

딥러닝을 활용한 산지습지 수위 예측 모형 개발

김동현·김정욱*·곽재원**·아이미·김종성·김형수***,†

인하대학교 토목공학과

*국립환경과학원 물환경연구부 물환경평가연구과

**낙동강홍수통제소

***인하대학교 사회인프라공학과

Development of Water Level Prediction Models Using Deep Neural Network in Mountain Wetlands

Donghyun Kim·Jungwook Kim*·Jaewon Kwak**·Imee V. Necesito·Jongsung Kim·Hung Soo Kim***,†

Department of Civil Engineering, Inha University

*Water Quality Assessment Research Division, Water Environment Research Department, National Institute of Environment Research

**Nakdong River Flood Control Office

***Department of Civil Engineering, Inha University

(Received : 06 May 2020, Revised : 18 May 2020, Accepted : 18 May 2020)

요약

습지는 수문, 환경, 생태학적으로 중요한 기능 및 역할을 하며, 특히 습지 내의 수위는 습지의 기능과 환경 등 다양한 분석을 위해 필수적인 자료이다. 그러나 습지는 수위자료를 측정하지 않는 미계측 지역이 많기 때문에, 수위 예측에 대한 연구는 매우 미흡한 실정이다. 따라서 본 연구에서는 습지의 수위를 예측하기 위해 다중회귀분석, 주성분회귀분석, 인공신경망, DNN을 활용하여 수위 예측모형을 개발하였다. 대상지역으로 경상남도 양산시에 위치한 금정산 산지습지를 선정하였고, 2017년 4월부터 2018년 7월까지의 수위 측정자료를 종속변수로 사용하였다. 수문자료와 기상자료를 독립변수로 사용하였다. 예측력 평가결과 최종 모형으로 선정된 DNN을 활용한 수위 예측모형의 예측력 평가결과 RMSE는 6.359, NRMSE는 18.91%로 비교적 산지 습지의 수위를 잘 예측하는 것으로 나타났다. 본 연구결과를 활용한다면 기존의 미비하였던 미계측 지점의 수위를 활용한 습지 유지 및 관리 기법 개발에 기초자료로 사용할 수 있을 것으로 판단된다.

핵심용어 : 딥러닝, 산지습지, 주성분분석, 인공신경망

Abstract

Wetlands play an important function and role in hydrological, environmental, and ecological, aspects of the watershed. Water level in wetlands is essential for various analysis such as for the determination of wetland function and its effects on the environment. Since several wetlands are ungauged, research on wetland water level prediction are uncommon. Therefore, this study developed a water level prediction model using multiple regression analysis, principal component regression analysis, artificial neural network, and DNN to predict wetland water level. Geumjeong-Mountain Wetland located in Yangsan-city, Gyeongsangnam-do province was selected as the target area, and the water level measurement data from April 2017 to July 2018 was used as the dependent variable. On the other hand, hydrological and meteorological

† To whom correspondence should be addressed.
Department of Civil Engineering, Inha University
E-mail: sookim@inha.ac.kr

- Donghyun Kim Department of Civil Engineering, Inha University / Doctor's Course (yesdktpdi@naver.com)
- Jungwook Kim Water Quality Assessment Research Division, Water Environment Research Department, National Institute of Environment Research / Researcher (kjjw1128@korea.kr)
- Jaewon Kwak Nakdong River Flood Control Office / Researcher (firstsword@naver.com)
- Imee V. Necesito Department of Civil Engineering, Inha University / Doctor's Course (imeenecesito@inha.edu)
- Jongsung Kim Department of Civil Engineering, Inha University / Doctor's Course (kjjs0308@naver.com)
- Hung Soo Kim Department of Civil Engineering, Inha University / Professor (sookim@inha.ac.kr)

data were used as independent variables in the study. As a result of evaluating the predictive power, the water level prediction model using DNN was selected as the final model as it showed an RMSE value of 6.359 and an NRMSE value of 18.91%. This research study is believed to be useful especially as a basic data for the development of wetland maintenance and management techniques using the water level of the existing unmeasured points.

Key words : Deep Learning, Mountain Wetland, Principal Component Analysis, Artificial Neural Network

1. 서 론

습지는 수위조절, 홍수 및 가뭄 저감 등 환경적, 생태적, 수문학적 측면으로 인간 생활에 중요한 역할을 하고 있고, 유량, 수위 및 침수심 등 수리·수문학적인 조건은 습지를 비롯한 수(水)환경에 대하여 중요한 제약조건이다(Kwak et al., 2017; Kim et al., 2017). 특히, 습지에 서식하는 생물 종에 따라 침수심 또는 허용 수위의 제한을 가지고 있다. 따라서 생물 종에 따라 수리·수문환경 조건이 매우 다르게 나타나기 때문에, 적절한 습지의 관리 및 보호를 위해서는 수위 측정 및 예측이 중요한 것으로 알려져 있다(Keddy et al., 2000; Bittmann et al., 1965). 전 세계적으로 습지의 수위를 측정 및 예측하는 것이 중요하다는 것은 강조되고 있지만, 람사르 습지(Ramsar wetlands) 등과 같은 일부 습지에 국한되어 수위를 측정하고 있다. 또한, 많은 국가에서 습지의 수위를 측정할 필요가 있는 특정한 경우에 수위계를 이용하여 수위를 측정하지만, 해당 연구가 끝난 경우 더 이상 모니터링(monitoring)을 진행하지 않아 습지 데이터를 장기적으로 확보하는데 어려움이 있다. 람사르 습지와 같은 세계적으로 중요한 습지 이외에도 하천 주변에는 많은 습지가 존재하고 이러한 습지가 하천의 지속가능한 이용과 건강한 생태계에 매우 중요하다(Kim et al., 2019). 단계적으로 습지의 수위 관측소를 늘려가야 하지만, 모든 습지 유역에 수위 관측소를 설치하기에는 예산 및 장비의 한계가 발생하기 때문에 기존에 구축된 자료를 활용하여 습지의 수위를 예측하는 연구가 필요하다고 판단된다.

국내·외에서 수위 데이터를 예측하기 위한 선행연구들을 살펴보면, 주로 하천, 습지 등에 통계적 모형을 활용하여 예측한 사례들이 있었다(Kumar et al., 2005; Yu et al., 2006; Chau., 2006). 하천의 수위를 예측한 사례들을 살펴보면 주로 시계열 모형(Time series model)과 인공신경망(artificial neural network, ANN)을 활용하여 하천 수위를 예측하였다(Tiwari et al., 2010; Jun et al., 2013; Byeon et al., 2014; Castillo et al., 2018). 습지의 수위를 예측한 연구를 살펴보면, Rezaeianzadeh et al. (2015)은 수위를 예측하는데 있어 인공신경망을 습지 수위예측에도 적용시켜 Baseflow recession analysis와 같이 그 적용 가능성을 평가하였다. 또한, Rezaeianzadeh et al. (2018)은 습지 수위 모델링을 통하여 미국 해안 Alabama 주 상류에 위치한 습지에 적용하였다.

수위 예측에 관한 기존 연구들을 살펴보면, 주로 통계적

모형을 사용하였고, 강우, 온도 등 기상학적 자료를 독립변수로 사용하였다. 그러나 습지의 수위 예측연구의 경우 사례를 찾아보기 쉽지 않을 만큼 매우 미비하였고, 다양한 통계모형을 적용하여 지역에 맞는 통계모형을 평가 및 비교하여 예측하였던 하천에서의 수위 예측 연구과는 달리 인공신경망을 활용하여 다양한 통계모형들과 적용 가능성을 비교 및 평가하지 못하는 한계가 있었다. 따라서, 본 연구에서는 기존의 인공신경망 이외에 다중회귀분석(multiple regression analysis), 주성분회귀분석(principal component analysis), DNN(deep neural network)과 같은 다양한 통계모형을 활용하여 습지에 적합한 수위 예측모형을 개발하고자 한다. 개발된 모형을 통해 예측된 수위를 활용하여 습지의 침수범위 및 침수심을 분석할 수 있고, 이를 통해 습지에 서식하고 있는 생물의 서식환경 변화와 기능변화를 예측할 수 있다. 하지만 습지수위 예측에 관한 연구는 미흡하여 미계측 습지 유역에 대한 관리가 어렵다. 따라서 본 연구에서 개발된 수위 예측 모형은 수위의 관측이 어려운 미계측 유역에 대하여 수위 예측을 위한 대체 방법이 될 수 있을 것이라 기대한다.

이를 위해 본 연구에서는 경상남도 양산시에 위치한 금정산 산지습지를 대상지역으로 선정하였고, 금정산 산지습지의 수위자료를 종속변수로 구축하였다. 우포늪과 가장 가까운 기상관측소의 기상자료를 독립변수로 구축하였다. 모형의 과적합을 방지하기 위해 자료를 학습구간(training)과 예측구간(test)으로 구분하였고, 학습구간의 데이터를 활용하여 다중회귀분석, 주성분회귀분석, 인공신경망, DNN과 같은 다양한 통계모형을 활용하여 우포늪의 수위 예측모형을 개발하였다. 개발된 예측모형을 Test 구간의 데이터에 입력하여 예측 수위를 산정하였고, 상관계수(Correlation Coefficient), RMSE(Root Mean Square Error)를 평가지표를 활용하여 모형별 예측 성능을 평가하였다.

2. 연구방법

2.1 다중회귀분석

다중회귀분석은 독립변수(dependent variable)가 2개 이상으로 구성되고, 독립변수의 값을 이용하여 종속변수(independent variable)의 값을 예측하는 통계적 기법을 이야기한다. 다중회귀분석은 선형함수라고 가정하여 종속변수 y 에 대하여 n 개의 독립변수 $x_1, x_2, x_3 \dots x_n$ 의 관계를 다음 Eq. (1)과 같이 나타낸다.

$$y_i' = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_i + \epsilon_i \quad (1)$$

$(i = 1, 2, \dots, n), \epsilon_i \sim n(0, \sigma^2)$

여기서, β_0 은 상수, $\beta_1, \beta_2, \dots, \beta_i$ 은 독립변수의 회귀계수, ϵ_i 은 종속변수를 예측할 때 발생하는 오차를 뜻한다. 또한, 회귀모형에서는 독립변수들 간의 상관관계가 높을 경우 다중공선성의 문제가 발생한다(Kim et al., 2018). 다중공선성을 판별하기 위하여 분산 분산팽창요인(Variance Inflation Factor, VIF)을 통해 평가하고, VIF가 10 이상일 때 다중공선성이 높다고 판단한다(Kim et al., 2017). 다중공선성을 해결하기 위하여 통계적 유의성이 높은 변수를 추출할 수 있는 변수선택법을 고려할 수 있고, 변수선택법으로는 가장 예측력이 좋은 단계적 선택법(Stepwise), 전진 선택법(Forward), 후방 소거법(Backward)이 있다.

2.2 주성분 회귀 분석

주성분 분석(Principal Component Analysis, PCA)은 일부 변수를 추출하지 않고, 공분산 행렬이나 상관행렬의 연산을 통하여 상관성이 강한 여러 가지의 변수들 사이에서 소수의 성분만을 추출하는 통계기법이다(Kim et al., 2018). 그리고 이러한 차원 축소 과정을 통하여 다중공선성 문제를 해결할 수 있다. 또한, 주성분 회귀분석은 전체 변수의 90%이상의 정보를 포함하고 있어, 일부 변수만을 추출하는 방법보다는 정보손실 측면에서 더 효율적이라고 할 수 있다. 다음 Eq. (2)는 주성분 회귀분석에 대한 식을 나타냈다.

$$y_{i,j} = \beta_{0,j} + \beta_{1,j} \xi_{i,1} + \dots + \beta_{K,j} \xi_{i,k} + \epsilon_{i,j} \quad (2)$$

$(i = 1, 2, \dots, n)$

여기서, $\xi_{i,k}$ 는 $\tilde{\Sigma}$ 행렬의 (i,k) 위치의 값이며, 이는 모든 $j(j = 1, \dots, p)$ 에 대하여 시행한다(임예지, 2017).

2.3 인공신경망

인공신경망의 구조는 다음과 같다. 예측하고자 하는 변수가




Fig. 1. The Structure of Artificial Neural Network

입력 되어지는 입력층(input layer), 외부와 직접연결이 이루어지지 않는 은닉층(hidden layer), 예측결과를 출력해주는 출력층(output layer)으로 구분된다(Choi et al., 2009). 인공신경망은 학습(training)을 통하여 예측인자(predictor)와 예측변수(predictand) 사이의 관계를 학습하고, 예측인자와 예측변수 사이의 관계를 추정한다(Kang et al., 2008). 다음 Fig 1과 같이 인공신경망의 구조를 도식화 하였다.

2.4 DNN(deep neural network)

딥러닝의 핵심은 수많은 데이터 속에서 패턴을 발견하여 예측하는 것이다. 기존의 머신러닝 알고리즘들은 데이터의 양이 많아질수록 성능에 한계가 있으나, 딥러닝은 데이터의 양이 많아질수록 성능이 선형적으로 증가하는 장점이 있다. DNN의 구조는 인공신경망과 비슷하지만, Hidden layer에서 2개 이상의 개수를 지니는 차이점이 있다. 다음 Fig. 2와 같이 DNN의 구조를 도식화 하였다.




Fig. 2. The Structure of Deep Neural Network

2.5 예측력 평가 기법

예측력 평가 방법으로는 평균제곱근오차(Root Mean Square Error, RMSE)와 RMSE를 표준화한 NRMSE(Normalized Root Mean Squared Error)를 사용하였다. 두 가지 방법 모두 0에 가까울수록 예측이 실제값과 유사하다는 것을 의미한다. RMSE, NRMSE, CC는 다음과 Ep. (3), (4)와 같이 표현된다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad (3)$$

$$NRMSE = \frac{RMSE}{Max(y_i) - Min(y_i)} \quad (4)$$

3. 산지습지 수위 예측함수 개발

3.1 대상유역 선정

본 연구의 대상유역은 경상남도 금정산에 위치한 장군습지이다. 장군습지는 금정산 장군봉 부근에 위치하고 있으며,

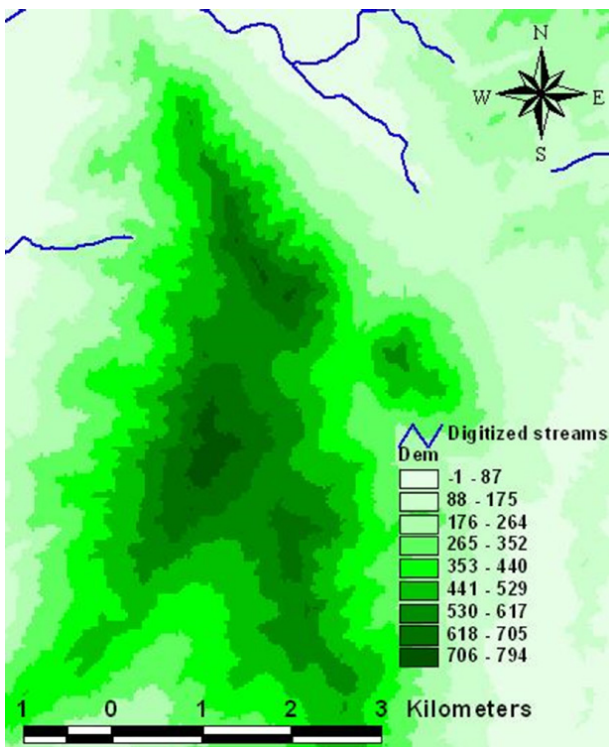


Fig. 3. Study Area(Janggun wetland, Oh et al, 2018)

해발고도는 약 590m이다. 주변 하천으로는 낙동강 수계에 양산천이 위치하고 있다. 장군습지는 북서-남동 방향으로 길게 늘어져 있는 형태를 가지고 있으며, 습지의 경사는 완만하게 이루어져 있다. 다음 Fig. 3과 같이 금정산에 위치한 산지습지(장군습지)를 도식화 하였다.

3.2 종속변수 및 독립변수 설정

금정산 산지습지의 수위를 예측하기 위한 예측모형을 개발하기 위하여 종속변수로 2017년 4월 20일부터 2018년 7월 31일까지의 금정산 산지습지의 수위(water level) 관측 자료를 사용하였다. 금정산 산지습지의 효율적인 이용 및 관리를 위하여 2017년 4월부터 금정산 산지습지 내에 수위측정장비를 설치하여 운영하였으며, 1시간 단위로 수위를 측정하였다. 본 연구에서는 측정된 수위 자료를 일 평균 수위 자료로 변환하여 종속변수로 사용하였다. 독립변수로는 기상청에서 관리하는 종관기상관측(ASOS)의 시간단위 강우 자료 및 기상자료를 활용하여 일 평균 자료로 변환하여 사용하였다. 독립변수로는 일 평균 강우량(mm), 일 평균기온(°C), 일 최저기온(°C), 일 최고기온(°C), 일 최대 순간 풍속(m/s), 일 최대 풍속(m/s), 일 평균 풍속(m/s), 일 평균 이슬점 온도(°C), 일 평균 최소 상대습도(%), 일 평균 상대습도(%), 일 평균 증기압(hPa), 일 평균 현지기압(hPa), 일 평균 최고 해면기압(hPa), 일 평균 최저 해면기압(hPa), 일 평균 해면기압(hPa)을 구축하였다. 본 연구에서는 금정산 산지습지의 수위를 예측하는데 영향을 주는 독립변수를 활용하였

으며(Oh et al, 2018), 표준화 방법으로는 Re-scaling방법을 활용 하였다.

4. 산지습지 예측함수 개발

4.1 다중회귀모형 개발

다중회귀모형을 활용하여 산지습지 예측함수를 개발함에 있어서, 독립변수들 간의 상관성으로 인하여 다중공선성의 문제가 발생할 수 있다. 이러한 문제점을 해결하기 위하여 분산팽창요인(Variance Inflation Factor, VIF)을 통해 이를 검토하였고, 통상적으로 VIF가 10 이상인 경우 다중공선성의 문제가 발생한다고 정의하였다. 따라서 본 연구에서는 다중공선성 문제를 해결하기 위하여 변수선택법 중 단계적 선택법(Stepwise)을 활용하였다. 다음 Eq. (6)과 같이 다중회귀모형을 구축하였다. 또한, 단계적 선택법을 활용하여 변수를 선택하였을 경우, 다음 Table 1과 같이 나타났다.

Table 1. Dependent Variable and Independent Variable

Variable	VIF	Variable	VIF
Average Maximum Sea Level Pressure	2.96	Average Precipitation	2.77
Average Relative Humidity	4.10	Average Wind Speed	10.75
Average Temperature	2.26	Average Maximum Wind Speed	62.96
Average Maximum Temperature	3.46	Average Vapor Pressure	9.88

4.2 주성분 회귀모형 개발

주성분 회귀모형을 구축하기 이전에 독립변수의 신뢰도 검정 및 모형의 적용성 평가를 선행하였다. 독립변수들 간 상관성으로 인하여 다중공선성 문제를 해결하기 위하여 주성분 분석 방법을 활용 할 수 있다. 본 연구에서는 앞서 구축된 다중 회귀모형의 다중공선성 문제가 다수 발생했던 독립변수에 대하여 주성분 분석을 통해 소수의 주성분을 도출하였고, 이를 다시 회귀모형의 독립변수로 활용하였다. 주성분 분석을 수행하기 위하여 신뢰도 검정을 통해 모형의 적용 가능성을 판단하였다. 주성분 분석을 수행함에 있어 회전방법은 Varimax 방법을 사용하여 주성분 점수를

Table 2. KMO and Bartlett's Test Result of Independent Variables

Test		Result
Kaiser-Meyer-Olkin Measure of Sampling		0.95
Bartlett's test of Sphericity	Approx. Chi-Square	90914.184
	Degree of freedom	405
	P-Value	0.000014

도출하였다. 성분의 개수 선정 방법은 누적 기여율이 90% 이상일 때로 결정하였다. 신뢰도 검정 결과는 KMO가 0.95이며, Bartlett의 유의확률이 0.000014로 나타났다. 선정된 성분 개수는 총 3개로 총 분산의 약 92%를 설명하는 것으로 나타났으며, 모든 변수에서 성분적재량이 0.5 이상으로 도출되었다. 다음 Table 2와 같이 나타났다.

4.3 인공신경망 모형 개발

수집된 자료들의 통계 단위 및 범위가 상이하기 때문에 인공신경망 모형을 구축하기 위하여 종속변수 및 독립변수에 대한 표준화가 선행되어야 한다. 따라서 본 연구에서는 Re-scaling방법을 활용하여 본 연구에서는 1개의 종속변수 및 15개의 독립변수에 대하여 표준화 하였다. 인공신경망 모형은 블랙박스(Black-Boxes) 모형이기 때문에 다중회귀 모형 및 주성분 회귀모형과는 다르게 식이 도출되지 않는다. 반면 다음 Fig. 4와 같이 도식화 할 수 있으며, 이를 통하여 각 노드들의 가중치를 파악할 수 있다. 본 연구에서는 매개변수 중 히든노드의 수를 1씩 증가시키며 매개변수를 보정하여 최적의 인공신경망 모형을 개발하였다.




Fig. 4. Visualization of Artificial Neural Network

4.4 DNN(deep neural network) 모형 개발

딥러닝의 학습 모형 성능은 입력된 데이터에 따라 달라지기도 한다. 또한, 모형을 구성하는 매개변수 및 하이퍼 파라미터에 의해 결정되기도 한다. 모형 학습에 의하여 최적의 값이 결정되는 가중치 및 바이어스를 매개변수라 하고, 이외에 모형 학습을 효과적으로 수행하기 위해 설정해야 하는 요소를 하이퍼 파라미터라고 한다. 하이퍼 파라미터에는 학습률, 은닉층 수, 은닉층 노드 수, Dropout, Epoch 등

Table 3. Setting of Hyper-parameter

Hyper-parameter	Values
Learning Rate	0.1, 0.01
Hidden layer	2, 3, 4, 5, 6, 7, 8, 9, 10
Hidden Nodes	5, 10, 15
Dropout	0.5
Epoch	1,000
Batch Size	1, 10, 100
Optimizer	Adam
Activation	ReLU

이 있으며 매개변수와 달리 사용자가 모형에 대한 최적의 조합을 직접 설정하여야 한다. 또한, 각 모델은 입력 및 출력 변수에 따라 최적의 하이퍼 파라미터 값은 모형에 따라서 상이하기 때문에, 특정한 값이 최적의 값이라고 정의할 수 없다. 따라서 시행 착오법을 활용하여서 최적의 하이퍼 파라미터 값을 도출하여야 한다. 본 연구에서 사용된 하이퍼 파라미터 설정값은 다음 Table 3과 같다.

4.4 예측력 평가 결과

본 연구에서는 금정산 산지습지의 수위를 예측하기 위하여, 다중회귀모형, 주성분 회귀모형, 인공신경망 모형, DNN 모형을 개발하였다. 종속변수로는 금정산 산지습지의 수위자료를 활용하였으며, 독립변수로는 기상자료를 활용하였다. 예측력을 평가하기 위하여 데이터의 학습 구간은 2017년 4월 20일부터 2018년 2월 28일까지로 설정하였으며, 평가 구간은 2018년 3월 1일부터 2018년 7월 31일까지로 설정하였다. 예측력 평가 방법으로는 RMSE와 NRMSE를 활용하였다. 다음 Table 4와 Fig. 4와 같이 각각의 모형에 대한 예측력 평가 결과를 나타내었다.

Table 4. Result of Water Level Prediction Functions

Classification	RMSE	NRMSE(%)
Multiple Regression Model	15.576	46.31
Principal Component Analysis	12.761	37.93
Artificial Neural Network	8.848	26.31
Deep Neural Network	6.359	18.91

다중회귀모형의 예측력 평가 결과 RMSE는 15.576, NRMSE는 46.31%로 나타났으며, 주성분 회귀모형의 예측력 평가 결과 RMSE는 12.761, NRMSE는 37.93%로 나타났다. 인공신경망 모형의 예측력 평가 결과 RMSE는 8.848, NRMSE는 26.31%로 나타내며, DNN 모형의 예측력 평가 결과 RMSE는 6.359, NRMSE는 18.91%로 나타났다. 예측력 평가 결과 DNN 모형을 활용한 예측력이 가장 우수하게 도출되었다.

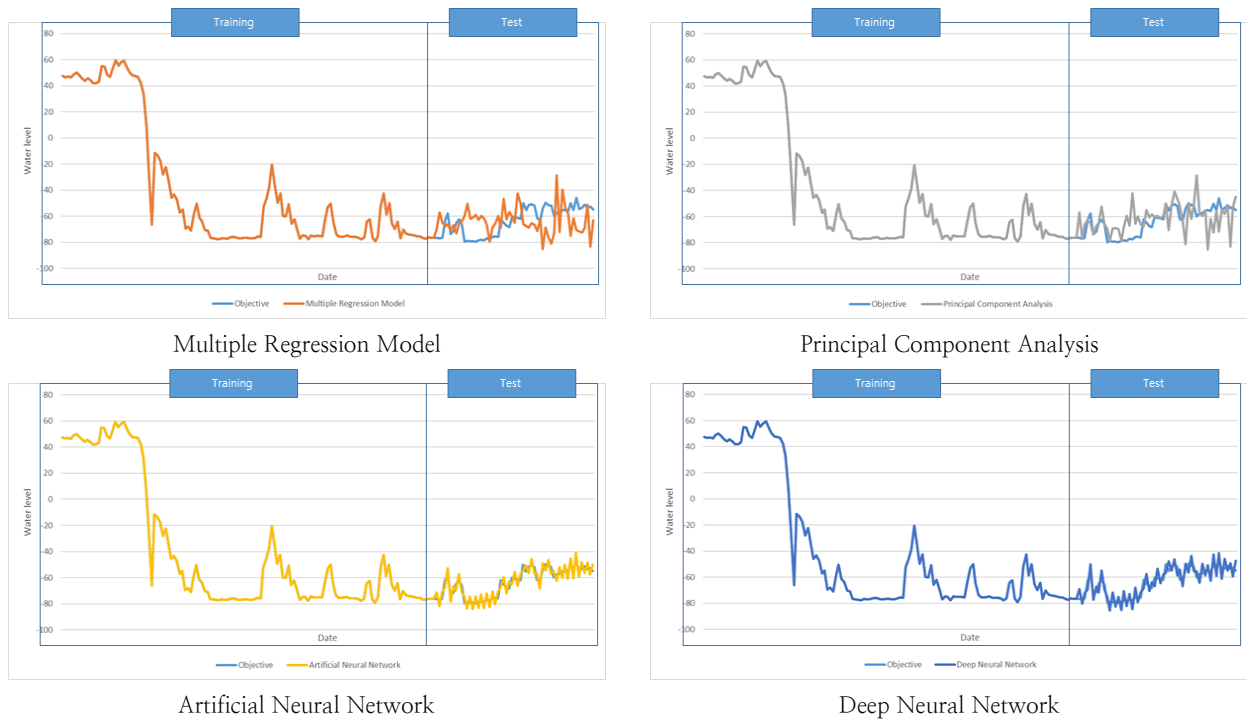


Fig. 5. Result of Water Level Prediction Functions

5. 결 론

습지의 기능 중 가장 중요한 역할을 하는 수위 자료는 활용 가능성이 매우 높지만, 지형적 특성으로 인해 관측에 대한 한계가 있었다. 따라서 본 연구에서는 습지의 수위를 예측할 수 있도록 다양한 통계적 기법을 활용하여 수위 예측 모형을 개발하였다. 본 연구에서 개발한 모형은 습지 환경에 영향을 줄 수 있는 주변 지역의 수위 및 기상자료와 같은 다양한 변수들을 활용하여 새로운 수위 예측 모형을 개발하였다.

최종 모형으로 선정된 DNN을 활용한 수위 예측모형의 예측력 평가결과 RMSE는 6.359, NRMSE는 18.91%로 비교적 산지습지의 수위를 잘 예측하는 것으로 나타났다. 특히 선행연구에서 사용하였던 인공신경망에 비해 예측 성능이 우수하다는 장점이 있는 것으로 나타났다. 본 연구성과를 활용한다면 기존의 미비하였던 수위를 이용한 습지 관리에 기초자료로 사용할 수 있을 것으로 판단된다.

감사의 글

이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2017R1A2B3005695).

References

Bittmann, E. Grundlagen und Methoden des biologischen

Wasserbaus. In Der Biologische Wasserbau an den Bundesstrassen; Bundesanstalt f. Gewaesserkunde: Koblenz, Germany, 1965; pp. 1–56.

Byeon, S.J.; Lee, S.H.; Choi, G.W.; Jung, J.G. Use of Gauged Water Level and Precipitation Data to Predict Short Term Water Level Changes. *Korean Rev. Crisis Emerg. Manag.* 2014, 10, 247–264.

Castillo, J.M.M.; Cspedes, J.M.S.; Cuchango, H.E.E. Water Level Prediction Using Artificial Neural Network Model. *Int. J. Appl. Eng. Res.* 2018, 13, 14378–14381.

Chau, K.W. Particle swarm optimization training algorithm for ANNs in stage prediction of shing mun river. *J. Hydrol.* 2006, 329, 363–367.

Jun, H.D.; Lee, J.H. A Methodology for Flood Forecasting and Warning Based on the Characteristic of Observed Water Levels Between Upstream and Downstream. *J. Korean Soc. Hazard Mitig.* 2013, 13, 367–374.[Korea Literature]

Keddy, P.A. *Wetland Ecology: Principles and Conservation*; Cambridge University: Cambridge, UK, 2000.

Kim, J.W. Prediction and Evaluation of Hydro-Ecology, Functions, and Sustainability of a Wetland under Climate Change. Ph.D. Thesis, Inha University, Incheon, Korea, 2019.

Kim, J.W.; Lee, B.E.; Kim, J.G.; Oh, S.H.; Jung, J.W.; Lee, M.J.; Kim, H.S. Functional Assessment of Gangcheon Replacement Wetland Using Modified HGM. *J. Wetl. Res.* 2017, 19, 318–326.[Korea

- Literature] DOI <https://doi.org/10.17663/JWR.2017.19.3.318>
- Kumar, A.P.S.; Sudheer, K.P.; Jain, S.K.; Agarwal, P.K. Rainfall runoff modeling using artificial neural networks: Comparison of network types. *Hydrol. Process.* 2005, 19, 1277–1291.
- Kwak, J.W.; Kim, G.H.; Kim, J.W.; Singh, V.P.; Kim, H.S. Assessment of hydrological regimes for vegetation on riparian wetlands in Han River Basin, Korea. *Terr. Atmos. Ocean. Sci.* 2017, 28, 1055–1067.[Korea Literature] doi: [10.3319/TAO.2017.03.25.01](https://doi.org/10.3319/TAO.2017.03.25.01)
- Rezaeianzadeh, M.; Kalin, L.; Anderson, C. Wetland Water-Level Prediction Using ANN in Conjunction with Base-Flow Recession Analysis. *J. Hydrol. Eng.* 2015, 22, 1–11.
- Rezaeianzadeh, M.; Kalin, L.; Hantush, M. An Integrated Approach for Modeling Wetland Water Level: Application to a Headwater Wetland in Coastal Alabama, USA. *Water* 2018, 10, 1–17.
- Tiwari, M.K.; Chatterjee, C. Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach. *J. Hydrol.* 2010, 394, 458–470.
- Yu, P.S.; Chen, S.T.; Chang, I.F. Support vector regression for real-time flood stage forecasting. *J. Hydrol.* 2006, 328, 704–716.