

Research Paper

## 아파트 수선유지 비용 예측을 위한 딥러닝 프레임워크 제안

# A Deep Learning Framework for Prediction of Apartment Repair and Maintenance Costs

김지명<sup>1</sup> · 손승현<sup>2\*</sup>

Kim, Ji-Myong<sup>1</sup> · Son, Seunghyun<sup>2\*</sup>

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

<sup>2</sup>Researcher, Department of Architectural Engineering, Mokpo National University, Muan-gun, Jeonnam, 58554, Korea

\*Corresponding author

Son, Seunghyun  
Tel : 82-61-450-2457  
E-mail :  
seunghyun@mnu.ac.kr

Received : April 17, 2024

Revised : April 29, 2024

Accepted : May 12, 2024

### ABSTRACT

The sustained upkeep of apartment buildings necessitates ongoing maintenance and timely repairs, particularly given their complex nature due to extensive areas, common facilities, and multiple residential and service structures. Additionally, the need for cost-effective maintenance is paramount for ensuring safety, preserving value, and maintaining economic efficiency. However, the multitude of external variables influencing apartment complex maintenance, coupled with the challenges in data collection, have resulted in limited research in this domain. To address this gap, the current study aims to develop a framework for predicting maintenance costs utilizing deep learning techniques, grounded in real-world apartment complex maintenance cost data. This study intends to provide a practical and valuable contribution to the field of apartment complex management, empowering stakeholders with enhanced predictive capabilities for optimizing maintenance strategies and resource allocation.

**Keywords :** facility management, deep learning algorithm, apartment complex, repair and maintenance cost

## 1. 서론

아파트는 한국을 포함해 여러 나라에서 광범위하게 채택된 주된 주거 방식으로 자리매김했다. 이러한 아파트 단지들은 한정된 도심 공간 내에서 상당한 인구를 수용하는 효과적인 대안을 제공한다. 더욱이, 인구 밀도가 높은 지역에서 개별적인 주택 건설의 어려움에 직면할 때, 아파트는 제한된 땅에서도 많은 사람들이 거주할 수 있는 가능성을 열어, 보다 효율적인 거주 옵션을 제안한다는 장점을 가진다[1]. 이에 따라, 다수의 주민이 거주하는 대규모 아파트 단지는 세심하고 과학적인 관리가 요구된다. 아울러, 정밀한 수선유지비 산출은 예산과 관리 측면에서 중대한 영향을 끼친다. 정확한 수선유지비 산출로 예상치 못한 비용 상승이나 예산 초과를 방지하며 예산을 효과적으로 배정할 수 있다. 또한, 적절한 유지보수 계획을 위해 수선유지비의 정밀한 산정이 필수적이다. 또한, 정확한 비용 산출은 유지보수 작업의 결정과 우선순위를 정하는 데 도움을 준다. 정기적인 유지보수는 시설의 안정적이고 안전한 운영을 보장한다. 수선유지비용의 추정과 관리자에게 필수적인 작업을 식별하고 예산을 배정하여 시설의 기능과 안전성을 유지하는 데 기여할 수 있다. 또한, 정밀한 수선유지비 산정은 아파트 단지의 장기적인 자산 관리에 도움을 준다. 수선 및 유지 관리 비용을 예측하고 예산을 효율적으로 운용함으로써 시설의 수명을 연장하고 장기 계획을 수립할 수 있다. 특히, 적절한 유지 관리는 거주민의 만족도에 긍정적인 영향을 미치며, 시설을 우수한



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.

상태로 유지하고 필요한 수리를 즉각 처리함으로써 거주민의 편안함과 만족감을 증진시킨다. 이러한 이유로 수선유지비 산정은 아파트 단지 관리의 혁신을 위한 핵심 요소가 된다. 정확하고 효율적인 수선유지비 산정은 시설 운영과 유지 관리를 최적화하고 거주민의 만족도를 높이는 데 기여할 수 있다.

그럼에도 불구하고 아파트 단지의 수선유지비 예측 방법과 예측 모델 개발은 다양한 문제에 직면하고 있다. 예를 들어, 아파트 단지의 수선 및 유지 관리 비용은 다양한 요인과 건물의 나이, 기후조건, 시설의 유형, 시장의 동향 등 다양한 요소에 의해 영향을 받는다. 이런 다양한 요소와 그 상호작용을 설명하는 모델을 개발하는 것은 복잡하고 어렵다[2]. 더욱이, 수리 및 유지 관리 비용은 종종 비선형적 관계를 가지고 있으며, 예측하기 어려운 불확실성을 내포한다. 예를 들어, 갑작스런 시설 고장과 수리는 예측하기 어렵기 때문에 모델에서 이런 비선형성과 불확실성을 포착하고 관리하는 것은 상당한 도전이다[3]. 게다가, 유지보수 비용 예측 모델을 개발하기 위해서는 충분한 양과 질의 데이터가 필요하다. 그러나 아파트 단지마다 데이터 수집 및 관리 방식이 다르며, 데이터의 불규칙성과 한계로 인해 모델 개발이 어려울 수 있다[4]. 이런 고려 사항으로 인해 아파트의 수선유지비용 예측을 위한 모델 기술 개발은 복잡하고 어려운 과제이다.

따라서 본 연구의 목적은 실증적 데이터를 바탕으로 아파트 단지의 수선유지비용을 체계적이고 과학적으로 예측할 수 있는 방법론을 제안하는 것이다. 본 연구에서 제안하는 개발 프레임워크와 모델은 향후 다양한 건물군에 적용될 수 있으며, 시설관리의 발전에 기여할 것이다.

## 2. Literature reviews

시설관리는 물리적 자산을 효율적으로 유지, 관리, 그리고 개선하는 기능을 담당한다. 예산을 적절히 활용하는 효과적인 시설관리는 에너지 효율 증가, 적절한 유지 보수, 자원의 최적 활용을 통해 운영 비용을 낮추는 데 기여한다. 시설관리는 설비, 건물, 인프라 같은 물리적 자산의 수명을 유지하고 늘리는 데도 중요한 역할을 한다. 정기적인 유지보수와 시의적절한 수리는 건물의 성능 감소를 예방하며 장기적인 서비스 기간을 보장한다. 또한, 시설관리는 거주자와 방문자에게 안전하고 보호된 환경을 마련하는 데 기여한다. 이는 거주자의 작업 효율과 지속 가능한 발전에도 긍정적인 영향을 미친다. 시설관리의 이러한 중요한 역할 때문에, 최근 이 분야를 향상시키기 위한 연구가 여러 분야에서 활발하게 진행되고 있다[5]. 또한, 대규모 시설이 늘어나면서 시설 운영 및 유지 관리 시장이 성장하고 있으며, 시설 자산의 관리와 운영을 함께 고려해야 한다는 새로운 시각이 나타나고 있다[6].

건축물 유형에 따른 시설관리는 보안, 안전성, 운영의 효율성, 에너지 효율, 그리고 유지보수 등 여러 면에서 중요하다. 각 건물은 특별한 목적과 운영상의 필요를 가지며, 이에 맞는 시설관리는 그 목적을 이루는데 기여한다. 보안 및 안전 측면에서는 각 건물 유형에 맞는 예방 및 대응 조치를 통해 건물과 이용자를 잠재적 위험으로부터 보호할 수 있다. 운영 효율을 측면에서는 건물 유형에 맞춘 시설관리 방안은 고객 만족도 향상과 효율적 운영에 유리하다. 에너지 효율은 건물의 에너지 소비를 최적화해 비용 절감과 환경 지속가능성을 증진시키고, 유지보수는 건물의 수명을 늘리고 예기치 않은 고장이나 파손을 방지하는데 도움을 준다. 이렇게 건물 유형에 따른 적합한 시설 관리는 건물 운영의 안전과 효율을 보장하며, 비용 절감과 지속 가능한 운영을 실현시킨다[7].

다양한 건물 유형에 대한 시설관리 비용 예측에 관한 연구가 진행되었다. 예를 들어, Ghodoosi et al.[8]은 교량 구조물의 유지보수비용을 최적화하기 위해 시스템 신뢰성 분석과 유전 알고리즘을 사용하는 방법에 초점을 맞추었다. 이 접근법은 유지보수비용과 구조적 신뢰성 간의 균형을 찾는 것을 목표로 하고 있다. Krstić and Marenjak[9]는 대학 건물의 운영비용과 유지보수비용을 추정하기 위한 모델을 제안했다. 이 모델은 대학 건물의 특정 특징을 고려하여 유지 보수 및 운영비용을 예측하고 최적화하였다. Bayzid et al.[10]은 도로 건설 장비의 유지보수 비용 예측에 관한 사례 연구를 통해, 다양한 요인을 고려해 도로 건설 장비의 유지보수 활동을 계획하는 데 유용한 모델을 소개하였다. Meshref et al.[11]은 산업군 건물의 수명 주

기 비용을 예측하기 위해 다양한 건물 구조 대안을 고려한 딥러닝 예측 모델을 개발했다. 그들의 모델은 딥러닝 기법을 활용해 건물의 수명 주기 비용을 예측하고, 건물 구조 결정에 도움을 주고 있다. Au-Yong et al.[12]는 오피스 건물의 유지보수 비용을 예측하기 위해 상태 기반 유지 보수 방식을 적용한 모델을 제시했다. 이 모델은 건물 상태를 기반으로 유지보수 활동을 계획하고 비용을 예측하는 것을 목적으로 하고 있다. 이와 선행연구들을 살펴보면, 다양한 건물 유형에 대한 시설 관리 비용 예측을 위한 연구가 다수 진행되었지만, 아파트 건물과 같이 특정 건물에 대한 연구는 거의 없다. 그 이유는 시설물 유지관리에는 장기간에 걸쳐 이루어지며, 유지보수 관련 업체별 상이한 규정이 있어 건물마다 특성을 고려한 수선주기 및 비용설정이 난해하기 때문이다. 즉, 특정건물에 대한 수선주기 및 비용 데이터 확보가 어렵다. 그러나 본 연구에서는 대한민국 성남시에 위치한 1,800세대 아파트의 수선유지비 데이터를 확보하였으며, 이를 활용하여 아파트 건물의 수선유지비용 예측을 위한 딥러닝 기반의 예측 모델 프레임워크를 제안하고자 한다.

### 3. Research method

본 연구는 대규모 아파트 단지에서 발생한 수선유지비 데이터를 활용하여, 딥러닝 알고리즘을 활용한 수선유지비 예측 모델을 만들기 위한 프레임워크를 제안한다. 이 과정을 진행하는 구체적인 단계는 다음과 같다. 첫째, 실제 아파트 단지에서의 수선유지비용을 수집한다. 둘째, 관련한 기타 관련 변수들을 수집한다. 셋째, 이 데이터를 분석을 위해 입력과 출력 변수를 전처리한다. 넷째, 데이터를 옴타마이져별로 딥러닝 알고리즘 모델로 훈련시킨다. 마지막으로, 최적의 예측 모델의 구조와 하이퍼파라미터를 결정한다

### 4. Data collection

본 연구에서는 대한민국 성남시에 위치한 약 1,800세대 규모의 아파트 단지에서 수선유지비 데이터를 수집하였다. 이 아파트 단지는 1994년에 준공되었고, 총 22개 동으로 이뤄져 있다. 이 아파트는 준공 이후 약 30년이 지난 노후화된 단지라는 특성으로 인해 장기 수선유지비 데이터 확보의 적합한 대상이고, 비교적 큰 규모의 단지이기 때문에 본 연구에서 채택하였다. 수집 범위는 2013년부터 2023년까지의 수선유지 비용이며, 이 데이터에는 수리비용의 상세 항목과 해당 비용이 발생한 월 등의 정보가 포함되어 있다. 모델의 출력 변수로는 수선유지 비용으로 설정하였고, 입력 변수로는 수선유지비용 상세, 월, 건물의 나이를 사용하였다. 모델의 입력과 출력변수에 대한 상세한 설명은 Table 1과 같다. Table 2에서는 입력변수와 출력 변수의 기술 통계를 보여주고 있다.

**Table 1.** Definitions of variables

Variables		Explanations
Output	Repair and maintenance amount	Monthly repair and maintenance costs(KRW)
Input	Classification	Classification of costs for repairs and maintenance(1 to 6) 1. external structure 2. internal structure 3. electricity, fire protection, elevators, smart home systems, etc. 4. water, gas, drainage, ventilation equipment, etc. 5. heating and hot water supply equipment 6. seating area and outdoor facilities
		Calendar month
	Age of building	Number of years elapsed since the building was completed.

**Table 2.** Descriptive statistics of variables

Variables	N	Minimum	Maximum	Average	Std. Deviation
Repair and maintenance amount	1,736	0.00	10,143,330	1,212,110.79	1,414,475.91
Classification	1,736	6.00	6.00	3.04	1.52
Calendar month	1,736	12.00	12.00	5.62	3.08
Age of building	1,736	31.00	31.00	20.57	2.62

## 5. 딥러닝 알고리즘의 활용

본 연구는 LSTM(Long Short-Term Memory) 알고리즘을 예측 모델 개발을 위해 활용하였다. LSTM은 시계열 데이터의 분석 및 예측에 일반적으로 사용되는 알고리즘으로 많은 산업과 연구영역에서 높은 성능을 인정받고 있다[13]. LSTM은 네트워크 구조와 하이퍼파라미터의 정밀한 설정이 예측 모델의 효과성에 결정적 영향을 미치기 때문에, 이를 최적화하는 것이 매우 중요하다[14]. 하이퍼파라미터는 배치 크기, 최적화 방법, 에포크 수, 활성화 함수 등을 포함하고, 이 설정들은 특정 네트워크 구조에 맞춰 변화하기 때문에 다양한 조합 사이에서 중요한 설정을 식별하는 것이 핵심적이다. 이러한 최적화 과정은 복잡한 데이터 패턴과 종속성을 효과적으로 포착하는 능력을 제공하기 때문에, 모델의 예측 정확도와 전체 성능을 향상시킬 수 있다. 더욱이, 이 과정을 통해 얻은 네트워크 구조와 하이퍼파라미터는 모델의 일반화 능력을 높이는 데 중요한 역할을 한다. 다양한 네트워크 구조와 하이퍼파라미터 조합의 심층적 탐색을 가능하게 하는 시뮬레이션 기반의 접근 방식은 모델이 더 나은 예측력과 견고성을 갖고 다양한 데이터 환경 및 실제 상황을 처리할 수 있게 한다.

예를 들면, 옵티마이저는 모델의 성능을 개선하기 위해 손실 함수를 최소화하는 알고리즘으로, 가중치 조절 및 학습률 관리 등을 담당한다. 따라서, 적절한 옵티마이저의 선택은 필수적이다. RMSprop, Adam, Adadelta, AdaGrad와 같은 일반적으로 사용되는 옵티마이저는 모델 학습 과정에 각각 다른 영향을 미치며, RMSprop은 학습률을 조절해 매개변수 업데이트 속도를 균일하게 한다[15]. Adam은 각 매개변수에 대해 학습률을 조절할 수 있는 적응형 학습률 알고리즘이다. Adadelta는 최신 정보만을 활용하여 학습률을 조정한다. 각 옵티마이저의 특성과 한계를 고려해 특정 모델이나 데이터 특성에 가장 적합한 옵티마이저를 선택하는 것이 중요하다. AdaGrad는 업데이트의 역사를 기반으로 학습률을 자동 조정한다. 이 연구에서는 RMSprop, AdaGrad, Adadelta, Adam을 각각 실험하고 비교하여 최적의 옵티마이저를 선별했다. 아울러, 배치 크기는 학습의 속도에 직접적인 영향을 미치므로, 학습 과정의 안정성을 위해 적당한 배치 크기를 유지하는 것이 중요하다. 또한, 본 연구에선 비선형 관계를 학습하고 표현하는 데 중요한 활성화 함수로 ReLU를 사용했다. ReLU는 양수 입력에 대해 입력 값을 그대로 전달하고, 음수 입력에 대해서는 0을 반환함으로써, 시그모이드 함수의 한계를 극복한다. 이러한 특성 덕분에 ReLU는 널리 사용되는 활성화 함수가 되었다[16]. 에포크는 훈련 데이터 전체가 모델을 통해 학습되는 횟수를 의미하며, 이 연구에서는 1,000 에포크와 5의 배치 크기로 설정하여 데이터를 효과적으로 학습시켰다[17].

Table 3은 옵티마이저와 레이어 수에 따른 모델의 학습 결과인 R-square, MAE, RMSE를 나타낸다. 최적의 모델은 R-square 값이 가장 크고 RMSE(Root mean square error)와 MAE(Mean absolute error) 값이 낮은 조건을 선택하였다. Table 3과 같이 RMSprop을 옵티마이저로 사용하고 3개 레이어를 가진 조건에서 최상의 결과를 얻었다. 따라서 아파트 수선유지비 예측모델의 구성은 Table 4와 같다.

**Table 3.** Learning outcomes by optimizer

Optimizer	Number of Layer	R-Square	RMSE	MAE
RMSprop	1	0.637	0.488	0.301
	2	0.634	0.380	0.203
	3	0.769	0.372	0.169
Adam	1	0.019	0.950	0.587
	2	0.042	1.025	0.602
	3	0.072	0.884	0.504
Adadelat	1	0.009	1.151	0.965
	2	0.031	0.916	0.734
	3	0.052	0.979	0.716
AdaGrad	1	0.145	0.799	0.607
	2	0.280	0.755	0.536
	3	0.167	0.832	0.563

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

Arrangement		Specifics
Deep learning algorithm		Long Short-Term Memory(LSTM)
Network structure	Nodes	48-64-80
	Number of layers	3
Hyper parameters	Batch Size	10
	Epoch	100
	Activation Function	Rectified Linear Unit function
	Optimizer	RMSprop

## 6. 토론

이 연구는 딥러닝 알고리즘을 사용해 아파트 단지의 수선유지 비용을 예측하는 프레임워크를 제시했다. 연구 과정에는 실제 아파트 단지에서 발생하는 수선유지 비용 데이터의 수집과 영향을 미치는 다양한 변수의 분석이 포함되었다. 또한, 딥러닝 알고리즘 모델의 학습 과정을 최적화하기 위해 하이퍼파라미터와 네트워크 구성에 대한 조정을 포함하는 시뮬레이션을 진행한 뒤, 결과를 광범위하게 분석했다. 연구 결과는 3개 층을 가진 RMSprop 최적화 알고리즘을 사용했을 때 모델이 가장 우수한 성능을 보여주는 것으로 나타났다.

이 모델의 프레임워크는 다양한 분야로 확장이 가능하다. 예를 들어, 보험 회사는 수리 비용을 정확히 평가해 보험 청구 과정을 간소화할 수 있다. 또한, 정부 기관은 도시 인프라의 유지관리 및 수리 예산을 관리하는 데 본 연구의 모델을 활용할 수 있다. 더 나아가, 아파트와 같은 대규모 주거 시설의 스마트 홈 기술과의 결합을 통해 혁신적 연구의 기반을 마련할 수 있을 것이다. 아울러, 시공사에서는 아파트 건설 동안 발생할 수 있는 수리 및 유지 관리 비용을 예측하고, 예산 및 유지 관리 계획을 수립하는 데 본 연구의 모델을 활용할 수 있다. 더불어, 부동산 중개인과 개발자는 예산 책정 과정에 모델을 통합해 고객에게 정확한 예산 견적을 제공할 수 있다. 공공 부문에서는 도로 및 교량을 포함한 도시 인프라의 수리 및 유지 관리 예산 책정에 유용하게 활용될 수 있다. 이뿐만 아니라, 자동차, 항공, 에너지 산업, 플랜트 등 다양한 분야에서도 수선유지비 예측에 본 연구의 모델을 응용할 수 있을 것이다.

그러나 본 연구는 데이터 확보의 어려움으로 인하여 단일 아파트 단지의 데이터에 초점을 맞추고 있다. 따라서 다양한 국



가, 도시, 아파트 단지의 추가 데이터를 수집을 통한 비교 분석과 검증을 수행하는 추가 연구가 필요하다. 이를 통해 모델의 신뢰도를 향상시킬 필요가 있다. 또한, 본 연구는 특정 건물 유형에만 집중되어 연구 범위를 넓혀 다양한 건물 유형에 대한 데이터 수집 및 분석을 포함하는 연구가 요구된다.

## 7. 결론

대규모 건축물과 고층빌딩이 급증함에 따라, 시설관리의 복잡성이 크게 상승하고 중요도 또한 커지고 있다. 이는 복잡한 관리 전략과 정교한 조직 구조에 대한 수요를 증가시키고 있으며, 현대 건축물의 복잡한 유지 보수 및 운영 요구를 충족시키기 위해 고급 시설 관리의 필요성을 더욱 강조하고 있습니다. 시설관리 분야는 진화하는 표준, 빠른 기술 발전, 강화된 규제, 지속 가능성에 대한 증가하는 초점 등 여러 외부 요인에 의해 변화하고 있습니다. 이러한 요인들은 현대 건축물이 직면한 다양한 문제를 효과적으로 해결하기 위해 포괄적이고 체계적인 시설관리 접근법의 중요성을 부각시키고 있다. 따라서, 고도화된 시설관리는 변화하는 외부 환경에 적응적으로 대응하고, 건물 및 구성 요소의 효율적인 운영을 보장하는 예방적 접근 방식을 필요로 한다. 이를 위해서는 정확한 예산 배정과 주의 깊은 예산 계획이 필수적이다. 특히, 현대 건물의 복잡성으로 인해 수리 및 유지 보수 비용을 정확하게 예측할 수 있는 모델의 필요성이 점점 더 중요해지고 있다. 정확한 예측으로 시설 관리자는 예산을 효과적으로 추정 및 할당하고, 잠재적 문제를 사전에 방지하는 사전 유지 보수 계획을 세울 수 있습니다. 이와 같이, 고도화된 시설관리는 자원 할당의 최적화와 유지 보수 활동의 우선순위를 정하는 데 있어 필수적이며, 이는 비용 효율성을 높이고 자산의 수명을 연장하는 데 기여한다.

본 연구는 아파트 단지의 수선유지비 데이터를 기반으로 한 딥러닝 알고리즘 기반 예측 모델 개발의 프레임워크를 제안하였다. 본 연구의 프레임워크는 아파트 단지 수선유지와 관련된 비용을 효율적으로 예측하여, 아파트 건설 프로젝트의 재무 관리 위험을 줄이는 데 기여할 것으로 기대된다. 제안된 모델 및 프레임워크는 또한 광범위한 시설관리 분야에서 다양한 산업과 건물 유형으로 확장될 수 있을 것이다.

## 요약


본 연구의 주요 목표는 아파트 단지 수선유지 비용을 예측하기 위해 딥러닝 기법을 적용한 예측 모델 구축 프레임워크를 제안하는 것이다. 아파트 건물을 이상적인 상태로 관리하기 위해서는 지속적인 유지 및 시의적절한 수리가 필수적이다. 아파트 단지는 광범위한 면적, 공동 시설, 다수의 주거 동, 서비스 지역 등으로 인해 유지관리가 복잡하다. 또한, 아파트의 안전성 보장, 가치 유지 및 경제적 효율성 때문에 경제적이고 합리적인 유지보수의 중요성이 점점 커지고 있다. 그러나 아파트 단지 수선유지는 다양한 외부 요인의 영향을 받고 데이터 수집이 어려워 연구가 부족한 상황이다. 따라서 본 연구는 실제 아파트 단지 유지보수 비용 데이터를 기반으로 딥러닝 기법을 활용해 유지보수 비용을 예측하는 모델 개발 프레임워크를 제시하고자 한다. 본 연구의 프레임워크 및 결과는 실질적으로 아파트 단지의 유지보수 비용 예측에 활용될 수 있으며, 궁극적으로 아파트 단지의 시설 관리 향상에 기여할 것이다.


키워드 : 시설관리, 딥러닝 알고리즘, 아파트단지, 수선유지 비용

## Funding

This research was supported by a grant(NRF-2022R1F1A106314113 and NRF-2021R1C1C2091677) from the National Research Foundation of Korea by Ministry of Science and ICT.

## ORCID

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

Seunghyun Son,  <http://orcid.org/0000-0003-1349-5586>

## References

1. Islam R, Nazifa TH, Mohammed SF, Zishan MA, Yusof ZM, Mong SG. Impacts of design deficiencies on maintenance cost of high-rise residential buildings and mitigation measures. *Journal of Building Engineering*. 2021 Jul;39:102215. <https://doi.org/10.1016/j.job.2021.102215>
2. Kim S, Lee S, Ahn YH. Evaluating housing maintenance costs with loss-distribution approach in South Korean apartment housing. *Journal of Management in Engineering*. 2018 Dec;35(2):04018062. [https://doi.org/10.1061/\(ASCE\)ME.1943-5479.0000672](https://doi.org/10.1061/(ASCE)ME.1943-5479.0000672)
3. Lee KH, Ahn YH, Chae CU. Establishment of the repair cycle of the components of the apartment housing. *KIEAE Journal*. 2014 Apr;14(2):69-75. <https://doi.org/10.12813/kieae.2014.14.2.069>
4. Choi SM, Lee YS. Economic analysis for setting appropriate repair cycles on the fixed materials and facilities in the public rental housing. *Advances in Materials Science and Engineering*. 2016 Nov;2016(1):7423801. <https://doi.org/10.1155/2016/7423801>
5. Jeong Y, Lee Y, Jung Y. Requirements management framework for design management and information characteristics. *Korean Journal of Construction Engineering and Management*. 2020 Nov;21(6):3-15. <https://doi.org/10.6106/KJCEM.2020.21.6.003>
6. Lee IH, Jung YS. Evaluation of construction information transfer requirements for efficient asset management. *Journal of the Korean Society of Construction Management*. 2018 Jul;19(4):12-20. <https://doi.org/10.6106/KJCEM.2018.19.4.012>
7. Atkin B, Brooks A. *Total facility management*. 5th Edition. UK: Wiley Blackwell; 2021. 464 p.
8. Ghodoosi F, Abu-Samra S, Zeynalian M, Zayed T. Maintenance cost optimization for bridge structures using system reliability analysis and genetic algorithms. *Journal of Construction Engineering and Management*. 2018 Dec;144(2):04017116. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001435](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001435)
9. Krstić H, Marenjak S. Maintenance and operation costs model for university buildings. *Tehnički vjesnik*. 2017 May;24(Supplement 1):193-200. <https://doi.org/10.17559/TV-20140606093626>
10. Bayzid SM, Mohamed Y, Al-Hussein M. Prediction of maintenance cost for road construction equipment: a case study. *Canadian Journal of Civil Engineering*. 2016 Mar;43(5):480-92. <https://doi.org/10.1139/cjce-2014-0500>
11. Meshref A, El-Dash K, Basiouny M, El-Hadidi O. Implementation of a life cycle cost deep learning prediction model based on building structure alternatives for industrial buildings. *Buildings*. 2022 Apr;12(5):502. <https://doi.org/10.3390/buildings12050502>
12. Au-Yong CP, Ali AS, Ahmad F. Prediction cost maintenance model of office building based on condition-based maintenance. *Eksploatacja i Niezawodność-Maintenance and Reliability*. 2014 Dec;16(2):319-24.
13. Yang C, Trudel E, Liu Y. Machine learning-based methods for analyzing grade crossing safety. *Cluster Comput*. 2017 Jan;20:1625-35. <https://doi.org/10.1007/s10586-016-0714-2>
14. Xia Y, Wang J, Wei D, Zhang Z. Combined framework based on data preprocessing and multi-objective optimizer for electricity load forecasting. *Engineering Applications of Artificial Intelligence*. 2023 Mar;119:105776. <https://doi.org/10.1016/j.engappai.2022.105776>
15. Huk M. Stochastic optimization of contextual neural networks with RMSprop. In *Intelligent Information and Database*

Systems. Proceedings of the 12th Asian Conference, ACIIDS; 2020 Mar 23-26; Phuket, Thailand, Berlin (Germany): Springer International Publishing. 2020. p. 343-52.

16. Lim KK. Analysis of railroad accident prediction using zero-truncated negative binomial regression and artificial neural network model: A case study of national railroad in south korea. *KSCE Journal of Civil Engineering*. 2023 Oct;27(1):333-44. <https://doi.org/10.1007/s12205-022-1198-7>
17. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017 May;60(6):84-90. <https://doi.org/10.1145/3065386>