

## 웨이블릿 변환을 적용한 인공신경망에 의한 충주댐 일유입량 예측 Forecast of the Daily Inflow with Artificial Neural Network using Wavelet Transform at Chungju Dam

류 용 준\* / 신 주 영\*\* / 남 우 성\*\*\* / 허 준 행\*\*\*\*

Ryu, Yongjun / Shin, Ju-Young / Nam, Woosung / Heo, Jun-Haeng

### Abstract

In this study, the daily inflow at the basin of Chungju dam is predicted using wavelet-artificial neural network for nonlinear model. Time series generally consists of a linear combination of trend, periodicity and stochastic component. However, when framing time series model through these data, trend and periodicity component have to be removed. Wavelet transform which is denoising technique is applied to remove nonlinear dynamic noise such as trend and periodicity included in hydrometeorological data and simple noise that arises in the measurement process. The wavelet-artificial neural network (WANN) using data applied wavelet transform as input variable and the artificial neural network (ANN) using only raw data are compared. As a results, coefficient of determination and the slope through linear regression show that WANN is higher than ANN by 0.031 and 0.0115 respectively. And RMSE and RRMSE of WANN are smaller than those of ANN by 37.388 and 0.099 respectively. Therefore, WANN model applied in this study shows more accurate results than ANN and application of denoising technique through wavelet transforms is expected that more accurate predictions than the use of raw data with noise.

**Keywords** : wavelet transform, denoising, artificial neural network

### 요 지

본 연구에서는 비선형적 모델인 웨이블릿-인공신경망을 적용하여 충주댐 유역의 일유입량을 예측하였다. 일반적으로 시계열 자료는 경향성, 주기성 및 추계학적 성분의 선형조합으로 이루어져 있다. 그러나 이러한 자료를 통해 시계열 모형 구축 시 경향성 및 주기성은 제거되어야 하는 성분이다. 따라서 수문기상자료에 포함되어있는 경향성 및 주기성과 같은 비선형 동역학적 잡음과 측정과정에서 발생하는 단순잡음을 제거시키기 위해 디노이징기법인 웨이블릿 변환을 적용하였다. 웨이블릿 변환을 적용한 자료를 입력자료로 사용한 웨이블릿-인공신경망(WANN)과 원자료를 사용한 인공신경망(ANN)을 비교하였다. 산정결과 결정계수와 선형회귀를 통한 기울기는 WANN이 ANN보다 각각 0.032, 0.0115 더 큰 값을 나타냈고, 타겟값과 예측값 사이의 오차를 나타내는 RMSE와 RRMSE는 WANN 모형이 ANN 보다 각각 37.388, 0.099 더 작은 값을 나타냈다. 따라서 본 연구에서 적용한 WANN 모형이 ANN 보다 정확한 결과를 나타내었으며, 웨이블릿 변환을 통한 디노이징 기법의 적용이 잡음이 포함되어 있는 원자료의 사용보다 더 정확한 예측을 하는 것으로 판단된다.

\* 연세대학교 대학원 토목공학과 석사과정 (e-mail: ryj@yonsei.ac.kr)

Graduate Student, School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea

\*\* 연세대학교 대학원 토목공학과 (e-mail: hyjyshin@gmail.com)

School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea

\*\*\* 연세대학교 대학원 토목공학과 박사과정 (e-mail: nws77@yonsei.ac.kr)

Ph. D. Student, School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea

\*\*\*\* 교신저자, 연세대학교 사회환경시스템공학부 토목환경공학과 교수 (e-mail: jhheo@yonsei.ac.kr, Tel: 02-2123-2805)

*Corresponding Author*, Professor, School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea

## 1. 서론

시계열 분석을 통한 수문자료의 예측은 수문시스템의 장기계획에 있어서 매우 중요한 요소이다. 특히 하천유역 내의 인자를 이용하여 댐의 하천유량을 예측하는 일은 수문특성의 연구와 자연재해에 대한 대비 및 수공구조물과 방재시설의 설계 시 중요한 역할을 한다. 그러나 다양한 현상이 발생하는 자연현상에서 정확한 예측을 하기란 쉬운 일이 아니다. 따라서 예측에 대한 정확도를 높이고 불확실성을 줄이는 연구가 활발히 이루어지고 있다. 기존의 자기회귀모델, 이동평균모델 등의 추계학적 모델을 통해 많은 연구가 이루어졌으나 기후변화와 복잡해진 자연현상을 예측하기 위해서 보다 더 정확한 예측 모델이 요구되어졌다. 따라서 toy 모델, 인공신경망 모델 등 다양한 예측기법을 수문학에 접목시켜 보다 더 정확하게 예측하고자 연구가 활발히 이루어지고 있다. 특히 이 중 인공신경망은 수문자료의 예측 모델로 많은 연구가 수행되어왔고 높은 예측 결과로 연구에 활발히 이용되고 있다. 인공신경망은 유출에 대해 적합한 유연성(flexibility)을 가지고 있는 모델이다(Hsu et al., 1995). 이러한 예측 모형에서도 예측을 위한 입력 자료에 다양한 성분이 포함되어 있는 경우 모형이 정확하다고 해도 결과에 큰 오차를 포함하게 된다. 특히 자료의 변동이 큰 비정상성을 포함하거나 장기간 큰 변화가 있는 자료의 경우에 대해서는 자료 속에 예측에 오차를 주는 다양한 성분들이 성분이 포함되어진다. 일반적으로 이러한 시계열 자료의 경우 크게 경향성(trend), 주기성(periodicity) 및 추계학적 성분(stochastic component)의 선형 조합으로 이루어진다. 그러나 이러한 자료를 통해 시계열 모형 구축 시 경향성, 주기성은 제거되어야 하는 성분이다(Cho and Kim, 1998). 또한 측정과정에서 축적되는 오차에 의한 단순잡음과 자연현상들 사이에 발생하는 상호간섭에 의한 비선형 동역학적 잡음(nonlinear dynamical noise) 역시 배제되어야 하는 성분이다. 이러한 성분을 포함한 시계열 자료를 통해 예측 하는 경우 결과의 신뢰도에 큰 영향을 준다. Cannas et al. (2006)에 의하면 이러한 변동성이 큰 자료를 인공신경망에 적용할 시에는 필히 전처리과정을 거쳐야한다. 이러한 성분을 제거하기 위한 전처리 과정으로 디노이징 기법이 있다. 대표적인 디노이징 기법으로는 이산 코사인 변환(discrete cosine transform), 푸리에 변환(Fourier transform), 단시간 푸리에 변환(short time Fourier transform), 웨이블릿 변환(wavelet transform) 등이 있다(Lee and Kim, 1999). 이 중 웨이블릿 변환은 푸리에 변환과 단시간 푸리에 변환의 발전된 형태로 기존의 단점을 보완하고 있다. 특히 시간의 정보를 유동적으로 적용할 수 있다는 점에서 시간을 포함한 자료인 시계열 자료에 대하여 분석시 큰 장점을 가지고 있다. 따라서 시계열 분석 및 다양한 분야에 많이 사용되고 있다(Kozłowski, 2005; Gao et al., 2010; Daniel et al., 2010). 본 연구에서는 시간의 정보에 대해 가장 잘 표현하는 기법인 웨이블릿 변환을 전처리 과정으로 선택하여 인공신경망에 적용하였다.

본 연구의 목적은 여러 유역인자들 중 하천유량에 가장 영향을 미치는 변수를 추출하고 보다 정확한 예측모델을 구축하는 것이다. 자료의 전처리 과정인 디노이징 기법을 통한 자료의 성분분리에 관한 연구이며, 특히 인공신경망 적용 시 예측력을 높이고자한다.

## 2. 기본이론

### 2.1 디노이징 기법(Denoising Technique)

#### 2.1.1 웨이블릿 변환

자료의 성분 분석과 디노이징 기법으로 널리 사용되는 방법으로 푸리에 변환이 있다. 푸리에 변환은 신호의 자료를 주파수 성분으로 분해하여 각 주파수 성분에 대한 상대적 크기를 가지고 신호의 특징을 파악하는 방법이다. 신호를 사인 함수(sine function)와 코사인 함수(cosine function)의 무한급수들의 합으로 표현될 수 있다는 것이 푸리에 이론(Fourier theory)이다. 그러나 실제 자료는 주기함수를 포함하지 않는 경우가 많다. 이러한 자료를 해석 및 디노이징하기 위해서 사인 함수와 코사인 함수의 주기를 이용하여 표현하는데 이러한 과정을 푸리에 변환이라 한다. 푸리에 변환을 통해 시간영역의 함수는 주파수 영역에서 처리하게 되는데 이것을 주파수 영역해석이라 한다. 이러한 푸리에 변환은 Eq. (1)로 정의된다.

$$F(jw) = F.T[f(t)] = \int_{-\infty}^{\infty} f(t)e^{-jw t} dt \quad (1)$$

여기서,  $f(t)$ 는 원자료,  $F(jw)$ 는  $jw$  성분의 크기이다. 푸리에 변환을 한 자료를 다시 원 자료로 변환시키는데 이

것을 푸리에 역변환(Fourier inverse transform)이라고 하고 그 식은 Eq. (2)와 같다.

$$f(t) = F.T^{-1}[F(jw)] = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(jw)e^{jw t} dw \quad (2)$$

하지만 푸리에 변환은 함수의 시간영역을 주파수 영역으로 변환하기 때문에 시간영역에 대한 정보가 사라지게 되어 특정 사상의 위치를 시간영역에 대해 파악할 수 없으며, 비정상 시계열에 대해 한계를 갖는다(Smith et al., 1998). 따라서 푸리에 변환을 통한 디노이징은 한계를 갖게 된다. 이러한 단점을 극복하기 위해 나온 방법이 단시간 푸리에 변환(short time Fourier transform: STFT)이다. 단시간 시간 영역에 창함수(window function)를 사용하여 변환범위를 시간 축에 따라 이동한다. 창함수의 크기는 시간-주파수 영역의 분해능을 결정하며 그 식은 Eq. (3)과 같다.

$$F(w,t) = \int_{-\infty}^{\infty} f(t)w(t-x)e^{-jw t} dt \quad (3)$$

여기서,  $w(t-x)$ 가 창함수로 신호  $f(t)$ 의 국소화된 시간  $x$ 에 대한 정보를 의미한다. 단시간 푸리에 변환을 한 자료를 원 자료로 변환하는 과정인 단시간 푸리에 역변환(short time fourier inverse transform)에 대한 식은 Eq. (4)와 같다.

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(w,t)w(t-x)e^{jw t} dw dx \quad (4)$$

일반적으로 창함수의 크기에 따라 정해진 분해능이 결정되고 Fig. 1(a)에서 보이듯이 창함수의 크기는 동일하다(Graps, 1995). 이는 각각의 창함수 영역 사이에 신호의 불연속을 일으키는 원인이 되며, 전체 신호의 에너지를 특정 주파수에 집중시키지 못하는 단점이 있다. 이러한 문제 때문에 시계열 자료 적용 시 고정된 주파수 외의 자료에 대

해서는 해석이 곤란하다(Torrence and Compo, 1998). 이러한 단점을 해결하기 위하여 나온 이론이 연속 웨이블릿 변환이다(Daubechies, 1990). 웨이블릿 변환은 Fig. 1(b)에서 보이듯이 고주파수 영역에서는 시간축의 창폭을 조밀하게 하여 시간영역의 분해능을 증가시키고, 저주파수 영역에서는 시간축의 창폭을 증가시켜 주파수의 분해능을 증가시킨다. 따라서 웨이블릿 변환이 단시간 푸리에 변환보다 자료를 처리함에 있어서 유연한 해석이 가능하다.

연속 웨이블릿 변환(Wf)은 웨이블릿 함수( $\psi$ )에 의해 Eq. (5)와 같이 정의된다.

$$Wf(a,b) = \int_{-\infty}^{\infty} f(t)\psi^{a,b}(t) dt \quad (5)$$

$$\psi^{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad a > 0$$

여기서,  $a$ 는 영역의 크기이고  $b$ 는 시간을 의미한다. 그러나 시계열 자료를 신호로 처리하는 경우는 주파수의 변화보다 시간에 따라 변화하는 특성을 효율적으로 표현하는 것이 중요하다. 따라서 연속함수인 Eq. (5)에 대한 이산화가 필수적이다. 이산화를 위해  $a$ 는 정수  $k$ 에 대한 2의 멱급수로,  $b$ 는 정수  $j$ 로 교체하면 Eq. (6)과 같다.

$$Wf(2^k,j) = \int_{-\infty}^{\infty} f(t)\psi_{k,j}(t) dt = \langle f, \psi_{k,j} \rangle \quad (6)$$

여기서,  $\psi_{k,j}$ 는 Eq. (7)과 같다.

$$\psi_{k,j}(t) = 2^{k/2} \psi(2^k t - j) \quad (7)$$

이러한 이산화과정을 만족시키기 위해서는 계산이 효율적이고, 역변환 과정에서 안정적이어야 한다. 이러한 과정을 만족하는  $\psi_{k,j}$ 는 직교 기저(orthonormal basis)가 있다.

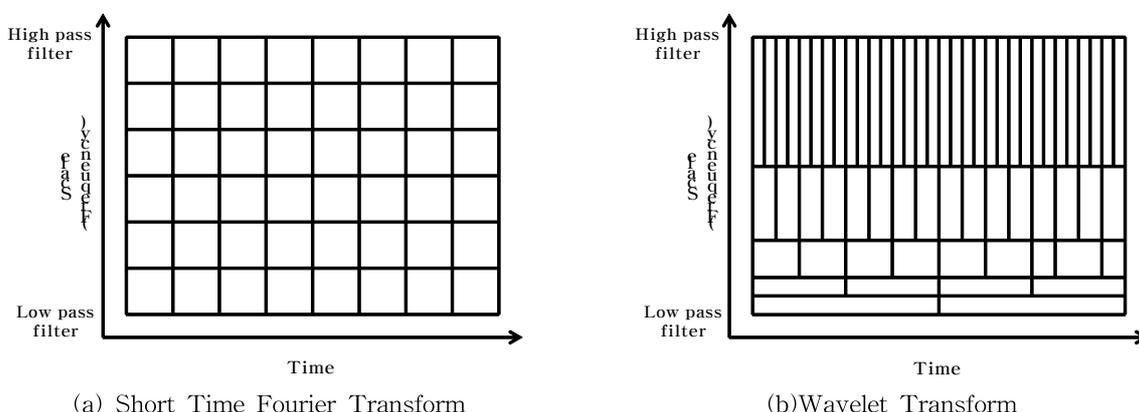


Fig. 1. Concept of Short Time Fourier Transform and Wavelet Transform

따라서 연속신호  $f$ 에 대해서 Eq. (8)이 성립한다.

$$f = \sum_{k=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} \langle f, \psi_{k,j} \rangle \psi_{k,j} \quad (8)$$

여기서, 정보의 범위는 지지영역의 크기( $L$ ) 대하여  $[j2^{-k} - L2^{-k}, j2^{-k} + L2^{-k}]$ 로 국한된다. 이러한 범위는  $k$ 값이 큰 경우에 대하여 고주파 정보를,  $k$ 값이 작은 경우에 대하여 저주파 정보를 포함하고 있다. 이산화를 위한 직교 기저를 찾기 위한 많은 연구가 이루어졌는데 그 결과 Daubechies의 웨이블릿 함수가 제시되었다(Daubechies, 1988). 이는 하나의 식으로 이루어진 것이 아닌 스케일링 함수(scaling function)와 웨이블릿 함수의 조합으로 이루어졌으며 스케일링 함수는 Eq. (9), 웨이블릿 함수는 Eq. (10)과 같다. Eqs. (9) and (10)은 세밀화식(refinement equation) 또는 2-스케일 관계식(2-scale relation equation)이라고도 한다.

$$\phi(x) = \sqrt{2} \sum_n h_n \psi(2x - n) \quad (9)$$

$$\psi(x) = \sqrt{2} \sum_n g_n \phi(2x - n) \quad (10)$$

여기서,  $h_n$ 은 유한수열로 Eq. (11)의 조건을 만족하며  $g_n$ 은 Eq. (12)와 같이  $h_n$ 의 함수이다.

$$\sum_n h_n h_{n+2k} = \begin{cases} 1 & k=0 \\ 0 & k \neq 0 \end{cases} \quad (11)$$

$$\sum_n h_n = \sqrt{2}$$

$$g_n = (-1)^n h_{1-n} \quad (12)$$

위의 과정을 통해 Eqs. (13) and (14)와 같이 연속 웨이블릿과 이산 웨이블릿의 관계를 얻을 수 있다.

$$\langle f, \phi_{k,j} \rangle \cong \sum_n h_{n-2j} \langle f, \phi_{k+1,j} \rangle \quad (13)$$

$$\langle f, \psi_{k,j} \rangle \cong \sum_n h_{n-2j} \langle f, \psi_{k+1,j} \rangle \quad (14)$$

이러한 웨이블릿 변환을 적용하기 위해 신호의 개수 ( $N$ )는  $2^m$ 이라고 가정하고 주어진 이산신호에 대하여 Eq. (15)를 만족한다고 가정한다.

$$\langle f, \phi_{m,l} \rangle \cong f_l \quad l=0,1,\dots,2^m-1 \quad (15)$$

Eqs. (13) and (14)에서  $k$ 를  $m$ 부터  $k_0 (\geq 0)$ 까지 낮춰가며 적용을 하면  $\langle f, \psi_{k,j} \rangle$ 와  $\langle f, \phi_{k_0,l} \rangle$ 을 구할 수 있다. 이 과정을 다음 Eqs. (16) and (17)로 나타낸다.

$$C^k(j) = \langle f, \phi_{k,j} \rangle \quad (16)$$

$$D^k(j) = \langle f, \psi_{k,j} \rangle \quad (17)$$

이러한 웨이블릿 변환 과정을 분해(decomposition)과정이라고도 한다. 그리고 변환된 자료를 다시 합성하는 과정을 웨이블릿 역변환(inverse wavelet transform) 또는 복원(reconstruction)과정이라고 하며 Eq. (18)로 표현된다. 여기서 분해과정에 대한 그림은 Fig. 2, 복원과정은 Fig. 3과 같다.

$$C_j^k = \sum_n h_{j-2n} C_n^{k+1} + g_{j-2n} D_n^{k+1} \quad (18)$$

### 2.1.2 웨이블릿 축소기법(Wavelet shrinkage)

웨이블릿 축소기법을 통한 디노이징은 Donoho and Johnstone (1994)에 의해 제안되었고, 이 방법은 신호로부터 잡음을 제거하거나 통계학에서 무변수 추정 등에 널리 이용된다. 웨이블릿 축소 기법은 크게 3단계로 구성되어있다. 첫 번째는 분해단계로 레벨  $j$ 를 선택하고,  $j$ 레벨까지 웨이블릿 분해를 하는 것이다. 다음은 문턱계수결정(threshold detail coefficients)단계로 1부터  $j$ 레벨까지 문턱계수를 결정하여 각각의 계수에 적용하는 과정이다. 마지막은 복원과정으로 수정된 계수료를 적용하여 디노이징된 자료를 얻는 것이다(Baek et al., 1998). 이러한 웨이블릿 축소를 이용한 알고리즘은 Fig. 4와 같다.

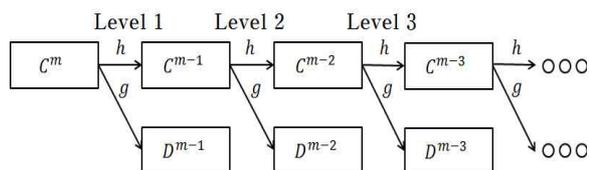


Fig. 2. Process of Wavelet Decomposition

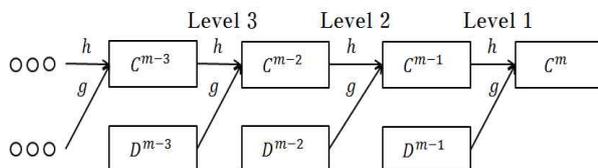


Fig. 3. Process of Wavelet Reconstruction

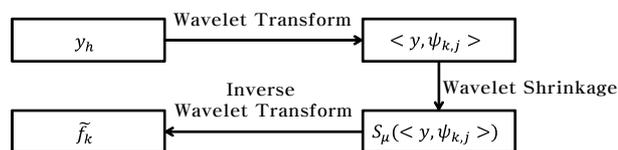


Fig. 4. Algorithm using Wavelet Shrinkage

## 2.2 인공신경망(Artificial neural network)

### 2.2.1 인공신경망의 구조

인공신경망은 인간의 뇌에서 이루어진 생물학적인 학습과 지식전달절차를 컴퓨터 공학적으로 응용한 분야이다. 구조는 입력층과 출력층, 그리고 이 사이에 하나 또는 그 이상의 은닉층으로 구성되어있고 각각의 구성층은 가중치인 연결강도에 의해 결정된다. 이 연결강도는 feedback으로 보정이 가능하다(Bishop, 1995). 인공신경망의 기본적인 구조는 Fig. 5와 같다.

### 2.2.2 인공신경망의 학습

학습(learning)은 입력층에 입력된 자료와 출력층을 거쳐 나온 학습자료에 대하여 일정한 학습규칙을 통해 연결가중치가 보정하는 과정이다. 이러한 과정에서 반복적인 학습과정을 거쳐 신경망 내 입력자료와 출력자료의 진행을 최적화하는 가중치를 결정한다(Bishop, 1995). 즉, 오차가 최소가 되는 경우의 연결강도를 선택하게 된다. 오차함수는 평균제곱오차(mean square error: MSE)를 구해서 결정하게 되는데 예측값( $Y_i$ )과 타겟값( $D_i$ )에 대하여 그 식은 Eq. (19)와 같다.

$$\text{평균제곱오차}(MSE) = \frac{1}{N} \sum (Y_i - D_i)^2 \quad (19)$$

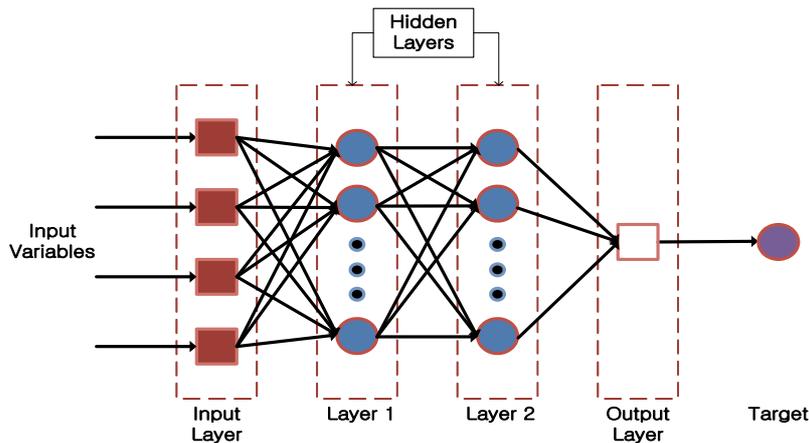


Fig. 5. Structure of Artificial Neural Network

Table 1. Basic Statistics of Data at Chungju Dam

Data	Location		Average value	Maximum value	Minimum value
	Longitude	Latitude			
Streamflow	127°59'33"E	37°0'22"N	177.0 $m^3/s$	15150.6 $m^3/s$	0.3 $m^3/s$
Precipitation	127°59'33"E	37°0'22"N	3.4 $mm/day$	220.6 $mm/day$	0.0 $mm/day$

가중치의 초기 값은 임의로 결정되며 학습과정을 통해 일정한 학습규칙을 가지고 가중치가 변화하게 된다. 본 연구에서는 경사하강법(gradient descent method)에 의해 가중치 증가량을 결정하고 이를 통해 가중치를 결정하게 된다. 가중치 변환 함수( $w_{ij}$ )는 Eq. (20)과 같다.

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t+1) + \mu \Delta w_{ij}(t) \quad (20)$$

여기서,  $\mu$ 는 모멘텀이고  $\Delta w_{ij}$ 는 가중치 증가량이다.

## 3. 분석방법

### 3.1 대상 자료

본 연구에서는 다양한 댐 정보 가운데 댐유입량에 가장 큰 영향을 미치는 강수량을 이용하여 댐 유입량을 예측하였다. 한강유역에 있는 충주댐의 강수량과 유입량을 입력자료로 선정하였다. 충주댐의 강수량, 유입량은 모두 1990년 1월 1일부터 2007년 12월 31일까지 각각 일자료를 사용하였다. 총 자료의 수는 6574개로 구성되어있으며 자료에 대한 기본 통계량은 Table 1과 같다. 그리고 강수량, 유입량에 대한 자료를 각각 Figs. 6 and 7에 나타내었다.

### 3.2 웨이블릿 인공신경망 구성

본 연구에서는 웨이블릿을 통해 디노이징한 자료를 입력자료로 적용한 인공신경망(WANN)과 원자료를 입력자

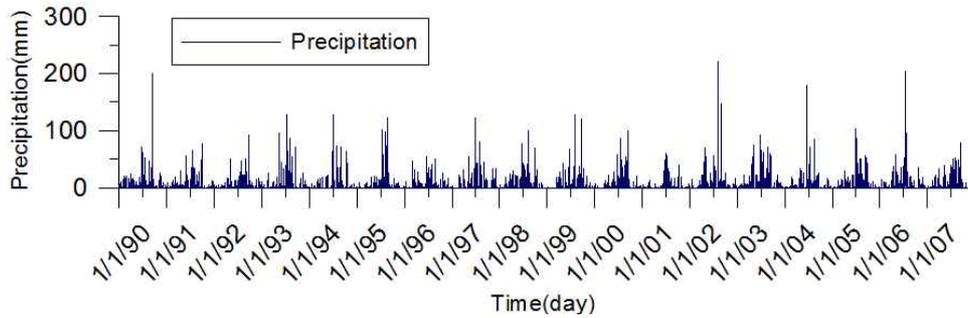


Fig. 6. Time Series of Precipitation at Chungju Dam

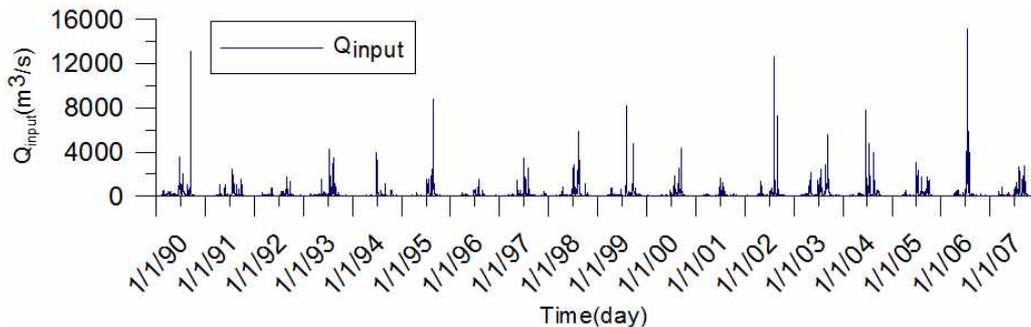


Fig. 7. Time Series of Streamflow at Chungju Dam

료로 선택한 인공신경망(ANN)을 구성하여 비교 및 검토 하였다. 입력자료는 상관계수를 통해 결정하였으며, 상관 계수의 결과에 따라 시차(time lag)의 길이를 결정하여 입력변수로 활용하였다. 두 모델 모두 자료 변환의 유무의 차이만 있으며, 인공신경망모델의 구성은 동일하다.

인공신경망 구조는 입력층, 은닉층 및 출력층으로 이루어져 있다. 인공신경망은 전방향 다층퍼셉트론구조로 하였고, 역전파(backpropagation) 알고리즘을 선택하였다. 입력층에는 1개의 층과 6개의 입력변수가 들어가도록 동일한 수의 노드(node)를 주었고, 시행착오법(trial and error method)을 사용 은닉층은 1개의 층을 결정하고 다양한 노드에 대해 실험을 해보았다. 실험결과 10개의 노드일 때 최적의 값을 산정하고 선택하였다. 은닉층과 출력층의 노드의 전이함수(transfer function)가 결정하게 되는데 은닉층의 경우, 유연성을 높여주기 위하여  $-1 \leq a \leq 1$ 의 범위를 가지는 쌍곡선 탄젠트 시그모이드(hyperbolic tangent sigmoid) 함수를 사용하였고 출력층에서는 출력값이 음(-)의 값을 가지지 않기 위해 로그 시그모이드(log sigmoid) 전이함수를 적용하였다.

전체자료의 자료 중 1990년 1월 1일부터 2000년 12월 31일까지의 자료는 가중치를 구하기 위한 learning set으로, 2001년 1월 1일부터 2002년 12월 31일까지의 자료는 계산된 가중치를 검증하기 위한 validation set으로, 2003

년 1월 1일부터 2007년 12월 31일까지의 자료는 결과를 출력하기 위한 testing set으로 구성하였다.

## 4. 적용 및 결과

### 4.1 웨이블릿 변환

웨이블릿 변환의 적용시 적절한 웨이블릿 함수의 선택은 매우 중요하다(Farge, 1992). 시계열 자료의 적용시 웨이블릿 함수의 선택에 관한 정량적인 기준이 아직까지는 명확히 제시되어있지 않다. 일반적으로 급격한 변화나 계단형 자료에는 Daubechies 1번 웨이블릿 함수(db1)인 Haar 함수를 사용하고, 부드러운 변화를 나타내는 자료에는 감쇠하는 코사인 함수를 적용한다(Torrence and Compo, 1998). Jin et al.(2005)에서는 강우량, 유입량의 상대적 완만함을 고려하여 Daubechies 9번 웨이블릿 함수(db)를 선택하였다. 따라서 본 연구에서도 Daubechies 9번 웨이블릿 함수를 선택하기로 하였다.

또한 Jin et al.(2005)에 의하면 분해단계는 일반적인 경우 5내지 7이면 충분하다고 알려져 있다. 따라서 본 연구에서는 분해단계를 5로 결정하였다. 문턱값은 비교적 큰 값을 갖는 계수를 줄이는 방법인 약문턱값 함수(soft threshold function)를 채택하였으며 일반적으로 널리 사용하는 universal방법을 결정하였다. Donoho and

Johnstone (1994)에 의해 제시된 약문턱값 함수는 Eq. (21), 문턱값은 Eq. (22)로 나타내었다.

$$S_\lambda = \begin{cases} x - \lambda & x > \lambda \\ 0 & |x| < \lambda \\ x + \lambda & x < -\lambda \end{cases} \quad (21)$$

$$\lambda = \sigma \sqrt{2 \log N} \quad (22)$$

여기서,  $\sigma$ 에 대한 값은 scale 함수로 식 Eq. (23)과 같이 나타낸다.

$$\sigma^2 = \frac{1}{0.6745} \text{median}(| < R_{1, \psi_{1,k}} > |) \quad (23)$$

또한 Kim et al. (2003)에 따라 웨이블릿 변환 과정 속에 미래 자료가 포함되는 것을 막기 위해 입력자료와 타겟자료를 나누어 웨이블릿 분해과정만을 이룬 뒤 인공신경망에 학습을 시켰으며, 학습을 통해 예측한 자료를 복원과정을 통해 다시 하나의 자료로 역변환을 이루었다. 여기서 분해과정을 거친 자료의 결과를 Figs. 8 and 9에 나타내었다. 여기서  $s$ 는 원자료,  $d_i$ 는 각각 분해단계에 따른 분해계수,  $a_5$ 는 5단계까지 분해되어 나온 분해 값이다.

#### 4.2 입력자료 선정

입력자료는 절대상관계수를 고려하여 선정하였다. 절대상관계수( $|R|$ )는  $0 \leq |R| \leq 1$ 의 범위를 갖는데 상관성의 기준으로는 Ha and Lee(2010)에 의하면 0~0.2에서는

상관관계가 거의 없고, 0.3~0.6에서는 상관관계가 존재, 0.7 이상인 경우에는 매우 강한 상관관계로 해석한다. 따라서 본 연구에서는 절대상관계수가 0.3 이상인 경우에 대하여 입력변수로 선택하였으며 절대상관계식은 Eq. (24)과 같다.

$$\text{절대상관계수}(|R|) = \left| \frac{\sum_{i=1}^n (Y_i - \bar{Y})(D_i - \bar{D})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (D_i - \bar{D})^2}} \right| \quad (24)$$

여기서, 총 자료의 수  $n$ 에 대한 두 자료를 각각  $Y_i$ 와  $D_i$ 로 하고  $\bar{Y}$ 는  $Y_i$ 에 대한 평균,  $\bar{D}$ 는  $D_i$ 에 대한 평균이다. 웨이블릿을 변환한 자료를 이용하여 계산한 절대상관계수와 원자료를 사용하여 계산한 절대상관계수 산정하였다. 현재유입량과 시차를 적용한 유입량의 자료와 절대상관계수를 구한 결과는 Table 2, 현재 유입량과 시차를 적용한 강수량의 자료와의 절대상관계수를 구한 결과는 Table 3에 나타내었다.

절대상관계수 산정결과에서 보면 유입량은  $Q_{t-1}$ 에서  $Q_{t-3}$ 까지의 결과가 0.3 이상의 값을 갖고 있었고, 그 이상의 시차 자료에 대해서는 0.3 이하의 결과를 갖고 있었다. 강수량의 경우도 시차가 3인 경우, 즉  $P_{t-1}$ 에서  $P_{t-3}$ 까지의 결과가 0.3 이상의 결과를, 그 이상의 시차 자료에 대해서는 0.3 이하의 값을 갖고 있었다. 따라서 입력자료는 상관계수가 0.3 이상인 결과, 즉, 유입량에 대해서  $Q_{t-1}$ ,  $Q_{t-2}$ ,

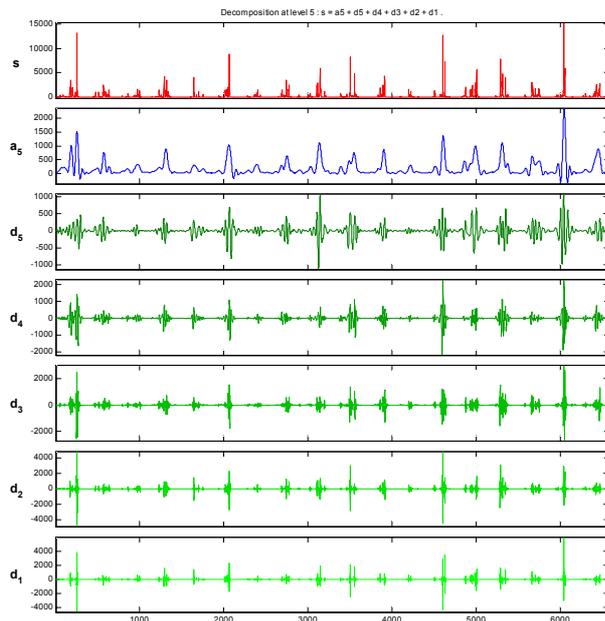


Fig. 8. Time Series of Inflow using Wavelet Decomposition

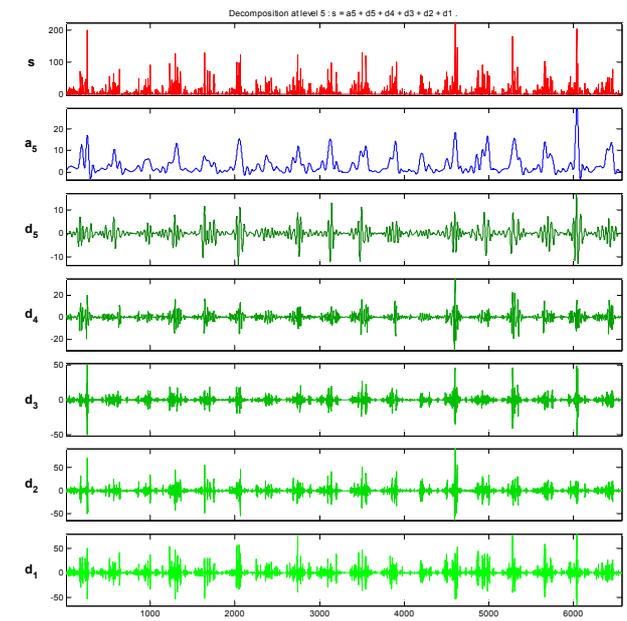


Fig. 9. Time Series of Precipitation using Wavelet Decomposition

$Q_{t-3}$ , 강우량에 대해서  $P_{t-1}$ ,  $P_{t-2}$ ,  $P_{t-3}$ 의 자료를 선택하였다. ANN의 경우 원자료 그대로 입력하였으며, WANN의 경우 선택된 자료를 웨이블릿 분해과정을 거친 뒤 입력자료로 사용하였다. 각각 구성한 ANN과 WANN의 구조는 Figs. 10 and 11과 같다.

### 4.3 인공신경망 적용 결과

원자료를 사용한 ANN과 웨이블릿 디노이징 기법을 적용한 WANN을 비교하기 위하여 결정계수( $R^2$ )와 평균제곱근오차(root mean square error, RMSE), 평균제곱근상대오차(relative root mean square error, RRMSE)를 구하였다. 결정계수는 Eq. (25), 평균제곱근오차는 Eq. (26), 평균제곱근 상대오차는 Eq. (27)로 나타내며 각각 산정 결과는 Table 4와 같다.

$$\text{결정계수}(R^2) = \left( \frac{\sum_{i=1}^n (Y_i - \bar{Y})(D_i - \bar{D})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (D_i - \bar{D})^2}} \right)^2 \quad (25)$$

$$\text{평균제곱근오차}(RMSE) = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - D_i)^2} \quad (26)$$

$$\text{평균제곱근상대오차}(RRMSE) = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{Y_i - D_i}{D_i} \right)^2} \quad (27)$$

산정결과를 살펴보면 결정계수는 WANN이 ANN보다 0.032 높게 나타났고, RMSE와 RRMSE는 WANN이 ANN보다 각각 37.388, 0.099 작은 값을 나타냈다. 또한 타겟값과 예측값의 상관성을 파악하기 위해 산포도(scatter plot)를 표시하였고 선형회귀분석을 통해 기울기를 계산하였다. 그 결과는 Figs. 12 and 13과 같다.

선형회귀분석을 통한 기울기를 보면 WANN이 0.8381, ANN이 0.8163으로 WANN이 ANN보다 0.0115 높은 기울기를 보였다.

따라서 상관성을 나타내는 결과인 결정계수와 선형회귀를 통한 기울기를 검토해보면 WANN이 ANN보다 높은 상관성을 나타내었고, 두 값의 오차를 나타내는 RMSE와 RRMSE의 결과를 보면 WANN이 더 낮은 오차 값을 산정하였다.

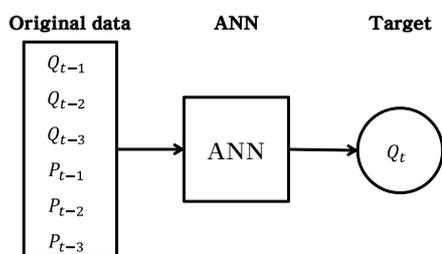


Fig. 10. Structure of ANN

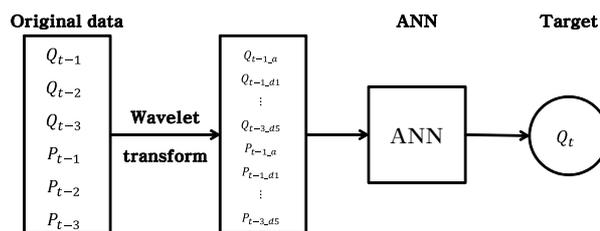


Fig. 11. Structure of WANN

Table 2. Coefficient of Absolute Correlation between Inflow and Inflow using Time Lag

Data	$Q_{t-1}$	$Q_{t-2}$	$Q_{t-3}$	$Q_{t-4}$
Denoising data	0.6783	0.4180	0.3368	0.2746
Original data	0.6780	0.4176	0.3364	0.2742

Table 3. Coefficient of Absolute Correlation between Inflow and Precipitation using Time Lag

Data	$P_{t-1}$	$P_{t-2}$	$P_{t-3}$	$P_{t-4}$
Denoising data	0.7708	0.4878	0.3395	0.2678
Original data	0.7376	0.4655	0.3117	0.2452

Table 4.  $R^2$ , RMSE, and RRMSE of ANN and WANN

Structure	$R^2$	RMSE	RRMSE
ANN	0.873	276.722	28.196
WANN	0.905	239.334	28.097

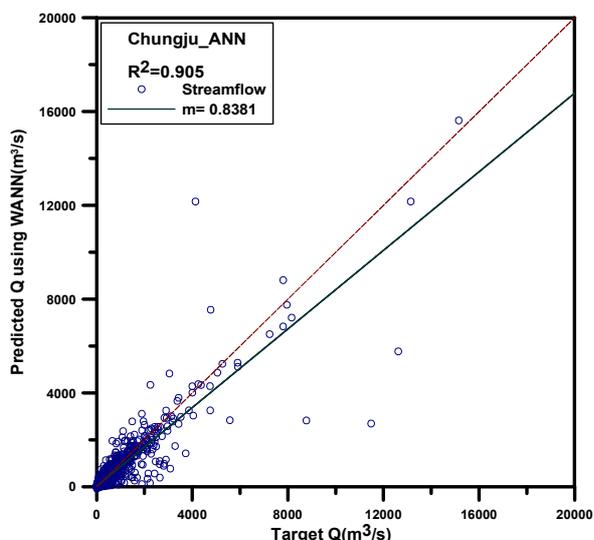


Fig. 12. Comparison Target Inflow and Predicted Inflow using WANN

## 5. 결 론

본 연구는 웨이블릿-인공신경망을 이용하여 충주댐의 일유입량을 예측한 연구이다. 입력자료의 전처리 과정으로 웨이블릿 변환을 사용하여 인공신경망에 적용하였다. 웨이블릿 변환은 Daubechies의 9번 웨이블릿 기저함수를 사용하였으며, 5단계까지 자료분해를 하였다. 웨이블릿 변환을 적용한 자료를 입력자료로 사용한 웨이블릿-인공신경망(WANN)과 원자료를 사용한 인공신경망(ANN)을 비교하여 다음과 같은 결론들을 도출하였다.

- 1) 절대상관계수를 적용하여 시차에 따른 상관성을 분석해본 결과 충주댐의 일자료 선정 시 시차가 3일까지 영향을 미친다고 판단된다. 따라서 오늘의 자료를 예측할 경우 과거의 3일까지 영향력이 크고, 그 이상의 자료는 작은 영향을 미친다는 것을 알 수 있었다. 따라서 시차 3일의 자료인 유입량  $Q_{t-1}$ ,  $Q_{t-2}$ ,  $Q_{t-3}$  과, 강우량  $P_{t-1}$ ,  $P_{t-2}$ ,  $P_{t-3}$ 의 자료를 선택하였다.
- 2) 웨이블릿 변환 자료와 원자료를 시차를 주고 절대상관계수를 구한 결과를 보면 모두 웨이블릿 변환 자료가 원자료보다 상관계수가 높게 나타났다. 따라서 입력자료에서도 웨이블릿 변환을 한 결과가 더 높은 상관성이 있음을 알 수 있다.
- 3) 입력층이 6개인 WANN과 ANN을 구성하고 예측모델을 돌려본 결과, 타겟값과 예측값 사이의 상관성을 나타내는 결정계수와 선형회귀를 통한 기울기는 WANN이 ANN보다 각각 0.032, 0.0115 더 큰 값을

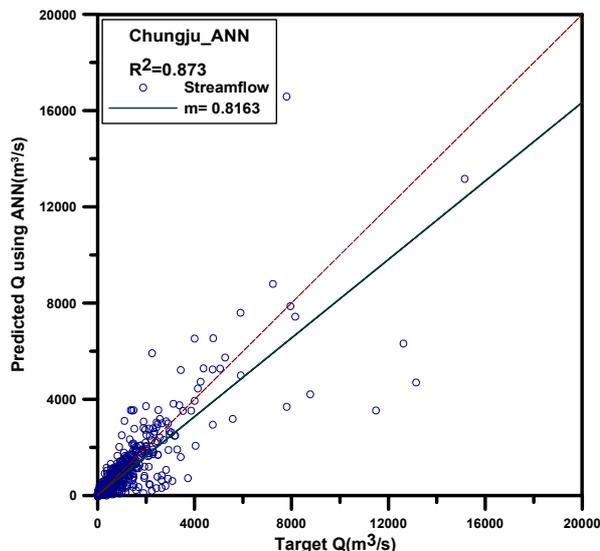


Fig. 13. Comparison Target Inflow and Predicted Inflow using ANN

나타냈고, 타겟값과 예측값 사이의 오차를 나타내는 RMSE와 RRMSE는 WANN이 ANN보다 각각 37.388, 0.099 더 작은 값을 나타냈다. 이 결과를 통해 분석해보면 타겟값과 예측값 사이에 WANN이 ANN보다 더 높은 상관성을 갖고 있고, 더 작은 오차를 포함하고 있음을 의미한다. 따라서 WANN을 통해 예측한 값이 ANN보다 더 좋은 결과를 나타냈다.

따라서 본 연구에서 적용한 WANN 모형이 ANN 모형보다 정확한 결과를 산정하였으며 웨이블릿 변환을 통한 디노이징 기법의 적용이 잡음이 포함되어 있는 원자료의 사용보다 더 정확한 예측을 한다고 판단된다. 또한 이러한 웨이블릿 변환을 통해 수문자료를 변환시킴으로써 다양한 연구에 사용될 수 있을 것으로 예상된다.

## 감사의 글

본 연구는 한국건설교통기술평가원 건설기술혁신사업의 [기후변화에 의한 수문 영향분석과 전망(09-기술혁신 C01)]과제의 지원으로 수행되었으며 이에 감사드립니다.

## REFERENCES

- Baek, U.J., Kang, S.J., and Chung, C.B. (1998). "Comparison of Various Denoising Algorithms Using Wavelet Transformation." *Theories and Applications of Chemical Engineering*, Vol. 4, No. 2, pp. 2313-2316.

- Bishop, C.M. (1995). "Neural networks for pattern recognition." Oxford. pp. 140-148.
- Cannas, B., Fanni, A., See, L., and Sias, G. (2006). "Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning." *Physics and Chemistry of the Earth*, Vol. 31, No. 18, pp. 1164-1171.
- Cho, Y.J., and Kim, J.M. (1998). "Water Supply forecast Using Multiple ARMA Model Based on the Analysis of Water Consumption Mode with Wavelet Transform." *Journal of Korea Water Resources Association*, Vol. 31, No. 3, pp. 317-326.
- Daniel, B.G., Francisco, J.D.P., David, G.O., José, F.D.H., Míriam, A.-R., Mario, M.Z., and Isabel, T.D. (2010). "Wavelet-Based denoising for traffic volume time series forecasting with self-organizing neural networks." *Computer-Aided Civil and Infrastructure Engineering*, Vol. 25, No. 7, pp. 530-545.
- Daubechies, I. (1988). "Orthonormal bases of compactly supported wavelets." *Communications on Pure and Applied Mathematics*, Vol. 41, No. 7, pp. 909-996.
- Daubechies, I. (1990). "The wavelet transform, time-frequency localization and signal analysis." *IEEE Transactions on Information Theory*, Vol. 36, No. 5, pp. 961-1005.
- Donoho, D.L., and Johnstone, I.M. (1994). "Ideal spatial adaptation by wavelet shrinkage." *Biometrika*, Vol. 81, No. 3, pp. 425-455.
- Donoho, D.L., and Johnstone, I.M. (1995). "Adapting to unknown smoothness via wavelet shrinkage." *Journal of the American Statistical Association*, Vol. 90, No. 432, pp. 1200-1224.
- Farge, M. (1992). "Wavelet transforms and their applications to turbulence." *Annual Review of Fluid Mechanics*, Vol. 24, pp. 395-457.
- Gao, J., Sultan, H., Hu, J., and Tung, W.W. (2010). "Denoising nonlinear time series by adaptive filtering and wavelet shrinkage: A comparison." *IEEE Signal Process Letter*, Vol. 17, No. 3, pp. 237-240.
- Graps, A. (1995). "An introduction to wavelets." *IEEE Computational Science & Engineering*, Vol. 2, No.2, pp. 50-61.
- Ha, J.C., and Lee, D.H. (2010). "Working note for marketing analysis." Adambooks, p. 84.
- Hsu, K., Gupta, H.V., and Sorooshian, S. (1995). "Artificial neural network modeling of rainfall-runoff process." *Water Resources Research*, Vol. 31, No. 10, p. 2517.
- Jin, Y.H., Park, S.C., and Lee, Y.K. (2005). "Application of Wavelet Transform for Extraction of long-and Short-term Components in a Hydrological Time Series." *KSCE Journal of Civil Engineering*, Vol. 25, No. 6B, pp. 493-499.
- Kim, T.W., and Valdes, J.B. (2003). "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks." *Journal of Hydrologic Engineering*, Vol. 8, No. 6, pp. 319-328.
- Kozłowski, B. (2005). "Time series denoising with wavelet transform." *Journal of Telecommunications and Information Technology*, Vol. 3, pp. 91-95.
- Lee, N.Y., and Kim, Y.Y. (1999). "What is the Wavelet?" *Korean Society for Noise and Vibration Engineering (KSNVE)*, Vol. 9, No. 5, pp. 867-875.
- Smith, L.C., Turcotte, D.L., and Isacks, B.L. (1998). "Stream flow characterization and feature detection using a discrete wavelet transform." *Hydrological Processes*, Vol. 12, No. 2, pp. 233-249.
- Torrence, C., and Compo, G.P. (1998). "A practical guide to wavelet analysis." *Bulletin of American Meteorological Society*, Vol. 79, No. 1, pp. 61-78.

논문번호: 12-073	접수: 2012.06.29
수정일자: 2012.09.05/09.27	심사완료: 2012.09.27