

연구논문

유량 보간 신경망 모형의 개발 및 낙동강 유역에 적용

손아롱* · 한건연** · 김지은***

경북대학교 건설, 토목공학부 박사과정*, 경북대학교 건설, 토목공학부교수**,
경북대학교 건설, 토목공학부 석사과정***

(2009년 7월 1일 접수, 2009년 9월 22일 승인)

Development of Flow Interpolation Model Using Neural Network and its Application in Nakdong River Basin

Son, Ah Long* · Han, Kun Yeon** · Kim, Ji Eun***

Ph.D. Candidate, School of Archi. & Civil Engineering, Kyungpook National Univ., Daegu 702-701, Korea*

Professor, School of Archi. & Civil Engineering, Kyungpook National Univ., Daegu 702-701, Korea**

Master's degree, School of Archi. & Civil Engineering, Kyungpook National Univ., Daegu 702-701, Korea***

(Manuscript received 1 July 2009; accepted 22 September 2009)

Abstract

The objective of this study is to develop a reliable flow forecasting model based on neural network algorithm in order to provide flow rate at stream sections without flow measurement in Nakdong river. Stream flow rate measured at 8-days interval by Nakdong river environment research center, daily upper dam discharge and precipitation data connecting upstream stage gauge were used in this development. Back propagation neural network and multi-layer with hidden layer that exists between input and output layer are used in model learning and constructing, respectively. Model calibration and verification is conducted based on observed data from 3 station in Nakdong river.

Keywords : FFN, flow interpolation, neural network, river flow estimation

1. 서론

수자원의 효율적인 관리를 위해서는 신뢰성 있는 유량자료의 획득이 대단히 중요하며, 우리나라는 양질의 유량자료를 획득하기 위해 매년 많은 시간과 돈을 투자하고 있으나 자료의 질적인 면에서 만족할 만한 성과를 얻지 못하고 있다(낙동강물환경연구소, 2006). 현재까지 우리나라의 유량자료는 댐의 수문자료와 수량관리 부처인 국토해양부에서 운영하는 수위표 지점의 수위-유량곡선에서 산출된 자료에 의존하고 있으며 수위-유량 관계식을 보정하기 위한 유량측정사업이 지속적이지 못하고 있다. 이 관계식은 특히 유량이 적은 저수기 및 갈수기에는 부정확하다는 한계가 있다. 또한 이러한 수위-유량측정이 본류에 소수 존재할 뿐이어서 지천의 소유역에 대한 유량자료는 전무하다고 할 수 있다(낙동강물환경연구소, 2005).

이에 2004년부터 수질오염총량관리제가 시행됨에 따라 낙동강수계의 수질오염총량관리 단위유역 말단에서의 수질과 정확한 유량을 측정하여 장기간에 걸친 수질 및 유량변동을 파악하고 기준 유량설정 등 주요 수질정책의 기초자료로 제공하기 위하여 국립환경과학원 낙동강물환경연구소에서 낙동강수계 유량측정사업을 실시하였다(낙동강물환경연구소, 2005). 하지만 국립환경과학원 낙동강물환경연구소에서 오염총량관리를 위한 낙동강수계 유량측정은 대략 8일 간격으로 실시되며, 수자원의 효율적인 관리를 위한 일 유량을 알 수가 없는 한계점을 가지고 있다.

따라서 저수기 및 갈수기에 수질정책의 기초자료를 제공하기 위해서 하천을 포함한 유역의 정확한 강우-유출특성의 파악이 필요하다. 그럼에도 불구하고 강우-유출특성 또한 유역 내 강우의 시·공간적 분포가 다르며 그 자체가 비선형성이 강하고 여러 변동성을 포함하므로, 강우로부터 하천의 유출량의 정확한 해석이 불가능하다. 따라서 강우-유출특성을 파악하는 방법 이외에 새로운 유량 산정방법이 요구되어진다.

컴퓨터가 등장하였고 최근 인공지능 분야에서 신

호처리, 지능제어 및 패턴인식 등의 수단으로 사용되고 있는 신경망은 학습이라는 최적화 과정을 통해 입력과 출력으로 구성되는 하나의 시스템을 비선형적으로 구축할 수 있으며 이러한 이점을 활용하여 수자원 분야에서 다양하게 적용되고 있다. 강우-유출처리와 같은 목적으로 Minns and Hall(1996), Furundzic(1998) 등이 연구하였으며, See(1997)외에 홍수량 예측, Cigizoglu(2002)는 유사예측을 그리고 Mai andnd Ddndy(2001) 등은 유역-환경관계를 연구하였다. 기존의 유량에 관한 신경망모형은 한 지점에서 과거의 일정기간 동안


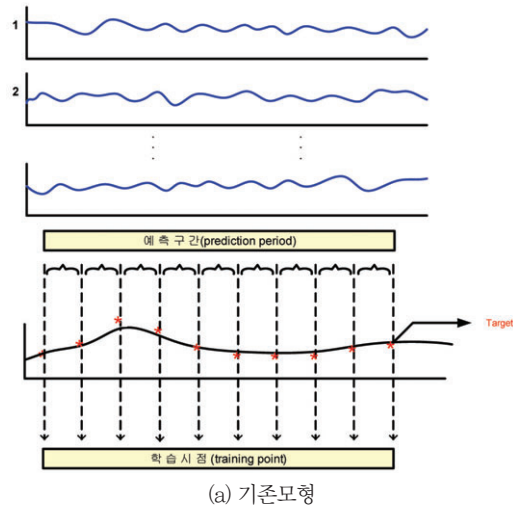


그림 1. 유량예측 신경망 모형의 개요

학습을 통하여 유량패턴을 파악하여 향후의 유량을 예측하는 모형이 주를 이루었다(Mahabir *et al.* (2003), Kerh and Lee(2006), M. Erkan(2009)). 그러나 본 연구에서는 그림 1과 같이 국립환경과학원 낙동강물환경연구소에서 오염총량관리를 위한 낙동강수계 유량측정사업의 대략 8일 간격의 유량 측정결과를 신경망 이론에 적용하였으며 그 외의 측정하지 않은 기간에 대하여 보간하여 유량을 산정해보고자 한다. 기존모형은 과거의 수위-유량 곡선으로부터 유량패턴을 학습하여 향후의 유량을 예측하도록 모형을 구성하였으나 본 모형은 측정된 유량을 바탕으로 측정되지 않은 기간의 유량을 예측하도록 구성하였다.

II. 신경망모형 개발

1. 다층신경망

본 연구에서 사용된 신경망은 생물학적 신경세포의 특성을 수학적으로 모형화하여 프로그래밍화 한 것으로 크게 입력층, 출력층 그리고 모형에 따라 은닉층이 존재하기도 한다. 학습이란 특정 응용목적에 따라 연결강도를 변경하는 과정이다. 신경망뉴런은 입력을 통합하는 결합함수와 통합된 결과의 작동범위를 제공하는 활성화함수로 구성되어 있으며 다음식과 같다(Kwok and Yeung, 1997a).

식(1)에서 x_i 는 입력층에서 받아들이는 입력값, w_{ji} 는 각각의 가중계수, y_j 는 출력값을 의미한다. 그리고 f 는 결합함수이다.




그림 2. 신경망뉴런

$$y_i = f\left(\sum_{j=1}^n x_j w_{ji}\right) \quad (1)$$

본 연구에서 사용된 신경망모형은 은닉층이 존재하는 다층신경망으로서 선형분리가 불가능한 문제해결에 있어 효과적이다(Kwok and Yeung, 1997b).

그림 3에서 볼 수 있듯이 식(2)은 입력값 x_i 와 입력층과 은닉층사이의 가중계수 v_{ji} 의 결합함수로서 은닉층의 값 z_j 를 구하고 식(3)에서 은닉층 값과 은닉층과 출력층사이의 가중계수 w_{kj} 의 결합함수로서 출력층의 값 y_k 를 구한다. n, m 은 각각 입력층 수와 은닉층 수이다.

$$net_{zj} = \sum_{i=1}^n v_{ji} x_i \rightarrow z_j = f(net_{zj}) \quad (2)$$

$$net_{yk} = \sum_{j=1}^m w_{kj} z_j \rightarrow y_k = f(net_{yk}) \quad (3)$$

2. 역전파 알고리즘

오류역전파 알고리즘은 다층신경망의 학습에 효과적으로 사용하는 알고리즘의 하나로서 다양한 분야에 가장 널리 사용되는 학습방법이다(Rumelhart and McClelland, 1986; Eberhart and Dobbins, 1990). 오류 역전파 알고리즘은 출력층의 오차신호를 이용하여 은닉층과 출력층간의 연결강도를 변경하고, 출력층의 오차신호를 은닉층에 역전파하여

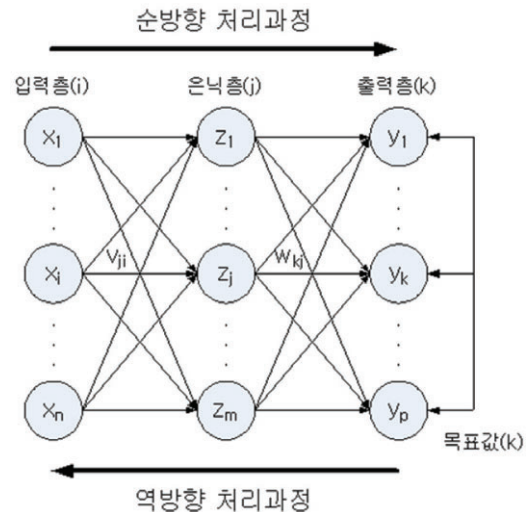


그림 3. 오류역전파 알고리즘

입력층과 은닉층과의 연결강도를 변경하는 학습 방법이다(Lachtermacher and Fuller, 1995). 연결 강도를 변경하는 법칙으로는 델타규칙을 사용하였으며 다음 식과 같다.

$$E = \frac{1}{2} \sum_{j=1}^m (d_j - y_j)^2 \tag{4}$$

$$\Delta w_{ji} = -\alpha \frac{\partial E}{\partial w_{ji}} \tag{5}$$

$$\delta_{yj} = (d_j - y_j) f'(net_{yj}) \tag{6}$$

여기서, α 는 학습률이고, δ_{yj} 는 출력층 j 뉴런에서 발생하는 오차신호, 그리고 d_j 는 출력층 j 뉴런에서의 목표값이다.

$$\Delta w_{ji} = \alpha (d_j - y_j) f'(net_{yj}) x_i \tag{7}$$

입력층과 출력층 사이의 연결강도 w_{ji} 가 출력층 j 뉴런의 출력오차에 관여하였을 것으로 이를 보정하기 위해서 출력층 j 뉴런의 오차신호 δ_{yj} 를 역전파시켜 연결강도의 변화량 Δw_{ji} 를 계산하여, 다음 단계의 연결강도를 변경하게 된다. 식은 다음과 같다.

$$w_{k+1} = w_k + \Delta w \tag{8}$$

3. 신경망 모형의 통계적 평가

유량예측 신경망 모형의 성능을 판단하기 위해서 표 1에 제시된 상대첨두오차(RPE), 상대총량오차(RVE), 절대평균편차(AMB), 평균제곱오차(RMSE), 상관계수(CC), 모형개선지수(SS)를 이용하여 모형의 예측결과를 검증하였다. 본 모형의 검

증결과는 모의 결과에서 제시하였다. 여기서 상관계수는 식(9)과 같이 예측치와 관측치의 선형상관성을 나타내며, 모형개선지수는 지속예측(Persistence forecasting) 모형과 비교하여 예측모형의 개선 정도를 나타낸다. 지속예측 모형은 가장 간단한 예측 모형으로 현재의 강우가 선행시간 후에 그대로 나타날 것이라고 예측하는 모형이다.

각 예측모형의 검증방법 및 기준은 다음 표 1과 같다.

$$CC = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{[\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2]^{1/2}} \tag{9}$$

III. 실제유역에 적용 및 검토

1. 대상유역

본 연구의 신경망 유량예측 모형의 적용유역은 유역 면적 23,817.3 km², 유로연장이 521.5 km인 낙동강 전 유역으로써 모의 지점은 낙동수위관측소, 왜관수위관측소, 진동수위관측소로 지정하였다. 모의 시 각 관측소의 목표치인 8일 측정유량자료는 낙동수위관측소인 경우 낙본 D이고 왜관수위관측소의 경우 낙본 E이며 진동수위관측소의 경우 낙본 I지점이다.

표 1. 예측모형의 검증기준

상대첨두오차(Relative Peak Error)	$RPE = \frac{F_p - O_p}{O_p}$	F_p : 예측 첨두치, O_p : 관측 첨두치
상대총량오차(Relative Volume Error)	$RVE = \frac{F_v - O_v}{O_v}$	F_v : 예측 총량, O_v : 관측 총량
절대평균편차(Absolute Mean Bias)	$AMB = \frac{1}{N} \sum_{t=1}^N [F(t) - O(t)]$	N : 총 자료수, $F(t)$: 예측치, $O(t)$: 관측치, t : 시간
평균제곱오차(Root Mean Square Error)	$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [F(t) - O(t)]^2}$	
상관계수(Correlation Coefficient)	CC	예측치와 관측치의 선형상관계수
모형개선지수(Skill Score)	SS	지속예측 대비 모형의 개선 정도

2. 신경망모형개발

본 연구에서는 낙동강물환경연구소의 8일 측정 유량이 가지는 정확성을 이용하면서 상류 댐의 일 방류량자료와 유역별 강우자료 및 국토해양부의 수위 관측소의 수위자료를 연계하여 유량을 예측할 수 있는 유량예측 신경망 모형 FFN(Flow Forecasting By Neural Network)을 개발하였다.

신경망 모형의 출력값은 낙동강물환경연구소에서 측정하지 않은 기간에 대하여 유량을 예측할 수 있도록 구성하였으며 신경망 모형의 구조는 입력층과 출력층 사이에 하나의 은닉층이 존재하는 다층 신경망으로 구성하였으며, 학습단계에서는 오류 역전파 알고리즘 학습방법 중 모멘텀법을 사용하였다. 은닉층의 뉴런수는 입력층 뉴런의 두배로 구성하였으며, 학습반복수는 오차값의 수렴성을 고려하여 1,000~6,000번을 500번을 간격으로 적용하고 학습률과 모멘텀 상수는 각각 0.001과 0.01을 사용하였다. 활성화 함수는 항등 함수, 경사 함수, 계단 함수, 시그모이드(Sigmoid) 함수 등이 사용되고 있으며, 이들 중 미분 가능한 비선형 함수이며, 미분식이 간단하다는 장점으로 인해 신경망의 활성화 함수로 가장 많이 사용되는 시그모이드 함수를 사용하였다. 유량예측을 위한 FFN 모형의 입력층은 공통적으로 상부 댐의 방류량과 지류의 유출을 반영하기 위하여 유역의 면적평균 강우량 자료 및 수위관측소의 수위-유량곡선으로부터 산정된 유량을 활용하였다.



그림 4. 신경망모형 개발

3. 입력층의 구성

우리나라의 경우 대부분의 하천이 댐에 의한 홍수방어 및 저류기능을 수행하고 있어 하도의 홍수위는 댐방류량에 의한 영향이 지배적이다. 따라서 낙동강 유역의 유량을 예측하기 위하여 연구범위의 단위유역 유량 산정에 영향을 미치는 다목적댐인 안동댐, 임하댐, 합천댐, 남강댐의 댐 방류량의 영향을 반영한 신경망 모형을 구축하였다. 댐의 방류량 자료는 국가 수자원관리종합정보 시스템(WAMIS)에서 수집하였다.

본 연구에서는 지류의 유출을 대신하여 지류 유출량에 큰 영향을 미치는 강우량을 산정하였고, 국토해양부 관할 T/M과 자기강우계를 포함한 142개 지점, 수자원공사 관할 48개 지점, 그리고 기상청 관할 24개 지점 중 최근 강우패턴을 고려할 수 있으며 강우 관측망이 낙동강 유역에 가급적 균일한 공간 분포를 유지함을 만족시키는 관측소 자료를 선정하였다. 또한, 선정된 관측소 자료의 지점 강우량은 GIS를 이용하여 Thiessen 계수를 산정한 후 22개 중권역 별 유역 평균 강우량으로 환산하였으며, 강우관측소에서의 결측치 보완은 역거리법으로 산




그림 5. 신경망모형 적용지점(낙동, 왜관, 진동)

출처: 국가 수자원관리종합정보 시스템(WAMIS)-지형자료 수문관측망도_유량

정하였다.


역거리법은 결측관측소와 주위관측소간의 거리를 가중인자로 사용하는 방법이다. 결측관측소의 좌표가 (x_o, y_o) 일 때 i 관측소와의 거리의 자승은 $D_i^2 = (x_o - x_i)^2 + (y_o - y_i)^2$ 이고 가중인자 α_i 는 식 (10)과 같이 주어지고 결측치는 식 (11)에 대입하여 구할 수 있다.

$$\alpha_i = \frac{1/D_i^2}{\sum 1/D_i^2} \tag{10}$$


$$R_x = \sum_{i=1}^n \alpha_i R_i \tag{11}$$

여기서 R_x 는 관측점 x 의 결측치, α_i 는 관측점 i 의 기여도를 나타내는 가중인자, R_i 는 관측점 i 의 강우량, n 은 주위 관측점의 수이다.


본 모형에서 유출을 검토하기 위해서는 수위자료가 아닌 유량자료를 이용하여 해당 분석을 수행하게 되므로 정도 높은 유량자료의 확보는 대단히 중요한 문제이다. 수위자료와는 달리 유량자료의 경우 연속적으로 측정하는 것은 예산과 장비 측면에서 현실적으로 어려운 문제이므로 연속자료 생성이 상대적으로 용이한 수위자료에 대한 관측을 수행한 후 이를 수위-유량관계에 적용하여 유량자료를 산정하게 된다.



(a) Case I: 지보, 달지, 낙동



(b) Case II: 낙동, 일선교, 구미, 왜관



(c) Case III: 왜관, 성주, 고령교, 현풍, 진동

그림 6. 2005년~2007년 유량환산

표 2. 각 모의지점 별 입력값

모 의 지 점	낙본 D	낙본 E	낙본 I
수 계 구 간	안동시와 예천군 경계점후부터 상주시와 구미시 경계점전까지 전구간 및 유역	상주시와 구미시 경계점후부터 구미시와 칠곡군 경계점전까지 전구간 및 유역	남강 합류점후부터 밀양시 청도천 합류점전까지 전구간 및 유역
경도	128-18-05	128-23-53	128-38-36
위도	36-21-26	36-06-39	35-22-22
댐방류량	임하댐, 안동댐	임하댐, 안동댐	임하댐, 안동댐, 합천댐, 남강댐
강우 관측소 (중권역)	안동댐하류, 내성천, 영강, 병성천, 위천, 낙동상주, 낙동구미	Case 1+ 감천, 낙동왜관	Case 2+ 화천, 낙동고령, 황강, 낙동창녕, 남강, 낙동밀양
수위관측소	지보, 달지	일선교, 구미	성주, 고령교, 현풍
총입력층 수	11	13	23
비교수위관측소	낙동	왜관	진동
은닉층 뉴런수	입력층 뉴런의 두배		
학습반복수	5000번		
학습률	0.001		
모멘텀 상수	0.01		

유량 환산을 위해 본 연구의 범위에 해당하는 국토해양부 수위자료를 수집하여 이상치 여부를 검토하였으며 유량환산결과를 비교·검토한 후 패턴이 고르고 신뢰도가 높은 정상적인 수문곡선의 경향을 고려하여 그림 6과 같이 10개 지점(지보, 달지, 낙동, 일선교, 구미, 왜관, 성주, 고령교, 현풍)의 수위-유량 환산 값을 선정하였다.

본 모형에서 목표지점은 모형의 결과를 비교, 검증하기 위해 국립환경과학원 낙동강물환경연구소의 낙동강수계 총량관리단위유역 41개 단위유역 말단지점의 실측유량측정 지점과 국토해양부의 수위관측소가 일치하는 지점을 대상구역으로 설정하였다. 그리하여 선정된 목표지점은 Case 1은 낙본

D(낙동), Case 2의 경우 낙본 E(왜관), Case 3은 낙본 I(진동)이며, 진동지점의 경우 낙본 I지점의 유량실측치를 목표치로 하여 모의한 결과를 비유량법을 사용하여 환산하여 진동수위관측소의 유량과 비교 후 검토하였다. 각 모의지점 별 입력값은 다음 표 2와 같다.

4. 모의 결과

본 연구의 신경망 유량예측 모형의 적용유역은 낙동강 전 유역으로써 대상구역은 낙동강전유역이며 모의기간 2005년~2007년에 대해 모의 지점 낙동수위관측소(낙본 D), 왜관수위관측소(낙본 E), 진동수위관측소(낙본 I)를 모의하였다. 모의 결과 학

표 3. 학습횟수에 따른 검증결과


	학습횟수	RPE	RVE	AMB	RMSE	CC	SS
Case I. 낙동	1000회	-0.79	-0.09	79.19	317.45	0.80	0.56
	2000회	-0.79	-0.08	82.20	315.39	0.80	0.57
	3000회	-0.79	-0.08	85.18	316.00	0.79	0.57
Case II. 왜관	4000회	-0.77	-0.13	71.72	352.91	0.86	0.60
	4500회	-0.77	-0.13	71.76	352.65	0.86	0.60
Case III. 진동	5000회	-0.77	-0.13	71.81	352.47	0.86	0.60
	4000회	-0.30	-0.13	124.61	325.69	0.95	0.86
	4500회	-0.30	-0.14	124.27	323.43	0.95	0.86
	5000회	-0.30	-0.14	124.47	322.22	0.95	0.86

습 횡수가 증가함에 따라 오차와 상관계수 및 모형 개선지수가 향상된 값으로 수렴하였으며, 표 3에서 볼 수 있듯이 case 1의 경우 반복횟수 2000번의 모의 결과가 가장 잘 일치하였고 case 2 및 case 3의 경우 반복횟수 5000번의 모의 결과가 가장 잘 일치하였다. 그림 7은 목표지점의 수위관측소 유량과 모의한 결과 및 낙동강물환경연구소 8일 실측치를 비교한 그래프이다. 위의 그래프에서 볼 수 있듯이 7~8월경의 유량 예측치와 관측치 사이의 오차가 발생함을 확인할 수 있으며, 이것은 낙동강물환경연구소는 갈수기의 수질에 대한 영향을 고려하기 때문에 홍수기에는 많은 유량을 측정하지 않으므로


자료가 상대적으로 부족함에서 발생한 것으로 보인다. 그러나 7~8월경을 제외한 다른 시기에는 상관계수가 0.80에서 0.95사이로 유량 예측치와 관측치가 거의 일치함을 볼 수 있다.

IV. 결론


지금까지 신경망 모형을 통한 시계열 자료의 예측에서는 장기간의 데이터 수집을 통하여 향후 기간의 시계열 자료를 예측하거나 특정 이벤트를 통하여 향후 유사한 이벤트를 예측하였다. 하지만 본 연구에서는 낙동강 유역의 유량 예측을 위해 역전



(a) 낙본 D



(a) 낙본 E



(a) 낙본 I

그림 7. FFN모형 모의 결과

표 4. 각 case별 모의 결과

구 분	case 1	case 2	case3
비교지점	낙동	왜관	진동
모의기간	2005 ~ 2007년		
목표지점	낙본 D	낙본 E	낙본 I
상관계수	0.80	0.86	0.95
모형개선지수	0.57	0.60	0.86
상대첨두오차	-0.79	-0.77	-0.3
상대총량오차	-0.08	-0.13	-0.14
절대평균편차	82.20	71.81	124.47
평균제곱오차	315.39	352.47	322.22

파 신경망 모형을 사용하였으며 낙동강물환경연구소의 8일 간격 유량측정결과를 일 유량으로 보간하는 모형을 개발하였다.

본 연구를 통하여 얻은 결론은 첫 번째로 강우-유출자료 및 댐 방류량 자료의 비선형적인 특성을 가장 잘 반영할 수 있는 유량보간 신경망모형을 개발하여 낙동강 유역에 적용함으로써 신뢰도 높은 수질정책의 기초자료를 제공할 수 있을 것으로 보인다. 두 번째로 댐 방류량과 강우자료 및 상류 수위 관측소의 유량 자료를 이용한 유량예측신경망모형의 일 유량결과의 적용가능성을 표 4와 같이 검증하였다. 유량예측모형을 모의기간 2005년~2007년 동안 목표지점인 낙동, 왜관, 진동에 대해 모의한 결과 상관계수가 0.80~0.95로써 상관계수가 높았다. 그리고 세 번째는 그림 6과 같이 상류 수위 관측소의 유량 자료의 수문곡선 경향성 검토를 통해 유량 입력 자료의 신뢰성을 높였다. 끝으로 제시된 모형은 지속적인 수문자료의 질적 향상과 유출패턴의 축적으로 그 성능을 향상시킬 수 있을 것이며 또한 홍수기의 더 정확한 유량예측을 위한 적용사례의 확장 및 수질신경망 모형의 적용에 대한 연구가 병행되면 하천의 종합적 데이터를 구축할 수 있을 것이다.

사 사

본 연구는 낙동강수계관리위원회 · 국립환경과학원 낙동강물환경연구소에서 시행한 환경기초조사

사업의 연구비 지원으로 수행되었습니다.

참고문헌

- 낙동강물환경연구소, 2005, (오염총량관리를 위한 '05) 낙동강수계 유량측정사업 운영결과.
- 낙동강물환경연구소, 2006, (오염총량관리를 위한 '06) 낙동강수계 유량측정사업 운영결과.
- 김성원, 2001, 하천유역에서 홍수유출량의 예측을 위한 신경망기법의 적용, 대한토목학회논문집, 20(6-B), 801-811.
- 김주환, 1993, 신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구, 박사학위 논문, 인하대학교.
- 윤강훈, 서봉철, 2004, 댐방류량을 이용한 한강 유역 신경망 유출 예측모형에 관한 연구, 한국수자원학회 논문집, 24(1B), 47-53.
- Anthony, W. M., 1996, Extended Rainfall-Runoff Modelling using Artificial Neural Networks. *Hydroinformatics '96, Proceedings of the 2nd International Conference on Hydroinformatics*, Zurich, Switzerland, pp. 207-213.
- Fletcher, D. S. and Goss, E., 1993, Forecasting with neural networks: an application using bankruptcy data, *Information & Management*, 24, 159-167.
- Kerh, T. and Lee, C. S., 2006, Neural networks forecasting of flood discharge at an unmeasured station using river upstream information, *Advances in Engineering Software*, 37(8), 533-543.
- Kwok, T. Y. and Yeung, D. Y., 1997a, Constructive algorithms for structure learning in feedforward neural networks for regression problems, *IEEE Transactions on Neural Networks*, 8(1), 630-645.
- Kwok, T. Y. and Yeung, D. Y., 1997b,

- Objective functions for training new hidden units in constructive neural networks, *IEEE Transactions on Neural Networks*, 8(5), 1131-1148.
- Lachtermacher G. and Fuller J. D., 1995, Backpropagation in time-series forecasting, *Journal of Forecasting*, 14(4), 381-393.
- M. Erkan Turan and M. Ali Yurdusev, 2009, River flow estimation from upstream flow records by artificial intelligence methods, *Journal of Hydrology*, 369, 71-77.
- Minns, A. W. and Hall, M. J., 1996, Artificial neural networks as rainfall-runoff models, *Hydrological Sciences Journal*, 41(3), 399-417.
- Thirumalaiah, K., 1998, River stage forecasting using artificial neural networks, *ASCE Journal of Hydrologic Engineering*, 3(1), 26-32.
- Zhang, B. and Govindaraju, R. S., 2003, Geomorphology-based Artificial Neural Networks (GANNs) for Estimation of Direct Runoff over Watersheds, *Journal of Hydrology*, 237, 18-34.