

Research Paper

소규모 건설현장의 안전사고 예측을 위한 딥러닝 알고리즘 기반의 예측프레임워크 제안

Proposal of a Prediction Framework Based on Deep Learning Algorithm to Predict Safety Accidents at Small-scale Construction Sites

김지명*

Kim, Ji-Myong*

Associate Professor, Department of Architectural Engineering, Mokpo National University, Muan-gun, Jeonnam, 58554, Korea

*Corresponding author

Kim, Ji-Myong

Tel : 82-61-450-2457

E-mail : jimy6180@gmail.com

Received : September 27, 2023

Revised : November 8, 2023

Accepted : November 9, 2023

ABSTRACT

This study aims to develop a framework for an accident prediction model leveraging a deep neural network algorithm, specifically tailored for small-scale construction sites. Notably, the incidence of accidents in the construction sector is markedly higher compared to other industries, with a significant contribution from small-scale sites. The challenging nature of construction in urban settings, coupled with the increasing frequency of adverse weather conditions, is likely to escalate accident risks at these sites. Anticipating and mitigating accidents at small-scale construction sites is therefore crucial to decrease the overall industry accident rate. Consequently, this research introduces a Deep Neural Network-based model for forecasting accidents at small-scale construction sites. The framework and findings of this study are poised to serve as a guideline for the safety management of small-scale construction projects, ultimately aiding in the realization of safer, more sustainable construction practices at these sites.

Keywords : small-scale construction site, safety management, accident, deep neural network algorithm

1. 서론

건설업은 사고 건수와 사고 건수가 다른 산업에 비해 훨씬 높다는 오명을 갖고 있다. 한국노동청이 발표한 2021년 산업재해 현황에 따르면, 건설업 사고의 주요 원인은 붕괴, 끼임, 눌림, 물체에 부딪힘, 전복, 부딪힘 등 다양하다. 특히 건설업에서는 5인 미만 사업장에서 사망자가 가장 많이 발생한 것으로 알려졌고, 재해 피해자 수를 분석해 보면 사상자 수와 비슷한 경향을 보이고 있다. 재해 피해자는 기타 업종(38.9%), 건설업(26.3%), 제조업(23.7%) 순으로 높았다. 다만, 사고 사망자는 건설업(50.4%), 제조업(22.2%), 기타업종(14.9%) 순으로 나타났다. 건설업의 사망자 수는 두 번째로 높은 제조업에 비해 2.3 배나 높았다.

앞선 통계에서 볼 수 있듯이 건설업은 산업의 특성상 다른 산업에 비해 안전사고에 더 많이 노출되어 있다[1-5]. 이러한 특징을 몇 가지 요약하면, 첫째, 건설산업은 작업환경의 특수성으로 인해 외부환경에 직접적으로 노출되기 때문에 옥외작업, 날씨, 지형 등에 의해 큰 영향을 받는다. 또한, 가설 구조물의 반복적인 조립과 해체, 다수의 건설기계 및 중량물 취급 등 작업 자체에 많은 위험이 따른다[2]. 둘째, 건설산업 내부환경에서는 최저임찰에 따른 낮은 공사가격, 공사발주기간, 공사기간 부족 등 건설계약의 불평등과 일방적 성향이 있다. 이는 재하도급, 공정별 하도급, 공종별 하도급으로 이어져 안전관리의 미흡



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

으로 이어지고 있다[1,3]. 셋째, 최근 건축물의 초고층화, 복합화, 도심 건설 등 건설산업에 도입되는 신기술 및 신공법의 급속한 유입으로 인해 건설 기술 환경의 변화가 발생하고 있다. 이는 건설사의 규모에 따른 기술의 편차 및 안전대책의 미흡으로 이어지고, 이는 안전기술의 저하, 공사비 절감, 공사기간 단축, 안전 고려사항 소홀 등의 사고발생 원인으로 기인하고 있다[4]. 마지막으로 건설업계의 안전문화를 들 수 있다. 근로자의 유동성이 높은 건설업의 특성상 건설근로자는 고용이 불안정하여 근로자가 현재 건설현장에 대한 소속감이 부족하고 안전교육 기회도 부족하다. 또한, 일일 근무시간이 불확실하고, 지속적인 작업으로 피로가 누적되어 근로자의 안전의식이 퇴행되는 현상이 나타나고 있다. 더욱이, 근로자의 급격한 고령화와 외국인 근로자의 유입은 건설산업의 안전문화 선진화를 저해하고 있다[1,5]. 이러한 이유들로 인해 건설산업의 작업환경, 내부환경, 기술환경, 안전문화 등으로 인해 건설산업은 다른 산업에 비해 사고 발생 가능성이 높다. 따라서 건설산업의 문제점을 분석하고, 해당 산업의 사고발생을 줄이기 위한 개선 방안을 도출하고 건설현장의 사고예방에 대한 연구가 시급히 요구된다.

2. Literature review

소규모 건설현장은 중형 혹은 대형 건설현장에 비해 사고에 더 취약하다. 그 이유는 다음과 같이 요약될 수 있다. 첫째, 소규모 건설현장(공사비20억원미만)은 중형 혹은 대형 건설현장에 비해 안전관리 조직과 기술체계가 상대적으로 부족하다. 현행 안전관리체계에서는 소형 건설현장은 재해예방 전문 지도기관의 기술지도 대상 사업장으로 분류되고, 대형 건설현장은 지정 대상 사업장으로 분류하고 있다. 즉, 소형 건설현장은 안전관리자를 선임할 의무가 없다. 이는 사고예방 전문지도기관의 기술지도를 받고 있는 공사비 20억원 미만 건설현장에서 사고 발생 건수가 더 많기 때문에 안전관리조직의 부재가 사고에 미치는 영향이 크다는 점을 잘 보여준다. 현장 안전조직의 부재는 안전교육 미이행, 기본 안전수칙 미준수 등이 발생하여 사고 발생률이 증가한다[6]. 둘째, 소규모 건설현장은 대규모 건설현장에 비해 경제적으로 상당히 열악하다. 소형 건설현장은 상대적으로 공사기간이 비교적 짧고, 공사비가 낮아 공사기간과 공사기간에 치중하여 사고율이 높다. 더욱이, 이러한 경제적 열세는 안전에 대한 투자의 부족이나 기피로 이어져 중소 건설현장의 작업환경을 악화시키기도 한다. 또한, 안전과 관련된 전문기술, 장비, 기능 등 안전에 필요한 투자가 제대로 이루어지지 않아 사고예방을 위한 안전관리가 미흡하다. 또한, 소규모 건설현장은 건설기간이 짧아 건설현황을 파악하기 어려워 건설환경 개선을 위한 투자가 어렵다[7,8]. 셋째, 소규모 건설현장은 정책적 지원과 제도적 규제를 통한 안전관리의 사각지대에 놓여 있다. 예를 들어 안전보건 의무의 범위와 대상을 확대하고 처벌의 강도를 대폭 강화하기 위해 2022년 시행된 중대재해처벌법은 소규모 건설현장(상시근로자 5인 미만)을 제외하고 있다. 또한 소규모 건설사(시공능력 상위 1,000위 밖)는 사고가 발생해도 입찰에 있어 불이익이 없어 사업주 및 기타 관리자 등의 안전보건 인식이 부족하기도 하다[8,9]. 앞에서 살펴보았듯이, 건설산업의 안전사고 예방을 위한 다양한 노력에도 불구하고 건설산업의 안전사고는 소규모 현장을 중심으로 증가하고 있다. 따라서 소규모 건설현장의 안전사고를 줄이지 않고는 건설산업 전체 사고 건수를 낮추는 것은 불가능하다[7]. 사고를 줄이기 위해서는 사고 위험을 줄이기 위한 적극적인 투자가 필수적이다. 이를 위해서는 잠재적인 사고 위험에 대한 정교한 예측이 필수적이다. 이러한 사고위험 예측은 발생할 수 있는 사고의 종류와 규모를 파악하여 사고위험을 예방하고 감소시키는 데 활용될 수 있으며, 궁극적으로 건설사업의 연속성을 보장하고 수익증대에 영향을 미칠 수 있다. 그럼에도 불구하고, 위에서 논의한 바와 같이 소규모 건설현장과 다른 규모 건설현장은 특성이 뚜렷한 차이가 있음에도 불구하고, 이러한 차이를 고려한 건설사고 위험도를 정량화하는 연구와 모델은 부족한 실정이다.

건설 프로젝트의 사고위험도 분석은 건설현장의 잠재적인 위험을 사전에 예방 및 제거하여 관리하고, 최종적으로 사고위험을 감소시키는 것이다. 이는 결국 사고 위험을 줄여 성공적인 건설 프로젝트로 이어질 수 있다. 또한, 사고 위험도 분석을 통한 예측은 건설 프로젝트에서 제한된 자원을 적절하게 배분하고 실행하기 위한 전략을 수립하는 척도로 사용될 수 있다

[10,11]. 결과적으로, 정교한 사고 위험 분석은 유익하고 지속 가능한 건설 프로젝트에 매우 중요하다. 그러나 객관적이고 과학적인 사고 위험도 분석에는 어려움이 존재한다. 그 이유는 사고위험도 평가에서는 전문가, 엔지니어, 고객의 의견이나 경험이 활용되는 경우가 많고, 의견이나 경험 외에 지수화에 어려움이 있는 주관적 지표도 사고위험도 평가에 포함되기 때문이다[12,13]. 예를 들어, 건설 관련 전문가나 엔지니어의 지식과 경험을 바탕으로 한 설문 조사나 체크리스트 등의 정성적 방법론이 사고 위험 평가 자주 사용된다[14]. 그 이유로는 정량적 방법론을 사용하기 위해서는 신뢰성 있는 데이터 확보가 가장 중요한 요소이지만, 신뢰성 있는 데이터 수집의 한계로 인해 건설업계에서는 정성적 방법론이 강요되는 경우가 많기 때문이다[15,16]. 또한 건설현장의 특수성과 복잡성으로 인해 다양한 지표의 영향을 받아 정량적 분석에 어려움이 있다[1]. 이는 건설현장에는 외부 업무 프로세스가 많고, 각 프로세스별 전문업체가 다수가 한정된 장소에서 짧은 공사기간 내에 작업이 이루어지기 때문에 수없이 많고 복합적인 위험지표로부터 보호받지 못하고 있어 사고에 대한 엄청난 불확실성을 안고 있기 때문이다[17,18]. 이로 인해 건설산업은 지난 수십 년간 사고를 줄이기 위해 적극적인 투자와 정책, 제도를 강화하고 도입했지만, 건설산업의 사고 건수는 여전히 타 산업보다 매우 높다[19,20]. 따라서 건설현장의 사고위험도 분석을 고도화하고 개선하기 위해서는 신뢰할 수 있는 데이터 수집 및 분석이 필수적이며, 데이터의 과학적이고 정량적인 분석을 위해서는 신뢰할 수 있고 진보된 분석기법이 전제되어야 한다.

과거연구에서 볼 수 있듯이, 기존의 많은 연구에서는 건설사고 데이터 분석을 통해 위험지표를 식별하고 평가함으로써 효과적인 안전관리를 위한 분석 방법 및 프레임워크를 제안하였다. 그럼에도 불구하고, 건설산업의 재해율은 여전히 다른 산업에 비해 높은 수준이므로 이를 개선하기 위한 지속적인 연구와 노력이 시급하다. 이러한 노력의 연장선에서 본 연구에서는 딥러닝 기법을 적용하여 소규모 건설현장 사고 발생 예측 모델 프레임워크를 제안코자 한다. 딥러닝 기법은 퍼지로지, 머신러닝 등 다른 인공지능 기법에 비해 복잡한 구조를 가질 수 있어, 보다 다면적이고 대용량의 데이터를 빠르고 정확하게 처리할 수 있다[21]. 이 기법은 최근 건설현장에서 급속히 구현되고 있는 드론, IoT, 센서, CCTV 등에서 생산 및 축적되는 대량의 빅데이터를 분석하는데 적극적으로 도입할 수 있으며, 비용 절감에 기여할 것으로 기대된다. 이에 본 연구에서는 딥러닝 알고리즘을 활용하여 건설현장 규모의 특성을 고려한 건설현장 사고분석 방법을 제안코자 한다.

3. Research Framework

본 연구의 궁극적인 목표는 딥러닝 알고리즘을 활용하여 소규모 건설현장의 사고예측 모델의 프레임워크를 제안하는 것이다. 세부 목적은 첫째, 건설현장에서 발생하는 사고사례 및 지표를 수집한다. 둘째, 수집된 데이터를 건설현장 규모별 나

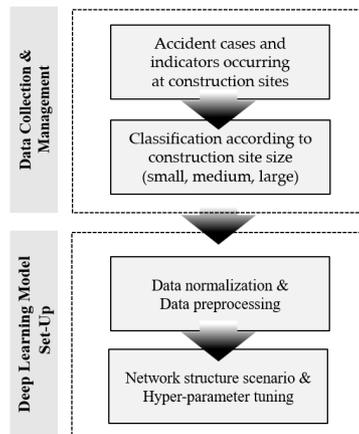


Figure 1. Research framework

누어 분류한다. 셋째, 수집된 소규모 건설현장의 사고 데이터를 기반으로 딥러닝 알고리즘 모델을 생성한다. 본 연구의 프레임워크는 Figure 1과 같다.

4. 데이터 수집

본 연구에서는 2010년부터 2021년까지 국내 소규모 건설현장에서 발생한 사고사례를 기반으로 딥러닝 모델을 개발하였다. 사고사례는 한국산업안전보건공단에서 수집하였다. 한국산업안전보건공단에서 수집한 자료에는 사고 현장의 공사 규모, 전체 근로자 수, 공사 진행 상황, 사고 피해자의 국적, 직업 유형 등이 포함되어 있다. 사고는 사고 유형 분류, 사고 내용, 사고 일시, 사고로 인한 총 입원 일수 등으로 구성되어 있다. 이 중 사고의 심도를 산출하기 위한 출력변수로 치료일수를 사용하였으며, 사례의 통일성을 위해 사망사고는 제외하였다. 치료일수는 정규분포를 위해 로그변환을 수행하였다. 본 연구에서는 건설현장 사고와 관련된 위험지표에 대한 선행연구를 통해 사고시각, 근로자수, 직업구분, 사고국적, 고용상태, 사고 일자, 공사진행상황을 입력변수로 선정하였다[22-24]. Table 1은 입력 및 출력 변수를 설명하고 있다. 시간과 요일은 작업자의 집중도, 공사 난이도 등에 따라 영향을 받고, 사고 발생 및 사고 심도에 영향을 미치기 때문에 재해 위험도 측정 및 평가에 광범위하게 사용되는 지표이다[1,24]. 각각은 명목변수로 입력되었다. 직업분류, 사고 국적, 고용상태 등도 통계적으로 사고와 유의한 관련이 있어 사고 관련 지표로 활용되는 경우가 많다[3]. 예를 들어, 사고가 발생한 국적은 비이주 노동자와 이주 노동자로 구별된다. 비이주근로자는 이주근로자에 비해 경력이 길고 안전교육 기회도 많아 사고 위험이 낮다. 또한 정규직은 비정규직에 비해 재해위험이 적기 때문에 고용형태를 정규직과 비정규직으로 구분하였다. 직업분류, 사고국적, 고용상태 등을 모두 명목변수로 입력되었다. 근로자 수는 사고 위험도를 나타내는 지표로 자주 사용되는데, 이는 건설 현장이 클수록 근로자가 안전 교육을 받을 수 있는 기회와 안전 담당자의 수준 높은 안전 관리를 받을 수 있기 때문에 근로자가 사고에 덜 취약하기 때문이다[3,22]. 공정율은 공사가 진척되고 다양한 공정이 전개될수록 다양한 전문 건설업체가 더 많이 참여하기 때문에 건설현장의 복잡도 높아져 사고 위험도 또한 높아지게 된다. 이러한 이유로 공정율은 사고위험지수로 널리 채택되고 있으며, 본 연구에서는 이를 수치변수로 입력하였다[5]. 소규모 건설현장의 분류는 산업안전보건법에 따라 분류되었다. 산업안전보건법에서는 총공사비가 20억원 미만인 건설현장을 소규모 건설현장으로 분류하고 있다[6]. 수집된 데이터의 자세한 설명은 Table 1과 같다. 수집된 데이터의 자세한 통계는 Table 2와 같다. 수집된 데이터는 총 2,109건이었다.

Table 1. Detailed descriptions of variables

Variables	Descriptions
Remedy days	Total number of remedy days for accident treatment(Output variables)
Number of worker	Total number of workers at the construction site where the accident occurred
Occupation types	Occupation types according to the Korean Standard Occupational Classification
Time zone	Time zone when the accident occurred at the construction site
Employment type	Classification according to employment type of construction site accident workers
Accident day	Day of the week when accidents occurred at construction sites
Construction progress rate	Construction progress rate at the time an accident occurred at a construction site
Nationality of accident victim	Classification according to nationality of accident victims

Table 2. Statistics of descriptive analysis

Variables	Number	Min	Max	Average	STD
Remedy days	2,109	1.00	100.00	10.69	14.16
Number of worker	2,109	2.00	5.00	3.85	1.00
Occupation types	2,109	1.00	4.00	3.47	0.58
Time zone	2,109	0.00	1.00	0.94	0.23
Employment type	2,109	1.00	7.00	4.00	2.06
Accident day	2,109	1.00	100.00	50.62	27.06
Construction progress rate	2,109	0.00	1.00	0.05	0.22
Nationality of accident victim	2,109	2.00	5.00	2.00	5.00

5. 딥러닝 알고리즘 모델 제안

본 섹션에서는 여러 산업 분야의 예측과 인식에 적용되는 딥러닝 알고리즘을 활용하여 소규모 건설현장의 사고를 예측하는 모델 프레임워크를 제안코자 한다. 딥러닝 알고리즘은 여러 계층의 신경망으로 구성된다. 이러한 이유로 다양한 유형의 데이터에 적용할 수 있으며 수많은 산업 분야에서 광범위하게 적용된다[23]. 예를 들어 Recurrent Neural Network(RNN), Deep Neural Network(DNN), Convolutional Neural Network(CNN), Auto Encoder(AE), Generative Adversarial Network(GAN) 등 처리 방법에 따라 다양한 알고리즘이 있다. 그 중 DNN은 다양한 특정 기능을 식별하기 위해 여러 계층이 작동하기 때문에 복잡한 비선형 관계를 가진 데이터의 예측 및 분류에 일반적으로 적용된다[25]. 따라서 본 연구에서는 건설현장 사고 데이터의 비선형성을 고려하여 DNN을 활용하여 건설 규모에 따른 사고 예측 모델을 개발하기 위한 프레임워크를 제안한다.

본 논문에서는 최적의 DNN 모델을 결정하기 위해 일반적으로 인공신경망의 예측오차 평가지표로 사용되는 MAE(Mean Absolute Error, 평균 절대 오차)와 RMSE(Root Mean Squared Error, 평균 제곱근 오차)를 산출하여 비교하였다[26]. MAE는 실제값과 예측값의 차이를 절대값으로 계산하여 평균을 내고, RMSE는 잔차를 하나의 척도로 표시한다. 따라서 MAE와 RMSE가 0에 가까울수록 모델의 예측력이 높아진다. 수집된 데이터는 z-score 정규화를 통해 데이터를 정규화하는 전처리 과정을 거쳤다. z-score 정규화는 표준편차와 평균을 이용하여 데이터의 범위를 조정하고 단위와 수량에 따른 차이를 보정하므로 건설사고 사례와 지표의 다양성을 고려하여 채택하였다[27]. 정규화된 데이터는 학습 데이터(70%)와 테스트 데이터(30%)로 랜덤하게 분리하였다. 이 중 학습 데이터의 30%가 검증 데이터로 사용되었다.

DNN 모델은 각 신경망 노드의 가중치를 변경하는 역전파 알고리즘을 통해 최적화 모델을 구현한다. 따라서 최적화 모델을 위해서는 시행착오 방법을 통해 최적의 네트워크 구조 시나리오와 하이퍼파라미터를 찾는 것이 필수적이다[28]. 하이퍼매개변수는 학습 과정을 제어하는 매개변수로 드롭아웃, 배치 크기, 에포크, 옵티마이저 및 활성화 함수 등이 있다[29]. 예를 들어, 드롭아웃은 딥러닝 모델의 성능 저하를 초래하는 과적합 문제를 해결하기 위한 정규화 페널티이다. 배치 크기는 DNN 모델의 데이터 학습 단위를 설정하고 모델의 효율적인 학습에 영향을 미친다. Epoch는 모델의 데이터 학습 과정에서 학습 횟수를 지정하고, Optimizer는 모델의 데이터 학습 속도를 제어하여 모델의 안정성을 제어한다. 활성화 함수는 최소 비용 함수를 규정하는 방법을 지정한다[30]. 본 연구에서 사용된 데이터의 한계와 유사한 이전 연구의 네트워크 구조 및 하이퍼파라미터를 나타내기 위해 레이어 수는 3으로 설정하고 드롭아웃은 (0 또는 0.2)로 설정하였다. 배치 크기는 5로 설정되었고, Epoch는 1,000으로 설정하였다[27-30]. Optimizer는 확률론적 목적함수의 모멘트 이론을 이용한 Adaptive Moment Estimation(Adam)이라는 최적화 알고리즘을 선택하였다. Adam Method는 계산의 편리성과 응용의 다양성으로 인해 많은 분야에서 사용되고 있다[30]. 활성화 함수로는 Sigmoid 함수를 보완하기 위해 고안된 ReLu(Rectified Linear Unit) 함수를 사용하였다[31].

Table 3은 네트워크 구조와 하이퍼파라미터에 따라 학습한 결과를 나타낸다. 시나리오 중 MAE와 RMSE 값이 최소인 시나리오를 최종 모델로 지정하였다. 일반적으로 드롭아웃이 0일 때보다 드롭아웃이 0.2일 때 시나리오의 손실함수가 더 큰 것으로 나타났다. 또한 노드 수가 증가할수록 MAE와 RMSE 값이 점차 증가하다가 노드 수가 500-500-500일 때 MAE와 RMSE 값이 가장 작은 값을 나타냈다. Table 4는 소규모 건설현장 모델의 최적화된 네트워크 구조와 하이퍼파라미터를 보여준다.

Table 3. Outcomes of the learning process

Network Structures	Dropout(0)		Dropout(0.2)	
	RMSE	MAE	RMSE	MAE
50-50-50	0.393	0.323	0.415	0.350
100-100-100	0.384	0.315	0.402	0.335
200-200-200	0.372	0.295	0.395	0.330
300-300-300	0.369	0.293	0.391	0.323
400-400-400	0.367	0.292	0.383	0.316
500-500-500	0.365	0.290	0.385	0.315
600-600-600	0.371	0.295	0.393	0.321
700-700-700	0.370	0.290	0.387	0.316
800-800-800	0.371	0.297	0.387	0.316
900-900-900	0.370	0.296	0.387	0.316

Table 4. Detailed description of optimization model

Construction	Descriptions	
Network structures	Node	500-500-500
	Layer	3
Hyper Parameter	Optimizer	Adaptive Moment Estimation
	Activation Function	Rectified Linear Unit function
	Dropout	0
	Batch Size	5
	Epoch	1000

6. 토론

본 연구에서는 DNN 알고리즘을 적용하여 소규모 건설현장의 안전사고 예측 모델을 개발하기 위한 프레임워크를 제안하였다. 자료수집을 위해 한국산업안전보건공단 건설현장에서 발생한 사고사례를 수집하였다. 입력변수와 출력변수의 경우 시행착오 방법을 통해 네트워크 시나리오와 하이퍼파라미터를 학습하여 최종 최적 모델이 확정하였다. 따라서 본 연구에서 제시한 프레임워크에 따라 다양한 건설 관련 주제들이 건설 현장 사고 예측 모델을 구축함으로써 정확하고 객관적인 사고 위험도를 도출할 수 있다. 예를 들어 소규모 건설현장 시공사는 전문가 컨설팅이나 별도의 위험성 평가 없이도 DNN 알고리즘을 적용한 사고 예측 모델을 개발하고 사고 위험도를 정량화하여 안전관리에 적용할 수 있다. 특히, 발주자는 사고 위험도의 사전 예측을 통해 자산 상태 및 위험 성향을 고려하여 위험 확률 수준을 설정할 수 있으며, 이를 기반으로 예산 책정의 지침으로 활용할 수 있다. 또한, 사고위험 저감을 위한 적절한 투자를 통해 사고를 줄이고 예방할 수 있을 것이다. 또한 시공사

는 건설현장에 대한 적정 보험 가입 및 가입한 보험료의 적정여부를 판단하는 기준으로도 활용될 수 있다. 추가적인 위험에 대해서는 특약이나 보장범위 확대 등을 통해 재정적 위험 전가전략을 선제적으로 수립하는 것이 가능할 것이다. 이를 통해 궁극적으로 건설현장의 적극적인 사고관리가 가능해지며, 이를 통해 건설현장의 높은 재해율 감소와 사고로 인한 사회적 비용 절감에 기여하게 될 것이다.

그러나 본 연구에서는 산업안전보건공단에서 수집한 사고사례를 바탕으로 모델을 구축하였다. 따라서 보험회사나 공공기관을 통해 건설현장 사고의 금전적 손실 데이터를 추가하거나, 다른 나라의 건설현장 사고 사례 등의 추가자료를 확보하여 비교 검증하는 추가적인 연구가 필요하다. 또한, 모델의 점진적인 정교화를 위해서는 추가적인 영향지표 발굴과 추가 데이터 확보가 필수적이다. 또한, 본 연구에서는 DNN 알고리즘만을 차용하였지만, 향후 연구에서는 다른 딥러닝 알고리즘을 도입하여 비교 또는 교차검증 연구를 통해 모델의 신뢰도를 높이는 것이 중요하다. 또한 DNN 알고리즘의 특성상 각 노드 간의 상호 관계 및 가중치를 확인할 수 없다. 이는 DNN 알고리즘의 블랙박스를 통해 예측 결과를 일반적으로 제시함으로써 사용자가 예측 결과의 과정과 근거에 접근할 수 없다는 단점을 가지고 있기 때문이다. 따라서 향후 모델의 신뢰성과 수용성을 높이고 사용자 불안을 해소하기 위해서는 XAI(eXplainable AI) 도입을 통해 변수와 가중치를 정의하는 것이 필요하다[32].

7. 결론

건설산업은 다른 산업에 비해 안전 사고 발생 위험이 높다. 또한, 최근 건설 프로젝트의 복잡화와 규모의 증가, 도시 건설의 급증으로 인해 건설현장의 재해율이 증가하고 있다. 사고율 감소 및 예방을 위해서는 선진적이고 정확한 사고위험 정량화 모델이 절실히 필요하다. 그러나 기존 사고위험도 정량화 모델 및 연구에서는 건설현장의 규모에 따라 특성에 상당한 차이가 있음에도 불구하고 이를 고려하지 못하고 있다. 따라서 본 연구에서는 소규모 건설현장을 위한 딥러닝 알고리즘 기반의 사고 예측 모델 개발을 위한 프레임워크를 제안하였다.

예측 모델 개발을 위해 건설현장의 사고 사례 데이터를 기반으로 선행 연구에서 사용된 사고 관련 지표를 수집하고 DNN 알고리즘 모델을 개발하였다. 본 연구의 모델을 통해 건설현장에서 발생할 수 있는 사고를 예측함으로써 수많은 건설 관련 주체들이 쉽고 빠르게 사고 관련 위험을 사전에 예측할 수 있게 될 것이다. 최적의 DNN 모델을 설정하기 위해, 기존 연구에서 활용한 최적의 하이퍼파라미터 구성요소와 네트워크 구조 시나리오를 참조하여 시행착오를 거쳐 최종 모델을 확정하였다.

본 연구에서 개발된 DNN 모델은 건설현장의 사고위험도 예측에 기여할 수 있을 것으로 판단된다. 또한, 본 연구에서 제시된 연구 결과와 프레임워크는 사고 손실 감소 및 안전 관리를 위한 참고 자료로 사용될 수 있으며, 궁극적으로 건설산업의 재해율 감소에 기여할 것으로 예상된다. 또한 본 연구의 연구 결과와 프레임워크는 기타 고위험 산업의 사고 예측 및 기타 위험 연구에 실질적인 도움이 될 수 있다. 또한, 본 연구의 딥러닝 모델은 건설현장의 사고예측 기법을 고도화하고, 사고예측의 정확도를 향상시킬 것으로 예상된다. 또한, 모델의 유효성에 대한 추가적인 검증과 지속적인 데이터 수집을 통해 모델이 더욱 발전할 가능성이 있다.

요약

건설산업의 재해율은 다른 산업에 비해 매우 높다. 그 이유로 다른 규모에 비해 상대적으로 더 사고에 취약한 소규모 건설현장의 높은 재해발생율을 꼽고 있다. 최근 난이도 높은 도심 건설공사의 증가, 악천후의 증가 등으로 앞으로 소규모 건설현장의 사고 발생 위험은 더 커질 것으로 예상된다. 따라서 소규모 건설현장의 사고를 사전에 예측하고 이를 통한 사고 예방 및 저감은 건설산업의 재해율을 낮추기 위해 반드시 필요하다. 따라서, 본 연구에서는 소규모 건설현장 사고를 예측하기 위한 Deep Neural Network Algorithm 기반의 사고 예측 모델 개발 프레임워크를 제안하였다. 본 연구의 프레임워크와 결과를 활

용하여 소규모 건설현장 안전관리의 가이드 라인으로 활용이 가능하며, 궁극적으로 소규모 건설현장에서의 사고 위험을 줄임으로써 지속가능한 건설사업관리에 기여할 수 있을 것이다.

키워드 : 소규모 건설현장, 안전관리, 사고, 심층신경망 알고리즘

Funding

This research was funded by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(2022R1F1A106314112).

ORCID

Ji-Myong Kim,  <https://orcid.org/0000-0002-1907-4291>

References

1. Gledson BJ, Greenwood D. The adoption of 4d bim in the UK construction industry: an innovation diffusion approach. *Engineering, Construction and Architectural Management*. 2017 Nov;24(6):950-67.
2. Kim JM, Kim T, Son K, Bae J, Son S. A quantitative risk assessment development using risk indicators for predicting economic damages in construction sites of South Korea. *Journal of Asian Architecture and Building Engineering*. 2019 Oct;18(5):472-8. <https://doi.org/10.1080/13467581.2019.1681274>
3. Kim JM, Kim T, Ahn S. Loss assessment for sustainable industrial infrastructure: Focusing on bridge construction and financial losses. *Sustainability*. 2020 Jul;12(13):5316. <https://doi.org/10.3390/su12135316>
4. Kim JM, Kim T, Bae J, Son K, Ahn S. Analysis of plant construction accidents and loss estimation using insurance loss records. *Journal of Asian Architecture and Building Engineering*. 2019 Nov;18(6):507-16. <https://doi.org/10.1080/13467581.2019.1687089>
5. Kim JM, Ha KC, Ahn S, Son S, Son K. Quantifying the third-party loss in building construction sites utilizing claims payouts: A case study in South Korea. *Sustainability*. 2020 Dec;12(23):1015. <https://doi.org/10.3390/su122310153>
6. Yum SG, Ahn S, Bae J, Kim JM. Assessing the risk of natural disaster-induced losses to tunnel-construction projects using empirical financial-loss data from South Korea. *Sustainability*. 2020 Sep;12(19):8026. <https://doi.org/10.3390/su12198026>
7. Jang YR, Go SS. A study on the priority safety management items in the medium and small sized construction sites. *Korean Journal of Construction Engineering and Management*. 2020 Jul;21(4):38-49. <https://doi.org/10.6106/KJCEM.2020.21.4.038>
8. Bae KS, Yoon JD, Ahn HS, Shim KB. Industrial accident status analysis and policy direction: Focusing on small and medium-sized construction sites. Sejong (Korea): Korea Labor Institute; 2013. 268 p.
9. Won JH, Yoon YH, Oh TG, Park HG, Jeong SH. Measures for assigning responsibility to the client to prevent accidents at small-scale construction sites in the construction industry. Ulsan (Korea): Korea Occupational Safety and Health Agency; 2019. 184 p.
10. Jeong M. Kingpin for the prevention of safety accidents at construction sites and the act on punishment of serious accidents. *Construction Engineering and Management*. 2020 Jan;12(8):3435-45.
11. Ahn S, Kim T, Kim JM. Sustainable risk assessment through the analysis of financial losses from third-party damage in bridge construction. *Sustainability*. 2020 Apr;12(8):3435. <https://doi.org/10.3390/su12083435>
12. Laryea S. Risk pricing practices in finance, insurance and construction. *Proceedings of the Construction and Building Research*

- Conference of the Royal Institution of Chartered Surveyors; 2008 Sep 4-5; London, United Kingdom. Reading (United Kingdom): Reading; of University; 2008. 16 p.
13. Baker S, Ponniah D, Smith S. Techniques for the analysis of risks in major projects. *Journal of the operational research society*. 1998 Jun;49(6):567-72. <https://doi.org/10.2307/3010665>
 14. Dikmen I, Birgonul MT, Arikan AE. A critical review of risk management support tools. *Proceedings of the 20th Annual Conference of Association of Researchers in Construction Management*. 2004 Sep;2:1145-54.
 15. Wood G, Ellis RCT. Risk management practices of leading UK cost consultants. *Engineering, Construction and Architectural Management*. 2003 Aug;10(4):254-62. <https://doi.org/10.1108/09699980310489960>
 16. Molenaar KR. Programmatic cost risk analysis for highway megaprojects. *Journal of construction engineering and management*. 2005 Mar;131(3):343-53. [https://doi.org/10.1061/\(ASCE\)0733-9364\(2005\)131:3\(343\)](https://doi.org/10.1061/(ASCE)0733-9364(2005)131:3(343))
 17. Cagno E, Caron F, Mancini M. A multi-dimensional analysis of major risks in complex projects. *Risk Management*. 2007 Feb;9(1):1-18.
 18. Zou PX, Zhang G, Wang J. Understanding the key risks in construction projects in China. *International Journal of Projects Management*. 2007 Aug;25(6):601-14. <https://doi.org/10.1016/j.ijproman.2007.03.001>
 19. Baloi D, Price AD. Modelling global risk factors affecting construction cost performance. *International Journal of Projects Management*. 2003 May;21(4):261-9. [https://doi.org/10.1016/S0263-7863\(02\)00017-0](https://doi.org/10.1016/S0263-7863(02)00017-0)
 20. Allison WR, Hon KHC, Xia B. Construction accidents in australia : Evaluating the true costs. *Safety Science*. 2019 Dec;120:886-96. <https://doi.org/10.1016/j.ssci.2019.07.037>
 21. Weili F, Lieyun D, Hanbin L, Peter EL. Falls from heights: A computer vision-based approach for safety harness detection. *Automation in Construction*. 2018 Jul;91:53-61. <https://doi.org/10.1016/j.autcon.2018.02.018>
 22. Kim JM, Son K, Yum SG, Ahn S. Analyzing the risk of safety accidents: The relative risks of migrant workers in construction industry. *Sustainability*. 2020 Jul;12(13):5430. <https://doi.org/10.3390/su12135430>
 23. Ahmed S. Causes and effects of accident at construction site: A study for the construction industry in Bangladesh. *International journal of sustainable construction engineering and technology*. 2019 Dec;10(2):18-40.
 24. Nevada Department of Transport. Risk Management and Risk-Based Cost Estimation Guidelines. NV: Nevada Department of Transport; 2012. 10 p.
 25. Zhong G, Wang LN, Ling X, Dong J. An overview on data representation learning: From traditional feature learning to recent deep learning. *The Journal of Finance and Data Science*. 2016 Dec;2(4):265-78. <https://doi.org/10.1016/j.jfds.2017.05.001>
 26. Gu J, Wang Z, Kuen J. Recent advances in convolutional neural networks. *Pattern recognition*. 2018 May;77:354-77. <https://doi.org/10.1016/j.patcog.2017.10.013>
 27. Na H, Park BH. Developing accident models of rotary by accident occurrence location. *International Journal of Highway Engineering*. 2012 Aug;14(4):83-91.
 28. Bae SW, Yoo JS. Apartment price estimation using machine learning: Gangnam-gu, Seoul as an example. *Real Estate Stud*. 2018 Jun;24(1):69-85.
 29. Kim J, Yum S, Son S, Son K, Bae J. Modeling deep neural networks to learn maintenance and repair costs of educational facilities. *Buildings*. 2021 Apr;11(4):165. <https://doi.org/10.3390/buildings11040165>
 30. Kim JM, Bae J, Son S, Son K, Yum SG. Development of model to predict natural disaster-induced financial losses for construction projects using deep learning techniques. *Sustainability*. 2021 May;13(9):5304. <https://doi.org/10.3390/su13095304>
 31. Ryu JD, Park SM, Park SH, Kwon CW, Yoon IS. A study on the development of a model for predicting the number of highway traffic accidents using deep learning. *Journal of Korean Society*. 2018 Jan;17(1):14-25.
 32. Dikshit A, Pradhan B. Interpretable and explainable AI (XAI) model for spatial drought prediction. *Science of the Total Environment*. 2021 Dec;801:149797. <https://doi.org/10.1016/j.scitotenv.2021.149797>