

## 중소하천유역에서 Hybrid Neural Networks에 의한 수문학적 예측

### Hydrological Forecasting Based on Hybrid Neural Networks in a Small Watershed

김 성 원\* / 이 순 탁\*\* / 조 정 석\*\*\*

Kim, Sungwon / Lee, Soontak / Cho, Jeong-Seok

#### Abstract

In this study, Radial Basis Function(RBF) Neural Networks Model, a kind of Hybrid Neural Networks, was applied to hydrological forecasting in a small watershed. RBF Neural Networks Model has four kinds of parameters in it and consists of unsupervised and supervised training patterns. And, Gaussian Kernel Function(GKF) was used among many kinds of Radial Basis Functions(RBFs). K-Means clustering algorithm was applied to optimize centers and widths which are the parameters of GKF. The parameters of RBF Neural Networks Model such as centers, widths, weights, and biases were determined by the training procedures of RBF Neural Networks Model. And, with these parameters, the validation procedures of RBF Neural Networks Model were carried out. RBF Neural Networks Model was applied to Wi-Stream basin which is one of the IHP Representative basins in South Korea. 10 rainfall events were selected for training and validation of RBF Neural Networks Model. The results of RBF Neural Networks Model were compared with those of Elman Neural Networks(ENN) Model. ENN Model is composed of One Step Secant BackPropagation(OSSBP) and Resilient BackPropagation(RBP) algorithms. RBF Neural Networks Model shows better results than ENN Model. RBF Neural Networks Model spent less time for the training of model and can be easily used by the hydrologists with little background knowledge of RBF Neural Networks Model.

*keywords* : Radial Basis Function, K-Means clustering algorithm, Gaussian Kernel Function, Centers, Widths, Hydrological Forecasting

#### 요 지

본 연구에서는 중소하천수계에서 수문학적 예측을 위하여 Hybrid Neural Networks의 일종인 반경기초함수(RBF) 신경망모형이 적용되었다. RBF 신경망모형은 4종류의 매개변수로 구성되어 있으며, 자율 및 지도훈련과정으로 이루어져 있다. 반경기초함수로서 가우스핵함수(GKF)가 이용되었으며, GKF의 매개변수인 중심과 폭은 K-Means 군집알고리즘에 의해 최적화 된다. 그리고 RBF 신경망모형의 매개변수인 중심, 폭, 연결강도와 편차벡터는 훈련을 통하여 최적 매개변수의 값이 결정되며, 이 매개변수들을 이용하여 모형의 검증과정이 이루어진다. RBF 신경망모형은 한국의 IHP 대표 유역중 하나인 위천유역에 적용하였으며, 모형의 훈련과 검증을 위하여 10개의 강우사상을 선택하였다. 또한 RBF 신경망모형과 비교검토하기 위하여 엘만 신경망(ENN)모형을 이용하였으며, ENN 모형은 일단계 활선역전과(OSSBP) 및 탄성역전과(RBP)알고리즘으로 이루어져 있다. 모형의 훈련과 검증과정을 통하여 RBF 신경망모형이 ENN 모형보다 양호한 결과를 나타내는 것으로 분석되었다. RBF 신경망모형은 훈련시키는데 시간이 적게 들고, 이론적 배경이 부족한 수문학자들도 쉽게 사용할 수 있는 신경망모형이다.

**핵심용어** : 반경기초함수, K-Means 군집알고리즘, 가우스핵함수, 중심, 폭, 수문학적 예측

\* 동양대학교 토목환경공학과 전임강사

Full time lecturer, Dept. of Civil and Environmental Engr., Dongyang University, Yeungju, Kyungbuk, 750-712, Korea (E-mail : swkim68@phenix.dyu.ac.kr)

\*\* 영남대학교 토목도시환경공학부 교수

Professor, School of Civil, Urban and Environmental Engr., Yeungnam University, Kyungsan, Kyungbuk, 712-749, Korea (E-mail : leest@yucc.yeungnam.ac.kr)

\*\*\* 대구대학교 건설환경공학부 교수

Professor, School of Civil, Architectural and Environmental Engr., Taegu University, Kyungsan, Kyungbuk, 712-714, Korea (E-mail : jscho@taegu.ac.kr)

## 1. 서 론

과학과 공학의 여러 분야에 있어서 예측모형의 개발을 위하여 신경망(Neural Networks)이 최근에 와서 많이 사용되어 지고 있다. 전통적인 모형화기법보다 신경망에 의한 접근법의 주요장점은 수학적 표현의 진행과정에 있어서 복잡한 특성을 요구하지 않는다는 점이다. 수문학과 수자원에 있어서 신경망의 적용은 Daniell(1991)에 의해 처음 제시되었다. 그 이후에 여러 종류의 실제 혹은 가징된 상황을 고려하여 유출예측에 많이 이용되어 왔다. 신경망모형에 의한 유출예측에 관한 연구로는 개념적모형으로부터 생성된 자료에 대한 유출모의(Liong and Chan, 1993; Minns and Hall, 1996), 단기간 유출모의 및 예측(Isobe et al., 1994), 장기간 유출예측(Smith and Eli, 1995; Raman and Sunilkumar, 1995)등이 있다.

신경망이론을 이용한 응용기법은 주로 역전파훈련 알고리즘을 이용한 다층 퍼셉트론(MultiLayer Perceptron, MLP)형태의 기법이며, 역전파훈련 알고리즘은 근본적으로 주어진 문제에 대하여 비최적화 해법을 나타내는 구배하강법이다. 그와는 반대로 은닉층 노드의 전이함수에 비선형성을 가진 반경기초함수(Radial Basis Function, RBF)는 매개변수들의 최적화과정을 선형탐색법으로 수행한다. RBF를 이용한 연구로는 실제자료에 의한 유출예측(Fernando and Jayawardena, 1998) 및 모의된 상태에 대한 유출예측(Mason et al., 1996)이 있으나, 아직까지 Hybrid Neural Networks기법의 일종인 RBF를 응용한 연구 성과는 많지 않은 실정이다. 또한 MLP에서는 일반적으로 주어진 문제에 대하여 최적네트워크의 크기를 모르는 실정이며, 수문학적 연구에 사용된 MLP는 보통 시행착오법에 의해서 네트워크의 크기 및 구조를 결정한다.

따라서 본 연구에서는 국제수문개발계획(IHP)의 대표유역인 낙동강 위천유역에서 수문학적 예측을 위하여 RBF를 이용한 강우-유출모형을 제시하였으며, 제시된 RBF 신경망모형의 훈련 및 검증과정을 통하여 모형의 적합성을 검토하였다. 또한 RBF 신경망모형과 비교검토를 위한 신경망모형으로 기존의 MLP형태의 전방향 역전파(Feed-Forward BackPropagation, FFBP)신경망모형을 수정한 엘만신경망(Elman Neural Networks, ENN)모형을 이용하였으며, ENN 모형은 일단계 할선역전파(One Step Secant

BackPropagation, OSSBP) 및 탄성 역전파(Resilient BackPropagation, RBP) 알고리즘으로 구성되어 있다.

## 2. 적용모형

### 2.1 반경기초함수(Radial Basis Function, RBF) 신경망모형의 개요

RBF 신경망모형은 항상 3개의 층인 입력층, 은닉층 및 출력층으로 구성되어 있으며, 전방향 네트워크를 형성하고 있다(Hush and Horne, 1993; Moody and Darken, 1989; Poggio and Girosi, 1990; Wasserman, 1993). RBF 신경망모형의 훈련과정은 MLP 신경망모형에 사용된 훈련과정과 근본적으로 다르다. RBF 신경망모형은 이원화된 단계로 구성되어 있으며, 첫 번째 단계에서는 RBF 신경망모형의 은닉층의 매개변수인 중심(Centers)과 폭(Widths)을 자율 훈련(Unsupervised training)을 이용하여 결정하고, 두 번째 단계에서는 첫 번째 단계에서 결정된 RBF 신경망모형의 출력값에 대하여 평균제곱오차(Mean Square Error, MSE)의 최소화과정에 기초를 둔 지도 훈련(Supervised training)을 통하여 은닉층과 출력층의 연결강도와 편차벡터를 결정한다. 첫 번째 단계에서 중심의 위치를 결정하기 위하여 본 연구에서는 군집(Clustering)알고리즘의 하나인 K-Means 군집 알고리즘을 이용하였다. RBF 신경망모형의 은닉층에서 사용되어질 수 있는 군집알고리즘은 많지만 K-Means 군집알고리즘이 많이 사용된다. 이 알고리즘은 단순성과 양호한 결과를 나타내기 때문에 가장 광범위하게 알려진 군집알고리즘이며, 군집화과정(Clustering process)은 각 은닉층에 대한 중심의 위치가 안정되었을 때 종료된다. 표 1은 본 연구에 적용된 K-Means 군집알고리즘의 연산과정을 나타내고 있다(Duda and Hart, 1973; Jain and Dubes, 1988; Tou and Gonzalez, 1974).

RBF 신경망모형의 매개변수중 하나인 폭은 각 노드와 관계된 자료의 분포정도(Spread)를 나타내고 있으며, 다양한 방법으로 결정되어 질 수 있다. 그러나 보편적인 방법은 입력층노드와 중심사이의 평균거리를 동일하게 구성하는 방법이며, 다음 식(1)과 같이 나타낼 수 있다.

표 1. K-Means 군집알고리즘의 연산과정

```

procedure K-Means
  Initialize the cluster centers  $u_{ji}$ ,  $i=1,2,\dots,m$  ;
  /* typically these are set equal to the input layer samples */
  repeat
    /* Group all patterns with the closest cluster center */
    for all  $x_i$  do
      Assign  $x_i$  to  $\theta_{ji^*}$ , where  $u_{ji^*} = \min \|x_i - u_{ji}\|$  ;
    endloop
    /* Compute the sample means. */
    for all  $u_{ji}$  do
      
$$u_{ji} = \frac{1}{m} \sum_{i=1}^m x_i$$
 ;
    endloop
  until there is no change in cluster assignments from one iteration to the next ; end ; { K-Means }
  
```

$$\sigma_{ji}^2 = \frac{1}{M} \sum_{i=1}^m (x_i - u_{ji})^2, \quad x_i \in \theta_{ji} \quad (1)$$

여기서  $\sigma_{ji}$ 는 RBF의 폭,  $u_{ji}$ 는 RBF의 중심,  $x_i$ 는 입력벡터요소이다. 또한  $M$ 은 입력층노드의 수를 나타내고 있고,  $\theta_{ji}$ 는 중심인  $u_{ji}$ 와 함께 분류된 훈련패턴이며, 아랫첨자  $i, j$ 는 입력층과 은닉층을 나타내고 있다.

두 번째 단계에서 훈련을 시작하기 전에 이미 연결강도와 편차벡터의 값은 Nguyen-Widrow(1990)방법에 의해 초기화되며, 입력층과 은닉층사이의 RBF 매개변수인 중심과 폭은 첫 번째 단계에서 더 이상의 변화가 일어나지 않는 일정한 값으로 고정된다. 따라서 두 번째 단계에서 RBF 신경망모형은 출력벡터(Output vector)와 목표벡터(Target vector)의 값을 비교하여 출력벡터와 목표벡터사이의 오차를 최소화하는 방향으로 연결강도와 편차벡터를 갱신하며, 오차가 수렴한계인 평균제곱오차(Mean Square Error, MSE)의 값보다 작아질 때까지 이 과정을 반복한다(Tsoukalas and Uhrig, 1997).

## 2.2 반경기초함수(Radial Basis Function, RBF) 신경망모형의 구성

RBF 신경망모형의 입력층과 은닉층사이의 연결함수는 입력벡터요소  $x_i$ 에서 중심(Centers)인  $u_{ji}$ 를 제한 값의 제곱에 대한 평방함수로 나타내고 있으며,

다음 식(2)와 같이 나타낼 수 있다.

$$R_j = \sqrt{\left(\sum_{i=1}^m (x_i - u_{ji})^2\right)} \quad (2)$$

여기서 아랫첨자  $i, j$ 는 입력층과 은닉층을 나타내고 있으며,  $R_j$ 는 입력벡터들 사이의 반경거리(Radial distance)를 나타낸다. 따라서 입력벡터를  $X = [x_1, x_2, \dots, x_m]^T$ 라 나타내고, 입력층과 은닉층의 연결강도벡터를 보통 반경중심(Radial centers) 혹은 중심으로 표시하며  $U^{(j)} = [u_{j1}, u_{j2}, \dots, u_{jm}]^T$ 라고 나타내면 식(2)는 식(3)과 같이 나타낼 수 있다.

$$R_j = \|X - U^{(j)}\| \quad (3)$$

여기서  $\|\cdot\|$ 는 유클리드거리(Euclidean distance)이다. 또한  $R_j$ 를 은닉층의 전이함수인  $\phi_1(\cdot)$ 에 적용하면 다음 식(4)와 같이 나타낼 수 있다.

$$S_j = \phi_1(R_j) = \phi_1(\|X - U^{(j)}\|) \quad (4)$$

또한 출력층은  $S_j$ 와 은닉층과 출력층의 연결강도 벡터의 연산 결과치를 입력벡터로 받으며, 다음 식(5)와 같이 나타낼 수 있다.

$$T_k = \sum_{j=1}^n W_{kj} \cdot S_j = \sum_{j=1}^n W_{kj} \cdot \phi_1(\|X - U^{(j)}\|) \quad (5)$$

여기서  $W_{kj}$ 는 은닉층과 출력층사이의 연결강도벡터이고, 각  $k$ 에 대하여 식(5)는 RBF을 나타내고 있다 (Powell, 1987). 그리고 출력층의 전이함수  $\Phi_2(\cdot)$ 에 나타내어 출력층의 결과치를 표시하면 다음 식(6)과 같이 나타낼 수 있다.

$$Q(t) = \Phi_2\left(\sum_{j=1}^n W_{kj} \cdot S_j + B_2\right) \quad (6)$$

$$= \Phi_2\left(\sum_{j=1}^n W_{kj} \cdot \Phi_1(\|X - U^{(j)}\|) + B_2\right)$$

여기서  $Q(t)$ 는 출력벡터로서 본 연구에서는 무성 지점의 1시간 예측 홍수량,  $B_2$ 는 출력층의 편차벡터를 나타내고 있다. 또한 보통 은닉층의 전이함수  $\Phi_1(\cdot)$ 는 RBF를 사용하며, 일반적으로 RBF의 종류로는 Thin Plate Spline Function, Gaussian Kernel Function, Multiquadric Function 및 Inverse-Multiquadric Function 등이 있다(Mason et al., 1996). 본 연구에서는 Gaussian Kernel Function(GKF)을 사용하였으며 입력이 0일 때 최대값은 1이고, 입력벡터와 중심사이의 거리가 감소함에 따라 출력벡터의 값은 증가한다. GKF는 다음 식(7)과 같이 나타낼 수 있다.

$$\Phi_1(\cdot) = \exp(-B_1 R^2) = \exp\left[-\frac{\sum_{i=1}^m (x_i - u_{ji})^2}{2\sigma^2}\right] \quad (7)$$

여기서  $B_1$ 는  $\frac{1}{2\sigma^2}$ 으로 나타내고 보통 일정한 값

을 가지며,  $\sigma$ 는 RBF의 폭을 나타낸다. 그리고 출력층의 전이함수  $\Phi_2(\cdot)$ 는 전이함수중에서 선형전 이함수(Pure Linear Transfer Function, PLTF)를 사용하였다. 그림 1은 RBF 신경망모형의 은닉층의 입·출력과정 및 GKF를 나타낸 것이다.

### 2.3 엘만 신경망(Elman Neural Networks, ENN)모형

본 연구에서의 ENN 모형은 기존에 많이 적용되어 온 전방향 역전파(Feed-Forward BackPropagation, FFBP)신경망모형을 수정한 것으로 입력층, 은닉층 및 출력층으로 구성되어 있다. 각 층의 연결강도와 편차벡터는 Nguyen-Widrow(1990)에 의해 초기화되며, 특정한 역전파훈련 알고리즘에 의해서 연결강도와 편차벡터를 갱신(Update)한다(Lin and Lee, 1996). 또한 은닉층의 전이함수는 쌍곡선 탄젠트시그모이드 전이함수(Hyperbolic Tangent Sigmoid Transfer Function, HTSTF), 출력층의 전이함수는 로그시그모이드 전이함수(Log Sigmoid Transfer Function, LSTF)를 사용한다. 본 연구의 ENN 모형에 사용된 알고리즘은 기존의 역전파훈련 알고리즘을 개선한 일 단계 할선역전파(One Step Secant BackPropagation, OSSBP) 및 탄성 역전파(Resilient BackPropagation, RBP)알고리즘을 이용하였으며 각 알고리즘의 상세한 설명은 다음과 같이 나타낼 수 있다.

Hidden Layer in RBF Neural Networks Model




그림 1. RBF 신경망모형의 은닉층의 입·출력과정 및 GKF

### 2.3.1 일단계 할선역전파(One Step Secant BackPropagation, OSSBP) 알고리즘

OSSBP 알고리즘은 출력치에 높은 정도의 값이 요구될 때 많은 차수에 의하여 훈련을 가속화할 수 있으며, 할선법(Secant method)과 공액구배법(Conjugate gradient method)사이에서 강한 연결성을 제공한다(Battiti, 1992; Broomhead and Lowe, 1988). OSSBP 알고리즘은 연결강도와 편차벡터에 관해서 오차의 평방합이 허용치이하가 되는 미분함수를 계산하는데 사용되며, 각 연결강도와 편차벡터는 다음 식(8)과 같이 갱신되어 질 수 있다.

$$X_{k+1} = X_k + \alpha_k \bar{d}_k \quad (8)$$

여기서  $X_{k+1}$  는 k+1회 반복시의 연결강도나 편차벡터,  $X_k$  는 k회 반복시의 연결강도와 편차벡터,  $\alpha_k$  는 상수, 그리고  $\bar{d}_k$  는 k회 반복시의 탐색방향(Search direction)을 나타내고 있다.  $\alpha_k$  는 탐색방향을 따라서 오차의 평방합을 최소화하기 위하여 사용하는 학습율(Learning rate)이다. 초기탐색방향  $\bar{d}_0$  는 초기오차구배  $\bar{g}_0$  를 이용하여  $\bar{d}_0 = -\bar{g}_0$  로 결정하며, 반복을 위하여 탐색방향은 현재 구배와 전 단계의 구배로부터 계산되어 진다. k+1회 반복시의 탐색방향  $\bar{d}_{k+1}$  는 다음 식(9)와 같이 나타낼 수 있다.

$$\bar{d}_{k+1} = -\bar{g}_{k+1} + A_{k+1} \bar{p}_{k+1} + B_{k+1} \bar{y}_{k+1} \quad (9)$$

여기서  $\bar{g}_{k+1}$  는 오차구배이고  $\bar{p}_{k+1} = X_{k+1} - X_k$  으로 나타내며, 연속된 연결강도나 편차벡터의 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(10) 및 (11)과 같이 나타낼 수 있다.

$$A_{k+1} = -\left(1 + \frac{\bar{y}_{k+1}^T \cdot \bar{y}_{k+1}}{\bar{p}_{k+1}^T \cdot \bar{y}_{k+1}}\right) \frac{\bar{p}_{k+1}^T \cdot \bar{g}_{k+1}}{\bar{p}_{k+1}^T \cdot \bar{y}_{k+1}} + \frac{\bar{y}_{k+1}^T \cdot \bar{g}_{k+1}}{\bar{p}_{k+1}^T \cdot \bar{y}_{k+1}} \quad (10)$$

$$B_{k+1} = \frac{\bar{p}_{k+1}^T \cdot \bar{g}_{k+1}}{\bar{p}_{k+1}^T \cdot \bar{y}_{k+1}} \quad (11)$$

### 2.3.2 탄성 역전파(Resilient BackPropagation, RBP) 알고리즘

탄성 역전파(Resilient BackPropagation, RBP) 알고리즘은 국부적인 구배정보를 기초로 하여 연결강도나 편차벡터 단계의 직접적인 적합성을 실행하는 알고리즘이며, 이 알고리즘을 실행하기 위하여 각 연결강도나 편차벡터의 갱신크기(Update size)를 결정하는 갱신값(Update value)인  $\Delta_k$  를 도입한다. 이 갱신값은 다음 식(12)-(14)와 같은 오차함수  $E$  의 훈련동안에 계산된다(Riedmiller and Braun, 1993).

$$\Delta_{k+1} = \eta^+ * \Delta_k, \text{ if } \frac{\partial E}{\partial X_k} * \frac{\partial E}{\partial X_{k+1}} > 0 \quad (12)$$

$$\Delta_{k+1} = \eta^- * \Delta_k, \text{ if } \frac{\partial E}{\partial X_k} * \frac{\partial E}{\partial X_{k+1}} < 0 \quad (13)$$

$$\Delta_{k+1} = \Delta_k, \text{ else} \quad (14)$$

여기서  $X_{k+1}$  는 k+1회 반복시의 연결강도나 편차벡터,  $X_k$  는 k회 반복시의 연결강도와 편차벡터,  $\eta^-$  와  $\eta^+$  는 조정계수(Adjustment factor)이며,  $\eta^-$  와  $\eta^+$  의 범위는  $0 < \eta^- < 1 < \eta^+$  이다. 연결강도나 편차벡터의 미분방정식은 모든 단계에서 부호가 변화하며, 마지막으로 갱신된 값이 과다하여 국부최소점을 초과할 때, 갱신된 값  $\Delta_{k+1}$  는  $\eta^-$  에 의하여 감소한다.

## 3. 적용유역 및 자료

### 3.1 분석대상지점 및 수문자료의 선정

본 연구의 대상유역은 낙동강유역의 중소하천유역이며, 국제수문개발계획(IHP)대표유역인 위천유역으로서 1982년부터 2001년까지 약 20년에 걸쳐서 장기간 수문관측을 실시하고 있다. 수문관측시설은 수위관측소 6

개소, 지하수위관측소 6개소, 강우량 및 증발량관측소 11개소가 있으나, 기상관측소는 유역 내에 없고 인근 지역인 의성, 대구, 선산 및 영천에서 관측하고 있다. 분석대상유역의 하천수계 구성은 그림 2와 같이 본류와 비교적 큰 1개의 지류로 구성되어 있다. 본 연구에서는 위천유역출구의 유량관측지점인 무성지점(No.1)에서 홍수유출량의 수문학적 예측을 위한 강우-유출모형을 구성하였으며, 강우량은 11개 강우관측소의 티센면적비를 이용한 유역평균강우량자료 또한 홍수량은 동시간 대의 홍수유출량자료를 이용하였다. 본 연구에서는 어느 특정한 해의 강우자료만 이용할 경우는 분석결과와 신뢰도가 감소하므로, 이를 방지하기 위하여 표 2와 같이 1980년대에서 1990년대 초반까지 10개의 강우사상을 무작위로 선정하였다. 이들 중 Case 1-5 사상은 신경망모형의 훈련에 이용하였으며, Case 6-10사상은 신경망모형의 검증에 이용하였다. 표 2는 본 연구에서 선정한 강우사상별 강우지속시간, 최대강우강도 및 총강우량의 특성을 나타내었으며, 본 자료는 국제수문개발계획(IHP) 대표유역 연구조사보고서의 자료를 인용한 것이다(건설교통부, 1982-1992).

본 연구에서는 유역평균강우량과 홍수유출량을 RBF 신경망모형 및 ENN 모형의 입력층노드로 선정하였으며, 입력층노드의 선행시간은 홍수유출량의 계열상관분석과 유역평균강우량과 홍수유출량의 교차상관분석을 통하여 선행시간을 결정하였다. 본 계열상관분석과 교차상관분석을 위하여 신경망모형의 훈련에 사용될 Case 1-5까지의 자료를 이용하였으며, 그 결과치는





그림 2. 위천 유역도와 각 관측소의 위치

그림 3(a)-(e)와 같다. 그림 3(a)-(e)에 의하면 유역 평균강우량과 홍수유출량의 교차상관계수는 Case 1에서는 5시간, Case 2에서는 8시간, Case 3에서는 5시간, Case 4와 Case 5에서는 6시간 선행에서 최대값을 나타내고 있다. 이것은 현재의 홍수유출량이 교차상관계수의 최대값에 해당하는 선행시간 강우량에 의해


표 2. 본 연구에 사용된 강우사상과 자료의 특성

Rainfall event	Date	RD(hr)	MRI(mm/hr)	TR(mm)
Case 1	83/6/20 00:00 - 83/6/21 05:00	30	12.633	106.592
Case 2	84/4/18 04:00 - 84/4/19 12:00	33	6.948	84.712
Case 3	85/8/17 01:00 - 85/8/18 00:00	24	12.082	94.189
Case 4	86/7/21 07:00 - 86/7/22 07:00	25	12.054	48.321
Case 5	87/7/14 19:00 - 87/7/16 11:00	40	16.470	135.969
Case 6	88/7/13 18:00 - 88/7/15 16:00	47	17.929	211.428
Case 7	89/8/21 11:00 - 89/8/23 02:00	40	17.162	91.647
Case 8	90/6/19 17:00 - 90/6/21 20:00	52	10.869	55.021
Case 9	91/7/07 07:00 - 91/7/12 21:00	135	7.520	95.036
Case 10	92/7/12 06:00 - 92/7/13 22:00	41	15.988	89.356


[Note] RD : Rainfall Duration, MRI : Maximum Rainfall Intensity, TR : Total Rainfall




(a) case 1




(b) case 2



(c) case 3



(d) case 4



(e) case 5

그림 3. 계열상관분석 및 교차상관분석의 결과치

영향을 많이 받는 것으로 설명할 수 있으며, Case 1-5의 최대 교차상관계수의 평균값은 6시간으로 분석되었다. 따라서  $Q(t)$ 의 홍수유출량의 예측을 위하여 입력층노드의 유역평균강우량은  $P(t-6)$ ,  $P(t-5)$ ,  $P(t-4)$ ,  $P(t-3)$ ,  $P(t-2)$  그리고  $P(t-1)$ 으로 결정하였다. 또한 홍수유출량의 계열상관계수는 선행시간이 증가함에 따라 급격히 감소하는 것으로 나타났으며, 계열상관계수가 평균 0.5이상 에 해당하는 선행시간은 평균 3시간으로 분석되어서 입력층노드의 홍수유출량은  $Q(t-3)$ ,  $Q(t-2)$  그리고  $Q(t-1)$ 으로 결정하였다. 따라서 본 연구에서의 입력층 노드는 6개의 유역평균강우량과 3개의 홍수

유출량을 포함하여 전부 9개의 노드로 결정하였다.

### 3.2 모형평가를 위한 통계지표

본 연구에서는 신경망모형을 평가하기 위하여 예측 오차(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,  $CC$ )의 통계지표를 선정하였으며, 신경망모형의 훈련 및 검증결과를 평가하였다 (Kim and Lee, 2000).

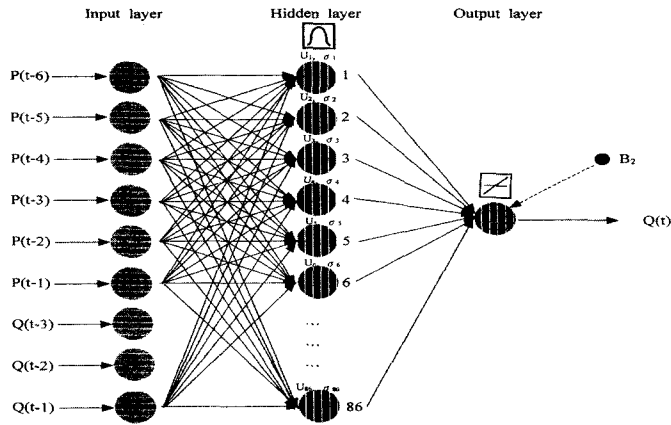


그림 4. 제시된 RBF 신경망모형의 구조

## 4. 신경망모형의 훈련

### 4.1 RBF 신경망모형의 훈련

본 연구에서 적용한 RBF 신경망모형은 전절 2.1에서 나타난 바와 같이 자율훈련과 지도훈련의 두 부분으로 나누어서 구성된 Hybrid Neural Networks의 일종이며, 은닉층의 중심의 수가 한정되었을 때 RBF 신경망모형은 종료된다. 즉 프로그램의 초기에 중심의 위치에 대한 분포정도를 어떻게 설정하느냐에 따라 은닉층의 중심의 수는 변화하게 된다. 또한 동일한 분포정도에 대하여는 프로그램의 실행횟수에 관계없이 동일한 결과치를 나타내고 있다. 그러나 RBF 신경망모형은 일반적으로 입력층노드수가 증가함에 따라 중심의 수도 급격하게 증가하는 단점이 있다(Demuth and Beale, 1998). 본 연구에서의 RBF 신경망모형은 입력층노드수를 9개, 출력층노드수를 1개로 하였으며, 은닉층노드수는 K-Means 군집알고리즘에 의해 최소의 중심수를 가지면서 최적의 결과치를 나타내기 위하여 분포정도를 0.1에서 2.0까지 0.1씩 증가시켰다. 그 결과 분포정도가 0.8일 경우의 중심의 수가 86개로 최소를 나타내었으며, 그때의 폭의 값은 0.693으로 나타났다. 따라서 본 연구에서는 중심의 수 즉 은닉층노드수가 86개일 경우의 RBF 신경망모형을 훈련하였다. 또한 RBF 신경망모형의 매개변수는 첫 번째 단계에서는 중심과 폭, 두 번째 단계에서는 연결강도와 편차벡터로 구성되어 있으며, 모형의 훈련과정은 5개의 훈련자료를

모두 이용하여 RBF 신경망모형의 매개변수를 최적화하였으며, 평균제곱오차(MSE)의 수렴한계치는 0.001로 선정하였다. 그림 4는 본 연구에서 제시된 RBF 신경망모형의 구조를 나타낸 것이다.

### 4.2 ENN 모형의 훈련

본 연구에서는 RBF 신경망모형과 비교검토를 위한 모형으로 OSSBP 및 RBP 알고리즘을 가진 ENN모형을 적용하였으며, ENN 모형의 구성은 입력층 및 은닉층노드수는 각각 9개, 출력층노드수는 1개인 9-9-1 네트워크로 구성하였다. 또한 10회의 훈련결과 중 OSSBP-ENN 및 RBP-ENN 모형에서 각각 최적의 통계 결과치를 나타내는 연결강도와 편차벡터를 ENN 모형의 검증에 이용하였다. 그림 5는 제시된 ENN 모형의 구조를 나타낸 것이며, 그림 6은 ENN 모형이 평균제곱오차(MSE)의 수렴한계치인 0.001에 수렴하는 과정을 나타낸 것이다. 수렴시간 및 반복횟수는 OSSBP-ENN 모형의 경우 15초와 204회, RBP-ENN 모형은 13초와 171회가 필요한 것으로 나타났다. 표 3(a)는 모형의 검증에 사용된 OSSBP-ENN 모형의 최적 연결강도와 편차벡터, 표 3(b)는 RBP-ENN 모형의 최적 연결강도와 편차벡터를 나타낸 것이다.

표 4는 RBF 신경망모형과 OSSBP-ENN 및 RBP-ENN 모형의 훈련결과에 대한 통계분석을 나타내고 있으며, 그림 7(a)-(e)는 RBF 신경망모형과 OSSBP-ENN 및 RBP-ENN 모형의 훈련결과에 대



표 3(a). OSSBP-ENN 모형의 최적연결강도와 편차벡터

Hidden Layer		Input Variables and Weights									Output Layer
Node j	Bias B <sub>1</sub>	P(t-6)	P(t-5)	P(t-4)	P(t-3)	P(t-1)	P(t-1)	Q(t-3)	Q(t-2)	Q(t-1)	W <sub>1j</sub>
1	-0.284	-0.894	0.084	1.037	0.748	0.518	1.228	-0.329	-0.115	0.514	0.860
2	0.819	0.961	0.248	-0.502	-0.623	-0.599	0.126	0.371	0.939	-1.167	-1.180
3	-0.525	0.701	-0.170	-1.020	0.454	0.420	-1.012	-0.909	-0.110	-0.553	0.292
4	-0.288	0.223	-0.393	0.538	-1.051	-0.392	0.110	0.183	0.351	0.178	-0.265
5	0.059	0.673	1.293	0.732	-0.187	0.382	0.908	-0.707	-1.053	-1.953	-1.656
6	-0.450	0.885	0.979	-0.243	-0.045	-0.737	0.624	-1.670	0.661	2.156	2.277
7	0.111	-0.612	-1.670	0.204	0.245	-1.042	0.679	-0.992	-0.909	-0.795	-0.864
8	-0.239	0.851	0.958	-0.599	-0.053	0.966	0.106	0.839	0.627	-1.054	-0.609
9	0.047	-0.896	0.498	-1.084	-0.798	-1.305	-0.015	-0.100	-0.258	-0.402	-0.642
Bias B <sub>2</sub>											-1.241

표 3(b). RBP-ENN 모형의 최적연결강도와 편차벡터

Hidden Layer		Input Variables and Weights									Output Layer
Node j	Bias B <sub>1</sub>	P(t-6)	P(t-5)	P(t-4)	P(t-3)	P(t-1)	P(t-1)	Q(t-3)	Q(t-2)	Q(t-1)	W <sub>1j</sub>
1	-1.190	1.265	-0.453	0.980	0.195	-0.506	-0.252	1.439	-0.545	0.011	-0.578
2	1.242	-0.079	0.731	-1.200	1.245	-0.825	-0.455	0.378	-0.268	-1.332	-0.379
3	2.138	-0.864	-0.744	-0.489	-0.458	-0.079	0.322	0.540	-1.242	-1.105	-1.383
4	-1.981	0.939	0.311	0.740	-0.687	0.716	0.848	-4.498	0.347	0.313	0.862
5	0.932	-0.960	-0.700	1.513	-1.050	-0.745	0.165	-1.008	-0.598	0.895	0.854
6	0.548	-1.547	0.410	-1.215	-0.509	0.471	1.102	-1.138	-0.199	-3.542	-0.611
7	0.390	0.563	0.345	1.340	-1.051	0.040	0.098	-0.545	-0.386	-1.193	-1.767
8	-0.420	0.599	0.934	1.219	-0.085	-1.197	1.255	-1.276	0.372	1.363	0.935
9	1.817	-3.211	2.882	0.926	-1.450	-0.618	0.542	33.495	-1.880	-61.605	-0.573
Bias B <sub>2</sub>											-0.515




그림 5. 제시된 ENN 모형의 구조

한 계산 및 실측된 홍수유출 수문곡선을 비교하고 있다. 홍수유출 수문곡선의 상승부, 첨두부 및 하강부에

서 각 모형에 의해 계산된 홍수유출 수문곡선은 실측된 홍수유출 수문곡선과 유사한 패턴을 나타내는 것으




그림 6. ENN 모형의 훈련에 의한 평균제곱오차의 수렴과정

표 4. RBF 신경망모형과 OSSBP-ENN 및 RBP-ENN 모형의 훈련결과에 대한 통계분석

Statistics Events	RBF					OSSBP-ENN					RBP-ENN				
	m(e) (cms)	s(e) (cms)	s(e)/ s(y)	R <sub>max</sub> (%)	CC	m(e) (cms)	s(e) (cms)	s(e)/ s(y)	R <sub>max</sub> (%)	CC	m(e) (cms)	s(e) (cms)	s(e)/ s(y)	R <sub>max</sub> (%)	CC
1	-0.3155	1.2799	0.0113	100.2	0.967	0.2089	28.3076	0.2489	105.3	0.936	5.6292	34.3915	0.3024	103.4	0.925
2	0.0613	2.7317	0.0710	100.1	0.967	-11.3948	15.0728	0.3920	86.0	0.936	6.7194	14.9516	0.3888	103.7	0.926
3	-0.0834	1.7253	0.0057	100.0	0.958	-8.5258	53.2299	0.1769	91.2	0.944	-13.4691	61.9634	0.2060	86.4	0.938
4	-0.5703	2.6378	0.0579	100.2	0.958	-3.4405	23.8707	0.5237	118.5	0.835	-1.7504	25.6465	0.5626	109.8	0.878
5	0.5926	3.1523	0.0115	100.0	0.975	20.6001	35.3887	0.1286	100.8	0.971	7.0438	20.6009	0.0749	96.2	0.973

로 분석되었으며, 특히 RBF 신경망모형의 경우 실측된 홍수유출 수문곡선을 완벽하게 재현하는 것으로 나타났다. 따라서 통계분석결과와 홍수유출 수문곡선의 분석을 통하여 본 연구에서 선정한 RBF 신경망모형과 OSSBP-ENN 및 RBP-ENN 모형은 우수한 모형으로 나타났으며, 특히 RBF 신경망모형은 나머지 두 모형보다 우수한 모형으로 나타났다. 그리고 RBF 신경망모형의 검증에는 모형의 훈련을 통하여 산정된 매개변수인 중심, 폭, 연결강도 및 편차벡터, ENN 모형의 검증에는 연결강도 및 편차벡터를 이용하였다.


### 5. 신경망모형의 검증

RBF 신경망모형의 검증을 위하여 훈련을 통하여 결정되어진 RBF 신경망모형의 입력층과 은닉층사이의 매개변수인 중심과 폭 및 은닉층과 출력층사이의 매개변수인 연결강도 및 편차벡터를 이용하여 RBF 신경망모형의 검증에 이용하였다. 또한 ENN 모형의 검증을 위하여 OSSBP-ENN 및 RBP-ENN 모형의 훈련을 통하여 결정된 연결강도 및 편차벡터를 이용하여 모형의 검증에 사용하였으며, 검증결과에 대한 통계분석은 표 5와 같다. 표 5에 의하면 RBF 신경망모형과


OSSBP-ENN 및 RBP-ENN 모형의 훈련결과에서 나타난 것처럼 RBF 신경망모형에 의한 검증결과가 OSSBP-ENN 및 RBP-ENN 모형의 검증결과보다 우수한 결과치를 나타내는 것으로 분석되었다. 따라서 본 연구의 중소하천수계인 위천유역에서 RBF 신경망모형에 의한 수문학적 예측은 아주 우수한 결과를 나타내는 것으로 사료된다. 그림 8(a)-(e)는 RBF 신경망모형과 OSSBP-ENN 및 RBP-ENN 모형의 검증결과에 대한 계산 및 실측된 홍수유출 수문곡선을 비교하고 있다. 특히 RBF 신경망모형에 의해 계산된 홍수유출 수문곡선의 상승부, 침두부, 및 하강부에서 실측된 홍수유출 수문곡선을 완벽하게 재현하는 것으로 분석되었다.

### 6. 결론 및 토의


본 연구에서는 중소하천유역의 하나인 IHP 대표유역의 위천유역에서 수문학적 예측을 위한 RBF 신경망모형이 제시되었다. RBF 신경망모형은 기존의 MLP 신경망모형이 지도훈련을 하는 모형인 점에 비해 입력층과 은닉층은 자율훈련 및 은닉층과 출력층은 지도훈련으로 이루어진 일종의 Hybrid Neural Networks




(a) Case1, 훈련




(b) Case2, 훈련



(c) Case3, 훈련



(d) Case4, 훈련




(e) Case5, 훈련


그림 7. 홍수유출 수문곡선의 비교

표 5. RBF 신경망모형과 OSSBP-ENN 및 RBP-ENN 모형의 검증결과에 대한 통계분석


Statistics Events	RBF					OSSBP-ENN					RBP-ENN				
	m(e) (cms)	s(e) (cms)	s(e)/ s(y)	R <sub>max</sub> (%)	CC	m(e) (cms)	s(e) (cms)	s(e)/ s(y)	R <sub>max</sub> (%)	CC	m(e) (cms)	s(e) (cms)	s(e)/ s(y)	R <sub>max</sub> (%)	CC
1	0.2400	1.8946	0.1580	100.0	0.959	23.6880	67.8942	0.5299	90.0	0.865	-2.5249	39.1297	0.3054	93.3	0.933
2	-0.3700	1.8677	0.1890	100.0	0.965	-7.0127	24.9665	0.1958	90.8	0.958	-6.4729	22.4783	0.1763	93.8	0.963
3	-0.4100	1.6927	0.1610	100.0	0.961	2.7951	18.0726	0.4198	98.8	0.910	0.0807	15.0044	0.3486	96.7	0.922
4	0.1100	0.2350	0.0780	100.0	0.973	1.1242	8.3851	0.2789	94.8	0.954	-0.0433	7.4311	0.2472	92.2	0.962
5	-0.4300	1.5199	0.2134	99.9	0.956	0.2034	19.5200	0.5034	77.1	0.857	-3.1750	19.3422	0.4986	71.8	0.856




(a) Case6, 검증




(b) Case7, 검증



(c) Case8, 검증



(d) Case9, 검증



(e) Case10, 검증

그림 8. 홍수유출 수문곡선의 비교

모형이다. 또한 본 RBF 신경망모형과 비교검토를 위한 모형으로 OSSBP-ENN 및 RBP-ENN 모형을 이용하였다.

RBF 신경망모형에서 RBF의 매개변수인 중심과 폭을 결정하기 위하여 군집알고리즘의 하나인 K-Means 군집알고리즘을 적용하였으며, 은닉층의 전이함수로서 RBF는 GKF를 사용하였다. 또한 RBF 신경망모형 및 ENN 모형의 입력층노드수는 9개, 은닉층의 경우 RBF 신경망모형은 86개, ENN 모형은 9개의 은닉층 노드수로 결정하였으며, 출력층노드수는 RBF 신경망

모형 및 ENN 모형에서 1개로 결정하였다. 본 연구의 RBF 신경망모형 및 ENN 모형은 MATLAB Version 5.3(1998)으로 프로그래밍을 하였으며, Intel Celeron Processor-466MHz CPU를 가진 Pavilion Hewlett Packard PC를 이용하여 모형의 훈련 및 검증을 실시하였다.

RBF 신경망모형 및 ENN 모형의 훈련결과에 대한 통계분석 및 홍수유출 수문곡선의 비교를 통하여 RBF 신경망모형이 다른 두 신경망모형보다 우수한 모형으로 나타났다. 또한 모형의 훈련과정을 통하여 결정된

RBF 신경망모형의 매개변수인 중심, 폭, 연결강도 및 편차벡터와 OSSBP-ENN 및 RBP-ENN 모형의 매개변수인 연결강도와 편차벡터를 이용하여 신경망모형을 검증하였으며, 훈련결과와 같이 RBF 신경망모형이 OSSBP-ENN 및 RBP-ENN 모형보다 우수한 모형으로 나타났다.

지난 10여년 동안 수공학분야에 있어서는 MLP 신경망모형을 많이 적용하였으나, 본 연구에서는 RBF 신경망모형을 수문학적 예측에 적용하여 아주 우수한 결과를 나타내었다. 그러나 RBF 매개변수인 중심과 폭에 대한 분포정도 및 최적치산정에 관한 연구결과는 아직 없으므로 이에 관한 연구가 필요하며, RBF 신경망모형을 이용한 자연하천에서 실시간 유출해석 및 홍수에경보 시스템의 구축, 교각의 세굴해석 및 댐의 최적방류량산정 등의 적용에 관한 지속적인 연구가 필요한 것으로 사료된다.

### 참 고 문 헌

- 건설교통부(1982-1992). 국제수문개발계획(IHP) 대 표유역 연구조사 보고서.
- Battiti, R.(1992). "First and second order methods for learning : between steepest and descent Newton's method" *Neural Computation*, Vol. 4, No. 2, pp. 141~166.
- Broomhead, D.S. and Lowe, D.(1988). "Multivariable functional interpolation and adaptive networks." *Complex Systems*, Vol. 2, pp. 321~355.
- Daniell, T.M.(1991). "Neural networks-application in hydrology and water resources engineering." *Int. Hydro. and Water Resour. Symp.*, Inst. of Engineers, Perth, Australia, pp. 797~802.
- Demuth, H., and Beale, M.(1998). *Neural network toolbox : for use with MATLAB user's guide*, The Math Works Inc.
- Duda, R.O., and Hart, P.E.(1973). *Pattern Classification and Scene Analysis*, Wiley, New York, NY.
- Fernando, D.A.K, and Jayawardena, A.W.(1998). "Runoff forecasting using RBF networks with OLS algorithm." *J. of Hydro. Eng.*, Vol. 3, No. 3, pp. 203~209.
- Hush, D.R., and Horne, B.G.(1993). "Progress in supervised neural networks." *IEEE Signal Processing Magazine*, Vol. 10, No. 1, pp. 6~39.
- Isobe, I., Ohkado, T., Hanyuda, H., and Gotoh, Y.(1994). "The development of a forecasting system of the water levels of rivers by neural networks." *J. Japan Soc. of Hydro. and Water Resour.*, Vol. 7, No. 2, pp. 90~97.
- Jain, A.K., and Dubes, R.C.(1988). *Algorithms for clustering data*, Prentice Hall, New Jersey.
- 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 Combinational Optimization in Civ. and Struct. Engrg.*, Topping, B.H.V., and Khan, A.I., eds., Civil Comp Press, U.K., pp. 67~70.
- Lin, C.T., and Lee, C.S.G.(1996). *Neural Fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems*, Prentice Hall, New Jersey.
- Mason, J.C., Price, R.K., and Tem'me, A.(1996). "A neural network model of rainfall-runoff using radial basis functions" *Hydro. Sci. J.*, Vol. 41. No. 3, pp. 399~417.
- Minns, A.W., and Hall, M.J.(1996). "Artificial neural network as rainfall runoff models." *Hydro. Sci. J.*, Vol. 43, No. 3, pp. 281~294.
- Moody, J.E., and Darken, C.J.(1989). "Fast learning in networks of locally-turned processing units." *Neural Computation*, Vol. 1, pp. 281~294.
- Nguyen, D.H. and Widrow, B.(1990). "Neural

- network for self-learning control systems.” *IEEE Contrl Systems Magazine*, pp. 18~23.
- Poggio, T., and Girosi, F.(1990). “Networks for approximation and learning.” *Proceedings of the IEEE*, Vol. 78, pp. 1481~1497.
- Powell, M.J.D.(1987). “Radial basis functions for multivariable interpolation : A review.” in *Algorithms for the Approximation of Functions and Data*, Mason, J.C., and Cox, M.G., eds., Oxford, England : Clarendon Press, pp. 143~167.
- Riedmiller, M., and Braun, M.(1993). “A direct adaptive method for faster backpropagation learning : The RPROP algorithm” *Proceedings of the IEEE International Conference on Neural Networks*, San Francisco.
- Raman, H, and Sunilkumar, N.(1995). “Modeling water resources time series using artificial neural networks.” *Hydro. Sci. J.*, Vol. 40, No. 2, pp. 145~162.
- Smith, J., and Eli, R.N.(1995). “Neural network models of rainfall-runoff process.” *J. Water Resour. Plng. and Mgmt.*, ASCE, Vol. 121, No. 6, pp. 499~508.
- Tou, J.T., and Gonzalez, R.C.(1974). *Pattern Recognition Principles*, Addison-Wesley, Reading, MA.
- Tsoukalas, L.H., and Uhrig, R.H.(1997). *Fuzzy and neural approaches in engineering*, John Wiley & Sons Inc.
- Wasserman, P.D.(1993) *Advanced Methods in Neural Computing*, Van Nostrand Reitrand, New York.

(논문번호:00-031/접수:2000.05.22/심사완료:2001.06.18)