

사물인터넷 환경에서 랜덤포레스트를 이용한 실시간 낙상 사고 예측

방찬우¹, 김봉현^{2*}

¹서원대학교 정보통신공학과 석사과정, ²서원대학교 컴퓨터공학과 교수

Real-time Fall Accident Prediction using Random Forest in IoT Environment

Chan-Woo Bang¹, Bong-Hyun Kim^{2*}

¹Master's Student, Department of Information Communication Engineering, Seowon University

²Professor, Department of Computer Engineering, Seowon University

요약 2023년 기준 국내 건설업에서 발생한 사고 재해자 수는 26,829명으로 기타의 사업(서비스업)에 이어 두 번째에 해당한다. 전 업종 재해자 사고 유형으로는 넘어짐(29,229명), 떨어짐(14,357명) 순으로 이루어져 있다. 위 자료를 토대로 본 연구에서는 건설 현장에서 빈번하게 발생하는 낙상 사고를 예측하기 위해 안전모와 깔창에 센서를 부착하고, 이를 통해 수집된 데이터를 바탕으로 랜덤 포레스트 알고리즘을 적용한 스마트 안전 장비를 제안한다. 랜덤 포레스트 모델은 여러 결정 트리를 생성하여 각 트리의 예측을 종합함으로써 높은 정확도로 낙상 사고를 실시간으로 판별할 수 있다. 이 모델은 안전모에 부착된 MPU-6050 센서에서 수집된 데이터를 통해 노동자의 낙상 사고 여부와 행동 유형을 분류한다. 안전모로부터 일차적으로 판별된 낙상사고는 깔창에 부착된 센서를 통해 이차적으로 예측하여, 예측 정확도를 높인다. 이를 통해 사고 발생 시 신속한 대응이 가능하여 노동자의 사망 및 재해사고를 줄일 수 있다고 기대한다.

주제어 : 사물인터넷, 랜덤포레스트, 안전 장비, 낙상 감지, 앙상블 학습

Abstract As of 2023, the number of accident victims in the domestic construction industry is 26,829, ranking second only to other businesses (service industries). The accident types of casualties in all industries were falls (29,229 people), followed by falls (14,357 people). Based on the above data, this study attaches sensors to hard hats and insoles to predict fall accidents that frequently occur at construction sites, and proposes smart safety equipment that applies a random forest algorithm based on the data collected through this. The random forest model can determine fall accidents in real time with high accuracy by generating multiple decision trees and combining the predictions of each tree. This model classifies whether a worker has had a fall accident and the type of behavior through data collected from the MPU-6050 sensor attached to the hard hat. Fall accidents that are primarily determined from hard hats are secondarily predicted through sensors attached to the insole, thereby increasing prediction accuracy. It is expected that this will enable rapid response in the event of an accident, thereby reducing worker deaths and accidents.

Key Words : IoT; Random Forest; Safety Equipment; Fall Detection; Ensemble Learning

*교신저자 : 김봉현(bhkim@seowon.ac.kr)

접수일 2024년 07월 03일 수정일 2024년 07월 30일 심사완료일 2024년 08월 14일

1. 서론

낙상 사고란 의지와 관계없이 넘어져 뼈와 근육 등에 손상을 입는 사고를 말한다. 낙상 사고는 건설업에서 가장 흔한 사고 중 하나로, 심각한 부상 또는 사망으로 이어질 수 있다[1].

‘고용노동부 2023년 산업재해 현황’에 따르면 2023년도 건설업에서 발생한 사고 재해자 수는 26,829명으로 기타의 사업(서비스업)에 이어 두 번째에 해당하고, 사고 사망자 수는 356명으로 압도적인 지표를 보인다. 전 업종 사고 재해자의 사고 유형은 넘어짐(28,228명)과 떨어짐(14,357명) 순서로 이루어져 있으며, 사고사망 유형으로는 떨어짐(286명)이 압도적으로 큰 비중을 차지하고 있다[2]. 근로자의 안전을 보장하기 위해 중대재해법, 산업안전보건법 개정 및 건설업 기초안전보건교육을 실시하고 있음에도 지속해서 발생하는 안전사고에 대응하기 위해서는 사고 유형을 파악하는 것이 중요하다[3].

본 논문에서는 건설 노동자의 실시간 낙상 사고를 예측하기 위해 스마트 안전 장비로 건설 현장에서 필수적으로 착용해야 하는 안전모와 안전화 깔창을 선택하였다. 각 IoT 장비에는 ESP32-WROOM-32D 보드를 부착하였고, 건설 노동자의 안전모 착용 여부와 낙상 판별을 위해 압전센서 및 가속도 센서를 부착하고 안전화 깔창에 압전센서를 부착한다. 안전모를 통해 수집된 데이터에 활용하여 랜덤포레스트 알고리즘을 통해 학습 후 저장한 모델을 통해 사용자의 행동 유형을 예측한다. 만약 낙상 사고가 감지되었으면 안전화 깔창을 통해 수집한 데이터를 통해 이차적으로 낙상 사고를 정확하게 감지할 수 있는 시스템을 구축하고자 한다. 이를 통해 실시간으로 건설 현장에서 발생하는 낙상 사고 여부를 판별할 수 있으며, 낙상 사고를 통해 수집된 데이터를 활용하여 낙상 사고가 자주 발생하는 유형을 파악함으로써, 적절한 대응 방안을 마련할 수 있도록 시스템을 구축하고자 한다.

2. 관련 이론

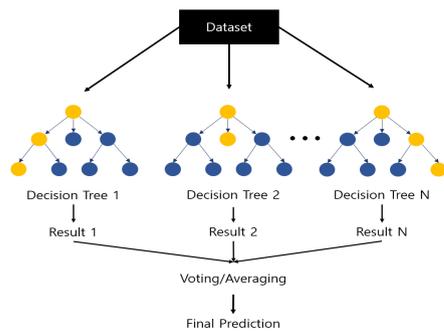
2.1 앙상블 학습(Ensemble Learning)

앙상블 학습(Ensemble Learning)은 여러 개의 개별 모델을 결합하여 하나의 예측 모델을 만드는 기법이다. 이 방법은 개별 모델의 약점을 보완하고 전체적인 예측 성능을 향상하고 높은 안정성을 얻을 수 있다는 장점이 있다[4]. 앙상블 학습 방법에는 대표적으로 보팅(Voting),

부스팅(Boosting), 배깅(Bagging)과 같이 세 가지 유형이 있다. 보팅이란 여러 모델의 예측 결과를 결합하여 최종 예측을 결합하는 가장 간단한 앙상블 학습이다. 보팅에는 각 모델의 예측 결과를 투표로 취합하여 가장 많은 표를 얻은 결과를 최종 예측 결과를 도출하는 하드 보팅과 각 모델의 예측 확률을 평균 내어 최종 예측 결과를 도출하는 소프트 보팅으로 이루어져 있다[5]. 부스팅이란 각 모델을 순차적으로 학습시키며, 이전 모델이 틀린 데이터에 가중치를 부여하여 다음 모델에서 오류를 개선하는 방식으로 진행된다[6]. 배깅이란 원본 데이터셋으로부터 무작위로 부트스트랩 샘플(Bootstrap Sample)을 추출하여 각 모델을 개별적으로 학습시킨 후 보팅을 통해 최종 예측 결과 값을 도출해내는 방법이다. 대표적인 배깅 기법으로는 랜덤포레스트(Random Forest)가 있다[7].

2.2 랜덤포레스트(Random Forest)

랜덤포레스트(Random Forest)는 앙상블 학습 방법 중 하나로, 다수의 결정 트리를 결합하여 분류, 회귀 분석 등에 작업을 수행하는 알고리즘으로써 여러 개의 부트스트랩 샘플에 대해 결정 트리를 만들어 그 결과들을 종합하여 예측 성능을 향상하는 원리를 지니고 있다[8]. 랜덤포레스트는 여러 트리들의 예측을 결합하여 예측 결과를 도출한다는 특징을 지니고 있어 정확도가 높고, 각 트리들은 독립적으로 작동하기에 과적합을 방지한다는 장점 및 각 특징에 대한 중요도를 평가할 수 있는 장점이 있다[9]. 랜덤포레스트 모델의 구조는 아래 Fig. 1과 같다.



[Fig. 1] Random Forest Structure

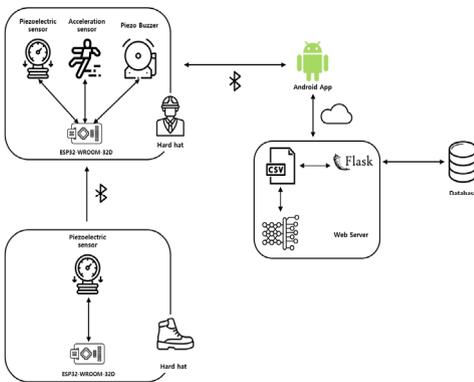
랜덤포레스트 훈련 과정으로는 전처리된 데이터에서 무작위로 여러 개의 부트스트랩 샘플을 생성 후 각 부트스트랩 샘플에 대해 생성된 결정 트리를 훈련한다. 훈련은 트리의 각 노드에서 무작위로 선택된 특징을 사용해 최적의 분할 기준을 찾은 후 최대 깊이, 최소 샘플 수 등

의 조건을 충족할 때까지 분할한다. 더 이상 분할할 수 없으면 해당 노드에 예측 값을 설정한다. 각 결정 트리가 독립적으로 수행한 예측을 통해 다수결 투표 또는 각 트리의 예측 값의 평균을 통해 최종 예측 값을 산출한다 [10][11]. 이러한 과정을 통해 여러 개의 결정 트리를 독립적으로 훈련하고 이를 결합하여 예측 성능을 향상하는 방식으로 실시간으로 입력되는 센서 데이터를 기반으로 사용자의 행동 유형 및 낙상 여부를 예측할 수 있다고 기대할 수 있다.

3. 연구 과정

3.1 시스템 설계

본 논문은 건설 현장에서 노동자의 실시간 행동 유형을 파악할 수 있는 시스템을 구현하고자 한다. 아래 Fig. 2는 안전모의 시스템 구조를 나타낸다. Fig. 2에서 보는 바와 같이, 시스템은 IoT 장비로 안전모와 깔창을 사용하고 모바일 기기와 웹 서버로 이루어져 있다.



[Fig. 2] System Diagram

본 논문에서 제시하는 안전모에는 여러 센서와 제어 및 Bluetooth 통신을 위한 ESP32-WROOM-32D 보드가 부착되어있다. ESP32 보드의 특징인 BLE 다중 연결 기능을 이용해, 안전모에 부착된 ESP32 보드는 서버 보드, 깔창에 부착된 ESP32 보드는 클라이언트 보드로 설정한다. 깔창에 부착된 압전센서 값은 BLE 통신을 통해 안전모에 부착된 ESP32 서버 보드로 전송되고, 전송받은 센서의 값과 안전모에 부착되어있는 센서의 값을 종합한 데이터는 BLE 통신을 통해 노동자의 모바일 기기로 송신된다. 모바일 기기로 수집된 데이터는 웹 서버로 전송되

며, 웹 서버에서 수집된 데이터는 저장 후 학습 또는 사용자의 행동 유형 예측에 사용된다. 학습된 모델을 통해 사용자의 행동 유형이 낙상 사고로 예측이 되면, 깔창에 부착된 압전센서 값을 이용하여 이중으로 낙상 사고를 판별할 수 있다. 낙상 사고 발생 시 낙상 전후 5초 동안의 데이터가 Database에 저장된다. 저장된 데이터는 모바일 기기에서 확인할 수 있으며, 안전모에 부착된 부저를 작동시킨다. 이를 통해 노동자의 행동 유형을 실시간으로 파악할 수 있고, 낙상 사고 발생 시 즉각적인 대처를 통해 건설 현장에서의 안전 관리를 크게 향상할 수 있다.

3.2 하드웨어 설계

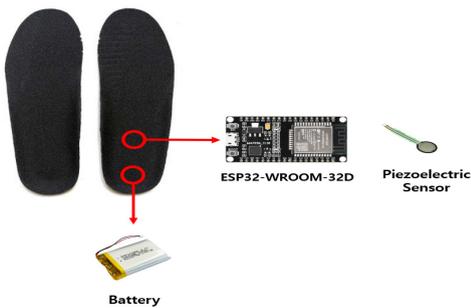
본 논문에서 제시한 IoT 장비는 안전모와 안전화 깔창이다. 각 IoT 장비에는 저전력 블루투스(BLE) 4.2 버전이 내장되어 있으며, BLE 다중 연결이 가능한 ESP32-WROOM-32D 보드를 사용한다[12]. 안전모에는 압전센서 FSR-406, 가속도 센서 MPU-6050, Piezo 부저, 배터리와 5V로 변환시켜주는 컨버터를 부착하여 노동자의 낙상을 감지할 수 있다. 안전모 구조도는 아래 Fig. 3과 같다.



[Fig. 3] Safety Helmet

안전모는 건설 현장에서 필수적으로 착용해야만 한다. 이 특성을 이용하여 압전센서는 Fig. 3과 같이 안전모 내 피 앞부분에 부착한다. 압전센서는 압력이 가해질 때마다 저항값이 변하는 특성이 있다[13]. 안전모를 착용 후 압전센서가 특정 압력 이상의 값을 감지하여 노동자의 안전 모 착용 상태를 인지할 수 있다. 안전모 내부 상단에 3축 자이로스코프와 3축 가속도계를 통합하여 운동 및 방향, 가속도, 각속도 등의 데이터를 수집할 수 있는 가속도 센서를 부착하여 노동자의 행동 유형에 따른 센서 값을 수집해 사용자의 낙상 사고를 인지할 수 있다[14]. 보드는 ESP32-WROOM-32D 보드를 사용한다. 보드 및 각 센서는 배터리를 이용해 전원을 지속해서 공급받아야 하

기에 안전모 앞부분에 배터리 및 5v 변환기를 부착하였다. 또한, 낙상 사고가 발생 시 주위에 있는 노동자들에게 긴급 상황임을 알릴 수 있도록 뒤쪽에 부저 모듈을 부착하였고, 실시간 노동자 행동 유형 분석을 위해 센서 값을 수집 및 위급상황 발생 시 부저를 작동시킬 수 있는 스위치를 부착하였다. 안전화 또한 건설 현장에서 필수적으로 착용해야 한다는 특성을 이용해 본 시스템의 IoT 장비로 선택하였다. 깔창에 부착된 압전센서의 값을 통해 안전화의 착용 여부 및 낙상 사고가 발생 시 값의 변화를 통해 학습된 데이터와 같이 사용해 사용자의 낙상을 예측할 수 있다. 안전화 깔창의 구조도는 아래 Fig. 4와 같다.



[Fig. 4] Safety Shoe Insole

3.3 데이터 수집

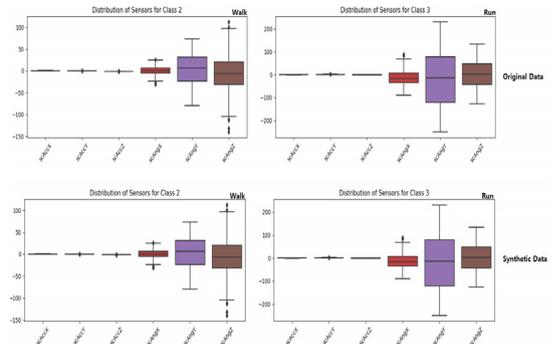
본 연구는 7개의 일상 행동 유형과 4개의 낙상 행동 유형의 데이터 세트를 활용하였다. 데이터 수집을 위해 일상 행동 유형은 직접 안전모를 착용 후 수집하였으며, 낙상 행동 유형은 매트 위 안전모를 떨어트리는 방식으로 연구를 진행하였다. 총 11개 유형의 데이터들은 각 행동 유형마다 초 동안 MPU-6050 센서 가속도 데이터(X,

<Table 1> Data Type

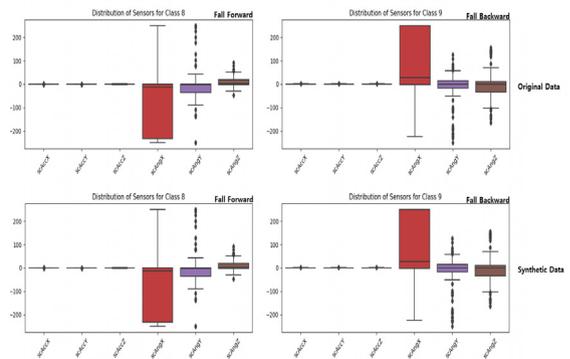
Division	Behavior types	Number of original data set	Number of synthetic data set
Fall Type	Fall Forward	30	30
	Fall Backward	30	30
	Fall to the left	30	30
	Fall to the right	30	30
Non-Fall Type	Rest	30	30
	Walk	30	30
	Run	30	30
	Tilt Head Forward	30	30
	Tilt Head Back	30	30
	Tilt Head Right	30	30
	Tilt Head Left	30	30

Y, Z 축), 자이로스코프 데이터(X, Y, Z 축)를 33회 수집하고 행동을 30번 반복하여 각 행동 유형마다 5,940개의 데이터를 수집한다. 일상 행동 유형 및 낙상 행동 유형의 리스트는 Table 1과 같다.

수집한 데이터들은 CSV 파일 형식으로 저장되며, 각 행은 시간 순서에 따라 기록된 센서 값을 나타낸다. 행동 유형에 대한 원본 데이터에 과적합 방지 및 새로운 데이터에 대한 일반화 능력을 높일 수 있고 원본 데이터의 구조를 유지하면서 데이터의 양을 증가시킬 수 있는 가우시안 잡음(Gaussian Noise)을 추가하여 만든 합성 데이터를 각 행동 유형마다 원본과 같은 크기의 데이터를 추가로 생성한다. 일상 행동 유형 7가지의 원본 데이터와 추가한 데이터의 수는 총 83,160개이고, 4가지의 낙상 행동 유형의 원본 데이터와 추가한 데이터의 수는 총 47,520개로 수집하였다[15]. 아래 Fig. 5는 일상 행동 유형 중 걷기와 뛰기 행동의 원본 데이터와 가우시안 잡음을 이용해 추가한 합성 데이터의 데이터 분포도 비교이고, Fig. 6은 낙상 행동 유형 중 앞으로 넘어지기와 뒤로 넘어지기 행동 원본 데이터와 가우시안 잡음을 이용해 추가한 합성 데이터의 데이터 분포도 비교이다.



[Fig. 5] Comparison of non-fall data distribution



[Fig. 6] Comparison of fall data distribution

본 논문에서는 안전모에 부착된 MPU-6050 센서를 이용해 각 행동 유형마다 2초 동안 가속도, 자이로스코프 데이터를 수집하고, 가우시안 잡음을 추가한 합성 데이터를 이용하여 일상 행동 유형과 낙상 행동 유형을 예측하고자 한다.

3.4 낙상 알고리즘 설계

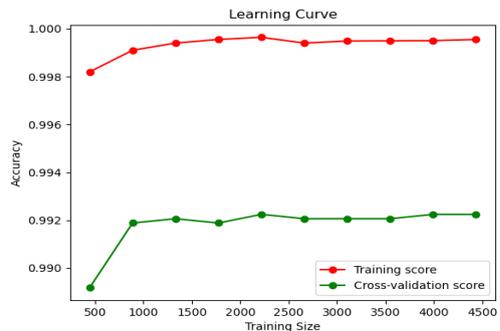
본 논문에서 낙상 사고 발생 시 낙상 사고임을 인지하기 위해 스마트 장비로 안전모를 선택하였다. 건설 현장에서 반드시 착용해야 하는 안전모의 특성을 이용해 안전모를 착용했을 때 데이터의 수집이 이루어지도록 설계하였다. 안전모의 착용 여부를 확인하기 위해 이마가 맞는 안전모의 내피에 압전센서를 부착하였고, 낙상 사고를 인지하기 위해 안전모 내부에 3축 가속도 센서를 부착하였다. 안전모에 부착된 센서값을 통해 낙상 사고임을 인지하면 안전화 깔창에 부착된 압전센서를 이용해 낙상 사고 발생 여부를 이차 검증을 통해 판별한다. 압전센서의 값이 30 이상일 때 안전모의 착용을 의미한다. 안전모에 부착된 MPU-6050 센서를 통해 수집된 데이터를 기반으로 낙상 사고를 예측하기 위한 랜덤 포레스트 알고리즘을 적용하였다. 랜덤 포레스트 알고리즘은 여러 개의 결정 트리를 활용하여 구성된다. 결정 트리는 데이터 샘플링, 노드 분할, 트리 성장, 예측을 통해 구축된다. 안전모에 부착된 센서를 통해 수집한 데이터는 결정 트리를 통해 분석된다. 분석 결과 낙상 사고 유형의 결과가 나왔을 경우, 깔창에 부착된 압전센서를 통해 이차적 검증을 수행한다. 이때, 압전센서의 값이 200 이하일 때 노동자의 낙상사고임을 판단하여 모바일 기기로 알림 전송

후 안전모에 부착된 부저가 작동된다. 낙상 사고 판별 순서도는 Fig. 7과 같다.

4. 연구 결과

노동자 행동 유형 예측을 위한 랜덤포레스트 모델의 정확도는 아래 Fig. 8과 같으며 분류결과표인 Table 2를 통해 각 성능 지표의 정확한 수치를 확인할 수 있다. 또한, 아래 Fig. 9의 혼동 행렬을 통해 각 행동 유형 별 정확도를 볼 수 있다.

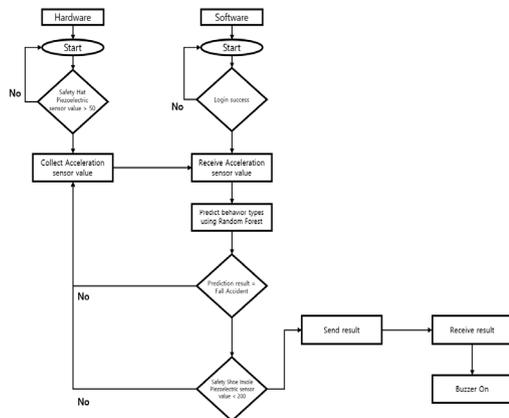
각 행동 유형 별 분류결과표를 토대로 일상 행동 유형 및 낙상 행동 유형 모두 98% 이상의 수치를 보이며 정확도는 99.2를 나타내며 높은 정확도를 보여주고 있다. 또한, 훈련 정확도 및 교차 검증 정확도의 차이가 크지 않고 일정 훈련 데이터 크기 이상에서는 훈련 정확도 수치와 교차 검증 정확도 수치가 안정화되고 있음을 알 수 있다.



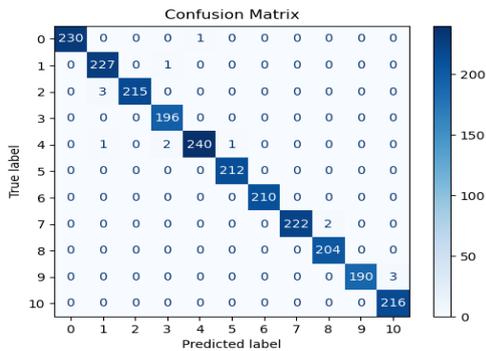
[Fig. 8] Learning Curve

<Table 2> Classification Result

	Precision Score	Recall	f1-score	support
Rest	1.00	1.00	0.99	231
Walk	0.98	1.00	0.99	228
Run	1.00	0.99	0.99	218
Tilt Head Forward	0.98	1.00	0.99	196
Tilt Head Back	1.00	0.98	0.99	244
Tilt Head Right	1.00	1.00	1.00	212
Tilt Head Left	1.00	1.00	1.00	210
Fall Forward	1.00	0.99	1.00	224
Fall Backward	0.99	1.00	1.00	204
Fall to the left	1.00	0.98	0.99	193
Fall to the right	0.99	1.00	0.99	216
Accuracy			0.99	2376
Macro avg	0.99	0.99	0.99	2376
Weighted avg	0.99	0.99	0.99	2376



[Fig. 7] Flowchart for Determining Fall Accidents



[Fig. 9] Confusion Matrix

5. 결론

본 논문에서는 건설 현장에서 노동자의 행동 유형을 예측하기 위해 스마트 안전 장비로 건설 현장에서 필수적으로 착용해야 하는 안전모와 안전화 깔창을 선택하였다. 안전모에 장착된 MPU-6050 가속도 센서의 값을 이용하여 랜덤포레스트 모델을 통해 노동자의 행동 유형을 예측하고자 하였다. 랜덤포레스트 모델은 7가지의 일상 행동 유형 및 4가지의 낙상 행동 유형 판별에 대해 높은 결과를 나타내는 것을 확인하였다. 그러나, 행동 변화에 대한 데이터의 행동 유형을 낙상 사고로 잘못 예측을 하는 경우가 발생하였다. 이 문제를 해결하기 위해 안전화 깔창에 압전센서를 부착하여 예측 모델이 낙상 사고 발생으로 잘못 판단할 경우 이차적으로 낙상 판별 여부를 확인할 수 있도록 하였다. 또한, 낙상 사고를 통해 수집된 데이터를 활용하여 낙상 사고가 자주 발생 되는 유형을 파악함으로써, 적절한 대응 방안을 마련해 노동자의 안전을 효과적으로 보호하고 사고를 예방하는 데 크게 기여할 수 있을 것으로 기대된다.

추후 연구 방향으로는 낙상 사고와 유사한 데이터를 보이는 행동 유형 추가 및 피실험자의 체격 등 다양한 환경에서 추가 연구 및 모바일 기기에서 사용자의 위치를 파악할 수 있도록 개발하여 건설 현장뿐만 아니라 다양한 산업 현장에서도 활용할 수 있도록 연구해보고자 한다.

REFERENCES

- [1] H.H. Sim and K.S. Kang, "A study on the death accident analysis of ladder and prevention measures for fall accidents," *Journal of the Korea Safety Management & Science*, Vol.19, No.4, pp.95-104, 2017.
- [2] C. W. Bang and B. H. Kim, "Design of smart safety equipment platform for construction site workers," *Journal of Next-generation Convergence Technology Association*, Vol.6, No.7, pp.1182-1188, 2022.
- [3] Y. Seo, S. Kim, D. Lee, J. Jung, and D. Kim, "Correlation analysis between awareness of the serious accidents and safety consciousness of construction workers under the act on the punishment of serious accidents," *Korean Journal of Construction Engineering and Management*, Vol.25, No.3, pp.47-57, 2024.
- [4] K. W. Lee, Y. J. Won, Y. B. Song, and K. S. Cho, "Development of machine learning ensemble model using artificial intelligence," *Journal of the Korean Society for Heat Treatment*, Vol.34, No.5, pp.211-217, 2021.
- [5] B.U. Jeon, J.S. Kang, and K. Chung, "AutoML and CNN-based soft-voting ensemble classification model for road traffic emerging risk detection," *Journal of Convergence for Information Technology*, Vol.11, No.7, pp.14-20, 2021.
- [6] S. Park, "Malicious insider detection using boosting ensemble methods," *Journal of the Korea Institute of Information Security & Cryptology*, Vol.32, No.2, pp.267-277, 2022.
- [7] S.H. Min, "Bankruptcy prediction using an improved bagging ensemble," *Journal of Intelligence and Information Systems*, Korea Intelligent Information System Society, December 30, 2014.
- [8] H. I. Kim, Y. S. Lee, and B. Kim, "Real-time flood prediction applying random forest regression model in urban areas," *Journal of Korea Water Resources Association*, Vol.54, Spc1, pp.1119-1130, 2021.
- [9] J. Hong and S.J. Jeon, "Prediction of safety grade of bridges using the classification models of decision tree and random forest," *KSCE Journal of Civil and Environmental Engineering Research*, Vol.43, No.3, pp.397-411, 2023.
- [10] J. A. Chun, H.J. Lee, S.H. Im, D. Kim, and S.S. Baek, "Comparative assessment of frost event prediction models using logistic regression, random forest, and LSTM networks," *Journal of Korea Water Resources Association*, Vol.54, No.9, pp.667-680, 2021.
- [11] D.H. Hwang and Y.S. Seo, "A study on accounting fraud detection using neural network and random forest," *Proceedings of the Korea Information Processing Society Conference*, pp.692-693, 2023.
- [12] I. Mahmoud, I. Saidi, and C. Bouzazi, "Design of an IOT system based on face recognition technology using ESP32-CAM," *International Journal of Computer Science and Network Security*, Vol.22, No.8, pp.1-6, 2022.
- [13] Y.H. Kim, "A study of vibration energy harvesting for the bimorph piezoelectric sensor," *Journal of Sensor*

Science and Technology, Vol.19, No.4, pp.313-319, 2010.

- [14] G.C. Park, S.H. Kim, S.-W. Baik, J.-H. Kim, and G.-R. Jeon, "Discrimination of fall and fall-like ADL using tri-axial accelerometer and bi-axial gyroscope," Journal of Sensor Science and Technology, Vol.26, No.1, pp.7-14, 2017.
- [15] Y. Gao and N.H. Kim, "Direction information concerned algorithm for removing Gaussian noise in images," Journal of Information and Communication Convergence Engineering, The Korean Institute of Information and Communication Sciences, December 31, 2011.

방 찬 우(Chan-Woo Bang)

[준회원]



- 2022년 2월 : 서원대학교 컴퓨터 공학과(공학학사)
- 2022년 3월 ~ 현재 : 서원대학교 정보통신공학과 석사과정
- E-Mail : bcw0219@naver.com

<관심분야>

사물인터넷, 데이터사이언스, 딥러닝

김 봉 현(Bong-Hyun Kim)

[정회원]



- 2009년 2월 : 한밭대학교 컴퓨터 공학과(공학박사)
- 2012년 ~ 2015년 : 경남대학교 컴퓨터공학과 교수
- 2020년 3월 ~ 현재 : 서원대학교 컴퓨터공학과 교수

■ E-Mail : bhkim@seowon.ac.kr

<관심분야>

데이터사이언스, 딥러닝, 생체신호분석, IoT응용서비스