

인공지능기법을 이용한 하천유출량 예측에 관한 연구

안 승 섭 · 신 성 일* · 정 순 돌*
경일대학교 건설정보공학부 · *경일대학교 대학원 건설정보공학부
(2004년 5월 6일 접수; 2004년 7월 9일 채택)

Study on Streamflow Prediction Using Artificial Intelligent Technique

Seung-Seop Ahn, Seong-II Shin* and Soon-Dol Jeong*

School of Construction Information Engineering, Kyungil University, Daegu 712-701, Korea

*School of Construction Information Engineering, Graduate School, Kyungil University, Daegu 712-701, Korea

(Manuscript received 6 May, 2004; accepted 9 July, 2004)

The Neural Network Models which mathematically interpret human thought processes were applied to resolve the uncertainty of model parameters and to increase the model's output for the streamflow forecast model. In order to test and verify the flood discharge forecast model eight flood events observed at Kumho station located on the midstream of Kumho river were chosen. Six events of them were used as test data and two events for verification. In order to make an analysis the Levengerg-Marquart method was used to estimate the best parameter for the Neural Network model. The structure of the model was composed of five types of models by varying the number of hidden layers and the number of nodes of hidden layers. Moreover, a logarithmic-sigmoid varying function was used in first and second hidden layers, and a linear function was used for the output. As a result of applying Neural Networks models for the five models, the N10-6model was considered suitable when there is one hidden layer, and the N10-9-5model when there are two hidden layers. In addition, when all the Neural Network models were reviewed, the N10-9-5model, which has two hidden layers, gave the most preferable results in an actual hydro-event.

Key Words : Streamflow Forecasting, Neural Network Model

1. 서 론

자연하천의 홍수유출자료는 침투, 토양 특성, 상류에서의 수위 등과 같은 변수들의 변동이 비선형으로 하천 홍수량에 많은 영향을 끼치기 때문에 제어점에서 홍수량을 정확히 예측하는 것은 매우 어려운 작업이라고 말할 수 있다. 유역에서의 유출은 매우 복잡하고 불확실한 과정에 의해 진행되며, 이러한 복잡한 과정을 확정적인 모델과 추계학적인 모델로 모의하여 수위와 유량을 예측하는 것은 매우 힘든 일이다. 또한 입력 자료에도 관측의 시간적 간격의 한계 등의 문제가 있어 불확실성을 내포하

고 있다.

모형의 실제 적용시 모형의 불확실성, 입력자료의 불확실성, 매개변수의 불확실성 및 시스템의 초기상태 등으로 인해 모형의 결과 값과 실측자료가 불일치하는 문제가 발생하게 된다. 이와 같은 불확실성에 의한 모형오차를 줄이기 위해 사용하는 매개변수의 추정방법들은 매우 복잡하고 많은 시간을 필요로 하게 된다. 모형의 매개변수 결정에 있어서도 방법상의 문제 외에도 측정이 어려운 자료와 불확실한 자료 등으로 많은 문제점을 가진다. 그러므로 수학적 알고리즘에 대한 적용이 어려운 경우와 유출관계를 하천유역이라는 시스템에서 발생된 신호 체계의 입출력패턴으로 취급하고 인간의 사고과정에 근거를 둔 신경회로망의 수학적 알고리즘을 이용하여 수문계의 예측에 적용할 수 있을 것이다.

Corresponding Author : Seung-Seop Ahn, School of Construction Information Engineering, Kyungil University, Daegu 712-701, Korea
Phone : +82-53-850-7314
E-mail : ahnssso@kiu.ac.kr

신경망에 대한 이론적 개념은 1950년대에 이루어졌으나 입력에서 출력으로의 사상을 학습하는 훈련 방법은 1980년대 이후 컴퓨터의 급속한 발달로 활발히 연구되기 시작하였다. 신경망 이론을 수문학에 도입하려는 시도는 French^{1~3)}에 의한 강우 예측에서 시작되었으며, 그 후 Karunanithi와 Grenney 등⁴⁾은 하천유출예측에 있어서 신경망을 적용하여 분석하였으며, Smith와 Robert⁵⁾는 지류를 포함한 복합하천유역에 신경망모델을 적용하여 유출과정을 시뮬레이션시켜서 그 타당성을 검토하였다. 또한 국내에서는 김주환⁶⁾에 의한 신경회로망을 이용한 일 및 시 유출량 예측, 이남훈 등⁷⁾에 의해 수답증발산량 예측에 대한 신경회로망 이론의 적용가능성 검토, 안승섭 등⁸⁾, 이순탁 등⁹⁾, 심순보 등¹⁰⁾에 의한 유출량 예측, 김성원 등¹¹⁾에 의한 하천수위표지점에서 신경망기법을 이용한 홍수위의 예측 등의 연구가 진행된 바 있다. 최근에는 강문성 등¹²⁾, 윤강훈 등¹³⁾에 의해 인공지능망 이론을 이용한 장기유출해석 및 단기 홍수량 예측에 관한 연구를 실시된 바 있다.

따라서 강우로 인한 하천 유출량 예측의 모형화 과정에서 발생하는 불확실한 모형 매개변수의 가정으로 인한 한계를 극복하고 모형출력의 정도를 높이기 위한 해석방법이 필요하다. 본 연구에서는 기존의 하천유출량예측 모형이 가지는 불확실성 등으로 인하여 유출량 추정과정에서 발생하는 여러 오차요인을 해소하기 위한 방안의 하나로 최근에 소개된 이론인 인공지능기법을 이용하여 하천유출량 예측에 적용하고자 한다.

2. 모형의 기본이론

신경회로망은 생물체의 신경망에서 출발한 것으로, 많은 수의 간단한 프로세서들이 서로 연결되어 있는 병렬 계산 시스템이다. 모형의 학습방법은 지도학습(Supervised learning)과 자율학습법(Unsu-

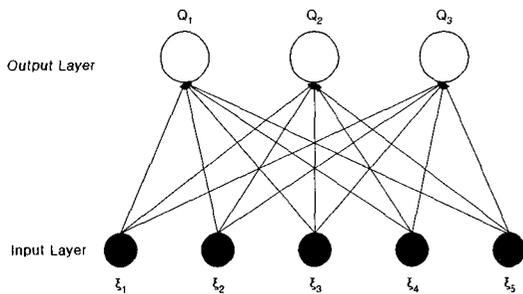
pervised learning)으로 나눌 수 있으며, 지도학습은 출력 값과 비교할 수 있는 기지의 정답이 존재하며 그 오차를 이용하여 학습하는 방법이지만, 자율학습은 교사가 존재하지 않으며 정답이 존재하지 않는다. 그러나 이 방법은 정확한 정보 없이 입력자료의 흥미 있는 범주나 특징을 발견하여 자기조직화에 의해 훈련을 하게 되고 결과를 출력한다.

2.1. 모형의 구조

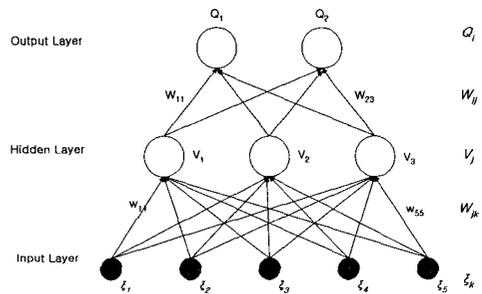
신경회로망 모형의 구조는 Fig. 1과 같이 순방향(Feed-forward)의 단순인식자(Simple Perception) 모형과 이층신경망(Two-layer neural network) 모형으로 나타낼 수 있다. 단순인식자 모형은 Fig. 1(a)와 같이 입력층과 출력층으로 구성되며 그 한계 때문에 입력층과 출력층 사이에 하나 또는 그 이상의 은닉층을 가지는 다층신경망 모형이 제시되었다. 그림에서 출력 성분들은 Q_i , 은닉층의 성분들은 V_j , 그리고 입력자료들은 ξ_k 로 표기하였다. 또한 입력층에서 은닉층으로의 연결강도와 은닉층에서 출력층으로의 연결강도는 각각 W_{jk} 와 W_{ij} 로 표기하였다.

다층 신경망 모형 중 입력층과 출력층 사이에 하나의 은닉층이 존재하는 이층신경망모형의 구조는 Fig. 1(b)와 같이 입력층과 출력층이 존재하고 그 사이에 은닉층이 존재한다. 여기서, 입력층과 출력층은 각각 외부로부터의 입력을 받아들이고 결과를 출력하는 역할을 수행하며, 은닉층은 입력층으로부터 출력층으로의 계산과정에 이용된다. 또한 각 층 사이에는 연결강도가 존재하며 이들은 두 층의 성분들 사이의 연결정도를 나타내며, 입력과 출력값에 따라서 이들 연결강도를 조절해 나간다. 즉, 다층 신경망이란 은닉층의 개수가 2개 이상인 구조로 지금까지의 계산과정을 같은 방법에 의하여 확장할 수 있다.

이층신경망 모형에 의한 입력층에서 출력층으로



(a) A Simple Perceptron



(b) A Two-Layer Neural Network

Fig. 1. Structure of Neural Network Model.

의 계산을 위하여, 입력자료의 서로 다른 패턴을 위치차 μ 에 의하여 구분하면 μ 번째 패턴의 입력자료 중 k 번째 성분은 ξ_k^μ 로 표기되며, 이 경우 은닉층의 j 번째 성분으로의 입력값 h_j^μ 는 식(1)과 같이 계산할 수 있다.

$$h_j^\mu = \sum_k W_{jk} \xi_k^\mu \quad (1)$$

여기서, W_{jk} 는 입력층의 k 번째 성분과 은닉층의 j 번째 성분을 연결하는 강도이다.

실제 신경망의 계산에서는 여기에 성분 θ_j 가 추가되나, 수식을 간단한 형태로 전개하기 위하여 생략하였다. 그리고, 은닉층의 j 번째 성분 V_j^μ 는 전달함수 $g(x)$ 를 통하여 식(2)와 같이 정리된다.

$$V_j^\mu = g(h_j^\mu) = g\left(\sum_k W_{jk} \xi_k^\mu\right) \quad (2)$$

같은 방법에 의하여 은닉층으로부터 출력층에 대한 입력성분은 식(3)과 같이 된다.

$$h_i^\mu = \sum_j W_{ij} V_j^\mu = \sum_j W_{ij} g\left(\sum_k W_{jk} \xi_k^\mu\right) \quad (3)$$

여기서, W_{ij} 는 은닉층의 j 번째 성분과 출력층의 i 번째 성분을 연결하는 강도이고, h_i^μ 는 i 번째 출력층의 성분으로 입력되는 은닉층으로부터의 가중합이다.

식(2)에서 이용된 전달함수를 은닉층에서 출력층으로의 관계에 사용하면 이층 신경망 구조에서 i 번째 출력층의 성분은 식(4)와 같이 되며, 이 관계는 μ 번째 입력패턴 ξ^μ 로부터 이에 따른 i 번째 출력 성분 Q_i^μ 를 계산하는 과정으로써, 입력층과 출력층 그리고 은닉층으로 구성된 이층 신경망 구조의 입력과정을 설명하고 있다.

$$Q_i^\mu = g(h_i^\mu) = g\left(\sum_j W_{ij} V_j^\mu\right) = g\left(\sum_j W_{ij} g\left(\sum_k W_{jk} \xi_k^\mu\right)\right) \quad (4)$$

2.2. 역전파 알고리즘

입출력층으로 구성된 단순인식자 모형의 한계점 때문에 다층신경망은 뛰어난 적용성에도 불구하고 학습방법이 없어 활발한 연구가 진행되지 못하다가 80년대 중반 역전파 알고리즘을 이용한 다층 신경망의 학습방법이 발표되면서 역전파 알고리즘과 그 적용을 위한 활발한 연구가 이루어지고 있다. 역전파 알고리즘은 주어진 입력과 출력에 대한 적절한 연결강도를 구하기 위한 방법이다.

역전파 알고리즘의 네트워크는 입력층, 출력층 및 다수의 은닉층으로 구성되며, 학습과정은 연결과 관련된 값이 적당한 변화를 보이지 않거나 오차함수

의 기준을 만족할 때 중지한다. 즉, 오차함수가 0에 접근할수록 더욱 적절한 신경망이 완성되는 것이며, 역전파 알고리즘에서는 이를 위하여 경사하강(gradient descent) 알고리즘을 이용한다. 경사하강 알고리즘은 오차함수의 최소화를 위하여 가장 널리 쓰이는 방법으로 오차 함수의 경사(gradient)에 비례하여 변수를 조절해 나가게 된다.

은닉층과 출력층사이의 연결강도에 경사하강 알고리즘을 적용하면 역전파알고리즘의 적용에 따른 은닉층과 출력층사이의 연결강도의 조절량 ΔW_{ij} 는 식(5)와 같이 된다.

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}} = \eta \sum_\mu \xi_i^\mu - Q_i^\mu g'(h_i^\mu) V_j^\mu = \eta \sum_\mu \delta_i^\mu V_j^\mu \quad (5)$$

여기서, η 는 학습율(learning rate) 이고, $\delta_i^\mu = g'(h_i^\mu) [\xi_i^\mu - Q_i^\mu]$ 이다. 그리고 입력층과 은닉층의 연결강도의 조절량 ΔW_{jk} 는 연쇄법칙(chain rule)을 적용하면 식(6)과 같이 된다.

$$\begin{aligned} \Delta W_{jk} &= -\eta \frac{\partial E}{\partial W_{jk}} = -\eta \sum_\mu \frac{\partial E}{\partial V_j^\mu} \frac{\partial V_j^\mu}{\partial W_{jk}} \\ &= \eta \sum_\mu \xi_k^\mu - Q_j^\mu g'(h_j^\mu) W_{ij} g'(h_i^\mu) \xi_k^\mu \\ &= \eta \sum_\mu \delta_j^\mu W_{ij} g'(h_i^\mu) \xi_k^\mu = \eta \sum_\mu \delta_j^\mu \delta_k^\mu \end{aligned} \quad (6)$$

여기서, $\delta_j^\mu = g'(h_j^\mu) \sum_i W_{ij} \delta_i^\mu$ 이다.

식(6)에서 은닉층 V_j 와 관련된 δ 의 값을 계산하기 위해서는 출력층 Q_i 로부터의 δ 값들이 필요하다. 입력신호가 신경망에서 입력층으로부터 출력층으로 전파해 가는데 비해 오차의 값들은 역방향으로 출력층에서 입력층으로 전파해 나가기 때문에 식(5)와 식(6)에 의하여 신경망의 연결강도를 조절해 나가는 방법을 오차 역전파(error back propagation) 또는 역전파(back propagation) 알고리즘이라 한다. 결국 역전파 알고리즘은 어떠한 형태의 신경망 구조가 설정되었을 때, 식(5)와 식(6)을 통하여 주어지는 패턴에 적절한 신경망을 학습시키는 과정을 의미한다.

3. 모형의 적용 및 고찰

3.1. 대상유역 및 자료수집

본 연구에서는 하천유출량 예측을 위한 신경회로망을 적용하기 위하여 금호강 중류에 위치한 금호수위표 지점을 대상으로 선정하였다. 연구대상 유역은 Fig. 2에서 나타난 바와 같이 유역면적 920.833km² (금호강 전 유역면적 2,087.9km²의 약 44.1%), 유로연장 64.454km이며, 평면직교좌표계로는 동경 128°41' ~

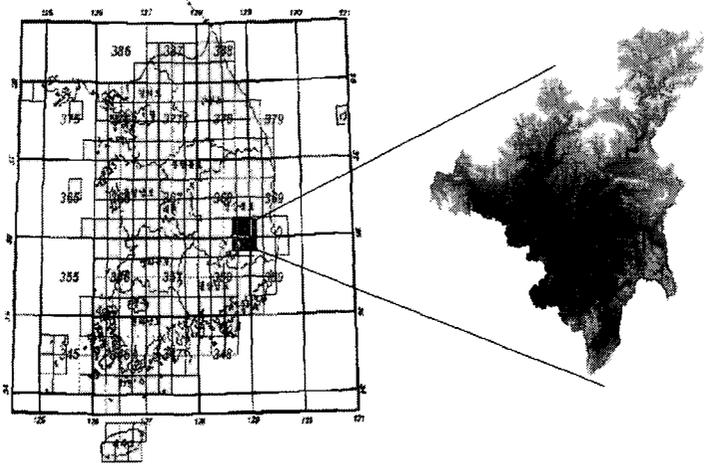


Fig. 2. Location Map of Study Area.

Table 1. Test and Verification Period

Storm No.	Date	Duration (hr)	Total Rainfall(mm)	Remark
1	97. 7. 5 13:00 ~ 7. 8 09:00	69	90	Test data
2	97. 7. 15 16:00 ~ 7. 17 18:00	50	139	"
3	98. 6. 24 21:00 ~ 6. 28 23:00	98	118	"
4	99. 8. 3 05:00 ~ 8. 6 04:00	71	75	"
5	99. 9. 22 03:00 ~ 9. 25 00:00	69	152	"
6	00. 8. 24 17:00 ~ 8. 27 20:00	75	114	"
7	00. 9. 12 17:00 ~ 9. 17 06:00	109	245	Verification data
8	02. 8. 7 19:00 ~ 8. 11 23:00	100	214	"

129°13', 북위 35°49'~36°15'사이에 위치하고 있다.

해석을 위한 수문기상학적 자료는 낙동강 홍수통제소 T/M수위국 및 강우관측소의 실측강우량과 유출량 자료를 수집하여 이용하였으며, Table 1과 같이 최근에 발생한 8개의 주요 호우사상 자료를 이용하였다. 이용된 자료중에서 1997년 7월부터 2000년 8월까지 6개 자료는 학습자료로 이용하였고, 2000년 9월부터 2002년 8월까지 2개 자료는 본 연구에서 설정된 모형의 검증용을 위한 자료로 이용하였다.

3.2. 모형의 적용 및 분석

본 연구에서는 신경회로망 모형을 이용하여 시간 단위로 유출량을 예측하기 위해 선행강우량 및 유출량을 입력변수로 하여 미래의 유출량을 예측하는 모형을 식(7)과 같이 구성하였다.

$$Q(t+1) = f [Q(t), Q(t-1), Q(t-2), Q(t-3), Q(t-4); R(t), R(t-1), R(t-2), R(t-3), R(t-4)] \quad (7)$$

식(7)의 좌변은 현시점에서 1시간 후의 예측된 유

출량이고, 우변은 t를 현시점이라면 4시간 전까지의 5개 계열 유출량과 4시간 전까지의 5개 계열 유역 평균강우량으로 총 10개 계열로 구성하였다.

입력력 변수에 의해 신경회로망에서 추정된 연결강도는 비선형성을 모의하는 예측 모형식의 매개변수 역할을 한다. 입력층 노드(node)수나 은닉층 노드 수에 대한 기존의 연구 결과를 검토하면, Anmala¹⁴⁾는 El Dorado유역에 대한 월유출량 예측을 위한 신경회로망을 은닉층 노드수의 변화에 대해 연구한바 있고, 김주환⁶⁾의 연구에서는 은닉층의 노드수는 입력층 노드수가 d개 일 때 2d+1개로 하였으나 안경수와 김주환¹⁵⁾의 연구에서는 은닉층의 노드수가 12개 이상일 경우 유출모의 결과 향상에 큰 영향이 없다고 결론지은 바 있다. 또한 심순보 등¹⁶⁾의 연구에서도 은닉층의 노드수는 Levenberg-Marquardt방법에 의한 경우 입력층 노드수의 4/5n이 가장 좋다고 결론지은 바 있었다. 이러한 연구 결과로 볼 때, 은닉층 수나 은닉층 노드 수를 결정하기 위한 명확한 기준이 없으므로 본 연구에서는 은닉층 수를 1~2개, 은닉층별 노드수를 3~9개로 변화시켜가면서 5

개의 모형으로 구성하였다. 그러나 양질의 자료를 이용하여 은닉층의 개수 및 적용 노드 수에 따른 유출량 예측의 민감도 변화 등에 대한 계속적인 연구를 통하여 이들의 설정기준을 제안할 필요가 있을 것이라고 판단된다.

하천유역에 집중 호우발생시 유출에 가장 큰 영향을 미치는 인자는 강우량이며, 유출량은 수문학적 지속성이 많은 자료이므로 본 연구에서는 5시간 선행강우량과 5시간 선행 유출량을 입력변수로 하여 1시간 후의 유출량을 예측하기 위해 Table 2와 같이 5개의 기본모형을 구성하였다. 모든 모형에 있어 첫 번째 항은 입력층 노드 수, 두 번째 항은 첫 번째 은닉층의 노드 수, 세 번째 항은 두 번째 은닉층의 노드 수를 나타낸다. 설정된 모형의 은닉층 수와 노드 수에 따른 학습효과를 분석하기 위해 신경회로망 모형에서는 Levengerg-Marquart방법을 이용하였으며, 신경회로망 모형을 20,000번의 반복횟수(epoch)로 실행하였다.

본 연구에서 선정된 신경회로망 모형의 학습 및 검증결과는 실측 홍수유출량과 신경회로망 모형에 의해 예측된 홍수유출량의 통계분석에 의해 평가하였다. 분석에 사용된 통계지표는 Table 3과 같이 5개의 항목을 이용하였다.

Table 3에서 N은 자료의 수, $p = m + (m + n + 1)$ ($h_1 + h_2$)는 신경회로망 모형 및 뉴로-퍼지 모형의 매개변수의 수를 나타내고 있으며, n은 입력층노드 수, h_1 은 첫 번째 은닉층 노드의 수, h_2 은 두 번째

은닉층 노드의 수, m은 출력층 노드의 수를 나타내고 있다. 또한 $y_t(x)$ 는 홍수유출량의 실측자료, $\bar{y}_t(x)$ 는 홍수유출량의 예측자료, μ_y 는 홍수유출량 실측자료의 평균, $\bar{\mu}_y$ 는 홍수유출량 예측자료의 평균, $s(x)$ 는 홍수유출량 실측자료의 표준편차, $\bar{s}(x)$ 는 홍수유출량 예측자료의 표준편차, $\max[y(t)]$ 는 실측 홍수유출량의 값 중에서 최대치를 나타내고 있으며 그때의 $\bar{y}_t(t)$ 는 실측 홍수유출량의 최대치에 대응하는 동일시간대의 예측 홍수유출량을 나타내고 있다.

최적 매개변수에 의해 추정된 신경회로망 모형에 의한 예측 결과는 Fig. 3에 나타낸 바와 같고, 각 모형에 따른 정확성 및 적합도를 분석한 결과 Table 4에 나타낸 바와 같다.

먼저, 모형의 예측오차의 평균오차 ME는 Table 4에 나타낸 바와 같이 본 연구에서 설정된 5개의 모형 즉, N10-3, N10-6, N10-3-3, N10-6-3 및 N10-9-5모형에서 각각 $-16.059 \sim 22.535 \text{ m}^3/\text{s}$, $-8.252 \sim 0.948 \text{ m}^3/\text{s}$, $-8.052 \sim 5.434 \text{ m}^3/\text{s}$, $-6.960 \sim 3.698 \text{ m}^3/\text{s}$, 및 $-7.567 \sim 2.693 \text{ m}^3/\text{s}$ 로서 N10-6모형과 N10-9-5모형에 의한 오차가 비교적 낮게 검토되었다.

다음으로 모형의 평균제곱오차의 평방근 RMSE에 대한 검토결과 본 연구에서 설정된 N10-3, N10-6, N10-3-3, N10-6-3 및 N10-9-5모형에서 각각 $32.740 \sim 157.182 \text{ m}^3/\text{s}$, $31.974 \sim 93.137 \text{ m}^3/\text{s}$, $34.442 \sim 80.733 \text{ m}^3/\text{s}$, $18.674 \sim 40.603 \text{ m}^3/\text{s}$ 및 $11.017 \sim 27.493 \text{ m}^3/\text{s}$ 로 검토되

Table 2. Structure of the neural Network Model

Model	Number of Nodes		Output Layer Node	Learning Number
	1st Hidden Layer	2nd Hidden Layer		
N10-3	3	-	1	20,000
N10-6	6			
N10-3-3	3	3		
N10-6-3	6	3		
N10-9-5	9	5		

Table 3. Indices of Statistical Analysis

Index	Relation
Mean Error, ME	$\frac{1}{N} \sum_{t=1}^N [y_t(x) - \bar{y}_t(x)]$
Root mean square error, RMSE	$\sqrt{\frac{1}{N-p} \sum_{t=1}^N [y_t(x) - \bar{y}_t(x)]^2}$
Peak discharge ratio, Q_{\max}	$\frac{\bar{y}_t(t)}{\max[y_t(x)]} \times 100$
Correlation coefficient, R	$\frac{1}{N} \sum_{t=1}^N \left[\frac{y_t(x) - \mu_t(x)}{s(x)} \right] \left[\frac{\bar{y}_t(x) - \bar{\mu}_t(x)}{\bar{s}(x)} \right]$

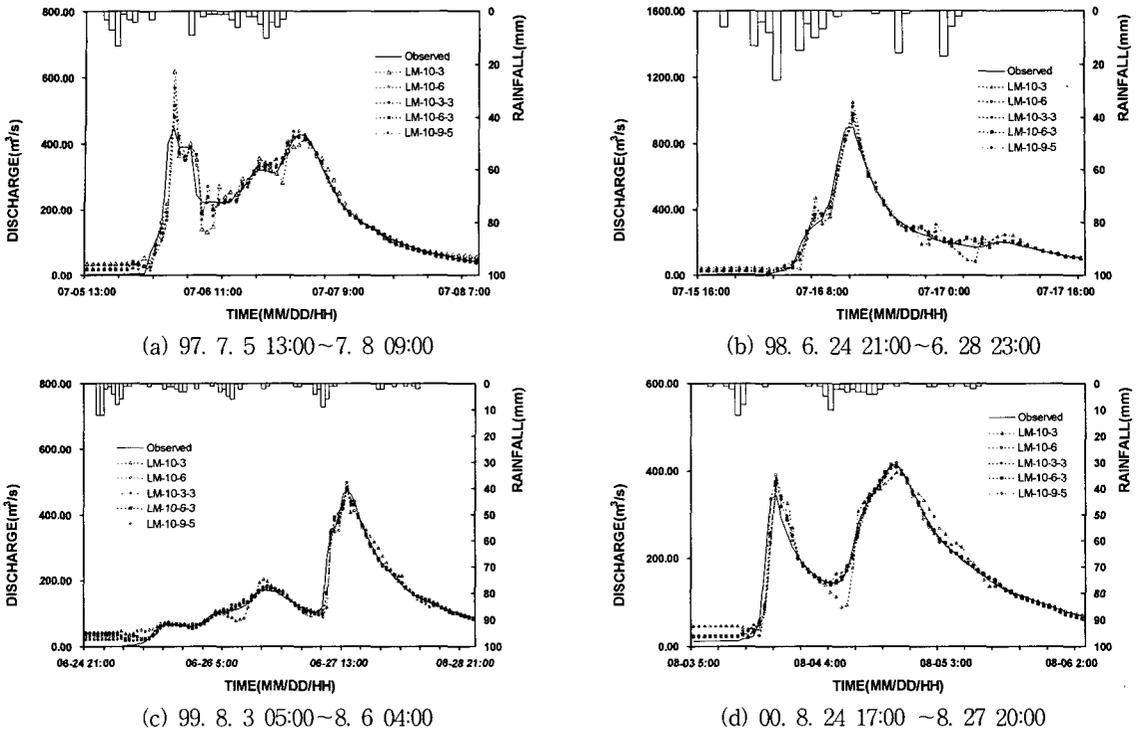


Fig. 3. Comparison of Applying Neural Network Models.

Table 4. Comparison of Statistical Analysis between Applying Neural Network Models

Storm	Model	ME	RMSE	R	Q _{max} (%)
97. 7. 5 13:00 ~7. 8 09:00	N10-3	-3.015	69.336	0.945	138.572
	N10-6	0.671	93.137	0.956	127.345
	N10-3-3	3.624	80.733	0.968	108.176
	N10-6-3	1.039	40.603	0.965	115.512
	N10-9-5	0.604	27.493	0.963	115.966
97. 7. 15 16:00 ~7. 17 18:00	N10-3	0.055	157.182	0.966	116.717
	N10-6	-3.116	31.974	0.993	103.642
	N10-3-3	-8.052	46.138	0.985	113.709
	N10-6-3	-5.554	22.224	0.992	108.903
	N10-9-5	-3.736	15.402	0.993	105.932
98. 6. 24 21:00 ~6. 28 23:00	N10-3	-1.823	32.740	0.974	100.567
	N10-6	-0.545	34.844	0.991	103.463
	N10-3-3	-0.155	34.442	0.991	105.389
	N10-6-3	0.104	36.406	0.990	100.772
	N10-9-5	0.083	17.146	0.990	102.268
99. 8. 3 05:00 ~8. 6 04:00	N10-3	-2.443	41.528	0.972	95.954
	N10-6	0.948	58.842	0.979	101.080
	N10-3-3	2.599	53.270	0.983	100.143
	N10-6-3	1.803	21.723	0.986	98.893
	N10-9-5	1.351	16.204	0.982	100.278
99. 9. 22 03:00 ~9. 25 00:00	N10-3	22.535	114.919	0.976	87.508
	N10-6	0.315	44.293	0.998	95.742
	N10-3-3	5.434	65.059	0.997	95.727
	N10-6-3	3.698	18.674	0.999	95.630
	N10-9-5	2.693	11.360	0.999	96.545
00. 8. 24 17:00 ~8. 27 20:00	N10-3	-16.059	44.947	0.842	122.387
	N10-6	-8.252	44.872	0.983	103.514
	N10-3-3	-5.765	65.186	0.941	115.278
	N10-6-3	-6.960	19.615	0.957	107.895
	N10-9-5	-7.567	11.017	0.971	102.691

Table 5. Statistical Analysis of Estimated Neural Network Model

Storm	Model	ME	RMSE	R	Q_{max} (%)
00.9.12 17:00~9.17 06:00	N10-9-5	1.820	37.426	0.990	98.086
02.8. 7 19:00~8.11 23:00	N10-9-5	7.509	51.715	0.985	103.358

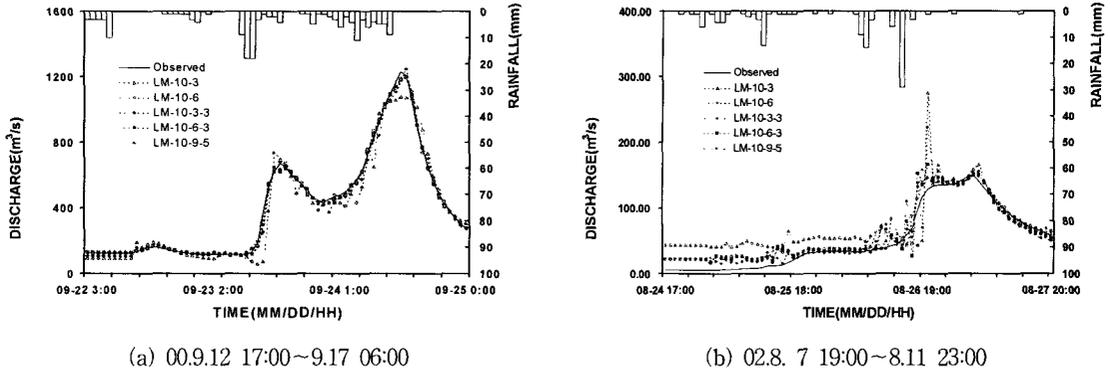


Fig. 4. Forecsated Result One-hour Lead Time.

어 설정된 모형 중에서 N10-9-5모형의 결과가 가장 우수한 것으로 분석되었다.

또한, 첨두유량비 Q_{max} 에 대한 검토결과 N10-3, N10-6, N10-3-3, N10-6-3 및 N10-9-5모형에서 각각 87.508~138.572(%), 95.742~127.345(%), 95.727~115.278(%), 95.630~115.512(%), 및 96.545~115.966%로 검토되어서 첨두유량비의 경우에는 설정된 모형이 거의 비슷한 정도의 결과를 나타내고 있음을 알 수 있었다. 마지막으로 상관계수 R에 대한 검토결과 N10-3모형에서 6번째 호우(2000.8.24 17:00~8.27 20:00)만 0.842를 나타내고 있으나, 모든 호우에 대한 설정모형의 적용 결과 0.941~0.999의 값을 나타내고 있는 것으로 분석되었다.

이상의 검토결과를 볼 때 전체적으로 N10-9-5모형이 다른 신경회로망 모형보다 다소 우수한 것으로 나타났다.

3.3. 모형의 검증 및 고찰

전절에서 결정되어진 신경회로망 모형인 N10-9-5모형을 검증에 이용하였으며, 그 결과 Table 5 및 Fig. 4와 같았다. Table 5 및 Fig. 4에 나타난 바와 같이 2000.9.12 17:00~9.17 06:00 호우사상에서는 ME는 1.820(cms), RMSE는 37.426(cms), Q_{max} 는 98.086(%), R은 0.990를 나타내고 있는 것으로 분석되었으며, 2002.8.7 19:00~8.11 23:00 호우사상에서는 ME는 7.509(cms), RMSE는 51.715(cms), Q_{max} 는 103.358(%), R은 0.985를 나타내고 있는 것으로 분석 검토되었다. 이와 같은 검증 결과를 볼 때 본

연구에서 설정된 신경회로망 모형의 연결강도와 편차는 최적치라고 판단되며, 모형의 검증과정에서도 N10-9-5모형의 우수성을 확인할 수 있었다.

4. 결 론

본 연구에서는 강우-유출과정을 유역이라는 시스템 내에서 발생한 신호체계를 패턴으로 간주하고 모형을 구성하는 각 유닛의 매개변수를 신경회로망을 이용하여 최적화하는 방법으로 실제 수문계에 적용하고 하천유출량 및 강우의 과거 기록치를 이용하여 유출량을 예측하였다.

금호강유역 금호수위표 지점의 홍수량 예측을 위해 8개의 홍수 사상을 선택하였으며, 6개는 모형의 학습자료, 2개는 검증자료로 사용하였다. 신경회로망 모형의 최적 매개변수를 찾기 위해 Levengerg-Marquart방법을 이용하여 은닉층 수와 은닉층 노드수를 변화 시켜 5가지 모형을 구성하였다.

분석결과 5개의 모형중에서 N10-9-5모형의 결과값이 전체적으로 안정된 예측을 하는 것으로 나타났다. 그러나, 본 연구에서 사용된 소규모 자료만으로 모형의 우수성을 판단하기에는 상당히 어려운 점이 많으므로 보다 많은 양질의 자료를 이용한 보완이 필요하다고 사료된다. 특히, 양질의 자료를 이용하여 은닉층의 개수 및 적용 노드수에 따른 신경회로망 모형에 의한 유출량 예측의 민감도 변화 등에 대한 지속적인 연구를 통하여 이들의 설정기준을 제안함으로써 유출예측의 정도를 높일 수 있을 것이라고 판단된다. 또한 본 연구를 기초로 하여 선

행 예측시간과 입력층의 노드수의 변화에 따른 유출 예측의 변화양상 등에 대하여 검토된다면 기존의 홍수유출예측 모형이 가지는 매개변수 추정 의 어려움을 극복할 수 있는 유출예측 모형을 제안할 수 있을 것이다.

참 고 문 헌

- 1) French, M. N., H. Andrieu and W. F. Krajewski, 1994, A Model for Real-Time Quantitative Rainfall Forecasting Using Remote Sensing: 1. Formulations, WRR, 30(4), 1075-1083.
- 2) French, M. N., H. Andrieu and W. F. Krajewski, 1994, A Model for Real-Time Quantitative Rainfall Forecasting Using Remote Sensing: 2. Case Studies, WRR, 30(4), 1085-1097.
- 3) French, M. N., W. F. Krajewski and R. R. Cuykendall, 1992, Rainfall Forecasting in Space and Time Using a Neural Network, Journal of Hydrology, 137, 1-31.
- 4) Karunanithi, N., W. J. Grenney, D. Whitley and K. Bovee, 1994, Neural networks for river prediction, J. of Comp. in Civil Engineering, ASCE, 8(2), 201-220.
- 5) Smith, J. and N. E. Rober, 1995, Neural-Network Models of rainfall-Runoff Process, Journal of Water Resources Planning and Management, ASCE, 121(6), 499-508.
- 6) 김주환, 1993, 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구, 인하대학교 대학원 박사학위논문, 139pp.
- 7) 이남호, 정하우, 1994, 신경회로망을 이용한 수답증발산량 예측, 백프로패게이션과 카운터프로패게이션 알고리즘의 적용, 한국농공학회지, 36(2), 88-95.
- 8) 안승섭, 김성원, 1997, 인공지능기법을 이용한 일유출량의 추계학적 비선형해석, 한국농공학회지, 39(6), 54-66.
- 9) 이순탁, 임기석, 1999, 하천유출 예측을 위한 신경회로망모형, 대한토목학회학술발표회논문집 III, 67-70pp.
- 10) 심순보, 김만식, 1999, 유입량 예측을 위한 신경망 모형과 저류함수 모형의 비교연구, 대한토목학회논문집, 19(II-1), 79-90.
- 11) 김성원, 호세살라스, 2000, 하천수위표지점에서 신경망기법을 이용한 홍수위의 예측, 한국수자원학회논문집, 33(2), 247-262.
- 12) 강문석, 박승우, 2003, 신경망이론을 이용한 단기 홍수량 예측, 한국농공학회지, 45(2), 45-57.
- 13) 윤강훈, 서봉철, 신현석, 2004, 신경망을 이용한 낙동강 유역 하도유출 예측 및 홍수예경보 이용, 한국수자원학회논문집, 37(2), 145-154.
- 14) Anmala, J., K. V. Nedunuri, R. S. Govindaraju and J. K. Koelliker, 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, 348-357pp.
- 15) 안경수, 김주환, 1998, 신경망회로망을 이용한 유출수문곡선 모의에 관한 연구, 한국수자원학회논문집, 31(1), 13-25.
- 16) 심순보, 김만식, 심규출, 1998, 신경망이론에 의한 다목적 저수지의 홍수유입량 예측, 한국수자원학회논문집, 31(1), 45-57.
- 17) Pao, Y. H., 1989, Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Publishing Co., Inc., 269-290pp.