

# 스마트폰 내장형 가속도 센서를 이용한 사용자 행위 인식

김주희\*, 남상하\*, 허세경\*, 김인철\*\*

\*경기대학교 컴퓨터학과 학부생

\*\*경기대학교 컴퓨터학과 교수

e-mail:{chilang, namsh, tprudzzang, kic}@kgu.ac.kr

## Activity Recognition with Accelerometer-Embedded SmartPhones

Joo-Hee Kim\*, Sang-Ha Nam\*, Se-Kyeong Heo\*, In-Cheol Kim\*\*

\*Undergraduate Course, Dept of Computer Science, Kyonggi University

\*\*Faculty, Dept of Computer Science, Kyonggi University

### 요 약

스마트폰의 내장형 3축 가속도 센서를 이용한 사용자 행위 인식은 사용자 개개인의 행위 패턴이 모두 달라 사용자에게 따른 의존성이 크고, 스마트폰의 위치나 방향이 일정하게 고정되어 있지 않기 때문에 센서 데이터를 토대로 서로 다른 행위들을 정확히 분류하는데 어려움이 있다. 본 논문에서는 특정 사용자나 스마트폰의 특정 위치에 대한 의존성이 적은 효과적인 행위 인식 방식을 제안하고, 이를 기초로 안드로이드 스마트폰 기반의 실시간 행위 인식 시스템을 구현하였다. 총 6642개의 데이터 집합을 이용하여 본 논문에서 제안한 행위 인식 시스템의 사용자 의존성 및 폰 위치 의존성 분석 실험을 수행하고, 그 결과를 소개한다.

### 1. 서론

인간의 행위 추론은 현재와 미래의 모바일 컴퓨팅에서 필수적인 요소이다. 인간의 행위를 인식하고 이해한다면 신체활동을 모니터링 하여 다양한 서비스를 제공할 수 있다. 예로 매일의 신체활동을 체크하여 의사나 가족들에게 전송해주는 어플리케이션은 사용자의 건강관리나 노인 의료관리에 도움을 줄 수 있을 것이다. 행위 인식을 위해서는 카메라 영상 등 다양한 센서 데이터들을 이용할 수 있지만, 최근에는 가속도 센서 데이터를 이용한 행위 인식에 관한 연구가 활발히 진행되고 있다. 기존 연구들에서는 가속도 센서나 방향 센서, 자이로 센서 등을 몸의 특정 부위에 직접 부착하는 방식을 많이 사용하였으나 이 방식은 비교적 높은 행위 인식률을 얻을 수 있는 장점은 있지만, 착용의 불편함 때문에 자연스러운 실생활 환경에서 사용자 행위를 장시간 모니터링하기에는 제약이 많다. 이에 반해, 스마트폰 내장형 3축 가속도 센서를 행위 인식에 이용할 경우, 착용의 불편함도 없을 뿐 아니라 후대의 편의성으로 인해 스마트폰 사용자의 일상생활 속에서 지속적으로 행위를 감지할 수 있다. 또한, 감지된 사용자 행위 정보를 토대로 유용한 서비스를 스마트폰 앱을 통해 직접 제공할 수도 있으며, 경우에 따라서는 인터넷 통신 기능을 이용해 원격의 응용 서비스 시스템에 전달 가능하다는 장점들이 있다. 하지만 스마트폰 내장형 가속도 센서는 신체 부착형 센서들에 비해 사용자의 신체 움직임을 정확히 포착하기 어렵고, 동일한 행위라도 특정 사용자와 스마트폰

의 특정 위치와 방향에 따라 가속도 센서값이 상이하여 정확한 행위 인식이 어렵다는 문제점을 가지고 있다.

본 논문에서는 특정 사용자나 스마트폰의 특정 위치에 대한 의존성이 적은 효과적인 행위 인식 방식을 제안하고, 이를 기초로 안드로이드 스마트폰 기반의 실시간 행위 인식 시스템을 구현하였다. 사용자 의존성과 스마트폰의 위치 의존성을 줄이기 위해 스마트폰 3축 가속도 센서를 이용하여 3가지의 위치 (손, 바지앞주머니, 바지뒷주머니)로 수행한 6가지의 행위 {정지,걷기,뛰기,계단올라가기,계단내려가기,점프}의 데이터를 수집하였다. 불필요한 데이터를 삭제한 후 각 행위에 대한 특징을 추출하여 해당 데이터를 SVM(Support Vector Machine) 학습 알고리즘을 통해 실시간 행위 인식을 위한 분류기를 생성하였다. 총 6642개의 데이터 집합을 이용하여 본 논문에서 제안한 행위 인식 시스템의 사용자 의존성 및 스마트폰 위치 의존성 분석 실험을 수행하고 그 결과를 소개한다.

### 2. 관련 연구

연구 [1]에서는 나이키+아이팟 스포츠 키트와 아이폰을 이용하여 행위 인식을 하였다. 행위는 {걷기, 달리기, 자전거타기, 앉기} 총 4개로 8명의 실험자가 참여하여 16번 데이터를 수집하였다. 위치는 제한하지 않았고, 전처리 후 데이터를 분류하였다. 특징의 종류는 {나이키+아이팟 패킷페이로드(Packet Payload) 특징, 가속도 크기 관련 특징, 가속도 빈도수 관련 특징} 크게 3가지 종류로 분류할 수 있다. 훈련과 테스트를 같은 데이터로 할 경우 정확도 99.48%, 다를 경우 97.4%의 성능을 보였다. 연구 [2]에서는 스마트폰의 위치, 방향 등의 제한없이 자연스러운 신체활동을 인식하여 사용자의 하루 소비 열량에 대한 모


※ 본 논문은 지식경제부 산업원천기술개발사업(10035348, 모바일 플랫폼 기반 계획 및 학습 인지 모델 프레임워크 기술 개발)의 지원으로 수행되었음.

니터링이 가능하도록 행위와 방향에 대한 데이터를 다양하게 수집하여 진행하였다. {서기, 걷기, 달리기, 자전거타기, 계단 오르기, 계단 내려오기, 드라이브} 총 7개의 행위와 {바지앞주머니, 바지뒷주머니, 자켓주머니, 바지 주머니 [액정이 안쪽방향/바깥쪽방향, 위아래가 정방향/역방향]} 총 7개의 방향을 선택하여 데이터를 수집하였다. 가속도 크기와 값사이의 상관관계도 고려하여 총 22개의 특징을 추출하였다. 이 연구에서는 SVM 알고리즘을 사용하여 분류기를 학습하였고, 평균 93%의 분류정확도를 보였다. 연구 [3]에서는 특정 사용자보다 모든 사용자에게 적용 가능한 모델을 만들기 위하여 29명의 다양한 사용자로 실험하였다. 행위는 {걷기, 달리기, 계단 올라가기, 계단 내려가기, 앉기, 서기} 로 총 6개로 다른 연구와는 다르게 정지를 앉기와 서기로 구분하였고, 스마트폰의 위치는 주머니로 통일하였다. 1초에 20개의 데이터를 수집하여 결정트리(Decision Tree), 신경망(Neural Network) 등의 알고리즘으로 분류하였다. 가속도의 평균, 표준편차, 평균 절댓값 등 총 43개의 특징들을 추출하여 행위 분류에 사용하였다.

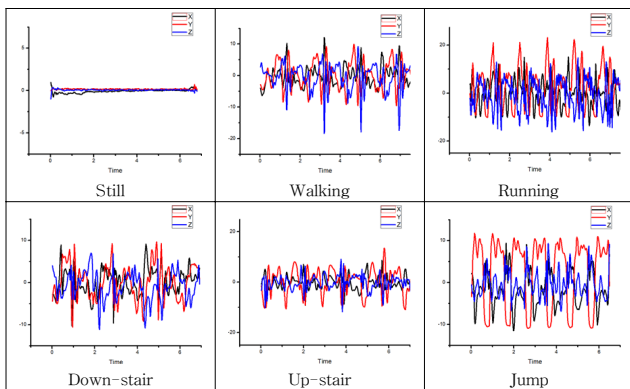
### 3. 사용자 행위 인식

#### 3.1 시스템 개요

본 논문에서는 스마트폰의 3축 가속도 센서를 이용하여 특정 사용자나 특정 위치에 대한 의존성이 적으며 다수의 사용자에게 성능이 견고하여 일반화하기에 유리한 행위인식 방식을 제안한다. 또한 제안한 행위 인식 방식을 바탕으로 실시간 행위 인식 시스템을 구현하였다. 인식 대상 행위들은 (표 1)에서 보는 바와 같이 {정지, 걷기, 뛰기, 계단 내려가기, 계단 올라가기, 제자리 점프}로 총 6개이고, 각 행위들은 일반적으로 (표 2)와 같은 가속도 센서값(X,Y,Z)의 변화 패턴을 보인다.



(표 1) 인식 대상 행위들



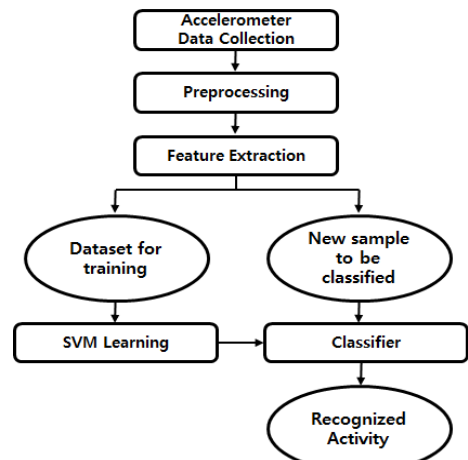
(표 2) 행위 별 가속도 입력 값의 변화

스마트폰 사용자의 6가지 행위 인식은 크게 (그림 1)과 같은 과정을 거쳐 수행된다. 먼저 3축 가속도 센서를 통하여 행위 데이터를 수집하고, 불필요한 데이터를 삭제하는 전처리 과정을 거친다. 그 후 다듬어진 행위 데이터에서 각 행위들을 구분하기에 적합하다고 판단한 특징들을 추


출한다. 다수의 특징 벡터들로 이루어진 입력 파일로부터 SVM 알고리즘을 적용함으로써 행위 분류기를 생성한다. 생성된 분류기에 새로운 실시간 테스트 데이터를 적용함으로써 해당 행위를 판별하게 된다.

#### 3.2 데이터 수집 및 전처리

{X, Y, Z}축의 센서값은 안드로이드 스마트폰의 3축 가속도 센서를 사용하여 안드로이드에서 제공하는 가장 빠른 주기로 읽어 들인다. 가속도 센서값은 실측 약 100Hz의 속도로 행위에 대한 값을 받아 1초에 한 번 66개의 특징으로 이루어진 특징 벡터를 만들어낸다. 특징벡터는 사용자와 행위, 그리고 (표 3)과 같은 {손, 바지 뒷주머니, 바지 앞주머니} 총 3가지의 스마트폰 위치별로 구분되어 스마트폰에 저장된다. 인식되어지는 6가지 행위 데이터는 3명의 실험자가 총 6642개의 특징 벡터를 수집한 것으로 이루어진다.



(그림 1) 사용자 행위 인식 전체 과정



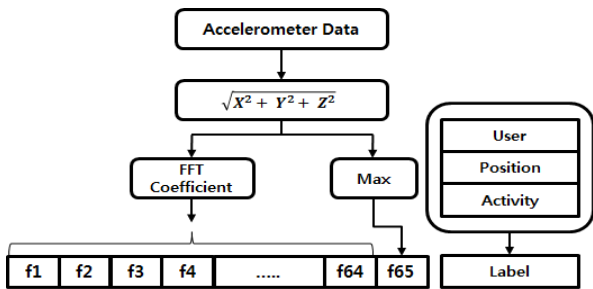
(표 3) 3가지 폰의 위치

훈련 데이터 수집 단계에서 각 행위 데이터안에 포함은 되지만 수집하고자 하는 행위와 관련없는 (예를 들어 수집을 시작하면서 스마트폰을 주머니에 넣는 행위나 수집을 마무리 하기 위해 스마트폰을 주머니에서 꺼내는 행위) 불필요한 데이터를 제거하기 위한 작업이 필요하다고 판단되어, 데이터 수집 후 전처리 작업을 시행하였다. 전처리는 행위와 관련없다고 판단되는 데이터(수집 직후와 수집을 끝내기 직전의 센서 데이터)인 앞/뒤 약 5초가량을 삭제하였다.

#### 3.3 특징 추출

사용자 인터페이스에서 사용자별, 행위별, 스마트폰의 위치별에 따른 라벨을 지정하고 훈련데이터 수집을 시작

하면 (표 2)와 같은 각 축의 순수한 센서값을 읽어들인다. 이 센서값을 (그림 2)에서처럼 가공하여 그 가공된 값으로부터 1초마다 66개의 특징들이 기록된 특징 벡터들이 만들어지게 된다. 추출되는 66개의 특징 중 64개의 특징은 DFT(Discrete Fourier Transform)의 고속 방식인 FFT(Fast Fourier Transform)의 여러 알고리즘 중 DIT(Decimation-in-time) Radix-2 FFT 방법으로 값을 산출한다. DIT Radix-2 FFT는 (식 1) 과 같이 N개 길이의 시퀀스를 보다 작은 길이의 시퀀스로 연속해서 분해함으로써 DFT 연산량을 줄이는 방식 중 분해를 주파수가 아닌 시간 영역에서 하는 방식이다. 우리의 데이터는 시간과 밀접하게 연관된 연속적인 데이터이기 때문에 시간영역의 분해에 따른 방식이 적합할 것으로 판단된다. 그리고 65번째 특징은 3축 센서 최대값으로 이루어지고, 마지막 66번째는 각 부류가 될 라벨로 구성된다. 라벨에는 각 사용자와 각 위치와 각 행위에 대한 구분이 모두 포함되어 있다.



(그림 2) 특징 추출 과정

$$X(k) = \frac{DFT_N[[x(0), x(2), \dots, x(N-2)]]}{2} + W_N^k \frac{DFT_N[[x(1), x(3), \dots, x(N-1)]]}{2} \quad (식 1)$$

### 3.4 분류기 학습 및 인식

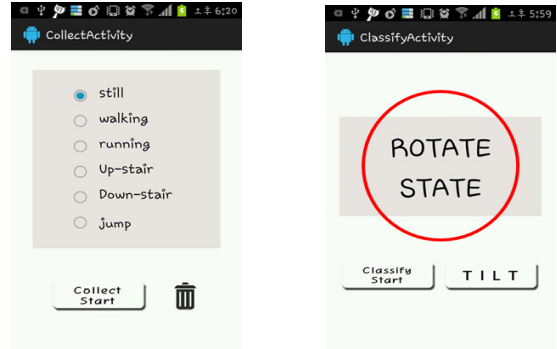
본 논문에서는 스마트폰의 내장형 3축 가속도 센서를 이용하여 행위 데이터를 수집하였고 수집된 데이터에 포함되어 있는 불필요한 데이터를 삭제하는 전처리 과정을 거쳐 특징 벡터 파일을 만들었다. 해당 파일은 특정 사용자가 아닌 다수의 임의의 사용자에게 적용 가능하고, 스마트폰을 자유롭게 소지하여도 성능이 견고한 행위 분류기를 만들고자 하는 연구 목적에 따라 학습하였다.

학습 알고리즘으로는 SVM 알고리즘을 채택하였다. SVM 알고리즘은 분류 문제를 해결하기 위해 최적의 분류 경계면(Hyperplane)을 제공하여 일반화 능력이 높은 알고리즘이다. 인공신경망과 비슷한 수준의 높은 예측력을 나타낼 뿐 아니라 지역 최적화(local optimum)와 같은 한계점들을 완화하는 장점을 가진다. 뿐만 아니라 적은 학습 자료만으로 신속하게 분별학습을 수행하여 실제 응용에 있어서 높은 수준의 성과를 내고 있다. 이처럼 우리의 목적과 상통하는 SVM 알고리즘을 사용하여 학습하였고, 이러한 행위 인식 시스템을 바탕으로 실시간 행위 분류기를 구현하였다.

### 4. 구현 및 평가

우리는 앞서 제시한 방법대로 6가지 행위와 3가지 위치에 대한 데이터를 수집하고, 전처리와 특징추출 단계를 거

쳐 SVM 알고리즘으로 훈련 및 테스트하였다. 또한 그 데이터를 기반으로 실시간 행위 분류기를 구현하였다. 수집기와 실시간 행위 분류기의 사용자 인터페이스는 (그림 3)에서 볼 수 있다. (그림 3)의 (a)는 구현 프로그램의 데이터 수집 화면을 보여준다. 수집하고자 하는 행위를 선택하고 시작버튼을 누르면 행위데이터 수집이 시작되고, 동일 버튼을 한번 더 누르면 데이터 수집을 종료한다.



(a) 데이터 수집 화면 (b) 행위 분류 화면

(그림 3) 구현 프로그램의 실행 화면들

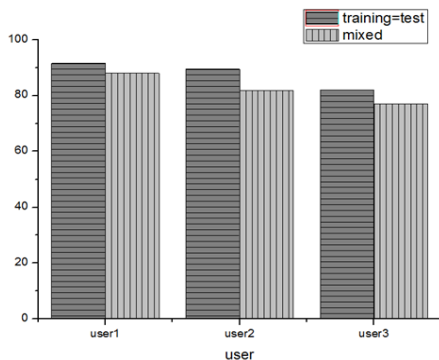
삭제버튼으로 전체 데이터를 삭제할 수도 있다. (그림 3)의 (b)는 실시간 행위 분류기 화면으로, 분류 시작 버튼을 누르고 행위를 수행하면 중앙의 두 번째 텍스트로 현재 수행중인 행위를 인식하여 행위 이름을 출력한다.

훈련과 성능 테스트는 학습 알고리즘들을 다수 제공하고 시각적 분석기능이 뛰어난 데이터마이닝 툴 Weka를 사용하였다. Weka는 데이터 파일에 대한 학습을 수행하고 성능을 테스트할 때 옵션으로 분류기 코드를 생성해준다. Weka에 입력되는 데이터 파일은 릴레이션(relation), 속성(Attribute), 인스턴스(Instance)로 구성된 Arff 파일 형식을 따른다. 본 논문에서 제안한 행위 인식 시스템의 성능을 분석하기 위해 아래와 같은 실험들을 수행하였다.

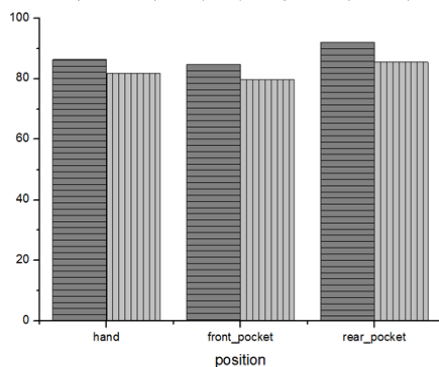
첫 실험에서는 본 논문에서 제안한 행위 인식 시스템의 각 사용자에게 따른 의존성을 알아보기 위해 사용자 의존 성능(user-dependent performance)과 사용자 혼합 성능(user-mixed performance)을 분석하였다. 사용자 의존 성능 측정을 위해서는 3명의 실험자별로 동일 사용자의 데이터를 각각 훈련 데이터 집합과 테스트 데이터 집합으로 나누어 분류 성능을 측정된 뒤, 이들의 평균을 구하였다. 사용자 혼합 성능 측정을 위해서는 3명의 실험자 데이터를 사용자 구분없이 혼합한 뒤, 이 혼합 데이터 집합을 훈련용과 테스트용으로 나누어 분류 성능을 측정하였다. 성능 검증 방식은 데이터를 모두 혼합한 후 k개로 분할하여 테스트에 사용하는 k-분할 검증(k-fold validation)을 사용하였고, 이후의 모든 실험에 대한 검증 역시 같은 방식을 사용하였다. 결과는 (그림 4)의 그래프에서 볼 수 있다. 각 위치별로 평균 84~91%(표준편차 27)의 정확도를 보였고, 사용자를 혼합한 경우에도 그래프에서처럼 이보다 5~6% 정도 낮은 79 ~ 85%의 정확도를 보임으로 특정 사용자에게 구애받지 않고 사용자간 차이에 있어 견고한 정확도를 보인다는 것을 알 수 있다.

두 번째 실험에서는 행위 인식 시스템의 스마트폰 위치에 따른 의존성을 분석하기 위해 각 스마트폰 위치별로 구분된 데이터와 혼합된 데이터에 대한 분류 성능을 측정하여 비교하였다. 결과는 (그림 5) 그래프에서 볼 수 있듯

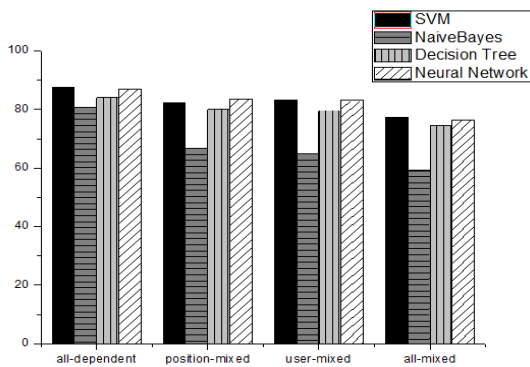
이 사용자들의 각 위치별 정확도는 평균 82~91%(표준편차 1~6)를 보였다. 위치를 모두 혼합하여 데이터를 사용하였을 경우 위치별로 사용한 데이터보다 4~8%로 낮은 76~87%의 정확도를 보였다. 위치에 따른 차이 역시 분류 성능에 큰 영향을 끼치지 않는다는 것을 확인할 수 있다.



(그림 4) 사용자 의존성 분석 결과



(그림 5) 스마트폰 위치 의존성 분석 결과



(그림 6) 학습 알고리즘 별 성능 분석

마지막으로 행위 인식에 사용되는 학습 알고리즘별 성능을 분석하기 위해, 본 연구에서 채택한 SVM 외에 나이브 베이즈(Naive Bayes), 결정 트리(C4.5), 신경망 등의 알고리즘들을 학습에 적용하고, 분류성능을 측정하여 비교하였다. 이 실험을 위해서는 사용자와 스마트폰의 위치를 모두 구분하지 않고 혼합한 데이터 집합을 훈련용과 테스트용으로 나누어 이용하였다. 학습 알고리즘별 성능은 (그림 6)와 같다. SVM 알고리즘은 여러 실험에서 다른 알고리즘에 비해 77~87%의 좋은 성능을 보였다. 나이브 베이즈 알고리즘은 59~80%로 가장 낮은 성능을 보였고, 신경망 알고리즘은 76~86%로 SVM과 비슷한 성능을 보였다. 한편, 이 실험에 나타난 SVM의 77% 분류 성능은 사용자 및 폰 위치의 의존성을 배제한 혼합 분류 성능으로서, 사

용자-의존 방식보다는 10% 가량 분류 성능이 낮지만 이것 역시 높은 분류 성능으로 판단할 수 있다. 지금까지 설명한 성능은 ‘계단올라가기’와 ‘계단내려가기’ 행위가 포함되어 있다. 앞서 예상한대로 이 두 행위는 방향성이 있기 때문에 현재의 특징 추출로는 분류 정확도가 50~60% 정도로 낮다. 이 두 행위에 대한 낮은 정확도의 영향으로 전체 성능이 평균 21% 정도 하향되었다. 두 행위를 제외할 경우 90~96% 까지 성능이 올라가게 된다.

### 5. 결론

본 논문에서는 일반화가 가능할만큼의 사용자 행위 분류 성능향상을 목적으로 스마트폰 내장형 3축 가속도 센서를 이용하여 데이터를 수집하고, SVM(Support Vector Machine) 알고리즘을 통해 각 위치 {손, 바지앞주머니, 바지뒷주머니} 에 따른 6가지의 행위 {정지, 걷기, 뛰기, 계단올라가기, 계단내려오기, 제자리점프}를 효과적으로 분류하는 행위 인식 방식을 제안하였다. 또한 실제 구현한 실시간 행위 인식 시스템과 그 성능도 소개하였다. 그 결과 사용자 및 스마트폰 위치 혼합 분류 성능이 77% 이상으로 확인되었다. 방향성있는 계단 오르내리기를 제외할 경우는 96% 가량의 분류정확도를 보였다.

현재 이용하고 있는 특징은 특별히 방향성을 고려하고 있지 않다. 향후 연구를 통해 방향성 있는 특징들을 개발함으로써 계단 올라가기, 계단 내려가기와 같이 상하 방향성이 중요한 행위에 대한 분류 성능을 개선할 수 있을 것이다.

### 참고문헌

- [1] T. Scott Saponas, Jonathan Lester, Jon Froehlich, James Fogarty, James Landay, "iLearn on the iPhone: Real-Time Human Activity Classification on Commodity Mobile Phones", Proc. of UW-CSE, 2008.
- [2] Lin Sun, Daqing Zhang, Bin Li, Bin Guo, and Shijian Li, "Activity Recognition on an Accelerometer Embedded Mobile Phone with Varying Positions and Orientations", Proc. of Lect Notes in Comput Sci vol. 6406, pp 548-562, 2010.
- [3] Jennifer R. Kwapisz, Gary M. Weiss, Samuel A. Moore, "Activity Recognition using Cell Phone Accelerometers", SensorKDD, 2010.
- [4] A. M. Khan, Y.-K. Lee, S. Y. Lee, T.-S. Kim, "Human Activity Recognition via An Accelerometer-Enabled-Smartphone Using Kernel Discriminant Analysis", Proc. of 5<sup>th</sup> International Conference on FutureTech, 2010.
- [5] Mohd Fikri Azli bin Abdullah, Ali Fahmi Perwira Negara, Md. Shohel Sayeed, Deok-Jai Choi, Kalaiarasi Sonai Muthu, "Classification Algorithms in Human Activity Recognition using Smartphones", International Journal of Computer and Information Engineering vol. 6, pp 77-84, 2012.