

Detection of Moving Direction using PIR Sensors and Deep Learning Algorithm

Jiyoung Woo*, Jaeseok Yun**

Abstract

In this paper, we propose a method to recognize the moving direction in the indoor environment by using the sensing system equipped with passive infrared (PIR) sensors and a deep learning algorithm. A PIR sensor generates a signal that can be distinguished according to the direction of movement of the user. A sensing system with four PIR sensors deployed by 45° increments is developed and installed in the ceiling of the room. The PIR sensor signals from 6 users with 10-time experiments for 8 directions were collected. We extracted the raw data sets and performed experiments varying the number of sensors fed into the deep learning algorithm. The proposed sensing system using deep learning algorithm can recognize the users' moving direction by 99.2 %. In addition, with only one PIR sensor, the recognition accuracy reaches 98.4%.

▶Keyword: Passive infrared, movement direction detection, deep learning, machine learning, convolutional neural network

1. Introduction

우리는 현재 주위의 모든 사물들이 인터넷 연결성을 가지고 서로 정보를 공유하고 협업하는 사물인터넷 (IoT: the Internet of Things) 시대를 맞이하고 있다 [1]. 이렇게 인터넷에 연결된 물리 또는 가상 사물들로부터 수집되는 데이터들은 수집되는 양에서나 증가하는 속도로 보나 과거 데이터 집합과는 다른 특징을 가지고 있으며 빅데이터 (big data)라는 새로운 이름으로 불리고 있다 [2].

기계 학습 (machine learning)은 컴퓨터에게 많은 예제를 보여주고 학습시켜 인간의 개입 없이 동작할 수 있는 자동화된 기기를 구현하거나, 데이터와 히스토리 안에 내포된 유용한 의미들을 찾아내어 사용자에게 의미 있는 서비스를 제공하는 다양한 방식으로 활용되어 왔다 [3]. 인체로부터 다양한 센서를 기반으로 수집한 데이터를 분석하여 실내 환경에서 사용자가 누구인지 파악하거나, 파악한 사용자의 위치와 이동 방향을 추

적하여 행위를 유추하는 맥락 인지 (context-awareness)는 기계 학습의 대표적인 활용 분야이다 [4].

빅데이터 시대에 맞춰 데이터 분석과 학습을 위해 널리 사용되어 왔던 기계 학습 알고리즘에도 많은 변화와 시도가 이루어지고 있다. 특히 오래전 제안되어 널리 활용되었던 인공 신경망 (neural network)과 강화 학습 (reinforcement learning)은 GPU (graphic processing unit) 하드웨어의 기계 학습 활용성과 함께 눈부신 발전을 이루어, 특정 분야에서는 전문가가 직접 특징을 추출하고 학습 모델을 설계하는 전통적인 기계 학습 알고리즘을 앞서는 성능을 보이고 있다. 딥러닝 (deep learning)으로 대표되는 이 새로운 학습 방법은 특히 방대한 양의 데이터 집합을 분석하고 특징을 찾아내야 하는 빅데이터 응용 도메인에 매우 적합하다고 볼 수 있다.

이러한 흐름에 따라 본 논문에서는 딥러닝 알고리즘을 적용

• First Author: Jiyoung Woo, Corresponding Author: Jaeseok Yun

*Jiyoung Woo (jywoo@sch.ac.kr), Dept. of Bigdata Engineering, Soonchunhyang University

**Jaeseok Yun (yun@sch.ac.kr), Dept. of Internet of Things, Soonchunhyang University

• Received: 2018. 12. 12, Revised: 2019. 02. 18, Accepted: 2019. 02. 18.

• This work was supported by the Soonchunhyang University Research Fund (No. 20180120).

• This work was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education (NRF-2017R1D1A3B03032676).

하여 실내 환경에서 사용자의 이동 방향을 인식하기 위한 방법을 제안한다. 수동 적외선 (PIR: passive infrared) 센서를 활용하여 6명의 사용자를 대상으로 8방향으로 움직이게 하는 과정에서 센서 데이터를 수집하고 수집한 신호를 딥러닝 알고리즘을 적용하여 99% 이상의 방향 인식률을 보였다.

II. Related Works

일반적으로 PIR 센서는 디지털 출력값을 활용하여 모니터 공간 내 재질 감지를 위해 사용되어왔다. 그러나 Lee는 두 개의 센싱 소자로 구성된 PIR 센서가 적외선을 방출하는 오브젝트의 이동 방향에 따라 다른 아날로그 신호를 출력하는 특성을 활용하여 사용자의 이동 방향을 구별할 수 있음을 보였다 [5]. 동일한 특성을 가진 PIR 센서의 아날로그 신호와 기계 학습 알고리즘을 활용하여 사용자의 이동 방향을 인식하는 방법이 제안되었고 [6], 나아가 PIR 센싱 소자의 배열을 이동 방향을 고려하여 배치 시킨 센싱 시스템과 기계 학습 알고리즘을 적용한 사용자 방향 인식 방법이 연구되었다 [7].

지난 수년 동안 딥러닝 알고리즘이 가장 활발하게 적용되고 있는 분야는 이미지 인식과 음성 인식 분야이다 [8, 9]. Ngiam은 텍스트, 이미지, 오디오 데이터를 학습하기 위해 사용되어온 딥러닝 네트워크를 멀티모달 데이터 (오디오와 비디오)에 적용하여 여러 데이터 집합을 이용해 성능을 검증하였다 [10]. Castro는 '자기 중심적' 웨어러블 카메라를 이용해 촬영한 사진들을 이용하여 일상생활에서 행위를 학습하고 예측하기 위해 딥러닝 기법을 사용하였다 [11].

특히 최근들어 센서 기술의 발달로 수집이 가능해진 생체 신호 (biomedical signal)를 분석하기 위해서도 딥러닝 기술들이 연구되고 있다 [12]. Zhang은 생체 신호 기반 사용자 인식을 위해 합성곱 신경망 (CNN: convolutionary neural network) 기반의 딥러닝 기법을 적용한 신호 처리와 특징 추출에 관해 연구하였다 [13]. 제안한 알고리즘을 8개 심전도 (ECG) 신호 데이터 집합에 적용하여 (18-47명의 사용자) 평균 93.5% 인식 결과를 보였다. Schirrmeister는 뇌파도 (EEG) 신호를 해석하고 가시화 하기 위해 CNN을 적용한 딥러닝 기법을 제안하였다 [14]. Everson은 손목 착용형 광용적맥파 (PPG) 센서로부터 수집한 신호를 이용하여 생체 인식을 위한 딥러닝 기반 프레임워크인 BiometricNet을 제안하였다. 해당 시스템은 12명 사용자를 대상으로 96% 인식률을 보였다 [15].

국내에서도 딥러닝을 활용하는 연구가 활발히 이루어지고 있는데 대표적으로, Hong은 CNN 기반 SVM (support vector machine)을 활용하여 해변 안전을 위한 비디오 감시 (video surveillance) 시스템에 적용하여 수영하는 사람을 감지해내는 기법을 제안하고 성능을 검증하였다 [16]. Baek은 OpenCV 이미지 프로세싱 라이브러리와 딥러닝 도구인 텐서플로를 활

용하여 기존의 텍스트 기반 실종자 인텍싱 시스템을 개선한 이미지 기반 인텍싱 시스템을 구현하였다 [17].

관련 연구들을 종합하였을 때 기존 PIR 센서 활용 방법은 이진 출력값을 활용하는 방법이 대부분이나, PIR 센서의 아날로그 출력 신호는 감지된 대상자의 이동 방향이나 센서로부터의 거리 등 사용자 행위에 대한 풍부한 정보를 가지고 있음을 알 수 있다. 또한 생체 신호 센서로부터 수집한 스트림(stream) 데이터 학습에 딥러닝 알고리즘이 수 십명 이상의 피실험자들을 대상으로 높은 성능을 보이고 있음을 알 수 있다.

따라서 본 논문에서는 PIR 센서가 출력하는 디지털 신호가 아닌 아날로그 출력 신호들을 활용하고, 이를 이용해 사용자의 다양한 행위 관련 정보 중에서 움직이는 이동 방향을 딥러닝 알고리즘을 이용해 학습하는 방법을 제안하고자 한다.

III. The Proposed Method

1. PIR sensing system

사용자가 이동할 때 PIR 센서로부터 아날로그 신호를 수집하기 위한 센싱 시스템은 기존 연구에서 제안되어 개발된 모델을 활용하였다. 아래 Fig. 1-(a)에서 보듯이 개발된 센싱 시스템은 4개의 PIR 센서를 가지고 있다. 각 센서의 센싱 소자의 배열 방향이 45°씩 증가하도록 센서를 회전하여 배치함으로써, 각 PIR 센서의 아날로그 출력 신호는 해당 방향으로 사용자가 움직일 때 가장 뚜렷하게 식별 가능한 (distinguishable) 특징을 갖는다. Fig. 1-(b)는 센싱 시스템을 설치한 공간을 나타내며 PIR 센싱 소자의 배치 방향과 일치하는 8개의 움직임 평면 (D_1, \dots, D_8)을 가지게 된다.




Fig. 1. Array of 4 PIR sensors (a) and the monitored field

2. Data collection

위에서 설명한 PIR 센싱 시스템과 National Instrument 데이터 수집 장치를 이용해 실험실 공간에서 데이터를 수집하였다. 사용자가 움직이는 실험 공간은 위 그림에서 보듯이 가로 세로 3.6 미터인 정사각형이며, 6명의 사용자가 실험 공간에서 움직이는 동안 PIR 센서 데이터를 수집하였다. 피실험자들은 원으로 표시된 8개 점에서 8개 (D_1, \dots, D_8) 방향으로 걸도록 지시받았고, 각 방향에 대해 10번의 샘플 데이터를 수집하여 총

480 (6명 * 8방향 * 10번) 세트의 PIR 센서 (480 * 4 센서) 신호를 이동 방향 인식 실험에 활용하였다. Fig. 2는 한 명의 피실험자가 D1 방향으로 걷는 동안 센싱 시스템에서 수집한 신호를 보여주고 있다. 그림에서 보듯이 D1 방향과 같은 방향으로 센싱 소자가 배치되어 있는 1번 PIR 센서가 가장 폭이 큰 변화를 보이고, 2번과 4번은 비슷하지만, 전압값이 부호가 반대로 출력되고 있으며, 이동 방향과 직각으로 센싱 소자가 배치된 3번 PIR 센서가 가장 폭이 작은 아날로그 신호를 출력하고 있음을 알 수 있다.




Fig. 2. The PIR analog signals captured from a participant

위 그림에서 보듯이 PIR 센서의 아날로그 신호는 이동 방향에 따라 변화 폭과 변화 시간이 다른 특징들을 내포하고 있는데 딥러닝 알고리즘에 수집한 원시데이터 (raw data)들을 적용하면 추가적인 전처리 작업이나 특징 추출 작업 없이 이동 방향 인식이 가능하다. 본 논문에서는 인간의 걸음 속도를 고려하여 10 Hz의 샘플링 속도로 데이터 수집 장치를 구동하였고 실험 공간을 약 3초 만에 통과할 수 있기 때문에 각 센서마다 총 30개의 시계열 데이터를 갖는다. 다음 Table 1은 Fig. 2에서 표현한 PIR 센서의 시계열 데이터 일부를 보이고 있으며, 실제 값에서도 센싱 소자 배치 방향과 피실험자의 이동 방향에 따른 신호의 특징들을 확인할 수 있다.

Table 1. A piece of time series data of PIR sensors

PIR_1	PIR_2	PIR_3	PIR_4	Direction
...	D1
-0.8367	-0.0935	0.8192	1.0739	D1
0.3504	0.7422	1.0731	0.0889	D1
2.4513	1.8985	0.6796	-1.9808	D1
2.4517	2.1751	-0.3081	-2.4160	D1
1.1916	-0.4163	-1.4195	-1.6936	D1
-0.7201	-1.3482	-1.2190	-0.1263	D1
...	D1

3. Deep learning algorithms

LeCun은 기존 기계 학습 기술의 한계점을 설명하고 빅데이터를 분석하기 위해 사용할 수 있는 딥러닝의 유용성에 대해서 잘 정리하였다 [18].

전통적인 기계 학습 기법은 데이터 수집-전처리 과정-특징 추출-특징 벡터 기반 학습 과정을 거치고, 학습 방법에 따라 크

게 분류하였을 때 감독 학습 (supervised learning)과 비감독 학습 (unsupervised learning)으로 나뉜다. 이 과정에서 전처리 과정과 특징 추출은 기계 학습에서 필수적이고 학습 성능을 좌우하는 가장 중요한 과정이라고 할 수 있다. 즉 수집한 데이터에 내포된 의미를 가장 잘 표현할 수 있는 특징 (feature)을 찾아내야 하고, 해당 특징을 이용해 학습하고자 하는 개념 (concept)과 가정 (hypothesis)를 가장 잘 표현할 수 있는 계산 모델 (computational model)을 선정하는 것이 중요하다. 그러나 대규모 빅데이터의 데이터 집합을 대상으로 전처리 과정과 특징을 추출하는 과정은 많은 리소스를 요구하고 시간이 소비되는 작업이며, 기존 기계 학습 기법을 적용하기에는 제한적인 부분이 많다. 특히 현대 정보통신 사회에서 빠른 속도로 규모가 커져가는 데이터들 속에서 의미와 패턴을 찾아내고 서비스로 연결하기 위해서는 ‘있는 그대로의’ 원시 데이터 (raw data)를 이용해 스스로 특징 벡터를 추출하고 학습하는 딥러닝 기법이 적합하다고 할 수 있다.

본 논문에서 딥러닝 적용을 위한 응용 분야로 선택한 사용자 이동 방향 인식 시스템의 경우에도, 기존 연구에서는 전통적인 기계 학습 알고리즘 (예, support vector machine)을 활용하기 위해 PIR 센서 신호로부터 전처리 과정을 거쳐 신호의 최대값과 최소값의 크기, 최대값과 최소값의 시간 간격 등을 특징으로 추출하기 위한 수동 작업 (manual engineering)을 수행한다. 그러나 인식이 필요한 사용자의 수가 증가하게 되고, 연속된 시계열 아날로그 신호에서 특정 한 사람의 이동 신호를 잘라내고 특징을 추출하는 작업은 추가적인 작업이 필요하거나 때에 따라서는 매우 어려운 작업이 될 수 있다. 따라서 본 논문에서는 기존 기계 학습 방법이 아닌 딥러닝 알고리즘을 활용하여 다수의 사용자에게도 적용이 가능하고 센서 신호로부터 특징을 자동으로 추출하여 특징 추출이 어려운 경우에도 이동 방향 인식에 강점을 가질 수 있는 시스템을 제안한다.

4. Convolutionary neural network (CNN)

본 연구에서는 많은 이미지 처리 분야에서 좋은 성능을 보여준 합성곱 신경망 (CNN)을 이용하였다. 합성곱 신경망은 은닉 뉴런에서 지역적으로 연결된 여러 데이터만을 고려하여 데이터를 추상화하여 표현이 가능하다.

이미지 처리에 사용되는 합성곱 신경망의 2D 입력 이미지 데이터와 유사한 입력 형식을 가지도록, 네 개 PIR 센서와 10 Hz로 3초간 측정된 30개의 센서 출력값을 (30 * 4) 행렬로 표현하여 시간별 센서값이 블록 단위로 처리될 수 있도록 하였다.

합성곱 신경망은 다음과 같은 구성요소를 가진다.

합성곱 신경망은 이미지 형태의 격자구조의 데이터에서 지역 연결성을 활용하기 위해 합성곱 층을 구성하는데, 격자 형태의 데이터에서 일부만 추출하는 필터를 이용하여 지역적으로 가까운 데이터를 추출하여 특징을 추상화한다.

본 연구에서 사용한 센서 데이터의 경우에도 시간의 연속성과 네 방향 센서가 관련성을 가지기 때문에 합성곱 신경망은

본 연구의 데이터에 적합한 구조이다. 시간을 세로 축, 센서의 종류를 가로축으로 하여, 시간의 흐름에 따라 발생하는 센서값이 지역적으로 연결될 수 있도록 하였다. 센서의 경우에는 네 가지 센서를 방향성이 가까운 순서대로 배치되도록, PIR_1, PIR_2, PIR_3, PIR_4 순으로 배열하였다.

Fig. 3은 사용자 이동 방향 인식을 위해서 제안한 합성곱 신경망을 구성하는 각 계층들을 설명하고 있다.




Fig. 3. The component layers of the proposed CNN

합성곱 신경망의 필터는 30 * 4의 데이터에서 일부 데이터만을 추출하도록 4 * 3 크기 필터를 사용하였다. 합성곱 신경망에서는 다수 필터를 겹쳐서 연속으로 사용할 수 있는데, 본 연구에서는 첫 번째 합성곱 계층에서는 150개, 두 번째 합성곱 계층에서는 100개의 필터를 사용하였다 (Fig. 3의 좌상단).

합성곱 신경망의 가중치 개수와 전체 계산량을 줄이기 위해 필터를 통해 추상화된 데이터의 크기를 줄여주는 풀링 계층 (pooling layer)를 사용한다. 본 연구에서는 최대값 풀링 방법 (max pooling)을 이용하였다 (Fig. 3의 우상단).

또한 일부 노드를 사용하지 않는 탈락 계층 (dropout layer)을 두었다 (Fig. 3의 좌하단). 탈락 계층은 신경망의 훈련을 위해 사용되는 예제들에 대해 과적합 (overfitting)이 일어나는 것을 방지하기 위함이 목적이다. 마지막 단계에서는 모든 노드가 결과 계층 (output layer)으로 연결될 수 있도록 하는 완전 연결 계층을 두었다 (Fig. 3의 우하단).

Fig. 4는 제안된 합성곱 신경망을 이용해 사용자 이동 방향 인식을 위해 데이터가 처리되는 전체 프레임워크를 보인다. 아래로부터 보았을 때 네 개의 PIR 센서로부터 수집한 데이터 집합이 합성곱 계층을 통해 추상화되어 표현되고 계산량과 시간을 줄이기 위해 최대값 풀링과 추가 합성곱 계층을 통과한다. 과적합을 막기 위한 탈락과 전체 연결 계층을 통과하여 마지막 출력 계층에서는 값을 얻기 위해 Sigmoid 함수를 사용한다.

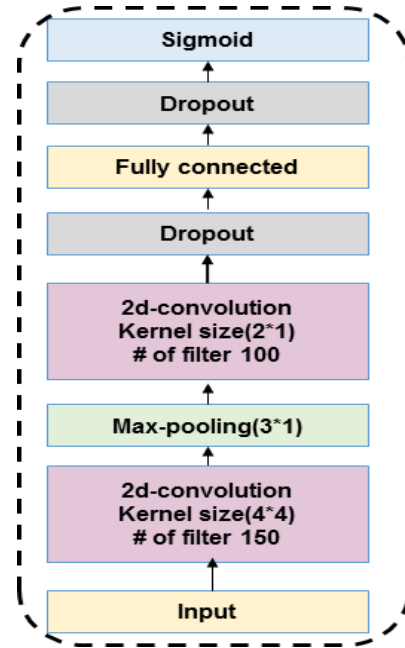


Fig. 4. The framework of the proposed CNN

IV. Experimental Results

기존 이동 방향 인식 연구에서는 PIR 센서 별로 변수를 생성하고 (즉, 네 개 PIR 센서로부터 초당 10 Hz로 샘플링한 값 * 3초) 이 값들을 변수화하여 총 120개의 변수를 토대로 기계 학습 알고리즘을 적용하였다.

딥러닝을 적용한 본 연구에서도 기존 연구와 동일한 방식으로 실험을 하고 성능 비교 평가를 할 수 있도록 480개의 데이터 집합을 대상으로 10-fold 교차 검증을 하였고, 난수를 생성하여 데이터 세트 분할 과정을 10번 수행하여 총 100번의 반복실험을 진행하였다. 10-fold 교차 검증에서는 방향별로 60개 (6명 * 10회 반복실험)의 데이터가 골고루 선정되도록 하였다. 전체 데이터의 90%를 학습에 사용하였고, 10%를 검증하는데 사용하여, 검증 데이터에 대한 정확도를 산출하였다.

합성곱 신경망 훈련을 위해서는 학습 반복 수를 50으로 설정하였고, 1회 학습에 사용되는 데이터의 개수는 세 개로 하였다. 학습 반복 수를 높이면 학습 데이터에 대한 출력 정확도는 높게 나오지만 검증 데이터에 대한 정확도가 떨어지는 과적합 문제가 발생하는 것을 발견하였다.

이동 방향 인식 정확도 (recognition rate)는 100번 반복실험 (10-times 10-fold) 과정에서 검증 데이터에 대한 인식률의 평균으로 구하였다. 특히 적용된 PIR 센서의 배치 방향과 인식 정확도 변화의 상관관계를 파악하기 위해 데이터 집합에서 적용된 PIR 센서의 번호를 Fig. 5에서 보이는 바와 같이 변경하면서 실험을 반복하였다. 선정된 다섯 종류의 PIR 센서 배치 조합을 Table 2에서 보여주고 있다.

Table 2. The selected PIR sensor sets for experiments

	PIR sensors involved in each sensor set
Set 1	PIR_1
Set 2	PIR_1, PIR_3
Set 3	PIR_2, PIR_4
Set 4	PIR_1, PIR_2, PIR_3
Set 5	PIR_1, PIR_2, PIR_3, PIR_4




Fig. 5. Deploying raw data of the PIR sensors with respect to the selected sensor sets

Table 3은 3장에서 제안된 합성곱 신경망에 수집한 PIR 센서 데이터 집합을 적용하여 실험한 결과를 보여주고 있다. Table 2에서 보인 다섯 가지 센서 조합에 따라 이동 방향 인식 실험을 수행하였고 기존 연구에서 발표된 전통적인 기계 학습 알고리즘을 사용한 인식 결과와 본 논문에서 제안한 합성곱 신경망의 성능을 비교 분석하였다.

두 개 이상의 PIR 센서에 SVM 알고리즘을 적용한 사례와 비교했을 때 합성곱 신경망의 인식률 결과가 거의 비슷하거나 다소 낮지만, ‘하나의’ PIR 센서만 적용했을 때에는 제안한 딥러닝 알고리즘이 훨씬 높은 인식률을 보임을 알 수 있다.

SVM은 시간별 각 센서의 값을 독립적인 변수로 간주하고, 모든 변수를 고차원의 영역으로 투영하여 각 클래스를 구분하는 초평면 (hyper plane)을 도출하는 방식이다. 반면 합성곱 신경망은 특정 구간 (예로서 네 개의 PIR 센서를 적용했을 경우 네 번의 샘플링 구간)의 센서값을 종합하고, 두 개 이상의 센서가 있을 때 해당 센서값들을 종합하여 사용하는 방식을 이용하였다. Fig. 2에서 보는 것과 같이 한 방향에 대해 네 개의 센서가 서로 다른 형태의 신호를 보내는데, 합성곱 신경망에서 필터를 이용해 이를 하나의 값으로 풀링하여 사용하게 되면 각 센서의 값이 상이하다는 속성을 다소 잃기 때문인 것으로 보인다. 하지만 1개의 센서를 이용하는 경우는 경우에도 성능이 높게 나오는 것으로 보아, 시간에 따른 값에 필터를 씌워 풀링하는 것의 효과는 크다고 할 수 있다.

본 실험에서 SVM이 합성곱 신경망보다 높은 인식률을 보이는 이유는 모든 피실험자의 수집 데이터로부터 이동 방향을 잘

인식할 수 있는 신호 영역을 찾아내고 특징을 추출하는 수동 작업의 효과라고 판단할 수 있다. 즉, 각 실험마다 이동 방향에 맞게 최대 진폭 변화를 보이는 센서와 해당 구간의 신호를 추출하여 특징값으로 이용했기 때문이다. 하지만 하나의 센서만을 사용한 경우에는 이동 방향에 따라 신호의 진폭 변화가 줄어들고 따라서 인식 정확도가 감소하게 된다.

Fig. 6은 한 명의 피실험자가 8개 방향으로 움직일 때 센서 한 개만 (PIR_1)을 이용하여 수집한 센서값들을 보여주고 있다. 그림에서 보듯이 이동 방향 1, 3, 8과 2, 4, 7에 따른 센서 신호가 비슷한 양상을 보이는 것을 알 수 있다. 센서값만을 SVM 등 전통적인 기계 학습에 사용하는 경우 신호가 비슷하게 나타나는 방향에 대한 인식률이 떨어지게 되는데, 이러한 문제는 합성곱 신경망을 적용하여 해결 가능한 것을 알 수 있다. 다시 말해서, Fig. 6을 살펴보면 센서값이 증가 또는 감소하는 시점은 각 이동 방향마다 조금씩 다름을 알 수 있다. 합성곱 신경망의 경우 센서값에서 다양한 특징을 자동으로 추출하는데, 그 과정에서 SVM 연구에서 사용하지 않았던 센서값 변화 시점들을 특징으로 찾아내고 활용했기 때문에 한 개의 센서만으로도 좋은 성능을 보인 것으로 판단할 수 있다.

Table 3. Recognition performance with respect to the selected PIR sensor sets

	PIR_1	PIR_1,3	PIR_2,4	PIR_1,2,3	PIR_1,2,3,4
Bayes net	81.19	94.60	98.69	97.64	97.92
Decision table	72.77	82.73	84.13	82.58	83.75
Decision tree	86.44	93.63	97.19	97.15	97.77
Instance-based learning	89.04	97.40	98.67	98.15	98.75
Multilayer perceptron	84.42	97.38	98.33	98.44	99.00
Naive bayes	74.92	91.88	96.98	94.98	98.04
Support vector machine	80.04	98.29	98.67	99.08	99.52
CNN	96.01	98.02	98.04	98.08	98.12




Fig. 6. The PIR_1 sensor signals captured from a participant moving in eight directions

V. Conclusions

기계 학습은 이미지와 영상, 텍스트와 손글씨, 음성과 소리, 생체 정보 등 데이터 획득이 가능한 거의 모든 분야에서 특정 패턴 인식, 데이터 연관 관계 추출, 상황 예측, 자동 분류, 특이 상황 감지 등 인간의 지능을 대신할 수 있는 컴퓨터 시스템을 구축하는데 핵심적인 역할을 수행해 왔다. 그러나 데이터 크기가 비약적으로 커지고 증가 속도도 매우 빨라지는 빅데이터 시대에는 전통적인 기계 학습 방법을 적용하기에는 제한적인 부분이 많다. 특히 GPU 등 하드웨어의 발달로 빠른 연산이 가능해지며, 다층 신경망 (multilayer neural network)과 같이 과거에 제안되어 활발히 사용되었지만 최근에는 비교적 많은 관심을 받지 못했던 기계 학습 기법들이 재조명되고 빅데이터 분석에 맞추어 변형된 합성곱 신경망 등 딥러닝 알고리즘이 활발히 연구되고 있다.

본 논문에서는 PIR 센서의 아날로그 신호를 이용해 사용자 이동 방향을 인식할 수 있는 방법을 제안한다. 전통적인 기계 학습에서 필수적인 전처리 과정과 특징 추출 없이 원시 데이터를 바로 입력값으로 이용하여 자동으로 특징을 추출하고 인식을 수행하는 합성곱 신경망을 설계하고 구현하였다.

6명의 피실험자로부터 네 개의 센서 별로 10 Hz 샘플링 속도로 3초 동안 수집한 PIR 신호를 가지고 120개 (= 센서 4 * 10Hz * 3초) 값을 가지는 시계열 데이터 세트를 토대로 합성곱 신경망에 적용하였다. 120개의 시계열 센서값을 30 * 4의 행렬로 표현하여 이미지처럼 블록 단위로 처리될 수 있도록 하였다. 일반적인 합성곱 신경망과 동일하게 합성곱 계층, 풀링 계층, 탈락, 완전 연결 계층 등을 이용하여 신경망을 구성하였다.

실험 결과 기존 연구에서 네 개의 PIR 센서에 SVM 알고리즘을 이용하여 얻은 99.5%보다는 다소 인식율이 떨어지지만, 한 개의 PIR 센서만을 사용해 얻은 결과보다는 훨씬 높은 성능을 보임을 알 수 있다. 이와 같은 실험 결과를 통해 딥러닝 특히, 본 논문에서 제안한 합성곱 신경망은 이동 방향에 따른 단일 PIR 센서값의 진폭 변화뿐만 아니라 신호의 증가 또는 감소 시점 등을 특징으로 자동 추출하여 인식에 사용하여 좋은 성능을 보였음을 유추할 수 있다.

본 연구에서는 6명의 피실험자를 대상으로 테스트를 수행하였지만, 추후 PIR 센싱 시스템을 Wi-Fi 등 주변 네트워크에 연결하여 실시간으로 데이터를 수집할 수 있는 환경이 되면, 많은 사용자를 대상으로 확대하여 적용해 볼 수 있다. 사용자 수가 많아지게 되면, 제안하는 딥러닝 모델의 대용량 처리능력이 전통적인 기계 학습 방법보다 상대적으로 높은 수준의 결과를 보일 것으로 예상할 수 있다.

향후 연구에서는 딥러닝 모델 중 다른 모델을 적용해 보고자 한다. 사용한 데이터는 시간의 흐름에 따라 수집되는 스트림 데이터이기 때문에 데이터의 발생 순서를 고려하는 recurrent neural network (RNN)의 적용을 고려해 볼 수 있다. 본 연구에서는 각 센서의 값이 독립적이지 않고, 센서가 90도 증가하

도록 배치하여 센서간 연관성이 있기 때문에 CNN을 사용하였다. 즉, 여러 센서의 값을 합쳐서 사용하는 것이 가능하다고 판단되어 그 효과를 파악하고자 CNN을 사용하였다. 필터 사이즈를 조정하면서 실험해본 결과, 센서의 값을 종합하지 않을 때보다 (4 * 1 사이즈 필터) 네개의 센서값을 종합하여 (4 * 4 사이즈 필터) 사용하는 경우가 성능이 더 높게 나타나 CNN이 효과적임을 알 수 있다. 향후 연구에서 하나의 센서만으로 CNN과 RNN의 성능을 비교해보고자 한다.

REFERENCES

- [1] L. Atzori, A. Iera, and G. Morabito, "The Internet of Things: A survey," *Computer Networks*, vol. 54, no. 15, pp. 2787-2805, October 2010.
- [2] X. Wu, X. Zhu, G.-Q. Wu, and W. Ding, "Data Mining with Big Data," *IEEE Transactions on Knowledge and Data Engineering*, vol. 26, no. 1, pp. 97-107, January 2014.
- [3] F. Pedregosa et al., "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, no. , pp. 2825-2830, October 2011.
- [4] G. D. Abowd, A. K. Dey, P. J. Brown, N. Davies, M. Smith, and P. Steggles, "Towards a Better Understanding of Context and Context-Awareness," *Proceedings of the 1st International Symposium on Handheld and Ubiquitous Computing (HUC 1999)*, pp. 304--307, Karlsruhe, Germany, September 27-29 1999.
- [5] W. Lee, "Method and Apparatus for Detecting Direction and Speed using PIR sensor," U.S. Patent No. 5,291,020, March 1994.
- [6] P. Zappi et al., "Tracking Motion Direction and Distance With PIR Sensors," *IEEE Sensors Journal*, vol. 10, no. 9, pp. 1486--1494, September 2010.
- [7] J. Yun and M.-H. Song, "Detecting Direction of Movement using PIR Sensors," *IEEE Sensors Journal*, vol. 14, no. 5, pp. 1482-1489, May 2014.
- [8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Advances in Neural Information Processing Systems 25*, pp. 1097-1105, 2012.
- [9] G. Hinton et al., "Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups," *IEEE Signal Processing Magazine*, vol. 29, no. 6, pp. 82--97, October 2012.
- [10] J. Ngiam, A. Khosla, M. Kim, J. Nam, H. Lee, and A. Ng, "Multimodal Deep Learning," *Proceedings of the 28th International Conference on Machine Learning (ICML '11)*,

- pp. 689--696, Bellevue, Washington, USA, June 2011.
- [11] D. Castro, S. Hickson, V. Bettadapura, E. Thomaz, G. Abowd, H. Christensen, and I. Essa, "Predicting Daily Activities From Egocentric Images Using Deep Learning," Proceedings of the 18th International Symposium on Wearable Computers (ISWC '15), pp. 75--82, Osaka, Japan, September 7-11 2015.
- [12] K. Sundararajan and D. L. Woodard, "Deep Learning for Biometrics: A Survey," ACM Computing Surveys, vol. 51, no. 3, pp. Article No. 65, July 2018.
- [13] Q. Zhang, D. Zhou, and X. Zeng, "HeartID: A Multiresolution Convolutional Neural Network for ECG-Based Biometric Human Identification in Smart Health Applications," IEEE Access, vol. 5, no. , pp. 11805--11816, 2017.
- [14] R. T. Schirrmester, J. T. Springenberg, L. D. J. Fiederer, M. Glasstetter, K. Eggenberger, M. Tangermann, F. Hutter, W. Burgard, and T. Ball, "Deep learning with convolutional neural networks for EEG decoding and visualization," Human Brain Mapping, vol. 38, no. 11, pp. 5391--5420, November 2017.
- [15] L. Everson, D. Biswas, M. Panwar, D. Rodopoulos, A. Acharyya, C. H. Kim, C. V. Hoof, M. Konijnenburg, and N. V. Helleputte, "BiometricNet: Deep Learning based Biometric Identification using Wrist-Worn PPG," IEEE International Symposium on Circuits and Systems (ISCAS '18), pp. 1--5, Florence, Italy, May 27-30 2018.
- [16] D. Hong, Y. Kim, "Efficient Swimmer Detection Algorithm using CNN-based SVM. Journal of The Korea Society of Computer and Information, 22(12), 79-85.
- [17] Y.-T. Baek, S.-H. Lee, J.-S. Kim. (2017). Intelligent missing persons index system Implementation based on the OpenCV image processing and TensorFlow Deep-running Image Processing. Journal of The Korea Society of Computer and Information, 22(1), 15-21.
- [18] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," Nature, vol. 38, no. 7533, pp. 436-444, 2015

Authors



Jiyoung Woo received the B.S., M.S., and Ph.D. degrees in industrial engineering from KAIST in 2000, 2002, and 2006, respectively. From 2008 to 2010, she was a Researcher with the Artificial Intelligence Laboratory, Arizona University, USA.

From 2010 to 2016, she was a Research Professor with the Graduate School of Information Security, Korea University. She is currently a Professor with the Big Data Engineering Department, Soonchunhyang University. Her research interests include data mining and business intelligence.



Jaeseok Yun is an assistant professor with the Department of Internet of Things at Soonchunhyang University. Prior to his current position, he worked as a senior researcher with the IoT Platform Research Center at Korea Electronics Technology

Institute (KETI) from 2009 to 2016. He also worked as a postdoctoral research scientist with the Ubiquitous Computing Research Group in the School of Interactive Computing at Georgia Institute of Technology, GA, USA from 2006 to 2009. He received his B.S. degree in Electronics Engineering from Chonnam National University in 1997. He also earned his M.S. and Ph.D. degrees in Mechatronics from Gwangju Institute of Science and Technology (GIST) in 1999 and 2006, respectively. His research interests include ubiquitous computing, Internet of Things, machine learning, and intelligent systems.