

치매 환자를 위한 딥러닝 기반 이상 행동 탐지 시스템[☆]

Deep Learning-based Abnormal Behavior Detection System for Dementia Patients

김 국 진¹ 이 승 진¹ 김 성 중¹ 김 재 근¹ 신 동 일¹ 신 동 규^{1*}
Kookjin Kim Seungjin Lee Sungjoong Kim Jaegeun Kim Dongil Shin Dong-kyoo shin

요 약

고령화로 인해 증가하는 노인 비율만큼이나 치매를 앓는 노인 수 또한 빠르게 늘고 있는데 이는 사회적, 경제적 부담을 발생시킨다. 특히, 간병인의 근무 시간 손실 및 간호 부담으로 인한 의료 비용 증가와 같은 간접비용을 포함하는 치매 관리 비용은 수년에 걸쳐 기하급수적으로 증가하고 있다. 이러한 비용을 줄이기 위해 치매 환자를 돌보기 위한 관리 시스템 도입이 시급하다. 따라서 본 연구는 항상 치매 환자를 돌볼 수 없는 환경이나 독거노인을 관리하기 위한 센서 기반 이상 행동 탐지 시스템을 제안한다. 기존 연구들은 단지 행동을 인지하거나 정상 행동 여부를 평가하는 정도였고 센서로부터 받은 데이터가 아닌 이미지를 처리하여 행동을 인지한 연구도 있었다. 본 연구에서는 실데이터 수집에 한계가 있음을 인지하여 비지도 학습 모델인 오토인코더와 지도 학습 모델인 장·단기 기억 모형을 동시에 사용했다. 비지도 학습 모델인 오토인코더는 정상 행동 데이터를 학습하여 정상적인 행동에 대한 패턴을 학습시켰고 장·단기 기억 모형은 센서로 인지 가능한 행동을 학습시켜 분류를 좀 더 세분화했다. 테스트 결과 각각의 모델은 약 96%, 98% 이상의 정확도를 도출하였고 오토인코더의 이상치가 3% 이상을 갖는 경우 장·단기 기억 모형을 통과하도록 설계했다. 이 시스템을 통해 혼자 사는 노인이나 치매 환자를 효율적으로 관리할 수 있으며 돌보기 위한 비용 또한 절감할 수 있을 것으로 전망된다.

☞ 주제어 : 이상 행동 감지, 딥러닝, 오토인코더, 장·단기 기억 모형

ABSTRACT

The number of elderly people with dementia is increasing as fast as the proportion of older people due to aging, which creates a social and economic burden. In particular, dementia care costs, including indirect costs such as increased care costs due to lost caregiver hours and caregivers, have grown exponentially over the years. In order to reduce these costs, it is urgent to introduce a management system to care for dementia patients. Therefore, this study proposes a sensor-based abnormal behavior detection system to manage dementia patients who live alone or in an environment where they cannot always take care of dementia patients. Existing studies were merely evaluating behavior or evaluating normal behavior, and there were studies that perceived behavior by processing images, not data from sensors. In this study, we recognized the limitation of real data collection and used both the auto-encoder, the unsupervised learning model, and the LSTM, the supervised learning model. Autoencoder, an unsupervised learning model, trained normal behavioral data to learn patterns for normal behavior, and LSTM further refined classification by learning behaviors that could be perceived by sensors. The test results show that each model has about 96% and 98% accuracy and is designed to pass the LSTM model when the autoencoder outlier has more than 3%. The system is expected to effectively manage the elderly and dementia patients who live alone and reduce the cost of caring.

☞ keyword : Abnormality detection, Deep-learning, AutoEncoder, Long Short-Term Memory models

1. 서 론

생활환경 개선과 의학 발전으로 인해 급격한 인구고령화가 전세계적으로 진행되고 있으며, 우리나라도 빠른 수명 연장과 지속적인 저출산으로 인구의 고령화가 급격하게 진행되고 있다. 국내 통계청 자료에 의하면 65세 이상 고령 인구는 2018년 총 인구의 14.71%를 차지하였으나 2060년 40.97%로 약 2.8배 증가할 것으로 예상했다. 이에 따라 독거노인 인구 또한 증가하고 있는데 우리나라 노

¹ Dept. of Computer Science and Engineering, Sejong Univ., Seoul, 05006, Korea.(209, Neungdong-ro, Gwangjin-gu, Seoul)

* Corresponding author (shindk@sejong.ac.kr)

[Received 5 March 2020, Reviewed 23 March 2020, Accepted 22 April 2020]

☆ 본 연구는 보건복지부의 재원으로 한국보건산업진흥원의 보건 의료기술 연구개발사업 지원에 의하여 이루어진 것임 (No, HI18C2191)

☆ 본 논문은 2019년도 한국인터넷정보학회 추계학술발표대회 우수 논문 추천에 따라 확장 및 수정된 논문임.

인의 1/5은 독거노인이며 2019년 독거노인 가구 수는 147만 가구를 넘었고 2040년에는 2배 이상 증가할 것으로 전망하고 있다. 노인들이 흔하게 앓는 치매 환자 또한 빠른 속도로 증가 중이다. 2018년 국내 전체 노인 인구의 1/10 정도가 치매 환자이며 30년 후에는 200만 명을 넘을 것으로 전망하고 있다 [1].

독거노인이나 치매 환자가 증가함에 따라 이들에 대한 경제적, 사회적 부담도 증가하고 있다. 이것은 국제 사회적으로 해결해야 하는 중요한 사회 문제가 되었으며 단순히 생계비용을 제공해주는 것이 아닌 그들을 돌보고 관리해야 하는 문제가 됐다. 노인 인구수가 증가할수록 그들을 관리하기 위한 경제적, 사회적 부담이 증가할 것이며 그에 따른 비용을 줄이기 위해서라도 앞에 언급한 사람들을 관리하기 위한 시스템은 필수적이다. 물리적인 관리의 어려움과 그들을 관리하는데 필요한 비용을 줄이기 위해 본 논문에서는 센서 데이터를 이용하여 노인과 치매환자의 이상 행동을 감지하여 더 효율적으로 관리하고자 한다.

하지만 그들의 일상 행동 데이터를 얻는 것은 쉽지 않다. 또한 침대, 냉장고, 문 등 센서가 부착된 장소에서 생성되는 센서 데이터를 얻는 것도 마찬가지로 쉽지 않다. 데이터를 구하더라도 정상적인 일상 행동 데이터 외에 이상 행동이라 정의할 만한 데이터를 얻는 것은 더욱 어렵다. 따라서 본 연구에서는 요양 시설의 일정표를 참고하여 센서 데이터를 생성했다. 또한 센서 데이터로 판별할 수 있다고 생각되는 이상 행동에 대해 정의하고 이에 따른 이상 행동 데이터를 생성했다.

이를 통해 생성된 정상 행동 데이터로 오토인코더 모델을 학습하였으며 라벨링이 진행된 이상 행동 데이터로 장·단기기억 모형(Long Short-Term Memory models) [2]을 학습했다. 따라서 본 논문에서는 생성한 데이터를 통해서 세 모델을 학습하고 이상 행동을 감지하는 시스템을 제안한다.

2. 관련 연구

2.1 행동 예측 및 탐지에 관한 연구

2.1.1 스마트 홈 데이터 이용 연구

스마트 홈 데이터를 이용하여 행동을 분석하는 연구는 워싱턴 주립 대학교에서 많이 진행됐다. 해당 연구를 진행한 연구팀은 스마트 홈 환경을 구성한 후 지원자들을

통해 데이터를 수집하고 행위 인지에 관한 연구를 진행했다.

Singla 등 (2010) [3]은 2명의 스마트 홈 데이터를 이용하여 일상생활 속에서 이루어지는 행동들을 인지하고자 했다. 실험 과정에서 확률 모델을 이용하였는데 그 중 은닉 마코프 모델(Hidden Markov Model, HMM)을 사용하였고 행동을 인지하는데 약 60% 정도의 정확도를 보였다. HMM 알고리즘은 섞여있는 여러 활동들을 인지하는 데에는 성공하였으나 여러 거주자들의 행동을 파악하는 일에 대해서는 고려하지 않았다.

Dawadi 등 (2016) [4]은 개인의 일상 패턴을 표현하는 활동 곡선(activity curve)의 개념을 소개하고 행동 데이터를 통해 생성되는 활동 곡선을 비교함으로써 일상적인 행동의 변화를 탐지하는 방법을 제안했다. 다른 시간대의 활동 곡선을 비교하기 위해 PCAR(Permutation-based Change detection in Activity Routine) 알고리즘을 소개하였는데 많은 데이터들 속에서 행동 패턴을 표현하는 것이 가능하다는 것을 보여주었다. 하지만 RBANS(Repeatable Battery for the Assessment of Neuropsychological Status)와 같은 다른 지표들과의 상관성은 찾지 못했다. Das 등 (2016) [5]은 센서에서 발생하는 데이터들을 통해 원-클래스 비교-기반(One-Class Classification-Based) 행동 여러 탐지를 제안하였다. 정상 행동 데이터에서 추출된 특징들의 이상치를 검출한 뒤, OCSVM(One-class support vector machine)을 이용하여 원-클래스 분류를 제안하였다. 활동 오류 예측 시에는 평균 60%의 재현율을 얻었으나 모든 활동에 대한 접근 방식의 평균 오 탐지율은 45%였다.

2.1.2 영상 및 센서 데이터 이용 연구

스마트 홈 데이터가 아닌 비디오나 이미지와 같은 데이터를 이용하여 이상 행동을 인지하거나 행동을 예측하는 연구도 있다. Vondrick 등 (2016) [6]은 비디오 데이터를 이용하여 이미지가 나타내는 행동을 학습하고 다음 행동을 예측하는 연구를 진행했다. Zhong 등 (2004) [7]은 대규모 비디오 데이터를 이용하여 비정상 행동을 감지하기 위한 모델을 개발했다. 이 모델은 비지도 학습 중 하나인 K-means(K-means clustering)를 적용하여 개발하였으며 대규모 비디오 처리에 효율적이고 안정적으로 수행했다. Chen 등 (2007) [8]은 실시간으로 비정상 행동을 감지하는 시스템을 제안했다. 이미지 정보를 이용하여 신체를 감지하고 추적하여 행동을 인지한 후 베이지안 프레임워크를 multi-SVM(Multi-class Support vector Machine)


과 통합하여 인식률을 향상시키는 방법을 제안했다. Mehran 등 (2009) [9]은 사람들이 다니는 모습을 담은 비디오에서 이상 행동을 감지하는 방법을 소개하였다. 사람들의 정상 행동을 모델링하기 위해 사회행동력(Social Force) 모델을 사용하였으며 이상 행동과 정상 행동을 분류하기 위해 BoW(Bag of Words) 방식을 사용했다. 이 외에 다른 센서들을 이용하여 비정상 활동을 감지하는 연구들도 있다. Yin 등 (2008) [10]은 신체에 무선 센서를 부착하여 비정상 활동을 감지하는 연구를 진행했다. 이를 위해 두 가지 단계를 수행하였는데 먼저 OCSVM을 이용하여 정상 행동을 학습했다. 그 이후에 KNLR(Kernel Nonlinear Regression)을 이용하여 정상 활동 모델에서 비정상 활동 모델을 유도하는 작업을 진행했다. 이 방식은 탐지율과 오 탐지율 간의 절충점을 얻을 수 있는 장점이 있었으나 비정상적인 행동이 정상적인 행동으로 변할 때, 비정상적인 모델을 생성하는 문제가 있었다. Hung 등 (2010) [11]은 혼자 사는 노인들의 일상 행동에서 비정상 행동을 감지하기 위한 연구를 진행하였다. 이 연구에서는 RFID(Radio-Frequency Identification) 기반 센서 네트워크를 사용하여 노인들의 일상생활 행동 데이터를 수집하였으며 은닉 마코프 모델과 SVMs(Support vector machines)을 이용하여 노인의 행동을 평가하였다. Gaddam 등 (2010) [12]은 센서 네트워크를 기반으로 하는 가정용 모니터링 시스템을 제안하였다. 인지 센서는 일상생활에서 비정상 행동 패턴을 감지하여 노인을 모니터링 하는데 사용하며 이상 행동 발생 시 보호자가 알 수 있도록 하였다.

이와 같은 연구들 외에도 행동을 예측하거나 행동의 변화 및 정상 행동 여부를 판단하는 연구들이 존재한다. 하지만 이상 행동을 정의하거나 이상 행동 데이터를 이용하여 연구를 진행한 사례는 찾아보기 어렵다. 이는 정상 행동 외의 다른 이상 행동에 대한 데이터를 구하는 것이 쉽지 않다는 것을 의미한다. 따라서 본 연구에서는 일상생활에서 얻을 수 있는 행동들을 일반적인 센서 데이터를 이용하여 수집하고 오토인코더와 장·단기 기억 모델을 이용하여 이상 행동을 감지하는 시스템을 제안한다.

2.2 오토인코더 알고리즘

본 연구에서 사용한 오토인코더는 대표적인 비지도 학습 알고리즘 중 하나이다 [13]. 오토인코더는 지도 학습과 다르게 목표 값을 출력하지 않고 라벨 정보가 없는 데이터의 특징을 분석하거나 추출한다. 오토인코더는 그림 1

과 같이 기본적으로 입력 데이터를 내부 표현으로 바꾸는 인코더와 내부 표현을 출력으로 바꾸는 디코더가 있다. 일반적으로 내부 표현을 담당하는 은닉층의 크기가 입력 데이터보다 작기 때문에 입력 데이터의 중요한 특성을 학습하는 특징이 있다. 또한 오토인코더는 비지도 학습이므로 정답이 되는 라벨이 없다. 하지만 일반적으로 출력의 크기가 입력의 크기와 같고 손실 값을 구할 때 입력을 출력 값의 타겟 값으로 계산하기 때문에 자기감독(Self-Supervised) 학습이라 하기도 한다. 이러한 오토인코더를 사용할 때, 활성 함수를 사용하지 않고 비용 함수로 MSE(Mean Squared Error)를 사용한다면 간단한 PCA(Principal Component Analysis)를 수행할 수 있다.




(그림 1) 오토인코더 구조
(Figure 1) Autoencoder structure

2.1.1 적층 오토인코더

적층 오토인코더 [14]는 다른 신경망과 마찬가지로 여러 개의 은닉층을 가진 오토인코더를 의미한다. 따라서 다층 오토인코더(Multi-layer Autoencoder) 또는 심층 오토인코더(Deep Autoencoder)라고 부를 수 있다. 적층 오토인코더는 다른 심층 신경망들과 다르게 일반적으로 중간 은닉층을 기준으로 대칭 형태를 갖는다. 이는 오토인코더가 인코더와 디코더를 갖는 형태로 구성되어있기 때문이며 그림 2와 같은 형태를 갖는다.

기존 심층 신경망들이 깊은 구조를 가질 때 더 좋은 성능을 갖기도 하지만 그에 따른 문제들이 발생하기도 한다. 이와 같이 오토인코더도 여러 층을 사용하는 경우 더 강력하게 데이터의 특징을 추출할 수 있으나 과적합(overfitting)되거나 인코딩 과정에서 은닉층의 크기가 작아지기 때문에 기울기 소실(Vanishing Gradient) 문제가 발생할 수 있다.



(그림 2) 적층 오토인코더 구조
(Figure 2) Stacked autoencoder structure

2.1.2 변이 오토인코더

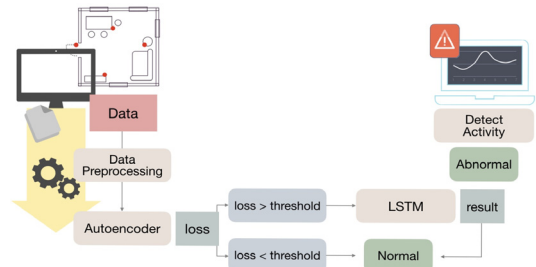
흔히 VAE(Variational AutoEncoder)라 부르는 변이 오토인코더 [15]는 사실상 기존 오토인코더들과 관련성이 깊지는 않다. 이것을 오토인코더라고 부르는 이유는 단지 기존 오토인코더와 구조가 비슷하며 인코딩과 디코딩의 과정을 거치기 때문이다. 변이 오토인코더는 기존 오토인코더와 다르게 중간에 코딩 공간(coding space) 또는 잠재 공간(latent space)이라 부르는 공간이 있다. 이 잠재 공간은 가우시안 분포를 따르는데 입력된 데이터가 인코더를 거치게 되면 해당 데이터 분포의 평균과 표준편차가 얻어진다. 이렇게 학습을 통해 평균과 표준편차가 얻어지면 디코더가 해당 가우시안 분포에서 데이터를 랜덤하게 샘플링한다. 따라서 기존 오토인코더가 데이터를 압축하고 다시 풀어내는 과정에서 데이터의 특징을 학습하는 것과 달리 변이형 오토인코더는 학습된 분포에서 데이터를 샘플링하는 생성 모델에 가깝다.

2.1.3 그외 오토인코더

앞서 소개한 오토인코더 외에도 입력 데이터에 잡음을 추가하여 오토인코더가 데이터의 특징을 더욱 잘 찾도록 하는 잡음 제거 오토인코더(Denoising Autoencoder) [14]가 있으며 은닉 노드에 희소성(sparsity) 제한을 걸어둌으로써 활성 노드 개수를 줄이도록 하여 유용한 특성을 추출하도록 하는 희소 오토인코더(Sparse Autoencoder) [16]가 있다. 두 오토인코더 모두 데이터의 패턴을 추출하는데 제약을 걸어둌으로써 학습하는데 더욱 유용한 정보를 얻도록 하는 특징이 있다.

3. 딥러닝 기반 이상 행동 시스템 설계 및 구현

본 연구는 치매 환자의 이상 행동을 판별하기 위해 비지도 학습 모델인 오토인코더와 장·단기 기억 모형을 사용했다. 그림 3은 본 연구에 사용된 이상 행동 감지 시스템의 구조도이다.



(그림 3) 이상 행동 감지시스템 구조도
(Figure 3) Abnormal behavior detection system diagram

본 연구에서는 모델의 성능 평가를 위해 모든 데이터의 전처리를 마친 후 모델의 입력으로 사용하였으나 실제 환경에서는 하나의 로그가 전달된다. 따라서 실제 환경과 유사하게 만들어놓은 시스템 사용 시, 센서가 작동할 때마다 로그 데이터를 하나씩 받고 일정 개수의 로그 데이터가 쌓이면 모델의 입력으로 들어가도록 했다. 일정 개수의 로그 데이터를 모으는 이유는 하나의 로그 데이터만으로는 이상 행동 데이터 여부를 알기 어렵다고 판단하였기 때문이다. 최소한의 데이터 묶음이 모델의 입력으로 들어가야 일련의 데이터에 대한 이상치가 보다 정확하게 출력될 것이라고 가정했다.

데이터 묶음이 먼저 오토인코더 모델에 입력되면 데이터에 대한 이상치 값이 출력된다. 출력된 이상치 값이 실험을 통해 정해진 이상치 기준 값을 넘는 경우에 이상 행동 데이터에 가능성을 두고 동일한 데이터 묶음이 두 번째 모델인 장·단기 기억 모형의 입력으로 들어가게 된다. 장·단기 기억 모형은 정상, 불면, 반복 행동에 대한 지도 학습을 진행하였으므로 세 가지 분류에 대한 값을 출력한다. 최종적으로 입력된 데이터에 대한 값이 행동으로 출력되면 분류된 이상 행동에 따라 보호자에게 알림을 줄 수 있다. 또한 하루에 대한 데이터가 쌓이게 되면 오토인코더 모델을 추가적으로 학습하여 기존 모델을 대체하여 사용할 수 있다.

3.1 데이터 소개

3.1.1 이상 행동의 정의

치매 환자의 이상 행동에 대해서 명확히 제시된 바는 없다. 하지만 일반적으로 의미하는 치매 환자의 이상 행동들에 대해 몇 가지 서술하면 표 1과 같다.

(표 1) 치매 환자의 이상 행동 종류

(Table 1) Aberrant Behavior Types in Dementia Patients

	이상 행동
1	배회
2	낙상
3	불면
4	망상 / 환각
5	파국적인 행동(공격성)
6	반복 질문 / 반복 행동
7	과식 / 이식 / 거식
8	약물 과다 복용
9	수집 행위 / 불결 행위 등 부적절한 행동

위와 같이 분류한 이상 행동들 중 센서 데이터를 이용하여 판별할 수 있다고 가정한 이상 행동은 배회 행동/낙상, 불면, 반복 행동이다. 배회 행동이나 낙상의 경우 GPS(Global Positioning System)가 측정 가능한 밴드를 착용하여 데이터를 수집하는 경우 판별 가능하다고 보았고 불면의 경우는 센서가 동작하지 않을 새벽 시간에 다수의 센서 데이터가 발생할 시 판별 가능하다고 가정했다. 반복 행동의 경우는 과식, 약물 과다 복용 등을 포함하고 있는데 시간대에 맞지 않는 센서 발생이나 하나 이상의 센서가 다수 동작하는 경우 판별 가능하다고 판단했다.

본 연구에서는 가정 및 병실에 센서를 부착하여 사용한다고 가정했다. 따라서 우선적으로 연구에 포함한 이상 행동은 불면과 반복 행동이며 이상 행동 데이터 생성 시 두 가지 행동에 대해서만 고려했다.

3.1.2 정상 행동 데이터

치매 환자의 정상적인 일상 데이터를 얻기 위해 요양 시설 등의 일정표를 참고하여 가능한 센서 로그 데이터를 생성했다. 참고한 일정표는 그림 4와 같다.

요양 병원에 있는 노인이나 환자가 그림 4와 같은 일정표에 따라 행동한다고 가정하고 데이터를 생성했다. 이때, 가정한 센서 부착 위치는 문, 창문, 냉장고, 서랍, 보조

침대로 5가지이며 각 센서들은 표 2와 같이 다음 행동을 취할 때 사용된다고 가정했다. 또한 참고한 일정에 따라 가능한 행동들을 표 3과 같이 정의했다.

주간일정표

일	화	수	목	금	토	일
06:00	아침 단장, 아침식사 준비					
07:00	아침 식사 및 식후 위생관리					
08:00	재활특성예 따른 기온 측정 및 환자건강 체크					
09:00	의료진 회상 및 물리치료					
10:00	안지계활동	종아골계활동	마음요법	안지계활동	목욕요법	안지계활동 / 안지계활동
11:00	안지계활동	마음요법	종아골계활동	안지계활동	목욕요법	/
12:30	점심식사 및 식후 위생관리, 투약					
13:30	물리치료 및 환자건강 체크					
14:00	안지계활동	생물체조	안지계활동	목욕요법	레크리에이션	안지계활동 / 안지계활동
17:00	저녁 식사 및 식후 위생관리, 자세관리					
18:00	휴식 및 여가활동, TV 시청					
20:00	수면환경 점검					
비고	♡ 복복 서비스 : 주 1회, 오전 9시 ~ 12시 ♡ 야간돌봄 서비스 : 매일 1 : 3주 수요일, 2 : 4주 금요일, 오전 10시 ~ 12시					

(그림 4) 요양 시설 일정표

(Figure 4) Nursing home schedule

(표 2) 행동 정의 및 센서 매치

(Table 2) Behavior definition and sensor match

행 동	센 서
1. 침대 이용	5. 보조 침대
2. 식사	
3. 화장실 이용	1. 문
4. 보조 침대 사용	5. 보조 침대
5. 창문 열기	2. 창문
6. 냉장고 열기	3. 냉장고
7. 서랍 열기	4. 서랍
8. 문 열기	1. 문

(표 3) 일정에 따른 가능 행동 번호

(Table 3) Possible action number according to schedule

	일 정	행동 번호
1	6시 기상 ~ 7시 아침 준비	1, 3, 5, 8
2	7시 20분 ~ 8시: 아침 식사 이후	1, 3, 6, 8
3	8시 ~ 10시: 건강체크 및 휴식	1, 3, 5, 6, 7, 8
4	10시 경 외출 (활동 시간)	1, 3, 8
5	12시 경 돌아옴	1, 3, 8
6	12시 20분 ~ 2시: 점심 식사 이후	1, 3, 6, 7, 8
7	2시 경 외출 (활동 시간)	1, 8
8	5시 경 돌아옴	1, 8
9	5시 20분 ~ 6시: 저녁 식사 이후	1, 3, 6, 7

표 3의 정의는 다음과 같은 사항을 가정했다.

- 선행조건

- 식사 및 복용해야 하는 약 등은 요양 시설에서 제공한다. 따라서 약통에 센서를 부여하지 않음.
- 식사 시간 약 15~20분은 행동이 없다고 간주.
- 화장실은 병실 외부에 있다. 따라서 화장실 이용 시 문을 열어야 한다.

위 사항들을 고려하여 데이터를 생성하였으며 최대한 실제 데이터와 유사하게 만들기 위해 표 3의 각 스케줄마다 1~10번의 행동이 이루어질 수 있다고 가정했다. 또한 각 행동들은 정의한 가능 행동 번호들 중 랜덤하게 선택했다. 한 번의 행동에 따른 센서가 동작할 때, 하나의 로그가 아닌 다수의 로그가 발생할 것이라 판단하여 2~20개의 랜덤한 로그를 생성하도록 하였고 각 로그는 1~30초 간격으로 랜덤하게 발생한다.

생성되는 데이터 종류는 날짜, 시간, 센서 번호, 센서 발생 횟수로 각 로그는 [YYYY-MM-DD, hh:mm:ss, #, #]와 같은 형태로 생성된다. 학습에 사용되는 센서 로그 데이터는 30일에 해당하는 데이터이며, 하루 당 약 600개 정도의 로그가 생성된다. 이에 대한 예시는 표 4와 같다.

(표 4) 정상 행동 센서 로그 예시

(Table 4) Normal behavior sensor log example

날 짜	시 간	센서번호	발생횟수
2019-07-19	6:00:18	1	1
2019-07-19	6:00:37	1	2
2019-07-19	6:00:51	1	3
2019-07-19	6:01:07	1	4

3.1.3 이상 행동 데이터

이상 행동 데이터는 보다 구체적인 이상 행동을 구분하기 위해 생성하였으며 3.1.1에서 정의하였듯이 치매 환자가 취할 수 있는 여러 이상 행동들 중 센서로 판별 가능할 만한 ‘반복 행동’과 ‘불면’에 대한 데이터를 생성했다. 이 중 ‘반복 행동’에는 과식, 약물 과다 복용, 특정 행동 반복 등 여러 가지를 포함하고 있다.

이상 행동 데이터는 지도학습 모델을 학습할 때 사용하므로 데이터에 라벨을 부여하였으며 이상 행동 데이터를 만드는 데 다음과 같은 사항들을 가정했다.

- 선행조건

- 00:30 ~ 4:30 시간대에 일정 시간 이상 센서가 동작

하는 경우 및 다수의 센서가 동작하는 경우 불면이라 가정.

- 발생할 수 없는 시간대에 센서가 반복적으로 동작 및 하나 이상의 센서가 다수 동작하는 경우 반복 행동이라 가정.

이상 행동 데이터는 위 사항 및 3.1.2에 포함되는 정상 행동 데이터 가정 사항을 포함하여 생성했다. 데이터 생성 방식은 3.1.2에 설명한 것과 동일하며 이상 행동의 특이사항만 추가적으로 포함된다. 생성되는 데이터 종류는 날짜, 시간, 센서 번호, 센서 발생 횟수, 라벨로 정상 행동 데이터와 다르게 각 로그마다 행동 라벨이 부여된다. 로그 형식은 [YYYY-MM-DD, hh:mm:ss, #, #, #]으로 정상 행동 데이터 형식에 라벨 데이터만 추가된다. 모델 학습에 사용되는 데이터는 정상 행동 데이터와 마찬가지로 30일에 해당하는 데이터이며, 하루 당 약 600개 정도의 데이터가 생성된다. 표 5는 그중 일부 예시이다.

(표 5) 이상 행동 센서 로그 예시

(Table 5) Abnormal behavior sensor log example


날 짜	시 간	센서번호	발생횟수	라 벨
2019-07-19	0:21:06	2	1	1
2019-07-19	0:21:29	2	2	1
2019-07-19	4:12:18	1	1	2
2019-07-19	4:13:08	1	2	2

3.2 데이터 전처리

3.2.1 정상 행동 데이터 전처리


이상 행동을 감지하기 위한 첫 번째 모델로 오토인코더를 사용한다. 이때 오토인코더 모델에 들어갈 입력 형태를 만들기 위한 전처리 과정을 진행한다.

정상 행동 데이터는 하나의 로그에 날짜, 시간, 센서 번호, 센서 발생 횟수에 대한 값이 포함되어 있다. 이 중 사용한 데이터는 시, 분, 센서 번호, 센서 발생 횟수에 해당하는 값으로 날짜 데이터는 무의미하다고 판단하여 제거했다. 또한 시간 데이터를 사용하는 데 있어 정확한 센서 발생 시간이나 보호자를 위한 알람 시스템을 위해서는 되도록 섬세한 시간 데이터가 필요하다고 판단하여 시와 분 데이터를 사용했다. 이때, 시는 24시로 구분하였으며 분은 0~9, 10~19, 20~29, 30~39, 40~49, 50~59분으로 나누어 총 6가지로 구분한다. 센서값은 3.1.2에서 설명한



(그림 5) 단층 오토인코더 모델 구조

(Figure 5) Single layer autoencoder model structure

(그림 6) 적층 오토인코더 및 잡음 제거 오토 인코더 모델 구조
(Figure 6) Stacked autoencoder and denoising autoencoder model structure

4. 실험 결과

본 연구에서는 오토인코더와 장·단기 기억 모형을 이용하여 치매 환자 관리 시스템을 표8의 환경에서 구현하였으며 가상의 데이터를 통해 실험했다. 실험 결과 생성된 데이터의 분포도와 모델의 성능 결과 및 시스템 출력 결과를 확인해본다.

(표 8) 실험환경 하드웨어 및 소프트웨어

(Table 8) Experimental Hardware and Software

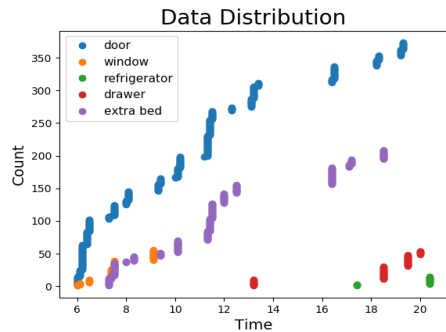
구분	사용 하드웨어 및 소프트웨어
운영체제	Windows 10 Pro
프로세서	AMD Ryzen 7 3700X 8-Core Processor 3.59 GHz
메모리	64GB
사용 언어	Python 3.6.9
사용 라이브러리	tensorflow-gpu 1.12.0, keras 2.2.4, pandas 0.25.0, numpy 1.16.4

4.1 센서 사용 분포도

그림 7과 그림 8은 각각 실험 전 생성한 정상 행동 데


이터와 이상 행동 데이터의 센서 사용 분포도이다.

그래프의 x축은 시간을 나타내며 y축은 시간에 따른 센서 발생 누적 횟수를 의미한다. 두 그림을 비교해보면 이상 행동 데이터 또한 정상 행동 데이터가 포함되어 있으므로 유사한 센서 사용 형태를 띄고 있으나 그림 8의 경우 새벽 시간에 센서가 발생하거나 특정 시간에 과도하게 센서가 발생하는 등의 모습을 확인할 수 있다.



(그림 7) 정상 행동 데이터 센서 사용 분포도

(Figure 7) Normal behavior data sensor usage distribution chart



(그림 8) 이상 행동 데이터 센서 사용 분포도


(Figure 8) Abnormal behavior data sensor usage distribution chart

4.2 이상 행동 감지 시스템 실험 결과

앞 장에서 설명하였듯이 이상 행동 감지 시스템은 오토인코더와 장·단기 기억 모형 두 가지로 구성됐다. 오토인코더의 성능 테스트는 입력과 출력이 얼마나 유사한지를 통해 정확도를 얻을 수 있다.


먼저 실험에 사용된 모든 오토인코더와 장·단기 기억 모형은 학습하는데 한 달(약 30일)에 해당하는 데이터를

사용하였으며 테스트 데이터로는 일주일에 해당하는 데이터를 사용했다. 모델 학습 시 에포크(epoch)는 50, batch 크기는 32로 설정했다. 그림 9는 단층 오토인코더 모델에 정상 행동 데이터를 넣었을 때 정확도 및 손실 그래프이다. 이상 행동 데이터의 경우는 정상 행동 데이터가 포함되어 있어 정확도나 손실 그래프로는 크게 구분하기 어렵다. 따라서 그림 10은 이상 행동 데이터에서 이상치 정도를 확인하기 위한 손실 그래프이다. 이상치 정도는 1에서 100사이로 표현하였으며 빨간 선은 본 시스템에서 기준으로 삼고 있는 기준선이다. 이때 사용한 기준치는 3% 정도이다. 오토인코더 모델에 데이터가 입력되어 이상치를 구한 뒤 해당 기준치를 넘으면 장·단기 기억 모형에 재입력된다.



(그림 9) 단층 오토인코더에서 정상 행동 데이터의 정확도 및 손실 그래프

(Figure 9) Accuracy and loss graph of normal behavior data in single layer autoencoder distribution chart



(그림 10) 단층 오토인코더에서 이상 행동 데이터의 손실 그래프
(Figure 10) Loss graph of abnormal behavior data in a single layer autoencoder

표 9는 단층 오토인코더에 정상 행동 데이터를 입력으로 넣었을 때, 입력한 값과 오토인코더 모델을 거쳐 출력된 값이다. 이 때 사용된 데이터는 모델 학습에 포함되지 않았다. 표 9의 입력 값의 경우는 출력 데이터 형식에 맞춰 0~9, 10~19, 20~29, 30~39, 40~49, 50~59분을 각각 0, 10, 20, 30, 40, 50분으로 변형하여 나타내었다. 입력 값과 출력 값을 비교해보면 두 값이 거의 동일한 것을 확인할 수 있다.

(표 9) 정상 행동 데이터 입력 및 출력 결과 예시

(Table 9) Example of normal behavior data input and output results

	입력 값			출력 값		
	시	분	센서번호	시	분	센서번호
1	6	0	1	6	0	1
2	6	0	1	6	0	1
3	6	0	1	6	0	2
4	6	0	2	6	0	2
5	6	10	2	6	10	2
6	6	10	2	6	10	2
7	6	10	2	6	10	2

표 10은 동일한 모델에 이상 행동 데이터를 입력으로 넣었을 때, 입력한 값과 모델을 거쳐 출력된 값이다. 표 9와 마찬가지로 입력 값의 분 속성은 변형하여 나타내었다. 표 10의 입력 값과 출력 값을 비교해보면 표 9에 본 결과와 다르게 많은 차이를 보이는 것을 알 수 있다. 이와 같이 오토인코더 모델은 정상 행동 데이터가 입력되는 경우는 높은 정확도를 보이나 이상 행동 데이터가 입력되는 경우는 낮은 정확도를 보인다는 것을 알 수 있다.

(표 10) 이상 행동 데이터 입력 및 출력 결과 예시
(Table 10) Example of abnormal behavior data
input and output results

	입력 값			출력 값		
	시	분	센서번호	시	분	센서번호
1	1	10	3	19	10	3
2	1	10	3	19	10	3
3	1	10	3	17	20	3
4	1	20	3	17	20	3
5	1	20	3	17	20	3
6	1	20	3	17	20	3
7	1	20	3	17	20	3

두 모델 중 오토인코더의 경우에는 단층 오토인코더, 적층 오토인코더, 잡음 제거 오토인코더 총 세 가지 모델의 성능을 평가해보았다. 표 11은 세 모델 각각의 은닉층 크기를 변경해보면서 성능을 테스트 한 뒤, 가장 성능이 좋았던 모델만 비교한 결과 및 장·단기 기억 모형의 성능 결과이다.

실험 결과를 확인해보면 세 종류의 오토인코더 중 단층 오토인코더의 성능이 가장 좋으며 적층 오토인코더의 성능 또한 나쁘지 않다. 본 연구에서는 주로 성능이 가장 좋은 단층 오토인코더와 장·단기 기억 모형의 결합으로 테스트했다. 오토인코더의 경우에는 데이터가 쌓일수록 사용자의 데이터에 맞게 계속해서 학습될 수 있으므로 시간이 지날수록 더 좋은 성능을 가질 것으로 예상된다. 장·단기 기억 모형 또한 성능이 좋는데 이 모델의 단점은 더 좋은 모델로 사용하기 위해 꾸준한 라벨링 작업이 필요하다는 것이다.

(표 11) 딥러닝 모델 성능 비교
(Table 11) Comparison of Deep Learning Model
Performance

	모델	정확도
오토인코더 (Autoencoder)	단층 오토인코더 (Single Layer Autoencoder)	96.84%
	적층 오토인코더 (Stacked Autoencoder)	96.31%
	잡음 제거 오토인코더 (Denoising Autoencoder)	93.96%
	장·단기 기억 모형(LSTM model)	99.02%

5. 결 론

본 연구의 목적은 가정 혹은 시설 등에 부착 가능한 센서를 통해 사람의 이상 행동을 감지하는 것이다. 하지만 이러한 센서 데이터를 얻는 것은 쉽지 않기 때문에 치매 환자들을 돌보는 요양 시설의 일정표를 참고하여 데이터를 생성했다. 따라서 본 연구의 결과가 모든 환경에서 좋은 성능을 보인다고 일반화할 수 없다. 그럼에도 본 연구에서 사용한 모델의 결과는 꽤 높은 수치의 결과를 보여준다. 이를 통해 오토인코더 모델이 정상 행동의 패턴을 찾아낼 수 있다는 것을 알 수 있으며 장·단기 기억 모형을 통해 오토인코더의 결과를 더 정교하게 만들어 주는 것을 확인할 수 있다. 이는 실제로 센서를 부착하고 실제 환자들이나 사람들이 사용하였을 때 많은 데이터가 모이게 되면 더 좋은 성능을 보일 가능성을 보여준다.

따라서 추후에는 본 연구에서 사용한 모델을 더 보완하고 추가적으로 사용할 수 있는 데이터를 잘 선정하여 보다 정교한 시스템을 만들 예정이다. 또한 이상 행동 감지 외에도 사람들에게 알림을 주고 모니터링 할 수 있는 시스템을 추가할 예정이다.

참고문헌(Reference)

- [1] Bin-na Kim et al., "Global Trends of Dementia Policy 2018", central dementia center (NIDR-1801-0022), 2018.
https://ansim.nid.or.kr/community/pds_view.aspx?bid=185
- [2] S. Hochreiter & J. Schmidhuber, "Long short-term memory," Neural computation, 9(8):1735 - 1780, 1997.
<https://www.mitpressjournals.org/doi/pdf/10.1162/neco.1997.9.8.1735>
- [3] G. Singla, D. J. Cook, & M. Schmitter-Edgecombe, "Recognizing independent and joint activities among multiple residents in smart environments," Journal of ambient intelligence and humanized computing 1(1), pp 57-63, 2010.
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2958106>
- [4] P. N. Dawadi, D. J. Cook, & M. Schmitter-Edgecombe, "Modeling patterns of activities using activity curves," Pervasive and mobile computing 28, pp 51-68, 2016.
<https://www.sciencedirect.com/science/article/pii/S157411921500173X>

- [5] B. Das, D. J. Cook, N. C. Krishnan & M. Schmitter-Edgecombe, "One-class classification-based real-time activity error detection in smart homes," IEEE journal of selected topics in signal processing 10(5), pp 914-923, 2016.
<https://ieeexplore.ieee.org/abstract/document/7421975>
- [6] C. Vondrick, H. Pirsiavash & A. Torralba, "Anticipating visual representations from unlabeled video," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp 98-106, 2016.
<https://arxiv.org/abs/1504.08023>
- [7] H. Zhong, J. Shi & M. Visontai, "Detecting unusual activity in video," In Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2004, Vol 2, pp. 1-8, 2004.
<https://ieeexplore.ieee.org/abstract/document/1315249/>
- [8] Y. Chen, G. Liang, K. K. Lee & Y. Xu, "Abnormal behavior detection by multi-SVM-based Bayesian network," In 2007 International Conference on Information Acquisition, IEEE, pp. 298-303, 2007.
<https://ieeexplore.ieee.org/abstract/document/4295746>
- [9] R. Mehran, A. Oyama, & M. Shah, "Abnormal crowd behavior detection using social force model," In 2009 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, pp. 935-942, 2009.
<https://ieeexplore.ieee.org/abstract/document/5206641/>
- [10] J. Yin, Q. Yang, & J. J. Pan, "Sensor-based abnormal human-activity detection," IEEE Transactions on Knowledge and Data Engineering 20(8), pp. 1082-1090, 2008.
<https://ieeexplore.ieee.org/document/4358934>
- [11] Y. X. Hung, C. Y. Chiang, S. J. Hsu & C. T. Chan, "Abnormality detection for improving elder's daily life independent," In International conference on smart homes and health telematics, Springer, Berlin, Heidelberg, pp. 186-194, 2010.
https://link.springer.com/chapter/10.1007/978-3-642-13778-5_23
- [12] A. Gaddam, S. C. Mukhopadhyay, & G. S. Gupta, "Elder care based on cognitive sensor network," IEEE Sensors Journal 11(3), pp. 574-581, 2010.
<https://ieeexplore.ieee.org/abstract/document/5483132/>
- [13] P. Baldi, "Autoencoders, unsupervised learning, and deep architectures," In Proceedings of ICML workshop on unsupervised and transfer learning, pp. 37-49, 2012.
<https://dl.acm.org/citation.cfm?id=3045796.3045801>
- [14] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, & P. A. Manzagol, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," Journal of machine learning research 11, pp. 3371-3408, 2010.
<http://www.jmlr.org/papers/volume11/vincent10a/vincent10a.pdf>
- [15] D. P. Kingma, & M. Welling, "Auto-encoding variational bayes," arXiv preprint arXiv:1312.6114, 2013.
<https://arxiv.org/abs/1312.6114>
- [16] A. Ng, "Sparse autoencoder," CS294A Lecture notes 72, pp. 1-19, 2011.
<https://web.stanford.edu/class/cs294a/sparseAutoencoder.pdf>

● 저 자 소 개 ●



김 국 진(Kook-jin Kim)

2017년 학점은행제 정보보호학과(공학사)

2019년~현재 세종대학교 대학원 컴퓨터공학과(석사과정)

관심분야 : 인공지능, 클라우드, 알고리즘, 정보보호, etc.

E-mail : kjkim@sju.ac.kr

❶ 저 자 소 개 ❶



이 승 진(Seung-Jin Lee)

2018년 세종대학교 컴퓨터공학과(공학사)

2020년 세종대학교 대학원 컴퓨터공학과(공학석사)

관심분야 : 인공지능, 데이터마이닝, 생체신호 데이터처리 etc.

E-mail : cilabjin1819@gmail.com



김 성 중(Sung-joong Kim)

2016년 서울호서직업전문학교 사이버해킹보안과(공학사)

2018년 세종대학교 대학원 컴퓨터공학과(공학석사)

2019년~현재 세종대학교 대학원 컴퓨터공학과(박사과정)

관심분야 : 정보보호, 사이버전, 데이터마이닝, etc.

E-mail : tjdwnd2004@sju.ac.kr



김 재 근(Jae-guen Kim)

2018년 숭실대학교 컴퓨터공학과(공학사)

2018년~현재 세종대학교 대학원 컴퓨터공학과(석사과정)

관심분야 : 머신러닝, 데이터마이닝, 사이버전, etc.

E-mail : jackeun0310@sju.ac.kr



신 동 일(Dong-il Shin)

1988년 연세대학교 컴퓨터과학과(공학사)

1993년 Washington State University 대학원 컴퓨터과학과(공학석사)

1997년 North Texas University 대학원(공학박사)

1998년~현재 세종대학교 컴퓨터공학과 교수

관심분야 : 정보보호, 생체신호 데이터처리, 데이터마이닝, 머신러닝, etc.

E-mail : dshin@sejong.ac.kr



신 동 규(Dong-kyoo Shin)

1986년 서울대학교 컴퓨터과학과(공학사)

1992년 Illinois Institute of Technology 대학원 컴퓨터과학과(공학석사)

1997년 Texas A&M University 대학원 컴퓨터과학과(공학박사)

1998년~현재 세종대학교 컴퓨터공학과 교수

관심분야 : 머신 러닝, 유비쿼터스 컴퓨팅, 생체신호 데이터처리, 정보보호, etc.

E-mail : shindk@sejong.ac.kr