

다층신경망모형에 의한 일 유출량의 예측에 관한 연구

A Study on the Forecasting of Daily Streamflow using the Multilayer Neural Networks Model

김 성 원*

Kim, Sungwon

Abstract

In this study, Neural Networks models were used to forecast daily streamflow at Jindong station of the Nakdong River basin. Neural Networks models consist of CASE 1(5-5-1) and CASE 2(5-5-5-1). The criteria which separates two models is the number of hidden layers. Each model has Fletcher-Reeves Conjugate Gradient BackPropagation(FR-CGBP) and Scaled Conjugate Gradient BackPropagation(SCGBP) algorithms, which are better than original BackPropagation(BP) in convergence of global error and training tolerance. The data which are available for model training and validation were composed of wet, average, dry, wet+average, wet+dry, average+dry and wet+average+dry year respectively. During model training, the optimal connection weights and biases were determined using each data set and the daily streamflow was calculated at the same time. Except for wet+dry year, the results of training were good conditions by statistical analysis of forecast errors. And, model validation was carried out using the connection weights and biases which were calculated from model training. The results of validation were satisfactory like those of training. Daily streamflow forecasting using Neural Networks models were compared with those forecasted by Multiple Regression Analysis Model(MRAM). Neural Networks models were displayed slightly better results than MRAM in this study. Thus, Neural Networks models have much advantage to provide a more systematic approach, reduce model parameters, and shorten the time spent in the model development.

keywords : FR-CGBP, SCGBP, Neural Networks model, Multiple Regression Analysis Model, forecasting

요 지

본 연구에서는 낙동강 진동지점에서 일유출량을 예측하기 위하여 신경망모형이 제시되었다. 신경망모형의 구조는 CASE 1(5-5-1)과 CASE 2(5-5-5-1)로 구성하였으며, 은닉층의 수에 따라 두 가지의 모형으로 분류하였다. 각 신경망모형은 광역최소점과 훈련임계치에 수렴하는데 기존의 역전파훈련 알고리즘(BP)보다 뛰어난 Fletcher-Reeves 공액구배 역전파훈련 알고리즘(FR-CGBP)과 축적된 공액구배 역전파훈련 알고리즘(SCGBP)을 이용하였다. 그리고 모형의 훈련과 검증에 위하여 이용된 자료는 풍수년, 평수년, 갈수년, 풍수년+평수년, 풍수년+갈수년, 평수년+갈수년 및 풍수년+평수년+갈수년으로 구분하여 구성하였다. 모형의 훈련과정에서 각 자료를 이용하여 최적 연결강도와 편차가 결정되어 졌으며, 동시에 일유출량이 계산되어졌다. 예측오차의 통계분석을 통하여 풍수년+갈수년의 자료를 제외하고는 훈련결과가 양호한 것으로 나타났다. 모형의 검증에는 모형의 훈련을 통해 산정된 CASE 1의 SCGBP 알고리즘의 연결강도와 편차를 이용하였으며, 검증의 결과는 훈련결과처럼 만족스러운 것으로 분석되었다. 또한 본 연구에서 선정한 신경망모형과 비교검토하기 위하여 다중회귀분석모형을 적용하여 일유출량을 예측하였으며, 그 결과 신경망모형이 다소 우수한 결과를 나타내는 것으로 분석되었다. 이와같이 신경망모형은 조직적인 접근법, 매개변수의 감소 및 모델을 개발하는데 소모되는 시간을 줄일수 있는 장점이 있다.

핵심용어 : FR-CGBP, SCGBP, 신경망모형, 다중회귀분석모형, 예측

* 콜로라도 주립대학교 토목공학과 박사후과정

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

(E-mail : swkim@lamar.colostate.edu)

1. 서 론

하천유출량의 정확한 예측은 수자원 기술자 및 관리자에게는 주요 과업중 하나이며, 기술적, 경제적, 그리고 정치적 범주내에서 수자원시스템의 효과적인 운영을 가능하게 한다. 전반적인 유출분야에 있어서 예측 시스템은 수자원시스템의 적절한 제어와 정책에 대한 신뢰할만한 기초자료를 제공한다. 일반적으로 시간 및 일의 선행시간을 가지는 하천유출량은 홍수예경보와 수자원시스템의 실시간운영을 위하여 보통 이용되며, 주 및 월 단위의 선행시간을 가지는 하천유출량의 예측은 관개용수, 발전소계획, 그리고 가뭄해석을 위하여 일반적으로 이용되고 있다. 수많은 하천유출량의 예측 기법이 과거에 사용되었고 또한 지금까지 제시되어오고 있는데 일반적으로 통계학적/추계학적 개념과 개념적/물리적개념에 기초를 둔 기법으로 구분 할 수 있다. 첫 번째 범주인 통계학적/추계학적 기법은 단순 혹은 다중선형 및 비선형 회귀, ARMA, XARMA, 주기적인 매개변수를 가지는 ARMA, XARMA, 그리고 전이함수모형(TFM)을 의미하고 있으며, 일반적으로 유출량이 단순히 통계학/추계학적 조건에서 강우, 기온 및 증발량과 같은 많은 수문학적 및 기상학적 인자와 관련이 있는 black-box 형의 모형들이 있다(Hipel and McLeod, 1994). 그와는 반대로 개념적/물리적인 개념은 유역에서 발생하는 물리적인 과정(수문학적 순환)을 수학적으로 표현하는 기법을 나타내고 있으며, 모형을 구성하는 여러 인자들을 통하여 미분형식의 연속방정식 및 모멘텀방정식의 해법을 이용하고 있다. 일반적으로 개념적/물리적인 개념에 기초를 둔 모형은 크게 사상모형과 연속모형으로 구분하고 있다(Rosso et al., 1994).

하천유출량의 예측을 위하여 인공신경망(Artificial Neural Networks, ANNs)의 적용에 관한 연구는 1990년대에 와서야 부각되고 있는 실정이다. 신경망모형에 의한 유출예측에 관한 외국의 연구로는 개념적모형으로부터 생성된 자료에 대한 유출모의(Liong and Chan, 1993; Minns and Hall, 1996), 단시간 유출모의 및 예측(Isobe et al., 1994; Zealand et al., 1999), 장기간 유출예측(Smith and Eli, 1995; Raman and Sunilkumar, 1995; Tokar and Johnson, 1999)등이 수행되었다. 또한 국내에서는 일 유출량의 비선형 예측(김주환, 1993), 저수지 홍수유입량예측(심순보와 김만식, 1999a)에 관한 연구가 있을

뿐이다. 그러나 신경망해석을 위한 여러 상용프로그램의 개발로 인하여 유출분야에 관한 연구가 활발히 진행되고 있다(NeuralWare, 1993; Demuth and Beal, 1998).

본 연구에서는 낙동강유역의 주요수위표지점인 진동지점에서 하천 일유출량의 예측을 위하여 다층신경망모형을 제시하였으며, 신경망모형의 훈련은 기존의 역전파훈련 알고리즘을 개선한 FR-CGBP, SCGBP 알고리즘을 이용하였다. 또한 일유출량의 예측기법은 일 유출량 수문자료를 몇 개로 구분하였으며, 이는 어떠한 특성을 가진 일유출량 시계열자료라도 신경망모형은 모델링이 가능한 것을 수문학적으로 입증하기 위함이다. 따라서 수문시계열 자료의 특성이 상이한 풍수년(wet year), 평수년(average year), 갈수년(dry year), 풍수년 + 평수년(WA), 풍수년 + 갈수년(WD), 평수년 + 갈수년(AD), 그리고 풍수년 + 평수년 + 갈수년(WAD)으로 구분하였으며, 신경망모형의 훈련(training)을 통하여 최적 연결강도와 편차를 산정하였다. 또한 훈련에 의해 산정한 매개변수를 이용하여 모형을 검증(validation)하였으며, 다중회귀분석모형과 비교하여 신경망모형의 우수성을 입증하였다.

2. 훈련알고리즘과 신경망모형

본 연구에서 선정한 신경망모형은 FR-CGBP 및 SCGBP 알고리즘으로 훈련을 시키며, 이 과정은 일 유출량의 예측에 관한 신경망모형의 응용에 있어서 어느 알고리즘이 더 나은 결과를 나타내는가를 판단하기 위함이다. 기본적으로 신경망모형의 훈련 목적은 전역오차(global error) E를 감소하는 것이며, 다음 식(1)과 같이 나타낼 수 있다(Thirumalaiah and Deo, 1998).

$$E = \frac{1}{P} \sum_{i=1}^P E_i \quad (1)$$

여기서 P는 훈련패턴의 총 개수이고, E_i는 훈련 패턴 t에 대한 오차이다. 그리고 E_i는 다음 식(2)와 같이 나타낼 수 있다.

$$E_i = \frac{1}{2} \sum_{v=1}^N (O_v - T_v)^2 \quad (2)$$

여기서 N은 출력층노드의 총 수, O_v는 v번째

출력층노드의 모의된 출력치, T_v 는 v 번째 출력층노드의 목표 출력치이다. 다음에 설명된 훈련 알고리즘은 연결강도와 편차를 조정함으로써 이러한 전역오차의 값을 감소하고 있다.

2.1 플레처-리브 공액구배 역전파훈련 (Fletcher-Reeves Conjugate Gradient BackPropagation, FR-CGBP) 알고리즘

FR-CGBP 알고리즘은 연결강도와 편차에 대해 구배연산과 연속적인 보정에 있어서 일반적인 역전파훈련 알고리즘과는 다르다. 탐색방향(search direction) \bar{d}_k 는 각 훈련 반복횟수 k 에서 계산되고, 오차함수 $E(X)$ 는 탐색방향을 따라서 최소화된다. 즉 구배하강은 오차경사의 방향으로 진행되는 것이 아니고 전단계 오차의 연직방향으로 진행되며, 구배변화는 각 단계에서 수행된 오차최소화가 연속적인 단계로부터 어떤 장에도 없이 완전하게 보전되는 장점 때문에 이전단계의 연직으로 작용한다. 일반적으로 CGBP 알고리즘의 진행과정은 다음과 같이 4가지의 단계로 구분된다 (Fletcher and Reeves, 1964; Kim and Lee, 2000).

① 난수에 의해 연결강도 벡터 W 를 초기화하고, 역전파에 의한 초기 오차구배 \bar{g}_0 를 계산한다. 초기 탐색방향 \bar{d}_0 를 $\bar{d}_0 = -\bar{g}_0$ 로 결정한다.

② 각 반복단계 k 에 대하여 선형탐색에 의하여 오차함수 $E(W_k + \alpha_k \bar{d}_k)$ 를 최소화하는 상수로서 학습율(Learning rate) α_k 를 결정한다. 여기서 \bar{d}_k 는 반복횟수 k 에서의 탐색방향이다. 또한 연결강도 벡터 W_{k+1} 를 다음 식(3)과 같이 갱신한다.

$$W_{k+1} = W_k + \alpha_k \bar{d}_k \quad (3)$$

③ 반복회수 $k+1$ 에서 오차가 수용가능하거나 혹은 어떤 특정한 연산 반복횟수나 구배에 도달하면 CGBP 알고리즘은 종료한다. 그렇지 않으면 반복회수 $k+1$ 에서 오차구배 \bar{g}_{k+1} 를 사용하여 다음 식(4)와 같이 새로운 탐색방향 \bar{d}_{k+1} 를 산정한다. 여기서 β_k 는 시간중속 매개변수이며, β_k 를 어떻게 산정하느냐에 따라 여러종류의 CGBP 알고리즘으로 분류된다. 본 연구에서는 Fletcher-Reeves에 의해 시간중속 매개

변수를 식(5)와 같이 산정하였다.

$$\bar{d}_{k+1} = -\bar{g}_{k+1} + \beta_k \bar{d}_k \quad (4)$$

$$\beta_k = \frac{\bar{g}_k^T \bar{g}_k}{\bar{g}_{k-1}^T \bar{g}_{k-1}} \quad (5)$$

④ 다음 단계 계산을 위하여 ②로 이동한다.

2.2 축척된 공액구배 역전파훈련(Scaled Conjugate Gradient BackPropagation, SCGBP) 알고리즘

CGBP 알고리즘은 Hessian 행렬이 양의 값을 가지는 함수에서는 일반적으로 수렴이 잘 되는 것으로 알려져있다. 그러나 이러한 상황은 항상 잘 접해지는 것은 아니며, Hessian 행렬이 양의 값이 아닌 경우에 이러한 문제를 해결하는 SCGBP 알고리즘이 제시되었는데, 이 알고리즘은 단계크기(step size)를 결정하기 위하여 레벤버그-마퀴트(Levenberg-Marquardt) 접근법을 사용하여 선형탐색과정의 시간이 소모되는 것을 방지할 수 있다. 레벤버그-마퀴트 접근법은 전방향 신경망(Feedforward Neural Networks)에서 훈련의 내용뿐만 아니라 최적화이론의 내용까지 포함하는 것으로서 공액구배 접근법과 함께 결합하여 사용된다. 즉 Hessian 행렬의 특성을 제어하기 위한 방법으로 Lagrange 승수인 λ_k (Fletcher, 1975)를 공액구배 접근법에 도입하여 각 반복단계에서 축척 δ_k 의 부호에 따라서 적용시킨다. 일반적으로 SCGBP 알고리즘의 진행과정은 다음과 같이 9가지의 단계로 구분된다 (Moller, 1993).

① 연결강도 벡터 W 와 스칼라 $0 < \sigma < 10^{-4}$, $0 < \lambda_1 < 10^{-6}$ 그리고 $\bar{\lambda}_1 = 0$ 을 설정하며, 초기 오차구배 \bar{g}_0 를 계산한다. 그리고 초기 탐색방향 \bar{d}_0 를 $\bar{d}_0 = \bar{g}_0 = -E'(W_0)$ 로 설정하고, success = true로 한다.

② 만약 success = true 이면, 그때 2차 정보를 식 (6)과 같이 계산한다.

$$\sigma_k = \sigma / |\bar{d}_k|,$$

$$\bar{s}_k = [E'(W_k + \sigma_k \bar{d}_k) - E'(W_k)] / \sigma_k,$$

$$\delta_k = \bar{d}_k^T \bar{s}_k \quad (6)$$

③ 축척 δ_k 를 식 (7)과 같이 설정한다.

$$\delta_k = \delta_k + (\lambda_k - \bar{\lambda}_k) |\bar{d}_k|^2 \quad (7)$$

④ 만약 $\delta_k \leq 0$ 이면 그때 Hessian 행렬은 식(8)과 같이 일정한 양의 범위를 형성한다.

$$\begin{aligned} \bar{\lambda}_k &= 2(\lambda_k - \delta_k / |\bar{d}_k|^2) \\ \delta_k &= -\delta_k + \lambda_k |\bar{d}_k|^2 \cdot \lambda_k = \bar{\lambda}_k \end{aligned} \quad (8)$$

⑤ 단계 크기를 식(9)와 같이 계산한다.

$$\mu_k = \bar{d}_k^T \bar{g}_k, \quad \alpha_k = \mu_k / \delta_k \quad (9)$$

⑥ 비교 매개변수를 식(10)과 같이 계산한다.

$$\Delta_k = 2 \delta_k [E(W_k) - E(W_k + \alpha_k \bar{d}_k)] / \mu_k^2 \quad (10)$$

⑦ 만약 $\Delta_k \geq 0$ 일 경우, 식(11)과 같이 오차에 있어서 연속적인 감소가 행하여 질 수 있다.

$$W_{k+1} = W_k + \alpha_k \bar{d}_k, \quad \bar{\lambda}_k = 0, \quad \text{success} = \text{true} \quad (11)$$

만약 반복횟수의 수가 연결강도의 수보다 증가하면, 그 때 알고리즘은 식(12)와 같이 재시작한다.

$$\bar{d}_{k+1} = \bar{g}_{k+1} \quad (12)$$

그렇지 않으면

$$\begin{aligned} \beta_k &= (|\bar{g}_{k+1}|^2 - \bar{g}_{k+1}^T \bar{g}_k) / \mu_k, \\ \bar{g}_{k+1} &= -E'(W_{k+1}), \\ \bar{d}_{k+1} &= \bar{g}_{k+1} + \beta_k \bar{d}_k \end{aligned} \quad (13)$$

만약 $\Delta_k \geq 0.75$ 이면 그때의 축척 매개변수가 식 (14)와 같이 감소된다.

$$\lambda_k = \frac{1}{4} \lambda_k \quad (14)$$

그렇지 않으면

$$\bar{\lambda}_k = \lambda_k, \quad \text{success} = \text{false} \quad (15)$$

⑧ 만약 $\Delta_k < 0.25$ 이면 그때의 축척 매개변수가 식(16)과 같이 증가된다.

$$\lambda_k = \lambda_k + [\delta_k (1 - \Delta_k) / |\bar{d}_k|^2] \quad (16)$$

⑨ 만약 최급강하방향이 $\bar{g}_k \neq 0$ 이면, 그때 $k=k+1$ 로 설정하고 ② 단계로 간다. 그렇지 않으면 종결하고, 목표하는 최소치로서 W_{k+1} 를 출력한다.

2.3 신경망모형의 구조

본 연구에서 하천유역의 일유출량을 산정하기 위한 신경망모형은 은닉층의 수에 따라 2종류로 구분하였으며, 하나는 은닉층의 수가 1개인 경우(CASE 1)와 다른 하나는 은닉층의 수가 2개인 경우(CASE 2)로 결정하였다. 또한 강우, 증발량, 유출량과 같은 자료는 토양특성, 초기토양함수, 침투 및 지하수특성과 같은 자료에 비하여 관측이 상대적으로 쉬우며, 자료의 수집에 있어서 비용이 저렴한 편이다. 일반적으로 이용할 수 있는 실시간 자료를 사용하는 모형은 운영할 수 있는 예측시스템에 쉽게 적용할 수 있을 것이다. 따라서 본 연구에서는 일유출량을 예측하기 위하여 강우-유출과정의 물리적 현상을 나타내는 강우, 증발량 및 유출량을 입력층노드로 결정하였다. 강우량은 낙동강유역의 진동지점의 일평균강우량을 티센가중치에 의해 산정하였으며, 일평균강우량을 산정하는데 사용된 강우관측소는 51개 강우관측소의 자료를 이용하였다. 또한 증발량은 진동지점의 인근에 있고 자료의 보유년도가 많은 거창측후소의 증발접시 증발량자료를 이용하였다. 그리고 일유출량의 예측을 위한 입력층노드 선행시간을 결정하기 위하여 풍수년, 평수년 및 갈수년을 모두 포함한 훈련자료를 이용하여 선행강우량과 유출량 및 선행 유출량과 유출량자료의 상관관계를 분석하였다. 그 결과 강우와 유출량은 상관관계가 최대인 2일 선행시간까지의 강우량에 해당하는 P_t, P_{t-1}, P_{t-2} 로 결정하였으며, 유출량과 선행유출량은 상관계수의 값이 급격히 감소하기전인 1일 선행시간인 유출량 Q_{t-1} 로 결정하였다. 마지막으로 증발접시 증발량자료는 유출량과는 지체가 없는 것으로 가정하여 증발량 E_t 로 결정하였으며, 실제증발량은 접시로부터 측정된 양에 접

시계수를 곱하여서 얻어지나, 본 연구에서는 증발접시 증발량을 분석에 이용하였다. 또한 신경망모형의 은닉층노드수는 입력층노드수와 동일하게 결정하였으며, 출력층노드수는 1개로서 현재 유출량으로 결정하였다. 따라서 본 연구에서 제시된 신경망모형은 식(17) 및 (18)과 같이 나타낼 수 있으며, 식(17)은 CASE 1, 식(18)은 CASE 2를 나타내고 있다.

$$Q(t) = \phi_2 \left(\sum_{k=1}^l W_{kj} \cdot \phi_1 \left(\sum_{j=1}^5 W_{ji} \cdot X(t) + B_1 \right) + B_2 \right) \quad (17)$$

여기서 i, j, k 는 입력층, 은닉층 그리고 출력층을 나타내고 있으며, $Q(t)$ 는 진동지점의 예측 일유출량, $\phi_1(\cdot)$ 는 은닉층에서의 로그-시그모이드 전이함수, $\phi_2(\cdot)$ 는 출력층에서의 로그-시그모이드 전이함수, W_{kj} 는 은닉층과 출력층사이의 연결강도, W_{ji} 는 입력층과 은닉층사이의 연결강도, $X(t)$ 는 증발량 (E_t), 일강우량 (P_{t-2}, P_{t-1}, P_t) 및 일유출량 (Q_{t-1})의 시계열, B_1 는 은닉층에서의 편차, B_2 는 출력층에서의 편차를 나타낸 것이다.

$$Q(t) = \phi_3 \left(\sum_{l=1}^2 W_{lk} \cdot \phi_2 \left(\sum_{k=1}^5 W_{kj} \cdot \phi_1 \left(\sum_{j=1}^5 W_{ji} \cdot X(t) + B_1 \right) + B_2 \right) + B_3 \right) \quad (18)$$

여기서 i, j, k, l 은 입력층, 은닉층 1, 은닉층 2 그리고 출력층을 나타내고 있으며, $Q(t)$ 은 진동지점의 예측 일유출량, $\phi_1(\cdot)$ 는 은닉층 1에서의 로그-시그모이드 전이함수, $\phi_2(\cdot)$ 는 은닉층 2에서의 로그-시그모이드 전이함수, $\phi_3(\cdot)$ 는 출력층에서의 로그-시그모이드 전이함수, W_{lk} 는 은닉층 2와 출력층사이의 연결강도, W_{kj} 는 은닉층 1과 은닉층 2사이의 연결강도, W_{ji} 는 입력층과 은닉층 1사이의 연결강도, $X(t)$ 는 증발량 (E_t), 일강우량 (P_{t-2}, P_{t-1}, P_t) 및 일유출량 (Q_{t-1})의 시계열, B_1 는 은닉층 1에서의 편차, B_2 는 은닉층 2에서의 편차, B_3 는 출력층에서의 편차를 나타낸 것이며, 편차는 일반적으로 신경망모형이 적절한 해를 찾을 수 있도록 오차의 변화를 증

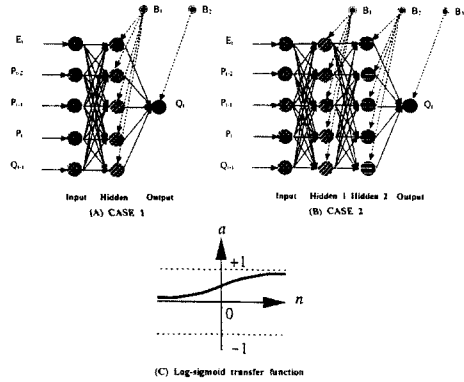


Fig. 1. Proposed structure of Neural Networks models and transfer function

가시켜 오차가 훈련임계치(training tolerance)에 도달할 수 있도록 탐색을 하거나, 필요한 훈련의 반복횟수를 감소시키는 역할을 하고 있다. 또한 Fig. 1은 본 연구에서 제시된 신경망모형의 구조와 전이함수를 나타낸 것이다.

3. 신경망모형의 적용

3.1 연구대상유역 및 수문자료의 선정

본 연구의 대상유역은 낙동강유역의 진동지점이며, 진동지점의 일유출량을 예측하기 위하여 1966년부터 1995년까지의 30년자료의 일유출량자료를 이용하였다. 본 연구에 사용된 수문자료는 기존편 용수공급능력평가(낙동강·금강수계)보고서(1999)에서 제시된 자료를 인용하였다. 30년간의 수문자료 중에서 연평균유출량이상위 1, 2번째를 풍수년(wet year), 14, 15번째를 평수년(average year), 29, 30번째를 갈수년(dry year)으로 구분하였다. 또한 모형의 훈련(training)과 검증(validation)을 위한 자료의 구성은 풍수년, 평수년, 갈수년의 1년과 풍수년+평수년, 풍수년+갈수년, 평수년+갈수년의 2년 및 풍수년+평수년+갈수년의 3년의 모두 7개의 자료로 구성하였다. 다음 Table 1은 본 신경망모형에 사용된 자료의 선정 및 선정된 자료의 기초 통계치를 나타내고 있다. Table 1에 의하면 훈련자료인 1966년의 연평균유출량이 379.654cms 로서 낙동강유역 진동지점의 연유출량의 평균적 특성 즉 평수년을 나타내는 것으로 가정하였으며, 1970년과 1977년의 경우 각각 559.209cms 및 165.571cms로서 풍

Table 1. Summary of statistics of the daily precipitation and streamflow data used for training and validation

Analysis	Data Type	Years	Precipitation(mm)				Streamflow(cms)			
			Mean	SD	CV	SC	Mean	SD	CV	SC
Training	W	1970	3.838	9.131	2.379	3.967	559.209	985.371	1.762	3.305
	A	1966	3.014	6.141	2.037	3.372	379.654	514.234	1.355	3.457
	D	1977	2.236	5.825	2.605	4.680	165.571	211.543	1.277	3.362
	WA	1970+1966	3.426	7.787	2.273	4.069	469.432	790.518	1.684	3.854
	WD	1970+1977	3.027	7.695	2.534	4.442	362.391	738.882	2.039	4.622
	AD	1966+1977	2.625	5.993	2.283	3.956	272.613	407.252	1.494	4.223
	WAD	1970+1966+1977	3.029	7.211	2.381	4.284	368.145	672.197	1.826	4.589
Validation	W	1985	4.160	10.335	2.484	3.736	683.079	1,126.126	1.649	3.651
	A	1974	3.250	8.343	2.567	4.011	391.829	731.683	1.867	4.212
	D	1995	2.318	7.156	3.087	5.776	151.771	486.614	3.206	7.637
	WA	1985+1974	3.705	9.396	2.536	3.904	537.454	960.083	1.786	4.043
	WD	1985+1995	3.239	8.930	2.757	4.471	417.425	906.425	2.172	4.623
	AD	1974+1995	2.784	7.781	2.795	4.726	271.800	632.435	2.327	5.193
	WAD	1985+1974+1995	3.243	8.735	2.684	4.339	408.893	852.115	2.084	4.599

[Note] W : Wet, D : Dry, A : Average, WD : Wet+Dry, WA : Wet+Average, AD : Average+Dry, WAD : Wet+Average+Dry, SD : Standard Deviation, CV : Coefficient of Variation, SC : Skewness Coefficient

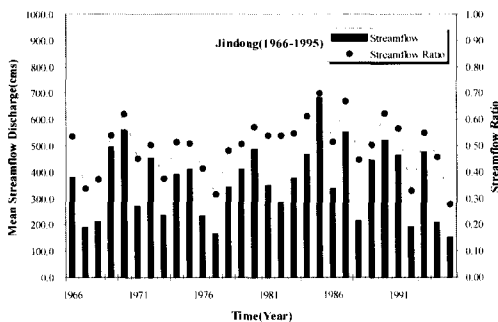


Fig. 2. Mean streamflow discharge and streamflow ratio at Jindong station of the Nakdong River basin(1966-1995)

수년과 갈수년의 특성을 나타내고 있는 것으로 가정하였다. 또한 신경망모형의 검증에 위하여 각각 683.079cms, 391.829cms 및 151.771cms의 연평균 유출량을 가진 1985년, 1974년 및 1995년을 풍수년, 평수년 및 갈수년으로 선택하였다. Fig. 2는 진동지점의 30년간의 자료에 대한 연평균유출량과 유출율의 변화율을 나타낸 것이다.

3.2 최적매개변수 선정을 위한 신경망모형의 훈련

신경망모형의 훈련과정은 최적 연결강도와 편차를 결정하기 위하여 오차를 최소화하는 반복되는 과정이다. 본 연구에서는 7개의 훈련자료가 있으며, FR-CGBP와 SCGBP 알고리즘을 이용하여 오차를 최소화한다. 선정된 평균제곱오차(MSE)의 임계치는 0.0005로 하였으며, 신경망모형의 훈련을 평균제곱오차의 임계치와 같거나 감소하기 시작할 때까지 반복하였다. 또한 입력층의 연결강도와 편차의 초기치는 난수로 -1에서 1 사이의 값을 발생시켰으며, 신경망모형의 각 층에 대한 초기치는 CASE 1과 CASE 2에 Nguyen and Widrow(1990) 방법을 이용하였다. 따라서 신경망모형의 훈련은 입력층의 연결강도와 편차의 초기치가 난수로 발생되기 때문에 훈련결과치가 조금씩의 차이가 있다. 따라서 모의된 일유출량값의 최적치를 산정하기 위하여 하나의 훈련자료에 대해 10회의 훈련을 시행착오법으로 반복하여 최적의 결과치를 산정하였다. 또한 신경망모형의 훈련결과를 실측 일유출량과 신경망모형에 의해 예측된 일유출량의 통계분석에 의해 평

가되었다. 본 연구에서 선정된 통계지표는 예측오차 (forecasting bias, $m(e)$), 평균제곱오차의 평방근 (root mean square error, $s(e)$), 잡음신호비(noise-to-signal ratio, $s(e)/s(y)$), 첨두유출비(peak runoff ratio, R_{max}) 및 상관계수(correlation coefficient, CC)로서 신경망모형의 훈련 및 검증결과를 평가하였다. 다음 Table 2는 신경망모형을 평가하는 통계지표를 나타낸 것이다. 여기서 N 은 자료의 수, $p = m + (m + n + 1)(h_1 + h_2)$ 는 신경망모형의 매개변수의 수를 나타내고 있으며, n 은 입력층노드수, h_1 은 은닉층 1의 노드수, h_2 은 은닉층 2의

노드수, m 은 출력층노드수를 나타내고 있다. 또한 $y_t(x)$ 는 일유출량의 실측자료, $\bar{y}_t(x)$ 는 일유출량의 예측자료, μ_y 는 일유출량 실측자료의 평균, $\bar{\mu}_y$ 는 일유출량 예측자료의 평균, $s(x)$ 는 일유출량 실측자료의 표준편차, $\bar{s}(x)$ 는 일유출량 예측자료의 표준편차, $\max[y(t)]$ 는 실측 일유출량의 값 중 에서 최대치를 나타내고 있으며 그때의 $\bar{y}_t(x)$ 는 실측 일유출량의 최대치에 대응하는 동일시간대의 예측 일유출량을 나타내고 있다.

Table 2. Statistical analysis index

Index	Equation
Forecast Bias[m(e)]	$\frac{1}{N} \sum_{t=1}^N [y_t(x) - \bar{y}_t(x)]$
Root Mean Square Error[s(e)]	$\sqrt{\frac{1}{N-p} \sum_{t=1}^N [y_t(x) - \bar{y}_t(x)]^2}$
Noise to-signal ratio[s(e)/s(y)]	$\sqrt{\frac{\sum_{t=1}^N [y_t(x) - \bar{y}_t(x)]^2}{\sum_{t=1}^N [y_t(x) - \mu_y]^2}}$
Peak runoff ratio[R _{max}]	$\frac{\bar{y}_t(x)}{\max[y_t(x)]} \times 100$
Correlation Coefficient [CC]	$\frac{1}{N} \sum_{t=1}^N \left[\frac{y_t(x) - \mu_y(x)}{s(x)} \right] \left[\frac{\bar{y}_t(x) - \bar{\mu}_y(x)}{\bar{s}(x)} \right]$

Table 3. Training results of Neural Networks models at Jindong station of the Nakdong River basin(CASE 1)

Data	Algorithm	Iteration	Time (sec)	Statistical analysis				
				m(e)(cms)	s(e)(cms)	s(e)/s(y)	R _{max} (%)	CC
W	FR-CGBP	474	215	3.066	159.968	0.162	94.6	0.985
	SCGBP	682	310	2.733	159.949	0.162	99.9	0.986
A	FR-CGBP	212	97	0.517	81.619	0.159	91.0	0.986
	SCGBP	366	167	5.467	81.372	0.159	95.0	0.987
D	FR-CGBP	3,546	1,610	1.609	49.236	0.233	99.9	0.973
	SCGBP	4,729	2,147	-1.896	49.234	0.233	93.2	0.975
WA	FR-CGBP	326	148	3.969	155.831	0.197	89.5	0.980
	SCGBP	459	209	-0.209	154.174	0.197	87.4	0.982
WD	FR-CGBP	3,340	1,516	-3.907	382.307	0.484	81.5	0.921
	SCGBP	4,232	1,921	-4.229	382.182	0.483	82.4	0.922
AD	FR-CGBP	1,550	704	0.225	79.776	0.196	93.9	0.980
	SCGBP	1,980	899	-1.223	79.673	0.196	94.3	0.980
WAD	FR-CGBP	111	51	4.213	155.992	0.231	80.6	0.973
	SCGBP	188	86	5.711	155.016	0.231	81.5	0.974

Table 4. Training results of Neural Networks models at Jindong station of the Nakdong River basin(CASE 2)

Data	Algorithm	Iteration	Time (sec)	Statistical analysis				
				m(e)(cms)	s(e)(cms)	s(e)/s(y)	R _{max} (%)	CC
W	FR-CGBP	642	296	0.617	169.242	0.172	93.5	0.985
	SCGBP	749	346	0.559	169.209	0.172	96.3	0.986
A	FR-CGBP	252	117	-2.451	85.698	0.167	98.9	0.986
	SCGBP	389	180	-0.223	85.362	0.167	94.6	0.987
D	FR-CGBP	3,849	1,775	1.276	52.084	0.246	97.7	0.973
	SCGBP	4,931	2,274	-0.017	52.021	0.246	99.1	0.974
WA	FR-CGBP	333	154	0.416	160.109	0.203	90.4	0.980
	SCGBP	532	246	4.590	159.947	0.202	88.7	0.981
WD	FR-CGBP	3,634	1,676	3.277	392.214	0.496	88.2	0.921
	SCGBP	4,758	2,194	0.287	392.125	0.496	98.9	0.923
AD	FR-CGBP	2,253	1,039	2.686	81.850	0.201	90.0	0.980
	SCGBP	2,874	1,325	0.908	81.877	0.201	92.5	0.981
WAD	FR-CGBP	166	77	0.074	157.570	0.234	81.8	0.973
	SCGBP	208	96	2.656	157.342	0.234	87.5	0.975

또한 Table 3과 4는 CASE 1과 CASE 2에서의 훈련결과를 나타낸 것이다. 신경망모형의 훈련을 위하여 MATLAB Version 5.3(1998)으로 프로그래밍을 하였으며, Intel Celeron Processor-466MHz CPU를 가진 Pavilion Hewlett Packard PC를 이용하였다. 훈련에 필요한 시간은 FR-CGBP 및 SCGBP 알고리즘이 훈련입계치에 도달할 때 까지의 시간이며, 반복횟수와 은닉층의 수에 비례하는 것으로 나타났다. Table 3과 4에 의하면 CASE 1과 CASE 2의 경우 1년(W, A, D)의 자료중에서 평수년이 훈련에 필요한 반복횟수와 시간이 가장 적게 필요한 것으로 나타났고, 갈수년의 경우 그 반대의 결과를 나타내고 있다. 또한 SCGBP 알고리즘이 FR-CGBP 알고리즘보다 전반적인 통계분석 결과가 미소하게 양호한 것으로 나타났다. 2년(WA, WD, AD)의 자료의 경우 풍수년+평수년(WA)이 훈련에 필요한 반복횟수와 시간이 가장 적게 필요한 것으로 나타났고, 풍수년+갈수년(WD)의 경우는 그 반대의 결과를 나타내고 있다. 또한 SCGBP 알고리즘이 FR-CGBP 알고리즘보다 전반적인 통계분석 결과가 미소하게 양호한 것으로 나타났다. 그리고 3년(WAD)의 자료의 경우 풍수년+평수년+갈수년(WAD)의 SCGBP 알고리즘이 FR-CGBP 알고리즘보다 미소하게 양호한 것으로 나타났으며, 신경망모형의 훈련에 있어서 풍수년+갈수년(WD)의 자료, 즉 서로 완전히 상반된 특성을 가진 자료의 통계분석결과가 가장

좋지 않은 것으로 나타났다. 이와같은 신경망모형의 훈련결과를 수문자료의 특성에 의해 기인하는 것으로 사료되며, 자료의 표준편차, 변동계수, 왜곡도계수의 값이 낮은 값에 수렴하는 자료, 즉 자료의 분포특성이 동일할수록 본 신경망모형의 훈련결과는 우수한 것으로 사료된다. 그리고 SCGBP 알고리즘이 FR-CGBP 알고리즘보다 연산과정이 복잡한 원인으로 인하여 신경망모형의 훈련에 다소 시간과 반복회수를 많이 필요로 하는 것으로 사료된다. 따라서 본 연구에서는 신경망모형의 훈련에 필요한 반복횟수 및 시간을 비롯하여 통계분석결과와 모형의 구성에 있어서의 용이함등을 종합평가하여 CASE 1의 SCGBP 알고리즘에 의해 선정되어진 각 연결강도와 편차를 신경망모형의 검증에 이용하였다. 다음 Table 5는 CASE 1의 SCGBP 알고리즘에 의한 풍수년+평수년+갈수년(WAD) 자료의 훈련결과 산정된 최적매개변수를 나타내고 있으며, Fig. 3은 CASE 1과 CASE 2의 풍수년+평수년+갈수년(WAD) 자료의 훈련에 있어서 훈련입계치에 대한 평균제곱오차의 수렴과정을 나타내고 있다. 또한 Fig. 4(a)-(b)는 CASE 1과 2에서 풍수년+평수년+갈수년(WAD) 자료가 순차적으로 발생한 수문시계열의 훈련에 의해 모의된 일 유출수문곡선을 실측 일 유출수문곡선과 비교하였으며, 일 유출수문곡선의 상승부, 첨두부 및 감소부에서 신경망모형에 의해 모의된 일 유출수문곡선은 실측 일 유출수문곡선을 잘 반영하는 것

Table 5. The best-fit weights and biases for Neural Networks model with SCGBP algorithm(CASE 1, WAD data)

Hidden Layer		Input Variables and Weights					Output Layer
		E_t	P_{t-2}	P_{t-1}	P_t	Q_{t-1}	
Node j	Bias B_j	W_{j1}	W_{j2}	W_{j3}	W_{j4}	W_{j5}	W_{lj}
1	-10.010	5.801	0.250	0.253	3.663	4.946	3.119
2	-7.749	5.762	2.012	2.688	-3.342	0.749	-1.368
3	-0.936	-0.103	-0.790	-0.233	-0.652	-17.581	-11.325
4	0.811	5.291	1.916	1.648	-4.696	1.007	-0.043
5	-3.189	-0.161	2.703	4.096	-2.082	4.345	3.312
Bias B_2							-1.786




Fig. 3 Mean square errors for Neural Networks models training(WAD data)




Fig. 4(a) Comparison of observed and simulated streamflow hydrographs from the WAD data (Training, CASE 1)

로 분석되었다.

3.3 최적매개변수에 의한 신경망모형의 검증

전절 3.2에서 신경망모형의 훈련과정을 통하여 CASE 1의 SCGBP 알고리즘에 의해 산정된 최적 연결강도와 편차 및 모형의 검증자료를 이용하여 신경망모형을 검증하였으며, 검증결과는 Table 6과 같다. Table 6에 의하면 1년(W, A, D)의 자료중에서는 평수년(A), 2년(WA, WD, AD)의 자료중에서는 풍수년+평수년(WA)의 검증결과가 가장 양호하였으며, 3년(WAD)의 검증결과도 아주 양호한 것으로 나타났다. 그러나 신경망모형의 훈련과정처럼 풍수년+갈수년(WD)의 검증결과는 다른 자료들에 비해서 결과치가 좋지 않은 것으로 판단되며, 신경망모형의 검증과정을 통하여 훈련결과의 우수성을 설명할 수 있다. 다음 Fig. 5는 풍수년+평수년+갈수년(WAD) 자료의 검증에 의해 모의된 일 유출수문곡선을 실측 일 유출수문




Fig. 4(b) Comparison of observed and simulated streamflow hydrographs from the WAD data (Training, CASE 2)

Table 6. Validation results of Neural Networks model at Jindong station of the Nakdong River basin

Data	Network	Algorithm	Statistical analysis				
			m(e)(cms)	s(e)(cms)	s(e)/s(y)	R _{max} (%)	CC
W	5-5-1	SCGBP	7.602	548.014	0.487	96.1	0.905
A	5-5-1	SCGBP	90.606	237.568	0.481	92.9	0.930
D	5-5-1	SCGBP	42.723	242.821	0.499	97.8	0.910
WA	5-5-1	SCGBP	18.536	325.293	0.339	91.8	0.943
WD	5-5-1	SCGBP	146.881	537.469	0.593	79.6	0.842
AD	5-5-1	SCGBP	34.614	269.826	0.427	99.4	0.919
WAD	5-5-1	SCGBP	44.275	286.405	0.336	77.2	0.949




Fig. 5 Comparison of observed and simulated streamflow hydrographs from the WAD data(Validation)

곡선과 비교하였으며, 일 유출수문곡선의 상승부, 침투부 및 감소부에서 신경망모형에 의해 검증된 일 유출수문곡선은 실제 일 유출수문곡선을 잘 반영하는 것으로 분석되었다.

4. 다중회귀분석모형(Multiple Regression Analysis Model : MRAM)

4.1 다중회귀분석모형(MRAM)의 적용

본 연구에서는 선정한 신경망모형의 검증결과를 비교검토하기 위한 모형으로 다중회귀분석모형(MRAM)을 선정하였다(Salas et al, 1999). 기존의 개념적 및 물리적 모형은 일반적으로 모형의 운영에 있어서 많은 매개변수와 입력자료를 필요로 하는 단점이 있다(NWS, 1996). 따라서 본 연구에서는 신경망모형과 비교분석하기 위한 모형을 간단히 나타내기 위하여 신

경망모형의 입력층노드를 이용하여 다중회귀분석모형을 구성하였으며, 다음 식(19)와 같이 나타낼 수 있다.

$$Q_t = b_0 + b_1 E_t + b_2 P_{t-2} + b_3 P_{t-1} + b_4 P_t + b_5 Q_{t-1} \quad (19)$$

여기서 $b_i (i=1, \dots, 5)$ 는 경사계수로서 종속변수인 일유출량 Q_t 에 대한 각 변수들의 효과를 나타내고 있다. 또한 표준화된 다중회귀분석모형은 다음 식(20)과 같이 나타낼 수 있다.

$$Z_{Q_t} = t_1 Z_{E_t} + t_2 Z_{P_{t-2}} + t_3 Z_{P_{t-1}} + t_4 Z_{P_t} + t_5 Z_{Q_{t-1}} \quad (20)$$

여기서 Z 값은 각 종속변수 및 독립변수에 대하여 $Z = \frac{x - \bar{x}}{\sigma}$ 으로 표준화된 변량들이고, $t_i (i=1, \dots, 5)$ 는 표준화된 부분회귀계수이다. 또한 다중회귀분석모형을 평가하는 기준은 다중결정계수(coefficient of multiple determination, CMD), 평균제곱오차의 평방근, 독립변수의 상대적 중요성 및 잔차분석(residual analysis) 등이 있으나, 본 연구에서 신경망모형의 평가기준으로 선정한 통계지표와 비교하여 상관계수(CC), 평균제곱오차의 평방근(RMSE) 및 잡음신호비(noise-to-signal ratio)를 비교토록 하였다.

4.2 다중회귀분석모형(MRAM)의 매개변수의 결정

본 연구에서는 신경망모형의 훈련자료를 이용하여 다중회귀분석모형의 매개변수를 산정하였으며, 일유출




Fig. 6 Comparison of observed and simulated streamflow hydrographs from the training WAD data(MRAM)

량을 산정하였다. 다음 Table 7은 신경망모형의 훈련 자료를 이용하여 매개변수($b_i, i=1, \dots, 5$)를 산정하여 구한 다중회귀분석모형 및 실측 일유출량과의 통계분석을 나타낸 것이다. Table 7에 의하면 본 다중회귀분석모형에 의해 산정된 일유출량은 통계분석을 통하여 양호한 결과를 유도하였으나, 본 연구에서 제시한 신경망모형의 훈련결과보다는 모형의 적합성이 떨어지는 것으로 나타났다. 또한 표준화된 다중회귀모형을 이용하여 모형의 부분회귀계수에 의한 독립변수의 상대적 중요성을 비교하여 볼 때 현재의 일유출량에 가장 영향을 미치는 독립변수로는 1일 선행시간의 일유출량(Q_{t-1})으로 나타났으며, 가장 상관성이 없는 독립변수로는 증발잠시 증발량(E_t)으로 나타났다. Table 8은 풍수년+평수년+갈수년(WAD) 자료의 상관행렬(correlation matrix)을 나타낸 것이다. Table

Table 7. Multiple Regression Analysis Model(MRAM) using training data at Jindong station of the Nakdong River basin

Data	Type	Regression Model	Statistical Index		
			s(e)(cms)	s(e)/s(y)	CC
W	Normal	$Q_t = -0.945 - 5.114E_t + 23.126P_{t-2} + 24.425P_{t-1} - 2.446P_t + 0.720Q_{t-1}$	290.747	0.295	0.956
	Standardized	$Z_{Q_t} = -0.010Z_{E_t} + 0.214Z_{P_{t-2}} + 0.226Z_{P_{t-1}} - 0.022Z_{P_t} + 0.719Z_{Q_{t-1}}$			
A	Normal	$Q_t = 12.868 - 7.036E_t + 18.516P_{t-2} + 17.250P_{t-1} - 0.750P_t + 0.752Q_{t-1}$	175.561	0.341	0.941
	Standardized	$Z_{Q_t} = -0.028Z_{E_t} + 0.221Z_{P_{t-2}} + 0.206Z_{P_{t-1}} - 0.009Z_{P_t} + 0.751Z_{Q_{t-1}}$			
D	Normal	$Q_t = 3.975 + 0.015E_t + 8.431P_{t-2} + 2.976P_{t-1} + 0.205P_t + 0.821Q_{t-1}$	211.543	0.394	0.920
	Standardized	$Z_{Q_t} = 0.0001Z_{E_t} + 0.232Z_{P_{t-2}} + 0.081Z_{P_{t-1}} + 0.006Z_{P_t} + 0.821Z_{Q_{t-1}}$			
WA	Normal	$Q_t = -6.798 - 6.340E_t + 22.468P_{t-2} + 22.833P_{t-1} - 1.579P_t + 0.728Q_{t-1}$	286.295	0.315	0.950
	Standardized	$Z_{Q_t} = -0.014Z_{E_t} + 0.223Z_{P_{t-2}} + 0.226Z_{P_{t-1}} - 0.015Z_{P_t} + 0.728Z_{Q_{t-1}}$			
WD	Normal	$Q_t = 89.009 + 2.0663E_t + 17.359P_{t-2} + 17.267P_{t-1} + 0.101P_t + 0.663Q_{t-1}$	548.771	0.604	0.814
	Standardized	$Z_{Q_t} = 0.048Z_{E_t} + 0.169Z_{P_{t-2}} + 0.168Z_{P_{t-1}} + 0.001Z_{P_t} + 0.630Z_{Q_{t-1}}$			
AD	Normal	$Q_t = 2.852 - 4.490E_t + 15.713P_{t-2} + 12.160P_{t-1} + 0.666P_t + 0.780Q_{t-1}$	173.246	0.363	0.932
	Standardized	$Z_{Q_t} = -0.021Z_{E_t} + 0.217Z_{P_{t-2}} + 0.168Z_{P_{t-1}} + 0.009Z_{P_t} + 0.780Z_{Q_{t-1}}$			
WAD	Normal	$Q_t = -36.104 - 1.260E_t + 21.526P_{t-2} + 21.212P_{t-1} - 0.149P_t + 0.738Q_{t-1}$	294.311	0.324	0.947
	Standardized	$Z_{Q_t} = -0.003Z_{E_t} + 0.222Z_{P_{t-2}} + 0.219Z_{P_{t-1}} - 0.002Z_{P_t} + 0.738Z_{Q_{t-1}}$			

Table 8. Correlation matrix for the training data at Jindong station of the Nakdong river basin(WAD data)

	E_t	P_{t-2}	P_{t-1}	P_t	Q_{t-1}	Q_t
Daily pan evaporation, t	1.000	0.053	0.007	-0.077	0.050	0.089
Daily precipitation, t-2	0.053	1.000	0.482	0.135	0.471	0.549
Daily precipitation, t-1	0.007	0.482	1.000	0.482	0.240	0.402
Daily precipitation, t	-0.077	0.135	0.482	1.000	0.158	0.201
Daily streamflow, t-1	0.050	0.471	0.240	0.158	1.000	0.753
Daily streamflow, t	0.089	0.549	0.402	0.201	0.753	1.000

Table 9. Results of statistical analysis of the validation data by MRAM

Data	Statistical Index		
	s(e)(cms)	s(e)/s(y)	CC
W	563.544	0.487	0.901
A	277.909	0.497	0.921
D	254.112	0.511	0.903
WA	354.213	0.379	0.911
WD	567.231	0.601	0.823
AD	289.700	0.456	0.902
WAD	296.546	0.356	0.923

8에 의하면 상관행렬 분석결과의 경우 현재의 일유출량은 1일 선행시간의 일유출량(Q_{t-1})과 2일 선행시간의 일강우량(P_{t-2})과는 높은 상호상관이 있는 것으로 나타났다. 또한 Fig. 6은 신경망모형의 훈련자료에 대하여 다중회귀분석모형에 의해 모의된 풍수년+평수년+갈수년(WAD) 자료의 일 유출수문곡선을 실측 일 유출수문곡선과 비교하였다.

4.3 다중회귀분석모형(MRAM)의 검증

신경망모형의 훈련자료를 이용하여 다중회귀분석모형의 각 매개변수를 산정하였으며, 산정된 매개변수를 이용하여 다중회귀분석모형을 검증하기 위하여 신경망모형의 검증자료를 이용하여 일유출량을 산정하였다. Table 9는 신경망모형의 검증자료를 이용하여 Table 7에 구한 다중회귀분석모형의 매개변수로서 산정한 일 유출량의 통계분석을 나타낸 것이다. Table 9에 의하면 신경망모형의 검증결과가 다중회귀분석모형의 결과치보다 다소 우수한 것으로 나타났으며, 본 연구의 신




Fig. 7 Comparison of observed and simulated streamflow hydrographs from the validation WAD data(MRAM)

경망모형은 하천유역의 일유출량산정에 있어서 우수한 모형이라고 사료된다. 다음 Fig. 7은 신경망모형의 검증자료에 대하여 다중회귀분석모형에 의해 모의된 풍수년+평수년+갈수년(WAD) 자료의 일 유출수문곡선

을 실측 일 유출수문곡선과 비교하였다.

5. 결 론

본 연구에서는 낙동강유역의 진동지점에서 일유출량을 예측하기 위하여 다층신경망모형을 적용하였으며, 사용된 훈련 알고리즘은 기존의 역전파훈련 알고리즘을 보완한 FR-CGBP와 SCGBP 알고리즘을 이용하였다. 일유출량 예측을 위하여 진동지점의 1966년부터 1995년까지의 30년의 일유출량 자료, 낙동강유역 51개 강우관측소의 일강우량을 티센가중치에 의해 산정한 유역평균강우량 자료 및 거창측후소의 증발접시 증발량자료를 이용하였다. 또한 본 연구에서 적용한 신경망모형은 은닉층의 수에 따라서 CASE 1과 CASE 2로 구분하였으며, 전이함수는 로그-시그모이드함수를 사용하여 다음과 같은 결론을 얻었다.

(1) 진동지점의 30년간의 일유출량 자료를 각각 풍수년, 평수년 및 갈수년으로 구분하여 풍수년, 평수년, 갈수년, 풍수년+평수년, 풍수년+갈수년, 평수년+갈수년 및 풍수년+평수년+갈수년의 7개의 훈련 및 검증자료로 구성하였으며, 신경망모형을 적용하여 훈련시킨 결과 풍수년+갈수년자료를 제외하고는 훈련결과가 양호한 것으로 나타났다. 또한 검증에 사용될 모형은 훈련에 필요한 시간, 학습횟수 및 통계분석결과를 토대로 하여 SCGBP 알고리즘을 가진 CASE 1으로 선정하였으며, CASE 2의 경우도 수문사상을 재현하는데 무리는 없으나 CASE 1의 경우보다는 효과가 떨어지는 것으로 판단된다.

(2) 신경망모형의 훈련에 의해 산정된 연결강도와 편차를 검증자료에 적용시켜 일유출량을 산정한 결과 훈련결과처럼 양호한 결과를 나타내었다. 그러나 풍수년+갈수년과 같이 서로 완전히 상반된 특성을 가진 자료의 경우는 신경망모형의 검증결과가 좋지않은 것으로 나타났으나, 풍수년+갈수년을 제외한 분포특성이 동일한 자료일수록 일유출량을 잘 예측하는 것으로 나타났다. 이와같은 신경망모형의 검증결과는 수문자료의 특성에 의해 기인하는 것으로 사료된다.

(3) 본 연구에서 선정한 신경망모형의 우수성을 비교하기 위하여 다중회귀분석모형을 적용하였으며, 신경망모형의 훈련자료를 이용하여 다중회귀분석모형의 매개변수와 일유출량을 산정하였다. 또한 신경망모형의 검증자료를 이용하여 얻어진 매개변수로 일유출량을 산정하여 신경망모형의 검증결과치와 비교하였다. 그 결과 신경망모형의 결과치가 다중회귀분석모형의 결과

치보다 다소 양호한 상태를 나타내고 있는 것으로 나타났다.

따라서 본 연구의 신경망모형은 모형의 구성이 간편하고, 신경망에 관한 지식이 부족한 수문학자들도 쉽게 모형화할 수 있는 장점이 있다. 따라서 신경망모형을 이용한 실시간 유출해석, 장기간 하상변동해석, 및 댐의 최적운영을 산정 등 광범위한 수문, 수리 및 수자원문제 해결을 위한 지속적인 연구가 필요한 것으로 사료된다.

References

- 건설교통부, 한국수자원공사(1999). 기존댐 용수공급 능력조사(낙동강·금강수계)보고서.
- 김주환(1993). “신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구.” 박사학위논문, 인하대학교.
- 심순보, 김만식(1999a). “충주다목적댐 홍수유입량 예측을 위한 최적 신경망모형의 개발.” 대한토목학회논문집, 대한토목학회, 제 19권, 제II-1호, pp. 67~78.
- Demuth, H., and Beale, M.(1998). *Neural network toolbox : for use with MATLAB user's guide*, The Math Works Inc.
- Fletcher, R.(1975). *Practical methods of optimization*, John Wiley & Sons, New York.
- Fletcher, R., and Reeves, C.M.(1964). “Function minimization by conjugate gradient” *Computer Journal*, Vol. 7, pp. 149~154.
- Hipel, K.W., and McLeod, A.I.(1994). *Time series modeling of water resources and environmental systems*, Development in Water Science 45, Elsevier.
- Isobe, I., Ohkado, T., Hanyuda, H., Oda, S., and Gotoh, Y.(1994). “The development of a forecasting system of the water levels of rivers by neural networks.” *J. of Japan Soc. of Hydro. and Water Resour.*, Vol. 7, No. 2, pp. 90~97.
- Kim, S., and Lee, S.(2000). “Forecasting of flood stage using neural networks in the Nakdong river, South Korea.” *Proc.*,

- Watershed Management & Operations Management 2000*, ASCE/EWRI, Fort Collins, CO.
- Liong, S.Y., and Chan, W.T.(1993). "Runoff volume estimates with neural network." *Proc., 3rd Int. Conf. in Application of AI to Civ. and Struct. Engrg. Neural Networks and Combinatorial Optimization in Civ. and Struct. Engrg.*, B.H.V. Topping and A.I.Khan, eds., Civil-Comp. Press, U.K., pp. 67~70.
- Minns, A.W., and Hall, M.J.(1996). "Artificial neural network as rainfall runoff models." *J. of Hydr. Res.*, Vol. 34, No. 4, pp. 537~548.
- Moller, M.F.(1993). "A scaled conjugate gradient algorithm for fast supervised learning" *Neural Networks*, Vol. 6, pp. 525~533.
- NeuralWare, Inc., Neural Computing(1991). *NeuralWorks Professional II/Plus and NeuralWorks Explorer*, Pittsburgh, PA.
- Nguyen, D.H. and Widrow, B.(1990). "Neural network for self-learning control systems." *IEEE Control Systems Magazine*, pp. 18~23.
- NWS(National Weather Service)(1996). *National Weather Service River Forecast System (NWSRFS)*, U.S. Department of Commerce, NOAA, National Weather Service, Office of Hydrology, Silver Spring, MD.
- Raman, H., and Sunilkumar, N.(1995). "Modeling water resources time series using artificial neural networks." *Hydro. Sci.*, Vol. 40, No. 2, pp. 145~162.
- Rosso, R., Peano, A., Becchi, I., and Bemporad, G.A.(1994). *Advances in distributed hydrology*, Water Resources Publications, 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.
- 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.
- 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.
- Tokar, A.S., and Johnson, P.A.(1999). "Rainfall-runoff modeling using artificial neural networks." *J. of Hydro. Eng.*, ASCE, Vol. 4, No.3, pp. 232~239.
- Zealand, C.M., Burn, D.H., and Simonovic, S.P.(1999). "Short term streamflow forecasting using artificial neural networks." *J. of Hydro.*, Vol. 214, pp. 32~48.

(논문번호:00-021/접수:2000.03.30/심사완료:2000.07.31)