

딥러닝 기반 낙상 감지 시스템의 구성과 적용

우종석¹, 리오넬¹, 정상중², 정완영^{1*}

¹부경대학교 인공지능융합학과, ²동서대학교 인공지능융합학과

Configuration and Application of a deep learning-based fall detection system

Jong-Seok Woo¹, Lionel Kyenyeneye¹, Sang-Joong Jung², Wan-Young Chung^{1*}

¹Dept. of Artificial Intelligence Convergence, Pukyong National University

²Dept. of Applied Artificial Intelligence, Dongseo University

요약 낙상은 일상의 활동 중에 예기치 않게 발생하여 생활에 많은 어려움을 초래한다. 본 연구는 고위험 직종 종사자들의 낙상 감지를 위한 시스템을 구성하고 자료를 수집하여 예측 모델에 적용함으로써 그 유효성을 검증하는 것을 목적으로 하였다. 이를 위해 가속도센서와 자이로센서를 통해 가속도 신호와 방위각을 산출하여 낙상 여부를 감지하는 웨어러블 기기를 구성하였다. 그리고 연구 참여자들이 이 기기를 복부에 착용하고 정해진 활동을 수행하는 과정에서 낙상과 관련한 동작으로부터 필요한 데이터를 측정하고 기기 내에 존재하는 블루투스 장치를 통해 컴퓨터로 전송하였다. 이렇게 수집된 데이터를 필터링 등을 통해 처리하여 딥러닝 알고리즘들인 1D CNN, LSTM, CNN-LSTM에 근거한 낙상 감지 예측 모델들에 적용하고 그 결과를 평가하였다.

• 주제어 : 낙상 감지, 딥러닝 알고리즘, 웨어러블 기기, 필터링, 처리

Abstract Falling occurs unexpectedly during daily activities, causing many difficulties in life. The purpose of this study was to establish a system for fall detection of high-risk occupations and to verify their effectiveness by collecting data and applying it to predictive models. To this end, a wearable device was configured to detect fall by calculating acceleration signals and azimuths through acceleration sensors and gyro sensors. In addition, the study participants wore the device on their abdomen and measured necessary data from falls-related movements in the process of performing predetermined activities and transmitted it to the computer through a Bluetooth device present in the device. The collected data was processed through filtering, applied to fall detection prediction models based on deep learning algorithms which are 1D CNN, LSTM and CNN-LSTM, and evaluate the results.

• Key Words : Fall detection, deep-learning algorithm, wearable device, filtering, processing

Received 8 November 2023, Revised 26 December 2023, Accepted 28 December 2023

* Corresponding Author Wan-Young Chung, Dept. of Artificial Intelligence Convergence, Pukyong National University, 45, Yongso-ro, Nam-gu, Busan, Korea. E-mail: wychung@pknu.ac.kr

I. 서론

낙상과 관련한 문제는 주로 노인들의 의료 사고를 중심으로 주목을 받았다. 물론 낙상은 노인에게서 발생률이 높지만[1], 실제로는 모든 연령에서 발생할 수 있다. 특히 건설업 등의 산업 현장 종사자를 비롯하여 소방관과 같이 고위험 직종에 종사하는 사람들은 낙상 사고의 위험에 크게 노출되어 있다.

실제로 국내 2022년 산업재해 발생 현황을 보면, 전체 재해자 중에서 넘어짐(19.24%)과 떨어짐(11.04%)의 비율이 여타 부분보다 높으며, 이러한 낙상과 관련되는 사고에 의한 산업재해는 건설업(41.29%) 등의 고위험 직종에서 주로 발생하는 것으로 나타났다[2]. 또한 낙상과 관련되는 또 다른 고위험 직종인 소방직 공무원들의 최근 5년간(2018-2022) 피해 현황을 보면 순직 24명, 공상 4,658명에 이르렀다[3]. 이에 따라 이와 관련한 연구의 필요성이 증가하고 있다[4].

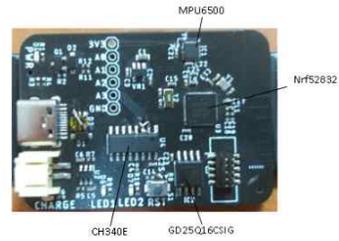
본 연구는 고위험 직종 종사자들의 낙상 감지를 위한 예측 모델을 생성하고 그 유효성을 검증하는 것을 목적으로 하였다. 낙상 감지는 크게 상황 인식 시스템과 웨어러블 장치 시스템으로 나뉜다[5]. 상황 인식 시스템은 사용자의 신체에 무언가를 부착하지 않아도 된다는 장점이 있지만[6], 실내에 제한되거나 사각지대에서 발생하는 상황을 감지하지 못한다는 단점이 존재한다[7]. 이에 따라 본 연구는 웨어러블 장치를 이용하는 측정 방식을 적용하였으며, 가속도센서와 자이로센서를 통해 가속도 신호와 방위각을 산출하여 낙상 여부를 감지하는 장치를 구성하였다[8-9]. 센서는 손목과 같은 움직임이 많은 부위에 부착하기도 하고[10] 허리에 부착하기도 한다[11]. 본 연구는 이 장치를 안정적인 데이터 획득을 위해 복부에 착용하고 수행한 동작을 모니터링하여 데이터를 관련 수집하고, 수집된 데이터를 처리하여 CNN, LSTM, CNN-LSTM 등에 근거한 낙상 감지 예측 모델에 적용하였다. 그리고 감지 모델의 성능은 Recall 값에 영향을 받기 때문에[12] Recall 값을 중심으로 그 성능을 평가하였다.

II. 시스템의 구성

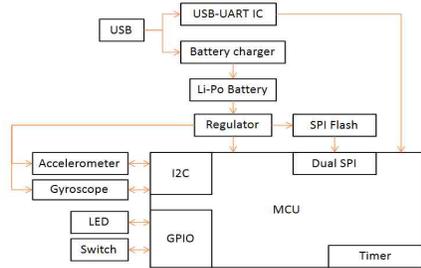
2.1. 웨어러블 장치의 설계

본 연구에서는 고위험 직종 종사자들의 활동 현장에서 낙상 사고가 발생했을 때, 신속하게 사고를 인지

하고 필요한 조치를 취하는 데 유용하도록 다음의 Fig. 1과 같이 현장에 적용할 수 있는 낙상 감지 시스템을 구현하여 PCB를 설계 제작하였다. 이 시스템에는 IMU 센서인 MPU6500을 장착하였는데, 이것은 선형 가속도를 측정하는 3축 가속도센서와 X, Y, Z축을 이용한 회전속도를 측정하는 3축 각속도센서로 구성되었다. 이를 통해 사용자가 움직이는 방향과 움직임 도중 기울어지는 정도를 측정하였다.



(a) Hardware device



(b) Block diagram

Fig. 1. Overall device structure

MPU6500은 6축 측정 센서이며 가속도의 측정 범위를 $\pm 16g$ 로, 각속도의 측정 범위는 $\pm 2000\text{deg/sec}$ 로 하였다. 이 장치에는 저전력으로 작동이 가능한 MCU 이면서 Bluetooth Low Energy 통신을 지원하는 NRF52832를 사용하였다. 그리고 이 장치는 3.7V, 600mA에 해당하는 Lithium polymer battery를 연결하여 별도의 외부 전원 없이도 작동할 수 있으며, 또한 배터리의 충전 역시 가능하게 되어 있다.

2.2. 모델의 구현

낙상 감지의 유효성을 평가하기 위해 1D CNN, LSTM, CNN-LSTM에 기반한 세 가지 모델을 구현하였다. 이를 위해 브라우저를 통해 Python 코드를 작성할 수 있는 구글 코랩을 이용하였으며, 환경 구성에 사용된 툴을 정리하면 다음과 같다.

Table 1. Development tool

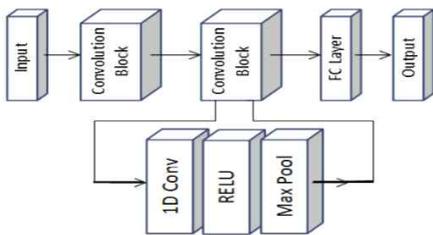
Tool	Specification
Platform	Google Colaboratory
Language	Python 3
Module	TensorFlow
GPU	V100

이런 모델들의 경우, 하이퍼 파라미터를 사용자가 설정하여 딥러닝 모델의 학습 프로세스를 제어하는데, 하이퍼 파라미터를 어떻게 설정하는가에 따라 모델의 결과값이 달라진다. Sigmoid 함수를 이용하여 각 시점에서의 낙상 발생을 예측하게 하였고, MinMaxScaler를 통해 기울기 소실 문제를 완화하며 동시에 학습의 안정성과 효율성을 증가시켰다. 하이퍼 파라미터는 모델의 정확성과 성능에 직접적인 영향을 미치기 때문에 각 모델에 대해 동일한 조건의 하이퍼 파라미터를 동일적으로 설정하였다.

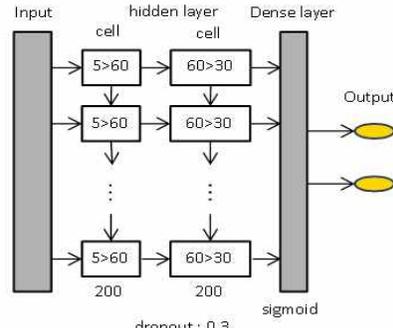
Table 2. Fixed hyper parameter setting

Hyper parameter	Common Parameter Setting
Normalization	MinMaxScaler
Optimization Function	adam
Loss Function	crossentropy
Dropout	30%
Activation Function	sigmoid
Sequence Length	200 Frame

1D CNN은 CNN 모델의 일종으로, CNN을 시계열 분석에 적용하기 위해 구현된 것이다. 이것을 바탕으로 합성곱 레이어에 ReLU 함수와 Max Pooling 레이어를 연결시킨 블록 2개를 배치하였다. 그리고 LSTM은 RNN의 장기 의존성 문제를 해결하기 위해 나온 모델이다. 이에 대해서는 2개의 LSTM 레이어를 적용하였으며 첫 레이어는 60개의 유닛을, 두 번째 레이어는 30개의 유닛을 적용하였다.



(a) 1D CNN Structure



(b) LSTM Structure

Fig. 2. Model Structure

그리고 CNN-LSTM의 경우는 1D CNN의 구조에서 두 번째 Convolution Block의 위치에 LSTM의 구조를 적용하여 독립된 모델로 설정하였다.

III. 데이터의 수집 및 처리

3.1. 실험 환경

실생활에서 행해지는 동작들은 대부분 연속적이어서 쉽게 구분되지 않는데, 본 연구에서는 낙상과 관련하여 일상적인 동작을 ADL(activity of daily life)과 낙상(fall)으로 구분하였다[13-14]. 여기서 ADL에는 서 있기, 걷기, 달리기, 앉았다 일어나기, 누웠다 일어나기, 계단 오르기가 포함되고, 낙상에는 앞으로 넘어지기, 뒤로 넘어지기, 옆으로 넘어지기가 포함되었다. 그리고 실험 참가자들에게 이러한 동작을 수행하도록 하고 데이터를 수집하였다.

Table 3. Action Classification

Task	Description
서있기	일정시간 움직이지 않기
걷기	평지에서 30m 천천히 이동
달리기	정해진 시간동안 정해진 코스를 달리기
앉았다 일어나기	서있는 상태에서 의자에 앉았다 다시 일어나기 20회
누웠다 일어나기	서있는 상태에서 매트에 누웠다 다시 일어나기 20회
계단오르기	60초 동안 계단 오르내리기
앞으로 넘어지기	준비된 매트에 정해진 자세로 넘어지기 10회
뒤로 넘어지기	
옆으로 넘어지기	

데이터는 3축 가속도의 값과 roll, pitch 값 이외에 가속도의 크기를 수신 단계에서 함께 측정하였으며, 그 결과로 나타난 가속도의 크기와 roll, pitch 값을 기반으로 하여 낙상에 관련되는 데이터를 데이터 윈도우로 분류하였다. 각 윈도우는 낙상 시점과 전후의 데이터가 함께 들어갈 수 있도록 2초간 200개의 데이터가 포함되도록 설정하였다[15].

낙상이 발생하면 사람의 몸이 기울어지면서 지면에 부딪히는 상황에 이르기까지 각도가 크게 변하며, 지면에 몸이 닿은 이후에도 신체 상태가 안정될 때까지 일정한 시간이 걸린다. 이를 근거로 roll, pitch 값과 가속도의 크기를 비교하여 낙상의 시작과 끝을 정하고, 그에 기반하여 낙상을 구별하였다. 이를 예시하면 다음 Fig. 3과 같다.

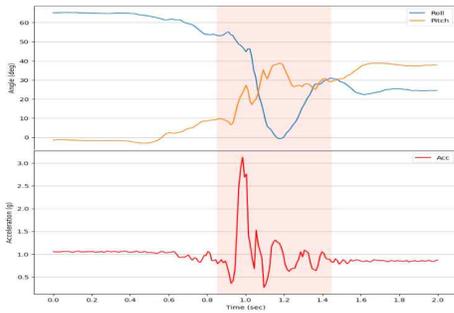
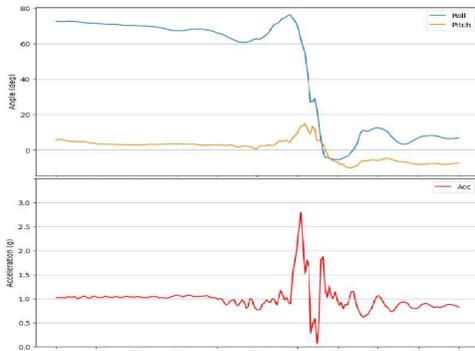
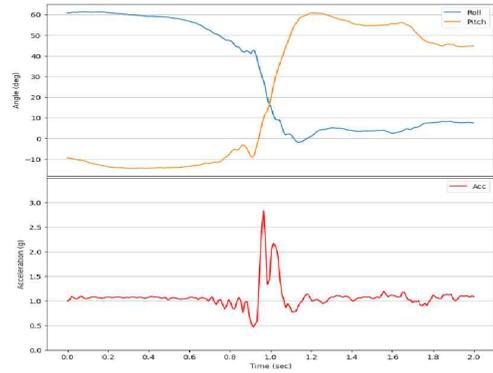


Fig. 3. Defining Fall Range by Comparing Changes in Angle and Magnitude of Acceleration.

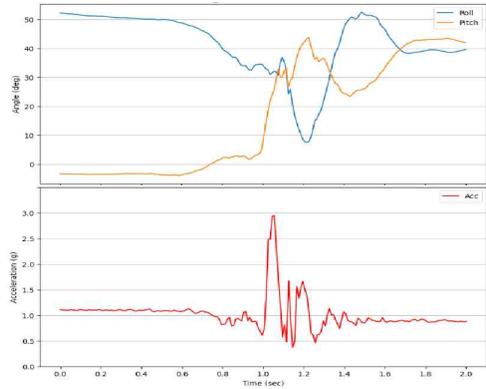
실제로 세 유형(forward, backward, side)의 낙상은 유사하면서도 각각 독특한 양상을 보였는데, 이것을 예시하면 다음 Fig. 4와 같다.



(a) Forward fall data



(b) Backward fall data



(c) Side fall data

Fig. 4. Example of falling experiment data

3.2. 각도 측정

IMU 센서를 활용하여 각도를 구할 때, 가속도센서는 진동 등의 고주파에 취약하며, 자이로센서는 드리프트와 같은 저주파의 영향을 받게 된다. 따라서 센서를 통합하고 노이즈를 줄이기 위해 필터링이 요구되는데, 이에 대해 상보 필터(complementary filter)를 활용하여 가속도센서와 자이로센서에서 나타나는 단점을 보완하도록 하였다. 이 상보 필터를 수식으로 나타내면 다음 (1)과 같다.

$$Angle = a(pre_Angle + Angle_{gyr}) + (1-a)Angle_{acc} \quad (1)$$

여기서 a 는 가중치로, 일반적으로 자이로센서값을 더 신뢰해서 1에 가까운 값을 가지게 된다. 본 연구에서는 가중치를 0.95로 설정하였으며, 따라서 최종적으로 측정하고자 하는 각도인 roll, pitch 값은 다음 수식 (2), (3)과같이 하였다.

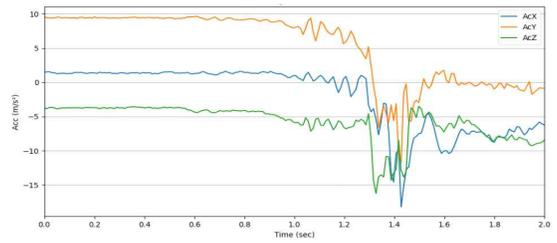
$$roll = 0.95(gx*dt + Angle_{gyr}) + 0.05*atan2(-ax, az)*180/PI \quad (2)$$

$$pitch = 0.95(gy*dt + Angle_{gyr}) + 0.05*atan2(-ax, \sqrt{(ay)^2 + (az)^2})*180/PI \quad (3)$$

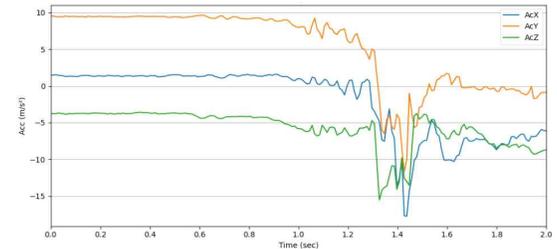
그리고 계산은 측정 장치의 MCU 내에서 수행되며 가속도 값과 함께 서버로 전송되도록 하였다.

3.3. 데이터 증강

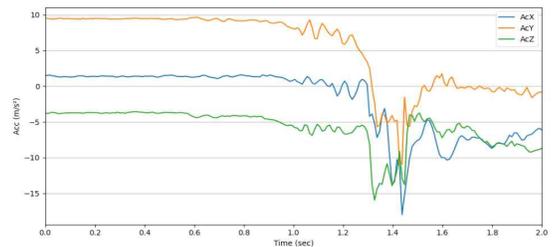
낙상은 그 위험성으로 인해 데이터 수집에 어느 정도 한계가 있다. 그런데 데이터가 부족하면 과적합(overfitting)과 같은 문제가 생기면서 알고리즘 적용 과정에서 학습이 제대로 이루어지지 않을 수 있다. 이런 문제를 해결하기 위해 데이터 증강(augmentation)을 통해 개선할 필요가 있다. 본 연구에서는 시계열 데이터에 적용이 용이한 가우시안 노이즈(Gaussian Noise) 추가와 시간 왜곡(Time Warping)을 적용하여 ADL과 낙상 데이터 간의 비율 차이를 완화하였다. 다만 가속도의 크기는 3축 가속도센서의 값에 의해 결정되기 때문에 데이터 증강이 직접적으로 적용되지 않도록 하였다. 그 대신에 증강을 통해 3축 센서값이 변하면 가속도의 크기 값도 변하므로, 가속도 크기의 값은 변화된 3축 센서값에 따라 계산되어 저장되도록 설정하였다. 데이터 증강 적용 전후의 상황은 Fig. 5와 같다.



(a) Before augmentation



(b) Noise added augmentation



(c) Time distortion augmentation

Fig. 5. Comparison of Augmented Data.

Table 3. Result according to learning rate

	Learning Rate	Accuracy	Precision	Recall	F1-Score
1D CNN	0.001	0.933	0.804	0.652	0.720
	0.0005	0.940	0.792	0.731	0.760
	0.0001	0.947	0.864	0.701	0.774
LSTM	0.001	0.942	0.810	0.721	0.763
	0.0005	0.935	0.763	0.732	0.747
	0.0001	0.952	0.812	0.823	0.817
CNN-LSTM	0.001	0.940	0.837	0.670	0.745
	0.0005	0.951	0.886	0.720	0.794
	0.0001	0.944	0.910	0.634	0.747

IV. 적용 결과

수집하여 처리한 데이터를 앞 2장에서 구현한 모델의 학습에 적용하고 그 결과를 비교 평가하였다. 이에 대해 scikit-learn에서 제공하는 분류 예측 리포트인 classification_report에 의거하여 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-Score를 계측하여 평가 지표로 삼았다. 그리고 학습률은 학습의 속도와 안정성에 직접적으로 관련되기 때문에 최적의 결과를 얻기 위해서는 다양한 값을 부여하여 결과를 검토할 필요가 있다. 그리하여 학습률은 0.001, 0.0005, 0.0001의 세 가지 변수를 기준으로 하였다.

각 모델에 적용한 결과를 보면, 우선 1D CNN 모델은 전반적으로 학습률이 감소됨에 따라 평가 지표가 향상되는 양상을 보였다. 다만, Precision에서는 학습률 0.0005가 0.001에 비해 낮았으며, Recall에서는 학습률 0.0001이 0.0005에 비해 낮게 평가되었다. LSTM 모델 역시 전반적으로는 학습률이 감소됨에 따라 평가 지표가 향상되는 양상을 보였다. 다만, 학습률 0.0005에서 0.001에 비해 Recall을 제외한 나머지 세 가지 평가 지표가 낮게 나타났다. 그리고 CNN-LSTM은 CNN이나 LSTM과 달리 학습률이 감소됨에 따라 평가 지표가 높아지는 양상이 두드러지지 않았다. 특히 이것은 학습률 0.0005에서 Precision을 제외한 나머지 평가 지표가 높게 나타났다.

한편, 평가 지표 중에서 Recall은 긍정적 표본을 탐지하는 모델의 능력을 측정하므로, 낙상 감지의 평가에서 Recall 값은 중요한 요소가 된다. 이에 따라 위의 세 가지 모델의 경우 Recall 값을 기준으로 그 성능을 종합적으로 비교해 볼 수 있는데, 이를 위해 각 모델에서 Recall 값이 가장 높게 나타난 학습률 조건에서의 평가 지표별 측정값을 정리하면 다음과 같다.

Table 4. Result by deep learning models

	1D CNN	LSTM	CNN-LSTM
Accuracy	0.940	0.952	0.951
Precision	0.792	0.812	0.886
Recall	0.731	0.823	0.720
F1-score	0.760	0.817	0.794

위에서 보면, Precision을 제외하고 Accuracy를 비롯하여 Recall, 그리고 Recall과 Precision을 조합한 F1-score에서 LSTM이 가장 높게 나타났다. 그리고 가

장 높은 Recall 값이 도출된 LSTM의 정확도와 손실은 Fig. 6과 같이 나타났으며, 정확도는 전반적으로 우상향하고 손실은 우하향하는 양상을 보였다.

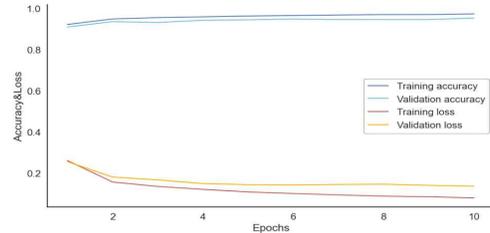


Fig. 6. Accuracy and loss of LSTM.

위의 Table 4에서 0.823으로 제시된 LSTM의 Recall 값은 유사 연구인 손목에 부착된 센서를 사용한 연구 [12]의 결괏값 중 하나인 Threshold 2.5를 기준으로 나타난 Recall 값 0.8333과 매우 유사한 수치에 해당한다.

이와 같은 결과를 통해 복잡하고 변동성이 강한 시계열 데이터의 처리에 강점이 있는 LSTM은 다른 모델에 비해 낙상 감지에 유의미한 결과를 도출해 줄 것으로 기대할 수 있다.

V. 결론

본 연구에서는 웨어러블 기기를 신체에 부착하여 낙상과 관련한 동작을 모니터링하고, 이를 통해 수집한 데이터를 딥러닝 모델에 적용하여 각 모델의 낙상 감지에 대한 유효성을 평가하였다. 구체적으로는 데이터 수집을 위한 기기를 구성하고, 데이터를 수집하여 특정한 크기의 세트에 분할하였으며, 이것을 딥러닝 모델인 1D CNN, LSTM, CNN-LSTM에 적용하였다. 이 과정에서 0.001, 0.0005, 0.0001의 세 가지 학습률 변수를 적용하여 주어진 지표로 평가하였을 때 LSTM이 가장 우수한 성능을 보이는 것을 확인할 수 있었다. 특히 낙상 감지에 중요한 지표로 작용하는 Recall을 기준으로 성능을 판별할 경우에도 LSTM이 더 나은 성능을 보여주었다.

본 연구에 더하여 낙상 동작에 대한 면밀한 모니터링을 통해 분석에 필요한 정보를 추가하고, 모델에 대한 파라미터를 다양한 방식으로 적용한다면 더욱 정밀한 판별이 가능할 것이다. 향후 좀 더 다양한 조건을 추가하여 낙상 감지 능력을 확인하는 연구를 지속하고자 한다.

REFERENCES

- [1] 질병관리청 국가건강정보포털
<https://health.kdca.go.kr/healthinfo/biz/health/gnrizHealthInfo/gnrizHealthInfo/gnrizHealthInfoView.do>
- [2] 고용노동부 정책자료실, ‘2022년 산업재해현황분석’,
https://www.moel.go.kr/info/publicct/publicctDataView.do?bbs_seq=20231202281
- [3] 소방청, ‘2023 소방청 통계연보’
https://www.nfa.go.kr/nfa/releaseinformation/statistical-information/main/?boardId=bbs_00000000000019&mode=view&cntId=55
- [4] Jae-Jung Kim, Min-Ho Park, Sin-Ho Kim, Ji-Yun Seo, Do-Un Jeong, “Implementation of the Fall Detection System based on IMU Sensor Applicable to Industrial Sites,” 한국정보통신학회 여성 ICT 학술대회 논문집, Vol. 2021 No. 8, pp.33-36, 2021.
- [5] Pil-Seong Jeong, Yang-Hyun Cho, “Fall Detection System based Internet of Things,” Journal of the Korea Institute Of Information and Communication Engineering, Vol. 19 No. 11, pp.2546-2553, 2015.
- [6] Lin, C. W., Z. H. Ling, Y. C. Chang, C. J. Kuo, “Compressed -domain Fall Incident Detection for Intelligent Homecare”, Tje Journal of VLSI Signal Processing, Vol. 49, No. 3, pp. 393-408, 2007
- [7] In-Kyung Kim, Dae-Hee Kim, Song Noh, Jae-Koo Lee, “1D CNN and Machine Learning Methods for Fall Detection,” KIPS Transactions on Software and Data Engineering, Vol. 10 No. 3, pp.85-90, 2021.
- [8] Q. Li, J. A. Stankovic, M. Hanson, A. Barth, “Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information.” Sixth International Workshop Wearable and Implantable Body Sensor Networks(BSN) 2009, Berkeley, CA, 3-5 June 2009,
- [9] Bourke, A. K., G. M. Lyons, “A threshold-based fall-detection algorithm using a bi-axial gyroscope sensor“, Medical Engineering and Physics, Vol. 30, pp.84-90, 2008.
- [10] Jeong-Hyun Roh, Jin-Heon Kim, “Fall detection based on acceleration sensor attached to wrist using feature data in frequency space”, Smart media journal Vol. 10 No. 3, 31-38, 2021.
- [11] Luna-Perejón, F. Domínguez-Morales, M. J. Civit-Balcells, A. “Wearable Fall Detector using Recurrent Neural Networks.”, Sensors 19, 4885, 2019.
- [12] Khojasteh, Samad Barri, Villar, José R. Chira, Camelia, González, Victor M. Enrique de la Cal, “Improving fall detection using an on-wrist wearable accelerometer.”, Sensors 18, 1350, 2018.
- [13] Hyun Park, Jun-Mo Park, Yeon-Chul Ha, “Implementation of Acceleration Sensor-based Human activity and Fall Classification Algorithm,” The Journal of Korea Institute of Convergence Signal Processing, Vol. 23 No. 2, pp.76-83, 2022.
- [14] Do-Un Jeong, Wan-Young Chung, “Posture and activity monitoring using a 3-axis accelerometer,” Journal of Sensor Science and Technology, Vol. 16 No. 6, pp.467-474, 2007.
- [15] 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.

저자소개

우 종 석 (Jong-Seok Woo)



2021년 2월 : 부경대학교
전자공학과(공학학사)
2023년 8월 : 부경대학교
인공지능융합학과(공학석사)
관심분야 : AI 시스템, 무선 통신,

리 오 넬 (Lionel Nkenyenye)



2019년 2월 : 동의대학교
컴퓨터공학과(공학박사)
2019년 11월 : 세종대학교
박사후연구원
2021년 8월~현재 : 부경대학교
박사후연구원
관심분야 : 엣지 컴퓨팅, 지능형
엣지 AI 시스템, 통신 시스템

정 상 중 (Sang-Joong Jung)



2009년 2월 : 동서대학교
유비쿼터스IT학과(공학석사)
2013년 2월 : 부경대학교
전자공학과(공학박사)
2013년 12월 : University of Oulu
정보통신공학과(공학박사)
2020년 6월~현재 : 동서대학교
인공지능융합학과 조교수

관심분야 : 스마트 레이더 시스템, 모바일 응용, 헬스케어,
스마트 양식, 사물인터넷

정 완 영 (Wan-Young Chung)



1989년 2월 : 경북대학교
전자공학과(공학석사)
2998년 2월 : 규슈 대학교 센서
공학과(공학박사)
1999년 2월~2008년 2월 :
동서대학교 조교수
2008년 2월~현재 : 부경대학교 교수

관심분야: 무선통신, 유비쿼터스 헬스케어, 스마트 라이팅,
가시광 통신, 임베디드 시스템