

# 딥러닝을 이용한 스마트 교육시설 공사비 분석 및 예측 - 기획·설계단계를 중심으로 -

## 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 -

정 승 현\*                      권 오 빈\*\*                      손 재 호\*\*\*  
Jung, Seung-Hyun          Gwon, Oh-Bin                  Son, Jae-Ho

### Abstract

The purpose of this study is to predict more accurate construction costs and to support efficient decision making in the planning and design stages of smart education facilities. The higher the error in the projected cost, the more risk a project manager takes. If the manager can predict a more accurate construction cost in the early stages of a project, he/she can secure a decision period and support a more rational decision. During the planning and design stages, there is a limited amount of variables that can be selected for the estimating model. Moreover, since the number of completed smart schools is limited, there is little data. In this study, various artificial intelligence models were used to accurately predict the construction cost in the planning and design phase with limited variables and lack of performance data. A theoretical study on an artificial neural network and deep learning was carried out. As the artificial neural network has frequent problems of overfitting, it is found that there is a problem in practical application. In order to overcome the problem, this study suggests that the improved models of Deep Neural Network and Deep Belief Network are more effective in making accurate predictions. Deep Neural Network (DNN) and Deep Belief Network (DBN) models were constructed for the prediction of construction cost. Average Error Rate and Root Mean Square Error (RMSE) were calculated to compare the error and accuracy of those models. This study proposes a cost prediction model that can be used practically in the planning and design stages.

키워드 : 스마트 교육, 공사비 예측, 인공지능망, 딥러닝, 기획·설계 단계

Keywords : SMART Education, Construction Cost Estimation, Artificial Neural Network, Deep Learning, Planning-Design Stage

## 1. 서론

### 1.1 연구의 배경과 목적

건설 프로젝트는 사업의 안정적인 운영을 위하여 사업비를 예측하고 관리한다. 사업비 예측은 프로젝트 진행단

계에 따라 기법을 달리하며, 그중 계획·기본설계 단계에는 주로 단위면적당 공사비를 이용하고 있다.

단위면적당 공사비는 기존 유형별 건축물들을 대상으로 매년 공시하는 공사비 산출 기법이다. 기획·설계단계에서 이용되는 단위면적당 공사비는 상세 단가 견적과  $\pm 10\%$  차이를 보이는 것으로 나타난다(Hira et al., 1988). 초기단계에 효율적인 의사결정을 위해서는 위험 부담을 줄여야 하고, 이를 위해 정확한 공사비 예측이 필요하다. 단위면적당 공사비를 이용하는 것은 오차가 크기 때문에 위험 부담으로 의사결정을 지원하기 어렵다고 판단된다. 또한, 단위면적당 공사비 산출은 지역과 각 사업의 특징 등을 무시한 평균 공사비 산출이기 때문에 조달청은 이와 같은

\* M.S Student., Dept. of Architectural Engineering, Hongik Univ. Korea

\*\* Ph D., Dept. of Architectural Engineering, Hongik Univ., Korea

\*\*\* Professor, Ph.D., Dept. of Architectural Engineering, Hongik Univ., Korea  
Corresponding Author,  
Tel:                                                  E-mail: Jaehoson@gmail.com

문제를 보완하기 위한 연구 개발이 필요함을 강조하였다 (Kim, 2017). 이런 문제에도 단위면적당 공사비는 이용이 간단하고, 공사 사례가 많은 건축물은 기존 사례를 참고하여 보정이 가능하기 때문에 현재도 사용되고 있다.

하지만 실적공사비 자료의 부족과 자료 수집의 한계를 가지는 사업은 이를 극복하지 못하고 실용성에 대한 문제를 가진다. 그중 2011년부터 시범교육 운영된 스마트 교육은 S교육청의 주체 하에 진행되고 있으며, 기간이 얼마 되지 않아 실적 사례가 쌓이지 못한 교육시설이다. S 교육청에서 전면적으로 실시하고 있는 스마트(Self-directed, Motivated Adaptive, Resource enriched Technology Embedded) 교육은 ICT(Information and Communications Technologies)를 기반으로 IT 기기를 활용한 자기 주도학습이다. ICT 기술을 최대한 활용한 시범교육으로 기존 교육과는 다른 특징을 가지고 있다(Chang, 2017). 그러므로 스마트 교육시설 신축사업에서는 실적 사례가 부족하고 단위면적당 공사비를 활용하여 공사비를 예측하는 것이 어려운 실정이다.

제한된 데이터에서 정확한 공사비 예측을 위해서는 입력 자료들의 특성과 패턴을 최대한 분석 및 학습할 수 있어야 한다. 딥러닝(Deep Learning)은 입력 변수와 출력 변수 관계에 숨겨진 패턴과 특성을 발견하여 일반화가 가능하다. 현재 딥러닝은 분별과 회귀를 할 수 있는 모델부터, 데이터 생성 능력을 갖춘 모델도 존재한다. 입력변수가 불완전하고 변동이 클 경우 반복학습(Learning by Examples)을 통하여 그 오차를 줄여가기 때문에 데이터 수에 민감한 회귀분석보다 정확한 산정이 가능하다(Cho et al., 2013). 특히, 교육시설 기획·설계단계에서는 명확한 조건이 제한적이고, 데이터가 부족한 단계이기 때문에 딥러닝을 활용한 코스트 모델링이 통계적 모델링보다 유효하리 판단된다.

총공사비의 기본이 되는 상세견적은 산출되기까지 많은 시간이 걸린다. 사업 초기단계에서 이를 예측할 수 있다면, 많은 시간 동안 의사결정 기간이 주어지고 사업 위험성을 판단하고 대비할 수 있다.

본 연구에서는 기획·설계단계에서 적은 실적 데이터만으로 다수의 변수를 적용하여 공사비 예측이 가능한 모델 구축을 목적으로 한다.

실적 자료로는 S교육청 교육시설물 중·고등학교의 공사비 자료를 바탕으로 18개의 실적자료로 작성되었다.

이를 통하여 프로젝트 초기 단계에서 상세견적 공사비를 예측하고, 의사결정 기간을 초기 단계로 확대하여 사업 위험성 및 대안 결정을 지원하도록 제안한다.

## 1.2 연구의 범위와 방법

S교육청이 주체가 되어 미래 교육 시범사업으로 스마트 교육이 반영된 학교시설물의 설계와 시공이 시작된 것은 2015년부터이다 (Chang, 2017). 본 연구에서는 스마트 교육 개념을 포함한 교육시설물 공사비 예측을 목표로 하기 때문에 2015년부터 2018년까지의 S교육청 신설 중·고등학교를 대상으로 연구 데이터를 수집하였다.

본 연구의 범위는 스마트 교육시설 신축 기획·설계단계에서 수행되었으며, 방법 및 절차는 다음과 같다.

- 1) 관련 문헌 조사를 통하여 공사비 예측이 가능한 다양한 연구 방법에(ANN, DNN, DBN : Artificial Neural Network, Deep Neural Network, Deep Belief Network) 대한 이론적 고찰을 수행한다.
- 2) 2015년도에서 2018년도까지 S교육청 산하에서 신축된 중·고등학교에 대한 실적 자료를 조달청 "나라장터"<sup>1)</sup>와 S교육청<sup>2)</sup>을 통하여 수집한다.
- 3) 수집된 실적 자료를 조사하여 공사비에 영향을 주는 대표적 변수를 선정하고 입력 및 출력 변수로서 정리한다.
- 4) 다중회귀분석, DNN, DBN 모델을 구축한다.

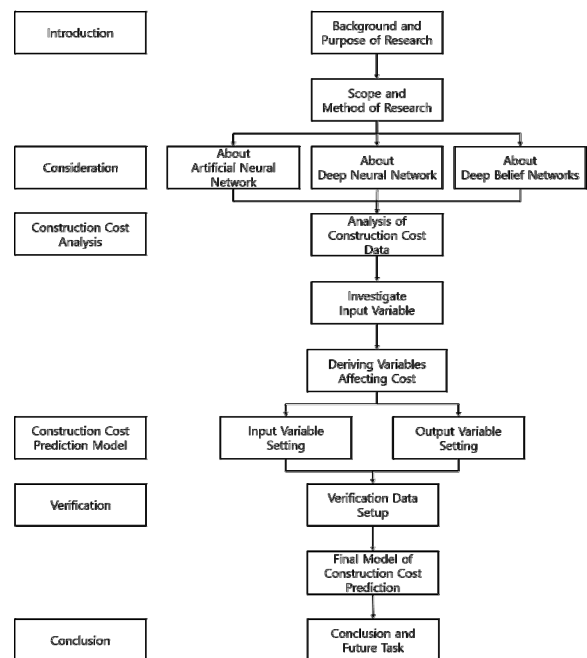


Fig. 1. Steps of the research process

- 1) Korea On-line E-procurement System, <http://g2b.go.kr/index.jsp>, Site accessed September 21, 2018
- 2) Sejong City Office of Education, <http://sje.go.kr/sje>, Site accessed September 21, 2018

5) 구축된 DNN과 DBN 모델, 회귀 모델을 평가 데이터에 적용하여 예측 공사비 정확도를 비교·분석한다.

Fig. 1로 연구의 방법 및 절차를 도식화한다.

## 2. 이론적 고찰

본 연구에서는 ANN, DNN, DBN에 대한 이론적 고찰을 수행하였으며, 다음과 같이 정리한다.

### 2.1 인공신경망 및 딥러닝

데이터에는 어떤 패턴이 존재하며 이를 분석하여 학습하는 것이 인공신경망이다. 인공신경망은 인간의 뇌 신경망을 모방하여 구조화한 인공지능으로 데이터 분석에 효율적이다. 하지만 학습이 깊어지면 오버피팅(Overfitting)<sup>3)</sup>과 기울기 소실(Vanishing gradient)이 쉽게 발생하는 취약점을 가지고 있다. 기울기 소실은 출력이 0 또는 1에 수렴하며 활성화 함수의 표현 한계에 의해 기울기가 0이 되는 현상이다. 기울기가 0이 된 값은 입력층으로 역전파하여 계산하더라도 아무런 의미가 없게 되어 학습이 일어나지 않게 되는 것을 의미한다. 하지만 활성화 함수에 관한 개발 연구가 활발하게 진행되었고, 기울기 소실 문제를 보완할 수가 있었다. 본 연구에서는 기울기 소실 문제를 보완한 활성화 함수를 사용하였다(Goki, 2016).

2006년 Hinton 교수에 의해 발표된 딥러닝은 인공신경망에서 개발된 인공지능 모델이다. 이로 인해 인공신경망의 많은 문제가 해결되었고 은닉층을 다수로 형성하여 학습할 수 있게 되었다(Hinton et al., 2006). 딥러닝의 대표적인 모델은 DNN으로 은닉층이 다수로 형성되어 있다.

다음은 딥러닝의 이론적 고찰을 간략하게 정리한다.

#### 1) 단층 퍼셉트론(Single-Layer Perceptron)




Fig. 2. Diagram of Single-Layer Perceptron(Rosenblatt, 1958)

3) 오버피팅: 한정된 학습데이터에 너무 깊게 학습이 진행되어 실제 데이터에는 잘 맞지 않게 되는 현상이다.

단층 퍼셉트론은 Rosenblatt(1958)에 의해 개발되었으며, 인공신경망을 이루는 가장 간단한 형태를 보이는 구조이다. Fig. 2는 단층 퍼셉트론의 구조를 나타낸다.

단층 퍼셉트론은 인공신경망의 가장 기본적인 모형이다. 외부 입력 값을 받아 연결하는 입력층과 이를 처리하여 결과를 출력하는 출력층으로 이루어져 있다.

#### 2) 다층 퍼셉트론(Multi-Layer Perceptron)

다층 퍼셉트론은 인공신경망의 이론중 하나로 역전파신경망(Back Propagation Network)과 다층전방향신경망(Multi-Layer Feedforward Network)이라고도 불린다. Fig. 3은 다층 퍼셉트론의 구조를 나타낸다.




Fig. 3. Diagram of Multi-Layer Perceptron

기본적으로 입력층, 은닉층, 출력층으로 구성되며 각 층은 다수의 뉴런(Node)을 가진다(Josh et al., 2017). 본 연구에서 이용된 ANN, DNN, DBN 모두 다층 퍼셉트론 구조를 가지고 있다.

#### 3) 역전파 알고리즘 (Back-Propagation Algorithm)

입력층의 각 노드에 입력 패턴에 따라 임의의 가중치를 주면, 이 신호는 은닉층까지 전달되고 출력층에 도달하여 출력값과 목표값을 비교한다. 비교로 도출된 오차를 줄이기 위하여 연결 강도를 조절하며 역전파한다. 이 과정을 반




Fig. 4. Back Propagation Algorithm Process

복하며 오차를 줄이는 것이 역전파 알고리즘이다(Rashid, 2016). 역전파 알고리즘은 인공신경망 및 딥러닝에서 일반적인 알고리즘으로 활용된다.

Fig. 4는 역전파 알고리즘의 학습과정을 나타낸 것이다.

4) 하이퍼 파라미터(Hyper-Parameter)

인공신경망 및 딥러닝은 입력층, 은닉층, 출력층을 통하여 출력값을 도출하는 구조를 가지며, 각 층간 연결강도를 통하여 신경이 전달된다. 적절한 은닉층, 학습률, 소실 함수, 활성화 함수, 모멘텀, 학습과정 최대 횟수, 학습과정 반복 횟수 등 파라미터를 설정함으로써 기울기 소실, 오버피팅 등의 문제를 예방하고 좋은 성능을 가진 모델을 구축할 수 있다. 본 연구에서는 적합한 파라미터를 찾기 위하여 하이퍼 파라미터를 이용하였다. 설정된 다양한 파라미터들을 학습하고 시도하여 최적화된 파라미터를 찾아내는 것이 하이퍼 파라미터이다(Goki, 2016).

5) ReLU(Rectified Linear Unit), TanH(Hyperbolic Tangent)

기울기 소실, 학습 수렴 속도, 오버피팅 등을 보완하기 위하여 다양한 활성화 함수들이 개발되었다. 대표적으로 ReLU, TanH를 설명한다. ReLU 함수는 가중치가 양수일 경우, 그대로 나타낸다. 가중치가 양수 일 때는 은닉층이 다수여도 기울기 소실이 발생하지 않는다. TanH 함수는 Sigmoid와 유사한 형태를 가지지만 확장된 형태라고 할 수 있다(Goki, 2016). 0이 아닌 -1까지 확장되었기에 출력 범위가 넓어 더 빠르게 수렴한다. ReLU와 TanH의 함수는 다음과 같으며, 다음 Fig. 5와 같다.




Fig. 5. ReLU & TanH

6) ANN

인공신경망(ANN)은 일반적으로 1개의 은닉층을 이루는 신경망 모델을 뜻한다. 인공지능 모델로 구축은 복잡하지 않고 간단하고, 많은 데이터에도 반복학습을 통해 빠르게

분석가능하다. 딥러닝이 개발된 후, 다양한 기법들이 개발되었고 인공신경망도 자연스럽게 개선되었다. 하지만 은닉층, 연결강도 등 다양한 파라미터들을 최적화된 값으로 수렴시키는 과정에서 오버피팅이 발생하는 경향을 보인다. 이는 학습된 인공신경망 모델로 새로운 데이터를 예측할 시에 성과가 떨어지는 것을 뜻한다.

7) DNN

DNN은 ANN에서 발전된 모델로서, 은닉층이 다수로 형성되어 깊은 구조를 가진다. 이는 더욱 복잡한 데이터를 모델링할 수 있다는 장점을 가진다. 딥러닝을 활용한 일반화 기법이 지속적으로 개발되며 오버피팅 문제도 많은 부분 최소화되었다. 하지만 한정된 적은 데이터로 학습을 수행할 시에는 여전히 오버피팅이 발생한다는 문제가 있다.

8) DBN

RBM(Restricted Boltzmann Machine)은 블록 단위로 사전학습(Pre-training)을 수행하는 알고리즘이다. 관찰 가능한 가시층 (Visible Layer)과 은닉층만으로 구성되어 있고, 같은 층안의 노드들은 연결 없이 층과 층 사이의 노드 연결만이 존재한다. 이런 RBM 블록 단위를 여러 겹으로 쌓아 이루어진 형태가 DBN이다. 다음 Fig. 6은 DBN 학습 과정을 나타낸다.




Fig. 6. DBN Process

가시층 X1이 입력되어 은닉층 h1이 최대한 정확하게 구성되도록 학습한다. 그리고 h1으로 다시 h2가 구성되도록 훈련을 한다. 이런 과정을 수차례 반복하여 모든 층을 구성하고, 블록 단위로 쌓아 올린다. 이에 가중치들은 이미 학습되어 고정되었기 때문에 오버피팅을 피할 수 있다. 또한, 학습용 데이터가 적을 때에도 입력을 재구성해나가기 때문에 기울기 소실과 오버피팅을 방지할 수 있다. 적은 데이터로도 레이어 노드들을 생성하여 데이터로서 활용하기 때문에 DBN이 적은 데이터에 유용하다고 불리는 이유이다. 하지만 방대한 양의 데이터를 입력하여 모델을 구축할 시에는 상대적으로 계산이 복잡해지고 과대해져 필요이상으로 학습과정이 무거워지는 단점이 있다(Hinton, 2009; Larochelle et al., 2009; Ribeiro et al., 2011; Timothy, 2015; Chen, 2015).

### 2.2 선행연구 고찰

Kang et al(2017)은 2000년부터 건설 분야에서 인공지능을 적용하여 연구한 사례를 분석하였다. 해당 연구에서는 인공지능을 이용한 건설 분야 연구에서 인공지능경망을 이용한 연구가 50%를 넘는 것으로 나타났다. Kim et al (2008), Han et al(2011), Cho et al(2013)에서는 초기 공사비 예측에 있어 신경망을 적용한 모델이 회귀분석을 적용한 모델보다 정확한 공사비 예측 결과를 보임을 입증하였다. 다음 Table 1은 인공지능을 이용한 대표적인 공사비 예측 연구를 정리한 것이다.

Table 1. Research using artificial intelligence

Author	A field of Study	Contents
Kim et al., 2008.	Educational facility construction cost	Prediction of construction cost using artificial neural network
Han et al., 2011	Road construction cost	Prediction of road construction cost using artificial neural network
Cho et al., 2013	elementary school construction cost	Prediction of school construction cost using artificial neural network
Kang et al., 2017.	Construction costs	Artificial Intelligence Research Trends in Architecture

선행연구 결과 인공지능을 이용한 공사비 예측 연구는 지속적으로 진행되어왔으나, 인공지능경망을 이용하는 연구가 주를 이루고 있었다. 인공지능경망은 데이터 수가 적을 경우 기울기 소실과 오버피팅의 문제로 일반화된 모델을 구축하기 어렵다. 실적 사례가 적은 공사는 한정된 데이터로 인하여 학습 자료의 부족으로 오버피팅이 쉽게 발생한다. 오버피팅이 발생된 모델은 평가모델의 일반화를 방해하여 데이터를 예측할 시에 오차가 정밀하지 못한 결과를 만든다.

이에 본 연구에서는 실적 사례가 적은 스마트 교육 중·고등학교 신축 프로젝트 기획·설계단계에서 공사비 예측을 위해 딥러닝(DNN, DBN)을 활용한 공사비 예측 모델을 구축하고 이를 기존의 인공지능경망 예측 모델과 비교하여 실적 사례가 적은 프로젝트에서도 유용한 모델을 제공하고자 한다.

### 3. 실적 데이터 분석

본 연구는 기획·설계단계에서 선택 가능한 변수를 알기 위해 공사비 예측 선행연구들을 조사하였다. 조사된 선행연구들을 동일한 기획·설계단계에서 진행되었던 연구이다. 다음 Table 2는 선행연구 예측 모델에서 사용된 변수를 정리하였다.

Table 2. Selection of Variables in Prior Research

Author	Selection of Variables	
Kim et al, 2008.	1. Gross area 2. Lot area 3. Building area 4. Underground area	5. Ground floor area 6. No. of classrooms 7. Construction period
Shin et al, 2012.	1. Financing type 2. Facility type 3. No. of classrooms 4. Gross area	5. Building area 6. No. of floors 7. No. of basements 8. Construction period
Cho et al, 2013.	1. Financing type 2. Gross area 3. Building area 4. Lot area	5. Underground area 6. Ground floor area 7. School type 8. No. of classrooms

선행연구들에서 주로 연면적, 건축면적, 대지면적, 지하층 수 혹은 지하면적, 발주방식, 학교구분, 교실 수, 공사기간이 변수로 사용된 것을 알 수 있다.

다음 Fig. 7은 코스트 모델링에 변수를 선택하기 위한 단계별 진행 7단계를 도식화한 것이다(Ferry et al., 1999; Park et al., 2003).




Fig. 7. Cost factor in Design planning Step

Ferry(1999)의 연구를 적용하여 선행연구에서 조사된 변수는 Table 3과 같이 분류 할 수 있다.

Table 3. Example of Application (Step 2, 3)

Step	Example of Application	
2	Space	gross area, no. of classrooms(normal and practice classroom), building area, lot area, underground area.
3	Elements	construction period

본 연구에서 사용된 실적 자료들은 모두 PQ발주 방식이다. 그러므로 발주방식은 변수로서 의미가 없다. 따라서 본 연구에서는 선행연구와 Ferry(1999)를 참고하여 연면적, 건축면적, 대지면적, 지하면적, 학교구분, 일반교실 수, 특별교실 수, 공사기간을 변수로서 선택한다.

입력 변수로 사용된 데이터는 S교육청에서 제공되는 자료가 사용되었으며, Table 4는 실적 데이터를 정리한 표이다.

Table 4. Data Summary

No.	Type	Gross Area (m <sup>2</sup> )	Lot Area (m <sup>2</sup> )	Building Area (m <sup>2</sup> )	Regular Classroom	Special Classroom	Underground Area (m <sup>2</sup> )	Construction Period (Days)	Total. Cost (One million)
A..01	high	15499	16695	4538	48	12	342	400	24263
A..02	mid	13686	16031	3767	41	14	421	420	22979
A..03	mid	13694	15001	3864	48	14	336	420	21613
A..04	high	16822	17542	4773	46	13	659	428	27129
A..05	high	16362	15067	4287	51	8	512	420	25787
A..06	mid	11720	15092	3272	34	7	495	434	18832
A..07	mid	13943	18928	3981	42	14	366	424	24221
A..08	mid	10864	21707	4116	34	8	353	390	19350
A..09	high	15781	16741	4423	50	10	456	390	26838
A..10	mid	13500	14320	4015	41	10	323	360	21770
A..11	high	16833	16900	5731	54	14	492	341	25909
A..12	high	18410	15850	5253	59	14	352	350	26520
A..13	high	15682	16700	5344	42	15	371	330	25115
A..14	high	16314	16700	4955	43	11	2228	342	24472
A..15	mid	14276	15397	4440	41	12	436	339	23151
A..16	mid	13865	14965	4304	29	18	594	252	21419
A..17	mid	14340	15500	4056	35	13	206	341	23797
A..18	mid	15174	15536	4507	41	12	342	33	23979

### 4. 공사비 예측 모델링

#### 4.1 건설공사비지수를 이용한 공사비 보정

실적 자료에 기록된 자료들은 각 연도가 상이하며 과거 시점들이기 때문에 현재 시점의 가치로 보정이 필요하다. 본 연구에서는 자료들의 보정을 위하여 한국건설기술연구원에서 개발한 건설공사비지수를 이용하여 보정한다.

건설공사비지수(Construction Cost Index)는 "건설공사에 투입되는 직접공사비를 대상으로 특정시점(한국은행의 생산자 물가지수)의 물가를 100으로 하여 재료, 노무, 장비 등 세부 투입자원에 대한 물가변동을 추정하기 위해 작성된 가공통계 자료"으로 정의하고 있다(KICT, 2004).

본 연구에서 적용된 공사비지수는 2010년을 특정 시점으로 발표된 공사비지수로 다음의 Table 5와 같다.

Table 5. Construction Cost Index by year

classification	january trends by year			
	2015	2016	2017	2018
construction cost index	114.2	113.4	120.4	125.8

#### 4.2 인공신경망(ANN)을 이용한 모델링

인공신경망 및 딥러닝 모델은 입력 값들이 극단적인 값 차이를 보이면 학습에 문제가 될 수 있다. 본 연구에서는 이런 문제를 방지하기 위하여 데이터를 표준화하고 학습

을 진행하였다. 표준화는 정규분포에서 평균을 빼고 표준편차로 나눈 것으로 데이터들의 평균을 0으로 맞춰 표준편차를 1로 만들어준다. 본 연구에 사용된 데이터는 변수의 특징상 상호 극적인 값 차이를 보이는 것이 있기에 표준화를 수행하였다. 모델의 더 정확한 학습을 위하여 학습과 검증 데이터를 별도로 설정하여 교차검증을 할 수가 있다. 총 18개의 데이터 중 11개를 학습용 데이터, 3개를 검증 데이터로 구분하며, 4개를 평가용 데이터로 하였다. 본 모델의 구조는 다층 퍼셉트론의 구성을 가지고 있으며, 하이퍼 파라미터를 활용하여 적절한 활성화 함수, 은닉층의 수, 은닉층 노드의 수, 소실 함수, 학습률, 최대 반복 학습 횟수, 모멘텀, Drop out 등을 찾게 하였다.

하이퍼 파라미터는 다양한 파라미터 설정 값을 이용하여 모델을 생성 할 것이며, 교차검증을 3회 실시하여 학습이 제대로 이루어졌는지 비교한다. 모델 선정 기준은 RMSE(Root Mean Square Error)로 하여 가장 낮은 수치를 보이는 파라미터 모델이 출력되게 하였다. RMSE는 평균 제곱근 오차로서 오차의 표준편차를 알 수 있는 통계적 수치이다. RMSE는 다음의 식과 같다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$$

$n$  = The number of data points

$Y_i$  = Represents observed values

$\hat{Y}_i$  = Represents predicted values

본 연구에서는 하이퍼 파라미터를 R과 Java를 연동하여 작성하였으며, 다음 Fig. 8과 같이 작성하였다.

하이퍼 파라미터로 선별된 ANN 모델로 평가 데이터를 예측하면, 다음 Table 7과 같다.

```

1 #Hyper Params
2 activation_opt <- c("Tanh", "Rectifier")
3 metric_opt <- c("AUTO", "deviance", "MSE")
4 loss_opt <- c("Automatic", "Quadratic", "Huber", "Absolute")
5 rho_opt <- c(0.5, 0.7, 0.9, 0.99)
6 epochs_opt <- c(500, 600, 700, 800, 900, 1000, 1200, 1500)
7 l1_opt <- c(0, 0.00001, 0.0001, 0.001, 0.01, 0.1)
8 l2_opt <- c(0, 0.00001, 0.0001, 0.001, 0.01, 0.1)
9 hyper_ANN <- list(hidden = list(c(1), c(2), c(3), c(4), c(5), c(6), c(7), c(8)),
10 activation = activation_opt,
11 rate = c(0.1, 0.01, 0.005, 0.001),
12 rate_annealing = c(1e-8, 1e-7, 1e-6, 1e-5),
13 stopping_metric = metric_opt,
14 input_dropout_ratio = c(0, 0.1, 0.2, 0.3),
15 loss = loss_opt,
16 rho = rho_opt,
17 momentum_start = c(0.8, 0.5),
18 momentum_stable = c(0.99, 0.8, 0.5),
19 epochs = epochs_opt,
20 epsilon = c(1e-10, 1e-8, 1e-6, 1e-4),
21 l1 = l1_opt,
22 l2 = l2_opt)
23 search_criteria <- list(strategy = "RandomDiscrete", max_models = 500,
24 stopping_tolerance = 0.001,
25 stopping_rounds = 20,
26 max_runtime_secs = 900)
27 deep_grid <- h2o.grid("deeplearning",
28 grid_id = "deep_grid",
29 x = x,
30 y = y,
31 standardize = TRUE,
32 training_frame = deep.train,
33 validation_frame = deep.valid,
34 seed = 1,
35 nfolds = 3,
36 hyper_params = hyper_ANN,
37 search_criteria = search_criteria)
38 grid_rmse <- h2o.getGrid(grid_id = "deep_grid",
39 sort_by = c("rmse"),
40 decreasing = FALSE)
41 print(grid_rmse)
42

```

Fig. 8. Hyper Parameter in R and Java

RMSE를 기준으로 하여 선택된 인공신경망(ANN)의 하이퍼 파라미터 결과는 다음 Table 6과 같다.

Table 6. Hyper-Parameter results (ANN)

ANN Model	Hyper-Parameter
Activation	Rectified Linear Unit
Epochs	503
Hidden Layer	[8]
Dropout ratio	0.2
Learning rate	0.01
Momentum	0.8
RMSE(Validation)	1046

하이퍼 파라미터로 선택된 ANN 모델은 반복학습 횟수가 503회이고, 활성화 함수는 ReLu가 적합한 것으로 나타났다. ANN은 은닉층을 단층으로 가지는 모델로 노드 수는 8개가 가장 적합한 것으로 나타났다.

다음 Fig. 9는 하이퍼 파라미터로 선별된 모델을 구축하고 평가 데이터의 공사비를 예측하기 위해 작성한 R 언어이다.

```

47 #ANN Model
48 best_ANN_model <- grid_rmse@model_ids[[1]]
49 ANN_model <- h2o.getModel(best_ANN_model)
50 ANN_model_perf <- h2o.performance(model = ANN_model, newdata = deep.test)
51 h2o.rmse(ANN_model_perf)
52 best_pred1 <- h2o.predict(ANN_model, newdata = deep.test)
53 best_pred1
54 summary(ANN_model)

```

Fig. 9. ANN Modeling by Hyper Parameter

Table 7. Error rate & RMSE of ANN model

ANN model	Error rate	RMSE
Test 1	0.32%	2115
Test 2	2.19%	
Test 3	19.6%	
Test 4	0.03%	
Average Error Rate	5.54%	

실제 공사비와 ANN 모델에서 예측된 공사비의 오차율은 평균 오차율로 나타내며, 평균 오차율의 식은 다음과 같다.

$$Error\ Rate(\%) = \frac{|DO - AO|}{DO} \times 100$$

$$Average\ Error\ Rate(\%) = \left( \sum_{i=1}^n |Error_i| \right) / n$$

DO = Desire Output

AO = Actual Network Output

Error<sub>i</sub> = "i" th Error Rate

4개의 평가 데이터로 예측된 공사비들의 평균 오차율이 5.54%이고, 평가 데이터에 의한 오차율 범위가 약 0.03%에서 19.5%까지 상당히 넓은 편이다. 이는 분산을 넓게 하여, RMSE를 높게 만드는 요인이다.

### 4.3 딥러닝(DNN, DBN)을 이용한 모델

#### 1) DNN

본 연구의 DNN 모델은 인공신경망(ANN)과 같이 하이퍼 파라미터를 적용하여 가장 적합한 파라미터 설정을 선택하게 하였다. DNN은 은닉층이 다수로 형성되어 심층 학습을 하는 모델이다. 하이퍼 파라미터는 DNN에 맞게 은닉층을 다수 선택할 것이고, RMSE 기준으로 학습이 가장 탁월한 노드 수를 설정한다.

DNN의 하이퍼 파라미터 결과는 다음 Table 8과 같다.

Table 8. Hyper-Parameter results (DNN)

DNN Model	Hyper-Parameter
Activation	Hyperbolic Tangent
Epochs	1503
Hidden Layer	[10, 10, 10]
dropout ratio	0
Learning rate	0.1
Momentum	0.8
RMSE(Validation)	1589

하이퍼 파라미터로 설정된 DNN 모델은 TanH 활성화 함수를 가지고, 반복학습 횟수는 1503회로 나타났다. 해당 DNN 모델은 은닉층이 3개의 층으로 구성되어 각 10개의 노드를 가진다. 본 모델로 평가 데이터를 예측한 결과, 다음 Table 9와 같다.

Table 9. Error rate & RMSE of DNN model

DNN model	Error rate	RMSE
Test 1	0.38%	926
Test 2	9.20%	
Test 3	5.15%	
Test 4	1.02%	
Average Error Rate	3.94%	

평가 데이터로 예측된 공사비는 평균 오차율이 3.94%이지만 오차율 범위가 0.4%에서 9.2%로 넓은 편이다.

## 2) DBN

DBN 모델은 DNN과 같은 파라미터를 적용하였다. 단, 이루어지는 알고리즘이 다르기에 은닉층의 설정은 각기 다르게 하여 결과를 비교하였다. 다음 Table 10은 DBN 모델들을 구축하여 비교한 후, RMSE의 수치를 작성한 표이다.

Table 10. Hidden layer test of DBN model

Hidden Layer	RMSE
C (10,10,10)	820.1
C (20,20,20)	760.4
C (30,30,30)	601.7
C (40,40,40)	1358.4
C (50,50,50)	1436.1
C (60,60,60)	1511.0
C (70,70,70)	1818.3
C (80,80,80)	1401.6
C (90,90,90)	1859.2
C (100,100,100)	1966.5

각 은닉층 노드 수가 30인 모델의 RMSE가 601.7로 오차가 가장 낮으므로 해당 모델을 선택한다. 다음 Table 11은 해당 DBN 모델을 평가데이터로 예측한 표이다.

Table 11 Error rate & RMSE of DBN model

C (30,30,30)	DBN model	Error rate	RMSE
	Test 1	4.11%	601.7
	Test 2	2.26%	
	Test 3	1.81%	
	Test 4	1.03%	
	Average Error Rate	2.30%	

오차율은 1%에서 4%로 비교적 분산된 정도가 넓지 않은 것으로 보였다. 이는 실제값과 예측값이 전체적으로 차이가 균등하다는 것을 알 수가 있다.

## 4.4 모델별 비교 및 평가

본 연구에서는 스마트 교육을 운영하고 있는 S교육청의 중·고등학교를 대상으로 총공사비를 예측하였다. 구축된 모델은 ANN, DNN, DBN로 인공지능경망과 딥러닝으로 분류된다. 평가 결과는 Table 12와 같다.

Table 12. Comparison of DBN, DNN, ANN

Classification	RMSE	Average Error Rate
DBN Model	601.7	2.30%
DNN Model	926	3.94%
ANN Model	2115	5.54%

구축된 3가지 모델의 평균오차율이 미국건축협회 AACE (2016)에서 권고하는 기획·설계단계의 견적 오차 범위 ( $\pm 15\%$ ) 내에 존재한다. 그 중 DBN의 평균오차율이 2.3%로 가장 유효한 것으로 판단된다.

RMSE는 예측값의 오차에 대한 표준편차를 나타내는 통계적 수치이다. 3가지 모델 중 역시 DBN 모델이 가장 적은 RMSE (601.7)값을 갖는다. 이는 평가데이터의 평균 공사비(238억)를 기준으로 삼을 경우 예측값이 약 6억 정도로 오차의 편차를 갖는 것을 의미한다. 이 역시 AACE의 권고 오차 범위 안에 있으므로 예측값이 유효한 것으로 판단된다. 그러므로 3가지 모델 중 DBN이 가장 적은 평균오차율과 RMSE 값을 가지므로 최적의 모델로 선정되었다.

## 5. 결론

기획·설계단계의 기존 공사비 예측에는 단위면적당 공사비가 이용되었지만, 실적 사례가 적은 공사비 예측에는 적합하지 않다고 판단되었다. 본 연구에서는 인공지능경망, DNN, DBN을 활용하여 적은 사례를 가진 스마트 교육 학교 신축 프로젝트의 기획·설계단계에서 공사비 예측이 유용한 모델을 구축 및 비교하였다. 인공지능경망 모델은 RMSE가 2115로 비교적 높았으며 넓은 오차 범위를 가졌다. 이는 오버피팅이 발생한 것으로 생각되며 이로 인해 오차의 편차가 높아진 것으로 판단된다. 인공지능경망 모델은 하이퍼 파라미터를 이용하여 최대한 적합한 파라미터가 선정되었기 때문에 한정된 데이터가 문제를 발생시킨 것으로 생각된다. DNN 모델은 3.94%의 평균 오차율을 보



이며 상대적으로 낮게 나타났지만, 오차범위가 0.38%에서 9.2%까지 나타난다. 깊은 학습이 가능했던 DNN 모델이 ANN 모델보다 오차범위는 개선되었으나, 여전히 오차범위가 비교적 넓은 편이다. ANN과 DNN 모델은 모두 오버피팅이 발생한 것으로 보이며 오차범위가 넓어 실제 데이터에 사용하기에는 실용성이 떨어진다. 이는 적은 실적 자료로 인한 문제로 보인다. DBN 모델의 경우 평균 오차율이 2.3%로 가장 낮게 나타났고, RMSE가 601.7로 낮아 오차 범위도 가장 안정적이다. DBN 모델은 초기 가중치를 고정하여 오버피팅 문제를 방지한 모델이기 때문에 한정된 데이터에도 비교적 정밀한 예측이 가능한 것으로 판단된다.

기존 연구로 많이 사용된 인공신경망 모델은 한정된 데이터에 오버피팅이 발생되어 정확한 예측이 어려웠다. DBN 모델은 생산모델로서 비교적 적은 데이터에 유용하고 오버피팅 문제를 보완한 모델이기 때문에 비교적 낮은 오차를 나타냈다. 본 연구에서는 DBN 모델이 적은 사례를 가지는 교육시설 프로젝트에 다른 모델과 비교하여 더 유효할 것으로 예상된다.

상세단가견적이 산출되기까지는 많은 시간이 걸리지만, 이를 초기단계에서 예측함으로써 의사결정 기간을 초기단계로 확대하고 사업 위험성을 미리 대비할 수가 있다. 본 연구의 결과는 스마트 교육과 같은 적은 실적 사례를 가지는 사업도 기획·설계단계에서 공사비를 예측함으로써, 효율적이고 합리적인 의사결정을 지원할 것으로 예상된다.

## 감사의 글

이 논문은 2017학년도 홍익대학교 학술연구진흥비에 의하여 지원되었습니다.

## References

1. AACE. (2016). "Cost Estimate Classification System" AACE International Recommended Practice, No. 18R-97.
2. Chang, D. H. (2017). "Spatial Distinction and Site Planning of Newly-established Schools in Sejong City by Educational Curriculum and Administrative Clients" master's dissertation, Cheongju University.
3. Chen, X. (2015) "Stock Price Prediction Via Deep Belief Networks" Doctoral dissertation, University of New Brunswick.
4. Cho, H. G., and Kim, K. G. (2013). "A comparison of construction cost estimation using multiple regression analysis and neural network in elementary school project." Journal of the Korea Institute of Building Construction., 13(1), pp.66-74.
5. Ferry, D. J., and Brandon, P. S. (1999). "Cost planning of buildings" Fifth Edition, GRANADA.
6. Goki, S. (2016). "Deep Learning from Scratch" Hanbit Publishing Network Inc.
7. Han, H. D., and Kim, J. H. and Yoon, J. H. and Seo, J. W. (2011). "Road Construction Cost Estimation Model in the Planning Phase Using Artificial Neural Network" Korean Society of Civil Engineers, 31(6D), pp.829-837.
8. Hinton, G. E. (2009). "Deep belief networks" Scholarpedia, 4(5), pp.5947.
9. Hinton, G. E., and Osindero, S., and Teh, Y. W. (2006). "A fast learning algorithm for deep belief nets" Neural computation, 18(7), pp.1527-1554.
10. Hira, N. A., and Walter, J. C. (1988). "Estimating: from Concept to Completion" Prentice Hall Inc.
11. Jang, B. T. (2017). "Jang professor's Deep Learning" Hongrung Publishing Company.
12. Josh, P., and Adam, G. (2017). "Deep Learning: A Practitioner's Approach" O'Reilly Media Inc.
13. Kang, I. S., and Mun, J. W., and Park, J. C. (2017). "Recent Research Trends of Artificial Intelligent Machine Learning in Architectural Field - Review of Domestic and International Journal Papers -" Journal of the Architectural Institute of Korea Structure & Construction., 33(4), pp.63-68.
14. KICT. (2004) "Development of Construction Cost Index" KOREA INSTITUTE of CIVIL ENGINEERING & BUILDING TECHNOLOGY.
15. Kim, M. H. (2017). "Construct information system construction and open system development plan" Korean Public Procurement Service.
16. Kim, S. K., and Son, J. H. (2008). "A Study on the Analysis and Estimation of the Construction Cost by Using Artificial Neural Network in the BTL Projects for Educational Facilities" Journal of the Architectural Institute of Korea Structure & Construction., 24(6), pp.135-142.
17. Korea On-line E-procurement System, <http://g2b.go.kr/index.jsp>, Site accessed September 21, 2018
18. Larochelle, H., and Bengio, Y., and Louradour, J., and Lamblin, P. (2009). "Exploring strategies for training deep neural networks" Journal of machine learning

- research, 10(Jan), pp.1-40.
19. Park, H. Y., and Song, Y. S. and Kim, S. K. (2003). "A Study on the Standard Database for Cost Modelling of Apartment Housing Projects" Journal of the Architectural Institute of Korea Structure & Construction, 19(6), pp.177-184.
  20. Rashid, T. (2016). "Make Your Own Neural Network" Createspace Independent Publishing Platform.
  21. Ribeiro, B., and Lopes, N. (2011). "Deep belief networks for financial prediction" In International Conference on Neural Information Processing., Springer Berlin Heidelberg, pp.766-773.
  22. Rosenblatt, F. (1958). "The perceptron: a probabilistic model for information storage and organization in the brain" Psychological review, 65(6), pp.386.
  23. Sejong City Office of Education, <http://sje.go.kr/sje>, Site accessed September 21, 2018
  24. Shin, J. M., and Kim, G. H. (2012). "A study on predicting construction cost of educational building project at early stage using support vector machine technique" The journal of Sustainable Design and Educational Environment Research, 11(3), pp.46-54.
  25. Timothy, M. (2015). "Deep Belief Nets in C++ and Cuda C, Volume 1, Restricted Boltzmann Machines and Supervised Feedforward Networks" CreateSpace Inc.

접수 2018. 11. 15  
1차심사완료 2018. 11. 19  
2차심사완료 2018. 11. 29  
게재확정 2018. 11. 29