

다중 시구간 신경회로망을 이용한 인간 행동 인식

이 현 진*

송실사이버대학교 ICT공학부

Human Activity Recognition using Multi-temporal Neural Networks

Hyun-Jin Lee*

Division of ICT Engineering, Korea Soongsil Cyber University, Seoul 03132, Korea

[요 약]

스마트폰에 내장된 가속도 센서를 이용하여 사용자의 동작 상태나 행동을 인식하기 위한 연구가 다양하게 진행되어 왔다. 본 논문에서는 스마트폰의 3D 가속도 정보에 신경회로망을 적용하여 사람의 행동을 인식하는 연구를 진행하였다. 시계열 데이터를 신경회로망에 그대로 적용하면 성능상의 문제가 발생한다. 따라서 여러 시구간에 대해 특징을 추출하여 각 시구간에 대해 신경회로망을 학습시키고, 이 신경회로망들의 출력들을 입력으로 하여 학습하여 구성하는 다중 시구간 신경회로망을 제안하였다. 제안하는 방법을 실제 가속도 데이터에 적용한 결과 SVM, AdaBoost, IBk 등 다른 분류기보다 우수한 성능을 보였다.

[Abstract]

A lot of studies have been conducted to recognize the motion state or behavior of the user using the acceleration sensor built in the smartphone. In this paper, we applied the neural networks to the 3-axis acceleration information of smartphone to study human behavior. There are performance issues in applying time series data to neural networks. We proposed a multi-temporal neural networks which have trained three neural networks with different time windows for feature extraction and uses the output of these neural networks as input to the new neural network. The proposed method showed better performance than other methods like SVM, AdaBoot and IBk classifier for real acceleration data.

색인어 : 행동 인식, 다중 시구간, 신경회로망, 스마트폰

Key word : Activity Recognition, Multi-temporal, Neural Networks, Smartphone

<http://dx.doi.org/10.9728/dcs.2017.18.3.559>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 12 June 2017; Revised 21 June 2017

Accepted 25 June 2017

*Corresponding Author; Hyun-Jin Lee

Tel: +82-02-708-7863

E-mail: hjlee@mail.kcu.ac

1. 서론

스마트폰 시장이 활성화 되면서, 스마트폰이 기본적인 전화 및 문자 이외에도 게임, 동영상과 같은 멀티 태스킹을 활용하는 수단이 되었다. 또한 다양한 센서의 부착으로 사용자의 신체 활동에 대한 인식을 위해 사용되고 있다[1]. GPS, 가속도, 자이로스코프, 조도, 방향 센서 등 스마트폰 사용자의 위치와 현재 상태를 파악하기 위한 다양한 센서가 사용되고 있으며[2], 앞으로 더욱 많은 센서가 사용될 것이다. 부착형 센서는 손, 발, 가슴 등 다양하고 일정한 위치 부착하여 측정이 이루어 지고, 스마트폰 센서는 사용자의 손이나 주머니, 가방 등 협소한 공간에서 측정이 이루어진다. 부착형 센서는 스마트폰 센서보다 정밀하지만 사용자의 편리성이 저하되어 서비스를 활성화 하는데 장애가 될 수 있다. 하지만 스마트폰 센서는 정밀도는 떨어지지만 이용자의 거부감을 줄일 수 있어서 서비스를 활성화하기 쉽기 때문에 신체 활동 인식 분야에서 연구가 진행되고 있고, 그 성능을 높이기 위한 연구들이 진행되고 있다[3].

본 논문에서는 스마트폰의 가속도 센서를 이용하여 수집된 데이터로부터 인간의 행동을 인식하는 방법을 제안한다. 행동 인식을 위하여 일정 시구간의 가속도 센서 데이터에 대한 이동평균의 통계정보로 입력노드의 수를 축소하며 다양한 시구간 정보를 추출한다. 추출된 시구간 정보를 입력으로 하는 다중 시구간 신경회로망을 구성하여 초단기에서 단기간의 행동 특징을 모두 반영하여 분류 성능을 향상시킨다.

본 논문의 구성은 다음과 같이 구성된다. 2장에서는 행동 인식에 관련된 연구들을 소개하고, 3장에서는 제안하는 방법인 다중 시구간 신경망을 소개한다. 4장에서는 데이터에 적용한 실험결과를 분석하고, 5장에서는 이 연구의 결과와 향후 연구 계획으로 결론을 맺는다.

II. 관련 연구

2-1 행동인식과 스마트폰 센서 관련 연구

Shin 등[4]은 스마트폰 센서를 이용하여 여행 모드(Travel Mode: 기차, 지하철, 자동차 버스 등 구분)를 인식할 수 있는 어플리케이션을 제안하였는데, 여행 모드 간의 가속도 분포가 가우시안(Gaussian)을 따르며, 여행 모드 간에 차가 큰 것을 이용하여 저 전력으로 구성하는 방법을 제안하였다.

Lee 등[3]은 스마트폰 센서 중 가속도 센서를 이용하여 스마트폰의 제스처(왼쪽, 오른쪽, 바깥쪽 등)를 인식하는 시스템을 연구하였다. Shoaib[5]은 스마트폰 센서 중 가속도, 자이로스코프(gyroscope), 자기장 센서 등 이기종 센서들을

사용하여 인간의 행동을 인식하는 시스템을 제안하였다. Anguita 등[6]은 스마트폰 센서에 기록된 데이터를 사용한 공용 데이터 집합을 소개하였으며, 이 데이터 집합을 대상으로 연구된 방법의 성능을 소개하고, Hardware-Friendly SVM (HF-SVM)을 제안하였다. Reiss 등[7]과 Chetty 등[8], Ronao 등[9]은 이 데이터를 이용하여 인간의 행동 인식 알고리즘을 개발하였으며, Reiss 등은 Confidence-based AdaBoost (ConfAdaBoost) 알고리즘을 제안하였다. Chetty 등은 k-최근접 이웃 기반의 Lazy IBk Classifier (IBk)를 제안하였다. Ronao 등은 딥러닝 기반의 Deep Convolutional Neural Networks (convnet)를 이용한 행동 인식 알고리즘을 제안하였다.

Stisen 등[10]은 다양한 스마트폰 센서에 의해 기록된 데이터를 공용 데이터 집합으로 소개하였다. 스마트폰 뿐만 아니라 스마트 시계의 데이터를 측정하여 디바이스를 다양하게 하였고, 측정 주기를 200Hz로 짧게 사용하였다. 이 데이터 집합에 의사 결정 나무, SVM, k-NN 등의 방법으로 행동 인식을 수행하였다.

2-2 분류기

1) 멀티클래스 서포트벡터 머신 (Multiclass SVM)

데이터 분류기로 많이 사용되는 서포트 벡터 머신(Support Vector Machine: SVM)은 생물 정보학, 텍스트 인식, 이미지 인식, 로봇 공학 및 여러 분야에서 다양하게 사용되고 있다. SVM은 커널(kernel)을 사용하여 데이터를 분류하는 것으로, 커널을 이용하여 비선형 문제에 선형 방법론을 적용하여 해결할 수 있다. 하지만, SVM의 성공적인 적용을 위해서는 데이터 전처리와 적절한 커널 선택이 중요하고, 이 작업이 가장 어려운 작업중의 하나이다. SVM은 이진 분류를 기본적으로 수행하지만, One-vs-All 기법을 사용하여 다분류(multiclass)를 수행할 수 있다[6].

2) Lazy IBk Classifier (IBK)

게으른 학습 분류기(Lazy learners classifier)는 분류 시간 동안 실시간으로 학습한다는 원칙을 기반으로 하며 실제로 학습 시간 동안 학습 인스턴스를 저장한다. IBk 분류기는 k-최근접 분류기(k-nearest neighbor)와 매우 유사하다. 이 알고리즘의 학습은 분류 단계에서 기존 데이터중 가장 가까운 거리를 찾기 때문에 느린 경향이 있으며, 다양한 검색 알고리즘을 사용하면 가장 가까운 이웃을 찾는 속도를 높일 수 있다[8]. 또한 선형 탐색 기법이나 kD 트리 또는 커버(cover)트리를 사용하여 성능을 향상시킬 수도 있다. Chetty 등이 사용한 거리 함수는 유클리드 거리 함수이고, 사용된 이웃들의 수는 1이다.

3) Confidence-based adaptive boosting (ConfAdaBoost)

초기 부스팅(boosting) 알고리즘들의 어려움을 해결하기

위하여 에이다부스트(AdaBoost)가 Freud와 Schapire에 의해 소개되었다. 에이다부스트는 SVM과 유사하게 학습 데이터와 약한 분류기(weak classifier)를 반복적으로 호출한다. 모든 데이터에 대해 같은 가중치로 시작하여, 잘못 분류된 데이터의 가중치는 매 반복 단계마다 증가하여, 분류하기 어려운 데이터에 집중할 수 있도록 한다. ConfAdaBoost는 AdaBoost 알고리즘을 신뢰도 기반(confidence-based)으로 확장한 것이다[7]. 기본 방법은 분류기를 학습시 반환되는 약한 분류기의 신뢰도를 인스턴스의 가중치를 계산하기 위해서만 사용 하지만 ConfAdaBoost는 이 신뢰도를 알고리즘의 예측에도 사용한다.

4) 컨볼루션 신경망 (Convolutional Neural Networks)

컨볼루션 신경망 (Convolutional Neural Networks)은 일반적인 신경회로망 (Neural Networks)과 매우 유사하다. 컨볼루션 신경망은 학습 가능한 가중치(weight)와 바이어스(bias)로 구성되어 있다. 각 뉴런은 입력을 받아 내적 연산(dot product)을 수행 한 뒤 선택에 따라 비선형(non-linear) 연산을 한다. 전체 네트워크는 일반적인 신경망 처럼 미분 가능한 하나의 스코어 함수(score function)을 갖는다. 또한 컨볼루션 신경망은 마지막 층에 SVM이나 소프트맥스(Softmax)와 같은 손실 함수(loss function)를 가지며, 일반 신경망을 학습시킬 때 사용하는 각종 기법들을 동일하게 적용할 수 있다. 컨볼루션 신경망의 입력 데이터가 이미지이기 때문에 이미지 데이터가 갖는 특성들을 인코딩(encoding)할 수 있다. 이러한 아키텍처는 포워드 함수(forward function)를 더욱 효과적으로 구현할 수 있고, 네트워크를 학습시키는데 필요한 모수(parameter)의 수를 크게 감소시킬 수 있다. Ronao 등은 이미지에 최적화된 컨볼루션 신경망에 센서 데이터를 직접 입력 데이터로 사용하여 행동 인식에 적용하였다[10].

5) DCNN+

가장 효과적인 딥러닝 알고리즘 중의 하나인 DCNN(Deep Convolutional Neural Networks)은 음성 인식 및 이미지 분류에서 우수한 성능을 보인다. Jiang 등은 센서 데이터를 이미지로 변환한 후 DCNN을 사용한 분류기를 제안하였다[11]. 36 X 68 입력 이미지를 사용하여 두 개의 컨볼루션(Convolution) 층과 2개의 부표본(subsampling) 층을 구성하여 120 차원의 특징 벡터를 출력하는 DCNN 아키텍처를 구성하였다. DCNN의 학습 결과가 모호한 경우에는 SVM을 사용하여 보정받는 DCNN+ 를 제안하였다.


III. 제안하는 방법

3-1 다중 시구간 분석


스마트폰의 센서 데이터는 시계열 데이터이지만, 주기성

이 없다. 시간의 흐름에 따라 데이터가 변화 되는데, ARIMA 와 같은 전통적인 시계열 분석 알고리즘을 사용하면 주기성이 없기 때문에 좋은 성능을 보일 수 없다. 사람의 행동은 참나에 이루어지는 것이 아니라 연속성이 있는 움직임의 결과에 의해서 이루어진다. 즉, 걷다가 계단을 올라갈 때 몇 초 이내의 움직임을 보여야 계단을 올라간 행위가 끝났다고 인식할 수 있다. 따라서, 행동에 대한 센서 데이터는 관측되는 시기마다 독립적인 값이 아니라, 일정 기간의 센서 데이터를 관측해야 움직임을 정확하게 인식할 수 있다.

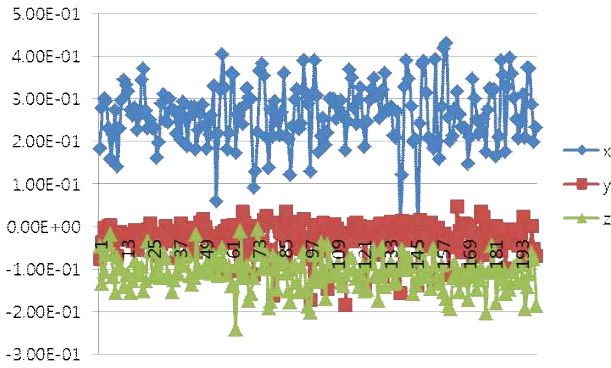
인간의 행동은 행동 종류와 변화에 따라 (그림 1) 과 같이 관측되는 시기마다 다른 패턴을 보인다. 일어서기(standing), 앉기(sitting) 행위와 같은 정적인 행위는 짧은 시간을 관측하거나 긴 시간을 관측해도, 센서 데이터의 변화량은 크지 않기 때문에 100ms 이내의 짧은 시간의 관측으로도 행위를 정확하게 인식할 수 있다. 하지만, 걷기(walking), 오르내리기(upstairs, downstairs)와 같은 동적인 행위는 센서 데이터의 변화량이 크기 때문에, 짧은 시간의 관측보다는 1초 이내의 긴 시간의 관측해야 행위를 정확하게 인식 할 수 있다. 따라서, 성능향상을 위해서는 짧은 시간을 관측하는 모델과 긴 시간을 관측하는 모델을 조합하는 것이 필요하다.




(a) 일어서기에 대한 센서 데이터
(a) Sensor data for standing



(b) 앉기에 대한 센서 데이터
(b) Sensor data for sitting



(c) 걷기에 대한 센서 데이터
(c) Sensor data for walking



(d) 오르기에 대한 센서 데이터
(d) Sensor data for upstairs

그림 1. 일어서기, 앉기, 걷기, 오르기에 대한 센서 데이터 변화 추이

Fig. 1. The sensor data change trend of standing, sitting, walking and upstairs

시계열 데이터를 인식하기 위해서 미가공 데이터를 입력으로 사용하면 입력층의 크기가 커지고 학습이 오래 걸리고, 우수한 인식률을 기대하기도 어렵다. 따라서 입력층의 속성을 일정하게 하고, 관측되는 창의 크기를 달리하여 초단기와 단기의 관측을 반영하여 시구간을 추출 하였다. 창의 크기는 5, 10, 20으로 하였으며, 이는 수집 주기가 50 Hz이므로 각각 0.25초, 0.5초, 1초 간의 움직임에 대한 정보를 나타낸다.

3-2 시구간 추출

제안하는 방법의 시구간 추출은 2단계로 이루어진다. 먼저, 이동 평균을 계산한다. 이동 평균은 창(window)의 크기를 5개, 10개, 20개로 변화하면서 계산하고, 각각의 분류 성능 및 결합을 통한 성능 향상을 위해 사용하였다.

x 는 3D 가속도 센서에서 나온 가속도 데이터를 의미하고, n 은 전체 데이터 크기이고, k 는 이동 평균을 계산하기 위

한 창의 크기 (5, 10, 20)이다. 데이터 내의 임의의 위치 i 에서 이동 평균을 계산하기 위한 x_j 항목이 표시된다. 참조 입력 x_i 를 창의 제일 오른쪽에 위치시킨다. 데이터 집합의 시작과 끝을 제외하면, 창의 크기는 k 가 되고, 참조 입력 x_i 가 데이터 집합의 시작 지점과 끝 지점에 있을 때는 창의 크기로 k 를 가질 수 없기 때문에 그에 따른 조정을 했다. 수식 (1)은 k 개의 데이터에 대한 이동 평균을 계산한 것이다. 여기서, d 는 3D 축인 X, Y, Z를 의미한다.

$$avg_{d_i} = \begin{cases} \frac{1}{k_i} \sum_{j=i-k_i}^i x_j & \text{if } i < k \ (1 \leq k_i < k) \\ \frac{1}{k} \sum_{j=i-k}^i x_j & \text{if } k \leq i \leq n-k \\ \frac{1}{k_i} \sum_{j=i-k_i}^i x_j & \text{if } i > n-k \ (1 \leq k_i < k) \end{cases} \quad (1)$$

수식 (1)과 같은 방법으로 이동 최대값(\max_{d_i})과 이동 최소값(\min_{d_i})을 계산한다. 각 가속 방향 데이터의 이동 최대값과 이동 최소값의 차이는 수식(2)와 같이 계산한다.

$$\begin{cases} D_{x_i} = \max_{x_i} - \min_{x_i} \\ D_{y_i} = \max_{y_i} - \min_{y_i} \\ D_{z_i} = \max_{z_i} - \min_{z_i} \end{cases} \quad (2)$$

가속 방향 간의 차이는 수식 (3)과 같이 계산한다.

$$\begin{cases} D_{a1_i} = D_{x_i} - D_{y_i} - D_{z_i} \\ D_{a2_i} = D_{y_i} - D_{z_i} - D_{x_i} \\ D_{a3_i} = D_{z_i} - D_{x_i} - D_{y_i} \end{cases} \quad (3)$$

그리고, 이동 평균 간의 차이는 수식 (4)와 같이 계산한다.

$$\begin{cases} D_{1_i} = avg_{x_i} - avg_{y_i} - avg_{z_i} \\ D_{2_i} = avg_{y_i} - avg_{z_i} - avg_{x_i} \\ D_{3_i} = avg_{z_i} - avg_{x_i} - avg_{y_i} \end{cases} \quad (4)$$

이러한 과정을 통하여 이동 평균, 이동 최대값, 이동 최소값 9개, 이동 평균 간의 차이인 기울기 자료 9개로 모두 18개의 입력 데이터 속성이 생성된다.

3-3 다중 시구간 신경망의 구성

제안하는 다중 시구간 신경회로망의 구조는 (그림 2)와 같

다. 입력 데이터의 다중 시구간 추출은 창 크기가 5, 10, 20으로 한뒤 이에 대하여 각각 단일 시구간 신경회로망 3개를 구성한다. 이들을 결합하기 위하여 3개의 단일 시구간 신경회로망의 출력을 입력으로 하는 신경회로망을 구성하였다. 이 신경회로망은 단일 시구간 신경회로망의 구조와 동일하게 입력층의 노드는 18개 (단일 시구간의 신경회로망의 출력 6개 X 3 개의 신경회로망), 은닉층의 노드는 60개, 출력층의 노드는 6개로 구성하였다. 각 단일 시구간의 신경회로망은 입력층의 노드는 18개, 은닉층은 1층이면서 노드는 60개, 출력층의 노드는 6개로 구성하였다.

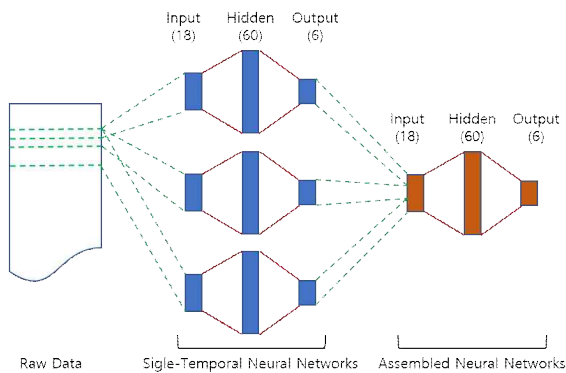


그림 2. 제안하는 다중 시구간 신경회로망의 구성도
Fig. 2. The Proposed Multi-temporal Neural Networks architecture

가중치의 학습은 오류 역전파 (Error Backpropagation) 알고리즘을 사용하였고, 활성화수는 수식 (5)와 같이 로지스틱(Logistic) 함수를 사용하였다.

$$K = \frac{1}{1 + e^{-x}} \quad (5)$$

IV. 실험 방법 및 결과

4-1 데이터 집합

실험에 사용한 데이터는 스마트폰에서 수집된 공개된 데이터이다[5]. 데이터 집합은 걷기(walking), 오르기(upstairs), 내려가기(downstairs), 앉기(sitting), 일어서기(standing), 눕기(laying)의 6가지 행동으로 구성된다. Galaxy S II 스마트폰에서 3D 가속도 센서 (Accelerometer), 3D 자이로스코프 센서의 데이터를 50Hz (20ms 당 1회)로 측정되었고, 그중 3D 가속도 센서의 데이터를 사용하였다. 실험을 위해 70%는 학습 집합으로 30%는 테스트 집합으로 나누었다. 각 데이터는 행동 레이블

(ground-truth)이 포함되어 있고, K-폴드 교차 검증 (k-fold cross-validation)을 사용하여 테스트 성능을 측정하였다.

4-2 제안하는 알고리즘의 성능

제안하는 알고리즘은 단위 시구간에 대한 신경회로망 3개(net5, net10, net20)와 이 신경회로망을 결합한 다중 시구간 신경회로망(net.multi)으로 구성된다. (그림 3)은 네 신경회로망 모델의 학습 결과를 개별 행동 관점에서 재현율(recall)과 정확도(accuracy)를 비교한 것이다.




그림 3. 단위 시구간 신경회로망과 제안하는 다중 시구간 신경회로망의 인식 정확도 비교

Fig. 3. Comparison between three Single-temporal Neural Networks (net5, net10 and net20) and Multi-temporal Neural Networks (net.mult)

(그림 3)에서처럼 성능(accuracy)은 단위 시구간 신경회로망에 있는 창의 크기를 키울수록 향상되었다. 걷기(walking), 오르기(upstairs), 내려가기(downstairs)처럼 센서 움직임의 변화가 큰 동적인 행동의 경우에는 재현율은 단위 시구간 신경회로망의 창의 크기가 증가함에 따라 점점 증가하는 것을 확인할 수 있었다. 하지만, 일어서기(standing), 앉기(sitting)처럼 센서 움직임의 변화가 작은 정적인 행동의 경우에는 재현율은 단위 시구간 신경회로망의 창의 크기가 작을수록 더 우수한 것을 확인할 수 있었다. 단위 시구간 신경회로망을 결합한 제안하는 다중 시구간 신경회로망의 경우에는 이 두 특징들을 모두 수용하기 때문에 전체적인 성능뿐 아니라 개별 행동에 대해서도 높은 성능을 보였다.

<표 1>은 다중 시구간 신경회로망의 분류 결과를 나타내는 혼동 행렬(Confusion Matrix)이다. 정확도와 재현율, 정밀도 (precision)을 보여주고 있다. (그림 3)에서 알 수 있듯이 움직임이 큰 걷기, 오르기, 내려가기에서는 서로 오인식되는 경우를 보이고 있고, 움직임이 작은 일어서기, 앉기, 눕기는 100%의 정확도를 보였다.

표 1. 다중 시구간 신경회로망의 Confusion Matrix

Table 1. Confusion matrix of the Multi-temporal Neural Networks

		Predicted Class					Recall	
		walking	upstairs	downstairs	standing	sitting		laying
Actual Class	walking	495		1			99.8 %	
	upstairs	1	466	4			98.94 %	
	downstairs	1	5	414			98.57 %	
	standing				491		100 %	
	sitting					532	100 %	
	laying						537	100 %
Precision		99.6 %	98.94 %	98.81 %	100 %	100 %	100 %	99.59 %

4-3 성능 비교

인간의 행동 인식을 위한 다른 알고리즘들과 제안하는 알고리즘의 성능을 비교하였다. <표 2>는 동일한 데이터 집합 [6]에 Multi Class SVM (MC-SVM)[5], Lazy IBk Classifier (IBK)[8], Confidence-based adaptive boosting (ConfAdaBoost)[7], Convolutional Neural Networks (Convnet)[10], DCNN+ [11]의 분류 결과이다.

표 2. 다른 분류기와의 성능 비교

Table 2. Performance comparison with different classifiers

Performance	
Algorithms	Accuracy
MC-SVM	96.37 %
IBK	92.98 %
ConfAdaBoost	99.29 %
Convnet	95.75 %
DCNN+	97.59 %
MTNN	99.59 %

제안하는 다중 시구간 신경회로망 (Multi-Temporal Neural Networks, MTNN)은 짧은 시점과 긴 시점의 데이터에 대한 모델을 결합함으로써 인간의 행동을 분류하는데 있어서 우수한 성능을 보였다.

V. 결론

본 논문에서는 스마트폰 센서를 이용하여 효율적으로 인간의 행동을 인식할 수 있는 다중 시구간 신경회로망을 제안하였다. 스마트폰 센서로 측정된 인간의 행동은 움직임의 변화가 큰 동적인 행동은 긴 시구간에서의 관찰이 필요하고, 움직임의 변화가 작은 정적인 행동은 짧은 시구간에서의 관찰이 필요하였다. 이처럼 분류되어야 할 행동이 서로 다른 시구간에서의 관찰을 수행해야 할 경우 제안하는 다중 시구간 신경회로망이 서로 다른 시구간에서의 분류 모델을 생성하고,

이를 결합하는 신경회로망을 구성함으로써 높은 성능을 보일 수 있었다. 특히, 동적인 움직임과 정적인 움직임을 명확하게 분류하고, 각 움직임 사이에서도 높은 분류 성능을 보일 수 있었다.

제안하는 알고리즘은 딥 러닝(Deep Learning)의 적용을 위한 기초단계의 연구이다. 입력에 이동 평균이라는 통계 정보로 시구간 추출을 한 뒤 학습에 적용시켰지만 군집화 기법들을 활용하여 스스로 특징을 추출할 수 있도록 하면, 자율적인 분류가 가능하도록 구성할 수 있다. 또한, 사람에 따라 센서가 움직이는 패턴은 달라질 수 있다. 손에 들고 있는 상태에서 어떤 사람은 거의 손이 움직이지 않고, 어떤 사람은 10 ~ 15도 내외로 흔들면서 이동할 수 있다. 또한 가방에 스마트폰이 있는 경우를 생각해 보면 가방을 고정된 상태에서 움직이는 사람도 있고, 적당히 흔들면서 움직이는 사람도 있다. 따라서 사람에 따라 다른 움직임 특성을 반영할 수 있는 개인화된 신경회로망을 구성방안에 대한 연구가 필요하다.

참고문헌

- [1] D. Anguita, A. Ghio, L. Oneto, X. Parra and J. L. Reyes-Ortiz, "Human Activity Recognition on Smartphones using a Multiclass Hardware-Friendly Support Vector Machine," *International Workshops of Ambient Assisted Living*, Vol. 7657, pp. 216-223, 2012.
- [2] J.Y. Lee and J. S. Kwon, "Error Correction Scheme in Location-based AR System Using Smartphone," *The Journal of Digital Contents Society*, Vol. 16, No. 2, pp.179- 187, 2015.
- [3] M. C. Lee and S. B. Cho, "Accelerometer-Based Gesture Recognition using Hierarchical Recurrent Neural Network with Bidirectional Long Short-Term Memory," *The Journal of KIISE : Software and Applications*, Vol. 39, No. 12, pp. 1005-1011, 2012.
- [4] D. Shina, D. Aliagab, B. Tuncerc, S. M. Arisonad, S. Kim,

D. Zunda and G. Schmitt, "Urban sensing: Using smartphones for transportation mode classification," *Computers, Environment and Urban Systems*, Vol. 53, pp. 7-86, 2015.

[5] M. Shoaib, "Human activity recognition using heterogeneous sensors," in *Proceeding of ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 2013.

[6] D. Anguita, A. Ghio, L. Oneto, X. Parra and J. L. Reyes-Ortiz, "A public domain dataset for human activity recognition using smartphones," in *Proceeding of 21th European Symposium on Artificial Neural Networks, computational Intelligence and Machine Learning*, pp. 24-26, 2013.

[7] A. Reiss, G. Hendeby and D. Stricker, "A Competitive Approach for Human Activity Recognition on Smartphones," in *Proceeding of European Symposium on Artificial Neural Networks*, pp. 455-40, 2013.

[8] G. Chetty, M. White and F. Akther, "Smart Phone Based Data Mining For Human Activity Recognition," *Procedia Computer Science*, Vol. 40, pp. 1181-1187, 2015.

[9] C. A. Ronao and S. B. Cho, "Human activity recognition with smartphone sensors using deep learning neural networks," *Expert Systems with Applications*, Vol. 59, pp. 235-244, 2016.

[10] A. Stisen, H. Blunck, S. Bhattacharya, T. S. Prentow, M. B. Kjærsgaard, A. Dey, T. Sonne and M. M. Jensen, "Smart Devices are Different: Assessing and Mitigating Mobile Sensing Heterogeneities for Activity Recognition", in *Proceeding of 13th ACM Conference on Embedded Networked Sensor Systems*, pp. 127-140, 2015.

[11] W. Jiang and Z. Yin, "Human Activity Recognition using Wearable Sensors by Deep Convolutional Neural Networks," in *Proceeding of the 23rd ACM international conference on Multimedia*, pp. 1307-1310, 2015.



이 현 진

1996년: 순천향대학교 전산학과
공학사
1998년: 연세대학교 대학원 컴퓨터
과학과 공학석사
2002년: 연세대학교 대학원 컴퓨터
과학과 공학박사

2003년~현재: 숭실사이버대학교 ICT공학부 부교수
관심분야 : 기계학습, 빅데이터, 온라인교육