

하천수위표지점에서 신경망기법을 이용한 홍수위의 예측

The Flood Water Stage Prediction based on Neural Networks Method in Stream Gauge Station

김 성 원* / 호세 살라스**

Kim, Sung Won / Salas, Jose D.

Abstract

In this paper, the WSANN(Water Stage Analysis with Neural Network) model was presented so as to predict flood water stage at Jindong which has been the major stream gauging station in Nakdong river basin. The WSANN model used the improved backpropagation training algorithm which was complemented by the momentum method, improvement of initial condition and adaptive-learning rate and the data which were used for this study were classified into training and testing data sets. An empirical equation was derived to determine optimal hidden layer node between the hidden layer node and threshold iteration number. And, the calibration of the WSANN model was performed by the four training data sets. As a result of calibration, the WSANN22 and WSANN32 model were selected for the optimal models which would be used for model verification. The model verification was carried out so as to evaluate model fitness with the two-untrained testing data sets. And, flood water stages were reasonably predicted through the results of statistical analysis. As results of this study, further research activities are needed for the construction of a real-time warning of the impending flood and for the control of flood water stage with neural network method in river basin.

Keywords: WSANN model, Improved Backpropagation Training algorithm, training data, testing data, calibration, verification

요 지

본 연구에서는 낙동강유역의 주요 수위표지점중 진동수위표지점에서 홍수위를 예측하기 위한 신경망모형인 WSANN모형이 제시되었다. WSANN모형은 모멘트방법, 초기조건의 개선 및 적응학습속도에 의해 보완되어진 개선된 역전파훈련 알고리즘을 이용하였고, 본 연구에 사용된 자료는 훈련자료와 테스팅자료로 분할하였으며, 최적 은닉층 노드수를 결정하기 위하여 은닉층노드와 임계학습횟수로부터 경험식이 유도되었다. 그리고 WSANN모형의 보정은 4개의 훈련자료에 의해 실시되었으며, WSANN22와 WSANN32모형이 모델의 검증에 사용될 최적모형으로 결정되었다. 모형의 검증은 훈련되지 않은 2개의 테스팅자료를 이용하여 모형의 적합성을 평가하기 위하여 이루어 졌으며, 통계분석의 결과를 통하여 홍수위를 합리적으로 예측하는 것으로 나타났다. 따라서 본 연구의 결과를 기본으로 신경망기법을 이용한 실시간 홍수예보 시스템의 구축 및 홍수위의 제어에 관한 지속적인 연구가 필요것으로 사료된다.

핵심용어 : WSANN모형, 개선된 역전파훈련 알고리즘, 훈련자료, 테스팅자료, 보정, 검증

* 콜로라도 주립대학교 토목공학과 박사후과정

Postdoctoral Fellow, Dept. of Civil Engrg., Colorado State University, Fort Collins, CO, 80523, U.S.A.
(swkim@lamar.colostate.edu)

** 콜로라도 주립대학교 토목공학과 교수

Professor, Dept. of Civil Engrg., Colorado State University, Fort Collins, CO, 80523, U.S.A

1. 서 론

하천홍수위의 예측은 수자원계획과 운영에 있어서 주요한 입력정보를 형성하며, 만약 주어진 수문년이내에 연속적인 수위추정을 기준으로 행하여 진다면 하천홍수위의 예측은 두가지 측면에서 도움이 될 것이다. 첫째로는 홍수시에 임박한 홍수에 대한 홍수예경보에 대한 정보를 제공할 수 있으며, 두 번째로 홍수시의 저수지의 방류량을 조절하는데 도움이 될 것이다. 하천홍수위에 대한 자료는 일반적으로 자동계측기에 의하여 계측에 편리한 하천수위표지점에서 구할 수 있으며, 이러한 자료 및 이 자료에 기초를 둔 장래홍수사상의 예측은 강우, 침투와 토양특성과 같은 매개변수들의 변동이 비선형으로 하천홍수위에 영향을 많이 끼치기 때문에 매우 어려운 작업이라고 말할 수 있다. 연속적인 하천홍수위의 예측은 직접적인 방법과 간접적인 방법으로 분류되어진다. 직접적인 방법은 통계적인 상관기법을 적용하여 왔으며(Mutreja et al., 1987), 간접적인 방법으로는 강우-유출모델이나 혹은 상류의 유량관측지점에서 목표로 하는 하류의 유량관측지점까지 유출을 추적하는 기법을 통한 유출량의 예측을 이용하여 수위-유량관계곡선에 의한 홍수위로 전환하는 방법을 적용하여 왔다. 그러나 이런 간접적인 방법의 경우 정확한 수위-유량관계곡선이 필요한 것이 필수적이다.

수자원의 모의기법 및 예측에 신경망기법(Neural Networks Method)의 적용에 관한 연구는 1990년대에 와서야 부각되고 있는 실정이다. 신경망에 관한 외국의 연구로는 시공간적 영역에서 강우예측(French et al., 1992), 강우-유출과정에 관한 연구(Smith, 1992; Bonafe et al., 1994; Karunanithi et al., 1994; Hsu et al., 1995; Markus et al., 1995; Smith and Eli, 1995; Dawson and Wilby, 1998; Thirumalaiah and Deo, 1998), 시공간적 가뭄해석(Crespo and Mora, 1993; Shin and Salas, 1997), 저수지운영(Roman and Chandramouli, 1996)에 관한 연구가 수행되었다. 또한 국내에서는 연평균 강우량의 공간해석 및 시공간적 가뭄해석(신현석과 박무종, 1999a, 1999b), 저수지 홍수유입량예측(심순보와 김만식, 1999a), 하천유출량의 비선형 예측(김주환, 1993), 강우예측(오남선과 선우중호, 1996)에 관한 연구가 있으며, 신경망해석을 위한 상용프로그램의 개발로 인하여 연구가 활발히 진행되고 있는 실정이다.(Sigmon, 1989; Demuth and Beal, 1998)

본 연구에서는 낙동강유역의 주요수위표지점인 진동지점에서의 하천홍수위의 예측을 위하여 신경망기법을 이용한 WSANN(Water Stage Analysis with Neural Network)모형을 제시하였으며, 입력자료로는 고령교 및 적포교지점의 홍수위와 유역평균강우량을 이용하였다. 또한 제시한 모형의 보정(Calibration) 및 검증(Verification) 과정을 통하여 최적 훈련매개변수의 선정 및 홍수위사상을 모의(Simulation)하였으며, 모형의 적합성을 검토하였다.

2. 신경망이론

그물과 같이 연결된 뇌의 정보처리과정의 동적기동을 표현하기 위하여 개발된 신경망은 정보, 통신, 제어분야 등 복잡한 문제에 적용되고 있다. 인간의 두뇌를 형성하고 있는 신경조직은 뉴런(Neuron)이라는 신경소자가 복잡하게 얹힌 비선형시스템으로 이들은 서로 연결해 주는 연결강도에 의하여 시스템의 성능을 향상시킨다. 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 표현 될 수 있으며 입력과 출력간의 상관관계는 뉴런간의 연결강도에 의존한다. 또한 연결강도는 훈련과 자기조직에 의하여 조정된다. 신경망은 이러한 뇌와 동일한 계산방식을 사용한 커넥션리즘(Connectionism)에 기반을 둔 수리모형이다. (Freeman and Skapure, 1991; Kosko, 1992; Smith, 1993; Gallant, 1993; Haykin, 1994).

2.1 역전파훈련 알고리즘(Backpropagation Training Algorithm)

역전파훈련 알고리즘은 최급하강법(Gradient descent method)을 이용한 전역오차의 최소화과정을 포함하고 있으며, 네트워크의 연결강도와 편차는 각 반복동안에 오차함수의 음의 경사방향으로 조금씩 이동함으로써 조정되어진다. 반복횟수는 특정한 수렴상태에 도달하거나 혹은 반복횟수가 종료될 경우까지 반복되어지며, 수학적으로 연결강도벡터와 편차벡터의 최급하강을 행렬식의 형태로 나타내면 다음 식 (1)~(2)와 같이 나타낼 수 있다.

$$W^m(k+1) = W^m(k) - ng^m X^{m-1} \quad (1)$$

$$b^m(k+1) = b^m(k) - ng^m \quad (2)$$

여기서 $W^m(k+1)$ 은 m 층에서 $(k+1)$ 회 반복시의 연결강도벡터인데, 본 연구에서는 $m=1$ 은 은닉층, $m=2$ 는 출력층을 나타내고 있으며, $b^m(k+1)$ 은 m 층에서 $(k+1)$ 회 반복시의 편차벡터, $W^m(k)$ 는 m 층에서 k 회 반복시의 연결강도의 벡터, $b^m(k)$ 는 m 층에서 k 회 반복시의 편차벡터, n 은 진행간격의 크기인데 본 연구에서는 학습속도로서 0.95의 값을 나타내고 있으며,

X^{m-1} 은 $m-1$ 층에서의 입력벡터를 나타내고 있다. 또한 g^m 는 구배벡터로서 은닉층에 미분가능한 함수인 로그-시그모이드 전이함수(Log-sigmoid activation function) 및 출력층에 선형전이함수(Linear activation function)를 사용하였으며, 다음 식 (3)~(4)와 같이 나타낼 수 있다. 또한 로그-시그모이드 및 선형전이함수는 다음 Fig. 1과 같이 나타낼 수 있다.

$$g^1 = f^1(x)(W^2)g^2, \quad (3)$$

$$f^1(x) = \frac{d}{dx} \left(\frac{1}{1+e^{-x}} \right) = \left(1 - \frac{1}{1+e^{-x}} \right) \left(\frac{1}{1+e^{-x}} \right)$$

$$g^2 = -2f^2(x)(T-A), \quad f^2(x) = \frac{d}{dx}(x) = 1 \quad (4)$$

여기서 T 는 목표벡터(Target vector), A 는 출력벡터(Output vector)를 나타내고 있다.

역전파훈련 알고리즘을 적용하기 위해서는 먼저 입력자료의 정규화과정과 $-0.5 \sim 0.5$ 범위이내의 난수에 대해 모든 연결강도와 편차의 초기화과정이 필요하다. 각 은닉층노드는 모든 입력층노드에 의해 모여진 입력

연결강도의 합에 편차를 합하여서 로그-시그모이드 전이함수에 의하여 그 결과를 변환시킨다. 또한 각 출력층노드는 은닉층노드에서 계산되어진 것과 같은 방법으로 작용하여 선형전이함수에 의하여 그 결과를 출력시킨다. 이 네트워크의 출력결과(A)와 목표벡터(T)의 차이는 오차구배를 나타내며, 주어진 학습패턴에 대해서 최급하강법은 식 (1)~(2)에 의해서 새로운 연결강도와 편차에 대한 평가를 할 수 있다. 반복횟수는 모든 출력층노드와 훈련패턴에 대해 오차제곱합(Sum of Square Error)이 최소에 도달할 때까지 반복되어진다.

2.2 개선된 역전파훈련 알고리즘(Improved Backpropagation Training Algorithm)

순수한 역전파훈련 알고리즘에서 오차 최급하강법은 사용하기가 간단하나, 문제의 해석에 있어서 다소 노리개 수령되고 안정된 학습을 보장할 수 있는 고정된 학습속도를 선택할 간단한 방법이 없으며, 네트워크가 높은 오차를 갖는 최소로 쉽게 빠질 수 있다. 따라서 이러한 역전파훈련 알고리즘의 문제점을 개선하기 위한 세 가지의 직접적인 방법이 있다. 첫째는 모멘텀방법으로서 오차표면에서 역전파의 민감도를 감소시킴으로서 네트워크가 낮은 오차의 해를 찾는 과정에서 얇은 최소점을 피하는 데 도움을 준다. 두 번째로 초기조건의 개선방법으로 은닉층에 로그-시그모이드와 출력층에 선형전이함수를 가진 네트워크에 대하여 모든 초기조건을 난수를 사용하여 초기화하는 것보다 타당한 값을 취하면, 지역 최소점에 빠질 가능성도 감소하고 학습을 어렵게 하지 않아도 되며, 학습시간도 감소한다. 마지막으로 적응학습속도방법으로 가능한 안정하게 학습을 하면서 학습단계의 크기를 증가시키기 위하여 적응학습속도를 사용하여 학습속도를 감소시킬 수 있

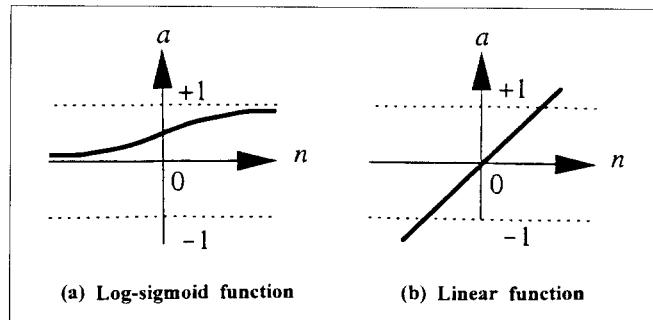


Fig. 1. Activation function (a) Log-sigmoid function
(b) Linear function

다.(Tsoukalas and Uhrig, 1997)

따라서 본 연구에서는 개선된 역전파훈련 알고리즘을 이용하기 위하여 은닉층에 로그-시그모이드 전이함수를 사용하고 출력층에 선형전이함수를 가진 네트워크를 구성하여 은닉층의 연결강도와 편차를 얻기 위하여 Nguyen과 Widrow(1990)가 개발한 층의 입력공간을 교차하여 층의 각 뉴런의 활동영역을 균등하게 분할하기 위하여 변수값을 선택하는 초기조건을 개선한 방법을 적용하고 출력층의 연결강도와 편차는 작은 난수값을 이용하였으며, 모멘트와 적응학습속도를 사용하였다. 본 연구에서 모멘트항을 추가한 연결강도벡터와 편차의 최급하강은 다음 식 (5)~(6)과 같이 나타낼 수 있다.

$$W^m(k+1) = \gamma W^m(k) - (1 - \gamma)ng^m X^{m-1} \quad (5)$$

$$b^m(k+1) = \gamma b^m(k) - (1 - \gamma)ng^m \quad (6)$$

여기서, γ 는 모멘텀계수로서 본 연구에서는 0.9의 값을 사용하였다. 또한 본 연구에서의 개선된 역전파훈련 알고리즘을 이용하여 입력자료를 훈련시키기 위하여 사용된 훈련매개변수는 학습속도, 모멘텀, 평방합오

Table 1. List of training parameters

Patameters	Variable	Value
Learnining rate	lr	0.95
Momentum factor	momentum	0.90
Tolerance of SSE	err_goal	0.001
Increasing multiplier	lr_inc	1.05
Decreasing multiplier	lr_dec	0.70
Error ratio	err_ratio	1.04

차의 허용한계, 학습속도를 증가시키기 위한 승수, 학습속도를 감소시키기 위한 승수와 새로운 오차와 이전 오차의 최대 비로서 다음 Table 1과 같이 나타낼 수 있다. Table 1에 제시한 값들 중에서 학습속도는 Tawfik et al.(1997)에 의해 제시된 값을 이용하였으며, 나머지 값들은 Smith(1993)가 제시된 값을 이용하였다.

3. 분석대상지점의 수문자료해석

3.1 분석대상지점 및 수문자료의 선정

WSANN모형을 적용하기 위한 수위표지점은 낙동강유역의 주요수위표 지점중에 진동지점을 선정하였으

Table 2. Summary of hydrologic data

Station	Date	Total time (hr)	HMS (m)	HMP (mm)	HMR (m ³ /sec)	HAR (m ³ /sec)	TFV (10 ⁶ /m ³)
Koryeonggyo	1984.09.02-1984.09.11	240	11.50	8.56	10,834.4	3,094.8	2,673.9
	1987.07.12-1987.07.21	240	9.09	10.16	6,707.2	1,581.8	1,366.7
	1990.09.11-1990.09.20	240	6.40	7.58	3,233.0	925.9	799.9
	1991.08.22-1991.08.31	240	8.35	6.17	5,377.0	1,839.0	1,588.9
	1993.07.11-1993.07.20	240	8.21	9.79	5,570.7	1,691.9	1,461.8
	1993.08.07-1993.08.16	240	9.05	7.38	6,602.7	2,822.2	2,438.3
Jeokpogyo	1984.09.02-1984.09.11	240	10.80	8.47	8,366.1	2,991.1	2,584.3
	1987.07.12-1987.07.21	240	8.08	10.25	4,491.0	1,265.0	1,093.0
	1990.09.11-1990.09.20	240	6.06	6.64	2,471.0	869.4	751.2
	1991.08.22-1991.08.31	240	8.34	6.81	4,802.4	1,370.0	1,494.7
	1993.07.11-1993.07.20	240	7.90	8.91	4,275.0	1,790.4	1,546.9
	1993.08.07-1993.08.16	240	8.97	6.99	5,473.7	2,850.9	2,463.1
Jindong	1984.09.02-1984.09.11	240	9.98	7.44	8,840.1	3,318.9	2,867.5
	1987.07.12-1987.07.21	240	9.22	12.12	7,445.8	2,735.6	2,363.6
	1990.09.11-1990.09.20	240	6.06	5.35	3,052.1	1,365.9	1,180.2
	1991.08.22-1991.08.31	240	8.78	7.35	6,709.0	2,653.9	2,293.0
	1993.07.11-1993.07.20	240	8.01	8.36	5,521.8	2,386.3	2,061.7
	1993.08.07-1993.08.16	240	9.01	6.36	7,087.2	3,996.5	3,453.0

[Note] HMS : Hourly Maximum Stage, HMP : Hourly Maximum Precipitation, HMR : Hourly Maximum Runoff, HAR : Hourly Average Runoff, TFV : Total Flood Volume

며, 입력자료로는 고령교 및 적포교수위표지점의 홍수위 및 유역평균강우량을 이용하였다. 따라서 각 수위표지점의 홍수위사상은 기왕의 자료중에서 자료의 신뢰성이 비교적 높은 6개의 시간홍수위자료를 채택하였으며, 동시에 동시간대의 유역평균강우량을 산정하여 입력층노드의 자료로 이용하였다. 유역평균강우량의 산정과정은 홍수위사상과 동시간대의 각 강우관측소의 시간강우량에 각 강우관측소의 티센면적비를 곱하여서 티센유역평균강우량(TAMP)을 구하였으며, 고령교수위표지점은 35개의 강우관측소, 적포교는 44개의 강우관측소, 진동수위표지점은 51개의 강우관측소자료를 이용하였다. 또한 홍수위사상 1 ~ 4까지를 신경망모형의 보정에 사용되는 훈련자료(Training data)로 이용하였고, 홍수위사상 5 ~ 6를 신경망모형의 검증에 사용되는 테스팅자료(Testing data)로 이용하였다. 다음 Table 2는 본 연구에 이용된 시간수문자료의 첨두홍수위, 첨두 유역평균강우량, 첨두유출량, 평균유출량 그리고 총 유출체적을 나타내었으며, 본 연구에 이용된 자료는 기존댐 용수공급능력평가(낙동강·금강수계)보고서(1999)에서 제시된 자료를 인용하였다.

또한 진동수위표지점에서의 홍수위는 제시한 고령교 및 적포교수위표지점의 홍수위 및 유역평균강우량 뿐

만아니라 낙동강수계의 다목적댐인 안동, 임하, 합천 및 남강댐의 방류량이 많은 영향을 끼치므로 고려대상이 되지만, 본 연구에서는 홍수위와 유역평균강우량의 범위로만 제한하였다. 그리고 참고로 선정된 6개 홍수위사상에 대하여 낙동강유역의 안동다목적댐과 합천다목적댐은 발전용 방류만이 있을 뿐이고, 여수로와 수문제어에 의한 방류는 없는 것으로 나타났으며, 임하다목적댐의 경우 발전용 방류량과 6번째 홍수위사상(1993/07/19~1993/08/16)에 대하여 여수로 방류량이 있었으나, 다른 홍수위에서는 수문제어에 의한 방류량은 없는 것으로 나타났다. 마지막으로 남강다목적댐에서는 6개의 홍수위사상에 대하여 발전용 방류와 일류문 및 재수문에서는 수문제어에 의한 방류는 있었으나, 배사문에 의한 방류는 없는 것으로 나타났다.

3.2 표본자료의 기초통계분석

표본자료의 기초통계분석은 홍수위사상 표본자료의 평균, 표준편차, 변동계수, 왜곡도계수, 첨도계수 및 1차 계열상관계수를 산정하여 자료의 특성치를 분석하였으며(Salas et al., 1999), 표본자료의 기초통계분석의 결과치는 Table 3과 같이 나타낼 수 있다. Table 3에 의하면 고령교 수위표지점의 홍수위사상의 평균은

Table 3. Summary of basic statistics analysis

Station	Date	Basic statistics					
		Mean(m)	SD(m)	CV	SC	KC	Lag-1
Koryeonggyo	1984.09.02~1984.09.11	5.841	2.924	0.501	0.611	1.931	0.9949
	1987.07.12~1987.07.21	3.403	2.796	0.822	0.892	2.270	0.9960
	1990.09.11~1990.09.20	2.887	1.529	0.530	1.154	2.959	0.9953
	1991.08.22~1991.08.31	3.346	2.921	0.873	0.571	1.780	0.9952
	1993.07.11~1993.07.20	3.537	2.795	0.790	0.113	1.660	0.9929
	1993.08.07~1993.08.16	5.112	2.618	0.512	0.099	1.504	0.9937
Jeokpogyo	1984.09.02~1984.09.11	6.090	2.615	0.429	0.495	1.777	0.9946
	1987.07.12~1987.07.21	3.291	2.642	0.803	0.735	1.846	0.9951
	1990.09.11~1990.09.20	3.329	1.265	0.380	0.988	2.557	0.9946
	1991.08.22~1991.08.31	4.082	2.730	0.669	0.361	1.591	0.9942
	1993.07.11~1993.07.20	3.954	2.513	0.636	0.047	1.564	0.9929
	1993.08.07~1993.08.16	5.748	2.284	0.397	-0.103	1.473	0.9932
Jindong	1984.09.02~1984.09.11	5.750	2.502	0.435	0.480	1.735	0.9943
	1987.07.12~1987.07.21	4.622	2.944	0.637	0.389	1.545	0.9944
	1990.09.11~1990.09.20	4.026	0.988	0.245	0.800	2.384	0.9933
	1991.08.22~1991.08.31	4.837	2.614	0.541	0.214	1.505	0.9939
	1993.07.11~1993.07.20	4.470	2.292	0.513	0.019	1.538	0.9932
	1993.08.07~1993.08.16	6.383	1.934	0.303	-0.151	1.378	0.9927

[Note] SD : Standard deviation, CV : Coefficient of variation, SC : Skewness coefficient,
KC : Kurtosis coefficient

2.887–5.841(m), 표준편차는 1.529–2.924(m), 변동계수는 0.501–0.873, 왜곡도계수는 0.099–1.154, 첨도계수는 1.504–2.959 그리고 1차 계열상관계수는 0.9929–0.9960의 분포를 나타내었으며, 적포교 수위표지점의 홍수위사상의 평균은 3.291–6.090(m), 표준편차는 1.265–2.730(m), 변동계수는 0.308–0.803, 왜곡도계수는 (-)0.103–0.988, 첨도계수는 1.473–2.557 그리고 1차 계열상관계수는 0.9929–0.9951의 분포를 나타내었다. 또한 진동 수위표지점의 홍수위사상의 평균은 4.026–5.750(m), 표준편차는 0.988–2.944(m), 변동계수는 0.245–0.637, 왜곡도계수는 (-)0.151–0.800, 첨도계수는 1.378–2.384 그리고 1차 계열상관계수는 0.9927–0.9944의 분포를 나타내었다. 따라서 기초통계분석의 결과를 검토하면 각 수위표지점에서 비슷한 분포를 나타내고 있는 것으로 나타났다. 특히 홍수위사상의 왜곡도계수의 평균값은 고령교 수위표지점은 0.57, 적포교수위표지점은 0.42 및 진동수위표지점은 0.29을 나타내고 있어서 진동수위표지점의 홍수위사상의 왜곡도계수의 평균값이 가장 0에 근접하는 것으로 나타났으며, 홍수위자료에 대한 1차 계열상관계수의 값의 범위로 판단하면 관측치 시계열의 선형의존성이 높은 것으로 판단된다.

3.3 각 수위표지점의 교차상관분석

동일유역내에서는 홍수시에 홍수조절을 위한 댐 방류조건에 따른 하류 수위표지점의 유량 및 수위에 많은 영향을 끼치므로 교차상관분석을 통하여 각 시계열의 통계학적 특성을 유지하는 것 뿐만 아니라, 시계열

의 상호종속성을 유지할 수 있다. 각 수위표지점에서의 홍수위사상의 상관관계분석을 위하여 교차상관분석(Cross-correlation analysis)을 실시하였으며, 교차상관분석은 먼저 세 수위표지점에서 두 지점의 교차공분산함수(Cross-covariance function)을 구한 후 두 지점의 교차상관계수(Cross-correlation coefficient)를 계산하며, 교차상관계수는 두 지점사이의 시계열 자체(Lag)에 대한 선형종속성을 관측하는데 일반적으로 사용된다. 그리고 교차상관계수의 값은 -1에서 1까지의 범위를 나타내고 있으며, 만약 교차상관계수의 절대치가 1이면 두 지점사이의 자료는 완전 선형종속성이 있으며, 반대로 값이 0이면 선형종속성이 없는 것으로 나타난다. 교차상관계수는 다음 식 (7)과 같이 나타낼 수 있다.

$$\hat{\rho}_k^{(ij)} = \frac{\frac{1}{N} \sum_{t=1}^{N-k} (X_t^{(i)} - \hat{\mu}_X^{(i)}) (X_{t+k}^{(j)} - \hat{\mu}_X^{(j)})}{\hat{\sigma}_X^{(i)} \hat{\sigma}_X^{(j)}} \quad (7)$$

여기서, $\hat{\rho}_k^{(ij)}$ 는 i 및 j지점사이의 지체시간이 k 차인 교차상관계수, $X_t^{(i)}$ 는 i지점 지속기간(t)의 표본자료, $X_{t+k}^{(j)}$ 는 j지점 지속기간(t+k)의 표본자료, $\hat{\mu}_X^{(i)}$ 는 i지점 표본자료의 평균, $\hat{\mu}_X^{(j)}$ 는 j지점 표본자료의 평균, $\hat{\sigma}_X^{(i)}$ 는 i지점 표본자료의 표준편차, $\hat{\sigma}_X^{(j)}$ 는 j지점 표본자료의 표준편차, t는 지속기간(t=1,2,⋯ 시간), k는 지체시간(Lag time)이고

Table 4(a). Summary of lag-0 cross-correlation analysis

Event \ Site	Event 1			Event 2			Event 3			Event 4			Event 5			Event 6		
	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3
1	1.00	0.98	0.98	1.00	0.98	0.95	1.00	0.93	0.81	1.00	0.99	0.98	1.00	0.98	0.93	1.00	0.96	0.91
2	0.98	1.00	1.00	0.98	1.00	0.95	0.93	1.00	0.95	0.99	1.00	0.99	0.98	1.00	0.98	0.96	1.00	0.98
3	0.98	1.00	1.00	0.95	0.95	1.00	0.81	0.95	1.00	0.98	0.99	1.00	0.93	0.98	1.00	0.91	0.98	1.00

Table 4(b). Summary of lag-1 cross-correlation analysis

Event \ Site	Event 1			Event 2			Event 3			Event 4			Event 5			Event 6		
	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3
1	0.99	0.98	0.98	0.99	0.97	0.95	0.99	0.94	0.82	0.99	0.98	0.97	0.99	0.98	0.94	0.99	0.97	0.91
2	0.97	0.99	0.99	0.98	0.99	0.95	0.92	0.99	0.96	0.98	0.99	0.99	0.97	0.99	0.98	0.96	0.99	0.98
3	0.97	0.99	0.99	0.95	0.94	0.99	0.78	0.94	0.99	0.97	0.99	0.98	0.92	0.97	0.99	0.90	0.97	0.99

N 은 표본자료의 수를 나타내고 있다. 또한 두 지점에 대한 교차상관계수의 값을 행렬식으로 나타내었으며, 다음 식 (8)과 같다.

$$\hat{M}_k = \begin{bmatrix} \hat{\rho}_k^{(11)} & \hat{\rho}_k^{(12)} & \cdots & \hat{\rho}_k^{(1n)} \\ \hat{\rho}_k^{(21)} & \hat{\rho}_k^{(22)} & \cdots & \hat{\rho}_k^{(2n)} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\rho}_k^{(n1)} & \hat{\rho}_k^{(n2)} & \cdots & \hat{\rho}_k^{(nn)} \end{bmatrix} \quad (8)$$

여기서, $\hat{\rho}_k^{(ij)}$ 는 식 (7)에 의하여 산정이 된다. 두 지점의 교차상관계수의 값은 지체시간이 0과 1일 경우에 행렬식으로 산정하였으며 다음 Table 4(a)-(b)와 같이 나타내었다. 여기서 1은 고령교 수위표지점, 2는 적포교 수위표지점, 3은 진동 수위표지점을 의미하고 있다.

Table 4(a)-(b)에 의하면 Event 3 홍수위사상의 진동과 고령교 수위표지점의 1차 교차상관계수의 값을 제외하고는 교차상관계수의 값이 0.8이상을 나타내고 있으므로 두 지점사이의 1시간 지체시간에 따른 홍수위사상의 선형종속성이 높은 것으로 나타났다.

4. WSANN모형의 적용

4.1 WSANN모형의 구성

본 연구에서의 비선형 강우-홍수위의 관련성을 모형

화과정을 통하여 신경망에 의한 예측모형을 정의하면 다음 식 (9)와 같이 나타낼 수 있다.

$$X(t+1, t+2, t+3) =$$

$$g_2(\sum_{k=1} W_{kj} \cdot g_1(\sum_{j=1} W_{ji} \cdot X(t-h) + B_{ji}) + B_{kj}) \quad (9)$$

여기서, $X(t+1, t+2, t+3)$ 은 진동수위표지점의 1, 2 및 3시간 예측홍수위, $g_1(\)$ 는 은닉층에서의 로그-시그모이드 전이함수, $g_2(\)$ 는 출력층에서의 선형전이함수, W_{kj} 는 은닉층과 출력층사이의 연결강도, W_{ji} 는 입력층과 은닉층사이의 연결강도, $X(t-h)$ 는 전시간 강우 및 홍수위의 시계열($h=4, 3, \dots, 0$), B_{kj} 는 은닉층과 출력층사이의 편차, B_{ji} 는 입력층과 은닉층사이의 편차를 나타낸 것이며, 편차는 신경망모형이 적절한 해를 찾을 수 있도록 변화를 증가시키거나, 필요한 훈련의 반복횟수를 감소시키는 역할을 하고 있다.

WSANN모형의 입력층 노드수를 결정하기 위하여 일반적으로 고령교에서 진동수위표까지의 홍수파의 도달시간은 약 10시간 미만인데, 신경망모형의 입력층의 노드수를 적절하게 산정하고 또한 홍수파의 영향권 내의 지체시간을 고려하여 홍수위사상의 계열상관계수의 값이 0.95이상일때의 지체시간과 동시간대의 유역평균 강우량을 입력노드로 결정하였다. 따라서 계열상관계수

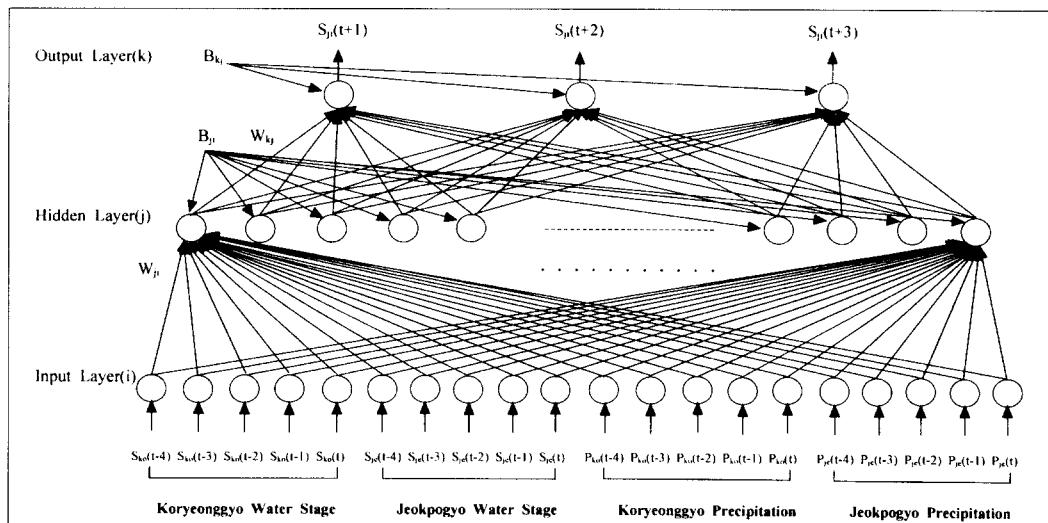


Fig. 2 Architecture of proposed WSANN model

의 값이 0.95이상일때의 지체시간이 각 홍수위사상에 대해서 평균 4시간이므로 신경망모형의 입력층에는 고령교 및 적포교수위표지점의 4시간 전부터 현재시간까지의 10개 계열 홍수위와 유역평균강우량으로 총 20개의 노드로 구성하였으며, 출력층에는 1, 2 및 3시간후의 홍수위 3개의 노드로 구성하여 Fig. 2와 같이 나타내었다. 그리고 Fig. 3은 본 신경망모형의 훈련과정을 나타낸 것이다. Fig. 3에 의하면 본 연구에서는 연결 강도와 편차의 초기화과정은 제시한 바와 같이 은닉층

은 Nguyen과 Widrow(1990) 방법, 출력층은 난수를 이용하였으며, 반복횟수는 특정한 수렴상태에 도달하거나 혹은 반복횟수가 종료할 때까지 계속되며, 오차가 제시한 값의 범위이면 그 때의 연결강도와 편차는 다음의 검증과정을 위하여 저장하여 놓고 프로그램은 정지한다. 그렇지 못할 경우에는 목표벡터와 출력벡터를 비교하여 역전파과정을 거쳐서 연결강도와 편차를 조정하고 일정한 수렴상태나 반복횟수가 종료할 때까지 계속된다.

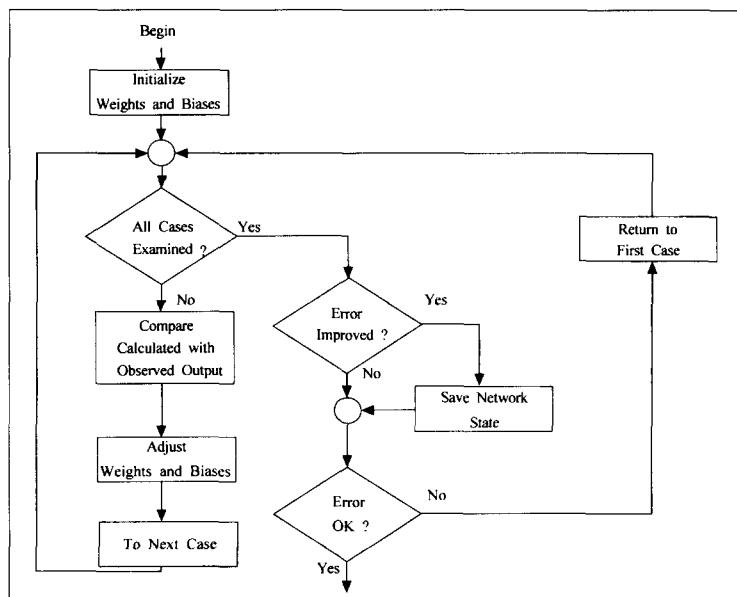


Fig. 3 WSANN model training procedure

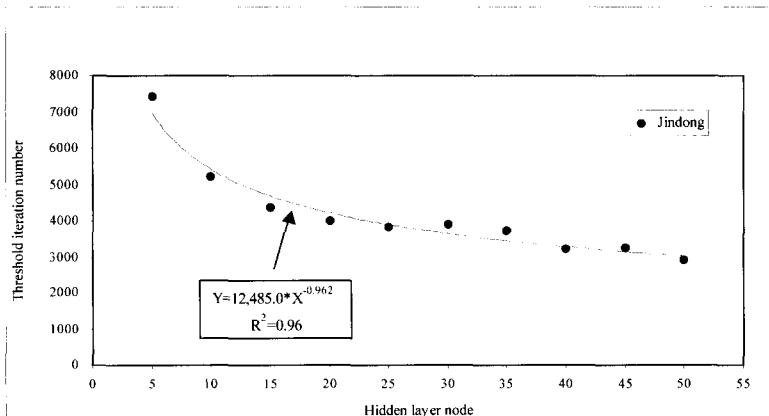


Fig. 4 Relationship of hidden layer node and threshold iteration number

4.2 학습횟수와 은닉층노드의 결정

본 연구의 Table 1에서 선정한 매개변수들을 이용하여 훈련에 사용되는 4개 홍수위사상의 훈련자료에 대하여 은닉층 노드수를 5개에서 50까지 5개씩 증가시켰을 때 오차의 평방합이 허용오차인 0.001과 같거나 감소하기 시작하는 임계학습횟수와의 관계를 유도하였으며, 다음 Fig. 4와 같이 나타낼 수 있다. Fig. 4에 의하면 은닉층 노드수와 임계학습횟수는 비선형 감소함수를 나타내고 있는 것으로 분석되었다. 그러므로 본 연구에서 선정한 은닉층 노드수와 학습횟수는 학습시간과 효율등을 고려하여서 은닉층 노드수는 20개 및 30개를 선정하였으며, 학습횟수는 은닉층 노드수가 20개와 30개일때의 임계학습횟수보다 적은 경우인 2,000회 및 임계학습횟수보다 많은 경우인 5,000회로 결정하였다. 또한 WSANN모형은 은닉층 노드수와 학습횟수에 따라서 세분화하여 모형의 훈련에 이용하였다. 예를들면 WSANN22모형의 앞의 숫자 2는 은닉층 노드수가 20개 일 경우, 뒤의 숫자 2는 학습횟수 5,000번을 나타내고 있다.

4.3 최적모형선정을 위한 통계지표

하천홍수위의 정확한 예측을 위한 최적 WSANN모형을 선정하기 위하여 통계적 분석방법을 이용하였으며, 기존의 범주내에서 모형화의 목적을 만족시켜야 한

다. 따라서 이 과정은 보통 오차해석을 통해서 이루어진다. 본 연구에서의 하천 수위표지점에서 홍수위를 예측하기 위한 지표로서 예측편차(Forecast bias)가 있다. 예측편차는 관측자료와 예측자료사이의 오차의 평균을 나타내고 있으며 다음 식 (10)과 같이 나타낼 수 있다.

$$m(e) = \frac{1}{V} \sum_{t=1}^V [y_t(x) - \bar{y}_t(x)] = \mu_y - \bar{\mu}_y \quad (10)$$

여기서, V 는 자료의 수, $y_t(x)$ 는 홍수위의 관측자료, $\bar{y}_t(x)$ 는 홍수위의 예측자료, μ_y 는 관측자료의 평균, $\bar{\mu}_y$ 는 예측자료의 평균을 나타내고 있다. 그리고 평균제곱오차의 평방근(Root mean square error)의 계산으로 예측정도에 대한 정확성을 평가할 수 있으며, 다음 식 (11)과 같이 나타낼 수 있다.

$$s(e) = \sqrt{\frac{1}{V} \sum_{t=1}^V [y_t(x) - \bar{y}_t(x)]^2} \quad (11)$$

또한 상관계수의 값을 통하여서 예측정도를 평가할 수 있으며, 다음 식 (12)와 같이 나타낼 수 있다.

$$R = \frac{1}{V} \sum_{t=1}^V \left(\frac{y_t(x) - \mu_y(x)}{\sigma_{(y_t(x))}} \right) \left(\frac{\bar{y}_t(x) - \bar{\mu}_y(x)}{\sigma_{\bar{y}_t(x)}} \right) \quad (12)$$

Table 5(a). Summary of statistical analysis for WSANN model calibration(1 hour ahead prediction)

Event	Model	HLN	TI	Statistical Index		
				m(e)(m)	s(e)(m)	R
Event 1	WSANN21	20	2,000	0.0138	0.1801	0.993
	WSANN22		5,000	-0.0002	0.1279	0.994
	WSANN31	30	2,000	0.0210	0.2013	0.992
	WSANN32		5,000	-0.0125	0.1040	0.995
Event 2	WSANN21	20	2,000	0.0303	0.2156	0.993
	WSANN22		5,000	0.0003	0.1664	0.994
	WSANN31	30	2,000	0.0003	0.2485	0.991
	WSANN32		5,000	0.0006	0.2006	0.993
Event 3	WSANN21	20	2,000	-0.0003	0.1074	0.990
	WSANN22		5,000	0.0001	0.1007	0.991
	WSANN31	30	2,000	0.0002	0.1006	0.991
	WSANN32		5,000	0.0004	0.1005	0.991
Event 4	WSANN21	20	2,000	0.0311	0.1620	0.994
	WSANN22		5,000	-0.0001	0.0960	0.995
	WSANN31	30	2,000	0.0002	0.1516	0.994
	WSANN32		5,000	0.0028	0.1339	0.994

[Note] HLN : Hidden Layer Node, TI : Training Iteration

여기서, $\sigma_{(y_t(x))}$ 는 관측자료의 표준편차, $\sigma_{\bar{y}_t(x)}$ 는 예측자료의 표준편차를 나타내고 있다.

4.4 훈련과정을 통한 신경망모형의 보정

낙동강의 주요 수위표지점인 진동지점에서 하천홍수 위의 예측을 위하여 WSANN모형을 훈련시켰으며, 훈련에 사용된 자료는 홍수위사상 1~4까지의 자료를 이

용하였다. 또한 전절 4.3에서 제시한 통계지표를 이용하여 훈련결과를 통계분석하였으며, 다음 Table 5(a)~(c)와 같다. Table 5(a)~(c)에 의하면 1시간 후의 홍수위의 예측일 경우 WSANN모형의 $m(e)$ 는 $(-0.0125\text{--}0.0311)(m)$, $s(e)$ 는 $0.0960\text{--}0.2485(m)$ 및 R 은 0.990이상, 2시간 후의 홍수위의 예측일 경우 WSANN모형의 $m(e)$ 는 $-0.0121\text{--}0.0391(m)$,

Table 5(b). Summary of statistical analysis for WSANN model calibration(2 hour ahead prediction)

Event	Model	HLN	TI	Statistical Index		
				$m(e)(m)$	$s(e)(m)$	R
Event 1	WSANN21	20	2,000	0.0008	0.1669	0.993
	WSANN22		5,000	-0.0002	0.1168	0.995
	WSANN31	30	2,000	0.0160	0.1673	0.993
	WSANN32		5,000	-0.0121	0.1132	0.995
Event 2	WSANN21	20	2,000	0.0391	0.2018	0.993
	WSANN22		5,000	0.0006	0.1727	0.994
	WSANN31	30	2,000	0.0001	0.3258	0.988
	WSANN32		5,000	0.0003	0.2130	0.993
Event 3	WSANN21	20	2,000	-0.0001	0.0971	0.991
	WSANN22		5,000	-0.0001	0.0958	0.991
	WSANN31	30	2,000	0.0003	0.0976	0.991
	WSANN32		5,000	0.0001	0.0924	0.991
Event 4	WSANN21	20	2,000	0.0259	0.1470	0.994
	WSANN22		5,000	-0.0003	0.0960	0.995
	WSANN31	30	2,000	0.0001	0.1930	0.993
	WSANN32		5,000	-0.0013	0.1151	0.995

[Note] HLN : Hidden Layer Node, TI : Training Iteration

Table 5(c). Summary of statistical analysis for WSANN model calibration(3 hour ahead prediction)

Event	Model	HLN	TI	Statistical Index		
				$m(e)(m)$	$s(e)(m)$	R
Event 1	WSANN21	20	2,000	-0.0071	0.1629	0.994
	WSANN22		5,000	-0.0004	0.1152	0.995
	WSANN31	30	2,000	0.0063	0.1521	0.994
	WSANN32		5,000	-0.0102	0.1184	0.995
Event 2	WSANN21	20	2,000	0.0297	0.1820	0.993
	WSANN22		5,000	0.0003	0.1975	0.993
	WSANN31	30	2,000	-0.0001	0.2919	0.990
	WSANN32		5,000	-0.0003	0.1936	0.993
Event 3	WSANN21	20	2,000	0.0003	0.0949	0.991
	WSANN22		5,000	-0.0001	0.0944	0.991
	WSANN31	30	2,000	0.0001	0.0936	0.991
	WSANN32		5,000	0.0001	0.0943	0.991
Event 4	WSANN21	20	2,000	0.0272	0.1647	0.993
	WSANN22		5,000	-0.0002	0.1167	0.995
	WSANN31	30	2,000	0.0001	0.1606	0.994
	WSANN32		5,000	-0.0121	0.1293	0.994

[Note] HLN : Hidden Layer Node, TI : Training Iteration

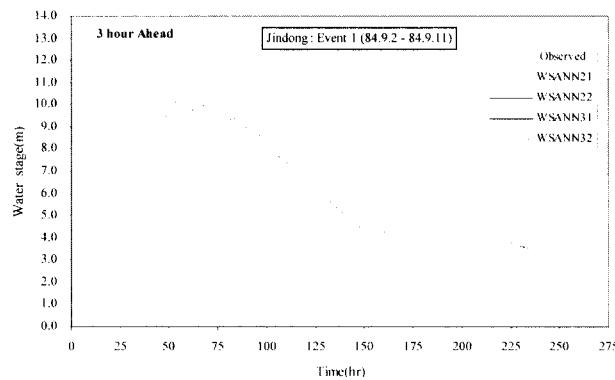


Fig. 5(a) Comparison of observed and calibrated flood water stage in 3 hour ahead prediction(Event 1)

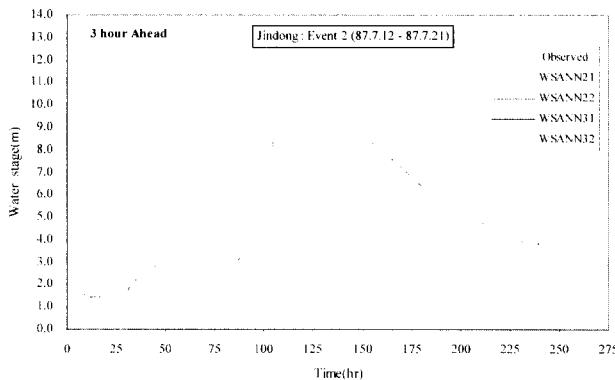


Fig. 5(b) Comparison of observed and calibrated flood water stage in 3 hour ahead prediction(Event 2)

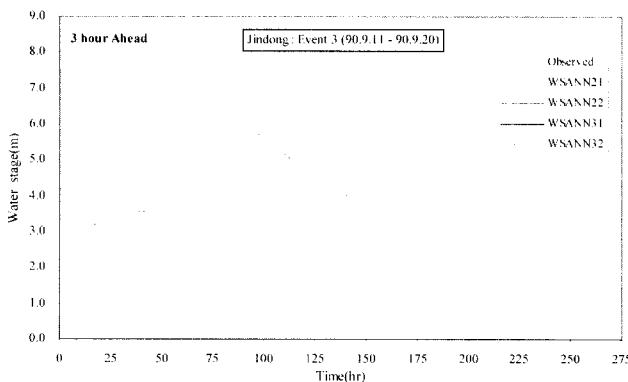


Fig. 5(c). Comparison of observed and calibrated flood water stage in 3 hour ahead prediction(Event 3)

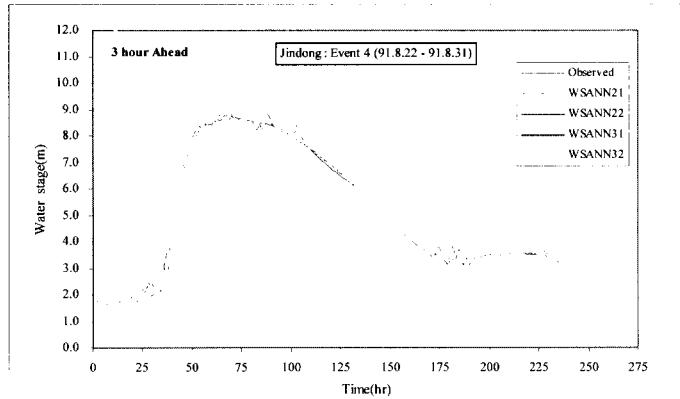


Fig. 5(d). Comparison of observed and calibrated flood water stage in 3 hour ahead prediction(Event 4)

$s(e)$ 는 0.0924–0.3258(m) 및 R은 0.988이상으로 나타났으며, 3시간 후의 예측일 경우 WSANN모형의 $m(e)$ 는 -0.0121–0.0297(m), $s(e)$ 는 0.0936–0.2919(m) 및 R은 0.990이상으로 분석되어 매우 양호한 결과를 보여주고 있으며, 일반적으로 은닉층 노드 수와 학습회수가 많을수록 좋은 결과를 나타내고 있는 것으로 분석되었다. 이상과 같은 모형의 보정을 통하여 모형의 검증에 이용할 모형은 WSANN22 및 WSANN32모형으로 선정하였다. 다음 Fig. 5(a)-(d)는 진동수위표지점에서 홍수위사상 1-4에 대하여 실측 홍수위와 WSANN모형에 의한 3시간 예측홍수위를 나타내고 있으며, 홍수위수문곡선을 검토하면 홍수위의

상승부, 첨두부 및 감소부에서 WSANN모형에 의해 산정한 예측홍수위는 실측홍수위를 잘 반영하는 것으로 분석되었다.

4.5 테스팅과정을 통한 최적 신경망모형의 검증

보정과정에서 제시한 WSANN22 및 WSANN32모형을 검증하기 위하여 훈련되지 않은 홍수위사상인 1993년 7월 11일–1993년 7월 20일 및 1993년 8월 7일–1993년 8월 16일 자료와 신경망모형의 훈련과정을 통해 산정된 WSANN모형의 매개변수인 연결강도 및 편차를 이용하여 진동수위표지점에서 홍수위를 예측하였으며, 예측결과는 다음 Table 6과 같다. Table 6에

Table 6. Summary of statistical analysis for WSANN model verification

Event	Prediction	Model	HLN	Statistical Index		
				$m(e)(m)$	$s(e)(m)$	R
Event 5	1 H Ahaed	WSANN22	20	0.1028	0.2215	0.974
		WSANN32	30	0.0922	0.1392	0.983
	2 H Ahead	WSANN22	20	-0.0859	0.2303	0.964
		WSANN32	30	-0.0435	0.1348	0.973
	3 H Ahead	WSANN22	20	0.0508	0.2308	0.963
		WSANN32	30	-0.0077	0.1383	0.983
Event 6	1 H Ahaed	WSANN22	20	-0.1024	0.2369	0.973
		WSANN32	30	0.0165	0.1902	0.984
	2 H Ahead	WSANN22	20	0.0748	0.2446	0.972
		WSANN32	30	-0.0113	0.1951	0.974
	3 H Ahead	WSANN22	20	0.0736	0.2455	0.972
		WSANN32	30	0.0182	0.1983	0.984

[Note] HLN : Hidden Layer Node

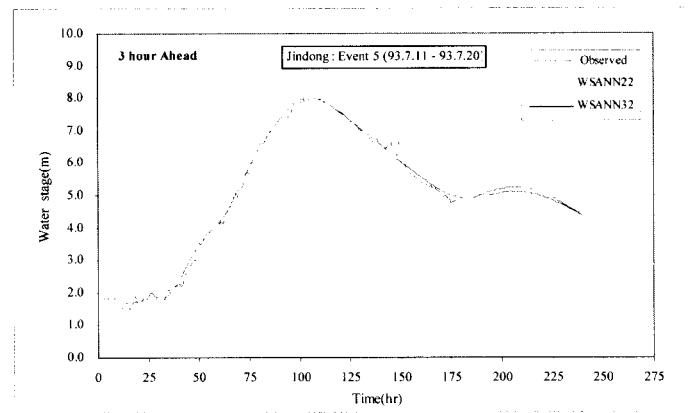


Fig. 6(a). Comparison of observed and verified flood water stage in 3 hour ahead prediction(Event 5)

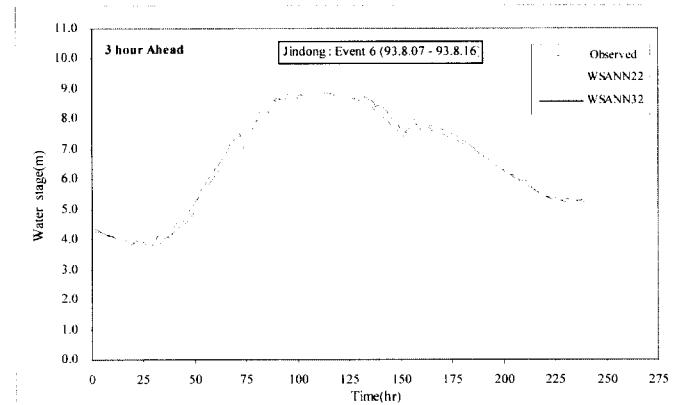


Fig. 6(b). Comparison of observed and verified flood water stage in 3 hour ahead prediction(Event 6)

의하면 보정과정에서 최적모형으로 선정된 WSANN22 및 WSANN32모형을 이용하여 훈련되지 않은 자료로써 홍수위를 예측한 결과 보정과정에서 산정된 것보다는 오차가 큰 것으로 나타났으나, 모형의 적합성을 평가하기 위한 오차의 범위로는 충분히 미소한 것으로 판단되어 하천홍수위의 예측을 위한 WSANN22 및 WSANN32모형의 적합성은 높은 것으로 판단된다. 다음 Fig. 6(a)-(b)는 진동수위표지점에서 홍수위사상 5 및 6에 대한 실측홍수위와 WSANN22 및 WSANN32모형에 의해 3시간 예측 홍수위를 나타내고 있으며, Fig. 7(a)-(b)는 홍수위사상 5 및 6에 대한 실측홍수위와 WSANN22모형에 의해 3시간 예측홍수위의 분산도(Scatter diagram)을

나타내고 있다. Smith(1993)는 실험을 통하여 은닉층 노드수와 학습횟수는 많을수록 좋은 결과를 얻는다고 하였으며, 본 연구의 결과도 Smith(1993)의 실험결과를 반영하는 것으로 분석되었다. 그러나 입력층 노드수, 출력층 노드수, 학습시간 및 효율에 대한 기준이 연구목적에 따라 상이하므로 일반적인 은닉층 노드수와 학습횟수의 설정기준이 확립되어야 한다고 사료된다.

5. 요약 및 결론

일반적으로 하천홍수위의 정확한 예측은 홍수예경보를 통하여 홍수제어에 대한 정보를 제공할 수 있으며, 저수지의 홍수조절을 위한 방류량의 제어에 많은 도움

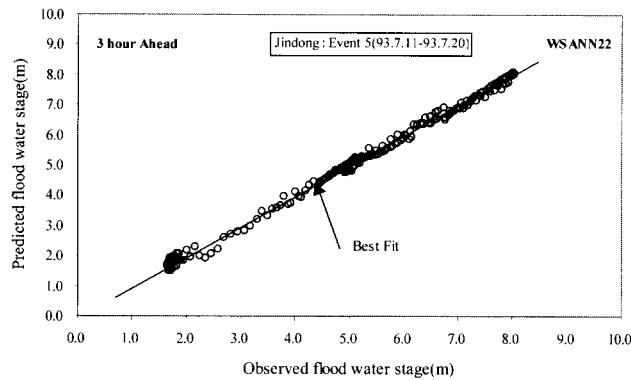


Fig. 7(a). Scatter diagram of observed and verified flood water stage in 3 hour ahead prediction(Event 5)

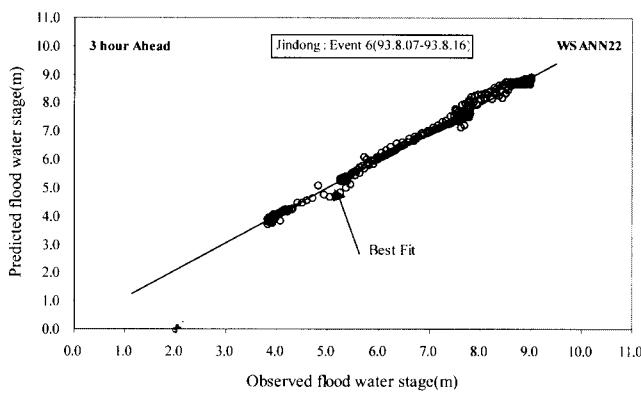


Fig. 7(b). Scatter diagram of observed and verified flood water stage in 3 hour ahead prediction(Event 6)

이 된다. 본 연구에서는 이러한 하천홍수위의 정확한 예측을 위하여 기존의 물리적모형이나 통계학적방법을 대체할 수 있는 인간의 사고과정을 수학적으로 모형화 한 신경망기법을 이용하였으며, 낙동강유역의 진동수위 표지점에서 1, 2 및 3시간후의 홍수위의 예측을 위하여 WSANN모형을 제시하였고 연구결과 다음과 같은 결론을 얻을 수 있었다.

(1) 선정된 홍수위사상의 기초통계치인 평균, 표준편차, 변동계수, 왜곡도계수, 첨도계수 및 1차 계열상관계수의 분석결과 각 수위표지점에서의 통계분석치가

유사한 결과를 나타내고 있으며, 교차상관분석에 의하여 각 수위표지점의 선형의존성이 높은 것으로 나타났다.

(2) 홍수위의 예측을 위하여 제시된 WSANN모형은 개선된 역전파훈련 알고리즘을 이용하였으며, 입력층 노드에서는 고령교 및 적포교수위표지점의 4시간전에서 현재시간까지의 홍수위와 유역평균강우량을 사용하여, 20개의 노드로 구성하였으며, 출력층 노드에서는 1, 2 및 3시간후의 홍수위를 예측하기 위하여 3개의 노드로 구성하였다. 또한 제시된 WSANN모형의 은닉

총 노드수와 학습횟수사이에서 오차의 평방합이 허용 오차와 값이 같거나 작아지는 임계학습횟수와 은닉층 노드수와의 관계를 유도하였다.

(3) 6개의 홍수위사상 중 4개의 홍수위사상을 훈련자료로 선정하였고, 이 훈련자료로서 WSANN모형을 보정하였으며, 보정결과에 대한 통계분석을 통하여 WSANN22 및 WSANN32모형을 검증과정에 이용할 최적모형으로 선정하였다. WSANN모형의 보정과정을 통하여 은닉층 노드수와 학습횟수가 많을수록 양호한 결과를 유도하는 것으로 분석되었다.

(4) 훈련되지 않은 2개의 홍수위사상에 대하여 WSANN22 및 WSANN32모형을 검증하여 모형의 적합성을 검토하였고, 실측홍수위와의 비교결과 하천홍수위를 합리적으로 예측하는 것으로 분석되었으며, 하천홍수위의 예측을 위한 본 WSANN모형은 적합하다고 할 수 있다. 따라서 본 연구결과를 기초로 하여 신경망모형을 이용한 실시간 홍수예경보 시스템의 구축 및 홍수위의 제어에 관한 지속적인 연구가 필요것으로 사료된다.

참 고 문 헌

건설교통부, 한국수자원공사(1999). 기준댐 용수공급 능력조사(낙동강·금강수계)보고서.

김주환(1993). 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구. 박사학위논문, 인하대학교.

신현석, 박무종(1999a). “신경망기법을 이용한 연평균 강우량의 공간해석.” 한국수자원학회논문집, 한국수자원학회, 제32권, 제1호, pp. 3-13.

신현석, 박무종(1999b). “신경망을 이용한 우리나라의 시공간적 가뭄의 해석” 한국수자원학회논문집, 한국수자원학회, 제32권, 제1호, pp. 15-29.

심순보, 김만식(1999a). “총주다목적댐 홍수유입량 예측을 위한 최적 신경망모형의 개발.” 대한토목학회논문집, 대한토목학회, 제19권, 제Ⅱ-1호, pp. 67-78.

오남선, 선우중호(1996). “신경망이론에 의한 강우 예측에 관한 연구.” 한국수자원학회논문집, 한국수자원학회, 제29권, 제4호, pp. 109-118.

Bonafe, A., Galeati, G., and Sforza, M.(1994). “Neural networks for daily mean flow forecasting.” in *Hydraulic Engineering Software V*, Vol. 1, edited by W.R. Blain

and K.L. Katsifarakis, Water Resources and Distribution, Computational Mechanics Publication, Southampton, UK, pp. 131-138.

Bras, R.L., and Rodrigues-Iturbe, I.(1985). *Random functions and hydrology*. Addison-Wesley Publication.

Crespo, L., and Mora, E.(1993). “Drought estimation with neural networks.” *Advanced in Engineering Software*, Elsevier, Whitstable, Kent, UK, pp. 167-170.

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.

Demuth, H., and Beale, M.(1998). *Neural network toolbox : for use with MATLAB user's guide*, The Math Works Inc.

Freeman, J.A., and Skapure, D.M.(1991). *Neural networks algorithms, applications and programming technology*, Addison-Wesley Publishing Co., Reading, MA.

French, M.N., Krajewski, W.F., and Cuykendal, R.R.(1992). “Rainfall forecasting in space and time using a neural network.” *J. of Hydrology*, Amsterdam, Netherlands, Vol. 137, pp. 1-37.

Gallant, S.I.(1993). *Neural network learning and expert systems*, MIT Press, Cambridge, MA.

Haykin, S.(1994). *Neural networks : A comprehensive foundation*, Macmillan College Pub. Comp., Inc.

Hsu, K., Gupta, H.V., and Soroosian, S.(1995). “Artificial neural networks modeling of the rainfall-runoff process.” *Water Reour. Res.*, Vol. 31, No. 10, pp. 2517-2106.

Karunamithi, N., Grenney, W. J., Whitley, D., and Bovee, K.(1994). “Neural Networks for river flow prediction.” *J. of Computing in Civ. Engrg.*, ASCE, Vol. 8, No. 2, pp. 201-220.

Karunamithi, N., Whitley, D., and Malaiya, Y.K.(1992b). “Using neural networks in

- reliability prediction." *IEEE Software*, Vol. 9, No. 4, pp. 53-59.
- Kosko, B.(1992). *Neural Network and Fuzzy systems*, Prentice-Hall, Inc., Eaglewood Cliffs, N.J.
- Markus, Salas, J.D. and M., Shin, H.S.(1995). "Predicting streamflows based on neural network." *1995 First International Conference on Water Resources Engineering*, ASCE, San Antonio, TX.
- Mutreja, K.N., Yin, A., and Martino, I.(1987). "Flood forecasting model for Citandy River." *Flood hydrology*, V.P. Singh, ed., Reidel, Dordrecht, The Netherlands, pp. 211-220.
- Nguyen, D.H. and Widrow, B.(1990). "Neural network for self-learning control systems." *IEEE Control Systems Magazine*, pp. 18-23.
- Roman, H. and Chandramouli, V.(1996). "Deriving a general operating policy for reservoirs using neural network." *J. of Water Resour. Plng. and Mgmt.*, ASCE, Vol. 122, No. 5, pp. 342-347.
- Salas, J.D., Delleur, J.W., Yevjevich, V., and Lane, W.L.(1980). *Applied and modeling of hydrologic time series*, Water Resources Publication, Littleton, CO.
- Salas, J.D., Smith, R. A., Tabios III, G. Q., and Heo, J. H. (1999). *Statistical computer techniques in water resources and environmental engineering*, Unpublished text book in CE622, Colorado State University, Fort Collins, CO.
- Sigmon, K.(1989). *MATLAB primer*, Dept. of Mathematics, Univ. of Florida, Gainesville, FL.
- Shin, H.S., and Salas, J.D.(1997). "Spatial analysis neural network model and its applications to hydrological and environmental data." *Water Resources Paper*, No. 109, Dept. of Civil Engr., Colorado State University, Fort Collins, CO.
- Smith, J.(1992). *Streamflow forecasting using a backpropagation neural network*, M.S. Thesis, West Virginia Univ., Morgantown, WV.
- Smith, J., and Eli, R.N.(1995). "Neural network models of rainfall-runoff process." *J. of Water Resour. Plng. and Mgmt.*, ASCE, Vol. 121, No. 6, pp. 499-508.
- Smith, M.,(1993). *Neural networks for statistical modelling*, Van Nostrand Reinhold, New York, pp. 1-114.
- Tawfik, M., Ibrahim, A., and Fahmy, H.(1997). "Hysteresis sensitive neural network for modeling rating curves." *J. of Computing in Civ. Engrg.*, ASCE, Vol. 11, No. 3, pp. 206-211.
- Thirumalaiah, K., and Deo, M.C.(1998). "River stage forecasting using artificial neural networks." *J. of Hydro. Eng.*, ASCE, Vol. 3, No.1, pp. 26-32.
- Tsoukalas, L.H., and Uhrig, R.H.(1997). *Fuzzy and neural approaches in engineering*, John Wiley & Sons Inc.

(논문번호:99-081/접수:1999.09.29/심사완료:2000.02.12)