

머신러닝 기반의 건설근로자 동작 및 주변환경에 따른 위험도 판단 모델

임호용*¹, 김지안*², 박용범*³, 서범규*⁴, 김기일*⁵

Machine Learning-based Risk Assessment Model for Construction Workers with Actions and Surrounding Environment

HoYong Lim*¹, Jian Kim*², YongBeom Park*³, BeomKyu Suh*⁴, and Ki-Il Kim*⁵

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임
(RS-2022-II221200)

요 약

건설근로자의 위험도는 다양한 동작과 환경 변화에 따라 달라지지만, 기존 연구는 정적 통계자료나 일부 요인만 고려하여 실시간성과 통합적 위험 판단에 한계가 있었다. 본 연구는 이러한 한계를 극복하기 위해, 웨어러블 센서 기반 시계열 데이터를 활용한 CNN-LSTM과 산업안전 기준 수식을 결합한 위험도 판단 모델을 제안한다. Pseudo-label을 생성해 지도학습을 수행하고, 동작·생체·환경 요인을 통합 반영해 고위험·중위험·저위험 세 등급으로 분류하며 VTT-ConIoT 데이터셋 실험에서 Accuracy 99%, F1-score 0.95, Macro 0.95, Weighted 0.99의 성능을 보였다. 이는 기존 HAR 연구를 위험도 예측으로 확장한 독창성을 입증한다. 다만, 본 연구는 Pseudo-label을 활용했으므로 향후 실제 레이블 데이터 검증을 통해 일반화 성능을 보완할 필요가 있다.

Abstract

Construction workers' risk varies with motion and environment, but prior studies relied on static data or single factors with limited integration. We propose a CNN-LSTM based model using wearable sensor data and safety standards, applying pseudo labels to classify risk levels from motion, physiological, and environmental factors. On the VTT-ConIoT dataset, the model achieved 99% accuracy and strong F1-scores (macro 0.95, weighted 0.99), demonstrating originality in extending HAR to risk prediction. However, since pseudo labels were used, further validation with real-world labeled data is required to ensure generalization, and future work will focus on validation across diverse construction environments.

Keywords

risk assessment model, CNN-LSTM, construction safety, wearable sensors

* 충남대학교 컴퓨터공학과(*⁵교신저자)
- ORCID¹: <https://orcid.org/0009-0009-6209-7315>
- ORCID²: <https://orcid.org/0009-0000-3369-0771>
- ORCID³: <https://orcid.org/0009-0000-4168-3918>
- ORCID⁴: <https://orcid.org/0009-0008-7797-9655>
- ORCID⁵: <https://orcid.org/0000-0002-8366-3533>

• Received: Jul. 01, 2025, Revised: Sep. 25, 2025, Accepted: Sep. 28, 2025
• Corresponding Author: Ki-Il Kim
Dept. of Computer Science and Engineering, Chungnam National University, Daejeon, Korea
Tel.: +82-42-821-6856, Email: kikim@cnu.ac.kr

I. 서 론

건설 현장은 고온, 고소작업, 반복 동작 등으로 근로자가 신체적·정신적 부담에 지속적으로 노출되는 고위험 환경이다. 이러한 환경은 사고 발생 가능성을 높이며, 특히 옥외 작업이 많아 기온, 습도, 풍속 등 외부 환경 변화가 위험도 판단에 직접적으로 작용한다. 따라서 이러한 복합 요인을 실시간으로 반영할 수 있는 안전관리 시스템이 요구된다. 이에 대한 관련 연구와 한계는 다음 장에서 정리하고, 본 논문에서 제안하는 모델의 구체적 구조와 절차는 III장에서 상세히 설명한다.

II. 관련 연구

건설근로자의 위험도 평가는 정적 기준이나 작업 유형별 산출 방식이 제안되었으나[1], 이는 현재 상태, 환경 변화에 대응이 어렵다. 동일한 환경에서도 작업자 활동에 따라 위험도가 상이하니 이를 반영하기 어렵다. 또한 웨어러블 기반 건강 모니터링 연구[2]-[4]가 진행되었으나, 단순 클러스터링에 의존해 복합 분석, 정량적 위험도 분류에 한계가 있었다.

건설근로자의 위험도는 작업 시 수행하는 동작에 크게 영향을 받기 때문에 다양한 동작 인식 기법이 연구되었다. CNN과 LSTM을 결합한 모델은 센서 데이터를 효과적으로 처리해 높은 인식 정확도를 보였다[5][6]. 또한 VTT-ConIoT(Technical Research Centre of Finland Ltd.-Construction Internet of Things) 데이터셋을 활용해 실제 작업 환경에서 복잡한 활

동을 자동 인식하는 모델이 개발되었으나[7], 이들 연구는 동작 인식에 국한되어 전체적인 위험도 판단으로 확장되지 못했다. VTT-ConIoT 데이터셋은 핀란드 기술연구센터에서 만든 건설 현장 작업자의 활동 인식을 위한 데이터셋으로, 실제 건설 현장에서 수집된 IMU 기반 센서 동작인 걷기·굽힘·도구 사용 등 다양한 동작을 포함하고 있다. 이러한 요구 사항에 대하여 본 논문은 산업안전 기준을 기반으로 위험 요인을 수식화하여 정량화하고, 이를 통합해 고위험·중위험·저위험 세 등급으로 분류하는 모델을 제안한다. 이를 위해 Pseudo-label 기반 지도학습과 CNN-LSTM(Convolution Neural Network-Long Short-Term Memory) 동작 인식을 결합하였으며, 인식된 작업 유형을 위험도 회귀·분류 모듈과 연계해 가중치로 반영함으로써 기존 연구와 차별성을 갖는다. 특히, 본 논문의 CNN-LSTM 모델은 단순 HAR(Human Activity Recognition)을 위험도 예측 모델로 확장한 독창성이 있다. 그 결과 VTT-ConIoT 데이터셋 실험에서 Accuracy 99%를 달성하였다.

III. 근로자 위험도 판단 모델

본 연구에서는 웨어러블 센서를 통해 수집된 시계열 데이터를 활용하여 작업자의 동작, 생체, 외부 환경 정보를 분석하고 이를 바탕으로 위험도를 정량적으로 분류하는 모델을 제안한다. 제안된 모델은 시계열 딥러닝 기반의 동작 인식 모듈과 회귀·분류 기반 위험도 예측 모듈을 결합하여, 근로자의 위험 수준을 실시간으로 정밀하게 분류할 수 있다.

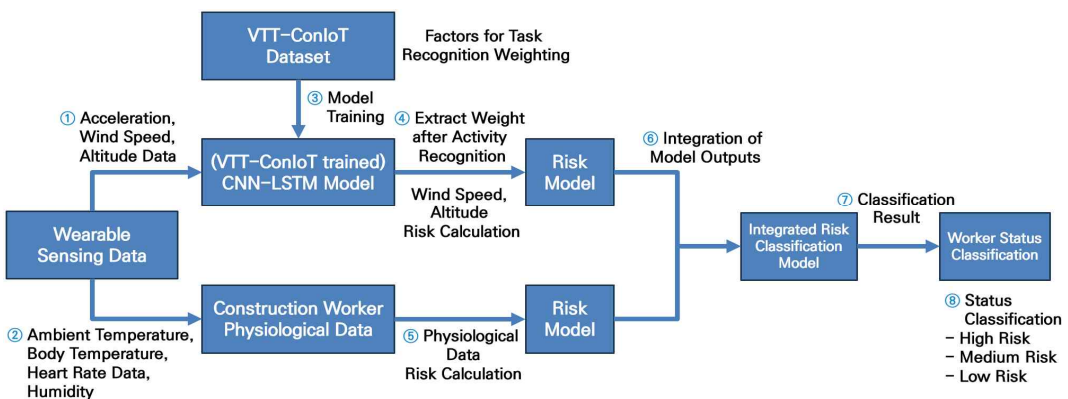


그림 1. 위험도 판단 프로시저
Fig. 1. Procedures for risk assessment

전체 절차는 그림 1과 같이 다섯 단계로 구성된다. 첫째, VTT-ConIoT 데이터셋을 활용해 CNN-LSTM으로 작업자의 동작 유형을 예측한다.

둘째, 풍속·고도 데이터를 이용해 외부 위험도를 산출한다. 셋째, 체온·심박수·온습도 데이터를 회귀 모델에 입력하여 생체 위험도를 산출한다. 넷째, 외부와 생체 위험도를 가장 평균하여 통합 위험도를 계산한다. 다섯째, 로지스틱 회귀를 통해 최종 위험 등급을 고위험·중위험·저위험으로 분류한다.

또한, 근로자의 작업 상태를 판별하기 위해 제안하는 CNN-LSTM 모델을 학습시키기 위하여 VTT-ConIoT 데이터셋[7]을 이용하였다. 위험도 산출에는 산업안전 기준의 임계값을 활용하였으며, 표 1과 같이 풍속, 고도, 온도, WBGT(Wet Bulb Globe Temperature), 체온, 심박수 등을 기준으로 정량화하였다. 예를 들어, 온도와 관련 위험도는 WBGT 식 (1)를 계산하며, 작업자의 열 스트레스 평가 지표로 활용된다.

$$WBGT = 0.7 \times T_{wb} + 0.2 \times T_g + 0.1 \times T_{db} \quad (1)$$

여기서 T_{wb} 는 습구온도, T_g 는 흑구온도, T_{db} 는 건구온도, 습도·복사열·기온을 종합적으로 반영한다. 본 연구에서는 $WBGT \geq 30^\circ\text{C}$ 일 경우 고위험으로 분류하였다. 특히 제안하는 CNN-LSTM 모델의 과적합을 예방하기 위하여 Early Stopping과 Dropout을 0.3으로 적용하여 학습을 진행하였다.

IV. 성능평가

III장에서 제안한 모델은 VTT-ConIoT 데이터셋으로 학습 및 평가되었으며, 성능 평가는 Precision,

Recall, Accuracy, F1-score로 수행하였다. 실제 건설 현장에서 레이블 확보가 어려워 산업안전 기준 기반 임계값으로 생성한 Pseudo-label을 정답값으로 사용하였다. 표 2에 따르면 전체 Accuracy는 99%였으며, 저위험은 모든 지표가 1.00, 중위험은 Precision 0.96, F1-score 0.98, 고위험은 Precision 1.00, Recall 0.77을 기록하였다. Macro 평균 F1-score는 0.95, Weighted 평균은 0.99로 데이터 불균형에도 강건한 성능을 보였다.

표 2. Confusion Matrix 평가 결과
Table 2. Evaluation result for confusion matrix

Risk level	Precision	Recall	F1-score	Support
Low risk	1	1	1	7,527
Medium risk	0.96	1	0.98	2,026
High risk	1	0.77	0.87	320

그림 2의 ROC Curve는 AUC=1.00이 산출되었으나 고위험 Recall이 0.77로 나타나 불일치가 있었다. 이는 고위험 표본 부족과 Pseudo-label 특성으로 인한 과대평가 가능성이 있으며, 따라서 AUC 단독보다는 Precision, Recall, F1-score와 함께 해석하였다.

비록 Pseudo-label 기반이라는 한계가 있으나, 제안 모델은 동일 데이터셋 내 단순 CNN, LSTM 기반 모델보다 높은 분류 성능을 달성하였다. Accuracy 99%와 Macro F1-score 0.95는 위험도 예측 문제에서도 CNN-LSTM 구조가 효과적임을 보여주며, 이는 기존 HAR 연구를 위험도 예측으로 확장할 수 있음을 입증한다. 따라서 본 연구의 결과는 향후 실제 레이블 기반 검증 이전에도 충분한 기여가 있다고 판단된다.

표 1. 건설 작업 위험 요소별 산정 기준
Table 1. Criterion for risk in construction Work

Category	Risk factor	Threshold criteria	Application method
External environment	Wind speed	Very high risk if ≥ 10 m/s	Classified as high risk
	Altitude	Higher altitude increases wind speed	Used to adjust wind risk
	Ambient temperature	Outdoor work prohibited if $\geq 35^\circ\text{C}$	High temperature risk based on temperature and humidity
	Humidity(WBGT)	Work prohibited if $\geq 30^\circ\text{C}$	Risk assessment based on WBGT index
Physiological information	Body temperature	Work must stop if $> 38.5^\circ\text{C}$	Classified as high risk
	Heart rate	Rest required if bpm ≥ 120 (MHR: $180 - \text{age}$)	Risk assessed based on MHR exceedance

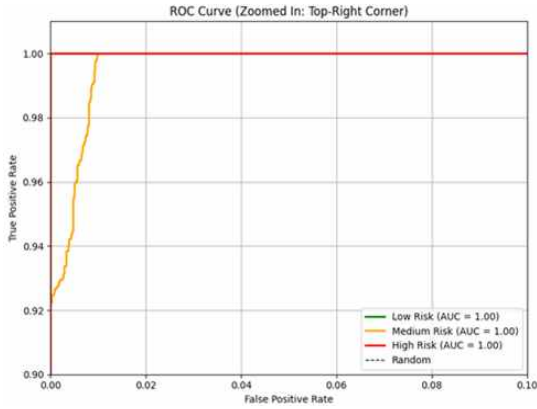


그림 2. 위험 등급 평가를 위한 ROC Curve
Fig. 2. ROC Curve for Risk Assessment

또한, 제안된 모델의 성능을 기존 연구와 비교하였을 때, CNN-LSTM 모델을 제시한 연구[5]에서는 내부 데이터셋(iSPL)을 활용하여 Accuracy 99.06%를 달성하였다. 본 연구의 모델은 위험도 분류라는 더 복잡한 문제를 다루면서도 Accuracy 99%를 기록하여, 기존 CNN-LSTM 기반 활동 인식 모델과 비교했을 때에도 경쟁력 있는 성능을 보였다.

V. 결 론

본 연구에서는 웨어러블 센서 기반 시계열 데이터를 활용하여 건설 근로자의 동작, 생체, 환경 요인을 통합적으로 반영한 CNN-LSTM 기반 위험도 통합 예측 모델을 제안하였다. 실험 결과 전체 Accuracy는 99%, F1-score는 0.95로 높은 성능을 보여 기존 HAR 연구가 동작 인식에 국한된 것과 달리, 위험도 예측으로 확장한 차별성을 확인하였다.

이러한 결과는 건설 현장의 실시간 안전관리 체계 구축과 작업자 맞춤형 안전대책 마련에 기여할 수 있다는 시사점을 제공한다. 본 연구는 Pseudo-label 기반이라는 한계에도 불구하고, 기존 활동 인식 연구보다 높은 성능을 보였다는 점에서 학문적 기여가 있다. 향후 실제 레이블 데이터와 다양한 건설 환경에 적용을 통해 모델의 일반화 성능을 보완할 필요가 있다.

References

- [1] J. Cho, "Development of Risk Assessment Indicators for Industrial Logistics Safety Management", *Journal of the Korea Safety Management & Science*, Vol. 22, No. 4, pp. 1-8, Dec. 2020. <https://doi.org/10.12812/ksms.2020.22.4.001>.
- [2] P. L. Lee, "Enhancing Construction Worker Safety: Real-time Health Monitoring through Wearable Technology", *International Journal of Enterprise Modelling*, Vol. 17, No. 3, pp. 139-147, Sep. 2023. <https://doi.org/10.35335/emod.v17i3.81>.
- [3] J. H. Kim, B. W. Jo, and D. K. Kim, "Development of an IoT-Based Construction Worker Physiological Data Monitoring Platform at High Temperatures", *Sensors*, Vol. 20, No. 19, p. 5682, Oct. 2020. <https://doi.org/10.3390/s20195682>.
- [4] C. Dobbins and R. Rawassizadeh, "Towards Clustering of Mobile and Smartwatch Accelerometer Data for Physical Activity Recognition", *Informatics*, Vol. 5, No. 2, pp. 29, Jun. 2018. <https://doi.org/10.3390/informatics5020029>.
- [5] R. Mutegeki and D. S. Han, "A CNN-LSTM Approach to Human Activity Recognition", *Proc. 2020 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, Fukuoka, Japan, pp. 362-366, Feb. 2020. <https://doi.org/10.1109/ICAIIIC48513.2020.9065078>.
- [6] W. C. Carlos, A. Copetti, and O. S. M. Gomes, "Human Activity Recognition: An Approach 2D CNN-LSTM to Sequential Image Representation and Processing of Inertial Sensor Data", *AIMS Bioengineering*, Vol. 11, No. 2, pp. 527-560, Apr. 2024. <https://doi.org/10.3934/bioeng.2024024>.
- [7] S. Mäkela, A. Lämsä, and J. Peltola, "Introducing VTT-ConIoT: A Realistic Dataset for Activity Recognition of Construction Workers Using IMU Devices", *Sustainability*, Vol. 14, No. 1, pp. 220, Jan. 2022. <https://doi.org/10.3390/su14010220>.