

추계학적모형과 신경망모형을 연계한
병렬저수지군의 유입량산정
Streamflow Estimation using Coupled Stochastic and Neural
Networks Model in the Parallel Reservoir Groups

김 성 원*
Kim, Sungwon

Abstract

Spatial-Stochastic Neural Networks Model(SSNNM) is used to estimate long-term streamflow in the parallel reservoir groups. SSNNM employs two kinds of backpropagation algorithms, based on LMBP and BFGS-QNBP separately. SSNNM has three layers, input, hidden, and output layer, in the structure and network configuration consists of 8-8-2 nodes one by one. Nodes in input layer are composed of streamflow, precipitation, pan evaporation, and temperature with the monthly average values collected from Andong and Imha reservoir. But some temporal differences apparently exist in their time series. For the SSNNM training procedure, the training sets in input layer are generated by the PARMA(1,1) stochastic model and they covers insufficient time series. Generated data series are used to train SSNNM and the model parameters, optimal connection weights and biases, are estimated during training procedure. They are applied to evaluate model validation using observed data sets. In this study, the new approaches give outstanding results by the comparison of statistical analysis and hydrographs in the model validation. SSNNM will help to manage and control water distribution and give basic data to develop long-term coupled operation system in parallel reservoir groups of the Upper Nakdong River.

Keywords : Spatial-Stochastic Neural Networks Model, PARMA(1,1), LMBP, BFGS-QNBP, parallel reservoir groups

요 지

본 연구에서는 낙동강 상류유역의 병렬 다목적댐군인 안동 및 임하다목적 댐의 장기간 유입량을 산정하는데 공간추계 신경망모형이 사용되었다. 공간추계 신경망모형은 역전파 알고리즘으로 LMBP와 BFGS-QNBP를 각각 사용하였다. 공간추계 신경망모형의 구조는 입력층, 은닉층 및 출력층의 3개의 층과 차례대로 8-8-2개의 노드로 구성되어 있다. 입력층 노드는 안동 및 임하다목적 댐의 월평균유입량, 월면적강우량, 월별 증발접시 증발량과 월평

* 동양대학교 지구환경시스템공학과 전임강사, 공학박사, 수자원개발기술사
Senior Lecturer, Dept. of Civil and Environmental Engr., Dongyang University, Yeongju, Kyeongbook,
750-712, Korea.
(E-mail : swkim68@phenix.dyu.ac.kr)

균기온으로 구성되어 있으며, 자료시계열은 시간적으로 차이가 있다. 공간추계 신경망모형의 훈련을 위하여 추계학적 모형중 하나인 PARMA(1,1)에 의해서 훈련자료를 모의발생시켰으며, 모의발생된 자료는 공간추계 신경망모형의 훈련에 사용되었다. 훈련을 통하여 공간추계 신경망모형의 매개변수인 최적연결강도와 편차를 산정하였다. 산정된 매개변수는 안동 및 임하다목적 댐의 실측자료를 이용하여 공간추계 신경망모형의 검증에 이용되었으며, 통계분석과 수문곡선의 비교를 통하여 우수한 결과를 나타내었다. 따라서 공간추계 신경망모형은 낙동강 상류유역의 병렬 저수지군의 장기간 연계운영기법 개발을 위하여 기초적인 자료를 제공하고, 용수분배 및 관리에 도움을 줄 것이다.

핵심용어 : 공간추계 신경망모형, PARMA(1,1), LMBP, BFGS-QNBP, 병렬 저수지군

1. 서론

1990년대 이후로 신경망이론은 수자원의 수량 및 수질의 변화를 모형화 하는데 전통적인 수치해석 및 경험식을 대체할 수 있는 효과적인 기법의 하나로 이용되어 오고 있다. 특히 최근에 와서는 신경망에 기반을 둔 많은 모형이 유출예측, 가뭄해석 및 저수지의 유입량의 예측에 적용되고 있다(Thirumalaiah and Deo, 1998, 2000; Tokar and Johnson, 1999; Zealand et al., 1999; 김성원 외, 2001, 2002a, b; 신현석과 박무중, 1999, Jain et al., 1999; Coulibaly et al., 2000a, b). 수공학에 있어서의 신경망기법의 대부분은 역전파 알고리즘을 이용한 다층퍼셉트론 신경망모형이며, 전통적인 모형화기법보다 신경망에 의한 접근법의 주요장점은 수학적 표현의 진행과정에 있어서 복잡한 특성을 요구하지 않는다는 점이다. 다목적 댐의 장기간 유입량을 정확하게 산정하는 것은 수자원 기술자 및 관리자들에게 주요 과업 중 하나이며, 기술적, 경제적 그리고 정치적인 범주 내에서 수자원시스템의 효과적인 운영을 가능하게 하며, 가뭄해석, 관개용수 및 발전소계획을 위하여 사용하고 있다. 다목적 댐의 장기간 유입량을 산정하는 기법은 일반적으로 개념적/물리적인 기법과 통계학적/추계학적 기법이 있다. 첫 번째 범주인 개념적/물리적인 기법은 유역에서 발생하는 수문학적 순환을 수학적으로 표현하고 있으며, 모형을 구성하는 여러 인자들을 통하여 미분형식의 연속 및 운동량방정식의 해법을 이용하고 있다. 두 번째 범주인 통계학적/추계학적 기법은 단순선형, 다중선형, 비선형 회귀식, ARMA, ARMAX 기법을 의미하고 있으며, 일반적으로 다목적 댐의 장기간 유입량을 산정하는 모형 구성인자의 시계열이 일치하지 않을 경우에는 모형의 구성 및 매개변수의 산정이 난이하다.

본 연구에서는 낙동강유역의 상류에 위치하고 있는 병렬 저수지군인 안동 및 임하다목적 댐의 장기간 유입

량을 산정하기 위하여 부족한 훈련자료의 시계열은 추계학적 모형에 의해 모의발생시키는 기법을 이용하였으며, 기존의 신경망모형을 변형한 공간추계 신경망모형(Spatial-Stochastic Neural Networks Model, SSNNM)을 제시하였다. 공간추계 신경망모형은 공간적으로 동일한 위치에 있지 않는 병렬다목적 댐군에서 선행시간의 월평균유입량, 월면적강우량, 월별 증발점시 증발량 및 월평균기온과 같은 입력변수들을 이용하여 안동 및 임하다목적 댐의 월평균유입량을 동시에 산정할 수 있는 신경망모형이다. 또한 공간추계 신경망모형의 훈련 및 검증을 통하여 모형의 적합성을 검토하고, 병렬 저수지군의 새로운 형태의 장기간 연계운영기법 개발을 위한 기초자료를 제공하고자 한다.

2. 신경망모형과 훈련알고리즘

신경망은 뉴런이라는 기초적인 단위로 구성되어 있으며, 각 뉴런은 입력자료를 받아들이고 그 입력된 자료를 처리하며 출력형태로 전환한다. 입력형태는 순수자료일 수도 있고 다른 뉴런의 출력결과일 수도 있으며, 출력형태는 마지막 처리과정의 결과치이거나 다른 뉴런의 입력자료일 수도 있다. 신경망은 이러한 뇌와 동일한 계산방식을 사용한 커넥셔니즘(Connectionism)에 기반을 둔 수리모형이다(Gallant, 1993; Haykin, 1994). 또한 적용된 훈련알고리즘은 연결강도와 편차를 조정함으로써 전역오차의 값을 최소화하는 역전파 훈련알고리즘이다. 본 연구에서 제시한 신경망모형은 공간추계 신경망모형이고, 적용된 역전파 훈련 알고리즘은 Levenberg-Marquardt 역전파(LMBP)알고리즘과 BFGS 의사뉴턴(BFGS-QNBP)알고리즘이며, 상세한 내용은 다음과 같다.

2.1 공간추계 신경망모형(Spatial-Stochastic Neural Networks Model, SSNNM)의 구성

공간추계 신경망모형(SSNNM)은 MATLAB Ver-

sion 6.0(2000)으로 프로그래밍을 하였으며 입력층, 은닉층 및 출력층으로 구성되어 있고, 역전파 알고리즘을 이용한 다층퍼셉트론(MultiLayer Perceptron, MLP)형태의 기법이다. 일반적으로 강우, 증발량 및 유출량과 같은 자료는 토양특성, 초기토양함수, 침투 및 지하수특성과 같은 자료에 비하여 관측이 상대적으로 쉬우며, 자료의 수집에 있어서 비용이 저렴한 편이다. 따라서 낙동강 상류유역의 안동 및 임하다목적 댐에서 장기간 유입량을 산정하기 위한 입력층의 노드는 안동 및 임하다목적 댐 유입과정의 물리적 현상을 나타내는 선행시간의 월평균유입량, 월면적강우량, 월별 증발접시 증발량 및 월평균기온으로 설정하였다. 그리고 은닉층의 노드 수는 입력층의 노드 수와 동일하게 구성하였으며, 출력층의 노드 수는 안동 및 임하다목적 댐의 장기간 유입량에 해당하는 월평균유입량으로 구성되어 있다. 구성된 공간추계 신경망모형은 다음 식 (1)과 같이 나타낼 수 있으며, 공간추계 신경망모형의 개발과정은 그림 1과 같다. 그림 2는 본 연구에서 제시된 공간추계 신경망모형의 구조를 나타낸 것이다.

$$Q(t_a, t_i) = \phi_2\left(\sum_{k=1}^2 W_{ki} \cdot \phi_1\left(\sum_{j=1}^8 W_{ji} \cdot X(t) + B_{1j}\right) + B_{2k}\right) \quad (1)$$

여기서 i, j, k 는 입력층, 은닉층 그리고 출력층을 나타내고 있으며, $Q(t_a, t_i)$ 는 안동 및 임하다목적 댐에서 월평균유입량, $\phi_1(\cdot)$ 는 은닉층에서의 로그-시그모이드 전이함수, $\phi_2(\cdot)$ 는 출력층에서의 선형전이함수, W_{ki} 는 은닉층과 출력층사이의 연결강도, W_{ji} 는 입력층과 은닉층사이의 연결강도, $X(t)$ 는 안동 및 임하다목적 댐에서 선행시간의 월평균유입량, 월면적강우량, 월별 증발접시 증발량 및 월평균기온의 시계열, B_{1j} 는 은닉층에서의 편차, B_{2k} 는 출력층에서의 편차를 나타낸 것이다. 편차는 일반적으로 신경망모형이 최적의 해를 찾을 수 있도록 오차의 변화를 증가시켜 훈련임계치에 도달할 수 있도록 탐색을 하거나, 필요한 훈련의 반복횟수를 감소시키는 역할을 하고 있다(김성원, 2000a).

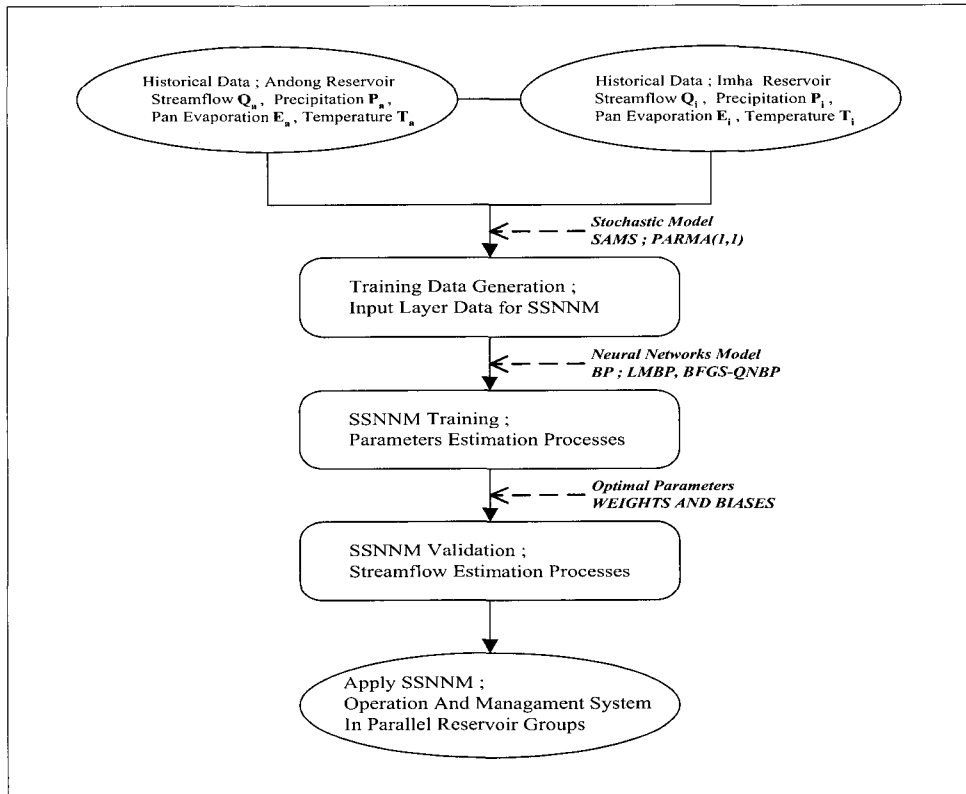


그림 1. 공간추계 신경망모형의 개발과정

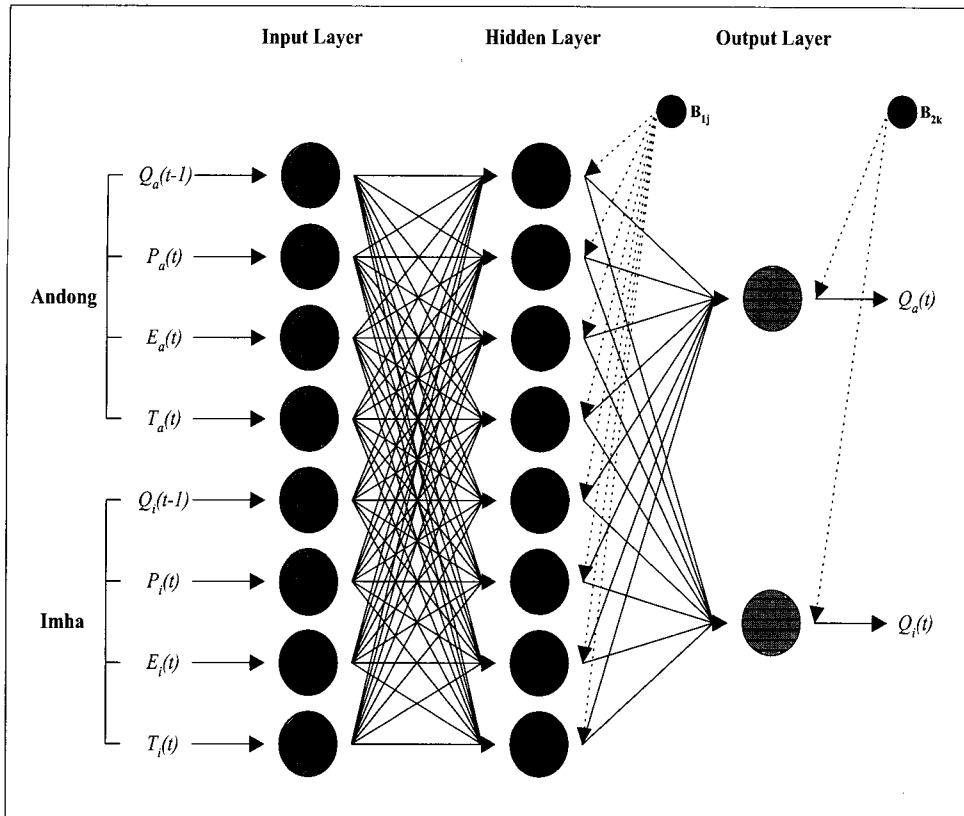


그림 2. 제시된 공간추계 신경망모형의 구조

2.2 Levenberg-Marquardt 역전파(LMBP) 알고리즘

LMBP 알고리즘은 비선형 함수의 오차제곱의 합을 최소화하도록 계획된 기법으로 뉴턴법의 변형법이며, 신경망의 훈련에 의해 오차의 수렴과정에 대한 지표(Index)가 평균제곱오차일 경우에 가장 적절한 기법으로 알려져 있다. 또한 LMBP 알고리즘은 연결강도를 제어할 경우 갱신규칙(Update Rule)을 사용한다. LMBP 알고리즘의 주요과정은 자코비안 행렬(Jacobian Matrix)을 계산하는 것이며, 자코비안 행렬을 계산하기 위해서는 최급하강 역전파 알고리즘의 변형형태를 이용해야 한다. 정상적인 역전파 훈련알고리즘에서는 신경망의 연결강도와 편차를 이용하여 제공오차의 미분값을 계산한다. 그러나 자코비안 행렬을 생성하기 위해서는 제공오차의 미분값 대신에 오차의 미분값을 계산하는 것이 필요하다. 일반적으로 LMBP 알고리즘의 진행과정은 다음과 같이 4가지의 단계로 구분된다(Hagen

and Menhaj, 1994; Kim and Lee, 2000).

① 모든 입력자료를 이용하여 대응하는 출력 값을 계산하고, 오차는 식 (2)와 같이 계산한다. 여기서 E_k 는 오차벡터, T_k 는 목표 출력벡터, O_k 는 모의 출력 벡터이다. 또한 입력자료에 대한 제공오차의 합을 식 (3)과 같이 계산한다. 여기서 $E_{j,k}$ 는 k번째 입력-목표 벡터에 대한 오차의 j번째 요소를 나타내고 있다.

$$E_k = T_k - O_k \quad (2)$$

$$E(x) = \sum_{k=1}^Q (T_k - O_k)^T (T_k - O_k) = \quad (3)$$

$$\sum_{k=1}^Q E_k^T E_k = \sum_{k=1}^Q \sum_{j=1}^M (E_{j,k})^2 = \sum_{i=1}^N (v_i)^2$$

② 자코비안 행렬을 계산한다. 그리고 초기화 후 순환관계(Recurrent Relationship)를 이용하여 민감도를 계산하며, Marquardt 민감도로 각각의 행렬을 증대시킨 후 자코비안 행렬의 요소를 계산한다.

③ 식 (4)를 이용하여 연결강도를 갱신한다. 여기서 J 는 각 연결강도에 대한 오차미분의 자코비안 행렬, μ_k 는 학습율이고 $v(W_k)$ 는 매개변수벡터에 해당된다.

$$\Delta W_k = -[J^T(W_k)J(W_k) + \mu_k I]^{-1} J^T(W_k)v(W_k) \quad (4)$$

④ $W_k + \Delta W_k$ 를 이용하여 제곱오차의 합을 재 계산한다. 만약 새로운 제곱오차의 합이 ①단계에서 계산한 값보다 작다면, μ 를 ν 로 나누고 $W_{k+1} = W_k + \Delta W_k$ 로 설정한 후에 ①단계로 되돌아간다. 만약 제곱오차의 합이 줄어들지 않으면, μ 에 ν 를 곱하고 ③단계로 되돌아간다.

2.3 BFGS 의사뉴턴(BFGS-QNBP)알고리즘

Shanno(1978)는 CGBP 알고리즘의 변형된 기법에 대한 연구를 통하여 광범위한 문제에 대하여 성능이 뛰어난 기법인 Broyden-Fletcher-Goldfarb-Shanno (BFGS) 의사뉴턴(Quasi Newton) 알고리즘을 제시하였다. BFGS-QNBP 알고리즘의 k+1회 반복에 대한 탐색방향은 다음 식 (5)와 같이 정의된다.

$$\bar{d}_{k+1} = -\bar{g}_{k+1} + A_{k+1}\bar{p}_{k+1} + B_{k+1}\bar{y}_{k+1} \quad (5)$$

여기서 \bar{g}_{k+1} 는 오차구배이고 $\bar{p}_{k+1} = W_{k+1} - W_k$ 으로 나타내며, 연속된 연결강도의 차이를 나타내고 있다. 또한 $\bar{y}_{k+1} = \bar{g}_{k+1} - \bar{g}_k$ 으로 나타내며, 연속된 오차구배의 차이로 나타낼 수 있다. 또한 A_{k+1} 과 B_{k+1} 는 다음 식 (6) 및 (7)과 같이 나타낼 수 있다.

$$A_{k+1} = -\left(1 + \frac{\bar{y}_{k+1} \cdot \bar{y}_{k+1}}{\bar{p}_{k+1} \cdot \bar{y}_{k+1}}\right) \frac{\bar{p}_{k+1} \cdot \bar{g}_{k+1}}{\bar{p}_{k+1} \cdot \bar{y}_{k+1}} + \frac{\bar{y}_{k+1} \cdot \bar{g}_{k+1}}{\bar{p}_{k+1} \cdot \bar{y}_{k+1}} \quad (6)$$

$$B_{k+1} = \frac{\bar{p}_{k+1} \cdot \bar{g}_{k+1}}{\bar{p}_{k+1} \cdot \bar{y}_{k+1}} \quad (7)$$

또한 모든 단계에서 탐색방향은 음의 구배방향에서 재시작 되어진다. 오차함수 $E(x)$ 를 최소화하기 위한 연속된 연결강도 벡터는 탐색방향을 따라서 1차원 최소화법을 이용하여 계산되어지며, 1차원 최소화법은 2차 보간법에 기초를 두고 있고 음의 구배치가 효율적으로

산정되어 질 수 있는 하나의 단계에서 역전과 방향으로 향하게 된다. BFGS-QNBP 알고리즘은 많은 종류의 테스트에 대해서 뛰어난 결과를 나타내었다(Battiti, 1989; Battiti and Masulli, 1990, Gill et al., 1981, 김성원, 2000b).

3. 유역개요 및 자료

3.1 유역현황

본 연구의 대상유역인 낙동강 상류유역의 안동다목적 댐은 유역면적이 낙동강 전체 유역의 1/15에 해당하는 1,584.0km²이고 우리나라 4대강 유역종합개발계획에 의거하여 유역 내에 최초로 건설된 다목적 댐으로서 1971년 4월 진입도로를 착수한 이래 5년 6개월 후인 1976년 10월 공사 준공하였으며, 1977년부터 정상운행을 개시하여 1970년대부터 고도산업화에 따라서 용수 수요가 급증하였던 대구, 부산 등 하류 도시 및 산업지역과 김해평야 등 농경지에 용수공급을 담당하고 있다. 또한 임하다목적 댐은 낙동강본류와 제 1지류인 반변천과의 합류지점으로부터 약 18km 상류의 반변천에 위치하고 있으며, 1984년 12월 착공하여 7년 6개월 만인 1992년 5월에 완공하였다. 유역면적은 안동다목적 댐의 유역면적보다는 15%정도가 작은 1,376.3km²이고 대부분 산악지구로 되어 있으며 하천구배도 비슷한 편이고, 안동다목적 댐과 더불어 하류의 용수공급을 담당하고 있다(건설교통부, 한국수자원공사, 1991, 1999).

3.2 자료의 수집

본 연구에 적용할 공간추계 신경망모형의 입력자료는 안동 및 임하다목적 댐의 선행시간의 월평균유입량, 월면적강우량, 월별 증발접시 증발량 및 월평균 기온자료로 구성되어 있다. 안동다목적 댐의 경우 월평균유입량(1977-2000), 월면적강우량(1977-1999), 안동관측소의 월별 증발접시 증발량(1983-1990) 및 월평균 기온자료(1983-2000)로 구성되어 있으며, 임하다목적 댐의 경우 월평균유입량(1993-2000), 월면적강우량(1993-1999), 영덕관측소의 월별 증발접시 증발량(1980-1990) 및 월평균 기온자료(1980-2001)로 구성되어 있다. 자료의 수집은 안동 및 임하다목적 댐의 월평균유입량은 한국건설기술연구원(KICT)의 수문자료를 이용하였으며, 안동다목적 댐의 월면적강우량은 영주, 부석, 안동, 석포, 길안, 미질, 재산 및 수비관측소의 일강우량을 이용하여 티센가중치에 의해 면적강우량을 산정하여 월별




그림 3. 공간추계 신경망모형의 입력자료 시계열

로 합산하였으며, 임하다목적 댐의 월면적강우량은 죽장, 안동, 길안, 현서, 미질, 재산 및 수비관측소의 일강우량을 이용하여 티센가중치에 의해 면적강우량을 산정하여 월별로 합산하였다. 그리고 월별 증발접시 증발량은 안동관측소의 경우 폐쇄 및 이전 그리고 결측에 의하여 신뢰성 있는 시계열은 1983년부터 1990년까지로 선정하였고, 영덕관측소는 신뢰성있는 시계열을 1980년부터 1990년까지로 선정하여 기상년보의 자료를 이용하였다. 또한 안동 및 영덕관측소의 월평균 기온자료는 기상청 홈페이지(www.kma.go.kr)의 무료 공개자료와 기상년보의 자료를 이용하였다(기상청, 1983-1990). 다음 그림 3은 본 연구에 사용된 각 자료의 시계열을 나타낸 것이다.

3.3 기상자료의 확충

본 연구의 공간추계 신경망모형의 훈련은 모의발생시킨 자료를 이용하고 검증은 실제 관측치를 이용하고자 한다. 그러나 그림 3과 같이 자료의 동일 시계열을 고려할 경우 기상자료인 안동 및 영덕관측소의 월별 증발접시 증발량자료는 1991년부터는 증발접시의 폐쇄로 인하여 관측자료가 없는 실정이다. 따라서 월별 증발접시 증발량자료의 확충을 위하여 공간추계 신경망모형의 입력자료중 월별 증발접시 증발량자료와 상관성이 높은 자료는 기상자료인 월평균 기온자료이고 상대적으로 수문자료인 선행시간의 월평균유입량과 월평균강우량은 상관성이 낮은 실정이다. 따라서 본 연구에서는 월평균 기온을 독립변수, 월별 증발접시 증발량을 종속변수로 선정한 이변량 회귀분석모형(Bivariate Regression

Analysis Model, BRAM)을 이용하여 월별 증발접시 증발량자료를 확충하였으며, 이변량 회귀분석모형은 선형함수(Linear Function)을 적용하였다. 일반적으로 이변량 회귀분석모형은 다음 식 (8)과 같이 나타낼 수 있다.

$$\hat{Y} = b_0 + b_1 X \quad (8)$$

여기서 b_1 은 경사계수이고, 회귀분석 결과로 산정된 값이므로 회귀계수라고도 한다. 또한 안동 및 영덕관측소의 1983년부터 1990년까지와 1980년부터 1990년까지의 월별 증발접시 증발량자료와 월평균 기온자료를 이용하여 이변량 회귀분석모형의 매개변수를 산정하였으며, 산정된 매개변수를 이용하여 안동관측소는 1991년부터 2000년, 영덕관측소는 1991년부터 2001년까지의 월별 증발접시 증발량자료를 확충하였다. 다음 표 1은 안동 및 영덕관측소에서 2변량 회귀분석모형, 통계분석과 분산분석(Analysis of Variance)을 나타내었으며, 안동관측소의 분석결과가 영덕관측소의 분석결과보다 양호한 것으로 나타났다. 그러나 영덕관측소의 분산분석의 경우 $b_1 = 0$ 의 귀무가설이 채택(Accept)되어 이를 사용하기에는 무리가 따를 것으로 통계적으로 판단되나 기상자료의 분산분석 결과치 산정이 연구의 주요관점이 아니고 또한 통계분석의 결과치가 양호하기 때문에 영덕관측소 회귀모형을 이용하여 월별 증발접시 증발량자료를 확충하였다.

표 1. 증발집시 증발량 회귀분석(안동 및 영덕관측소)

Station	Type	BRAM	Statistical Analysis			Analysis of Variance		
			S(e)(mm)	S(e)/S(y)	CC	Computed F	Critical F	Null Hypothesis
Andong	Linear	$E_t = 4.210 T_t + 64.54$	29.70	0.586	0.813	182.93	94.00	Reject that $b_1=0$
Yeongdeok	Linear	$E_t = 2.979 T_t + 68.73$	26.23	0.719	0.742	123.54	130.00	Accept that $b_1=0$

표 2. 수문자료의 분석(안동 및 임하다목적 댐)

Statistics	Data	Streamflow(cms)		Precipitation(mm)	
		Andong	Imha	Andong	Imha
Mean		370.29	211.88	1,104.17	988.00
S.D.		123.41	163.60	257.51	265.51
S.C.		0.17	0.26	0.19	-0.10
C.V		0.33	0.77	0.23	0.27
Max.		586.30	433.90	1,567.30	1,280.40
Min.		180.50	28.40	716.40	626.20
Cor.Coeff.	Lag-1	0.0367	0.1967	0.2423	0.2701
	Lag-2	-0.1091	-0.2305	-0.0869	-0.1307




그림 4. 계열상관도(연평균유입량)

3.4 수문자료의 분석

본 연구의 공간추계 신경망모형의 입력자료는 월평균유입량, 월면적강우량, 월별 증발집시 증발량과 월평균 기온자료로 구성되어 있지만 실제 수문분석은 월평균

유입량과 월면적강우량이 주요자료이다. 따라서 월별 자료를 연 단위로 합산한 연평균유입량과 연면적강우량에 대한 분석결과는 다음 표 2와 같으며, 계열상관도(Correlogram)는 그림 4 및 5와 같다.




그림 5. 계열상관도(연면적강우량)

4. 공간추계 신경망모형의 훈련

생하였으며, 제시된 PARMA(1,1)모형은 다음 식 (9)와 같이 나타낼 수 있다.

4.1 훈련자료의 모의발생

본 연구의 공간추계 신경망모형의 훈련자료는 부족한 자료 시계열을 모의발생시킨 자료를 이용하였다. 따라서 부족한 자료시계열은 추계학적 모형의 일종인 PARMA(1,1)모형에 의하여 월평균유입량, 월면적강우량, 월별 증발점시 증발량과 월평균 기온자료를 모의발

$$y_{\nu, \tau} = \mu_{\tau} + \varphi_{1, \tau}(y_{\nu, \tau-1} - \mu_{\tau-1}) + \varepsilon_{\nu, \tau} - \theta_{1, \tau} \varepsilon_{\nu, \tau-1} \quad (9)$$

여기서 ν 는 년(Year), τ 는 계절(Season)이고 $\tau = 1, 2, \dots, \omega$ 이며 계절의 수를 나타내고 있다. 일

표 3. PARMA(1,1)모형의 월평균유입량 매개변수 산정(안동 및 임하다목적 댐)

Data Month	Streamflow(cms)			
	Andong		Imha	
	Phi-1	Theta-1	Phi-1	Theta-1
1	0.286	0.231	-0.414	-1.728
2	8.657	6.913	1.310	-0.858
3	0.783	0.641	0.513	0.097
4	0.426	0.398	3.232	1.896
5	-0.157	-0.311	1.041	1.792
6	2.710	2.623	0.228	-0.052
7	-0.694	-0.947	6.068	2.110
8	-0.391	-0.680	1.720	-0.680
9	-1.116	-1.277	0.010	0.362
10	0.083	0.040	2.251	0.201
11	0.302	0.330	0.074	0.074
12	-1.451	-1.742	0.353	0.705

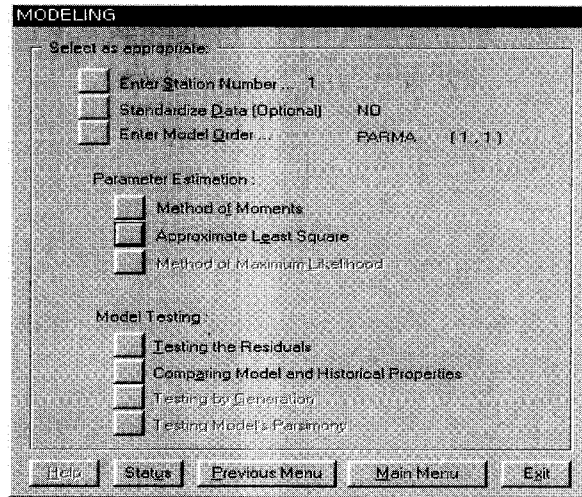


그림 6. 월평균유입량의 매개변수 선정과정

반적으로 PARMA (1,1)모형은 월유출량을 모의하는데 사용된다(Salas et al., 1980). 본 연구의 PARMA (1,1)모형은 SAMS(Salas J. D., 1998) Package를 이용하였고, 계절의 수는 12계절로 하였다. 그리고 모의 발생한 표본(Sample)은 2개의 표본이며, 각 표본마다 100년씩의 월평균유입량, 월면적강우량, 월별 증발접시 증발량과 월평균 기온자료를 모의발생하였다. 모의된 자료중 첫 번째 표본자료에서 초기에 발생하는 편차를 제거하기 위하여, 후반부 50년간의 자료만을 이용하여 공간추계 신경망모형의 훈련자료로 사용하였다. 다음 표 3은 PARMA(1,1)모형에 의해 선정된 안동 및 임하다목적 댐의 월평균유입량의 매개변수값이고, 근사최소자승법(Method of Approximate Least Square)에 의해 선정하였으며, 그림 6은 SAMS Package를 이용하여 안동다목적 댐의 월평균유입량의 매개변수 선정과정을 나타낸 것이다.

4.2 최적 매개변수 선정을 위한 훈련

공간추계 신경망모형의 훈련과정은 최적연결강도와 편차를 결정하기 위하여 오차를 최소화하는 반복되는 과정이다. 본 연구에서는 안동 및 임하다목적 댐의 실측자료를 이용하여 모의발생시킨 자료를 훈련자료로 사용하였으며, 선정된 훈련임계치(Training Tolerance)의 허용한계는 0.001로 설정하였다. 따라서 공간추계 신경망모형의 훈련은 오차가 훈련임계치와 같거나 감소하기 시작할 때까지 반복하였다. 입력층의 연결강도와 편차의 초기치는 난수로 -1에서 1 사이의 값을 발생시

켰으며, 공간추계 신경망모형의 각 층에 대한 초기치는 Nguyen and Widrow(1990)방법을 이용하였다. 따라서 신경망모형의 훈련은 입력층의 연결강도와 편차의 초기치가 난수로 발생되기 때문에 훈련 결과치가 조금씩의 차이가 있으므로, 모의발생된 월평균유입량 값의 최적치를 산정하기 위하여 하나의 훈련자료에 대해 10회의 훈련을 시행착오법으로 반복하여 최적의 결과치를 산정하였다. 훈련은 Intel Pentium III-933MHz CPU를 가진 PC를 이용하였으며, LMBP 공간추계 신경망모형은 26회의 반복횟수가 필요한 것으로 나타났으며 BFGS-QNBP 공간추계 신경망모형은 939회의 반복횟수가 필요한 것으로 나타났다. 또한 공간추계 신경망모형의 훈련결과는 모의발생시킨 월평균유입량과 공간추계 신경망모형에 의해 선정된 월평균유입량의 통계분석에 의해 평가되었다. 통계분석 결과는 LMBP 및 BFGS-QNBP 공간추계 신경망모형이 모두 양호한 결과를 나타내었으나, 반복횟수와 훈련시간을 기준으로 평가할 때 LMBP 공간추계 신경망모형이 다소 우수한 모형으로 판단되었다. 또한 안동 및 임하다목적 댐의 월평균유입량을 비교할 경우 안동다목적 댐의 훈련결과가 임하다목적 댐보다 양호한 것으로 나타났다. 다음 표 4는 공간추계 신경망모형 훈련결과의 통계분석을 나타내었고, 표 5는 LMBP 공간추계 신경망모형의 입력층과 은닉층 및 은닉층과 출력층 사이의 최적연결강도와 편차를 나타내었다. 또한 그림 7은 LMBP 및 BFGS-QNBP 공간추계 신경망모형의 훈련에 있어서 반복횟수에 따른 평균제곱오차의 수렴과정을 나타낸 것

표 4. 공간추계 신경망모형 훈련결과의 통계분석

Data	Reservoir	Algorithm	Training Time(sec)	Iteration Number	Network Configuration	Statistical Analysis			
						m(e)(cms)	s(e)(cms)	s(e)/s(y)	CC
Training	Andong	LMBP	3	26	8-8-2	0.128	8.560	0.222	0.98
		BFGS-QNBP	45	939	8-8-2	0.369	8.796	0.229	0.98
	Imha	LMBP	3	26	8-8-2	-0.021	12.999	0.322	0.96
		BFGS-QNBP	45	939	8-8-2	0.237	12.745	0.315	0.96

표 5. LMBP 공간추계 신경망모형의 최적연결강도와 편차

Hidden Layer		Input Variables and Weights								Output Layer	
		Q _a (t-1)	P _a (t)	E _a (t)	T _a (t)	Q _i (t-1)	P _i (t)	E _i (t)	T _i (t)		
Node j	Bias B _{1j}	W _{j1}	W _{j2}	W _{j3}	W _{j4}	W _{j5}	W _{j6}	W _{j7}	W _{j8}	W _{1j}	W _{2j}
1	-15.318	-0.411	-4.253	7.516	16.347	-3.683	-0.684	1.893	-1.916	0.091	-1.572
2	-5.122	1.510	0.771	1.307	3.331	0.190	-1.479	-0.329	0.719	1.867	3.998
3	5.277	-0.865	1.337	-1.719	-3.149	-0.549	0.998	0.725	-1.023	3.742	0.529
4	7.455	-4.433	-6.843	4.369	-0.338	-2.533	5.184	5.378	-10.287	-0.204	1.090
5	4.724	1.529	-13.631	2.688	0.564	0.083	-0.933	-8.964	-0.827	-0.108	0.023
6	4.325	3.389	-19.652	-2.895	11.587	-3.286	11.508	5.189	0.575	-0.402	-1.872
7	-7.872	-6.827	-6.962	8.110	-2.299	-2.899	2.903	4.606	4.414	-0.044	0.979
8	1.297	4.081	9.460	-1.824	-3.324	4.849	-0.162	-5.664	-3.636	-0.038	0.447
Bias B ₂₁										-2.715	
Bias B ₂₂										0.085	

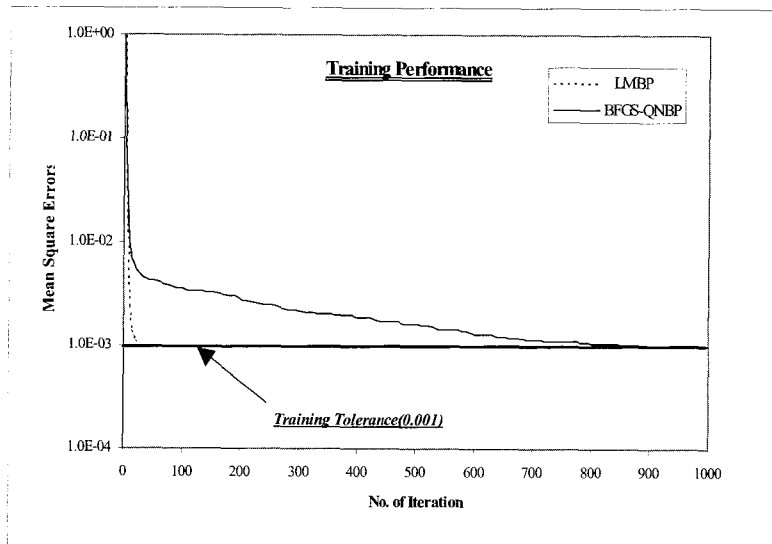


그림 7. 평균제곱오차의 수렴과정

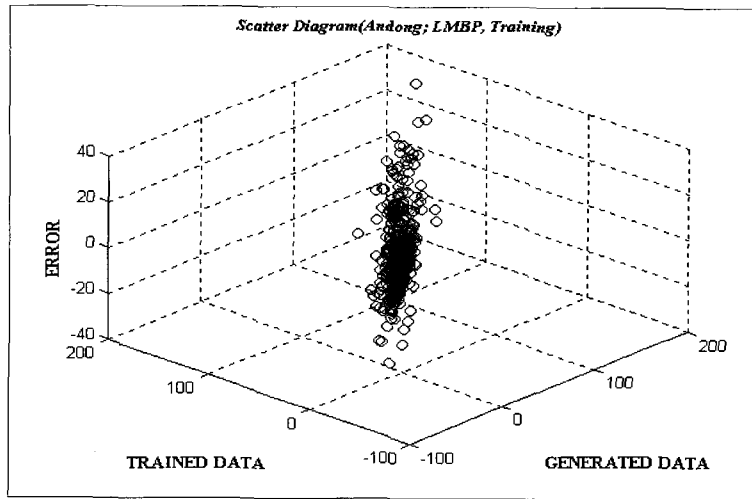


그림 8. 3차원 오차분산도(안동다목적 댐; LMBP, 훈련)

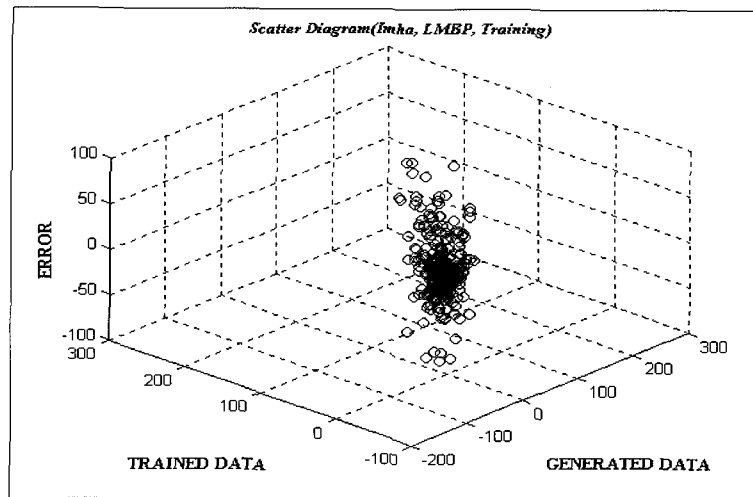


그림 9. 3차원 오차분산도(임하다목적 댐; LMBP, 훈련)

이고, 그림 8과 9는 LMBP 공간추계 신경망모형 훈련 결과의 오차분산도를 3차원으로 나타내었다.

5. 공간추계 신경망모형의 검증

5.1 최적매개변수에 의한 공간추계 신경망모형의 검증

전절 4.2에서 LMBP 및 BFGS-QNBP 공간추계 신경망모형의 훈련에 대한 통계분석 결과는 우수한 것으로 나타났으나, 훈련시간과 반복횟수에 있어서 LMBP 공간추계 신경망모형이 BFGS-QNBP 공간추계 신경망

모형에 비교해서 다소 우수한 것으로 나타났다. 그러나 공간추계 신경망모형의 검증을 위해서는 LMBP 및 BFGS-QNBP 공간추계 신경망모형의 훈련에 의해 선정된 최적연결강도와 편차를 전부 사용하였다. 공간추계 신경망모형의 검증에 사용된 자료는 안동 및 임하다 목적 댐의 실측자료인 월평균유입량, 월면적강우량, 월별 증발접시 증발량 및 월평균 기온자료를 사용하였으나, 시계열이 동일한 자료군을 구성하기 위하여 1993년부터 1999년까지의 자료를 이용하였다. 전절 3.3과 같이 월별 증발접시 증발량자료는 실측치가 아닌 이변량

표 6. 공간추계 신경망모형 검증결과의 통계분석

Data	Reservoir	Algorithm	Network Configuration	Statistical Analysis			
				m(e)(cms)	s(e)(cms)	s(e)/s(y)	CC
Validation	Andong	LMBP	8-8-2	6.835	15.129	0.333	0.86
		BFGS-QNBP	8-8-2	15.608	22.416	0.494	0.85
	Imha	LMBP	8-8-2	9.320	22.378	0.627	0.81
		BFGS-QNBP	8-8-2	12.855	32.984	0.923	0.80




그림 10. 월평균유입량 수문곡선의 비교(안동다목적 댐, 검증)




그림 11. 월평균유입량 수문곡선의 비교(임하다목적 댐, 검증)

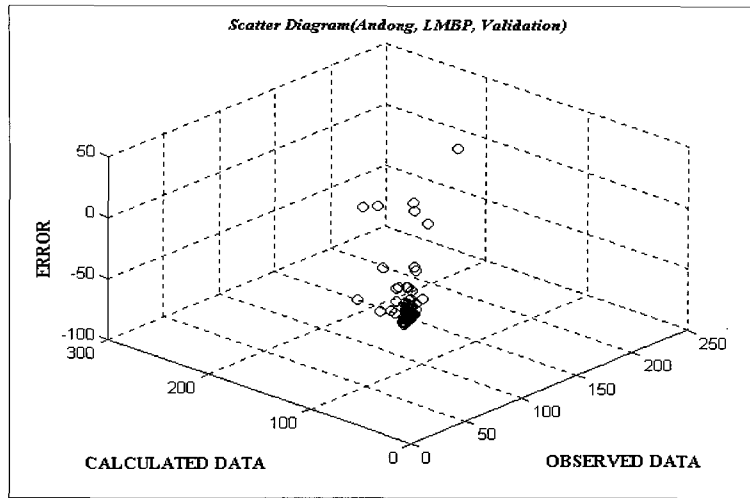


그림 12. 3차원 오차분산도(안동다목적 댐; LMBP, 검증)

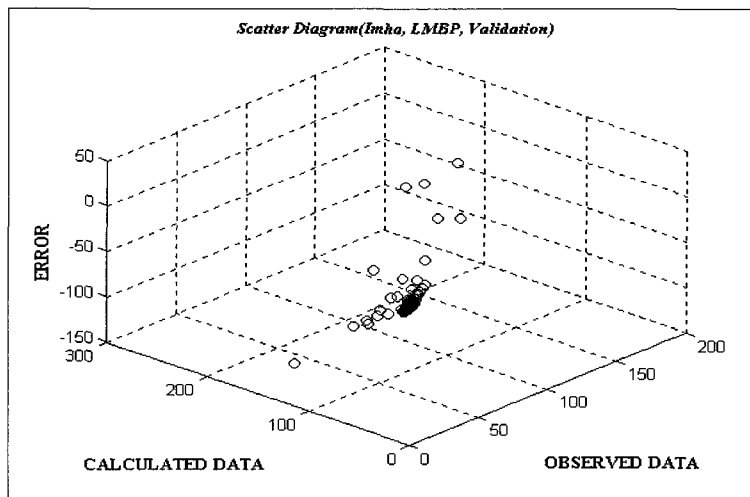


그림 13. 3차원 오차분산도(임하다목적 댐; LMBP, 검증)

회귀분석모형을 이용하여 확충된 자료를 이용하였다. 다음 표 6은 공간추계 신경망모형의 검증결과이다. 표 6에 의하면 공간추계 신경망모형에 의해 안동다목적 댐의 월평균유입량의 검증결과가 임하다목적 댐보다 다소 양호한 것으로 분석되었다. 그 이유는 공간추계 신경망모형의 훈련자료를 모의발생시킬 때 안동다목적 댐의 월평균 유입량자료가 임하다목적 댐과 비교하면 장기간의 신뢰성 있는 자료이므로 그에 따른 모의발생된 자료의 통계학적 특성도 원자료를 신뢰성있게 반영하는 것으로 사료된다. 또한 공간추계 신경망모형의 훈련결과처럼 LMBP 공간추계 신경망모형의 매개변수에 의해 산정된 월평균유입량이 BFGS-QNBP 공간추계 신경

망모형의 매개변수에 의해 산정된 월평균유입량보다 양호한 결과를 나타내고 있다. 그림 10과 11은 LMBP 및 BFGS-QNBP 공간추계 신경망모형의 검증에 의해 산정된 월평균유입량을 실측 월평균유입량 수문곡선과 비교하였으며, 그림 12와 13은 LMBP 공간추계 신경망모형 검증결과에의 오차분산도를 3차원으로 나타내었다.

6. 결론 및 토의

본 연구에서는 낙동강유역의 상류에 위치하고 있는 병렬 저수지군인 안동 및 임하다목적 댐의 장기간 유입량을 산정하기 위하여 부족한 훈련자료의 시계열은 추계학적 모형에 의해 모의발생시키는 기법을 이용하였으

며, 기존의 신경망모형을 변형한 공간추계 신경망모형을 제시하였다. 적용된 역전파 알고리즘은 LMBP 및 BFGS-QNBP 알고리즘을 적용하였으며, 공간추계 신경망모형의 각 층의 노드 수는 8-8-2개로 구성되어 있다. 공간추계 신경망모형의 훈련은 최적연결강도와 편차를 산정하는 과정이고, PARMA(1,1)모형에 의해서 훈련자료를 모의발생시켰다. 훈련결과 LMBP 공간추계 신경망모형은 26회의 반복횟수가 필요한 것으로 나타났으며, BFGS-QNBP 공간추계 신경망모형은 939회의 반복횟수가 필요한 것으로 나타났다. 또한 산정된 매개변수를 이용하여 실측자료로서 공간추계 신경망모형을 검증하였으며, 통계분석과 월평균유입량 수문곡선의 비교분석을 통하여 공간추계 신경망모형은 우수한 모형으로 판단된다. 따라서 공간추계 신경망모형은 병렬 저수지군의 새로운 형태의 장기간 연계운영기법 개발을 위한 기초자료를 제공할 수 있을 것으로 판단되며, 저수지 운영 및 운영체제와 연계하여 지속적인 연구가 필요하리라 사료된다.

참 고 문 헌

건설교통부, 한국수자원공사(1991). **영천댐 도수로 도수에 따른 안동댐 및 입하댐 연계운영방안 보고서**.

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

기상청(1983-1990). **기상년보**.

김성원(2000a). “다층신경망모형에 의한 일 유출량의 예측에 관한 연구.” **한국수자원학회 논문집**, 한국수자원학회, 제 33권, 제 5호, pp. 537-550.

김성원(2000b). “하천유역에서 홍수유출량의 예측을 위한 신경망기법의 적용.” **대한토목학회 논문집**, 대한토목학회, 제 20권, 제 6-B호, pp. 801-811.

김성원, 이순탁, 조정석(2001). “중소하천유역에서 Hybrid Neural Networks에 의한 수문학적 예측.” **한국수자원학회논문집**, 한국수자원학회, 제 34권, 제 4호, pp. 303-316.

김성원, 조정석(2002b). “SSNNM에 의한 다목적 댐군의 월평균유입량 산정.” **2002년 대한토목학회 학술발표회논문집**, 대한토목학회, pp. 155-158.

김성원, 조정석, 정재용(2002a). “추계학적 신경망모형에 의한 다목적댐의 유입량산정.” **2002년 한국수자원학회 학술발표회 논문집**, 한국수자원학회, pp. 98-103.

신현석, 박무중(1999). “신경망을 이용한 우리나라의 시공간적 가뭄의 해석.” **한국수자원학회 논문집**, 한국수자원학회, 제 32권, 제 1호, pp. 15-29.

Battiti, R. (1989). “Accelerated back-propagation learning : two optimization methods.” *Complex System*, Vol. 3, pp. 331-342.

Battiti, R., and Masulli, F. (1990). “BFGS optimization for faster and automated supervised learning.” *Proc of Int. Neural Network Conf. (INNC 90)*, Paris, France, pp. 757-760.

Coulibaly, P., Anctil, F., and Bobée, B.(2000a). “Daily reservoir inflow forecasting using artificial neural networks with stopped training approach.” *J. Hydro*, Vol. 230, pp. 244-257.

Coulibaly, P., Anctil, F., and Bobée, B.(2000b). “Neural network-based long-term hydropower forecasting system.” *J.Comp. Aided Civ. and Infrastruct. Engrg.*, Vol. 15, No. 5, pp. 355-364.

Demuth, H., and Beale, M.(2000). *Neural network toolbox : for use with MATLAB user's guide*, The Math Works Inc.

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

Gill, P.E., Murray, W., and Wright, M.H. (1981). *Practical Optimization*, Academic Press, NY.

Hagen, M.T., and Menhaj, M.(1994). “Training feed-forward networks with the Marquardt algorithm.” *IEEE Transactions on Neural Networks*, Vol. 5, No. 6, pp. 25-32.

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

Jain, S.K., Das, D., and Srivastava, D.K.(1999). “Application of ANN for reservoir inflow prediction and operation.” *J. Water Resour. Plng. and Mgmt.*, ASCE, Vol. 125, No. 5, pp. 263-271.

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.

Nguyen, D.H. and Widrow, B.(1990). “Neural

- network for self-learning control systems." *IEEE Control Systems Magazine*, pp. 18-23.
- Salas, J.D.(1998) *SAMS ; Stochastic Analysis, Modeling, and Simulation user manual*, Colorado State University, Fort Collins, CO.
- Salas, J.D., Delleur, J.R., Yevjevich, V., and Lane, W.L.(1980). *Applied Modeling of Hydrologic Time Series, Water Resources Publications*, Littleton, CO.
- Shanno, D.F.(1978). "Conjugate gradient methods with inexact searches." *Mathematics of Operations Research*, Vol. 3, No. 3, pp. 244-256.
- 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.
- Thirumalaiah, K., and Deo, M.C.(2000). "Hydrological forecasting using neural networks." *J. of Hydro. Eng.*, ASCE, Vol. 5, No. 2, pp. 180-189.
- Tokar, A.S., and Johnson, P.A.(1999). "Rainfall-runoff modeling using artificial neural networks." *J. Hydrologic Engrg.*, ASCE, Vol. 4, No. 3, pp. 232-239.
- Zealand, C.M., Bum, D.H., and Simonovic, S.P.(1999). "Short term streamflow forecasting using artificial neural networks." *J. Hydro.*, Vol. 214, pp. 32-48.

(논문번호:02-79/접수:2002.09.23/심사완료:2003.02.21)