

Research Paper

양방향 DNN 해석을 이용한 삼성분계 콘크리트의 배합 산정에 관한 연구

A Study on the Calculation of Ternary Concrete Mixing using Bidirectional DNN Analysis

최주희¹ · 고민삼² · 이한승^{3*}

Choi, Ju-Hee¹ · Ko, Min-Sam² · Lee, Han-Seung^{3*}

¹Master's Course, Department of Smart-City Engineering, Hanyang University, Sangnok-Gu, Ansan-si, Gyeonggi-do, 15588, Korea

²Professor, Department of ICT, Hanyang University, Sangnok-Gu, Ansan-si, Gyeonggi-do, 15588, Korea

³Professor, Department of Architectural Engineering, Hanyang University, Sangnok-Gu, Ansan-si, Gyeonggi-do, 15588, Korea

*Corresponding author

Lee, Han-Seung
Tel : 82-31-400-5181
E-mail :
ercleehs@hanyang.ac.kr

Received : October 20, 2022

Revised : December 1, 2022

Accepted : December 4, 2022

ABSTRACT

The concrete mix design and compressive strength evaluation are used as basic data for the durability of sustainable structures. However, the recent diversification of mixing factors has created difficulties in calculating the correct mixing factor or setting the reference value concrete mixing design. The purpose of this study is to design a predictive model of bidirectional analysis that calculates the mixing elements of ternary concrete using deep learning, one of the artificial intelligence techniques. For the DNN-based predictive model for calculating the concrete mixing factor, performance evaluation and comparison were performed using a total of 8 models with the number of layers and the number of hidden neurons as variables. The combination calculation result was output. As a result of the model's performance evaluation, an average error rate of about 1.423% for the concrete compressive strength factor was achieved. and an average MAPE error of 8.22% for the prediction of the ternary concrete mixing factor was satisfied. Through comparing the performance evaluation for each structure of the DNN model, the DNN5L-2048 model showed the highest performance for all compounding factors. Using the learned DNN model, the prediction of the ternary concrete formulation table with the required compressive strength of 30 and 50 MPa was carried out. The verification process through the expansion of the data set for learning and a comparison between the actual concrete mix table and the DNN model output concrete mix table is necessary.

Keywords : deep-learning, concrete mixing proportions, concrete mix design, strength prediction

1. 서론

건축물의 주요 구조 재료로서 사용되는 콘크리트는 설계압축강도를 만족시키기 위한 배합설계가 중요시된다. 이러한 콘크리트 배합설계는 설계압축강도로부터 소요배합강도를 산정하고 이를 만족시키기 위한 사용재료의 비율을 시공성 및 내구성을 고려하여 실시하게 된다. 그러나, 배합설계는 사용재료에 따라 무수한 변수가 존재하며 배합요소의 다변화로 인해 정확한 검정이 간단하지 않다[1]. 또한 사용재료의 물성, 통계적 관리상태 및 배합산정표 등의 데이터가 공개되어 있지 않아 콘크리트 압축강도를 통한 예측이나 실질적인 배합산정은 매우 어려운 실정이다.

최근에는 공개되거나 논문 등을 통해 발표된 콘크리트 배합 데이터를 사용하여 콘크리트의 압축강도나 염소이온 확산계수를 딥러닝 기반으로 예측하는 연구가 실시되고 있다. 그러나, 이러한 연구는 대부분 배합 인자 및 사용재료를 입력데이터



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.

로 하여 콘크리트의 강도나 염소이온 확산계수를 산정하는 것으로, 콘크리트 소요압축강도를 만족시키기 위한 배합 인자 및 사용재료 예측에 대한 연구는 전무한 실정이다.

따라서 본 연구에서는 기존의 콘크리트 배합 인자 등의 사용재료 데이터로부터 강도만을 예측하던 연구와 달리, 딥러닝 기술을 사용하여 소요압축강도를 만족시키기 위한 삼성분계 콘크리트에 대한 사용재료의 배합비율을 예측하는 것을 목적으로 하였다. 이를 위해 본 연구에서는 역전파 및 순전파 기법을 적용한 양방향적 DNN(Deep Neural Network) 모델 설계를 진행하고, DNN 모델에 대한 성능평가를 실시하여 최종적으로 삼성분계 콘크리트 배합표 예측을 수행하였다.

2. 양방향 DNN 해석에 대한 이론적 고찰

2.1 DNN(Deep Neural Network)의 구성

DNN은 복잡한 수준의 인공신경망(ANN, Artificial Neural Network) 모델을 뜻하며, 입력값의 정보를 추출하여 여러 개의 비선형 분석기법의 조합을 통해 학습을 수행하는 딥러닝 모델의 일종이다[2]. 은닉층과 소수의 은닉 뉴런으로 이루어진 단순한 형태의 인공신경망과 달리 DNN 모델은 다수의 은닉 뉴런으로 구성된 다층의 은닉층으로 이루어져 있으며, 값의 입력을 받는 입력층과 값을 출력하는 출력층, 입력층과 출력층 사이에 다중 비선형 구조로 이루어진 은닉층으로 구성되어 있다[3]. 이러한 일반적인 DNN의 구조는 Figure 1에서 나타난다.




Figure 1. DNN model architecture




Figure 2. Diagram of the neuron output calculation process

DNN을 포함한 인공신경망 모델의 학습은 입력값에 가중치를 곱하여 편향을 더한 값을 출력하는 학습 과정을 거치면서 가중치 및 편향을 조절하여 출력값과 실제값 간의 오류를 줄여나가는 것을 의미한다. 이때, 활성화 함수는 가중치 및 편향을 통해 연산이 이루어진 신호의 조합을 출력값으로 변환시키는 역할을 하는 함수로서, 신호의 범위를 조절하여 이상치를 걸러낼 수 있도록 하는 역할을 수행한다[3]. 인공신경망 모델은 이러한 연산을 이어나가면서 그에 따른 가중치, 편향 등의 매개 변수들을 조절해나가는 과정으로 학습을 수행한다. Figure 2는 인공신경망 모델 내부 뉴런의 입력값과 출력값 사이의 상관 관계를 도식화한 것을 나타내며, 식 (1)은 이를 수식화하여 나타낸 것이다.

$$O = f\left(\sum_{j=1}^n (w_j x_j) + b\right) \tag{1}$$

O : 은닉뉴런의 출력

x_j : 입력값

- w_j : 입력값의 가중치
- b : 편향
- f : 활성화 함수

역전파(Back-Propagation)는 기존의 단순한 순전파(Forward-Propagation) 구조가 복잡한 문제를 해결하지 못한다는 한계점을 기점으로 주장된 입력값의 패턴 분류를 위해 인공신경망 모델에 적용하는 방법으로서, 입력값과 결과값을 지정한 후 학습을 진행하여 훈련과정에서 계산된 출력값과 실제값 간의 계산을 통해 오류를 조정하면서 오차를 0에 근사시키는 방법이며, 본 연구의 경우 모델 학습 시에는 역전파 과정, 모델 예측 시에는 순전파 과정을 통해 이루어진다[4].

2.2 DNN 모델 성능개선 기법

DNN 모델의 복잡도에 비해 데이터 세트가 비교적 적을 경우, DNN 모델 학습 중 가중치가 0으로 수렴하여 사라지면서 학습이 중지되는 Vanishing Gradient가 발생한다[5]. 본 연구에서는 이러한 문제점 개선 및 DNN 모델의 성능 개선을 위하여 Figure 3과 같은 미분을 이용하여 손실 즉, 오차가 낮아지는 방향으로 최적의 특성값을 탐색하는 경사하강법(Gradient Descent Algorithm)을 사용하였다. 또한, 드롭아웃(Dropout), 가중치 초기화(Weight initialization), 배치 정규화(Batch Normalization) 등의 기법을 적용하여 Vanishing Gradient를 방지함으로써 모델 성능을 개선하고자 하였으며, Figure 4에서는 본 연구에서 사용된 성능개선 기법에 대한 개요를 나타내었다.

또한, 단일 학습-평가 데이터 세트로 평가를 수행할 시 학습 결과가 특정 학습-평가 데이터 세트 조합에 치중되어 모델의 일반적인 성능과 차이가 날 수 있다. 따라서 본 연구에서 보다 일반적인 상황에서의 모델 성능을 평가하기 위해서 전체 데이터 세트를 10개의 학습-평가 그룹으로 나누어 학습을 10번 수행하여 모든 데이터에 대하여 학습 및 검증이 이루어지도록 하는 ‘10-Fold Cross Validation’ 기법을 사용하였다.




Figure 3. Gradient descent algorithm

- Dropout**
 Omitting a certain percentage of nodes and randomly connecting the remaining nodes to prevent overfitting
- Weight Initialization**
 Initialize the weights of model to prevent convergence to zero to prevent the activation value of each layer converges to 0
- Batch Normalization**
 Adjust the activation values of each layer to be properly distributed to improve speed and prevent overfitting

Improving the performance of DNN model

Figure 4. Performance improvement techniques

2.3 DNN 모델 성능평가 방법

DNN 모델과 같은 비선형의 회귀모델의 성능 평가를 위한 지표는 여러 가지가 존재하나, 본 연구에서는 DNN 모델의 성능평가 지표로서 Table 1과 같이 MSE(Mean Squared Error), MAPE(Mean Absolute Percentage Error), 오류율의 총 3가지의 회귀분석을 위한 성능평가 지표를 사용하였다. MSE 는 실제값과 예측값의 차이를 제공하여 평균화시킨 성능평가 지표이

며, 제공하여 평균화하는 과정에 의해서 이상치에 더 민감하게 반응하기 때문에 데이터 세트의 이상치를 감지해야 할 필요가 있을 때 주로 사용되는 성능평가 지표이다. MAPE는 모든 실제값과 예측값의 차이의 합으로서 직관적인 차이를 나타내는 성능평가 지표로서, 이상치에 있어 MSE에 비해 덜 민감하게 반응하는 형상을 보인다[6]. 오류율은 전체 데이터 중 잘못된 분류한 비율을 나타내는 성능평가 지표로서 주로 이진분류모델에서 사용되나 직관적인 모델의 성능평가가 가능하다는 특징이 있다. 또한, 모델 학습과정 중 학습 경향을 파악하기 위한 모델 성능평가로서 손실값 즉, 오류율을 평가하였으며, 매 학습 종료시점에서 학습 시, 검증 시의 오류율을 분석하여 DNN 모델의 성능 평가를 진행하였다.

Table 1. Evaluation metrics

Evaluation metrics	Function
MSE(Mean Squared Error)	$\frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2$
MAPE(Mean Absolute Percentage Error), %	$\frac{100}{n} \sum_{i=1}^n \left \frac{y^{(i)} - \hat{y}^{(i)}}{y^{(i)}} \right $
Error Rate, %	$\frac{1}{n} \sum_{i=1}^n \left \frac{y^{(i)} - \hat{y}^{(i)}}{y^{(i)}} \right $

$y^{(i)}$ = input value, $\hat{y}^{(i)}$ = predicted value

3. 콘크리트 배합 산정을 위한 양방향 DNN 모델 구축

3.1 데이터 세트 구축

본 연구의 콘크리트 배합요소 예측 모델 설계를 위한 데이터 세트로 플라이애쉬, 고로슬래그를 사용한 삼성분계 콘크리트 데이터 총 812개를 사용하였다. 콘크리트 데이터는 W/B 20~72%의 국내 레미콘 플랜트 현장배합 데이터 및 국내 5개 학회 최근 게재논문 데이터로 구성되어 있으며, 데이터 세트에 대한 기본적인 통계표는 Table 2와 같다. 본 연구의 데이터 세트는 물(water), 시멘트(cement), 잔골재(s), 굵은골재(g), 플라이애쉬(fly), 고로슬래그(bfs), 양생온도, 양생습도, 압축강도의 총 9가지 인자로 구성되어 있으며, 이 중 압축강도를 제외한 8가지 인자를 DNN 모델의 입력값으로 설정하였으며 압축강도 인자를 DNN 모델의 출력값으로 설정하여 사용하였다. 이 때, DNN 학습 시 모델이 일정 데이터에 대해 편향되게 학습이 진행되는 것을 방지하기 위하여 데이터 세트의 통계값에 따라 DNN 모델의 학습 시에 사용되는 입력 초기값을 설정하였다. 입력 초기값의 설정 시, 타겟으로 설정된 압축강도에 가장 근접한 데이터 10개를 선정하여 이에 대한 평균값을 각각의 인자의

Table 2. Ternary concrete data set

	Mean	SD	Median	Min	Max
Water(kg/m ³)	173.8	12.41	171.0	124.3	210.0
Cement(kg/m ³)	214.6	32.27	206.0	66.0	408.0
Sand(kg/m ³)	838.1	69.19	841.0	600.0	1056.0
g(kg/m ³)	915.9	43.56	921.0	765.0	1103.0
Fly-ash(kg/m ³)	56.2	14.37	56.0	20.0	180.0
Blast-furnance slag(kg/m ³)	72.8	15.61	72.0	30.0	196.0
Curing temperature(°C)	20.0	0.74	20.0	5.0	20.0
Curing humidity(%)	99.2	5.56	100.0	60.0	100.0
Compressive strength(MPa)	21.9	5.70	20.4	16.1	80.0

입력 초기값으로 설정하였으며, 양생온도 및 양생습도 인자에 대해서는 실험실 환경의 수증양생을 고정하기 위하여 각각의 입력 초기값을 통계표 상에서 최대값으로 나타나는 20, 100 값으로 설정하였다.

또한, 본 연구의 데이터 세트 내 인자별 값 범위가 다양하게 나타나기 때문에 이에 따른 모델의 가중치 학습 오류 등의 모델의 성능 저하를 방지하기 위하여 인자별 값 범위를 일정하게 조절하는 데이터 전처리 기법인 정규화를 사용하였다. 데이터 세트의 인자별로 식 (2)의 ‘MinMaxScaler’ 정규화 공식을 사용하여 데이터 정규화 작업을 거쳐 인자 값 범위가 0~1 사이 값의 일정한 범위를 가지도록 데이터 전처리 과정을 수행하였다.

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \tag{2}$$

- X' : 정규화된 입력값
- X : 입력값
- X_{min} : 입력값 중 최소값
- X_{max} : 입력값 중 최대값

3.2 양방향 DNN 모델 설계

Figure 5는 본 연구의 DNN 모델의 예측 과정을 나타낸 것으로, 본 연구의 DNN 모델은 크게 두 단계로 나누어져 있으며 이러한 단계들은 개별적이지 않은 하나의 과정으로 수행된다. 또한, 단계에 따라 도출되는 값 및 역할이 상이하게 나타나며, 종합적인 모델의 성능평가는 두 단계를 종합적으로 성능평가를 수행하였다.

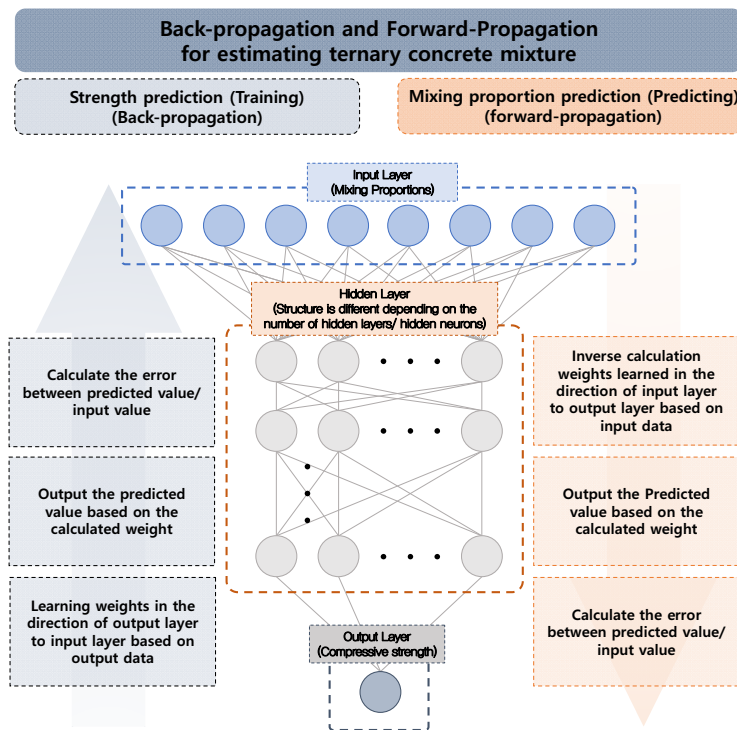


Figure 5. DNN model flow chart for predicting concrete strength and mixing proportions

먼저 강도 예측단계에서는 DNN 모델의 가중치 학습을 진행하여 출력층에서 입력층으로 향하는 방향으로 가중치 계산, 즉 학습을 진행한다. 이후, 계산된 가중치를 기반으로 예측되는 출력값을 출력하여 예측된 출력값과 실제 출력값 간의 오차를 계산 및 이를 줄여나가는 방향으로 학습을 반복하며 출력값으로는 강도 예측값이 도출되게 된다. 다음 배합 인자 예측단계는 강도 예측단계에서 학습이 이루어졌던 가중치를 기반으로 출력값에 따른 입력값 즉, 배합요소를 예측하는 단계로서 입력층에서 출력층의 방향으로 학습 시 도출된 가중치를 순방향으로 계산하여 이에 따른 배합 인자 예측값을 도출하였다. 모델의 성능평가는 강도 예측 및 배합 인자 예측단계를 통해 도출된 예측된 강도값과 예측된 배합 인자 값들과 실제 데이터 세트 값 간의 오차를 통해 진행된다. 모델의 성능평가를 위한 지표로서 2.3장에서 설명된 총 3가지의 성능평가 지표를 사용하여 분석하여, 각 모델의 구조에 따른 성능차이를 비교 및 평가를 진행하였다.

본 연구의 DNN 모델 구조는 Figure 6에서 나타나듯이 각 은닉층마다 배치정규화, 활성화함수, 가중치 초기화, 드롭아웃 과정을 반복하도록 설계하였다. 입력층과 출력층 사이의 과정을 epoch 횟수에 따라 반복하여 학습 종료에 도달하는 것을 1회 학습한 것으로 하여 10-Fold Cross Validation에 따라 총 10회 반복적인 학습을 수행하였다.

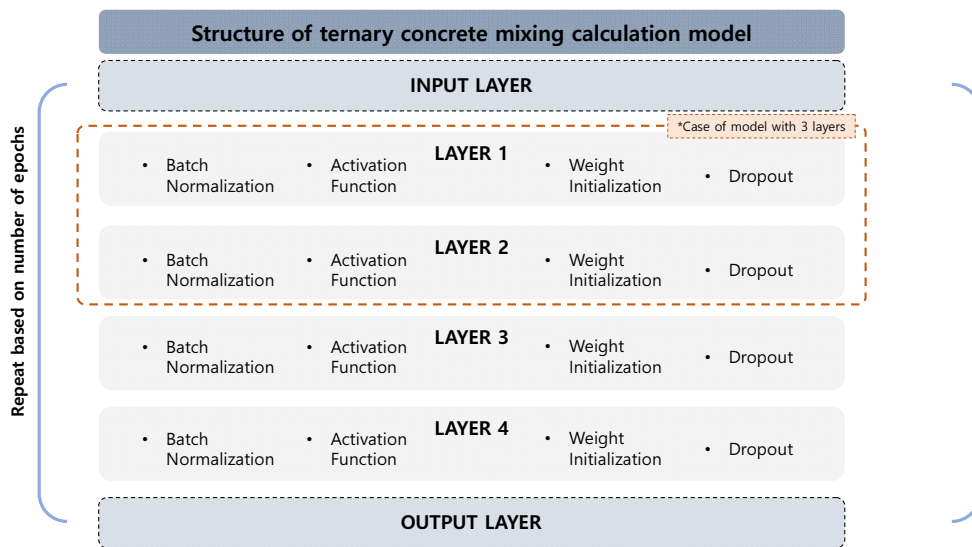


Figure 6. DNN model structure for prediction of ternary concrete mixing proportions

DNN 모델 구현을 위한 언어로 파이썬(Python 3.7.12)을 사용하였으며, 파이썬 개발환경으로 아나콘다(Anaconda)를 기반으로 하는 주피터 랩(Jupyter Lab 3.3.2)을 사용하였다. 본 연구의 DNN 모델의 분석 변수 및 분석 수준은 Table 3과 같다. DNN 모델 학습을 위한 Validation 데이터는 10-Fold Cross Validation 기법을 적용하여 전체 데이터의 10%를 사용하였다. DNN 모델은 층 수를 각각 3, 5, 은닉층 내 은닉뉴런 수를 각각 256, 512, 1024, 2048로 하여 총 8개의 모델을 설계하였으며, 모든 모델에 대하여 공통적으로 한 번의 학습 시 사용되는 데이터의 개수인 Batch size를 32, 최적화 알고리즘으로 사용된 Adam의 학습률을 0.001, 모든 데이터에 대한 학습 수인 epoch를 2000으로 적용하였다. 이 때, 모델 학습 중 가장 낮은 오류율을 나타낸 epoch로부터 400 이상으로 벗어났을 경우 또는 epoch가 2000에 도달했을 경우 모델 학습이 중지되도록 설정하였다. 또한, DNN 모델 학습이 특정값에 편향되지 않도록 모델 학습 시 입력되는 초기값은 각 인자별 평균값으로 설정하였으며, 예외로 양생온도 및 습도 인자에 있어 실험실 환경 내 수중양생 기반의 예측값을 출력하기 위해 각 인자의 최대값인 20과 100을 입력 초기값으로 설정하였다.

Table 3. Analysis condition of parameter in DNN model

Analysis factor	Analysis level
Validation Ratio	10%*
Layer Number	3, 5
Dense	256, 512, 1024, 2048
Batch Size	32
Activation Function	relu
Lerning Rate	0.001
Dropout Rate	0.1
Training Steps(epoch)	0~2000**
Evaluation Metrics(in Predicting)	MSE, MAPE, error rate
Evaluation Metrics(in Training)	loss, MSE, val_loss, val_MSE

*10-fold Cross Validation

**Stop the training when epoch exceeds(epoch representing the maximum accuracy)+400 or reaches 2000.

4. 콘크리트 배합 산정을 위한 양방향 DNN 모델 성능평가

4.1 본 연구 개발 양방향 DNN 모델의 학습성능 비교 평가

각각 학습데이터에 대한 손실값 즉, 오류율을 ‘Loss’, 검증데이터에 대한 손실값을 ‘Val_Loss’로 나타내었으며, 모든 손실값은 모델 구조 중의 손실함수로서 설정된 MSE에 기반하여 측정되었다. Figure 7은 학습 진행 중의 학습횟수에 따른 손실값 변화를 그래프로 나타낸 것으로, 손실값은 10-fold Cross Validation에 따라 10회 학습된 결과의 평균값으로 계산하였다. 각 모델에 대하여 약 600~2000회의 학습이 진행되었으나 200회 이후로는 미비한 하락세를 보이며 최종값에 수렴하였으며, 이러한 최종 수렴 손실값은 평균 5.39463, 10.7798을 나타내었다. 가장 손실값이 낮은 모델은 5L-2048N 모델로 손실값은 각각 4.808698와 9.255496으로 나타났다. 학습 과정 시의 데이터에 대한 모델의 성능은 모델의 은닉층 수가 많아질수록, 은닉 뉴런의 수가 많아질수록 손실값이 낮게 나타났으며 손실값 그래프에서 높은 경사를 나타내어 비교적 적은 학습 횟수에서 DNN 모델의 낮은 오차를 나타내어 모델 학습을 종료하였으나, 빠른 손실값 하락 이후 손실값의 변동을 나타내었다. 이와 같이, 복잡한 모델의 경우 비교적 적은 학습 횟수를 통해 학습이 가능하였으나 많은 은닉층 및 은닉뉴런 수에 의해 비교적 한 번 학습 시의 학습 시간이 길게 나타나는 것을 확인하였다. 이에 따라 학습 횟수 및 학습 시간에 따른 모델 구조의 최적화가 필요할 것으로 판단된다.

4.2 양방향 DNN 모델을 통한 콘크리트 배합산정 성능 평가

수집된 812개의 콘크리트 배합 데이터에 대하여 배합요소 및 압축강도의 총 9가지 인자에 대한 실제값 및 예측값은 서로 상호대응하게 출력된다. Table 4는 DNN 모델을 통해 역방향 해석을 적용한 콘크리트 압축강도의 예측값 중 예시로서 DNN3L-256 모델의 출력값을 일부를 나타낸 것으로, 표에서 왼쪽의 9가지 인자가 기존 데이터 세트 상의 데이터를 의미하며 오른쪽의 9가지 인자가 본 연구를 통해 도출해낸 예측값을 의미한다. 이러한 출력 결과는 실제값과 모델의 예측값을 기반으로 성능평가 척도를 사용한 모델의 성능평가를 위해 사용되었다. 이 때, 모델 학습 시에 재료의 물성 정보가 입력되지 않아 추후 입력 인자의 추가를 통해 결과로서 출력된 예측값에 대한 신뢰성을 향상시켜야 할 것으로 판단된다.

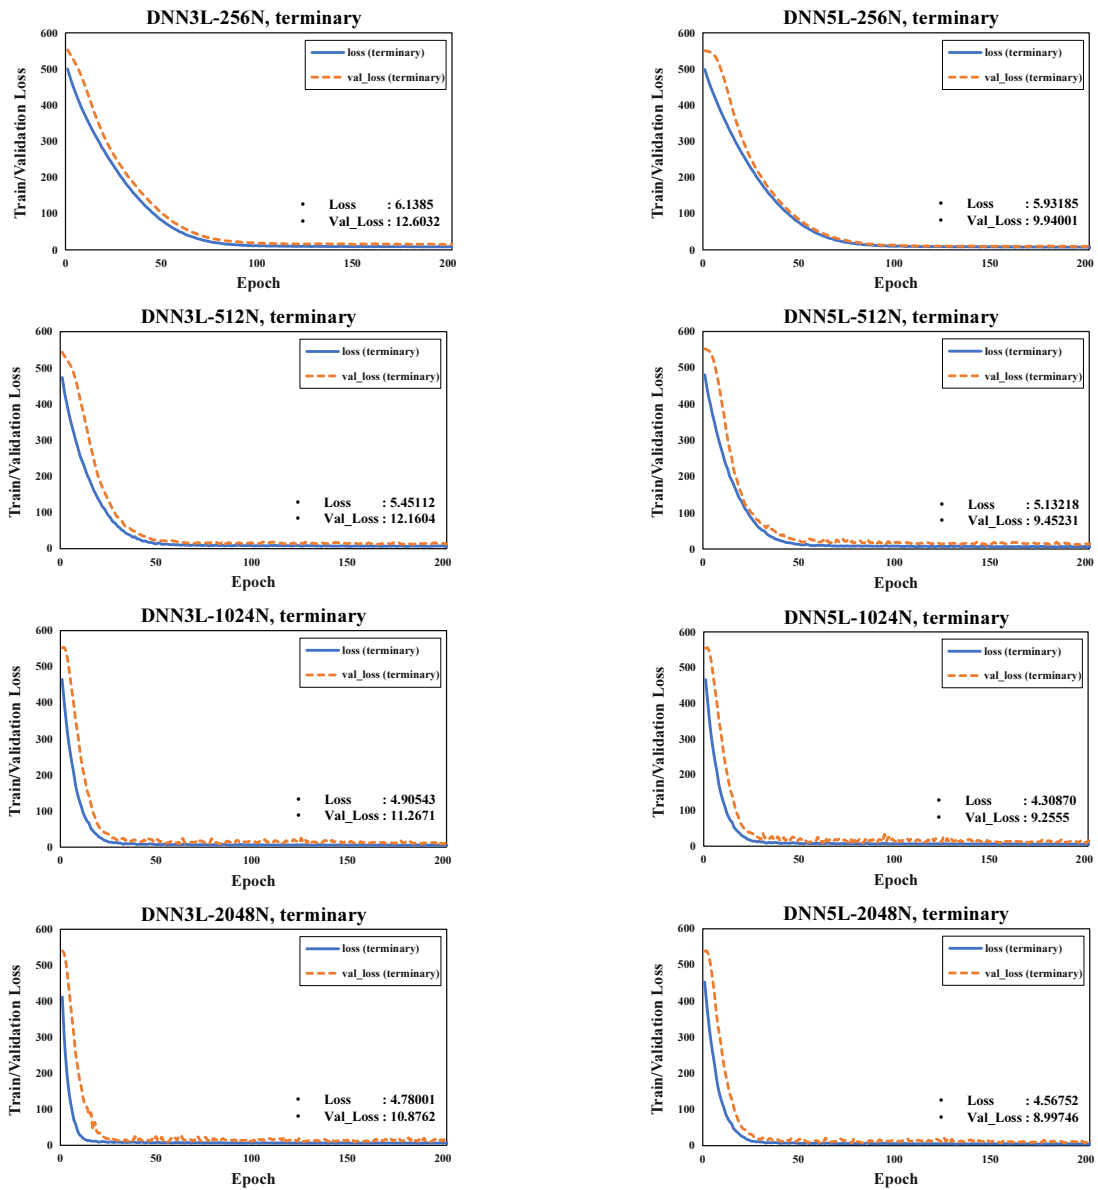


Figure 7. Loss value change during training by model structure

Table 4. Input value and predicted value results example of DNN3L-256 model

Concrete Mixing Data(Input value)									Concrete Mixing Data of DNN(Predicted value)								
w	c	s	g	fly	bfs	t	h	taget	pred_target	pred_w	pred_c	pred_s	pred_g	pred_fly	pred_bfs	pred_t	pred_h
160	214	840	934	51	75	20	100	29.174	29.172	168.650	241.127	827.237	923.840	64.804	83.895	20.010	99.031
161	199	863	930	47	70	20	100	23.912	23.905	173.989	221.638	830.500	926.691	55.918	72.527	20.000	99.524
159	213	825	949	51	74	20	100	24.265	24.237	177.788	225.835	807.578	943.727	56.300	76.965	20.000	99.413
162	192	834	964	46	67	20	100	23.984	23.642	178.829	223.123	824.446	927.650	54.000	76.090	18.540	95.152
160	211	840	937	50	74	20	100	26.914	26.910	175.338	223.473	845.728	908.668	54.581	82.902	20.003	99.476

w : water / c : cement / s : sand / g : aggregate / fly : fly ash / bfs : blast furnace slag / t : curing temperature / h : curing humidity / target : concrete compressive strength

압축강도 예측단계에서 모델의 학습 및 예측이 적절하게 이루어졌는지 평가를 위하여 콘크리트 압축강도 인자에 대한 모델의 예측성능 평가를 진행하였으며, 압축강도 실제값과 예측값 간의 오류율 평가 결과는 Table 5와 같다. 압축강도에 대한 모델 구조에 따른 예측성능을 평가한 결과 모델이 복잡해질수록 오류율이 낮게 나타나 모델의 예측 성능이 높게 나타나는 것으로 나타났다.

Table 5. Evaluation of compressive strength prediction performance by error rate according to model structure

	DNN3L-256	DNN5L-256	DNN3L-512	DNN5L-512	DNN3L-1024	DNN5L-1024	DNN3L-2048	DNN5L-2048
Error rate(%)	2.7182189	0.8751603	2.0386	0.8466657	1.8312014	0.7752847	1.563338	0.7367141

Figure 8은 성능평가 지표 중 MSE, MAPE를 사용하여 모델 구조에 따른 9가지 인자에 대한 모델의 예측성능을 평가한 것을 나타낸다. 본 연구에서 사용된 지표는 예측값과 실제값과의 오차의 정도를 나타내는 지표로서 지표 값이 낮을수록 모델의 높은 성능을 의미한다. 모든 DNN 모델에 대하여 평균적으로 MSE 약 0.0000481, MAPE 약 8.22%를 만족하였으며, 이 중 가장 낮은 오차를 보인 모델은 DNN5L-2048 모델로 각각 MSE 약 0.0000367, MAPE 약 7.89%를 나타내었다. 콘크리트 압축강도를 포함한 9가지 인자에 대해 모델의 은닉층 및 은닉뉴런 수가 높을수록, 즉 모델의 복잡도가 증가할수록 MSE 및 MAPE가 감소하는 형상을 보여 예측성능이 높게 나타나는 것으로 확인되었다.




Figure 8. MSE, MAPE performance evaluation of model by model structure

Figure 9는 모델 중 각각 가장 낮은 성능과 높은 성능을 보였던 DNN3L-256 모델과 DNN5L-2048 모델에 대하여 총 8가지의 배합 인자에 대한 예측 성능평가 결과를 나타낸다. 이 때, 배합 인자별 예측 성능평가는 데이터 세트 상의 배합 인자의 값이 다양한 범위를 나타낸 것에 기인하여 성능평가 척도 중 MAPE를 기반으로 성능 비교를 진행하였다. 배합 인자에 따른 모델의 예측 성능평가 또한, 은닉층 수 및 은닉뉴런이 증가할수록 MAPE가 낮아져 모델의 예측성능이 향상되는 결과를 나타내었다. 배합인자별로 분석 시 데이터 세트 상에서 편차가 작게 나타났던 양생온도 및 습도 인자에 대해 DNN3L-256 모델이 각각 3.99%, 3.751%, DNN5L-2048 모델이 각각 2.000%, 3.148%의 값을 나타내며 MAPE가 가장 낮게 나타난 것으로 확인되었다. 반면, 시멘트와 혼화재인 플라이애쉬, 고로슬래그와 같은 결합재에 대하여 다른 인자들에 비해 평균 약 3~4배의 비교적 높은 MAPE를 나타내었다. 데이터 세트 상에서 양생온도 및 양생습도 인자가 낮은 표준편차를 보였으며, 이에 비해 결합재 인자가 인자들의 평균값 대비 높은 표준편차를 보였던 것을 감안하였을 때 이러한 배합인자별 예측 성능은 데이터 세트 상의 데이터의 편차에 영향을 받은 것으로 판단된다. 또한, 선행 연구에서 강도추정식 도출을 위한 배합인자와 압축강도와의 상관계수 평가 결과에서 결합재 인자가 압축강도에 대한 중요한 배합인자로서 평가되었다는 점에 따라[7], 결합재 인자에 대한 심층적인 분석 및 이에 대한 모델의 보완이 필요할 것으로 판단된다.

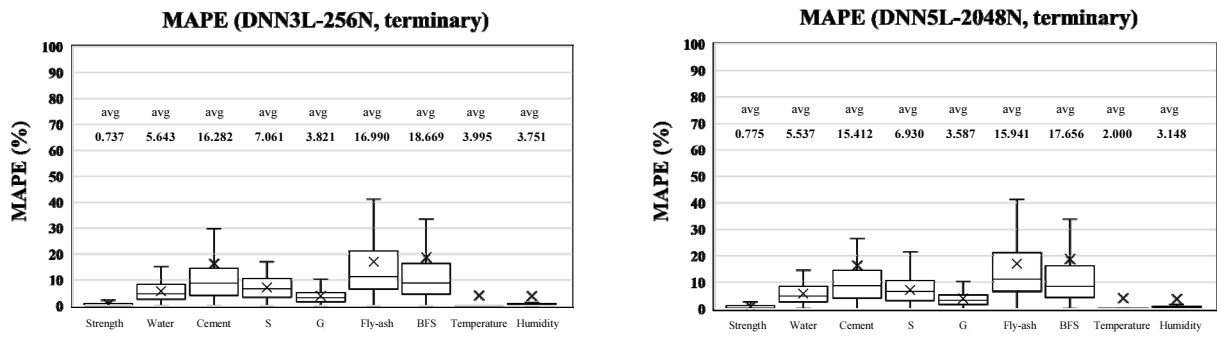


Figure 9. Evaluation of mixing proportions prediction performance by model structure

4.3 양방향 DNN 모델을 통한 소요압축강도에 대한 콘크리트 배합 산정

학습된 양방향 DNN 모델을 사용하여 특정 소요압축강도를 입력값으로 하여 삼성분계 콘크리트 배합을 산정하는 과정을 수행하였다. 삼성분계 콘크리트 배합 산정을 위해 학습된 DNN 모델에 대하여 랜덤한 값을 가지는 배합표를 생성 후, 이에 대한 예측압축강도값을 출력하여 배합요소 및 예측압축강도의 총 9가지 인자를 가진 예측 배합 데이터 세트 10,000,000개를 구축하였다. 이후, 소요압축강도 30, 50MPa를 입력하여 소요압축강도에 가장 적합한 예측강도값을 가진 삼성분계 콘크리트 배합표를 출력하는 코드를 구현하였으며, 재료의 물성 등의 기본적인 정보를 입력하게 하여 이에 따른 배합 산정 결과를 출력하도록 하였다. 입력한 재료의 물성은 사용된 데이터 세트 중의 물성 정보 중 일부를 기반으로 선정하여 가정하였으며, 배합 산정을 위해 가정된 재료의 물성 정보는 Table 6과 같다.

Table 6. Physical properties of materials assumed for prediction

Air(%)	Density(kg/m ³)				
	Cement	Fly ash	Blast furnace slag	Sand	Coarse aggregate
4.5	3.16	2.16	2.84	2.60	2.64

예측 배합 데이터 세트 구축 시, 각각의 배합인자들의 범위는 학습에 사용한 데이터 세트 중 이상치 10%를 제외한 데이터 세트의 최소값, 최대값 범위를 사용하였으며, 실험실 환경의 수중양생의 조건으로 배합표를 출력하기 위하여 양생온도 및 습도를 각각 20°C와 100%로 제한하여 배합표 예측을 진행하였다. DNN 모델을 통한 삼성분계 콘크리트 배합 출력 결과는 Table 7과 같이 나타난다. 소요압축강도 30, 50MPa에 대하여 소요압축강도 및 예측강도 간의 오류율은 평균 0.0001%를 만족하였다. 소요압축강도를 50MPa으로 하였을 때 소요압축강도를 30MPa로 하였을 때보다 예측강도와 오차가 비교적 크게 나타났는데, 이는 DNN 모델 학습 시 사용된 데이터 세트 상 압축강도에 따른 데이터 양의 차이가 영향을 미친 것으로 판단된다.

Table 7. Prediction of concrete mixing proportions according to compressive strength

Input Compressive Strength (Input value)	Result of calculating the concrete mixing proportions according to the input compressive strength (Predicted value)									
	Target(MPa)	W/B(%)	s/a(%)	w(kg/m ³)	c(kg/m ³)	s(kg/m ³)	g(kg/m ³)	fly(kg/m ³)	bfs(kg/m ³)	t(°C)
30	43	51	154	271	32	54	923	874	20.0	100.0
50	33	46	138	275	58	85	818	944		

target = concrete compressive strength, W/B = water-binder ratio, s/a = fine total aggregate ratio, w = water, c = cement, s = sand, g = coarse aggregate, fly = fly ash, bfs = blast furnace slag, t = curing temperature, h = curing humidity

5. 결론

본 연구에서는 삼성분계 콘크리트의 배합 산정을 위하여 양방향 DNN 해석을 통해 배합요소 및 강도를 예측하는 모델을 설계 및 성능평가를 진행하였으며 다음과 같은 결론을 도출하였다.

- 1) 기존 콘크리트 강도 및 염소이온 확산계수 예측모델 등에서는 주로 역전파 기법이 단독적으로 사용되었으나, 본 연구에서는 콘크리트 강도 및 배합요소의 동시적인 예측을 위해 역전파 및 순전파 기법을 동시 접목하여 양방향 DNN 모델을 구축하였다. 또한 양방향 DNN 모델의 예측 성능향상을 위한 성능개선기법으로서 경사하강법, 드롭아웃, 가중치 초기화, 배치 정규화 등의 기법을 적용하였다.
- 2) 기존 배합표를 통해 강도 예측 뿐 아니라 역방향으로 소요압축강도로부터 배합요소를 예측하기 위한 방법을 해석적으로 제안하였으며, 평균 오류율 약 1.423%의 높은 정확도로 콘크리트 압축강도 예측값을 도출하였다.
- 3) 은닉층 수 및 은닉뉴런 수를 변수로 하여 DNN 모델 구조에 따른 성능 비교를 수행하였다. 성능 비교 결과, 은닉층 수 및 은닉뉴런 수가 가장 많은 DNN5L-2048 모델이 가장 낮은 오차를 보였으며 은닉층 수 및 은닉뉴런 수가 많아져 모델이 복잡해질수록 오차율이 낮아지는 것을 확인하였다. 이는 콘크리트와 같은 복잡한 혼합물에 대하여 다양한 인자들의 상관관계 분석 시 단순한 모델에 비해 복잡한 모델이 높은 성능을 나타낼 수 있었기 때문으로 사료된다.
- 4) 배합요소에 따른 예측성능 평가 비교 결과, 결합재(시멘트, 플라이애쉬, 고로슬래그)의 경우 16.1428%, 16.954%, 18.013%의 비교적 높은 MAPE 값을 나타내었다. 본 연구에서 사용된결합재 인자가 데이터 세트 상에서 비교적 큰 편차가 나타나게 되어 이러한 편차가 오차에 영향을 미친 것으로 판단되며, 이에 따라 추후 결합재 인자의 상관관계에 대한 심층적인 분석이 필요할 것으로 판단된다.
- 5) 본 연구 개발 DNN 모델을 사용하여 특정 소요압축강도에 대하여 삼성분계 콘크리트 배합표 산정을 수행하였다. 양생 온도 및 양생습도의 출력값을 제한하여 소요압축강도 30, 50MPa에 대한 가장 적합하다고 예측되는 삼성분계 콘크리트 배합표를 출력하였으며, 출력된 콘크리트 배합표를 통한 소요압축강도와 예상되는 압축강도의 차이는 평균 약 0.0001%의 오차를 나타내었다. 이 때, 소요압축강도 설정값에 따라 소요압축강도와 예상되는 압축강도 간의 오차가 차이를 보여 다양한 압축강도를 가지는 넓은 범위의 콘크리트 배합 데이터 수집이 필요할 것으로 판단되며, 실질적인 배합요소 예측 성능 평가를 위해 실제 콘크리트 배합표와의 비교검증을 필요할 것으로 판단된다. 추가적인 연구에서 다양한 유형의 콘크리트의 데이터 수집을 통한 배합요소 산정을 위한 DNN 모델 확장이 가능할 것으로 판단된다.

요약

콘크리트의 배합설계와 압축강도 평가는 지속가능한 구조물의 내구성을 위한 기초적인 자료로서 활용되고 있다. 하지만, 콘크리트 배합설계는 최근 배합요소의 다변화 등의 이유로 인하여 정확한 배합요소 산정이나 기준값 설정에 어려움을 겪고 있다. 본 연구에서는 인공지능 기법 중 하나인 딥러닝 기법을 사용하여 삼성분계 콘크리트의 배합요소를 산정하는 양방향 해석의 예측모델을 설계하는 것을 목적으로 한다. 콘크리트 배합요소 산정을 위한 DNN 기반 예측모델은 층 수, 은닉 뉴런 수를 변수로 한 총 8개의 모델을 사용하여 성능평가 및 비교를 실시하였으며, 이후 학습된 DNN 모델을 사용하여 소요 압축강도에 따른 콘크리트 배합 산정 결과를 출력하였다. 모델의 성능평가 결과, 콘크리트 압축 강도 인자에 대하여 평균 약 1.423%의 오류율을 나타내었으며, 삼성분계 콘크리트 배합인자 예측에 대하여 평균 8.22%의 MAPE 오차를 만족하였다. DNN 모델의 구조별 성능평가 비교 결과, 모든 배합인자에 대하여 DNN5L-2048 모델이 가장 높은 성능을 보였다. 학습된 DNN 모델을 사용하여 30, 50MPa의 소요압축강도를 가지는 삼성분계 콘크리트 배합표 예측을 진행하였으며, 추후 학습을 위한 데이터 세트 확장과 실제 콘크리트 배합표와 DNN 모델 출력 콘크리트 배합표 간의 비교를 통한 검증 과정이 필요할

것으로 판단된다.

키워드 : 딥러닝, 콘크리트 배합요소, 콘크리트 배합설계, 강도 예측


Funding


This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government (MSIT)(No. NRF-2018R1A5A1025137).


Acknowledgement

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government (MSIT)(No. NRF-2018R1A5A1025137).

ORCID

Ju-Hee Choi,  <https://orcid.org/0000-0003-0977-8559>

Min-Sam Ko,  <https://orcid.org/0000-0001-5525-7725>

Han-Seung, Lee,  <https://orcid.org/0000-0001-9776-5859>

References

1. Kim IS, Lee JH, Yang DS, Park SK. Prediction on mix proportion factor and strength of concrete using neural network. *Journal of the Korea Concrete Institute*. 2002 Aug;14(4):457-66. <https://doi.org/10.4334/JKCI.2002.14.4.457>
2. Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*. 2013 Mar;35(8):1798-828. <https://doi.org/10.1109/TPAMI.2013.50>
3. Bello SA, Oyedele L, Olaitan OK, Olonade KA, Olajumoke AM, Ajayi A, Akanbi L, Akinade O, Sanni ML, Bello AL. A deep learning approach to concrete water-cement ratio prediction. *Results in Materials*. 2022 Sep;15:100300. <https://doi.org/10.1016/j.rinma.2022.100300>
4. Werbos PJ. Generalization of backpropagation with application to a recurrent gas market model. *Neural networks*. 1988;1(4):339-56. [https://doi.org/10.1016/0893-6080\(88\)90007-X](https://doi.org/10.1016/0893-6080(88)90007-X)
5. Squartini S, Hussain A, Piazza F. Preprocessing based solution for the vanishing gradient problem in recurrent neural networks. *Proceedings of the 2003 International Symposium on Circuits and Systems; 2003 May 25-28. Bangkok (Thailand): NY: Institute of Electrical and Electronics Engineers; 2003. p. 7762895. https://doi.org/10.1109/ISCAS.2003.1206412*
6. Chicco D, Warrens M J, Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*. 2021 Jul;7:e623. <https://doi.org/10.7717/peerj-cs.623>
7. Im CH, Jee NY, Cho HB. The estimation of compressive strength of concrete used admixture on the basis of mix design. *Spring Annual Conference of Architectural Institute of Korea; 2003 Apr 26; Yongin (Korea): Seoul (Korea): Architectural Institute of Korea; 2003. p. 251-4.*