

신경회로망을 이용한 유출수문곡선 모의에 관한 연구

A Study on the Simulation of Runoff Hydrograph by Using Artificial Neural Network

안 경 수* / 김 주 환**

Ahn, Kyoung Soo / Kim, Ju Hwan

Abstract

It is necessary to develop methodologies for the application of artificial neural network into hydrologic rainfall-runoff process, although there is so much applicability by using the functions of associative memory based on recognition for the relationships between causes and effects and the excellent fitting capacity for the nonlinear phenomenon. In this study, some problems are presented in the application procedures of artificial neural networks and the simulation of runoff hydrograph experiences are reviewed with nonlinear functional approximator by artificial neural network for rainfall-runoff relationships in a watershed, which is regarded as hydrologic black box model. The neural network models are constructed by organizing input and output patterns with the observed rainfall and runoff data in Pyoungchang river basin under the assumption that the rainfall data is the input pattern and runoff hydrograph is the output patterns. Analyzed with the results, it is possible to simulate the runoff hydrograph with processing element of artificial neural network with any hydrologic concepts and the weights among processing elements are well-adapted as model parameters with the assumed model structure during learning process. Based upon these results, it is expected that neural network theory can be utilized as an efficient approach to simulate runoff hydrograph and identify the relationship between rainfall and runoff as hydrosystems which is necessary to develop and manage water resources.

Keywords: pattern recognition, artificial neural network, rainfall-runoff model, error back propagation algorithm, runoff hydrograph

요 지

신경회로망은 어떤 사상에 대한 인과관계를 연상기억능력을 통하여 인식할 수 있는 기능을 가지고 있을 뿐 아니라 비선형 현상에 대한 적용능력이 뛰어나 수문계의 강우-유출 현상에 대한 적용가능성은 많으나 이를 수문학적으로 검증하는데는 아직 검토단계라 할 수 있으며 적용에 따른 방법론에 대한 연구가 필요하다 할 수 있다. 본 연구에서는 하천유역에서 호우의 발생에 따른 하천의 홍수유출수문곡선을 모의하기 위한 블랙박스모형으로서 신경회로망이론의 적용에 따른 문제를 수문학적으로 규명하고자 하였다. 이를 위한 방법으로서 홍수발생의 직접적인 원인인 강우패턴을 신경회로망의 입력패턴으로 하고 이에 따른 출력패턴을 유출수문곡선이라는 가정하에 신경회로망모형을 구성하고 평창강유역에서 발생된 과거 홍수기록자료를 이용하여 그 결과를 제시하였다. 본 연구결과에 의하면 신경회로망의 학습이 수행되는 동안 어떠한 형태로든 수문학적 개념을 토대로 구성된 모형의 구조에 잘 적응되고 있음을 알 수 있었다. 이 결과를 토대로 지금까지 복잡한 과정을 거쳐야 하는 강우-유출 모형화 과정에서 발생되는 문제점을 해결할 수 있는 접근방법으로서 활용될 수 있을 것으로 기대된다.

핵심용어 : 패턴인식, 신경회로망, 강우-유출모형, 오차역전파 알고리즘, 유출수문곡선

* 인천대학교 토목·공학과 교수

** 한국수자원공사 수자원연구소 선임연구원

1. 서 론

하천유역에서 호우의 발생에 따른 하천의 유출수문곡선의 예측을 위하여 지금까지 많은 연구가 이루어져 왔으나 유역내 수문순환시스템은 그 자체가 비선형성이 강하고 여러가지 우연성분 및 변동성분을 포함하기 때문에 강우로부터 유출기동을 파악하기에는 많은 어려움을 겪어 왔다. 강우-유출모형으로부터 수문곡선의 예측은 유출량에 관한 정보를 사전에 파악하기 위한 것으로 유역을 하나의 수문시스템으로 간주하여 유역내의 강우량과 하천유출량 또는 예측강우량 등의 관련정보를 근거로 첨두유량과 도달시간, 유속, 위험수위 지속시간 등을 미리 추정함으로써 하류지역의 홍수피해를 최소화하는데 있을 뿐만 아니라 수문학에서 기본적인 문제로서 지금까지 많은 물리적, 수학적 접근이 시도되어 왔다. 강우-유출과정의 모형화 방법으로는 이 관계를 물리적 법칙으로 표현하려는 방법과 첨두유량만을 문제시하여 이를 경험적으로 산정하는 방법, 그리고 입력자료의 획득에 따른 어려움으로 인하여 유역을 시스템으로 하여 입력과 출력에만 의존하여 강우를 유출로 변환시키는 반응함수를 유도하는 블랙박스 모형 등으로 분류된다(윤태훈, 1981).

수문순환과정에서 강우와 이로 인한 응답으로 나타나는 유출현상은 그 과정이 매우 복잡하고 해석하여야 할 물리적 구조가 매우 다양하며 각각의 강우-유출사상에 대한 매개변수들이 사상에 따라 각기 다르게 나타나므로 수문계를 물리적으로 모형화하기는 매우 어렵다. 또한 자연현상으로서 강우-유출사상은 매우 복잡한 양상을 띠고 있으며 자료에 포함된 오차로 인한 왜곡, 자료의 기록년수에 따른 오차와 자료수집과정에서 기타의 잡음으로 인하여 물리적 거동에 대한 수학적 표현방법이 미흡하기 때문에 모형이 설정된다 할 지라도 모형에 대한 매개변수를 모형에 맞도록 추정하기 곤란하다. 따라서 실제 유역에서 발생되는 물리적 현상들을 간략화하여 입력과 출력간의 관계만을 나타낼 수 있는 유역시스템모형이 많이 사용되고 있다.

유출해석은 1932년 Sherman이 선형이론을 근거로 단위유량도법을 발표한 이후 정보제어이론이나 예측이론을 적용함으로써 이루어져 왔으며 이는 강우-유출과정이 결정론적 과정과 확률론적 과정이 복합적으로 구성되어 있어 비선형 제어이론의 도입이 가능하기 때문이다. 유출모형은 현상에 대한 정확성과 간결성 및 가용 입력자료의 확보 등에 따라 선정되지만 호우의 발

생과 더불어 발생되는 홍수량의 가장 큰 요인은 강우량의 변화일 것이다. 하천유량의 예측은 유역의 특성과 관측자료의 가용유무에 따라 모형시스템을 구성하여 매 시간마다 실시간으로 입력되는 새로운 자료를 다음 시간단계의 예측모형에 반영하여 장래 발생 가능한 유출량을 계산함으로써 이루어진다. 강우-유출모형의 매개변수를 추정하기 위한 과정에서는 각각의 강우-유출사상에 대한 매개변수들이 사상에 따라 각기 다르게 나타나므로 최적값을 추정하여야 하는데 이는 모형설정 또는 개발자들의 과거자료를 토대로 형성된 경험과 숙련도에 따라 좌우되며 인위적인 조정 및 보정을 필요로 한다. 또한 단위도이론을 이용한 강우-유출과정의 해석에서는 단위도의 기본가정이 실제 적용시 비선형성의 처리와 같은 문제점 때문에 이를 적용하기 위해서는 상당한 어려움이 따른다. 수문계의 유출해석에 적용되고 있는 정보제어 및 예측이론은 수문현상에 포함되어 있는 비선형성과 자료에 포함된 오차로 인한 왜곡 및 자료수집과정에서 발생되는 잡음을 제거시킬 수 있는 수단을 제공한다. 특히 인공지능분야에서 신호처리, 지능제어 및 패턴인식 등의 수단으로 사용되고 있는 신경회로망은 학습이라는 최적화 과정을 통해 최근 수문계의 모형화 및 예측수단으로 사용되고 있다. 이는 신경회로망의 구조와 기능이 복잡한 자연현상을 있는 그대로 받아들여 축적시킴으로써 매개변수를 적응시키고 이를 지식으로 현상에 대한 재현능력이 뛰어나기 때문인 것으로 판단되며 수학적으로 표현이 불가능한 수문계를 정량화하기 위한 시도일 것이다. 또한 신경회로망의 연상기억능력은 수문계의 충격반응함수로 사용하여 강우-유출과정의 응답함수로서의 적용이 가능하기 때문이다.

신경회로망 이론의 강우-유출모형화에 대한 적용사례는 강관원 등(1992)에 의한 일단위 하천유출량의 예측에 관한 연구가 있었으며, 이후 홍수예경보를 위한 유출량 예측을 위하여 ARMAX형태의 수문시계열자료를 신경회로망으로 구조화하여 실시간 홍수예측에 적용한 사례가 있다(김주환, 1993). 또한 신경회로망을 유출량 예측분야 뿐만 아니라 시간적 공간적으로 복잡하게 분포되어 있는 강우예측수단으로 활용한 사례가 있는데, French(1992) 등은 신경회로망을 이용하여 강우의 공간분포의 예측을 위하여 적용하였고 국내에서는 신경망이론에 의한 예측강우를 Kalman Filter 모형에 의한 예측결과와 비교한 연구(오남선, 1996)가 있었으며 실시간 기상자료에 의한 다지점강우예측(정재성, 1996) 등의 강우예측분야에서도 활발히 연구되고 있다.

강우 및 유출량 예측분야 이외에 Lennis-Antonio (1995)는 하천 하류부의 수위를 예측하기 위하여 신경회로망을 적용하고 이를 부정류 해석 결과와 비교하여 좋은 결과를 보여주었으며 Minoru 등(1995)은 신경회로망의 연상기억능력을 이용하여 정수장 및 급배수시스템의 운영을 위한 1일 및 1시간 용수수요량을 예측하였다. 이외에도 Anmala 등(1995)은 El Dorado 유역의 월유출량의 예측을 위한 신경회로망을 중간층 뉴런수의 변화에 따라 구성하고 이들을 비교, 검토하여 결과를 제시한 바 있다.

본 연구에서는 지금까지의 연구결과를 토대로 신경회로망 이론의 수문학적 적용성을 검토하고 그 결과를 고찰하여 수문계에서 유출량 모의 및 예측수단으로서의 활용성 여부와 앞으로의 연구방향을 제시하고자 한다.

2. 적용 예측이론

2.1 신경회로망

신경회로망은 그물과 같이 연결된 뇌의 정보처리과정의 동적거동을 표현하기 위하여 개발된 것으로서 여러 가지 정보, 통신, 제어 분야의 복잡한 문제에 적용되고 있다. 인간의 두뇌를 형성하고 있는 신경조직은 뉴런이라는 신경소자가 복잡하게 얹힌 비선형 시스템으로 이들을 서로 연결해 주는 연결강도에 의하여 시스템의 성능을 향상시킨다. 처리소자(processing element)라 불리는 각 뉴런은 다른 뉴런으로부터 신호를 입력받아 이를 종합하여 뉴런의 반응여부인 출력을 결정한다. 반응을 할 경우 뉴런은 전기펄스를 내어서 연결된 다른 뉴런에 신호로서 전달한다. 이러한 입력과 출력의 상호작용은 동적과정으로 표현된다. 따라서 자극과 반응의 관계로서 표현될 수 있는 입력과 출력간의 상관관계는 뉴런간의 연결강도에 의존하며 이 관계를 나타낸 것이 그림 1이다. 그림 1(a)의 생물학적 신경조직을 그림 1(b)에서처럼 이를 수학적으로 표현한 것으로서 신경회로망은 이러한 뇌와 동일한 계산방식을 사용한 커넥션리즘(connectionism)에 기반을 둔 수리모형이라 할 수 있다. 그림 1에서 X 는 입력패턴을 구성하는 입력벡터이며 W 는 연결강도를 의미한다. 또한 Σ 는 각 입력벡터를 연결강도를 곱하여 합해주는 결합함수(summation function)이며 $f(\cdot)$ 는 전달함수(transfer function)를 나타낸다. 여기서 전달함수는 처리소자의 동작범위를 제공하는 함수로서 선형함수(linear function), 계단함수(step function),

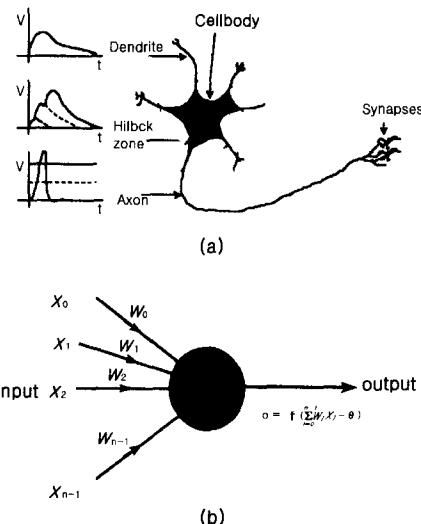


그림 1. 생물학적 신경회로망(a)과 인공신경회로망(b)

선형계단함수(linear threshold function), 시스모이드함수(sigmoid function) 그리고 Gaussian함수 등이 있으며 전달함수에 의하여 계산된 결과가 어떤 임계치를 초과하면 그 값을 처리소자의 출력값으로 하며 그렇지 않을 경우 학습에 필요한 연결강도의 조정량에 영향을 미치지 않는 값을 출력하게 된다. 본 연구에서는 다음과 같이 표현되는 시스모이드 함수를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

2.2 퍼셉트론에 의한 신경회로망의 학습

퍼셉트론(perceptron)은 미국의 Rosenblatt(1958)가 패턴을 분류하기 위하여 제안했던 신경회로망 모형으로 그림 1(b)와 같이 하나의 뉴런, 즉 처리소자를 의미하며 후에 Rumelhart 등(1986)에 의하여 다층퍼셉트론(multi-layer perceptron)으로 발전하였다. 다층퍼셉트론은 여러 개의 처리소자를 각 계층에 모형을 구성한 것으로서 입력자료를 받아들이는 입력층(input layer), 결과를 나타내는 출력층(output layer)으로 구성되며 두 개의 층 사이에는 중간층(hidden layer)을 두어 각 패턴마다 필요한 정보를 학습시킬 수 있도록 한 것이다. 입력층은 대상패턴인 각 입력값을 입력층과 중간층간의 연결강도를 곱해서 중간층으로 전달한다. 중간층은 입력층으로부터 받은 값들을 모두 합하여 전달함수를 통하여 출력하게 되고 이 값들은 다시 중간

층과 출력층 사이의 결합강도와 곱해 출력층으로 보내진다. 오차역전파 알고리즘(error back propagation algorithm)은 다층퍼셉트론에서 입력패턴과 출력패턴에 대하여 오차를 줄여가는 과정, 즉 학습(learning)과정이며 크게 두 단계로 이루어진다. 첫째는 신경회로망의 입력패턴에 따라 각 처리소자의 입력치와 전달함수를 이용하여 출력을 산출하는 순방향처리(feedforward)이고 둘째는 실제값과 계산값과의 차이를 역으로 진행시키면서 오차가 최소가 되도록 층과 층사이의 연결강도를 변화, 조절해 나가는 역방향처리(feedback)이다. 이러한 학습규칙은 결국 오차를 최소화하기 위한 규칙이므로 연결강도와 오차공간에서의 오차를 최소로 하여 연결강도를 구하는 최급강하법이 된다. 다층퍼셉트론 신경회로망에서 p 를 패턴번호($p=1, \dots, P$), i 를 입력층의 i 번째 처리소자 ($i=1, \dots, I$), j 는 중간층의 j 번째 처리소자 ($j=1, \dots, J$) 그리고 k 를 출력층의 k 번째 처리소자 ($k=1, \dots, K$)라 하면 입력층, 중간층 그리고 출력층에서 각 연결강도의 계산은 다음과 같은 과정으로 진행된다. 신경회로망의 목적함수를 제곱오차라고 하는 경우, 이것은 출력층에서 출력되는 값 o 와 실제값 y 와의 제곱오차의 합으로 표시되는 오차함수로 표현될 수 있다. 즉, y_{pk} 를 p 번째 입력패턴에 대한 k 번째 처리소자의 실측값, o_{pk} 를 p 번째 입력패턴에 대한 출력층의 k 번째 처리소자의 출력값이라 한다면 하나의 패턴 p 에 대한 오차 E_p 와 모든 패턴에 대한 총오차 E_t 는 다음과 같고 오차 E_t 가 최소화되는 것으로 한다.

$$E_p = \frac{1}{2} \sum_k (y_{pk} - o_{pk})^2 \quad (2)$$

$$E_t = \sum_p E_p \quad (3)$$

입력층의 I 개의 처리소자에 입력패턴 X 를 입력받아 각각 J 개의 처리소자로 구성된 중간층벡터 H , 또 이 값을 전달받아 K 개의 처리소자로 이루어진 출력층의 출력패턴벡터 Y 가 3층 구조의 다층퍼셉트론을 형성하는 경우, 전달함수를 거치지 않은 중간층의 출력값 net_{pj} 는 입력패턴을 구성하는 입력층의 i 번째 처리소자의 입력값 x_{pi} 와 입력층과 중간층의 연결강도를 표시하는 연결강도행렬 V_{ji} 를 곱하여 합한 값 net_{pj} 를 전달함수로 보내져 다음 식으로 나타낼 수 있다.

$$f(net_{pj}) = \frac{1}{1 + \exp(-net_{pj})} \quad (4)$$

여기서, $net_{pj} = \sum_i V_{ji}x_{pi}$

이 때 중간층의 상태는 중간층의 처리소자에 bias항 Θ 를 포함하여 다음과 같이 된다.

$$[f(net_{pj})] = [H] = [f(net_{pj} + \Theta)] \quad (5)$$

여기서 Θ 는 입력층 및 중간층의 처리소자에 추가로 부가되는 bias항으로 입력층의 정보를 분산시켜 저장할 목적으로 두며 신경회로망의 수렴을 도와 학습이 효과적으로 수행되도록 하는 것이다. 중간층은 입력층으로부터 받은 값들을 처리소자의 결합함수로 모두 합한 값을 전달함수를 통과시켜 출력하게 된다. 즉 중간층의 j 번째 처리소자의 출력값 h_{pj} 와 중간층과 출력층사이의 연결강도 W_{kj} 를 곱해서 출력층으로 보낸다. 중간층과 출력층의 상태는 연결강도 W_{kj} 에 의하여 표현되며 p 번째 패턴에 대한 출력층의 k 번째 처리소자의 출력값 net_{pk} 는 다음과 같이 계산된다.

$$net_{pk} = \sum_k W_{kj} h_{pj} \quad (6)$$

같은 층 내에 있는 처리소자들은 모두 동일한 결합함수와 전달함수를 가지며, 학습 방법 역시 동일하다. 따라서 p 번째 패턴에 대한 출력층의 k 번째 처리소자의 출력값 net_{pk} 가 전달함수를 거친 $f(net_{pk})$ 는 다음과 같다.

$$[f(net_{pk})] = [O] = [f(net_{pk} + \Theta)] \quad (7)$$

중간층이 있는 다층퍼셉트론에서는 중간층의 목표출력치를 알 수 없어 오차의 미분을 구하는 것이 쉽지 않다. 중간층이 없는 경우 오차의 제곱에 대한 곡면이 하나의 최소점을 갖는 포물선 모양을 하고 있으나 중간층이 있는 경우에는 제곱오차의 곡면도 일반적으로 단순하지 않아 제곱오차의 국부적 최소값에 수렴할 가능성 있다. 따라서 델타규칙을 일반화한 일반화 델타규칙(Generalized Delta Rule : GDR)을 사용하여 다층퍼셉트론을 학습시킨다. GDR은 중간층의 목표값을 알 수 없기 때문에 출력층의 오차를 반영하여 중간층 연결강도를 조정하는 학습규칙이다. 따라서 출력층의 오차를 먼저 계산하고 이 값을 중간층에 역전파시켜 오차의 미분으로 표현하여 연결강도를 조정한다. 출력층의 k 번째 출력벡터에 대하여 한 개의 처리소자에 대한 오차는 $\epsilon_k = (y_k - o_k)$ 이며 한 층에는 여러 개의 처리소자가 있다. 하나의 패턴 p 가 입력되었을 때, 하나의 층에 존재하는 모든 처리소자의 오차를 $\delta p_k = (y_{pk} - o_{pk})$ 라면 패턴 p 에 대한 오차는 다음과 같이 쓸 수 있다.

$$E_p = \frac{1}{2} \sum_{k=1}^K \delta_{pk}^2 \quad (8)$$

여기서 $\delta_{pk}=0$ 인 경우 출력된 계산값은 목표값과의 오차가 없어 연결강도의 조정이 이루어지지 않으며, $\delta_{pk}>0$ 인 경우에는 연결강도를 증가시키고 $\delta_{pk}<0$ 인 경우, 연결강도를 감소시켜 학습이 진행된다.

(1) 출력층 연결강도의 조정

연결강도의 조정량은 최급강하법으로부터 연결강도 W_{kj} 에 대한 오차 E_p 가 감소하는 음(-)의 기울기, ΔE_p 를 계산하여 모든 처리소자에서 오차가 줄어든 만큼의 연결강도의 조정량을 구하게 된다. 따라서 출력층을 구성하는 처리소자들의 제곱오차의 합을 최소화하도록 하는 연결강도의 조정량 ΔW_{kj} 는 다음 관계식과 같으며 오차가 감소하는 방향으로 표시된다.

$$\Delta W_{kj} \propto = \frac{\partial E_p}{\partial W_{kj}} \quad (9)$$

p 번째 입력패턴에 대한 k 번째 처리소자의 오차를 δ_{pk} 로 정의하면 델타규칙으로부터 δ_{pk} 와 중간층으로부터 입력되는 h_{pj} 를 곱해서 오차를 최소화시킬 수 있는 연결강도의 조정량 ΔW_{kj} 를 구할 수 있다. 일반화를 위해 서는 학습률 η 를 $\delta_{pk} h_{pj}$ 에 곱하여 각 처리소자에 대한 연결강도 조정량의 평균크기를 결정하는 값으로 보통 0.0~1.0사이의 값을 사용한다. 따라서 각 중간층의 출력 h_{pj} 에 연결대응하는 연결강도의 조정량 ΔW_{kj} 는 다음과 같이 된다.

$$\Delta W_{kj} = \eta \delta_{pk} h_{pj} \quad (10)$$

여기서 δ_{pk} 는 p 번째 패턴에 대한 출력층의 오차를 나타내므로 다음과 같이 쓸 수 있다. 즉, $o_{pk}=f(net_{pk})$ 이므로

$$\delta_{pk} = -\frac{\partial E_p}{\partial o_{pk}} = -\frac{\partial E_p}{\partial net_{pk}} \quad (11)$$

식 (11)에서 δ_{pk} 는 다음과 같이 쓸 수 있다.

$$\begin{aligned} \delta_{pk} &= -\frac{\partial E_p}{\partial net_{pk}} = -\frac{\partial E_p}{\partial o_{pk}} \frac{\partial o_{pk}}{\partial net_{pk}} \\ &= (y_{pk} - o_{pk}) f'(net_{pk}) \end{aligned} \quad (12)$$

여기서 $f'(net_{pk})$ 는 전달함수의 net_{pk} 에 대한 미분으로서 $f'(net_{pk})=f(net_{pk}) \cdot (1-f(net_{pk}))=o_{pk}(1-o_{pk})$ 이다. 따라서 식 (12)은 다음과 같이 쓸 수 있다.

$$\delta_{pk} = (y_{pk} - o_{pk}) o_{pk} (1 - o_{pk}) \quad (13)$$

출력층과 중간층의 연결강도 조정량 ΔW_{kj} 는 이상의 결과를 이용하여 다음과 같이 정리 된다.

$$\Delta W_{kj} = \eta (y_{pk} - o_{pk}) o_{pk} (1 - o_{pk}) h_{pj} = \eta \delta_{pk} h_{pj} \quad (14)$$

연결강도의 변화량은 오차를 줄여 나가는 음의 기울기에 비례하며 이를 이용하여 출력층과 중간층의 연결강도의 조정량은 전단계에서의 조정량에 모멘텀 (momentum)상수를 고려하면 다음과 같이 표현된다.

$$\Delta W_{kj}(t+1) = \eta \delta_{pk} h_{pj} + \alpha \Delta W_{kj}(t) \quad (15)$$

여기서 t 는 반복회수, η 는 학습률, α 는 모멘텀 상수이다. η 의 값이 클수록 연결강도의 조정량은 커지며 모멘텀상수 α 는 학습과정에서 연결강도에 의한 오차의 진동을 막으면서 학습률을 크게 해주기 위하여 도입된 것으로 바로 전 연결강도의 변화량 $\Delta W_{kj}(t)$ 를 어느 정도 고려하여 현재의 연결강도 조정량을 계산하도록 한 것이다. 본 연구에서는 η 및 α 값을 각각 0.9, 0.7을 적용하였다. 따라서 다음 단계를 위해 조정된 연결강도는 식 (15)에 의해 다음과 같이 계산된다.

$$W_{kj}(t+1) = W_{kj}(t) + \Delta W_{kj}(t) \quad (16)$$

이 과정은 신경회로망이 안정될 때까지 또는 목적함수가 허용오차의 범위내에 이를 때까지 반복되며 최종적으로 최적의 연결강도를 계산하게 된다.

(2) 중간층 연결강도의 조정

다중 인식자에서는 중간층의 오차를 결정해야 하므로 이를 위하여 출력층의 오차를 반영하여 p 번째 입력패턴에 대한 중간층의 j 번째 처리소자의 델타값 δ_{pj} 를 결정해야 한다. 여기에서도 오차를 최소화하는 방향으로 연결강도를 변화시켜야 하므로 입력층과 출력층의 연결강도 V_{ji} 에 대하여 오차 E_p 의 기울기, ∇E_p 를 계산하여 조정량을 구한다. 입력층과 중간층간의 연결강도 공간에서의 오차에 대한 기울기는 중간층과 출력층의 연결강도 조정량 ΔW_{kj} 를 계산하는 것과 마찬가지로 최급강하법으로 구할 수 있다.

$$\Delta V_{ji} = -\eta \frac{\partial E_p}{\partial V_{ji}} \quad (17)$$

또 δ_{pj} 를 p 번째 입력패턴에 대한 j 번째 처리소자의 델타값이라면 델타규칙으로부터 입력층과 중간층의 연결강도 조정량은 다음과 같다.

$$\Delta V_{ji} = \eta \delta_{pj} x_{pi} \quad (18)$$

식 (19)는 위 식을 고려하여 다음과 같이 전개된다.

$$-\eta \frac{\partial E_p}{\partial V_{ji}} = -\eta \frac{\partial E_p}{\partial net_{pj}} \frac{\partial net_{pj}}{\partial V_{ji}} \quad (19)$$

$$\begin{aligned}
&= -\eta \frac{\partial E_p}{\partial net_{pj}} x_{pi} \\
&= -\eta \frac{\partial E_p}{\partial h_{pj}} \frac{\partial h_{pj}}{\partial net_{pj}} x_{pi} \\
&= -\eta \left(-\frac{\partial E_p}{\partial h_{pj}} \right) f'(net_{pj}) x_{pi} \\
&= \eta \delta_{pj} x_{pi}
\end{aligned}$$

여기에서 위 식의 $-\partial E_p / \partial h_{pj}$ 는 직접 계산할 수 없으므로 다음과 같이 정리 할 수 있다.

$$\begin{aligned}
-\frac{\partial E_p}{\partial h_{pj}} &= -\sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial h_{pj}} \\
&= \sum_k \left(-\frac{\partial E_p}{\partial net_{pk}} \right) \frac{\partial}{\partial H_{pj}} \sum_j W_{kj} h_{pj} \\
&= \sum_k \left(-\frac{\partial E_p}{\partial net_{pk}} \right) W_{kj} = \sum \delta_{pk} W_{kj} \quad (20)
\end{aligned}$$

따라서 식 (19)와 식 (20)으로부터 δ_{pj} 는 다음과 같이 된다.

$$\begin{aligned}
\delta_{pj} &= f'(net_{pj}) \sum_k \delta_{pk} W_{kj} \\
&= h_{pj}(1-h_{pj}) \sum_k \delta_{pk} W_{kj} \quad (21)
\end{aligned}$$

여기서, $\delta_{pk} = (y_{pk} - o_{pk}) o_{pk} (1-o_{pk}) = (y_{pk} - o_{pk})$
 $f'(net_{pk})$ 이고 $f'(net_{pk}) = h_{pj}(1-h_{pj})x_{pi}$ 이므로

$$\frac{\partial E_p}{\partial V_{ji}} = -\sum_k (y_{pk} - o_{pk}) f'(net_{pk}) W_{kj} f'(net_{pj}) x_{pi} \quad (22)$$

이를 다시 정리하면 다음과 같다.

$$\Delta V_{ji} = \eta \delta_{pj} x_{pi} = \eta f'(net_{pj}) x_{pi} \sum_k \delta_{pk} W_{kj} \quad (23)$$

따라서 입력층과 중간층의 연결강도 $\Delta V_{ji}(t+1)$ 은 모멘텀항 $\alpha \Delta V_{ji}(t)$ 을 합하여 연결강도의 조정량을 구할 수 있다.

$$\Delta V_{ji}(t+1) = \eta \delta_{pj} x_{pi} + \alpha \Delta V_{ji}(t) \quad (24)$$

여기에서도 α 는 학습과정에서 오차의 진동을 막으면서 학습률을 크게 해주기 위한 것으로 중간층과 출력층에서 사용된 값과 같다. 조정량을 식 (24)로부터 구하면 다음 단계의 입력층과 중간층의 연결강도는 다음 식으로 추정할 수 있다.

$$V_{ji}(t+1) = V_{ji}(t) + \Delta V_{ji}(t) \quad (25)$$

여기서 t 는 반복회수를 나타내며 α 는 최적해를 구하는

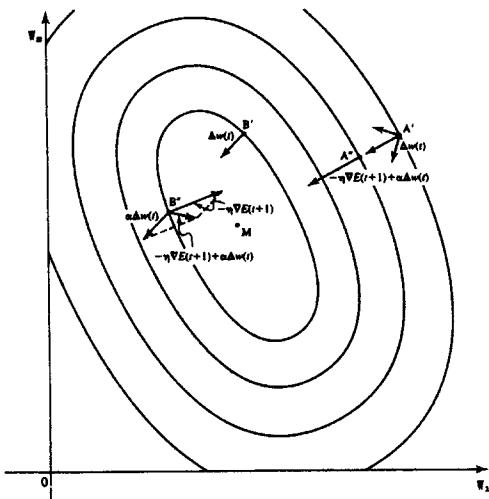


그림 2. 오차역전파 알고리즘의 모멘텀계수

과정에서 수렴의 속도를 증진시켜 신경회로망의 학습을 효율적으로 수행하도록 하는 모멘텀상수로서 0.0~1.0의 값을 갖는다. 그림 2는 모멘텀항을 추가함으로써 최적해인 M으로의 도달을 도와주는 과정을 설명한 것으로서 각각 A'에서 A''로 또는 B'에서 B''로 이동함으로써 최적해로의 수렴과정에서 매개변수의 조정량을 효과적으로 조정할 수 있도록 한 것이다. 신경회로망모형은 이상과 같은 과정을 거쳐 출력층의 총오차($E = \sum E_p$)가 임의의 오차허용치를 만족하게 되면 반복학습을 끝낸다.

3. 수문계의 적용

3.1 대상자료

본 연구에서는 건교부의 IHP대표유역 조사보고서로 부터 평창강유역 방류지점의 홍수시 강우, 유량자료를 대상으로 하였으며 각각의 호우사상 특성은 표 1과 같다. 표 1의 19개 호우자료로부터 17개 사상을 선택하여 매개변수의 추정과정인 신경회로망모형의 학습을 위하여 사용하였고 2개 사상(16번, 19번 호우사상)은 추정된 모형에 대한 검증자료로 사용하였다.

3.2 모형의 구성

유출수문곡선의 추정은 수문계의 기본적인 문제중의 하나로서 이를 위하여 강우-유출모형을 적용하게 되는데 각각의 호우사상의 특성에 따라 각각 다른 모형 매개변수를 갖게 된다. 신경회로망은 인간 두뇌의 학습기능을 모형화한 정보처리 시스템이므로 외부로부터 지식

표 1. 호우사상별 특성

Flood Event No	Date	Max. Rainfall (mm/hr)	Peak discharge(cms)
1	1983. 7. 2.	11,884	263.94
2	1983. 7. 14.	9,447	118.20
3	1984. 7. 2.	19,481	1182.9
4	1984. 8. 28.	8,918	180.45
5	1985. 7. 10.	26,231	415.74
6	1985. 8. 16.	16,072	230.53
7	1986. 7. 16.	8,337	300.227
8	1986. 10. 10.	7,239	156.98
9	1987. 6. 7.	10,135	259.27
10	1987. 7. 21.	15,429	155.6
11	1988. 7. 9.	7,050	436.8
12	1988. 7. 19.	17,954	713.9
13	1989. 7. 24.	18,885	1217.9
14	1989. 9. 14.	5,028	97.384
15	1989. 9. 15.	6,679	195.2
16	1990. 5. 13.	8,691	180.07
17	1990. 6. 20.	14,237	982.10
18	1990. 6. 24.	13,661	562.5
19	1990. 9. 10.	21,770	2915.4

이나 정보가 입력되면 동적상태반응을 일으켜 필요한 출력을 생성시키는 네트워크라 할 수 있다. 생물학적인 신경세포들은 그들이 가져야 할 지식이나 능력들이 모두 사전에 프로그램된 것이 아니라 계속적인 학습을 통하여 이루어지며 일정기간동안 일어난 학습과정에서 새로운 지식이 들어왔을 때 신경회로망을 다시 수정하여 개선함으로써 주어진 입력에 대하여 기대되는 출력값을 출력할 수 있도록 재구성하게 된다. 신경회로망이 정보 또는 지식을 습득하는 방법은 학습을 통하여 이루어지며 이는 원하는 출력과 신경회로망을 통하여 계산된 출력간에 오차가 있는 경우 그 오차에 대하여 계속적으로 반복하면서 각 결선에 대한 매개변수를 최적화하기 위하여 연결강도를 조정하는 것으로 그림 3과 같다.

다층퍼셉트론은 신경회로망 모형중의 하나로서 그림 4에서와 같이 입력층과 한 개 이상의 중간층 그리고 출력층이 있는 계층적 구조를 가지며 입력 출력 방향에 따라 순방향의 다층구조를 나타낸다. 그림 4에서 V 는 입력 층과 중간층을 구성하고 있는 뉴런 즉, 처리소자간의 연결강도이며, W 는 중간층과 출력층을 구성하고 있는

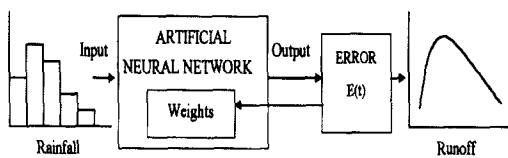
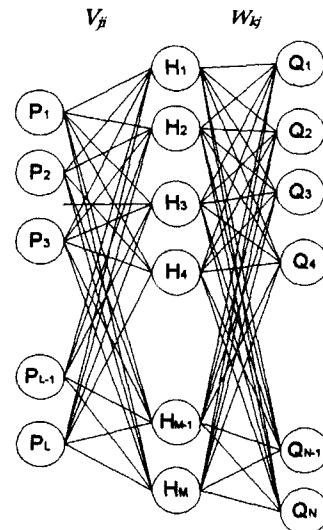


그림 3. 모형의 매개변수추정을 위한 학습알고리즘 개념도



input layer hidden layer output layer

그림 4. 다층퍼셉트론 신경회로망모형

뉴런들 간의 연결강도를 의미하며, L 개의 뉴런으로 구성된 강우계열을 입력층, M 개의 뉴런으로 구성된 중간층, 그리고 N 개의 뉴런으로 구성된 출력층으로 유출수문곡선을 의미한다. 여기서 입력층은 다른 층으로부터 들어오는 연결선없이 신경회로망의 외부로 부터 입력을 받아 전달하게 되며 대부분의 경우 외부의 입력값을 그대로 중간층으로 전달시킨다. 또 다층인식자의 각 층에 있는 모든 처리소자들은 보통 방향성을 가진 결선으로 연결되어 있고 각 연결선들은 연결강도를 가지고 있어 주어진 입력에 따라 그 결선을 거쳐 출력된다. 연결강도는 한 처리소자가 다른 처리소자에 미칠 수 있는 영향력의 크기를 표시한다. 따라서 학습과정에서는 주어진 입력에 대하여 출력과의 상관관계가 큰 영향력이 있는 입력층의 처리소자를 선택적으로 큰 연결강도를 부여하게 되는데 이 과정이 신경회로망의 학습과정이며 오차역전파 알고리즘은 다층퍼셉트론을 학습시키기 위하여 가장 널리 사용되고 있는 학습알고리즘이다.

신경회로망의 학습은 각 층의 처리소자와의 관계를 나타내는 연결강도를 결정하기 위한 과정이다. 따라서 본 연구에서는 신경회로망의 학습을 위한 강우자료와 이에 대응하는 유출량자료를 학습시켜 각각의 강우패턴을 갖는 호우사상의 모의가 가능한 지의 여부를 조사하기로 하였다.

4. 적용 및 고찰

유출수문곡선의 모의를 위한 신경회로망 모형은 MODEL I, MODEL II, MODEL III, MODEL IV, MODEL V, MODEL VI의 6가지에 대하여 검토하였으며 이를 위하여 각 모형의 중간층 처리소자를 12개, 24개, 48개, 120개, 144개, 192개로 구성하였다. 여기에 96개의 강우자료가 하나의 강우사상을 나타내는 입력패턴으로 입력되고, 출력층에서는 50시간의 유출량이 출력패턴으로 출력되어 유출수문곡선을 모의하는 것으로 구성하였다. 지금까지 연구결과에 의하면 신경회로망을 이용하여 유출수문곡선을 모의하고자 하는 경우 독립된 호우사상별 자료를 적용하는 것보다는 연속적으로 관측된 강우 또는 유출량 계열에 적용하는 것이 더욱 타당한 것으로 나타나고 있으나 현재 입수 가능한 시간별 강우-유출자료는 홍수발생시점부터 종료시까지 하나의 사상으로 관측, 기록되고 있기 때문에 이를 신경회로망 모형에 학습시키기 위하여 각각의 사상에 대한 강우 및 유출 지속시간을 일정하다고 가정하고 정해진 지속시간에 대한 유출량만을 모의할 수 있도록 하였다.

이는 평창강유역의 방림지점에 대한 과거 유출량 자료를 조사한 결과 유출량의 변화는 관측이 시작된 시간으로부터 50시간 이내에서 대부분 첨두유량이 발생하고 있었으며 이는 신경회로망을 이용하여 유출수문곡선을 모의할 경우 컴퓨터의 용량에 따라 지속시간의 범위를 증가시킬 수 있을 뿐만 아니라 만약 획득 가능한 자료가 시간별로 연속적으로 관측되었을 경우에는 연속적인 모의가 가능하여 신경회로망의 적용성을 더욱 높일 수 있을 것이다.

그림 5는 신경회로망이 학습을 반복하는 동안 각 모

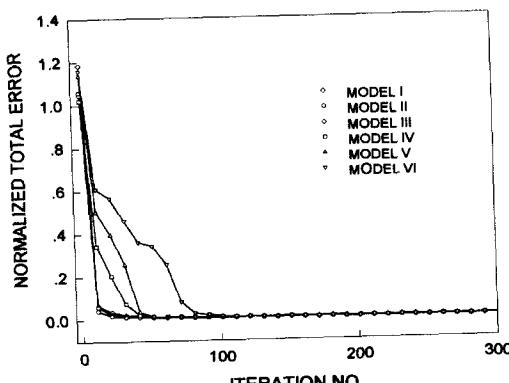


그림 5. 반복학습에 따른 오차변화

표 2. 모형별 반복횟수와 오차범위

model \ index	iteration number	total error	error limit
MODEL I	6967	9.998916E-05	0.0001
MODEL II	4815	9.998096E-05	0.0001
MODEL III	4097	9.996039E-05	0.0001
MODEL IV	4414	9.996656E-05	0.0001
MODEL V	4262	9.997182E-05	0.0001
MODEL VI	6294	9.988659E-05	0.0001

형의 오차가 감소하는 경향을 보여주는 것으로 대부분의 모형이 반복횟수에 따라 감소하는 경향을 보였으며 학습초기에 거의 수렴하는 것으로 나타났다. 각 모형에 대한 반복횟수와 최종오차는 표 2에서 볼 수 있다.

평창강유역의 19개 사상에 대하여 신경회로망의 학습, 즉 매개변수 추정을 위하여 사용된 17개 사상(1번~15번, 17번~18)에 대한 모의결과중 1번, 2번, 4번, 8번, 9번, 11번, 15번사상에 대한 유출수문곡선을 그림 6~그림 12에 도시하였으며 이 결과에 의해 검증을 위해 사용된 호우사상 16번, 19번 사상에 대하여는 그림 13과 14에 도시하였다. 즉, 17개 사상에 대하여는 각각의 모형에 대한 매개변수로서 연결강도를 추정하기 위하여 학습된 사상이며 여기서 얻어진 신경회로망 모형의 매개변수를 사용하여 16번 사상과 19번사상에 대하여 유출수문곡선을 모의한 결과가 그림 13과 14이다.

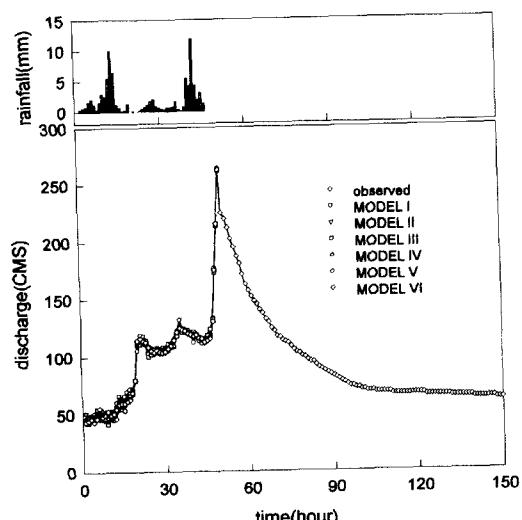


그림 6. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.1)

이들로부터 대부분의 호우사상에 대한 자료특성을 잘 나타내고 있는 것으로 보이나 검증을 위하여 사용된 2개 호우사상중에서 19번 호우에 대한 결과에서 첨두유량의 발생시간을 나타내기에는 어려움이 있었다. 이는 19번 사상의 특성이 연속적인 3개의 첨두유량을 가지고 있어 이를 재현하기 어려운 것으로 파악되었으며 16번 호우사상의 경우에도 같은 경향을 보여주고 있었다. 그

러나 신경회로망의 학습을 위한 호우사상들은 대부분 각 사상별 특성을 잘 나타내고 있음을 알수 있었다. 표 3에서는 본 연구에서 사용된 호우사상에 대하여 실측유출량과 모의유출량과의 상관계수를 나타낸 것으로 모형의 학습을 위한 호우사상의 경우에는 0.9 이상의 상관계수값을 보여 주었으나 검증을 위한 대상 호우에 대해서는 0.8 이상의 값을 보여 주었다. 이와 같이 중간층

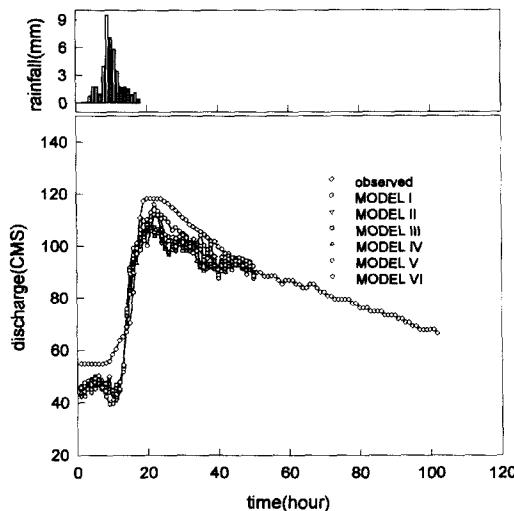


그림 7. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.2)

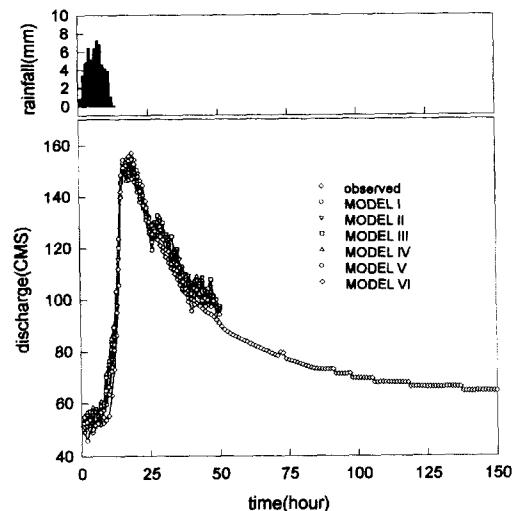


그림 9. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.8)

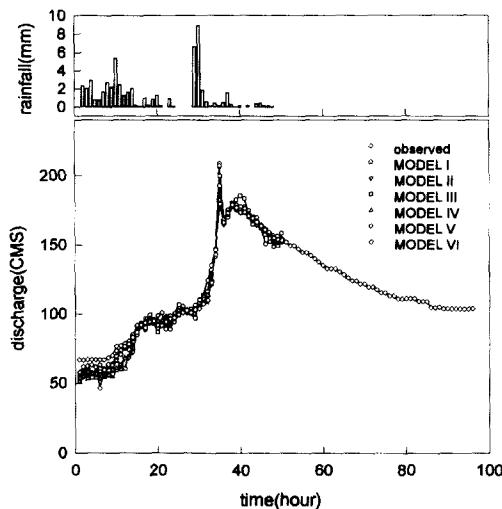


그림 8. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.4)

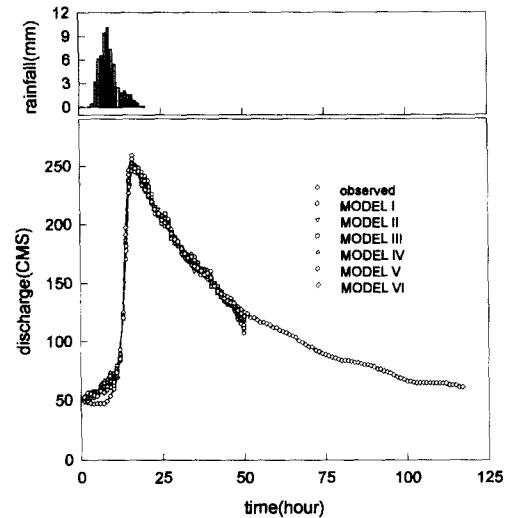


그림 10. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.9)

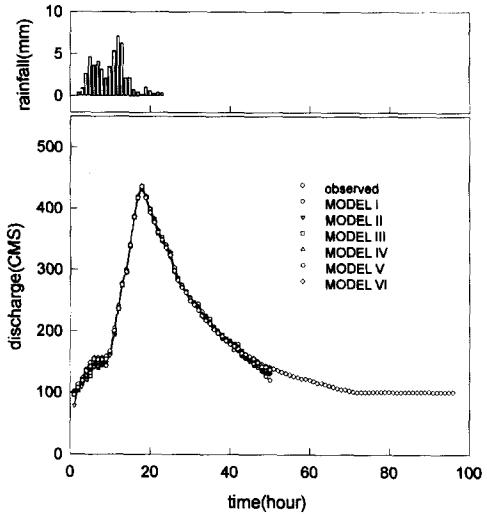


그림 11. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.11)

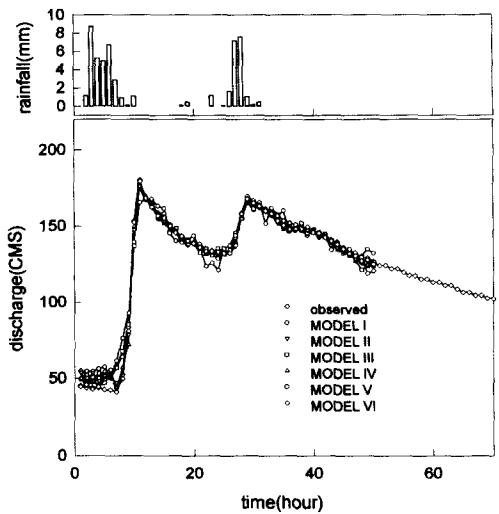


그림 13. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.16)

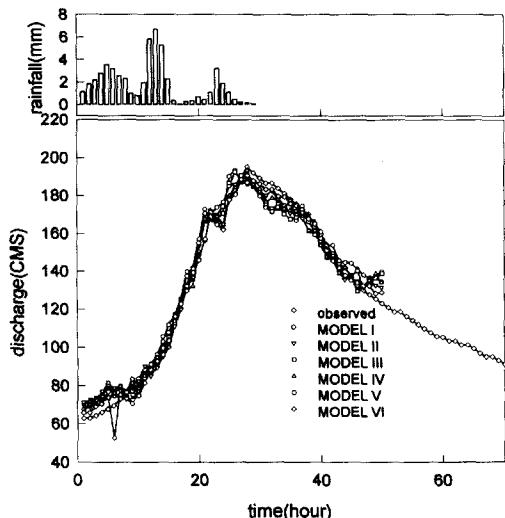


그림 12. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.15)

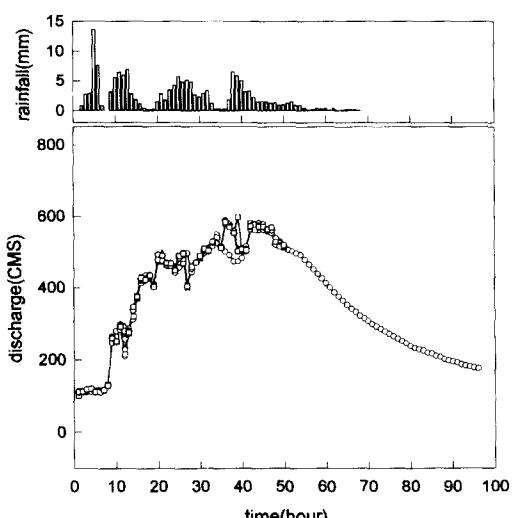


그림 14. 각 모형에 대한 관측유출량과 모의유출량과의 비교도 (호우사상 No.19)

처리소자의 수를 변화시키면서 MODEL I에서부터 MODEL VI까지 비교한 결과 이들간의 큰 차이는 볼 수 없었으며 오차역전파 알고리즘을 이용하여 수문모형에 적용할 경우 적합한 중간층 처리소자 수를 찾아내기 위해서는 많은 시도와 반복작업을 통하여 이루어 진다. 이 점에 대해서는 아직 뚜렷한 연구결과를 찾아보기 어려우나 신경회로망 모형과 최적화기법을 결합하여

문제를 해결하려는 시도가 되고 있으며 장차 수문계의 적용을 위한 연구가 필요할 것으로 생각된다. 또한 표 4는 관측첨두유량과 모의첨두유량을 비교한 것으로서 호우사상 7번의 경우 모의된 유출수문곡선의 지속시간이 첨두유량이 발생되기 전으로 나타나 표에 수록하지 않았으나 나머지 대부분의 경우 최대 10.472%의 범위내에서 유사한 것으로 나타났다.

표 3. 관측유출량계열과 모의유출량계열과의 상관계수

Flood Event No	MODEL I	MODEL II	MODEL III	MODEL IV	MODEL V	MODEL VI
1	0.98	0.96	0.97	0.99	0.99	0.99
2	0.95	0.92	0.93	0.93	0.94	0.97
3	0.98	0.97	0.98	0.99	0.99	0.97
4	0.99	0.99	0.99	0.99	0.99	0.99
5	0.99	0.99	0.99	0.99	0.99	0.99
6	0.98	0.98	0.99	0.99	0.99	0.99
7	0.99	0.99	0.99	0.99	0.99	0.99
8	0.98	0.98	0.97	0.99	0.98	0.99
9	0.99	0.99	0.99	0.99	0.99	0.99
10	0.99	0.99	0.99	0.99	0.99	0.99
11	0.99	0.99	0.99	0.99	0.99	0.99
12	0.99	0.99	0.99	0.99	0.99	0.99
13	0.99	0.98	0.99	0.99	0.99	0.99
14	0.91	0.97	0.98	0.99	0.96	0.96
15	0.98	0.97	0.97	0.99	0.99	0.99
16	0.86	0.87	0.87	0.89	0.89	0.89
17	0.99	0.99	0.99	0.99	0.99	0.99
18	0.99	0.99	0.99	0.99	0.99	0.99
19	0.84	0.85	0.86	0.87	0.87	0.87

표 4. 관측첨두유량과 모의첨두유량

Flood Event No	observed (cms)	simulated											
		MODEL I	error (%)	MODEL II	error (%)	MODEL III	error (%)	MODEL IV	error (%)	MODEL V	error (%)	MODEL VI	error (%)
1	263.9	261.3	0.985	264.0	0.038	262.3	0.606	262.9	0.379	263.40	0.189	262.8	0.417
2	118.20	116.0	1.861	111.9	5.330	106.1	10.237	107.0	9.475	108.6	8.122	112.2	5.076
3	1182.9	1182.9	0.000	1182.6	0.025	1182.5	0.034	1181.9	0.085	1183.2	0.025	1182.1	0.068
4	208.6	179.7	13.854	192.6	7.670	199.8	4.219	206.8	0.863	205.9	1.294	207.0	0.767
5	415.7	417.3	0.385	416.0	0.072	414.1	0.385	412.3	0.818	410.9	1.155	413.0	0.650
6	230.5	218.6	5.163	220.3	4.425	226.7	1.649	226.5	1.735	224.1	2.777	227.0	1.518
7	-	-	-	-	-	-	-	-	-	-	-	-	-
8	157.0	147.0	6.369	146.9	6.433	149.9	4.522	152.7	2.739	149.9	4.522	154.5	1.592
9	259.3	250.6	3.355	246.0	5.129	250.2	3.509	252.1	2.777	252.5	2.622	256.2	1.196
10	1558.7	1556.5	0.141	1555.4	0.212	1553.5	0.334	1549.9	0.565	1549.3	0.603	1549.8	0.571
11	436.8	433.9	0.664	432.4	1.007	435.6	0.275	433.8	0.687	433.3	0.801	435.8	0.229
12	713.9	711.5	0.336	710.9	0.420	711.3	0.364	711.0	0.406	710.8	0.434	711.9	0.280
13	1217.9	1214.5	0.279	1213.6	0.353	1213.2	0.386	1213.0	0.402	1213.4	0.369	1211.1	0.558
14	97.4	102.9	5.647	107.6	10.472	105.2	8.008	106.5	9.343	110.8	13.758	103.7	6.468
15	195.2	186.3	4.559	186.7	4.355	189.7	2.818	193.3	0.973	189.8	2.766	190.7	2.305
16	180.1	165.3	8.218	175.1	2.776	175.7	2.443	177.9	1.222	176.0	2.277	179.1	0.555
17	982.1	981.8	0.031	981.2	0.092	981.0	0.112	977.9	0.428	977.7	0.448	976.9	0.529
18	2915.4	2911.7	0.127	2914.1	0.045	2914.3	0.038	2915.5	0.003	2915.8	0.014	2917.4	0.069
19	562.5	579.7	3.058	572.6	1.796	573.3	1.920	571.5	1.600	569.8	1.298	570.9	1.493

5. 결 론

본 연구에서는 신경회로망에서 제공되고 있는 이론을 기초로 여러 가지 형태의 모형을 설정하여 수문계의 유출수문곡선을 모의하여 그 결과를 제시하였으며 이를 다음과 같이 요약할 수 있다.

(1) 평창강유역의 19개 사상을 대상으로 강우 및 유출량자료를 6가지의 서로 다른 형태를 갖는 신경회로망 모형을 구성하여 수행한 결과 본 연구에서 설정한 중간 층의 범위에서는 큰 차이를 보이지 않아 중간층 처리소자가 12개 이상이 되는 경우 유출모의 결과의 향상에 큰 영향을 미치지 않았으며 각 모형에 대하여 유사한 결과를 얻을 수 있었다.

(2) 본 연구에서 모의된 유출량을 관측치와 비교한 결과에서는 매개변수의 추정과정인 학습에 사용된 경우 0.9 이상, 학습에 사용되지 않은 경우에는 0.8 이상의 상관계수를 얻을 수 있었으며 첨두유출량은 10.472%의 오차범위에서 재현되었다. 따라서 축적된 호우사상자료가 충분할 경우 과거의 가장 유사한 호우사상을 모의함으로써 장래 발생될 유출량의 예측정도를 높일 수 있는 방법으로서 사용될 수 있을 것으로 생각된다.

(3) 모형의 매개변수 추정과정인 신경회로망의 학습 과정에서 오차의 감소는 거의 초기단계에서 이루어졌으며 오차의 범위내에 수렴하기 위해서는 학습률이나 모멘텀 계수를 수문계에서 취급하고 있는 자료의 특성에 맞게 조정할 경우 수렴속도를 증진시킬 수 있을 것으로 판단되며 최적화기법과 도입한 추가적인 연구가 요구된다.

(4) 블랙박스 모형으로서 신경회로망은 어떠한 형태로든 입출력형태에 따라 모형의 매개변수를 적응시킬 수 있었으며 수문학적 개념을 토대로 발전시킬 경우 수문모형의 매개변수 추정을 위한 적용방법으로 사용될 수 있을 것으로 생각된다.

(5) 본 연구에서는 신경회로망 이론을 근거로 수문계의 강우-유출사상의 모의를 위하여 어느 정도 제한을 두고 수행되었으나 장차 이를 활용할 경우 각 유역별 수문학적 인자와의 결합을 통하여 유출량 추정에 따른 정확도를 향상시킬 수 있을 것으로 기대되며 장래 수자원의 개발 및 관리를 위한 효율적인 접근방법으로 활용될 수 있을 것이다.

감사의 글

본 연구는 1995년도 인천대학교 연구비 지원에 의하여 수행된 것으로 지원에 감사를 드립니다.

참 고 문 헌

- 장관원, 박찬영, 김주환 (1992). “패턴인식 방법을 적용한 하천유출량의 비선형 예측.” *한국수문학회지*, 제25권, 제3호, pp. 105-113.
- 김주환(1993). 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구. 박사학위논문, 인하대학교.
- 오남선 (1996). 신경망이론과 Kalman Filter 강우예측모형의 비교연구. 박사학위논문, 서울대학교.
- 윤태훈 (1981) “홍수예보 모형.” *한국수문학회지*, 제14권, 제2호, pp. 5-6.
- 정재성 (1996). 실시간 기상자료와 신경망이론에 의한 디지털 강우예측 모형 연구. 박사학위논문, 전북대학교.
- Amala, J., Nedunuri, K.V., Govindaraju, R.S. and Koelliker J.K.(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.
- Kang, K.W., Park, C.Y., and Kim, J.H. (1993). “Neural network and its application to rainfall-runoff forecasting.” *Korean Journal of Hydrosciences*, Vol. 4, pp. 1-10.
- French, M.N., Andrieu, H., and Krajewski, W.F. (1992). “Rainfall forecasting in space and time using a neural network.” *Journal of Hydrology*, Vol. 137, pp. 1-31.
- Lennis-Antonio, A.T. (1995). *Optimizing the Apure river basin reservoir system using a multimodel approach*. MSc Thesis, International Institute for Infrastructural Hydraulic and Environmental Engineering, IHE, Netherlands.
- Minoru, M., Takashi, T., and Kazuo, M. (1995). “Water demand prediction by memory based learning.” *IWSA Specialized Conf. on Advanced Treatment and Integrated Water System Management into 21st Century*, Osaka, Japan, Vol. 1, pp. 316-317.

- Rosenblatt, F. (1958). *The Perceptron : A theory of statistical separability in cognitive system*. Report No. VG-1196-1. Cornell Aeronautic Lab., Inc., Buffalo.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1986). "Learning internal representations by error back propagation." *Parallel distributed processing*, Edited by Rumelhart, D.E., McClelland, J.L. and PDP Research Group, Chapter 8, Cambridge, MA, MIT Press.

〈최종본 접수일 : 1997년 12월 9일〉