

# 신경망이론을 이용한 소유역에서의 장기 유출 해석

Long Term Streamflow Forecasting in Small Watershed  
using Artificial Neural Network

강 문 성 (서울대)\* · 박 승 우 (서울대)

Kang, Moon Seong · Park, Seung Woo

## Abstract

A artificial neural network model was developed to analyze and forecast the flow fluctuation at small streams in the Balan watershed. Backpropagation neural networks were found to perform very well in forecasting daily streamflows. In order to deal with slow convergence and an appropriate structure, two algorithms were proposed for speeding up the convergence of the backpropagation method, and the Bayesian Information Criterion (BIC) was proposed for obtaining the optimal number of hidden nodes. From simulations using daily flows at the HS#3 watershed of the Balan Watershed Project, which is 412.5 ha in size and relatively steep in landscape, it was found that those algorithms perform satisfactorily.

## I. 서 론

소유역에서의 장기유출은 시간적 공간적 변동이 심한 기상인자 및 수문지상인자 등의 영향을 받음은 물론, 수문자료가 포함하고 있는 비선형성과 불확실성 등으로 인해 강우-유출과정을 수학적으로 모형화하기란 쉽지 않다.

수문과정의 모형화는 불확실하고 비합리적인 시스템의 초기상태, 강우-유출과정의 불확실한 모형구조, 그리고 비정규성과 비선형성으로 인한 불확실한 매개변수 등 때문에 모형과 실측치 간에 불일치를 초래하고 있다. 이와같은 문제를 해결하기 위하여 수문학자들은 수문순환과정을 수학적 모형으로 설정하고 강우-유출에 관한 정량적 해석을 하고자 많은 시도를 하고 있다 (김주환, 1993).

이러한 불확실한 비선형 자연현상을 모형화하기 위해 비매개변수법의 일종인 인공신경망 (artificial neural network, ANN)을 이용한 수문계의 적용이 1990년 이후 활발히 이루어지고 있으며, 최근 10년 동안 수자원 및 환경 분야에서 여러 각도로 응용되어지고 있다.

인공신경망 이론은 인간의 정보처리 과정을 공학적으로 모델링한 것으로서, 어떤 시스템의 인과관계를 연상기억능력을 이용하여 인식할 수 있도록 한 블랙박스 모형이다. 인공신경망은 그 모형 자체의 비선형성 (nonlinearity)을 갖음으로서 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.

한편, 신경망 이론의 수문계의 적용에 있어서는 아직 학습방법에 따른 최적해를 구하는 데

한계가 있으며, 그 적용의 정규화가 미흡하는 단점도 지니고 있다. 따라서 신경망의 여러 문제들을 해결하기 위해서는 수문계의 다양한 적용을 통한 검토가 이루어져야 할 것이다.

본 연구의 목적은 신경망이론을 이용한 소유역에서의 장기유출을 해석하기 위하여, 신경망이론 중 모멘트법과 학습적용률을 고려한 오류역전파 알고리즘에 의한 일별 장기유출예측모형을 구성하고, 시험유역에 개발된 모형을 적용하여 그 결과를 고찰하므로서 본 모형의 적용가능성을 평가하는데 있다.

## II. 연구방법

### 1. 신경망 이론

신경망 모형은 인간의 정보처리 과정을 수학적으로 모델링한 것으로서 입력과 출력을 가지는 자동적인 학습기계라고 말할 수 있다. 그림1은 인간의 두뇌를 모델링한 기본적인 신경망 단일소자인 뉴런의 구조를 나타내고 있다.

모형에서의 연산과정은 그림1에서와 같이 입력자료 (input signal)인  $x_i$ 와 연결강도 (Synaptic weights)의 벡터인  $w_{ji}$ 에 의한 곱의 형태로 나타내어지는 결합함수 (summing junction)인  $\Sigma$ 가 계산된다. 이 결합함수로부터 출력이 선형 또는 비선형적인 특성을 가지게 하는 활성함수 (activation function)을 통해 출력의 과정으로 연산이 수행되어진다.

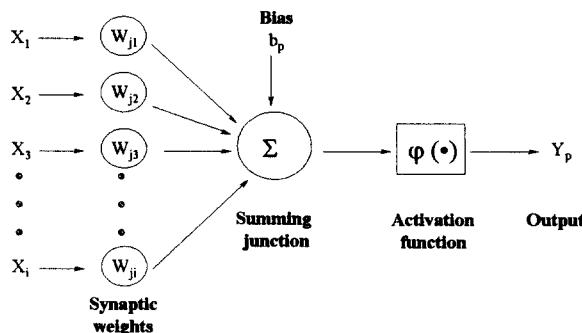


그림1. 신경망 모형의 연산구조

### 2. 모형의 구성

장기유출모형은 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.

다층 순방향 신경망(feed-forward neural networks) 훈련은 실측치와 모의치의 비선형 최소자승인 가중함수를 최소화하는 것으로서 교사훈련(Supervised training)이라고 한다. 이것은 다음 식 (1)과 같이 나타내어진다.

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

여기서,  $n$ 은 실측치의 패턴 수,  $m$ 은 총 출력단위,  $y_{pk}$ 는 실측된 반응인 목표출력값,  $p_{pk}$ 는 모

델에 의한 모의 출력값이다.

하나의 출력단위를 갖는 경우 ( $m=1$ )는 다음 식 (2)와 같이 나타내어진다.

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

오차  $E$ 의 최소화는 최적화기법중에서 경사하강법 (gradient descent method)을 사용하였다. 신경망모형에서 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,  $N$ 은 총 입력노드의 수,  $W_{ji}$ 는 입력층과 은닉층 사이의 연결강도,  $x_{pi}$ 는 패턴  $p$ 에 대한  $i$ 번째 값, 그리고  $g(net_{pi})$ 는 뉴런의 활성화함수이다.

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

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

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

여기서,  $M$ 은 은닉단위의 수,  $W_{kj}$ 는 출력층의  $k$ 와 은닉층 노드  $j$ 와 연결되는 연결강도, 그리고  $P_{pk}$ 는  $k$  번째의 예측 출력값이다.

chain rule을 사용하여  $E$ 을 연결강도에 대한 일차 편미분으로 나타내면, 연결강도는 급강하 방향으로 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 학습율로서 스칼라이다.

본 모형에서는 최적화기법인 경사하강법에 학습과정에서 발생할 수 있는 지역 최소값 (local minima value) 문제와 오차를 최소화하고 수렴속도를 향상시키기 위해 모멘트법 (momentum)과 적응학습율 (adaptive learning rate)을 고려하였다.

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

$$BIC = M \ln(MSE) + P \ln M \quad (8)$$

여기서,  $M$ 은 신경망의 자료수,  $MSE$ 는 평균자승오차, 그리고  $P$ 는 매개변수의 수(weights and biases)를 나타낸다.

은닉층의 최적 노드수를 얻기 위한 stopping rule은 다음 식 (9)와 같이 구성하였다.

$$\left| \frac{BIC(k+1) - BIC(k)}{BIC(k)} \right| \leq 0.001 \quad (9)$$

본 모형의 수행 정도를 평가하기 위하여 Nash와 Sutcliffe (1970)가 제안한 효율지수 (Efficiency Index, EI)를 사용하였다. 효율지수는 식 (10)과 같이 나타내어진다.

$$EI = (ST - SE)/ST \quad (10)$$

$$ST = \sum_{i=1}^N (Q_i - \bar{Q})^2 \quad (11)$$

$$SE = \sum_{i=1}^N (Q_i - F_i)^2 \quad (12)$$

여기서, ST는 분산의 합, SE는 실측치와 모의치의 자승오차의 합이다.

### 3. 모형의 입출력 자료

모든 자료는 이론적인 정규화 범위인 [0, 1]대신에 [0.05, 0.095] 범위로 변환하였으며, 식(13)과 같다.

$$X' = 0.05 + 0.90 \left[ \frac{1}{(X_{\max} - X_{\min})} \right] \times (X - X_{\min}) \quad (13)$$

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

식(13)을 변환하여 일별 유량값으로 모의할 경우, 유량의 최소값과 최대값에 제한요소가 나타나므로, 좀 더 큰 범위를 나타내기 위한 방법들을 사용할 수 있다 (Huynh, 2000). 본 연구에서의 최소값과 최대값은  $[0.8Q_{\min}, 1.2Q_{\max}]$ 의 범위를 적용하였다. 본 모형의 입력층은 강우와 유출량의 함수로 구성하였다.

## III. 결과 및 고찰

### 1. 시험유역 및 수문자료

본 연구의 시험유역은 경기도 화성군 봉담읍과 팔탄면에 위치한 밭안저수지와 기천저수지를 포함하고 있는 밭안유역을 선정하였다. 밭안유역은 1996년부터 서울대학교 농공학과에서 수문 및 수질 모니터링을 실시하고 있는 유역으로서 6개의 소유역으로 구분하였으며, 이 중에서 강우에 따른 유출특성이 민감하게 나타나고 있는 HS#3 소유역의 일유출량 자료를 이용하여 모형을 적용하였다. HS#3 소유역은 유역면적은 412.5 ha이고, 토지이용상태는 논이 26.3 %, 밭이 9.6 %, 산림이 58.1 %, 그리고 주거지 등 기타가 6.1 %로 구성되어 있는 전형적인 농업유역이다.

유역의 강우량 자료는 시험유역 현장에 설치되어 있는 디지털 강우계를 이용하여 10분 단위의 강우자료를 사용하였고, 결측자료는 수원기상대 강우자료와의 상관관계를 이용하여 보완하였다. 유출량 자료는 현장에 설치된 자기수위계와 압력식 수위계로부터 수위-압력관계 및 수위-유량관계를 이용하여 일유량을 산정하였다.

본 연구의 자료기간은 1996년부터 2000년의 자료를 이용하였다. 본 모형의 학습은 1996년과 1997년 자료를 이용하여 보정하였고, Testing 자료는 1999년 유출량 자료를 이용하여 검정하였다.

그림2는 1998년의 대홍수에 의한 하상변동 전후의 수위-압력관계를 보여주고 있다. 수위-유량관계식의 결정계수는 1996-1998년이 0.913, 1999-2000년은 0.9875의 값을 보였다.

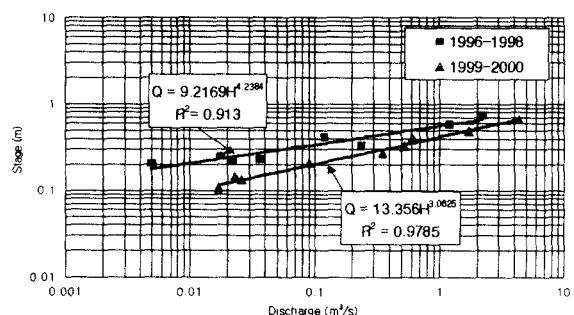


그림2. 수위-유량 관계 (HS#3)

## 2. 모형의 보정

모형의 보정을 위한 학습자료는 1996년 4월부터 1997년 12까지의 자기수위계에서 습득한 일 유출량 자료를 이용하였다. 은닉층의 최적 노드수를 결정하기 위하여 은닉층의 노드수를 1~21까지 변환시키면서 학습을 수행하였다.

그림3과 그림4는 은닉층의 노드수에 따른 총오차, 자승오차, 그리고 모형의 효율지수를 보여주고 있다. 그림3에서와 같이 은닉층의 노드수에 따른 총오차는 0.043~0.132의 범위를 보였으며, 노드수가 13일 때 가장 작은 값을 나타냈다. 모형의 효율지수는 은닉층의 노드수가 13일 때 가장 큰 0.95의 값을 나타냈으며, 전체적으로 0.83~0.95의 값을 보였다. 자승오차합은 0.1 2~0.43의 범위를 보였다. 그림4에서 보듯이 은닉층의 노드수에 대한 학습횟수에 따른 총오차의 변화를 보면, 노드수가 13일 때 최종적으로 가장 작은 값을 보이고 있다. 그러나, 6000회 학습까지는 노드수가 6일 때 보다 큰 오차를 보이고 있다. 또한, 노드수 6일 때와 13일 때는 최종 학습 결과의 총오차와 모형의 효율지수가 거의 차이가 없었다. 이러한 현상은 차후에 검정과정에서 적절한 모의를 나타내는데 문제가 있으므로 본 모형에서는 은닉층의 최적 노드수를 6으로 하였다.

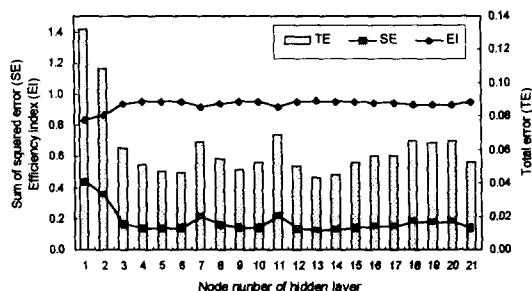


그림3. 은닉층 노드수에 따른 학습결과

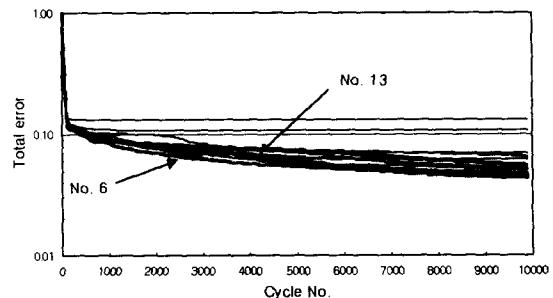


그림4. 은닉층 노드수에 따른 총오차

모형의 은닉층의 최적 노드수를 6으로 하여 HS#3 소유역에 대하여 강우에 따른 일유출량을 모의한 결과는 그림5에서와 같다. 모형의 효율지수는 0.982의 값을 나타냈고, 그림5에서와 같이 모의결과가 실측자료의 경향을 잘 따라가도록 학습되었음을 알 수 있다. 그림6은 학습결과와 실측자료의 산포도를 나타내고 있다. 모형의 실측치와 모의치의 상관계수는 0.992로서 양호한 결과를 나타내었다.

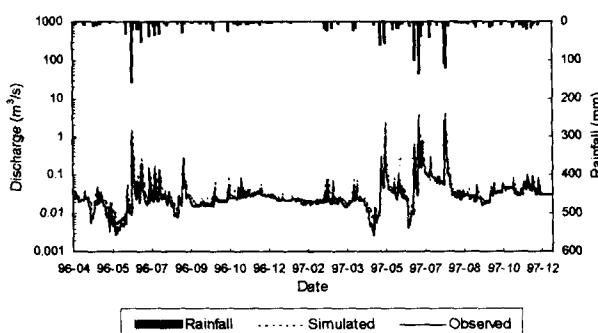


그림5. 학습시 모의치와 실측치의 비교

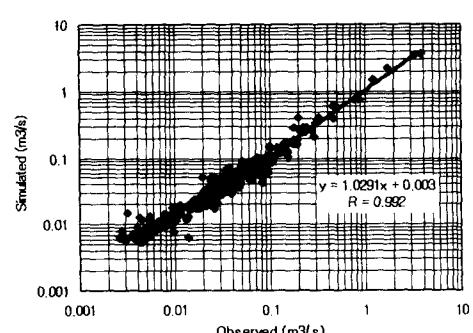


그림6. 실측치와 모의치의 산포도

### 3. 모형의 검정

Testing 자료는 1999년 1월부터 1999년 11월까지의 압력식 수위계로부터 얻어진 일유출량 자료를 이용하였다. 모형의 검정 결과, 모형의 효율지수는 0.723, 상관계수는 0.945의 값을 보였다.

그림7은 강우에 대한 Testing 결과값과 실측치를 비교한 것이고, 그림8은 모형의 검정에 대한 실측치와 모의치의 산포도를 나타내고 있다.

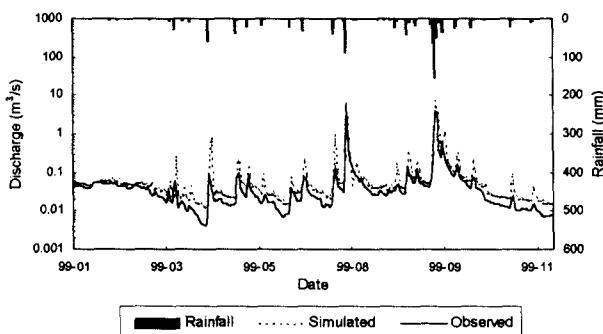


그림7. 검정시 모의치와 실측치의 비교

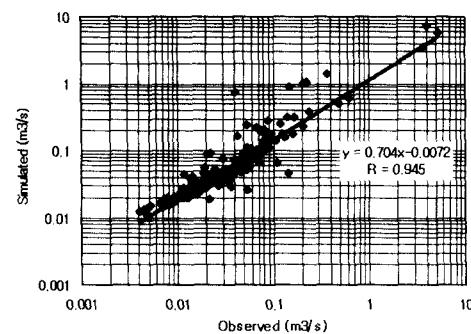


그림8. 실측치와 모의치의 산포도

## IV. 요약 및 결론

본 연구에서는 신경망이론의 오류역전파 알고리즘을 이용한 일별 장기유출예측모형을 구성하였고, 개발된 모형을 시험유역인 발안유역의 HS#3 소유역에 적용하여 보정과 검정을 수행하였으며, 그 결과를 고찰하였다. 본 연구의 결과를 정리하면 다음과 같다.

- 1) 신경망이론인 오류역전파 알고리즘에 의한 일별 장기유출예측모형을 구성하였다.
- 2) 은닉층의 노드수에 따른 총오차는 0.043~0.132의 범위를 보였고, 모형의 효율지수는 0.83~0.95의 값을 보였으며, 자승오차합은 0.12~0.43의 값으로 나타났다. 모형의 은닉층 최적 노드수는 오차와 모형효율지수를 고려하여 6으로 결정하였다.
- 3) 모형의 보정 결과, 모형의 효율지수는 0.982, 상관계수는 0.992의 값을 나타냈다.
- 4) 모형의 검정 결과, 모형의 효율지수는 0.723, 상관계수는 0.945의 값을 보였다.

## 참고문현

1. 김주환, 1993. 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구, 인하대학교 박사학위논문.
2. 안경수, 김주환, 1998. 신경회로망을 이용한 유출수문곡선 모의에 관한 연구, 수자원학회지논문집, 제31권 제1호, pp. 13~25.
3. Sajikumar, N. and Thandaveswara, B. S., 1999. A nonlinear rainfall-runoff model using ANN, Journal of Hydrology, Vol. 216, pp. 32~55.
4. Sureerattanar, S. and Phien, H. N., 1997. Back-propagation networks for daily stream flow forecasting, Water Resources Journal No. 195, pp. 1~7.
5. Zealand, C. M., Burn, D. H., and Simonovic, S. P., 1999. Short term stream flow forecasting using ANN, Jour. of Hydrology, Vol., 214, pp. 32~48.