

Research Paper

피쳐 스케일링과 타겟변수 로그변환에 따른 건축 공사비 예측 성능 분석

Analysis of the Construction Cost Prediction Performance according to Feature Scaling and Log Conversion of Target Variable

강윤호¹ · 윤석현^{2*}

Kang, Yoon-Ho¹ · Yun, Seok-Heon^{2*}

¹Master's Course, Graduate School, GyeongSang National University, Jinju, 52828, Korea

²Professor, Department of Architectural Engineering, GyeongSang National University, Jinju, 52828, Korea

*Corresponding author

Yun, Seok-Heon
Tel : 82-55-751-6542
E-mail : gfyun@gnu.ac.kr

Received : May 18, 2022

Revised : June 9, 2022

Accepted : June 10, 2022

ABSTRACT

With the development of various technologies in the area of artificial intelligence, a number of studies to application of artificial intelligence technology in the construction field are underway. Diverse technologies have been applied to the task of predicting construction costs, and construction cost prediction technologies applying artificial intelligence technologies have recently been developed. However, it is difficult to secure the vast amount of construction cost data required for machine learning, which has not yet been practically used. In this study, to predict the construction cost, the latest artificial neural network(ANN) method is used to propose a method to improve the construction cost prediction performance. In particular, to improve predictive performance, a log conversion method of target variables and a feature scaling method to eliminate the difference in the relative influence of each column data are applied, and their performance in predicting construction cost is compared and analyzed.

Keywords : machine learning, log conversion, construction cost, target, feature scaling

1. 서론

1.1 연구의 배경 및 목적

구글 딥마인드(Google DeepMind)가 개발한 인공지능인 알파고와 2020년에 GPT-3와 알파폴드가 세상에 알려지면서 인공지능(Artificial Intelligence, AI)에 관한 관심이 높아지고 있으며, 이의 핵심 기술인 머신러닝(Machine learning)과 딥러닝(Deep learning)을 활용하는 분야도 증가하고 있다.

특히 건축 분야에서는 공동주택 사업과 대형건축물에 머신러닝을 적용하고 있다. Seo[1] 최근 이루어지는 건설 프로젝트에서 기획, 설계단계가 공사비 예측 및 산정의 필요성과 중요성이 대두되고 있다. 건설 프로젝트는 대형화되고 있어 기획, 설계단계에서 제한된 설계정보에 의한 공사비 예측은 설계단계에서 핵심이 될 수 있다. 과거에는 통계를 통한 분석을 활용하여 공사비를 예측하는 시스템이 많았으나, 점차 인공신경망(Artificial Neural Network, ANN), 사례기반추론(Case-Based Reasoning) 등과 같은 다양한 인공지능 기법을 이용하여 공사비를 예측하는 방법들이 활발하게 연구되고 있다. 이처럼 공사비를 예측하기 위한 머신러닝 기술이 어느 정도 자리를 잡았으며 이 기술의 발달을 통해 실용적인 수준까지 성장하였다. 하지만 아직 기술에 대한 정확도가 낮아, 공사비를 예측하기 위한 모델을 발전시킬 필요성이 있다.



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.

본 연구에서는 국내 조달청에서 발주한 자료를 이용하여, 머신러닝을 기반으로 공사비 예측 모델발전을 위한 최적의 학습모델을 찾는 것을 목적으로 한다. 이를 위해 공사비 예측에 필요한 머신러닝 학습모델 구조에 따른 학습 성과 차이를 분석하고자 한다.

1.2 연구범위와 구성

본 연구는 조달청에서 제공하는 총 251개의 데이터를 학습데이터로 활용하였다. 이들 자료는 2017년부터 2019년까지 3년간 건축 공단이 발주한 451건 중 기준에 부합하는 자료를 추출하여 사용하였다. Visual Studio Code 개발환경을 사용하였고 건축공사비에 영향을 미치는 요소를 11가지로 설정하였다. 다음은 연구의 수행 방법 및 절차이다.

첫째, 선행연구 조사를 통하여 공사비 예측이 가능한 다양한 연구 방법에 대한 이론적 고찰을 수행한다. 이를 바탕으로 연구 방향을 설정한다. 둘째, 2017년부터 2019년까지 건축 공단이 발주한 자료를 조달청에서 제공하는 자료와 비교하여 수집, 분석한다. 셋째, 수집된 자료를 통해 공사비에 영향을 주는 요소를 산정하고 이 요인을 함께 고려할 수 있는 공사비 모델을 구축한다. 넷째, 본 연구의 공사비 예측 모델 결과를 제시한다. Figure 1은 본 연구의 절차 및 방법을 나타낸 그림이다.

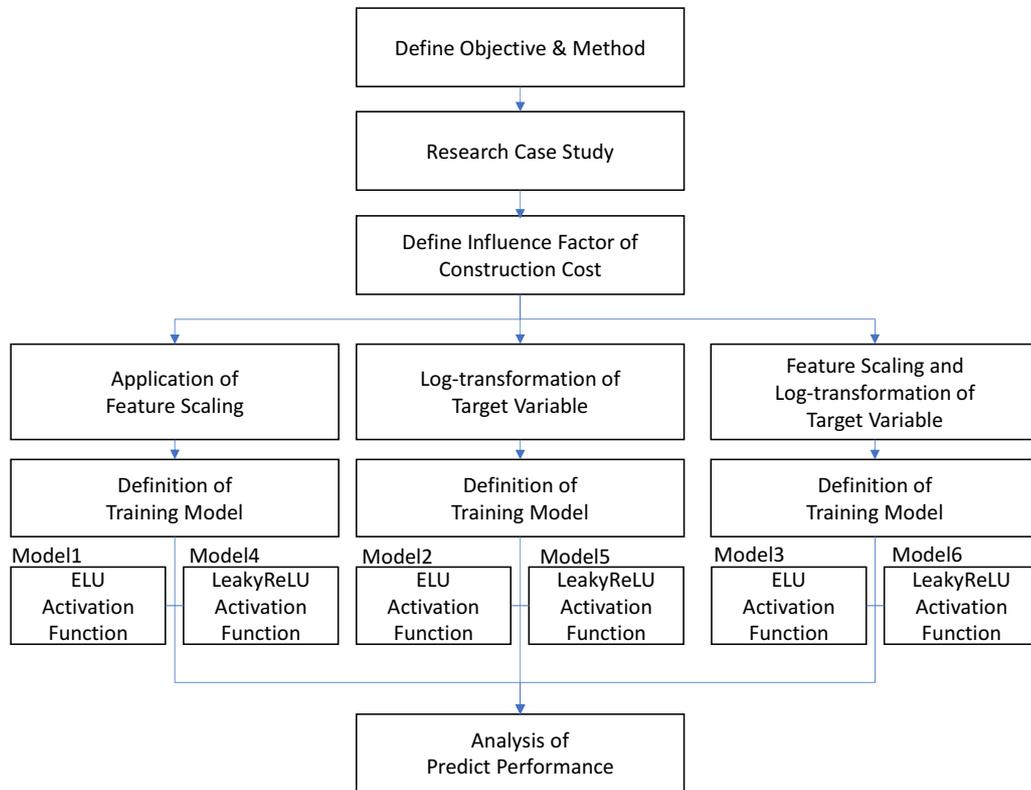


Figure 1. Research procedures and methods

1.3 선행연구 검토 및 차별성

Jung et al.[2]의 연구 결과는 국내 S 교육청 교육시설물 중 2015년부터 2018년까지의 교육청 신설 중·고등학교를 대상으로 연구에 필요한 데이터를 수집하고, 공사비 자료를 바탕으로 18개의 실적자료로 데이터베이스를 구축하였다. 인공지능망, DNN, DBN을 활용하여 적은 사례를 가진 스마트 교육학교 신축 프로젝트 기획 설계단계에서 공사비 예측이 가능한 모

델을 구축 및 비교하였다.

Oh and Kim[3]의 연구 결과는 머신러닝 기법 중 하나인 MARS(Multivariate Adaptive Regression Spine) 모형을 활용하여 서울시 아파트를 대상으로 물리적 특성을 대변하는 네 가지 주요 변수(전용면적, 세대수, 층수, 경과 연도)를 중심으로 주택가격 추정모형을 구축하였다. MARS 모형을 통해 변수들의 영향력이 차별화되는 변곡점을 도출시키고 변곡점을 더미변수에 대한 기준으로 활용하여 기존 선행연구를 바탕으로 한 선형회귀모형과 MARS 모형에 기반한 선형회귀 모형을 비교 및 분석하였다. 그리고 실제로 주택 특성들이 가격에 반영되는 양상을 보다 객관적으로 분석할 수 있는 개선된 헤도닉 모형을 제시하였다.

Hyeon et al.[4]의 연구 결과는 국내 2002년부터 2008년까지 발주된 메가 프로젝트 규모 사업 19건을 기반으로 데이터베이스를 구축하였다. 메가 프로젝트 사업을 구상하고 계획하는 사업 초기 단계에서 기존의 추적된 단위시설물에 대한 실적 데이터를 활용하고, 유사 시설물에 대한 정보를 제공할 수 있는 사례기반추론(CBR)을 활용하여 공사비를 예측하고, 의사결정을 지원할 수 있는 공사비 예측 모델을 개발하였다.

Table 1은 위의 국내 공사비 예측 관련 문헌의 예측 방법을 정리한 결과이다.

Table 1. Domestic construction cost forecasting literature

	Author(Issued Year)	prediction method
A	Jung et al.(2018)	Projection of construction cost in planning and design stage using artificial neural network, DNN, and DBN
B	Oh and Kim(2017)	Building a Housing Price Estimation Model Using the MARS Model
C	Hyeon et al.(2009)	Using case-based reasoning(CBR) to predict construction costs in the planning and planning stages, which are in the early stages of the project

Tayefeh Hashemi et al.[5]의 연구 결과는 건설회사를 통해 수집된 실제 데이터 10,000개를 기반으로 회귀 접근법이 포함된 머신러닝 프레임워크를 개발하였다. 주어진 예산을 통해 최상의 기능을 가진 주택을 지을 수 있도록 최고의 회귀정확도를 위한 인공지능망 프레임워크를 형성하고, 이를 통해 머신러닝 기반 추정 결과는 선형회귀 모델과 의사결정 트리모델이 각각 건설비용과 유지비용을 정확하게 예측하는 모델을 구축하였다.

Pham et al.[6]의 연구 결과는 30년 동안 머신러닝 기법을 통한 비용추정을 위해 수집된 데이터를 기반으로 건설공사의 직접원가와 간접원가에 따른 비용추계에 분석방법론을 적용하였다. 건설 및 관련 프로젝트의 비용추정을 예측하고 적절한 적용방법을 찾을 수 있도록 다양한 분석 방법과 머신러닝 알고리즘을 구축하였다.

Zhirui[7]의 연구 결과는 중국 선양에서 2015년 9월부터 2021년 8월까지 총 72개월간 평균 집값을 데이터로 수집하였다. 총 66건 데이터를 통해 엘만신경망, BP신경망, RBF신경망을 사용하여 주택가격을 예측하는 모델을 구축하였다. 이를 통해 도출된 예측값을 비교한 결과 엘만신경망이 우수하다는 결과를 얻었다.

Table 2는 국외에서의 공사비 예측 관련 연구사례에서 공사비 예측 방법을 정리한 표이다.

Table 2. Literature on predicting overseas construction costs

	Author(Issued Year)	Prediction method
A	Sanaz Tayefeh et al.(2020)	Projection of construction cost in planning and design stage using artificial neural network, DNN, and DBN
B	Pham et al.(2021)	Building a Housing Price Estimation Model Using the MARS Model
C	Zhao Zhirui(2021)	Using case-based reasoning(CBR) to predict construction costs in the planning and planning stages, which are in the early stages of the project

기존 연구사례를 보면 적은 데이터를 활용한 선형회귀 모델 방식을 기반으로 모델을 구축하였다. 이를 통하여 인공신경망(Artificial Neural Network, ANN) 방식을 활용해 구축하는 사례가 적어 공사비 예측 관련 부분은 연구 선상에 머물러 있다. 현재 시점에서 인공신경망에 적용하는 방법론과 최적화하는 연구가 부족하여 예측 정확도를 높이기 위해 모델 및 파라미터의 구성을 최적화하는 연구가 필요할 것으로 보인다.

2. 공사비 예측성능 분석

2.1 공사비 예측 학습모델 구성

본 연구는 건축공사비 예측 모델의 정확도를 높이기 위해서 피쳐스케일링과 타겟변수를 로그변환 하는 방법을 적용하고자 한다. 이를 위하여 피쳐스케일링과 타겟변수를 로그변환 하는 방법을 적용한 모델과 활성화 함수를 달리하는 모델 6가지를 정의하고, 각 모델의 공사비 예측성능을 비교하였다.

공사비 예측을 위한 머신러닝(Machine learning) 학습모델을 개발하기 위하여 본 연구에서는 Visual Studio Code 개발환경을 바탕으로 케라스(Keras) 라이브러리를 사용하였다. 또한, 공사비 예측에 사용된 데이터는 2017년부터 2019년까지 공공건축 분야에서 발주한 3년간의 데이터이며, 이들 중 공사비 예측 모델 구축에 필요한 기준에 부합하는 데이터를 확보한 251개의 데이터를 선별하여 사용하였다.

본 연구에서는 공사비에 영향을 주는 영향요인을 건축물의 규모와 특성을 정의할 수 있는 요인으로 11가지를 정하였다. 건축설계도서에서 건축개요에 정의되어있는 정보들을 참고하여 공사유형, 연면적, 건축면적, 최고 높이, 최대 지상 층수, 최대 지하 층수, 대지면적, 조경면적, 기준층 층고, 주차대수, 공사 년도로 총 11가지를 영향요인으로 정의하였다. 이에 따른 영향요인 11가지를 정리한 것은 Table 3이다.

Table 3. Factors influencing construction costs

Influence Factor	Description	Example
Building Classification	Types of facilities classified into 10 types.	Research facilities and institutes. general government building, office. medical and enshrinement facilities. dormitory, residential facilities. fire station, police station, etc. welfare facilities, libraries. control center, sports facilities. school. correctional, training facilities, transportation facilities.
Total Area	The total area of each floor of the building.	
Building Area	The area occupied by the building.	
Total Height	The total height of the building.	
Super Structure Floor	The number of floors on the ground.	
Basement Floor	The number of basement floors.	
Site Total Area	The entire land area.	
Landscape Area	Landscape area.	
Typical Floor Height	Height of the base floor.	
Parking Lot	The number of cars parked.	
Building Year	Construction year.	

공사비 예측 모델은 최적화 방식에 따라 학습 성능 차이를 보일 수 있다. 이러한 성능차이를 확인하기 위해 최적화 방식으로 피쳐스케일링, 타겟변수를 로그변환 하는 방법을 모델에 적용하였으며, 모델을 각각 피쳐스케일링만 사용하였을 경우,

타겟변수를 로그변환 하는 방법을 사용하였을 경우, 두 방법을 같이 사용하였을 경우로 3가지 모델을 정의하였다. 여기서 활성화 함수 차이에 의한 모델을 비교하기 위해 활성화 함수를 ELU와 LeakyReLU를 적용하여 추가적으로 3가지 모델을 더 정의하였다. 이를 Keras 라이브러리를 적용하여 모델을 구축하고 활성화 함수와 노드 수의 조건은 동일하게 설정하였다. 학습 횟수는 1,000회로 적용하였고 이에 따른 모델구조를 정리한 것은 Table 4와 같다.

Table 4. Machine learning model structure

	Model structure	Activation function	Node
Model 1	Feature scaling	ELU	6, 100, 64, 32, 16, 1
Model 2	Log conversion of target variable	ELU	6, 100, 64, 32, 16, 1
Model 3	Log conversion of target variable + feature scaling	ELU	6, 100, 64, 32, 16, 1
Model 4	Feature scaling	LeakyReLU	6, 100, 64, 32, 16, 1
Model 5	Log conversion of target variable	LeakyReLU	6, 100, 64, 32, 16, 1
Model 6	Log conversion of target variable + feature scaling	LeakyReLU	6, 100, 64, 32, 16, 1

2.2 피쳐스케일링 적용

피쳐스케일링은 데이터의 특징이나 독립 변수의 구간을 표준화하는 방법론을 정의로 한다. 이는 영향요인 데이터 값의 범위가 크게 차이 날 때 주로 사용하는 정규화 방식이다. 만약 데이터 분석 시, 데이터가 큰 영향요인이 있으면 모델에 있어 상대적으로 많은 영향력을 미칠 수 있어 가중치 불균형이 일어날 가능성이 있다.

본 연구는 가중치 불균형 현상을 예방하기 위해 피쳐 스케일링 방식을 적용한다. 추가적으로 활성화함수 변경으로 인한 기울기 소실의 문제를 예방하기 위해 활성화 함수의 종류인 ELU와 LeakyReLU를 사용하여 모델에 적용하였다. Figure 2는 머신러닝 모델에 피쳐스케일링 방법과 활성화 함수 ELU를 사용하였을 때의 결과 그래프이다.

Figure 2는 Model 1의 학습 결과를 보여준다. 왼쪽의 그래프는 Epochs 값에 따른 Loss 변화를 나타낸 결과이고 오른쪽 그래프는 Epochs 값에 따른 MAE 변화를 나타낸 결과이다. Model 1은 피쳐스케일링과 활성화 함수 ELU를 사용하여 모델을 구성하였으며, 이 경우 학습 횟수 200에서 400 사이에서 학습데이터와 검증데이터의 LOSS 값과 MAE 값이 0에 수렴하고 있다. Model 1일 경우 200에서 400 사이에 최적의 값을 찾을 수 있을 것으로 판단된다.

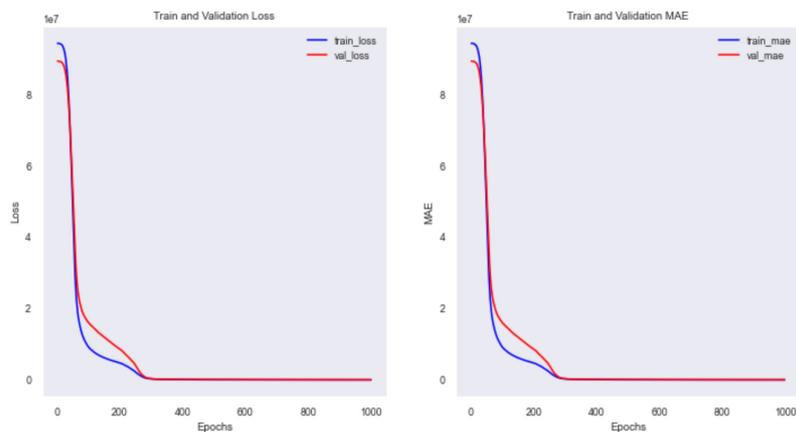


Figure 2. Result of Feature Scaling(ELU) Model

Figure 3은 Model 4의 학습 결과를 보여준다. Model 4은 피처스케일링과 활성화 함수 LeakyReLU를 사용하여 모델을 구성하였으며, 이 경우 학습 횟수가 약 200에서 학습데이터와 검증데이터의 LOSS 값과 MAE 값이 0에 수렴하고 있는 것을 볼 수 있다. Model 4일 경우 200에서 최적의 값을 찾을 수 있을 것으로 판단된다.

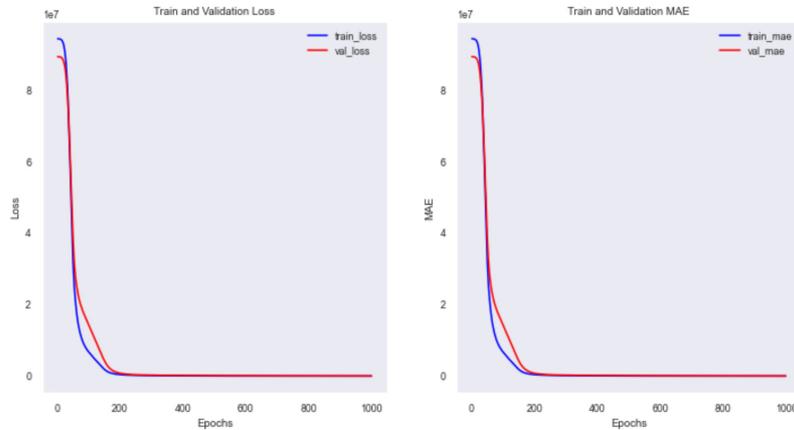


Figure 3. Result of Feature Scaling(LeakyReLU) Model

2.3 타겟변수 로그변환 적용

타겟변수를 로그 변환하는 것은 피처스케일링과는 다르게 영향요인이 아닌 타겟 변수에 대한 불균형을 줄이기 위해 정규화하는 방식이다. 본 연구의 타겟 변수는 전체공사비로 이를 활성화 함수 ELU와 함께 Model 2에, LeakyReLU와 함께 Model 5에 적용하여 모델을 구성하고자 하였다.

Figure 4는 Model 2의 학습 결과 그래프이다. 왼쪽의 그래프는 타겟변수를 로그 변환하는 방법의 Epochs 값에 따른 Loss 변화를 나타낸 그래프이고 오른쪽 그래프는 Epochs 값에 따른 MAE 변화를 나타낸 그래프이다. Model 2는 타겟변수를 로그 변환과 활성화함수 ELU를 사용하여 모델을 구성하였으며, 이 경우 학습 횟수 200에서 400 사이에 학습데이터와 검증데이터의 LOSS 값과 MAE 값이 0에 수렴하고 있는 것을 볼 수 있다. Model 2 경우 200에서 400 사이에 최적의 값을 찾을 수 있을 것으로 판단된다.

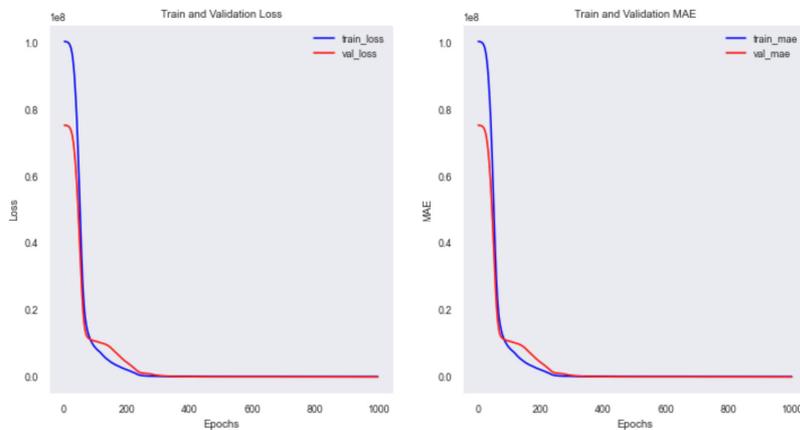


Figure 4. Result of target variable log conversion(ELU) model

Figure 5는 Model 5의 학습 결과를 보여주고 있다. Model 5는 타겟변수를 로그 변환과 활성화 함수 LeakyReLU를 사용하여 모델을 구성하였으며, 이 경우 학습 횟수 약 200에서 학습데이터와 검증데이터 모두 LOSS 값과 MAE 값이 0에 수렴하고 있는 것을 볼 수 있다. Model 5일 경우 200에서 최적의 값을 찾을 수 있을 것으로 판단된다.

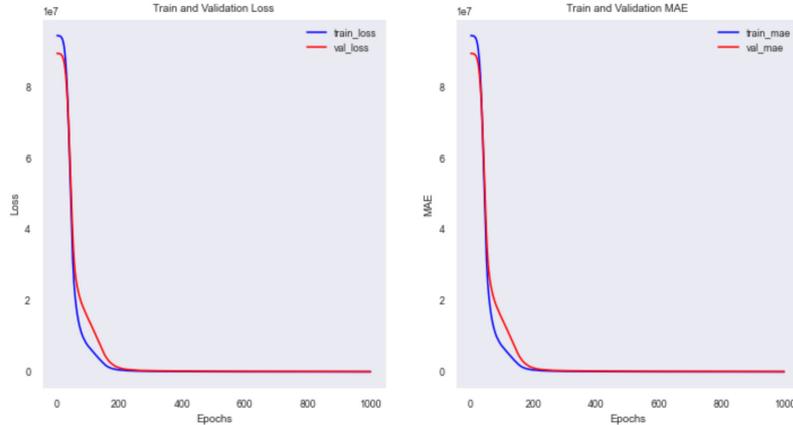


Figure 5. Result of target variable log conversion(LeakyReLU) model

2.4 타겟변수 로그변환과 피쳐스케일링 적용

데이터의 특징이나 독립 변수의 구간을 표준화하는 방법론인 피쳐스케일링과 타겟변수에 대한 정규화 방식인 타겟변수 로그변환을 같이 사용하여 모델을 구성하고자 하였다. 이처럼 피쳐스케일링과 타겟변수 로그변환을 통해 모든 데이터에 정규화를 시도하면, 예측성능을 향상시킬 수 있다.

Figure 6은 Model 3의 학습 결과를 보여주고 있다. 위의 피쳐스케일링과 타겟변수 로그변환과 같이 왼쪽의 그래프는 Epochs 값에 따른 Loss 변화를 나타낸 그래프이고 오른쪽 그래프는 Epochs 값에 따른 MAE 변화를 나타낸 그래프이다. Model 3은 타겟변수를 로그변환 하는 방법과 피쳐스케일링을 함께 사용하였고 활성화 함수 ELU를 사용하여 모델을 구성하였으며, 이 경우 학습 횟수 200에서 400 사이에서 학습데이터와 검증데이터의 LOSS 값과 MAE 값이 0에 수렴하고 있는 것을 볼 수 있다. Model3일 경우 200에서 400 사이에 최적의 값을 찾을 수 있을 것으로 판단된다.

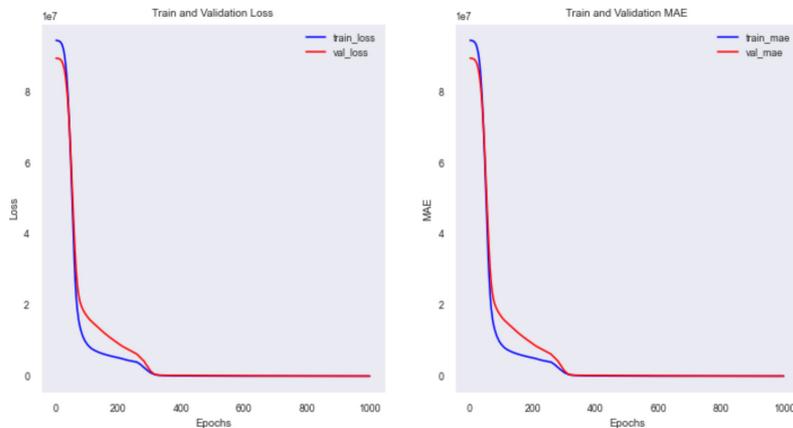


Figure 6. Result of feature Scaling & target variable log conversion(ELU) model

Figure 7은 Model 6의 학습 결과를 보여주고 있다. Model 6은 피쳐스케일링과 타겟변수를 로그변환 하는 방법과 같이 사용하였고 활성화 함수 LeakyReLU를 사용하여 모델을 구성하였다. 이 경우 학습 횟수 약 200에서 학습데이터와 검증데이터의 LOSS 값과 MAE 값이 0에 수렴하고 있는 것을 볼 수 있다. Model 6일 경우 200에서 최적의 값을 찾을 수 있을 것으로 판단된다.

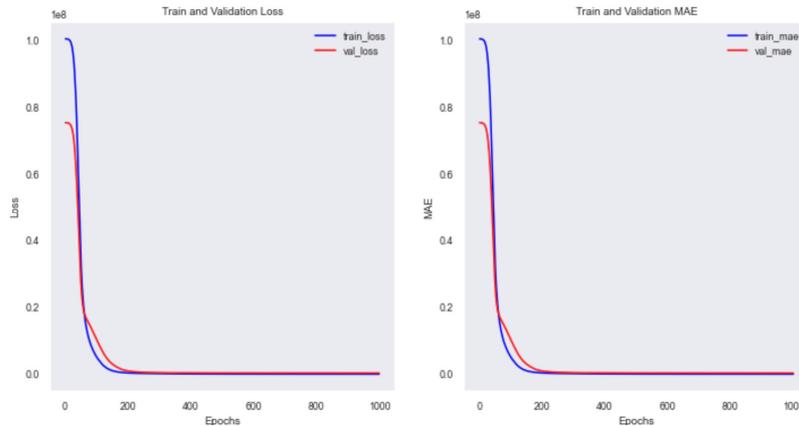


Figure 7. Result of feature Scaling & target variable log conversion(LeakyReLU) model

2.5 모델의 성능 비교

본 연구는 사용된 모델 6개를 비교 분석하여, 공사비 예측에 최적 모델을 찾고자 하였다. 6개 모델의 공사비 예측 정확도를 분석한 결과는 Table 5와 같다. 결과를 살펴보면, 피쳐스케일링과 타겟변수 로그변환을 사용한 방법을 모두 활용한 경우가 피쳐스케일링이나 타겟변수의 로그변환을 사용하는 방법을 개별적으로 적용한 것보다 정확도가 높은 것으로 나타났으며, 그 중에서도 ELU 활성화 함수를 적용한 경우가 LeakyReLU 활성화함수를 적용한 경우가 오차율이 작은 것을 알 수 있다. 연구에서 적용한 결과 Model 3의 경우가 오차율 3.97% 로 가장 정확도가 높은 것을 알 수 있다.

Table 5. Comparison of error rates

	Model structure	Activation function	Average error rate
Model 1	Feature scaling	ELU	7.36%
Model 2	Log conversion of target variable	ELU	6.26%
Model 3	Log conversion of target variable + feature scaling	ELU	3.97%
Model 4	Feature scaling	LeakyReLU	10.02%
Model 5	Log conversion of target variable	LeakyReLU	8.71%
Model 6	Log conversion of target variable + feature scaling	LeakyReLU	7.92%

3. 결론

본 연구에서는 인공신경망(Artificial Neural Network, ANN) 방법을 사용하여 공사비 예측 방법에 적용하였다. 공사비 예측을 위한 머신러닝 학습 모델 구성에 있어서, 영향요인의 구성과 노드의 깊이, 최적화하는 방식에 따라 예측 모델의 성능이 각각 다르게 나타나게 된다. 본 연구에서는 공사비 예측성능을 향상시키기 위한 방법으로, 각 열의 데이터 크기에 따른 상대

적 영향력의 차이를 제거하기 위해 피쳐 스케일링 방법을 적용한 모델과 타겟변수를 로그변환 하는 방법을 적용한 모델을 총 6가지의 모델로 나눠 공사비 예측성능을 비교 분석하고자 하였다. 전체적으로 활성화 함수를 평균 오차율 값이 약 2~3% 가량 학습성능이 좋다. 따라서 활성화 함수를 LeakyReLU를 사용하는 것보다 ELU함수를 사용하는 것이 적합하다고 판단 된다. 또한 피쳐스케일링 방법을 적용한 모델, 타겟변수를 로그변환하는 방법적용 한 모델인 경우 평균 오차율이 7.36%로 타겟변수를 로그변환하는 방법을 사용하였을 때보다 약 0.5%가량 예측 성능이 높게 나타나는 것을 확인하였다. 하지만 타겟변수를 로그변환하는 것과 피쳐스케일링을 함께 사용하였을 때 평균 오차율이 3.97%로 다른 모델보다 약 2%가량 예측성 능이 높게 나타났다. 따라서 타겟변수를 로그 변환하는 것과 피쳐스케일링을 함께 사용하는 것이 모델을 구성하는 데 있어 더 효율적일 것이라 판단된다.

요약

건설 분야에서 머신러닝(Machine learning)에 필요한 방대한 공사비 자료를 확보하는 데 어려움이 있어, 아직은 실용적으로 활용되지는 못하고 있다. 본 연구에서는 이러한 공사비 예측을 위하여 최신의 인공신경망(ANN) 방법을 사용하여, 공사비 예측성능을 향상 시키기 위한 방법을 제시하고자 한다. 특히 타겟변수를 로그 변환하는 방식, 피쳐스케일링 방식을 적용하고자 하였으며, 이들의 공사비 예측성능을 비교 분석하고자 한다. 이는 향후 다양한 조건을 갖는 공사비 예측과 적정 공사비 검증에 도움을 줄 수 있을 것으로 예측된다.

키워드 : 머신러닝, 로그변환, 공사비예측, 타겟변수, 피쳐스케일링

Funding

National Research Fund(NRF)

Acknowledgement

This research was supported by the National Research Foundation of Korea(NRF) funded by the Ministry of Education(NRF-2019R1A2C1005833).

ORCID

Yoon-Ho Kang,  <http://orcid.org/0000-0003-3981-7256>

Seok-Heon Yun,  <http://orcid.org/0000-0001-5439-4111>

References

1. Seo YG. A model study for predicting construction costs in the planning and design stages through performance construction cost analysis [master's thesis]. [Seoul (Korea)]: Korea University. 2009. 62 p.
2. Jung SH, Kwon OB, Son JH. A study on the analysis and estimation of the construction cost by using deep learning in the SMART educational facilities -Focused on planning and design stage-. Journal of Korean Institute of Educational Facilities. 2018

Nov;25(6):35-44. <https://doi.org/10.7859/kief.2018.25.6.035>

3. Oh JH, Kim JS. Prediction of housing price using machine learning:Focusing on MARS. Korean Association for Housing Policy Studies Symposium; 2017 Nov; Seoul, Korea. Seoul (Korea): Korean Association for Housing Policy Studies; 2017. p. 153-71.
4. Hyun CT, Hong TH, Son MJ, Kim YS, Jang DW. Development of the construction cost prediction model based on case-based reasoning in the planning phase of mega-project. *Journal of the Architectural Institute of Korea Structure & Construction*. 2009 May;25(9):181-90.
5. Tayefeh Hashemi S, Ebadati OM, Kaur H. Cost estimation and prediction in construction projects: a systematic review on machine learning techniques. *SN Applied Sciences*. 2020 Sep;2:1703. <https://doi.org/10.1007/s42452-020-03497-1>
6. Pham TQD, Quang NH, Vo ND, Bui VS, Tran VX. Fast and Accurate Estimation of Building Cost Using Machine Learning. *Research in Intelligent and Computing in Engineering*. 2021 Jan;1254:515-25. https://doi.org/10.1007/978-981-15-7527-3_49
7. Zhirui Z. Analysis and prediction of housing prices in shenyang city based on elman neural network. *Scholars Journal of Engineering and Technology*. 2021 Nov;9(10):159-63. <https://doi.org/10.36347/sjet.2021.v09i10.001>