

DNN을 활용한 콘크리트 건조수축 예측 모델의 활성화 함수 비교분석

Comparison on of Activation Functions for Shrinkage Prediction Model using DNN

한준희^{1*} · 김수호² · 백성진² · 한수환³ · 김종⁴ · 한민철⁵

Han, Jun-Hui^{1*} · Kim, Su-Hoo² · Han, Soo-Hwan² · Beak, Sung-Jin³ · Kim, Jong⁴ · Han, Min-Cheol⁵

Abstract : In this study, compared and analyzed various Activation Functions to present a methodology for developing a natural intelligence-based prediction system. As a result of the analysis, ELU was the best with RMSE: 62.87, R²: 0.96, and the error rate was 4%. However, it is considered desirable to construct a prediction system by combining each algorithm model for optimization.

키워드 : 심층 신경망, ReLU, LeakyReLU, ELU

Keywords : deep neural network,

1. 서론

건설 산업의 인공지능(Artificial Intelligence Algorithms)의 활용은 현재 그 범위가 지속적으로 확대되며, 설비, 안전진단 및 구조 분야에 활용되며, 컴퓨터 공학과 융복합 기술 개발이 이루어지고 있다. 또한, 콘크리트의 수축으로 인한 균열은 구조물의 성능저하 현상을 촉진하게 되므로 이에 대하여 철저한 관리가 요구된다.

이에 따라 건설 재료 분야에서는 콘크리트의 역학적 특성으로 콘크리트의 수축을 방지하고자 화학혼화제 및 예측식 개발이 활발하게 이루어지고 있다. 따라서, 본 연구진은 이러한 콘크리트의 건조수축을 AI를 활용한 예측 모델로 심층 신경망(DNN) 알고리즘을 통하여 건축재료 분야의 융복합 기술의 발전을 목적으로 심층 신경망(DNN) 알고리즘의 활성화 함수의 종류별 콘크리트 수축 예측 모델에 적용하여 각각의 활성화 함수별 성능을 비교분석 하고자 한다.

2. 연구계획 및 방법

본 연구의 분석계획은 표 1과 같다. 먼저, 학습에 적용된 9393개 데이터는 국내 게재된 논문에서 배합 및 재령별 수축량 데이터를 활용하였다. 또한, 심층 신경망의 내부 알고리즘은 자체적으로 제공하는 매개변수로 He 초기화, 배치 정규화, 드롭아웃을 실험변수 설정하였다. 각 매개변수 적용에 따른 예측성능은 평균 제곱근 오차(Root Mean Square Error, RMSE), 결정 계수(R²) 및 손실함수(Loss function)를 평가하였다.

표 1. 분석계획

학습모델	학습 방식	가중치 조정 방식	정규화	활성화 함수	결과 분석		
DNN	오차 역전파	확률적 경사 하강법	He 초기화	LeakyReLU	RMSE	손실함수	R ²
			배치 정규화	ReLU			
			드롭아웃	ELU			

심층 신경망의 구성은 입력층(Input layer), 은닉층(Hidden layer)과 출력층(Output layer)으로 이루어졌으며, 은닉층은 총 4개의 층으로 구성하였다. 또한, 확률적 경사 하강법의 학습률은 0.001로 설정하였고, Test, Validation 데이터의 비율은 0.3%으로 설정하였다. 활성화 함수는 LeakyReLU, ReLU, ELU로 내부 자체적으로 제공하는 알고리즘을 활용하였다. 마지막으로 모델의 반복 학습량은 1000회로 고정하였고, 손실함수의 최적화 알고리즘은 Adam을 적용하였다.

1) 청주대학교, 건축공학과, 박사과정, 교신저자(gksehxhf@naver.com)

2) 청주대학교, 건축공학과, 석사과정

3) 청주대학교 산학협력단 연구원

4) 청주대학교, 조교수,공학박사

5) 청주대학교, 교수,공학박사

3. 실험결과 분석 및 고찰

그림 2는 심층 신경망 알고리즘 모델의 활성화 함수별 성능평가 결과를 나타낸 것이다. 성능평가 지표는 평균 제곱근 오차(RMSE), 손실함수(Loss function) 및 Test 데이터와 예측데이터의 결정계수 R^2 값 순으로 나타낸 것이다.

이전에는 생물학적 뉴런의 방식과 비슷한 시그모이드 활성화 함수를 활용하였지만, 시그모이드의 그래디언트 소실 문제로 특정 양수 값에 수렴하지 않는 ReLU 활성화 함수와 ReLU의 훈련하는 동안 일부 뉴런이 0 이외의 값을 출력하지 않는 Dying ReLU 현상을 해결하기 위한 ReLU 변종으로 LeakyReLU 와 소규모 데이터셋에서 과대적합 문제를 방지한 ELU을 활용하였다.

그림 2의 a)와 같이 LeakyReLU는 반복 학습 1000회 진행 시 RMSE는 63.77 R^2 은 0.95로 5% 오차율로 나타났다. 다음으로 그림 2의 b)와 같이 ReLU 활성화 함수는 반복 학습 1000회 진행 시 RMSE는 77.35 R^2 은 0.94로 오차율 6%로 나타났다.

마지막 그림 2의 c)와 ELU 같이 반복 학습 1000회 진행 시 RMSE는 62.87, R^2 은 0.96로 4% 오차율로 나타났다.

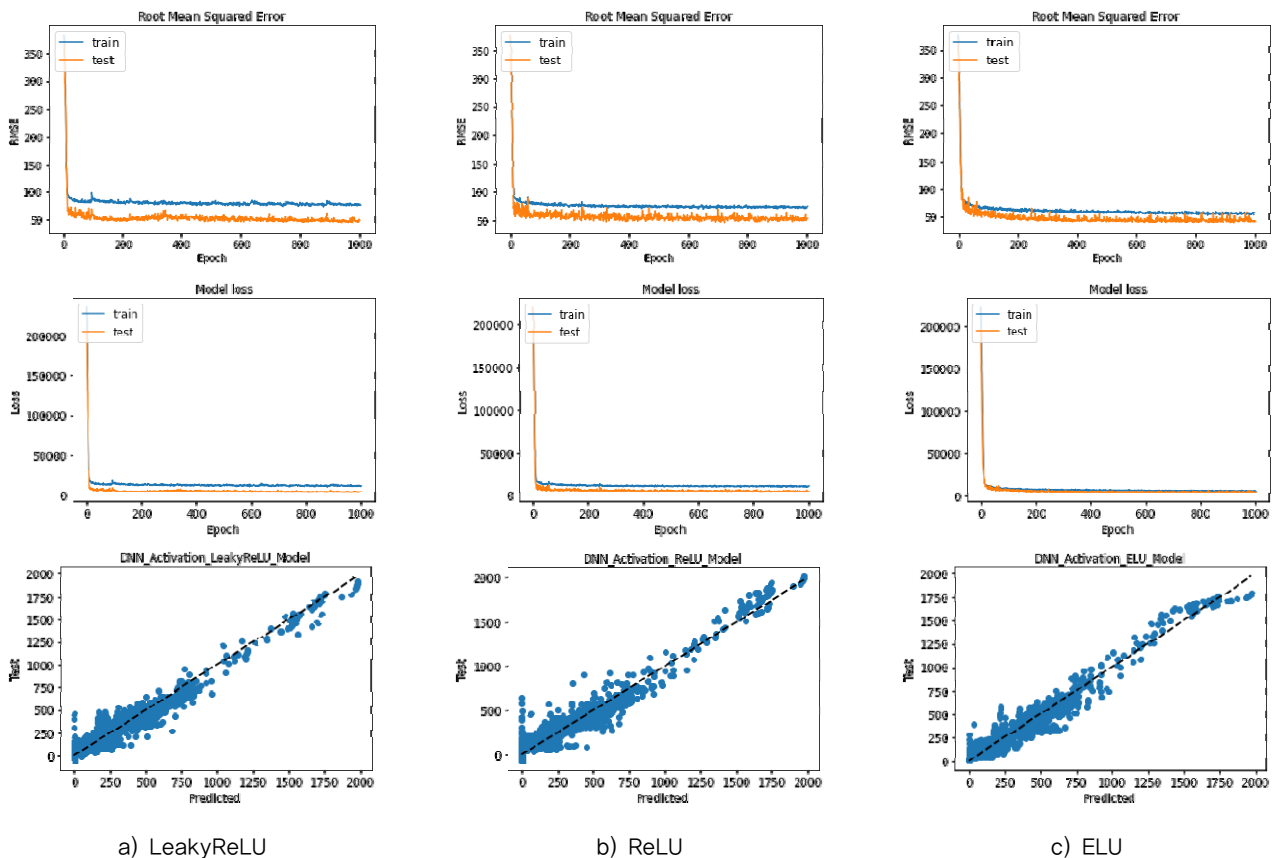


그림 2. 심층 신경망 알고리즘 모델의 매개변수의 성능 평가지표

4. 결론

본 연구는 인공지능 기반의 예측시스템 개발을 위한 방법론을 제시하기 위해 다양한 활성화 함수를 비교 분석하였다. 분석결과 활성화 함수의 정확성은 $ELU > LeakyReLU > ReLU$ 로 나타났다. 하지만, val_loss 값이 상당히 높은 것으로 나타났다. 이는 옵티마이저 혹은 심층 신경망 자체의 문제가 있는 것으로 사료된다, 따라서, 추후 연구로 순환신경망의 LSTM을 활용하여 콘크리트 수축량 예측 모델에 대하여 고찰하고자 한다.

참고문헌

1. Chen. Y. (2015). Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks, Article in IEEE Transactions on Geoscience and Remote Sensing, 54(10), 1~20.
2. Bengio. Y. A. (2013). Representation Learning: A Review and New Perspectives, IEEE Trans. PAMI, special issue Learning Deep Architectures.