

비선형 증발접시 증발량 산정을 위한 시간적 분해모형

The Temporal Disaggregation Model for Nonlinear Pan Evaporation Estimation

김성원* · 김정현** · 박기범*** · 김형수****

Kim, Sungwon · Kim, Jung-Hun · Park, Ki-Bum · Kim, Hung Soo

Abstract

The goal of this research is to apply the neural networks models for the temporal disaggregation of the yearly pan evaporation (PE) data, Republic of Korea. The neural networks models consist of multilayer perceptron neural networks model (MLP-NNM) and generalized regression neural networks model (GRNNM), respectively. And, for the performances evaluation of the neural networks models, they are composed of training and test performances, respectively. The three types of data such as the historic, the generated, and the mixed data are used for the training performance. The only historic data, however, is used for the testing performance. From this research, we evaluate the application of MLP-NNM and GRNNM for the temporal disaggregation of nonlinear time series data. We should, furthermore, construct the credible monthly PE data from the temporal disaggregation of the yearly PE data, and can suggest the available data for the evaluation of irrigation and drainage networks system.

Keywords : pan evaporation, temporal disaggregation model, stochastic model, MLP-NNM, GRNNM

요 지

본 연구의 목적은 연 증발접시 증발량의 시간적인 분해를 위하여 신경망모형을 적용하는데 있다. 신경망모형은 각각 다층 퍼셉트론 신경망모형(MLP-NNM)과 일반화된 회귀신경망모형(GRNNM)으로 구성되어 있다. 그리고 신경망모형의 수행평가를 위하여 훈련 및 테스트과정으로 구성되었다. 신경망모형의 훈련과정을 위하여 실측, 모의 및 혼합자료와 같은 세 가지 형태의 자료가 사용되었으며, 테스트과정을 위해서는 실측자료만 이용되었다. 본 연구를 통하여 비선형 시계열자료의 시간적 분해를 위해서 MLP-NNM과 GRNNM의 적용성을 평가하였다. 게다가 연 증발접시 증발량 자료의 시간적 분해로부터 신뢰성있는 월 증발접시 증발량자료를 구축할 수 있을 것이며, 관개배수 네트워크 시스템의 평가를 위한 이용가능한 자료를 제공할 수 있을 것이다.

핵심용어 : 증발접시 증발량, 시간적 분해모형, 추계학적 모형, MLP-NNM, GRNNM

1. 서 론

증발과정은 자연적 및 농업적인 환경시스템의 에너지와 물 수지의 주요인자를 나타내며, 증발과정에 의한 수분손실량의 추정은 수자원의 모니터링, 조사 및 운영, 관개배수시스템의 설계와 관계계획에 있어서 주요한 인자이다(Molina Martinez *et al.*, 2005; Gundekar *et al.*, 2008). 증발과정은 일반적으로 질량전이(Mass transfer)와 물 수지 방법과 같은 간접적인 방법에 의하여 관측되어 지며, 증발량 관측을 위한 직접적인 방법중 하나는 증발접시 증발량이다(Eslamian *et al.*, 2008). 계획되고 있는 혹은 기존의 저수지를 비롯하여 관개 프로젝트가 있는 모든 지점에 대하여 증발접시를 설치한다는 것은 비현실적이며, 정확한 관측도구가 설치될 수 없거나 혹은 유

지관리가 어려운 접근할 수 없는 지역을 가지는 것 또한 비합리적이다(Kisi, 2006). 증발접시의 이용은 도구적인 제한과 관측오차, 유수의 교란, 조류 혹은 다른 동물들에 의한 유수의 이용뿐만 아니라, 증발량 관측의 정도를 감소시킬 수 있는 여러 가지 유지문제와 같은 실제적인 문제에 의하여 영향을 받는다(Jensen *et al.*, 1990). 증발접시가 이용될 수 없는 곳에서의 증발접시 증발량의 추정에 대한 연구는 수문학자, 농학자 및 기상학자들에게는 중요한 의미를 가지고 있다(Kisi, 2006). 증발과정은 자연현상에서 매우 심한 비선형 관계이며, 증발접시 증발량의 추정에 대한 연구는 진행과정에 있어서 내재적인 비선형성을 나타낼 수 있는 모형을 통하여 접근 할 수 있다(Kisi, 2006; Eslamian *et al.*, 2008).

최근에 많은 연구자들은 증발접시 증발량의 산정에 있어서

*정회원 · 교신저자 · 동양대학교 철도토목학과 부교수 · 공학박사 · 수자원개발기술사 (E-mail : swkim1968@dyu.ac.kr)

**정회원 · 동양대학교 대학원 철도토목학과 석사과정

***정회원 · 동양대학교 철도토목학과 겸임교수 · 공학박사

****정회원 · 인하대학교 사회기반시스템공학부 교수 · 공학박사

신경망이론을 이용한 모형화 기법의 적용성을 증명하여 왔다 (Keskin and Terzi, 2006; Deswal and Pal, 2008; Rahimi Khoob, 2009). Sudheer *et al.*(2002)은 신경망이론을 이용하여 Class A 증발접시 증발량의 예측을 검토하였으며, 예측 결과는 기존의 공식 중에서 Stephens and Stewart 공식과 비교되었다. 그들은 이용할 수 있는 기상인자로부터 증발과정을 모형화 하는데 신경망기법의 이용을 제시하였으며, 온도, 상대습도, 일조시간 및 풍속과 같은 관측된 기상인자들의 적절한 조합을 이용하였다. Bruton *et al.*(2000)은 입력자료로서 관측된 기상인자들을 이용하여 일 증발접시 증발량을 산정하는데 신경망기법을 이용하였다. 또한 일 증발접시 증발량을 다중선형회귀분석 및 Priestly-Taylor 공식을 이용하여 산정하였으며, 신경망모형의 결과치와 비교하였다. 그들은 강우, 온도, 태양열 방사 및 풍속과 같은 관측된 기상인자들의 적절한 조합을 이용하였다. Kisi(2006)는 관측된 기상학적 변수를 이용하여 일 증발접시 증발량을 추정하는데 뉴로-퍼지모형을 이용하였다. 그는 뉴로-퍼지모형을 위하여 온도, 태양열방사, 풍속, 대기압 및 상대습도와 같은 관측된 기상인자들의 적절한 조합을 이용하였다. 그는 이용할 수 있는 기상학적 자료로부터 증발과정을 모형화하는데 있어서 뉴로-퍼지모형이 성공적으로 이용될 수 있다는 것을 나타내었다. 또한 Kim and Kim(2008)은 우리나라에서 일 증발접시 증발량과 알팔파 기준증발산량의 모형화를 위하여 유전자알고리즘이 내재된 신경망모형을 이용하였으며, 입력층노드의 불확실성 분석을 통하여 최적모형을 선정하여, 기뎌해석 및 관계배수 시스템해석을 위한 참고자료를 제공할 수 있는 증발접시 증발량 및 알팔파 기준증발산량의 지도를 구축하였다.

또한 증발접시 증발량의 산정에 있어서 추계학적 모형과 신경망모형을 연계한 연구성과로는 김성원과 김형수(2008)가 월 증발접시 증발량과 월 알팔파 기준증발산량의 모형화를 위하여 추계학적 모형과 신경망모형을 연계한 통합운영방법을 개발하여 적용하였다. 그 결과 통합운영방법을 이용하여 최소비용과 노력으로 월 증발접시 증발량과 월 알팔파 기준증발산량을 동시에 모형화가 가능하게 되었다. 그러나 강우 및 유출량과 같은 비선형 시계열자료에 대한 수문학적 분해 모형의 개발 및 적용에 대한 연구(Burian *et al.*, 2000, 2001; Gutierrez-Magness and McCuen, 2004; Tan, *et al.*, 2007; Zhang *et al.*, 2008; Choi *et al.*, 2008)는 수행된 경험이 있지만, 연 증발접시 증발량자료를 월 증발접시 증발량자료로 분리하는 연구는 아직 수행되지 않았다.

본 연구의 목적은 우리나라 주요 기상관측소에서 관측된 연 증발접시 증발량자료를 제시된 두 가지의 신경망모형을 이용하여 월 증발접시 증발량자료로 분리하고자 한다. 신경망모형을 적용한 시간적 분해모형의 훈련과정 수행을 위해 구성된 훈련자료는 세 가지의 종류로 이루어지며, 각각 실측자료, 모의자료(추계학적 모형을 이용하여 모의발생) 및 혼합자료(실측자료와 추계학적 모형을 이용하여 모의발생시킨 모의자료를 혼합)로 각각 구성된다. 그리고 훈련과정의 수행결과 선정된 최적 매개변수를 이용하여 실측자료로서 테스트 과정을 실시하고자 한다. 또한 본 연구에서는 신경망모형을 이용하여 신뢰성있는 월 증발접시 증발량을 산정할 수 있는 시간적 분해모형의 개발을 제시하고자 한다.

2. 신경망모형과 유전자 알고리즘

2.1 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, 2009). 본 연구에서 적용된 MLP-NNM은 은닉층 1개, 은닉층 노드수는 12개, 출력층 노드수는 12개, 최대 반복횟수는 10,000회, 오차 임계치는 0.001로 설정하였다. 또한 본 연구에서는 QuickProp 역전파 훈련알고리즘을 이용하였다. 따라서 본 연구에서 적용된 MLP-NNM의 출력층 노드중에서 1월, 6월 및 12월의 노드는 다음 식 (1a)-(1c)와 같이 나타낼 수 있으며, 다음 Fig. 1은 본 연구에 적용된 MLP-NNM 구조를 나타낸 것이다.

$$PE_1(t) = \Phi_2 \left[\sum_{j=1}^n W_{1j} \cdot \Phi_1 \left(\sum_{j=1}^{12} W_{ji} \cdot PE_y(t) + B_1 \right) + B_2 \right] \quad (1a)$$

$$PE_6(t) = \Phi_2 \left[\sum_{j=1}^n W_{6j} \cdot \Phi_1 \left(\sum_{j=1}^{12} W_{ji} \cdot PE_y(t) + B_1 \right) + B_2 \right] \quad (1b)$$

$$PE_{12}(t) = \Phi_2 \left[\sum_{j=1}^n W_{12j} \cdot \Phi_1 \left(\sum_{j=1}^{12} W_{ji} \cdot PE_y(t) + B_1 \right) + B_2 \right] \quad (1c)$$




Fig. 1 The developed architecture of MLP-NNM

2.2 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 동일하다. 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 MLP-NNM과는 상당히 다른 양상을 가지고 있다. 입력층과 은닉층 사이에서의 훈련과정은 RBFNNM의 경우처럼 자율훈련(Unsupervised training)으로 구성되어서 K-means나 OLS 알고리즘과 같은 특별한 군집알고리즘을 필요로 하며, 군집알고리즘의 반경은 훈련이 시작하기 전에 결정되어 져야 한다. 또한 은닉층과 합산층 사이에서의 훈련과정은 은닉층에서의 출력값에 대하여 평균제곱오차의 최소화과정에 기초를 둔 지도훈련(Supervised training)으로 구성된다(Specht, 1991; Wasserman, 1993; Tsoukalas and Uhrig, 1997; 김성원 등, 2001).

GRNNM의 입력층과 은닉층사이의 연결함수는 입력벡터인 x_i 에서 중심인 u_{ji} 를 제한 값의 평방합에 대한 제곱근으로 나타내고 있으며, 다음 식 (2)와 같이 나타낼 수 있다.

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

여기서 아랫첨자 i, j 는 각각 입력층과 은닉층을 나타내고 있으며, R_j 는 입력벡터들 사이의 반경거리를 나타내며 입력벡터는 다음 식 (3)과 같이 나타낼 수 있다.

$$X = [x_1, x_2, \dots, x_m]^T \quad (3)$$

여기서 반경중심 $U^{(j)}$ 는 다음 식 (4)와 같이 나타낼 수 있다.

$$U^{(j)} = [u_{j1}, u_{j2}, \dots, u_{jm}]^T \quad (4)$$

그리고 식 (2)는 다음 식 (5)와 같이 나타낼 수 있다.

$$R_j = \|X - U^{(j)}\| \quad (5)$$

여기서 $\|\cdot\|$ 은 유클리드 거리(Euclidean length)이다. R_j 를 은닉층의 전이함수에 $\Phi_1(\cdot)$ 적용하면 다음 식 (6)과 같이 나타낼 수 있다.

$$S_j = \Phi_1(R_j) = \Phi_1(\|X - U^{(j)}\|) \quad (6)$$

은닉층의 전이함수 $\Phi_1(\cdot)$ 는 반경기초함수가 주로 광범위

하게 사용된다. 본 연구에서는 가우시안 핵함수(GKF)가 사용되었으며, 입력벡터값이 0일 경우에 최대값은 1이고 입력벡터와 중심사이의 거리가 감소함에 따라서 출력벡터의 값은 증가한다. GKF는 다음 식 (7)과 같이 나타낼 수 있다.

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

여기서 B_1 는 $\frac{1}{2\sigma^2}$ 으로 나타내고 보통 일정한 값을 가지며, 는 반경기초함수의 폭을 나타내고 있다. 합산층은 S_j 와 은닉층과 합산층의 연결강도벡터의 연산 결과치를 받으며 다음 식 (8)과 같이 나타낼 수 있다.

$$T_k = \sum_{j=1}^n W_{kj} \cdot S_j = \sum_{j=1}^n W_{kj} \cdot \Phi_1(\|X - U^{(j)}\|) \quad (8)$$

여기서 아랫첨자 k 는 합산층, T_k 는 합산층에서 연산값, W_{kj} 는 은닉층과 합산층 사이의 연결강도를 나타내며 식 (8)로부터 합산층에서의 1번, 6번 및 12번 합산노드와 제법노드의 연산은 식 (9a)-(9d)와 같이 나타낼 수 있다.

$$S_1 = \Phi_2\left(\sum_{j=1}^n W_{1j} \cdot \Phi_1(\|X - U^{(j)}\|)\right) \quad (9a)$$

$$S_6 = \Phi_2\left(\sum_{j=1}^n W_{6j} \cdot \Phi_1(\|X - U^{(j)}\|)\right) \quad (9b)$$

$$S_{12} = \Phi_2\left(\sum_{j=1}^n W_{12j} \cdot \Phi_1(\|X - U^{(j)}\|)\right) \quad (9c)$$

$$D_1 = \sum_{j=1}^n W_{13j} \cdot \Phi_1(\|X - U^{(j)}\|) \quad (9d)$$

여기서 $\Phi_2(\cdot)$ 는 합산층의 전이함수이며, 본 연구에서는 선형 전이함수(Pure linear transfer function, PLTF)를 사용하였다. 또한 S_1 은 1번 합산노드의 연산된 값, S_6 은 6번 합산노드의 연산된 값, S_{12} 는 12번 합산노드의 연산된 값이고 D_1 은 제법노드의 연산된 값을 나타내고 있다. 마지막으로 출력층노드의 함수는 각 합산노드의 연산된 값을 하나의 제법노드의 연산된 값을 단순히 나누어서 구성되어 진다. 본 연구에서 적용된 GRNNM의 출력층 노드중에서 1월, 6월 및 12월의 노드는 다음 식 (10a)-(10c)와 같이 나타낼 수 있다.

$$FE_1(t) = \frac{S_1}{D_1} \quad (10a)$$

$$PE_6(t) = \frac{S_6}{D_1} \quad (10b)$$

$$PE_{12}(t) = \frac{S_{12}}{D_1} \quad (10c)$$

여기서 $PE_1(t)$ 는 계산된 1월 증발접시 증발량, $PE_6(t)$ 는 계산된 6월 증발접시 증발량이고 $PE_{12}(t)$ 는 계산된 12월 증발접시 증발량이다. 본 연구에서 적용된 GRNNM는 은닉층 1개, 클러스터 센터는 20개, 은닉층 노드수는 12개, 합산층

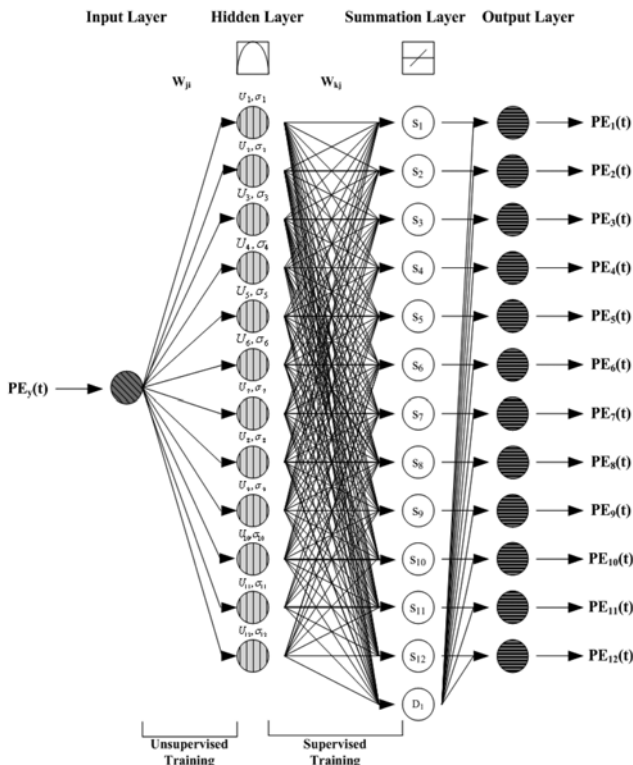


Fig. 2 The developed architecture of GRNNM

노드수는 13개, 출력층 노드수는 12개, 최대 반복횟수는 10,000회, 오차 임계치는 0.001로 설정하였다. 또한 본 연구에서 지도훈련(Supervised training)의 경우 QuickProp 역전파 훈련알고리즘을 이용하였다. 다음 Fig. 2은 본 연구에 적용된 GRNNM 구조를 나타낸 것이다.

2.3 유전자 알고리즘(Genetic Algorithm, GA)

본 연구에서 GA에 의한 GRNNM의 훈련과정은 입력층노드와 매개변수인 연결강도의 초기화 과정으로부터 시작한다. 이때 GRNNM의 출력층에서의 전반적인 오차는 목적함수의 최적치로서 계산되어 진다. 또한 충분한 수의 세대가 진행된 후에 광역 해(Global solution)에 도달하는 것을 목표로 하여 하나의 세대에서 다음 세대로 반복되어 진다. 일반적으로 GA에서 모집단의 크기에 대한 설정은 각 목적에 따라 영향을 끼치므로 이에 대한 추가적인 연구가 필요하다(Deb, 2001). 따라서 본 연구에서는 연결강도 갱신을 위하여 세대의 모집단의 크기는 100으로 설정하여 시도하였으며, 최적값이 1%라도 개선되지 않는 20세대에 대하여 자동으로 종료하는 과정 및 신경망모형의 출력층에서 선정된 허용오차의 수렴에 도달할 때까지 한 세대에서 다음 세대로 반복되는 과정을 설정하였다. 본 연구에서 GA의 적용과정은 첫 번째는 훈련자료를 이용하여 GRNNM을 훈련시키는 것이며, 두 번째는 첫 번째 과정에서 형성된 GRNNM을 이용하여 테스트자료에 대한 최적운영을 위하여 전 범위를 검토하는 것이다(Kim and Kim, 2008). GA는 각 입력층노드에 대한 평활인자 승수(Multiplier)를 찾고 있으며, 비록 훈련과정에 대하여 탐색기법으로 GA를 사용하지 않은 경우보다 시간은 좀 더 걸리지만 테스트자료에 대하여 가장 양호하게 운영될 수 있는 GRNNM을 구성할 수 있다(Neuroshell 2, 1993).

3. 추계학적 모형

주기성 자기회귀이동평균 모형은 주기성 자기회귀(Periodic Autoregression, PAR)모형에 주기성의 이동평균 매개변수를 포함하여 확장하며 일반적으로 PARMA(p,q)로 나타낸다. 저차수의 PARMA 모형은 주기적인 수문시계열의 모형화에 사용된다. 예를 들면 PARMA (1,1) 모형은 다음 식 (11)과 같이 나타낼 수 있다.

$$y_{v, \tau} = \mu_{\tau} + \Phi_{1, \tau}(y_{v, \tau-1} - \mu_{\tau-1}) + \varepsilon_{v, \tau} - \theta_{1, \tau} \varepsilon_{v, \tau-1} \quad (11)$$

여기서 v 는 년(year), τ 는 계절(Season)이고 $\tau = 1, 2, \dots, \omega$ 이며 계절수를 나타내고 있다. 식 (11)과 같은 모형은 주로 월 유출량계열에 적용된다(Salas *et al.*, 1980). 본 연구에서는 선행연구(김성원과 김형수, 2008)에서 월 증발접시 증발량 및 PM 공식에 의해 산정된 월 알팔파 기준증발산량 훈련자료를 모의발생시켜 가장 양호한 결과를 유도한 PARMA (1,1) 모형을 이용하였다. 그리고 모의발생한 표본은 2개의 표본으로 하였으며, 500년에 해당되는 월 증발접시 증발량을 모의발생 시켰다. 모의된 자료 중에서 첫 번째 표본자료는 선택하지 않았으며, 두 번째 표본자료를 선택하였다. 또한 두 번째 표본자료에서 초기에 발생하는 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(Kim, 2004).

4. 연구대상의 선정 및 자료

본 연구에서는 기상청의 관리 하에 있는 76개의 기상관측소 중에서 기상관측 자료의 기록기간이 장기, 중기 및 단기 간의 자료를 보유하고 있어야 하며, 각 권역을 대표할 수 있는 도시와 도서지역인 제주도에 소속된 기상관측소를 포함하는 것을 기준으로 하여 선정하였다. 따라서 연구대상 기상관측소는 서울, 강릉, 인천, 부산, 제주 및 목포관측소를 선정하였다. 본 연구에 필요한 기상자료는 국토해양부의 관리 하에 있는 국가 수자원관리종합정보시스템(Water management information system, WAMIS)의 홈페이지(www.wamis.go.kr)의 무료 공개자료로 부터 필요한 자료를 이용하였다. 본 연구에서 장기간 자료를 보유하고 있는 기상관측소로는 서울과 강릉관측소를 선정하였다. 서울관측소의 경우 1907년 10월에 기상관측을 실시한 이후 1919년, 1950-1953년 및 1991-1994년의 자료가 결측되어 있으나, 자료의 신뢰성이 양호한 상태이다. 강릉관측소의 경우 1912년 1월에 기상관측을 실시한 이후에 1919년, 1950-1951년 자료가 결측되어 있으나, 서울관측소의 경우처럼 자료의 신뢰성이 양호한 상태이다. 중기간 자료를 보유하고 있는 기상관측소로는 인천과 부산 관측소를 선정하였다. 인천관측소의 경우 1949년 1월에 기상관측을 실시한 이후에 1950-1951년 자료가 결측되어 있으나, 자료의 신뢰성은 양호하다. 그리고 부산관측소의 경우 1965년 1월부터 기상관측을 실시하였고 결측자료는 없는 상태이며, 자료의 신뢰성은 양호하다. 마지막으로 단기간 자료를 보유하고 있는 기상관측소로는 제주와 목포관측소를 선정하였다. 제주 및 목포관측소의 경우 1980년 1월부터 기상

관측을 실시하였고 결측자료는 없는 상태이며, 자료의 신뢰성은 양호하다.

5. 훈련과정의 수행

신경망을 이용한 문제해석에서 결정되지 않은 문제들 중 하나가 어떠한 형태의 신경망구조가 주어진 문제에 대하여 가장 적절하게 사용되는가의 문제라고 할 수 있다. 일반적으로 바람직한 신경망구조는 적은 수의 은닉층 노드를 포함하고 있으며, 실제 함수의 양호한 접근성에 대한 연결강도가 필요하다. 신경망모형의 구조는 시산법의 과정 후에 결정되어진다. 신경망모형의 구조가 너무 작은 경우에는 정확하게 학습하기 위한 충분한 자유도를 가지지 않으며, 신경망모형의 구조가 너무 큰 경우에는 훈련동안에 수렴이 되지 않거나 자료를 과대평가하는 경향이 있다(Kim et al., 2009).

5.1 최적모형선정을 위한 통계지표

본 연구에서 적용된 MLP-NNM 및 GRNNM의 훈련 및 테스트과정의 수행결과는 실측된 월 증발접시 증발량과 MLP-NNM 및 GRNNM에 의해 산정된 월 증발접시 증발량의 통계분석에 의하여 평가되도록 하였다. 본 연구에서 선정된 통계학적 지표는 상관계수(Correlation coefficient, CC), 평균제곱오차의 평방근(Root mean square error, RMSE), Nash-Sutcliffe 계수(Nash-Sutcliffe coefficient, E) 및 평균절대 상대오차(Average absolute relative error, AARE)이다. 다음 Table 1은 MLP-NNM 및 GRNNM의 수행결과를 평가하기 위한 통계학적 지표를 나타낸 것이다. 여기서 $\bar{y}_i(x)$ = 계산된 월 증발접시 증발량(mm), $y_i(x)$ = 실측된 월 증발접시 증발량(mm), \bar{u}_y = 계산된 월 증발접시 증발량의 평균(mm), u_y = 실측된 월 증발접시 증발량의 평균(mm) 및 n=고려된

Table 1. Summary of statistical index

| Index | Equation | Model Evaluation |
|-------|---|------------------|
| CC | $\frac{\frac{1}{n} \sum_{i=1}^n [y_i(x) - u_y][\bar{y}_i(x) - \bar{u}_y]}{\sqrt{\frac{1}{n} \sum_{i=1}^n [y_i(x) - u_y]^2} \sqrt{\frac{1}{n} \sum_{i=1}^n [\bar{y}_i(x) - \bar{u}_y]^2}}$ | Efficiency |
| RMSE | $\sqrt{\frac{1}{n} \sum_{i=1}^n [\bar{y}_i(x) - y_i(x)]^2}$ | Efficiency |
| E | $1 - \frac{\sum_{i=1}^n [y_i(x) - \bar{y}_i(x)]^2}{\sum_{i=1}^n [y_i(x) - u_y]^2}$ | Efficiency |
| AARE | $\frac{1}{n} \sum_{i=1}^n \left \frac{\bar{y}_i(x) - y_i(x)}{y_i(x)} \right \times 100\%$ | Effectiveness |

월 증발접시 증발량의 총수이다. AARE의 통계학적 지표는 훈련된 모형으로부터 정확하게 월 증발접시 증발량을 모형화하는데 있어서 모형의 유효성(Effectiveness)을 평가하며, 그 외의 CC, RMSE 및 E의 통계학적 지표는 복잡하고 비선형의 자연현상을 기록할 수 있는 모형의 효율(Efficiency)을 정량화한다(Kim and Kim, 2008).

5.2 실측자료의 이용

본 연구의 실측자료의 이용을 위한 훈련자료는 다음과 같다. 장기간의 자료로는 서울관측소의 경우는 1908년부터 2002년까지의 결측기간을 제외한 86년의 자료를 선택하였으며, 강릉관측소의 경우는 1912년부터 2002년까지의 결측기간을 제외한 88년의 자료를 선택하였다. 중기간의 자료로는 인천관측소의 경우는 1949년부터 2002년까지의 결측기간을 제외한 52년의 자료를 선택하였다. 부산관측소의 경우는 1965년부터 2002년까지의 38년의 자료를 선택하였다. 그리고 단기간의 자료로는 제주 및 목포관측소의 경우는 1980년부터 2002년까지의 23년의 자료를 선택하였다. 그리고 MLP-NNM과 GRNNM의 훈련과정에 따른 선행과정으로 입력층자료인 연 증발접시 증발량자료를 표준화하여 적용하였다. 일반적으로 입력층자료들을 표준화하는 주요한 이유 중 하나는 각 입력층자료들이 서로 다른 단위로서 관측된 값들을 나타내

Table 2. Statistical analysis of the monthly PE for the training performance (Historic data)

| Station | Statistical Index | Neural Networks Model | |
|-----------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Seoul | CC | 0.948 | 0.889 |
| | RMSE | 13.970 | 20.295 |
| | E | 0.899 | 0.787 |
| | AARE | 0.0018 | 0.0028 |
| Kangreung | CC | 0.869 | 0.714 |
| | RMSE | 18.775 | 27.560 |
| | E | 0.754 | 0.471 |
| | AARE | 0.0027 | 0.0030 |
| Incheon | CC | 0.948 | 0.877 |
| | RMSE | 12.836 | 19.513 |
| | E | 0.898 | 0.764 |
| | AARE | 0.0024 | 0.0034 |
| Busan | CC | 0.899 | 0.745 |
| | RMSE | 11.733 | 18.708 |
| | E | 0.808 | 0.511 |
| | AARE | 0.0029 | 0.0038 |
| Jeju | CC | 0.963 | 0.832 |
| | RMSE | 10.678 | 23.019 |
| | E | 0.928 | 0.665 |
| | AARE | 0.0035 | 0.0073 |
| Mokpo | CC | 0.985 | 0.974 |
| | RMSE | 5.963 | 7.847 |
| | E | 0.970 | 0.949 |
| | AARE | 0.0013 | 0.0022 |

고 있기 때문에 이러한 입력층자료들을 표준화하고 무차원 단위에서 입력층자료들을 재배치함으로써, 각 입력층자료들의 상사성의 효과를 제거하기 위한 것으로 판단된다(Kim and Kim, 2008; Kim *et al.*, 2009). 다음 Table 2는 실측자료를 이용한 MLP-NNM과 GRNNM의 훈련과정의 수행결과를 나타내고 있다. Table 2에 의하면 MLP-NNM의 훈련과정의 수행결과에 대한 통계분석 결과 CC가 0.869~0.985, RMSE가 5.963~18.775(mm), E가 0.754~0.970 및 AARE가 0.0013~0.0035(%)이고, GRNNM의 훈련과정의 수행결과에 대한 통계분석 결과 CC가 0.714~0.974, RMSE가 7.847~27.560(mm), E가 0.471~0.949 및 AARE가 0.0022~0.0073(%)으로 분석되었다. 따라서 선택된 6개의 기상관측소에서 MLP-NNM의 훈련과정의 수행결과가 GRNNM의 훈련과정의 수행결과보다 양호한 것으로 분석되었다.

5.3 모의자료의 이용

본 연구의 모의자료의 이용을 위한 훈련자료는 “5.2 실측자료의 이용”에서 실측된 월 증발접시 증발량자료를 모의자료의 구축을 위하여 이용하였다. 따라서 MLP-NNM 및 GRNNM의 훈련과정을 위한 입력층자료는 본 연구에서 선택한 추계학적 모형인 PARMA (1,1)을 이용하여 500년의

자료를 모의발생시켰다. 모의발생된 월 증발접시 증발량자료 중에서 초기에 발생하는 편차(Bias)를 제거하기 위하여 초기의 50년 자료는 제거하였으며, 나머지 450년의 월 증발접시 증발량자료를 이용하였다. 따라서 입력층자료에 해당하는 연 증발접시 증발량은 각 월 증발접시 증발량자료를 합하여 선정하였다. 그러므로 MLP-NNM 및 GRNNM의 훈련과정을 위한 입력층자료는 450개의 모의된 연 증발접시 증발량자료로 구성되어 있다. 다음 Table 3은 모의자료를 이용한 MLP-NNM과 GRNNM의 훈련과정의 수행결과를 나타내고 있다. Table 3에 의하면 MLP-NNM의 훈련과정의 수행결과에 대한 통계분석 결과 CC가 0.853~0.941, RMSE가 12.026~19.579 (mm), E가 0.727~0.886 및 AARE가 0.0003~0.0006(%)이고, GRNNM의 훈련과정에 대한 통계분석 결과 CC가 0.790~0.910, RMSE가 14.574~22.967(mm), E가 0.623~0.827 및 AARE가 0.0004~0.0008(%)으로 분석되었다. 따라서 선택된 6개의 기상관측소에서 MLP-NNM의 훈련과정의 수행결과가 GRNNM의 훈련과정의 수행결과보다 양호한 것으로 분석되었다.

5.4 혼합자료의 이용

본 연구의 혼합자료의 이용을 위한 훈련자료는 “5.2 실측자료의 이용”에서 실측된 월 증발접시 증발량자료와 “5.3

Table 3. Statistical analysis of the monthly PE for the training performance (Generated data)

| Station | Statistical Index | Neural Networks Model | |
|-----------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Seoul | CC | 0.940 | 0.906 |
| | RMSE | 14.869 | 18.423 |
| | E | 0.884 | 0.821 |
| | AARE | 0.0004 | 0.0005 |
| Kangreung | CC | 0.853 | 0.790 |
| | RMSE | 19.579 | 22.967 |
| | E | 0.727 | 0.624 |
| | AARE | 0.0006 | 0.0008 |
| Incheon | CC | 0.938 | 0.893 |
| | RMSE | 13.710 | 17.817 |
| | E | 0.880 | 0.797 |
| | AARE | 0.0003 | 0.0005 |
| Busan | CC | 0.873 | 0.790 |
| | RMSE | 13.132 | 16.495 |
| | E | 0.761 | 0.623 |
| | AARE | 0.0003 | 0.0004 |
| Jeju | CC | 0.941 | 0.906 |
| | RMSE | 13.409 | 16.824 |
| | E | 0.886 | 0.820 |
| | AARE | 0.0003 | 0.0004 |
| Mokpo | CC | 0.939 | 0.910 |
| | RMSE | 12.026 | 14.574 |
| | E | 0.883 | 0.827 |
| | AARE | 0.0003 | 0.0004 |

Table 4. Statistical analysis of the monthly PE for the training performance (Mixed data)

| Station | Statistica Index | Neural Networks Model | |
|-----------|------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Seoul | CC | 0.940 | 0.910 |
| | RMSE | 14.842 | 18.118 |
| | E | 0.884 | 0.828 |
| | AARE | 0.0003 | 0.0013 |
| Kangreung | CC | 0.854 | 0.786 |
| | RMSE | 19.508 | 23.217 |
| | E | 0.730 | 0.618 |
| | AARE | 0.0005 | 0.0006 |
| Incheon | CC | 0.938 | 0.898 |
| | RMSE | 13.707 | 17.471 |
| | E | 0.880 | 0.806 |
| | AARE | 0.0003 | 0.0004 |
| Busan | CC | 0.873 | 0.798 |
| | RMSE | 13.108 | 16.221 |
| | E | 0.762 | 0.636 |
| | AARE | 0.0003 | 0.0004 |
| Jeju | CC | 0.941 | 0.906 |
| | RMSE | 13.398 | 16.781 |
| | E | 0.886 | 0.821 |
| | AARE | 0.0003 | 0.0004 |
| Mokpo | CC | 0.940 | 0.910 |
| | RMSE | 11.994 | 14.556 |
| | E | 0.883 | 0.828 |
| | AARE | 0.0003 | 0.0004 |

모의자료의 이용"에서 선정된 월 증발접시 증발량자료를 합한 혼합자료로 구성하였다. 따라서 MLP-NNM 및 GRNNM의 훈련과정을 위한 입력층 자료수는 각각 서울관측소는 536개, 강릉관측소는 538개, 인천관측소는 502개, 부산관측소는 488개, 제주 및 목포관측소는 473개의 혼합된 연 증발접시 증발량자료로 구성되어 있다. 다음 Table 4는 혼합자료를 이용한 MLP-NNM과 GRNNM의 훈련과정의 수행결과를 나타내고 있다. Table 4에 의하면 MLP-NNM의 훈련과정의 수행결과에 대한 통계분석 결과 CC가 0.854~0.941, RMSE가 11.994~19.508(mm), E가 0.730~0.886 및 AARE가 0.0003~0.0005(%)이고, GRNNM의 훈련과정의 수행결과에 대한 통계분석 결과 CC가 0.786~0.910, RMSE가 14.556~23.217(mm), E가 0.618~0.828 및 AARE가 0.0004~0.0013(%)으로 분석되었다. 따라서 선택된 6개의 기상관측소에서 MLP-NNM의 훈련과정의 수행결과가 GRNNM의 훈련과정의 수행결과보다 양호한 것으로 분석되었다. 또한 MLP-NNM의 경우 선택된 6개의 기상관측소에서 실측자료를 이용한 훈련과정의 수행결과가 모의자료 및 혼합자료를 이용한 훈련과정의 수행결과보다 양호한 것으로 분석되었다. GRNNM의 경우 목포관측소를 제외하고는 모의자료 및 혼합자료를 이용한 훈련과정의 수행결과가 실측자료를 이용한 훈련과정의 수행결과보다 양호한 것으로 분석되었다.

6. 테스트과정의 수행

테스트과정은 몇 개의 범주 이내에서 신경망모형이 모형화의 목적을 충분히 충족시킬 수 있을지에 대하여 검증하는 과정을 의미하고 있다. 따라서 신경망모형이 훈련과정을 통하여 선정된 각각의 매개변수를 이용하여 새로운 자료인 테스트자료로서 검증하는 과정이다. 본 연구에서 MLP-NNM 및 GRNNM의 경우 실측자료, 모의자료 및 혼합자료를 이용하여 훈련과정이 이루어 졌으므로 총 6종류의 매개변수 군을 훈련과정을 통하여 선정할 수 있다. 또한 훈련과정의 경우 각각 실측자료, 모의자료 및 혼합자료를 이용하였으므로, 그 결과치를 비교한다는 것은 큰 의미가 없을 수도 있다. 그러나 테스트과정의 경우 6개 기상관측소에서 동일한 시계열을 이용함으로써 어떤 종류의 신경망모형과 훈련자료가 가장 양호한 것인지를 판단할 수 있는 기준을 제시할 수 있을 것으로 판단된다.

6.1 실측자료의 이용

본 연구에서는 실측자료를 이용한 훈련과정을 통하여 선정된 MLP-NNM과 GRNNM의 매개변수를 이용하여 테스트과정을 실시하였다. 테스트과정에서 테스트자료는 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 동일한 시계열인 2003년부터 2007년까지의 5년간의 자료를 선택하였으며, 5개의 자료로 구성되어 있다. 다음 Table 5는 실측자료를 이용한 훈련과정의 수행결과 선정된 매개변수를 이용하여 MLP-NNM과 GRNNM의 테스트과정의 수행결과를 나타내고 있다. Table 5에 의하면 MLP-NNM의 테스트과정에 대한 통계분석 결과 CC가 0.789~0.952, RMSE가 11.800~20.015(mm),

Table 5. Statistical analysis of the monthly PE for the testing performance (Historic data)

| Station | Statistical Index | Neural Networks Model | |
|-----------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Seoul | CC | 0.952 | 0.903 |
| | RMSE | 11.800 | 20.596 |
| | E | 0.899 | 0.692 |
| | AARE | 0.0004 | 0.1407 |
| Kangreung | CC | 0.801 | 0.735 |
| | RMSE | 18.037 | 25.362 |
| | E | 0.574 | 0.158 |
| | AARE | 0.0189 | 0.1603 |
| Incheon | CC | 0.825 | 0.866 |
| | RMSE | 18.452 | 25.240 |
| | E | 0.643 | 0.332 |
| | AARE | 0.0066 | 0.3160 |
| Busan | CC | 0.789 | 0.643 |
| | RMSE | 16.195 | 24.204 |
| | E | 0.615 | 0.140 |
| | AARE | 0.0115 | 0.1328 |
| Jeju | CC | 0.875 | 0.885 |
| | RMSE | 18.504 | 27.396 |
| | E | 0.763 | 0.480 |
| | AARE | 0.0306 | 0.2325 |
| Mokpo | CC | 0.837 | 0.852 |
| | RMSE | 20.015 | 19.087 |
| | E | 0.695 | 0.723 |
| | AARE | 0.0312 | 0.0585 |

E가 0.574~0.899 및 AARE가 0.0004~0.0312(%)이고, GRNNM의 테스트과정에 대한 통계분석 결과 CC가 0.643~0.903, RMSE가 19.087~27.396(mm), E가 0.140~0.723 및 AARE가 0.0585~0.3160(%)으로 분석되었다. 따라서 선택된 6개의 기상관측소에서 실측자료를 이용한 경우 MLP-NNM의 테스트과정의 수행결과와 GRNNM의 테스트과정의 수행결과를 비교해보면 어떤 종류의 신경망모형이 더 양호한 것으로 설명하기에는 불가능한 것으로 판단된다. 다음 Fig. 3(a)-(f)는 서울, 강릉, 인천, 부산, 제주 및 목포관측소의 실측자료를 이용한 훈련과정의 수행결과를 이용하여 MLP-NNM과 GRNNM의 테스트과정의 수행결과에 대한 월 증발접시 증발량자료의 시계열의 비교를 나타낸 것이다.

6.2 모의자료의 이용

본 연구에서는 모의자료를 이용한 훈련과정을 통하여 선정된 MLP-NNM과 GRNNM의 매개변수를 이용하여 테스트과정을 실시하였다. 테스트과정에서 테스트자료는 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 동일한 시계열인 2003년부터 2007년까지의 5년간의 자료를 선택하였으며, 5개의 자료로 구성되어 있다. 다음 Table 6는 모의자료를 이용한 훈련과정의 수행결과 선정된 매개변수를 이용하여 MLP-NNM과 GRNNM의 테스트과정의 수행결과를 나타내고 있

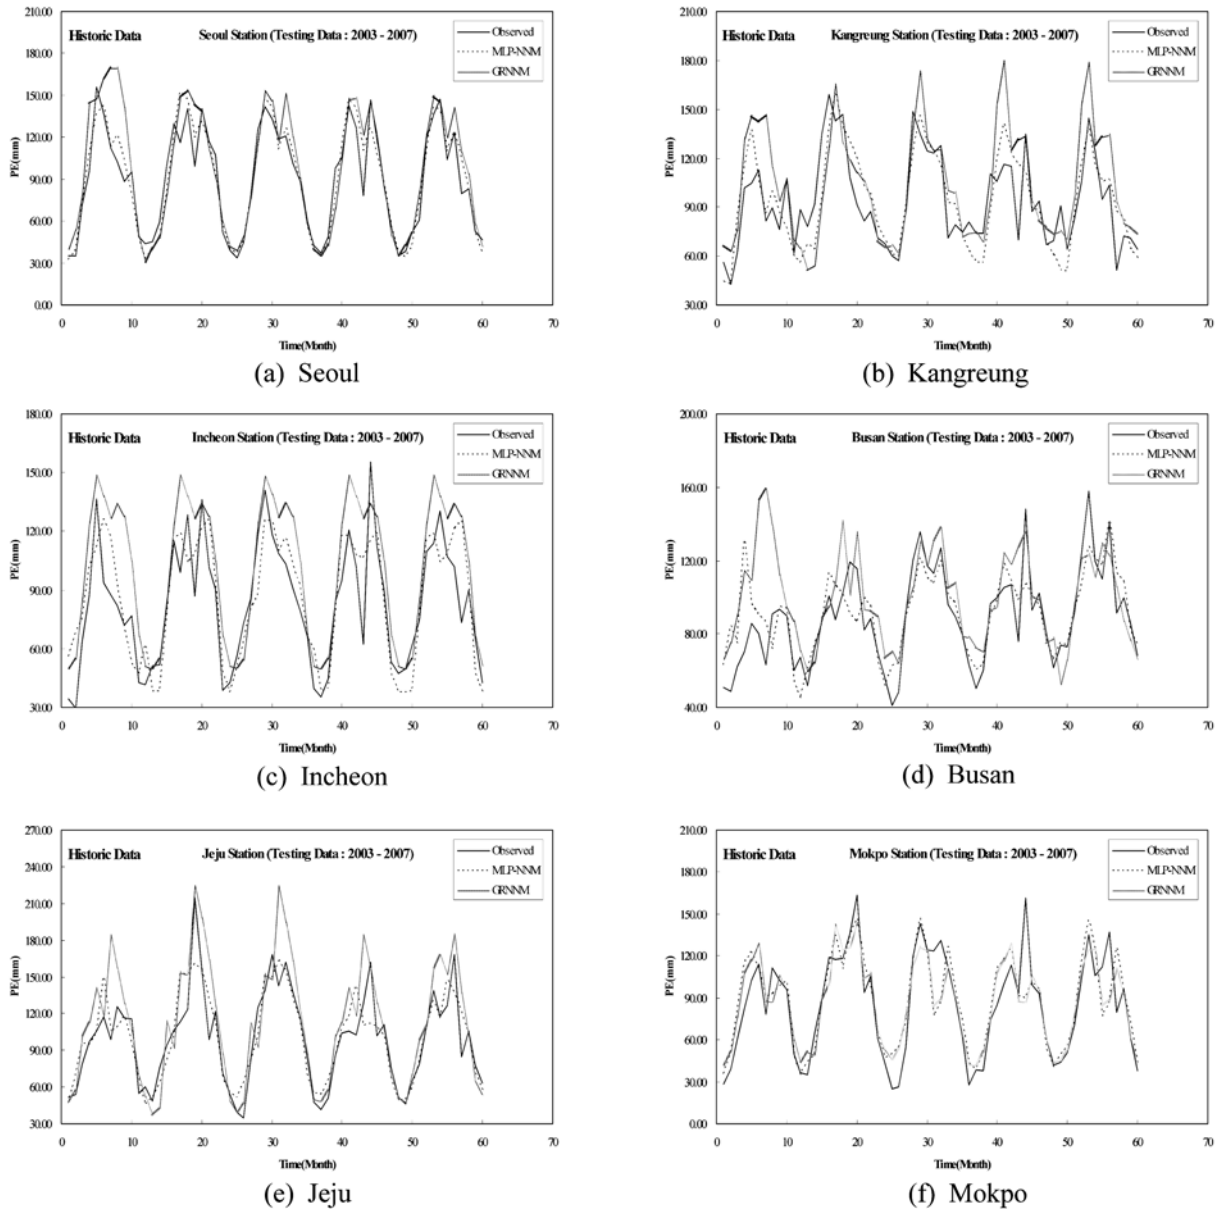


Fig. 3 Comparison of the monthly PE for the testing performance (Historic data)

다. Table 6에 의하면 MLP-NNM의 테스트과정에 대한 통계분석 결과 CC 가 0.811~0.952, $RMSE$ 가 11.733~16.999(mm), E 가 0.622~0.900 및 $AARE$ 가 0.0065~0.0509(%)이고, GRNNM의 테스트과정에 대한 통계분석 결과 CC 가 0.754~0.941, $RMSE$ 가 13.474~24.188(mm), E 가 0.300~0.868 및 $AARE$ 가 0.0191~0.2659(%)으로 분석되었다. 따라서 선택된 6개의 기상관측소에서 모의자료를 이용한 경우 MLP-NNM의 테스트과정의 수행결과가 GRNNM의 테스트과정의 수행결과보다 양호한 것으로 분석되었다. 다음 Fig. 4(a)-(f)는 서울, 강릉, 인천, 부산, 제주 및 목포관측소의 모의자료를 이용한 훈련과정의 수행결과를 이용하여 MLP-NNM과 GRNNM의 테스트과정의 수행결과에 대한 월 증발집시 증발량자료의 시계열의 비교를 나타낸 것이다.

6.3 혼합자료의 이용

본 연구에서는 혼합자료를 이용한 훈련과정을 통하여 선정된 MLP-NNM과 GRNNM의 매개변수를 이용하여 테스트과정을 실시하였다. 테스트과정에서 테스트자료는 서울, 강릉,

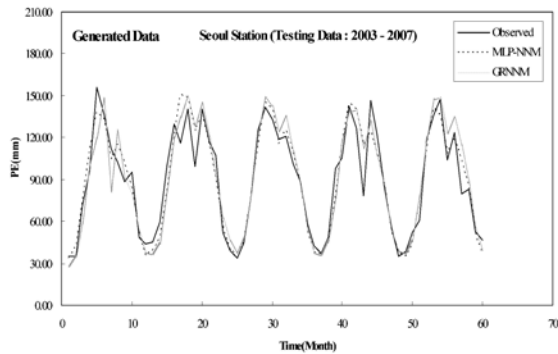
인천, 부산, 제주 및 목포관측소에서 동일한 시계열인 2003년부터 2007년까지의 5년간의 자료를 선택하였으며, 5개의 자료로 구성되어 있다. 다음 Table 7는 혼합자료를 이용한 훈련과정의 수행결과 산정된 매개변수를 이용하여 MLP-NNM과 GRNNM의 테스트과정의 수행결과를 나타내고 있다. Table 7에 의하면 MLP-NNM의 테스트과정에 대한 통계분석 결과 CC 가 0.811~0.952, $RMSE$ 가 11.808~17.086(mm), E 가 0.618~0.899 및 $AARE$ 가 0.0003~0.0320(%)이고, GRNNM의 테스트과정에 대한 통계분석 결과 CC 가 0.746~0.950, $RMSE$ 가 12.472~23.834(mm), E 가 0.256~0.887 및 $AARE$ 가 0.0355~0.2502(%)으로 분석되었다. 따라서 선택된 6개의 기상관측소에서 혼합자료를 이용한 경우 MLP-NNM의 테스트과정의 수행결과가 GRNNM의 테스트과정의 수행결과보다 양호한 것으로 분석되었다. 다음 Fig. 5(a)-(f)는 서울, 강릉, 인천, 부산, 제주 및 목포관측소의 혼합자료를 이용한 훈련과정의 수행결과를 이용하여 MLP-NNM과 GRNNM의 테스트과정의 수행결과에 대한 월 증발집시 증발량자료의 시계열의 비교를 나타낸 것이다.

Table 6. Statistical analysis of the monthly PE for the testing performance (Generated data)

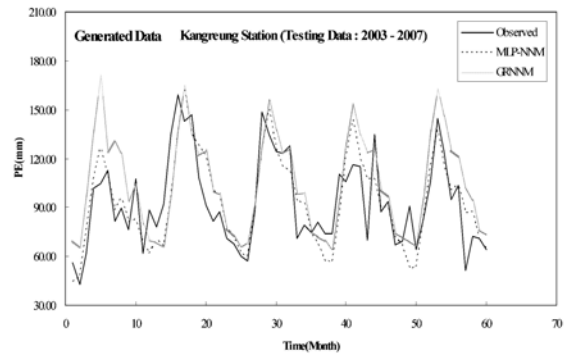
| Station | Statistical Index | Neural Networks Model | |
|-----------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Seoul | CC | 0.952 | 0.941 |
| | RMSE | 11.733 | 13.474 |
| | E | 0.900 | 0.868 |
| | AARE | 0.0065 | 0.0191 |
| Kangreung | CC | 0.811 | 0.754 |
| | RMSE | 16.999 | 23.117 |
| | E | 0.622 | 0.300 |
| | AARE | 0.0253 | 0.1581 |
| Incheon | CC | 0.896 | 0.855 |
| | RMSE | 13.762 | 24.188 |
| | E | 0.801 | 0.386 |
| | AARE | 0.0272 | 0.2659 |

Table 6. Continued


| Station | Statistical Index | Neural Networks Model | |
|---------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Busan | CC | 0.885 | 0.769 |
| | RMSE | 12.314 | 19.064 |
| | E | 0.777 | 0.466 |
| | AARE | 0.0291 | 0.1092 |
| Jeju | CC | 0.928 | 0.876 |
| | RMSE | 14.134 | 19.182 |
| | E | 0.862 | 0.745 |
| | AARE | 0.0318 | 0.0334 |
| Mokpo | CC | 0.945 | 0.921 |
| | RMSE | 12.550 | 15.410 |
| | E | 0.880 | 0.819 |
| | AARE | 0.0509 | 0.0562 |




(a) Seoul




(b) Kangreung




(c) Incheon



(d) Busan



(e) Jeju



(f) Mokpo

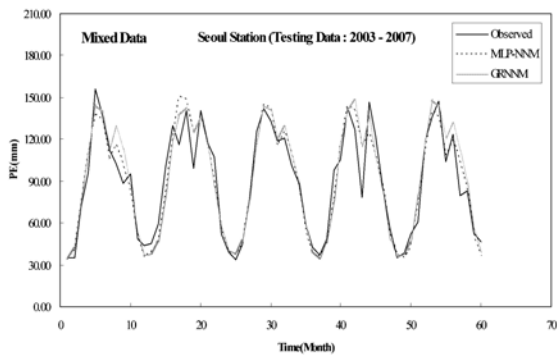
Fig. 4 Comparison of the monthly PE for the testing performance (Generated data)

Table 7. Statistical analysis of the monthly PE for the testing performance (Mixed data)

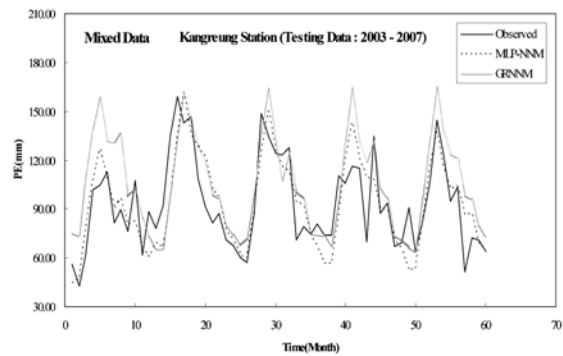
| Station | Statistical Index | Neural Networks Model | |
|-----------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Seoul | CC | 0.952 | 0.950 |
| | RMSE | 11.808 | 12.472 |
| | E | 0.899 | 0.887 |
| | AARE | 0.0055 | 0.0355 |
| Kangreung | CC | 0.811 | 0.746 |
| | RMSE | 17.086 | 23.834 |
| | E | 0.618 | 0.256 |
| | AARE | 0.0242 | 0.1726 |
| Incheon | CC | 0.894 | 0.869 |
| | RMSE | 13.926 | 22.647 |
| | E | 0.797 | 0.462 |
| | AARE | 0.0268 | 0.2502 |

Table 7. Continued

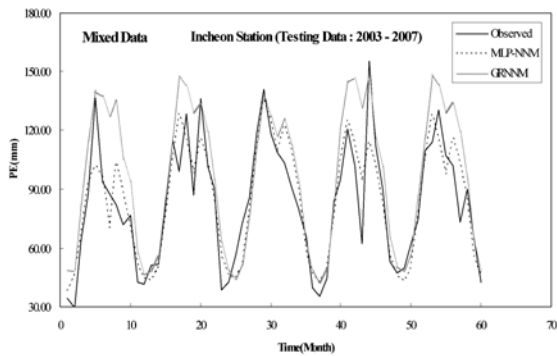
| Station | Statistical Index | Neural Networks Model | |
|---------|-------------------|-----------------------|--------|
| | | MLP-NNM | GRNNM |
| Busan | CC | 0.887 | 0.760 |
| | RMSE | 12.263 | 19.950 |
| | E | 0.779 | 0.416 |
| | AARE | 0.0280 | 0.1294 |
| Jeju | CC | 0.928 | 0.882 |
| | RMSE | 14.151 | 18.931 |
| | E | 0.861 | 0.752 |
| | AARE | 0.032 | 0.0433 |
| Mokpo | CC | 0.940 | 0.924 |
| | RMSE | 11.994 | 15.246 |
| | E | 0.883 | 0.823 |
| | AARE | 0.0003 | 0.0609 |



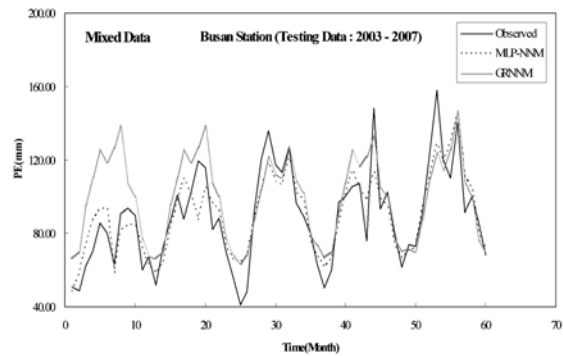
(a) Seoul




(b) Kangreung




(c) Incheon



(d) Busan



(e) Jeju



(f) Mokpo

Fig. 5 Comparison of the monthly PE for the testing performance (Mixed data)

Table 8. Results of the ANOVA test on the mean

| Model | Stations | Level of Significance | Mean | | | | | | |
|----------|-----------|-----------------------|----------------------|----------------------|-----------|---------|-----------------|---------------|---------------|
| | | | Two-sample t test | | | | | | |
| | | | Critical t statistic | Computed t statistic | | | Null hypothesis | | |
| Historic | Generated | Mixed | | Historic | Generated | Mixed | | | |
| MLP-NNM | Seoul | 0.05/0.01 | 1.981/2.621 | -0.0109 | 0.0117 | 0.0101 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Kangreung | 0.05/0.01 | 1.981/2.621 | -0.0118 | 0.0038 | 0.0004 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Incheon | 0.05/0.01 | 1.981/2.621 | -0.4080 | -0.0606 | -0.0661 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Busan | 0.05/0.01 | 1.981/2.621 | -0.4604 | -0.1146 | -0.1327 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Jeju | 0.05/0.01 | 1.981/2.621 | -0.0970 | -0.0074 | -0.0064 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Mokpo | 0.05/0.01 | 1.981/2.621 | -0.3401 | -0.0293 | -0.0315 | Accept/Accept | Accept/Accept | Accept/Accept |
| GRNNM | Seoul | 0.05/0.01 | 1.981/2.621 | -1.0500 | -0.1677 | -0.3138 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Kangreung | 0.05/0.01 | 1.981/2.621 | -1.8711 | -2.1043 | -2.3032 | Accept/Accept | Reject/Accept | Reject/Accept |
| | Incheon | 0.05/0.01 | 1.981/2.621 | -2.9105 | -2.3648 | -2.2661 | Reject/Reject | Reject/Accept | Reject/Accept |
| | Busan | 0.05/0.01 | 1.981/2.621 | -2.2217 | -2.0262 | -2.2053 | Reject/Accept | Reject/Accept | Reject/Accept |
| | Jeju | 0.05/0.01 | 1.981/2.621 | -1.6695 | -0.6411 | -0.7221 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Mokpo | 0.05/0.01 | 1.981/2.621 | -0.1871 | -0.9477 | -0.9920 | Accept/Accept | Accept/Accept | Accept/Accept |

본 연구에서 실측자료, 모의자료 및 혼합자료를 이용한 MLP-NNM과 GRNNM의 테스트과정의 수행결과를 분석하면 다음과 같다. 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용한 테스트과정의 수행결과가 실측자료의 훈련과정을 통하여 선정된 매개변수를 이용한 테스트과정의 수행결과보다 양호한 것으로 분석되었다. 또한 실측자료의 경우 MLP-NNM의 테스트과정의 수행결과와 GRNNM의 테스트과정의 수행결과를 비교할 때 어느 쪽이 더 양호한지는 판단되지 않으나, 모의자료 및 혼합자료의 경우 MLP-NNM의 테스트과정의 수행결과가 GRNNM의 테스트과정의 수행결과보다 양호한 결과를 나타내고 있다.

7. 자료의 동질성 검증

본 연구에서는 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서의 테스트자료인 실측된 월 증발접시 증발량자료와 실측자료, 모의자료 및 혼합자료를 이용한 훈련과정을 통하여 선정된 MLP-NNM과 GRNNM의 각 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료를 비교하여 동일 모집단에서 추출된 자료인지를 검토하는 동질성 검증(Homogeneity test)을 실시하였다. 동질성검증은 서울, 강릉, 인천, 부산, 제주 및 목포관측소의 월 증발접시 증발량자료에 대한 평균과 분산에 대한 일원분산분석(One-way analysis of variance, ANOVA) 및 Mann-Whitney U 검증(Test)을 실시하였다(McCuen 1993; Salas *et al.*, 2001).

7.1 일원분산분석

실측된 월 증발접시 증발량자료와 MLP-NNM과 GRNNM을 이용해서 산정된 월 증발접시 증발량자료에 대하여 먼저 평균에 대한 일원분산분석을 실시하였다. 분석은 2표본 t-검증(Two-sample t-test)을 이용하여 검증통계량(Test statistics) 및 자유도(Degrees of freedom)를 산정하였으며, 유의수준(Level of significance) 5% 및 1%에서 임계 검증통계량

(Critical test statistics)을 산정하여 두 표본에 대한 모집단의 평균은 동일하다는 귀무가설(Null hypothesis)의 채택(Accept) 혹은 거절(Reject)하는 과정을 실시하였다. 다음 Table 8은 월 증발접시 증발량자료의 평균에 대한 동질성 검증결과치를 나타내고 있다. Table 8에 의하면 실측된 월 증발접시 증발량자료와 MLP-NNM을 이용해서 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료의 평균에 대한 일원분산분석의 결과 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 5% 및 1%의 유의수준에서 모집단의 평균이 동일하다는 귀무가설이 채택되었다. 또한 실측된 월 증발접시 증발량자료와 GRNNM을 이용해서 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료의 평균에 대한 일원분산분석의 결과 서울, 제주 및 목포에서는 5% 및 1%의 유의수준에서 모집단의 평균이 동일하다는 귀무가설이 채택되었다. 그러나 강릉의 경우 실측자료는 5% 및 1%의 유의수준에서 모집단의 평균이 동일하다는 귀무가설이 채택되었고, 모의자료 및 혼합자료는 5%에서는 거절, 1%에서는 채택되었다. 인천의 경우 실측자료는 5% 및 1%의 유의수준에서 모집단의 평균이 동일하다는 귀무가설이 거절되었고, 모의자료 및 혼합자료는 5%에서는 거절, 1%에서는 채택되었다. 마지막으로 부산의 경우 실측자료, 모의자료 및 혼합자료에서 5%에서는 거절, 1%에서는 채택되었다.

두 번째로 분산에 대한 일원분산분석의 경우는 5% 및 1%의 유의수준에서 F-검증통계치(F-test statistics)을 계산하였으며, 임계 F-검증통계치와의 비교를 통하여 모집단의 분산이 동일하다는 귀무가설을 채택 혹은 거절하는 과정을 실시하였다. 다음 Table 9는 월 증발접시 증발량자료의 분산에 대한 동질성 검증결과치를 나타내고 있다. Table 9에 의하면 실측된 월 증발접시 증발량자료와 MLP-NNM을 이용해서 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정

Table 9. Results of the ANOVA test on the variance

| Model | Stations | Level of Significance | Variance | | | | | | |
|----------|-----------|-----------------------|----------------------|----------------------|-----------|-------|-----------------|---------------|---------------|
| | | | F-test statistics | | | | | | |
| | | | Critical F statistic | Computed F statistic | | | Null hypothesis | | |
| Historic | Generated | Mixed | | Historic | Generated | Mixed | | | |
| MLP-NNM | Seoul | 0.05/0.01 | 1.981/2.621 | 1.088 | 1.057 | 1.065 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Kangreung | 0.05/0.01 | 1.981/2.621 | 1.130 | 1.007 | 1.022 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Incheon | 0.05/0.01 | 1.981/2.621 | 1.012 | 1.146 | 1.141 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Busan | 0.05/0.01 | 1.981/2.621 | 1.478 | 1.536 | 1.548 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Jeju | 0.05/0.01 | 1.981/2.621 | 1.161 | 1.197 | 1.199 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Mokpo | 0.05/0.01 | 1.981/2.621 | 1.286 | 1.435 | 1.438 | Accept/Accept | Accept/Accept | Accept/Accept |
| GRNNM | Seoul | 0.05/0.01 | 1.981/2.621 | 1.394 | 1.133 | 1.114 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Kangreung | 0.05/0.01 | 1.981/2.621 | 1.487 | 1.167 | 1.151 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Incheon | 0.05/0.01 | 1.981/2.621 | 1.335 | 1.427 | 1.361 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Busan | 0.05/0.01 | 1.981/2.621 | 1.050 | 1.401 | 1.277 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Jeju | 0.05/0.01 | 1.981/2.621 | 1.701 | 1.057 | 1.051 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Mokpo | 0.05/0.01 | 1.981/2.621 | 1.496 | 1.232 | 1.239 | Accept/Accept | Accept/Accept | Accept/Accept |

Table 10. Results of the Mann-Whitney U test

| Model | Stations | Level of Significance | Mann-Whitney U test | | | | | | |
|---------|-----------|-----------------------|---------------------|------------|-----------|--------|-----------------|---------------|---------------|
| | | | Critical Z | Computed Z | | | Null hypothesis | | |
| | | | | Historic | Generated | Mixed | Historic | Generated | Mixed |
| MLP-NNM | Seoul | 0.05/0.01 | 1.960/2.575 | -0.010 | -0.063 | -0.058 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Kangreung | 0.05/0.01 | 1.960/2.575 | -0.016 | -0.100 | -0.068 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Incheon | 0.05/0.01 | 1.960/2.575 | -0.588 | -0.310 | -0.299 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Busan | 0.05/0.01 | 1.960/2.575 | -0.777 | -0.346 | -0.346 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Jeju | 0.05/0.01 | 1.960/2.575 | -0.189 | -0.331 | -0.315 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Mokpo | 0.05/0.01 | 1.960/2.575 | -0.357 | -0.210 | -0.205 | Accept/Accept | Accept/Accept | Accept/Accept |
| GRNNM | Seoul | 0.05/0.01 | 1.960/2.575 | -1.118 | -0.226 | -0.331 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Kangreung | 0.05/0.01 | 1.960/2.575 | -1.543 | -1.916 | -2.120 | Accept/Accept | Accept/Accept | Reject/Accept |
| | Incheon | 0.05/0.01 | 1.960/2.575 | -2.892 | -2.378 | -2.278 | Reject/Reject | Reject/Accept | Reject/Accept |
| | Busan | 0.05/0.01 | 1.960/2.575 | -2.199 | -2.157 | -2.315 | Reject/Accept | Reject/Accept | Reject/Accept |
| | Jeju | 0.05/0.01 | 1.960/2.575 | -1.396 | -0.987 | -1.055 | Accept/Accept | Accept/Accept | Accept/Accept |
| | Mokpo | 0.05/0.01 | 1.960/2.575 | -0.262 | -1.260 | -1.302 | Accept/Accept | Accept/Accept | Accept/Accept |

된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료의 분산에 대한 일원분산분석의 결과 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 5% 및 1%의 유의수준에서 모집단의 분산이 동일하다는 귀무가설이 채택되었다. 또한 실측된 월 증발접시 증발량자료와 GRNNM을 이용해서 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료의 분산에 대한 일원분산분석의 결과 서울, 강릉, 인천, 부산, 제주 및 목포에서 5% 및 1%의 유의수준에서 모집단의 분산이 동일하다는 귀무가설이 채택되었다.

7.2 Mann-Whitney U 검증

Mann-Whitney U 검증은 두 개의 독립적인 표본의 2표본 t-검증(Two-sample t-test)에 대한 비모수적인 대응법의 하나이며, 동일한 모집단으로부터 두 개의 독립적인 표본을 선정

할 수 있는지를 검증하기 위하여 사용되어 진다. 또한 세 개 이상의 독립적인 표본에 대해서는 Kruskal-Wallis 검증을 사용한다. 다음 Table 10은 월 증발접시 증발량자료의 Mann-Whitney U 검증을 이용한 동질성검증에 대한 결과치를 나타내고 있다. Table 10에 의하면 실측된 월 증발접시 증발량자료와 MLP-NNM을 이용해서 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료의 Mann-Whitney U 검증 결과 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 5% 및 1%의 유의수준에서 두 개의 표본자료가 동일 모집단에서 추출되었다는 귀무가설이 채택되었다. 또한 실측된 월 증발접시 증발량자료와 GRNNM을 이용해서 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료의 Mann-Whitney U 검증 결과 서울, 제주 및 목포에서는 5% 및 1%의 유의수준에서

두 개의 표본자료가 동일 모집단에서 추출되었다는 귀무가설이 채택되었다. 그러나 강릉의 경우 실측자료와 모의자료는 5% 및 1%의 유의수준에서 두 개의 표본자료가 동일 모집단에서 추출되었다는 귀무가설이 채택되었고, 혼합자료는 5%에서는 거절, 1%에서는 채택되었다. 인천의 경우 실측자료는 5% 및 1%의 유의수준에서 두 개의 표본자료가 동일 모집단에서 추출되었다는 귀무가설이 거절되었고, 모의자료 및 혼합자료는 5%에서는 거절, 1%에서는 채택되었다. 마지막으로 부산의 경우 실측자료, 모의자료 및 혼합자료에서 5%에서는 거절, 1%에서는 채택되었다. 따라서 본 연구에서 MLP-NNM을 이용하여 산정된 월 증발접시 증발량자료는 실측된 월별 증발접시 증발량자료와 동질성검증을 통하여 동질의 모집단을 가지는 자료군으로 채택되어 질 수 있는 것으로 판단되나, GRNNM의 경우는 관측소별로 차이가 있는 것으로 판단된다. 따라서 보편적으로 MLP-NNM의 수행결과가 GRNNM의 수행결과보다 양호하다고 판단된다.

8. 결론 및 추후 연구과제

본 연구에서는 우리나라 주요 기상관측소에서 관측된 연 증발접시 증발량자료를 제시된 MLP-NNM 및 GRNNM을 이용하여 월 증발접시 증발량자료로 분리하는데 있어서 각 신경망모형의 잠재성을 검토하였다. MLP-NNM 및 GRNNM을 이용한 시간적 분해모형의 훈련자료의 경우 실측자료, 모의자료 및 혼합자료로 각각 구성하였다. 그리고 모의자료의 경우 모의발생한 표본은 2개의 표본으로 하였으며, 500년에 해당되는 월 증발접시 증발량을 모의발생 시켰다. 모의된 자료 중에서 첫 번째 표본자료는 선택하지 않았으며, 두 번째 표본자료를 선택하였다. 또한 두 번째 표본자료에서 초기에 발생하는 편차(Bias)를 제거하기 위하여 초기의 50년 자료는 제거하였다. 훈련과정의 수행결과 선정된 최적 매개변수를 이용하여 실측자료로서 테스트과정을 실시하여 다음과 같은 결론을 유도하였다.

1. MLP-NNM 및 GRNNM의 훈련과정의 수행결과 MLP-NNM의 경우 실측자료를 이용한 수행결과가 모의자료 및 혼합자료를 이용한 수행결과보다 양호한 것으로 분석되었고, GRNNM의 경우 목포관측소를 제외하고는 모의자료 및 혼합자료를 이용한 수행결과가 실측자료를 이용한 수행결과보다 양호한 것으로 분석되었다.
2. MLP-NNM 및 GRNNM의 훈련과정의 수행결과 전반적으로 MLP-NNM의 수행결과가 GRNNM의 수행결과보다 양호한 것으로 분석되었다. 그러나 훈련과정에 사용된 훈련자료는 실측자료, 모의자료 및 혼합자료와 같은 다양한 자료로 구성되어 있어서 그 결과치를 비교한다는 것은 큰 의미가 없는 것으로 판단된다.
3. MLP-NNM 및 GRNNM의 훈련과정의 수행결과 산정된 각 6종류의 매개변수 군을 이용하여 테스트과정을 수행하였다. 그 결과 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용한 테스트과정의 수행결과가 실측자료의 훈련과정을 통하여 선정된 매개변수를 이용한 테스트과정의 수행결과보다 양호한 것으로 분석되었다. 따라서 본 연구를 통하여 분석에 이용된 자료의 수는 신경망

모형의 수행능력에 영향을 끼치는 것으로 판단된다.

4. MLP-NNM 및 GRNNM의 테스트과정의 수행결과, 실측자료의 훈련과정을 통하여 선정된 매개변수를 이용한 MLP-NNM의 테스트과정의 수행결과와 GRNNM의 테스트과정의 수행결과를 비교할 때 어느 쪽이 더 양호한지는 판단되지 않으나, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용한 MLP-NNM의 테스트과정의 수행결과가 GRNNM의 테스트과정의 수행결과보다 양호한 결과를 나타내고 있다.
5. 서울, 강릉, 인천, 부산, 제주 및 목포관측소에서 실측된 월 증발접시 증발량자료와 MLP-NNM과 GRNNM을 이용하여 실측자료, 모의자료 및 혼합자료의 훈련과정을 통하여 선정된 매개변수를 이용하여 테스트과정 수행결과 산정된 월 증발접시 증발량자료에 대하여 동질성검증을 위하여 평균과 분산에 대한 일원분산분석 및 Mann-Whitney U 검증을 실시하였다. 그 결과 MLP-NNM을 이용하여 산정된 월 증발접시 증발량자료는 실측된 월별 증발접시 증발량자료와 동질성검증을 통하여 동질의 모집단을 가지는 자료군으로 채택되어 질 수 있는 것으로 판단되나, GRNNM의 경우는 관측소별로 차이가 있는 것으로 판단된다. 따라서 보편적으로 MLP-NNM의 수행결과가 GRNNM의 수행결과보다 양호하다고 판단된다.

본 연구를 통하여 신경망모형을 이용하여 연 증발접시 증발량자료에 대한 시간적 분해모형의 구축에 대한 적용성을 검토하였으며, 그에 따른 잠재성을 분석하였다. 그러나 신경망모형을 기초로 한 시간적 분해모형의 보편적인 해석과 결론을 유도하기 위해서는 예를 들면 강우 및 유출량과 같은 더욱 다양한 시계열자료를 이용한 검증과정이 필요하며, 많은 종류의 신경망모형을 이용한 지속적인 연구가 필요한 것으로 판단된다.

참고문헌

- 국토해양부(2007) 수자원 관리 종합정보 시스템 홈페이지 <http://www.wamis.go.kr>.
- 김성원, 김형수(2008) 증발접시 증발량과 알팔파 기준증발산량의 모형화를 위한 통합운영방법. *대한토목학회논문집*, 대한토목학회, 제28권, 제2B호, pp. 199-213.
- 김성원, 이순탁, 조정석(2001) 중소하천유역에서 Hybrid Neural Networks에 의한 수문학적 예측. *한국수자원학회논문집*, 한국수자원학회, 제34권, 제4호, pp. 303-316.
- Bruton, J.M., McClendon, R.W., and Hoogenboom, G. (2000) Estimating daily pan evaporation with artificial neural networks. *Trans. of the ASAE*, ASAE, Vol. 43, No. 2, pp. 491-496.
- Burian, S.J., Durrans, S.R., Nix, S.J., and Pitt, R.E. (2001) Training artificial neural networks to perform rainfall disaggregation. *J. of Hydrol. Engr.*, ASCE, Vol. 6, No. 1, pp. 43-51.
- Burian, S.J., Durrans, S.R., Tomic, S., Pimmel, R.L., and Wai, C.N. (2000) Rainfall disaggregation using artificial neural networks. *J. of Hydrol. Engr.*, ASCE, Vol. 5, No. 3, pp. 299-307.
- Choi, J., Socolofsky, S.A., and Olivera, F. (2008) Hourly disaggregation of daily rainfall in Texas using measured hourly precipitation at other locations. *J. of Hydrol. Engr.*, ASCE, Vol. 13, No. 6, pp. 476-487.
- Deb, K. (2001) *Multi-objective optimization using evolutionary algorithms*, John Wiley & Sons, Chichester.
- Deswal, S. and Pal, M. (2008) Artificial neural network based mod-

- eling of evaporation losses in reservoirs. *Proceedings of World Academy of Science, Engineering and Technology*, Vol. 29, pp. 279-283.
- Eslamian, S.S., Gohari, S.A., Biabanaki, M., and Malekian, R. (2008) Estimation of monthly pan evaporation using artificial neural networks and support vector machines. *J. of Appl. Sci.*, Vol. 8, No. 19, pp. 3497-3502.
- Gundekar, H.G., Khodke, U.M., and Sarkar, S. (2008) Evaluation of pan coefficient for reference crop evapotranspiration for semi-arid region. *Irrig. Sci.*, Vol. 26, pp. 169-175.
- Gutierrez-Magness, A.L., and McCuen, R.H. (2004) Accuracy evaluation of rainfall disaggregation methods. *J. of Hydrol. Engr.*, ASCE, Vol. 9, No. 2, pp. 71-78.
- Haykin, S. (2009) *Neural networks and learning machines*, 3rd Edition, Pearson Education Inc., NJ, USA.
- Jensen, M.E., Burman, R.D., and Allen, R.G. (1990) *Evapotranspiration and irrigation water requirements*, ASCE Manual and Report on Engineering Practice No. 70, ASCE, NY, pp. 332.
- Keskin, M.E. and Terzi, O. (2006) Artificial neural networks models of daily pan evaporation. *J. of Hydrol. Engr.*, ASCE, Vol. 11, No. 1, pp. 65-70.
- Kim, S. (2004) Neural Networks Model and Embedded Stochastic Processes for Hydrological Analysis in South Korea. *KSCE J. of Civil Engr.*, KSCE, Vol. 8, No. 1, pp. 141-148.
- Kim, S. and Kim, H.S. (2008) Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. *J. of Hydro.*, Vol. 351, pp. 299-317.
- Kim, S., Kim, J.H., and Park, K.B. (2009) Statistical learning theory for the disaggregation of the climatic data. *Proc. 33rd IAHR Congress 2009*, IAHR/AIRH, Vancouver, British Columbia, Canada, pp. 1154-1162.
- Kisi, O. (2006) Daily pan evaporation modeling using a neuro-fuzzy computing technique. *J. of Hydro.*, Vol. 329, pp. 636-646.
- McCuen, R.H. (1993) *Microcomputer applications in statistical hydrology*, Prentice Hall, NJ, USA.
- Molina Martinez, J.M., Martinez Alvarez, V., Gonzalez-Real, M.M., and Baille, A. (2005) A simulation model for predicting hourly pan evaporation for meteorological data. *J. of Hydro.*, Vol. 318, pp. 250-261.
- Neuroshell 2 (1993) Ward systems group, Inc., MD, USA.
- Rahimi Khoob, A. (2009) Estimating daily pan evaporation using artificial neural network in a semi-arid environment. *Theor. Appl. Climatol.*, Doi : 10.1007/s00704-008-0096-3.
- Salas, J.D., Delleur, J.R., Yevjevich, V., and Lane, W.L. (1980) *Applied modeling of hydrologic time series*, Water Resor. Pub., Littleton, CO, USA.
- Salas, J.D., Smith, R.A., Tabios III, G.Q., and Heo, J.H. (2001) *Statistical computing techniques in water resources and environmental engineering*. Unpublished book in CE622, Colorado State University, Fort Collins, CO, USA.
- Specht, D.F. (1991) A general regression neural network. *IEEE Trans. on Neural Networks*, Vol. 2, No. 6, pp. 568-576.
- Sudheer, K.P., Gosain, A.K., Rangan, D.M., and Saheb, S.M. (2002) Modeling evaporation using an artificial neural network algorithm. *Hydro. Process.*, Vol. 16, pp. 3189-3202.
- Tan, K.S., Chiew, F.H.S., and Grayson, R.B. (2007) A steepness index unit volume flood hydrograph approach for sub-daily flow disaggregation. *Hydro. Process.*, Vol. 21, pp. 2807-2816.
- Tsoukalas, L.H. and Uhrig, R.E. (1997) *Fuzzy and neural approaches in engineering*. John Wiley & Sons Incorporated, New York, NY, USA.
- Wasserman, P.D. (1993) *Advanced methods in neural computing*, Van Nostrand Reinhold, New York, NY, USA.
- Zhang, J., Murch, R.R., Ross, M.A., Ganguly, A.R., and Nachabe, M. (2008) Evaluation of statistical rainfall disaggregation methods using rain-gauge information for west-central florida. *J. of Hydrol. Engr.*, ASCE, Vol. 13, No. 12, pp. 1158-1169.

(접수일: 2010.3.15/심사일: 2010.5.11/심사완료일: 2010.7.6)