

# 신경망모형을 이용한 시간적 분해모형의 개발

## 2. 모의자료의 적용

### Development of Temporal Disaggregation Model using Neural Networks

#### 2. Application of the Generated Data

김성원\*

#### Abstract

The goal of this research is to apply the neural networks models for the disaggregation of the pan evaporation (PE) data, Republic of Korea. The neural networks models consist of generalized regression neural networks model (GRNNM) and multilayer perceptron neural networks model (MLP-NNM), respectively. The disaggregation means that the yearly PE data divides into the monthly PE data. And, for the performances of the neural networks models, they are composed of training and test performances, respectively. The training data consist of the generated data using PARMA (1,1). And, the testing data consist of the historic data, respectively. From this research, we evaluate the impact of GRNNM and MLP-NNM for the disaggregation of the nonlinear time series data. We should, furthermore, construct the credible data of the monthly PE data from the disaggregation of the yearly PE data, and can suggest the methodology for the irrigation and drainage networks system.

*Key words :* Generated Data, Pan Evaporation, Temporal Disaggregation Model, GRNNM, MLP-NNM.

## 1. 서 론

증발량은 하천유출량하고는 다르게 수문학적 순환의 최소의 만족할 만큼 표시된 요인 중 하나이다. 증발량은 일반적으로 직접적인 측정보다는 질량이송, 에너지 수지 및 물수지를 기초로 하여 추정할 수 있다. NWS Class A pan은 오늘날 증발량의 추정에 가장 넓게 사용되고 있다. 수문학적 설계와 운영에 있어서의 지속적이다. Pan 증발량은 증발산량의 지표로서 사용되고 호수와 저수지의 증발량을 추정하는데 넓게 사용된다. 추계학적 모형과 신경망모형을 연계한 연구성과로는 Salas et al. (2000)이 신경망모형을 이용하여 연 유출량자료의 예측에 있어서 훈련과정에 대한 표본자료에 관계된 불확실성을 평가하기 위하여 AR(1)모형을 이용하여 훈련자료를 모의발생시킨 연구를 수행한 바가 있다. 그 결과 50개의 훈련자료가 25개의 훈련자료보다 통계학적으로 양호한 결과를 유도하는 것으로 분석되었다. 또한 Kim (2003)은 추계학적 모형과 신경망모형을 연계하여 병렬저수지군인 안동댐과 임하댐의 월 평균유입량을 모형화를 시도하였는데, 엘리뇨, 라니냐 및 지구온난화와 같은 기후변화의 고려가 이루어지지 않아서 모형화의 결과치가 양호하지 않은 것으로 나타났다. Mishra et al. (2007)은 선형 추계학적모형과 비선형 인공신경망모형을 이용하여 가뭄의 발생과 심도를 예측하여 양호한 결과치를 나타내었다.

본 연구의 목적은 우리나라 주요 기상관측소에서 관측된 연간 소형 증발접시 증발량자료를 월별 소형 증발접시 증발량자료로 분리하고자 제시된 두 가지의 신경망모형을 이용하여 시간적인 분해모형을 개발하고자 한다. 신경망을 이용한 시간적 분해모형의 경우 추계학적 모형을 이용하여 모의발생시킨 자료를 적용하였으며, 훈련결과 선정된 최적 매개변수를 이용하여 실측자료로서 테스트과정을 실시하였다. 본 연구를 통하여 신경망을 이용한 시간적 분해모형의 개발을 위하여 훈련자료는 모의자료, 테스트자료는 실측자료로 구성하였으며 신뢰성있는 월별 소형 증발접시 증발량을 산정할 수 있는 시간적 분해모형의 개발이 가능한 것으로 판단된다.

## 2. 신경망모형

### 2.1 일반화된 회귀신경망모형 (Generalized Regression Neural Networks Model, GRNNM)

본 연구에 적용된 일반화된 회귀신경망모형 (GRNNM)은 반경기초함수 신경망모형 (Radial basis function neural networks model, RBFNNM)의 변형된 형태의 신경망모형이다. GRNNM은 입력층, 은닉층, 합산층 및 출력층의 4개의 층으로 구성되었으며, 비선형 회귀이론에 기초를 둔 신경망모형이다. 입력층, 은닉층 및 합산층노드는 완전히 연결된 구조로 형성되어 있으나, 출력층의 노드는 합산층의 노드 중 몇 개로만 연결이 되어있다. 합산층 (Summation layer)은 여러 개의 합산노드 (Summation node)와 하나의 제법노드 (Division node)의 2종류의 노드로 구성되어 있다. 합산노드수는 출력층 노드수와 동

\* 정회원, 공학박사, 수자원개발기술사, 동양대학교 철도토목학과 부교수 ; E-mail : [swkim68@phenix.dyu.ac.kr](mailto:swkim68@phenix.dyu.ac.kr)

일하다. 제법노드는 어떤 전이함수를 사용하지 않고 은닉층노드의 가중전이값 (Weighted transfer value)을 합한 것과 같다. GRNNM의 각 출력층노드는 합산층의 합산노드와 제법노드로 연결되어 있으며, 합산층과 출력층 사이는 연결강도로 구성되어 있지 않다. 각 출력층노드의 계산은 합산층의 합산노드로부터 계산된 값을 제법노드로부터 계산된 값으로 나누어 산정한다. GRNNM의 훈련과정은 다층 퍼셉트론 신경망모형 (MLP-NNM)과는 상당히 다른 양상을 가지고 있다. 입력층과 은닉층 사이에서의 훈련과정은 반경기초함수 신경망모형의 경우처럼 자율훈련 (Unsupervised training)으로 구성되어서 K-means나 OLS 알고리즘과 같은 특별한 군집알고리즘을 필요로 하며, 군집알고리즘의 반경은 훈련이 시작하기 전에 결정되어 족야 한다. 또한 은닉층과 합산층 사이에서의 훈련과정은 은닉층에서의 출력값에 대하여 평균제곱오차의 최소화 과정에 기초를 둔 지도훈련 (Supervised training)으로 구성된다 (김성원 등, 2001; Kim and Jee, 2006; Specht, 1991; Tsoukalas and Uhrig, 1997; Wasserman, 1993). 본 연구에서 GRNNM은 은닉층 1개, 클러스터 센터는 20개, 은닉층 노드수는 12개, 전이함수는 tansigmoid, 최대 반복횟수는 10,000회, 임계치는 0.001로 설정하였다. 또한 본 연구에서는 QuickProp 역전과 훈련알고리즘을 이용하였다. 다음 그림 1은 본 연구에 적용된 GRNNM 구조를 나타낸 것이다.

## 2.2 다층퍼셉트론 신경망모형 (Multilayer Perceptron Neural Networks Model, MLP-NNM)

일반적으로 MLP-NNM은 입력층, 출력층 및 그 사이에 1개 혹은 그 이상의 은닉층으로 구성되어 있으며, 각 층에서의 노드는 그 다음 층의 노드와 상호 긴밀하게 연결되어 있다. 또한 본 연구에서 MLP-NNM을 적용하는 과정은 훈련 및 테스트과정으로 구성되어 있다. 일반적으로 훈련과정을 통하여 MLP-NNM의 최적 매개변수를 결정하며, 결정된 매개변수를 이용하여 MLP-NNM의 테스트과정을 수행한다 (Haykin 2003). 본 연구에서 MLP-NNM은 은닉층 1개, 은닉층 노드수는 12개, 전이함수는 tansigmoid, 최대 반복횟수는 10,000회, 임계치는 0.001로 설정하였다. 또한 본 연구에서는 QuickProp 역전과 훈련알고리즘을 이용하였다. 다음 그림 2는 본 연구에 적용된 MLP-NNM 구조를 나타낸 것이다.

## 3. 추계학적 모형

주기성 자기회귀이동평균 모형은 주기성 자기회귀 (Periodic Autoregression, PAR) 모형에 주기성의 이동평균 매개변수를 포함하여 확장하여 일반적으로 PARMA ( $p,q$ )로 나타낸다. 저차수의 PARMA 모형은 주기적인 수문시계열의 모형화에 사용된다. 예를들면 PARMA (1,1) 모형은 다음 식(1)과 같이 나타낼 수 있다.

$$y_{v,\tau} = \mu_\tau + \Phi_{1,\tau}(y_{v,\tau-1} - \mu_{\tau-1}) + \varepsilon_{v,\tau} - \Theta_{1,\tau}\varepsilon_{v,\tau-1} \quad (1)$$

여기서  $v$  는 년 (year),  $\tau$ 는 계절 (Season)이고  $\tau = 1, 2, \dots, \omega$ 이며 계절수를 나타내고 있다. 식 (1)과 같은 모형은 주로 월 유출량계열에 적용된다 (Salas et al., 1980). 본 연구에서는 신경망모형의 훈련자료를 모의발생 하기위하여 PARMA (1,1) 모형을 이용하였다. 그리고 모의발생한 표본은 2개의 표본으로 하였으며, 500년에 해당되는 월별 증발량을 모의발생시켰다. 모의된 자료 중에서 첫 번째 표본자료는 선택하지 않았으며, 두 번째 표본자료를 선택하였다. 또한 두 번째 표본자료에서 초기에 발생되는 편차 (Bias)를 제거하기 위하여 초기의 50년 자료는 제거하였으며, 각 PARMA (1,1) 모형의 매개변수는 근사 최소자승법 (Method of approximate least square)을 이용하여 산정하였다. 따라서 제시된 신경망모형의 입력층 변수는 모의발생 시킨 월별 소형 증발량 증발량자료를 합한 결과치에 해당되는 연간 소형 증발접시 증발량자료이고, 출력층 변수는 모의발생시킨 월별 소형 증발접시 증발량자료이다.

## 4. GRNNM 및 MLP-NNM의 적용

### 4.1 훈련과정 (Training Performance)

본 연구의 훈련과정에서 훈련자료는 먼저 서울관측소의 경우는 1908년부터 2002년까지의 결측기간을 제외한 86년의 자료를 선택하였으며, 강릉관측소의 경우는 1912년부터 2002년까지의 결측기간을 제외한 88년의 자료를 선택하였다. 인천관측소의 경우는 1949년부터 2002년까지의 결측기간을 제외한 52년의 자료를 선택하였다. 부산관측소의 경우는 1965년부터 2002년까지의 38년의 자료를 선택하였다. 따라서 신경망모형의 입력층자료는 추계학적 모형인 PARMA (1,1)을 이용하여 선택되어진 자료로서 500년의 모의발생시켰다. 모의발생된 자료중에서 초기에 발생되는 편차 (Bias)를 제거하기 위하여 초기의 50년 자료는 제거하였으며, 나머지 450년의 자료를 훈련자료로 이용하였다. 따라서 각 신경망모형의 훈련을 위한 입력자료는 5,400개의 모의된 시계열자료로 구성되어 있다. 그리고 GRNNM 와 MLP-NNM의 훈련에 따른 진행과정으로서 입력층의 입력변수인 연간 소형 증발접시 증발량자료를 표준화하여 적용하였다. 일반적으로 입력변수들을 표준화하는 주요한 이유 중 하나는 각 입력변수들이 서로 다른 단위로서 관측된 값들을 나타내고 있기 때문에 이러한 입력변수들을 표준화하고 무차원단위에서 입력변수들을 재배치함으로써, 각 변수들의 상상성의 효과를 제거하기 위한 것으로 판단된다 (Kim and Kim, 2008a, b).

### 4.2 테스트과정 (Test Performance)

본 연구의 테스트과정에서 테스트자료는 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 동일한 시계열인 2003년부터 2007년까지의 5년간의 자료를 선택하였다. 테스트과정은 훈련과정을 통하여 산정된 매개변수를 이용하여 테스트자료를 검증하였다. 다음 그림 3(a) - 4(f)는 서울, 강릉, 인천, 부산, 제주 및 목포관측소의 테스트자료를 이용하여 GRNNM과 MLP-NNM의 결과치에 대한 월별 소형 증발접시 증발량자료의 시계열을 나타낸 것이다.

## 5. 결 론

본 연구에서는 GRNNM과 MLP-NNM을 이용하여 연간 소형 증발접시 증발량자료를 월별 증발접시 증발량자료로의 분리를 시도하였다. 사용된 자료는 서울, 강릉, 인천, 부산, 제주, 및 목포관측소의 자료를 이용하였으며, 훈련자료는 추계학적 모형으로 모의발생 시킨 자료를 이용하였고 테스트자료를 실측 관측자료를 이용하였다. 분석결과 MLP-NNM의 분석결과가 GRNNM의 결과치보다 양호한 것으로 분석되었다. 또한 본 연구를 통하여 우리나라 관개배수 시스템 구성을 위한 월별 소형 증발접시증발량 기준자료를 제공할 수 있는 방법론을 제시할 수 있을 것으로 판단된다.

## 참고문헌

1. 김성원, 이순탁, 조정석 (2001). “중소하천유역에서 Hybrid Neural Networks에 의한 수문학적 예측.” *한국수자원학회 논문집*, 한국수자원학회, 제 34권, 제 4호, pp. 303-316.
2. Haykin, S. (2003). *Neural networks : A comprehensive foundation*, 4th Indian Reprint, Pearson Education, Singapore.
3. Kim S. (2003). “Neural networks model and embedded stochastic processes for hydrological analysis in South Korea.” *KSCE Journal of Civil Engineering* 8: 141-148.
4. Kim, S., and Jee, H. (2006). “An expansion of the ungaged pan evaporation using neural networks model in rural regions, South Korea.” *Proc. World Environmental & Water Resources Congress 2006*, ASCE/EWRI, Omaha, NE. [ Printed in CD ]
5. Kim, S., and Kim, H.S. (2008a). “Uncertainty reduction of the flood stage forecasting using neural networks model.” *J. Americ. Water Resor. Assoc.*, Vol. 44, No. 1, pp. 148-165.
6. Kim, S., and Kim, H.S. (2008b). “Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling.” *J. Hydro.*, Vol.351, pp. 299-317.
7. Mishra AK, Desai VR, Singh VP. (2007). “Drought forecasting using a hybrid stochastic and neural network model.” *Journal of Hydrologic Engineering*, Vol. 12, pp.626-638.
8. Salas, J.D., Delleur, J.R., Yevjevich, V., and Lane, W.L. (1980) *Applied modeling of hydrologic time series*, Water Resor. Pub., Littleton, CO.
9. Salas JD, Markus M, Tokar AS. (2000). “ Streamflow forecasting based on artificial neural networks.” In *Artificial neural networks in hydrology*, Water science and technology Library Vol. 36, Govindaraju RS, Ramachandra Rao A (eds). Kluwer Academic Press: 23-51.
10. Specht, D.F. (1991). “A general regression neural network.” *IEEE Trans. on Neural Networks*, Vol. 2, No. 6, pp. 568-576.
11. Tsoukalas, L.H. and Uhrig, R.E. (1997). *Fuzzy and neural approaches in engineering*, John Wiley & Sons Incorporated, New York.
12. Wasserman, P.D. (1993). *Advanced methods in neural computing*, Van Nostrand Reinhold, New York.

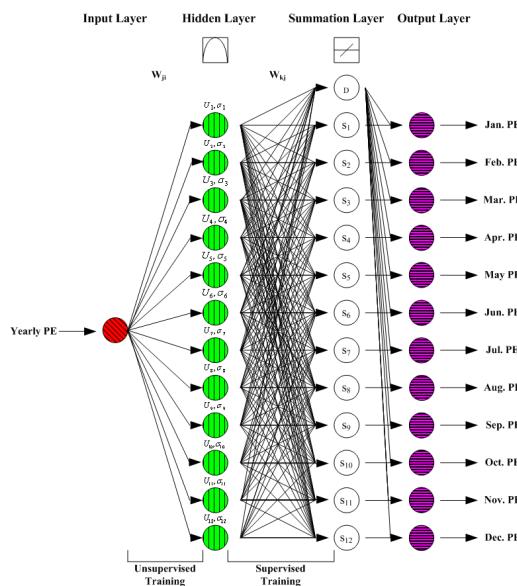


그림 1. GRNNM의 구조

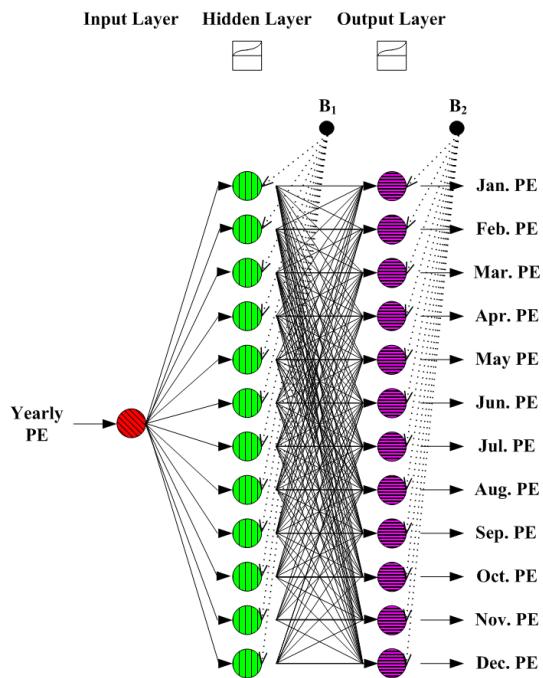


그림 2. MLP-NNM 의 구조

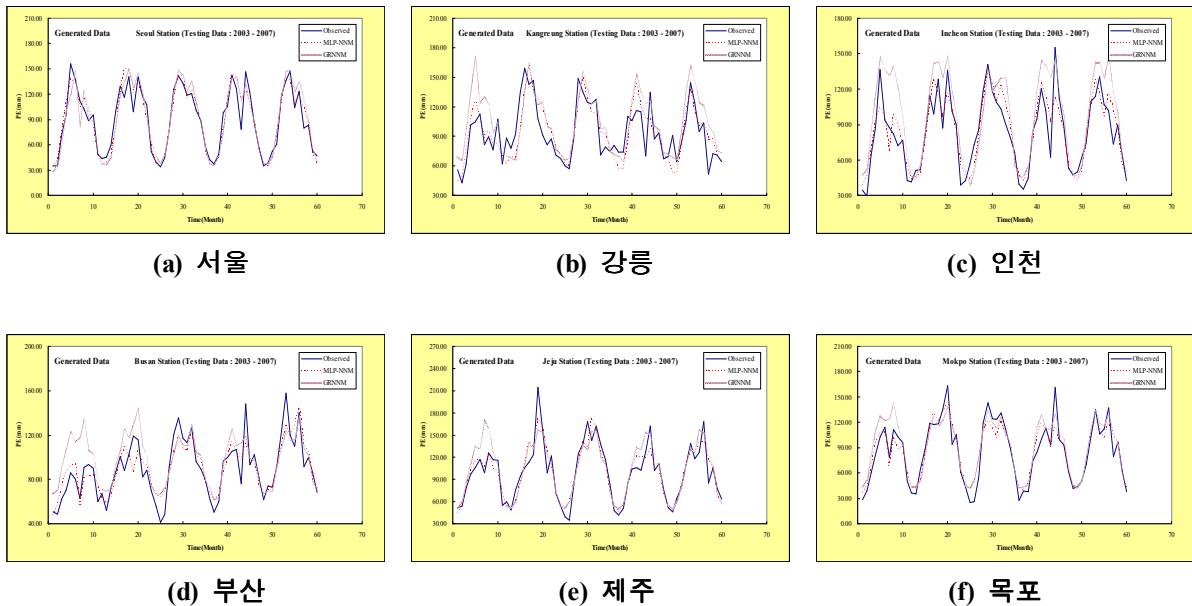


그림 3 증발접시 증발량의 비교 (Testing Data)