

시분할 특징 융합 합성곱 신경망을 이용한 스마트폰 사용자의 행동 검출

신현준¹ · 광내정² · 송특섭^{3*}

Detection The Behavior of Smartphone Users using Time-division Feature Fusion Convolutional Neural Network

Hyun-Jun Shin¹ · Nae-Jung Kwak² · Teuk-Seob Song^{3*}

¹Researcher, Division of Convergence of Computer and Media, Mokwon University, Daejeon, 35349, Korea

²Assistant Professor, Department of Cyber Security, Baejae University, Daejeon, 35345 Korea

^{3*}Professor, Division of Convergence of Computer and Media, Mokwon University, Daejeon, 35349, Korea

요 약

스마트폰의 보급 이후 웨어러블 디바이스에 대한 관심이 높아지고 다양화되면서 사용자들의 생활에 밀접하게 연 관되고 있으며, 개인화된 서비스를 제공하기 위한 방법으로 사용되고 있다. 본 논문에서는 스마트폰에 내장된 3축 가속도 센서와 3축 자이로 센서의 정보를 합성곱 신경망에 적용하여 사용자의 행동을 검출하는 방법을 제안한다. 인 간의 행동은 동작의 크기와 범위에 따라서 동작을 구성하는 신호 데이터의 지속시간을 포함한 시작 시점과 끝나는 시점이 다르다. 이로 인해 합성곱 신경망에 그대로 적용하면 행동 인식 정확도에 대한 성능상의 문제가 있다. 따라서 센서 데이터를 시간의 구간에 따라 분할된 특징을 학습하는 시분할 특징 융합 합성곱 신경망(TDFFCNN: Time-Division Feature Fusion Convolutional Neural Network)을 제안하였다.

ABSTRACT

Since the spread of smart phones, interest in wearable devices has increased and diversified, and is closely related to the lives of users, and has been used as a method for providing personalized services. In this paper, we propose a method to detect the user's behavior by applying information from a 3-axis acceleration sensor and a 3-axis gyro sensor embedded in a smartphone to a convolutional neural network. Human behavior differs according to the size and range of motion, starting and ending time, including the duration of the signal data constituting the motion. Therefore, there is a performance problem for accuracy when applied to a convolutional neural network as it is. Therefore, we proposed a Time-Division Feature Fusion Convolutional Neural Network (TDFFCNN) that learns the characteristics of the sensor data segmented over time. The proposed method outperformed other classifiers such as SVM, IBk, convolutional neural network, and long-term memory circulatory neural network.

키워드 : 딥러닝, 인공지능, 시계열 데이터 분류, 행동 인식

Keywords : Deep learning, AI, Time-Series Data Classification, Human activity Recognition

Received 12 May 2020, Revised 20 May 2020, Accepted 8 June 2020

* **Corresponding Author** Teuk-Seob Song(E-mail:teukseob@mokwon.ac.kr, Tel:+82-42-829-7635)

Professor, Division of Convergence of Computer and Media, Mokwon University, Daejeon, 35349, Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.9.1224>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

사용자 행동 인식(HAR: Human Activity Recognition)은 다양한 센서를 활용하여 사람의 동작과 관련된 데이터를 수집하고 분석하여 행동을 인식하는 것을 의미한다. 사용자 행동은 인간과 기술이 상호작용하기 위한 필수적인 정보를 제공하며, 신체 활동 정보를 통해 건강 상태를 유추할 수 있어 웰니스, 헬스케어 등의 분야에서 많이 활용되고 있다. 스마트폰의 보급 이후 웨어러블 디바이스에 대한 관심이 높아지고 다양화되면서 생활에 밀접하게 연관되었으며, 실생활에 적용이 간단하며 대량의 데이터를 쉽게 수집할 수 있게 되었다. 따라서 사용자의 행동에 대해 이해하기 위하여 행동 패턴을 분석하고 인식하기 위한 연구들이 이루어지고 있다 [1].

행동 인식에서 가장 중요한 부분은 인식하기 위한 행동의 적절한 패턴 정보를 찾는 것이다. 센서로 측정된 데이터는 시간에 따른 크기를 갖는 신호 데이터로 시간 영역과 주파수 영역에 따른 특징을 갖는다.

행동을 인식하기 위해서는 특징이 가지는 패턴을 사용한다. 유사한 정보를 반복적인 패턴으로 정의되는 저수준 행동의 인식방법에 기계학습이 사용되며, 대표적으로 의사결정트리, 베이지안망, 최근접이웃, 서포트벡터머신, 인공신경망 등이 있다. 기존 기계학습의 데이터는 연구자가 직접 설계한 특징을 사용한다. 때문에 데이터의 종류와 성격에 따라 효율이 달라지며, 설계자에 관점에 따른 특징을 분석에 이용하기 때문에 새로운 데이터에 대응하기 어려우면 일반화된 모델을 생성하기 어렵다. 최근에는 하드웨어와 알고리즘의 발전으로 딥러닝의 성능이 좋아지면서 딥러닝을 이용한 행동 인식 방법에 대한 관심이 높아지고 있다. 딥러닝은 심층신경망을 활용한 기계학습 알고리즘으로 다른 기계학습과 달리 특징을 자동으로 추출하기 때문에 일반화된 모델 학습이 가능하다. 따라서 스마트폰 센서 기반의 사용자 행동 인식 분야에서 많은 연구가 진행되고 있으며, 지도학습을 통해 인식 성능을 높이기 위한 연구가 진행되고 있다 [2].

인간의 행동 패턴을 분석하고 이해하기 위해서는 물리적이며, 가장 기본적인 동작인 정적 동작과 동적 동작을 구분할 필요가 있다 [3]. 본 실험에서는 데이터 집합에 따라서 사용자의 행동에 대한 범위를 서기, 걷기, 달리기, 세 가지 동작과 걷기, 서기, 앉기, 눕기, 계단 오

르기, 계단 내려가기의 여섯 가지 동작으로 정의했다.

본 논문에서는 스마트폰 내장 센서를 통해 수집된 데이터를 이용하여 인간의 행동 검출 방법을 제안한다. 행동 인식을 위해 합성곱 신경망의 딥러닝 알고리즘을 응용하여 입력 데이터의 시간 축을 기준으로 다양한 시분할 특징을 추출하고, 특징 융합 합성곱 신경망(TDFFCNN: Time-Division Feature Fusion Convolutional Neural Network)을 통해 행동을 검출한다.

II. 관련 연구

스마트폰에 내장된 가속도 센서를 이용해 수집한 데이터를 공개했다[4]. 또한 서포트 벡터 머신 (Support Vector Machine)을 이용한 분류 방법을 제안했으며[5], 공개 데이터 집합을 대상으로 한 많은 알고리즘이 연구되었다. 그중 지도학습 알고리즘의 K-최근접 이웃을 응용한 게으른 학습 분류기 (LazyIBk Classifier)[6]를 제안하였으며, 딥러닝 알고리즘의 종류인 합성곱 신경망 (Convolution Neural Network)[7, 8]과 합성곱 신경망을 응용한 DCNN+[9], 분할 정복 기반 1D CNN[10]을 제안하였다.

서포트 벡터 머신은 이미지나 텍스트와 같은 비정형 데이터를 포함한 다양한 분류 문제에 많이 사용된다. 서포트 벡터 머신은 주어진 데이터 집합에서 초평면을 사용하여 데이터를 분류한다. 주로 선형 문제에 대한 이진 분류를 수행하지만, 커널 트릭을 이용해 비선형 문제를 선형 방법론을 적용하여 문제를 해결할 수 있다. 또 One-vs-All 기법을 사용하여 다중 클래스에 대한 분류를 수행할 수 있다[5].

게으른 학습 분류기는 K-최근접 이웃 알고리즘을 응용한 것으로 학습시간 동안 학습 인스턴스를 저장하는 것으로 실시간 학습을 기반으로 한다. 게으른 학습 분류기 알고리즘의 학습은 분류 단계에서 기존 데이터에서 가장 가까운 거리를 찾기 때문에 많은 연산을 요구한다. [6]에서는 K를 1로 설정하고 유클리드 거리 알고리즘을 사용하는 방법을 제안했다.

합성곱 신경망의 동작은 일반적인 신경 회로망(Neural Networks)과 매우 유사하다. 신경 회로망에서는 하나의 노드는 학습 가능한 가중치와 편향으로 구성된다. 이를 합성곱 신경망에서는 영상처리에서 사용되는 필터의

개념으로 가중치가 하나의 값이 아니라 일정한 폭과 높이를 가지는 형태로 적용한 것이다. [8]는 합성곱 신경망에 가속도 센서 데이터 전처리 없이 사용하여 행동 인식에 적용하였다.

DCNN[9]은 신호 데이터를 그대로 사용하지 않고 각 동작에 해당하는 신호 데이터들의 집합을 이미지로 변환하여 합성곱 신경망에 적용하는 방법을 제안하였다. 두 개의 합성곱 레이어와 두 개의 풀링 레이어를 구성하여 120차원의 특징 벡터를 가지고 동작을 분류하며, DCNN[9]의 성능을 개선하기 위해 특징 벡터 대신 SVM을 적용한 DCNN+[9]를 제안하였다. 분할 정복 기반 1D CNN[10]은 독립된 세 개의 합성곱 신경망 모델을 사용해서 행동을 인식하는 방법을 제안했다. 학습 시 세 개의 독립된 모델을 학습시키며, 2단계에 걸쳐 학습한다.

III. 시분할 특징 융합 합성곱 신경망

그림 1은 학습된 모델에 CAM(Class Activation Map) 기법을 적용한 결과의 그림이다. CAM은 모델의 데이터 추론 과정에서 활성화되는 영역을 가시화한 것이다.

그림 2는 제안하는 시분할 특징 융합 합성곱 신경망(TDFFCNN: Time-division Feature Fusion Convolutional

Neural Network)의 전체 구조를 나타낸 그림이다. 제안하는 방법은 입력 데이터를 분할하는 시분할 레이어와 분할된 특징에 대해서 학습하는 합성곱 신경망 그리고 다층의 특징을 가지고 동작을 분류하는 특징 융합 분류기로 구성된다.

3.1. 시분할 레이어(Time-division Layer)

시분할 레이어는 입력 데이터를 시간을 기준으로 분할된 데이터를 학습한다. 스마트폰으로 측정된 센서의 데이터는 시계열 데이터로 주기성이 없으며 시간의 흐름에 따라 변한다. 또한, 사람의 행동은 연속적인 데이터에 의해 정의된다. 인간의 행동은 동작을 구성하는 시간은 서로 다르며, 동작의 시작 시점과 끝나는 시점 또한 다르다. 예를 들어 계단을 올라가는 동작은 앉는 동작에 비해서 지속시간이 상대적으로 길며, 시작 시점과 끝나는 시점 또한 다르게 표현된다. 합성곱 신경망은 데이터 전체 영역에 대해서 특징을 추출하기 때문에 데이터를 그대로 사용하면 좋은 성능이 나오기 어렵다. 따라서 센서 데이터의 전체뿐만 아니라 특정 부분에 해당하는 구간에 대해서도 관찰해야 정확하게 행동을 검출할 수 있다.

그림 3은 데이터 집합에 정의된 행동에 대한 센서 데이터를 그래프로 나타낸 것이다. 사람의 행동은 종류와

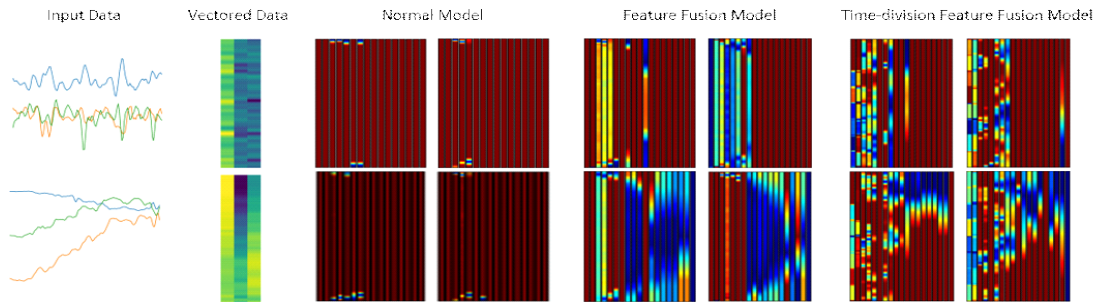


Fig. 1 Apply CAM techniques to Normal model, Feature Fusion Model and Time-division Feature Fusion model




Fig. 2 Overall structure of Time-Division Feature Fusion Convolutional Neural Network

관측 시점에 따라서 다른 특징을 보인다. 일어서기, 앉기와 같은 정적인 행동은 데이터의 변화량이 적기 때문에 짧은 구간을 관측해도 행동을 검출할 수 있다.

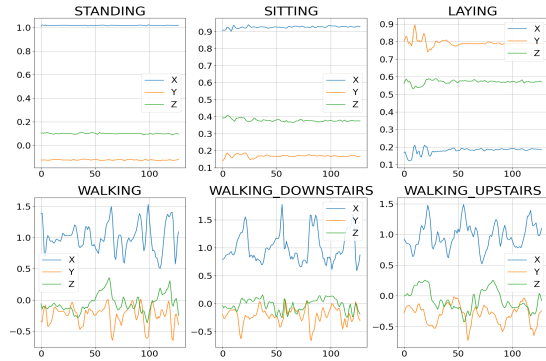


Fig. 3 Sensor data for standing, sitting, lying, walking, walking down stairs and walking up stairs

반면, 걸기, 계단 오르기, 계단 내려가기와 같은 동적인 동작은 데이터의 변화량이 크기 때문에 긴 구간을 관측해야 정확하게 검출할 수 있다. 따라서 특징 추출의 성능 향상을 위해 데이터를 시점에 따라서 분할된 특징을 추출해야 하고, 이를 조합하여 분석할 필요가 있다. 시분할 레이어를 통해 추출된 시분할 정보는 데이터의 전체 영역뿐만 아니라 신호 데이터에서 시간을 기준으로 분할된 정보를 가지고 있으며, 짧은 시간에 이뤄지는 동작까지 수용할 수 있도록 도와준다.

Algorithm 1 Time-division layer

Input: input layer X , division rate K

Output: Result (array of cropped input data)

```

1: function TIME DIVISION( $X, K, N$ )
2:   Result  $\leftarrow$  list()
3:   Shape  $\leftarrow$  data size of  $X$ 
4:   for  $i \leftarrow 0$  to  $K$  do
5:     Pool  $\leftarrow 2^i$ 
6:     Filter  $\leftarrow \lfloor \text{Shape} \times \frac{1}{2} \rfloor$ 
7:   end for
8:   for  $i \leftarrow 0$  to  $K$  do
9:     for  $n \leftarrow 0$  to Pool[ $i$ ] do
10:       $y_1 \leftarrow n \times \text{Filter}[i]$ 
11:       $y_2 \leftarrow n \times \text{Filter}[i] + \text{Filter}[i]$ 
12:      Padding1  $\leftarrow \lfloor 0 - y_1 \rfloor$ 
13:      Padding2  $\leftarrow \lfloor \text{Shape} - y_2 \rfloor$ 
14:      Cropped[ $y_1 : \text{Padding}_1$ ]  $\leftarrow 0$ 
15:      Cropped[ $y_1 : y_2$ ]  $\leftarrow X[y_1 : y_2]$ 
16:      Cropped[ $y_2 : \text{Padding}_2$ ]  $\leftarrow 0$ 
17:      Result  $\leftarrow$  Cropped
18:     end for
19:   end for
20:   return Result
21: end function
    
```

Fig. 4 Algorithm for splitting input data over time in a time division layer

그림 4는 시분할 레이어의 알고리즘으로 시분할 레이어의 동작 과정을 나타낸다. 입력으로 들어온 센서의 신호 데이터를 2^K 개의 같은 크기로 분할한다. 그리고 분할된 2^K 개의 영역은 순서대로 선택되며, 선택된 영역을 제외하고 0으로 채워준다.

그림 5는 시분할 레이어를 통해 학습되는 데이터를 나타낸 그림이다. 학습 시 0인 부분은 상대적으로 가중치의 활성화가 이루어지기 어렵다. 따라서 데이터가 존재하는 영역에서 가중치의 활성화가 많이 이뤄지며, 동시에 데이터 증식의 역할도 수행한다. 이렇게 만들어진 데이터는 채널을 기준으로 연결되고 합성곱 신경망을 통해 학습된다.

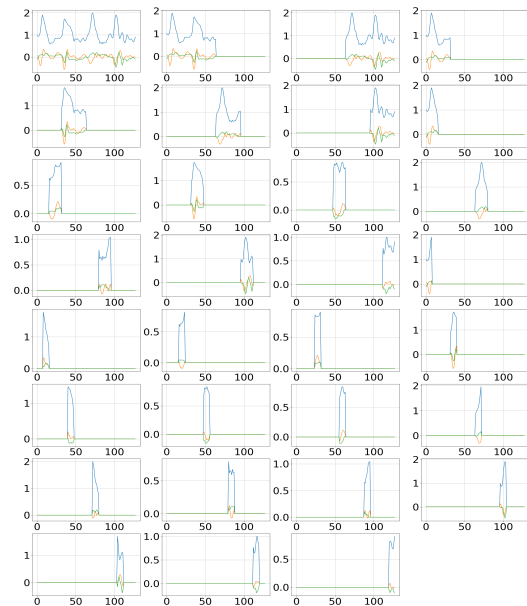


Fig. 5 Results of Time division layers

3.2. 합성곱 신경망 (Convolutional Neural Network)

합성곱 신경망은 시분할 된 데이터의 특징을 학습하는 부분이다. 제안하는 모델에서 사용된 합성곱 신경망의 구조는 두 종류의 모듈로 구성된다. 첫 번째 모듈은 3개의 합성곱 레이어와 다운 샘플링 레이어 1개로 구성되어 있으며, 두 번째 모듈은 2개의 합성곱 레이어와 1개의 다운 샘플링 레이어로 구성된다. 또한 모든 합성곱 레이어는 BN, ReLU, Conv (1×3)로 구성된다. 다운 샘플링 레이어는 합성곱 레이어를 통해서 만들어진 특징에서 가장 큰 수치에 해당하는 값을 이용해 샘플을 추출

하고, 추출된 특징의 사이즈를 줄여준다. 또한 인접한 정보에 대한 미세한 변화를 무시하기 때문에 데이터에 대해서 모델이 과적합 되는 문제를 예방하는 역할을 한다. 샘플링 커널의 크기는 2로 설정하였다.

3.3. 특징 융합 분류기 (Feature Fusion Classifier)

기존의 합성곱 신경망은 설계된 모든 합성곱 레이어와 다운 샘플링 레이어를 통과하고 나온 샘플을 가지고 완전 연결 레이어를 통해서 데이터를 분류하기 때문에 본 논문에서 제안하는 시분할 레이어를 통해서 분할된 데이터에 대한 특징을 적절하게 수용할 수 없는 문제가 있다.

그림 6은 제안하는 방법의 특징 융합 분류기의 구조를 나타낸 그림이다. 특징 융합 분류기는 합성곱 신경망의 Conv3_3, Conv4_3, Conv5_3, FC_7, Conv6_2, Conv7_2 레이어서 추출된 특징을 융합하여 동작을 분류한다. 합성곱 신경망은 깊이가 깊어질수록 특징의 해상도가 작아지며 수용 영역이 작아진다. 따라서 얇은 층의 레이어는 해상도가 크기 때문에 작은 특징에 대한 수용력이 높다. 반면 깊은 층의 레이어는 해상도가 작으므로 큰 특징에 대한 수용력이 크다. 따라서 다층의 특징을 융합함으로써 긴 시구간과 짧은 시구간에 대한 특징을 모두 수용한다.




Fig. 6 Structure of Feature Fusion Classifier

IV. 실험

실험은 두 개의 데이터 집합을 사용했다. K-폴드 교차 검증(K-fold cross validation)을 사용하여 성능을 측정했으며, 학습 데이터와 테스트 데이터는 각각 70%와 30%로 정의하였다.

첫 번째 데이터 집합은 AGBS(Acceleration sensor

and gyro sensor data built into the smartphone)로 실험을 위해 스마트폰에 내장된 3축 가속도 센서와 자이로 센서로부터 직접 측정된 데이터를 사용했다. 행동 범위는 서기(stand), 걷기(walk), 달리기(run)의 3가지 동작으로 정의된다. 각 데이터는 10Hz (100ms마다 1회)로 측정했다.

두 번째 데이터 집합은 UHD(UCI HAR Dataset)로 스마트폰을 이용해 수집된 공개 데이터 집합이다[4]. 행동 범위는 걷기(walking), 오르기 (upstairs), 내려가기 (downstairs), 앉기(sitting), 일어서기 (standing), 눕기 (laying)의 6가지 행동으로 정의된다. 센서의 데이터는 50Hz (20ms마다 1회)로 측정되었고, 그중 가속도 센서의 데이터를 사용하였다.

4.1. 실험 방법

모델을 최적화하기 위해 확률적 경사 하강법을 사용했으며, 관성은 0.9로 감쇠는 0.0001로 설정했다. 300번의 반복 학습을 했으며, 학습률은 10^{-2} 을 시작으로 50, 100, 150, 200, 225의 학습 진행도에 따라 10^{-1} 의 학습률을 감소시켰다. 학습에 사용된 샘플 데이터 집합은 32개를 사용했다.

제안하는 방법은 시구간에 대한 정보를 학습하기 위한 방법으로 시분할 레이어와 특징 융합 합성곱 신경망을 결합한 형태로 구성된다. 시분할 레이어는 입력 데이터를 시구간을 나누는 역할을 하는 레이어이다. 입력 데이터를 1부터 최대 2^k 개의 구간으로 나누고 각각의 데이터는 10개의 특징으로 확장하여 학습에 사용했다. 실험에서는 K를 4로 설정하였으며, 원본을 포함한 33개의 구간으로 분할된 데이터를 학습에 사용했다.

4.2. 실험 결과

제안하는 방법은 시분할 레이어와 연쇄 연결 합성곱 신경망이 결합한 형태로 구성된다.

그림 7은 제안하는 모델에서 시분할 레이어의 적용에 따른 정밀도와 재현율 결과를 비교한 것이다. (a)는 시분할 레이어 시분할 레이어를 사용하지 않은 결과이며, (b)는 시분할 레이어가 적용된 신경망의 결과이다. AGBS 데이터 집합의 경우 걷기, 달리기, 서기 동작으로 동작의 구성이 동적인 동작과 정적인 동작으로 특징이 뚜렷하기 때문에 시분할 레이어를 사용 여부에 상관없이 정밀도와 재현율이 모두 높게 나오는 것을 볼 수 있

다. 반면 UHD 데이터 집합의 경우 시분할 레이어를 사용하지 않은 신경망의 경우 앉기 동작과 일어서기 동작의 정밀도와 재현율이 다른 동작에 비해 상대적으로 낮게 나오는 것을 볼 수 있다.




Fig. 7 Comparison of using time-division layer of algorithm and not using time-division layer.

4.3. 성능 비교

센서 데이터를 이용한 인간의 행동 인식을 위한 알고리즘들과 제안하는 시분할 연쇄 연결 합성곱 신경망 알고리즘의 성능을 비교한다. 표 1은 동일한 공개 데이터 집합을 이용하여 측정된 알고리즘을 성능을 비교했다 [4]. 각각 Multi Class SVM (MC-SVM)[5], Lazy IBk Classifier (IBk)[6], Convolutional Neural Networks (Convnet)[8], DCNN+[9], 분할 정복 1D CNN[10], 제안하는 방법의 분류 결과이다.

제안하는 시분할 특징 융합 합성곱 신경망은 데이터 전체를 포함한 짧은 시점과 긴 시점에 대해 복합적인 특징에 대해 학습함으로써 인간의 행동을 검출하는 데 있어서 우수한 성능을 보였다.

Table. 1 Performance comparison with other classification algorithms

Algorithm	Accuracy
MC-SVM [5]	96.37%
IBk [6]	92.98%
Convnet [8]	95.75%
DCNN+ [9]	97.59%
1D CNN [10]	97.62%
TDFCNN	98.26(±0.55)%

V. 결론

본 논문에서는 스마트폰에 내장된 센서를 이용하여 사용자의 행동을 검출할 수 있는 시분할 특징 융합 합성곱 신경망을 제안하였다. 인간의 행동과 같은 움직임 데이터의 패턴은 시간에 따라 다르게 분석되어야 하는 경우 제안하는 방법을 통해 높은 성능을 보일 수 있었다. 특히, 정적인 동작에서 유사한 특징을 가지는 동작에 대한 성능 향상을 보였다.

제안하는 방법은 딥러닝 알고리즘 중에서 영상 처리에 특화된 합성곱 신경망에 인간의 행동을 측정하는 센서 데이터를 적용하기 위한 기초 단계의 연구이다. 정적인 특성과 동적인 특성 외에도 사용자의 휴대 방법에 의한 다양한 특성도 존재한다. 따라서 휴대 방법에 따라 다르게 측정된 데이터에 대한 특성을 반영하는 방법에 대한 연구가 필요하다.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the Korea National Research Foundation of Korea (NRF) funded by the Ministry of Education in 2018(NRF- 2018R1D1A1B07048675)

References


[1] D. Roggen, G. Troester, P. Lukowicz, L. Ferscha, J. Millan, and R. Chavarriaga, "Opportunistic human activity and context recognition," *IEEE Computer*, vol. 46, no. 2, pp. 36-45, Feb. 2013.

[2] R. A. Voicu, C. Dobre, L. Bajenaru, and R. I. Ciobanu, "Human physical activity recognition using smartphone sensors," *Sensors*, vol. 19, no. 3, pp. 458, Jan. 2019.

[3] S. M. Lee, H. Y. Joe, and S. M. Yun, "Machine learning analysis for human behavior recognition based on 3-axis acceleration sensor," *Information and communication*, vol. 33, no. 11, pp. 65-70, 2016.

[4] 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, Apr. 2013.
- [5] M. Shoaib, "Human activity recognition using heterogeneous sensors," in *Proceeding of ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 1-4, Sep. 2013.
- [6] G. Chetty, M. White and F. Akther, "Smart phone based data mining for human activity recognition," *Procedia Computer Science*, vol. 46, pp. 1181-1187, 2015.
- [7] A. Stisen, H. Blunck, S. Bhattacharya, T. S. Prentow, M. B. Kjærgaard, 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, Nov. 2015.
- [8] 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.
- [9] 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, Oct. 2015.
- [10] H. R. Cho, and S. M. Yoon, "Divide and conquer-based 1D CNN human activity recognition using test data sharpening," *Sensors*, vol. 18, no. 4, pp. 1055, Apr. 2018.



신현준(Hyeon-Jun Sin)

2019년 8월 목원대학교 융합컴퓨터미디어학부 컴퓨터공학과 공학사
※관심분야: 컴퓨터 비전, 컴퓨터 비전, 머신러닝, 딥러닝, 행동인식 및 상황인지



곽내정(Nae-Joung Kwak)

2005년 2월 : 충북대학교 정보통신공학과 공학박사
2005년 3월 ~ 2006년 2월 : 목원대학교 정보통신 공학과 프로그래밍 전문강사
2006년 3월 ~ 2009년 2월 : 목원대학교 정보통신 공학과 강의전임
2009년 3월 ~ 2020년 2월 : 현재 : 충북대학교, 배재대학교 시간강사
2020년 3월-현재 : 배재대학교 AI·SW 창의융합대학 사이버보안학과 강의전임
※관심분야: 영상처리, 멀티미디어 프로그래밍, 컴퓨터 비전, 머신러닝, 딥러닝, 행동인식 및 상황인지



송특섭(Teuk-Seob Song)

2001년 2월 연세대학교 수학과 (이학박사)
2006년 2월 연세대학교 컴퓨터과학과 (공학박사)
2006년 3월 ~ 현재 목원대학교 융합컴퓨터미디어학부 교수
※관심분야: 웹환경 어노테이션, 딥러닝, 센서네트워크