

스마트 기기를 이용한 다단계 퓨전 행위인지 프레임워크

(Multi-Level Fusion Activity Recognition Framework using Smart Devices)

허 태 호 [†] 이 승 룡 ^{††}
(Taeho Hur) (Sungyoung Lee)

요 약 관성센서 기반 행위인지 연구는 여러 센서를 신체에 부착하는 방식에서 스마트 기기의 출현 이후 최소한의 센서만을 이용하는 방향으로 변화되었다. 본 논문에서는 최소한의 센서를 활용한 행위인지를 위하여 일반적으로 쉽게 구할 수 있는 스마트폰과 스마트워치를 사용하여 일상생활 행위를 중심으로 한 다단계 퓨전 행위인지 프레임워크를 제안한다. 제안하는 프레임워크에서는 데이터 퓨전(Data Fusion), 특징 퓨전(Feature Fusion), 결정 퓨전(Decision Fusion)을 모두 사용하며, 결정 퓨전에서는 일반적으로 사용되는 다수결 투표(Majority Voting) 방식 혹은 가중 투표 방식(Weighted Voting)이 아닌 사후확률(Posterior Probability)에 기반한 퓨전 방식을 사용하여 정확도와 신뢰도를 높였다. 실험은 확률 방식의 사용 여부 및 각각의 퓨전을 사용/미사용 했을 때의 성능을 비교하여 제안하는 방식의 우수성을 입증하였다.

키워드: 행위인지, 스마트폰, 스마트워치, 퓨전, 사후확률

Abstract Traditional inertial sensor based activity recognition methods in which multiple sensor units are attached to the body is changing to accommodate the use of smart devices such as smartphones and smartwatches. In this paper, we propose a multi-level fusion activity recognition framework to recognize daily activities using smartphones and smartwatches which can be purchased easily for minimum sensor based activity recognition. The proposed framework uses various types of fusion techniques such as data fusion, feature fusion, and decision fusion. While the proposed framework does not use common methods of decision fusion such as majority voting or weighted voting, it does use posterior probability based fusion for better accuracy and confidence. Experiments are conducted to compare results between using and not using the probability and between using and not using each fusion technique. The results demonstrated the excellent performance of the proposed framework.

Keywords: Activity Recognition, smartphone, smartwatch, fusion, posterior probability

· 본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 대학ICT연구센터 육성지원사업(IITP-2017-0-01629) 및 디지털콘텐츠원천기술개발사업(No.2017-0-00655)의 연구결과로 수행되었음

[†] 학생회원 : 경희대학교 컴퓨터공학
hth@oslab.khu.ac.kr

^{††} 종신회원 : 경희대학교 컴퓨터공학 교수(Kyung Hee Univ.)
sylee@oslab.khu.ac.kr
(Corresponding author임)

논문접수 : 2018년 5월 4일

(Received 4 May 2018)

논문수정 : 2018년 7월 26일

(Revised 26 July 2018)

심사완료 : 2018년 8월 6일

(Accepted 6 August 2018)

Copyright©2018 한국정보과학회 : 개인 목적이나 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 제45권 제9호(2018. 9)

1. 서론

행위인지는 상황인지의 초석이 되는 기술로써 웨어러블 컴퓨팅, 퍼베이시브 컴퓨팅, 인간-컴퓨터 상호작용, 그리고 헬스케어 및 웰니스케어 등에서 널리 사용되고 있는 기술이다. 행위인지는 관성 센서, 환경 센서, 영상 센서 등 다양한 센서를 이용하여 앉기, 걷기 등 사용자가 수행 중인 행위를 파악한다. 이 중 관성 센서는 가속도 센서, 각속도 센서 및 지자기 센서 등을 이용한다. 과거의 관성 센서 기반 행위인지 연구는 다수의 센서를 사용자 신체 전반에 부착하여 얻은 데이터를 토대로 행위를 인지하였다. 이는 신체 각 부위의 움직임을 전반적으로 파악할 수 있기 때문에 높은 정확도를 얻을 수 있으나 다수 센서 구입 비용과 사용자 행동의 불편함을 가져온다. 또한 센서 자체는 연산 능력이 없기 때문에 실시간 인지가 불가능하거나 노트북, PDA 등을 같이 들고 다니면서 실시간 인지를 수행하였다. 그러나 스마트폰의 등장 이후 관성 센서 기반 행위인지 연구의 양상이 변화하였다. 스마트폰은 다양한 센서가 집적되어 있으며 자체 연산 능력을 가지고 있어 실시간 행위인지가 가능하다. 특히 현대 생활에서는 누구나 가지고 다니는 1인 1스마트폰 시대이기 때문에 센서 구입 비용의 부담이 없다. 더 나아가서 비슷한 기능을 가진 스마트워치가 출시된 이후 각각 단일 스마트폰, 단일 스마트워치 혹은 스마트폰과 스마트워치를 함께 사용하는 관성 센서 기반 행위인지 연구가 대세를 이루고 있다.

한편 패턴 인식 분야에서 사용되는 퓨전은 데이터 퓨전, 특징 퓨전, 그리고 결정 퓨전으로 나뉜다[1]. 데이터 퓨전은 각 모달리티(Modality)의 데이터를 하나로 합치는 방식으로 보다 종합적이고 효과적인 정보를 얻을 수 있게 한다. 특징 퓨전은 중복 혹은 불필요한 특징을 제거하며, 사실상 데이터 퓨전의 진보된 단계라고 볼 수 있다. 결정 퓨전은 각 모달리티가 도출해 낸 결론을 바탕으로 최종 결론을 결정하는 과정이며 일반적으로 다수결 투표 방식 혹은 가중 투표 방식을 사용한다. 현재까지 나온 스마트폰과 스마트워치를 사용한 연구들은 데이터 혹은 특징 퓨전을 기반으로 행위인지를 수행하며, 결정 퓨전을 사용하지 않는다. 이는 모달리티가 2개인 시점에서 1:1의 결과가 나올 경우 처리가 힘든 다수결 투표는 의미가 없으며, 가중치를 주는 방식이어도 2개 미만 나눌 수 있는 가중치 할당에 많은 사항이 고려되어야 하기 때문인 것으로 보인다.

본 논문에서는 기존 연구와 달리 스마트폰과 스마트워치를 이용하여 데이터 퓨전, 특징 퓨전, 결정 퓨전을 모두 사용하는 다단계 퓨전 행위인지 프레임워크를 제안한다. 본 프레임워크는 총 2번의 분류를 진행한다. 첫

번째 분류는 사후확률값을 얻기 위한 분류 과정으로 데이터 퓨전과 특징 퓨전이 사용된다. 첫 번째 분류에서 사용되는 특징 집합은 총 4개로써 이는 각각 스마트폰 특징 집합, 스마트워치 특징 집합, 스마트폰과 스마트워치 데이터 퓨전의 특징 집합, 그리고 스마트폰 특징과 스마트워치 특징의 특징 퓨전 집합이다. 이렇게 특징 집합 개수가 늘어난 이유는 두 기기로부터 동시에 데이터가 수집되었기 때문에 이들간의 상관관계를 알아보기 위함이다. 이후 첫 번째 분류에서는 SVM(Support Vector Machine)을 이용하며, 이 때 오류 수정 출력 코드(Error correcting Output Coding, ECOC)를 사용한다[2]. ECOC는 다수의 클래스를 각각의 이진 클래스로 나누어 학습한 후 이를 통합하는 방식으로 이진 분류 방식만을 이용하여 사용될 수 있으며, 본 논문에서는 현재 가장 높은 정확도와 대중성을 보여 많이 사용되는 SVM을 기반으로 분류를 수행하였다. ECOC 연구에 따르면 이를 이용할 경우 지도학습(Supervised Learning)에서 편견과 편차를 감소시켜 정확도를 향상시킬 수 있다고 본다[3]. ECOC를 이용하면 사후확률값을 계산할 수 있으며, 각각의 특징 집합 분류를 통해 얻은 사후확률값 집합을 결합하는 데이터 퓨전이 수행된다. 사후확률 기반 결정 퓨전은 기존의 가중 투표 방식처럼 가중치를 할당하기 위해 연구자가 직접 공식을 제안하거나 입력할 필요 없이 자동으로 프로세스가 진행되는 장점을 가진다. 이러한 사후확률을 기반으로 두 번째 분류가 진행되어 최종 행위 결론을 도출하게 된다. 본 논문에서 인지하는 행위로는 서기, 걷기, 뛰기의 기본 행위와 앉기, 눕기의 자세, 그리고 일상생활에서 높은 빈도로 수행하는 ADL(Activities of Daily Living) 중 스트레칭, 청소, 식사를 선정하여 총 8가지 행위를 인지하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 스마트폰과 스마트워치를 사용한 기존 연구 및 퓨전 연구에 대해 소개한다. 3장에서는 제안하는 스마트폰과 스마트워치를 이용한 행위인지 기법을 소개한다. 4장에서는 성능 평가를 통해 제안하는 방법의 타당성을 확인하며 마지막 5장에서는 결론을 내린다.

2. 관련연구

소개할 스마트폰과 스마트워치를 동시에 사용한 연구들은 스마트폰을 바지 앞주머니에, 스마트워치는 주(主)손에 착용하였으며, 본 논문에서도 이러한 방식을 따른다. Shoaib et al.은 가속도와 각속도 센서를 사용하고 평균과 표준편차만을 특징으로 하여 다양한 조합으로 도합 13가지의 기본 행위 및 ADL을 인지하는 비교실험을 진행하였으며, 두 기기를 모두 사용할 경우 가장 높은 정확도를 보장받을 수 있다는 결론을 얻었다[4].

Ramos et al. 역시 특징은 평균과 표준편차만을 이용하였으며 분류기별에 따라 다르지만 대체적으로 두 기기를 모두 사용한 쪽에서 더 높은 정확도를 보였다[5]. Vilarinho et al.은 사용자의 낙상 및 ADL을 인지하였다[6]. 인지는 단계별로 이루어지며, 먼저 스마트폰에서 임계점을 기반으로 한 탐지, 패턴 파악으로 인한 탐지 후 스마트워치를 이용한 임계점과 패턴 기반 탐지를 이용한다. Guiry et al.은 가속도와 각속도, 지자기 센서 뿐만 아니라 실내가 아닌 실외의 경우에서 GPS와 빛 정보 수집을 위한 조도 센서를 이용한 행위인지도 수행하였다[7]. Sefen et al.은 기본행위와 팔굽혀펴기, 크런치, 스쿼트 등의 운동행위를 포함하였으며, 시계열 특징과 주파수 값 중 가장 높은 2개 값을 특징으로 사용하였다[8]. 반면에 Ali et al.은 스마트워치를 발목에 착용하고 스마트폰을 자유롭게 소지하였으나, 스마트폰에서는 GPS만을 사용하여 속도 측정용으로만 사용하였다[9]. Shoaib et al.은 가속도, 각속도, 선형가속도 데이터

를 이용하여 두 센서 사용시의 우수성 및 반복 행위(지속적 행위) 및 비반복 행위(순간적 행위)의 인지 차이를 극복을 위해 윈도우 사이즈 크기를 변화시켜 실험을 진행하였다[10]. Duclos et al.은 의료 목적의 에너지 소비량 예측을 위해 성별, 나이별 및 행위를 네 가지 범주로 나누어 측정하고 피드백을 도입하였다[11].

이와 같이 스마트폰과 스마트워치를 동시에 사용하여 행위인지를 수행한 연구들은 일반적으로 사용하는 데이터 퓨전 및 특징 퓨전만을 사용했을 뿐 결정 퓨전을 사용하지 않고 있다.

3. 스마트기기를 이용한 다단계 퓨전 기반 행위 인지 기법

본 장에서는 스마트폰과 스마트워치를 이용하여 다단계 퓨전을 이용한 행위인지 기법에 대해 설명한다. 제안하는 인지 기법의 프레임워크는 그림 1과 같다. 1단계 퓨전에서는 데이터 퓨전이 수행되며, 2단계에서는 특징




그림 1 제안하는 다단계 퓨전 행위인지 프레임워크

Fig. 1 Proposed multi-level fusion activity recognition framework

퓨전이, 그리고 3단계에서는 첫 번째 분류, 결정 퓨전, 그리고 두 번째 분류를 통해 최종 행위 결론을 도출한다. 최종 분류 과정이 수행되기 전 먼저 수집된 훈련 데이터를 이용하여 행위인지 학습 모델을 생성해야 한다. 데이터 수집 시에는 스마트폰과 스마트워치가 동시에 부착된 상태에서 행위를 수행하며, 이에 따라 각 행위의 스마트폰과 스마트워치는 동일한 시간에 얻은 데이터이다.

3.1 1단계 퓨전: 데이터 퓨전

1단계 퓨전에서는 데이터 퓨전이 발생한다. 이로써 발생하는 데이터 집합은 총 3가지이며, 이는 각각 스마트폰, 스마트워치, 그리고 스마트폰과 스마트워치를 통합한 데이터이다. 데이터 수집을 수행하는 동안 모든 행위에 대해 스마트폰과 스마트워치의 데이터가 동시에 수집되기 때문에 이들간의 상관관계를 파악하기 위해 데이터 퓨전을 수행한다. 스마트폰과 스마트워치가 합쳐진 데이터에 대한 특징을 추출해 보면 스마트폰과 스마트워치 데이터에서 각각 동일한 특징을 추출하여 결합한 결과와는 다른 것을 알 수 있으며, 이는 의미 있는 데이터라 할 수 있다.

$$\text{Smartphone} = \{X_{p1}, Y_{p1}, Z_{p1}, \dots, X_{pn}, Y_{pn}, Z_{pn}\}$$

$$\text{Smartwatch} = \{X_{w1}, Y_{w1}, Z_{w1}, \dots, X_{wn}, Y_{wn}, Z_{wn}\}$$

$$\text{Integrated} = \{X_{p1}, Y_{p1}, Z_{p1}, X_{w1}, Y_{w1}, Z_{w1}, \dots, X_{pn}, Y_{pn}, Z_{pn}, X_{wn}, Y_{wn}, Z_{wn}\}$$

3.2. 2단계 퓨전: 특징 퓨전

2단계 퓨전에서는 먼저 각 데이터 집합에 대한 특징 추출이 이루어진다. 스마트폰 데이터 집합과 스마트워치 데이터 집합에서 추출되는 특징으로는 평균(Mean), 최댓값(Max), 최솟값(Min), 중앙값(Median), 한 원도우에서 최대로 많이 나온 값(Most frequent value), 범위(Range), 표준편차(Standard deviation), 사분범위값(Interquartile), 절대 평균 편차(Absolute mean deviation), 절대 중간 편차(Absolute median deviation)이며, 스마트폰과 스마트워치 데이터가 합쳐진 집합에 대해서는 평균(Mean), 최댓값(Max), 최솟값(Min), 중앙값(Median), 표준편차(Standard deviation), 절대 평균 편차(Absolute mean deviation), 절대 중간 편차(Absolute median deviation), 분산(Variance)이다. 스마트폰과 스마트워치 데이터가 합쳐진 집합에서 추출되는 특징에만 차이가 있는 이유는 여기에서 사용되는 특징들이 상관관계를 파악할 수 있는 특징이며, 스마트폰과 스마트워치의 특징 간의 거리(Distance)를 통해 파악한다.

각 데이터 집합에서 특징을 추출한 이후 분류 단계가 수행된다. 3개의 데이터 집합에서 추출된 특징에 대해서 각각의 분류가 수행되며, 이외에도 스마트폰과 스마트워치의 특징 집합이 합쳐진 특징 집합에 대한 분류가 이루어져 총 4개의 특징 집합에 대한 분류가 수행된다. 이

는 스마트폰과 스마트워치 데이터가 합쳐진 집합에 대한 특징과 각 기기의 특징 집합과의 상관관계를 보기 위함이다.

$$\text{SmartphoneFeature} = \{X_{p1}, Y_{p1}, Z_{p1}, \dots, X_{pn}, Y_{pn}, Z_{pn}\}$$

$$\text{SmartwatchFeature} = \{X_{w1}, Y_{w1}, Z_{w1}, \dots, X_{wn}, Y_{wn}, Z_{wn}\}$$

$$\text{IntegratedDataFeature} = \{X_{i1}, Y_{i1}, Z_{i1}, \dots, X_{in}, Y_{in}, Z_{in}\}$$

$$\text{SmartphoneFeature} + \text{SmartwatchFeature} = \{X_{p1}, Y_{p1}, Z_{p1}, X_{w1}, Y_{w1}, Z_{w1}, \dots, X_{pn}, Y_{pn}, Z_{pn}, X_{wn}, Y_{wn}, Z_{wn}\}$$

3.3 3단계 퓨전: 결정 퓨전

첫 번째 분류는 SVM을 이용하며, 이 때 ECOC 기법을 이용한다. 일반적인 분류 방법을 이용할 경우 결과값은 행위 레이블이 나오지만, ECOC를 이용할 경우 사후확률을 구할 수 있어 최종 출력값은 모든 행위에 대한 사후확률값이 된다. 예를 들면 ECOC를 사용하지 않고 일반 분류기를 이용하여 분류를 수행할 경우 최종 결과는 서기, 걷기 등의 행위 레이블이 된다. 그러나 ECOC 방식을 이용하면 분류 가능한 모든 행위에 대해 발생 가능한 확률이 부여된다. 즉 8개의 행위가 도출될 수 있을 경우 결과가 행위 한 가지가 아닌 모든 8개의 행위에 대하여 확률값이 주어지는 결과가 도출된다. 예를 들어 하나의 분류기에서 발생한 분류 결과는 다음 표 1과 같이 도출될 수 있으며, 표 안의 수치는 발생 가능한 행위에 대한 사후확률을 의미한다. 이 때 표에서 나타난 모든 행은 서로 독립적이며, 각각의 행에 담긴 모든 행위에 대한 사후확률값은 모두 의미가 있는 데이터이다.

본 논문에서는 총 4개의 분류 결과(스마트폰 특징 집합, 스마트워치 특징 집합, 스마트폰+스마트워치 데이터에 대한 특징 집합, 스마트폰+스마트워치 특징의 특징 집합)가 존재하기 때문에, 8개의 행위와 4개의 분류에 대하여 총 84=4096개의 조합이 발생한다. 각각의 조합

표 1 단일 분류기에서 도출되는 사후확률의 예
Table 1 Example of posterior probability deduced from single classifier

	Stand	Walk	Sit	Run	Lie	Stretch	Sweep	Eat
Stand	0.9	0	0.02	0	0.03	0	0	0.05
Walk	0	0.91	0	0.02	0	0.04	0.03	0
Sit	0.06	0	0.86	0	0.03	0	0.01	0.04
Run	0	0.01	0	0.95	0	0.03	0.01	0
Lie	0.05	0.01	0.06	0	0.81	0	0	0.07
Stretch	0	0.02	0	0.04	0	0.88	0.05	0.01
Sweep	0	0.01	0.01	0.03	0.01	0.05	0.87	0.02
Eat	0.01	0.02	0	0.06	0.01	0.04	0.04	0.82

에 대해서는 서로 다른 확률값이 할당된다. 예를 들어 제안하는 구조도에서는 총 4개의 중간 분류기가 있다고 할 수 있다. 이 때 첫 번째 분류 결과 중 가장 높은 확률이 걷기일 경우, 나머지 2, 3, 4번 분류기에서는 동일한 걷기 혹은 다른 행위가 가장 높은 확률을 가질 수 있다. 만약 4개 모두 동일하게 걷기의 확률이 가장 높을 경우, 그리고 1번 분류기에서 걷기의 확률이 0.9일 경우, 나머지 7개의 행위에 대해서는 총합 0.1만큼의 확률이 분산되어 주어지며, 이는 2, 3, 4번 분류기에서도 동일한 방식으로 각 행위별 확률이 주어진다. 이와 같은 방식으로 모든 행위 조합에 대해서 각각의 분류기는 모든 행위에 대한 확률을 할당하게 되며, 이러한 확률은 모두 동일하지 않고 차이가 존재한다. 이렇게 도출된 모든 분류 조합에 대한 확률값은 하나의 벡터로 합쳐진 후 두 번째 분류가 진행된다. 이 때는 ECOC 기법을 사용하지 않기 때문에 어떠한 분류기를 사용하여도 상관이 없으며, 가장 높은 확률을 가진 행위가 결과로 출력된다.

4. 성능 평가

본 장에서는 제안하는 스마트폰과 스마트워치를 이용한 다단계 퓨전 기법의 평가를 위한 평가 환경과 실험 결과에 대해 소개한다.

4.1 성능 평가 환경

데이터 수집과 테스트에 사용된 기기로는 삼성전자의 안드로이드 기반 스마트폰인 갤럭시 S5와 LG전자의 안드로이드 기반 스마트워치인 G Watch R을 사용하였다. 스마트폰은 사용자의 오른쪽 바지 앞주머니에 위치하였으며, 스마트워치는 실험 참여자가 모두 오른손잡이인 관계로 오른쪽 손목에 착용하였다. 데이터는 20~30대의 남성을 대상으로 수집하였으며, 행위 수집 가이드라인은 아래의 표 2와 같다.

각 기기에서 데이터 수집에 사용된 센서는 가속도 센서 하나뿐으로 하나의 데이터 윈도우는 1초 샘플 주기

표 2 행위 수집 가이드라인
Table 2 Activity collection guideline

	Guideline
Stand	- Standing at attention
Walk	- Walk with normal speed
Sit	- Sit still - Place both arms on both knees
Run	- Light jogging
Lie	- Lie still - Keep the arms at attention
Stretch	- Bend and unfold your upper body with your hands extended.
Sweep	- Sweep the floor with a mop
Eat	- Eating with a spoon while sitting

50hz로 X, Y, Z 축을 각각 50개씩 수집하여 총 3초의 150개 가속도 데이터로 구성된다. 수집된 데이터를 바탕으로 수치해석 전문 소프트웨어인 매트랩(Matlab)을 이용하여 훈련과 분류를 진행하였으며, 분류는 10겹 교차 타당성 (10-fold Cross Validation)를 수행하였다.

4.2 성능 평가 결과

첫 번째 실험은 확률 방식을 사용하지 않고 퓨전의 사용 유무에 따른 결과를 비교한다. 이 때 투표 방식은 단순 다수결 방식을 사용하였다. 그림 2, 3, 4, 5는 차례대로 아무런 퓨전 방식을 사용하지 않은 결과, 데이터 퓨전만을 한 결과, 특징 퓨전만을 한 결과, 그리고 데이터와 특징 퓨전을 모두 한 결과의 정오분류표를 나타낸다. 결과를 살펴보면 아무런 퓨전도 하지 않았을 때 정확도 약 93%로 가장 낮은 것을 볼 수 있으며, 퓨전을 진행할 수록 결과가 향상되어 모든 퓨전을 사용할 시 약 97%의 정확도를 달성함을 보여준다.

두 번째 실험은 확률 방식을 이용하여 진행하였다. 이 때에도 첫 번째 실험과 같이 아무런 퓨전 방식을 사용하지 않았을 때, 데이터 퓨전만을 사용했을 때, 특징 퓨전만을 사용했을 때, 그리고 데이터와 특징 퓨전을 모두




그림 2 퓨전 미사용시 행위인지 결과 정확도: 93.292%
Fig. 2 Activity recognition accuracy without using any fusion: 93.292%




그림 3 데이터 퓨전만 사용시 행위인지 결과 정확도: 93.714%
Fig. 3 Activity recognition accuracy using only data fusion: 93.714%.




그림 4 특징 퓨전만 사용시 행위인지 결과 정확도: 97.353%
Fig. 4 Activity recognition accuracy using only feature fusion: 97.353%




그림 5 데이터 및 특징 퓨전 사용시 행위인지 결과 정확도: 97.696%
Fig. 5 Activity recognition accuracy using both data fusion and feature fusion: 97.696%

표 3 확률 방식의 행위인지 실험 결과

Table 3 Activity recognition accuracy using probability method

	Use No Fusion	Use Only Data Fusion	Use Only Feature Fusion	Use All Fusions (Data + Feature + Decision)
SVM	99.08%	99.20%	99.49%	99.50%
DT	99.14%	99.15%	99.65%	99.66%
KNN	99.33%	99.36%	99.60%	99.61%
LDA	98.49%	98.58%	99.40%	99.41%

사용했을 때로 나누어서 진행하였다. 또한 사용한 분류기는 대중적으로 사용되는 네 가지 분류기(SVM, DT (Decision Tree), KNN (K-Nearest Neighbor), LDA (Linear Discriminant Analysis))를 사용하였으며, KNN의 K 상수는 3으로 설정하였다. 실험 결과는 다음 표 3과 같으며, 수치는 정확도(%)를 나타낸다. 결과는 이전 실험과 마찬가지로 아무런 퓨전을 사용하지 않았을 때 가장 낮은 정확도를 보이며 모든 퓨전 기법을 사용했을

때 가장 높은 정확도를 보인다.

위의 결과에서 보듯이 이전 실험에서 가장 높은 정확도를 보였던 확률 기반 방식을 사용하지 않고 모든 퓨전을 사용했을 때보다도 이번 실험에서 가장 낮은 정확도를 보인 아무런 퓨전을 사용하지 않고 확률 기반 방식을 사용했을 때에 더 높은 정확도의 결과를 보임을 알 수 있으며, 이에 따라 제안하는 확률 기반의 다단계 퓨전 기법의 성능이 가장 우수함을 알 수 있다.

5. 결론

본 논문에서는 최소한의 센서 기기를 이용한 행위인지를 위해 많은 사용자가 사용 중이며 쉽게 구할 수 있는 스마트폰과 스마트워치를 이용한 다단계 퓨전 행위인지 프레임워크를 제안하였다. 본 프레임워크는 데이터 퓨전, 특징 퓨전, 결정 퓨전을 모두 사용하며, 결정 퓨전에서는 일반적인 다수결 투표 혹은 가중치 투표 방식이 아닌 사후확률 기반의 퓨전을 이용하며, 확률 방식의 사용 여부 및 각각의 퓨전을 사용/미사용 했을 때의 성능을 비교하여 제안하는 방식의 우수성을 입증하였다.

실험 결과는 모두 97~99%의 높은 정확도가 나오며, 이러한 이유는 수행한 테스트가 오프라인 테스트이기 때문이다. 오프라인 테스트란 데이터 수집에 사용된 데이터를 이용하여 훈련과 테스트를 모두 진행하는 것으로 비록 데이터 수집 실험군은 20명으로 모두 다르지만 데이터 수집 감독관 한 명이 전체적인 수집 과정을 감독/관리했기 때문에 데이터 수집 방법 (자세)이 모두 비슷하여 데이터 수치가 비슷하기 때문이다.

향후 연구로는 먼저 스마트폰의 특성을 따라 스마트폰의 위치와 방향을 고정시키지 않고 자유로운 위치에서도 높은 정확도로 인지가 가능한 방법 및 그에 따른 퓨전 기법의 변화를 연구할 예정이며, 더 많은 실험군을 모집하여 온라인 테스트를 수행할 예정이다.

References

- [1] U. G. Mangai, S. Samanta, S. Das, P. R. Chowdhury, "A survey of decision fusion and feature fusion strategies for pattern classification," *IETE Technical review*, Vol. 27, No. 4, pp. 293-307, 2010.
- [2] T. G. Dietterich, G. Bakiri, "Solving multiclass learning problems via error-correcting output codes," *Journal of artificial intelligence research*, Vol. 2, pp. 263-286, 1994.
- [3] E. B. Kong, T. G. Dietterich, "Error-correcting output coding corrects bias and variance," *Proc. of the Twelfth International Conference on Machine Learning*, pp. 313-321, 1995.
- [4] M. Shoaib, S. Bosch, H. Scholten, P. J. Havinga, O. D. Incel, "Towards detection of bad habits by

- fusing smartphone and smartwatch sensors," *Proc. of 2015 IEEE International Conference on Pervasive Computing and Communication Workshops*, pp. 591-596, 2015.
- [5] F. B. A. Ramos, A. Lorayne, A. A. M. Costa, R. R. de Sousa, H. O. de Almeida, A. A. Perkusich, "Combining Smartphone and Smartwatch Sensor Data in Activity Recognition Approaches: an Experimental Evaluation," *Proc. of The 28th International Conference on Software Engineering and Knowledge Engineering*, pp. 267-272, 2016.
- [6] T. Vilarinho, B. Farshchian, D. G. Bajer, O. H. Dahl, I. Egge, S. S. Hegdal, A. Lønes, J. N. Slettevold, S. M. Weggersen, "A combined smartphone and smartwatch fall detection system," *Proc. on 2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing*, pp. 1443-1448, 2015.
- [7] J. J. Guiry, P. Van de Ven, J. Nelson, "Multi-sensor fusion for enhanced contextual awareness of everyday activities with ubiquitous devices," *Sensors*, Vol. 14, No. 3, pp. 5687-5701, 2014.
- [8] B. Sefen, S. Baumbach, A. Dengel, S. Abdennadher, "Human Activity Recognition-Using Sensor Data of Smartphones and Smartwatches," *Proc. on 8th International Conference on Agents and Artificial Intelligence*, pp. 488-493, 2016.
- [9] H. M. Ali, A. M. Muslim, "Human Activity Recognition Using Smartphone and Smartwatch," *International Journal of Computer Engineering In Research Trends*, Vol. 3, No. 10, pp. 568-576, 2016.
- [10] M. Shoaib, S. Bosch, O. D. Incel, H. Scholten, P. J. M. Havinga, "Complex human activity recognition using smartphone and wrist-worn motion sensors," *Sensors*, Vol. 16, No. 4, 426, 2016.
- [11] B. Cvetković, R. Szeklicki, V. Janko, P. Lutomski, M. Luštrek, "Real-time activity monitoring with a wristband and a smartphone," *Information Fusion*, Vol. 43, pp. 77-93, 2018.



허 태 호

2010년 경희대학교 컴퓨터공학과(학사)
2010년~현재 경희대학교 컴퓨터공학과
석박사과정. 관심분야는 유비쿼터스 컴퓨
팅, 행위인지, 상황인지, 인공지능



이 승 룡

1978년 고려대학교 재료공학과(공학사)
1987년 Illinois Institute of Technology
전산학과(석사). 1991년 Illinois Institute
of Technology 전산학과(박사). 1992~
1993년 Governors State University,
Illinois 조교수. 1993년~현재 경희대학
교 SW융합대학 컴퓨터공학과 교수. 관심분야는 유비쿼터스
컴퓨팅, 상황인지, 인공지능, 실시간 시스템, 미들웨어, 보안,
클라우드 컴퓨팅