

## 인공신경망 이론을 이용한 단기 홍수량 예측

### Short-term Flood Forecasting Using Artificial Neural Networks

강문성\* · 박승우\*\*

Kang, Moon Seong · Park, Seung Woo

#### Abstract

An artificial neural network model was developed to analyze and forecast Short-term river runoff from the Naju watershed, in Korea. Error back propagation neural networks (EBPN) of hourly rainfall and runoff data were found to have a high performance in forecasting runoff. The number of hidden nodes were optimized using total error and Bayesian information criterion. Model forecasts are very accurate (i.e., relative error is less than 3% and  $R^2$  is greater than 0.99) for calibration and verification data sets. Increasing the time horizon for application data sets, thus making the model suitable for flood forecasting, decreases the accuracy of the model. The resulting optimal EBN models for forecasting hourly runoff consists of ten rainfall and four runoff data(ANN0410 model) and ten rainfall and ten runoff data(ANN1010 model). Performances of the ANN0410 and ANN1010 models remain satisfactory up to 6 hours (i.e.,  $R^2$  is greater than 0.92).

*Keywords : Artificial neural network, Rainfall, Runoff, Naju, Flood forecasting*

#### I. 서 론

홍수기의 유출량 해석은 홍수예경보, 홍수조절, 그리고 수자원관리 및 운영 등에 기본적으로 이용되며, 정확한 홍수량의 예측은 수자원 관리를 위한 의사결정에서 피해를 경감시킬 수 있는 방안을 제시할 수 있다. 우리 나라에서는 집중호우에 의한

홍수피해가 자주 발생하고 있으며, 이러한 홍수피해를 줄이기 위해서는 해당 유역의 강우-유출 과정을 정확히 해석하여 홍수유출 특성을 파악하는 것이 중요하다.

그러나 강우-유출 과정은 시간적 공간적 변동이 심하고, 비선형성을 포함하고 있으며, 이를 단순한 수학적 모형으로 표현하기는 어렵다 (Hsu et al., 1995). 수문과정의 모형화는 불확실하고 비합리적인 시스템의 초기상태, 강우-유출과정의 불확실한 모형구조, 그리고 비정규성과 비선형성으로 인한 불확실한 매개변수 등 때문에 모형과 실측치간에 불일치를 초래하고 있다. 이와 같은 문제를 해결하

\* 서울대학교 농업생명과학연구원

\*\* 서울대학교 농공학과

\* Corresponding author. Tel.: +82-31-290-2371  
fax: +82-31-292-6807

E-mail address: kms97@phoenix.snu.ac.kr

기 위하여 수문학자들은 수문순환과정을 수학적 모형으로 설정하고 강우-유출에 관한 정량적 해석을 하고자 많은 시도를 하고 있다 (김주환, 1993).

인공신경망(artificial neural network, ANN)은 이러한 불확실한 비선형 자연현상을 모형화하기 위한 비매개변수법의 일종으로서, 수문계의 적용이 1990년 이후 활발히 이루어지고 있다. 인공신경망 이론은 인간의 정보처리 과정을 공학적, 수학적으로 모델링한 것으로서, 어떤 시스템의 인과관계를 연상기억능력을 이용하여 인식할 수 있도록 한 블랙박스 모형이다.

인공신경망은 그 모형 자체의 비선형성 (non-linearity)을 가짐으로서 통계적인 정규성과 정체성 (normality and stationarity)의 가정에서 자유롭다. 또한, 인공신경망은 기존에 설정된 신경망 모형을 문제의 목적에 따라 용이하게 변환이 가능한 적응성 (adaptivity)과 전산학적 병렬계산이 가능하여 그 처리가 합리적인 병렬성 (parallel property) 등의 장점을 지니고 있다 (강문성, 2001).

김주환 등(1992, 1993, 1998)은 신경회로망의 역전파 알고리즘을 이용하여 유출수문곡선을 모의하였고, 신현석 등(1999)은 신경망을 이용한 지역 기상학적인 가뭄 해석과 연평균 강우량의 공간분포 해석을 시도하였으며, 심순보 등(1998)은 신경망 이론을 이용하여 다목적 저수지의 홍수유입량을 예측하였다. 강문성 등(2001)은 소유역에서의 장기 유출해석을 위한 신경망 모형을 구성하고 그 적용성을 검토하였다. 외국의 경우, Anmala et al. (1995), Hsu et al. (1995), Anthony et al. (1996), Sureerattanar et al. (1997), Dawson et al. (1998), Sajikumar et al. (1999), Zealand et al. (1999), 그리고 Marina et al. (1999) 등의 많은 연구자들이 신경망 이론을 이용하여 강우에 따른 유출을 해석하고자 하였다.

그러나 신경망 이론의 수문계의 적용에 있어서는 아직 학습방법에 따른 최적해를 구하는 데 한계가 있으며, 그 적용의 정규화가 미흡하다는 단점도 지

니고 있다. 따라서 신경망의 여러 문제들을 해결하기 위해서는 수문계의 다양한 적용을 통한 검토가 이루어져야 할 것이다.

본 연구의 목적은 영산강 유역의 주요 수위표지점인 나주지점에서의 실시간 홍수량의 예측 및 해석을 위하여, 모멘트법과 학습적응률을 고려한 오류역전파 알고리즘에 의한 실시간 홍수량예측모형을 구성하고, 개발된 모형을 적용하여 보정 및 검정을 통한 최적학습매개변수를 비교 선정하며, 홍수의 사상을 모의함으로써 적용성을 평가하는 데 있다.

## II. 연구방법

### 1. 시험유역 및 수문자료

홍수량 예측을 위한 시험유역은 영산강 수계내의 나주 수위 관측소 지점을 대상으로 하였다. 나주 수위 관측소는 전라남도 나주시 남산동의 나주교 직하에 위치하고 있으며, 영산강 본류의 중류부를 대표하는 측점으로서, 유역면적은  $2,508.72 \text{ km}^2$ , 유로장은  $662.2 \text{ km}$ 이다. 나주 관측소는 1991년 영산강 홍수통제소가 개소되면서 영산강 홍수예경보 시스템의 일환으로 T/M (Telemetry) 수위관측소를 설치하여 1992년 4월부터 관측이 이루어지고 있는 지점이다.

본 연구의 홍수량 자료는 1997~2001년의 13

**Table 1 Summary of storm event data used in the Naju station**

Year	No of event	Name of event	Remarks
2001	3	ST010623, ST010711, ST010914	Calibration
2000	3	ST000714, ST000816, ST000912	Verification
1999	3	ST990701, ST990830, ST990919	Calibration
1998	2	ST980731, ST980928	Calibration
1997	2	ST970624, ST970802	Calibration
Sum	13		

개의 나주 지점 폭우사상을 선정하여 유출량 자료를 이용하였고, 강우량은 같은 시기에 발생한 삼서, 장성댐, 광주 지점의 우량자료를 사용하였다. Table 1은 선정된 폭우사상 자료를 나타내고 있으며, 폭우사상의 명칭은 폭우가 시작된 날짜를 붙여서 사용하였다. 2000년 자료는 검증(verification)자료로 사용하였고, 나머지 자료는 모형의 보정(calibration)자료로 사용하였다.

## 2. 신경망 이론

신경망 모형은 인간의 정보처리 과정을 수학적으로 모델링한 것으로서 입력과 출력을 가지는 자동적인 학습기계라고 말할 수 있다. Fig. 1은 인간의 두뇌를 모델링한 기본적인 신경망 단일소자인 뉴런의 구조를 나타내고 있다.

모형에서의 연산과정은 Fig. 1에서와 같이 입력자료 (input signal)인  $x_i$ 와 연결강도 (synaptic weights)의 벡터인  $w_{ji}$ 에 의한 곱의 형태로 나타내어지는 결합함수 (summing function)인  $\Sigma$ 가 계산된다. 이 결합함수로부터 출력이 선형 또는 비선형적인 특성을 가지게 하는 활성함수 (activation function)을 통해 출력의 과정으로 연산이 수행되어진다.

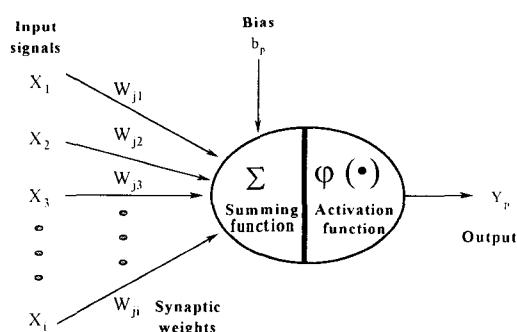


Fig. 1 Architecture of artificial neural network

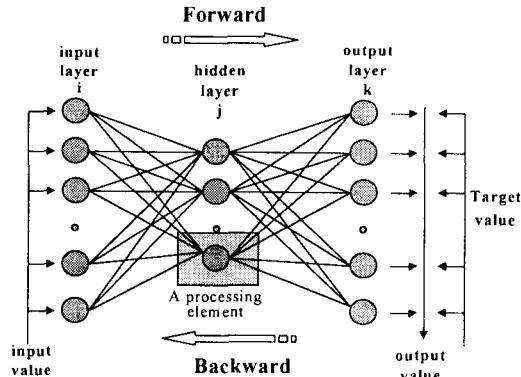


Fig. 2 Construction of multilayer neural network

## 3. 인공신경망 모형

유출예측모형은 다층 신경망 구조로 구성되며, 학습방법은 신경망 이론에서 가장 널리 이용되고 있는 오류역전파 (error back propagation, EBP) 알고리즘을 사용하였다. 오류역전파 알고리즘은 일반화된 델타규칙 (generalized delta rule)으로서, 출력층의 오차를 먼저 계산하고, 오차의 미분으로 표현되는 값을 은닉층으로 역전파시켜 연결강도를 반복적으로 조정해 나가는 방법이다. Fig. 2는 다층신경망의 구조를 보여주고 있다.

다층 순방향 신경망(feed-forward neural networks) 훈련은 실측치와 모의치의 비선형 최소 차승인 가중함수를 최소화하는 것으로서 교사훈련 (supervised training)이라고 한다. 이것은 다음식 (1)과 같이 나타내어진다.

$$E = \frac{1}{2} \sum_{p=1}^n \sum_{k=1}^m (y_{pk} - p_{pk})^2 \quad (1)$$

여기서,  $E$ 는 총오차,  $n$ 은 실측치의 패턴 수,  $m$ 은 총 출력단위,  $y_{pk}$ 는 실측된 반응인 목표출력값으로서 일 유출량,  $p_{pk}$ 는 모형에 의한 모의 출력값으로서 일 모의유출량을 나타내며, 식 (1)이 하나의 출력단위를 갖는 경우 ( $m=1$ )는 다음과 같이 나타내어진다.

$$E = \frac{1}{2} \sum_{p=1}^n (y_p - p_p)^2 \quad (2)$$

신경망 모형에서 순방향 연결강도의 합과 활성화 함수는 각각 식 (3)과 식 (4)와 같다.

$$net_{pi} = \sum_{i=1}^n W_{ji} x_{pi} \quad (3)$$

$$g(net_{pi}) = \frac{1}{1 + e^{-net_{pi}}} \quad (4)$$

여기서,  $net_{pi}$ 는 은닉층과 입력층 사이의 연결강도의 합, n은 총 입력노드의 수,  $W_{ji}$ 는 입력층과 은닉층 사이의 연결강도,  $x_{pi}$ 는 패턴 p에 대한 i번째 값, 그리고  $g(net_{pi})$ 는 뉴런의 활성화함수이다.

출력단위는 다음의 식 (5)와 식 (6)과 같이 나타내어지는 net input을 받는다.

$$net_{pk} = \sum_{j=1}^l W_{kj} g(net_{pj}) \quad (5)$$

$$P_{pk} = g(net_{pk}) \quad (6)$$

여기서, l은 은닉단위의 수,  $W_{kj}$ 는 출력층의 k와 은닉층 노드 j와 연결되는 연결강도, 그리고  $P_{pk}$ 는 k 번째의 예측 출력값으로서 모의 유출량값이다.

식 (1)에 의해 계산된 오차 E의 최소화는 최적화기법 중에서 경사하강법 (gradient descent method)을 사용하였다. 경사하강법은 연쇄법칙 (chain rule)을 사용하여 E를 연결강도에 대한 일차 편미분으로 나타내어지며, 연결강도는 급강하방향으로 이동하여 연결강도의 값을 조정해 나간다. 이것을 수식으로 나타내면 식 (7)과 같다.

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}} \quad (7)$$

여기서,  $\eta$ 는 학습률로서 스칼라이다.

본 모형에서는 최적화기법인 경사하강법에 학습 과정에서 발생할 수 있는 지역 최소값 (local mi-

nima value) 문제와 오차를 최소화하고 수렴속도를 향상시키기 위해 식 (7)에서의 적응학습률 (adaptive learning rate)에 모멘트법 (momentum)을 고려하였으며, 식 (8)과 같이 나타내어진다.

$$\Delta W_{kj}(t+1) = \eta \delta_{pk} h_{pj} + \alpha \Delta W_{kj}(t) \quad (8)$$

여기서,  $\Delta W_{kj}(t+1)$ 은 연결강도의 조정량,  $\delta_{pk}$ 는 p번쨰 패턴에 대한 출력층의 오차,  $\alpha$ 는 모멘텀 계수이다. 모멘텀 계수는 0에서 1 사이의 값을 가지며, Pahan Pao에 의하면 실험적으로 제안된 모멘텀 계수는 0.9, 학습률은 0.7이었다 (김주환, 1993). 선행 연구에 의하면, 모멘텀 계수는 주로 0.9~0.95를 사용하였으며, 본 연구에서는 모멘텀 계수와 학습률을 병행하여 오차의 감소 여부를 확인하여 중감시킴으로써 최적의 값을 추출하였고, 그 결과 모멘텀 계수는 0.95, 학습률은 0.7인 것으로 나타났다.

은닉층에서의 최적 노드수를 얻기 위한 방법으로 Rissanen(1978)가 제안한 Bayesian Information Criterion (BIC)을 사용하였으며, 그 식은 다음과 같다.

$$BIC = M \ln(MSE) + P \ln M \quad (9)$$

여기서, M은 신경망의 자료수, MSE는 평균자승 오차, 그리고 P는 매개변수의 수(weights and biases)를 나타낸다.

식 (9)에 의해 산정된 BIC를 이용한 은닉층 최적 노드수에서의 stopping rule은 다음 식 (10)과 같이 구성하였다.

$$\left| \frac{BIC(k+1) - BIC(k)}{BIC(k)} \right| \leq 0.001 \quad (10)$$

#### 4. 홍수량 예측 모형

본 연구에서는 모형의 입력층에서의 선행 시강우

$$ANN0404; Q(t) = function \left( \begin{array}{c} R_j(t-4), R_j(t-5), R_j(t-6), R_j(t-7) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4) \end{array} \right) \text{ for } j=1, 2, 3 \quad (11)$$

$$ANN0410; Q(t) = function \left( \begin{array}{c} R_j(t-1), R_j(t-2), R_j(t-3), R_j(t-4), R_j(t-5) \\ R_j(t-6), R_j(t-7), R_j(t-8), R_j(t-9), R_j(t-10) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4) \end{array} \right) \text{ for } j=1, 2, 3 \quad (12)$$

$$ANN1010; Q(t) = function \left( \begin{array}{c} R_j(t-1), R_j(t-2), R_j(t-3), R_j(t-4), R_j(t-5) \\ R_j(t-6), R_j(t-7), R_j(t-8), R_j(t-9), R_j(t-10) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5) \\ Q(t-6), Q(t-7), Q(t-8), Q(t-9), Q(t-10) \end{array} \right) \text{ for } j=1, 2, 3 \quad (13)$$

$$ANN0404T; Q(t) = function \left( \begin{array}{c} \bar{R}(t-4), \bar{R}(t-5), \bar{R}(t-6), \bar{R}(t-7) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4) \end{array} \right) \quad (14)$$

$$ANN0410T; Q(t) = function \left( \begin{array}{c} \bar{R}(t-1), \bar{R}(t-2), \bar{R}(t-3), \bar{R}(t-4), \bar{R}(t-5) \\ \bar{R}(t-6), \bar{R}(t-7), \bar{R}(t-8), \bar{R}(t-9), \bar{R}(t-10) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4) \end{array} \right) \quad (15)$$

$$ANN1010T; Q(t) = function \left( \begin{array}{c} \bar{R}(t-1), \bar{R}(t-2), \bar{R}(t-3), \bar{R}(t-4), \bar{R}(t-5) \\ \bar{R}(t-6), \bar{R}(t-7), \bar{R}(t-8), \bar{R}(t-9), \bar{R}(t-10) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5) \\ Q(t-6), Q(t-7), Q(t-8), Q(t-9), Q(t-10) \end{array} \right) \quad (16)$$

$$ANN0303T; Q(t) = function \left( \begin{array}{c} \bar{R}(t-1), \bar{R}(t-2), \bar{R}(t-3) \\ Q(t-1), Q(t-2), Q(t-3) \end{array} \right) \quad (17)$$

$$ANN0707T; Q(t) = function \left( \begin{array}{c} \bar{R}(t-1), \bar{R}(t-2), \bar{R}(t-3), \bar{R}(t-4), \bar{R}(t-5), \bar{R}(t-6), \bar{R}(t-7) \\ Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5), Q(t-6), Q(t-7) \end{array} \right) \quad (18)$$

$$ANN1000T; Q(t) = function \left( \begin{array}{c} Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5) \\ Q(t-6), Q(t-7), Q(t-8), Q(t-9), Q(t-10) \end{array} \right) \quad (19)$$

량과 시유량을 고려하여 총 9개의 시간별 흥수량 예측 모형을 구성하였다. 모형의 구성은 입력층에 사용된 삼서, 장성댐, 그리고 광주 지점의 시강우량 자료에 대해 티센법에 의한 면적가중평균 강우량을 사용하는 경우와 각 강우량 관측지점의 강우량을 사용하는 경우로 구분된다. ANN0404, ANN0410, ANN1010 모형은 각 강우량 관측지점의 강우량을 그대로 사용한 경유이며, 나머지 모형은 면적가중 평균강우량을 적용한 모형이다. 각각의 모형은 강우량 시계열 자료와 유량 시계열 자료의 구성 및 점강우량과 면적가중평균강우량의 적용이 실시간 유출 모의에 어떤 영향을 미치는지를 파악하기 위

하여 시계열 자료의 변수에 따라 다양한 형태의 모형을 구성하였다. 각 모형의 식은 식(11)~(19)과 같다.

여기서,  $Q(t)$ 는  $t$ 시간의 유량,  $R_j(t)$ 는  $j$  측점에 서의  $t$ 시간의 강우량,  $\bar{R}(t)$ 는  $t$ 일의 유역평균강우량,  $j$ 는 각각 삼서, 장성댐, 그리고 광주 측점이다.

모형의 입출력 자료는 구성된 흥수량 추정모형의 시그모이드 함수인 최소값 0과 최대값 1을 전달하므로 이론적인 정규화 범위로 변환하였으며, 식(20)과 같다.

$$X' = \left[ \frac{1}{(X_{\max} - X_{\min})} \right] \times (X - X_{\min}) \quad (20)$$

여기서,  $X'$ 은 변환된 변수이고,  $X_{\max}$  와  $X_{\min}$  은 보정 기간동안 사용된 실측자료의 최대값과 최소값이다.

식 (20)을 변환하여 시유량을 모의할 경우, 유량의 최소값과 최대값에 제한요소가 나타나므로, 좀 더 큰 범위를 나타내기 위한 방법들을 사용할 수 있다 (Huynh, 2000). 본 연구에서의 최소값과 최대값은  $\text{range}[0.8Q_{\min}, 1.2Q_{\max}]$ 의 범위를 적용하였다.

홍수량 예측 모형의 수행 정도를 평가하기 위하여 Nash와 Sutcliffe (1970)가 제안한 효율지수 (Efficiency Index, EI)를 사용하였다. 효율지수는 식 (21)~(23)과 같이 나타내어진다.

$$EI = (ST - SE)/ST \quad (21)$$

$$ST = \sum_{t=1}^N (Q_t - \bar{Q})^2 \quad (22)$$

$$SE = \sum_{t=1}^N (Q_t - F_t)^2 \quad (23)$$

여기서,  $N$ 은 자료의 수,  $Q_t$ 는  $t$ 시간의 실측 유량,  $\bar{Q}$ 는 실측 유량의 평균값,  $F_t$ 는  $t$ 시간의 모의 유량, ST는 분산의 합, SE는 실측치와 모의치의 차승오차의 합이다.

### III. 결과 및 고찰

#### 1. 모형의 보정

모형의 보정을 위한 학습자료는 강우량과 폭우사상의 형태를 고려하여 충분한 학습이 이루어지도록 1997년~1999년, 그리고 2001년의 강우량과 시유출량 자료를 이용하였다. 본 연구에서 구성된 9개의 모형에 대한 은닉층의 최적 노드수를 결정하기 위하여 각 모형의 은닉층의 노드수를 1~25까지 변환시키면서 3,000회 반복하여 학습을 수행하였다.

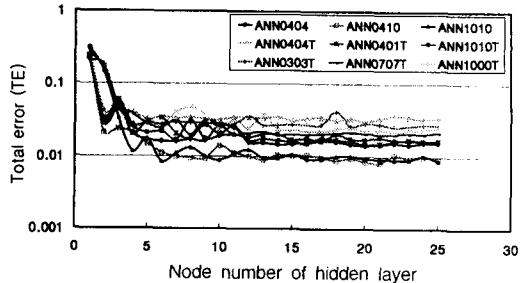


Fig. 3 Training results according to number

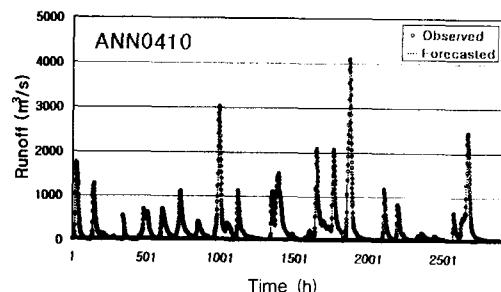


Fig. 4 Time series of observed and forecasted of nodes of hidden layer runoff for events from calibration set

Fig. 3은 각 모형별 은닉층의 노드수에 따른 총 오차(total error, TE)의 변화를 보여주고 있으며, 각 모형별 총오차가 가장 작은 은닉층의 노드수를 모형별 은닉층의 최적 노드수로 결정하였다. 각 모형별 은닉층의 노드수에 따른 모형의 학습 결과, 유량 시계열 4개 변수 및 10개 변수와 각 측점별 유량 시계열 10개 변수를 입력층으로 하는 ANN0410과 ANN1010 모형이 은닉층의 노드수에 따라 총오차가 가장 작게 나타남으로서 다른 모형에 비해 상대적으로 학습이 효과적으로 이루어졌음을 알 수 있다. Fig. 4는 ANN0410 모형의 학습에 의한 모의치와 실측치를 비교하여 보여주고 있다.

모형별 은닉층의 최적노드수에 따라 보정 자료기간에 대하여 모형을 적용하여 얻어진 실측치와 모의치를 비교한 결과는 Table 2에서와 같다. 구성된 모형별 실측치와 모의치를 비교한 결과, 총오차(total error, TE)는 0.0082~0.0305의 범위를

Table 2 Calibration statistics for each model

Model	a	b	TE	RB (%)	RMSE ( $m^3/s$ )	RMAE ( $m^3/s$ )	EI	$R^2$
ANN0404	16	20	0.0142	0.35	18.28	0.03	0.9986	0.9989
ANN0410	34	21	0.0082	0.08	12.04	0.02	0.9994	0.9994
ANN1010	40	6	0.0085	0.84	13.36	0.02	0.9993	0.9993
ANN0404T	8	17	0.0219	1.30	21.92	0.03	0.9980	0.9985
ANN0410T	14	20	0.0148	0.69	17.97	0.03	0.9987	0.9989
ANN1010T	20	17	0.0161	0.00	16.95	0.02	0.9988	0.9989
ANN0303T	6	22	0.0255	1.33	22.42	0.03	0.9980	0.9983
ANN0707T	14	8	0.0198	0.14	17.99	0.02	0.9987	0.9987
ANN1000T	10	20	0.0305	2.91	30.59	0.04	0.9960	0.9972

a: number of nodes of input layer. b: number of nodes of hidden layer

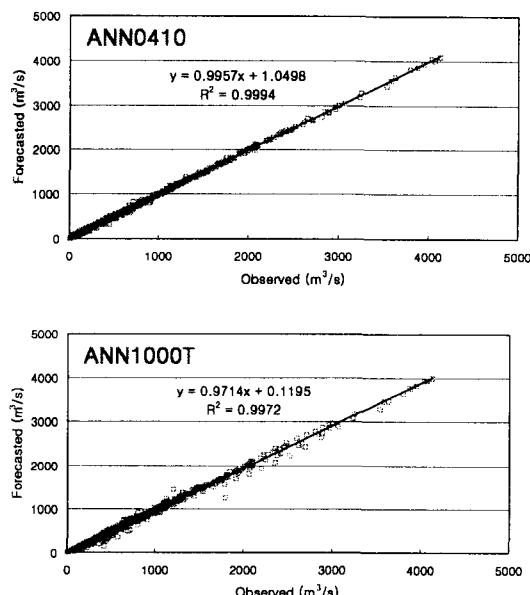


Fig. 5 Scatter plots comparing observed and forecasted runoff for calibration data

보였으며, ANN0410과 ANN1010 모형이 학습정도가 상대적으로 뛰어난 것으로 나타났다. 상대오차(relative bias, RB)는 0~2.91%의 범위를 보였고, RMSE(root mean square error)와 RMAE(relative mean absolute error)는 12.04~30.59  $m^3/s$ 와 0.02~0.04  $m^3/s$  범위의 값을 나타내었다.

모형의 효율성을 나타내는 효율지수 (efficiency index, EI)와 결정계수  $R^2$ (coefficient of determination)의 값은 모형별로 0.99 이상의 값을 보임으로서 학습의 결과가 양호한 것으로 나타났다. 이상의 결과로 볼 때, ANN0410과 ANN1010 모형이 학습정도가 뛰어나며, 실측치를 경향을 가장 잘 재현하는 것으로 나타났으며, 유출량만을 입력층으로 구성한 ANN1000T 모형이 학습정도가 가장 떨어지는 것으로 나타났다. Fig. 5는 학습이 가장 잘 이루어진 ANN0410과 학습정도가 가장 떨어지는 ANN1000T 모형의 실측치와 모의치의 산포도를 보여주고 있다.

## 2. 모형의 검증

모형의 검증은 2000년의 3개 폭우사상인 ST000714, ST000816, 그리고 ST000912의 자료기간에 대한 우량과 유량의 자료를 이용하였다.

모형별 검증 결과는 Table 3에서와 같이, 상대오차인 RB는 0.07~1.72%의 범위를 보였고, RMSE와 RMAE는 24.01~45.74  $m^3/s$ 와 0.02~0.04  $m^3/s$  범위의 값을 나타내었다. 모형의 효율지수와 결정계수의 값은 모형별로 0.99 이상의 값을

Table 3 Verification statistics for each model: model forecasting one hour in advance

Model	RB (%)	RMSE ( $m^3/s$ )	RMAE ( $m^3/s$ )	EI	$R^2$
ANN0404	0.45	24.01	0.03	0.9982	0.9983
ANN0410	0.27	38.84	0.03	0.9998	0.9985
ANN1010	0.89	33.66	0.03	0.9999	0.9989
ANN0404T	0.94	38.65	0.03	0.9998	0.9987
ANN0410T	0.07	36.36	0.02	0.9998	0.9986
ANN1010T	0.96	36.36	0.03	0.9998	0.9987
ANN0303T	0.92	36.90	0.03	0.9998	0.9989
ANN0707T	1.25	39.38	0.03	0.9998	0.9986
ANN1000T	1.72	45.74	0.04	0.9997	0.9980

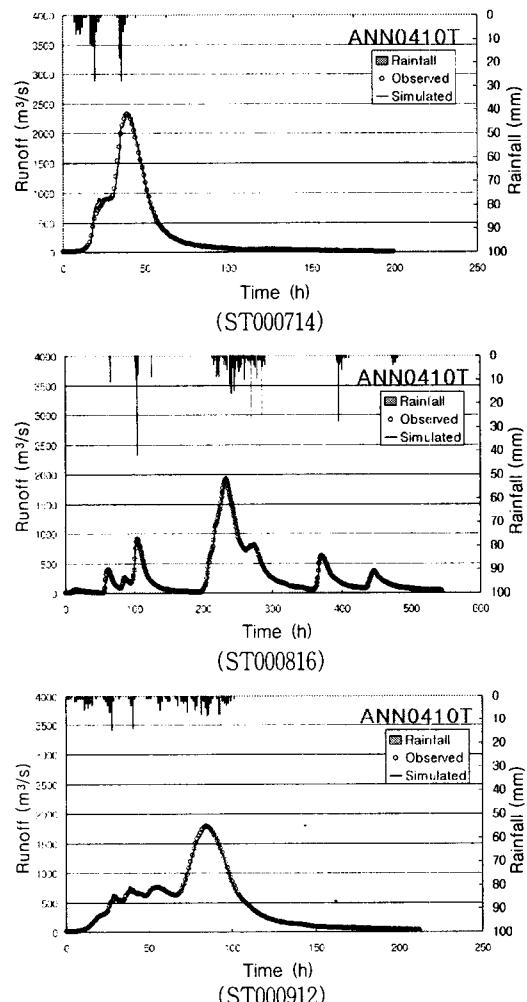


Fig. 6 Time series of observed and forecasted runoff for events from verification set

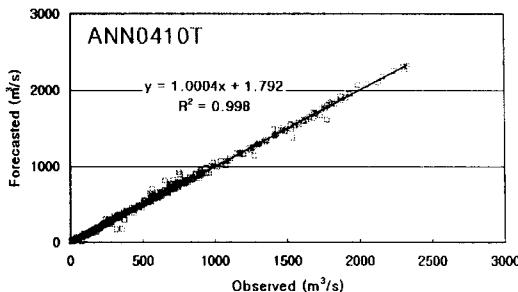


Fig. 7 Scatter plots comparing observed and forecasted runoff for verification data

보임으로서 검증 결과가 양호한 것으로 나타났다. 이상의 결과로 볼 때, ANN0410과 ANN0410T 모형이 검증 결과가 뛰어난 것으로 나타났으며, 유출량만을 입력층으로 구성한 ANN1000T 모형이 검증정도가 가장 떨어지는 것으로 나타났다. Fig. 6은 검증 결과가 가장 잘 이루어진 ANN0410T의 폭우사상에 대하여 실측치와 모의치를 나타내고 있으며, Fig. 7은 선정된 모든 폭우사상에 따른 시간별 유출량의 실측치와 모의치의 산포도를 보여주고 있다.

### 3. 모형의 응용

모형의 응용은 모형의 검증에 사용된 2000년의 3개 폭우사상인 ST000714, ST000816, 그리고 ST000912의 자료기간에 대한 우량과 유량의 자료를 이용하였다. 시간별 홍수량을 예측하기 위하여 각 모델에 따라 1시간에서 6시간까지 홍수량을 예측하여 그 결과를 평가하였다.

Fig. 8은 폭우사상별 예보시간에 따른 유출량의 실측치와 모의치를 비교하여 보여주고 있으며, Fig. 9는 모든 자료에 대해 예보시간별 실측치와 모의치의 결과를 산포도로 보여주고 있다. Fig. 8과 Fig. 9에서와 같이, 예보시간이 길어질수록 실측치의 재현 능력이 떨어지는 것을 알 수 있으며, ANN0410과 ANN1010 모형이 실측치를 잘 재현하고 있는 것으로 나타났다. 이러한 결과는 유역의 홍수 도달

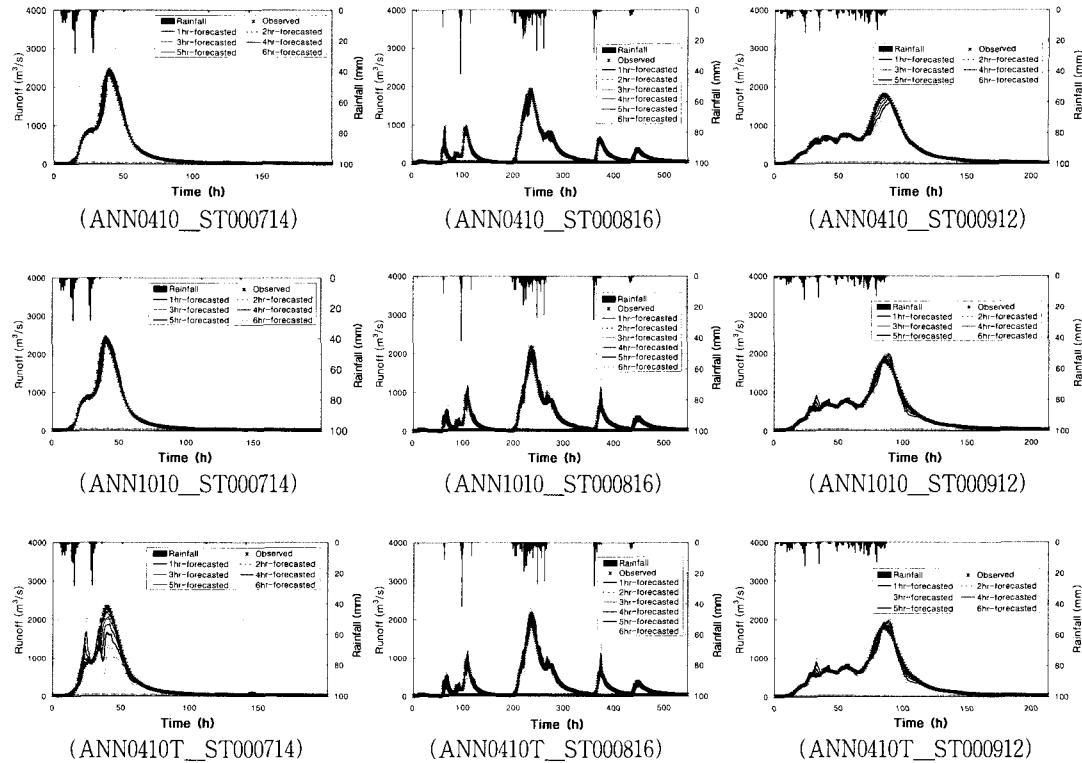
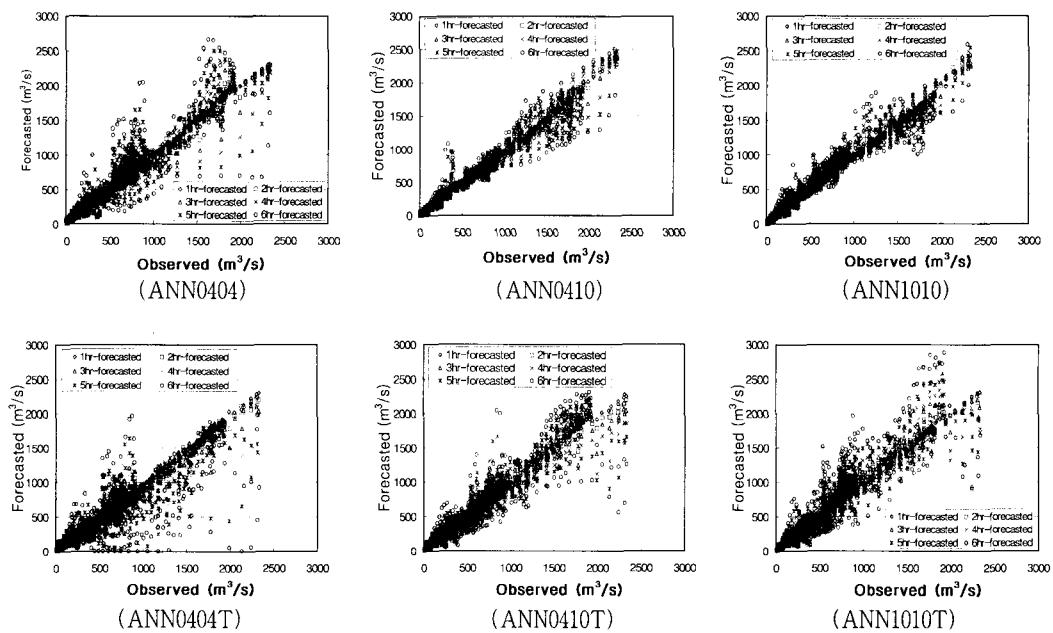


Fig. 8 Time series of observed and forecasted runoff from one to six hours in advance for application data



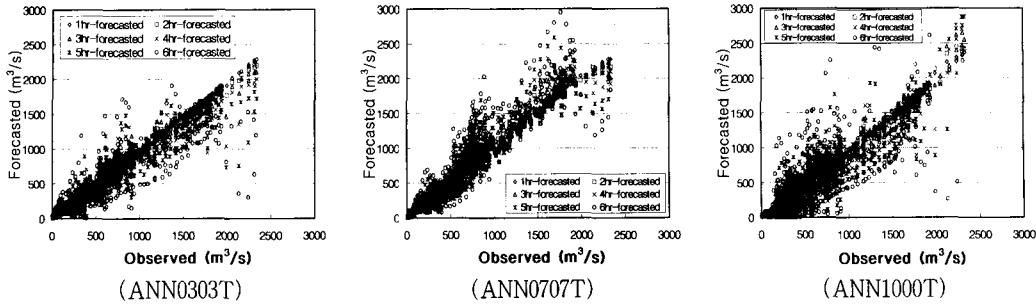


Fig. 9 Scatterplots comparing observed and forecasted runoff from one to six hours in advance for verification data

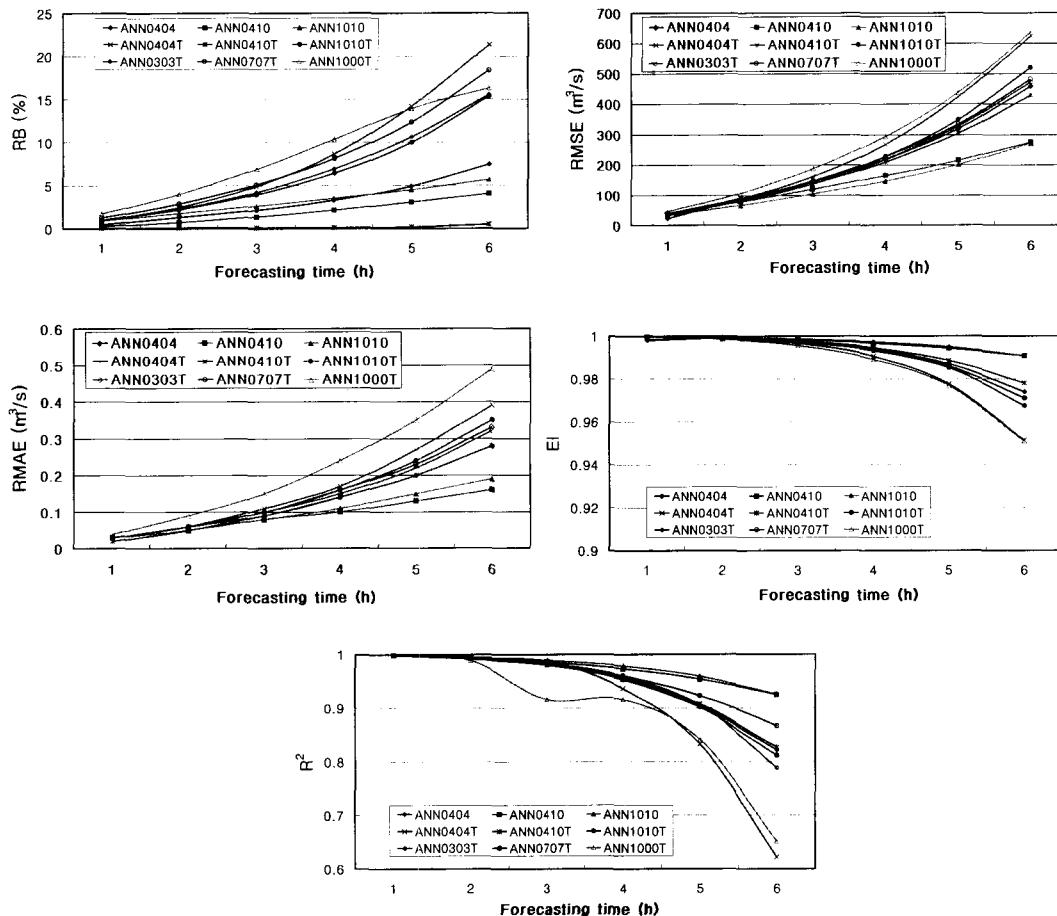


Fig. 10 RB, RMSE, RMAE, EI, and  $R^2$  as forecasting time from application data sets

시간이 10시간 내외인 것을 고려할 때, ANN0410과 ANN1010 모형이 유역 홍수 도달시간인 10시

간 전의 강우량을 입력층으로 사용했기 때문으로 사료된다. 또한, 면적가중평균 강우량을 사용한 모

형보다 각 강우측점의 강우량을 그대로 사용한 모형이 더 우수한 결과를 보였다.

Fig. 10은 2000년의 3개 폭우사상에 대해 예측 시간에 따른 RB, RMSE, RMAE, EI, 그리고  $R^2$ 의 변화를 보여주고 있다. 모든 모형은 예보시간이 길어질수록 예측 능력이 떨어지는 것으로 나타났다. RB는 ANN1010T가 가장 작은 것으로 나타났고, RMSE와 RMAE는 ANN0410과 ANN1010이 작은 값을 보였다. EI와  $R^2$ 의 경우에는 ANN0410과 ANN1010 모형이 6시간 후를 예측하여도 0.9 이상의 값을 보임으로서 실측치를 잘 재현하고 있음을 알 수 있다. 따라서, 면적가중평균 강우량보다 각 측점의 강우량을 그대로 사용하고, 10시간 전까지의 강우량을 입력자료로 사용하는 것이 우수한 결과를 보임을 알 수 있다.

각 모형별 자료기간에 대하여 6시간 후의 홍수량 예측 결과와 실측치의 통계적 변량을 비교한 결과는 Table 4에서와 같다. Table 4에서와 같이, RB는 0.46~21.31%의 범위를 보였으며, RMSE는 270.82~638.68  $m^3/s$ 의 범위를 나타냈으며 ANN1010 모형이 가장 작은 값을 보였다. RMAE는 0.16~0.49  $m^3/s$ 의 범위를 나타냈으며, ANN0410 모형이 가장 작은 값을 보였고, 유출량만을 입력층으로 구성한 ANN1000T 모형이 가장

큰 값을 보였다. EI는 모든 모형이 0.95~0.99의 값을 보였으며,  $R^2$ 은 0.6517~0.9273의 범위를 나타냈다. 각 모형별로 6시간 예보의 경우 통계적 변량을 근거로 비교하여 볼 때, ANN0410과 ANN1010 모형이 실측치를 가장 잘 반영하는 것으로 나타났고, 시우량 자료를 제외하고 유출량 자료만을 입력층으로 사용한 ANN1000T 모형이 상대적으로 실측치의 반영이 떨어지는 것으로 나타났다. 6시간 예보 결과에서도 10시간 이전까지 시우량과 각 강우측점 자료를 그대로 사용하여 입력층을 구성한 모형이 학습능력이 양호한 것으로 나타났다.

#### IV. 요약 및 결론

본 연구에서는 모멘트법과 학습적응률을 고려한 오류역전과 알고리즘에 의한 홍수량예측모형을 총 9개 구성하였고, 영산강 유역의 나주지점에 적용하여 보정 및 검증하였으며, 홍수량의 추정을 위한 예보시간별 예측을 수행하였고, 그 결과를 비교 평가하였다.

본 연구의 결과를 정리하면 다음과 같다.

- 1) 신경망 이론의 학습률과 모멘텀 계수를 고려한 오류역전과 알고리즘을 이용한 총 9개의 유출예측모형을 구성하였다.

- 2) 각 모형별 은닉층의 노드수에 따른 모형의 학습 결과, ANN0410과 ANN1010 모형이 은닉층의 노드수에 따라 총오차가 가장 크게 나타남으로서 학습이 가장 효과적으로 이루어졌다.

- 3) 모형별 은닉층의 최적노드수에 따라 보정 자료기간에 대하여 모형을 적용하여 통계적 변량을 비교한 결과, ANN0410과 ANN1010 모형이 학습 정도가 뛰어났으며, 유출량만을 입력층으로 구성한 ANN1000T 모형이 학습정도가 가장 떨어지는 것으로 나타났다.

- 4) 2000년의 폭우사상에 대한 모형별 검증 결과, ANN0410과 ANN0410T 모형이 검증 결과가

Table 4 Application statistics for each models' model forecasting six hours in advance

Model	RB (%)	RMSE ( $m^3/s$ )	RMAE ( $m^3/s$ )	EI	$R^2$
ANN0404	7.46	458.95	0.28	0.97381	0.8214
ANN0410	4.05	273.54	0.16	0.99101	0.9263
ANN1010	5.65	270.82	0.19	0.99119	0.9274
ANN0404T	21.31	625.24	0.39	0.95140	0.6222
ANN0410T	0.46	429.10	0.28	0.97789	0.8268
ANN1010T	15.35	520.87	0.35	0.96742	0.8114
ANN0303T	15.53	472.19	0.32	0.97100	0.7884
ANN0707T	18.35	482.86	0.33	0.97102	0.8674
ANN1000T	16.27	638.68	0.49	0.95101	0.6517

뛰어난 것으로 나타났으며, 유출량만을 입력층으로 구성한 ANN1000T 모형이 검증 정도가 가장 떨어지는 것으로 나타났다.

5) 1시간에서 6시간까지 시간별 홍수량을 예측하여 모형에 대한 응용 결과, 예측 시간이 길어질수록 실측치의 재현 능력이 떨어졌으며, ANN0410과 ANN1010 모형이 실측치를 잘 재현하고 있는 것으로 나타났으며, 이는 ANN0410과 ANN1010 모형이 유역 홍수 도달시간인 10시간 전의 강우량을 입력층으로 사용했기 때문으로 사료된다. 또한, 면적가중평균 강우량을 사용한 모형보다 각 강우측점의 강우량을 그대로 사용한 모형이 더 우수한 결과를 보였다.

6) 각 모형별로 6시간 후의 홍수량 예측 결과와 실측치의 통계적 변량을 비교한 결과, RB는 0.46~21.31%, RMSE는 270.82~638.68 m<sup>3</sup>/s, RMAE는 0.16~0.49 m<sup>3</sup>/s, EI는 0.95~0.99, 그리고 R<sup>2</sup>은 0.6517~0.9273의 범위를 나타냈으며, ANN0410과 ANN1010 모형이 6시간 시간별 예측이 실측치를 가장 잘 반영하는 것으로 나타났고, 시우량 자료를 제외하고 유출량 자료만을 입력층으로 사용한 ANN1000T 모형이 상대적으로 실측치의 재현 정도가 떨어지는 것으로 나타났다.

본 연구는 농림기술개발사업 (과제명 : 배수 개선 농경지의 침수피해 모의시스템 개발)에 의하여 수행된 연구결과의 일부임.

## References

- Ahn, K. S., and J. H. Kim. 1998. A study on the simulation of runoff hydrograph by using artificial neural network. *Journal of Korea Water Resources Association* 31(1): 13~25. (in Korean)
- Anmala, J., and K. V. Nedunuri. 1995. Neural networks for prediction of watershed runoff, 1st International Conference on Water Resources Eng. *Water Resources Planning and Management Div., ASCE*, San Antonio, Texas, USA, Aug. 14~18, pp. 348~357.
- Anthony, W. M.. 1996. Extented rainfall-runoff nodeling using aritificial neural networks, Proc. of the 2nd International Conf. on Hydroinformatics, '96, Zurich, Switzerland, pp. 207~213.
- Asaad, Y. S.. 1997. Application of a neural network technique to rainfall-runoff modeling. *Journal of Hydrology* 199: 272~294.
- Choi, J. K., and M. S. Kang. 2000. Application of neural network to water re-sources. *Korean National Committee on Irrigation and Drainage Journal* 7(2): 246~258. (in Korean)
- Dawson, C. W., and R. Wilby. 1998. An artificial neural network approach to rainfall-runoff modeling, *Hydrological Sciences* 43(1): 47~66.
- Hsu, K. N., H. V. Gupta, and S. sorooshian. 1995. Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research* 31(10): 2517~2530.
- Huynh, N. P. and S. Sureerattanan, 2000. Neural networks for filtering and forecasting of daily and monthly streamflows, *Water Resources Publications*, LLC, WEESHE, Hydrologic Modeling, pp. 203~218
- Kang, M. S., and S. W. Park. 2001. Forecasting long-term streamflow from a small watershed using artificial neural network. *Journal of the Korean Society of Agricultural Engineers* 43(2): 69~77. (in Korean)
- Kim, J. H. 1993. A study on hydrologic forecasting of streamflows based on artificial neural network. Ph.D. diss. Inha University. (in Korean)
- Marina, C., P. Andreussi, and A. Soldati. 1999. River flood forecasting with a neural

- network model, *Water Resources Research* 35(4): 1191–1197.
12. Nash, J. E. and J. V. Sutcliffe, 1970. River flow forecasting through conceptual models part I-A discussion of principles, *Journal of Hydrology* 10: 282–290.
  13. Sajikumar, N. and B. S. Thandaveswara. 1999. A nonlinear rainfall-runoff model using ANN, *Journal of Hydrology*, 216: 32–55.
  14. Shim, S. B., M. S. Kim, and K. C. Shim. 1998. Flood inflow forecasting on multi-purpose reservoir by neural network. *Journal of Korea Water Resources Association* 31(1): 45–57. (in Korean)
  15. Shin, H. S., and M. J. Park. 1999. Spatial analysis for mean annual precipitation based on neural networks. *Journal of Korea Water Resources Association* 32(1): 3–13. (in Korean)
  16. Shin, H. S., and M. J. Park. 1999. Spatial-temporal drought analysis of South Korea based on neural networks. *Journal of Korea Water Resources Association* 32(1): 15–29. (in Korean)
  17. Shin, H. S. 1998. Application of neural network to water resources and environments. *Magazine of Korea Water Resources Association* 31(1): 97–103. (in Korean)
  18. Sureerattanar, S. and H. N. Phien. 1997. Back-propagation networks for daily stream flow forecasting, *Water Resources Journal* No. 195: 1–7.
  19. Zealand, C. M., D. H. Burn, and S. P. Simonovic. 1999. Short term stream flow forecasting using ANN, *Journal of Hydrology*, Vol., 214, pp. 32–48.