

신경망 알고리즘을 적용한 유출수문곡선의 예측 Forecasting of Runoff Hydrograph Using Neural Network Algorithms

안 상 진* / 전 계 원** / 김 광 일***
Ahn, Sang Jin / Jun, Kye Won / Kim, Kwang Il

Abstract

The purpose of this study is to forecast of runoff hydrographs according to rainfall event in a stream. The neural network theory as a hydrologic blackbox model is used to solve hydrological problems. The Back-Propagation(BP) algorithm by the Levenberg-Marquardt(LM) techniques and Radial Basis Function(RBF) network in Neural Network(NN) models are used. Runoff hydrograph is forecasted in Bocheong stream basin which is a IHP the representative basin. The possibility of a simulation for runoff hydrographs about unlearned stations is considered. The results show that NN models are performed to effective learning for rainfall-runoff process of hydrologic system which involves a complexity and nonlinear relationships. The RBF networks consist of 2 learning steps. The first step is an unsupervised learning in hidden layer and the next step is a supervised learning in output layer. Therefore, the RBF networks could provide rather time saved in the learning step than the BP algorithm. The peak discharge both BP algorithm and RBF network model in the estimation of an unlearned are a is trended to observed values.

keywords : Runoff Hydrograph, Back-Propagation algorithm, Levenberg-Marquardt method, Radial Basis Function Network

요 지

본 연구는 하천에서 호우의 발생에 따라 하천 유출수문곡선을 예측코자 블랙박스모형의 신경망이론을 적용하여 수문학적인 문제를 규명하고자 하였다. 이를 위해 신경망 이론 중 Levenberg-Marquardt 방법에 의한 오차역전파 알고리즘과 Radial Basis Function Network(RBFN)를 이용하여 IHP 대표유역인 보청천유역에 수문곡선을 적용하여 선행유출량 예측과 미학습 유역의 적용성을 검토하였다. 그 결과 복잡하고 비선형적인 수문계의 강우-유출 과정의 학습에 있어 RBFN은 은닉층에서 자율학습, 출력층에서 지도학습의 두 단계로 나누어 학습을 함으로서 BP 알고리즘보다 학습 시간이 빠르게 나타났고, 선행유출량의 예측 결과 여러 통계적 지표에서 RBFN이 BP 알고리즘 보다 좋은 결과를 얻을 수 있었다. 미학습 유역의 적용성 검토에서도 BP 알고리즘과 RBFN 모두 침투치가 비교적 실측자료의 경향과 비슷한 경향으로 나타났다.

핵심용어 : 유출수문곡선, 역전파알고리즘, Levenberg-Marquardt method, Radial Basis Function Network

* 충북대학교 토목공학과 교수

Professor, Dept. of Civil Engineering, Chungbuk National University, Cheongju, Chungbuk 361-763, Korea
hydrosys@truit.chungbuk.ac.kr

** 충북대학교 대학원 토목공학과 박사과정

Doctoral Student, Dept. of Civil Engineering, Chungbuk National University, Cheongju, Chungbuk 361-763, Korea

*** POSCO 자원역

POSCO, Seoul 138-130, Korea

1. 서론

인류의 역사는 물과 함께 발전해 왔으며 물은 인류의 생존과 번영을 위해 커다란 공헌을 하고 있다. 그러나 이러한 물은 또한 가공할 자연재해 중의 하나로 인류를 위협하고 있다. 자연재해 중 우리 나라에서는 집중호우에 의한 홍수피해가 자주 발생하고 있다. 이러한 홍수피해를 줄이기 위해서는 그 지역의 강우-유출 과정을 정확히 해석해 홍수유출특성을 파악하는 것이 중요하다. 그러나 자연현상인 강우와 유출관계를 규명하는 일은 매우 복잡하여 하천에서의 유출량 추정에 많은 어려움을 겪어 왔다. 신경망 모형은 입력과 출력으로 구성되는 하나의 시스템을 병렬적이고 비선형적으로 구축할 수 있다는 장점 때문에 불확실한 강우-유출모형에 적용하기에 유리한 장점을 가지고 있다.

1990년 이후부터 신경망 이론을 이용해 유출현상을 해석하는 많은 연구가 발표되었다. French 등(1992)은 사-공간분포를 신경망모형의 입력력 자료로 구성하여 강우의 공간분포를 예측하였고, Karunanithu(1994)는 하천의 유출예측에 cascade-correlation 알고리즘을 적용해 유출수문곡선의 해석을 하였다. 한편 Hsu 등(1995)은 강우-유출 과정에 대해 신경망모형과 ARMAX 모형, SAC-SMA 모형을 적용하였으며, 비교적 신경망 모형의 적용이 좋은 결과를 나타내었다. 그리고 Mason 등(1996)은 강우-유출 과정을 해석하기 위해 Radial Basis Functions을 적용한 바 있다. Tohma 등(1996)은 과거의 강우와 유출량자료를 이용하여 홍수유출량 예측에 신경망모형을 적용하는데 학습에 사용된 과거의 호우사상에 대해 1시간, 3시간, 6시간 선행예측을 하여 신경망의 선행예측 시간에 대한 적용성을 검토하였다. Thirumalaiah(1998)는 신경망이론을 실시간 홍수위 예측에 이용하였다.

한편, 국내에서는 강관원 등(1992)과 김주환(1993)에 의해서 홍수시의 일단위와 시간위의 하천유출량을 예측할 수 있는 신경망모형을 구성하여 전이함수모형과 비교하였으며, 오경두와 진병호(1994)는 미계측유역의 강우-유출 시뮬레이션에 적용하였다. 그리고 오남진(1996)은 신경망이론을 이용한 강우예측모형을 구성하고 그 예측능력과 장·단점 등을 추계학적모형과 비교·검토한 바 있으며, 김만식(1998)은 다목적 저수지의 홍수유입량 예측을 위해 역전파알고리즘을 이용한 신경망모형을 개발하였다. 고원준 등(1999)은 신경망모형을 이용해 실시간으로 저수지의 유입량 예측모형을

구성하였고, 안상진 등(1999)은 Radial Basis Function Network(RBFN)를 이용해 유출수문곡선을 예측하였다.

따라서, 본 연구의 목적은 호우의 발생에 따른 하천 유역의 유출수문곡선을 예측하기 위해 신경망모형의 알고리즘 중 Levenberg-Marquardt 방법에 의한 오차역전파 알고리즘과 Radial Basis Function Network를 이용하여 IIIIP 대표유역인 보청천유역에 적용하여 선행유출량을 예측하고 이를 미하수 유역인 낙동강의 위천유역과 한강의 평창강유역에 적용하여 유출수문곡선을 예측하고 알고리즘의 적용가능성을 검토하는데 그 목적이 있다.

2. 신경망 이론

2.1 기본개념

인간의 뇌는 어떻게 해서 새로운 것을 배우는 지능을 가지게 되는 것일까? 그것은 바로 인간의 뇌의 구조가 정적인 상태에 있는 것이 아니라 주어진 자극에 대해 자신의 내부 상태를 능동적으로 변화시키는 동적인 시스템이기 때문이다. 그리고 인간의 뇌는 뉴런(neuron)이라는 신경소자가 복잡하게 얽힌 신경조직으로 형성되어 있기 때문에 복잡한 문제를 병렬처리할 수 있을 뿐 아니라 학습능력이 있어 지식의 분산 표현 방식, 디지털과 아날로그 신호의 처리 등 기존의 컴퓨터와는 전혀 다른 구조와 동작 방식을 사용하고 있다. 따라서 신경망은 이러한 뇌의 구조와 동작 방식을 단순화시켜 수학적으로 모델링 함으로써 뇌를 모방하고 있다. 신경망은 학습방법에 따라 지도학습(supervised learning) 모형과 자율학습(unsupervised learning) 모형으로 크게 구분된다. 지도학습에서 신경망은 출력값과 비교할 수 있는 미지의 정답이 존재하며, 그 오차를 이용하여 학습을 수행하게 된다. 지도학습은 교사 학습(learning with a teacher)이라 불리기도 하며 신경망에게 정확한 값을 알려주거나 출력값이 맞는지 틀리는지를 알려준다. 반면에 자율학습에서는 이용 가능한 정보로써 입력자료들 또는 신호만이 제공되며 신경망은 스스로 입력자료의 흥미 있는 범주나 특징을 발견해야만 한다. 따라서 자율학습 모형은 정확한 정보 없이 자기조직화에 의해 훈련을 하게 되고 결과를 출력한다.

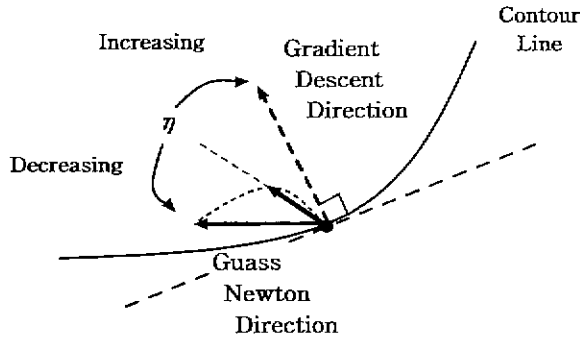


그림. 1 Levenberg-Marquardt 방법의 η

2.2 역전파 알고리즘

역전파 신경망(Back-Propagation Network: BPN)은 다층 퍼셉트론(Multi-Layer Perceptron: MLP)의 학습방법을 체계적으로 정리한 것으로서, 각각의 입력에 대해 기대하는 출력과 동일하거나 유사한 출력을 얻기 위해 반복학습을 통하여 신경망의 연결강도의 값을 구하는 알고리즘이다. MLP에서 이러한 학습은 입력 값과 우리가 원하는 목표 값을 가지고 연결강도를 조정하는 지도학습(supervised learning)을 하는 알고리즘이며, 전달함수(ϕ)는 비선형 함수를 사용하는데 주로 시그모이드 함수가 널리 사용되며 식(1)과 같다.

$$\phi(r) = (1 + e^{-r})^{-1} = \frac{1}{1 + e^{-r}} \quad (1)$$

전달함수에 의한 은닉층의 출력은 식(2)와 같이 나타낼 수 있다.

$$t_j = \phi(r_j) = \phi(\sum W_{ij}x_i) \quad (2)$$

여기서, W_{ij} 는 입력층과 은닉층 사이의 연결강도, x_i 는 입력자료, t_j 는 출력노드에 의해 전달되는 은닉층의 출력이다. 출력층에서 조합함수(combine function)는 주어진 실제출력 $y^{(k)}$ 에 대한 집단 $Y^{(k)}$ 에 따라 기증되어 합해지며 식(3)과 같다.

$$y^{(k)} \approx Y^{(k)} = \sum_{j=1}^n c_j^{(k)} t_j = \sum_j c_j^{(k)} \phi(\sum_i W_{ij}x_i) \quad (3)$$

여기서, c_j 는 은닉층과 출력층 사이의 연결강도, w_{ij} 는 입력층과 은닉층 사이의 연결강도이다.

2.2.1 Levenberg-Marquardt(LM) 방법

역전파 알고리즘에 의한 학습 과정에서 발생할 수 있는 지역최소값(local minima value)문제와 오차를 적게 해서 수렴 속도를 빨리 하여 학습 속도를 향상시키기 위해 Levenberg-Marquardt 방법을 이용하였다. 이 방법은 연결강도를 조정할 때 Levenberg-Marquardt update rule을 사용하게 되는데 그 자체가 일련의 선형방정식들의 해인 탐색방향을 사용하며, 행렬 형식으로 된 Levenberg-Marquardt update rule은 식(4)과 같다(Demuth와 Beale, 1994).

$$\Delta W = (J^T J + \eta I)^{-1} J^T e \quad (4)$$

여기서, J 는 각 연결강도에 대한 오차 미분의 Jacobian 행렬, η 는 적응학습을 I 는 항등행렬 그리고 e 는 오차벡터이다.

식(4)에서 η 가 증가하면 그림 1과 같이 최급하강법의 방향으로 근접하고, η 가 감소하면 가우스-뉴턴법의 방향으로 근접하게 되는데 가우스-뉴턴법은 빠르면서 극부최소값(error minima)에도 더 정확하게 가까워진다. 따라서, 적응학습을 η 를 조정하여 가능하면 가우스-뉴턴법 방향으로 근접하게 한다.

2.3 Radial Basis Function Network

Radial Basis Function Network(RBFN)는

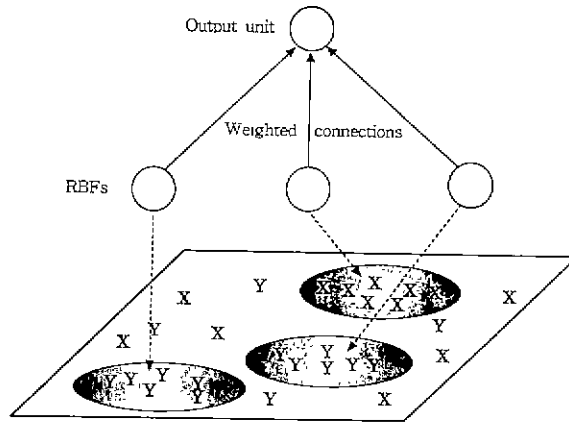


그림 2. RBFN의 학습

1988년 Broomhead & Lowe와 1989년 Moody & Darken등에 의해 radial function에 기반을 둔 네트워크를 제시함으로써 이에 대한 연구가 활발히 진행되어 왔다. MLP는 일반적으로 높은 분류능력을 가지고 있는 반면 학습시간 및 국부 최소값의 문제점을 가지고 있다. 이에 반해 RBFN는 학습속도가 빠르고 구성이 간단하며 분류능력이 우수한 장점이 있다. 그리고 은닉층에서 MLP가 시그모이드 함수인 것에 반해 RBFN에서는 가우시안 함수(gaussian function)를 사용한다.

RBFN의 학습 알고리즘은 여러 가지가 있다. 이 알고리즘의 대부분이 학습 알고리즘을 두 단계로 나누어 학습을 한다. 즉, 은닉층에서의 학습과 출력층에서의 학습 알고리즘으로 나누어진다(Hush, 1993).

은닉층에서의 학습은 클러스터링 알고리즘을 이용한 자율학습(unsupervised learning)을 한다. 여러 가지 클러스터링 알고리즘이 있지만 그 중 구현이 쉽고 간단하여 여러 응용 분야에서 많이 사용되는 알고리즘으로 k-means 클러스터링 알고리즘이 있다. k-means 클러스터링 알고리즘은 데이터의 집단화와 분석의 연구에 많이 이용되는 방법으로 각 집단의 중심으로부터 그 집단 내에 포함된 데이터 사이의 오차를 최소화하도록 집단의 중심점을 결정하는 것이다. 그림 2는 RBFN의 학습을 나타내고 있다. 출력층에서의 학습은 은닉층의 학습이 끝나고 난 뒤 하게 된다. 이때 은닉층 사이에서는 연결된 연결강도만 변하게 되고 일반적으로 최소평균자승(Least Mean Squares' LMS) 알고리즘을 이용하여 학습을 하게 된다(Hush, 1993).

3. 모형의 적용

3.1 대상유역 및 강우-유출 자료

홍수기의 유출수문곡선 예측을 위해 IFP대표유역인 보청천 기대지점(No.2)의 1983년부터 1993년 사이의 25개의 주요 호우사상을 매개변수 추정을 위한 학습자료로 사용하였고 1995년부터 1998년 사이의 10개의 호우사상을 검증자료로 이용하였다. 그리고 1998년 호우 및 유출자료를 검증자료로 사용하였다. 또한 타 지점의 유출수문곡선 예측을 위해 금강의 보청천 산계지점(No.1) 및 낙동강의 위천유역과 한강의 평창강유역의 주요 지점에 대한 호우 및 유출자료를 사용하였다. 기대지점의 선정된 호우 및 유출자료는 표 1과 같다.

3.2 모형의 구성 및 최적모형 선정

3.2.1 모형의 구성

본 연구에서는 하천 유출량의 모형화를 위해 시간의 흐름에 따른 비선형 강우-유출량의 관련성을 식(5)와 같이 정의하여 사용하였다. 또한, 입력변수를 결정하기 위해 예측할 유출량의 전시간 유출량자료 및 강우량자료를 고찰하여 입출력 변수들을 구성하였다.

$$Q(t+1) = f [R(t-k_i), Q(t-k_j)] \text{ for } k_i = 0, \dots, n, k_j = 0, \dots, m \quad (5)$$

여기서, $Q(t+1)$: 1시간 후의 예측 유출량,
 $R(t-k_i)$: k_i 시간 전의 강우량, $Q(t-k_j)$: k_j 시간

표 1. 보령천 기대지점의 주요 호우사상


No	beginning date	rainfall duration (hr)	discharge duration (hr)	maximum rainfall (mm/hr)	maximum discharge (cms)
1	1983. 6.19 08:00	10	72	14.90	167.17
2	1983. 7.14 15:00	16	104	8.22	91.71
3	1983. 8.23 24:00	14	46	10.30	57.57
4	1984. 6. 6 13:00	13	53	16.70	88.86
5	1984. 6.18 13:00	8	57	20.70	90.56
6	1984. 7.12 13:00	10	67	9.90	145.25
7	1984. 7.29 08:00	8	39	13.50	39.52
8	1985. 8.29 13:00	6	46	6.40	31.99
9	1985. 9. 6 16:00	6	100	14.80	82.46
10	1985. 9.18 23:00	13	50	10.50	275.73
11	1986. 6.28 13:00	9	70	9.20	67.24
12	1986. 7.11 07:00	7	47	11.00	69.65
13	1986. 8.27 09:00	6	61	9.30	40.91
14	1987. 6. 1 18:00	21	129	5.10	81.05
15	1987. 6.10 15:00	13	89	14.00	148.75
16	1987. 8. 2 22:00	4	32	5.40	53.67
17	1987. 8. 7 14:00	10	52	7.5	100.13
18	1988. 7.11 07:00	8	30	14.08	229.62
19	1988. 7.23 10:00	4	27	8.64	148.14
20	1990. 6.19 05:00	19	55	13.10	21
21	1990. 8.20 14:00	28	71	22.00	201.64
22	1991. 9.26 10:00	33	92	5.83	58.30
23	1992. 8.24 19:00	16	78	14.54	78.89
24	1993. 6.28 07:00	36	56	18.68	249.44
25	1993. 8.20 17:00	25	56	5.17	76.35
26	1996. 6.16 20:00	40	100	15.59	573.86
27	1996. 6.24 06:00	66	100	9.36	253.69
28	1996. 7.12 23:00	81	100	3.93	25.59
29	1996. 8.26 01:00	75	100	8.57	84.83
30	1997. 6.24 11:00	31	94	19.74	357.04
31	1997. 6.30 21:00	32	78	24.53	933.82
32	1997. 7. 4 24:00	44	97	10.85	889.47
33	1997. 7.15 05:00	40	92	9.95	272.96
34	1997. 8. 2 24:00	59	121	36.36	986.37
35	1998. 6.24 16:00	41	82	12.82	158.53
36	1998. 6.30 10:00	65	95	17.52	634.00
37	1998. 8. 4 04:00	37	72	12.80	248.97
38	1998. 8.10 21:00	49	69	37.13	6140.29

전의 유출량, k_i, k_j : 각각 n, m 개의 시제열이다.


3.3.2 최적모형의 선정

BPN모형은 은리층의 노드수 결정을 위해 노드 수를 5개~30개로 결정하여 수행하였고, 학습회수는 300

회~1,000회를 수행하였다. 그 결과 SSE의 빈화에 따라서 노드수는 5개, 10개, 12개, 15개로 결정하였고, 학습회수는 학습후 예측결과가 우수한 600회로 선정하였다. RBFN모형은 노드수와 중심값의 선택을 위해 15개~40개의 노드로 수행하였으며, 입력공간에서 영



(a) 1997년 6월 24일



(b) 1998년 8월 4일

그림 3. 유출수문곡선의 검증결과


역의 폭 결정에 중요한 역할을 하고 중심값에 영향을 미치는 spread 상수의 결정을 위해 0.1~20까지 spread 상수의 크기를 변화하며 학습을 수행하였다. 그 결과 노드수는 15개, 20개, 25개, 30개로 결정하고, spread 상수는 학습후 예측결과가 우수하게 나타난

4.0으로 선정하였다 그리고 보청천 유역 기대지점(유역면적 351.58km)의 주요 호우사상을 학습하여 매개변수를 추정하였고, 이를 학습에 사용되지 않은 1995년부터 1998년 사이의 10개의 호우사상에 적용하여 예측능력을 검증하였다. 모형의 검증결과는 그림 3 및

표 2. BPN과 RBFN의 검증결과 비교

Algorithm	구분	은닉층 노드수	학습회수 spread 상수	CC	R ²	RMSE	MF (%)	VE (%)	Time (min)
BP (Levenberg Marquardt)	BP1	5	Iterations 600	0.983	0.965	58.411	5.562	2.727	155
	BP2	10		0.982	0.963	56.896	2.441	2.388	235
	BP3	12		0.920	0.848	85.139	3.011	6.543	258
	BP4	15		0.933	0.881	72.676	2.569	5.135	312
RBF	RBF1	15	Spread 4.0	0.989	0.978	46.428	2.222	2.034	98
	RBF2	20		0.987	0.975	49.281	2.409	2.119	139
	RBF3	25		0.985	0.970	51.879	1.652	2.138	174
	RBF4	30		0.984	0.969	54.496	4.079	2.167	197

(a) BP2 모형의 구조



(b) RBF1 모형의 구조




그림 4. 최종 선정된 모형의 구조

표 2와 같다. 그림 3에서 알 수 있듯이 BPN은 RBFN에 비해 국부적으로 약간 진동을 하나 모두 매우 양호한 결과를 보이고 있다.

통계분석 결과 표 2에서 상관계수(correlation coefficient: CC)는 BPN에서 0.92이상, 결정계수(coefficient of determination: R^2)는 0.84이상, 평균제곱오차(root mean square error: RMSE)는 56.90~85.14사이, 침투유량의 퍼센트오차(percent error of maximum flow: MF)와 유출용적의 퍼센트오차(percent volume error: VE)는 각각 5.6%, 6.6% 이내로 나타났고, RBFN에서는 CC 0.98이상, R^2 0.96이상, RMSE는 49.28~54.50사이, MF와 VE는 각각 4.1%, 2.2% 이내로 나타났다. 따라서 최종 모형으로 BPN과 RBFN에서 각각 가장 좋은 통계분석 결과를 나타낸 BP2모형(학습회수 600회, 노드수 10)과 RBF1모형(spread상수 4.0, 노드수 15)을 최종 모형으로 선정하였고, 선정된 두 모형의 구조를 그림 4

에 도시하였다.

4. 결과분석

4.1 결과의 검증


본 연구에서 최적 모형으로 선정된 BP2와 RBF1 모형을 검증하기 위해 케릴라성 호우로 큰 피해를 준 1998년 8월 10일 호우사상에 적용하여 유출수문곡선을 1시간~4시간 선행예측 하였다. 예측결과는 그림 5 및 표 3에 나타났다. 그림 5에서 알 수 있듯이 선행예측결과 BP2 모형은 3시간, RBF1 모형은 4시간까지 양호한 결과를 얻었으며, BP2 모형은 출력함수인 시그모이드 함수의 특성으로 인하여 RBF1 모형보다 더 overfitting 또는 underfitting되는 결과를 나타내었다.

표 3에서 알 수 있듯이 BP2모형은 선행예측 3시간 이후 오차가 크게 증가하였고, RBF1모형은 선행예측


표 3. 선행예측한 유출수문곡선의 통계적 특성('98. 8.10)

Network	Lead time	CC	R^2	RMSE	MF (%)	VE (%)
BP2 (Levenberg Marquardt)	1	0.978	0.956	325.989	5.651	-2.718
	2	0.969	0.938	409.337	11.826	2.972
	3	0.835	0.697	924.906	15.355	0.484
	4	0.837	0.701	1039.659	23.487	14.611
RBF1	1	0.984	0.969	275.190	0.985	-2.849
	2	0.967	0.935	396.074	1.787	2.171
	3	0.920	0.846	612.516	3.090	-2.232
	4	0.902	0.814	737.754	11.070	14.686


(a) 1시간 선행예측 결과



(b) 2시간 선행예측 결과



(c) 3시간 선행예측결과



(d) 4시간 선행예측결과




그림 5. 선행예측 결과(보청천의 기대지점)





그림 6. 미학습유역의 유출수문곡선 예측 결과(보청천의 신계지점)

4시간까지 양호한 결과를 나타내었으며, RBF1모형이 BP2모형에 비해 좀더 정확한 결과를 나타내었다.

4.2 미학습 유역의 적용성 검토

본 연구에서 미학습 유역의 유출수문곡선 예측에 관한 적용성을 검토하기 위해 학습대상에 포함 안된 유

역 면적이 300km² 이상인 금강 보청천 유역의 산계 지점, 낙동강 위천 유역의 무성, 병천 지점 및 한 강 평창강 유역의 방림, 상안미 지점의 자료를 최적모형으로 선정된 BP2모형과 RBF1모형에 적용하여 유출수문곡선을 예측한 결과는 그림 6~8과 표 4와 같이 나타냈다.

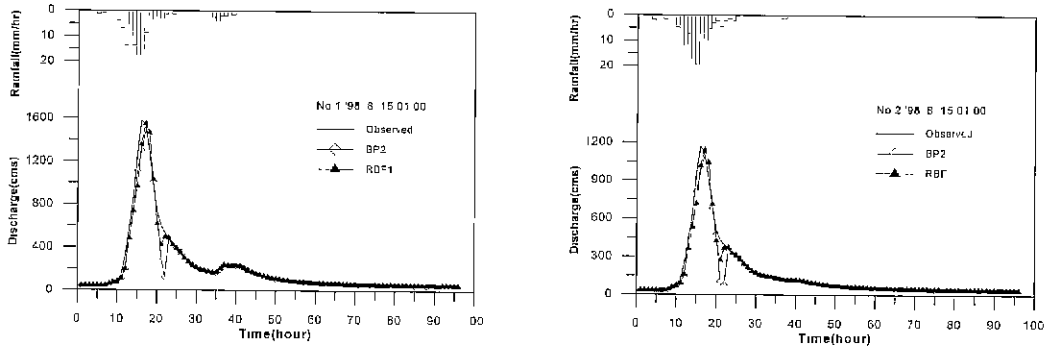


그림 7. 미학습유역의 유출수문곡선 예측 결과(위천의 무성, 병천지점)

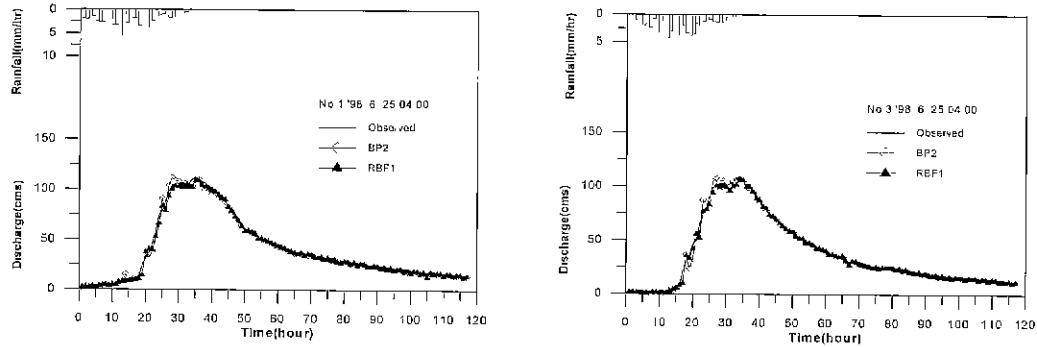


그림 8. 미학습유역의 유출수문곡선 예측 결과(평창강의 방림, 상안미지점)

표 4. 미학습유역 유출수문곡선 예측의 통계적 특성

유역	지점	Beginning date	Network	CC	R ²	RMSE	MF(%)	VE(%)
보청천	산 계	1997.6.24 11:00	BP2	0.980	0.960	6.509	8.281	2.286
			RBF1	0.982	0.965	5.933	1.033	0.682
		1998.8.10 21:00	BP2	0.966	0.932	525.600	10.434	10.797
			RBF1	0.977	0.955	422.585	2.527	5.566
위 천	무 성	1998.8. 8 15:00	BP2	0.981	0.962	65.072	5.739	6.785
			RBF1	0.987	0.974	53.063	1.984	4.799
	병 천	1998.8.15 15:00	BP2	0.973	0.948	54.785	5.749	7.603
			RBF1	0.986	0.971	40.375	2.551	4.657
평창강	방 립	1998.6.25 04:00	BP2	0.996	0.992	2.967	0.656	1.425
			RBF1	0.998	0.996	2.437	3.196	1.403
	상안미	1998.6.25 04:00	BP2	0.996	0.991	3.039	2.333	0.720
			RBF1	0.997	0.995	2.512	3.482	1.518

보청천 유역의 산계지점의 유출수문곡선 예측 결과 그림 6에서 알 수 있듯이 BP2모형과 RBF1모형 모두 실측수문곡선을 잘 예측하였다. 표 4에서 CC와 R2는 두 모형 모두 0.93이상으로 예측 능력이 우수하게 나타났다. MF와 VE는 10% 내외로 나타났으며, RBF1

모형이 BP2모형보다 적합한 결과를 얻을 수 있었다. 그리고 위천 유역의 무성지점 및 병천지점의 예측결과 그림 7과 같이 MF와 VE는 7%내외로 실측수문곡선의 경향을 잘 예측하고 있으며 RBF1모형이 좀더 나은 결과를 나타내었다. 또한 평창강 유역의 방림지점과

상안미지점의 유출수문곡선 예측결과 그림 8에서와 같이 두 지점 모두 비교적 침투치의 경향을 잘 따라 가는 것으로 나타났다

5. 결 론

본 연구에서는 시변성이 큰 홍수기의 시간유출을 예측하기 위해 신경망 이론 중 Back-Propagation (BP) 알고리즘과 Radial Basis Function Network (RBFN) 이론을 수문학적으로 적용하고 IFIP 대표유역인 보청천 유역의 홍수시의 시 강우 및 시 유출량 자료를 입력자료로 사용하여 유출량 예측 신경망 모형을 구성하고 적용성 검토를 하였다.

신경망 모형의 최적 모형을 찾기 위해 Levenberg - Marquardt (LM)방법을 이용한 BPN과 Radial Basis 뉴런을 이용한 RBFN에서 노드 수, 학습회수, spread 상수에 따라 8개의 모형을 구성하고 학습하지 않은 호우사상에 적용하여 최적 모형을 선정된 후 1시간~4시간까지 선행예측을 수행하였고, 또한 선정된 최적 모형을 이용하여 미학습 유역의 유출수문곡선을 예측했다 그리고 그 결과를 비교·분석하여 다음과 같은 결론을 얻을 수 있었다.

(1) 복잡하고 비선형이 강한 강우-유출 과정의 학습에 있어 RBFN은 입력층과 은닉층 사이에서 자율학습, 은닉층과 출력층에서 지도학습의 두 단계로 나누어 학습을 함으로써 BPN 보다 학습시간이 빠르게 나타났다.

(2) 선행유출량의 예측결과 여러 통계적 지표에서 Radial Basis 뉴런을 사용하는 RBFN이 BPN보다 양호한 결과를 얻을 수 있었다.

(3) 선행예측 시간에 있어서 보청천 기대지점에서는 BPN 알고리즘은 3시간까지 비교적 정확한 예측을 하였고, RBFN은 4시간까지 평균적으로 CC는 0.90이상, R2은 0.81이상, MF는 11.07% 그리고 VE는 14.69% 미만으로 나타나 비교적 양호한 결과를 얻을 수 있었다.

(4) 미학습 유역의 적용성 검토에서는 침투치가 비교적 실측자료의 경향과 비슷한 경향으로 나타났으며, RBFN이 BPN보다 적합한 결과를 얻을 수 있었다. 또한 미학습 유역에 대하여 일괄성 있는 유출패턴을 산출함으로써 강우-유출과정을 일반화 할 수 있었다.

(5) 수문자료가 많을 경우 RBFN은 BPN보다 분류 능력이 뛰어나므로 학습지점의 자료를 더욱 확충할 경우 유출량 예측시 유용하게 활용될 수 있을 것으로 사료된다.

참 고 문 헌

- 강관원, 박찬영, 김주환 (1992). "패턴인식방법을 적용한 하천유출의 비선형 예측." 한국수문학회지, 한국수문학회, 제25권, 제3호, pp. 105~113.
- 건설부 (1983~1998) 국제수문개발계획(IFIP) 연구보고서
고원준, 조원철 (1999). "신경회로망을 이용한 저수지 유입량의 실시간 예측모형 연구." '99년도 한국 수자원학회 학술발표회 논문집, 한국수자원학회, pp. 209~214
- 김만식 (1998). 다목적 저수지의 홍수유입량 예측을 위한 신경망모형. 박사학위논문. 충북대학교.
- 김주환 (1993) 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구. 박사학위논문, 인하대학교.
- 신현식, 최종남, 박부중 (1998). "신경망을 이용한 비선형 강우 및 홍수 유출 실시간 예측 모형." '98년도 대한토목학회 학술발표회 논문집(III), 대한토목학회, pp. 185~188.
- 안상진, 전계원, 김용용, 김진극 (1999). "신경망 알고리즘을 적용한 강우-유출수문곡선의 모의" '99년도 대한토목학회 학술발표회 논문집(III), 대한토목학회, pp. 43~46.
- 오경두, 전병호 (1994). "미계측 중소유역 유출 시뮬레이션을 위한 신경회로망 모형의 적용." 제36회 수공학 연구발표회 논문집. 한국수문학회, pp 317~323
- 오남선 (1996). 신경망이론과 Kalman Filter 강우예측모형의 비교연구. 박사학위논문. 서울대학교.
- 전계원 (2000). 신경망 알고리즘을 적용한 유출수문곡선의 예측. 석사학위논문. 충북대학교.
- Broomhead, D.S, and Lowe, D. (1988). "Multivariable functional interpolation and adaptive networks," *Complex Systems*, Vol. 2, pp. 321~355
- Demuth, H., and Beale, M. (1997). *Neural network toolbox : For use with MATLAB user's guide 3.0*. The Math Works Inc., pp. 2.1~6.19.
- French, M.N., Krajewski, W.F., and Cuykendall, R.R. (1992). "Rainfall forecasting in space and time using a neural network." *Journal of Hydrology*, Vol. 137, pp 1~31
- Hsu, Kuo-Lin, Gupta, H.V., and Sorooshian, S. (1995) "Artificial neural network modeling

- of the rainfall-runoff process." *Water Resources Research*, Vol. 3, pp. 2517~2530.
- Hush (1993) "Progress in supervised neural network." *IEEE Signal Processing Magazine*, pp. 8~38.
- Jang, J.-S. R., Sun, C.-T., and Mizutani, E. (1997) *Neuro-fuzzy and soft computing*. Prentice Hall, pp. 129~331.
- Karunanithi, N. (1994). "Neural networks for river flow prediction." *ASCE Journal of Computing in Civil Engineering*, Vol 8, No.2, pp. 201~219.
- Mason, J.C., Price R.K., and TEM'ME, A. (1996). "A neural network model of rainfall-runoff using radial basis functions" *Journal of Hydraulic Research*, Vol. 34, No.4, pp. 537~548.
- Moody, J., and Darken, C.J. (1989) "Fast learning in networks of locally-tuned processing units." *Neural Computation*, Vol. 1, pp. 281~294.
- Orr, M.J.L. (1999). Matlab functions for radial basis function networks. Technical report, Institute for Adaptive and Neural Computation, Division of Informatics, Edinburgh University, pp. 1~69.
- Thirumalaiah, K. (1998). "River stage forecasting using artificial neural networks." *ASCE Journal of Hydrologic Engineering*, Vol. 3, No.1, pp. 26~32.

(논문번호:00-008/접수:2000.02.09/심사완료 2000.07.18)