

1D CNN and Machine Learning Methods for Fall Detection

Inkyung Kim[†] · Daehee Kim^{††} · Song Noh^{†††} · Jaekoo Lee^{††††}

ABSTRACT

In this paper, fall detection using individual wearable devices for older people is considered. To design a low-cost wearable device for reliable fall detection, we present a comprehensive analysis of two representative models. One is a machine learning model composed of a decision tree, random forest, and Support Vector Machine(SVM). The other is a deep learning model relying on a one-dimensional(1D) Convolutional Neural Network(CNN). By considering data segmentation, preprocessing, and feature extraction methods applied to the input data, we also evaluate the considered models' validity. Simulation results verify the efficacy of the deep learning model showing improved overall performance.

Keywords : Machine Learning, Deep Learning, Fall Detection, 1D Convolutional Neural Network

1D CNN과 기계 학습을 사용한 낙상 검출

김 인 경[†] · 김 대 희^{††} · 노 송^{†††} · 이 재 구^{††††}

요 약

본 논문에서는 고령자를 위한 개별 웨어러블(Wearable) 기기를 이용한 낙상 감지에 대해 논한다. 신뢰할 수 있는 낙상 감지를 위한 저비용 웨어러블 기기를 설계하기 위해서 대표적인 두 가지 모델을 종합적으로 분석하여 제시한다. 기계 학습 모델인 의사결정 나무(Decision Tree), 랜덤 포레스트(Random Forest), SVM(Support Vector Machine)과 심층 학습 모델인 일차원(One-Dimensional) 합성곱 신경망(Convolutional Neural Network)을 사용하여 낙상 감지 학습 능력을 정량화하였다. 또한 입력 데이터에 적용하기 위한 데이터 분할, 전처리, 특징 추출 방법 등을 고려하여 검토된 모델의 유효성을 평가한다. 실험 결과는 전반적인 성능 향상을 보여주며 심층학습 모델의 유효성을 검증한다.

키워드 : 기계 학습, 심층 학습, 낙상 검출, 1차원 합성곱 신경망

1. 서 론

일반적으로 낙상(Fall)은 높은 곳에서 낮은 곳으로 신체의 중심을 잃고 빠르게 움직이는 것을 의미한다. 반면 ADL(Activity of Daily Living)은 사람들이 일상 생활에서 수행하는 자기 관리를 포함한 모든 활동을 의미하며, 걷기, 식사하기 등이 이에 해당한다. 현재까지 많은 낙상 검출 연구들은

낙상과 ADL을 분류하는 방식으로 진행되었다[1].

노인인구가 증가함에 따라 낙상에 대한 관심도 함께 증가하는 추세이다. 2017년 보건복지부에서 진행한 노인실태조사에 따르면 노인의 15.9%는 낙상을 경험했다고 응답하였다[2]. 낙상은 발생 후 1시간 이내에 구조되지 못하면 탈수, 폐렴, 저체온증과 같은 후유증을 유발할 가능성이 매우 높다[3]. 낙상의 조기 발견을 위해서는 노인들의 행동과 신체적 균형을 지속적으로 관찰해야 한다. 이러한 방법 중 하나가 웨어러블(Wearable)에 포함된 가속도계나 자이로스코프 센서를 사용하여 낙상을 검출하는 것이다.

본 논문에서는 웨어러블 기기의 센서를 통해 수집한 데이터를 대표적인 기계 학습 모델인 의사결정 나무(Decision Tree), 랜덤 포레스트(Random Forest), SVM(Support Vector Machine)과 심층 학습(Deep Learning) 모델인 1D CNN(Convolutional Neural Network)을 사용하여 낙상 검출 성능을 측정하고 비교하였다. 1D CNN의 구조는 Fig. 1에

※ 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No.2020-0-01826, AI기반 선도적 실전문제해결 연구인재 양성).

※ 이 논문은 2020년 한국정보처리학회 춘계학술발표대회에서 "기계학습 기반의 낙상 검출"의 제목으로 발표된 논문을 확장한 것임.

† 준 회원 : 국민대학교 컴퓨터공학과 석사과정

†† 비 회원 : 국민대학교 컴퓨터공학과 석사과정

††† 비 회원 : 인천대학교 정보통신공학과 조교수

†††† 비 회원 : 국민대학교 SW학부 조교수

Manuscript Received : July 22, 2020

First Revision : January 11, 2021

Accepted : January 16, 2021

* Corresponding Author : Jaekoo Lee(jaekoo@kookmin.ac.kr)

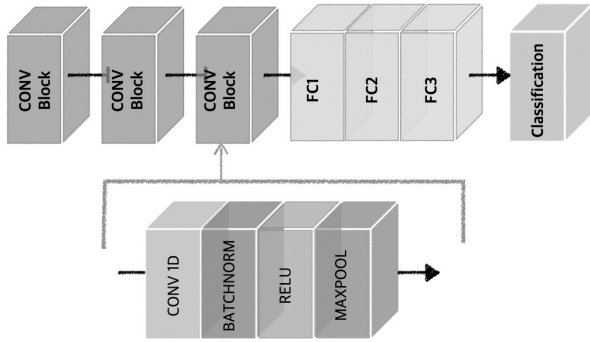


Fig. 1. 1D CNN Structure

서 확인할 수 있다. 실험 결과 기계 학습 모델 중 SVM의 F1 점수가 86%로 가장 높았고, 1D CNN의 F1 점수는 94%로 실험에 사용한 모델 중 성능이 가장 좋았다. 논문에서는 모델에 적용하기 위한 낙상 검출에 특화된 데이터 분할, 전처리 및 기계 학습을 위한 특징 추출 방법에 대해서도 함께 논할 예정이다.

2. 관련 연구

국내에서 진행된 연구들 중 기계 학습이나 심층 학습을 사용한 관련 연구의 다수는 웨어러블 기기와 같은 센서를 통해 추출한 센서 데이터 기반이 아닌 카메라를 통해 얻은 영상을 분석해서 낙상을 검출하고 예측하였다[4-7]. 이 외에도 낙상 이후 발생하는 실내 바닥의 진동을 측정, 분석하여 낙상의 유무를 판단한 연구도 존재한다[8]. 센서 데이터만 이용한 연구도 존재하지만 기계 학습이나 심층 학습을 사용한 경우가 아닌 단순 임계점을 기준으로 낙상과 ADL을 구분한 연구가 대다수였다[9]. 카메라를 통해 영상을 분석한 연구와 바닥의 진동을 이용한 연구는 낙상 검출 공간이 실내로 제한되며 검출 기기를 모두 실내에 설치해야 한다는 제한점을 갖는다. 임계점을 통해 낙상을 검출하는 연구의 경우, 사람이 경험적으로 임계점 값을 설정하고 이를 기준으로 낙상을 검출하는 것이기 때문에 신호 자체에 대한 규칙 분석이나 특징 추출이 부재하다. 이는 낙상의 규칙을 통한 검출이 아니기 때문에 일반화된 검출을 유도할 수 없다는 한계를 가지고 있다. 따라서 본 논문에서는 직접 추출한 특징을 적용하는 기계 학습 모델과 모델이 스스로 특징을 추출하여 학습하는 심층 학습 모델을 모두 적용하여 성능을 비교하고자 한다. 이를 통해 기계 학습과 심층 학습 기반의 낙상 검출에 대한 포괄적인 이해를 전달하고자 한다.

3. 본 문

3.1 1D CNN

CNN은 인간의 시신경을 모방하여 만든 심층 학습 구조 중 하나이다. 인간의 시신경 뉴런들은 작은 수용장(receptive

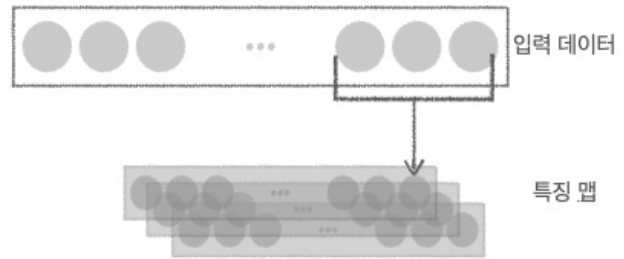


Fig. 2. 1D CNN Structure

field)을 가지고 있는데 여러 수용장이 겹쳐서 이를 합치면 전체 시야를 감싸는 구조를 갖게 된다. 1D CNN의 합성곱 층은 Fig. 2와 같이 필터(Filter)의 형태가 1차원으로 이루어져 있다. 필터가 이동하면서 한 수용장 안의 내용과 합성곱 층의 뉴런을 연결한다. 1D CNN을 사용하면 순환 신경망과 같은 다른 심층 학습 모델을 사용할 때보다 연산량이 적지만 비슷하게 높은 성능을 유도할 수 있는 이점이 있기 때문에 1D CNN을 사용하여 실험을 진행하였다.

3.2 데이터 설명

본 실험에서는 공개 데이터인 MobiAct 데이터 셋을 사용하였다[10]. MobiAct 데이터에는 11가지의 ADL과 4가지의 낙상데이터가 포함되어 있다. 수집된 데이터는 상황에 대한 라벨 값을 모두 포함하고 있다. 실험에는 가속도계 신호만을 이용하였다. 낙상이 발생하는 상황에서의 가속도계 신호 데이터를 시각화한 결과는 Fig. 3과 같다. Fig. 3의 분할된 영역은 각각 순서대로 'STD(서있기)', 'FALL(낙상)', 'LYI(누워있기)'를 의미한다.

3.3 데이터 분할

낙상의 특징을 추출하기 위해서 낙상이 일어나기 전 상황과 낙상이 발생한 후의 상황을 모두 포함해서 전처리를 진행했다. 기계 학습에 적용하기 위한 데이터의 경우 낙상으로 레이블 되어있던 부분을 기준으로 앞뒤로 1초 간격의 'STD'와 'LYI'가 포함되도록 수정하였다. 그 다음으로 모든 데이터 샘플

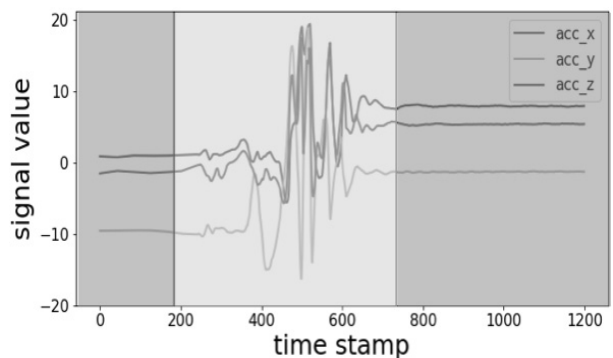


Fig. 3. MobiAct Data Sample

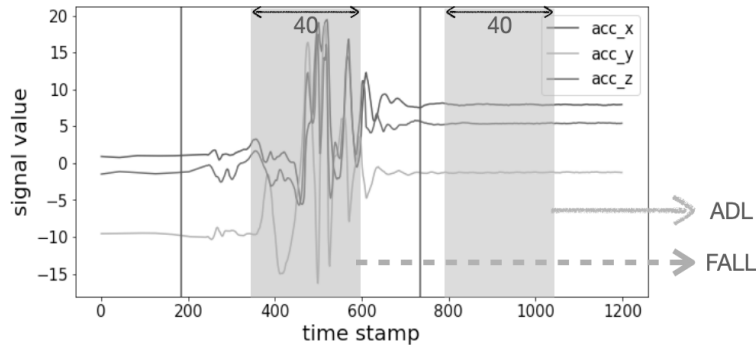


Fig. 4. Data Segmentation Method for 1D CNN

플의 길이를 '낙상'의 길이 중 최대 길이에 맞추어 푸리에 방법(Fourier Method)을 사용하여 재샘플링(Resampling)하였다. 이전 연구들[11,12]에서 낙상이 일어나는 시점부터 낙상이 발생한 후까지의 시간을 모두 포함하는 적절한 시간 간격이 약 2초라고 판단하였다. 실험에서는 데이터를 분할하는 한 윈도우가 141개의 값을 포함하도록 설정하였다. 즉, 한 윈도우 당 약 2초를 포함할 수 있도록 하였다.

심층 학습에 적용하기 위한 데이터의 경우, Fig. 4처럼 낙상으로 레이블 되어있는 데이터 구간을 30개의 샘플로 푸리에 방법을 사용하여 재샘플링하였다. 이후 재샘플링한 구간의 양쪽에 ADL 샘플을 추가하여 총 50개의 샘플을 하나의 데이터로 구성하였다. 이후 크기가 40인 윈도우(Window)를 데이터 샘플마다 이동하면서 30개의 낙상 데이터 샘플을 모두 포함한 경우에만 라벨을 '낙상'으로 설정하였다. ADL의 경우 MobiAct의 ADL 데이터를 사용하여 윈도우 크기를 40으로 설정하여 데이터를 추출하였다.

이후 평균 이동 필터(Average Filter)를 사용하여 신호들의 잡음을 제거하였다. 사용한 평균 이동 필터는 $M=2$ 인 다음의 식을 이용하였다.

$$Y[i] = \frac{1}{M} \sum_{j=-\frac{M-1}{2}}^{\frac{M-1}{2}} X[i+j] \quad (1)$$

3.4 특징 추출

특징 추출에 사용된 입력 값 벡터는 다음과 같다.

- 1) (a_x, a_y, a_z) 는 각각 가속도계 신호 데이터의 x, y, z 축 데이터를 의미한다. 3개의 축에 대해 각각 141개 샘플을 포함하는 $Y(1, \dots, 3, 1, \dots, 141)$ 로 표현할 수 있다.
- 2) A 는 x, y, z 축에 대한 삼차원 가속도를 의미한다. 각 축 벡터의 크기를 사용하여 계산하며 계산식은 아래와 같다.

$$A(1, \dots, 141) = \sqrt{Y(1, 1, \dots, 141)^2 + Y(2, 1, \dots, 141)^2 + Y(3, 1, \dots, 141)^2} \quad (2)$$

- 3) AV 는 벡터 A 의 각도 변화를 의미한다. AV 를 통해서 몸이 변화하는 각도를 계산하며 모든 x, y, z 에 대한 141차원의 벡터로 표현한다. n 은 1부터 141까지이며 이 값들을 통해 변화하는 (a_x, a_y, a_z) 에 대한 각도를 구할 수 있다.

$$AV = \left[\left[\cos^{-1} \left(\frac{Y^n * Y^{n+1}}{\|Y^n\| * \|Y^{n+1}\|} \right) \right] \right] \quad (3)$$

결과적으로 (a_x, a_y, a_z, A, AV) 는 특징을 추출하기 위해 사용한 벡터이다. 5개 벡터를 x 라고 칭할 때, 추출된 통계적 혹은 신호적 특징들은 다음과 같다.

- 1) 평균(Average): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 각각의 평균 값을 계산한다.
- 2) 최대값(Maximum): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 각각의 최대 값 계산하였다.
- 3) 최소값(Minimum): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 각각의 최소 값 계산하였다.
- 4) 에너지(Energy): 이산 신호의 에너지는 다음의 방법으로 계산하였다.

$$E = \sum_{i=1}^n |x[n] \text{ RIGHT}|^2 \quad (4)$$

- 5) 스펙트럴 에너지(Spectral Energy): 이산 신호의 푸리에 변환을 사용하여 스펙트럴 에너지 값을 계산하였다.

$$E = \sum_{i=1}^n |FFT(x)|^2 \quad (5)$$

- 6) 표준편차(Standard Deviation): 다섯 개의 벡터를 모두 사용하여 시간 윈도우 내의 표준 편차를 계산하였다.
- 7) 상관도(Correlation): 가속도계 벡터 사이의 상관도를 계산하였다. 즉 $(a_x, a_y), (a_x, a_z), (a_y, a_z)$ 사이의 상관도를 측정하였다.

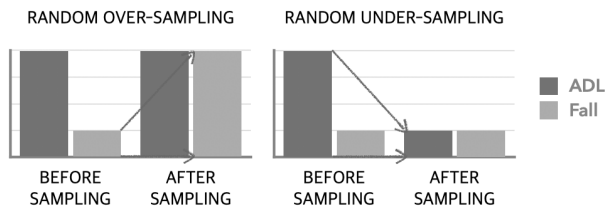


Fig. 5. Random Over-Dampling and Tandom Under-Sampling Method

$$corr(x,y) = \frac{E((X-\mu_x)(Y-\mu_y))}{\sigma_x \sigma_y} \quad (6)$$

제시된 방법들을 통해서 총 33개의 특징들을 추출하였고 이를 기계 학습 모델에 적용하였다.

3.5 임의 복원 추출

MobiAct 데이터의 낙상 데이터 비율이 ADL 데이터 비율보다 작기 때문에 데이터의 비율을 동일하게 맞추기 위한 임의 복원 추출 과정을 함께 진행하였다. 큰 데이터 수에 맞춘 임의 복원 추출(Random Over-Sampling)과 작은 데이터 수에 맞춘 임의 복원 추출(Random Under-Sampling)을 모두 진행하고 실험 결과를 비교하였다.

큰 데이터 수에 맞춘 임의 복원 추출의 경우, 더 적은 클래스의 인스턴스를 임의로 복제하여 데이터의 개수를 맞추준다. 작은 데이터 수에 맞춘 임의 복원 추출의 경우, 높은 비중을 차지하는 클래스의 값들을 임의로 제거하는 방식을 사용하였다.

4. 실험 결과

기계 학습 모델로는 의사결정 나무, 랜덤 포레스트, SVM을 사

용하였고 심층 학습 모델로는 1D CNN을 사용하였다. 실험 데이터의 경우 작은 데이터 수에 맞춰 임의 복원 추출하였다. 1D CNN의 경우 훈련 과정에서 교차 검증(Cross-Validation)을 사용하여 학습을 진행하였다. Table 1에서 실험 결과를 확인할 수 있다.

정밀도(Precision)와 재현율(Recall)의 경우 상충 관계에 있기 때문에 하나의 점수가 높으면 상대적으로 다른 점수가 낮은 경향을 보여주고 있다. 낙상 검출에서는 정확도(Accuracy) 점수만큼 정밀도와 재현율의 점수가 적절하게 함께 높아야 한다. 정밀도 점수는 잘못된 알람(False Alarm)의 여부를 알려주기 때문에 중요하다. 다른 연구들에서도 정밀도와 재현율을 함께 참고할 수 있는 F1 점수를 함께 사용한다.

기계 학습 모델의 실험 결과에서 전반적으로 작은 데이터에 맞춰 임의 복원 추출한 결과보다 큰 데이터에 맞춰 임의 복원 추출한 실험의 성능이 더 좋은 경향을 보여준다. 기계 학습 실험에서 F1 점수는 SVM을 큰 데이터에 맞추어 임의 복원 추출했을 때 86%로 가장 높았다. 정확도 점수 또한 큰 데이터에 맞추어 임의 복원 추출한 데이터를 사용한 SVM과 랜덤포레스트가 85%로 가장 높은 성능을 보였다.

1D CNN의 성능은 SVM보다 재현율을 제외한 모든 평가 지표에서 평균 7.7% 더 우수했다. 낙상 검출에서 중요한 F1 점수와 정밀도 점수에서 1D CNN은 SVM에 비해 각각 8%, 18% 더 우수했다. 교차 검증의 정확도는 95%, F1 점수는 94%를 달성하였다.

효율성 측면에서 기계학습 모델 중 가장 좋은 성능을 보여준 SVM의 경우, 큰 데이터에 맞춰 임의 복원 추출한 실험에서 학습 시간과 시험 시간에 각각 16.4초와 1.13초가 소요되었다. 반면 1D CNN은 검증 데이터셋에서 조기 멈춤을 적용했을 때 총 11에포크(Epoch)를 반복하였고 학습하는 데 12.2초가 소요되었고 시험 시간에 0.21초가 소요되었다. 이를 통해서 1D CNN을 활용하여 빠르고 정확하게 낙상을 검출할 수 있음을 증명하였다.

Table 1. Experimental Results

| | F1 Score | Precision | Recall | Accuracy |
|-----------------------|----------|-----------|--------|----------|
| Decision Tree | | | | |
| Random Under-Sampling | 0.77 | 0.76 | 0.78 | 0.77 |
| Random Over-Sampling | 0.77 | 0.79 | 0.76 | 0.78 |
| Random Forest | | | | |
| Random Under-Sampling | 0.83 | 0.79 | 0.88 | 0.82 |
| Random Over-Sampling | 0.85 | 0.86 | 0.83 | 0.85 |
| SVM | | | | |
| Random Under-Sampling | 0.85 | 0.80 | 0.90 | 0.84 |
| Random Over-Sampling | 0.86 | 0.82 | 0.90 | 0.85 |
| 1D CNN | | | | |
| Cross-Validation | 0.94 | 1.00 | 0.87 | 0.94 |

Table 2. Efficiency Comparison

| Model | Environment | Train Time(seconds) | Test Time(seconds) |
|--------|------------------|---------------------|--------------------|
| SVM | CPU E5-2698 | 16.4 s | 1.13 s |
| 1D CNN | GeForce GTX 1070 | 12.2 s | 0.21 s |

5. 결 론

이전 연구들에서 낙상을 검출하기 위한 방법으로 주로 영상을 사용하였다. 하지만 영상을 사용한 낙상 검출은 카메라를 실내에 설치해야 하기 때문에 초기 설치 비용이 비싸고 낙상 검출 공간이 실내로 제한된다는 한계점을 가지고 있다. 때문에 본 논문에서는 다양한 낙상 검출 방법 중 초기 설치비용이 상대적으로 저렴하고 실내외에서도 낙상을 바로 검출 할 수 있는 웨어러블 기기 기반의 센서 데이터를 사용하여 낙상 검출을 실험하였다. 이를 위해 기계 학습 모델과 심층 학습 모델을 사용하여 성능을 비교하였다. 대표적인 기계 학습 모델인 의사 결정 나무, 랜덤 포레스트, SVM 등을 적용하였고, 심층 학습 모델로는 1D CNN을 적용하였다. 모델에 적용하기 위한 데이터 분할 및 전처리를 적용하였고 기계 학습에 적용하기 위한 특징도 함께 추출하여 전반적인 낙상 검출에 대해 정략적으로 검증하였다. SVM의 낙상 검출 성능이 다른 기계 학습 모델에 비해 가장 높았으나 1D CNN의 검출 성능이 SVM에 비해 모든 성능 지표에서 평균 7.5% 더 높음을 확인하였다. 즉, 심층 학습 모델이 기계 학습 모델을 적용하였을 때보다 더 우수함을 증명하였다. 또한 1D CNN을 통해 빠르고 정확하게 낙상을 검출 할 수 있음을 증명하였다. 본 연구 결과를 기반으로 심층 학습을 적용한 낙상 종류 분류 실험을 진행하고자 한다.

References

- [1] D. Yachhirema, J. S. de Puga, C. Palau, and M. Esteve, "Fall detection system for elderly people using IoT and big data," *Procedia Computer Science*, Vol.130, pp.603-610, 2018.
- [2] Ministry of Health and Welfare, "2017 Survey of the Elderly," 2017.
- [3] S. R. Lord, C. Sherrington, and J. C. Close, "Falls in Older People: Risk Factors and Strategies for Prevention," Cambridge Univ. Press, 2007.
- [4] Sye-Hyun Hwang and Sung Bum Pan, "Fall Detection System Using the Open Source Hardware and RGB Camera," *The Journal of Korean Institute of Information Technology*, Vol.14, No.4, pp.19-24, 2016.
- [5] Serdaroglu Werkan, "Video Based Fall Down Detection with Deep Learning," *Institute of Control, Robotics and Systems*, Vol.2018, No.5, pp.273-274, 2018.
- [6] Dae-Eon Kim and BonKyue Jeon, "3D Convolutional Neural Networks based Fall Detection with Thermal Camera," *Journal of Korea Robotics Society*, Vol.13, No.1, pp. 45-54, 2018.
- [7] Seon-Gi Kim and Jong-Soo Ahn, "Implementation of fall-down detection algorithm based on Image Processing," *Journal of Satellite, Information and Communications*, Vol.12, Iss.2, pp.56-60, 2017.
- [8] Dong-Wan Kim, Jong-Hyun Rye, and Seung-Hwa Beack, "Fall detection of the elderly through floor vibrations," *Journal of Institute of Korean Electrical and Electronics Engineers*, Vol.18, No.1, pp.134-139, 2014.
- [9] S. J. Ahn and J. M. Kim, "The evaluation of pre-impact fall detection algorithm using public dataset," *Rehabilitation Engineering And Assistive Technology Society of Korea*, pp.192-193, 2018.
- [10] G. Vavoulas, M. Padiaditis, C. Chatzaki, E. G. Spanakis, and M. Tsiknakis, "The mobifall dataset: Fall detection and classification with a smartphone," In: *Artificial intelligence: Concepts, methodologies, tools, and applications*, IGIglobal, pp.1218-1231, 2017.
- [11] R. M. Gibson, A. Amira, N. Ramzan, P. Casaseca-de-la-Higuera, and Z. Pervez, "Multiplecomparator classifier framework for accelerometer-based fall detection and diagnostic," *Applied Soft Computing*, Vol.39, pp.94-103, 2016.
- [12] Banos, O., Galvez, J. M., Damas, M., Pomares, H., and Rojas, I. "Window size impact in human activity recognition," *Sensors*, Vol.14, No.4, pp.6474-6499, 2014.



김 인 경


<https://orcid.org/0000-0002-6373-7646>

e-mail : kim_jenn@kookmin.ac.kr

2020년 국민대학교 정치외교학(학사)

2020년~현 재 국민대학교 컴퓨터공학과 석사과정

관심분야 : Artificial Intelligence(AI) & Time Series Analysis



김 대 희

<https://orcid.org/0000-0001-9676-9604>

e-mail : frshield2@kookmin.ac.kr

2020년 국민대학교 소프트웨어전공(학사)

2020년~현 재 국민대학교 컴퓨터공학과 석사과정

관심분야 : Artificial Intelligence(AI) & Super Resolution & Object Detection



노 송

<https://orcid.org/0000-0002-0106-7106>
e-mail : songnoh@inu.ac.kr
2015년 미국 Purdue University, Electrical
and Computer Engineering(박사)
2015년 ~ 2018년 미국 Intel Corp. 시스템
엔지니어

2018년 ~ 현 재 인천대학교 정보통신공학과 조교수
관심분야: Signal Processing & Smart System Design



이 재 구

<https://orcid.org/0000-0002-5947-5487>
e-mail : jaekoo@kookmin.ac.kr
2018년 서울대학교 전기컴퓨터공학부(박사)
2011년 ~ 2013년 LG전자 CTO부문
주임연구원
2018년 SK텔레콤 ICT기술원 매니저

2018년 ~ 현 재 국민대학교 SW학부 조교수
관심분야: Artificial Intelligence(AI) & Machine Learning &
Deep Learning & Data Science