

# 스마트폰에서 센서 융합과 커널 판별 분석을 이용한 인간 활동 인식

조정길  
성결대학교 컴퓨터공학과 교수

## Human Activity Recognition Using Sensor Fusion and Kernel Discriminant Analysis on Smartphones

Jung-Gil Cho  
Professor, Department of Computer Engineering, Sungkyul University

**요약** 스마트폰을 이용한 인간 활동 인식은 컴퓨터 지능 분야에서 뜨거운 연구 주제이다. 스마트폰에는 다양한 센서가 장착되어 있다. 이러한 센서의 데이터를 융합하면 응용프로그램에서 많은 활동을 인식할 수 있다. 그러나 이러한 장치는 활용 가능한 센서 수가 제한되기 때문에 리소스가 적으며, 최적의 성능과 효율적인 특징 추출을 달성하기 위해서는 특징 선택 및 분류 방법이 필요하다. 이 논문에서는 이러한 요구사항에 따라 스마트폰-기반 HAR 체계를 제안한다. 이 논문에서 제안된 방법은 가속도 센서, 자이로 센서, 기압 센서에서 시간-도메인 특징을 추출하며, 커널 판별 분석(KDA)과 SVM을 적용하여 높은 정확도로 활동을 인식한다. 이 방법은 각 활동에 대해 각 센서에서 가장 관련성이 높은 특징을 선택한다. 우리의 비교 결과는 제안된 시스템이 이전의 스마트폰-기반 HAR 시스템보다 성능이 우수함을 보여준다.

**주제어** : 인간 활동 인식, 가속도 센서, 자이로 센서, 기압 센서, 특징

**Abstract** Human activity recognition(HAR) using smartphones is a hot research topic in computational intelligence. Smartphones are equipped with a variety of sensors. Fusing the data of these sensors could enable applications to recognize a large number of activities. However, these devices have fewer resources because of the limited number of sensors available, and feature selection and classification methods are required to achieve optimal performance and efficient feature extraction. This paper proposes a smartphone-based HAR scheme according to these requirements. The proposed method in this paper extracts time-domain features from acceleration sensors, gyro sensors, and barometer sensors, and recognizes activities with high accuracy by applying KDA and SVM. This approach selects the most relevant feature of each sensor for each activity. Our comparison results shows that the proposed system outperforms previous smartphone-based HAR systems.

**Key Words** : HAR, Acceleration sensor, Gyro sensor, Barometer sensor, Feature

### 1. 서론

활동 인식은 개체의 행동과 환경 조건에 대한 일련의

관찰을 통하여 하나 이상의 개체의 동작을 인식하는 것을 의미한다[1]. 인간 활동 인식(Human Activity Recognition, HAR) 연구는 중요한 연구 분야로 많은

관심을 받고 있다. HAR은 다양한 센서 데이터를 이용하여 인간의 움직임이나 행위에 따라 변화하는 패턴을 인지하는 기술이다[2].

HAR의 작업은 물리적 세계를 감지하는 것으로 시작하며, 이를 위해 두 가지 주요 기술인 외부 센서 및 웨어러블 센서가 사용되었다. 외부 센서의 경우는 일상적인 물체에 내장된 간단한 센서 및 비디오와 같은 장치이다. 반면에 웨어러블 센서의 경우는 사용자의 신체나 옷에 부착된 작은 센서를 사용하여 HAR를 처리하며, 높은 정확도로 활동을 인식할 수 있지만 보급성이 나쁘다. 따라서 이 연구의 초점은 사용자가 어디에서나 휴대할 수 있는 스마트폰 센서를 이용한 HAR에 있다.

요즘 스마트폰에는 가속도, 압력, 나침반, 자이로스코프, 근접, 조명, GPS, 마이크 및 카메라를 포함한 다양한 센서가 장착되어 있다. 이러한 장치들은 스마트폰을 휴대할 때 거의 모든 곳에서 일상생활의 일부가 되었다. 따라서 스마트폰은 편의성 및 편의성, Wi-Fi, 4G, 5G 및 블루투스과 같은 다양한 무선 인터페이스의 가용성으로 인해 다중 센서 기반 HAR를 위한 매력적인 대안 플랫폼이 되고 있다.

최근에 많은 연구들이 활동 분류를 위해 스마트폰을 사용했다[2-10]. 그러나 이전 연구의 대부분은 데이터 수집을 위해서만 스마트폰을 사용하고 추가 처리를 위해서는 PC와 같은 관련 장치로 전송되었다. 또한 스마트폰은 대부분 에너지가 제한되어 있으며 배터리 수명을 연장하는 것이 필수적이다. 따라서 활동 인식에 스마트폰을 사용하려면 배터리 수명을 보존하기 위해 경량 인식 시스템이 필요하다.

이에 이 논문에서는 센서 융합 접근방식에 기반한 스마트폰-기반 HAR 시스템을 소개한다. 이 연구는 다음과 같이 기여한다. 스마트폰에서 가장 일반적으로 사용가능한 세 가지 센서인 가속도 센서, 자이로 센서, 기압 센서를 이용하여 활동을 인식한다. 또한 배터리 수명을 보존하기 위해 세 가지 센서 모두에서 시간-도메인 특징만 사용한다. 그리고 빠른 응답을 보장하기 위해 짧은 시간과 데이터 윈도우가 사용된다. 또한 데이터 윈도우와 결합된 시간-도메인 특징만 사용하며, 비선형 판별 분석 접근법과 분류기가 결합되어 가장 최적의 결정 경계를 찾는다.

## 2. 관련 연구

HAR에 매우 적합한 장치는 단일 장치에 다양한 센서

가 있는 스마트폰이다. 스마트폰은 HAR에서 여러 가지 방법으로 사용되었다. Fahim(2013)와 Lara(2012)의 연구에서는 스마트폰 가속도 센서를 사용하여 걷기 및 달리기와 같은 움직임을 인식했다[3,4]. Lu(2009)의 연구에서는 사운드 분석을 사용하여 음향 환경을 분류하기 위해 마이크를 사용했다[5]. Liao(2007)와 Thiagarajan(2010)의 연구에서는 스마트폰 GPS 센서를 사용하여 교통 관련 활동을 인식했다[6-7]. 이들 접근법들 사이에서 하나의 공통점은 모두 HAR를 위해 한 개의 특정 종류의 센서를 사용했다는 것이다. 한 개의 센서를 사용하면 인식될 수 있는 활동 등급의 수 또는 인식 정확성인 인식 문제의 범위가 제한된다[8]. 이러한 문제는 여러 센서를 함께 사용하거나 융합하여 해결할 수 있다.

Han(2012)의 연구에서는 가속도 센서, 마이크로폰 및 GPS 센서를 사용하여 보행, 조깅 또는 정지와 같은 외래 활동 및 버스과 지하철 등의 교통 관련 활동을 인식할 수 있는 포괄적인 상황 인식기가 제공되었다[8]. 가속도계 데이터 분류를 위해 시간-도메인 특징, 주파수-도메인 특징 및 선형 예측 코딩(LPC) 기능을 갖춘 HMM을 사용했으며, MFCC(Mel Frequency Cepstral Coefficients)를 갖춘 GMMS를 오디오 데이터 분류에 사용했다. 이와 유사한 논문으로는 Ustev(2013)이 있다[9]. Anguita(2013)의 연구에서는 멀티 클래스 SVM 학습 알고리즘을 이용하여 가속도와 자이로 센서로 부터 얻은 데이터에서 561개의 특징을 기반으로 활동 분류를 하였다[10]. 또한 Siang(2018)의 연구에서는 가속도와 자이로 센서 데이터인 UCI Learning Repository를 사용하여 DNN 기반의 HAR 모델을 만들고, t-SNE 알고리즘을 이용하여 특정 활동 모델의 잘못 분류되는 원인을 파악하는 방법을 제시하였다[2]. 이 연구들에서는 다양한 분류기로 분류를 위한 특정 활동의 분류 정확성을 높이기 위하여 사용하였다. 그러나 매우 유사한 형태를 띠는 활동 간의 구분 작업(계단 오르기과 계단 내려가기)에 대하여 분류 성능이 낮게 나타나서 개선의 여지가 있음을 확인할 수가 있다.

앞에서 논의된 스마트폰-기반 활동 인식을 위한 다중 센서 접근 방식은 각각의 문제점들을 가지고 있다. 이러한 방법의 대부분은 다중레벨이나 다중분류 방법을 사용해서 활동 분류를 하였으며, 높은 인식 결과를 제공할 수는 있지만 긴 시간동안 윈도우를 사용하여 활동을 인식해야하는 문제가 발생된다. 또한 또 다른 문제점은 다중레벨이 아닌 접근 방식은 더 짧은 시간 윈도우를 사용하지만 특징 추출에서 시간-도메인과 주파수-도메인 특징 모두를 기반으로 한다. 따라서 이 논문에서는 주파수-

도메인 특징에 비해 에너지 효율과 연산 비용이 덜 소모 되는 시간-도메인 특징을 이용하며[11], 특징 선택과 분류에 효율적이기 때문에 KDA와 SVM을 적용한다.

### 3. 제안된 HAR 방법

제안된 시스템의 구조는 Fig. 1과 같이 센서 데이터 수집, 데이터 전처리, 특징 추출, 특징 선택, 분류, 인식된 활동의 6단계로 구성된다. 또한 제안된 HAR은 모델 학습 단계와 모델 적용 단계가 있는 지도(supervised) 기계 학습 방법을 사용한다.

데이터 수집에서는 스마트폰에 있는 3종류 센서(가속도 센서, 자이로 센서, 기압 센서)의 이산 시계열 데이터를 기록한다. 다음 단계인 데이터 전처리의 주된 작업은 데이터를 세분화하여 센서 데이터를 보정하고 잡음을 제거하여 특징 추출 단계를 위한 데이터를 준비하는 것이다. 특징 추출 단계는 통계적 및 기타 유형의 특징들을 추출한다. 그리고 특징 선택 단계는 유용한 특징을 선택하여 차원 축소를 달성한다. 특징 추출 후에 특징 선택을 통해서 특징 데이터를 얻은 다음에, 분류 단계에서는 학습하거나 활동 인식을 위한 모델을 적용하기 위해 관련 데이터셋 및 기계 학습 알고리즘을 선택한다. 인식된 활동 단계는 분류자가 활동을 인식한다.

제안된 시스템의 특징은 스마트폰의 에너지 효율, 연산 비용, 저장 공간을 고려하여 시간-도메인 특징을 이용하여 추출하였으며, 특징을 선택하는 데는 성능이 우수한 KDA를 이용하였다. 또한 활동을 분류하는 학습알고리즘은 적은 훈련 세트로 높은 분류 정확도가 달성되는 SVM을 이용하여 HAR의 인식률을 높였다.

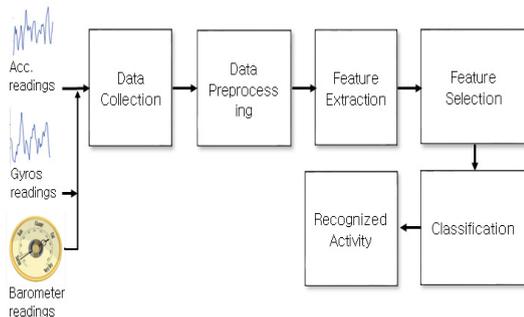


Fig. 1. Process flow of the proposed system

#### 3.1 데이터 수집

데이터 수집 단계의 주요 작업은 스마트폰 센서의 원시 데이터를 수집하는 것이다. 활동 인식 프로세스는 3초 윈도우를 사용하여 3개의 센서(가속도 센서, 자이로 센서, 기압 센서)에서 데이터를 수집하는 것으로 시작한다. 윈도우 크기는 Khan(2013)[11]의 결과에 따라 선택되었으며, 실시간 스마트폰 기반의 HAR 시스템을 구현했다. 서로 다른 물리적 활동의 가속 신호에 대한 탐색적 데이터 분석 기술을 사용한 신호는 자동 회귀(AR) 프로세스에 의해 생성되며, 이러한 신호의 정확한 시계열 모델은 낮은 샘플링 속도(20Hz)와 작은 데이터 윈도우(3초)를 사용하여 구축하였다.

이 논문의 연구에서는 총 6개의 활동을 목표로 하였으며, 이는 지난 10년 동안 HAR 영역에서 주로 탐구된 신체 활동의 조합이다[12]. 활동에는 걷기(walking), 위층 오르기(walking upstairs), 아래층 내려가기(walking downstairs), 앉다(sitting), 서다(standing), 눕다(laying)가 포함된다.

#### 3.2 데이터 전처리

활동 데이터를 수집한 후에, 데이터는 전처리 단계에서 센서 교정, 적절한 노이즈 제거, 데이터 분할을 거친다. 이 단계는 가속도 데이터의 경우에 데이터에 중력 성분과 같은 노이즈가 포함될 수 있기 때문에 중요하다.

스마트폰에 내장된 가속도와 자이로 센서는 편차(drift)와 편향(biase)을 일으킨다. 더 정확한 가속도 및 자이로스코프 데이터를 얻기 위하여 이 두 센서를 교정한다. 교정 전에 스케일링 및 오프셋 매개변수를 가져오며, 이러한 매개변수는 교정 중에 사용된다. 교정 매개변수를 얻기 위한 방법은 수평면에 배치된 스마트폰의 다른 6방향 축의 실제 값을 사용한 “6-위치” 정적 방법을 사용한다[13].

원시 센서 데이터를 교정한 후에는 노이즈 제거를 수행한다. 이 프로세스의 주요 목적은 저역-통과 필터(low-pass filter)를 이용하여 버(러움의 진동음)를 필터링하고 파형을 부드럽게 하여 센서의 랜덤 노이즈를 제거하는 것이다. 스마트폰에 내장된 3축 가속도 센서는 3차원( $x$ ,  $y$ ,  $z$ )을 따라 중력에 의한 일정한 가속도와 사용자가 모바일 장치에 가하는 가속도인 2가지 종류의 가속도를 저장한다[14]. 중력으로 인한 가속은 소음으로 간주되므로 실제 가속을 계산하기 위하여 중력을 제거한다. 중력 계수를 제거하는 기술은 저역-통과 필터를 이용

하는 안드로이드 자체 문서에 있으며 다음의 식과 같다[14].

$$g = (1 - \alpha) \times g + \alpha \times v_t \quad (1)$$

여기서  $\alpha$ 는 필터 벡터이다.  $g$ 는 처음에 0으로 설정된 전역 변수이며(3 개의 축에 해당하는 3개가 필요함),  $v$ 는  $t$ 의 특정 축에 대한 가속도계의 값이며,  $\overline{v}_t = v_t - g$ 와 같이 센서 값에서 뺀 중력을 분리한다.

센서로부터 수집된 데이터는 시계열 방식의 스트림이다. 데이터의 특징 추출을 용이하게 하기 위해, 시계열 센서 데이터는 세그먼트로 분할한다. 시계열 데이터를 처리할 때 슬라이딩 윈도우 기술이 널리 사용되고 효과적인 것으로 입증되었으며, 두 개의 연속 윈도우 사이에 겹치는 부분이 있는지 여부에 따라 겹치지 않는 슬라이딩 윈도우와 겹치는 슬라이딩 윈도우 방식이 있다[15]. 이 논문에서는 연속 데이터를 분석하는데 더 적합하며 우수한 평활성(smoothness property)을 가지는 겹치는 슬라이딩 윈도우 방식을 사용한다. Fig. 2는 가속도 센서 신호를 분할하는 겹치는 슬라이딩 윈도우 방식을 나타낸다. 여기서  $a_x, a_y, a_z$ 는 3축 가속도계의 3가지 성분을 나타내고,  $\Delta t$ 는 윈도우 크기를 의미하고,  $\vec{a}_t$ 는 시간  $[t, t + \Delta t]$ 에서  $a_x, a_y, a_z$ 의 판독 값을 나타낸다.  $\vec{a}_t$  및  $\vec{a}_{t+1}$ 은 센서 판독 값의 일부를 공유한다.

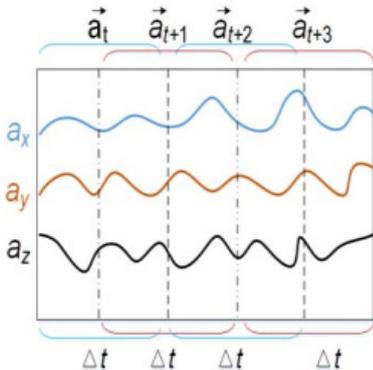


Fig. 2. Sliding window technique with overlapping

### 3.3 특징 추출

다른 분류 시스템과 마찬가지로 특징 추출은 모든 HAR 시스템에서 중요한 역할을 한다. 스마트폰은 일반적으로 에너지가 제한되어 있으므로 스마트폰의 배터리 수명을 연장해야 한다. 즉 HAR에 스마트폰을 사용하려면

배터리 수명을 보존하고 높은 정확도를 보장하기 위해 경량(에너지 효율적) 및 정확한(높은 식별력을 가짐) 기능이 필요하다. 특징 추출 방법에는 크게 시간-도메인과 주파수-도메인 방법으로 분류할 수 있으며, 각 센서의 특징 추출에 대한 자세한 내용은 다음과 같다.

스마트폰에 내장된 3축 가속도 센서 및 3축 자이로 센서는 활동을 인식하는 데 있어서 전력을 비교하고 합성 효과를 평가하기 위해, 가속도 윈도우는  $\vec{a}_t$ 로, 자이로스코프 윈도우는  $\vec{b}_t$ 로 나타낸다.  $\vec{a}_t$  및  $\vec{b}_t$ 는 다른 수의 판독 값을 포함 할 수 있지만 윈도우의 크기는  $t$ 이다. 샘플링 주파수가  $p$ 라고 가정하면 윈도우에  $N = p \times \Delta t$  판독 값이 있다.

3축 가속도 센서의 경우에, 각 판독 값은 3개의 축에 해당하는  $a_x, a_y, a_z$ 로 구성되며, 각 축마다  $N$ 개의 판독 값이 있으며 길이가  $N$ 인 벡터를 형성한다. 이것은 활동 인식에 효과적인 것으로 보이는 다양한 통계 특징을 추출 할 수 있다. 3축 자이로 센서의 경우에, 각 판독 값은 3개의 축에 해당하는  $b_x, b_y, b_z$ 로 구성되며, 가속도 센서와 마찬가지로 시간-도메인에서 통계적 특징을 추출한다.

스마트폰에 내장된 기압 센서는 공기 압력을 측정한다. 이 센서를 시스템에 포함시킨 주요 이유는 사용자가 신체 활동을 수행함에 따라 고도, 더 중요하게는 다른 지점 사이의 상대 고도를 추적 할 수 있기 때문이다. 이 정보는 위층으로 올라가거나 아래층으로 내려가는 등 고도가 증가하거나 감소하는 활동을 인식하는 데 도움이 된다. 고도는 기압 센서에 의해 포착된 공기 압력을 사용하여 다음의 식과 같이 계산된다[16].

$$h(p_0, p_t) = \frac{T_0}{L} \left( 1 - \left( \frac{p_t}{p_0} \right)^{RL/gM} \right) \\ = 44330 \times \left( 1 - \left( \frac{p_t}{p_0} \right)^{1/5.255} \right) \quad (2)$$

여기서  $h$ 는 고도,  $p_0$ 는 해수면의 표준 기압,  $p_t$ 는 시간  $t$ 의 압력 센서가 제공한 기압 추정치,  $T_0$ 는 해수면 표준 온도,  $L$ 은 온도 경과 율,  $R$ 은 범용 가스 상수,  $g$ 는 중력 가속도,  $M$ 은 건조한 공기의 몰(molar) 질량이다. 그리고 상대 고도는 건물 내 층간의 고도 차이와 같이 두 지점의 고도 차이인  $h_r(a, b) = h(p_o, p_b) - h(p_o, p_a)$ 로 계산한다. 여기서  $h_r$ 은 점  $a$ 와  $b$  사이의 상대 고도이다. 양의 값은 전체 고도의 증가를 반영하며, 음의 값

은 전체 고도의 감소를 반영한다. 이 연구에서 고도 차이는 기압/고도 데이터의 모든 3초의 윈도우마다 첫 번째, 중간 및 마지막 샘플 사이의 3 점(point) 사이에서 계산된다. 따라서 기압 센서 데이터로부터 계산된 고도 특징  $f_{alt}$  는 다음과 같이 표현된다.

$$f_{alt} = [h_r(f, m), h_r(m, l), h_r(f, l)] \quad (3)$$

여기서  $f$ ,  $m$  및  $l$  는 3초 윈도우에서 첫 번째, 중간 및 마지막 샘플이다. 합성 효과를 평가하기 위해, 기압 관련 윈도우는  $\vec{c}_i$  로 나타낸다.

가속도 센서, 자이로 센서, 기압 센서를 동시에 사용하면 추가 기능  $ff(\vec{a}_i, \vec{b}_i, \vec{c}_i)$  를 얻을 수 있다. 예를 들어, 우리는 자이로스코프와 중력 가속도 신호 사이의 각도를 계산할 수 있다. 특히, 3개의 감지 장치 중 하나에서 특징이 추출됨을 나타내기 위해 가속도 센서 관련 특징은  $F_a = f(\vec{a}_i)$ , 자이로 센서 관련 특징은  $F_b = g(\vec{b}_i)$ , 기압 센서 관련 특징은  $F_c = h(\vec{c}_i)$ 로 나타내며, 센서 융합 특징은  $F = F_a \oplus F_b \oplus F_c \oplus ff(\vec{a}_i, \vec{b}_i, \vec{c}_i)$ 로 나타낸다. 여기서  $f, g, h$  및  $ff$  는 특징 추출 함수로 명명되며,  $\oplus$  는 여러 특징 벡터를 단일 벡터로 병합하는 연결 함수이다. 따라서 추가 분석을 위해 특징의 세 가지 하위 집합을 얻을 수 있다.

특징 추출은 시간-도메인과 주파수-도메인 방법으로 계산한다. 이 논문에서는 스마트폰의 제약사항인 에너지 효율, 연산 비용, 저장 공간을 고려하여 시간-도메인 특징들을 선택하였다[17]. 정성 분석을 통하여 시계열 특징들의 연산 비용, 저장 공간, 모바일 기기 적합성 여부를 판단하여 조건에 합당하는 총 7개의 특징들을 선별하였다[17]. 선별된 7개의 특징들은 평균(Mean), 표준편차(Standard Deviation), 사분위수 범위(IQR), 평균 제곱근값(RMS), 영교차율(Zero-Crossing), 최댓값(Maximum), 최솟값(Minimum)이며, 선별된 특징들은 가속도 센서와 자이로 센서의 3개의 축별과 기압 센서로 총 49개를 추출하였다.

### 3.4 특징 선택

특징 추출 후에 특징을 선택하는 판별 분석이 수행된다. 활동 인식의 견고성을 높이고 계산 복잡성을 줄이기 위하여 특징 선택은 추출된 특징 데이터를 필요로 한다.

특징 추출 후에 특징의 다양성이 고차원 데이터를 형식화하는데서 얻어진다. 이러한 특징 중 일부는 인식의 정확성에 필요하지만 일부 특징은 덜 필요하고 효과적이지 않다. 이러한 고차원 데이터 훈련은 시스템 효율성을 떨어뜨릴 수 있기 때문에 효과적인 특징을 선택하는 것이 필수적이다. 따라서 이들 특징들의 차별적인 능력을 향상시키는 것이 바람직하며, 가장 유용한 특징들만 선택하여 차원 축소를 달성하면서 높은 클래스간의 분산을 줄이는 것이 바람직하다. 일반적으로 사용되는 차원 축소 방법에는 주성분 분석(PCA), 선형 판별 분석(LDA) 및 자기 회귀 모델(Auto regressive Model), 커널 판별 분석(KDA, kernel discriminant analysis)[18,19] 등이 있다. 이 논문에서는 이러한 각각의 차원 축소 방법의 성능 중에서 보다 나은 성능을 나타낸 KDA를 선택했다[18,19].

KDA는 커널 기술을 사용하여 비선형 판별 특징을 찾는 비선형 판별 접근방식이다. KDA는 비선형 매핑  $\varphi: R^n \rightarrow F$  에 의해 유발된 특징 공간  $F$ 의 문제를 고려한다. 이 연구에서는 다양한 옵션을 실험한 후 가우시안 커널을 사용하여 RBF(방사형 기본 함수)로  $\varphi$ 를 선택한다.

적절하게 선택된  $\varphi$ 의 경우, 내부 프로덕트  $\langle \cdot, \cdot \rangle$  은 커널 힐버트 공간을 재생하기 위해 만든  $F$ 로 정의할 수 있다. 보다 구체적으로,  $\langle \varphi(x_i), \varphi(x_j) \rangle = K(x_i, x_j)$  는  $K(\cdot, \cdot)$ 가 양의 준정부호(semidefinite) 커널 함수인 경우를 유지한다.  $F$ 에서 선형 판별을 찾으려면 다음 기준을 최대화해야한다:

$$J(\omega) = \frac{\omega^T S_b^\varphi \omega}{\omega^T S_w^\varphi \omega} \quad (4)$$

여기서  $S_b^\varphi$  와  $S_w^\varphi$  는  $F$ 의 클래스 간 및 클래스 내 분산 행렬이며 다음과 같이 정의된다.

$$S_b^\varphi = \sum_{k=1}^C m_k (\mu_\varphi^k - \mu_\varphi)^T, \\ S_w^\varphi = \sum_{k=1}^C \left( \sum_{i=1}^{m_k} (\varphi(x_i^k) - \mu_\varphi^k) (\varphi(x_i^k) - \mu_\varphi^k)^T \right) \quad (5)$$

여기서  $\omega$ 는 KDA 기준 벡터이다.  $\mu_\varphi^k$  와  $\mu_\varphi$  는 각각 k번째 클래스와 글로벌 평균의 평균이다.  $m_k$ 는 k번째 클래스의 샘플 수이다. 식 4에 대한 해는  $\varphi(x_i)$  와 계수  $\alpha_i$ 의 선형 조합이다.

$$\omega = \sum_{i=1}^m \alpha_i \varphi(x_i) \quad (6)$$

$\alpha = [\alpha_1, \dots, \alpha_m]^T$  라고하면 식 6은 다음의 식과 같다.

$$J(\alpha) = \frac{\alpha^T K W K \alpha}{\alpha^T K K \alpha} \quad (7)$$

그리고  $K W K \alpha = \lambda K K \alpha$  의 최대 고유 값에 대하여 최적의  $\alpha(s)$ 는 고유 벡터에 의해 주어진다. 여기서 K는 커널 행렬 ( $K_{ij} = K(x_i, x_j)$ ) 이고, W는 다음의 식과 같이 정의된다.

$$W_{ij} = \begin{cases} 1/m_k, & \text{if } x_i \text{ and } x_j \text{ belong to } k\text{th class} \\ 0, & \text{otherwise} \end{cases} \quad (8)$$

새로운 패턴  $x$ 의 경우에,  $F$ 의 KDA 기준 벡터  $\omega$ 에 대한 투영은  $(w, \varphi(x)) = \alpha^T K(:, x)$  와 같이 계산된다. 여기서  $K(:, x) = [K(x_1, x), \dots, K(x_m, x)]^T$  이다.

요약하면, 특징 선택 단계는 더 나은 판별 특징을 가진 선형 특징 공간에서 비선형 특징 공간으로의 매핑으로 간주 될 수 있는 KDA 특징 벡터를 생성한다.

### 3.5 분류

대부분 활동 인식 연구는 지도 기계 학습 방법을 채택한다. 즉 활동 인식의 문제는 분류 문제로 간주되는데, 먼저 활동이 정의되고 센서 특징 데이터에 활동 레이블이 붙은 다음, 레이블된 특징 데이터는 다른 기계 학습 알고리즘과 결합되어 다른 모델을 훈련하고 학습한다.

일반적으로 사용되는 학습 알고리즘은 의사결정 트리(DT), 베이지안, 인스턴스 기반 알고리즘, 신경망, 서포트 벡터 머신(SVM), Fuzzy Logic, 회귀 분석법, 그래프 모델, 앙상블 분류기, K-최근접 이웃(KNN, K-nearest neighbors) 등이 있다. 이 논문의 제안된 시스템은 활동 분류를 위해 SVM을 사용한다[20]. SVM은 매우 강력한 데이터 분류 기술이다. SVM의 작업은 최상의 분리 초평면을 찾는 데 있으며, 특징 공간 내에서 두 클래스의 학습 샘플 간에 최대 마진이 있는 평면이다. 이를 위해 SVM은 클래스 디스크립터의 가장자리에 배치된 훈련 사례에 중점을 둔다. 이렇게 하여 최적의 초평면이 장착될 뿐만 아니라 더 적은 훈련 샘플이 효과적으로 사용되기 때문에 적은 훈련 세트에 높은 분류 정확도가 달성된다[20].

기존의 SVM 알고리즘은 다음과 같은 최적화 문제로 요약된다.

$$\min_{w, b, \xi} \left\{ \frac{1}{2} w^T w + C \left( \sum_{i=1}^l \xi_i \right) \right\}$$

subject to:  $y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i, \xi_i \geq 0, \quad (9)$

여기서  $x_i$ 는 커널 함수인  $\phi(x)$ 를 사용하여 더 높은 차원 공간에 매핑되는 학습 벡터이다.  $w, b, \xi$  및  $C$ 는 각각 가중치 벡터(weight vector), 바이어스(bias), 여유 변수(slack variable) 및 페널티 오류 항(penalty error term)이다.

## 4. 실험 결과와 성능 평가

### 4.1 실험 결과

성능 평가를 위한 실험은 건강한 상태의 20대 실험자 2명이 일상생활에서 해당 활동을 할 때마다 지정한 시간 동안 지속적으로 데이터를 수집하였다. 또한 갤럭시 s9 인 하드웨어 플랫폼을 사용하여 가속도 센서, 자이로 센서, 기압 센서로 데이터를 수집하였다. 또한 쉬운 데이터 수집을 위하여 스마트폰 앱을 개발하여 사용하였다. 실험자는 활동 유형 및 장치 위치를 지정하고, 데이터 기록을 시작하고 중지하며, 수집된 데이터를 연구원에게 전송하였다.

활동 인식 모델의 일반화 성능을 평가하기에 적합한 방법은 모델의 학습 단계와 평가 단계에 서로 다른 데이터를 사용하는 것이다. 그러나 실제로는 실험 데이터셋이 제한되어 있기 때문에, 이 논문에서는 데이터셋을 분할하는 방법으로 10-fold 교차 검증을 사용하였다. 따라서 실험 및 평가를 위하여 2개의 데이터셋의 데이터를 10:1로 나누어 모델에 대해 학습 및 평가를 시행하였다. 이 논문에서 제안된 방법은 SVM 알고리즘을 사용한 기계 학습 모델을 설계하여 파이썬 기반의 scikit-learn 라이브러리[21]를 사용하여 분류기를 제작하였다.

스마트폰의 HAR은 일반적으로 지도 기계 학습을 채택하며 평가 프로세스는 지도 학습에서의 분류 평가와 같으므로, 혼동 행렬(confusion matrix)을 기반으로 가장 많이 사용하는 정확도(accuracy), 정밀도(precision, P), 재현율(recall, R), F1-Score를 평가 방법으로 사용하였다[22,23]. Table 1은 실험 데이터셋을 사용하여 기계 학습 분류 모델을 학습하고 검증한 결과이다.

Table 1. The result of experiment

	Precision	Recall	F1-Score
walking	0.966	0.990	0.978
walking upstairs	0.985	0.965	0.975
walking downstairs	0.986	0.979	0.982
sitting	0.969	0.922	0.945
standing	0.931	0.974	0.952
laying	1.000	0.998	0.999
Average	0.967	0.971	0.972

정밀도 평균, 재현율 평균, F1-Score 평균이 각각 96.7%, 97.1%, 97.2%의 성능을 보였으며, 이러한 결과로 이 논문의 모델 성능이 우수함을 알 수가 있다. 정밀도가 재현율에 비하여 조금 낮게 나온 이유는 실제 활동은 아닌데 예측 활동에서 맞게 처리한 결과가 조금 많게 나왔기 때문이다. 각각의 분류 성능에 대한 활동의 예측 결과를 구체적으로 확인하기 위하여 혼동 행렬을 작성하였다.

Fig. 3의 혼동 행렬은 각각의 모델별 예측 결과를 상세하게 나타내어 분석한 결과이며, 세로축은 실제 활동을 나타내며, 가로 축은 모델이 분류한 예측 활동을 나타낸다. 6 ADL에 대한 SVM을 사용한 결과는 Fig. 3에 제시되어 있으며, 2836 패턴으로 구성된 테스트 데이터의 전체 정확도는 97.2%이다.

		Predict Activity						
		WK	WU	WD	ST	SD	LY	R (%)
Actual Activity	WK	478	1	4				99
	WU	14	447	2				96.5
	WD	3	6	421				97.2
	ST				412	35		92.2
	SD				13	487		97.4
	LY					1	512	99.8
	P (%)	96.6	98.5	98.6	96.9	93.1	100	97.2

Fig. 3. Confusion Matrix of the classification results

각 클래스의 분류 성능은 정밀도 및 재현율 측정 기준에서 가장 낮은 재현율 수치는 92.2%이다. 잘못 분류된 표본들(n=79)중에서는 고도의 차이점(n=25)과 그 자리에서의 활동(n=48)에서 구별하는 것이 어려워서 대부분의 오류가 발생했다. 고도의 차이점에서는 '위층 오르

기'(WU)를 '걷기'(WK)나 '아래층 내려가기'(WD)로 잘못 분류되었으며, 그러나 '아래층 내려가기'는 '걷기'나 '위층 오르기'로 잘못 분류된 것이 상대적으로 적었다. 또한, 그 자리에서의 활동에서는 '앉다'(ST)를 '서다'(SD)로 잘못 분류되어 재현율이 가장 낮게 나타났다. 그러나 반대로 '서다'를 '앉다'로 잘못 분류된 것이 상대적으로 적어 학습한 모델이 활동을 '앉다'와 '서다' 중에서 '서다'로 분류하는 성향이 높다는 것을 알 수가 있다.

## 4.2 비교 평가

이 논문에서는 분류 정확도 비교 평가를 위하여 이 논문의 연구와 가장 유사한 최근의 연구 논문 4개를 선택하였으며, 각각의 연구 논문은 서로 다른 센서 융합을 사용하였다.

Fig. 4의 분류 정확도 비교 평가에서는 이 논문의 방법을 다른 4종류의 방법과 비교하였다. Fig. 4는 5가지 방법의 분류 정확도(차례대로 96.1%, 92.4%, 96.4%, 92.2%, 97.2%)를 나타내고 있으며, 그 중에서 이 논문의 방법이 가장 좋은 결과를 보여주고 있다. Ustev(2013)의 방법은 가속도, 자이로, 자기장 센서를 기반으로 하여 ADL을 측정하였다. Han(2012)의 방법은 가속도 센서와 마이크로폰을 기반으로 활동을 측정하였으나 이 논문과 비교하여 정확도 측면에서 낮게 측정되었다. 그 이유는 마이크로폰의 데이터가 인간 활동을 측정하는데 정확한 분류를 제공하지 못한 측면이 있었다. Anguita(2013)의 방법과 Siang(2018)의 방법은 가속도와 자이로 센서를 이용하여 ADL을 측정하였으나 주로 고도에 관련된 활동(앉다, 서다, 위층 오르기, 아래층 내려가기)에서 오류율이 높았다.

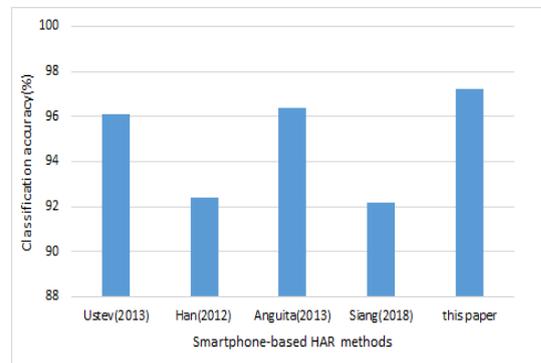


Fig. 4. Comparison of classification accuracy with other methods

이 논문의 연구는 신체 활동을 측정하는 통합 도구를 개발하려는 노력의 결과이다. 이 논문에서는 스마트폰 센서중에서 가속도, 자이로, 기압 센서를 융합하여 높은 정확도로 신체 활동의 일반적인 범주를 분류했다. 이 연구는 가속도를 기본으로 자이로스코프의 방향 판독 값과 기압 값을 융합하여 연구하였으며, 모든 활동을 인식하는데 유의한 것으로 나타났다. 우리의 가설은 자이로스코프와 기압 데이터를 추가하는 것이 전반적인 분류 정확도를 향상시킬 수 있다는 것이었다. 이는 Fig. 4에 나타난 결과에 의해 확인되었다. 거의 모든 활동이 스마트폰의 방향 변경과 고도에 관련되기 때문에 자이로스코프와 기압 데이터가 유용하다. 따라서 가속도 센서는 지정된 방향을 따라 직선 운동만 측정하기 때문에 자이로스코프와 기압 데이터는 가속도에 대한 강력한 보완 데이터 소스가 된다.

## 5. 결론

최근에 HAR 기술에 대한 관심이 높아짐에 따라서 해당 기술에 대한 많은 연구가 이루어지고 있다. 이 논문은 HAR에 대하여 스마트폰의 가속도, 자이로스코프, 기압 센서를 이용하여 측정하고 검증한 연구이다. 이 논문의 결과는 활동 분류를 위한 데이터 소스로 여러 센서를 융합하여 이용함으로써 분명한 이점을 제공하였다. 또한 이 논문에서는 가속도와 자이로 센서에서 추출한 특징들만으로는 분류하기 어려운 비슷한 활동들이 기압 센서를 추가함으로써 분류의 정확성을 높일 수 있다는 것을 확인할 수가 있었다. 그러나 활동 분류에 있어서는 활동성이 큰 활동과 함께 활동성이 작은 활동들을 추가하여 분류하는 것이 필요하다. 따라서 추가 연구에서는 분류되는 활동들을 좀 더 세분화하게 분류하고, 활동들을 더 정확하게 인지하고 분류할 수 있는 새로운 특징들과 그 특징들을 추출할 수 있는 지도 기계 학습 기반의 추출 기법을 연구할 것이다.

## REFERENCES

- [1] W. Liu, X. Li & D. Huang. (2011). A survey on context awareness. *CSSS '11*, 144-147. DOI: 10.1109/CSSS.2011.5972040
- [2] C. L. Y. Siang, G. W. Shin, Y. M. Kim & M. H. Yun. (2018). Human Activity Recognition using Deep Neural Network. *Proceeding of HCI Korea 2018*, 716-720.
- [3] M. Fahim, I. Fatima, S. Lee & Y. T. Park. (2013). Efm: evolutionary fuzzy model for dynamic activities recognition using a smartphone accelerometer. *Applied Intelligence*, 39(3), 1-14. DOI: 10.1007/s10489-013-0427-7
- [4] O. D. Lara & M. A. Labrador. (2012). A mobile platform for real time human activity recognition. *CCNC '12*, 667-671. DOI: 10.1109/CCNC.2012.6181018
- [5] H. Lu, W. Pan, N. D. Lane, T. Choudhury & A. T. Campbell. (2009). SoundSense: Scalable sound sensing for people-centric applications on mobile phones. *MobiSys '09*, 165-178. DOI: 10.1145/1555816.1555834
- [6] L. Liao, D. Fox & H. Kautz. (2007). Extracting places and activities from GPS traces using hierarchical conditional random fields. *International Journal of Robotics Research*, 26(1), 119-134.
- [7] A. Thiagarajan, J. Biagioni, T. Gerlich & J. Eriksson. (2010). Cooperative transit tracking using smart-phones. *SenSys '10*, 85-98. DOI: 10.1145/1869983.1869993
- [8] M. Han, L. T. Vinh, Y. K. Lee & S. Lee. (2012). Comprehensive context recognizer based on multimodal sensors in a smartphone. *Sensors*, 12(9), 12588-12605.
- [9] Y. E. Ustev, O. D. Incel & C. Ersoy. (2013). User, device and orientation independent human activity recognition on mobile phones: challenges and a proposal. *ESSANN 2013*, 1427-1436. DOI: 10.1145/2494091.2496039
- [10] D. Anguita, A. Ghio, L. Oneto, X. Parra & J. L. Reyes-Ortiz. (2013). A Public Domain Dataset for Human Activity Recognition using Smartphones. *In ESSANN 2013*.
- [11] A. M. Khan, M. H. Siddiqi & S. W. Lee. (2013). Exploratory data analysis of acceleration signals to select light-weight and accurate features for real-time activity recognition on smartphones. *Sensors*, 13(10), 13099-13122. DOI: 10.3390/s131013099
- [12] O. Lara & M. Labrador. (2013). A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys Tutorials*, 15(3), 1192-1209. DOI: 10.1109/SURV.2012.110112.00192
- [13] E. H. Shin & N. El-Sheimy. (2002). A new calibration method for strapdown inertial navigation systems. *Dieser Beitragist in der zfv 1/2002 erschienen*, 41-50.
- [14] Google. (2020). *Android SensorEvent: Isolating the Force of Gravity Using a Low-Pass Filter*. Develops [Online]. developer.android.com/reference/android/hardware/SensorEvent.html/

- [15] O. Banos, J. M. Galvez, M. Damas, H. Pomares & I. Rojas. (2014). Window size impact in human activity recognition. *Sensors*, 14(4), 6474-6499.  
DOI: 10.3390/s140406474
- [16] A. S. Greg Milette. (2012). *Professional Android Sensor Programming*. New York : John Wiley & Sons.
- [17] D. Figo, P. C. Diniz, D. R. Ferreira & J. M. P. Cardoso. (2010). Preprocessing techniques for context recognition from accelerometer data. *Personal and Ubiquitous Computing*, 14(7), 645-662.  
DOI: 10.1007/s00779-010-0293-9
- [18] S. Mika, G. Ratsch, J. Weston, B. Scholkop & K. R. Muller. (1999). Fisher discriminant analysis with kernels. *NNSP '99*, 41-48.  
DOI: 10.1109/NNSP.1999.788121
- [19] G. Baudat & F. Anouar. (2000). Generalized discriminant analysis using a kernel approach. *Neural Computation*, 12(10), 2385-2404.  
DOI: 10.1162/089976600300014980
- [20] C. W. Hsu, C. C. Chang & C. J. Lin. (2016). *A practical guide to support vector classification*. CiteSeerX [Online]. [www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf](http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf)
- [21] G. Hackeling. (2017). *Mastering Machine Learning with Scikit-learn*. Birmingham : Packt Publishing.
- [22] J. G. Cho. (2020). A location localization method using Smartphone sensor on a subway. *Journal of the Korea Convergence Society*, 11(3), 37-43.  
DOI : 10.15207/JKCS.2020.11.3.037
- [23] D. Khongorzul, S. M. Lee & M. H. Kim. (2019). OrdinalEncoder based DNN for Natural Gas Leak Prediction. *Journal of the Korea Convergence Society*, 10(10), 7-13.  
DOI : 10.15207/JKCS.2019.10.10.007

## 조 정 길(Jung-Gil Cho)

[정회원]



- 1987년 2월 : 숭실대학교 전자계산학과(공학사)
- 1993년 2월 : 숭실대학교 정보과학대학원(이학석사)
- 2003년 2월 : 충북대학교 전산과(이학박사)
- 2004년 3월 ~ 현재 : 성결대학교 컴퓨터공학과 교수

· 관심분야 : XML 문서관리, 정보 검색, 스마트폰 사용성

· E-Mail : jkcho@sungkyul.ac.kr