

Research Paper

적응형 뉴로-퍼지(ANFIS)를 이용한 건축공사비 예측

Prediction of Building Construction Project Costs Using Adaptive Neuro-Fuzzy Inference System(ANFIS)

윤석현¹ · 박우열^{2*}

Yun, Seok-Heon¹ · Park, U-Yeol^{2*}

¹Professor, Department of Architectural Engineering, GyeongSang National University, Jinju-Si, Gyeongnam, 36729, Korea

²Professor, Department of Architectural Engineering, Andong National University, Andong-Si, Gyeongbuk, 36729, Korea

*Corresponding author

Park, U-Yeol

Tel : 82-54-820-5897

E-mail : wypark@anu.ac.kr

Received : December 26, 2022

Revised : January 10, 2023

Accepted : January 12, 2023

ABSTRACT

Accurate cost estimation in the early stages of a construction project is critical to the successful execution of the project. In this study, an ANFIS model was presented to predict construction costs in the early stages of a construction project. To increase the usability of the model, open construction cost data was used, and a model using limited information in the early stage of the project was presented. We analyzed existing studies related to ANFIS to identify recent trends, and after reviewing the basic structure of ANFIS, presented an ANFIS model for predicting conceptual construction costs. The variation in prediction performance depending on the type and number of membership functions of the ANFIS model was analyzed, the model with the best performance was presented, and the prediction accuracy of representative machine learning models was compared and analyzed. Through comparing the ANFIS model with other machine learning models, it was found to show equal or better performance, and it is concluded that it can be applied to predicting construction costs in the early stage of a project.

Keywords : building construction, construction cost estimation, fuzzy theory, adaptive neuro-fuzzy inference system

1. 서론

1.1 연구의 배경 및 목적

건설 프로젝트의 초기단계에서 공사비를 정확하게 예측하는 것은 프로젝트를 성공적으로 수행하기 위해 매우 중요하다. 그러나 설계도면이 확정되지 않은 초기단계는 공사비 예측을 위해 활용할 수 있는 정보가 한정되기 때문에 공사비를 정확하게 예측하기가 어렵다. 따라서 프로젝트의 초기단계에서 공사비 예측의 정확도를 높이기 위한 연구가 많이 진행되었다.

Elfaki et al.[1]은 2014 이전 10년 동안 건설프로젝트의 비용예측과 관련된 연구를 분석하였는데, 과거의 데이터를 기반으로 학습하는 기계학습(Machine learning) 방식에서 인공신경망(Artificial Neural Networks; ANN)과 서포트 벡터 머신(Support Vector Machine; SVM)이 가장 많이 활용되었다고 분석하였다. Hashemi et al.[2]은 더 포괄적으로 1985년부터 2020년까지 공사비 예측과 관련된 연구논문 92편을 분석하였는데, 사용된 기법을 분석한 결과 ANN이 39편으로 가장 많았으며, 회귀분석(Regression Analysis; RA)이 21편, 사례기반추론(Case Based Reasoning; CBR)이 9편 순으로 나타났다. 공



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.

사비 예측과 관련된 연구 대부분은 프로젝트 초기단계인 입찰 이전단계에 프로젝트 관리자의 의사결정을 지원하기 위해 공사비를 예측하는 것에 초점을 두고 있는 것으로 나타났다.

기계학습은 불확실성을 다룰 수 있고, 불완전한 데이터로 예측이 가능할 뿐 아니라 유사한 사례를 기반으로 새로운 사례를 예측할 수 있다는 장점이 있다[1]. ANN의 경우 통계에 대한 전문적인 지식이 없어도 예측 모델을 만들 수 있고 변수들간의 내재적인 비선형관계를 탐지할 수 있는 능력이 있기 때문에 많은 예측 문제에 활용되어 왔다[2]. 최근에는 다층 신경망(Deep Neural Network; DNN)으로 발전되면서 다양한 분야에 적용되고 있다. DNN이 여러 분야에서 많은 성과를 내고 있지만 예측결과에 대해 원인을 설명하지 못하는 ‘블랙 박스(Black box)’와 같은 특성은 여전히 단점으로 지적되고 있다[1,2]. 또한 DNN은 기존의 단층 신경망과 비교하여 다층 구조를 채택하기 때문에 학습에 필요한 계산 부하가 증대하고, 복잡성 또한 증가하는 문제가 있을 뿐 아니라 신경망을 학습하기 위해 기존의 경사강하법을 채택하기 때문에 지역해(Local minima)에 빠질 위험성도 있다. 이러한 문제를 개선하기 위해 DNN과 퍼지시스템(Fuzzy systems)을 결합한 연구[3]가 시도되었다. 이 퍼지 신경망(Fuzzy Neural Network; FNN)은 퍼지로직과 신경망, 최적화기법을 결합한 것으로 신경망의 “블랙 박스”같은 특성을 개선하고 다양한 문제를 개선하는데 효과적으로 활용되고 있다[4]. FNN 기법 중에서는 적응형 뉴로-퍼지 시스템(Adaptive Neuro-Fuzzy Inference System; ANFIS)이 가장 많이 활용되고 있는데, 연산과정에서 부하가 작을 뿐 아니라 투명하고, 계산결과 또한 통계모델만큼 신뢰성있는(Robust) 결과를 산출하기 때문이다[4].

따라서 본 연구에서는 ANFIS 모델을 활용하여 건설프로젝트의 초기단계에 건축공사비를 예측할 수 있는 모델을 제시하고 다른 기계학습 알고리즘과 성능을 비교하여 ANFIS 모델의 적용가능성을 분석하고자 한다. 공사비 예측모델의 활용가능성을 높이기 위해 공개된 공사비 데이터를 활용하며, 프로젝트 관리자의 의사결정을 지원할 수 있는 공사비 예측모델을 제시하는 것을 목적으로 한다.

1.2 연구의 범위 및 방법

공사비 예측은 건설프로젝트의 진행단계에 따라 다양하게 진행된다. 설계단계가 진행될수록 프로젝트의 범위가 확정되기 때문에 공사비를 예측하기 위해 활용할 수 있는 정보는 증가하게 된다. 본 연구에서는 프로젝트 범위가 확정되지 않은 설계 초기단계에 공사비를 예측하는 것으로 연구 범위를 한정한다. 또한 설계초기 단계에서는 활용할 수 있는 정보가 많지 않기 때문에 과거의 데이터를 활용하였으며, DNN과 퍼지시스템을 결합한 FNN의 일종인 ANFIS 모델을 구축하여 공사비 예측 성능을 분석하는 것으로 연구의 범위를 한정한다. 연구의 방법은 다음과 같다.

첫째, ANFIS와 관련된 기존 연구를 분석하여 최근의 동향을 파악한 후 공사비 예측에 활용하기 위한 시사점을 도출한다.

둘째, ANFIS의 기본 구조를 고찰한 후 건축공사비 예측을 위한 ANFIS 모델을 구축한다. 이를 위한 공사비 데이터를 수집한 후 수집한 데이터를 분석하여 ANFIS 모델을 구축하기 위한 입력변수를 선정한다.

셋째, 건축공사비 예측을 위한 ANFIS 모델의 성능을 평가하기 위해 기존의 기계학습 모델의 예측 정확도를 비교한다. ANFIS의 모델의 매개변수에 따라 달라지는 예측 성능을 분석하고 비교한다.

2. ANFIS 기존연구 고찰

Talpur et al.[5]는 다층 신경망과 퍼지이론을 결합한 모델을 다층 뉴로-퍼지(Deep Neuro-Fuzzy System; DNFS)로 정의한 후 2015년부터 2020년까지 발표된 논문을 분석하였다. 신경망과 퍼지이론을 결합하는 방식은 여러 가지 제시되었으나 ANFIS 모델이 가장 빈번하게 사용되었으며, 다양한 분류문제나, 규칙기반 공정제어, 패턴 인식과 같은 다양한 분야에 성공적으로 적용되고 있는 것으로 나타났다.

ANFIS는 회귀유형의 예측문제에도 다양하게 적용되고 있다. 구조분야의 연구를 살펴보면 Cho et al.[6]은 섬유분포 및 전단저항 메커니즘에 많은 불확실성을 내포하는 SFRC 보의 전단강도 평가에 ANFIS 모델을 적용하였으며, 각 변수(전단경간비, 인장철근비, 섬유혼입률, 섬유계수)마다 퍼지 집합의 개수를 2개로 설정하여 총 퍼지집합의 개수는 8개를 적용하였다. 적용 결과 평가용 데이터의 경우 R^2 값이 평균 0.95, 변동계수(COV)가 0.17로서 해석정확도가 우수하다고 평가하였다. Sim and Choi[7] 전단경간비가 2.5 보다 큰 세장한 콘크리트 보의 전단강도를 예측하기 위하여 ANFIS 모델을 적용하였으며, 적용결과 ANFIS모델이 ACI 318-11이나 EC2와 같은 현행 설계기준 보다 개선된 정확도를 보여주었으며, 전단강도 평가 시 모델링 변수의 불확실성과 변수사이의 상호작용을 잘 설명할 수 있다고 제시하고 있다. 그 외에도 철근 부착강도 예측[8], 프리텐션 전달길이 산정[9], 콘크리트 압축강도 예측[10], 해양철근콘크리트구조물에서 철근의 부식정도를 예측[11] 에서도 ANFIS 모델은 좋은 결과를 보여주는 것으로 나타났다.

환경분야에서도 다양한 연구가 진행되었다. Rhee et al.[12] 광주광역시 대상 1일 상수도 급수량을 예측하기 위해 ANFIS 모델 적용을 적용하였으며 ANFIS 모형과 다중회귀모형을 비교한 결과, ANFIS를 적용한 일부 모델이 다중회귀모형보다 더 나은 결과를 얻을 수 있었다. Lee et al.[13] 태양광 발전량을 예측하기 위해 ANFIS 모델을 제시하였으며, 평가결과 일사량, 일조시간, 운량 및 최고기온을 모두 고려한 ANFIS모델이 가장 효과적인 것으로 나타났다. 그 외에도 저수지 수위 예측 [14], 단기 풍력발전 예측[15], 건축물 단기 전력부하 예측[16]에 적용된 방법들에서 더 나은 성과를 내는 것으로 나타났다.

공사비 예측과 유사한 연구로는 전자입찰 데이터를 분석하여 입찰가격을 예측하기 위한 연구[17]가 있었는데, 기초금액, 추정가격, 예가 범위, 낙찰 하한율 4개의 특성을 입력변수로, 낙찰 금액을 출력변수로 설정한 결과 ANFIS모델이 다층퍼셉트론(Multi layer peceptron)모델보다 예측능력이 낮은 것으로 나타났다. Cheng et al.[18]은 신경망과 퍼지 로직(Fuzzy logic)을 결합하여 매개변수를 유전 알고리즘(Genetic Algorithm; GA)로 최적화하는 방식의 초기단계 공사비 예측 모델을 제시하였으나, 입력변수로 내외부 마감 정보까지 포함하는 등 설계가 진행된 단계에 적용할 수 있는 독립변수를 사용하였다.

기존 연구를 보면 적용 대상별로 입력변수에 차이가 있고, 소속함수의 유형과 개수도 달라지는 것을 알 수 있으며, 일부 연구에서는 ANFIS 모델의 성능이 낮은 경우도 있었다. 경영경제분야에 적용된 ANFIS연구[4]를 보면 입력변수의 개수는 2개에서 5까지 다양하였으며, 적용된 소속함수의 개수도 최소 2개에서 최대 6개까지 다양하게 적용된 것으로 나타났다. 따라서 건축공사비를 예측하는 최적 모델을 구축하기 위해서는 적절한 매개변수의 선정에 주의할 필요가 있을 것으로 판단된다.

3. 건축공사비 예측을 위한 적응형 뉴로-퍼지(ANFIS) 모델

3.1 ANFIS의 기본 구조

여기서는 Jang[19]이 제안한 적응형 뉴로-퍼지 모델의 기본 개념 및 구조에 대해 살펴본다.

ANFIS는 Figure 1의(a)에서 볼 수 있는 바와 같이 여러 층으로 구성되는 DNN처럼 5개의 층으로 구성된다. DNN의 학습 과정과 다른 점은 퍼지화 노드(layer 1)와 후건부의 역퍼지화(Defuzzification) 노드(layer 4)가 학습과정에서 훈련되는 반면, 노드의 곱(product)에 해당하는 노드(layer 2)와 정규화 노드(layer 3)는 학습과정에서 수정되지 않는다. 각 층의 구조는 다음과 같다.

Layer 1은 입력변수(그림에서 x 와 y)의 퍼지화(Fuzzification)단계로서, 결정된 입력변수 별로 소속함수(Membership function)를 결정하고 소속정도(membership)를 정의하는 단계이다. 소속함수로는 가우시안(Gaussian) 함수나 generalized Bell 함수 등이 사용되며 가우시안(Gaussian) 함수가 많이 사용된다.

Layer 2는 규칙의 영향력을 계산하는 단계로서 이 층에서 각 노드는 Layer 1에서 구한 소속함수값을 규칙별로 곱한 가중치로 출력된다. Figure 1의(b)에서 볼 수 있는 바와 같이 입력변수(x 와 y)의 소속정도의 곱으로 노드에 해당하는 $W1$ 과 $W2$ 를

계산하는 단계이며 여기서 $\{p_i, q_i, r_i\}$ 는 후건부의 매개변수가 된다. 결국 주어진 입력으로부터 출력에 해당하는 f 를 합리적으로 추론할 수 있는 모델을 구축하는 것이 중요하다.

Layer 3은 영향력의 강도를 정규화(Normalize)하는 층으로서, 각 퍼지집합 별로 목적함수를 예측하는 퍼지규칙을 개발하는 단계이다. 개별 노드에서는 모든 가중치의 합에 대한 i 번째 규칙의 영향력의 비를 계산한다.

Layer 4은 역퍼지화층으로서 이 층의 노드가 적응형 노드(Adaptive nodes)가 되며, 각 노드에서는 정규화된 값과 후건부 매개변수 $\{p_i, q_i, r_i\}$ 의 곱으로 출력을 낸다.

Layer 5는 전체 출력값을 계산하는 단계로서 정규화된 소속함수와 최소제곱법을 통해 얻은 f 값을 퍼지화 과정을 거쳐서 최종출력값(f)을 얻을 수 있다. 이렇게 산정된 f 값을 실험값과 비교하여 발생된 오차를 역전파(back propagation) 학습을 반복하여 줄이는 방식으로 학습을 진행하게 된다.

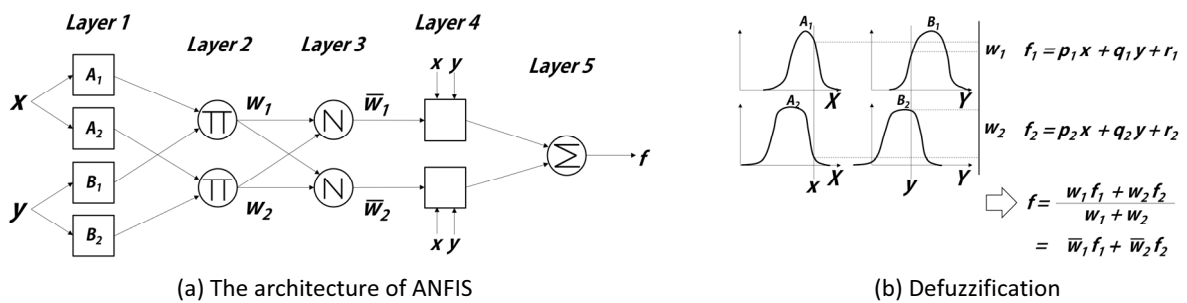


Figure 1. ANFIS based on Sugeno

3.2 건축공사비 예측을 위한 ANFIS 모델

3.2.1 데이터 수집 및 전처리

본 연구에서는 조달청에서 관리하는 ‘공사비정보광장’(<http://pcae.g2b.go.kr:8044/pbs/psa/psa0000/index.do> accessed on 15 November 2020)에서 공개하는 공공건축물의 공사비 데이터와 설계사무소 등을 통해 개별적으로 수집한 데이터를 포함하여 총 908개의 데이터를 수집하였다. 980개의 데이터 중 공사금액이 300억 원을 초과하는 프로젝트와 이상치(Outlier)를 제거한 후 830개의 데이터를 활용하였다. 이상치는 연면적보다 건축면적이 큰 경우과 같이 논리적으로 오류가 있는 데이터와, 매우 넓은 대지면적에 비해 공사규모가 지나치게 작아 상관관계가 현저하게 낮은 데이터를 이상치로 분류한 후 제거하였다. 또한, 300억 이상인 공공공사 프로젝트는 공사계약 방식이 달라질 뿐 아니라 개수가 많지 않아 모델 학습에 사용하기 어렵기 때문에 배제하였다.

Table 1. Parameters and attributes for the input and target variables

| Parameter Type | Parameter | Average | Standard Deviation | Minimum | Maximum |
|------------------|-----------------------------------|---------|--------------------|---------|---------|
| Input variables | Gross floor area(m ²) | 8046.3 | 5341.1 | 145.4 | 32269.2 |
| | Building area(m ²) | 2624.7 | 1747.9 | 26.5 | 11392.0 |
| | Building height(m) | 20.2 | 7.5 | 3.9 | 53.2 |
| | Number of floors | 4.1 | 1.8 | 1 | 15 |
| | Number of parking spaces | 78.7 | 76.1 | 2 | 7.6 |
| Target variables | Construction cost(million ₩) | 10103.4 | 6142.9 | 251.1 | 29859.1 |

데이터를 수집하는 과정에서 누락되거나 오기재되는 사례가 발생할 수 밖에 없기 때문에 수집된 데이터에는 결측치(Missing values)가 존재한다. 이 결측치를 처리하기 위해서 많은 연구에서는 단순하고 적용하기가 쉬운 평균값이나 중간값 등으로 단순 대체하는 방법을 많이 적용한다[20]. 그러나 단순 대체법은 고차원 데이터 집합일 경우 편향(Bias)나 비실재적인 결과를 야기할 수도 있다[21]. 이런 문제를 개선하기 위하여 최근에는 기계학습의 알고리즘을 활용한 대체법으로 k 근접 이웃(K Nearest Neighbor; KNN)이나 랜덤 포레스트(Random Forest; RF) 알고리즘을 활용한 방법이 활용되고 있다. 따라서 본 연구에서는 KNN으로 결측치를 대체한 데이터를 활용하였다.

3.2.2 입력변수의 결정

‘공사비정보광장’에 공개된 공사비 데이터에는 프로젝트와 관련된 다양한 정보가 함께 제공된다. 그러나 건축공사비와의 상관관계수가 높은 것은 변수를 순서대로 나열하면 연면적(m²), 건축면적(m²), 건축물 높이, 층수, 주차대수였다. 이 5가지 변수들은 설계 초기단계에 활용할 수 있는 변수이기 때문에 이 변수들을 입력변수로 활용하였다. Table 1은 입력변수 및 종속변수별로 최소값, 최대값, 평균, 표준편차를 나타낸 것이다.

3.2.3 모델의 평가

본 연구에서는 파이썬(Python)언어를 기반으로 공개된 오픈 소스를 이용하여 ANFIS 모델을 적용하였으며, ANFIS 모델의 성능을 비교하기 위해 기계학습 알고리즘도 사이킷 런(Scikit-learn) 라이브러리를 활용하였다.

본 연구에서 제시한 ANFIS모델과 다른 모델의 성능을 평가하기 위해 결정계수(R²)와 평균제곱근오차(Root Mean Square Error; RMSE)를 활용하였다. 결정계수는 일반적으로 회귀문제에 적용되는 기계학습 모델의 성능을 평가하는데 많이 적용된다. 결정계수는 다음식 (1)과 같이 계산되며, 0과 1사이의 값을 나타내면 1에 가까울수록 더 높은 성능을 나타낸다.

$$R^2 = 1 - \frac{\sum_{i=1}^n (T_i - P_i)^2}{\sum_{i=1}^n (T_i - \mu)^2} \tag{1}$$

RMSE는 식 (2)와 같이 오차제곱의 평균에 루트를 씌운 값을 나타내는데, 값이 작을수록 성능이 높다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - P_i)^2}{n}} \tag{2}$$

여기서 n은 샘플 개수, p_i는 샘플 i에 대한 모델의 예측 결과값, T_i는 목표값, μ는 목표값의 평균을 나타낸다.

4. 적용 결과

4.1 매개변수별 ANFIS 모델 성능

여기서는 소속함수의 종류 및 개수에 따라 ANFIS 모델의 성능이 어떻게 달라지는지 비교하였다. 모델의 성능을 비교하기 위하여 5겹 교차 검증(5 fold cross-validation)을 활용하였으며, 830개의 데이터를 5개 집합으로 나누어 학습용으로 80%,

검증용으로 20%를 적용하였다. 입력변수의 스케일의 차이에 따라 발생할 수 있는 영향력을 줄이기 위해 각 변수의 최대값과 최소값을 기준으로 0과 1 사이의 값으로 정규화(Normalization)한 후 학습을 진행하였다.

Table 2은 소속함수의 개수가 5개일 때 소속함수의 종류에 따라 ANFIS모델의 성능이 어떻게 달라지는지 나타낸 것이다. 소속함수에 따라 학습데이터와 검증용데이터에서의 성능에 큰 차이가 없으나 가우시안함수를 적용했을 때 성능이 가장 우수한 것으로 나타났다.

Table 2. Performance comparison of ANFIS models in terms of membership functions

| Membership function | Training dataset | | Testing dataset | |
|---------------------|------------------|----------------|-----------------|----------------|
| | RMSE | R ² | RMSE | R ² |
| Gaussian(mf=5) | 1915.0 | 0.903 | 2012.5 | 0.891 |
| Gbellmf(mf=5) | 1971.0 | 0.897 | 2014.3 | 0.890 |
| Sigmoid(mf=5) | 1945.3 | 0.899 | 2005.7 | 0.891 |

Table 3는 소속함수로 가우시안 함수를 적용했을 때 소속함수의 개수에 따른 ANFIS 모델의 성능을 나타낸 것이다. 소속함수의 개수가 5개 일 때 성능이 가장 우수한 것으로 나타났으며, 소속함수의 개수가 10개인 경우 학습에 필요한 연산 부하가 크고 성능이 개선되지 않기 때문에 5개 정도가 가장 적합한 것으로 판단된다. Figure 2는 가우시안 함수의 개수를 5개로 적용했을 때 입력변수별로 나타나는 소속함수의 유형을 나타낸 것이다.

Table 3. Performance comparison of ANFIS models in terms of number of membership function

| Number of membership function | Training dataset | | Testing dataset | |
|-------------------------------|------------------|----------------|-----------------|----------------|
| | RMSE | R ² | RMSE | R ² |
| 2 | 1959.4 | 0.898 | 2099.0 | 0.890 |
| 5 | 1915.0 | 0.903 | 2012.5 | 0.891 |
| 10 | 1944.6 | 0.899 | 2054.5 | 0.886 |




Figure 2. Membership functions in ANFIS model

소속함수의 종류 및 개수에 따라 성능을 비교한 결과로 볼 때 소속함수는 가우시안 함수를 적용했을 때, 그리고 소속함수의 개수가 5개일 때 가장 우수한 결과를 도출하였다.

4.2 ANFIS 모델과 기계학습 알고리즘 성능 비교

여기서는 ANFIS 모델과 다른 기계학습 알고리즘의 성능을 비교하였다. 기계학습의 알고리즘은 일반적으로 많이 적용되는 선형 회귀(Linear regression; LR), 신경망(Neural Networks; NN), 랜덤 포레스트(Random forest; RF), Light GBM을 적용하였다. 기계학습 알고리즘의 매개변수는 그리드 탐색(Grid search) 방식으로 추출하여 적용하였다.

Table 4에서 볼 수 있는 바와 같이 ANFIS 모델은 다른 기계학습 모델과 비교하여 거의 동등한 성능을 보여주는 것을 알 수 있다. RF와 Light GBM은 학습용 데이터에 과적합 되는 경향이 나타나는 것에 비해, ANFIS 모델은 학습용 데이터와 검증용 데이터에서 성능에 큰 차이가 없이 적용가능한 것을 확인하였다.

기계학습 모델의 경우 최적해를 도출하기 위해서는 각 모델에 필요한 최적의 매개변수를 선정해야 하며, 그리드 서치와 같은 방식은 계산부하가 높은 문제가 있다. ANFIS 모델 또한 소속함수의 개수가 증가하면 계산부하가 증가하는 단점이 있으나 소속함수의 개수가 5개 이하인 경우 계산부하가 높지 않고 비교적 고른 예측결과를 보이는 것으로 나타났다. ANFIS 모델은 그림 2와 같이 최적의 결과를 도출하는 소속함수를 그래프로 가시화할 수는 있으나 소속 함수의 개수가 많아지면 그래프로 표현하는 것만으로는 DNN의 블랙박스과 같은 문제를 개선하기에는 한계가 있는 것으로 판단된다.

Table 4. Performance comparison of ANFIS model with machine learning models

| Membership function | Training dataset | | Testing dataset | |
|-----------------------|------------------|----------------|-----------------|----------------|
| | RMSE | R ² | RMSE | R ² |
| ANFIS(mf=5, Gaussian) | 1915.0 | 0.903 | 2012.5 | 0.891 |
| Linear regression | 2006.6 | 0.893 | 2021.5 | 0.890 |
| Neural Networks | 1965.3 | 0.897 | 2006.9 | 0.890 |
| Random Forest | 1732.2 | 0.921 | 2111.1 | 0.879 |
| Light GBM | 1677.9 | 0.925 | 2080.4 | 0.882 |

5. 결론

본 연구는 건설프로젝트 관리자의 의사결정을 지원할 수 있도록 프로젝트 초기단계에서 공사비를 예측할 수 있는 ANFIS 모델을 제시하고 성능을 분석하였다. 공공기관에 의해 공개된 공사비 데이터를 활용하였으며 프로젝트 초기단계의 제한된 정보를 바탕으로 예측할 수 있는 모델을 제시하고자 하였다.

ANFIS와 관련된 기존 연구를 분석하여 최근의 동향을 파악하였으며 ANFIS의 기본 구조를 고찰한 후 건축공사비 예측을 위한 ANFIS 모델을 제시하였다. ANFIS의 모델의 소속함수의 종류와 개수에 따라 달라지는 예측 성능을 분석하여 가장 성능이 우수한 모델을 제시하였으며, 대표적인 기계학습 모델의 예측 정확도와 비교분석하였다.

적용 결과 연면적(m²), 건축면적(m²), 건축물 높이, 층수, 주차대수를 입력변수로 하는 모델을 구축하였으며, 소속함수로 가우시안 함수를 5개 적용했을 때 모델의 성능이 가장 우수한 것으로 나타났다. 또한 ANFIS 모델을 다른 기계학습 모델과 비교한 결과 동등 이상으로 성능을 나타내 프로젝트 초기단계 공사비 예측에 적용 가능할 것으로 판단된다.

본 연구는 DNN과 퍼지시스템을 결합한 FNN의 일종인 ANFIS 모델을 구축하여 공사비 예측 성능을 분석하는 것으로 연구의 범위를 한정하였지만, ANFIS 이외의 FNN 모델이나 ANFIS 모델을 적용할 때 최적의 매개변수를 자동으로 추출하는 방안에 대한 연구가 필요할 것으로 판단된다. 또한 많은 연구에서는 ANFIS 모델이 DNN의 블랙박스같은 단점을 개선할 수 있다고 제시하고 있으나 소속함수의 개수가 많아지면 소속함수를 그래프로 표현하는 것만으로는 한계가 있기 때문에 결과에 대한 모델의 설명가능성을 높이기 위해서는 추가적인 연구가 필요할 것으로 판단된다.

요약


건설 프로젝트의 초기단계에서 공사비를 정확하게 예측하는 것은 프로젝트를 성공적으로 수행하기 위해 매우 중요하다. 본 연구에서는 ANFIS 모델을 활용하여 건설프로젝트의 초기단계에 건축공사비를 예측할 수 있는 모델을 제시하였다. 모델의 활용도를 높이기 위해 공개된 공사비 데이터를 활용하였으며 프로젝트 초기단계의 제한된 정보를 바탕으로 예측할 수 있는 모델을 제시하고자 하였다. ANFIS와 관련된 기존 연구를 분석하여 최근의 동향을 파악하였으며 ANFIS의 기본 구조를 고찰한 후 건축공사비 예측을 위한 ANFIS 모델을 제시하였다. ANFIS의 모델의 소속함수의 종류와 개수에 따라 달라지는 예측 성능을 분석하여 가장 성능이 우수한 모델을 제시하였으며, 대표적인 기계학습 모델의 예측 정확도와 비교분석하였다. 적용결과 ANFIS 모델을 다른 기계학습 모델과 비교한 결과 동등 이상으로 성능을 나타내 프로젝트 초기단계 공사비 예측에 적용 가능할 것으로 판단된다.

키워드 : 건축공사, 공사비 예측, 퍼지 이론, 적응형 뉴로-퍼지 시스템

Funding

This work was supported by a Research Grant of Andong National University

ORCID

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

U-Yeol Park,  <http://orcid.org/0000-0003-2154-603X>

References

1. Elfaki AO, Alatawi S, Abushandi E. Using intelligent techniques in construction project cost estimation: 10-year survey. *Advances in Civil Engineering*. 2014 Dec;2014:107926. <https://doi.org/10.1155/2014/107926>
2. Hashemi TS, 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>
3. Hatri EC, Boumhidi J. Fuzzy deep learning based urban traffic incident detection. *Cognitive Systems Research*. 2018 Aug;50:206-13. <https://doi.org/10.1016/j.cogsys.2017.12.002>
4. Salleh MNM, Hussain K. A review of training methods of ANFIS for applications in business and economics. *International Journal of u- and e- Service, Science and Technology*. 2016 Jul;9(7):165-72. <https://doi.org/10.14257/ijunesst.2016.9.7.17>
5. Talpur N, Abdulkadir SJ, Alhussian H, Hasan MH, Aziz N, Bamhdi A. Deep neuro-fuzzy system application trends, challenges, and future perspectives: a systematic survey. *Artificial Intelligence Review*. 2022 Apr;56:865-913. <https://doi.org/10.1007/s10462-022-10188-3>
6. Cho HC, Lee DH, Hwang JH, Ju HJ, Kim KS, Seo SY. Shear strength evaluation of steel fiber-reinforced concrete flexural members using ANFIS. *Journal of the Architectural Institute of Korea Structure & Construction*. 2013 Jun;29(6):3-11. https://doi.org/10.5659/JAIK_SC.2013.29.6.3
7. Sim UC, Choi.KK. Prediction of shear strength of slender reinforced concrete beams with and without shear reinforcement using ANFIS. *Journal of the Architectural Institute of Korea Structure & Construction*. 2013 Dec;29(12):63-71. https://doi.org/10.5659/JAIK_SC.2013.29.12.63

doi.org/ 10.5659/JAIK_SC.2013.29.12.63

8. Kim MS, Cho HC, Lee KJ, Hahm KW, Han SJ, Kim KS. Estimation of bond strength of reinforcing bars in reinforced concrete members using ANFIS. *Journal of the Architectural Institute of Korea Structure & Construction*. 2016 Sep;32(9):27-34. https://doi.org/10.5659/JAIK_SC.2016.32.9.27
9. Kim MS, Han SJ, Cho HC, Oh JY, Kim KS. Prediction of transfer lengths in pretensioned concrete members using neuro-fuzzy system. *Journal of the Korea Concrete Institute*. 2016 Dec;28(6):723-31. <https://doi.org/10.4334/JKCI.2016.28.6.723>
10. Sinha DK, Satavalekar R, Kasilingam S. Application of adaptive neuro-fuzzy inference system for evaluating compressive strength of concrete. *International Journal of Fuzzy Logic and Intelligent Systems*. 2021 Jun;21(2):176-88. <https://doi.org/10.5391/IJFIS.2021.21.2.176>
11. Khayati GR, Rajabi Z, Ehteshamzadeh M, Beirami H. A hybrid particle swarm optimization with dragonfly for adaptive ANFIS to model the corrosion rate in concrete structures. *International Journal of Concrete Structures and Materials*. 2022 Jun;28:457-90. <https://doi.org/10.1186/s40069-022-00517-9>
12. Rhee KH, Moon BS, Kang IH. A study of prediction of daily water supply using ANFIS. *Journal of Korea Water Resources Association*. 1998 Dec;31(6):821-32.
13. Lee DJ, Lee JP, Lee CS, Lim HY, Ji PS. Development of PV power prediction algorithm using adaptive neuro-fuzzy model. *The Transactions of the Korean Institute of Electrical Engineers P*. 2015 Dec;64(4):246-50. <https://doi.org/10.5370/KIEEP.2015.64.4.246>
14. Seo YM, Choi EH, Yeo WK. Reservoir water level forecasting using machine learning models. *Journal of The Korean Society of Agricultural Engineers*. 2017 May;59(3):97-110. <https://doi.org/10.5389/KSAE.2017.59.3.097>
15. Osorio GJ, Matias JCO, Catalao JPS. Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information. *Renewable Energy*. 2015 Mar;75:301-7. <https://doi.org/10.1016/j.renene.2014.09.058>
16. Ghenai C, Al-Mufti OAA, Al-Isawi OAM, Amirah LHL, Merabet A. Short-term building electrical load forecasting using adaptive neuro-fuzzy inference system (ANFIS). *Journal of Building Engineering*. 2022 Jul;52:104323. <https://doi.org/10.1016/j.jobe.2022.104323>
17. Hwang DH, Bae YC. A prediction of bid price using MLP and ANFIS. *Journal of Korean Institute of Intelligent Systems*. 2020 Aug;30(4):309-14. <http://dx.doi.org/10.5391/JKIIS.2020.30.4.309>
18. Cheng MY, Tsai HC, Hsieh WS. Web-based conceptual cost estimates for construction projects using evolutionary fuzzy neural inference model. *Automation in Construction*. 2009Mar;18(2):164-72. <https://doi.org/10.1016/j.autcon.2008.07.001>
19. Jang J. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans Systems, Man, Cybernetics*. 1993 May-Jun;23(3):665-85. <https://doi.org/10.1109/21.256541>
20. Jerez JM, Molina I, Garcia-Laencina PJ, Alba E, Ribelles N, Martin M, Franco L. Missing data imputation using statistical and machine learning methods in a real breast cancer problem. *Artificial Intelligence in Medicine*. 2010 Oct;50(2):105-15. <https://doi.org/10.1016/j.artmed.2010.05.002>
21. Emmanuel T, Maupong T, Mpoeleng D, Semong T, Banyatsang M, Tabona O. A survey on missing data in machine learning. *Journal of Big Data*. 2021 Jun;8(1):1-37. <https://doi.org/10.21203/rs.3.rs-535520/v1>