

신경망을 이용한 낙동강 유역 하도유출 예측 및 홍수예경보 이용

Real-Time Forecasting of Flood Runoff Based on Neural Networks in Nakdong River Basin & Application to Flood Warning System

윤 강 훈* / 서 봉 철** / 신 현 석***

Yoon, Kang Hoon / Seo, Bong Cheol / Shin, Hyun Suk

Abstract

The purpose of this study is to develop a real-time forecasting model in order to predict the flood runoff which has the nature of non-linearity and to verify applicability of neural network model for flood warning system. Developed model based on neural network, NRDFM(Neural River Discharge-Stage Forecasting Model) is applied to predict the flood discharge on Waekwann and Jindong stations in Nakdong river basin. As a result of flood forecasting on these two stations, it can be concluded that NRDFM-II is the best predictive model for real-time operation. In addition, the results of forecasting used on NRDFM-I and NRDFM-II model are not bad and these models showed sufficient probability for real-time flood forecasting. Consequently, it is expected that NRDFM in this study can be utilized as suitable model for real-time flood warning system and this model can perform flood control and management efficiently.

Keywords : Neural Network, Back-propagation, Rainfall-Runoff, Flood Forecasting, Flood Warning System

요지

본 연구는 비선형성이 강한 강우-유출의 특성을 고려하여 홍수시 하도의 유출을 예측하고 하천유역의 홍수예경보에 이용하기 위하여 신경망 시스템의 모형화 가능성을 검증하였다. 신경망을 이용한 실시간 하도홍수 예측모형 (Neural River Discharge-Stage Forecasting Model; NRDFM)은 낙동강 유역의 왜관 및 진동 지점의 홍수량 예측에 적용하였다. NRDFM에 의한 하도홍수량의 왜관 및 진동 지점 예측결과를 실측치와 비교·검토한 결과 제시한 세 가지 모형 중 NRDFM-II의 예측성능이 가장 우수하였으며, NRDFM-I 및 NRDFM-III도 충분한 예측가능성을 보여주었다. 따라서, 본 연구에서 제시한 모형은 실시간 홍수예경보로의 적용이 가능하며, 이를 통하여 효율적으로 홍수를 통제 및 관리할 수 있을 것이다.

핵심용어 : 신경망, 역전파, 강우-유출, 홍수예측, 홍수예경보

* 한국건설기술연구원 수자원연구부 수석연구원

Research Fellow, Dept. of Water Resources Research, Korea Institute of Construction & Technology, Goyang, Gyeonggi 411-712, Korea
(E-mail : khyoon@kict.re.kr)

** 한국건설기술연구원 수자원연구부 연구원

Researcher, Dept. of Water Resources Research, Korea Institute of Construction & Technology

*** 부산대학교 토폭공학과 조교수

Assistant Professor, Dept. of Civil Engineering, Busan National University, Busan 609-735, Korea

1. 서 론

하천유역에서 호우에 의한 하천의 유출량을 예측하기 위하여 현재까지 많은 연구가 이루어져 왔으나, 유역 내 수문순환시스템은 그 자체가 비선형성이 강하고 여러 가지 변동성분을 포함하기 때문에 강우로부터 유출거동을 파악하기에는 많은 어려움이 있다. 일반적인 홍수의 통제 및 관리 측면에서 가장 중요한 것은 하천의 유출량을 강우-유출 관계에 의해 어떻게 표현할 수 있는가 하는 것이며, 특히 단기간 강우-유출 모형을 통한 홍수의 예측은 더욱 중요하다.

일반적으로 강우-유출 모형은 단시간 호우사상의 해석 모형을 의미하며, 이는 19세기 후반부터 개발되기 시작하였다. Sherman(1932)은 중첩의 원리를 근거로 단위유효우량에 의한 유출을 해석하는 단위도 이론을 소개하였다. 1960년대 이후의 개념적 모형으로는 Kimura(1961)가 저류함수법을 제안하였으며, 미공병단(1964)에서는 SSARR 모형을, Crawford와 Linsley(1966)는 SWM-IV 모형을, Burnash(1973)은 Sacramento 모형을, WMO(1975)는 Tank 모형을, Box와 Jenkins(1976)는 통계학적 이론과 접목이 가능한 매개변수에 의해 유출을 표현하는 접근방법을 제시하였다.

최근에는 지형정보시스템(Geographic Information System; GIS) 및 원격탐사(Remote Sensing; RS) 등에 의한 기초자료의 구축이 용이하여 매개변수 및 유역특성 인자의 공간적 변화까지도 고려할 수 있는 분포형 모형(distributed model)과 대표적 블랙박스 모형(black-box model)으로 알려진 신경망 등을 이용한 연구가 활발하게 진행중이다.

최근 인공지능 분야에서 신호처리, 지능제어 및 패턴인식 등의 수단으로 사용되고 있는 신경망은 학습(training)이라는 최적화 과정을 통해 입력과 출력으로 구성되는 하나의 시스템을 병렬적이고 비선형적으로 구축할 수 있다. 이러한 장점으로 인해 신경망 모형은 비선형 시계열 분석, 카오스 해석, 시그널 분석 등의 복잡한 자연현상에 성공적으로 적용되어 왔으며, 또한 수자원 분야에서도 강우예측, 실시간 홍수예측 등에 적용되었다. 국내에서도 김주환(1993), 심순보(1998), 이관수(2000), 안상진(2001) 등에 의해 강우-유출 모의를 통한 홍수예측에 적용된 사례가 있다.

기존에는 홍수예측을 위해 한강 및 낙동강 등에서 저류함수법에 의한 유역 유출을 예측하고 있으나, 이는 현재 수많은 자료의 축적으로 인해 다양한 모형의 검토가 요구되고 있다. 따라서, 본 연구에서는 홍수예측 능

력의 정확성을 향상시키기 위하여 저류함수법을 포함한 복잡한 물리적 매개변수에 의존하는 기존 모형들과는 달리 비선형적인 자연현상을 자동학습에 의해 모의가 가능한 신경망 모형을 사용하였다. 또한, 신경망 모형의 홍수예측 및 홍수예경보시스템에의 적용을 위해 다층전방향신경망(Multi-layered Feed-forward Neural Network; MFN) 구조를 가진 역전파(Back Propagation; BP) 알고리즘을 사용하여 낙동강 유역에 적용하였다.

2. 적용 이론

2.1 신경망 모형

신경단위(neuron)들은 일반적으로 그림 1과 같이 다층구조(multi-layer structure)로 병렬연결(parallel connection)되어 입력된 신호는 전방향(feed-forward)으로 전달이 가능하다. 이를 다층전방향 신경망(MFN)이라고 하며 이 네트워크는 입력층, 출력층, 은닉층으로 구성되어 있다. 그림 1에서 X_1, X_2, \dots, X_i 는 입력층 성분, H_1, H_2, \dots, H_j 는 은닉층 성분, Y_1, Y_2, \dots, Y_k 는 출력층 성분, W_{ij} 와 W_{jk} 는 각 층간의 가중치이다.

입력정보 X_i 는 입력층으로 입력되고 신경단위들은 입력정보를 가중연결(weighthed connection)하여 은닉층의 절점들로 전달한다. 각 은닉층의 절점들은 모든 입력층으로부터 각기 다른 연결강도(weight)에 의해 변환된 자료들을 받으며, 그림 1에서 은닉층 절점으로 가중된 입력, h_j 는 다음 식 (1)로 나타낼 수 있다.

$$h_j = \sum_{i=1}^{N_I} w_{ij} X_i + \theta_j, \quad j = 1, \dots, N_H \quad (1)$$

여기서, N_H 는 은닉층 절점수, θ_j 는 은닉층 j 번째 절점의 편차(bias)입력, w_{ij} 는 입력층 i 번째 절점과 은닉층 j 번째 절점 사이의 가중치를 나타낸다.

은닉층의 각 절점에서는 식 (1)에 의해 합산된 자료들을 대표적 전달함수인 식 (2)의 시그모이드(sigmoid) 함수나 식 (3)의 하이퍼볼릭탄젠트(hyperbolic tangent) 함수에 의해 비선형적으로 변환하여 가중연결에 의해 출력층으로 전달하며, 은닉층으로부터의 출력값 H_j 는 전달함수를 사용하여 $f(h_j)$ 로 나타낼 수 있다.

$$f(u) = \frac{1}{1 + e^{-u}} \quad (2)$$

$$f(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (3)$$

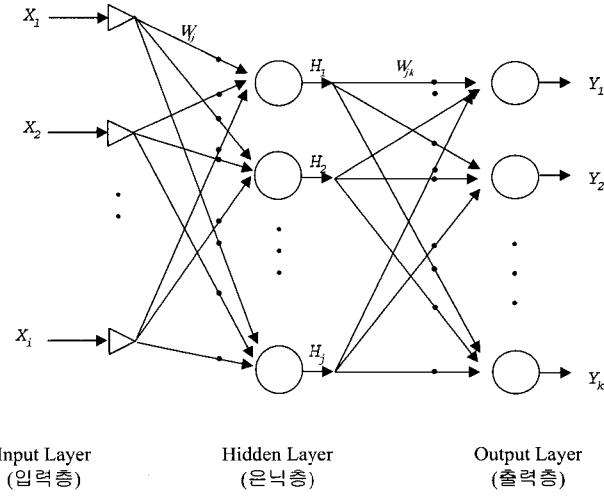


그림 1. 다층전방향 신경망(MFN)의 구조

각 출력층의 절점들은 모든 은닉층으로부터 각기 다른 가중치에 의해 변환된 자료들을 받으며, 각 절점은 합산된 자료들을 출력값의 목적에 따라 이진값의 출력을 위한 결합함수, 즉 연속값의 출력을 위한 선형 또는 비선형 함수에 의해 변환하여 출력하며 그 값이 신경망의 목적하는 출력값이 된다. 출력층으로의 가중된 입력은 식 (4)와 같이 나타낼 수 있다.

$$y_k = \sum_{j=1}^{N_h} w_{jk} H_j + \theta_k, \quad k = 1, \dots, N_o \quad (4)$$

여기서, N_o 는 출력층 절점수, θ_k 는 출력층 k 번째 절점의 편차입력, w_{jk} 는 은닉층 j 번째 절점과 출력층 k 번째 절점 사이의 가중치이다. 또한, 출력층으로부터의 출력값 Y_k 는 전달함수를 사용하여 $f(y_k)$ 로 나타낼 수 있다.

이상 다층전방향 신경망의 역학에 의한 출력을 다시 정리하면 식 (5)로 나타낼 수 있다.

$$Y_k = f \left[\sum_{j=1}^{N_h} w_{jk} f \left(\sum_{i=1}^{N_l} w_{ij} X_i + \theta_j \right) + \theta_k \right] \quad (5)$$

2.2 역전파 모형

역전파는 신경망 학습에 있어 가장 많이 사용되는 알고리즘이다. 역전파 모형은 네트워크 오차 함수를 최소화하는 경사하강법(gradient descent)과 일반화된 델타(delta) 법칙에 의해 학습되는 방법으로 처음에 Werbos(1974)에 의해서 개발되었지만 그 강력한 기능

은 오랫동안 인식되지 못하였고, Rumelhart 등(1986)에 의해 알고리즘이 다시 개발되어 맵핑 문제에 대한 은닉 절점의 학습방법을 설명함으로써 많이 사용되게 되었다.

역전파 모형의 네트워크는 입력층, 출력층, 그리고 다수의 은닉층으로 구성된다. 각 층에서의 절점은 정보를 받아 저장하고 처리하는 역할을 하며 다음 층의 절점과 연결되어있다. 학습의 시작 단계에서 모든 가중치는 난수를 사용하여 초기화되며 이러한 가중치는 일반화된 델타법칙 또는 경사하강법 원칙을 사용하여 반복적으로 갱신되거나 수정된다. 학습과정은 연결과 관련된 값이 적당한 변화를 보이지 않거나 오차함수의 기준을 만족할 때 중지한다. 따라서, 역전파 네트워크의 학습은 입력층에서 출력층으로 정보의 처리가 일어나는 전방향 과정과 출력층에서 입력층으로 에러가 역방향으로 전달되고 연결 강도가 수정되는 두 가지 과정으로 구성된다.

네트워크의 학습자료는 입력층에서 출력층으로 통과하며 네트워크의 출력은 목적치와 비교되고 오차가 계산된다. 이러한 오차는 각각의 절점으로 네트워크를 통하여 역방향으로 전파되며 동시에 식 (6)에 의해 연결 가중치가 조정된다.

$$\Delta w_{ij}(n) = -\varepsilon \frac{\partial E}{\partial w_{ij}} + \alpha \Delta w_{ij}(n-1) \quad (6)$$

여기서, $\Delta w_{ij}(n)$ 과 $\Delta w_{ij}(n-1)$ 은 n 과 $n-1$ 번째 반복학습동안 절점 i 와 j 사이의 가중치 증가분이다. 편차값(bias)의 보정을 위해서도 유사한 식이 사용되며

식 (6)에서 ϵ 과 α 는 각각 적응학습률(adaptive learning rate)과 모멘텀(momentum) 계수이다. 모멘텀 계수는 가중치의 발산을 방지하며 오차함수의 편평한 부분에서 학습속도를 높여주고, 학습률은 오차함수가 전역 최소값(global minima) 대신 지역최소값(local minima)을 갖지 않도록 한다. 역전파 알고리즘은 두 가지 단계로 수행되며 첫 번째 단계는 전방향 진행, 즉 입력값은 전방향으로 네트워크를 통과하여 출력층에 도착하고 오차가 계산된 이후 두 번째 단계로 네트워크의 역방향으로 시작된다. 출력층에서의 오차는 식 (6)에 따라 가중치가 수정되며 입력층 쪽의 역방향으로 전파된다.

3. 하도홍수 예측모형

홍수시 하도에서의 홍수위 예측은 T/M 강우관측에 의한 대상 하도지점 상류유역의 평균강우량산정과 하도지점의 T/M 수위 실측을 통해 가능하며, 이러한 자료들에 의해 구성되는 신경망 하도홍수 예측모형의 개요는 그림 2와 같다. 유역 홍수의 실시간 예측을 위해서는 다양한 강우 및 유출자료의 상황이 존재할 수 있으므로 신경망 하도홍수 예측모형(Neural River Discharge-Stage Forecasting Model; NRDFM)은 홍수시 실시간으로 수집될 수 있는 자료의 종류에 따라 그림 3과 같이 3가지로 구분하였다. 각 모형의 입력자료로 NRDFM-I은 선행강우량과 대상지점에서의 선행유출량을, NRDFM-II는 대상지점의 선행유출량과 상류지점의 유출량을, NRDFM-III는 선행강우량 및 대상지점의 선행유출량과 상류지점의 유출량을 사용하였다. 입력자료 중 유출량은 대상지점의 T/M 관측수위 값을 수위-유량관계 곡선식(건설교통부, 2000)에 의하여 유량으로 환산하였으며, 모형의 출력값인 하도 홍수량은 다시 수위-유량관계에 의해 홍수위로 환산하여 홍수예경보 업무에 활용될 수 있다.

각 모형별 특징을 보면 NRDFM-I에서는 대상 하도

지점에서의 강우-유출자료를 사용하여 모형을 구축하였고, NRDFM-II는 강우자료를 제외한 유출자료에 의한 예측을 시도했으며, NRDFM-III은 가능한 모든 강우-유출자료들을 사용하였다. 또한, 홍수의 적절한 대응을 위해서는 1, 2시간의 단시간 예측뿐만 아니라 장시간에 대한 예측이 필요하므로 본 연구에서는 10시간까지 예측이 가능하도록 모형을 구성하였다. 입력자료에 따른 각 모형을 수식화하면 식 (7)~식 (9)와 같이 표현할 수 있다.

NRDFM-I :

$$Q_1(t+N_l) = f[R(t), R(t-1), \dots, R(t-N_r); Q_1(t), Q_1(t-1), \dots, Q_1(t-N_{q1})] \quad (7)$$

NRDFM-II :

$$Q_1(t+N_l) = f[Q_1(t), Q_1(t-1), \dots, Q_1(t-N_{q1}); Q_2(t), Q_2(t-1), \dots, Q_2(t-N_{q2})] \quad (8)$$

NRDFM-III :

$$Q_1(t+N_l) = f[R(t), R(t-1), \dots, R(t-N_r); Q_1(t), Q_1(t-1), \dots, Q_1(t-N_{q1}); Q_2(t), Q_2(t-1), \dots, Q_2(t-N_{q2})] \quad (9)$$

여기서, $Q_1(t)$ 은 t 시간에서 대상지점의 예측유출량, $R(t)$ 는 대상지점 상류의 평균강우량, $Q_1(t)$ 은 대상지점의 실측유출량, $Q_2(t)$ 는 상류지점의 실측유출량, 그리고 $f(\cdot)$ 는 전달함수이다. 또한 N_l 은 선행예측시간, N_r 은 선행강우시간, 그리고 N_{q1} 및 N_{q2} 는 대상지점과 상류지점의 선행유출시간이다.

본 연구에서는 이상에서 제시한 각 모형의 학습을 위해 감독학습법 중 역전파 알고리즘의 모멘트법을 사용하였으며, 학습반복수(epoch)는 적절한 학습시간을 고려하여 모형별로 동일하게 2,000번을 적용하였다.

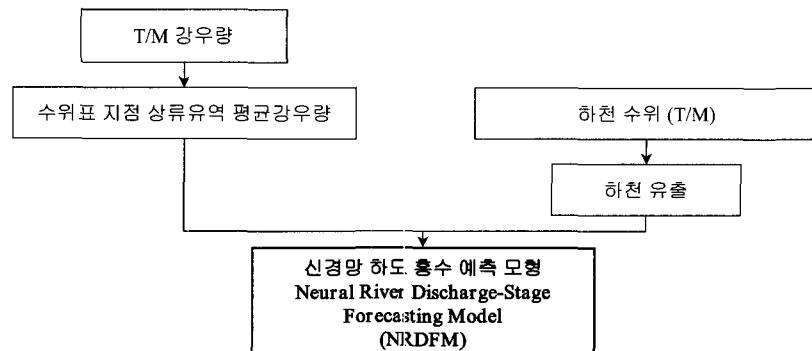


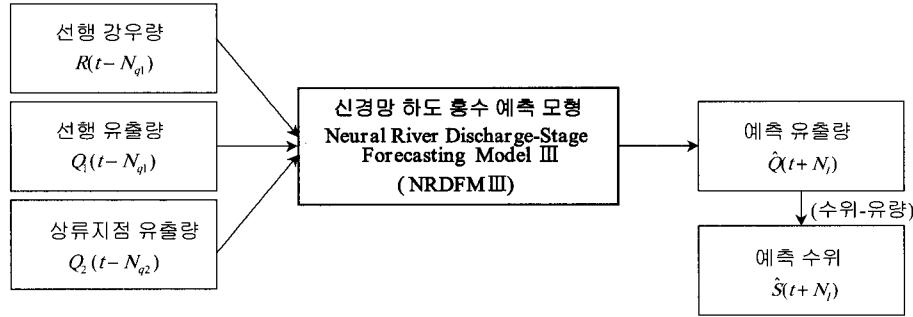
그림 2. 하도홍수 예측모형(NRDFM) 개요



(a) NRDFM- I



(b) NRDFM- II



(c) NRDFM- III

그림 3. 하도홍수 예측모형(NRDFM)의 구조

4. 모형의 적용

4.1 적용 대상지점 선정

본 연구에서는 앞에서 제시한 신경망 하도홍수 예측모형을 적용하기 위해 그림 4와 같이 우리나라 제2의 하천유역인 낙동강 유역의 주요 수위표 지점 중 왜관 및 진동지점을 선정하였다. 또한 왜관 및 진동지점의 홍수예측을 위한 상류지점으로 왜관은 사벌지점을, 진동은 왜관지점을 선정하였다. 왜관지점의 위치는 경북 칠곡군 약목면 구왜관철교로 상류의 유역면적이 11,074 km²으로 낙동강 전체유역의 약 50% 정도를 차지하고 있으며, 진동지점은 경남 함안군 칠서면 계내리에 위치하고 상류의 유역면적이 20,311 km²으로 전체유역 면적의 약 85% 이상에 달한다.

각 지점의 홍수유출특성을 보면 왜관지점이 평균 유역지체시간이 약 31시간, 평균 홍수유출율이 0.45이며 사벌~왜관 구간의 하도지체시간 평균은 약 12시간이다. 진동지점의 평균 유역 지체시간은 약 44시간, 평균 홍수유출율이 0.62이고 왜관~진동 구간의 하도지체시간 평균은 약 19시간이다(건설교통부, 2001).

4.2 홍수사상 선정 및 자료수집

신경망 하도홍수 예측모형의 학습 및 검증을 위한 홍수자료는 다음 표 1과 같이 왜관 및 진동 두 지점에 대하여 각각 7개 사상을 선정하였고, 각 4개 사상을 역전파 모형의 학습에, 각 3개 사상을 구축된 모형의 검증에 사용하였다. 선정된 각 홍수사상별 첨두강우량 및 첨두유입량 등의 홍수유출특성을 표 1과 같이 분석하였고, 홍수분석에 사용된 각 사상의 강우량 자료는 낙동

강홍수통체소의 수문자료 DB로부터 수집하여 왜관 및 진동 지점의 상류에 위치한 T/M 우량관측소 각 47개소 및 99개소의 지점강우량을 500m의 격자망을 기반으로

하는 크리깅(kriging) 기법을 적용하여 유역평균강우량으로 변환하였다.

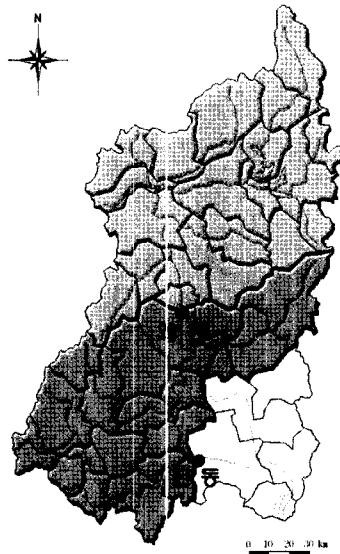


그림 4. 하도록수 예측 대상지점 선정

표 1. 학습 및 검증사상의 홍수유출 특성

지점명	자료	번호	학습 및 검증 대상	관측일	총강우량 (mm)	장 우 지 속 시 간 (hr)	점 부 유 입 량 (cms)	유입용적 ($\times 10^6$ m 3)
왜관	학습 자료	1	90/6/18 00:00 ~ 6/29 05:00	7.8	189.0	161	2,047	766.1
		2	91/8/20 00:00 ~ 8/26 05:00	6.2	102.5	74	3,861	602.3
		3	93/8/ 5 09:00 ~ 8/11 15:00	8.4	196.9	123	4,698	1,221.2
		4	97/7/ 4 21:00 ~ 7/ 9 21:00	9.7	134.6	54	3,977	715.1
	검증 자료	1	99/8/ 2 11:00 ~ 8/ 6 05:00	12.7	113.6	63	3,151	394.5
		2	99/9/19 11:00 ~ 9/27 09:00	12.1	231.5	125	7,615	1,411.8
		3	00/9/07 15:00 ~ 9/14 07:00	10.2	195.9	109	5,736	1,259.0
진동	학습 자료	1	90/6/18 00:00 ~ 7/ 1 07:00	8.1	215.4	213	4,312	2,548.6
		2	91/8/20 00:00 ~ 8/27 11:00	8.5	139.6	99	6,762	2,117.7
		3	93/8/ 5 09:00 ~ 8/17 11:00	7.3	228.9	214	7,674	4,172.5
		4	97/7/ 4 21:00 ~ 7/11 23:00	6.8	138.2	82	7,553	1,816.5
	검증 자료	1	99/8/ 2 11:00 ~ 8/ 9 13:00	8.2	121.1	116	4,260	1,384.2
		2	99/9/19 11:00 ~ 9/30 07:00	9.1	231.0	129	6,182	3,228.9
		3	00/9/ 7 15:00 ~ 9/16 09:00	8.3	224.9	138	9,558	3,392.6

5. 결과 및 고찰

본 연구의 각 NRDFM 모형 입력 변수들은 모형의 입력자료로 선정한 선행강우시간, 대상지점 및 상류지점의 유출량 선행시간, 은닉절점 개수에 대한 민감도 분석을 통하여 결정하였다. 은닉절점의 개수는 5, 10, 15, 20개 등에 대하여 분석한 결과 절점 개수에 따라 큰 변화양상을 보이지 않았으므로, 모형의 학습시간을 고려하여 10개로 고정하였다. 그 후, NRDFM 모형별로 10, 15, 20, 25, 30, 40시간의 선행강우시간과 10, 15, 20시간의 대상지점 유출량 선행시간, 10, 20, 30시간의 상류지점 유출량 선행시간에 대하여 민감도 분석을 수행하여 선정한 신경망 모형 입력변수의 선행시간은 표 3과 같으며, 표 3에서 선정한 입력변수들은 비매개변수법의 특성상 물리적인 의미를 내포하지는 않는다.

입력자료에 따른 모형의 성능을 판단하기 위하여 표 3에서 선정된 각 입력변수의 선행시간을 각 모형에 적용하였다. 적용결과는 표 2에서 제시한 상대첨두치오차(RPE), 상대총량오차(RVE), 절대평균편차(AMB), 제곱근평균자승오차(RMSE), 그리고 상관계수(CC)의 순서

로 표 4에 지점별로 비교하였다. 각 모형별 검증 결과는 왜관지점이 강우량의 입력없이 유출량만으로 예측을 시도한 NRDFM-II가 성능이 가장 우수하였다. 진동지점은 3가지 모형의 성과가 큰 차이를 나타내지는 않으며, 표 4에서 수치상으로는 NRDFM-I 이 가장 좋은 예측성과를 나타내고 있으나 그럼 8~그림 10을 보면 NRDFM-I 보다는 NRDFM-II가 실측치의 추세를 잘 따르고 있음을 알 수 있다. 또한, 전반적으로 모든 모형에서 장시간 예측도 상관계수가 0.96이상으로 만족할 만한 성능을 보여주고 있다.

적용된 검증자료 중 왜관지점은 검증사상 2, 진동지점은 검증사상 1에 대한 실측 및 예측 홍수수문곡선을 그림 5~그림 10에 나타내었다. 모든 예측 수문곡선의 앞 부분은 예측시작의 초기 부분으로 실제 수문곡선의 형태와 상이한 부분이 있으나, 시간이 경과함에 따라 점차적으로 실측치와 유사한 패턴을 갖게 되며, 홍수유출량의 첨두치는 1, 2시간의 단시간 예측치는 비교적 잘 맞으나 10시간의 장시간 예측치는 모형에 따라 과소 및 과대평가의 경향이 있었다.

표 2. 모형 검정 기준

상대첨두치오차 (Relative Peak Error)	$RPE = \frac{[\widehat{R}_p - R_p]}{R_p}$	\widehat{R}_p : 예측 첨두치 R_p : 관측 첨두치
상대총량오차 (Relative Volume Error)	$RVE = \frac{[\widehat{R}_v - R_v]}{R_v}$	\widehat{R}_v : 예측 총량 R_v : 관측 총량
절대평균편차 (Absolute Mean Bias)	$AMB = \frac{1}{N} \sum_{t=1}^N [\widehat{R}(t) - R(t)]$	N : 총 자료수 $\widehat{R}(t)$, $R(t)$: 예측치 및 관측치 t : 시간
제곱근평균자승오차 (Root Mean Square Error)	$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [\widehat{R}(t) - R(t)]^2}$	
상관계수 (Correlation Coefficient)	CC	예측치와 관측치 사이의 선형상관계수

표 3. 모형 입력변수 선정

지점명	모형	선행 강우시간	대상지점 유출선행시간	상류지점 유출선행시간	은닉절점 개수
왜관	NRDFM-I	10	10	-	10
	NRDFM-II	-	10	10	10
	NRDFM-III	10	10	10	10
진동	NRDFM-I	15	10	-	10
	NRDFM-II	-	10	10	10
	NRDFM-III	15	10	10	10

표 4. 지점별 모형 검증결과

모형	선행 예측 시간	왜관					진동				
		RPE	RVE	AMB	RMSE	CC	RPE	RVE	AMB	RMSE	CC
NRDFM-I	t+1	5.51	2.43	123.69	217.65	0.99	0.94	0.02	64.76	101.21	0.99
	t+2	4.81	2.65	153.76	253.24	0.99	0.90	0.02	72.14	110.38	0.99
	t+3	2.88	2.15	160.20	261.14	0.99	0.59	-0.19	73.40	122.08	0.99
	t+4	1.17	1.99	184.96	293.90	0.98	0.26	-0.48	79.68	128.92	0.99
	t+5	-0.74	2.48	218.91	346.93	0.98	0.05	-0.54	92.88	159.04	0.99
	t+6	0.12	3.60	265.98	424.23	0.97	0.32	-0.74	143.01	212.22	0.99
	t+7	-2.16	1.99	252.69	415.48	0.96	0.70	-0.70	210.59	283.32	0.98
	t+8	2.37	1.75	337.31	526.20	0.93	1.94	0.48	287.65	378.55	0.97
	t+9	14.26	2.15	571.84	813.24	0.84	1.34	-1.09	371.03	470.12	0.96
	t+10	19.73	8.27	674.69	990.76	0.78	1.49	-1.00	423.53	545.21	0.94
NRDFM-II	t+1	0.56	-1.25	86.72	133.46	0.99	-1.11	-3.68	157.67	184.51	0.99
	t+2	-2.72	-3.85	103.46	152.32	0.99	-0.67	-3.36	148.08	183.49	0.99
	t+3	-1.15	-2.69	137.90	200.84	0.99	-1.25	-3.25	144.24	179.60	0.99
	t+4	-8.30	-9.29	205.31	295.28	0.98	-3.25	-3.93	180.62	250.72	0.99
	t+5	-12.51	-11.61	269.09	393.79	0.97	-3.93	-4.29	198.65	279.82	0.99
	t+6	-11.18	-12.95	293.10	393.00	0.97	-3.23	-3.55	207.28	299.90	0.99
	t+7	-14.38	-18.52	392.58	505.00	0.96	-2.62	-3.14	245.90	354.18	0.99
	t+8	-14.95	-21.36	480.61	623.35	0.95	-5.10	-4.22	340.65	464.66	0.98
	t+9	-16.32	-25.87	598.96	757.92	0.95	-6.05	-3.61	409.98	544.61	0.97
	t+10	-19.78	-29.40	694.39	860.44	0.95	-6.62	-3.29	456.02	614.26	0.97
NRDFM-III	t+1	0.20	-6.07	171.41	252.20	0.99	0.38	0.08	75.36	126.31	0.99
	t+2	-4.41	-8.01	150.07	202.26	0.99	-1.85	-0.95	95.90	156.77	0.99
	t+3	-4.73	-8.14	163.91	223.09	0.99	-2.64	-1.21	130.06	203.42	0.99
	t+4	-10.00	-13.39	245.33	326.24	0.98	-6.11	-2.33	164.20	270.75	0.99
	t+5	-14.92	-17.79	327.25	444.01	0.98	-6.41	-2.28	193.94	304.30	0.99
	t+6	-11.17	-17.43	333.79	433.39	0.97	-7.38	-2.50	242.79	377.18	0.98
	t+7	-14.12	-22.50	428.51	554.41	0.97	-8.58	-1.78	296.05	439.38	0.98
	t+8	-16.44	-27.43	523.79	664.18	0.96	-9.48	-3.55	298.26	455.43	0.98
	t+9	-18.63	-29.62	591.43	752.09	0.96	-9.67	-2.16	338.32	503.72	0.97
	t+10	-24.05	-33.33	683.09	848.87	0.95	-11.06	-1.98	373.11	566.18	0.96

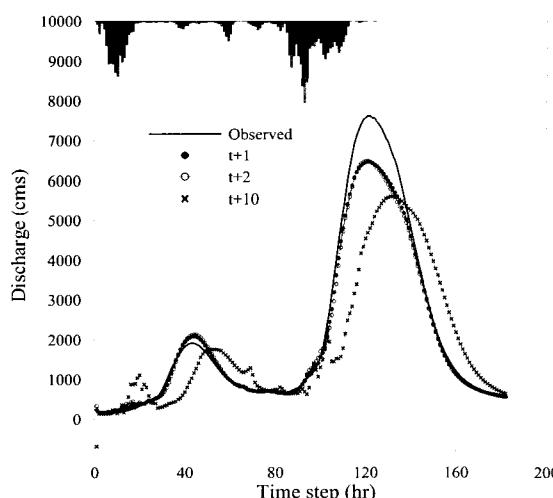


그림 5. 왜관지점 예측 홍수수문곡선(NRDFM-I)

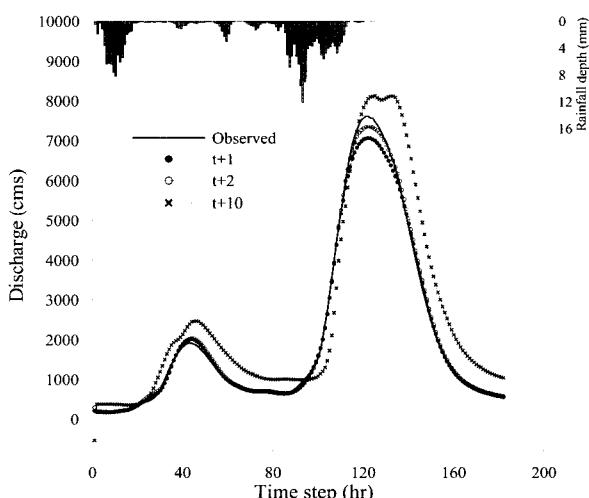


그림 6. 왜관지점 예측 홍수수문곡선(NRDFM-II)

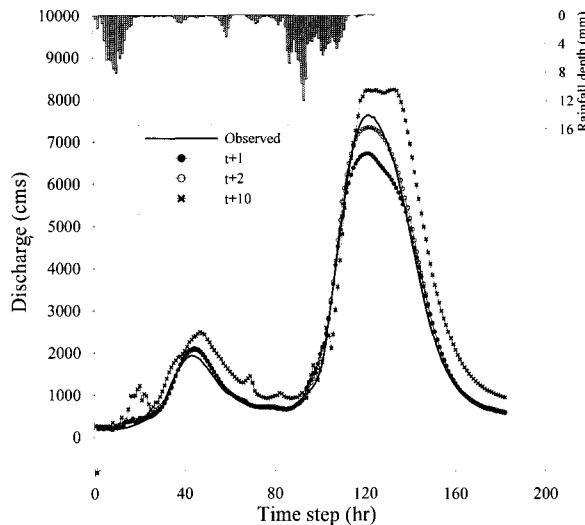


그림 7. 왜관지점 예측 홍수수문곡선(NRDFM-III)

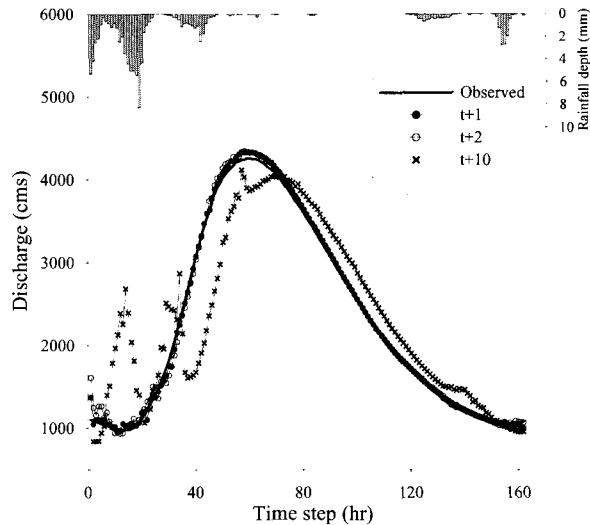


그림 8. 진동지점 예측 홍수수문곡선(NRDFM-I)

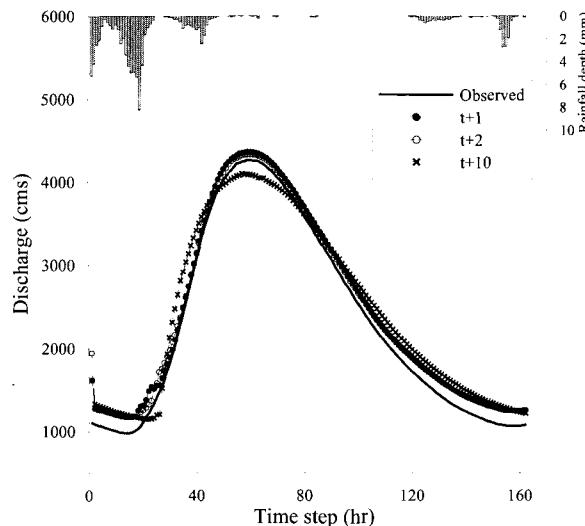


그림 9. 진동지점 예측 홍수수문곡선(NRDFM-II)

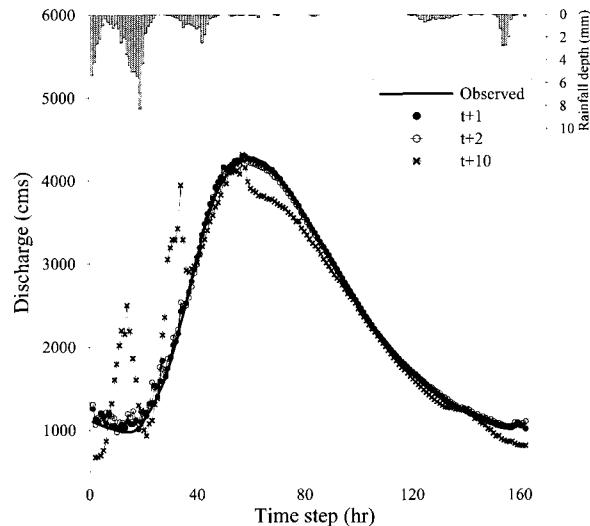


그림 10. 진동지점 예측 홍수수문곡선(NRDFM-III)

과를 요약하면 다음과 같다.

- (1) 신경망에서 각 모형의 매개변수가 물리적인 의미를 갖는다고 할 수는 없지만, 표 3에서와 같이 강우량과 유출량의 선행시간이 대체로 10시간 정도의 지체시간을 갖는다는 것은 강우에 의한 유출의 관계나 상류지점에서 하류지점까지의 유출량이 약 10시간 전의 강우량 및 유출량 값까지 상관성을 갖는다고 할 수 있다.
- (2) 전체적으로 모형의 성능은 강우량에서 유출량으로의 변환을 거치지 않고 대상지점 및 상류지점의 유출량으로 예측을 시도한 NRDFM-II가 가장 우수하였다. 입력변수가 가장 많은 NRDFM-III는 다른 모형에 비해 상대적으로 예측성과가 떨어지므로 입력변수의 개수가 증가함에 따라 오히려 그 예측결과의 정확성을 감소시키는 경향이 있음을

홍수의 예측에 있어 단기간 강우-유출 해석은 홍수통제 및 관리의 측면에서 매우 중요하다. 기존에는 한강 및 낙동강 등에 저류함수법에 의한 유역유출을 예측하여 홍수예경보에 활용하고 있으나, 이는 과거 홍수자료가 부족할 때에는 유용한 모형이었으나 홍수의 실시간 예측에는 많은 문제점이 있다. 본 연구에서는 이러한 문제점을 개선하고 실시간으로 불확실한 강우-유출의 비선형 시스템을 예측하기 위하여 역전파 신경망 모형을 사용하여 입력자료에 따라 3가지 모형을 구축하였다. NRDFM-I은 선행강우량과 선행유출량, NRDFM-II는 대상지점 및 상류지점의 선행유출량, 그리고 NRDFM-III는 선행강우량과 대상지점 및 상류지점의 선행유출량을 입력자료로 하며, 각 모형에 의한 적용결

- 알 수 있었다. 결과적으로 NRDFM-II가 가장 좋은 성과를 나타내었지만, NRDFM-I 및 NRDFM-III의 성과도 충분한 예측 가능성을 나타내고 있다.
- (3) 각 모형에서 단시간 예측에 비해 장시간의 예측결과가 과소 및 과다산정의 경향이 있었지만 상관계수가 0.96 이상이었으므로 장시간 예측에 대한 가능성을 보여주고 있다.

본 연구를 통하여 하천유역에서 발생할 수 있는 집중호우에 의한 홍수유출을 예측하기 위한 신경망 시스템 모형화의 가능성을 검증하였다. 특히, 제시된 모형은 지속적인 수문자료의 축적과 수위-유량관계 곡선의 품질향상 등을 통하여 그 성능을 향상시킬 수 있을 것이며, 신경망 모형을 하천유역의 홍수예보 지점에 확장·적용한다면 실시간 홍수예측으로의 활용이 가능할 것이다. 또한, 차후 홍수기 댐방류량을 고려한 하도홍수 모형의 지속적인 연구가 필요할 것으로 판단된다.

감사의 글

본 연구는 건설교통부 수자원국의 학술연구용역을 통하여 이루어졌으며, 지원에 감사합니다.

참 고 문 헌

- 건설교통부 (2001). 지능형 신경망 모형을 적용한 낙동강 홍수예보시스템 개선
- 건설교통부 낙동강홍수통제소 (2000). 낙동강홍수예경보.
- 김주환 (1993). 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구, 박사학위논문, 인하대학교.
- 심순보, 김만식, 심규철 (1998). “신경망 이론에 의한 다른 목적 저수지의 홍수유입량 예측”, 한국수자원학회 논문집, 한국수자원학회, 제31권, 제1호, pp. 45-57.
- 안경수, 김주환 (1998). “신경회로망을 이용한 유출수문곡선 모의에 관한 연구”, 한국수자원학회논문집, 한국수자원학회, 제31권, 제1호, pp. 13-25.
- 안상진, 전계원 (2001). “RBF를 이용한 홍수유출량 예측”, 대한토목학회 논문집, 대한토목학회, 제21권, 제6-B호, pp. 599-607.
- 이관수, 박성천, 이한민, 진영훈 (2000). “인공신경망 이론의 B.P 알고리즘을 적용한 영산강의 유출량 예측에 관한 연구”, 대한토목학회 논문집, 대한토목학회, 제20권, 제5-B호, pp. 679-688.
- Asaad Y. Shamseldin (1997). “Application of a neural network technique to rainfall-runoff modelling”,

- Journal of Hydrology*, Vol. 199, pp. 272-294.
- Box, G. E. P., and G. M. Jenkins (1976). *Time Series Analysis: Forecasting and Control*, Holden-Day, San Francisco.
- Burnash, R. J., R. L. Ferral, and R. A. McGuire (1973). *A generalized stream-flow simulation system in Conceptual Modeling for Digital Computers*, U.S. National Weather Service, Sacramento, Calif.
- Cameron M. Zealand, Donald H. Burn and Slobodan P. Simonovic (1999). “Short term streamflow forecasting using artificial neural networks”, *Journal of Hydrology*, Vol. 214, pp. 32-48.
- Crawford, N. H., and R. K. Linsley (1966). *Digital simulation in hydrology: Stanford watershed model IV*, Tech. Rep. 39, Dep. of Civ. Eng., Stanford, Calif.
- Hyun-Suk Shin and Jose D. Salas (2000). “Regional drought analysis based on neural networks”, *Journal of Hydrologic Engineering*, Vol. 5, No. 2, pp. 145-155.
- Jason Smith and Robert N. Eil (1995). “Neural-network models of rainfall-runoff process”, *Journal of Water Resources Planning and Management*, Vol. 121, No. 6, pp. 499-508.
- Kimura, Toshimitsu (1961). 저류함수법에 의한 홍수유출추적법(*Flood Runoff Routing by Storage Function Method*), 일본건설성 토목연구소.
- Marina Campolo, Paolo Andreussi, and Alfredo Soldati (1999). “River flood forecasting with a neural network model”, *Water Resources Research*, Vol. 35, No. 4, pp. 1191-1197.
- P.J. Werbos (1974). *Beyond regression: New tools for prediction and analysis in the behavioral sciences*, Ph.D. Thesis, Harvard University, Cambridge, MA.
- 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.
- WMO (1975). *Intercomparison of conceptual models used in operational hydrological forecasting*, Operational Hydrology Report, No. 7, W.M.O, Geneva.

(논문번호:03-61/접수:2003.07.21/심사완료:2004.01.30)