

딥러닝의 반복적 예측방법을 활용한 철근 가격 장기예측에 관한 실험적 연구

이용성¹ · 김경환^{2*}

¹건국대학교 일반대학원 건축학과 박사수로 · ²건국대학교 건축공학부 교수

Experimental Study on Long-Term Prediction of Rebar Price Using Deep Learning Recursive Prediction Method

Lee, Yong-Seong¹, Kim, Kyung-Hwan^{2*}

¹Graduate Student, Department of Architecture, Konkuk University Department of Architectural, Graduate School, Konkuk University

²Professor, Department of Architecture, Konkuk University

Abstract : This study proposes a 5-month rebar price prediction method using the recursive prediction method of deep learning. This approach predicts a long-term point in time by repeating the process of predicting all the characteristics of the input data and adding them to the original data and predicting the next point in time. The predicted average accuracy of the rebar prices for one to five months is approximately 97.24% in the manner presented in this study. Through the proposed method, it is expected that more accurate cost planning will be possible than the existing method by supplementing the systematicity of the price estimation method through human experience and judgment. In addition, it is expected that the method presented in this study can be utilized in studies that predict long-term prices using time series data including building materials other than rebar.

Keywords : Recursive prediction method, Long term prediction, Rebar price prediction

1. 서론

1.1 연구의 배경 및 목적

건축비용계획의 항목 중 건축재료비는 산출될 물량에 자재 단가를 곱하여 산정한다. 그리고 산정된 비용은 자재를 사용하기 위해 실구매할 때 자재의 단가변동으로 차이가 발생할 수 있다. 특히 자재의 단가변동으로 실구매 비용이 산정된 비용보다 증가할 경우 공사원가 상승에 원인이 될 수 있다(Choi & Kwon, 2008). 따라서 건축재료비를 산정하는 기존의 방식은 주문 시기와 주문량, 주문 시기에 책정된 단가를 대상으로 관련 비용함수를 최적화하여 기업이익을 남기고자 하는 의사결정의 한 범주로 이해할 수 있다(Lee et al., 2008). 하지만 건설업에서 사용할 비용을 미리 계획하는

기존의 방식은 결정권자의 경험과 판단을 통해 결정되기 때문에 이윤과 손실에 대한 불확실성이 내포되어있다. 특히 이윤과 손실에 대한 불확실성의 요인 중 하나로 철근과 같이 가격변동이 자주 발생하는 자재를 예로 들 수 있다. 철근은 거시경제의 영향과 가격 인상요인이 있으면, 이를 즉시 시장에 반영할 수 있는 시장 지배력 때문에 가격변동이 자주 발생하며, 2005년부터 2007년까지 연평균 약 -6.79%부터 15.64%까지 가격이 변동하였다(Choi & Kwon, 2008; Choi et al., 2009). 그리고 2008년에는 철근 가격이 전년 대비 연평균 약 65% 가격 폭등하여 여러 건설업체의 공사가 중단되는 사태까지 발생한 바 있다(Choi & Kwon, 2008). 따라서 본 연구에서는 철근 주문 시기에 책정된 단가를 사전에 파악할 수 있는 새로운 방법으로 딥러닝을 활용하고자 한다.

인공지능 기술의 한 종류인 딥러닝은 최근 컴퓨터 관련 기술과 하드웨어의 발전으로 인간의 판단과 속도, 정확도를 뛰어넘는 결과를 일부의 영역에서 얻고 있으며, 범용성이 뛰어나 번역, 음성인식, 자율주행차, 로봇틱스 등 다양한 분야에서 활용되고 있다(Jeong, 2017). 그리고 변동성이 큰 국제

* **Corresponding author:** Kim, Kyung-Hwan, Department of Architecture, Konkuk University, Seoul 05029, Korea
E-mail: kykim@konkuk.ac.kr
Received January 25, 2021 : **revised** March 11, 2021
accepted April 20, 2021

유가, 주택가격, 주식 등과 같은 가격을 예측하는 방법을 제시하는 기존의 연구가 있어 철근 가격을 예측하는 방법으로 활용 가능할 것으로 사료된다(Lee & Kim, 2020a; Lahari et al., 2018; Chen et al., 2017; Pawar et al., 2019). 하지만 기존의 연구에서 제시하는 결과는 정해진 시간 간격에 따라 변경 또는 관측된 값으로 구성된 시계열 데이터의 마지막 시점을 t 할 때 $t+1$ 만을 예측하여 제시한다. 그래서 철근의 주문 시기에 책정된 단가를 파악하기 위해서는 딥러닝을 활용한 $t+2$ 이상의 예측방법이 필요하다. 그리고 한국 물가정보에서 2001년 1월부터 현재 시점까지 월 단위로 제공하는 철근 가격데이터로 데이터셋을 구성하여 딥러닝의 입력데이터로 사용하고, 딥러닝의 예측범위를 $t+2$ 이상 예측하도록 변경하여 학습을 진행하면 학습데이터만 너무 과하게 학습하는 과적합(Overfitting)이 발생한다. 과적합은 예측의 신뢰성 확보를 위한 검증 구간과 실제 예측이 이뤄져야 하는 구간의 정확도를 크게 저하시킨다(Tensorflow.org, 2020).

이에 본 연구에서는 철근 가격의 주문 시기에 책정된 단가를 예측하여 인간의 경험과 판단을 기반으로 이뤄지는 의사결정 방식의 불확실성을 보완할 방법으로 딥러닝을 활용한 철근 가격의 장기예측방법을 제안하고자 한다.

1.2 연구의 방법

본 연구는 딥러닝을 활용하여 건축물의 주요자재인 철근 가격을 예측하기 위해 다음의 절차와 방법으로 연구를 진행하였다.

- 1) 문헌조사로 기존의 딥러닝을 활용하여 가격을 예측하는 연구에 대해 고찰한다. 또 특정 값을 예측하는 연구에서 딥러닝의 예측범위를 확대하여 장기예측이 가능한 방법에 대해 고찰한다.
- 2) 딥러닝 예측모델을 구성하고, 철근 가격예측에 사용할 데이터셋을 구성한다.
- 3) 딥러닝 모델과 구성된 데이터셋으로 실험을 진행한다. 이후 실험 결과를 통해 데이터의 마지막 시점 이후의 n 개월 예측값을 실제값과 비교하여 최종적인 예측성능을 판단한다.

2. 딥러닝 장기예측방법에 관한 고찰

딥러닝의 단기 예측방식은 학습으로 사용할 입력데이터와 입력데이터 마지막 시점의 다음 시점 값을 정답으로 재구성하는 과정이 필수적으로 요구된다. 그리고 이 단기 예측방식에서 학습으로 사용할 정답데이터의 시점을 <Fig. 1>과 같이 변경할 경우 예측범위의 확대가 가능하다(Choi & Lee, 2020). 하지만 이 방식의 경우 단기예측인 $t+1$ 에서 예측범위

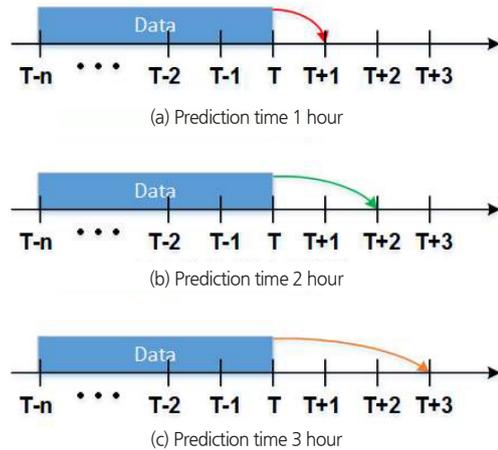


Fig. 1. Input data and prediction output data by prediction time (Choi and Lee, 2020)

를 $t+2, t+3$ 으로 확대함에 따라 예측성능이 크게 저하되는 문제점이 있다. 따라서 딥러닝을 활용해 특정한 값을 예측하는 기존의 연구에서 사용한 새로운 장기예측방식에 대해 알아보기 위해 문헌고찰을 실시하였다.

장기예측방식에 관한 선행연구를 살펴보면 Lee and Kim (2020b)은 철근 가격을 예측하기 위해 1개월(Month) 단위로 구성된 데이터의 시간 간격을 예측할 월(Month) 수 만큼, 데이터의 시간 간격을 재구성하여 Long Short Term Memory (LSTM)와 Bidirectional Recurrent Neural Network (BRNN)을 결합한 Bi-LSTM 모델의 입력데이터로 사용하고, 이를 단기 예측하여 예측범위를 부분적으로 1개월에서 3개월까지 확장하고 예측결과를 제시하였다. Kim et al. (2020a)은 Multi-Layer Perceptron (MLP) 모델로 시간별 일사량을 예측하고, 예측된 일사량과 기상예보 데이터를 딥러닝 모델인 LSTM의 입력데이터로 사용하여 태양광 발전량을 예측하였다. 그리고 이 과정을 반복하여 현시점에서 예측된 출력값을 다음 시점을 예측하기 위한 모델의 입력값으로 사용하는 방식으로 재귀과정을 반복해 태양광 발전량을 장기예측하였다. 그리고 Kim et al. (2020b)은 1달(Month) 단위의 콘크리트 침하데이터를 순환신경망의 입력데이터로 사용하고 딥러닝 모델을 활용한 일 대 다 예측방식을 통해 콘크리트 궤도의 장기 침하 예측모델을 제안하였다. 제안된 모델에서 콘크리트 침하를 장기예측하기 위해서 사용한 방식은 콘크리트 침하데이터인 $S_1 \sim S_6$ 데이터셋으로 S_7 를 예측하고, 이를 원데이터에 추가하여 $S_2 \sim S_7$ 로 데이터셋을 재구성한 후 S_8 을 예측하는 방식으로 콘크리트의 침하량을 장기예측하였다.

이상의 선행연구를 분석한 결과 딥러닝의 예측범위를 확장하기 위해 데이터의 시간 간격을 재구성하는 방식은 늘어나는 시간 간격만큼 데이터가 배로 감소하기 때문에 예측범

위 확장을 제한한다. 또 앞서 설명한 예보된 데이터를 활용한 장기예측방식은 딥러닝에서 사용할 데이터의 특성 일부가 미리 앞선 시점에 대한 예측값을 제시하는 경우 활용이 가능하다. 그리고 예측된 결과를 재사용하여 다음을 예측하는 방식은 고정된 데이터의 입력 크기로 인해 모델의 예측성능을 최대로 끌어올리기 위해 사용하는 하이퍼 파라미터 최적화의 탐색 범위를 제한한다. 또 이 방식을 활용하기 위해서는 딥러닝의 입력데이터가 상호 간 예측이 가능해야 한다. 따라서 현시점을 t 라 할 때, 딥러닝의 입력데이터로 사용되는 데이터를 각각 모두 예측하여 예측결과($t+1$)를 원 데이터 마지막 행으로 추가하고, 이를 딥러닝 모델의 입력데이터로 다시 사용하여 다음 시점($t+2$)을 예측하는 방식으로 반복하면, 딥러닝의 예측범위($t+n$) 확대가 가능할 것으로 추정된다.

3. 딥러닝 관련 이론적 고찰

3.1 RNN

순환신경망(Recurrent Neural Networks; RNN)은 인공 신경망의 일종으로, 은닉계층에서 이전의 정보를 기억할 수 있는 순환구조를 이룬다. 그리고 이전 출력의 영향 아래 현재까지 출력된 결과를 메모리에 기억한다. 학습은 입력데이터를 비선형 관계로 변환하여 입력의 다음 단계로 전달하여 -1과 1 사이의 작은 값을 출력한다(Rumelhart et al., 1985; Schuster & Paliwal, 1997).

3.1.1 BRNN

RNN은 예측결과가 이전 패턴을 기반으로 하는 경향을 나타내는 한계를 가지고 있다. 이러한 RNN의 단점을 보완하기 위해 BRNN이 제안되었다. 양방향 순환신경망(Bidirectional Recurrent Neural Networks; BRNN)은 서로 연결되지 않은 순방향과 역방향 은닉계층을 가지고 있다. 이 두 개의 은닉계층이 출력층에서 출력값을 예측하기 위해 사용된다. 입력값은 두 개의 은닉계층으로 전달되고 출력계층에서 두 은닉계층의 출력이 하나로 결합되어 최종 출력을 한다(Schuster & Paliwal, 1997).

3.1.2 LSTM

RNN의 출력값이 곱해지는 단계를 반복하면 출력값이 소실되어 학습이 이뤄지지 않는 기울기 소실(Vanishing gradient) 문제를 발생한다(Gao et al., 2019). 그리고 이 문제는 과거의 학습결과가 사라지는 장기의존성(Long-Term dependencies) 문제를 발생시킨다. 장단기 메모리(Long Short Term Memory; LSTM)는 이 문제를 극복하기 위해 제안되었다. LSTM 내부는 입력, 출력, 망각 게이트라는 구조에 의해 제어되며, RNN의 장기의존성 문제를 방지하여 시계열 데이터와 같은 방대한 데이터도 문제없이 처리한다

(Hochreiter & Schmidhuber, 1997).

3.2 하이퍼 파라미터 최적화

하이퍼 파라미터(Hyper-parameter)는 딥러닝 모델에서 사용자가 직접 조절하여 설정하는 값들을 지칭한다. 주로 입력데이터의 크기, Cell 내부의 은닉층 수, 학습량, 학습률과 같은 값들을 예로 들 수 있다. 이 값들은 입력되는 조합에 따라 딥러닝 모델의 예측성능이 달라지는데, 이때 모델의 예측성능을 최대로 끌어올리기 위해 하이퍼 파라미터의 조합을 탐색하는 과정을 하이퍼 파라미터 최적화라 한다(Bergstra & Bengio, 2012). 그리고 하이퍼 파라미터 최적화 방식 중 사용자가 직접 시도할 하이퍼 파라미터 입력값을 선정하고, 이를 사용하여 예측결과를 몇 차례 측정 후 가장 높은 예측성능을 나타낸 입력값을 수동으로 채택하는 방법을 Manual search라 한다(Larochelle et al., 2007). 또 다른 탐색방법으로는 시도할 하이퍼 파라미터 후보 입력값을 범위로 선정하고, 이를 무작위로 조합하여 자동으로 탐색하는 Random search가 있다(Bergstra & Bengio, 2012).

3.3 과적합

과적합은 딥러닝 모델이 데이터를 너무 상세하게 학습하는 것을 말한다. 이는 학습데이터가 불충분하거나 모델이 데이터 특성에 비해 너무 복잡할 때 발생한다. 그리고 이 문제의 결과는 학습 성과는 우수하지만, 학습데이터 이외의 다양한 변수에 대한 대응성이 떨어져 일반화된 모델의 예측정확도를 감소시킨다(Tensorflow.org, 2020).

3.4 Dropout

Dropout은 입력 비율에 따라 신경망의 뉴런을 확률적으로 사용하지 않게 하는 방법이다. 그리고 이를 통해 모델에서 발생하는 과적합 문제를 방지하여 예측성능을 향상시킨다(Srivastava et al., 2014).

3.5 데이터 정규화

데이터 간의 편차를 줄이기 위해 모든 입력데이터는 normalization를 진행하여 0~1 사이의 값으로 조정하여 적용한다. Normalization에 사용된 방법은 MinMaxscaler로 식(1)과 같다(Nayak et al., 2014).

$$X = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

x : 데이터

x_{\min} : 데이터의 최소값

x_{\max} : 데이터의 최대값

X : 스케일 변환데이터

3.6 모델 성능평가

딥러닝 모델의 예측성능을 측정 및 평가하기 위해 평균 제곱근 오차인 Root Mean Square Error (RMSE)를 이용하였다. RMSE는 모델의 예측값과 실제값의 차이를 다룰 때 사용하는 측도로 식(2)와 같다.

RMSE는 크기 의존적 에러(Scale-dependent Errors)에 속해 예측대상의 크기에 영향을 받는다. 그래서 스케일이 다른 예측대상의 RMSE가 비슷한 수치를 나타내는 경우 직관적인 해석이 어렵다는 단점이 있다(Willmott and Matsuura, 2005). 따라서 평균 절대 백분율 오차인 MAPE (Mean Absolute Percentage Error)를 추가로 사용한다. MAPE는 식(3)과 같다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (2)$$

$$MAPE(\%) = \frac{1}{n} \sum_{i=1}^n \left(\left| \frac{y_i - \tilde{y}_i}{y_i} \right| \right) * 100 \quad (3)$$

y_i : 실제값
 \tilde{y}_i : 예측값
 n : 데이터의 개수

MAPE에 대한 해석은 MAPE가 2일 경우 예측값이 실제값에서 평균 2% 벗어남을 의미한다.

4. 딥러닝 환경 구성

4.1 딥러닝 모델 구성

본 연구에서는 철근 가격예측에 적합한 모델을 탐색하기 위해 RNN, LSTM 그리고 BRNN과 LSTM을 결합한 Bidirectional LSTM(Bi-LSTM)을 모델로 각각 구성한다. 또 Bi-LSTM은 Cell layer를 추가 확장할 수 있도록 Stack Bidirectional Dynaminn RNN을 추가하였다. 그 외에 시스템 구성과 사용된 패키지 정보는 <Table 1>과 같다.

Table 1. System configuration specifications and package information

Classification	Program information
Operation system	Window 10
Programming Tool	Visual Studio Code
General-Purpose computing on Graphics Processing Units	Cuda 10.0
Graphics Processing Unit	RTX 2080 Ti
Language	Python 3.6.5
Deep Learning Library	Tensorflow - GPU 1.15.0
matplotlib 3.1.1	Data Visualization
numpy 1.16.5	Array
sklearn 0.23	RandomizedSearchCV Train_test_split

Dropout layer는 Cell layer의 다음에 위치시켜 출력 (Output)에만 적용하였다. 또 모델을 호출하여 사용할 수 있도록 함수로 정의하고, 하이퍼 파라미터 탐색기인 Random Search와 연결하였다. 그리고 하이퍼 파라미터 최적화는 Manual search를 이용하여 탐색할 입력값의 범위를 큰 폭으로 줄이고, Random search를 이용하여 축소된 입력값 범위 내에서 하이퍼 파라미터를 무작위로 조합하여 예측결과를 탐색할 수 있도록 설정하였다. 본 연구의 딥러닝 모델에서 사용되는 하이퍼 파라미터는 <Table 2>와 같다.

Table 2. Hyper parameter and Description

Hyper-parameter	Description
Sequence length(Seq)	Row length of input data
Learning rate(Lr)	Gradient Descent Learning speed
Hidden layer(Hd)	Hidden layer inside the Cell
Iterations(lters)	Iterative learning
number_layer(nL)	Number of LSTM Cell layers
keep_prob(kp)	Dropout rate

4.2 데이터셋 구성

본 연구에서는 Lee and Kim (2020a)의 연구에서 딥러닝으로 철근 가격을 단기예측하기 위해 사용한 월별 시계열 데이터 특성을 임의 선정하였다. 데이터의 출처와 항목들을 구분하기 위해 사용하는 ID는 <Table 3>과 같다. 모든 데이터는 2003년 1월부터 2020년 3월까지 1개월 간격으로 Comma-Separated Values (CSV) 파일로 정리하였다.

Table 3. Data information

ID	Name	source
A	Import price index(rebar and bar steel)	Korea National Statistical Office
B	The producer price index(rebar)	e-National Indicators
C	Dubai crude oil	e-National Indicators
D	Brent oil	e-National Indicators
E	West Texas Intermediete	e-National Indicators
F	Scrap iron(Unit price)	e-National Indicators
G	Scrap iron(the amount of imports)	e-National Indicators
H	Rebar production volumes	Korea National Statistical Office
I	Construction statistics	Korea National Statistical Office
J	Rebar price(0.560 SD300, general)	Korea Price Information

그리고 본 연구에서 사용할 예측방법의 특성상 데이터셋으로 구성된 데이터 특성만으로 상호 간 예측이 가능해야 한다. 그래서 데이터 간 선형상관관계 유의성이 높은 데이터를 선택하기 위해 피어슨 상관관계 분석을 활용하였다. 피어슨 상관관계수는 식(4)를 통해 산출된다(Benesty et al., 2009).

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

- \bar{x} : 표본집단 X의 평균
- \bar{y} : 표본집단 Y의 평균
- s_x : 표본집단 X의 표본 표준편차
- s_y : 표본집단 Y의 표본 표준편차
- n : 표본집단의 개체수
- r : 피어슨 상관계수

피어슨 상관계수는 -1 ~ +1의 사이 값으로 출력되며, 결과에 대한 해석은 상관계수 값이 -1 또는 +1에 근접할수록 각각 음 또는 양의 상관관계가 높은 것으로 해석할 수 있다 (Ji et al., 2019). 피어슨 상관계수 분석결과는 직관적 이해가 쉽도록 색상으로 표현할 수 있는 다양한 정보를 이미지 위에 열 분포 형태로 나타내는 히트맵으로 시각화하여 (Fig. 2)로 정리하였다.

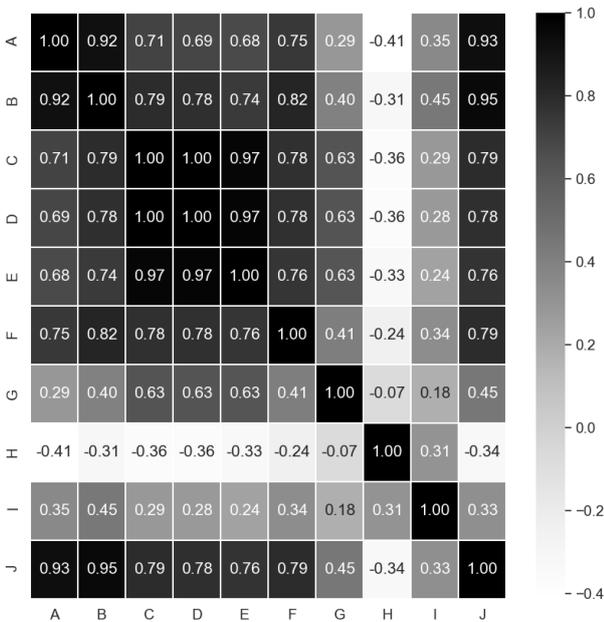


Fig. 2. Visualization of Pearson correlation coefficient analysis results

〈Fig. 2〉를 살펴보면 수입물가지수인 A, 생산량물가지수 B, 국제유가 C, D, E, 고철 가격 F, 철근 가격 J가 상호 간 강한 양의 상관관계를 나타낸다. 그리고 본 연구에서 사용할 데이터셋은 데이터 특성 수 만큼 예측의 대상 수도 같이 늘어나기 때문에 학습과 탐색으로 소요되는 시간이 크게 증가하는 것에 대한 고려가 필요하다. 그래서 강한 양의 상관관계를 나타내는 데이터 중에서 피어슨 상관계수가 0.9 이상을 나타내는 A, B, J만을 선택하여 데이터셋으로 구성하였다.

5. 딥러닝의 반복적 예측방식을 활용한 장기 예측방법

5.1 딥러닝의 단기 예측방법

순환신경망의 시계열 예측방법은 학습으로 사용될 데이터와 이에 따른 정답데이터가 필요하다. 따라서 신경망 알고리즘에서 예측에 사용할 데이터셋을 불러들인 후 모델의 Cell에 입력할 데이터와 이에 대한 정답데이터의 재구성 과정이 필수적으로 진행된다. 이 과정은 다음 (Fig. 3)과 같다.

```
def build_dataset(data, seq):
    dataX = []
    dataY = []
    for i in range(0, len(data) - seq):
        _x = data[i:i + seq, :]
        _y = data[i + seq, [-1]]

        dataX.append(_x)
        dataY.append(_y)
    return np.array(dataX), np.array(dataY)
```

Fig. 3. Data processing process for short-term prediction of the recurrent neural network

〈Fig. 3〉은 순환신경망의 단기예측 방법으로 사용되는 데이터 재구성과정으로, 정의된 함수에 입력값으로 사용되는 data는 전체 데이터를 의미하고, seq는 전체 데이터에서 부분적으로 데이터를 자르는 크기를 결정하는 하이퍼 파라미터를 의미한다. i는 0부터 전체 데이터의 행수에서 seq를 뺀 수의 직전까지의 범위를 갖고, 이를 0번째 행부터 순차적으로 seq의 크기만큼 데이터를 잘라 dataX인 리스트에 순서대로 저장한다. 그리고 _y는 _x의 다음 행의 마지막 값에 해당하는 예측대상을 정답으로 dataY에 순차적으로 저장한다. 그리고 이 방식을 통해 데이터를 재구성하게 되면 가장 마지막 행을 포함하는 _x는 이에 대한 _y가 없기 때문에 이 구간의 직전까지만 데이터를 재구성한다. 그리고 이 제외된 마지막 구간은 데이터의 범위를 벗어난 값을 예측할 때 사용된다.

5.2 반복적 예측방식의 장기예측방법

본 연구에서는 월별 철근 가격을 장기예측하기 위해 반복적 (Recursive) 예측방식을 사용하였다. 이 예측방식은 현재 시점에서 예측된 단기 예측값을 다음 시점을 예측하기 위한 모델의 입력값으로 사용하는 방법으로 출력된 예측값을 원 데이터에 추가하여 다음 모델의 입력데이터로 사용한다 (Taieb et al., 2010). 〈Fig. 4〉는 현재 시점인 t에서 n개월까지의 반복적 예측방식을 도식화한 것이다. t를 기준으로 1개월 후(t+1)의 예측값은 데이터셋(a, b, c)를 통해 c_{t+1}을 예

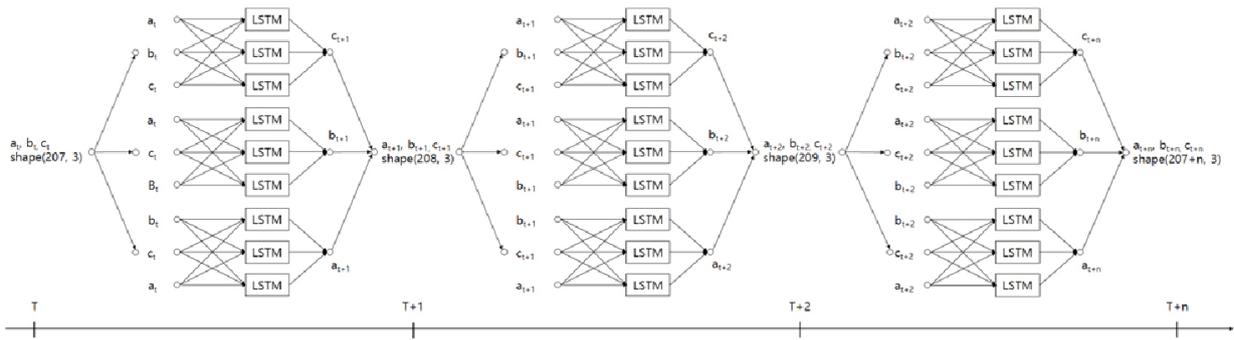


Fig. 4. Prediction method of rebar price using recursive Short-Term Forecasting Method

측하고, (b_t, c_t, a_t) 로 a_{t+1} 을 예측한다. (a_t, c_t, b_t) 로는 b_{t+1} 을 예측한다. 2개월 후($t+2$)는 1개월 후($t+1$)에서 예측된 데이터 $(a_{t+1}, b_{t+1}, c_{t+1}), (a_{t+1}, c_{t+1}, b_{t+1}), (c_{t+1}, b_{t+1}, a_{t+1})$ 를 사용하여 $c_{t+2}, b_{t+2}, a_{t+2}$ 를 예측한다. 이러한 과정을 n 시점까지 반복하여 미래의 월별 가격을 예측한다.

6. 실험 방법

딥러닝의 반복적 예측방식을 활용한 철근 가격의 장기예측 실험을 실시한다. 실험은 2가지 방식으로 진행된다.

첫 번째 실험은 본 연구에서 선정한 수입물가지수, 생산자물가지수, 철근 가격으로 구성된 데이터셋을 딥러닝 모델인 RNN, LSTM, Bi-LSTM에 입력데이터로 사용하여 예측대상 에 대한 단기($t+1$)예측성능이 모두 우수하게 측정되는 모델을 탐색하기 위한 실험이다.

두 번째 실험은 첫 번째 실험을 통해 선택된 딥러닝 모델로 예측대상인 수입물가지수, 생산자물가지수, 철근 가격을 모두 단기($t+1$)예측한다. 이후 예측값($t+1$)을 원 데이터의 가장 마지막 행으로 추가하고 다음 시점($t+2$)을 예측한다. 또 이 과정을 반복하여 철근 가격예측이 가능한 유효범위($t+n$)와 이에 따른 예측성능을 측정하는 실험이다. 그리고 본 연구에서 진행한 실험의 유효성을 확인하고자 두 번째 실험의 전체 과정을 총 3회 실시한다. 예측결과는 각각의 단기 예측값을 실제값과 비교하여 정확도로 나타낸다.

데이터셋의 80%는 학습데이터로 나머지 20%는 각각 10%씩 테스트1과 테스트2로 분할된다. 그리고 각각의 단기 예측과정은 Random Search에 의해 하이퍼 파라미터를 무작위로 조합하여 매 50회의 탐색을 수행한다. 하이퍼 파라미터의 탐색 범위는 학습률 0.0001~0.01, 시퀀스 길이 2~10, 은닉층 수 10~150, Dropout 비율 0.1~1.0, 학습량 5000이다. 이는 Manual Search를 통해 일부 한정하였다. 출력결과는 모델의 하이퍼 파라미터와 학습, 테스트 1, 2에 대한 RMSE, MAPE, 데이터셋의 범위를 벗어난 예측값($t+1$)이 포함된다. 이 출력결과는 모델에서 학습량이 5000까지 1씩 증가할 때

마다 측정하고, 측정된 결과 중에서는 식(5)의 조건을 충족할 경우만 기록된다. 이후 기록된 결과들에서는 학습 RMSE가 가장 좋은 결과를 선택한다.

$$0 < Test1R - TrainR < 0.01 \tag{5}$$

TrainR: 학습 RMSE

Test1R: 테스트1 RMSE

식(5)를 조건으로 설정한 이유는 학습성능과 테스트1 성능의 관계를 통해 과적합을 판단할 수 있는 기준이 명확하지 않기 때문이다. 따라서 식(5)는 예측결과와 실제값을 확인하는 경험적인 추론 과정을 통해 테스트1 성능이 학습성능을 초과하지 않으면서 설정한 식의 범위 내에 위치할 때 과적합이 발생하지 않은 것으로 가정하여 설정하였다. 그리고 테스트2 데이터는 모델의 학습과 검증과정에 이용되지 않으며, 예측성능을 측정하는 용도로만 사용한다.

7. 실험 결과

딥러닝의 반복적 예측방식을 활용한 철근 가격의 장기예측 첫 번째 실험 결과는 <Table 4>와 같다.

Table 4. First experiment result (Pred, 2020.4.)

Target	Model	Train RMSE	Test1 RMSE	Test2 RMSE	Pred 1month	Actual value	Accuracy (%)
A	RNN	0.04682	0.04768	0.04760	93.22	106.29	87.70
	LSTM	0.02361	0.02407	0.02390	104.05		97.89
	Bi-LSTM	0.01855	0.01954	0.01881	105.92		99.65
B	RNN	0.05243	0.05327	0.05287	103.97	109.50	94.95
	LSTM	0.02287	0.02373	0.02309	106.40		97.17
	Bi-LSTM	0.01532	0.01622	0.01612	106.85		97.58
J	RNN	0.02542	0.02620	0.02600	630,000	610,000	96.83
	LSTM	0.02553	0.02606	0.02599	629,000		96.98
	Bi-LSTM	0.02586	0.02623	0.02602	628,000		97.13

첫 번째 실험은 RNN, LSTM, Bi-LSTM에 데이터를 (A, B, J), (B, J, A), (A, J, B)의 형태로 입력하여 예측대상인 J, A,

Table 5. Second experiment result (2020.4.~2020.9.)

Target	Pred month	RMSE($\times 1000$)									MAPE(%)					
		Train			Test1			Test2			Test1			Test2		
		1st	2nd	3rd	1st	2nd	3rd	1st	2nd	3rd	1st	2nd	3rd	1st	2nd	3rd
A	1	18.55	15.67	15.59	19.54	16.61	16.05	18.81	15.63	15.64	1.73	1.57	1.46	1.63	1.41	1.33
	2	20.25	17.00	16.42	21.10	17.84	16.79	20.74	16.35	16.51	1.98	1.69	1.69	1.89	1.26	1.30
	3	16.43	18.49	17.87	16.99	19.28	18.65	16.46	17.00	18.47	1.56	1.78	1.67	1.42	1.51	1.45
	4	14.81	15.94	13.63	15.37	16.77	14.29	15.22	16.43	14.22	1.44	1.50	1.30	1.20	1.41	1.26
	5	15.52	13.20	18.41	16.29	13.75	18.93	16.29	13.48	18.65	1.40	1.24	1.67	1.40	1.12	1.37
	6	15.28	15.87	16.98	15.92	16.65	17.85	15.45	16.23	16.99	1.49	1.56	1.57	1.27	1.38	1.40
B	1	15.31	17.87	15.57	16.22	18.49	15.79	16.12	13.08	15.67	1.15	1.35	1.11	1.13	0.79	1.03
	2	22.52	16.45	24.39	23.49	17.38	25.39	23.13	16.58	24.58	1.67	1.10	1.69	1.68	1.12	1.82
	3	20.18	15.7	20.51	21.05	16.47	21.48	20.93	12.77	20.97	1.51	1.23	1.25	1.53	0.85	1.56
	4	14.27	16.31	24.93	15.25	16.82	25.52	14.40	12.98	25.11	0.91	1.24	1.75	0.88	0.98	1.93
	5	21.49	17.61	13.06	22.3	18.49	14.01	21.86	17.57	13.42	1.67	1.26	1.02	1.42	1.01	0.97
	6	24.81	19.40	22.00	25.53	20.19	22.87	25.28	19.86	22.76	1.83	1.36	1.48	1.93	1.12	1.44
J	1	25.86	26.52	26.22	26.22	26.71	27.21	26.01	26.65	26.51	2.32	2.39	2.37	2.13	2.25	2.25
	2	24.56	26.88	24.97	24.84	27.60	25.94	24.73	26.59	25.66	1.91	2.32	2.02	2.33	2.03	2.28
	3	25.07	26.52	25.92	25.99	27.33	26.86	25.41	26.44	26.68	2.06	2.26	2.27	1.98	2.28	2.16
	4	26.18	25.37	24.72	27.01	26.32	25.66	26.9	25.64	25.35	2.25	2.28	1.92	2.30	2.08	2.36
	5	27.46	25.46	25.23	28.24	26.43	26.15	27.83	25.16	25.49	2.34	2.12	2.08	2.15	2.23	2.28
	6	26.76	24.58	25.80	27.74	25.23	26.79	27.02	25.15	26.37	2.34	2.05	2.24	2.36	2.07	2.08

B를 단기예측(t+1)하였다. <Table 4>를 살펴보면 LSTM과 Bi-LSTM으로 B, J를 예측한 결과는 1% 미만의 정확도 차이로 Bi-LSTM이 더 나은 예측정확도를 나타냈으나, A를 예측한 결과에서는 Bi-LSTM이 LSTM보다 약 1.76% 높은 예측정확도 차이를 나타냈다. RNN은 나머지 두 모델보다 예측정확도가 낮은 결과를 나타냈다. 따라서 실험 결과를 통해 이후의 실험에서는 Bi-LSTM 모델을 사용하여 진행하였다. 두 번째 실험은 2003년 1월부터 2020년 3월까지의 데이터셋을 (A, B, J), (B, J, A), (A, J, B)로 Bi-LSTM 모델에 각각 입력데이터로 사용하고, 이를 앞서 설명한 반복적 예측방식으로 2020년 4월을 시작으로 9월까지 월별 예측값을 측정하였다. 그리고 이 과정을 3회 실시하여 <Table 5>, <Table 6>으로 정리하였다.

<Table 5>는 예측대상과 예측 기간, 실험 차시별로 학습 데이터, 테스트1, 테스트2에 대한 예측성능을 측정하여 기록한 결과로, MAPE를 통해 측정된 결과가 나타내는 오차를 퍼센트(%)로 확인할 수 있다. <Table 6>은 <Table 5>의 결과가 나타내는 각각의 예측 기간별 데이터의 범위를 벗어난 예측값을 실제값에 대한 정확도로 나타낸 결과이다. 그리고 <Table 5>를 시각화한 결과는 <Fig 5>와 같다.

실험의 주요 내용으로 <Table 6>을 살펴보면 총 6개월의 예측 기간 중 데이터 B가 5개월 예측값(t+5)부터 예측정확도가 감소하기 시작한다. 또 이를 시작으로 6개월 예측값(t+6)부터 데이터 A, B, J의 예측정확도도 감소하기 시작한다. 이는 6개월(t+6)을 예측하기 위해 사용한 5개월의 입력

Table 6. Predicted result of the second experiment

Target	Pred month	Actual value	Predict			Accuracy(%)			
			1st	2nd	3rd	1st	2nd	3rd	Ave.
A	1	106.29	105.92	104.69	104.57	99.65	98.49	98.38	98.84
	2	106.40	106.21	104.49	104.29	99.82	98.20	98.02	98.68
	3	104.79	103.03	105.39	103.54	98.32	99.43	98.81	98.85
	4	104.17	104.00	103.78	103.63	99.84	99.63	99.48	99.65
	5	103.55	103.53	104.90	105.62	99.98	98.71	98.04	98.91
	6	103.6	102.75	104.83	105.58	99.18	98.83	98.12	98.71
B	1	109.50	106.85	110.74	107.25	97.58	98.88	97.94	98.13
	2	110.83	108.81	108.20	109.01	98.18	97.63	98.36	98.06
	3	110.65	109.23	108.11	107.94	98.72	97.70	97.55	97.99
	4	109.65	107.05	111.00	106.90	97.63	98.78	97.49	97.97
	5	109.44	104.49	116.70	105.81	95.48	93.78	96.68	95.31
	6	109.44	105.12	115.59	101.97	96.05	94.68	93.17	94.63
J	1	610,000	628,000	627,000	624,000	97.13	97.29	97.76	97.39
	2	660,000	632,000	647,000	632,000	95.76	98.03	95.76	96.52
	3	670,000	644,000	657,000	638,000	96.12	98.06	95.22	96.47
	4	660,000	654,000	650,000	640,000	99.09	98.48	96.97	98.18
	5	670,000	653,000	666,000	644,000	97.46	99.40	96.12	97.66
	6	670,000	635,000	719,000	611,000	94.78	93.18	91.19	93.05

데이터가 많은 부분 오차가 누적된 예측값(t+5)으로 대체되었기 때문으로 추정된다.

최근 값을 예측하는 방법은 모델의 최종 출력에 해당하는 완전연결계층(Fully connected layer)에 저장된 가중치(W)와 바이어스(B)를 시퀀스 길이 만큼의 최근 데이터와 식(6)과 같이 연산하여 최종적으로 한 개의 예측값을 출력한다.

$$Recent\ pred_{(t+5)} = Fully\ connected \begin{pmatrix} a_{(t+1)} & b_{(t+1)} & j_{(t+1)} \\ a_{(t+2)} & b_{(t+2)} & j_{(t+2)} \\ a_{(t+3)} & b_{(t+3)} & j_{(t+3)} \\ a_{(t+4)} & b_{(t+4)} & j_{(t+4)} \end{pmatrix} * W + B \quad (6)$$

이때 실제값으로만 구성된 학습, 테스트1 데이터로 일반화가 된 가중치와 바이어스는 실제값으로 구성된 테스트1 데이터 구간에 대한 오차는 작게 발생시킨다. 하지만 입력데이터의 범위를 벗어난 값을 예측하기 위해 사용하는 데이터 구간에는 오차가 누적된 예측값들로 많은 부분이 대체되어 있기 때문에 완전연결계층의 연산을 통해 출력된 예측값(t+6)은 예측정확도가 크게 낮아지는 것으로 추정할 수 있

다. 이러한 문제점은 하이퍼 파라미터인 시퀀스 길이를 최근 값을 예측하기 위해 사용한 데이터 크기보다 크게 설정하여 실제 데이터를 더 많이 포함 시키면 예측정확도가 개선될 것으로 추정된다.

실험 결과에 따라서 본 연구에서 제안하는 방식은 수입물가지수 A, 생산자물가지수 B, 철근 가격 J를 월 단위로 단기 예측하여 4월의 예측값(A_{t+1}, B_{t+1}, J_{t+1})으로 5월을 예측(A_{t+2}, B_{t+2}, J_{t+2})하는 방식으로 7월(t+4)까지 진행하고, 이후 7월의 예측값(A_{t+4}, B_{t+4}, J_{t+4})으로 8월의 철근 가격을 예측(J_{t+5})하는 방식까지만 유효하다고 판단된다.

8. 결론

본 연구에서는 딥러닝의 반복적 예측방식을 활용하여 철근 가격을 장기예측하기 위해 2가지 실험을 진행하였다. 주요 내용은 다음과 같다.

첫 번째 실험은 본 연구에서 선정한 2003년 1월부터 2020년 3월까지 1달 시간 간격을 나타내는 수입물가지수, 생산자물가지수, 철근 가격을 데이터셋으로 구성하고, 이를 RNN, LSTM, Bi-LSTM의 입력데이터로 사용해 예측대상만 변경하는 방식으로 모두 단기 예측하여 3가지 예측대상에 대한 성능이 우수한 결과를 나타내는 딥러닝 모델을 선택하기 위한 실험을 진행하였다. 실험 결과는 Bi-LSTM을 사용한 결과가 수입물가지수 약 99.65%, 생산자물가지수 약 97.58%, 철근 가격 약 97.13%로 RNN, LSTM의 예측정확도보다 모두 우수하게 측정되었다.

두 번째 실험은 첫 번째 실험에서 선택된 딥러닝 모델인 Bi-LSTM과 수입물가지수, 생산자물가지수, 철근 가격의 2003년 1월부터 2020년 3월까지의 데이터로 2020년 4월을 예측하고, 예측결과를 원 데이터에 추가하여 5월을 예측하는 방식으로 2020년 4월부터 9월까지 총 6개월을 예측하였다. 그리고 이 전체 과정을 총 3회를 진행하였다. 실험 결과 생산자물가지수 8월의 예측값부터 예측 정확도가 감소하기 시작하였고, 8월의 예측값이 포함된 데이터셋으로 9월을 예측하였을 때 수입물가지수, 생산자물가지수, 철근 가격의 예측 정확도가 감소하였다. 이는 9월을 예측하기 위해 사용한 8월의 입력데이터에 많은 부분이 오차가 누적된 예측값으로 대체되어 발생하는 문제로 추정된다. 따라서 본 연구에서 제안하는 방식의 철근 가격예측범위는 1~5개월까지 유효한 것으로 판단된다.

본 연구에서 제안한 딥러닝의 반복적 예측방법을 활용한 철근 가격 장기예측에 관한 실험적 연구는 한국물가정보에서 제공하는 지역별 종류별 철근 가격데이터로 공사가 시작되기 5개월 이전에 철근의 단가변동을 사전에 파악하여 계

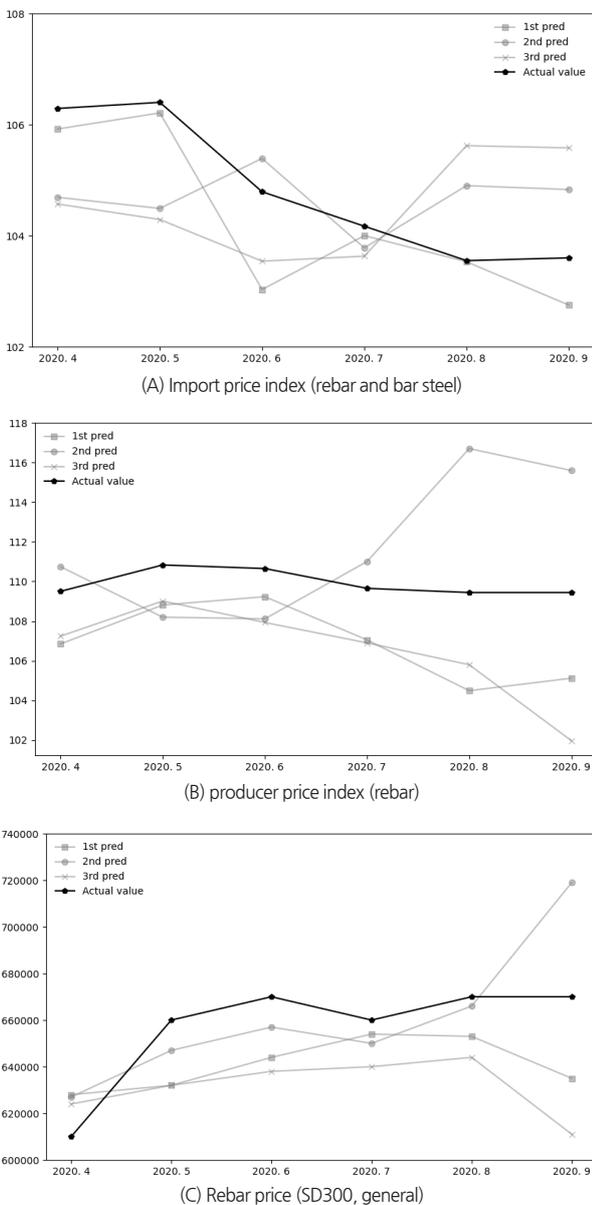


Fig. 5. Visualization to compare actual values with predicted values

획된 자재의 투입 시점 이전에 자재구매를 위한 적절한 시기의 판단이 가능할 것으로 사료된다. 또 한국물가정보에서는 철근 이외의 건축재료에 대한 다양한 시세 데이터를 제시하기 때문에 선택에 따라 본 연구에서 제시하는 방법이 여러 자재의 단가 예측에도 활용 가능할 것으로 판단되며, 이를 통해 다른 주요 건설 자재로의 확장으로 기존의 공사비 예측의 정확도 개선에도 활용될 수 있을 것이다.

References

- Benesty, J., Chen, J., Huang, Y., and Cohen, I. (2009). "Pearson correlation coefficient." *In Noise reduction in speech processing*, Springer, Berlin, Heidelberg, pp. 1-4.
- Bergstra, J., and Bengio, Y. (2012). "Random search for hyper-parameter optimization." *The Journal of Machine Learning Research*, 13(1), pp. 281-305.
- Choi, J., and Lee, S. (2020). "Short-term wind power forecast using hourly LSTM technique." *Korean Institute of Electrical Engineers*, 69(6), pp. 759-764.
- Choi, M., and Kwon, O. (2008). "Construction material cost increase and countermeasures." *Construction trend briefing by Korea Institute of Construction Industry*, 6, pp. 2-34.
- Choi, Y., Yim, H., and Park, B. (2009). "Analysis on the Lotting Price Fluctuation of the Multi-Family Attached House According to the Construction Material Cost Variation." *Journal of The Korean Society of Civil Engineers*, 29(6D), pp. 753-760.
- Hen, X., Wei, L., and Xu, J. (2017). "House price prediction using lstm." *arXiv preprint arXiv:1709.08432*.
- Hochreiter, S., and Schmidhuber, J. (1997). "Long short-term memory." *Neural computation*, 9(8), pp. 1735-1780.
- Jeong, D. (2017). "Trend on Artificial Intelligence Technology and Its Related Industry." *Korea Institute of Information Technology Magazine*, 15(2), pp. 21-28.
- Ji, S., Goo, Y., Baek, U., Park, J., and Yoon, S. (2019). "LSTM Learning Data Selection Technique for Number of Bitcoin Transactions Prediction." *In KNOM Conference*.
- Kim, B., Jung, S., Kim, M., Kim, J., Lee, H., and Kim, S. (2020a). "Solar Power Generation Forecasting based on LSTM considering Weather Conditions." *Journal of Korean Institute of Intelligent Systems*, 30(1), pp. 7-12.
- Kim, J., Lee, S.H., Choi, Y., and Woo, S. (2020b). "Long-term Settlement Prediction of Railway Concrete Track Based on Recurrent Neural Network (RNN)" *Journal of the Korean Geotechnical Society*, 36(3), pp. 5-14.
- Lahari, M.C., Ravi, D.H., and Bharathi, R. (2018). "Fuel Price Prediction Using RNN." *In 2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, IEEE, pp. 1510-1514.
- Larochelle, H., Erhan, D., Courville, A., Bergstra, J., and Bengio, Y. (2007). "An empirical evaluation of deep architectures on problems with many factors of variation." *In Proceedings of the 24th International Conference on Machine Learning*, pp. 473-480.
- Lee, J., Yoo, J., Kim, C., Lee, G., and Lim, B. (2008). "How to calculate the order point considering the fluctuations in demand for materials at construction sites." *Journal of the Architectural Institute of Korea-Structural System*, 24 (10), pp. 117-125.
- Lee, Y., and Kim, K. (2020a). "Experimental Study on the Short-Term Prediction of Rebar Price using Bidirectional LSTM with Data Combination and Deep Learning Related Techniques." *Korean Journal of Construction Engineering and Management*, KICEM, 21(6), pp. 38-45.
- Lee, Y., and Kim, K. (2020b). "Experimental Study on the Expansion of the Short-term Prediction Range of Rebar Prices Using Deep Learning." *Journal of The Architectural Institute of Korea*, 36(12), pp. 265-272.
- Nayak, S., Misra, B., and Behera, H. (2014). "Impact of data normalization on stock index forecasting." *International Journal of Computer Information Systems and Industrial Management Applications*, 6, pp. 257-269.
- Pawar, K., Jalem, R., and Tiwari, V. (2019). "Stock market price prediction using LSTM RNN." *In Emerging Trends in Expert Applications and Security*, pp. 493-503. Springer, Singapore.
- Rumelhart, D., Hinton, G., and Williams, R. (1985). *Learning internal representations by error propagation* (No. ICS-8506), California Univ San Diego La Jolla Inst for Cognitive Science, (No. ICS-8506), pp. 318-362.
- Schuster, M., and Paliwal, K. (1997). "Bidirectional recurrent neural networks." *IEEE transactions on Signal Processing*, 45(11), pp. 2673-2681.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). "Dropout: a simple way to prevent neural networks from overfitting." *The journal of machine learning research*, 15(1), pp. 1929-1958.
- Taieb, S., Sorjamaa, A., and Bontempi, G. (2010). "Multiple-output modeling for multi-step-ahead time series forecasting." *Neurocomputing*, 73(10-12), pp. 1950-1957.
- Willmott, C., and Matsuura, K. (2005). "Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance."

Climate research, 30(1), pp. 79-82.

Tensorflow.org. (2020). Overfitting and underfitting.
accessed Sep 27, 2020, https://www.tensorflow.org/tutorials/keras/overfit_and_underfit.stand.

요약 : 본 연구는 딥러닝의 반복적 예측방식을 활용하여 5개월의 철근 가격 예측방법을 제안한다. 이 방식은 입력데이터의 특성을 모두 단기예측하여 원 데이터에 추가하고, 추가된 데이터로 다음의 시점을 예측하는 과정을 반복하여 장기 예측한다. 본 연구에서 제시하는 방식으로 1개월에서 5개월까지 예측한 철근 가격의 예측 평균 정확도는 약 97.24%이다. 제안된 방식을 통해 인간의 경험과 판단을 통한 가격 추정방법의 체계성을 보완하여 기존의 방식보다 정확한 비용계획이 가능할 것으로 사료된다. 또 철근 이외의 건축재료를 비롯하여 시계열 데이터로 가격을 장기예측하는 연구에서 본 연구에서 제시한 방법이 활용될 수 있을 것으로 기대한다.

키워드 : 반복적 예측방식, 장기예측, 철근 가격예측
