

# Long Short-Term Memory를 이용한 부산항 조위 예측

김해림\* · 전용호\*\* · 박재형\*\*\* · 윤한삼\*\*\*\*†

\* 부경대학교 해양산업공학(협) 대학원생, \*\* ㈜씨엔에스솔루션 대표이사, \*\*\* ㈜씨엔에스솔루션 이사, \*\*\*\* 부경대학교 교양교육원 교수

## Tidal Level Prediction of Busan Port using Long Short-Term Memory

Hae Lim Kim\* · Yong-Ho Jeon\*\* · Jae-Hyung Park\*\* · Han-sam Yoon\*\*\*\*†

\* Graduate student, Interdisciplinary Program of Ocean Industrial Engineering, Pukyong National University, Busan 48515, Korea

\*\* CEO, CnS Solution Co., Ltd., Busan, 48508, Korea

\*\*\* Director, CnS Solution Co., Ltd., Busan, 48508, Korea

\*\*\*\* Professor, College of Liberal Arts, Pukyong National University, Busan 48513, Korea

**요 약 :** 본 연구는 조위 관측자료를 이용하여 부산항에서의 장기 조위 자료를 생성하는 Long Short-Term Memory (LSTM)으로 구현된 순환신경망 모델을 개발하였다. 국립해양조사원의 부산 신항과 통영에서 관측된 조위 자료를 모델 입력 자료로 사용하여 부산항의 조위를 예측하였다. 모델에 대하여 2019년 1월 한 달의 학습을 수행하였으며, 이후 2019년 2월에서 2020년 1월까지 1년에 대하여 정확도를 계산하였다. 구축된 모델은 부산 신항과 통영의 조위 시계열을 함께 입력한 경우에 상관계수 0.997 및 평균 제곱근 오차 2.69m로 가장 성능이 높았다. 본 연구 결과를 바탕으로 딥러닝 순환신경망 모델을 이용하여 임의 항만의 장기 조위 자료 예측이 가능함을 알 수 있었다.

**핵심용어 :** 부산항, 장단기 메모리(LSTM), 딥러닝, 순환신경망, 조위 예측

**Abstract :** This study developed a Recurrent Neural Network model implemented through Long Short-Term Memory (LSTM) that generates long-term tidal level data at Busan Port using tide observation data. The tide levels in Busan Port were predicted by the Korea Hydrographic and Oceanographic Administration (KHOA) using the tide data observed at Busan New Port and Tongyeong as model input data. The model was trained for one month in January 2019, and subsequently, the accuracy was calculated for one year from February 2019 to January 2020. The constructed model showed the highest performance with a correlation coefficient of 0.997 and a root mean squared error of 2.69 cm when the tide time series of Busan New Port and Tongyeong were inputted together. The study's finding reveal that long-term tidal level data prediction of an arbitrary port is possible using the deep learning recurrent neural network model.

**Key Words :** Busan Port, Long Short-Term Memory, Deep learning, Recurrent neural network, Tidal level prediction

### 1. 서 론

조석에 의한 조위는 선박의 안전 및 항만구조물 설계에 있어 주요한 인자 중의 하나이다. 특히, 연안 개발 등 인간 활동과 밀접하게 관련되는데 조위 기준면은 각종 연안(항만) 건설·매립 공사, 항해 안전, 해양경계 획정, 해안선 결정 등에 사용되는 매우 중요한 기본 정보이다(Kim, 2022).

국제수로기구(International Hydrographic Organization, IHO)는 기본수준면으로 최저 천문조위(Lowest Astronomical Tide, LAT)

를, 항해 안전을 위해 연육교 등을 통항하는 선박의 높이를 제한하기 위한 안전수직높이(vertical clearances)의 기준면으로 는 최고 천문조위(Highest Astronomical Tide, HAT) 또는 매우 유사한 높이의 기준면 사용을 결의하였다(IHO, 2018). 여기서 LAT 및 HAT로는 최소 1년 이상의 장기 관측을 통해 산출된 조석 조화상수를 사용해서 최소 19년 이상의 예측치를 이용하여 계산된 값 또는 그 외에 신뢰성이 있다고 밝혀진 검증된 방법을 통해 계산된 값이 권고되었다(IHO, 2018). 그러나 현실적으로 관측 기기의 분실 및 안정성, 소요 비용 등의 다양한 문제로 인하여 여러 지역에서 이와 같은 장기 관측을 수행하는 것은 어려운 실정이다(Kim, 2022).

최근 연안 및 해양 분야의 다양한 공학적인 문제들을 해

\* First Author : oct30limoohe@gmail.com, 051-629-7375

† Corresponding Author : yoonhans@pknu.ac.kr, 051-629-7375

결하기 위해 인공신경망 모델이 적용되고 있다(Deo, 2010). Mandal et al.(2005)은 바람의 스펙트럼 에너지를 입력하여 유의파고, Zero crossing 과 주기, 최대 스펙트럼 주기 등의 파랑 파라미터를 산출하는 모델이 제안하였다. Yaqci et al.(2005)은 유의파고, 평균파주기 등의 파랑 데이터를 입력하여 방파제의 파괴율을 추산하였다. 관측 분야에서는 Ustoorika and Deo(2008)이 기존 파고 데이터를 이용해 결측된 파고값을 예측하는 기법을, Beltrami(2008)은 실시간 쓰나미 탐지를 위한 인공신경망 모델을 제안하였다. 그 외에도 유의파고, 감소하천 수위, 빙하 이동을 예측하는 딥러닝 모델이 제안되었으며(Park et al., 2020; Jung et al., 2018; Zisis and Yingli, 2019) 조위 예측에 있어서도 Chang and Lin(2006), Wang et al.(2020) 등의 연구에서 인공신경망이 적용되었다.

그리고 Huang et al.(2003)은 미국 해양대기청(National Oceanographic and Atmospheric Administration, NOAA) 관측소 조위를 입력으로 하여 연안만에 위치한 임의 정점의 조위를 예측하는 인공신경망 모델을 제안하였다. 이는 인공신경망을 이용하여 선형회귀로 해석할 수 없는 조위 관측소와 출력 조위의 위상 및 진폭 차로 인한 비선형성을 고려하기 위함이다(Huang et al., 2003). 관측소와 출력 정점의 거리 및 위치에 따라 오차가 상이하나, 최대 591 km 거리의 관측소 입력에서 상관 계수 0.97로 높은 성능이 나타났다(Huang et al., 2003). 또한 Liang et al.(2008)은 태풍이나 폭풍해일과 같은 급격한 기상변화로 인한 조위 예측 및 결측 데이터 보완을 위한 조위 예측 모델을 제안한 바 있다.

그러나, 딥러닝 모델을 이용한 조위 예측 연구는 해외의 사례에 한정되어있으며 국내 연구는 전무한 실정이다. 국립해양조사원에 의해 46개 관측소에서 실시간 조위 관측이 수행되고 있으며, 이 데이터를 이용하면 우리나라 연안 조위 예측을 위한 인공신경망 모델을 개발할 수 있다. 또한 전술한 Huang et al.(2003) 및 Liang et al.(2008)의 연구 모두 한 개 관측소의 조위 자료를 입력하는데, 여러 관측소 자료를 함께 입력할 때의 성능 향상을 모의할 필요성이 있다.

이에 본 연구에서는 보다 효율적·경제적인 연안 이용 및 개발을 위하여 딥러닝을 이용한 임의 항만에서의 장기 조위 예측 모델을 개발하고자 하였다. 모델에 사용된 입력 자료로서 부산 신항, 통영, 부산 신항 및 통영의 3가지 조위 입력 자료를 구분하여 3개의 모델을 각각 개발하였다. 예측된 조위의 정확도를 검증하기 위하여 출력은 모두 부산 조위 관측소의 조위로 선정하였다.

## 2. 재료 및 방법

### 2.1 딥러닝 기법

딥러닝(Deep Learning)이란 컴퓨터가 인간과 같은 학습 및

사고를 할 수 있도록 하는 알고리즘을 의미하는 머신 러닝(Machine Learning)의 일종으로 인공신경망(Artificial Neural Network, ANN)을 이용하여 구현된다.

인공신경망은 Fig. 1과 같이 입력(Input), 은닉(Hidden) 및 출력(Output) 층(Layer)로 구성되며 각 층은 여러 개의 노드(Node)를 포함한다. 인공신경망의 입력값은 출력까지 Fig. 1의 왼쪽에서 오른쪽으로 각 층을 거쳐 단계적으로 전달된다. 각 노드의 값은 화살표로 표시된 것처럼 다음 층의 모든 노드와 연결되어 각각의 가중치가 곱해진 값으로 전달된다. 다음 층에서는 모든 이전 노드에 각 가중치가 곱해진 값들을 전달받고, 이들의 합을 계산한다. 여기에 데이터의 편향을 고려하기 위한 바이어스(bias)가 같이 더해진다. 다음 층의 임의의 노드에서의 값은 이것에 비선형 변환을 위한 활성화 함수(Activation Function)  $\sigma$ 가 취해진 것으로 식(1)과 같이 표현된다.

$$y_j = \sigma\left(\sum_{i=1}^N W_{ij}x_i + b_j\right) \quad (1)$$

여기서,  $y_j$ 는 입력층이 아닌 임의 층의  $j$ 번째 노드값,  $\sigma$ 는 활성화 함수,  $N$ 은 이전층의 노드 개수,  $W_{ij}$ 는 임의 층의  $j$ 번째 노드와 이전층의  $i$ 번째 노드가 연결된 가중치,  $x_i$ 은 이전층의  $i$ 번째 노드값,  $b_j$ 는 임의 층의  $j$ 번째 노드의 바이어스이다.




Fig. 1. Basic structure of artificial neural network.

딥러닝 모델은 일반적으로 은닉층이 2개 이상인 인공신경망 모델을 말한다. 딥러닝 모델에서 입력 값이 Fig. 1의 왼쪽에서 오른쪽 방향으로 전달되며 출력 값이 결정되는 것을 순전파(Forward Propagation)라고 한다. 초기 인공신경망의 가중치는 임의의 값이 사용된다. 순전파를 통하여 인공신경망의 출력이 결정되면 학습데이터와 비교하여 각 가중치들을 역순으로 수정한다. 이렇게 가중치를 수정하는 과정을 순전

과와 반대라는 의미에서 역전파(Back Propagation)라고 한다. 순전파를 통해 계산된 출력과 학습데이터를 비교하기 위하여 손실함수(Loss Function)를 사용한다.

본 연구와 같은 시계열 데이터 예측 분야에서는 주로 평균 제곱오차(Mean Squared Error, MSE), 평균절대오차(Mean Absolute Error, MAE), 평균 절대비 오차(Mean Absolute Percentage Error, MAPE) 등이 손실 함수로 사용된다.

학습 데이터(참값)와 모델의 출력(예측값)에 대해 손실 함수를 통해 그 차이가 계산되면 이 값을 이용하여 모델의 가중치 및 바이어스를 적절히 수정한다. 이는 학습 데이터와 모델 출력값 사이의 차이를 최소화하는 가중치 및 바이어스를 찾는 문제이며 이를 풀기 위해 많은 최적화 기법(optimizer)들이 사용되고 있다. 인공지능 연구의 초창기에는 경사하강법(Gradient Descent, GD), 모멘텀(Momentum) 등의 기법이 사용되었으나, 최근 여러 연구에서 Adam(Adaptive moment estimation) 기법(Kingma and Ba, 2014)이 주로 사용되고 있다.

위와 같은 과정을 통해 최적의 딥러닝 모델을 구축하기 위해서는 무엇보다 양질의 학습 데이터가 필요하다. 딥러닝 모델에서는 사용할 수 있는 데이터에 대하여 학습(Training) 및 테스트(Test)로 구분하여 사용한다. 학습 데이터는 딥러닝 모델의 학습을 위하여 사용되는 값으로 입력과 출력 데이터 모두 사용된다. 반면에 테스트 데이터는 학습된 모델의 출력을 계산하여 모델의 정확도를 평가할 때 사용된다.

2.2 순환신경망(RNN)과 LSTM

순환신경망(Recurrent Neural Network)은 Fig. 2와 같이 유닛(Unit) 간 순환적으로 연결된 구조의 인공신경망이다. 이러한 구조로 인하여 음성인식, 번역과 같이 연속적인 데이터 분석에 탁월한 성능을 나타낸다고 알려져 있다(Park et al., 2020). 순환신경망에서 시계열 데이터는 각 시각의 값에 대하여 처리되며, 연결된 다음 시각으로 정보가 전달된다.




Fig. 2. Basic structure of Recurrent Neural Network (RNN).

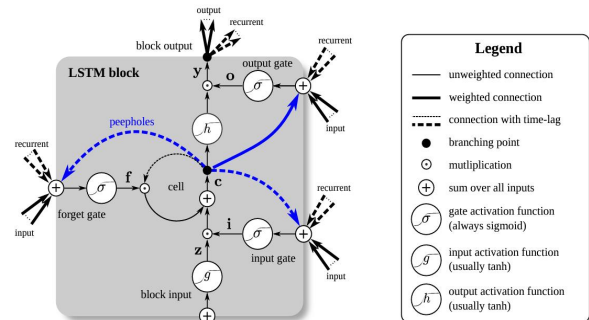
임의의 시각 t일 때 순환신경망의 출력  $h_t$ 는 현재 시각의 입력값인  $x_t$ 와 이전 시각의 은닉층에서 전달된  $h_{t-1}$ 에 대하여 식(2)와 같이 표현된다.

$$h_t = \sigma_h(W_h x_t + U_t h_{t-1} + b_h) \tag{2}$$

여기서,  $h_t, h_{t-1}$ 은 각각 임의의 시각 t 및 t-1에서의 출력값,  $\sigma_h$ 는 은닉층의 활성화 함수,  $W_h$ 는 입력값에 대한 가중치,  $x_t$ 는 임의의 시각 t에서의 입력값,  $U_t$ 는 은닉층에 대한 가중치,  $b_h$ 는 바이어스이다.

$\sigma_h$ 라고 표현되는 활성화 함수는 일반적으로 Hyperbolic Tangent 함수가 사용되고 있으며, Sigmoid나 ReLU와 같은 함수도 사용될 수 있다. 모델 내 가중치들은 인공신경망과 마찬가지로 역전파되면서 각 층에 대하여 오차 기울기를 이용하여 수정된다. 그러나 긴 시퀀스의 자료를 사용한 깊게 쌓은 심층 RNN의 경우 학습이 진행되다 오차경사의 기울기가 소실되고 입력층과 가까운 층에서의 데이터의 정보를 기억하지 못하고 학습에 활용할 수 없는 장기의존성(Long-term dependency) 소실 문제가 있다(Jung et al., 2018).

이러한 기존 순환신경망의 장기의존성 소실 문제를 해결하기 위하여 LSTM (Long Short-Term Memory)이 제안되었다(Hochreiter and Schmidhuber, 1997; Greff et al., 2017). 기울기 소실 문제란 순환신경망의 깊이가 깊어짐에 따라 입력 데이터에 가까운 층의 초기 정보가 사라지는 것을 의미한다. 이를 극복하기 위해 LSTM에서는 Cell State의 개념을 도입하여 장·단기 기억을 함께 저장 및 전달하도록 하였다. LSTM 레이어의 기본 구조는 Fig. 3과 같다.



※ Data source: Greff et al.(2017)

Fig. 3. Basic structure of Long Short-Term Memory (LSTM).

Cell state는 입력 게이트(Input gate), 망각 게이트(Forget gate), 출력 게이트(Output gate)의 값에 따라 업데이트된다. 먼저 망각 게이트  $f_t$ 는 이전 시각에 대한 정보를 버릴 것인지 결정하는데 식(3)과 같이 계산되며 0에서 1 사이의 값을 가진다. 입력 게이트  $i_t$ 는 현재 시각의 입력과 이전 시각에서 전달받은 값에 대하여 식(4)와 같이 표현된다. 현재의 Cell state  $C_t$ 는 입력 게이트를 후보 Cell state라고 하는  $\tilde{C}_t$ 와 곱한

것과 이전 Cell state  $C_{t-1}$ 에 망각 게이트  $f_t$ 가 곱해진 값을 통해 결정되는데 이를 표현하면 식(5) 및 (6)과 같다.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (5)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (6)$$

여기서,  $\sigma$ 는 활성화 함수,  $x_t$ 는 해당 시각의 입력이며,  $W_k$ 와  $b_k$ 는 임의 게이트  $k$ 에 대한 가중치 및 바이어스로 게이트별 각각의 값을 가진다.

출력 게이트  $o_t$ 는 식(7)과 같이 표현되며, LSTM의 최종적인 출력값은 Cell state와 출력 게이트에 의해 식(8)과 같이 계산된다.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \tanh(C_t) \quad (8)$$

### 2.3 모델 입·출력 자료

본 연구에서는 Huang et al.(2003) 및 Liang et al.(2008) 등의 연구와 같이 인근 관측소의 데이터를 입력하여 임의 정점의 조위를 생성하는 순환신경망 모델을 개발하였다.

모델의 입력 및 출력 자료는 국립해양조사원의 조위 관측소 자료를 사용하였으며, 사용된 조위 관측소의 위치는 Fig. 4와 같이 부산 신항(A-1), 통영(A-2), 부산항(B)이며 각 입력 데이터에 대하여 1개 관측소의 자료를 사용하였을 때와 2개 관측소의 자료를 사용하였을 때의 모델을 각각 구축하여 그 성능을 비교하였다. 각 실험 Case별 모델의 입력 및 출력 자료를 표로 나타내면 Table 1과 같다.

모델 학습을 위하여 2019년 1월 한 달의 자료를 사용하였으며, 학습된 모델의 정확도를 평가하기 위하여 2019년 2월에서 2020년 1월까지 1년의 자료를 사용하였다.

Table 1. Cases by No. time series and stations applied to long-term tidal level prediction model

Case	No. Time Series	Input Station	Output Station
1	1	Busan New Port	Busan Port
2		Tongyeong	
3	2	Busan New Port and Tongyeong	

### 2.4 모델 구성

본 연구에서 조위를 예측하기 위한 모델의 구조를 도식화하면 Fig. 5와 같다. 입력 데이터는 부산 신항 또는 통영의 48시간 조위 시계열 데이터를 사용하였다. 모델로는 LSTM으로 구현된 순환신경망(Hochreiter and Schmidhuber, 1997)을 사용하였으며, 출력으로 입력 자료의 마지막 시각의 부산 조위 관측소의 조위를 추정하도록 구성하였다.

개발된 모델의 명세는 Table 2와 같으며 부산 신항, 통영, 부산 신항과 통영을 입력으로 하는 3 Case에 대하여 부산 조위 관측소의 조위를 출력하도록 각각 개발하였다. 각 Case는 200, 100 및 50개의 LSTM 유닛으로 구성된 총 3개의 층으로 구현되었으며, 활성화 함수로는 순환신경망에서 널리 사용되는 Hyperbolic Tangent 함수를 사용하였다. 학습 데이터와의 오차를 계산하기 위한 손실함수로는 평균제곱오차(Mean Squared Error, MSE)가 사용되었으며, 학습을 위한 최적화 기법으로는 Adam 기법을 사용하였다. 또한 사전실험을 통해 확률론적 탐색을 위한 batch-size는 20개, 학습률은 0.00005, 학습 횟수(epoch)는 2,000회로 선택하였다. 또한 최종 학습된 모델의 성능을 평가하기 위한 지표로 상관계수(CC) 및 평균 제곱근 오차(RMSE)를 사용하였다(Kim and Yoon, 2011).




Fig. 4. The location of the tidal level observatory used in this study (A-1. Busan New Port, A-2. Tongyeong, B. Busan Port).

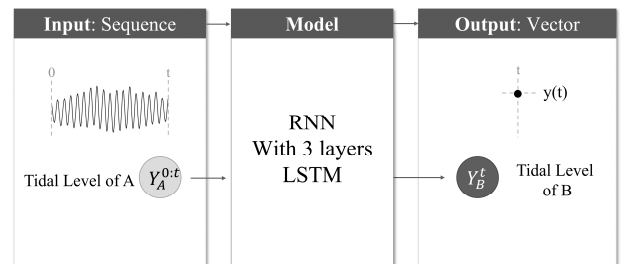


Fig. 5. Structure and calculation flow diagram of long-term tidal level prediction model.

Table 2. Characteristics of long-term tidal level prediction models

Parameters	Values	Parameters	Values
Model	RNN implemented by LSTM	Number of LSTM Unit	200-100-50
		Activation Function	Hyperbolic Tangent
Input	48 of hourly tidal level data at 1) Busan New Port, 2) Tongyeong, and 3) Busan New Port and Tongyeong	Loss Function	Mean Squared Error (MSE)
Output	Tidal level at Busan Port	Optimizer	Adam
Input Sequence Length	48	Learning Rate	0.00005
Number of LSTM layer	3	Performance	Correlation Coefficient (CC), Root Mean Squared Error (RMSE)

### 3. 결과 및 고찰

#### 3.1 각 Case별 조위 정확도 비교

전체 학습 기간에 대한 모델의 장기 조위 예측 결과와 실제 부산 조위 관측소의 조위 자료의 상관계수 및 평균 제곱근 오차는 Table 3과 같고 Case별 평균 제곱근 오차 및 상관관계를 그림으로 나타내면 각각 Fig. 6과 같다.

구축된 모델을 이용하여 3 Case에 대해 실험한 결과는 모든 Case에서 전체 기간에 대한 상관계수 0.99 이상으로 나타

나 딥러닝 추정 결과가 관측 데이터와 유사한 조위 패턴을 보임을 알 수 있다.

먼저 부산 신항 조위를 입력한 경우(Case 1)에 대하여 살펴보면 부산 조위 관측소의 예측 값이 관측 데이터와 높은 상관성을 보이거나, 전반적으로 과대평가된 것을 알 수 있다. 상관계수(CC) 0.997 및 평균 제곱근 오차(RMSE) 4.25 cm를 나타내었다. 통영 조위를 입력한 경우(Case 2)에는 상관계수(CC) 0.992 및 평균 제곱근 오차(RMSE) 4.17 cm로 나타났다. 마지막으로 부산 신항과 통영의 조위를 입력한 경우(Case 3) 다

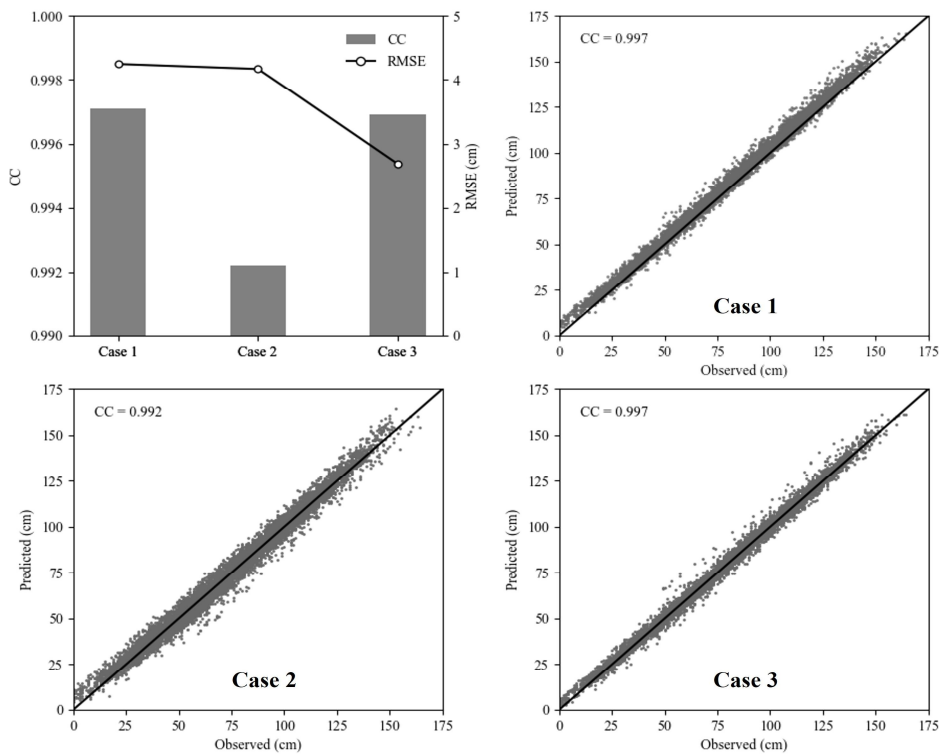


Fig. 6. RMSE (Root Mean Squared Error) and CC (Correlation Coefficient) of long-term tidal level prediction models and comparison between observed and predicted tidal level by cases in test period.

른 Case보다 가장 적은 오차 범위와 높은 상관계수를 가지고 있음을 알 수 있었으며, 상관계수(CC) 0.997 및 평균 제곱근 오차(RMSE) 2.69 cm를 나타내었다.

Table 3. CC (Correlation Coefficient) and RMSE (Root Mean Squared Error) of long-term tidal level prediction models in test period (Feb, 2019~Jan, 2020)

Case	CC	RMSE (cm)
1	0.997	4.25
2	0.992	4.17
3	0.997	2.69

### 3.2 비태풍시 조위 정확도 비교

전술한 결과는 2019년 2월에서 2020년 1월까지 1년의 자료를 사용함으로써 학습 입력 자료에는 태풍시와 비태풍시의 경우를 모두 포함하고 있다. 본 절에서는 학습된 딥러닝 모델을 이용하여 예측된 결과 중 태풍이 발생하지 않은 정상시에 한정하여 관측 데이터와 비교하였다.

Fig. 7은 모델의 테스트 기간 중 일부인 2019년 4월 3일부터 4월 12일에 대한 부산 조위 관측소의 모델의 예측치와 관측 데이터를 함께 나타낸 것이다. 그림에서 살펴보면 예측치와 관측치의 조위와 조시가 전반적으로 높은 일치율을 보인다. 따라서 구축된 모델은 비태풍시 조위 추정에서 높은 성능이 나타남을 알 수 있다.

### 3.3 태풍시 조위 정확도 비교

학습된 딥러닝 모델을 이용하여 예측된 결과를 태풍 내습 시기에 대하여 관측 데이터와 비교하였다. 대상으로 하는 태풍은 학습 입력 자료 중에서 2019년 9월 19일부터 9월 23일까지 활동했고 최저 기압 970 hPa를 기록했던 제17호 태풍 타파(TAPAH)이다.

태풍 상륙 시점에 대하여 부산 조위 관측소의 모델 예측치와 관측 데이터를 비교하여 나타내면 Fig. 8과 같다. 태풍의 내습 전후에는 비태풍시와 마찬가지로 관측치와 높은 일치율을 보이지만, 태풍이 부산에 근접한 2019년 9월 22일 및 23일에는 예측치의 오차가 증가하였다. 해당 기간에 대한 오차의 시계열을 확인하기 위하여 모델 예측치에서 관측치를 뺀 값을 Fig. 9로 나타내었다. 모델의 예측치는 Case 1, 2 및 3에서 관측치보다 각각 최대 9.16 cm, -15.06 cm 및 8.26 cm 높게 나타났다. Case에 따라 오차가 발생하는 정도 및 가장 큰 오차가 발생하는 시기는 상이하나, 전반적으로 유사한 오차 패턴을 보이는 것을 알 수 있다. 이처럼 오차의 발생은 태풍




Fig. 7. Comparison between observed and predicted by long-term tidal level prediction models in April 2019.




Fig. 8. Comparison between observed and predicted by long-term tidal level prediction models in typhoon Tapah 2019.




Fig. 9. Difference between model predictions and observed data by cases in typhoon Tapah 2019.

발생 시 급격한 기압 강하와 바람의 효과로 조위가 상승하여 평소와 다른 조위 패턴을 보이기 때문이며, 특히 모델 학습이 태풍이 발생하지 않은 2019년 1월에 대하여 수행되었기 때문으로 추정된다.

#### 4. 결론

본 연구에서는 딥러닝 기법인 LSTM으로 구현된 순환 신경망을 이용하여 부산 조위 관측소의 조위를 예측하는 모델을 개발하였다. 본 연구의 결과를 정리하면 다음과 같다.

1) 부산 조위 관측소의 조위를 예측하기 위하여 인근 관측소(부산 신항 및 통영)의 48시간 조위 자료를 입력하여 마지막 시각에서의 조위를 출력하는 순환신경망 모델을 개발하였다. 그 결과, 딥러닝 모델을 통해 단기 조위 관측 자료의 학습을 통하여 조위를 장기적으로 예측하는 것이 가능함을 확인할 수 있었다.

2) 학습된 모델을 가지고 2019년에 대한 1년간의 부산 조위 관측 자료를 생성한 결과, 3가지 실험 Case 모두에서 상관계수(CC) 0.99 이상 및 평균 제곱근 오차(RMSE) 5 cm 이하로 나타났다. 이를 통해 구축 모델의 임의 정점의 장기 조위 예측에 있어서 높은 성능을 보여주고 있다고 할 수 있다.

3) 하지만 학습된 모델은 태풍시 전반적으로 오차가 크게 증가하였으며, 이를 개선하기 위하여 태풍시에 대하여 학습 시키거나 추가 입력 데이터를 사용하는 등의 보완 연구가 필요함을 나타내고 있다.

최종적으로 본 연구에서는 상술한 바와 같이 부산 인근 관측소(부산 신항 및 통영)의 조위 자료를 입력으로 하는 딥러닝 기법을 이용하여 부산항의 조위를 예측하였다. 이와 같은 딥러닝 기법은 향후 보다 안전한 항만 및 해양구조물 설계, 태풍시 보다 빠른 의사결정 등을 위한 기초 데이터로 사용될 수 있을 것으로 기대된다.

#### 후 기

이 논문은 부경대학교 자율창의학술연구비(2021년)에 의하여 연구되었음.

#### References

- [1] Beltrami, G. M.(2008), An ANN algorithm for automatic, real-time tsunami detection in deep-sea level measurements, *Ocean Engineering*, Vol. 35, pp. 572-587.
- [2] Chang, H. K. and L. C. Lin(2006), Multi-point tidal prediction using artificial neural network with tide-generating forces, *Coastal Engineering*, Vol. 53, pp. 857-864.
- [3] Deo, M. C.(2010), Artificial neural networks in coastal and ocean engineering, *Indian Journal of Geo-Marine Science*, Vol 39, No. 5, pp. 589-596.
- [4] Greff, K., R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber(2017), LSTM: A search space odyssey, *IEEE transactions on neural networks and learning systems*, Vol. 28, No. 10, pp. 2222-2232.
- [5] Hochreiter, S. and J. Schmidhuber(1997), Long Short-Term Memory. *Neural Computation* Vol. 9, No. 8, pp. 1735-1780.
- [6] Huang, W., C. Murray, N. Kraus, and J. Rosati(2003), Development of a regional neural network for coastal water level predictions. *Ocean Engineering* Vol. 30, No. 17, pp. 2275-2295.
- [7] IHO(International Hydrographic Organization)(2018), Resolution on datums and benchmarks A2.5 3/1919, Resolutions of the International Hydrographic Organization Publication M-3 (2nd Edn).
- [8] Jung, S. H., H. Y. Cho, J. Y. Kim, and G. H. Lee(2018), Prediction of water level in a tidal river using a deep-learning based LSTM model, *Journal of Korea Water Resources Association*, Vol. 51, No. 12, pp. 1207-1216.
- [9] Kim, H. L.(2022), A Study on Irregular Tide Prediction Including Typhoon Effect Using a Deep Learning Approach, Pukyong National University, Ms thesis, p. 82.
- [10] Kim, T. Y. and H. S. Yoon(2011), Skill Assessments for Evaluation the Performance of the Hydrodynamic Model, *Journal of Korean Society for Marine Environmental Engineering*, Vol. 14, No. 2, pp. 107-113.
- [11] Kingma, D. P. and J. Ba(2014), Adam: A method for stochastic optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*.
- [12] Liang, S. X., M. C. Li, and Z. C. Sun(2008), Prediction models for tidal water-level including strong meteorologic effects using a neural network, *Ocean Engineering*, Vol. 35, No. 7, pp. 666-675.
- [13] Mandal, S., S. Rao, and D. H. Raju(2005), Ocean wave parameters estimation using back propagation neural network, *Elsevier J Marine Structures*, Vol. 18, pp. 301-318.
- [14] Park, J. S., K. M. Ahn, C. Y. Oh, and Y. S. Chang(2020), Estimation of Significant Wave Heights from X-Band Radar Using Artificial Neural Network, *Journal of Korean Society of Coastal and Ocean Engineering*, Vol. 32, No. 6, pp. 561-568.
- [15] Ustoorika, K. and M. C. Deo(2008), Filling up Gaps in Wave Data with Genetic Programming, *Marine Structures*, Elsevier, Vol. 20, pp. 177-195.
- [16] Wang, X. H., J. C. Yin, and H. F. Wang(2020), Modular Tide Prediction Model Based on Improved Wavelet Neural

Network, 2020 Chinese Control And Decision Conference (CCDC), Chinese Control And Decision Conference (CCDC), pp. 4234-4239.

- [17] Yagci, O., D. E. Mercan, H. K. Cigizoglu, and M. S. Kabdasli(2005), Artificial intelligence methods in breakwater damage ratio estimation, Elsevier J Ocean Engineering, Vol. 32, pp. 2088-2106.
- [18] Zisis, I. P. and T. Yingli(2019), Prediction of Sea Ice Motion With Convolutional Long Short-Term Memory Networks, IEEE Transactions on Geoscience and Remote Sensing, Vol. 57, No. 9, pp. 6865-6876.

---

Received : 2022. 04. 25.

Revised : 2022. 06. 07.

Accepted : 2022. 06. 27.