집 데이터 수

Table 2 The sample data for experiment

Activity and Posture	Samples (1 sample = 150 raws)
Walking (Fast)	1,190
Walking (Slow)	1,360
Running (Fast)	1,005
Running (Slow)	905
Cycling	1,080
Standing	990
Sitting	1,110
Lie down	1,410
Vehicle	945

표 3 혼합 가속도 센서 데이터 기반의 특징

Table 3 The features from combined acceleration data

Component	Features
Vertical	5-Linear Prediction Coefficients(LPC) 1-LPC Error 3-Standard Deviation
Horizontal	1-Zero Crossing Rate 1-Correlation between two Signal 1-Correlation FFT
Original Acceleration	1-Signal Vector Magnitude 1-Correlation between XY, Z 1-Correlation FFT

석한다. 그러나 행위와 자세를 동시에 인지하는 기존의 선행 연구들은 복수의 웨어러블 디바이스를 대상으로 이루어졌기 때문에[2,6,10] 본 실험에서 사용하는 샘플 데이터를 이용한 동일한 조건에서의 직접적인 비교가 어렵다. 이런 이유로 본 실험에서는 기존의 스마트폰 가속도 센서로부터 Signal Vector Magnitude를 이용한 걷기, 뛰기, 정지, 교통수단을 인지하는 선행 연구[11]와 본 연구에서 제안하는 혼합 데이터를 기반으로 걷기와 뛰기의 강도, 정지 및 추가적으로 자전거 행위를 인지 모델을 비교 분석한다. 또한 여기에 추가적으로 서기, 앉기, 누워있기 자세와 교통수단 인지를 추가한 행위 및 자세인지 결과를 도출하고 그 성능을 비교 분석한다.

실험을 위하여 대표적인 데이터마이닝 도구인 WEKA를 이용하였고 다수의 분류 알고리즘에 대하여 10-fold Cross Validation을 수행하였다. 실험에 사용된 혼합 가속도 센서 데이터 기반 특징은 표 3과 같다.

4.3 성능 평가 결과

실험 결과 다음 표 4와 같은 결과를 얻었다. 제안하는 기법과 선행 연구 모두 Support Vector Machine 분류 알고리즘인 SMO에서 가장 높은 정확도를 도출했다. 제안하는 기법이 평균 92.49%의 정확도를 보인 반면, 기존 연구 기법은 평균 88.86%를 보였다. 선행 연구에 대

표 4 제안하는 기법에 대한 분류 알고리즘별 성능(%)

Table 4 Accuracy comparison of each classifier

Classifier	Past	Proposed
SMO	91.88	94.89
NBTree	86.35	93.94
J48	90.28	91.22
BayesNet	88.57	92.48
NaiveBayes	87.24	89.90
Average	88.86	92.49




그림 13 제안하는 기법에 대한 분류 알고리즘별 결과

Fig. 13 Accuracy comparison of each classifier

한 평균 정확도가 다소 높게 도출되었지만 실제로 행위별 고르지 못한 분류 성능을 보였다. 각 분류 알고리즘별 성능 비교를 그림 13에서 나타내었다.

결과와 같이 걷기와 뛰기, 교통수단과 정지 구분에서 각각 잦은 분류 오차를 보였다. 이는 진동 패턴을 활용했을 경우에 발생하는 분류 혼잡 문제를 드러낸 것으로 분석되며 본 논문에서 앞서 기술한 정지 상태의 일상 움직임 패턴들과 교통수단에서의 신호 혼잡 문제로 분

표 6 선행 연구 알고리즘 적용 결과

Table 6 Confusion matrix of past researcher's algorithm

Activity	Walking	Running	Stay	Vehicle
Walking	0.947598	0.052402	0	0
Running	0.110787	0.880466	0	0.008746
Stay	0.04	0	0.706667	0.253333
Vehicle	0.129412	0.094118	0.035294	0.741176

석된다. 다음의 표 5, 6은 본 연구에서 궁극적으로 제안하는 혼합 데이터 기반의 행위 및 자세인지 결과를 나타낸 것이다. 제안하는 기법을 통해 평균 92.45%의 정확도를 보였고 앉기와 누워있기 자세인지에서 상대적으로 높은 분류 오차를 보였다.

4.4 실제 환경에서의 적용 방법 및 결과

본 절에서는 제안하는 기법을 기반으로 구현한 행위 및 자세인지 엔진을 안드로이드 스마트폰 애플리케이션으로 구현하고 이를 직접 피험자가 소지 후, 실제 일상 환경에서 활용해 본 후 그 결과를 시각적으로 표현하였다. 본 실험을 진행한 피험자는 본 실험의 데이터 수집에 참여한 모집단 중 한 명이며 20대 후반의 남성이며 다음의 표 7 시나리오에 따라 각각의 동작과 활동을 진행하였다.

최초, 실내(자택)에서 자세 변화를 진행 후 실외로 나가 도보로 약 10분 거리에 위치한 운동장으로 향한다. 이 운동장에는 250m 둘레의 트랙이 있으며, 이후의 모든 행동들은 본 트랙에서 이루어진다. 또한 각각의 동작을 지속할 때, 별도로 소지한 속도계를 이용하여 시나리오 상에 정해진 페이스를 유지토록 한다. 제안하는 기법을 실제 환경에서 적용 및 테스트 한 결과 그림 14와 같은 결과를 얻어내었다. 특정 상황에서 분류 오차가 나타났지만 전반적으로 우수한 성능을 보였음을 확인할 수 있다.

표 5 제안하는 혼합 데이터 기반의 행위 및 자세인지 실험 결과

Table 5 Confusion matrix of proposed algorithm

Activity/Posture	Walking (Fast)	Walking (Slow)	Running (Fast)	Running (Slow)	Cycling	Standing	Sitting	Lie down	Vehicle
Walking(Fast)	0.970588	0.029412	0	0	0	0	0	0	0
Walking(Slow)	0	1	0	0	0	0	0	0	0
Running(Fast)	0	0.074627	0.910448	0.014925	0	0	0	0	0
Running(Slow)	0	0	0	1	0	0	0	0	0
Cycling	0.069444	0	0.009259	0	0.912037	0.009259	0	0	0
Standing	0	0	0	0	0	1	0	0	0
Sitting	0	0	0	0	0	0	0.6	0.4	0
Lie down	0	0	0	0	0	0.003546	0	0.996454	0
Vehicle	0	0	0	0	0	0.047619	0.021164	0	0.931217

표 7 실제 환경에서의 테스트를 위한 시나리오

Table 7 Scenario for real-time experiment

No.	Guideline for activity and posture	Duration (min)
1	Lie down on the ground	2
2	Sit still on the chair	2
3	Standing up from the chair and keep it	2
4	Go out and walking (4~5km/h)	5
5	Go straight ahead (5~6km/h)	3
6	Cycling on the track (16~18km/h)	3
7	Running on the track (8~10km/h)	3
8	Running fast on the track (12~14km/h)	1
9	Walking on the track (4~5km/h)	5
10	Stand still	3
11	Walking on the track (4~5km/h)	4
12	Walking fast on the track (5~6km/h)	3
13	Take a bus and sitting in seat	about 40

5. 결 론

본 논문에서는 스마트폰과 웨어러블 디바이스에 장착된 가속도 센서 데이터를 혼합 활용하여 사용자의 행위와 자세를 인지하기 위한 기법과 실제 환경에서 이를 실시간으로 활용 가능한 방법을 제안하였다.

기존의 보편적인 행위인지, 자세인지 방법론과 달리 서로 다른 특성을 갖는 고정식과 비고정식 센서 데이터를 함께 이용하여 각각이 갖는 장점을 혼합함으로써 새로운 인지 방법을 제시하였다. 기존 중력에 대한 진동

패턴을 이용하는 행위인지 방법과 신체 방향 정보를 이용하는 자세인지 방법이 갖는 한계점을 분석하고 이를 함께 해결하고자 하였다. 각각의 센서로부터의 수직, 수평 신호 패턴을 혼합적으로 활용하여 특징 패턴을 발견하였고 이 과정에서 보다 다양한 행위 및 자세 패턴을 고려하였다. 실험 결과 제안하는 기법의 성능과 타당성을 입증하였고 실제 환경에서 실시간 테스트를 통해 그 활용 가능성을 보였다. 향후에는 현재 다소 낮은 성능을 보이는 자세인지와 교통수단 탑승 인지에 대해 보완이 요구되며, 또한 사용자의 행위나 자세뿐만 아니라 위치 정보를 함께 활용하여 사용자의 구체적인 상황까지도 인지 가능한 연구가 요구된다.

References

- [1] Ling Bao, and Stephen S. Intille, "Activity recognition from user-annotated acceleration data," *Pervasive Computing*. Springer Berlin Heidelberg, 1-17, 2004.
- [2] Gjoreski, Hristijan, and Matjaž Gams, "Activity/Posture recognition using wearable sensors placed on different body locations," *Proceeding of signal and image processing and applications*, 2011.
- [3] Muhammad Fahim, et al., "EFM: Evolutionary Fuzzy Model for Dynamic Activities Recognition using a Smartphone Accelerometer."
- [4] Manhyung Han, Young-Koo Lee, and Sungyoung Lee, "Comprehensive Context Recognizer Based on Multimodal Sensors in a Smartphone," *Sensors* 12.9




그림 14 실제 환경에서의 테스트 결과

Fig. 14 Result of real-time experiment

- (2012): 12588-12605.
- [5] Jun Yang, "Toward physical activity diary: motion recognition using simple acceleration features with mobile phones," *Proceedings of the 1st international workshop on Interactive multimedia for consumer electronics*, ACM, 2009.
 - [6] Muhannad Quwaider, Subir Biswas, "Body posture identification using hidden Markov model with a wearable sensor network," *Proceedings of the ICST 3rd international conference on Body area networks*, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2008.
 - [7] Ozlem Durmaz Incel, Mustafa Kose, and Cem Ersoy, "A Review and Taxonomy of Activity Recognition on Mobile Phones," *BioNanoScience*, pp.1-27, 2013.
 - [8] David Mizell, "Using gravity to estimate accelerometer orientation," *Proceedings of the Seventh IEEE International Symposium on Wearable Computers (ISWC'03)*, vol.1530, no.0811/03, 2003.
 - [9] Joana Raquel Cerqueira da Silva, "Smartphone Based Human Activity Prediction," MS. Thesis, University of Porto, 2013.
 - [10] Xiuxin Yang, "A Wearable Real-Time System for Physical Activity Recognition and Fall Detection," MS. Thesis, University of Saskatchewan Saskatoon, 2010.
 - [11] C. M. Chung, et al., "Smartphone based activity recognition for real environment," *The Korean Institute of Information Scientists and Engineers*, Proceedings of Korea Computer, pp.460-462, 2013.



이 호 성

2012년 을지대학교 의료전산학전공 학사
 2014년 경희대학교 컴퓨터공학과 석사
 관심분야는 모바일 기반 행위인지, 자세
 인지, 상황인지, 임베디드SW

이 승 룡

정보과학회논문지 : 소프트웨어 및 응용
 제 41 권 제 3 호 참조