

Research Paper

## 자연재해로 인한 건물의 피해 평가를 위한 딥러닝 기초 연구

# A Foundational Study on Deep Learning for Assessing Building Damage Due to Natural Disasters

김지명<sup>1</sup> · 윤경철<sup>2\*</sup>

Kim, Ji-Myong<sup>1</sup> · Yun, Gyeong-Cheol<sup>2\*</sup>

<sup>1</sup>Associate Professor, Department of Architectural Engineering, Mokpo National University, Muan-gun, Jeonnam, 58554, Korea

<sup>2</sup>Associate Professor, Department of Railway Management, Songwon University, Gwangju, 61756, Korea

\*Corresponding author

Yun, Gyeong-Cheol

Tel : 82-62-360-5833

E-mail :

kotsa1988@naver.com

Received : April 17, 2024

Revised : May 15, 2024

Accepted : May 21, 2024

### ABSTRACT

The escalating frequency and intensity of natural disasters and extreme weather events due to climate change have caused increasingly severe damage to societal infrastructure and buildings. Government agencies and private companies are actively working to evaluate these damages, but existing technologies and methodologies often fall short of meeting the practical demands for accurate assessment and prediction. This study proposes a novel approach to assess building damage resulting from natural disasters, focusing on typhoons—one of the most devastating natural hazards experienced in the country. The methodology leverages deep learning algorithms to evaluate typhoon-related damage, providing a comprehensive framework for assessment. The framework and outcomes of this research can provide foundational data for the evaluation of natural disaster-induced damage over the entire life cycle of buildings and can be applied in various other industries and research areas for assessing risk of damage.

**Keywords :** natural disaster, typhoon, building damage, risk assessment

## 1. 서론

최근에 기후 변화에 의한 기상 이상이 과거와 비교해 패턴 변화와 강도, 빈도의 급속한 증가를 보이며 인명과 건축물, 시설에 대한 피해 가능성을 높이고 있다[1,2]. 2014년 발표된 기후 변화에 관한 정부 간 패널의 제5차 평가 보고서는 지구 평균 기온의 상승, 강한 강수량 증가, 해수 산성화, 해수면 상승 등 부정적 영향을 경고하며 이런 상황은 앞으로 더욱 심화될 것으로 예상된다[3]. 한국에서 발생한 태풍을 분석한 결과, 태풍의 강도와 피해 위험이 증가하고 있음을 보여주며 이러한 현상은 전 세계적으로도 비슷한 양상을 보이고 있다[4]. 예를 들어, 2013년 아시아에서 발생한 태풍 하이옌은 5등급으로 분류되어 슈퍼 태풍으로 불리며, 마이크로네시아, 필리핀, 베트남, 중국 등을 잇달아 강타하여 약 3000억 달러의 피해를 입혔다. 이 태풍은 상륙 시 강한 바람을 동반한 태풍으로 기록되었으며, 이로 인해 막대한 인명 및 재산 피해를 낳았다. 1999년 유럽에서는 3개의 연속된 유럽 폭풍이 서유럽 국가들을 차례로 강타해 독일, 스위스, 프랑스에서 약 130억 유로의 피해가 발생했다 [5]. 2005년에는 5등급 허리케인 카트리나가 미국 남동부를 강타해 약 2000억 달러의 피해가 발생했으며, 이는 미국에서 발생한 자연재해 중 가장 큰 규모로 기록되었다[6]. 2017년에는 연속적으로 발생한 3개의 허리케인이 약 3000억 달러의 큰 피해가 발생하기도 하였다.



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.

이와 같이, 전 세계적으로 자연재해는 상당한 인명 및 건물의 피해를 초래하고 있으며, 재산 가치 증가와 도시 규모의 증가로 인해서 더욱 그 피해는 커지고 있다. 이러한 피해를 줄이기 위해 정부와 민간 부문은 자연재해로 인한 피해의 위험을 감소시키려는 노력을 하고 있으며, 효과적인 예방 및 복구 전략을 수립하기 위해 노력하고 있다. 이에 따라, 제한된 시간과 예산을 효율적으로 활용하여 자연재해로 인한 피해를 관리하기 위한 정교하고 과학적인 자연재해의 평가가 반드시 필요하다.

## 2. Literature reviews

자연재해가 야기하는 피해를 정밀하게 평가하려는 요구가 증가함에 따라, 민간 부문에서는 다양한 재난 모델 업체들이 각자의 자연재해별 모델을 개발하여 제공하고 있다[7,8]. 이 민간 모델들은 전 세계 보험사와 재보험사에서 널리 사용되며, 위험 관리, 보험 인수, 자연재해로 인한 손실 위험 평가 등의 중요한 결정을 내리는 데 중요한 역할을 한다. 그럼에도 불구하고, 이 모델들은 주로 주요 국가들을 대상으로 서비스를 제공하며, 다른 국가들에 대해서는 평가 서비스를 제공하지 못하는 한계가 있다. 또한, 정부 및 국제적 차원의 공공기관에서도 이를 평가하기 위한 재난 모델 개발이 이루어졌다. 이 재난 모델은 각 국가나 지역에서 발생 가능한 자연재해의 직접적이거나 간접적인 손실을 시뮬레이션하여 평가하는 데 사용된다. 이 모델들은 자연재해의 위험을 보다 정확하게 예측하고 대처 및 완화 전략을 수립하는 데 필수적인 도구로 여겨진다. 이에 따라 지속적으로 모델을 개발하고 개선하는 작업이 진행되고 있다[9]. 하지만 이 모델들은 특정 국가 및 지역의 건물 취약성, 지형, 재해 유형을 기반으로 구축되어 다른 지역에 적용하기에는 어려움이 있다. 게다가 이 모델들의 사용료가 고가여서 중소기업이 채택하기 어려우며, 자연재해에 대한 손실 평가가 모델 내부의 복잡한 알고리즘에 의존하기 때문에 사용자가 그 타당성을 판단하기 어렵다. 또한, 이 모델들은 시장에서 참조 모델로 활용되기도 하지만, 각 기업의 특성, 위험 선호도, 자본금 등에 따라 달라지므로 기업별로 맞춤형 모델을 개발할 필요가 있다. 그러므로 국가나 기업이 자신들의 자연재해 위험성을 정확히 평가하기 위해서는 기존의 모델 대신에 각각의 특성과 위험 노출도를 고려한 맞춤형 모델을 개발하는 것이 중요하다.

자연재해의 빈도와 심각성이 증가함에 따라, 이로 인한 경제적 손실도 더욱 커질 것으로 전망되고 있다. 아울러, 자연재해의 복잡한 피해 발생 구조와 다양한 사용자의 상황을 고려 시, 보다 정교하고 발전된 자연재해 피해 평가 모델이 필요하다는 인식이 커지고 있다. 이러한 맥락에서, 딥러닝 알고리즘을 활용한 자연재해 손실 평가 모델이 유용한 해결책이 될 수 있다. 과거에 수행된 많은 자연재해 위험도 평가 연구들은 다양한 딥러닝 알고리즘을 사용한 모델의 개선과 개발에 초점을 맞춰왔다[10-15]. 예를 들어, 침수지역의 다양한 특성 데이터를 기반으로 CNN을 사용하여 홍수 민감도 지도를 만드는 연구가 있었다[14]. Yi and Zhang[11]은 위성 영상 분석을 통해 CNN을 사용하여 지진으로 인한 산사태 위험을 예측하는 연구를 수행했다. 아울러, 토네이도 발생 시, 나무의 위성영상 데이터를 CNN으로 분석하여 풍속을 추정하고 건물 피해를 분류하는 연구도 진행되었다[12]. 또한, 건설 프로젝트에서 자연재해 손실 데이터를 딥러닝으로 예측할 때, 기존 통계 모델보다 예측 오차가 적다는 연구 결과가 있다[16]. 게다가, Moishin et al.[13]은 하이브리드 딥러닝 알고리즘을 사용하여 일별 강수량 데이터를 분석하고 홍수 발생을 예측했다. 이 하이브리드 모델은 장단기 기억 네트워크와 CNN을 결합하여 고급 홍수 위험 관리 기능을 제공하기도 한다.

이처럼 다양한 딥러닝 기술을 활용한 자연재해 피해 평가 모델 개발을 위한 많은 연구가 이루어지고 있다. 이 연구들은 기존 모델의 한계를 극복하고 혁신적인 기술을 통해 보다 정교하고 신뢰할 수 있는 의사결정 지원 도구를 제공하며 자연재해 피해 완화 전략 수립에 기여하고 있다. 따라서 이 연구에서는 딥러닝 알고리즘을 활용하여 자연재해 중 가장 큰 피해원인인 태풍의 피해 사례를 통해 자연재해로 기인한 건물 피해 평가 모델을 개발하기 위한 새로운 프레임워크를 제안하고자 한다.

### 3. Research methodology

이 연구의 핵심 목표는 태풍으로 인해 발생한 건물 손상 사례를 기반으로 딥러닝 알고리즘을 이용한 건물 손실 예측 프레임워크를 개발하고 제안하는 것이다. 구체적인 목표로는, 첫째, 태풍에 의해 발생한 건축물 손상 사례들을 수집하는 것이다. 둘째, 수집된 데이터를 딥러닝 알고리즘 학습에 적합하게 전처리하는 것이다. 셋째, 이 전처리된 데이터를 사용하여 딥러닝 알고리즘으로 학습을 진행하는 것이다. 마지막으로, 개발된 예측 모델의 구조와 하이퍼파라미터를 확립하는 것이다. 이 모든 과정은 Google Colaboratory를 사용하여 딥러닝 모델의 코드를 실행하며 진행하였다.

### 4. 데이터 수집

본 연구에서는 태풍에 의한 건축물 피해 예측 모델 개발을 위해 국내 한 원수보험회사로부터 태풍 매미와 관련된 피해 데이터를 수집하였다. 이 데이터는 보험 조건을 제외한 태풍으로 인한 건축물 피해액에만 초점을 맞췄으며, 연구의 범위 역시 대한민국으로 한정하였다. 태풍 매미는 한국에 큰 피해를 입힌 대표적인 태풍으로, 2003년 9월 12일 남해안에 상륙한 후 9월 13일 동해안을 통해 이탈하였다. 이 기간 동안 남해안의 주요 도시들이 심각한 피해를 입었으며, 결과적으로 6만1천여 명의 피해자와 135명의 인명 피해, 약 42억 달러의 재산 피해가 발생하였다. 태풍 매미는 괌 인근에서 시작하여 오키나와를 거쳐 한반도에 상륙한 강력한 태풍으로, 최대풍속 54m/s의 기록적인 강풍을 동반했으며, 이와 함께 폭우와 폭풍 해일이 피해를 더욱 심화시켰다.

이 연구에서 살펴본 결과 변수는 태풍 매미로 인해 발생한 한국의 한 보험사에서 발생한 건물별 피해액 자료이다. 수집된 피해액 자료는 건물의 금액으로 나누어 피해율로 나타내고, 정규분포를 위해 로그 변환을 하였다. 아울러 입력변수는 건물의 사용유형, 건물의 금액, 최대풍속을 사용하였다. 본 연구에서 사용된 건물의 사용유형, 건물의 금액, 최대풍속은 자연재해 특히 태풍의 피해를 평가하는 주요 지표로 사용되며, 통계적으로도 피해액과 강한 상관관계를 가지고 있다[17]. 예를 들어, 건물의 사용유형은 태풍에 의한 취약성을 나타내는 주요 지표로 피해액을 예측하고 정량화하는데 일반적으로 사용되어, 사용 형태에 따라, 상업용, 주거용, 산업용으로 나누어 입력되었다[18,19]. 또한, 건물의 금액은 태풍 피해와 음의 상관관계를 가지는 통계적으로 유의한 관계를 가져, 건물의 태풍 취약성 평가 혹은 정량화에 주로 포함되는 지표이다[20]. 아울러, 최대풍속은 태풍의 주요 위험인 바람에 의한 피해를 정량화하기 위한 주요 지표로 차용되며, 본 연구에서는 기상청의 10분 평균 최대 풍속(m/s)을 활용하여, 각 피해발생 건물별 풍속을 데이터를 수집하였다[21].

출력변수와 입력변수에 대한 설명은 Table 1과 같다. 태풍으로 인해 발생한 건물 피해의 총 개수는 817건이 있으며, 수집된 변수들의 기술 통계는 Table 2와 같다.

**Table 1.** Variable descriptions

	Variable	Description
Output	Building damage ratio	The damage ratio represents the proportion of the building's value lost due to Typhoon Maemi, calculated as the value of the damage divided by the entire property value
	Building usage	Refers to the type of buildings that incurred damages from the typhoon, including 1) commercial buildings, 2) residential buildings, and 3) industrial buildings
Input	Overall building value	The cumulative worth of all buildings that incurred damages due to the typhoon, expressed in millions of South Korean KRW
	Peak Wind Speed	The maximum wind speed recorded, calculated as a 10-minute average, and expressed in meters per second

**Table 2.** Descriptive statistics of variables

Variable	Min.	Max.	Average	Std.D
Building damage ratio	817	-8.57	-0.69	-5.57
Building usage	817	1	3	1.42
Overall building value	817	4.52	12.21	8.93
Peak Wind Speed	817	31.4	38.9	37.71

## 5. 딥러닝 알고리즘 모델 적용

자연재해 피해의 복잡성과 불확실성, 사용자별로 다른 상황과 특성을 반영하기 위해선 더욱 정밀하고 효과적인 자연재해 예측 모델이 필요하다. 아울러, 건물과 시설의 관리를 위한 사물인터넷, 정보통신, 센서 기술의 활용이 늘어남에 따라, 빅데이터의 양도 점점 복잡해지고 다양해질 전망이다. 이런 빅데이터를 분석하기 위해선 딥러닝 기술의 적용이 필수적이다. 딥러닝 알고리즘은 머신러닝의 한 분류로, 입력 데이터를 분류하고 예측하는 등 여러 분야에 활용되고 있으며, 사용 범위는 점차 확대되고 있다. 딥러닝 알고리즘은 구성과 처리 방식에 따라 다양하게 나뉘며, Deep Neural Network(DNN) 같은 경우, 은닉층의 수와 구성 요소의 조합에 따라 복잡한 비선형 상호작용을 모델링할 수 있어 다양한 분류 및 예측 작업에 널리 쓰인다[22]. 특히 자연재해와 같이 불확실하고 복잡한 비선형 데이터의 분석 및 예측에서 뛰어난 성능을 보이고 있다[16]. 본 연구에서는 태풍으로 발생하는 빅데이터를 분석하고 예측하기 위한 DNN 기반 모델 개발 프레임워크를 제시하고자 한다. 또한, DNN 기반 예측 모델로 자연재해 예측의 정확도를 높이고, 자연재해로 인한 경제적 손실을 줄이며, 재해 위험 감소 및 예방에 기여하는 것을 목적으로 한다. 데이터 전처리를 위해 z-score 정규화 방법을 사용했다. 개발된 DNN 모델은 RMSE와 MAE 지표로 평가되었으며, 이는 모델의 정확도를 나타내는 중요한 지표이다[23]. 최적의 DNN 모델을 만들기 위해서는 하이퍼파라미터와 네트워크 구조를 결정하는 시행착오 과정이 중요하다[24]. 역전파를 이용한 DNN은 입력과 출력 처리에 적합한 노드의 가중치를 조정하므로, 이상적인 구성을 찾기 위해 시행착오가 필요하다. DNN 모델은 3층 구조를 기본으로 하며, 드롭아웃 비율을 0 또는 0.2로 설정했다. 에포크는 1,000회, 배치 크기는 5로 설정했으며, Adam 최적화 알고리즘을 사용했다. Adam은 확률적 목적함수를 기반으로 한 최적화 방법이다[25]. 활성화 함수로는 ReLu를 채택했다. ReLu는 0 이상일 때 출력이 변하는 특성을 가지고 있다[26]. Table 3은 네트워크 구조와 드롭아웃에 따른 학습 결과를 보여주고 있다. 학습 결과, 드롭아웃 0일 때가 0.2보다 손실이 작았으며, 은닉층 노드 수가 많을수록 MAE와 RMSE가 줄

**Table 3.** Learning outcomes for each scenario

Network Structure	Dropout(0)		Dropout(0.2)	
	MAE	RMSE	MAE	RMSE
25-25-25	0.435	0.524	0.562	0.667
50-50-50	0.293	0.452	0.434	0.590
75-75-75	0.274	0.453	0.420	0.593
100-100-100	0.273	0.394	0.417	0.527
200-200-200	0.260	0.356	0.388	0.489
300-300-300	0.228	0.322	0.361	0.446
400-400-400	0.238	0.323	0.381	0.450
500-500-500	0.258	0.328	0.395	0.459
600-600-600	0.264	0.357	0.417	0.500
700-700-700	0.275	0.363	0.418	0.500

어 들었다. 따라서 드롭아웃 0과 300-300-300 노드 구성이 최적으로 결정됐다. 최종 네트워크 구조와 하이퍼파라미터는 Table 4와 같다.

**Table 4.** Configuration of the final model

Conformation		Descriptions
Hyper Parameter	Dropout	0
	Optimizer	Adaptive Moment Estimation Method
	Epoch	1,000
	Batch Size	5
	Activation Function	Rectified Linear Unit function
Network structure	Number of node	300-300-300
	Number of layer	3

## 6. 토론

본 연구는 자연재해로 인한 건축물 피해 예측을 위해 딥러닝 알고리즘을 이용한 예측 모델 개발의 프레임워크를 제시하였다. 따라서, 한국의 대표적인 자연재해 사례인 태풍 매미로 인한 건물 피해 사례를 한국의 한 보험회사로부터 수집하고, 관련 변수들을 수집하였다. 최적의 딥러닝 알고리즘 모델을 위해 DNN 알고리즘을 기반으로 다양한 네트워크 구조와 하이퍼 파라미터를 실험하여, 입력과 출력 변수의 학습 및 최소화 비용 함수와의 조합을 실험하고 최적의 조건을 제시하였다.

따라서, 본 연구의 DNN 모델을 활용함으로써, 공공 및 민간 분야의 위험 관리자 및 시설 관리자가 태풍으로 인한 피해를 예측하고, 자체적인 모델을 개발할 수 있을 것이다. DNN 모델을 통한 정확하고 신뢰할 수 있는 피해 예측을 통해 예상되는 피해를 줄이고 방지하기 위한 투자 전략을 세우는 데 도움이 될 것이다. 더불어, 정교한 태풍 피해 예측을 반영한 비상 준비금 설정에도 유용하게 쓰일 수 있다. 또한, 개별적으로 자신의 위험 선호도와 자산 규모를 고려하여 재정 안정성을 유지할 수 있는 계획을 수립할 수 있을 것이다. 아울러, 본 모델을 사용하여 손실 위험을 분산시키는 새로운 전략을 마련할 수 있다. 예를 들어, 예상 손실 위험에 따라 현재 가입한 보험의 적정 보험료 수준을 결정하고, 보장 범위를 조정하는 데에도 활용될 수 있다. 보험사는 정밀한 태풍 손실 예측을 통해 보험료 책정의 정확성을 높이고, 누적된 태풍 위험을 효과적으로 관리할 수 있게 될 것이다. 이를 통해 태풍으로 인한 경제적 손실을 줄이고, 피해 예방 및 위험 분산 전략을 개선하는 것이 가능하다. 개발된 모델과 방법론은 다른 산업, 학계에서 손실 분석 및 예측, 그리고 다른 자연재해 예측에 참고 자료로 사용될 수 있을 것이다. 더불어, 본 연구는 시설물과 건물의 관리 고도화에 큰 영향을 줄 수 있다. 최근 사물인터넷, 정보통신, 센서 등의 기술들이 건물 관리에 빠르게 도입되고 있어, 이러한 기술 사용에 따른 빅데이터의 집적을 효과적으로 분석하기 위한 관련 유사 연구에도 적용이 가능할 것이다.

그럼에도 불구하고, 본 연구는 국내 한 보험회사의 태풍 피해 사례 데이터만을 사용했다. 따라서 다른 국가 혹은 타 보험사의 데이터를 포함하여 모델을 업그레이드하고 검증하기 위한 추가 연구가 필요하다. 또한, 예측 오류를 줄이기 위한 새로운 변수 발굴이 필요하다. 자연재해 손실의 특성에 맞는 추가 변수를 찾아 모델의 정확도를 높이고, 더불어 건물 피해뿐만 아니라 인명 피해 예측까지 확장할 필요가 있다.

## 7. 결론

세계 곳곳에서 기후 변화로 인해 자연재해의 빈도와 심도가 빠르게 증가하고 있다. 이와 더불어 전세계적으로 자산이 증가함에 따라 자연재해로 기인한 피해의 피해가 앞으로 더욱 커질 전망이다. 이에 따라, 더욱 세밀하고 정밀한 자연재해 손실



예측 모델에 대한 니즈는 증가하고 있고, 시설물과 건물의 지속 가능한 관리를 위해서는 경제적 피해 예측에 기반한 위험 관리 전략 수립이 중요해 지고 있다. 이러한 배경에서 본 연구의 목적은 대표적인 자연재해 사례인 태풍 매미의 피해 사례를 통해 자연재해로 인해 발생하는 건물의 피해 비용을 정확히 예측하는 딥러닝 알고리즘 기반 모델을 구축하는 프레임워크를 제시하였다.

따라서, 본 연구의 결과와 프레임워크는 태풍으로 인한 건물 피해 예측에 성공적으로 적용될 수 있으며, 이를 통해 건물의 피해 위험을 줄이고 재무 관리를 개선하는 데 기여할 것으로 기대된다. 더 나아가, 본 연구의 결과는 다른 연구 영역, 산업 및 자연재해 연구에도 응용 가능할 것으로 보여, 자연재해로 인한 손실 감소에 큰 도움이 될 것이다. 본 연구에서 사용된 지표는 다른 자연재해 손실 예측에도 활용될 수 있다. 또한, 정부는 이들 지표들을 활용하여 위험 평가 기준을 설정할 수 있고, 민간 부문에서는 기업의 자산 규모나 위험 성향을 고려하여 누적된 위험을 효과적으로 관리할 수 있을 것이다. 결과적으로 본 모델을 통해 향후 자연재해로 기인한 피해 예측에 도움이 될 것으로 전망된다.

## 요약


기후 변화에 따른 자연재해와 이상기상의 빈도 및 심도가 날로 증가하면서, 사회기반시설과 건축물에 미치는 영향도 점차 커지고 있다. 이러한 문제에 대응하기 위해 다양한 정부 기관과 민간 부문에서는 이로 인한 피해를 정확히 평가하려는 노력을 기울이고 있지만, 현실에 부합하는 정밀한 피해 예측과 평가는 여전히 도전적인 과제로 남아 있으며, 현재의 기술 수준으로는 부족함이 많다. 이러한 배경 하에, 본 연구는 우리나라에서 발생하는 주요 자연재해 중 하나인 태풍에 의한 건축물 피해를 분석하여, 해당 피해를 정확히 평가할 수 있는 방법론을 제시하고자 한다. 딥러닝 알고리즘을 활용한 평가 방식과 프레임워크를 도입하여, 태풍으로 인한 건물 피해 평가에 관한 연구를 진행하였다. 본 연구의 결과는 건물의 수명주기 전반에 걸친 자연재해 피해 평가에 필요한 기본 데이터를 제공하고, 다양한 산업 및 연구 영역에서 위험 평가에 활용이 가능하다.


키워드 : 자연재해, 태풍, 건물피해, 위험평가

## Funding

This research was funded by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(2022R1F1A106314113) and supported by research fund from Songwon University2024 (A2024-20).

## ORCID

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

Gyeong-Cheol Yun,  <https://orcid.org/0000-0001-9253-201X>

## References

1. Kim JM, Kim T, Son K, Yum SG, Ahn S. Measuring vulnerability of typhoon in residential facilities: Focusing on typhoon maemi in south korea. Sustainability. 2019 May;11(10):1-11.
2. Kim JM, Son K, Yum SG, Ahn S. Typhoon vulnerability analysis in south korea utilizing damage record of typhoon maemi.

- Advances in Civil Engineering. 2020 Sep;2020(3):1-10. <https://doi.org/10.1155/2020/8885916>
3. IContribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Climate change 2014: impacts, adaptation, and vulnerability. Cambridge (UK): Intergovernmental Panel on Climate Change; 2014. Part A, Global and Sectoral Aspects; 1820 p.
  4. Kim JM, Son S, Lee S, Son K. Cost of climate change: Risk of building loss from typhoon in South Korea. Sustainability. 2020 Aug;12(17):1-11.
  5. Ulbrich U, Fink AH, Klawe M, Pinto JG. Three extreme storms over Europe in December 1999. Weather. 2001 Apr;56(3):70-80. <https://doi.org/10.1002/j.1477-8696.2001.tb06540.x>
  6. Blake ES, Landsea C, Gibney EJ. The deadliest, costliest, and most intense united states tropical cyclones from 1851 to 2010 (and other frequently requested hurricane facts). FL: National Hurricane Center; 2011. 49 p.
  7. Sanders DEA, Brix A, Duffy P, Forster W, Hartington T, Jones G, Levi C, Paddam P, Papachristou D, Perry G, Rix S, Ross F, Smith AJ, Seth A, Westcott D, Wilkinson M. The management of losses arising from extreme events. London (UK): Convention General Insurance Study Group GIRO; 2002. 261 p.
  8. Howard K, Robert M, Christophe VB. Risk analysis for extreme events: Economic incentives for reducing future losses. MD: National Institute of Standards and Technology; 2004. 103 p. Report No.: NIST GCR 04-871
  9. Kim JM, Woods PK, Park YJ, Kim T, Son K. Predicting hurricane wind damage by claim payout based on Hurricane Ike in Texas. Geomatics, Natural Hazards and Risk. 2016;7(5):1513-25. <https://doi.org/10.1080/19475705.2015.1084540>
  10. Al Najar M, Thoumyre G, Bergsma EW, Almar R, Benshila R, Wilson DG. Satellite derived bathymetry using deep learning. Machine Learning. 2021 Jul;112:1107-30.
  11. Yi Y, Zhang W. A new deep-learning-based approach for earthquake-triggered landslide detection from single-temporal rapideye satellite imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2020 Oct;13:6166-76. <https://doi.org/10.1109/JSTARS.2020.3028855>
  12. Shane Crawford P, Hainen AM, Graettinger AJ, van de Lindt JW, Powell L. Discrete-outcome analysis of tornado damage following the 2011 Tuscaloosa, Alabama, tornado. Natural Hazards Review. 2020 Jul;21(4):04020040. [https://doi.org/10.1061/\(ASCE\)NH.1527-6996.0000396](https://doi.org/10.1061/(ASCE)NH.1527-6996.0000396)
  13. Moishin M, Deo RC, Prasad R, Raj N, Abdulla S. Designing deep-based learning flood forecast model with ConvLSTM hybrid algorithm. IEEE Access. 2021 Mar;9:50982-93. <https://doi.org/10.1109/ACCESS.2021.3065939>
  14. Khosravi K, Panahi M, Golkarian A, Keesstra SD, Saco PM, Bui DT, Lee S. Convolutional neural network approach for spatial prediction of flood hazard at national scale of Iran. Journal of Hydrology. 2020 Sep;591:125552. <https://doi.org/10.1016/j.jhydrol.2020.125552>
  15. 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>
  16. Kim JM, Yum SG, Park H, Bae J. A deep learning algorithm-driven approach to predicting repair costs associated with natural disaster indicators: The case of accommodation facilities. Journal of Building Engineering. 2021 Oct;42:103098. <https://doi.org/10.1016/j.job.2021.103098>
  17. Kim JM, Son K, Kim YJ. Assessing regional typhoon risk of disaster management by clustering typhoon paths. Environment, Development and Sustainability. 2019 Oct;21(1):2083-96. <https://doi.org/10.1007/s10668-018-0086-2>
  18. Kim JM, Yum SG, Park H, Bae J. Strategic framework for natural disaster risk mitigation using deep learning and cost-benefit analysis. Natural Hazards and Earth System Sciences. 2022 Jun;22(6):2131-44. <https://doi.org/10.5194/nhess-22-2131-2022>
  19. D'Ayala D, Copping A, Wang H. A conceptual model for multi-hazard assessment of the vulnerability of historic buildings. Structural Analysis of Historical Constructions: Possibilities of Numerical and Experimental Techniques, Proceedings of the Fifth International Conference. New Delhi (India): Macmillan; 2006. p. 121-40.

20. Yum SG, Kim JM, Wei HH. Development of vulnerability curves of buildings to windstorms using insurance data: An empirical study in South Korea. *Journal of Building Engineering*. 2021 Feb;34:101932. <https://doi.org/10.1016/j.jobe.2020.101932>
21. De Silva DG, Kruse JB, Wang Y. Spatial dependencies in wind-related housing damage. *Natural Hazards*. 2008 Mar;47(3):317-30. <https://doi.org/10.1007/s11069-008-9221-y>
22. Betsis S, Kalogirou M, Aretoulis G, Pertziniidou M. Work accidents correlation analysis for construction projects in Northern Greece 2003 – 2007: A retrospective study. *Safety*. 2019 May;5(2):33. <https://doi.org/10.3390/safety5020033>
23. Kim JM, Lim KK, Yum SG, Son S. A deep learning model development to predict safety accidents for sustainable construction: A case study of fall accidents in south korea. *Sustainability*. 2022 Jan;14(3):1583. <https://doi.org/10.3390/su14031583>
24. 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.
25. Ajayi A, Oyedele L, Owolabi H, Akinade O, Bilal M, Davila Delgado JM, Akanbi L. Deep learning models for health and safety risk prediction in power infrastructure projects. *Risk Analysis*. 2020 Oct;40(10):2019-39. <https://doi.org/10.1111/risa.13425>
26. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Liu T, Wang X, Wang G, Cai J, Chen T. Recent advances in convolutional neural networks. *Pattern Recognition*. 2018 May;77:354-77. <https://doi.org/10.1016/j.patcog.2017.10.013>