

## 생체신호 기반 군집 유형화 및 스트레스 급증 예측 모델 개발 연구

한동훈<sup>1\*</sup>

<sup>1</sup>(주)세이프티흥우 대표, 동국대학교 선학 박사과정

### Biosignal-Based Clustering and Abrupt Stress Spike Prediction Model Development

Dong-Hun Han<sup>1\*</sup>

<sup>1</sup>CEO of Safety Heungwoo, Doctoral Program in Seon Studies, Dongguk University, Seoul

#### ABSTRACT

**Objectives:** Construction work involves long hours, irregular schedules, and frequent safety risks, resulting in substantial psychological and physical strain. This study aimed to characterize stress-related states among construction workers using wearable-derived biosignals and to develop an explainable model for short-term prediction of abrupt stress surges.


**Methods:** We analyzed 27,573 de-identified vital-sign records collected from April 1 to July 19, 2025. Four biosignal-derived indices (stress, tension, management, and arousal) along with demographic and work-related variables were included. Latent state patterns were identified using K-means clustering with the elbow method to determine the optimal number of clusters. A “stress surge” was defined as an increase of  $\geq 5$  points in the stress index compared with the previous measurement. Lagged biosignal indices and worker/work characteristics were entered into four classifiers (logistic regression, random forest, XGBoost, and LightGBM). The best-performing model was interpreted using Shapley Additive Explanations (SHAP).

**Results:** Three distinct clusters were identified: a tension/alert group (highest tension with mid-level stress), a high-risk stress group (highest stress and lowest management), and an active management group (highest management and lowest tension). LightGBM demonstrated the best predictive performance (accuracy, 0.803; recall, 0.816; AUROC, 0.877). SHAP analysis indicated that prior stress level was the most influential predictor, with lower baseline stress associated with higher surge risk and higher baseline stress associated with lower surge risk. Older age and higher prior tension and arousal increased surge risk, whereas a higher prior management index showed a protective association.

**Conclusions:** Wearable biosignals can support meaningful clustering of worker stress-related states and enable accurate, explainable prediction of short-term stress surges. The proposed integration of clustering, machine learning, and XAI offers a practical framework for real-time stress-risk monitoring and tailored interventions in high-risk construction worksites.

**Key words:** Construction workers, biosignals, stress surge, cluster analysis, machine learning, explainable artificial intelligence, SHAP

\*Corresponding author: Dong-Hun Han, Tel: 010-2603-7107, E-mail: easthun1@naver.com  
HEUNGWOO B/D 14F, 96, Jungang-daero, Jung-gu, Busan, Republic of Korea 48939  
Received: December 11, 2025 Revised: December 25, 2025, Accepted: December 26, 2025

 Dong-Hun Han <http://orcid.org/0009-0009-4577-3801>

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## I. 서 론

건설업은 고위험 산업현장으로 장시간 노동, 불규칙한 작업 환경, 안전사고 위험 등으로 인해 근로자의 정신적·신체적 부담이 매우 큰 산업이다(Zong et al., 2024; Pamidimukkala et al., 2025). 특히 반복되는 긴장 상태와 예측하기 어려운 작업 스케줄은 만성 스트레스와 피로를 초래하고, 이는 산업재해와 직무 소진으로 이어질 수 있다(Fitri et al., 2023; Karim et al., 2025). 그럼에도 스트레스와 같은 심리·생리적 위험 요인은 눈에 잘 보이지 않아, 현장에서 체계적으로 관리하기 어렵다는 한계가 존재한다(Gómez-Salgado et al., 2023).

기존의 직무 스트레스 평가는 주로 설문지나 자기보고식 설문도구에 의존해 왔다는 점이 다수 연구에서 보고되고 있다(Sano et al., 2018; Booth et al., 2022). 이러한 자기보고식 설문방법은 비교적 간편하지만, 응답자의 기억 편향이나 사회적 바람직한 편향에 영향을 받기 쉽고, 시간에 따른 미세한 변화를 실시간으로 포착하기 어렵다는 한계가 있다(Gao et al., 2023; Pinge et al., 2024). 이 문제는 최근 디지털 헬스 및 웨어러블 기반 스트레스 연구에서 반복적으로 지적되고 있다(Booth et al., 2022). 최근 웨어러블 센서 기술이 발전하면서 심박변이도(heart rate variability, HRV), 피부전도도(electrodermal activity, EDA), 심박수(heart rate, HR) 등 다양한 생체신호를 연속적으로 측정하고, 이를 활용해 스트레스 상태를 추정·분류하려는 연구가 활발히 수행되고 있다(Sano et al., 2018; Darwish et al., 2025). Darwish et al.(2025)은 실험실 환경과 실제 생활 환경을 아우르는 3단계 검증을 통해 웨어러블 기반 스트레스 모니터링 기술의 현장 적용 가능성을 제시하였고, Sano et al.(2018)은 웨어러블 센서와 모바일 사용 데이터를 결합하여 자기보고식 스트레스 및 정신건강 상태를 예측할 수 있음을 보여주었다. 이후 Booth et al.(2022)은 정보기술 종사자를 대상으로 한 장기 종단 연구에서 웨어러블·모바일 데이터를 활용한 스트레스 예측 모델의 예측력을 검증하였고, Pinge et al.(2024)과 Bolpagni et al.(2024), Kafková et al.(2024)의 체계적·범위 고찰에서는 HRV, EDA, HR와 같은 생체신호가 머신러닝 기반 스트레스 검출 및 모니터링의 핵심 입력 변수로 반복적으로 활용되고 있음을 보고하고 있어, 웨어러블 센서를 활용한 스트레스 평가가 자기보고식 설문을 보완하는 유망한 접근으로 자리 잡아 가고 있음을 시사한다. 선행연구들에서는 이러한 생체신

호와 모바일 행동 데이터가 자기보고식 스트레스, 정신건강 상태, 피로 수준을 예측하는 데 활용될 수 있는 근거(Booth et al., 2022; Bolpagni et al., 2024; Pinge et al., 2024)로 제시되고 있으며, 현장에서의 적용 가능성에 대한 관심도 점차 커지고 있다.

생체신호 기반 스트레스 연구는 크게 세 방향으로 전개되어 왔다. 첫째, 특정 시점의 생체신호 패턴을 이용해 현재의 스트레스 수준이나 감정 상태를 분류하는 연구가 있다(Darwish et al., 2025). 둘째, 일정기간 동안 웨어러블 센서 데이터를 바탕으로 스트레스 관련 상태를 유형화하거나, 위험 수준이 높은 집단을 분류하는 연구가 진행되고 있다(Mozgovoy, 2021; Bolpagni et al., 2024). 셋째, 반복 측정 자료를 활용해 향후 스트레스 수준이나 정신건강 상태를 예측하는 시계열 모델 연구도 보고되고 있으며, 일부 연구에서는 웨어러블 데이터를 활용한 개인 맞춤형 예측 모델의 필요성을 강조하고 있다(Booth et al., 2022; Pinge et al., 2024). 그러나 이러한 연구의 상당수는 대학생이나 사무직·정보기술 종사자 등 비교적 균질한 집단을 대상으로 하거나, 공개 데이터셋에 기반한 실험실 환경 연구에 머무르는 경우가 많다. 실제 건설현장과 같이 작업 강도와 환경 요인이 급변하는 고위험 산업에서, 생체신호를 이용해 근로자의 상태를 유형화하고 위험 변화를 예측한 연구는 아직 제한적이다.

또한 최근에는 예측 정확도 뿐만 아니라, 알고리즘이 어떤 근거로 위험을 판단하는지 설명하는 것이 중요하다는 인식이 확산되면서 설명가능 인공지능(Explainable AI, XAI)에 대한 관심이 커지고 있다. SHAP(Shapley Additive Explanations)와 같은 기법은 개별 변수의 기여도와 영향 방향을 정량적으로 보여주며, 스트레스 예측(Tariq et al., 2025), 열쾌적성 모델(Kim et al., 2024) 등에서 모델 해석에 활용되고 있다. 이러한 연구들은 복잡한 머신러닝 모델의 결과를 사용자와 의사 결정자가 이해할 수 있는 형태로 제시해야 한다는 점을 강조하지만(Jaber et al., 2022; Mollaei et al., 2022; Mollaei et al., 2023), 실제 산업안전·산업보건 영역, 특히 건설현장 근로자의 스트레스 관리에 XAI를 적용한 실증 연구는 아직 많지 않은 것으로 보고되고 있다(Abuwarda et al., 2022; Kafková et al., 2024; Pinge et al., 2024; Ibrahim et al., 2025).

특히 생체신호와 웨어러블 데이터를 활용한 스트레스 연구는 빠르게 성장하고 있으나, ① 건설현장과 같은 고위험 작업환경을 대상으로 한 연구, ② 생체신호 패턴을 바탕

으로 한 근로자 상태 군집화와 위험 예측을 동시에 다룬 연구, ③ 예측 모델과 설명가능 인공지능을 결합해 실질적인 관리전략 수립에 활용할 수 있는 정보를 제공하는 연구는 상대적으로 부족하다.

따라서 본 연구는 국내 건설현장 근로자를 대상으로 웨어러블 기반 생체신호를 활용하여 스트레스 위험을 현장 적용 가능한 방식으로 관리하기 위한 통합적인 분석결과를 제시하고자 한다.

첫째, 스트레스 지수, 긴장 지수, 관리 지수, 흥분 지수의 4개 생체신호 지표를 이용하여 K-means 군집분석을 수행하고, 근로자의 생리적 상태 패턴을 긴장/주의 군, 고위험 스트레스 군, 적극적 관리 군으로 유형화하고자 한다.

둘째, 직전 측정치 대비 스트레스 지수가 일정 수준 이상 급증하는 사건을 '스트레스 급증'으로 정의하고, 시차(지연) 변수를 포함한 기계학습 모형을 구축하여 단기 위험 급증을 사전에 예측할 수 있는지 평가하고자 한다.

셋째, 예측 성능이 가장 우수한 모형에 SHAP 기반 설명가능 인공지능 기법을 적용하여 스트레스 급증 예측에 기여하는 핵심 변수와 영향 방향을 규명하고, 이를 바탕으로 군집별·개인별 맞춤형 모니터링 및 중재 전략 수립에 활용할 수 있는 근거를 제시하고자 한다.

## II. 연구방법

### 1. 연구설계

본 연구는 건설현장 근로자의 생체신호 데이터를 활용하여 근로자 상태의 군집 유형을 도출하고, 스트레스 급증 사건을 예측하는 머신러닝 모형을 구축하며, 설명가능 인공지능 기법을 통해 예측 요인을 해석하고자 한 양적 연구이다. 이를 위해 하나의 데이터셋을 가지고 군집분석, 예측모형 개발, XAI(eXplainable Artificial Intelligence, XAI) 분석을 단계적으로 수행하는 설계를 적용하였다.

### 2. 연구대상 및 자료수집

연구에 사용된 자료는 2025년 4월1일~7월 19일 사이 국내 여러 건설현장에서 근로자에게 착용된 웨어러블 기기를 통해 수집된 생체신호 기반 상태 측정 데이터이다. 각 근로자들은 웨어러블 기기를 착용하고 일정 기간 반복 측정에 참여하였으며, 상태 측정은 하루 한번 진행되었다. 비식별 처리된 전체 자료는 27,573건

이었고, 이후 군집분석 및 예측모형에 활용하였다. 데이터에는 생체신호로부터 산출된 네 가지 지표와 인구사회학적 정보, 작업 관련 특성이 포함되어 있다. 생체신호 지표는 스트레스 지수, 긴장지수, 관리지수, 흥분지수로 구성되며, 모두 동일한 시스템에서 산출된 정량 점수로 값이 높을수록 해당 특성이 강하게 나타나는 것으로 해석하였다. 인구사회학적 변수로는 연령과 성별을, 작업 관련 변수로는 주요 공종과 주요 현장 정보를 사용하였다.

### 3. 변수 정의 및 목표변수 설정

예측모형의 목표변수는 스트레스 급증 여부로 정의하였다. 직전 측정 시점( $t-1$ )과 현재 시점( $t$ )의 스트레스 지수를 비교하여,  $t$  시점의 값이  $t-1$  시점 대비 5점 이상 증가한 경우를 '급증'으로 보아 1로 코딩하였고, 증가 폭이 5점 미만이거나 유지·감소한 경우를 '비급증'을 0으로 코딩하였다. 이를 통해 절대 수준이 아니라 단기적인 변화량에 기반한 급성 위험 사건을 포착하고자 하였다. 예측에 활용되는 설명변수는 전날 측정값을 반영한 시계열 지연변수와 개인·작업 특성 변수로 구성하였다. 스트레스, 긴장지수, 관리지수, 흥분지수에 대해 각각 직전 값(lag 1)을 생성하여 스트레스 lag1, 긴장지수 lag1, 관리지수 lag1, 흥분지수 lag1 변수를 만들었고, 예측 시점에서 실제로 관찰 가능한 정보만 포함되도록 시간 순서를 정렬하여 병합하였다. 성별, 공종, 현장과 같은 범주형 변수는 모형에 입력하기 위해 더미변수로 변환하였다.

### 4. 자료 전처리

자료 전처리 단계에서는 먼저 분석에 포함될 주요 변수들의 결측치 양상과 분포를 점검하였다. 전체 관측치에서 결측 비율은 대부분 1% 미만으로 낮게 나타났으며, 특정 변수에 국한된 국소적 결측 패턴도 확인되지 않았다. 결측 비율이 매우 낮고, 결측을 대체하는 과정에서 오히려 오차를 도입할 가능성이 있다고 판단하여, 본 연구에서는 결측이 포함된 관측치를 분석에서 제외(listwise deletion)하는 방식으로 처리하였다. 이 과정 이후에도 표본 크기는 충분히 유지되어 통계적 검정력에는 큰 영향을 주지 않는다고 판단하였다.

연속형 변수에 대해서는 이상치 및 극단값을 확인하기 위해 사분위범위(interquartile range, IQR)를 활용하였다. 각 변수별로 제1사분위수(Q1)와 제3사분위

수(Q3)를 산출한 후,  $Q1 - 1.5 \times IQR$  미만 또는  $Q3 + 1.5 \times IQR$  초과 구간에 해당하는 값을 잠재적 극단값으로 판정하였다. 이 가운데 생리적으로 불가능한 수준의 값(예: 비현실적으로 높은 심박수, 음수에 가까운 지표 등)이나 장비 오류로 인한 스파이크로 추정되는 관측치는 자료 품질을 저하시킬 수 있다고 보고 제거하였다. 반면 실제로 관찰 가능한 범위 내에서 다소 큰 변동을 보이는 값은 정보 손실을 최소화하기 위해 제거하지 않고 유지하였으며, 일부 변수에 대해서는 상·하위 극단값을 일정 기준 값으로 절단(truncation 또는 winsorization)하여 분석의 안정성을 높이고자 하였다.

군집분석과 예측모형 모두에서 변수의 측정 단위와 분포 차이가 결과에 영향을 주지 않도록 주요 지표에 대해 표준화를 수행하였다. 특히 스트레스 지수, 긴장지수, 관리지수, 흥분지수와 같이 동일한 범주에 속하지만 스케일이 상이할 수 있는 변수의 경우, 평균 0, 표준편차 1이 되도록 z-점수 변환을 적용하였다. 이를 통해 변수 간 규모(scale) 차이로 인해 군집분석에서 특정 변수가 과도하게 반영되거나, 머신러닝 모형에서 계수 추정과 분할 기준이 왜곡되는 문제를 최소화하고자 하였다.

이와 같은 전처리 과정을 거쳐, 분석에 사용된 데이터셋은 결측과 극단값의 영향을 완화하면서도 원자료가 가지는 시간적·생리학적 특성을 최대한 보존하는 방향으로 정제되었다.

## 5. 군집분석 절차

근로자 상태의 유형화를 위해 K-평균 군집분석을 실시하였다. 군집 수를 결정하기 위해 먼저 엘보우 메소드(elbow method)를 적용하였다. K 값을 1부터 8까지 변화시키면서 각 모형의 이너셔(inertia)를 산출한 결과, K가 1에서 3으로 증가하는 구간에서 이너셔가 크게 감소하였고, K=3 이후부터는 감소 폭이 완만해지는 팔꿈치 형태가 뚜렷하게 관찰되었다. 이러한 결과를 바탕으로 데이터 구조를 가장 잘 설명하면서도 모형의 복잡도가 과도하지 않은 값으로 K=3을 최종 군집 수로 선택하였다. 이후 표준화된 스트레스 지수, 긴장지수, 관리지수, 흥분지수를 이용해 K-평균 알고리즘을 적용하여 세 개의 군집 중심을 추정하고, 각 관측치를 가장 가까운 중심에 할당하였다. 도출된 군집에 대해 생체신호 지표의 평균값과 분포를 비교하고, 연령, 성별,工种, 현장 분포를 함께 분석하여 각 군집의 특성을 해석

하였다. 분석 결과를 바탕으로 세 군집을 긴장/주의 그룹(군집 0), 고위험 스트레스 그룹(군집 1), 적극적 관리 그룹(군집 2)으로 명명하였다.

## 6. 스트레스 급증 예측모형 개발

스트레스 급증 예측을 위해 로지스틱 회귀(logistic regression), 랜덤 포레스트(random forest), Extreme Gradient Boosting(XGBoost), Light Gradient Boosting Machine(LightGBM) 네 가지 분류 알고리즘을 비교하였다.

선형 모형인 로지스틱 회귀와 트리 기반 앙상블 모형인 랜덤 포레스트, XGBoost, LightGBM을 함께 포함하여, 변수 간 관계를 단순 선형으로 가정하는 접근과 비선형·상호작용 효과를 반영하는 접근의 성능 차이를 동시에 평가하고자 하였다.

모형 학습을 위해 먼저 전체 데이터를 훈련(training)과 검증(test) 용도로 분할하였다.

이때 스트레스 급증(1)과 비급증(0)의 비율이 두 데이터셋에서 비슷하게 유지되도록 층화추출(stratified sampling)을 적용하여, 80%는 훈련용, 20%는 검증용 데이터로 구성하였다.

이와 같은 층화 분할은 발생 빈도가 낮은 사건을 예측하는 이진 분류 문제에서 양성·음성 비율이 왜곡되는 것을 막고, 학습 과정의 편향을 줄이기 위해 일반적으로 사용하는 절차로 제시되어 있다(Kuhn & Johnson, 2013).

훈련 데이터에서는 5-fold 교차검증(5-fold cross-validation)을 사용해 각 알고리즘의 주요 하이퍼파라미터를 조정하였다.

훈련 데이터를 다섯 개의 폴드로 나누는 후, 한 폴드는 검증용으로, 나머지 네 폴드는 학습용으로 사용하여 모형을 적합시키고, 이를 폴드별로 순환시켜 총 다섯 번의 학습-검증을 수행하였다.

각 하이퍼파라미터 조합에 대해 폴드별 성능을 평균하여 비교하고, 가장 우수한 성능을 보인 조합을 해당 알고리즘의 최종 하이퍼파라미터로 선택하였다.

이러한 k-fold 교차검증 절차는 단일 홀드아웃(hold-out) 방식에 비해 데이터 활용 효율을 높이고, 과적합(overfitting)을 줄이며, 하이퍼파라미터 선택의 안정성을 높이는 방법으로 알려져 있다(Hastie et al., 2009; Kuhn & Johnson, 2013).

교차검증에서 선정된 최적 하이퍼파라미터를 고정한

뒤, 훈련 데이터 전체를 이용해 각 알고리즘을 다시 학습하여 최종 예측모형을 구축하였다. 그 후 최종 학습된 네 개 모형에 대해서는 검증 데이터를 이용해 예측 성능을 평가하였다. 모형 평가는 정확도(accuracy), 민감도/재현율(recall), 정밀도(precision), 특이도(specificity), F1 점수(F1-score), 수신자 조작 특성 곡선 하 면적(area under the receiver operating characteristic curve, AUROC)을 산출하는 방식으로 이루어졌다. 이 중 AUROC를 주요 비교 지표로 사용하였다.

AUROC는 다양한 분류 임계값에서의 민감도와 특이도 간 균형을 하나의 값으로 요약하는 지표로, 양성·음성 비율이 불균형한 이진 분류 문제에서 모형의 판별력을 평가하는 데 적합한 것으로 보고되었다(Bradley, 1997).

네 가지 모형 간 비교 결과, LightGBM이 가장 높은 AUROC를 보였으며, 정확도와 재현율 측면에서도 상대적으로 균형 잡힌 성능을 나타냈다.

이에 따라 LightGBM을 본 연구의 최종 스트레스 급증 예측모형으로 선정하였고, 이후 설명 가능 인공지능 분석 역시 LightGBM을 대상으로 수행하였다.

### 7. 설명가능 인공지능(XAI) 분석

예측모형이 어떤 변수를 어떻게 활용해 스트레스 급증 여부를 판단하는지 해석하기 위해 Shapley Additive Explanations(SHAP)를 적용하였다. 먼저 전체 관측치를 대상으로 변수별 평균 절대 SHAP 값을 계산하여, 스트레스 급증 예측에 대한 전반적인 중요도를 비교하였다. 이어서 SHAP 요약 플롯(summary plot)을 통해 각 변수 값의 높고 낮음이 예측값에 미치는 방향과 크기를 시각적으로 확인하였다. 특히 가장 영향력이 큰 변수로 나타난 스트레스 lag1에 대해서는 SHAP 의존도 플롯을 분석하여 baseline 수준에 따라 급증 위험이 어떻게 달라지는지 살펴보았다. 관리지수 lag1, 흥분지수 lag1, 긴장지수 lag1 등 다른 주요 변수에 대해서도 SHAP 분포를 통해 위험 요인과 보호 요인으로서의 역할을 해석하였다. 이를 통해 단순히 '어떤 변수가 중요하다'는 수준을 넘어, 변수 수준과 조합에 따라 스트레스 급증 위험이 어떻게 변화하는지까지 분석하고자 하였다.

### 8. 윤리적 고려

윤리적 측면에서 본 연구는 연구용으로 제공된 비식

별화 2차 자료를 활용하였다. 데이터에는 이름, 주민등록번호, 연락처 등 개인을 직접 식별할 수 있는 정보가 포함되어 있지 않았으며, 특정 개인이나 사업장을 추정할 수 있는 세부 정보도 제공되지 않았다. 자료 수집 단계에서 이미 현장 차원의 동의 절차가 완료된 상태였으며, 본 연구는 수집이 완료된 비식별 자료를 분석하는 2차 연구의 성격을 갖기 때문에 기관생명윤리위원회(IRB) 심의 면제 대상에 해당하는 것으로 판단하였다. 분석 및 보고 과정에서는 군집, 현장, 공중 정보 역시 통계적으로 의미 있는 집단 단위로만 제시하여 개별 근로자와 개별 사업장이 노출되지 않도록 하였다.

## III. 결 과

### 1. 일반적인 특성

Table 1은 K-means 군집분석으로 도출된 세 군집(군집 0: 긴장/주의, 군집 1: 고위험 스트레스, 군집 2: 적극적 관리)의 일반적인 특성을 제시한다. 군집 0은 전체 데이터의 가장 큰 비중(16,025건)을 차지하며, 평균 연령은 52.9세로 군집 1과 유사하지만, 관리감독자와 살수차 등 책임과 작업 강도가 높은 직무 비중이 높아 긴장지수가 가장 높은 잠재위험군으로 분류된다. 군집 1은 6,901건으로 구성되며, 평균 연령은 52.9세, 남성 비율 95.4%로 나타났고, 특정 건설 현장과 일반 근로자, 터널그라우팅 공중 비중이 높아 스트레스 수준이 가장 높고 관리지수가 가장 낮은 고위험군으로 해석된다. 군집 2는 4,647건으로, 평균 연령이 50.1세로 상대적으로 젊고, 덤프트럭, 시스템동바리, 미장 등 숙련공 비중이 높은 것으로 나타났다. 이 군집은 관리지수가 높고 긴장지수가 낮아 안정적인 생체신호 패턴을 보이는 적극적 관리군으로 볼 수 있다.

Table 2는 K-means 군집분석으로 도출된 세 군집의 생체신호 지표(스트레스, 긴장지수, 관리지수, 흥분지수)의 평균값과 군집 정의를 제시한다. 긴장/주의 군집인 Cluster 0은 긴장지수가 43.46으로 세 군집 중 가장 높고 스트레스는 11.50 수준으로, 아직 극단적 스트레스 수준은 아니지만 긴장 상태가 누적되어 향후 급증 위험이 큰 집단으로 해석된다. 고위험 스트레스 군집에 해당하는 Cluster 1은 스트레스 평균이 15.29로 세 군집 중 가장 높고, 관리지수는 4.08로 가장 낮아, 높은 스트레스를 경험하면서도 이를 조절·관리하지 못하는 집단으로 특징지어진다. 적극적 관리 군집인

**Table 1.** General characteristics

Category	Total mean	Cluster 0: Tension/ Alert group (N/%)	Cluster 1: High-risk stress group (N/%)	Cluster 2: Active management group (N/%)
Number of records		16,025	6,901	4,647
age	52.4 ± 11.9	52.9 ± 11.6	52.9 ± 11.3	50.1 ± 13.2
Gender distribution (%)	27,573	Male 97.2 Female 2.8	Male 95.4 Female 4.6	Male 96.1 Female 3.9
Main sites		A sites D sites G sites	B sites E sites H sites	C sites F sites
Main trades (n)		Water truck driver (83) Supervisor (1,073) Tunnel grouting (41)	General laborer (37) Tunnel grouting(21)	Dump truck driver (50) System scaffolding (15) Plastering (14)
Summary of characteristics		Highest tension index; latent risk group	Highest stress and lowest management index; high-risk group	High management index and low tension index; stable group

Note: Clusters were derived by K-means analysis (K=3) using four biosignal indicators (stress, tension index, management index, and excitement index).

**Table 2.** Average values of three clusters of worker biosignals using K-means cluster analysis

Cluster	Stress index	Tension index	Management index	Arousal index	Data	Group
Cluster 0	11.5	43.46	8.87	64.67	16,025	Elevated tension / alertness group
Cluster 1	15.29	40.41	4.08	62.62	6,901	High-stress risk group
Cluster 2	12.26	35.92	20.49	65.81	4,647	Active self-management group

Cluster 2는 스트레스 지수가 12.26 관리지수가 20.49로 월등히 높고, 긴장지수는 35.92로 가장 낮은 반면, 스트레스와 흥분지수는 중간 수준을 유지하여 압박 상황에서도 비교적 효과적으로 스트레스를 관리하는 집단으로 볼 수 있다. 이러한 결과는 동일한 생체지표라도 조합과 균형에 따라 위험 프로파일이 크게 달라질 수 있음을 보여준다.

Table 3은 스트레스 급증(이전 측정 대비 5점 이상 증가) 예측을 위해 구축한 네 가지 분류 모델(Logistic Regression, Random Forest, XGBoost, LightGBM)의 성능을 비교한 결과를 제시한다. Logistic Regression은 Accuracy 0.702, AUROC 0.731로 가장 낮은 성능을 보여 비선형 패턴과 변수 간 복잡한 상호작용을 충분히

반영하지 못하는 한계를 보였다. Random Forest와 XGBoost는 각각 AUROC 0.812, 0.854로 성능이 향상되었으나, 최종적으로 LightGBM 모델이 Accuracy 0.803, Recall 0.816, Precision 0.800, F1-score 0.808, AUROC 0.877을 보여 가장 우수한 예측력을 나타냈다. 특히 Recall이 0.816으로 높은 것은 실제 스트레스 급증 사례를 놓치지 않고 탐지하는 데 유리하다는 점에서 산업안전보건 관점에서 중요한 의미를 갖는다. 이 결과는 의사결정나무 기반 부스팅 기법이 시계열 생체신호와 인구학적 정보를 결합한 스트레스 급증 예측에 적합한 알고리즘임을 보여주었다.

Table 3에서 제시한 분류 성능을 ROC 곡선으로 비교한 결과는 Figure 1에 나타났다. 점선으로 표시된 무

**Table 3.** Performance comparison of stress surge prediction models

Model	Accuracy	Recall	Precision	F1-score	AUROC
Logistic Regression	0.702	0.691	0.705	0.698	0.731
Random Forest	0.761	0.784	0.755	0.769	0.812
XGBoost	0.788	0.801	0.792	0.796	0.854
LightGBM	0.803	0.816	0.8	0.808	0.877




Figure 1. Comparison of ROC curves and AUC by stress surge prediction model

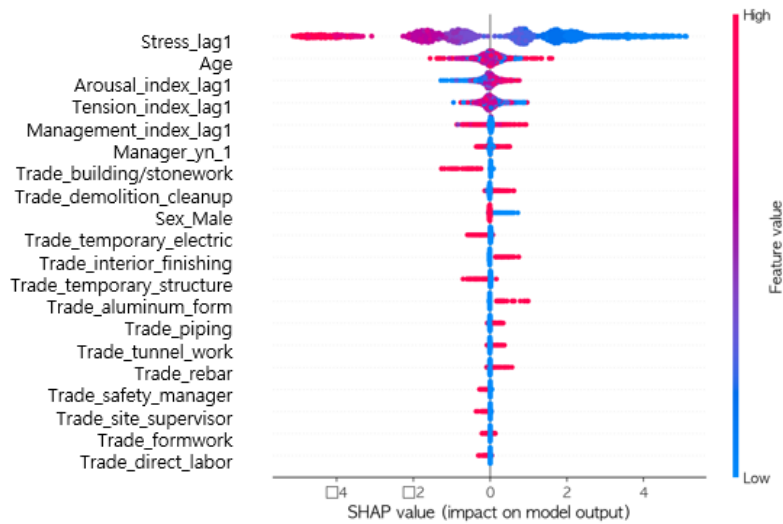


Figure 2. SHAP summary plot by key variables in the stress surge prediction model

작위 추정 기준선(AUC = 0.50)과 비교할 때, 모든 모델의 ROC 곡선은 좌상단 방향으로 치우쳐 있어 우연 수준을 상회하는 예측력을 보였다. 로지스틱 회귀와 결정트리는 비교적 완만한 곡선을 나타냈고, 랜덤 포레스트와 XGBoost는 기준선에서 더 멀어지면서 AUC가 각각 0.854, 0.861 수준으로 향상되었다. LightGBM의 ROC 곡선은 대부분의 구간에서 다른 모델보다 좌상단

에 위치하며 가장 높은 AUC 값(0.877)을 보여, 스트레스 급증 여부를 구분하는 데 가장 우수한 예측 성능을 갖는 모델로 확인되었다. 특히 거짓 양성률이 0.2~0.4 범위일 때 진짜 양성률이 빠르게 증가하는 패턴이 뚜렷해, 실제 현장에서 스트레스 급증 사례를 놓치지 않으면서도 허위 경보를 일정 수준으로 관리할 수 있는 모델이라는 점을 확인하였다.

Figure 2은 Light GBM 기반 스트레스 급증 예측 모델에 대해 SHAP Summary Plot을 제시한 것이다. 상단에 위치한 변수일수록 평균 SHAP 값이 커서 예측에 미치는 영향이 크며, 각각의 점은 단일 관측치에서 해당 변수가 모델 출력에 기여한 정도를 나타낸다. 먼저 스트레스lag1이 가장 상위에 위치하며, 낮은 값(파란색 점)일수록 SHAP 값이 양(+) 방향으로 치우쳐 스트레스 급증 확률을 높이는 경향이 나타났다. 반대로 스트레스 lag1이 높은 경우(붉은색 점)에는 SHAP 값이 주로 음(-) 영역에 분포해 급증 위험을 낮추는 방향으로 작용하는 양상이 확인되었다. 직전 스트레스 수준이 낮을수록 이후 급격히 상승할 여지가 크고, 이미 높은 수준에서는 오히려 급증보다는 유지·완만한 감소로 회귀하는 패턴을 모델이 학습한 결과로 해석된다.

두 번째로 중요한 변수인 나이의 경우, 붉은색 점이 양(+) 영역에 더 많이 분포해 연령이 높을수록 스트레스 급증 위험에 기여하는 방향으로 작용하는 경향이 관찰되었다. 흥분지수 lag1과 긴장지수 lag1도 상위에 위치하며, 값이 높은 관측치에서 SHAP 값이 대체로 양(+) 방향으로 이동해 단기적인 각성·긴장 상태가 스트레스 급증 가능성을 높이는 요인으로 작용함을 확인하였다. 관리지수 lag1은 상대적으로 음(-) 영역에 더 많이 분포하여, 직전 관리지수가 높을수록 이후 급증 위험을 완화하는 보호 요인으로 기능하는 양상이 나타났다.

하위에 위치한 공중 관련 변수들과 manageryn 등의 터미 변수들은 SHAP 값의 절대 크기는 작지만, 특정 공중(예: 터널공사, 내부마감, 안전관리자 등)에서 붉은색 점이 약간 양(+) 영역에 치우치는 패턴이 관찰되었다. 이는 일부 직무와 역할이 스트레스 급증 위험에 소폭 기여할 수 있음을 시사하지만, 생체신호 변수에 비하면 영향력은 제한적이라는 점을 의미한다. 전반적으로 이 SHAP Summary Plot은 스트레스 lag1, 나이, 흥분·긴장지수와 같은 생체 및 개인 특성이 스트레스 급증 예측에서 핵심적인 설명 변수로 작동하고 있음을 시각적으로 보여준다.

## IV. 고찰

### 1. 군집분석 결과와 선행연구 비교

본 연구에서 건설현장 근로자의 생체신호를 기반으로 K-means 군집분석을 수행한 결과, 긴장/주의 군집(군집 0), 고위험 스트레스 군집(군집 1), 적극적 관리 군

집(군집 2)이라는 세 가지 유형이 도출되었다. 이는 생체신호로부터 스트레스 관련 상태를 유형화하려는 국제적인 연구 동향과 비슷한 양상을 보인다. Mozgovoy (2021)는 근로자들의 장기적인 생체신호를 활용해 스트레스 관련 상태를 추정하고, 신호 패턴에 따라 여러 상태 군을 제시했는데, 생체신호 기반 스트레스 상태를 '군집' 단위로 나누어 관리하려는 점에서 본 연구와 방향성이 유사하다. 다만 Mozgovoy(2021)가 개념적 프레임워크 차원에서 스트레스 상태의 장기 추정을 강조했다면, 본 연구는 긴장·관리·스트레스 지표를 결합해 잠재위험군-고위험군-안정군이라는 보다 실무 지향적인 세 가지 유형을 구분했다는 점에서 차이가 있다.

또한 웨어러블을 이용한 스트레스 탐지 연구들을 종합한 체계적·범위 고찰들을 보면(Bolpagni et al., 2024; Pinge et al., 2024), 대부분의 선행연구가 사무실이나 실험실 환경 또는 단기간 측정을 기반으로 고·저 스트레스 수준을 분류하는 데 중점을 두고 있으며, 실제 작업환경과 직무 특성을 반영한 군집 유형화 연구는 상대적으로 적은 것으로 보고되었다. 이와 비교하면, 본 연구는 특정 현장과 공중(관리감독자, 살수차운전자, 근로자, 트럭운전자 등)의 분포까지 함께 제시함으로써, 각 군집이 어떤 작업환경·역할과 맞물려 나타나는지를 보여 주었다는 점에서 현장 적용성이 높다고 볼 수 있다. 예를 들어, 긴장/주의 군집에서 관리감독자 비중이 높고, 고위험 스트레스 군집에서 일반 근로자와 일부 터널 공사가 많이 포함된다는 결과는, 단순한 생체신호 패턴을 넘어 '어떤 직무·역할이 어떤 유형의 스트레스 프로파일과 연결되는가'를 확인하였다. 이는 웨어러블 기반 스트레스 탐지의 가능성을 정리한 Pinge et al. (2024)과 Bolpagni et al.(2024)의 결과와 비교하여, 실제 작업현장에서 활용 가능한 구체적 군집 프로파일을 제시했다는 점에서 의의가 있다.

### 2. 스트레스 급증 예측 성능과 기존 모델 비교

본 연구에서 구축한 LightGBM 기반 스트레스 급증 예측 모델은 Accuracy 0.803, Recall 0.816, AUROC 0.877의 성능을 보였다. 선행연구에서 보고된 웨어러블 기반 스트레스 예측 성능과 비교해도 충분히 경쟁력 있는 수준이다. WESAD 데이터셋을 제시한 Darwish, et al.(2025)은 데이터가 다양한 분류 알고리즘의 성능 평가에 활용될 수 있음을 보여 주었고, 이후 여러 후속 연구에서 WESAD를 이용해 SVM(Support Vector

Machine), Random Forest, 딥러닝 모델 등을 적용했을 때 대체로 AUROC 0.8 이상 수준의 성능이 있다고 하였다. 또한 정보기술 종사자를 대상으로 장기간 웨어러블·모바일 데이터를 수집한 Booth et al.(2022)의 연구에서도, 지각된 스트레스 수준을 예측하는 모델이 AUROC 약 0.8 수준의 성능을 보이는 것으로 제시되었다.

이와 비교하면, 본 연구의 AUROC 0.877은 공개 데이터셋 기반 연구들에서 제시된 값과 유사하거나 그 이상에 해당하는 수준이다. 특히 Booth et al.(2022)가 지식노동자를 대상으로 한 장기 추적 연구에서 'robust stress prediction'의 필요성을 강조한 것과 달리, 본 연구는 건설현장이라는 고위험·고강도 작업환경에서 수집된 데이터를 이용해 이와 유사한 수준의 예측력을 확보했다는 점에서 의미가 있다. 또한 Darwish et al.(2025) 관련 후속 연구들이 주로 '현재 상태의 스트레스 수준 분류'에 중점을 둔 데 비해, 본 연구는 직전 값 대비 5점 이상 증가라는 '급증 이벤트'를 목표 변수로 설정했다는 점이 다르다. 즉, 기존 연구가 현재 스트레스 상태를 진단하는 모델에 가깝다면, 본 연구의 모델은 다음 측정 시점에 급격한 상태 악화가 발생할 가능성을 예측하는 조기경보 모델에 더 가깝다. 이러한 접근은 Pinge et al.(2024)가 연구에서 제시한 웨어러블 기반 스트레스 관리의 다음 단계는 선제적 개입을 위한 예측 모델'이라는 방향성과도 부합한다.

### 3. XAI·SHAP 분석 결과와 기존 XAI 연구 비교

LightGBM 모델에 대해 SHAP을 적용한 본 연구의 결과는, 어떤 변수가 스트레스 급증 예측에 핵심적인 역할을 하는지, 그리고 변수값의 수준에 따라 예측 방향이 어떻게 달라지는지에 대한 구체적인 정보를 제공한다. 스트레스 lag1이 가장 큰 기여도를 보였고, 낮은 baseline일수록 급증 가능성이 높고 이미 높은 수준에서는 급증 위험이 낮아지는 평균 회귀 패턴이 관찰되었다. 연령, 흥분지수 lag1, 긴장지수 lag1도 중요한 변수로 나타났으며, 관리지수 lag1은 보호 효과를 보였다.

이러한 XAI 기반 해석은 스트레스 분야의 선행 연구들과도 연결된다. Tariq et al.(2025)는 교육 환경에서 설문 기반 스트레스 자료에 여러 머신러닝 모델을 적용하고, SHAP을 이용해 불안, 수면, 학습·생활습관 등 심리·행동 관련 변수들이 스트레스 예측에서 높은 기여도를 보인다는 점을 제시했다. Kim et al.(2024)는 웨어

러블 생체신호(심박수, 피부온도 등)를 활용해 열쾌적성을 예측하는 LightGBM 모델을 구축하고, SHAP 분석을 통해 어떤 생체신호가 체감 온열감에 더 큰 영향을 미치는지, 그리고 그 영향 방향이 어떻게 달라지는지 시각적으로 제시했다. 두 연구 모두 '블랙박스 모델의 내적 작동 원리를 드러내고, 주요 변수와 그 영향 방향을 설명한다'는 XAI의 장점을 뚜렷이 보여준다.

본 연구의 SHAP 분석은 이러한 선행연구와 비교할 때 두 가지 측면에서 의미가 있다. 첫째, Tariq et al.(2025)가 설문 기반 데이터에서 심리·행동 요인의 중요성을 보여주었다면, 본 연구는 생체신호와 인구학적 변수를 결합한 모델에서 시간 지연 변수(스트레스 lag1, 흥분지수 lag1, 긴장지수 lag1)의 역할을 구체적으로 드러냈다. 특히 baseline 수준에 따른 SHAP 값의 부호 변화는, 단순히 '값이 높을수록 위험'이라는 일차원적 해석을 넘어서, 스트레스 수준의 높고 낮음이 각각 다른 방식의 위험 신호가 될 수 있음을 시사한다. 둘째, Kim et al.(2024)가 열쾌적성이라는 비교적 중립적인 결과변수에 대해 SHAP을 적용한 것과 달리, 본 연구는 건설현장 근로자의 스트레스 급증이라는 안전·보건에 직접 관련된 결과에 XAI를 적용했다는 점에서 응용적 파급효과가 크다. 이는 XAI가 단순한 모델 설명 도구를 넘어, 어떤 근로자를 우선 모니터링해야 하는지, 어떤 요인을 관리 전략의 핵심 타겟으로 삼아야 하는지에 대한 의사결정 근거를 제공한다는 점을 보여준다.

### 4. 본 연구의 위치와 향후 연구 방향

위의 비교를 정리하면, 본 연구는 Booth et al.(2022)이 제시한 장기 종단 웨어러블·자기보고 스트레스 예측 연구와 Darwish et al.(2018), Sano et al.(2018) 이후 축적된 생체신호 기반 스트레스 검출 연구들을 분석하여, 최근의 체계적 문헌고찰 연구(Bolpagni et al., 2024; Kafková et al., 2024; Pinge et al., 2024)에서 제시한 웨어러블·모바일 기반 스트레스 모니터링 흐름을 실제 산업현장, 특히 건설근로자라는 고위험 작업환경 맥락으로 확장한 사례로 볼 수 있다고 하였다.

선행연구가 주로 대학생이나 정보기술 종사자 등 비교적 균질한 집단을 대상으로, 현재 스트레스 수준을 분류하거나 정신건강 상태를 추정하는 데 중점을 두었다면, 본 연구는 건설현장이라는 고위험 작업환경에서 수집된 생체신호를 활용해 세부 군집 유형화·급증 예측

-설명가능성 분석을 하나의 프레임워크로 제시했다는 점에서 차별성을 가질 수 있을 것이다. 또한 Pinge et al.(2024)와 Bolpagni et al.(2024)가 리뷰에서 강조한 '웨어러블 기반 스트레스 연구의 다음 과제는 실제 현장에 적용 가능한 맞춤형 관리 전략'이라는 방향성도 비슷하다.

향후 연구에서는 Sano et al.(2018)가 제시한 것처럼 수면, 활동량, 스마트폰 사용 패턴 등 행동·생활습관 지표를 추가로 결합하거나, Booth et al.(2022)가 시도한 것처럼 개인별 장기 추적 데이터를 기반으로 한 개인화(personalized) 모델을 도입함으로써 예측력과 설명력을 동시에 높일 수 있을 것이다. 또한 Kim et al.(2024)의 연구처럼 다른 생리적 결과(예: 피로, 열부담, 수면의 질 등)에 대해 유사한 프레임워크를 적용해 다차원적 건강·안전 모니터링 체계를 구축하는 것도 하나의 확장 방향이 될 수 있다. 이런 점에서 본 연구는 웨어러블·생체신호 기반 스트레스 연구와 XAI 연구의 국제적 흐름 속에서, 건설업 근로자의 스트레스 위험 관리에 특화된 응용 사례를 제시한 출발점으로 평가할 수 있다.

## 5. 실무적 의의

본 연구는 웨어러블 생체신호를 활용하여 근로자를 세 가지 위험 유형으로 분류함으로써 단순 수준을 넘어선 맞춤형 관리 목표를 설정할 수 있는 근거를 제공한다. 개발된 LightGBM 모델은 높은 정확도로(AUROC 0.877) 다음 측정 시점의 급성 스트레스 급증 사건을 사전에 탐지하여 예방적 조치(예: 휴식 권고)를 가능하게 한다. 특히 SHAP 분석을 통해 낮은 스트레스 수준에서 발생하는 급격한 변화나 고연령 근로자의 위험 증가 등 복잡한 예측 근거를 이해 가능한 형태로 제시하여 관리의 투명성과 근로자 수용도를 높인다. 결과적으로, 기존의 사후적이고 획일적인 스트레스 관리 방식에서 벗어나 데이터 기반의 능동적 조기 경보 및 자원 효율화가 가능한 디지털 기반 지능형 안전보건 관리 시스템을 구축할 수 있다.

## V. 결 론

본 연구는 건설현장 근로자에게서 수집한 생체신호 데이터를 이용해, 군집분석·스트레스 급증 예측·설명가능 인공지능 분석을 하나의 흐름으로 묶어 분석한 연구

이다. 스트레스, 긴장지수, 관리지수, 흥분지수 4개 지표를 바탕으로 K-means 군집분석을 수행한 결과, 긴장/주의 군집, 고위험 스트레스 군집, 적극적 관리 군집이라는 세 가지 군집 유형이 분석되었다. 긴장/주의 군집은 긴장 수준이 가장 높으면서 스트레스는 중간 수준에 머무르는 잠재위험군으로 나타났고, 고위험 스트레스 군집은 스트레스가 가장 높고 관리지수가 가장 낮아 소진 위험이 큰 집단으로 확인되었다. 반대로 적극적 관리 군집은 관리지수가 높고 긴장지수가 낮아 생리적 안정성이 상대적으로 우수한 집단으로 분류되었다. 단순한 평균값 비교를 넘어, 세 군집이 서로 다른 작업현장과 공중에 분포한다는 점도 확인되어, 생체신호 패턴과 작업환경 특성을 함께 고려한 유형화가 가능함을 보여준다.

스트레스 급증 예측 모델의 성능 역시 실무 적용 가능성을 뒷받침한다. 직전 측정치 대비 스트레스가 5점 이상 증가하는 경우를 급증 사건으로 정의하고 여러 분류 알고리즘을 비교한 결과, LightGBM 모델이 Accuracy 0.803, Recall 0.816, AUROC 0.877로 가장 우수한 성능을 보였다. 기존 웨어러블 기반 스트레스 예측 연구들이 공개 데이터셋이나 정보기술 종사자들을 대상으로 AUROC 0.8 전후의 성능을 보고한 바 있다는 점을 고려하면(Booth et al., 2022; Darwish et al., 2025), 실제 건설현장 데이터를 활용한 본 모델의 예측력은 국제적 연구 수준과 비교해도 손색이 크지 않다. 특히 현재 스트레스 수준을 분류하는 데 그치지 않고, 다음 측정 시점의 급격한 악화를 예측한다는 점에서, 현장에서 선제적 개입을 위한 조기경보 도구로 활용될 여지가 크다.

설명가능 인공지능 분석 결과는 어떤 요인에 주의를 기울여야 하는지 보다 구체적인 결과를 제공한다. SHAP 분석에서 스트레스 lag1이 가장 영향력이 큰 변수로 나타났고, 기본적인 스트레스가 낮을수록 급증 가능성이 높고 이미 높은 구간에서는 오히려 급증 위험이 낮아지는 평균 회귀 패턴이 확인되었다. 연령, 흥분지수 lag1, 긴장지수 lag1도 중요한 위험 요인으로 작용했고, 관리지수 lag1은 급증 위험을 완화하는 보호 요인에 가까운 양상을 보였다. 이러한 결과는 스트레스 수준 자체뿐 아니라 최근의 변화 방향과 관리 역량을 함께 고려하는 것이 중요하다는 점을 시사하며, XAI를 활용한 선행연구들이 강조해 온 '모델의 판단 근거를 해석 가능한 형태로 제시할 필요성'(Kim et al., 2024;

Tariq et al., 2025)과 비슷한 결과를 보여주었다.

이러한 분석을 바탕으로 볼 때, 산업안전보건 측면에서 스트레스 관리는 최소한 두 축으로 나누어 접근하는 것이 적절하다. 하나는 고위험 스트레스 군집처럼 이미 높은 수준의 스트레스가 지속되는 집단에 대한 집중 개입으로, 상담, 휴식 보장, 작업 재조정 등 부담을 줄이는 조치가 필요하다. 다른 하나는 긴장/주의 군집처럼 아직 절대적인 스트레스 수준은 높지 않지만 긴장이 지속되고 급증 가능성이 큰 집단을 대상으로, 변화 징후를 면밀히 관찰하고 위험이 높아지기 전에 개입할 수 있는 모니터링 체계를 운영하는 것이다. 적극적 관리 군집은 상대적으로 양호한 상태를 유지하고 있어, 이들의 작업·조직 문화와 자기 관리 전략을 다른 집단에 확산하는 데 참고할 수 있다. 군집 유형을 단순한 통계 결과가 아닌 관리 전략의 기준으로 활용할 수 있다는 점에서 본 연구의 실무적 의의가 있다.

또한 예측 변수로 사용한 정보가 생체신호와 기본 인구학적 특성에 주로 국한되어 있어, 수면, 교대근무, 작업시간, 기상 상황과 같은 추가 요인을 함께 고려할 경우 모델의 설명력이 더 높아질 가능성이 커질 수 있다. 여성·외국인 근로자의 비율이 낮아 이들 집단에 특화된 분석을 수행하지 못했다는 점도 제한 사항으로 남는다. 향후에는 다기관 자료나 다른 산업군 데이터를 함께 활용해 모델의 일반화 가능성을 검증하고, 공개 데이터셋과의 교차 비교를 통해 본 연구 결과를 보다 확장해 볼 수 있겠다.

그럼에도 불구하고, 본 연구는 실제 건설현장 데이터를 바탕으로 군집 유형화, 급성 스트레스 급증 예측, 설명가능 인공지능 분석을 하나의 프레임으로 제시했다는 점에서 의미가 있다. 웨어러블·생체신호 기반 스트레스 연구가 현장 중심의 디지털 안전보건 관리 체계로 확장되는 과정에서, 본 연구가 하나의 참조 모델로 활용될 수 있기를 기대할 수 있다.

## References

- Abuwarda Z, Mostafa K, Oetomo A, Hegazy T, Morita P. Wearable devices: cross benefits from healthcare to construction. *Autom Constr* 2022;142:104501
- Adepu N, Kermanshachi S, Pamidimukkala A. Long-term physical and mental health impacts of COVID-19 on construction workers. In: International Conference on Transportation and Development 2024. Reston (VA): American Society of Civil Engineers; 2024. p.431-440
- Bolpagni M, Pardini S, Dianti M, Gabrielli S. Personalized stress detection using biosignals from wearables: A scoping review. *Sensors* 2024;24(10):3221 (<http://doi.org/10.3390/s24103221>)
- Booth BM, Vrzakova H, Mattingly SM, Martinez GJ, Faust L, D'Mello SK. Toward robust stress prediction in the age of wearables: Modeling perceived stress in a longitudinal study with information workers. *IEEE Trans Affect Comput* 2022;13(4):2201-2217 (<https://doi.org/10.1109/TAFFC.2022.3188006>)
- Bradley AP. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognit* 1997;30(7):1145-1159
- Darwish BA, Rehman SU, Sadek I, Salem NM, Kareem G, Mahmoud LN. From lab to real-life: A three-stage validation of wearable technology for stress monitoring. *MethodsX* 2025;14:103205 (<https://doi.org/10.1016/j.mex.2025.103205>)
- Fitri RY, Budiyanoto B, Hartanti RI. What is the relationship between job stress and work fatigue among construction workers? A cross-sectional study. *Arteri J Ilmu Kesehatan* 2023;5(2):117-126
- Gao N, Ananthan S, Yu C, Wang Y, Salim FD. Critiquing self-report practices for human mental and wellbeing computing at Ubicomp. *arXiv [Preprint]*. 2023 Nov 27 [cited 2025 Dec 10]. Available from: <https://arxiv.org/abs/2311.15496>
- Gómez-Salgado C, Camacho-Vega JC, Gómez-Salgado J, García-Iglesias JJ, Fagundo-Rivera J, Allande-Cussó R, et al. Stress, fear, and anxiety among construction workers: A systematic review. *Front Public Health* 2023;11:1226914 (<http://doi.org/10.3389/fpubh.2023.1226914>)
- Hastie T, Tibshirani R, Friedman J. The elements of statistical learning: data mining, inference, and prediction. 2nd ed. New York: Springer; 2009
- Ibrahim K, Barakat S, Al-Mekhlafi AB, Abdulkareem M, Al-Ghamdi SG. Benefits and challenges of wearable safety devices in the construction industry. *Smart Sustain Built Environ* 2025;14(1):50-71
- Jaber D, Hajj H, Maalouf F, El-Hajj W. Medically oriented design for explainable AI for stress prediction from physiological measurements. *BMC Med Inform Decis Mak* 2022;22(1):38.
- Kafková J, Řihat'ko M, Procházka A, Martínek J. A new era in stress monitoring: a review of embedded devices for non-invasive stress detection. *Electronics* 2024;13(19):3899

- Karim R, Guo X, Wu H. Advancing physical and mental fatigue analysis in construction workers: Insights, technologies, and future directions. *Dev Built Environ* 2025;24:100808 (<http://doi.org/10.1016/j.dibe.2025.100808>)
- Kim H, Lee G, Ahn H, Choi B. Interpretable general thermal comfort model based on physiological data from wearable bio sensors: Light Gradient Boosting Machine and SHapley Additive exPlanations (SHAP). *Build Environ* 2024;266:112127 (<http://doi.org/10.1016/j.buildenv.2024.112127>)
- Kuhn M, Johnson K. *Applied predictive modeling*. New York: Springer; 2013
- Mollaei N, Fujao C, Rodrigues J, Cepeda C, Gamboa H. Occupational health knowledge discovery based on association rules applied to workers' body parts protection: a case study in the automotive industry. *Comput Methods Biomech Biomed Engin* 2023;26(15):1875-1888
- Mollaei N, Fujao C, Silva L, Rodrigues J, Cepeda C, Gamboa H. Human-centered explainable artificial intelligence: automotive occupational health protection profiles in prevention of musculoskeletal symptoms. *Int J Environ Res Public Health* 2022;19(15):9552
- Mozgovoy V. Longitudinal estimation of stress-related states through bio-sensor data. *Appl Comput Inform* 2021 (<http://doi.org/10.1108/ACI-03-2021-0070>)
- Pamidimukkala A, Kermanshachi S, Almaskati DN. Mental health in construction industry: a global review. *Int J Environ Res Public Health* 2025;22(5):802
- Pinge A, Gad V, Jaisighani D, Ghosh S, Sen S. Detection and monitoring of stress using wearables: A systematic review. *Front Comput Sci* 2024;6:1478851(<http://doi.org/10.3389/fcomp.2024.1478851>)
- Sano A, Taylor S, McHill AW, Phillips AJK, Barger LK, Klerman E, et al. Identifying objective physiological markers and modifiable behaviors for self-reported stress and mental health status using wearable sensors and mobile phones: Observational study. *J Med Internet Res* 2018;20(6):e210 (<http://doi.org/10.2196/jmir.9410>)
- Tariq R, Orozco-del-Castillo MG, Zamir MT, Ramirez-Montoya MS, Wilberforce T. Explainable artificial intelligence for predictive modeling of student stress in higher education. *Sci Rep* 2025;15:38375(<http://doi.org/10.1038/s41598-025-22171-3>)
- Zong H, Yi W, Antwi-Afari MF, Yu Y. Fatigue in construction workers: a systematic review of causes, evaluation methods, and interventions. *Saf Sci* 2024;176:106529

#### <저자정보>

한동훈(박사과정) 세이프티흥우 대표 / 동국대학교 석학 박사과정