

시간지체 순환신경망모형을 이용한 수문학적 모형화기법

Hydrologic Modeling Approach using Time-Lag Recurrent Neural Networks Model

김성원*

Abstract

Time-lag recurrent neural networks model (Time-Lag RNNM) is used to estimate daily pan evaporation (PE) using limited climatic variables such as max temperature (T_{max}), min temperature (T_{min}), mean wind speed (W_{mean}) and mean relative humidity (RH_{mean}). And, for the performances of Time-Lag RNNM, it is composed of training and test performances, respectively. The training and test performances are carried out using daily time series data, respectively. From this research, we evaluate the impact of Time-Lag RNNM for the modeling of the nonlinear time series data. We should, thus, construct the credible data of the daily PE using Time-Lag RNNM, and can suggest the methodology for the irrigation and drainage networks system. Furthermore, this research represents that the strong nonlinear relationship such as pan evaporation modeling can be generalized using Time-Lag RNNM.

Key words : Time-Lag Recurrent NNM, Pan Evaporation, Hydrologic Modeling

1. 서 론

최근에 많은 연구자들은 증발접시 증발량의 산정에 있어서 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 결과치는 기존의 공식 중에서 Stephens and Stewart 공식과 비교되었다. 그들은 이용할 수 있는 기상인자로부터 증발과정을 모형화 하는데 신경망기법의 이용을 제시하였으며, 온도, 상대 습도, 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 다중 선형회귀분석 및 Priestly-Taylor 공식을 이용하여 산정하였으며, 신경망모형의 결과치와 비교하였다.

본 연구의 목적은 순환신경망모형의 특수한 형태인 시간지체 순환신경망모형을 이용하여 기상변수 중의 하나인 일 증발접시 증발량의 모형화를 검토하는데 있다. 신경망모형의 하나인 Time-Lag RNNM의 수행평가를 위하여 모형화의 과정은 훈련 및 테스트과정으로 구성되었다. 본 연구에서는 비선형 수문학적 시계열자료의 모형화를 위해서 제한된 서로 다른 기상변수를 이용하여 Time-Lag Recurrent NNM의 모형화에 대한 적용성을 평가하였다.

2. 신경망모형

2.1 시간지체 순환신경망모형 (Time-Lag Recurrent Neural Networks Model, Time-Lag RNNM)

시간지체 순환신경망모형 (Time-Lag RNNM)은 은닉층 및 출력층과 같은 임의의 한 층의 노드에서의 결과치가 이전 층의 노드로 피드백이 이루어지며, 피드백을 받는 층의 노드의 결과치는 시간 t 에서의 전 시간 ($t-\Delta t$)에 존재한 피드백 한 층의 노드 자체의 결과치의 함수로 나타낼 수 있다. 여기서 Δt 는 연산의 한번 과정에 대한 시간을 나타내고 있다. 이러한 Time-Lag RNNM은 모형의 결과치가 현재와 이전의 입력자료에 의존하기 때문에 단기간 기억장치 (Short-term memory)와 같은 유사한 특징을 나타내고 있다 (Giles et al., 1997; Li et al., 1989; Ryeu and Chung, 1996). Time-Lag RNNM은 시간적인 패턴을 인식하고 상기시킴으로서 전방향신경망모형보다 잠재적으로 강력하나, 운영에 있어서 전방향신경망모형보다 많이 복잡한 단점이 있다. 또한 전방향신경망모형은 출력값이 단지 구성된 입력층 노드의 함수로 구성되나 Time-Lag RNNM은 출력값이 시간의 함수로 구성되어 있으며, 주어진 입력자료와 초기 출력값에 대하여 안정적인 결과치로서 수렴하게 된다. 그리고 이러한 안정적인 결과치를 유도하기 위하여 전방향신경망모형과는 상이하게 많은 은닉층 노드수를 요구하고 있다 (Demuth and Beale, 2000). 본 연구에서 Time-Lag RNNM의 은닉층 노드수는 구성된 각 특성모형의 입력층 노드수와 동일하게 설정하였으며, 은닉층의 전이함수는 sigmoid, 학습규칙은 Quickprop 역전파 훈련알고리즘, 단계크기 (Step size)는 1.0 및 모멘텀은 0.5로 설정하였으며, 출력층의 경우 출력층 노드수는 1개, 출력층의 전이함수는 linearsigmoid, 학습규칙은 Quickprop 역전파 훈련알고리즘, 단계크기 (Step size)는 0.1 및 모멘텀은 0.5으로 설정하였다. 또한 최대반복회수는 50,000회, 오차임계치는 0.001로 설정하였다.

* 정회원, 공학박사, 수자원개발기술사, 동양대학교 철도토목학과 부교수 ; E-mail : swkim1968@dyu.ac.kr

3. 연구범위 및 자료

3.1 연구범위

본 연구에서 기상관측소는 제주도를 포함한 우리나라 기상청의 관리하에 있는 71개의 기상관측소중에서 선정하였다. 선택된 기상관측소는 먼저 전 국토에 골고루 분포되어 있어서 그 지역을 대표할 수 있는 지점이어야 하며, 최소 30년 이상의 기상관측 자료를 보유하고 있어야 한다. 따라서 이러한 조건에 부합되는 수많은 기상관측소 중에서 서울기상대 및 성산포기상대를 선택하였다.

3.2 연구범위

본 연구에 개발된 Time-Lag RNNM을 적용하기 위하여 필요한 기상자료는 국토해양부의 국가 수자원관리종합정보 시스템 (Water Management Information System, WAMIS)의 홈페이지(www.wamis.go.kr)와 기상청의 기상청 홈페이지(www.kma.go.kr)의 과거 무료 공개자료로부터 필요한 자료를 이용하였다. 그리고 Time-Lag RNNM을 적용하기 위하여 이용한 기상자료는 1985년 1월 1일부터 1990년 12월 31일까지의 일단위의 최대기온 (T_{max}), 최소기온 (T_{min}), 평균풍속 (W_{mean}), 평균 상대습도(RH_{mean}) 및 증발점시 증발량 (PE)의 기상자료를 이용하여 훈련자료 및 테스트자료로 구성하였다.

4. Time-Lag RNNM의 적용

4.1 훈련과정 (Training Performance)

본 연구에서 훈련과정은 서울기상대 및 성산포기상대로부터 1985년 1월 1일부터 1989년 12월 31일까지의 일단위의 기상자료를 이용하였으며, 총 1,826개의 자료시계열로 구성되어 있다. 또한 Time-Lag RNNM은 서울기상대 및 성산포기상대에서 각각 4개의 모형으로 구성하였다. 모형의 구성은 입력층 노드를 구성한 기상인자에 따라서 구분되었으며, 출력층 노드는 증발점시 증발량으로만 구성되었다. 다음 Table 1은 본 연구에서 구성된 Time-Lag RNNM의 특정기상대별 모형의 구조, 입력층 노드 및 출력층 노드를 나타내고 있다. 그리고 Time-Lag RNNM의 훈련에 따른 선행과정으로서 입력층 노드의 각 기상자료를 표준화하여 적용하였다. 일반적으로 입력층 노드들을 표준화하는 주요한 이유 중 하나는 각 입력층 노드들이 서로 다른 단위로서 관측된 값들을 나타내고 있기 때문에, 이러한 입력층 노드들을 표준화하고 무차원단위에서 입력층 노드들을 재배치함으로써 각 변수들의 상사성의 효과를 제거하기 위한 것으로 판단된다 (Kim and Kim, 2008a, b; Kim et al., 2009). 또한 각 모형별 훈련결과 광주기상대 및 대구기상대에서 5개의 입력층 노드로 구성된 SEO-MOD-4 및 SSP-MOD-4의 훈련결과가 가장 양호한 것으로 나타났다.

4.2 테스트과정 (Test Performance)

본 연구에서 테스트과정은 서울기상대 및 성산포기상대로부터 1990년 1월 1일부터 1990년 12월 31일까지의 일단위의 기상자료를 이용하였으며, 총 365개의 자료시계열로 구성되어 있다. 따라서 훈련과정 동안 산정된 매개변수를 이용하여 테스트과정에서 증발점시 증발량을 모형화하였다. 그 결과 훈련과정과 동일하게 서울기상대 및 성산포기상대에서 4개의 입력층 노드로 구성된 SEO-MOD-4 및 SSP-MOD-4의 테스트결과가 가장 양호한 것으로 나타났다. 다음 Figure 1(a)-(d)는 서울기상대의 SEO-MOD-1, SEO-MOD-2, SEO-MOD-3 및 SEO-MOD-4 모형의 훈련 및 테스트과정 결과 증발점시 증발량의 관측치와 계산치의 비교결과를 나타내고 있으며, 다음 Figure 2(a)-(d)는 성산포기상대의 SSP-MOD-1, SSP-MOD-2, SSP-MOD-3 및 SSP-MOD-4 모형의 훈련 및 테스트과정 결과 증발점시 증발량의 관측치와 계산치의 비교결과를 나타내고 있다.

5. 결 론

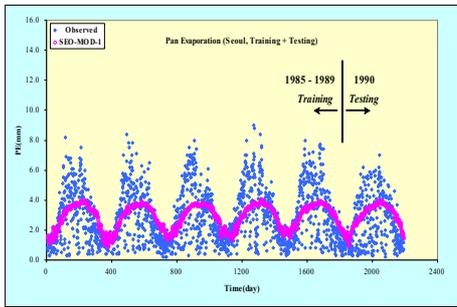
본 연구에서는 Time-Lag RNNM과 제한된 기상자료를 이용하여 증발점시 증발량을 모형화하였다. 적용된 기상자료는 서울기상대 및 성산포기상대의 기상자료인 1985년 1월 1일부터 1990년 12월 31일까지의 일단위의 최대기온 (T_{max}), 최소기온 (T_{min}), 평균풍속 (W_{mean}), 평균 상대습도(RH_{mean}) 및 증발점시 증발량 (PE)의 기상자료를 이용하였으며, 입력층 노드는 각 기상변수의 조합으로 구성하였다. 또한 출력층 노드는 증발점시 증발량 하나로만 구성되어 있다. 본 연구의 훈련 및 테스트과정을 통하여 서울기상대와 성산포기상대의 SEO-MOD-4 및 SSP-MOD-4의 모형이 가장 최적의 결과를 나타내는 것으로 분석되었다. 그러나 본 연구는 2개의 기상관측소 및 4개의 입력층 노드의 조합만으로 Time-Lag RNNM의 모형화를 평가하였다. 즉 Time-Lag RNNM과 제한된 기상변수만으로 증발점시 증발량의 모형화에 대한 적용성을 검토하였으며, 그에 따른 잠재성을 분석하였다. 그러나 Time-Lag RNNM의 보편적인 해석과 최적 기상변수의 선정에 대한 결론을 유도하기 위해서는 지속적인 연구가 필요한 것으로 사료된다. 또한 증발점시 증발량을 비롯한 다양한 수문시계열의 모형화 예를 들면 강우 및 유출량의 모형화의 연구에도 가능한 것으로 판단되며, 이에 따른 지속적인 연구가 요구된다.

참고문헌

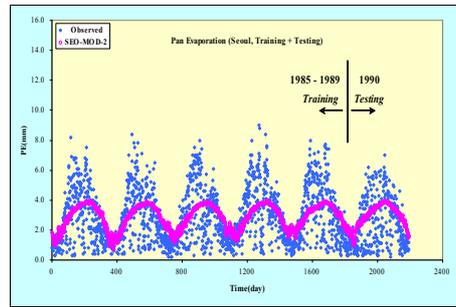
1. 국토해양부, 수자원 관리 종합정보 시스템 홈페이지 <http://www.wamis.go.kr>, 2009.
2. 기상청, 기상청 홈페이지 <http://www.kma.go.kr>, 2009.
3. Bruton, J.M., McClendon, R.W., and Hoogenboom, G. (2000). "Estimating daily pan evaporation with artificial neural networks." *Trans. of the ASAE*, ASAE, Vol. 43, No. 2, pp. 491-496.
4. Demuth, H. and Beale, M. (2000). *Neural network toolbox : for use with MATLAB user's guide*, The MathWorks Inc.
5. Deswal, S., and Pal, M.(2008). "Artificial neural network based modeling of evaporation losses in reservoirs." *Proc. of World Academy of Science, Engineering and Technology*, Vol. 29, pp. 279-283.
6. Giles, C.L., Lawrence, S., and Tsoi, A.C. (1997). "Rule inference for financial prediction using recurrent neural networks." *Proc. of 1997 IEEE/IAFE Conference on Computational Intelligence for Financial Engrg.*, IEEE Press, Piscataway, NJ, pp. 253-259.
7. 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.
8. Kim, S. and Kim, H.S. (2008a). "Uncertainty reduction of the flood stage forecasting using neural networks model." *J. Americ. Water Resor. Associ.*, Vol. 44, No. 1, pp. 148-165.
9. 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.
10. Kim, S., Kim, J.H., and Park, K.B. (2009). "Neural networks models for the flood forecasting and disaster prevention system in the small catchment." *Disas. Advn.*, Vol. 2, No. 3, pp. 51-63.
11. Li, J., Michel, A.N., and Porod, W. (1989). "Analysis and synthesis of a class of neural networks : linear system operating on a closed hypercube." *IEEE Trans. on Circuits and Systems*, Vol. 36, No. 11, pp. 1405-1422.
12. 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.
13. Ryue, J.K. and Chung, H.S. (1996). "Chaotic recurrent neural networks and their application to speech recognition." *J. Neurocomputing*, Vol. 13, pp. 281-294.
14. 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.

Table 1. Time-Lag RNNM structure

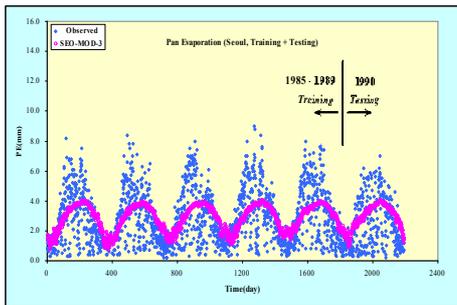
Station	Model	Input Nodes	Output Node
SEOUL	SEO-MOD-1	T_{\max}	PE
	SEO-MOD-2	T_{\max} , T_{\min}	PE
	SEO-MOD-3	T_{\max} , T_{\min} , W_{mean}	PE
	SEO-MOD-4	T_{\max} , T_{\min} , W_{mean} , RH_{mean}	PE
SEONGSANPO	SSP-MOD-1	T_{\max}	PE
	SSP-MOD-2	T_{\max} , T_{\min}	PE
	SSP-MOD-3	T_{\max} , T_{\min} , W_{mean}	PE
	SSP-MOD-4	T_{\max} , T_{\min} , W_{mean} , RH_{mean}	PE



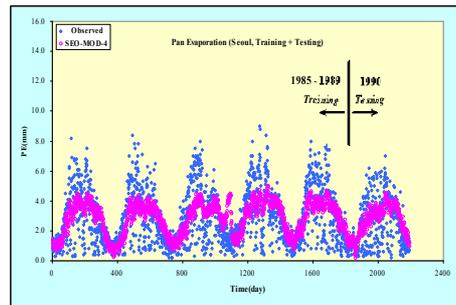
(a) SEO-MOD-1



(b) SEO-MOD-2

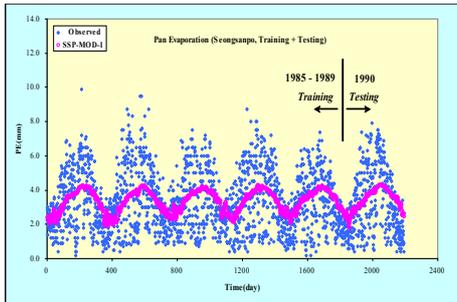


(c) SEO-MOD-3

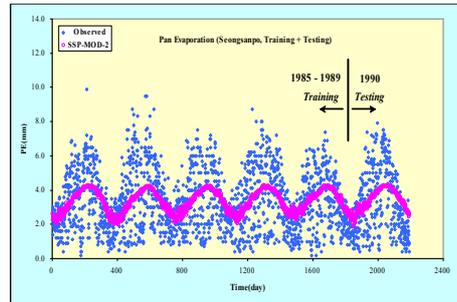


(d) SEO-MOD-4

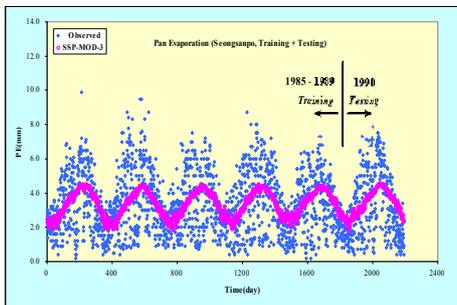
Figure 1. Comparison of pan evaporation for training and testing performance (Seoul station)



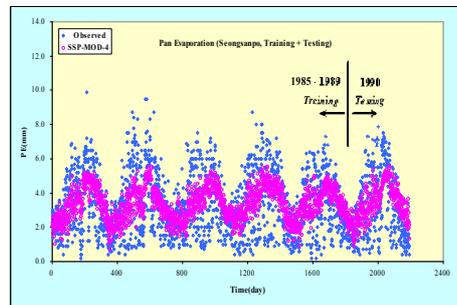
(a) SSP-MOD-1



(b) SSP-MOD-2



(c) SSP-MOD-3



(d) SSP-MOD-4

Figure 2. Comparison of pan evaporation for training and testing performance (Seongsanpo station)