



강우자료 형태에 따른 인공신경망의 일유입량 예측 정확도 평가

Influence of Rainfall observation Network on Daily Dam Inflow using Artificial Neural Networks

김석현^a · 김계웅^b · 황순호^b · 박지훈^c · 이재남^d · 강문성^{e,†}

Kim Seokhyeon · Kim Kyeung · Hwang Soonho · Park Jihoon · Lee Jaenam · Kang Moonseong

ABSTRACT

The objective of this study was to evaluate the influence of rainfall observation network on daily dam inflow using artificial neural networks(ANNs). Chungju Dam and Soyangriver Dam were selected for the study watershed. Rainfall and dam inflow data were collected as input data for construction of ANNs models. Five ANNs models, represented by Model 1 (In watershed, point rainfall), Model 2 (All in the Thiessen network, point rainfall), Model 3 (Out of watershed in the Thiessen network, point rainfall), Model 1-T (In watershed, area mean rainfall), Model 2-T (All in the Thiessen network, area mean rainfall), were adopted to evaluate the influence of rainfall observation network. As a result of the study, the models that used all station in the Thiessen network performed better than the models that used station only in the watershed or out of the watershed. The models that used point rainfall data performed better than the models that used area mean rainfall. Model 2 achieved the highest level of performance. The model performance for the ANNs model 2 in Chungju dam resulted in the R^2 value of 0.94, NSE of 0.94 NSE_{in} of 0.88 and $PBIAS$ of -0.04 respectively. The model-2 predictions of Soyangriver Dam with the R^2 and NSE values greater than 0.94 were reasonably well agreed with the observations. The results of this study are expected to be used as a reference for rainfall data utilization in forecasting dam inflow using artificial neural networks.

Keywords: Artificial neural network; dam inflow; rainfall observation network

1. 서 론

현재 사용하는 대부분의 강우-유출 모형은 지점 강우를 유역강우량 형태로 변환하여 입력자료로 이용하고 있다. Lee and Yoon (2005)은 Modified Clark 모형에 크리깅 기법으로 산정한 유역강우량을 적용하였으며 Jang et al. (2018)은 SWAT 모형에 입력자료를 위해 유역강우량 산정방법에 따른 유출량 정확도를 분석하였다. 이 때 산정방법에 따라 강우-유출 결과가 다르게 나타나며 적절한 유역강우량을 산

정하지 못할 경우 결과에 오차로 이어진다(Choi and Han, 2011).

이에 반해 회귀모형, 인공신경망과 같은 자료지향형 모형은 지점 강우와 같은 관측 자료를 전처리 없이 그대로 사용할 수 있고 유역 내에 위치한 기상자료 뿐만 아니라 관계가 정확히 밝혀지지 않은 유역 외부 기상대 자료도 활용할 수 있는 장점을 가진다.

인공신경망 기법은 뇌의 신경세포의 작용을 모델링기법으로 모사한 것으로, 다양한 변수들 간의 관계를 분석하는데 용이하고, 물리적 현상에 대한 근본적인 이해 없이도 비선형 상관관계에 대한 분석이 가능하여 수문, 수질분야를 포함한 다양한 분야에 활발히 이용되고 있다(Kim et al., 2016).

인공신경망을 이용한 강우-유출 연구로는 Kang and Park (2003)은 영산강유역에서 단기홍수량을 예측하였으며, Kang and Park (2001)은 발안유역에서 장기유출해석을 Lee et al. (2000)은 영산강에서의 유출량을 예측하였다. Ryu et al. (2012)은 인공신경망을 통한 일유입량 예측에서 웨이블릿 변환을 활용하여 정확도를 높이고자 하였다. Kim and Seo (2015)는 낙동강 유역에 대하여 인공신경망과 앙상블기법을 적용한 바 있다. Kim et al. (2016)은 Satellite-derived flow 시그널을 활용하여 관측소가 없는 임진강의 유역유출량에 대하여 사용하였다. Moradi and Lee (2018)는 남강댐 일 유출량 산정에 최적화알고리즘 별 예측을 비교 평가하였으며, Park et al.

^a MS Student, Department of Rural Systems Engineering, Seoul national University

^b PhD Student, Department of Rural Systems Engineering, Seoul national University

^c Research Fellow, Climate Services and Research Department, APEC Climate Center

^d Associate Researcher, Water Resources & Environment Research Group, Rural Research Institute, Korea Rural Community Corporation

^e Professor, Department of Rural Systems Engineering, Institute of Agriculture and Life sciences, Institute of Green Bio Science and Technology, Seoul national University

† **Corresponding author**

Tel.: +82-02-880-4582 Fax.: +82-02-873-2087

E-mail: mskang@snu.ac.kr

Received: November 29, 2018

Revised: March 7, 2019

Accepted: March 7, 2019

(2018)은 다목적댐 유입량 예측에 순환신경망과 인공신경망을 적용 평가하였다.

하지만 기존의 개발 및 적용되었던 인공신경망 모델들은 입력 자료에 대한 선정과 구성과정이 연구자 주관에 따라 결정되어 설명이 불확실하였다. 이러한 이유 때문에 인공신경망 모델은 수자원 및 환경 분야에서 다른 모델과 달리 보편적인 모델로써 평가받지 못하였다. 이는 인공신경망 모델링의 입력과 목표인자의 설정, 데이터 전처리, 인공신경망 구조 등의 방법론적인 측면의 연구가 거의 이루어지지 않았기 때문이다(Kim and Seo, 2017).

인공신경망을 통한 유역 유출량 예측에 유량자료와 강우량은 필수적 입력인자이다(Mimms and Hall, 1996; Ancil and Rat, 2005). 유량자료는 해당지점의 전일 유량을 사용하거나 상류 지역에 측정지점 자료를 활용하는 것이 일반적인데 반해 강우량 자료는 여러 방법이 혼용되어 사용되고 있다.

최근 연구의 강우량자료 활용방법을 살펴보면 Kim and Seo (2015)의 경우 낙동강유역 내 12개 지점강우량을 학습시켰고 Moradi and Lee (2018)는 남강댐 유역 내, 외 5개 지점강우량을 학습시켰다. 반면, Park et al. (2018)은 소양강댐, 충주댐 유역 내 강우량을 티센망을 통해 산정한 유역강우량을 사용하였다.

상기 연구에서는 티센망 등을 통해 유역강우량을 산출한 뒤 사용하거나 지점강우량을 그대로 학습시키는 방법을 혼용하고 있다. 또한 입력 자료로 고려되는 기상대도 연구자마다 다르며 유역 내부에 위치한 관측소만 고려하거나 유역 외부에 위치한 관측소까지 고려하는 방법이 혼용되고 있다. 이처럼 연구자마다 강우자료의 입력 방법에 있어 각기 다른 방법을 사용하고 있는 실정이며 이에 따라 수문 모의 결과에 미치는 영향을 평가할 필요가 있다.

이처럼 티센망 등을 통해 유역강우량을 산출한 뒤 사용하거나 지점강우량을 그대로 학습시키는 것이 혼용되고 있다. 또한 입력 자료로 고려되는 기상대도 연구자마다 다르며 유역 내부에 위치한 관측소만 고려하거나 유역 외부에 위치한 관측소까지 고려하는 방법이 혼용되어 사용되고 있다. 이처럼 연구자마다 강우자료 활용에 있어 연구자마다 각각 다른 방법을 사용하고 있는 실정이며 이에 강우자료 사용 방법 비교, 평가가 필요하다.

본 연구의 목적은 유입량예측 분야에서 인공신경망 모델 적용에 있어 강우자료 사용방법과 유역 내, 외부 강우관측소의 영향을 검토하여 추후 인공신경망을 통한 유입량 예측에 강우자료 사용 방법을 제시함에 있다.

II. 재료 및 방법

1. 연구대상지

본 연구의 대상지는 남한강 유역의 충주댐과 북한강유역의 소양강댐으로 선정하였다. 충주댐은 유역면적 6,629.3 km², 평균 유입량 154.5 m³/s이며 소양강댐의 유역면적은 2,783.2 km², 평균 유입량은 55.5 m³/s이다. 모의기간은 댐 운영기간과 기상대의 관측기간을 고려하여 충주댐은 1995년부터 2017년까지 23년으로 정하였으며 그 중 1995년부터 2010년까지 16년을 신경망학습에 사용하였고 2011년부터 2017년까지 7년을 모델의 검정에 사용하였다. 소양강댐은 1974년부터 2017년까지 44년을 모의기간으로 정하고 그 중 1974년부터 2007년까지 34년을 신경망학습에 2008년부터 2017년까지 10년을 검정에 사용하였다. Fig. 1과 Table 1은 소양강댐의 유역도와 티센망 분석결과이며 Fig. 2와 Table 2는 충주댐의 유역도와 티센망 분석결과이다.




Fig. 1 Study area - Soyangriver dam watershed

Table 1 Thiessen area of Soyangriver dam watershed

Name	Thiessen area (km ²)	Percentage (%)
Inje	1858.4	66.8
Chuncheon	345.1	12.4
Daegwallyeong	317.4	11.4
Sokcho	261.4	9.4
Hongcheon	0.8	0.0
Sum	2783.2	100.0



Fig. 2 Study area - Chungju dam watershed

Table 2 Thiessen area of Chungju dam watershed

Name	Thiessen area (km ²)	Percentage (%)
Yeongwol	1,678.5	25.3
Daegwanlyeong	1,505.4	22.7
Jaechon	1,004.8	15.2
Taebaek	691.2	10.4
Yeongju	467.2	7.0
Wonju	445.9	6.7
Chungju	428.7	6.5
Donghae	237.6	3.6
Bongwhoa	101.6	1.5
Hongcheon	36.0	0.5
Mungyeong	31.8	0.5
Gangneung	0.6	0.0
Sum	6,629.3	100.0

2. 유역평균강우량 산정방법

본 연구에서는 강우자료 형태에 따른 비교를 위해 유역평균강우량을 산정하였다. 유역평균강우량 산정방법은 실무에서 가장 많이 사용하는 Thiessen의 가중법을 사용하였다. Thiessen 가중법은 우량계의 분포상태를 고려하고 적용방법이 객관적이기 때문에 가장 널리 사용되고 있다. Thiessen의

가중법은 유역면적에 대한 각 관측점의 지배면적을 가중치로 삼아 우량 값과 곱하고 이를 유역면적으로 나누어 산정하며 이에 대한 식은 식 (1)과 같다.

$$P_m = \frac{A_1P_1 + A_2P_2 + \dots + A_NP_N}{A_1 + A_2 + \dots + A_N} = \frac{\sum_{i=1}^N A_iP_i}{\sum_{i=1}^N A_i} \quad (1)$$

여기서, P_m 은 유역평균강우량이며 P_1, P_2, \dots, P_N 은 관측점에 각각 기록된 강우량, A_1, A_2, \dots, A_N 은 각 관측점의 지배면적이다(Yoon, 2007).

3. 인공신경망

인공신경망(Artificial neural network)은 인간의 뇌에 신경세포의 작용을 모델링 기법으로 모사한 것으로 수자원분야에서 강우, 유출뿐만 아니라 가뭄, 수질 예측까지 광범위하게 적용되고 있다. 인공신경망은 블랙박스 모델이기 때문에 물리현상에 대한 사전지식 없이 최적 해를 찾아낼 수 있고 회귀분석보다 계산되는 가중치의 개수가 월등히 많아 비선형 문제해결에 좋은 결과를 보인다(Kim et al., 2016).

인공신경망은 입력층 (input layer), 은닉층 (hidden layer), 출력층 (output)으로 구성되어 있으며 각 층은 Fig. 3과 같은 1개 이상의 단일 뉴런으로 구성된다.

단일 뉴런에서의 연산과정은 Fig. 4와 같이 입력 자료인 x 와 연결강도의 벡터인 w 의 곱으로 이루어진 결합함수와 결합함수로부터 출력이 선형 또는 비선형으로 이루어지는 활성화함수를 통해 출력의 과정으로 연산이 되게 된다(Kang, 2003).




Fig. 3 Architecture of artificial neuron




Fig. 4 Structure of artificial neural network

4. 인공신경망 모형 구성

댐 유입량 산정을 위한 인공신경망의 입력 자료는 기상청 기상자료개방포털의 일 강우자료와 한강홍수통제소의 일 유입량자료를 적용하였다.

Table 3은 본 연구에서 구성한 모델을 나타낸 것이다. 모델은 기상자료 적용범위와 유역강우량의 적용 유무에 따라서 대상지 당 5개로 구성하였다. 먼저 유역강우량을 적용하지 않고 지점강우량을 직접적으로 학습시켰으며 기상자료 적용범위는 유역 내 강우자료만 구성한 경우 (Chung1, Soyang1), 티센망 분석에서 유역에 영향을 준다고 판단되는 강우자료 모두를 구성한 경우 (Chung2, Soyang2), 영향 관측소 중 유역 외부에 위치한 강우자료로만 구성한 경우 (Chung3, Soyang3)로 구분하였다. 또한 유역 외의 경우를 제외한 두 가지는 티센망을 통해 유역강우량을 적용한 모델 (Chung1-T, Chung2-T, Soyang1-T, Soyang2-T) 을 구축하였다.

인공신경망의 구조는 입력층 (Input Layer)에서 출력층 (output layer)사이에는 은닉층 (Hidden Layer)이 존재하는 다중신경망을 활용하였다. 모델의 최적 노드 수는 1-20개로 변화

시키면서 실측유입량 자료와 비교하여 최적 노드수를 결정하였다.

Performance Index로는 전방위 신경망에서 전형적으로 사용하는 MSE (Mean Square Error)을 사용하였으며 식(2)와 같다. 각 층에서 사용한 결합함수는 식 (3)과 같으며, 활성화 함수는 인공신경망 구성에 일반적으로 이용되는 Sigmoid 함수 식 (4)을 활용하였다.

$$Mean\ Square\ Error = \frac{1}{n} \sum_{i=1}^n [O_i - P_i]^2 \quad (2)$$

$$\sum_{i=1}^n = X_i w_{\pi} \quad (3)$$

$$\varphi = \frac{1}{1 + e^{-x}} \quad (4)$$

모형의 입출력 자료는 최솟값 0과 최댓값 1의 정규화를 수행하였으며 식(5)과 같다. 본 연구에서 X_{min} 은 0으로 고정하고 X_{max} 는 최댓값의 제한을 가지지 않기 위해 1.2배를 적용하였다.

$$X' = \left[\frac{1}{X_{max} - X_{min}} \right] \times (X - X_{min}) \quad (5)$$

신경망 학습을 위한 알고리즘은 Levenberg-Marquardt 알고리즘을 사용하였다. Levenberg-Marquardt방법은 수렴속도가 빠르고 경사하강법(gradient descent method)에 비하여 학습을 설정하지 않아도 되는 장점이 있다(Lee et al., 2019).

5. 모델의 평가

본 연구의 모델의 성능 평가를 위해 4가지 통계변량을 비

Table 3 Type of Input rainfall in model

Model name	The number of rainfall	Area mean	Meteorological range
Chung1	3	X	In watershed
Chung2	12	X	All in thiessen network
Chung3	7	X	Out of watershed in thiessen
Chung1-T	3	O	In watershed
Chung2-T	12	O	All in thiessen network
Soyang1	2	X	In watershed
Soyang2	5	X	All in thiessen network
Soyang3	3	X	Out of watershed in thiessen
Soyang1-T	2	O	In watershed
Soyang2-T	5	O	All in thiessen network

교하였다. 실측치와 모의치의 선형관계를 나타내는 결정계수 (R^2)와 수문모델링분야에서 널리 사용되는 Nash and Sutcliffe Efficiency (NSE) (Nash and Sutcliffe, 1970), 저유량에 대한 변형식인 NSE_{ln} (Pushpalatha et al., 2012), 총량에 대한 지표인 Percent BIAS ($PBIAS$) (Gupta, et al., 1999)를 적용하여 비교하였다. 각 통계변량의 식은 다음과 같다.

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (6)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - \bar{P})^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (7)$$

$$NSE_{ln} = 1 - \frac{\sum_{i=1}^n (\ln(O_i + \epsilon) - \ln(P_i + \epsilon))^2}{\sum_{i=1}^n (\ln(O_i + \epsilon) - \ln(\bar{O} + \epsilon))^2} \quad (8)$$

$\epsilon =$ small constant (1% of the mean streamflow)

$$PBIAS = \left| \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i)} \right| \quad (9)$$

III. 결과 및 고찰

1. 모델 구축

Fig. 5는 선행 강우일수 증가에 따른 충주댐의 오차를, Fig. 6은 소양강댐의 오차를 보여주고 있다. Table 4는 각 모델별 산정된 지연일과 최적노드수를 나타냈다. 본 연구에서는 도달시간을 고려하기 위해 0-7일까지 전일 강우량을 입력 자료에 추가하며 모의를 진행하였다. 그 결과 각 모델은 선행 일수

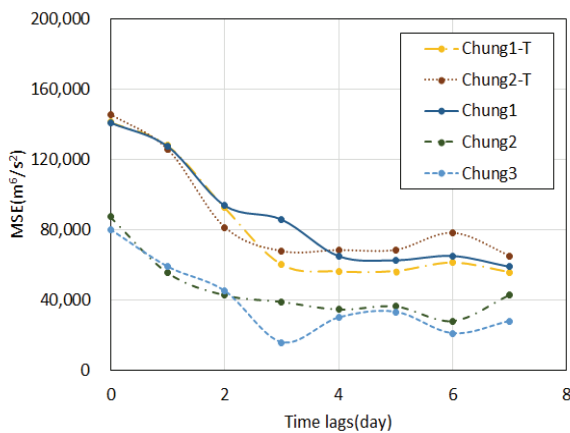


Fig. 5 MSE according to time lags (Chungju dam)

를 늘릴수록 오차가 감소하였으며 충주댐 4일, 소양강댐 2일 이후에는 일정 범위에서 진동하는 경향을 보였다. 이에 충주댐은 4일전, 소양강댐은 2일전까지의 강우를 입력 자료로 활용하였으며 이는 각 유역의 크기 및 경사에 따른 특성이 반영된 것으로 사료된다. 최적 노드 수는 1-2개로 변환하며 시행한 결과 각 모델 별 6-14개로 결정되었다.

Table 4 Time lags and hidden node of each model

Model Name	Time lags(day)	Hidden Node
Chung1	4	14
Chung2	4	6
Chung3	4	9
Chung1-T	4	8
Chung2-T	4	7
Soyang1	2	10
Soyang2	2	11
Soyang3	2	7
Soyang1-T	2	6
Soyang2-T	2	11

2. 모델 별 댐 유입량 산정결과

본 연구에서 구축된 10개의 인공신경망모형을 활용하여 소양강댐, 충주댐에 대하여 훈련 (training)과 검정 (testing)을 수행하였다. 훈련과 검정자료는 한강홍수통제소에서 제공하는 댐 운영 자료의 유입량자료를 활용하였다.

Table 5는 각 모델 별 유입량 산정의 훈련기간과 검정기간의 결과를 R^2 , NSE , NSE_{ln} , $PBIAS$ 4가지 통계량을 통해 나타냈다. Fig. 7은 충주댐의 검정기간 1:1 그래프를 과 Fig. 8은 소양강댐의 검정기간 1:1 그래프를 나타낸 것이다.

일 유입량 훈련결과 충주댐은 훈련결과 R^2 0.77~0.94, NSE

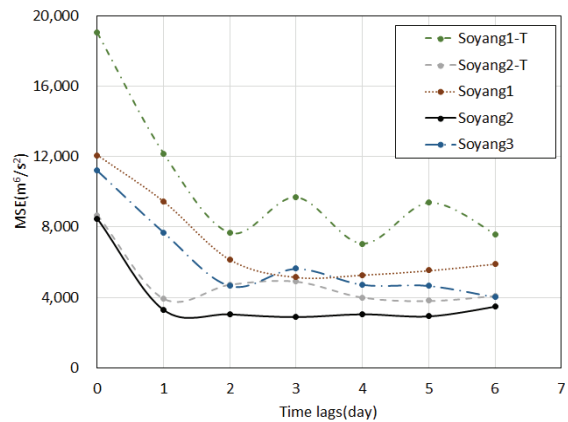


Fig. 6 MSE according to time lags (Soyangriver dam)

Table 5 Training and testing statics for each models

Model Name	Training				Testing			
	R^2	NSE	NSE_{in}	$PBIAS$	R^2	NSE	NSE_{in}	$PBIAS$
Chung1	0.77	0.76	0.87	0.05	0.43	0.40	0.78	-0.02
Chung2	0.94	0.94	0.88	-0.04	0.79	0.79	0.80	-0.05
Chung3	0.92	0.92	0.85	-0.05	0.76	0.75	0.76	-0.05
Chung1-T	0.82	0.82	0.90	-0.35	0.51	0.48	0.81	0.10
Chung2-T	0.79	0.79	0.91	0.00	0.48	0.43	0.84	-0.24
Soyang1	0.90	0.88	0.75	-0.03	0.84	0.84	0.64	-0.02
Soyang2	0.94	0.94	0.79	0.00	0.92	0.92	0.71	0.00
Soyang3	0.90	0.89	0.61	0.03	0.86	0.83	0.45	0.01
Soyang1-T	0.85	0.83	0.38	0.03	0.85	0.85	0.18	-0.01
Soyang2-T	0.93	0.92	0.84	0.00	0.90	0.90	0.77	0.00

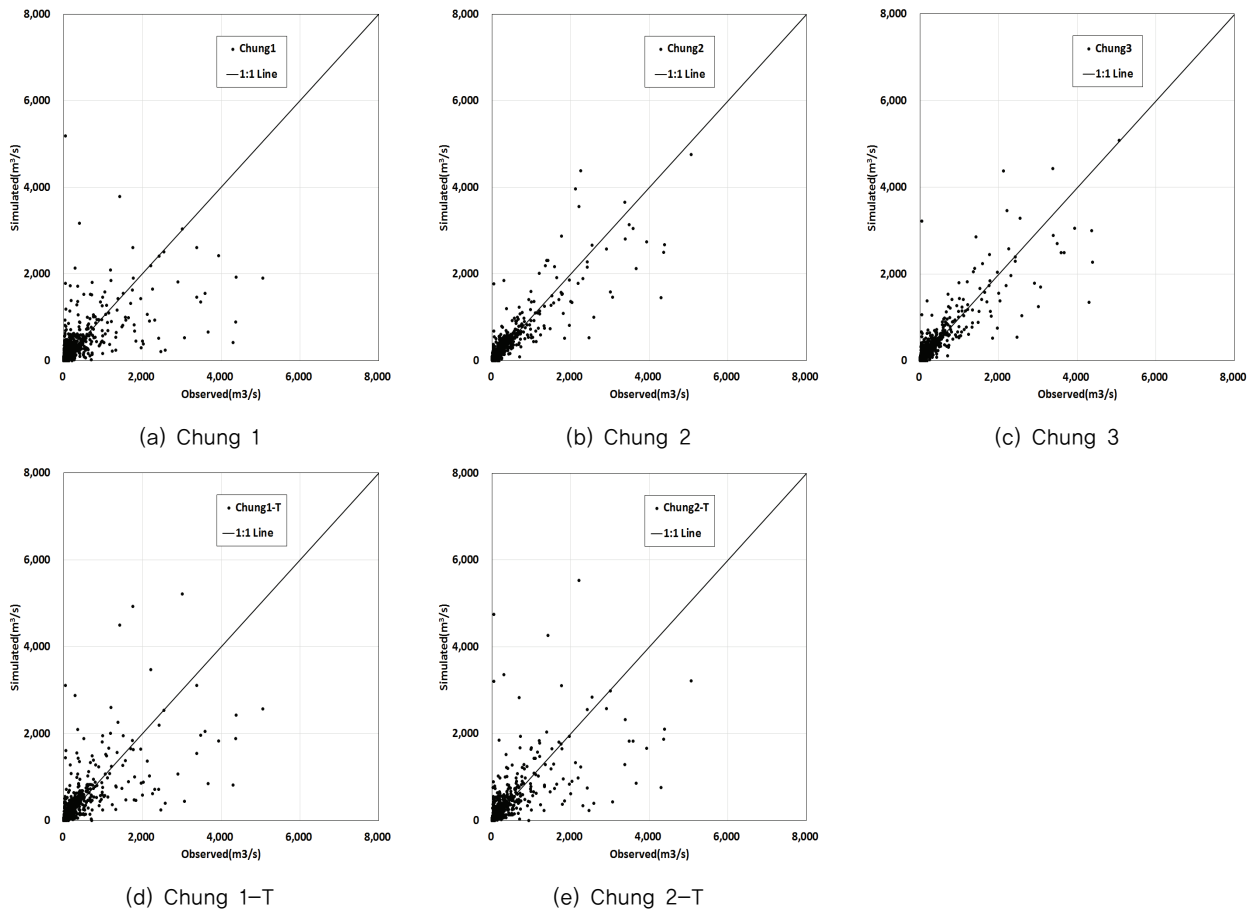


Fig. 7 Scatter plots comparing observed and simulated Chungju dam inflow by artificial neural network for testing period

0.76~0.94, NSE_{in} 0.85~0.90, $PBIAS$ -0.35~0.00로 나타났으며 소양강댐은 R^2 0.85~0.94, NSE 0.83~0.94, NSE_{in} 0.79~0.91, $PBIAS$ 는 -0.03~0.03 의 범위를 나타냈다.

일 유입량 검정결과는 충주댐은 R^2 0.43~0.79, NSE 0.40~

0.79, NSE_{in} 0.76~0.84, $PBIAS$ -0.24~0.10로 나타났으며 소양강댐은 R^2 0.84~0.92, NSE 0.83~0.92, NSE_{in} 0.18~0.77, $PBIAS$ 는 -0.02~0.01 의 범위를 나타내었다. 충주댐, 소양강댐 모두 티센망에 포함된 모든 기상대를 지점강우량을 입력

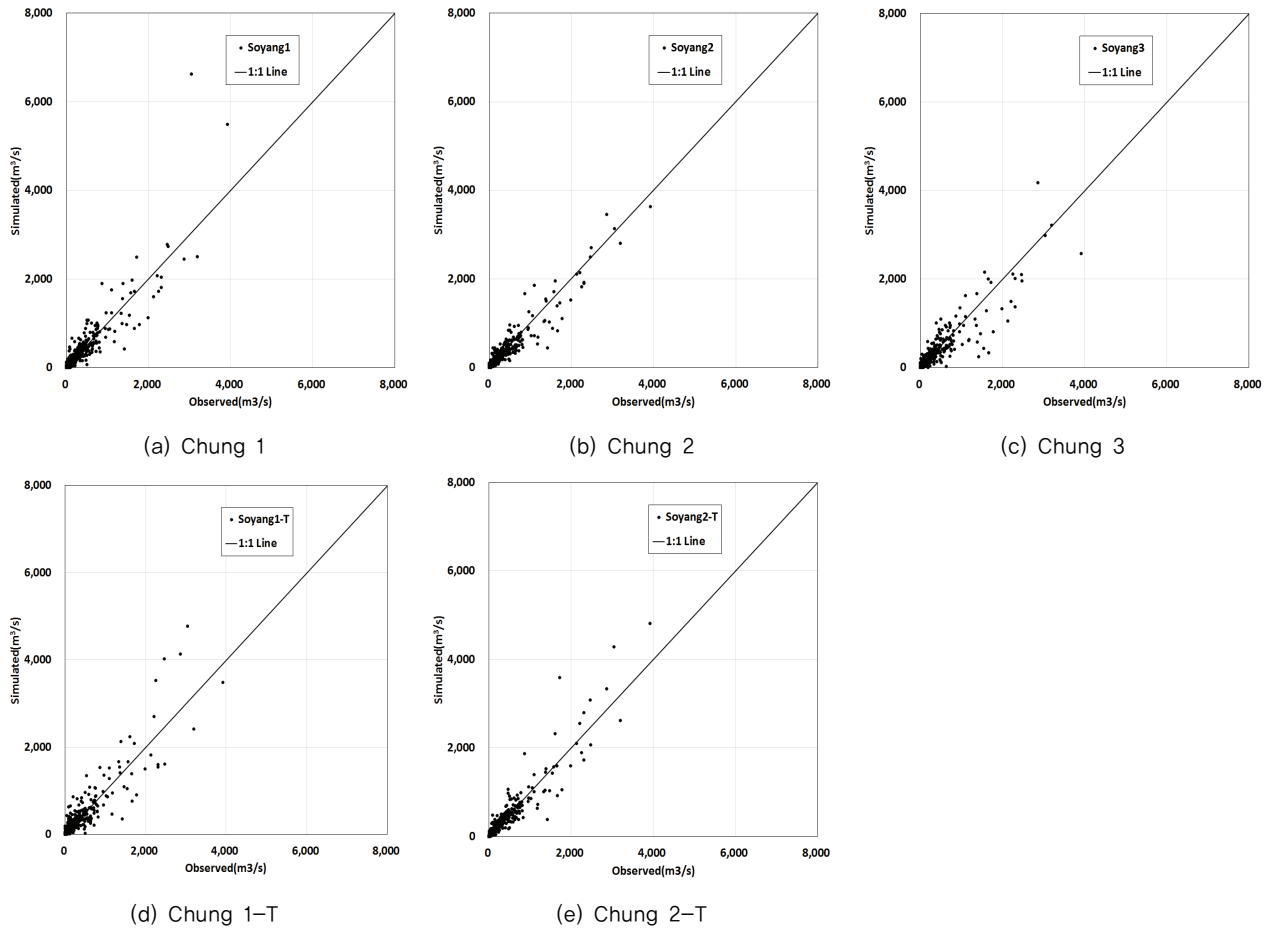





Fig. 8 Scatter plots comparing observed and simulated Soyangriver dam inflow by artificial neural network for testing period






(b) 2012-06-01~2012-09-30

Fig. 9 Time series of observed and simulated of Chungju dam inflow according to the meteorological range



(a) 2011-06-01~2011-09-30



(b) 2012-06-01~2012-09-30

Fig. 10 Time series of observed and simulated of Soyangriver dam inflow according to the meteorological range

자료로 구축한 Chung2, Soyang2 모델에서 가장 좋은 결과를 보였다. 검정결과 소양강 댐이 R^2 , NSE , $PBIAS$ 에서 우수한 경향을 나타내었으나 충주댐은 저유량에 대한 지표인 NSE_{ln} 에서 좋은 값을 나타내었다.

3. 기상대 적용방법에 따른 비교

기상대 적용방법에 3가지 따른 비교 결과 충주댐과 소양강 댐 모두 유역 내 기상대로 입력 자료를 구성한 경우보다 티센 망 내 모든 기상대를 포함했을 때 R^2 , NSE , NSE_{ln} , $PBIAS$ 모두 개선되었다.

좀 더 세부적으로 검정기간 중 유입량 변화가 많은 여름에 대하여 살펴보았다. Fig. 9은 충주댐의 검정기간인 2011-2017년 중 2011년 6월-9월과 2012년 6월-9월을 나타냈으며 Fig. 10은 소양강댐의 검정기간인 2011-2017년 중 2011년 7월-9월과 2012년 7월-9월을 나타낸 것이다.

충주댐은 유역 내 기상대만을 활용한 Chung1모델의 결과 2011년 7월 16일, 2012년 7월 20일과 같이 일부 유입량 증가는 반영하지 못하였다. 또한 2011년 6월 24일과 2011년 8월 17일처럼 일부 침투 유량이 실측보다 일찍 혹은 늦게 발생하는 경향을 나타냈다. 이 때문에 Fig. 7에서 Chung1의 1:1 그래

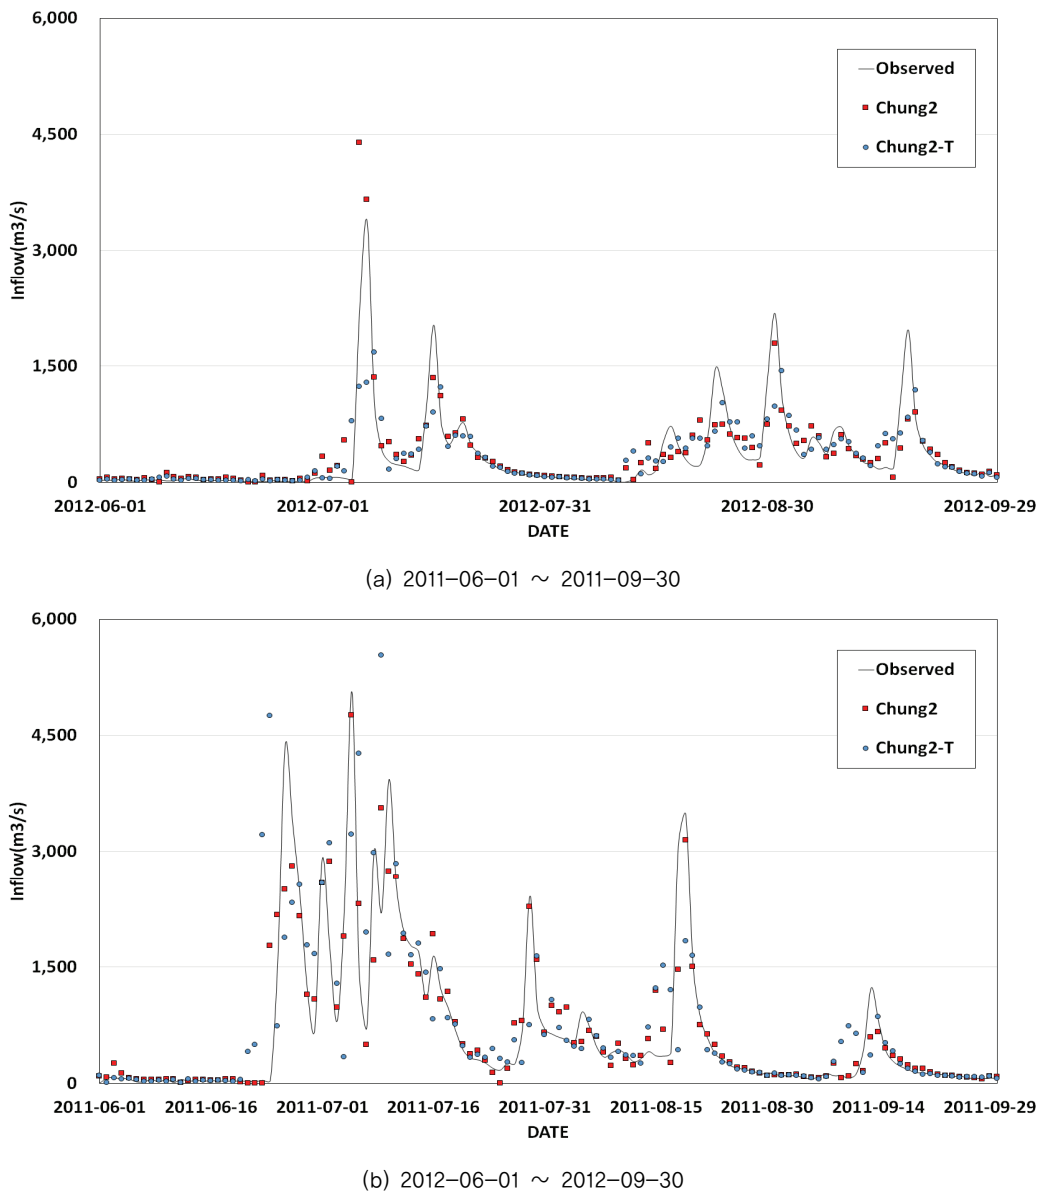


Fig. 11 Time series of observed and simulated of Chungju dam inflow according to the use of area mean rainfall

프에서 침투유량 발생일이 달라 대칭으로 나타난 것으로 사료된다. 유역 외 기상대만을 활용한 Chung3도 침투유량이 실측과 다른 날에 발생하는 날을 확인할 수 있었다.


소양강댐은 세 가지 모델 모두 정확도가 높았으나 Soyang3에서 침투유량 발생 일에 차이가 나는 것을 찾아볼 수 있었으며, 2011년 8월 3일과 2011년 8월 14일 같이 유입량 증가가 관측되지 않았으나 모델 상에는 증가로 기록된 경우를 확인할 수 있었다.

이는 일부 기상대만을 모델을 구성하였을 경우 학습과정에서 가중치 산정에 오차가 생기거나 유역 내 발생한 강우를


모두 고려하지 못하는 것으로 사료된다.

4. 입력자료 형태에 따른 비교분석

강우자료 입력형태에 따른 신경망학습 비교를 위해 기상대 적용방법 중 에서 가장 좋은 결과를 보인 Chung2, Soyang2와 Chung2-T, Soyang2-T를 비교하였다. Table 5와 같이 충주댐과 소양강댐 모두 지점강우량을 학습시킨 모델이 유역강우량 산정한 모델보다 정확도가 높았다. Fig. 11과 Fig. 12는 검정기간 중 유입량이 많은 2011년, 2012년 여름에 대하여 나타난 것이다.



(a) 2011-06-01 ~ 2011-09-30



(b) 2012-06-01 ~ 2012-09-30

Fig. 12 Time series of observed and simulated of Soyangriver dam inflow according to the use of area mean rainfall

충주댐은 유역강우량을 사용한 모델에서 첨두유량 발생 일에서 다소 차이가 발생했다. Fig. 11에 2011년 6월 24일과 7월 6일에서 확인할 수 있으며 이로 인해 Fig. 8의 Chung2-T 1:1 그래프에서 분포가 대칭으로 나타난 것으로 사료된다.

소양강댐은 유역강우량 사용한 모델의 과다 모의되는 경향을 보였다. 이러한 경향은 Fig. 12에 2011년 7월 1일에서 확인할 수 있으며 Fig. 8 Soyang2-T 1:1 그래프에서 확인할 수 있다.

유역강우량을 산출하여 학습시킬 때 유역면적이 큰 충주댐은 유입시간의 오차가 발생하였고 상대적으로 유역면적이 작은 소양강댐은 유입시간을 잘 반영하였다. 이는 유역면적이 클 경우 유역면적이 작을 때보다 강우의 위치에 따라 댐에 유입되는 시간이 다양하기 때문이며 이를 유역강우량 산정하면 공간분포, 시간분포의 왜곡이 생기게 되어 유입량과 유입시간을 정확히 예측하지 못한 것으로 사료된다.

IV. 요약 및 결론

본 연구에서는 강우-유출모형에 널리 활용되고 있는 인공신경망을 활용하여 강우자료 형태에 따른 인공신경망 모델을 구축하였고 그 결과를 비교 평가하였다.

본 연구의 결과는 다음과 같다.

1) 연구대상지는 충주댐, 소양강댐 유역으로 선정하였으며 댐 운영기간과 기상대 자료기간을 고려해 충주댐은 1995년부터 2010년을 훈련기간으로 2011년부터 2017년을 검증기간으로 소양강댐은 1974년부터 2007년을 훈련기간으로 2008년부터 2017년을 검증기간으로 적용하여 신경망을 통해 댐 유입량을 모의하였다.

2) 지점강우를 처리 없이 학습하는 경우와 유역강우량 산정 후 학습하는 경우를 구분하였으며 기상대 고려범위에 따른 10개의 모형을 구축하였다.

3) 각 모델별 시행착오 법을 통해 충주댐은 4일, 소양강댐은 2일의 선행강우자료를 입력 자료로 활용하였고 최적노드 수는 6-14개로 나타났다. R^2 , NSE , NSE_m , $PBIAS$ 를 통해 모델을 평가한 결과 모든 기상대를 활용한 Chung2, Soyang2 모델에서 가장 좋은 결과를 나타냈다.

4) 모든 기상대를 고려한 모델이 가장 정확도가 높았으며 일부 기상대만을 고려한 경우 유입량 증가를 반영하지 못하거나 실측치가 증가하지 않은 경우에 모의치에서 증가하는 경우가 발생하였으며 첨두유량 발생 일에 오차가 발생하였다.

5) 유역 평균 강우를 이용한 경우 충주댐은 첨두유량 발생 일에서 오차가 발생하였으며 소양강댐은 과다모의되는 경향을 보였다.

6) 이 결과는 유역 내, 외 기상대를 통해 많은 강우에 대하여 결정할 수 있고 지점강우량을 통한 학습을 통해 강우의 공간분포와 시간분포를 인공신경망의 가중치를 통해 결정할 수 있기 때문에 사료된다. 유역강우량을 산정하는 경우 면적에 따른 가중치를 고정하게 되고 강우지점 별 도달시간이 상이한 것을 고려하지 못하여 정확도가 감소하였다.

본 연구는 댐 유입량예측 분야에서 인공신경망 모델 적용에 있어 강우자료 사용방법별 결과를 비교 평가하고 있어 추후 인공신경망을 통한 유입량 예측 연구에 강우자료 사용방법에 참고 될 것으로 기대한다. 추후 유역강우량 산출방법을 추가하여 산출방법 별 정확도를 비교하고 기상, 증발산 등의 추가 입력자료를 고려하여 유입량 예측 정확도를 향상시킬 수 있을 것으로 사료된다.

감사의 글

이 논문은 2017년도 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2015R1A2A2A01008152).

REFERENCES

1. Anctil, F., and A. Rat, 2005. Evaluation of neural network streamflow forecasting on 47 watershed. *Journal of Hydrologic Engineering* 10(1): 85-88. doi:10.1061/(ASCE)1084-0699(2005)10:1(85).
2. Choi, S. Y., and K. Y. Han, 2011. Comparison and analysis for performance of flood stage prediction regression model according to type of input rainfall. *Journal of Korean Society of Hazard Mitigation* 11(5): 313-325 (in Korean).
3. Gupta, H., V. S. Sorooshian, and P. O. Yapo, 1999. Status of automatic calibration for hydrologic models: comparison with multilevel expert calibration. *Journal of Hydrologic Engineering* 4(2): 135-143. doi:10.1061/(ASCE)1084-0699(1999)4:2(135).
4. Hwang, J. S., S. Y. Choi, and H. S. Jeon, 2001. A classification analysis using bayesian neural network. *Journal of Korean Data & Information Science Society* 12(2): 11-25 (in Korean).
5. Jang, D. W., D. G. Kim, Y. S. Kim, and W. I. Choi, 2018. Application of SWAT model considering spatial distribution of rainfall. *Journal of Wetlands Research* 20(1): 94-103 (in Korean). doi:10.17663/JWR.2018.20.1.094.

6. Kang, M. S., M. G. Kang, S. W. Park, J. J. Lee, and K. H. Yoo, 2006. Application of grey model and artificial neural networks to flood forecasting. *Journal of the American Water Resources Association* 42(2): 473-486. doi:10.1111/j.1752-1688.2006.tb03851.x.
7. Kang, M. S., and S. W. Park, 2001. Forecasting long_term steamflow from a small watershed using artificial neural network. *Journal of the Korean Society of Agricultural Engineers* 43(2): 69-77 (in Korean).
8. Kang, M. S., and S. W. Park, 2003. Short-term flood forecasting using artificial neural networks. *Journal of The Korean Society of Agricultural Engineers* 45(2): 45-57 (in Korean).
9. Kim, H. L., K. S. Jun, and M. H. Choi, 2016. Estimation of river discharge using satellite-derived flow signals and artificial neural network model: application to injin river. *Journal of Korea Water Resources Association* 49(7): 589-597 (in Korean). doi:10.3741/JKWRA.2016.49.7.589.
10. Kim, M. E., J. M. Kim, S. J. Ye, J. B. Park, M. Y. Yun, and H. S. Shin, 2015. A study on water quality prediction model over midterm considering correlation between water quality and hydrologic factors. *Journal of Korean Society of Hazard Mitigation* 15(6): 459-470 (in Korean). doi: 10.9798/KOSHAM.2015.15.6.459.
11. Kim, S. E., and I. W. Seo, 2015. Artificial neural network ensemble modeling with exploratory factor analysis for streamflow forecasting. *Journal of Hydro informatics* 17(4): 614-639 doi:10.2166/hydro.2015.033.
12. Kim, S. E., and I. W. Seo, 2017. A study on improvement of generalization accuracy of artificial neural network modeling using factor analysis and cluster analysis: application to flow and water quality prediction. *Water for Future* 50(6): 31-40.
13. Kim, S. H., J. M. So, S. U. Kang, and D. H. Bae, 2017. Development and evaluation of dam inflow prediction method based on bayesian method. *Journal of Korea Water Resources Association* 50(7): 489-502 (in Korean). doi: 10.3741/JKWRA.2017.50.7.489.
14. Lee, G. S., S. C. Park, H. M. Lee, and Y. H. Jin, 2000. The prediction of runoff using artificial neural network in the Young-san River. *Journal of Korea Water Resources Association* 33(1): 251-256 (in Korean).
15. Lee, J. H., and S. H. Yoon, 2005. Runoff analysis using spatially distributed rainfall data. *Journal of Korea Society of Agricultural Engineers* 47(6): 3-14 (in Korean). doi:10.5389/KSAE.2005.47.6.003.
16. Lee, S. H., M. G. Kim, J. Y. Choi, and J. H. Bang, 2019. Estimating reference crop evapotranspiration using artificial neural network and temperature-based climatic data. *Journal of the Korean Society of Agricultural Engineers* 61(1): 95-105 (in Korean). doi:10.5389/KSAE.2019.61.1.095.
17. Mahsa, M., and T. S. Lee, 2018. Comparison of optimization algorithms in deep learning-based neural networks for hydrological forecasting: case study of nam river daily runoff. *Journal of Korean Society of Hazard Mitigation* 18(6): 377-384 (in Korean). doi:10.9798/KOSHAM.2018.18.6.377.
18. Minns, A. W., and M. J. Hall, 1996 Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal* 41(3): 399-417. doi:10.1080/02626669609491511.
19. Nash, J. E., and J. V. Sutcliffe, 1970. River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology* 10(3): 282-290. doi: 10.1016/0022-1694(70)90255-6.
20. Park, H. K., and E. K. Kim, 2013. Study on the modelling of algal dynamics in lake paldang using artificial neural networks. *Journal of Korean Society on Water Environment* 29(1): 19-28 (in Korean).
21. Park, J. C., N. Kim, and K. S. Ryoo, 2009. Improvement of inflow estimation data by precise measurement of water level in reservoir. *Journal of the Environmental Sciences* 18(3): 309-314 (in Korean).
22. Park, M. K., Y. S. Yoon, H. H. Lee, and J. H. Kim, 2018. Application of recurrent neural network for inflow prediction into multi-purpose dam basin. *Journal of Korea Water Resources Association* 51(12): 1217-1227 (in Korean). doi:10.3741/JKWRA.2018.51.12.1217.
23. Pushpalatha, R., C. Perrin, N. L. Moine, and V. Andréassian, 2012. A review of efficiency criteria suitable for evaluating low-flow simulations. *Journal of Hydrology* 420-421: 171-182. doi:10.1016/j.jhydrol.2011.11.055.
24. Ryu, Y. J., J. Y. Shin, W. S. Nam, and J. H. Heo, 2012. Forecast of the daily inflow with artificial neural network using wavelet transform at Chungju dam. *Journal of Korea Water Resources Association* 45(12): 1321-1330 (in Korean). doi:10.3741/JKWRA.2012.45.12.1321.
25. Yoon, Y. N., 2007. *Hydrology-basic and application*. Paju: cheongmoongak.