



기계학습모델을 이용한 저수지 수위 예측 Reservoir Water Level Forecasting Using Machine Learning Models

서영민^{*,†} · 최은혁^{**} · 여운기^{***}

Seo, Youngmin · Choi, Eunhyuk · Yeo, Woonki

Abstract

This study investigates the efficiencies of machine learning models, including artificial neural network (ANN), generalized regression neural network (GRNN), adaptive neuro-fuzzy inference system (ANFIS) and random forest (RF), for reservoir water level forecasting in the Chungju Dam, South Korea. The models' efficiencies are assessed based on model efficiency indices and graphical comparison. The forecasting results of the models are dependent on lead times and the combination of input variables. For lead time $t = 1$ day, ANFIS1 and ANN6 models yield superior forecasting results to RF6 and GRNN6 models. For lead time $t = 5$ days, ANN1 and RF6 models produce better forecasting results than ANFIS1 and GRNN3 models. For lead time $t = 10$ days, ANN3 and RF1 models perform better than ANFIS3 and GRNN3 models. It is found that ANN model yields the best performance for all lead times, in terms of model efficiency and graphical comparison. These results indicate that the optimal combination of input variables and forecasting models depending on lead times should be applied in reservoir water level forecasting, instead of the single combination of input variables and forecasting models for all lead times.

Keywords: Reservoir water level forecasting; Artificial neural network; Generalized regression neural network; Adaptive neuro-fuzzy inference system; Random forest

1. 서론

댐 저수지는 용수공급, 관개, 가뭄 및 홍수조절, 수력발전, 수질 및 수생태계, 주운, 내륙어업 등에서 중요한 역할을 한다. 댐 저수지의 목적별 저수용량은 저수지 수위를 기준으로 결정되어 각종 용수공급, 수력발전 및 홍수조절을 위해 활용된다(Jeong and Yun, 2007). 저수지 수위 변동은 퇴적토사의 산화 환원 반응 조건에 영향을 미치며(Eckley et al., 2015), 수력발전, 홍수조절 및 용수공급을 위한 저수지 운영은 수생태계에 영향을 줄 수 있는 수위변동을 초래한다(Ji et al., 2017). 따라서 댐 저수지의 최적 운영을 위하여 저수지 수위를 신뢰성 있게 예측하고 최적으로 모니터링하는 것은 댐 저수지의 수문학적, 생태환경학적 측면에서 필수적이라 할 수 있다.

ANN (artificial neural network), GRNN (generalized regression neural network) 및 ANFIS (adaptive neuro-fuzzy inference system) 등을 포함하는 기계학습모델 (machine learning models)은 강수, 하천유량 및 수위, 증발량, 지하수위 등과 같은 비선형 수문변수들의 모델링에 널리 적용되어 왔다 (Partal and Cigizoglu, 2008; Tiwari and Chatterjee, 2010; Adamowski and Chan, 2011; Rajae et al., 2011; Jothiprakash and Magar, 2012; Kim et al., 2015; Seo et al., 2015; Seo et al., 2016). 또한 분류 및 회귀를 위한 앙상블 학습모델 (ensemble learning model)인 RF (random forest)는 다양한 분야들에서 비선형 시계열을 모델링하기 위해 적용되어 왔다. 비록 RF가 수문학적 분야에서 널리 알려져 있지 않지만, 최근 수문학적 분야에서 RF의 적용이 성공적으로 이루어지고 있다(Booker and Woods, 2014; Yang et al., 2016).

기계학습모델을 이용한 저수지 수위 예측과 관련된 기존 연구들을 살펴보면, Chang과 Chang (2006)은 홍수기간동안 예측시간 1~3시간에 대한 저수지 수위를 예측하기 위하여 뉴로 퍼지 방법 (neuro-fuzzy approach)을 제안하였다. Altunkaynak (2007)은 터키 Van 호의 수위변화를 모델링하기 위하여 ANN 모델을 개발하였으며, ARMAX (autoregressive moving average with exogenous input)와 모델성능을 비교하였다. Yazar et al. (2009)은 ANFIS, ANN 및 SARIMA (seasonal autoregressive integrated moving average)를 이용하여 터키 Beysehir 호의

* Kyungpook National University, Department of Constructional and Environmental Engineering

** Korea Rural Community Corporation, Project Planning Department

*** Daegu Gyeongbuk Development Institute, Future Strategic Research Lab.

† Corresponding author

Tel.: +82-54-530-1440 Fax: +82-54-530-1449

E-mail: ymse@knu.ac.kr

Received: February 8, 2017

Revised: May 29, 2017

Accepted: May 30, 2017

수위변화를 연구하였다. Kisi et al. (2012)은 저수지 일수위 예측을 위하여 ANN, ANFIS 및 GEP (gene expression programming)를 적용하였다. Hipni et al. (2013)은 저수지 일수위 예측을 위하여 SVM (support vector machine)을 적용하였으며, 그 결과를 ANFIS와 비교하였다. Valizadeh와 El-Shafie (2013)는 말레이시아 Klang Gates 댐의 저수지 수위예측에서 ANFIS 모델의 정확도를 개선하기 위하여 각 입력 유형별로 특정 소속함수를 적용하였다. Valizadeh et al. (2014)은 ANFIS 모델에서 새로운 퍼지화 패턴의 성능평가를 위하여 두 가지 다른 ANFIS 모델을 사용하여 수위예측을 실시하였다. 여기서, 다른 유형의 소속함수 (membership function)를 사용한 ANFIS 모델의 정확성은 모든 입력에 대하여 동일한 유형의 소속함수를 사용한 ANFIS 모델과 비교되었다. Das et al. (2016)은 저수지 수위예측을 위하여 지수잔차수정 (exponential residual correction)을 포함한 베이저안 네트워크 모델 (Bayesian network model)에 기반한 확률론적 비선형 기법을 제안하였다.

본 연구에서는 저수지 일수위 예측에 대하여 기계학습모델의 적용성을 비교 및 평가하였다. 적용된 기계학습모델은 ANN, GRNN, ANFIS 및 RF이며, 모델성능평가를 위해 충주댐 유역을 연구지역으로 선정하였다. 모델성능은 예측시간 $t = 1, 5, 10$ days에 대하여 무차원 지표 (dimensionless indices) 및 잔차기반 지표 (residual error-based indices)를 포함하는 모델 효율성 평가지표와 도식적 비교를 통해 평가되었다.

II. 재료 및 방법

1. 분석자료

기계학습모델을 이용한 저수지 일수위 예측을 위하여 본 연구에서는 연구지역으로서 충주댐 유역을 선정하였다. Fig. 1은 분석유역의 개요도를 나타낸다. 기계학습모델 (ANN, GRNN, ANFIS, RF)의 구축을 위한 입력력 자료는 저수지 수위 (WL , m), 댐 유입량 (Q_{in} , m^3/s), 댐 방류량 (발전 방류량 + 여수로 방류량) (Q_{out} , m^3/s), 유역평균강우량 (R , mm)에 대한 일자료로서 국토교통부에 의해 운영되고 있는 WAMIS (WATER Management Information System, <http://www.wamis.go.kr>)로부터 1988~2015년 (총 28년) 기간에 대해 수집되었다. 수집된 자료들은 모델의 학습과 테스트를 위하여 두 부분으로 분할되었다. 즉, 1988~2008년의 자료 (21년, 75%)는 학습자료, 2009~2015년의 자료 (7년, 25%)는 테스트 자료로 설정하였다.

2. 분석방법

가. Artificial neural network (ANN)

ANN은 복잡한 비선형 및 다차원 입력력 관계를 모델링하기 위한 다층연산시스템이다. 가장 일반적으로 적용되는 ANN 구조인 MLP (multilayer perceptron)는 여러 개의 층으로 구성되는데, 수문학적 적용에서는 Fig. 2와 같이 입력층, 출력층 및 은닉층을 포함하는 세 개의 층을 가지는 MLP가 일반적으로 사용된다. Günther와 Fritsch (2010)에 따르면, 세 개의 층

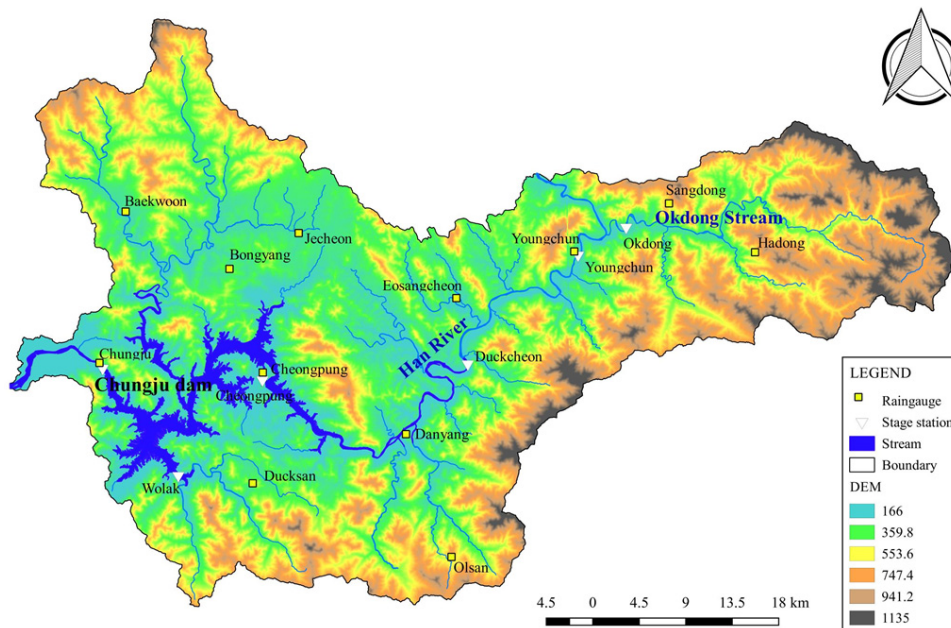
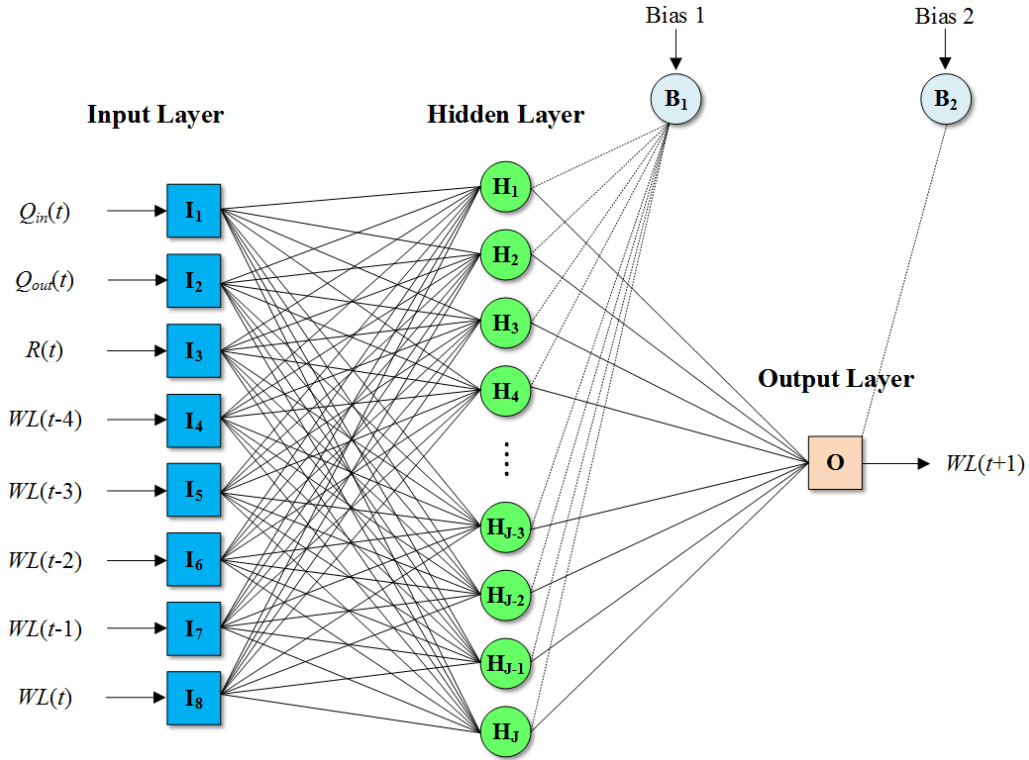


Fig. 1 Study region and observation stations

Fig. 2 ANN's architecture (input set 1 and $t = 1$ day)

및 J 개의 은닉노드를 가지는 MLP는 식 (1)과 같은 연산을 수행한다.

$$\begin{aligned} o(\mathbf{x}) &= f\left(w_0 + \sum_{j=1}^J w_j \cdot f\left(w_{0j} + \sum_{i=1}^n w_{ij} x_i\right)\right) \\ &= f\left(w_0 + \sum_{j=1}^J w_j \cdot f\left(w_{0j} + \mathbf{w}_j^T \mathbf{x}\right)\right) \end{aligned} \quad (1)$$

여기서 $\mathbf{x} = \{x_i, i = 1, 2, \dots, n\}$ 는 입력벡터, f 는 활성화 함수, $o(\mathbf{x})$ 는 출력벡터, w_0 는 출력노드에 대한 절편, w_j 는 연결강도, $\mathbf{w}_j = (w_{1j}, \dots, w_{nj})$ 는 연결강도벡터, w_{0j} 는 j 번째 은닉노드에 대한 절편이다. MLP에 대한 자세한 내용은 Günther와 Fritsch (2010)를 참조할 수 있다.

나. Generalized regression neural network (GRNN)

RBFNN (radial basis function neural network)을 수정한 모델인 GRNN은 복잡한 비선형 관계를 모델링하기 위한 비선형 회귀에 기반한 범용근사기 (universal approximator)이다. MLP와는 달리 GRNN은 단일 패스 학습 알고리즘 (one-pass learning algorithm)에 기초하기 때문에 반복학습과정을 필요로 하지 않는다 (Specht, 1991).

Fig. 3과 같이 GRNN은 입력층, 패턴층, 합산층 및 출력층과 같은 네 개의 층으로 구성된다. 첫 번째 층인 입력층은 입력 벡터를 수신하는 입력노드들을 포함한다. 두 번째 층인 패턴층은 먼저 식 (2)와 같이 패턴 가중치와 입력벡터 간의 유클리드 거리를 산정하고, 다음으로 식 (3)과 같이 RBF (radial basis function)를 이용하여 노드 출력을 산출한다 (Specht, 1991).

$$D_j = \sqrt{\sum_{i=1}^n (w_{ij} - x_i)^2}, i = 1, 2, \dots, n, j = 1, 2, \dots, k \quad (2)$$

$$f(D_j) = \exp\left(\frac{-D_j}{2\sigma^2}\right) \quad (3)$$

여기서 D_j 는 유클리드 거리, x_i 는 입력벡터의 원소, n 은 훈련패턴의 수, w_{ij} 는 패턴 가중치, k 는 입력벡터의 크기, f 는 RBF, σ 는 평활인자 (smoothing factor)이다.

세 번째 층은 합산층으로서 S_1 및 S_2 의 두 개의 노드로 구성된다. S_1 및 S_2 노드는 각각 식 (4)~(5)와 같이 패턴층으로부터의 출력값에 대한 가중 및 비가중합을 산정한다 (Specht, 1991).

$$S_1 = \sum_{j=1}^k y_j f(D_j) \quad (4)$$

$$S_2 = \sum_{j=1}^k f(D_j) \quad (5)$$

여기서 y_j 는 S_1 노드와 패턴층 간의 연결강도이다.

마지막으로 출력층은 S_1 노드의 출력치를 S_2 노드의 출력치로 나누어 예측값을 산출한다. GRNN에 대한 자세한 내용은 Specht (1991)를 참조할 수 있다.

다. Adaptive neuro-fuzzy inference system (ANFIS)

퍼지규칙 (fuzzy rule) 기반 시스템인 ANFIS는 퍼지추론시스템 (fuzzy inference system, FIS)과 적응신경망 (adaptive neural networks)을 결합한 수학적 모델이다. Mamdani (Mamdani and Assilian, 1975) 및 Sugeno 모델 (Takagi and Sugeno, 1985)이 대표적인 FIS는 모호한 정보를 반영하기 위하여 퍼지 IF-THEN 규칙을 활용한다.

Fig. 4와 같이 ANFIS는 다섯 개의 층으로 구성된다. 퍼지화 단계는 첫 번째 층에서 수행되며, 여기에서는 소속함수 (membership function)를 활용하여 수치값을 언어항 (linguistic

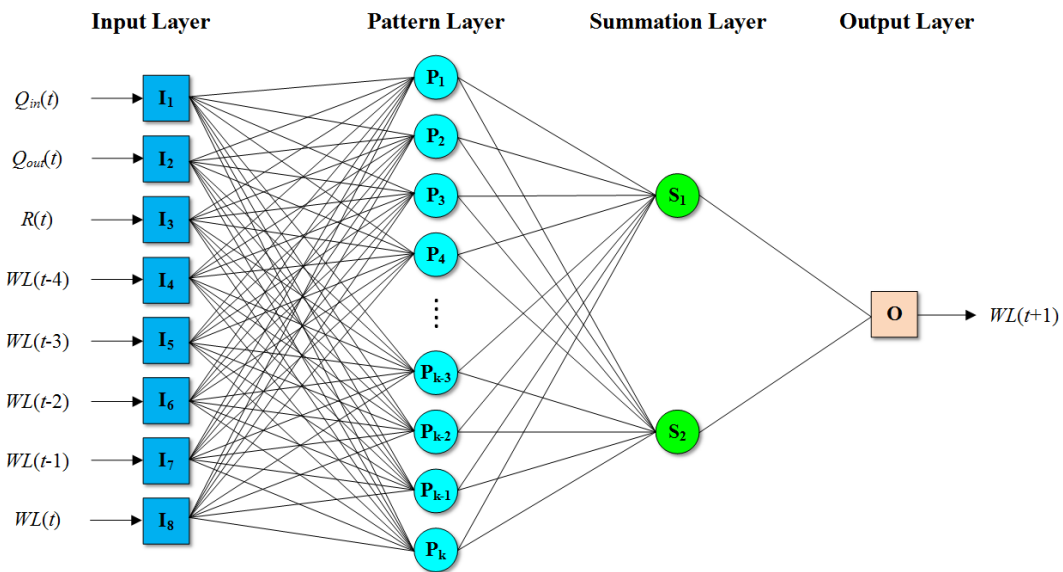


Fig. 3 GRNN's architecture (input set 1 and $t = 1$ day)

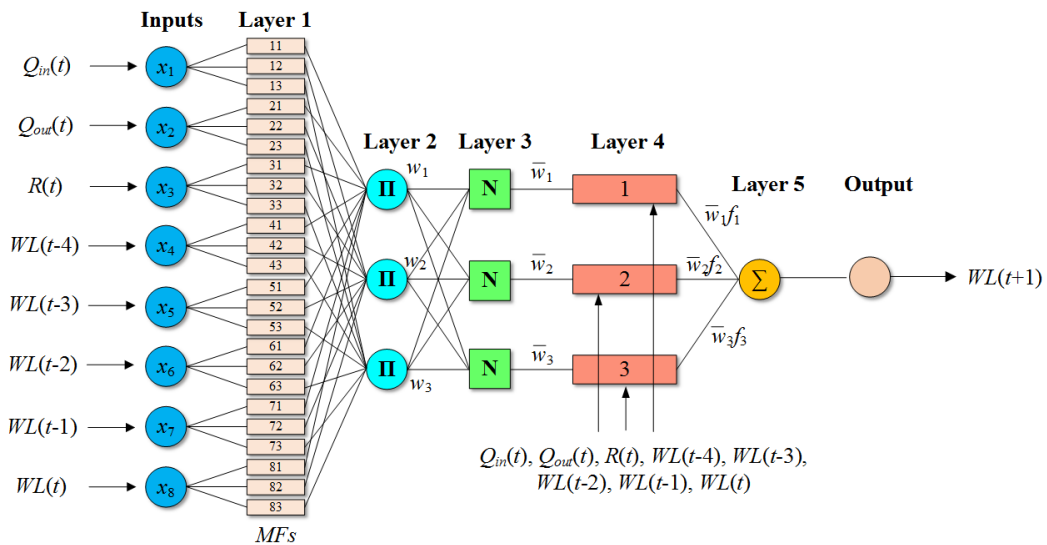


Fig. 4 ANFIS's architecture (input set 1 and $t = 1$ day)

terms)으로 변환한다. 두 번째 층은 t-norm (AND) 연산자를 활용하는 추정단계이며, 세 번째 층은 퍼지 IF-THEN 규칙에 대한 강도비를 산정한다. 네 번째 층에서는 결과 매개변수 (consequent parameters)가 산정되며, 마지막으로 다섯 번째 층에서는 유입되는 모든 입력신호들을 합산함으로써 전체 출력값을 산출한다. k 개의 입력과 m 개의 소속함수에 대하여 각 층의 출력값은 식 (6)~(10)과 같이 산정될 수 있다 (Jang et al., 1997).

$$O_{1,j} = \phi_{A_{ij}}(x_i), \quad i = 1, 2, \dots, m \quad (6)$$

$$O_{2,j} = w_j = \prod_{i=1}^k \phi_{A_{ij}}(x_i) \quad (7)$$

$$O_{3,j} = \bar{w}_j = \frac{w_j}{\sum_{q=1}^m w_q} \quad (8)$$

$$O_{4,j} = \bar{w}_j f_j = \bar{w}_j \left(\sum_{i=1}^k p_{ji} x_i + r_j \right) \quad (9)$$

$$O_5 = \sum_{j=1}^m \bar{w}_j f_j = \frac{\sum_{j=1}^m \bar{w}_j f_j}{\sum_{j=1}^m \bar{w}_j} \quad (10)$$

여기서 O_{1-5} 는 층 1~5로부터의 출력치, $\phi_{A_{ij}}$ 는 소속함수,

A_{ij} 는 언어라벨 (linguistic label), w_j 는 규칙강도, \bar{w}_j 는 정규화된 규칙강도, p_{ji} 및 r_j 는 결과 매개변수이다. ANFIS에 대한 자세한 내용은 Jang et al. (1997)을 참조할 수 있다.

라. Random forest (RF)

트리 기반 앙상블 메타알고리즘 (tree-based ensemble meta-algorithm)인 RF는 다중 CARTs (classification and regression trees)를 생성하고 집성된 예측치를 산출하는 bagging (bootstrap aggregating)을 일반화한 모델이다 (Breiman, 2001). RF에 대한 자세한 내용은 Breiman (2001)을 참조할 수 있다. RF에서는 먼저 훈련집합으로부터 bootstrap 표본이 발생되고, 단말 노드 (terminal node)의 개수가 최소 노드크기 (nodesize) 이하가 될 때까지 bootstrap 표본을 이용하여 CART가 성장하며, 다음으로 각 CART는 예측치를 산출한다. 이러한 CART 예측치들에 대한 가중평균은 최종 예측치를 산출하게 된다. RF 예측치는 식 (11)~(12)을 이용하여 CART 예측치들을 평균함으로써 산출된다 (Nguyen, 2015).

$$\hat{f}_b(x) = \sum_{i=1}^N w_i(x, \theta) Y_i \quad (11)$$

$$\hat{f}_{RF}(x) = \frac{1}{B} \sum_{b=1}^B \hat{f}_b(x) \quad (12)$$

여기서 N 은 훈련자료의 길이, X_i 는 예측변수 특성치, Y_i 는 반응변수 특성치, \hat{f}_b 는 b 번째 CART 예측치 ($b = 1, 2, \dots, B$),

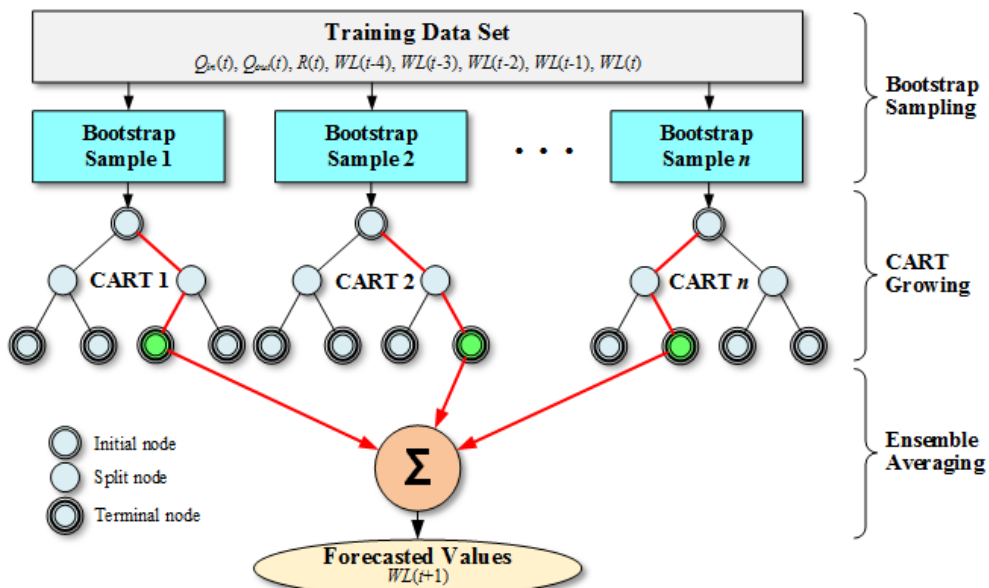


Fig. 5 RF's architecture (input set 1 and $t = 1$ day)

B 는 bootstrap 표본의 개수, w_i 는 가중치 함수, θ 는 CART의 성장을 제어하는 매개변수 벡터, \hat{f}_{RF} 는 RF 예측치이다.

Fig. 5는 RF 모델 구조의 한 예를 보여준다. Breiman (2001)을 따르면, RF의 주요 알고리즘은 bootstrap 샘플링, CART 성장 및 앙상블 집성 (ensemble aggregation)으로서 다음과 같이 구성된다.

- 단계 1: B 개의 bootstrap 표본을 생성
- 단계 2: 각 bootstrap 표본에 대하여 단말노드의 개수가 $nodesize$ 에 도달할 때까지 CART를 성장
- 단계 3: B 개의 CART로부터 산출된 값들을 앙상블 평균하여 RF 예측치를 산출

마. 모델성능평가

본 연구에서 모델성능은 무차원 지표 및 잔차오차기반 지표에 기초하여 평가되었다. Appendix는 본 연구에서 사용된 모델 효율성 지표를 요약하고 있다. 여기서, 무차원 지표는 일치지표 (index of agreement, d) 및 결정계수 (coefficient of determination, r^2)를 포함하며, 잔차오차기반 지표는 제곱근 평균제곱오차 (root-mean-square error, RMSE), 평균절대오차 (mean absolute error, MAE), 평균제곱상대오차 (mean squared relative error, MSRE) 및 평균고차오차 (mean higher order error, MS4E)를 포함한다. 무차원 지표의 값이 클수록, 잔차오차기반 지표의 값이 작을수록 모델성능이 우수함을 나타낸다. 모델 효율성 지표에 대한 자세한 내용은 Dawson과 Wilby (2001)를 참조할 수 있다.

III. 결과 및 고찰

1. 분석

ANN, GRNN, ANFIS 및 RF 모델을 구축하는데 가장 중

요한 단계 중 하나는 주요 입력변수를 선택하는 것이다. 본 연구에서는 입력변수에 대한 최적 지체시간을 결정하기 위하여 ACF (autocorrelation function), PACF (partial autocorrelation function), CCF (cross correlation function) 및 AMI (average mutual information)를 활용하였으며, 이에 근거하여 입력집합을 결정하였다. Table 1은 ANN, GRNN, ANFIS 및 RF 모델 구축을 위한 입력집합을 요약하고 있다.

ANN 모델 구축을 위해서는 은닉층의 노드 개수를 사전에 결정해야 한다. 본 연구에서는 Seo et al. (2015)에서 설명된 바와 같이 시행착오법을 이용하여 은닉층의 노드 개수를 결정하였다. 각 노드의 출력을 산정하기 위하여 로지스틱 시그모이드 함수 (logistic sigmoid function)를 활성화 함수로서 사용하였으며, 모델 학습을 위해 오차 역전파 알고리즘 (backpropagation algorithm)을 적용하였다.

GRNN 모델 구축에서 가장 중요한 단계는 GRNN 모델의 유일한 초매개변수 (hyperparameter)인 평활인자를 결정하는 것이다. 평활인자는 시행착오법 또는 최적화 알고리즘을 활용하여 결정될 수 있다. 본 연구에서는 시행착오법을 이용하여 최소 평균제곱오차 (mean square error)를 가지는 최적 평활인자를 결정하였다.

ANFIS 모델 구축에서 FIS는 차감 군집화 기법 (subtractive clustering method)을 이용하여 생성되었다. ANFIS 모델의 학습은 경사하강최적화 (gradient descent optimization)와 최소제곱법 (least-squares method)을 결합한 하이브리드 학습알고리즘 (hybrid learning algorithm)을 적용하였다 (Mathworks, 2016). 각 입력노드에 대한 소속함수의 유형과 개수는 Seo et al. (2015)에서 설명된 바와 같이 시행착오법을 이용하여 결정되었으며, 각 입력노드에 대하여 세 개의 가우시안 (Gaussian) 소속함수를 적용하였다.

RF 모델의 정확성은 RF 모델의 초매개변수인 트리개수 (B), 각 분기마다 사용되는 임의선택 변수의 개수 ($mtry$), 최소 노드크기 ($nodesize$)의 적절한 선택에 영향을 받는다. 본 연구에

Table 1 Input combinations for model configuration

Input sets	Input variables	Output variables
Set 1	$Q_{in}(t), Q_{out}(t), R(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 2	$WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 3	$Q_{in}(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 4	$Q_{out}(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 5	$R(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 6	$Q_{in}(t), Q_{out}(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 7	$Q_{in}(t), R(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$
Set 8	$Q_{out}(t), R(t), WL(t-4), WL(t-3), WL(t-2), WL(t-1), WL(t)$	$WL(t+1), WL(t+5), WL(t+10)$

Q_{in} : inflow, Q_{out} : outflow, R : rainfall, WL : water level

서는 최적 초매개변수 값을 결정하기 위하여 유전알고리즘 (genetic algorithm)을 활용하였다. ANN, GRNN, ANFIS 및 RF 모델의 효과적인 학습을 위해 모델의 입력자료는 [0, 1]의 범위로 정규화하였다 (Dawson and Wilby, 2001; Kim et al., 2012).

2. 모델성능평가

본 연구에서 모델 성능은 무차원 지표 (d, r^2)와 잔차오차기반 지표 (RMSE, MAE, MSRE, MS4E)를 활용하여 비교·평가하였다. Table 2는 전체 테스트 기간에 대한 모델 효율성 지표 산정결과를 요약하고 있다. Table 2로부터 예측시간 $t = 1$ day에 대한 결과를 살펴보면, 입력집합 1에 대한 ANFIS 모델인 ANFIS1의 경우 $d = 0.999, r^2 = 0.999, RMSE = 0.105, MAE = 0.030, MSRE = 0.006 \times 10^{-4}, MS4E = 0.021$ 로서 가장 우수한 모델 성능을 나타내었다. 예측시간 $t = 1$ day에 대하여 ANFIS1, ANN6, RF6, GRNN6의 순으로 우수한 모델 성능을 나타내었다. 예측시간 $t = 5$ days에 대한 결과를 살펴보면, 입력집합 1에 대한 ANN 모델인 ANN1의 경우 $d = 0.994, r^2 = 0.976, RMSE = 1.043, MAE = 0.431, MSRE = 0.667 \times 10^{-4}, MS4E = 49.342$ 로서 가장 우수한 모델 성능을 나타내었다. 예측시간 $t = 5$ days에 대하여 ANN1, RF6, ANFIS1, GRNN3의 순으로 우수한 모델 성능을 나타내었다. 예측시간 $t = 10$ days에 대한 결과를 살펴보면, 입력집합 3에 대한 ANN 모델인 ANN3의 경우 $d = 0.984, r^2 = 0.942, RMSE = 1.621, MAE = 0.911, MSRE = 1.624 \times 10^{-4}, MS4E = 90.388$ 로서 가장 우수한 모델 성능을 나타내었다. 예측시간 $t = 10$ days에 대하여 ANN3, RF1, ANFIS3, GRNN3의 순으로 우수한 모델 성능을 나타내었다.

한편, 본 연구에서는 테스트 기간 내 저수지 수위를 상시만 수위를 기준으로 저수위와 고수위로 구분하여 모델 효율성을 평가하였다. Table 3과 4는 저수위 및 고수위에 대한 모델 효율성 지표 산정결과를 각각 요약하고 있다. Table 3으로부터 예측시간 $t = 1$ day에 대한 결과를 살펴보면, ANN6의 경우 $d = 0.999, r^2 = 0.999, RMSE = 0.113, MAE = 0.067, MSRE = 0.008 \times 10^{-4}, MS4E = 0.004$ 로서 가장 우수한 모델 성능을 나타내었다. 예측시간 $t = 1$ day에 대하여 ANN6, ANFIS1, RF6, GRNN6의 순으로 우수한 모델 성능을 나타내었다. 예측시간 $t = 5$ days의 경우 ANN1, RF6, ANFIS1, GRNN3의 순으로 우수한 모델 성능을 나타내었다. 예측시간 $t = 10$ days에서는 ANN3가 가장 우수한 예측 결과를 나타내었으며, 그 다음으로 RF1, ANFIS3, GRNN3의 순으로 모델 성능이 우수함을 보여주었다. 고수위에 대한 모델 성능을 요약한 Table 4로부터 $t = 1$ day의 경우 ANFIS1이 $d = 0.996, r^2 = 0.989, RMSE = 0.109, MAE = 0.081, MSRE = 0.006 \times 10^{-4}, MS4E = 0.001$ 로서 가장 우수한 모델 성능을 나타내었으며, 그 다음으로 RF6, ANN6, GRNN6의 순으로 우수한 예측 결과를 보여주었다. $t = 5$ 및 10 days의 경우 ANFIS1 및 ANFIS3가 각각 상대적으로 나은 예측결과를 나타내긴 하였으나 모든 모델들의 고수위에 대한 예측 성능은 대체로 불량한 것으로 나타났다.

전체 테스트 기간에 대하여 예측시간 $t = 1$ day에서는 모든 모델들이 0.9 이상의 높은 무차원 지표와 낮은 잔차오차기반 지표를 가지면서 우수한 모델 성능을 나타내었으나 예측시간이 증가하면서 모든 모델의 성능은 점차 저하됨을 알 수 있다. ANFIS1과 ANN6 모델은 예측시간 $t = 1$ day에서 상대적으로 우수한 모델 성능을 나타내었으며, ANN1과 RF6 모델은 예측시간 $t = 5$ days에서, ANN3과 RF1 모델은 $t = 10$ days에

Table 2 Performance comparison for overall water level

Lead times (days)	Models	d	r^2	RMSE (m)	MAE (m)	MSRE (10^{-4})	MS4E (m^4)	Remarks
$t = 1$	ANN6	0.999	0.999	0.135	0.073	0.010	0.011	Set 6
	GRNN6	0.999	0.997	0.367	0.144	0.080	1.980	Set 6
	ANFIS1	0.999	0.999	0.105	0.030	0.006	0.021	Set 1
	RF6	0.999	0.999	0.249	0.083	0.036	0.266	Set 6
$t = 5$	ANN1	0.994	0.976	1.043	0.431	0.667	49.342	Set 1
	GRNN3	0.990	0.962	1.305	0.614	1.036	116.736	Set 3
	ANFIS1	0.993	0.971	1.137	0.466	0.794	76.664	Set 1
	RF6	0.993	0.973	1.101	0.462	0.733	48.194	Set 6
$t = 10$	ANN3	0.984	0.942	1.621	0.911	1.624	90.388	Set 3
	GRNN3	0.978	0.919	1.903	1.032	2.266	209.752	Set 3
	ANFIS3	0.980	0.926	1.823	1.002	2.075	177.320	Set 3
	RF1	0.984	0.939	1.644	0.870	1.682	95.727	Set 1

Table 3 Performance comparison for low water level

Lead times (days)	Models	d	r^2	RMSE (m)	MAE (m)	MSRE (10^{-4})	MS4E (m^4)	Remarks
$t = 1$	ANN6	0,999	0,999	0,113	0,067	0,008	0,004	Set 6
	GRNN6	0,999	0,997	0,359	0,140	0,077	1,963	Set 6
	ANFIS1	0,999	0,999	0,136	0,031	0,010	0,099	Set 1
	RF6	0,999	0,999	0,242	0,079	0,035	0,261	Set 6
$t = 5$	ANN1	0,994	0,976	1,027	0,420	0,651	48,540	Set 1
	GRNN3	0,990	0,960	1,317	0,654	1,094	75,334	Set 3
	ANFIS1	0,992	0,970	1,134	0,460	0,792	77,135	Set 1
	RF6	0,993	0,973	1,077	0,452	0,709	46,010	Set 6
$t = 10$	ANN3	0,984	0,942	1,600	0,894	1,594	89,182	Set 3
	GRNN3	0,978	0,919	1,876	1,015	2,221	204,498	Set 3
	ANFIS3	0,979	0,924	1,816	0,992	2,066	178,045	Set 3
	RF1	0,984	0,940	1,606	0,853	1,624	87,774	Set 1

Table 4 Performance comparison for high water level

Lead times (days)	Models	d	r^2	RMSE (m)	MAE (m)	MSRE (10^{-4})	MS4E (m^4)	Remarks
$t = 1$	ANN6	0,721	0,985	0,776	0,701	0,296	0,813	Set 6
	GRNN6	0,500	0,158	0,885	0,573	0,381	3,853	Set 6
	ANFIS1	0,996	0,989	0,109	0,081	0,006	0,001	Set 1
	RF6	0,751	0,940	0,661	0,454	0,213	0,873	Set 6
$t = 5$	ANN1	0,331	0,036	2,185	1,566	2,371	137,635	Set 1
	GRNN3	0,270	0,052	3,006	2,163	4,501	349,657	Set 3
	ANFIS1	0,399	0,044	1,459	1,062	1,053	23,620	Set 1
	RF6	0,296	0,050	2,633	1,637	3,453	288,674	Set 6
$t = 10$	ANN3	0,247	0,016	3,175	2,773	4,999	223,106	Set 3
	GRNN3	0,210	0,072	3,818	2,904	7,267	786,240	Set 3
	ANFIS3	0,285	0,005	2,504	2,117	3,104	97,416	Set 3
	RF1	0,195	0,062	4,015	2,675	8,044	971,281	Set 1

서 상대적으로 우수한 모델 성능을 나타내었다. GRNN 모델은 모든 예측시간에 대하여 가장 열등한 예측결과를 나타내었다. 이러한 결과들은 모델의 예측결과가 입력변수의 조합에 의존하며, 예측시간 $t = 1$ day에 대해서는 ANFIS 모델이 가장 우수한 저수지 일수위 예측결과를 나타내지만, 모든 예측시간에 대해서 종합적으로 살펴볼 경우 ANN 모델이 다른 모델들에 비해 저수지 일수위를 더 정확하게 예측하는 것으로 분석되었다.

3. 도식적 비교

본 연구에서는 저수지 수위 예측모델들의 정확성을 도식적으로 비교하기 위하여 테일러 도표 (Taylor diagram), 산점도

(scatter plot), 오차 시계열 및 상자그림 (box plot)을 활용하였다. Fig. 6은 저수지 수위 예측모델의 성능을 비교하기 위한 테일러 도표를 나타낸다. 테일러 도표는 상관계수 (correlation coefficient, CC), 표준편차 (standard deviation, SD), CRMSD (centered root-mean-square difference)에 근거하여 예측패턴이 관측패턴에 얼마나 잘 일치되는가에 대한 도식적인 요약 을 제공한다(Taylor, 2001). Fig. 6에서 회색 등고선은 CRMSD 값을 나타낸다. 예측패턴과 관측패턴 사이의 CRMSD 값은 수평축 상의 원 표시 (○)으로부터의 거리에 비례한다. 예측패턴에 대한 SD 값은 원점으로부터 반경방향 거리에 비례한다. 검정색 원호는 관측패턴에 대한 SD 값을 나타낸다. 어떤 모델이 검정색 원호에 가까울수록 예측패턴은 관측패턴에 근






Fig. 6 Taylor diagram

접합을 나타낸다. 각 점의 방위각 위치는 예측 및 관측패턴 간의 CC 값을 나타낸다. Fig. 6으로부터 각 예측시간에 대한 모델들은 예측시간별로 군집을 이루고 있으며, 예측시간이 증가할수록 모델의 예측 정확성이 저하됨을 알 수 있다. 예측시간 $t=1$ day에 대하여 ANFIS1, ANN6, RF6, GRNN6의 순으로 예측 정확성이 우수한 것으로 나타났다. 예측시간 $t=5$ days에 대하여 ANN1, RF6, ANFIS1, GRNN3의 순으로 예측 정확성이 우수한 것으로 나타났다. 예측시간 $t=10$ days에 대하여 ANN3, RF1, ANFIS3, GRNN3의 순으로 예측 정확성이 우수한 것으로 나타났다.


Figs. 7~9는 예측시간별 각 모델의 산점도를 나타내고 있다. 산점도에서 $y=x$ (파란색 직선) 직선에 자료점들이 가까이 위치할수록 예측 정확성이 우수함을 나타내고, 자료점에 대한 적합직선 (fitted line) $y=ax+b$ (빨간색 직선)의 기울기인 a 값이 1에 가까울수록, y 절편인 b 값이 0에 가까울수록, 즉




(a) ANN6



(b) GRNN6



(c) ANFIS1



(d) RF6

Fig. 7 Scatter plots ($t=1$ day)

적합직선이 $y=x$ 와 일치할수록 예측 정확성이 더 우수함을 나타낸다. 예측시간 $t=1$ day에 대한 산점도인 Fig. 7로부터 모든 모델은 $y=x$ 직선 주변에 가깝게 자료점들이 위치하여 예측 정확성이 우수함을 나타내며, ANFIS1과 ANN6 모델은 상대적으로 우수한 예측 정확성을 나타냄을 알 수 있다. 예측시간 $t=5$ days에 대한 산점도인 Fig. 8로부터 ANN1과 RF6 모델은 ANFIS1과 GRNN3 모델에 비해 상대적으로 우수한 예측 정확성을 나타내었으며, 예측시간 $t=10$ days에 대한 산점도인 Fig. 9로부터 ANN3와 RF1 모델은 ANFIS3와 GRNN3 모델에 비해 상대적으로 우수한 예측 정확성을 나타냄을 알 수 있다.

Fig. 10은 예측오차에 대한 시계열과 상자그림을 이용하여 저수지 수위 예측모델의 정확성을 비교하고 있다. 예측시간 t

= 1 day에 대하여 ANN6와 ANFIS1 모델이 상대적으로 낮은 예측오차를 나타내었으며, 예측시간 $t=5$ 및 10 days에 대하여 각각 ANN1과 RF6, ANN3와 RF1 모델이 상대적으로 낮은 예측오차를 나타내었다. GRNN 모델은 모든 예측시간에 대하여 상대적으로 높은 예측오차를 나타내었다. 오차의 크기는 고수위에서 크게 나타나는 경향이 있는 것으로 분석되었다. 기계학습모델은 과거의 관측자료를 이용하여 모델을 학습하게 되는데, 고수위 자료의 경우 저수위 자료에 비해 상대적으로 학습자료의 개수가 작기 때문에 저수위에 비해 오차가 커지는 것으로 판단된다.

저수지 수위 예측모델에 대한 테일러 도표, 산점도, 오차 시계열 및 상자그림으로부터 예측시간 $t=1$ day에 대해서는 ANN6와 ANFIS1 모델이 우수한 저수지 수위 예측결과를 나


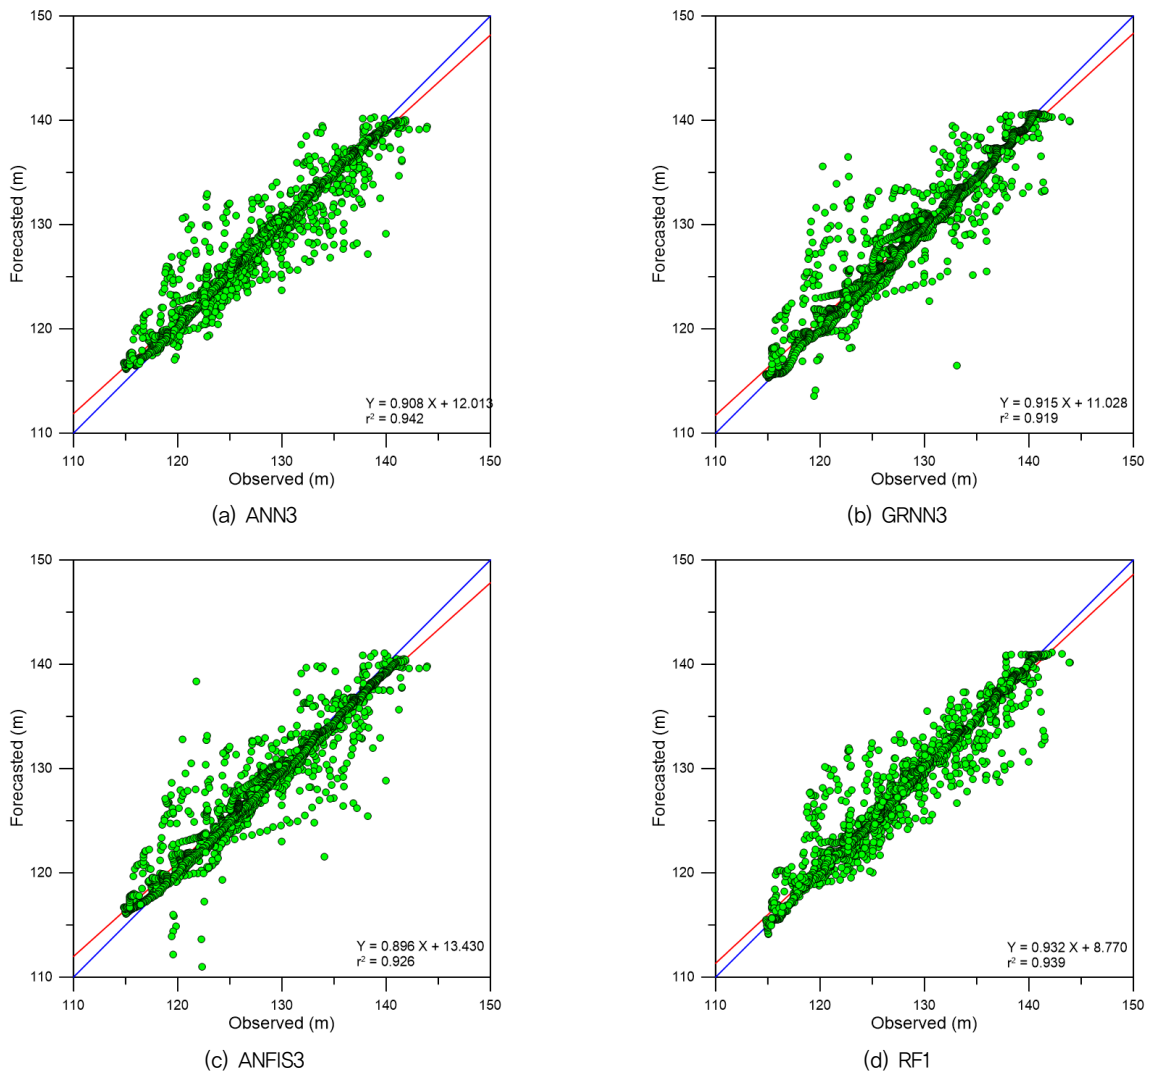


Fig. 8 Scatter plots ($t=5$ days)

Fig. 9 Scatter plots ($t = 10$ days)

타내었으며, 예측시간 $t = 5$ 및 10 days에 대해서는 각각 ANN1과 RF6, ANN3와 RF1 모델이 우수한 저수지 수위 예측결과를 나타내었다. 모든 예측시간에 대해서 종합적으로 살펴볼 경우, ANN 모델이 비교모델 중에서 가장 우수하게 저수지 수위를 예측하는 것으로 분석되었다.

IV. 결 론

본 연구에서는 저수지 수위 예측에서 기계학습모델인 ANN, GRNN, ANFIS 및 RF 모델의 적용성을 비교 및 평가하였다. 저수지 수위 예측모델의 성능평가를 위하여 충주댐 유역을 분석유역으로 선정하였으며, 모델 효율성 평가지표 (무차원

지표, 잔차기반 지표)와 도식적 비교 (테일러 도표, 산점도, 예측오차 시계열 및 상자그림)에 기반하여 모델 성능을 비교 및 평가하였다.

저수지 수위 예측모델의 예측결과로부터 예측시간 $t = 1$ day에 대해서는 ANFIS1과 ANN6 모델이 우수한 저수지 수위 예측결과를 나타내었으며, 예측시간 $t = 5$ 및 10 days에 대해서는 각각 ANN1과 RF6, ANN3와 RF1 모델이 우수한 저수지 수위 예측결과를 나타내었다. 모든 예측시간에 대하여 종합적으로 판단할 경우 ANN 모델이 가장 우수한 저수지 수위 예측결과를 나타내었다. 이러한 결과로부터 저수지 예측모델의 성능은 입력변수의 조합에 의존하며, 저수지 수위 예측을 위해 모든 예측시간에 대하여 단일 입력변수 조합 및 단일 예측모델을 적용할 것이 아니라 예측시간에 따라 최적의

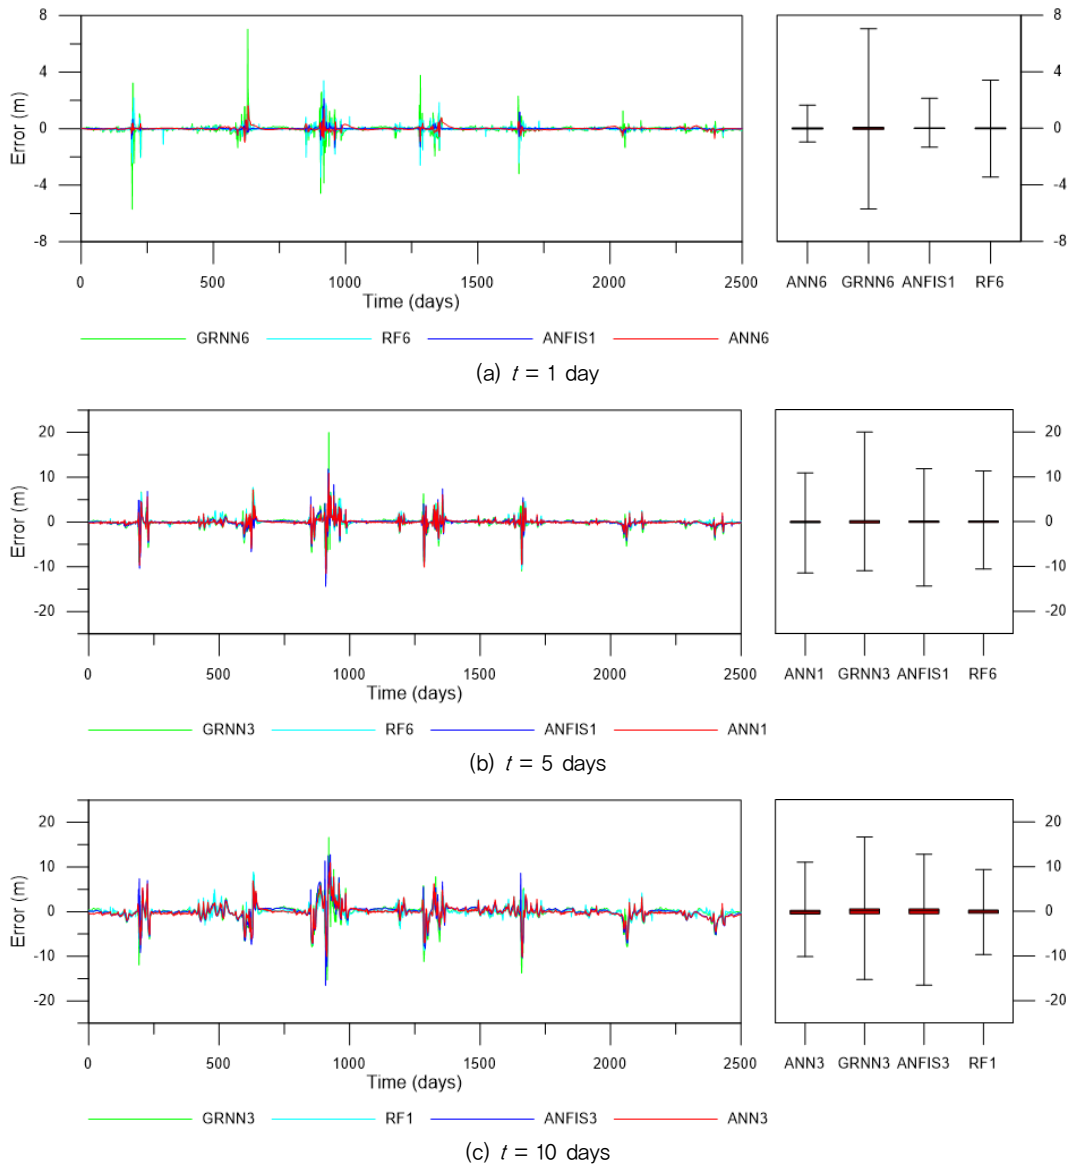


Fig. 10 Error time series and box plots

입력변수 조합 및 최적 예측모델을 적용하는 것이 합리적이라 판단된다. 예측시간 $t = 1$ day에 대해서는 모든 모델이 우수한 예측결과를 나타내었으나 예측시간이 증가할수록 예측 정확도는 점차 감소하였다. 따라서 향후 장기 예측시간에 대한 예측 정확도를 향상시키기 위하여 추가적인 연구가 필요할 것으로 판단되며, bootstrap 및 wavelet 해석과 결합한 하이브리드 모델 개발이 제안될 수 있을 것이다.

본 연구에서 제시한 기계학습모델들은 용수공급, 수력발전, 홍수조절, 수생태계 보전 측면에서 저수지의 거동을 효율적으로 예측하는데 도움을 줄 수 있을 것으로 판단된다. 다만

본 연구의 경우 국토교통부의 WAMIS 시스템에서 제공하고 있는 시계열 자료(저수위, 유입량, 방류량, 강우량)만을 대상으로 하므로 다양한 수문량(저수량, 증발량 등)에 대한 시계열 자료가 가용할 경우 보다 정확한 예측모델을 구성할 수 있을 것으로 판단된다. 기계학습모델의 경우 관측자료의 질과 양에 영향을 많이 받기 때문에 자료관리시스템에서 관측자료의 품질관리에 많은 노력이 이루어져야 할 것이다. 더불어 향후 연구로서 저수지 수위 예측을 위한 개념적 또는 물리 기반의 모델과 기계학습모델의 비교 연구가 제안될 수 있을 것이다.

Appendix. 모델 효율성 평가지표

일치지표 (index of agreement, d):

$$d = 1 - \frac{\sum_{i=1}^N (S_i - S_i^*)^2}{\sum_{i=1}^N (|S_i^* - \bar{S}| + |S_i - \bar{S}|)^2} \quad (A1)$$

결정계수 (coefficient of determination, r^2):

$$R^2 = \left[\frac{\sum_{i=1}^N (S_i - \bar{S})(S_i^* - \bar{S})}{\sqrt{\sum_{i=1}^N (S_i - \bar{S})^2 \sum_{i=1}^N (S_i^* - \bar{S})^2}} \right]^2 \quad (A2)$$

제공근 평균제곱오차 (root-mean-square error, RMSE):

$$RMSE = \left\{ \frac{1}{N} \sum_{i=1}^N [S_i^* - S_i]^2 \right\}^{0.5} \quad (A3)$$

평균절대오차 (mean absolute error, MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |S_i^* - S_i| \quad (A4)$$

평균제곱상대오차 (mean squared relative error, MSRE):

$$MSRE = \frac{1}{N} \sum_{i=1}^N \frac{(S_i - S_i^*)^2}{S_i^2} \quad (A5)$$

평균고차오차 (mean higher order error, MS4E):

$$MS4E = \frac{1}{N} \sum_{i=1}^N (S_i - S_i^*)^4 \quad (A6)$$

여기서 S_i^* 는 예측치, S_i 는 관측치, \bar{S} 는 관측치의 평균, \bar{S} 는 예측치의 평균, N 은 관측자료의 개수이다 (Dawson and Wilby, 2001).

REFERENCES

- Adamowski, J. and H. F. Chan, 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology* 407(1-4): 28-40.
- Altunkaynak, A., 2007. Forecasting surface water level fluctuations of lake Van by artificial neural networks. *Water Resources Management* 21(2): 399-408.
- Booker, D. J. and R. A. Woods, 2014. Comparing and combining physically-based and empirically-based approaches for estimating the hydrology of ungauged catchments. *Journal of Hydrology* 508: 227-239.
- Breiman, L., 2001. Random forests. *Machine Learning* 45(1): 5-32.
- Chang, F.-J. and Y.-T. Chang, 2006. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources* 29(1): 1-10.
- Das, M., S. K. Ghosh, V. M. Chowdary, A. Saikrishnaveni, and R. K. Sharma, 2016. A probabilistic nonlinear model for forecasting daily water level in reservoir. *Water Resources Management* 30(9): 3107-3122.
- Dawson, C. W. and R. L. Wilby, 2001. Hydrological modelling using artificial neural networks. *Progress in Physical Geography* 25(1): 80-108.
- Eckley, C. S., T. P. Luxton, J. L. McKernan, J. Goetz, and J. Goulet, 2015. Influence of reservoir water level fluctuations on sediment methylmercury concentrations downstream of the historical Black Butte mercury mine, OR. *Applied Geochemistry* 61: 284-293.
- Günther, F. and S. Fritsch, 2010. Neuralnet: training of neural networks. *The R Journal* 2(1): 30-38.
- Hipni, A., A. El-Shafie, A. Najah, O. A. Karim, A. Hussain, and M. Mukhlisin, 2013. Daily forecasting of dam water levels: comparing a support vector machine (SVM) model with adaptive neuro fuzzy inference system (ANFIS). *Water Resources Management* 27(10): 3803-3823.
- Jang, J. S. R., C. T. Sun, and E. Mizutani, 1997. *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*. Prentice-Hall, New Jersey.
- Jeong, J. H. and Y. N. Yun, 2007. *Water Resources Design Practice*. Goomibook (in Korean).
- Ji, D., S. A. Wells, Z. Yang, D. Liu, Y. Huang, J. Ma, and C. J. Berger, 2017. Impacts of water level rise on algal bloom prevention in the tributary of Three Gorges Reservoir, China. *Ecological Engineering* 98: 70-81.
- Jothiprakash, V. and R. B. Magar, 2012. Multi-time-step ahead daily and hourly intermittent reservoir inflow prediction by artificial intelligent techniques using lumped and distributed data. *Journal of Hydrology* 450-451: 293-307.
- Kim, S., Y. Seo, and V. P. Singh, 2015. Assessment of pan evaporation modeling using bootstrap resampling and soft computing methods. *Journal of Computing in Civil Engineering* 29(5): 04014063.
- Kisi, O., J. Shiri, and B. Nikoofar, 2012. Forecasting daily lake levels using artificial intelligence approaches. *Computers & Geosciences* 41: 169-180.
- Mamdani, E. H. and S. Assilian, 1975. An experiment in linguistic

- synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies* 7(1): 1-15.
18. Mathworks, 2016. Fuzzy logic toolbox user's guide. The Mathworks, Inc. http://www.mathworks.com/help/pdf_doc/fuzzy/fuzzy.pdf. Assessed 14 January 2017.
 19. Nguyen, T. T., 2015. An L1-regression random forests method for forecasting of Hoa Binh reservoir's incoming flow. *In Proceedings of 2015 Seventh International Conference on Knowledge and Systems Engineering (KSE)*, Ho Chi Minh City, Vietnam, 360-364.
 20. Partal, T. and H. K. Cigizoglu, 2008. Estimation and forecasting of daily suspended sediment data using wavelet-neural networks. *Journal of Hydrology* 358(3-4): 317-331.
 21. Rajaei, T., V. Nourani, Z. K. Mohammad, and O. Kisi, 2011. River suspended sediment load prediction: application of ANN and wavelet conjunction model. *Journal of Hydrologic Engineering* 16(8): 613-627.
 22. Seo, Y., S. Kim, O. Kisi, and V. P. Singh, 2015. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. *Journal of Hydrology* 520: 224-243.
 23. Seo, Y., S. Kim, O. Kisi, V. P. Singh, and K. Parasuraman, 2016. River stage forecasting using wavelet packet decomposition and machine learning models. *Water Resources Management* 30(11): 4011-4035.
 24. Specht, D. F., 1991. A general regression neural network. *IEEE Transactions on Neural Networks* 2(6): 568-576.
 25. Takagi, T. and M. Sugeno, 1985. Fuzzy identification of systems and its application to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics* 15(1): 116-132.
 26. Taylor, K. E., 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres* 106(D7): 7183-7192.
 27. Tiwari, M. K. and C. Chatterjee, 2010. Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach. *Journal of Hydrology* 394(3-4): 458-470.
 28. Valizadeh, N. and A. El-Shafie, 2013. Forecasting the level of reservoirs using multiple input fuzzification in ANFIS. *Water Resources Management* 27(9): 3319-3331.
 29. Valizadeh, N., A. El-Shafie, M. Mirzaei, H. Galavi, M. Mukhlisin, and O. Jaafar, 2014. Accuracy enhancement for forecasting water levels of reservoirs and river streams using a multiple-input-pattern fuzzification approach. *The Scientific World Journal*, 2014, Article ID 432976, 1-9.
 30. Yang, T., X. Gao, S. Sorooshian, and X. Li, 2016. Simulating California reservoir operation using the classification and regression-tree algorithm combined with a shuffled cross-validation scheme. *Water Resources Research* 52(3): 1626-1651.
 31. Yarar, A., M. Onucyildiz, and N. K. Coptoy, 2009. Modelling level change in lakes using neuro-fuzzy and artificial neural networks. *Journal of Hydrology* 365(3-4): 329-334.