



LSTM을 이용한 탄천에서의 시간별 하천수위 모의

Hourly Water Level Simulation in Tancheon River Using an LSTM

박창연^{a,†}
Park, Chang Eon

ABSTRACT

This study was conducted on how to simulate runoff, which was done using existing physical models, using an LSTM (Long Short-Term Memory) model based on deep learning. Tancheon, the first tributary of the Han River, was selected as the target area for the model application. To apply the model, one water level observatory and four rainfall observatories were selected, and hourly data from 2020 to 2023 were collected to apply the model. River water level of the outlet of the Tancheon basin was simulated by inputting precipitation data from four rainfall observation stations in the basin and average preceding 72-hour precipitation data for each hour. As a result of water level simulation using 2021 to 2023 data for learning and testing with 2020 data, it was confirmed that reliable simulation results were produced through appropriate learning steps, reaching a certain mean absolute error in a short period time. Despite the short data period, it was found that the mean absolute percentage error was 0.5544~0.6226%, showing an accuracy of over 99.4%. As a result of comparing the simulated and observed values of the rapidly changing river water level during a specific heavy rain period, the coefficient of determination was found to be 0.9754 and 0.9884. It was determined that the performance of LSTM, which aims to simulate river water levels, could be improved by including preceding precipitation in the input data and using precipitation data from various rainfall observation stations within the basin.

Keywords: LSTM; machine learning; RNN; hourly water level; Tancheon river

1. 서론

최근에는 기후변화의 원인으로 추정되는 집중호우 등의 이상기후가 빈번하게 발생하고 있으며, 이러한 자연현상으로부터 홍수나 가뭄 등의 물 관련 재해를 방지하기 위한 다양한 노력이 시도되고 있다. 강우 발생으로부터 나타나는 유출 현상을 정확하게 예측하고자 하는 노력 또한 이러한 시도 가운데 하나로서, 기존의 물리적 수문모형을 사용하는 방법 이외에 인공지능을 활용하는 기계학습을 이용하여 수리/수문 현상을 모의하고 분석하는 방법이 활발하게 연구되고 있다.

Dawson and Wilby (1998)은 역전파 알고리즘 신경망을 이용하여 강우-유출 분석을 실시하여, 데이터 최적화에 따라 홍수예측의 정확도가 향상되는 것을 입증하였다. Coulibaly and Anctil (1999)은 효율적인 저수지 운영을 위해 순환신경망(RNN, Recurrent Neural Network)을 적용한 단기 저수지 유입량 예측을 수행하여, 실시간 수문예측의 가능성을 확인한 바

있다. Chang et al. (2014)는 도시지역의 홍수예보를 위하여 순환신경망 모형을 적용하여 실시간 하천수위를 모의하였다. 이러한 연구는 Hochreiter and Schmidhuber (1997)에 의한 순환신경망의 또 다른 진보를 이룬 LSTM (Long Short-Term Memory) 모형의 출현으로 시간별 변화를 모의할 수 있는 기계학습의 진보를 가져왔는데, Huang et al. (2021)은 LSTM을 비롯한 다양한 기계학습 모형과 물리적 모형을 활용하여 조석의 영향을 받는 하천 유량을 모의하였으며, 물리적 모형은 첨두유량을 잘 모의하는 반면 LSTM 모형은 평균유량을 잘 모의하는 것으로 확인하였다.

국내에서도 Seo et al. (2017)은 저수지 수위예측을 위하여, Kim et al. (2019)은 해양분야의 재해예방을 위하여, 또 다른 Kim et al. (2020)은 도시유역의 홍수분석을 위하여, Kim et al. (2022)는 관개용수로의 CCTV 이미지를 이용하기 위하여, Jeong et al. (2022)은 sms 확률적 적설심 예측을 위하여, Joo et al. (2023)은 농업용저수지에서 CCTV 영상 기반 수위예측을 위하여 심층 신경망을 적용하여 그 활용성을 보여주었다. 특히, Jung et al. (2018)은 감조하천인 한강 잠수교를 대상으로 LSTM 모형을 활용하여 수위를 예측한 결과 선행시간 1시간이 가장 높은 정확도를 보이는 것으로 제시한 바 있으며, 또 다른 Jung et al. (2021)은 섬진강 수계 구례 지점의 하천수위를 1, 3, 6시간 선행 예측하였는데 LSTM 모형이 다른

^a Professor, Department of Smart Construction Information, Shingu College

[†] Corresponding author

Tel.: ***-****-****

E-mail: cepark@shingu.ac.kr

Received: May 17, 2024

Revised: June 30, 2024

Accepted: July 01, 2024

모형보다 우수한 예측 성능을 보인 것으로 보고하였다. Jang et al. (2019)은 토양수분 산정을 위하여 LSTM 모형을 적용한 바 있으며, Lee et al. (2021)은 하천수위 예측을 위하여 태화강 유역에, Chun et al. (2022)은 최적 학습기간 예측을 위해 용담 댐 소유역의 상류지점에 LSTM 모형을 적용하여 그 활용성을 높이 평가하였다.

본 연구에서는 다양한 수문학적 인자에 영향을 받는 탄천 유역을 대상으로 순환신경망의 하나인 LSTM 모형을 활용하여 대곡교 지점의 하천수위를 모의하였다. 유역 내의 4개 강 우관측소의 시간별 강수량 자료와 함께 각 시간별 선행강수량을 입력자료로 사용하여 유역 말단에서의 하천수위를 모의하였으며, 이를 기존 연구의 모의 방법들과 비교하여 그 적용성을 평가하였다.

II. 연구 방법

1. LSTM 모형

본 연구에서는 시간별 하천수위 모의를 위하여 딥러닝 기반의 LSTM 모형을 구축하고, 시험유역을 대상으로 하천수위 모의값을 비교 및 검증하였다. LSTM 모형은 시계열 데이터를 처리하는 RNN의 개선되어진 모형으로서, 인공신경망 기법들 가운데 하천수위와 같은 시계열 자료를 분석하고 모의하는 데에 큰 장점을 가지고 있다.

일반적으로 인공신경망은 Fig. 1에서와 같이, 입력층 (Input layer), 은닉층 (Hidden layer) 및 출력층 (Output layer)의 구조로 구성되어 있으며, 입력층으로부터의 가중치 (U)와 출력층으로의 가중치 (V) 이외에 RNN은 은닉층 노드 사이의 가중치 (W)를 가지고 있다. 그래서, RNN에서는 학습에 사용된 이전 자료에 대한 가중치를 다음 자료의 학습에 반영하여 가중치를 산정하게 되는데, 이러한 특징 때문에 특히 시계열 데이터를 학습하는데 큰 강점이 있다. 그러나 이러한 RNN은 학습 자료의 수가 많아지고 은닉층의 개수가 커지게 되는 경우 오

차 경사의 기울기 소실 문제가 발생하며, 입력층에 가까운 은닉층의 학습 정보를 기억하지 못해 학습에 사용할 수 없다는 단점이 발견되어 이를 보완하기 위하여 LSTM 개념이 제시되었다 (Hochreiter and Schmidhuber, 1997).

LSTM은 Fig. 1에서 볼 수 있는 바와 같이, 은닉 노드에 메모리 블록을 배치하고, 입력 게이트와 출력 게이트가 붙어 있는 구조이다. 입력층의 입력 벡터도 입력 게이트와 출력 게이트의 입력으로 들어가지만, 메모리 블록의 출력 또한 입력 및 출력 게이트의 입력으로 들어간다는 것이 특징이다. LSTM은 이후에 메모리 블록에 망각 게이트를 추가하는 등 계속적인 진보가 이루어지고 있다 (Oh, 2017).

본 연구에 사용되어진 LSTM 모형의 학습 목적함수는 아래 공식 (1)과 같은 평균절대값오차 (mae, Mean Absolute Error)를 사용하였으며, 자료 전체기간의 모의 결과에 대한 성능평가를 위하여 공식 (2)의 평균절대값백분율오차 (mape, Mean Absolute Percentage Error)를 사용하였다. 다만, 강우가 발생한 기간의 모의되어진 하천수위에 대한 모의치와 관측치 비교는 결정계수 (R^2)를 활용하였다.

$$mae = \frac{1}{|M|} \sum_{x=1}^M |y - o| \quad (1)$$

$$mape = \frac{1}{|M|} \sum_{x=1}^M \left| \frac{y - o}{y} \right| \times 100 \quad (2)$$

여기서, M은 자료의 개수, y는 기댓값 (관측된 하천수위), o는 예측치 (모의된 하천수위)이다.

설계되어진 LSTM 모형의 은닉층의 노드 개수인 'unit' 수, 학습에 사용하는 선행시간 자료의 수 'time step', 한 번에 학습할 수 있는 'batch size' 등은 준비실험을 통하여 적절한 값을 찾도록 하였으며, optimizer는 경사하강법에 적응적 학습률을 구현할 수 있는 'Adam'을 사용하였다.

2. 대상 유역

본 연구는 경기도 성남시와 서울시 및 용인시 일부 지역을 통과하는 Fig. 2의 탄천을 대상 유역으로 하였다. 탄천은 한강의 제1지류이며, 유출량의 비교 및 평가는 하천수위를 관측하고 있는 대곡교 지점의 관측수위를 활용하였는데 대곡교 지점의 유역면적은 187.75 km²이다. 해당 유역에는 4개 지점의 강수량 자료를 사용할 수 있어 대상 유역으로 선택하였다.

한강홍수통제소에서는 탄천 유역에 1개의 수위관측소와 4개의 강우관측소를 운영하고 있으며, 실시간 관측자료는 관련 사이트 (<https://www.hrfco.go.kr>)를 통하여 공유하고 있다.




Fig. 1 Different structures between RNN and LSTM (Oh, 2017)



Fig. 2 Location of study area

Fig. 2에 표시되어진 유일한 수위관측소인 대곡교 지점은 서울시와 성남시의 경계에 위치하고 있으며, 4개소의 강우관측소는 구미초등학교 (PS1), 대장동 (PS2), 성남북초등학교 (PS3), 한국학중앙연구원 (PS4)에 위치하고 있다. 본 연구에서는 이들 관측소의 2020년부터 2023년까지 4개년의 시간별 강수량과 하천수위를 수집하여 모형의 학습과 평가에 사용하였다. 풍부한 기간의 자료를 학습에 사용할 수도 있으나, 탄천은 유역이나 하천의 유출특성 변화가 해마다 많이 발생되고 있는 지역으로서, 최근의 짧은 학습 자료기간에 대한 모형의 적용성을 검토하기 위하여 4년치 자료만을 사용하였다.

III. 결과 및 고찰

1. 선행강수량 자료의 입력자료 활용

탄천유역에서의 하천수위 모의를 위한 LSTM 모형의 적용은 4개 강우관측소 지점의 강수량 자료와 각 시간별 선행강수량 자료를 입력하여 시간별 하천수위를 모의하도록 하였다. 강수량 자료는 각 지점의 시간별 원자료를 입력자료로 사용하였으며, 선행강수량 자료는 각 시간별로 이전 72시간 동안 발생하였던 시간평균 강수량을 계산하여 입력하였으며, 전체 5개 강수량 자료로부터 하천수위를 모의하도록 구성하였다. 모의를 위하여 1개로 구성된 은닉층의 노드 개수 unit은 16개, time step은 6시간, batch size는 64로 설정하였다. 또한, 강수량

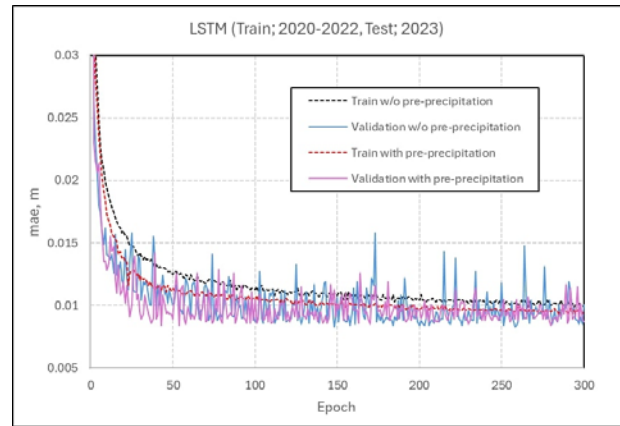


Fig. 3 Results of LSTM model simulations

및 하천수위 자료는 2020~2022년 자료는 학습에, 2023년 자료는 검정에 사용하였다.

Fig. 3은 탄천의 하천수위를 모의할 수 있는 LSTM 모형의 모의 결과를 보여준다. 선행강수량을 고려하지 않고 4개 지점 강수량 자료만 사용하는 경우와 비교하였는데, 선행강수량을 포함하는 입력자료를 사용하는 경우에 더 빠른 속도로 mae가 감소하면서 학습이 이루어지는 것을 볼 수 있으며, 검정 결과도 선행강수량을 포함하지 않은 입력자료를 사용하는 경우보다 더 이른 반복계산 Epoch에서 더 낮은 mae값으로 수렴해 나가는 것으로 나타났다. 사용되는 자료에 의한 과적합을 판단하기 위하여 k-겹 교차검증을 실시하였으며, 자료의 기간이 전체 4년인 것을 감안하여 k=4로 설정하여 평균 정확률 99.51%를 얻을 수 있었으며, 충분히 신뢰성 있는 모의결과를 얻을 수 있는 것으로 판단되었다.

Fig. 4는 Fig. 3의 모의결과 가운데 가장 안정된 검정 결과를 보여주는 Epoch 240~260 구간에서의 mae, mape를 비교하였는데, 학습 시에는 선행강수량을 포함하여 학습하였을 경우에 mae 0.0095~0.0099 m, mape 0.4651~0.4833%로서 선행강수량을 포함하지 않았을 경우의 mae 0.0101~0.0104 m, mape 0.4929~0.5103%보다 낮은 값을 보여 학습이 더 정밀하게 이루어진 것을 확인할 수 있으며, 검정 시에도 선행강수량을 포함하지 않은 경우의 mae 0.0083~0.0118 m, mape 0.3794~0.5545%보다 선행강수량을 포함한 경우에 mae 0.0087~0.0105 m, mape 0.3937~0.4870%로 더 편차가 적은 안정되고 양호한 평가가 이루어지는 것을 알 수 있었다. 이를 2023년의 강수량이 크게 나타났던 7월 11일과 7월 13일 강수에 대하여 일정 시간동안의 하천수위 모의치와 관측치 사이의 차이를 확인하기 위하여 결정계수 (R^2)를 비교한 결과에서도 R^2 의 최소값과 평균값이 선행강수량을 포함하는 경우에




Fig. 4 Comparison according to whether or not preceding precipitation is including

더 높게 나타났는데, 7월 13일 강수의 경우는 선행강수량을 포함한 경우가 평균 R^2 가 0.9674로서 포함하지 않은 경우의 0.9603보다 큰 값을 보여, 선행강수량을 포함하여 학습시킨 하천수위 모의치가 관측치에 더 일치하는 것으로 나타났다.

2. 학습 자료기간의 변경

Fig. 4에서의 2023년 7월 11일 강수에 대한 R^2 는 평균 0.7882 정도로 상당히 낮은 값을 보였는데, 실측 강수량과 하천수위 자료가 충분히 정확하다는 가정하에서 그 원인은 각 강우관측소 간의 시간별 강수량 분포의 차이에서 기인한 것으로 추정할 수 있었다. Fig. 5는 해당일의 누가강수량을 강우 관측소 지점별로 표시한 것으로, PS3 (성남북초등학교) 지점은 Fig. 2에서 볼 수 있듯이 유일하게 해당 유역의 동쪽에 위치하여 다른 인근의 3개 지점들과는 다른 시간대에 호우가 발생하였던 것으로 나타났다. 이러한 강우분포는 학습자료로 사용되어진 2020년~2022년에는 나타나지 않았던 현상으로 학습이 이루어지지 못한 상황에 대하여 모의 오차가 발생할 수밖에 없었던 것으로 판단되었다. 이러한 현상은 기후변화와 함께 계절라성 호우가 발생하는 빈도가 점점 커지고 있는 최근의 상황을 보여주는 것으로 추정되며, 이러한 최근 자료를 학습에 사용하여 하천수위 모의결과를 비교하도록 하였다.

Fig. 5와 같이 지점별로 상이한 강우분포를 포함하고 있는 2023년의 자료를 학습에 사용하기 위하여, 2021년~2023년의 자료를 학습에 사용하고 2020년 자료로 검정을 실시하였다. Epoch 240~260 구간에서의 모의 결과를 비교하면 mae는 학습 시는 0.0083~0.0087 m, 검정 시는 0.0120~0.0139 m로 나타났으며, mape는 학습 시는 0.4127~0.4308%, 검정 시는 0.5544~0.6226%로서 2023년 자료를 학습에 사용하였을 경우 학습 시 오차는 줄어들었으나 검정 시 오차는 조금 증가한 것으로 나타났으나, 검정 시 정확률이 99% 이상을 초과하여 하천수위 모의는 적절히 이루어진 것으로 판단되었다.

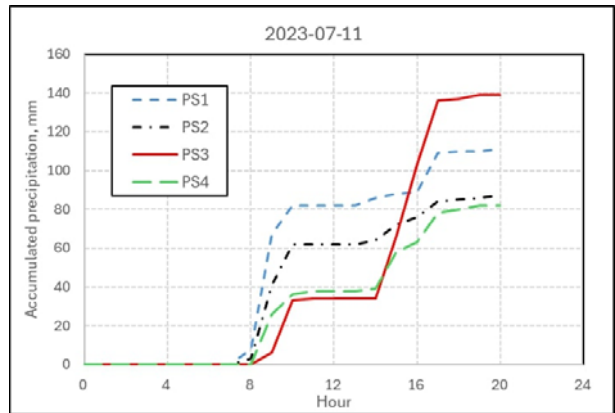


Fig. 5 Accumulated precipitation in study area




Fig. 6 Comparison of simulation results in validation and training

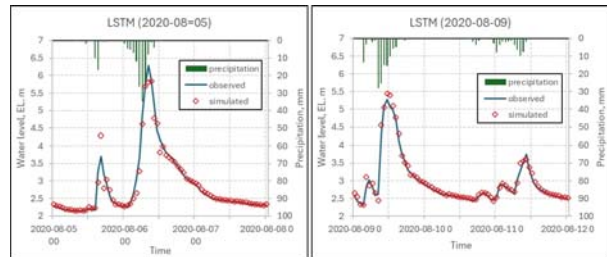


Fig. 7 Simulation results in validation

Fig. 6은 2023년 자료를 검정에 사용하여 R^2 이 0.7882였던 2023년 7월 11일의 하천수위 모의 결과와 2023년 자료를 학습에 사용한 같은 일의 하천수위 모의 결과를 관측치와 비교하여 보여주고 있으며, R^2 이 0.9975로서 특이한 강우분포를 보이는 강수량 자료가 포함되어진 입력자료로 적절한 학습이 이루어진 것을 알 수 있었다. Fig. 7에서는 검정에 사용되어진 2020년 자료에서 호우가 발생한 8월 5일과 8월 9일 강수에 대한 하천수위 모의 결과를 보여주고 있는데, 각각 결정계수가 0.9754, 0.9884로 매우 양호한 모의가 이루어졌음을 알 수 있었다.

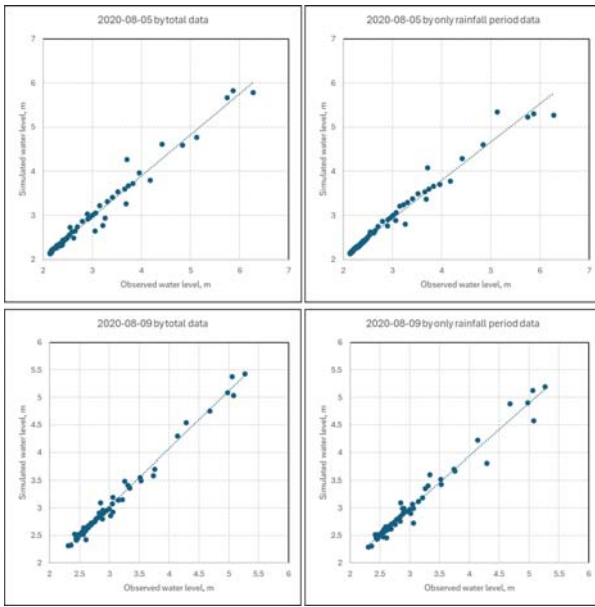


Fig. 8 Comparison of simulation results

3. 강우기간 자료만 사용하는 경우와의 비교

학습 성과를 높이기 위하여 강우기간 자료만을 학습에 사용하는 경우와 비교하기 위하여 2021~2023년의 자료에서 강우가 10 mm 이상 발생한 기간의 자료만 선별하여 학습에 사용하여, 무강우 기간을 포함하는 전체 자료를 모두 사용한 경우의 모의결과와 비교하였다. 강우기간 자료만 사용하게 되는 경우 자료의 수가 줄어들게 되어 은닉층의 unit 수는 8개로 구성하여 모의를 실시하였으며, 선행강수량은 입력자료에 포함하여 학습을 실시하였다. Fig. 8은 검정에 사용되어진 2020년 8월 5일과 8월 9일의 호우에 대한 하천수위의 모의치와 관측치를 비교한 것으로, 학습에 무강우 기간을 포함하는 전 데이터를 사용한 경우의 R^2 인 0.9754, 0.9884보다 강우기간 자료만을 사용한 경우의 R^2 이 더 적은 0.9740, 0.9727을 보여, 특별한 경우가 아니라면 강우기간만을 따로 분리하여 학습시킬 필요는 없을 것으로 판단되었다.

4. 1개 지점 강우자료만 사용하는 경우와의 비교

본 연구에서는 유역 내 4개 지점의 강우관측소 강수량 자료를 모두 활용하였는데, 1개 지점의 자료만 있는 것으로 가정하여 하천수위를 모의한 결과와 비교하였다. Fig. 9는 4개 강우관측소 강수량 자료 가운데 1개 관측소 자료만을 사용하는 경우와 4개 관측소 자료 전체를 사용하는 경우의 학습 시 mae 변화를 비교한 그림이다. 그림에서 볼 수 있듯이, 4개 지점의 강수량 자료를 함께 사용하는 경우가 1개 지점의 강수량

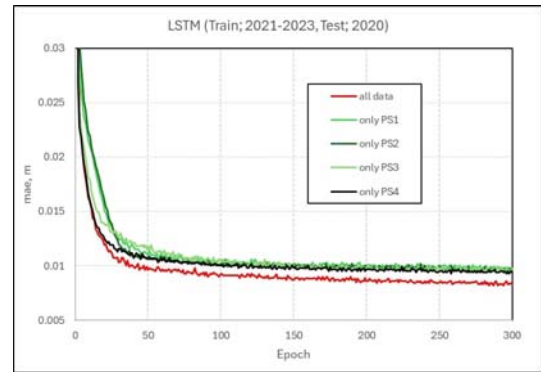


Fig. 9 Comparison of mae according to used precipitation data




Fig. 10 Comparison of R^2 according to used precipitation data

자료만 사용하는 경우보다 훨씬 낮은 오차에서 수렴되고 있는 것을 알 수 있으며, 이로부터 유역 내 여러 지점의 강수량 자료를 입력자료로 사용하는 것이 LSTM 모델을 적용하는데 유리할 것으로 판단되었다.

Fig. 10은 검정 시 호우가 발생한 8월 5일과 8월 9일에 대하여 하천수위 관측치와 모의치의 결정계수를 비교한 그림으로서, Fig. 9에서 안정된 모의 결과를 보이는 Epoch 240~260 구간에 대하여 분석하였다. 그림에서 8월 5일의 경우는 PS1, PS2 지점의 자료만을 사용한 경우의 R^2 평균이 각각 0.9816, 0.9814로서 4개 지점의 자료를 모두 사용하는 경우의 평균 R^2 인 0.9607보다 높은 값을 보였으나, 8월 9일의 강우에 대해서는 모든 경우에서 4개 지점 자료를 모두 사용하는 경우가 더 높은 R^2 평균치인 0.9561을 나타내어 전체적으로 유역 내 여러 지점의 강수량 자료를 함께 사용하는 경우에 모의결과의 정확성을 제고할 수 있을 것으로 판단되었다. 한편, 특이한 강우분포를 보였던 PS3 지점의 강우자료만을 사용하는 경우는 상대적으로 낮은 R^2 인 평균 0.9008을 보였으나, 전체적으로 1개 지점의 강우자료만을 사용하여도 R^2 이 0.9를 초과하는 충분히 신뢰성 있는 하천수위 모의가 가능한 것으로 판단되었다.

IV. 결론

인공지능의 기계학습을 활용하여 유역의 하천수위를 모의할 수 있는 기술에 대하여 그 적용성을 평가하기 위하여, LSTM 모델을 탄천 유역에 적용하였다. 탄천 유역 내의 4개 강우관측소 강수량 자료와 각 시간별 직전 72시간 평균 선행강수량 자료를 입력하여 유역 출구에서의 하천수위를 모의하도록 하였으며, 2020~2023년의 최근 강수량 자료와 하천수위 자료를 수집하여 학습 및 평가에 사용하였다. 2021~2023년 자료를 학습에 사용하고 2020년 자료로 검증을 실시하도록 한 하천수위 모의 결과, 짧은 자료기간에도 불구하고 빠른 시간에 일정한 평균절대값오차 (mae)에 도달하는 등 학습이 적절히 이루어지는 것으로 나타났으며, 검증 결과 평균절대값백분율오차 (mape)가 0.5544~0.6226%로서 99.4% 이상의 정확성을 보여주었다. 또한, 특정 호우기간에서의 급격하게 변화되는 하천수위의 모의치와 관측치를 비교한 결과, 결정계수 (R^2)가 0.9754, 0.9884로서 매우 일치하는 것으로 나타나, 4개 지점 강수량 자료와 선행강수량 자료를 입력자료로 하여 하천수위를 모의하도록 구성된 LSTM 모형은 적용성이 있는 것으로 판단되었다.

선행강수량을 입력자료에 포함하여 하천수위를 모의한 결과는 선행강수량을 포함하지 않는 경우에 비하여 학습 시 빠른 시간에 mae값이 감소하고 mape값 또한 편차가 적고 낮은 값을 나타내어, 선행강수량을 포함하여 더 높은 성능을 보인 것으로 판단되었다. 또한, 호우 시 학습효과 제고를 위하여 강우기간 자료만으로 학습하는 경우와 비교한 결과, 강우기간 자료만을 사용한 경우의 호우 기간 R^2 인 0.9740, 0.9727이 무강우 기간을 포함하는 전체 자료를 사용한 0.9754, 0.9884보다 조금 낮게 나타나, 짧은 자료기간을 고려하더라도 특별한 목적이 아니라면 무강우 기간을 자료에서 제외하지 않고 학습에 사용하여도 호우 시에 높은 모의 성능을 보여줄 수 있을 것으로 판단되었다. 본 연구에서는 유역 내의 4개 지점의 강수량 자료를 사용하였는데, 1개 지점의 강수량 자료만 사용하는 경우보다 훨씬 낮은 mae값으로 빠르게 수렴되는 학습단계를 확인할 수 있었으며, 호우 시 일정 기간의 모의 결과 또한 R^2 이 평균 0.9607, 0.9561로 높게 나타나는 등 모의 성능을 높일 수 있었던 것으로 판단하였다.

학습을 위한 자료기간이 짧으면, 충분한 학습이 이루어질 수 없을 수도 있으며, 미래에 발생할 수 있는 하천수위 모의를 위하여는 최근의 강수량 자료를 학습에 사용하는 것이 바람직할 것으로 판단되었으며, 자료기간에 따른 모형 성능의 상세한 비교 연구는 추후에 계속 진행되어 미계측 유역을 비롯한 우리나라 하천의 모든 필요한 곳에서 쉽게 기계학습에 의한 수문분석이 활발히 이루어지기를 기대한다.

감사의 글

본 연구는 신구대학교 산학협력단의 연구비 지원사업으로 수행되었음.

REFERENCES

- Chang, F. J., P. A. Chen, Y. R. Lu, E. Huang, and K. Y. Chang, 2014. Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control. *Journal of Hydrology* 517: 836-846.
- Chun, B. S., T. H. Lee, S. W. Kim, K. J. Im, Y. H. Jung, J. W. Do, and Y. C. Shin, 2022. Estimation of optimal training period for the deep-learning LSTM model to forecast CMIP5-based streamflow. *Journal of the Korean Society of Agricultural Engineers* 64(1): 39-50. (in Korean).
- Coulbaly, P., and F. Anctil, 1999. Real-time short-term natural water inflows forecasting using recurrent neural networks. In *Proc. International Joint Conference on IEEE*, 3802-3805. Washington DC, U.S.
- Dawson, C. W., and R. Wilby, 1998. An artificial neural network approach to rainfall-runoff modeling. *Hydrological Sciences Journal* 43(1): 47-66.
- Hochreiter, S., and J. Schmidhuber, 1997. Long short-term memory. *Neural Computation* 9(8): 1735-1780.
- Huang, X., Y. Li, Z. Tian, Q. Ye, Q. Ke, D. Fan, G. Mao, A. Chen, and J. Liu, 2021. Evaluation of short-term streamflow prediction methods in urban river basins. *Physics and Chemistry of the Earth, Parts A/B/C* 123. doi: 10.1016/j.pce.2021.103019.
- Jang, W., Y. Lee, J. Lee, and S. Kim, 2019. RNN-LSTM based soil moisture estimation using Terra MODIS NDVI and LST. *Journal of the Korean Society of Agricultural Engineers* 61(6): 123-132. (in Korean).
- Jeong, Y., Y. Lee, S. I. Lee, J. Seo, B. Kim, D. Seo, and Y. C. Won, 2022. Development of a stochastic snow depth prediction model using a Bayesian deep learning method. *Journal of the Korean Society of Agricultural Engineers* 64(6): 35-41. (in Korean).
- Joo, D., S. H. Lee, G. H. Choi, S. H. Yoo, R. Na, H. Kim, C. J. Oh, and K. S. Yoon, 2023. Development of methodology for measuring water level in agricultural water reservoir through deep learning analysis of CCTV images. *Journal of the Korean Society of Agricultural*

- Engineers* 65(1): 15-26. (in Korean).
10. Jung, J., H. Mo, J. Lee, Y. Yoo, and H. S. Kim, 2021. Flood stage forecasting at the Gurye-Gyo station in Sumjin River using LSTM-based deep learning models. *Journal of the Korean Society of Hazard Mitigation* 21(3): 193-201.
 11. Jung, S., H. Cho, J. Kim, and G. Lee, 2018. Prediction of water level in a tidal river using a deep-learning based LSTM model. *Journal of Korea Water Resources Association* 51(12): 1207-1216.
 12. Kim, H. I., J. Y. Lee, K. Y. Han, and J. W. Chow, 2020. Applying observed rainfall and deep neural network for urban flood analysis. *Journal of the Korean Society of Hazard Mitigation* 20(1): 339-350.
 13. Kim, K. H., M. G. Kim, P. R. Yoon, J. H. Bang, W. H. Myoung, J. Y. Choi, and G. H. Choi, 2022. Application of CCTV image and semantic segmentation model for water level estimation of irrigation channel. *Journal of the Korean Society of Agricultural Engineers* 64(3): 63-73. (in Korean).
 14. Kim, Y. G., T. W. Kim, J. S. Yoon, and M. K. Kim, 2019. Study of the construction of a coastal disaster prevention system using deep learning. *Journal of Ocean Engineering and Technology* 33(6): 590-596.
 15. Lee, M., J. Kim, Y. Yoo, H. S. Kim, S. E. Kim, and S. Kim, 2021. Water level prediction in Taewha River basin using deep learning model based on DNN and LSTM. *Journal of Korea Water Resources Association* 54(S-1): 1061-1069. (in Korean).
 16. Oh, I. S., 2017. *Machine learning*. Hanbit Academy, Inc., pp. 417-460.
 17. Seo, Y., E. Choi, and W. Yoo, 2017. Reservoir water level forecasting using machine learning models. *Journal of the Korean Society of Agricultural Engineers* 59(3): 97-110. (in Korean).