

인공신경망 이론을 이용한 소유역에서의 장기 유출 해석

Forecasting Long-Term Steamflow from a Small Watershed Using Artificial Neural Network

강 문 성* · 박 승 우**
Kang, Moon Seong · Park, Seung Woo

Abstract

An artificial neural network model was developed to analyze and forecast daily steamflow from a small watershed. Error Back propagation neural networks (EBPN) of daily rainfall and runoff data were found to have a high performance in simulating streamflow. The model adopts a gradient descent method where the momentum and adaptive learning rate concepts were employed to minimize local minima value problems and speed up the convergence of EBP method. The number of hidden nodes was optimized using Bayesian information criterion. The resulting optimal EBPN model for forecasting daily streamflow consists of three rainfall and four runoff data (Model34), and the best number of the hidden nodes were found to be 13. The proposed model simulates the daily streamflow satisfactorily by comparison compared to the observed data at the HS #3 watershed of the Baran watershed project, which is 391.8 ha and has relatively steep topography and complex land use.

I. 서 론

소유역에서의 장기유출은 시간적 공간적 변동이 심한 기상인자와 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 불확

실한 매개변수 등 때문에 모형과 실측치간에 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 있다. 인공신경망 이론은 인간의 정보처리 과정을 공학적, 수학적으

*서울대학교 대학원(박사수료)

**서울대학교 농업생명과학대학

키워드 : 인공신경망, 장기유출, 강우유출, 소유역

로 모델링한 것으로서, 어떤 시스템의 인과관계를 연상기억능력을 이용하여 인식할 수 있도록 한 블랙박스 모형이다. 인공신경망은 그 모형 자체의 비선형성 (nonlinearity)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 전산화적 병렬계산이 가능하여 그 처리가 합리적인 병렬성 (parallel property) 등의 장점을 지니고 있다.

김주환 등(1992, 1993, 1998)은 신경회로망의 역전과 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. 외국의 경우, Anmala 등(1995), Anthony 등(1996), Sureerattana 등(1997), Dawson 등(1998), Sajikumar 등(1999), 그리고 Zealand 등(1999) 많은 연구자들이 신경망 이론을 이용하여 강우에 따른 유출을 해석하고자 하였다.

신경망 이론의 수문계의 적용에 있어서는 아직 학습방법에 따른 최적해를 구하는 데 한계가 있으며, 그 적용의 정규화가 미흡하다는 단점도 지니고 있다. 따라서 신경망의 여러 문제들을 해결하기 위해서는 수문계의 다양한 적용을 통한 검토가 이루어져야 할 것이다. 현재 신경망 이론을 이용한 수자원분야에의 응용은 강우-유출 해석과 강우분포, 지하수 유동과 관련하여 활발하게 적용되고 있으나, 시공간적 변화가 심한 소유역에서의 적용은 미진한 상태이다.

따라서, 본 연구의 목적은 신경망 이론을 이용한 소유역에서의 장기유출을 해석하기 위하여, 신경망 이론 중 모멘트법과 학습적응도를 고려한 오류역전과 알고리즘에 의한 일별 장기유출예측모형을 구성하고, 시험유역에 개발된 모형을 적용하여 그 결과를 고찰함으로써 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. Fig. 1은 인간의 두뇌를 모델링한 기본적인 신경망 단일소자인 뉴런의 구조를 나타내고 있다.

모형에서의 연산과정은 Fig. 1에서와 같이 입력자료 (input signal)인 x 와 연결강도 (synaptic weights)의 벡터인 w 에 의한 곱의 형태로 나타내어지는 결합함수 (summing junction)인 Σ 가 계산된다. 이 결합함수로부터 출력이 선형 또는 비선형적인 특성을 가지게 하는 활성화함수 (activation function)을 통해 출력의 과정으로 연산이 수행되어진다.




Fig. 1 Architecture of artificial neural network




Fig. 2 Construction of multilayer neural network

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. Fig. 2는 다층신경망의 구조를 보여주고 있다.

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

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

여기서, E는 총오차, n은 실측치의 패턴 수, m은 총 출력단위, y_{pk} 는 실측된 반응인 목표출력값으로서 일 유출량, d_{pk} 는 모델에 의한 모의 출력값으로서 일 모의유출량을 나타내며, 식 (1)이 하나의 출력단위를 갖는 경우 (m=1)는 다음과 같이 나타내어진다.

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

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

$$net_{pj} = \sum_{i=1}^N W_{ji} x_{pi} \dots\dots\dots (3)$$

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

여기서, net_{pj} 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 $g(net_{pj})$ 는 뉴런의 활성화함수이다.

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

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

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

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

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

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

여기서, η 는 학습률로서 스칼라이다.

본 모형에서는 최적화기법인 경사하강법에 학습과정에서 발생할 수 있는 지역 최소값 (local minima value) 문제와 오차를 최소화하고 수렴속도를 향상시키기 위해 식 (7)에서의 적응학습률 (adaptive learning rate)에 모멘텀법 (momentum)을 고려하였으며, 식 (8)과 같이 나타내어진다.

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

여기서, $\Delta W_{kj}(t+1)$ 는 연결강도의 조정량, δ_{pk} 는 p번째 패턴에 대한 출력층의 오차, α 는 모멘텀 계수이다. 모멘텀 계수는 0에서 1 사이의 값을 가지며, Pahan Pao에 의하면 실험적으로 제한된 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 확

인하여 증감시킴으로써 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.

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

여기서, M은 신경망의 자료수, MSE는 평균자승오차, 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.

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

본 모형의 수행 정도를 평가하기 위하여 Nash와 Sutcliffe (1970)가 제안한 효율지수 (Efficiency Index, EI)를 사용하였다. 효율지수는 식 (11)과 같이 나타내어진다.

$$EI = (ST - SE) / ST \dots\dots\dots (11)$$

$$ST = \sum_{t=1}^N (Q_t - \bar{Q})^2 \dots\dots\dots (12)$$

$$SE = \sum_{t=1}^N (Q_t - F_t)^2 \dots\dots\dots (13)$$

여기서, Q_t 는 t일의 실측유량, \bar{Q} 는 실측유량의 평균값, F_t 는 t일의 모의유량값, ST는 분산의 합, SE는 실측치와 모의치의 자승오차의 합이다.

3. 모형의 입출력 자료

본 모형의 시그모이드 함수는 최소값 0과 최대값 1을 전달하므로 모든 자료는 이론적인 정규화 범위로 변환하였으며, 식 (14)과 같다.

$$X' = \left[\frac{1}{(X_{max} - X_{min})} \right] \times (X - X_{min}) \dots\dots (14)$$

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

식 (14)를 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 $range[0.8Q_{min}, 1.2Q_{max}]$ 의 범위를 적용하였다.

본 연구에서는 모형의 입력층에서의 선행 강우량과 일유량을 고려하여 여러 형태의 모형을 구성하였으며, 최적 모형으로 Model23 모형과 Model34 모형을 선정하였다. Model23 모형은 일강우량 시계열 2개 변수와 일유량 시계열 3개 변수로 구성하였으며, Model34 모형은 일강우량 시계열 3개 변수와 일유량 시계열 4개 변수로 구성하였다. 구성된 각 모형의 식은 다음과 같다.

$$\begin{aligned} \text{Model23; } Q(t) &= \text{funtion}(R(t), R(t-1), \\ &Q(t-1), Q(t-2), Q(t-3)) \\ &\dots\dots\dots (13) \end{aligned}$$

$$\begin{aligned} \text{Model34; } Q(t) &= \text{funtion}(R(t), R(t-1), \\ &R(t-2), Q(t-1), Q(t-2), \\ &Q(t-3), Q(t-4)) \dots\dots\dots (14) \end{aligned}$$

여기서, Q(t)는 t일의 유량, R(t)는 t일의 강우량이다.

III. 결과 및 고찰

1. 시험유역 및 수문자료

본 연구의 시험유역은 경기도 화성군 봉담읍과 팔탄면에 위치한 발안저수지와 기천저수지를 포함하고 있는 발안유역을 선정하였다. 발안유역은 1996년부터 서울대학교 농공학과에서 수문 및 수

질 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 391.8 ha이고, 토지이용상태는 논 17.6 %, 밭 13.5 %, 산림 60.8 %, 그리고 주거지 등 기타 8.1 %로 구성되어 있는 농업유역이다. Fig. 3은 대상유역의 소유역 구분도와 수문관측망을 보여주고 있다.

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, 검정 자료는 1999년과 2000년도의 유출량 자료를 이용하여 검정하였다.




Fig. 3 Location map of the study watershed




Fig. 4 Stage-discharge relationships (HS#3)

Fig. 4는 1998년의 대홍수에 의한 하상변동 전후의 수위-압력관계를 보여주고 있다. 수위-유량 관계식의 결정계수는 1996-1998년이 0.913, 1999-2000년은 0.9875의 값을 보였다.

2. 모형의 보정

모형의 보정을 위한 학습자료는 1996년 4월부터 1997년 12월의 일유출량 자료를 이용하였다. Model23과 Model34에 대해 은닉층의 최적 노드수를 결정하기 위하여 각 모형의 은닉층의 노드수를 1~21까지 변환시키면서 10,000회 반복하여 학습을 수행하였다.

Fig. 5와 Fig. 6은 각각 Model23과 Model34의 은닉층의 노드수에 따른 총오차(total error, TE), 자승오차(sum of squared error, SE), 그리고 모형의 효율지수(efficiency index, EI)를 보여주고 있다.

은닉층의 노드수에 따른 모형의 학습 결과, Model23은 Fig. 5에서와 같이 은닉층의 노드수에 따른 총오차는 0.059~0.137의 범위를 보였으며, 노드수가 13일 때 가장 작은 값을 나타냈다. 모형의 효율지수는 은닉층의 노드수가 19일 때 가장 큰 0.944의 값을 나타냈으며, 13일 때는 0.942였으며, 전체적으로 0.819~0.944의 값을 보였다. 자승오차합은 0.148~0.466의 범위를 보였다. Model34의 경우, 은닉층의 노드수에 따른 총오차는 노드수가 13일 때 가장 작은 값을 나타냈으며, 전체적으로 0.043~0.132의 범위를 보였다. 모형의 효율지수는 0.83~0.95의 값을 보였으며, 은닉층의 노드수가 13일 때 가장 큰 0.95의 값을 나타냈다.




Fig. 5 Training results according to number of nodes of hidden layer (Model23)




Fig. 6 Training results according to number of nodes of hidden layer (Model34)

자승오차합은 0.12~0.43의 범위를 보였다.

이상에서와 같이, Model34가 Model23에 비해 학습이 효과적으로 수행되었음을 알 수 있으며, Model23과 Model34의 은닉층에서의 최적노드수는 13으로 나타났다.

따라서, 본 연구에서는 Model23과 Model34의 학습결과를 바탕으로 모형의 보정에는 Model23에 은닉층의 최적노드수가 13인 Model23-h13 모형과 Model34의 은닉층 최적노드수가 6과 13일 때인 Model34-h6 모형 및 Model34-h13 모형으로 구성하였다.

Fig. 7은 구성된 모형을 적용하여 강우에 따른 일유출량을 학습한 모의치와 결과값을 비교하여 보여주고 있으며, Fig. 8은 실측치와 모의치의 산포도를 나타내고 있다. Fig. 7에서와 같이 모의결과가 실측자료의 경향을 잘 따라가도록 학습되었음을 알 수 있다.

Table 1 The results of comparison for each models

Item	Model23-h13	Model34-h6	Model34-h13
RB(m ³ /s)	0.063	0.082	0.066
RMSE(m ³ /s)	0.031	0.031	0.024
RMAE(m ³ /s)	0.164	0.164	0.143
R ²	0.983	0.985	0.991
R	0.991	0.992	0.995
EI	0.982	0.982	0.989

각 모형을 적용하여 얻어진 실측치와 모의치를 비교한 결과는 Table 1에서와 같다. 구성된 모형별 실측치와 모의치를 비교한 결과, 상대오차 (relative bias, RB)는 Model23-h13이 0.063 m³/s로 가장 작은 값을 보였고, RMSE(root mean square error)와 RMAE(relative mean absolute error)는 Model34-h13모형이 각각 0.024, 0.143 m³/s로서 가장 작은 값을 나타내었다. 결정계수 R²(coefficient of determination)의 값은 모형별로 0.98~0.99의 범위를 보였고, 상관계수 R(correlation coefficient)은 세 모형 모두 0.99의 값을 보였으며, 모형의 효율성을 나타내는 효율지수 (efficiency index, EI)는 모형별로 0.982~0.989의 범위를 보임으로서 학습의 결과가 양호한 것으로 나타났다. 이상의 결과로 볼 때, Model34-h13, Model34-h6, 그리고 Model23-h13 모형의 순서로 실측치를 가장 잘 모의하는 것으로 나타났다.

3. 모형의 검정

학습결과를 바탕으로 Model34-h6과 Model34-h13을 최적 모형으로 선정하였으며, 이를 검정에 이용할 모형으로 결정하였다. 검정자료는 1999년 1월부터 2000년 8월까지의 압력식 수위계로부터 얻어진 일유출량 자료를 이용하였다.

Model34-h6과 Model34-h13모형을 자료기간의 강우에 대해 적용한 결과와 실측치를 비교한 결과는 Fig. 9에 나타내고 있으며, Fig. 10은 각 모형의 검정에 대한 실측치와 모의치의 산포도를 나타






Fig. 7 Observed and simulated daily discharge






Fig. 8 Scatter diagram for each model

내고 있다. Fig. 10에서와 같이, 홍수기에 대해서는 많은 차이를 보이고 있는데, 이는 선정된 소유역이 도시화가 진행되고 있어 불규칙한 도시 하수가 유입되는 지역이고, 소유역의 특성상 홍수기 및 갈수기에 따른 자료의 변화에 영향을 많이 받아 변동이 심한 패턴을 학습하는데 어려움이 있음을 알 수 있다. 그러나 Fig. 9에서 보듯이, 전체적

인 경향성은 잘 나타내고 있다.

Model34-h6과 Model34-h13을 검정한 결과는 Table 2에서 보는 바와 같다. Table 2에서와 같이, Model34-h6의 검정 결과, 상대오차가 0.135 m^3/s 로서 Model34-h13의 0.169 m^3/s 보다 작은 값을 보였으나, RMSE와 RMAE는 Model34-h13이 각각 0.185, 0.293 m^3/s 으로서 양호한 결과를 보였다.




Fig. 9 Observed and simulated daily discharge

Model23-h6의 결정계수 R^2 과 상관계수 R은 각각 0.915, 0.956의 값을 보였으며, Model34-h13은 각각 0.924와 0.961의 값을 나타내었다.

Table 2 The results of comparison for each models

Item	Model34-h6	Model34-h13
RB(m ³ /s)	0.135	0.169
RMSE(m ³ /s)	0.198	0.185
RMAE(m ³ /s)	0.331	0.293
R^2	0.915	0.924
R	0.956	0.961
EI	0.550	0.679

IV. 요약 및 결론

본 연구에서는 신경망이론의 오류역전파 알고리즘을 이용한 일별 장기유출예측모형을 구성하였고, 개발된 모형을 시험유역인 발안유역의 HS#3

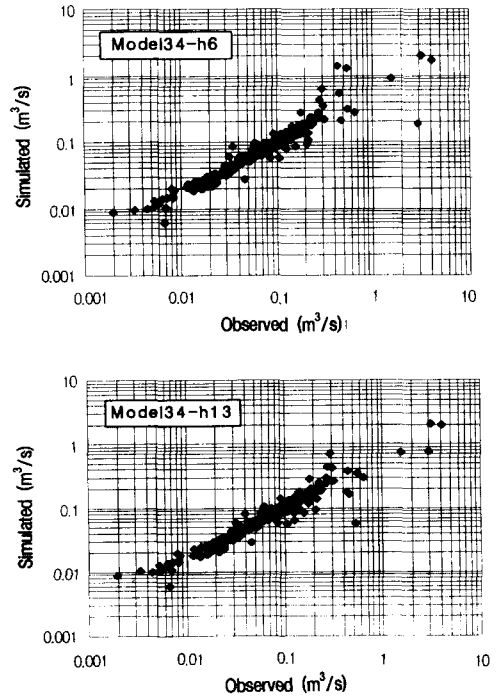


Fig. 10 Scatter diagram for each model

소유역에 적용하여 보정과 검정을 수행하였으며, 그 결과를 고찰하였다. 본 연구의 결과를 정리하면 다음과 같다.

1) 신경망 이론의 학습률과 모멘텀 계수를 고려한 오류역전파 알고리즘을 이용한 일별 장기유출 예측모형을 구성하였으며, 입력층의 노드수를 고려하여 Model23과 Model34모형을 구성하였다.

2) 은닉층의 노드수에 따른 Model23과 Model34 모형의 학습 결과, Model23 모형은 은닉층의 노드수가 13일 때의 오차가 가장 작은 0.059로 나타났고, Model34 모형은 은닉층의 노드수가 6일때와 13일 때 가 각각 0.46과 0.43으로 가장 작은 값을 보임으로서, 은닉층의 최적 노드수는 Model23 모형이 13, Model34 모형은 6과 13으로 나타났다.

3) Model23-h13, Model34-h6, 그리고 Model34-h13 모형을 적용한 결과, 상대오차는 Model23-h13이 0.063 m³/s로 가장 작은 값을 보였고, RMSE는 Model34-h13모형이 0.024 m³/s로서 가장 작은 값을 나타내었다. 결정계수 R^2 값은 모형별로 0.98~

0.99의 범위를 보였고, 효율지수는 모형별로 0.982~0.989의 범위를 보임으로서 학습의 결과가 양호한 것으로 나타났으며, Model34-h13, Model34-h6, 그리고 Model23-h13 모형의 순서로 실측치를 가장 잘 모의하는 것으로 나타났다.

4) 학습결과를 바탕으로 최적 모형은 Model34-h6과 Model34-h13 모형이 선정되었으며, 두 모형을 적용한 검정 결과, Model34-h6 모형은 상대오차가 $0.135 \text{ m}^3/\text{s}$ 로서 Model34-h13 모형의 $0.169 \text{ m}^3/\text{s}$ 보다 작은 값을 보였으나, RMSE는 Model34-h13이 $0.185 \text{ m}^3/\text{s}$ 로서 양호한 결과를 보였고, Model34-h6의 결정계수 R^2 은 0.915, Model34-h13은 0.924의 값을 나타내었다.

본 연구는 농림기술관리센타의 농림특정연구과제 "농업생태환경모니터링 및 종합적 환경관리시스템 개발 사업"의 농업특별세 지원으로 수행되었음.

참 고 문 헌

1. 김주환, 1993. 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구, 인하대학교 박사학위논문.
2. 신현석, 1998. 인공신경망의 수자원 및 환경분야에의 응용, 한국수자원학회지, 제31권 제1호, pp. 97-103.
3. 신현석, 박무종, 1999. 신경망 기법을 이용한 연평균 강우량의 공간 해석, 한국수자원학회지 논문집, 제32권 제1호, pp. 3-13.
4. 신현석, 박무종, 1999. 신경망을 이용한 우리나라의 시공간적 가뭄의 해석, 수자원학회지논문집, 제32권 제1호, pp. 15-29.
5. 심순보, 김만식, 심규철, 1998. 신경망이론에 의한 다목적 저수지의 홍수유입량 예측, 한국수자원학회논문집, 제31권 제1호, pp. 45-57.
6. 안경수, 김주환, 1998. 신경회로망을 이용한 유

- 출수문곡선 모의에 관한 연구, 수자원학회지논문집, 제31권 제1호, pp. 13-25.
7. Anmala, J., Nedunuri, K. V., 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.
8. Anthony, W. M., 1996. Extended rainfall-runoff modeling using artificial neural networks, Proc. of the 2nd International Conf. on Hydroinformatics, '96, Zurich, Switzerland, pp. 207-213.
9. Dawson, C. W., and Wilby, R. 1998. An artificial neural network approach to rainfall-runoff modeling, Hydrological Sciences, Vol. 43, No. 1, pp. 47-66.
10. 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
11. Nash, J. E. and J. V. Sutcliffe, 1970. River flow forecasting through conceptual models part I-A discussion of principles, Journal of Hydrology. Vol. 10, pp. 282-290.
12. Sajikumar, N. and Thandaveswara, B. S., 1999. A nonlinear rainfall-runoff model using ANN, Journal of Hydrology, Vol. 216, pp. 32-55.
13. Sureerattanan, S. and Phien, H. N., 1997. Back-propagation networks for daily stream flow forecasting, Water Resources Journal No. 195, pp. 1-7.
14. 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.