



## 인공신경망 기법을 이용한 장래 잠재증발산량 산정

### Estimation of Future Reference Crop Evapotranspiration using Artificial Neural Networks

이은정\* · 강문성\*\*† · 박정안\*\*\* · 최진영\*\*\* · 박승우\*\*

Lee, Eun Jeong · Kang, Moon Seong · Park, Jeong An · Choi, Jin Young · Park, Seung Woo

#### ABSTRACT

Evapotranspiration (ET) is one of the basic components of the hydrologic cycle and is essential for estimating irrigation water requirements. In this study, artificial neural network (ANN) models for reference crop evapotranspiration ( $ET_0$ ) estimation were developed on a monthly basis (May~October). The models were trained and tested for Suwon, Korea. Four climate factors, daily maximum temperature ( $T_{max}$ ), daily minimum temperature ( $T_{min}$ ), rainfall ( $R$ ), and solar radiation ( $S$ ) were used as the input parameters of the models. The target values of the models were calculated using Food and Agriculture Organization (FAO) Penman-Monteith equation. Future climate data were generated using LARS-WG (Long Ashton Research Station-Weather Generator), stochastic weather generator, based on HadCM3 (Hadley Centre Coupled Model, ver.3) A1B scenario. The evapotranspirations were 549.7 mm/yr in baseline period (1973-2008), 558.1 mm/yr in 2011-2030, 593.0 mm/yr in 2046-2065, and 641.1 mm/yr in 2080-2099. The results showed that the ANN models achieved good performances in estimating future reference crop evapotranspiration.

**Keywords:** Artificial Neural Networks; climate change; evapotranspiration, FAO Penman-Monteith; LARS-WG

#### 1. 서 론

기후변화에 관한 정부 간 협의체 (Intergovernmental Panel on Climate Change, IPCC) 4차 평가보고서에 따르면 지구온난화와 이상기후에 의해 21세기 후반 (2090-2099)에는 20세기 후반 (1980-1999)에 비해 평균기온이 1.1-6.4 °C 상승하고, 해수면은 18~59 cm 상승하는 것으로 예측되었으며, 기온과 강수량의 변화가 가뭄과 홍수의 빈도 증가를 가져와 작물의 생산을 위한 가용수자원의 감소를 초래할 것이라고 보고하여 기후변화가 점점 더 가속화 되고 있다는 점을 시사하고 있다 (IPCC, 2007, 2008). 기후변화는 생태계 변화, 작물생육, 식량문제 등 많은 분야에 영향을 미치게 되며, 기후변화로 인한 기온상승은 작물의 증발산량에 영향을 미치게 된다 (Hong et al., 2009).

농업용수개발과 수자원의 효율적인 관리계획 수립을 위해서

는 장래 농업용수 수요분석이 이루어져야 하며, 이를 위해서는 작물의 증발산량을 정확하게 예측하는 것이 필요하다. 작물의 증발산량은 작물의 증산량이나 토양의 증발량으로 이루어져 있지만 이들을 직접 측정하는 것은 현실적으로 어렵기 때문에 잠재증발산량을 통한 실제 증발산량 예측에 관한 연구가 활발히 진행되어왔다. 잠재증발산량을 계산하기 위해서는 Penman 식 (Penman, 1948), 수정 Penman 식 (Jensen et al., 1990), Blaney-Criddle 식 (Blaney and Criddle, 1962), FAO Penman-Monteith 식 (FAO, 1998) 등의 공식들이 많이 쓰인다. 이 중 Penman 식과 수정 Penman 식, FAO Penman-Monteith 식의 경우 계산 과정 시 많은 기상인자를 고려하는 번거로움이 있는 반면 비교적 정확하고, Blaney-Criddle 식은 고려하는 기상인자의 수가 적어 적용이 간편하지만 일조시간, 기온, 강수량 등 기후조건에 따른 영향을 반영하지 못하는 단점이 있다.

그러나 현재 장래 기후변화 시나리오를 적용하여 일 기상자료를 발생시키기 위해 널리 사용되고 있는 WGEN (A Model for Generation Daily Weather Generator) (Richardson and Wright, 1984), LARS-WG (Long Ashton Research Station-Weather Generator) (Semenov and Barrow, 2002)와 같은 모델들은 일 최고/최저기온, 강수량, 태양복사에너지 등 한정적인 기상자료만을 발생시킨다. 따라서 이와 같은 기상발생기 모형의 결과로부터 FAO Penman-Monteith 식을 적용하여 잠

\* 서울대학교 농업생명과학연구원 연구원  
 \*\* 서울대학교 조경·지역시스템공학부, 농업생명과학연구원 겸무연구원  
 \*\*\* 서울대학교 생태조경·지역시스템공학부  
 † Corresponding author Tel.: +82-2-880-4582  
 Fax: +82-2-873-2087  
 E-mail: mskang@snu.ac.kr  
 2010년 4월 13일 투고  
 2010년 7월 21일 심사완료  
 2010년 7월 21일 게재확정

재증발산량을 산정하는 데는 한계가 있다.

인공신경망 (Artificial Neural Network; ANN)은 미리 측정된 자료들 속에서 의미 있는 패턴과 규칙을 탐색하고 분석하여 일정한 규칙을 찾아내는 기계적 알고리즘 프로그램으로 이 프로그램을 이용한 연구들이 다양한 분야에서 활발히 이루어져 왔으며 현재와 과거의 입력값들과 이에 대응된 출력값들을 알고 있는 경우에 미래의 새로운 입력값들에 대한 출력값들을 추출하는 데 유용하게 이용되고 있다 (Son, 2003).

온도, 풍속, 일조시간, 상대습도, 이슬점 등 여러 기상인자 중 제한된 인자만을 이용하여 입력자료의 조합을 달리하고 ANN 모형을 구성하여 잠재증발산량을 예측하는 연구가 많은 연구자들에 의해 수행되었으며 (Odhiambo et al., 2001; Sudheer et al., 2003; Zanetti et al., 2007; Jain et al., 2008; Goroka et al., 2008), Xiaoqin et al. (2009)은 ANN 모형과 다중선형회귀 모형으로 잠재증발산량을 예측하고 그 결과를 비교·분석하였다. Kumar et al. (2009)는 ANN 모형을 구성하여 잠재증발산량을 예측하는 기존 연구들이 모형 개발이 이루어진 특정 지점에서만 적용될 수밖에 없는 점에 착안하여 특정 지점이 아닌 기타 다른 지역에서도 잠재증발산량을 예측할 수 있는 일반화된 인공신경망 (generalized ANN) 모형을 개발하여 분석하였다. 현재 기후변화가 작물증발산량에 미치는 영향에 관한 연구가 이루어지고는 있으나 (Hong et al., 2009; Chung, 2009), 장래 농업용수 수요량을 보다 정확하게 예측하고 평가하기 위해서는 다양한 적용을 통한 연구가 필요하다.

따라서 본 연구에서는 일기상발생기 LARS-WG 모형의 출력자료인 일 최고/최저기온, 강수량, 태양복사에너지 자료만으로 잠재증발산량을 예측하기 위해, 오류역전파 알고리즘에 의한 인공신경망 모형을 구성하고, 기후변화 시나리오에 따른 일별 기후자료를 생성하여 장래 잠재증발산량을 산정하고, 적용성을 평가하였다.

## II. 재료 및 방법

### 1. 기상자료 및 P-M법에 의한 잠재증발산량

인공신경망 모형을 이용하여 장래 잠재증발산량을 추정할 대상지역은 수원으로 하였다. Penman-Monteith 식을 이용하여 인공신경망 모형의 학습 및 검증자료로 사용될 잠재증발산량을 산정하고 LARS-WG를 이용하여 장래 일기상 자료를 발생시키기 위해 관측자료를 수집하였다.

관측자료는 경기도 수원시 권선구에 위치한 수원기상대에서 관측하고 제공하는 기상자료를 이용하였으며, 1973년~2008년까지 총 36개년 일별 기상자료를 수집하였다. 수집한 항목은 최

고/최저/평균기온, 평균풍속, 상대습도, 강수량, 태양복사량 및 일조시간 자료이다.

본 연구에서는 잠재증발산량을 산정하기 위해 Penman-Monteith 식을 이용하였다. Penman-Monteith 식은 1998년 국제식량농업기구에서 기존에 사용되던 20여 종류의 증발산량 공식들을 검토한 결과 건조 및 습윤 기후에서 비교적 정확하고 일정한 경향을 가지는 것으로 확인되었다 (Allen et al., 1998). Penman-Monteith 식은 식 (1)과 같다.

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma(1+0.34u_2)} \quad (1)$$

여기서,  $ET_0$  = 기준잠재증발산량 (mm/day),  $\Delta$  = 증기압 곡선의 기울기 (kPa/°C),  $R_n$  = 순복사량 (MJ/m<sup>2</sup>/day),  $G$  = 토양 열 유속 밀도 (MJ/m<sup>2</sup>/day),  $\gamma$  = 건조계 상수 (kPa/°C),  $T$  = 2m 높이에서의 일평균 기온 (°C),  $u_2$  = 2m 높이에서의 풍속 (m/s),  $e_s$  = 포화증기압 (kPa),  $e_a$  = 실제증기압 (kPa)이다.

잠재증발산량은 작물 생육기간에 해당하는 5월부터 10월까지의 기간에 대해 산정하였다.

### 2. 장래 기후변화 모의

일별 기상자료를 생성하는 일기상발생기는 미세측 지역이나 결측치가 있는 관측소의 기후자료를 생산하기 위한 목적으로 개발된 것으로 기후변화 영향평가에도 많이 적용되고 있다 (Bae et al., 2007). 이 중 LARS-WG 모형은 특정 지역에서의 기후자료를 모의하는 추계학적 일기상발생기로 강수량, 최고/최저 기온, 태양복사량을 모의한다 (Semenov and Barrow, 2002).

LARS-WG 모형은 입력자료를 분석하여 강수와 무강수일의 연속 (wet and dry series)의 빈도분포와 평균 및 표준편차, 월별 강수량의 빈도분포와 평균 및 표준편차, 월 최대/최소강수량, 월 최고/최저기온, 일 최고/최저기온, 지속적으로 최저기온이 0 °C보다 낮은 날의 분포, 최대기온이 30 °C 이상인 날의 분포 등의 매개변수를 산정하게 된다. 이렇게 산정된 매개변수들을 통해 기후자료를 생산하고, t-test와 F-test를 통해 모의된 기후자료의 평균과 분산이 관측치 값과 동일한 모집단에서 생성된 자료인지를 분석하게 된다. Semenov and Barrow (2002)에 따르면 오랜 기간 동안 모의된 기후자료의 통계적 특성이 입력자료의 통계적 특성에 근접한다고 한다.

LARS-WG ver.5.0에서는 HadCM3과 NCCCSM에 의한 A1B, A2, B1 배출시나리오를 제공하고 있으며 본 연구에서는 세계적인 경제중시 정책 때문에 2100년의 이산화탄소 (CO<sub>2</sub>) 농도

가 현재에 비해 약 1.9배 증가한다는 시나리오 A1B를 채택하였다. HadCM3 (Hadley Centre Coupled Model, ver.3)는 영국의 Hadley 기후예보 연구센터 (Hadley Centre for Climate Prediction and Research)에서 개발한 모델로 전 세계의 물리적 변화와 상태를 함께 고려하여 개발되었으며, 대기모델 (HadOM3)과 해양모델 (HadM3)로 구성되어 있다. 대기모델은 19개의 레벨로 나누어지며 2.50°×3.75°의 해상도를 가지고 있으며 해양모델의 경우 20개의 레벨로 구성되며 1.25°×1.25°의 해상도를 지닌다. HadCM3는 GCMs (전지구 기후모델)의 모델 중 하나로 기후변화 시나리오를 모색하기 위해 개발되었으며 해수의 3차원 표현과 지표의 3차원 생물권과 결합하여 분석한다. HadCM3는 전 모델인 HadCM2에서 고려하지 못했던 기체성분 (gas)을 고려할 수 있으며 과다 예측을 피하기 위한 인위적인 유동 (flux) 보정을 따로 하지 않아도 되는 장점이 있다.

### 3. 인공신경망

인공신경망 (Artificial Neural Network; ANN) 모형은 인간 두뇌의 신경세포를 모형화하여 지능을 구현하는 기법이다. 신경망은 입력층, 은닉층, 출력층을 구성하는 노드(node)로 이루어져 있으며, 각 계산요소는 가중치의 합 (weighted sum)과 같은 단순한 계산만을 수행한다 (Harvey, 1994). 인공신경망은 하나의 처리장치가 아닌 다수의 노드들의 상호작용을 통해 처리되므로 불완전한 자료로부터 학습과 의사 결정을 할 수 있으며, 이러한 적응성은 지속적인 학습을 통해 가중치를 변화시키면서 적합한 모델을 만든다. 그러나 인공신경망 모형은 입력변수와 출력변수간의 정확한 인과관계를 표현하지 못한다는 단점이 있어 변수간의 명백한 규칙을 규명하기는 어렵다는 한계가 있으나, 특이치가 있거나 불규칙한 모형에서도 우수한 예측력을 지니는 특징이 있다 (Makridakis et al, 1998).

일반적으로 많이 사용되고 있는 다층퍼셉트론 (multi-layer perceptron)은 입력층과 출력층 사이에 하나 이상의 은닉층 (hidden layer)이 존재하는 구조이다 (Fig. 1). 입력층을 제외한 은닉층과 출력층을 구성하고 있는 노드들은 합산함수 (summing function)와 활성화함수 (activation function)를 가지고 있으며, 각 노드들 사이에는 연결 가중치 (weight)가 있다.

인공신경망의 학습이란 각 노드와 노드를 연결하는 적절한 가중치의 값을 찾아내어 모형의 예측력을 높여주는 과정을 말한다. 본 연구에서는 다층퍼셉트론의 학습에 오류역전파 (error back propagation) 알고리즘을 사용하였다. 오류역전파 알고리즘은 델타법칙 (delta rule)에 기초하고 있는데, 델타법칙은 사용자가 지정한 목표값과 학습에 의한 출력값의 차이에서 만들

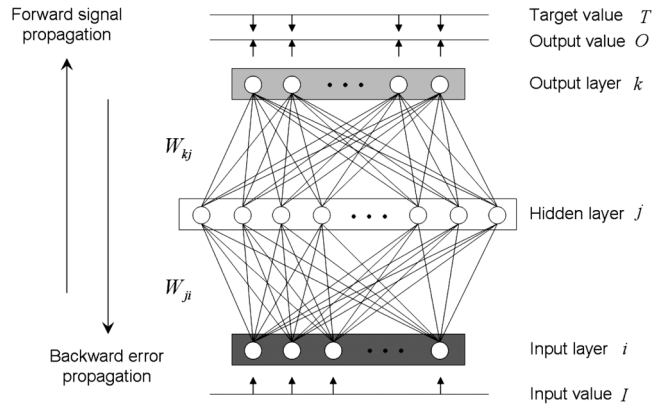


Fig. 1 Structural of multilayer neural network

어진 오차값을 이용하여, 오차를 줄여나가는 방향으로 학습을 하는 법칙으로 정의된다 (Jung, 2004).

다층 순방향 신경망(feed-forward neural network) 훈련은 실측치와 모의치의 비선형 최소 자승인 가중함수를 최소화하는 것으로서 교사훈련 (supervised training)이라고 하며 (Kang et al., 2003), 식 (2)와 같이 표현된다.

$$E = \frac{1}{2} \sum_{p=1}^n \sum_{k=1}^m (y_{pk} - p_{pk})^2 \quad (2)$$

여기서, E = 총오차, n = 실측치의 패턴 수, m = 총 출력단위, y<sub>pk</sub> = 실측된 반응인 목표 출력값으로서 Penman-Monteith 식에 의해 산정된 잠재증발산량, p<sub>pk</sub> = 모형에 의한 모의 출력값으로서 인공신경망 모형에 의해 모의된 잠재증발산량을 나타낸다.

신경망 모형에서 활성화함수는 미분 가능한 시그모이드 함수 (sigmoid function)를 사용하였으며, 오차 E의 최소화는 최적화기법 중에서 경사하강법 (gradient descent method)을 사용하였다. 본 모형에서는 최적화기법인 경사하강법에 학습과정에서 발생할 수 있는 지역 최소값 (local minima value) 문제와 오차를 최소화하고 수렴속도를 향상시키기 위해 적응학습률 (adaptive learning rate)에 모멘트법 (momentum)을 고려하였다.

### 4. 인공신경망 기법을 이용한 잠재증발산량 예측 모형

본 연구에서는 모형의 입력층에서 강수량, 최고/최저기온, 태양복사량을 고려하여 식 (3)과 같이 일 잠재증발산량 예측모형을 구성하였다.

$$ET_0(t) = function(R(t), T_{max}(t), T_{min}(t), S(t)) \quad (3)$$

여기서,  $ET_0(t) = t$  일의 잠재증발산량,  $R(t) = t$  일의 강수량,  $T_{max}(t) = t$  일의 최고기온,  $T_{min}(t) = t$  일의 최저기온,  $S(t) = t$  일의 태양복사량이다.

우리나라는 온대성 기후지대에 속하고 있어 월별 기상 특성이 다르게 나타난다. 따라서 이를 고려하여 보다 정확한 모형을 구축하기 위해 잠재증발산량 예측모형을 월별로 구축하였다. 증발산량은 작물생장과 관련이 있으므로 작물 생육기간 (growing season)인 5월부터 10월까지 총 6개의 모형을 구축하였다.

모형의 입력력자료는 구성된 잠재증발산량 예측모형의 시그모이드 함수인 최소값 0과 최대값 1을 전달하므로 이론적인 정규화 범위로 변환하였으며, 식 (4)와 같다.

$$X' = \left[ \frac{1}{(X_{max} - X_{min})} \right] \times (X - X_{min}) \quad (4)$$

여기서,  $X'$  = 변환된 변수,  $X_{max}$ ,  $X_{min}$  = 실측자료의 최대값과 최소값이다.

식 (4)를 이용하여 잠재증발산량을 모의할 경우, 잠재증발산량에 제한요소가 나타나므로, 좀 더 큰 범위를 나타내기 위한 방법들을 사용할 수 있으며 (Huynh and Sureerattanan, 2000), 본 연구에서는 Kang et al. (2003)의 연구에서와 같이 최소값과 최대값은  $range[0.8X_{min}, 1.2X_{max}]$ 의 범위를 적용하였다.

### III. 결과 및 고찰

#### 1. 기상자료 발생

기후변화를 고려한 장래 기상자료 발생을 위하여 수원기상대의 1973년~2008년까지 총 36년간의 자료를 이용하였다. 먼저, 36년간의 일별 최고기온, 최저기온, 강수량, 태양복사량 자료를 이용하여 LARS-WG 모형을 통해 입력자료와 통계적 특

성이 비슷한 일 기상자료를 발생시켜 모형의 적용성을 평가하였다. Table 1은 입력자료를 바탕으로 추정된 매개변수를 이용하여 발생된 300년치의 기상자료와 입력자료의 월별 특성을 비교한 것으로, Q-Test 결과 모형의 적용에 무리가 없는 것으로 판단된다.

추정된 매개변수를 바탕으로 HadCM3의 A1B 시나리오를 적용하여 2011-2030년 (2020s), 2046-2065년 (2055s), 2080-2099년 (2090s)년 기상자료를 100회씩 발생시켰다. 생성된 기상자료의 월별 최저치, 최고치, 평균은 Table 2와 같다. 기후변화가 진행될수록 최고기온, 최저기온은 올라가고, 강수량은 계절적 편차가 심해져 7월과 8월에 급격히 증가하였다. 태양복사량은 강수량의 변화와 반대의 양상을 나타내었는데 기후변화가 진행됨에 따라 강수량이 증가하면 태양복사량은 감소하고, 강수량이 감소하면 태양복사량은 증가하는 경향을 보였다.

#### 2. 잠재증발산량 예측모형의 보정과 검증

일 최고 / 최저기온, 강수량, 태양복사량 자료로부터 5월~10월까지의 잠재증발산량을 예측하기 위해 인공신경망 기법을 이용하여 잠재증발산량 예측모형을 구성하였다. 제한된 인자로부터 잠재증발산량을 추정하는 만큼 월별 기상특성의 차이에 따른 모형에의 영향을 최소화하기 위해 월별로 잠재증발산량 예측모형을 각각 구성하였다. 정확한 모형구축을 위해서는 모형의 학습에 이용되는 자료의 기간이 길어야 한다. 따라서 1973년부터 2002년까지의 기상자료 및 Penman-Monteith 식에 의해 산정된 기준 잠재증발산량값을 모형 보정을 위한 학습자료로 이용하였다.

월별로 구성된 6개의 모형에 대한 은닉층의 최적 노드수를 결정하기 위하여 각 모형의 은닉층의 노드수를 1~20까지 변환시키면서 5,000회 반복하여 학습으로 수행하였다. Table 3은 월별로 구성된 잠재증발산량 예측모형의 총오차 (total error, TE) 및 은닉층의 최적 노드수, 모형의 보정, 검증 결과를 나타낸다. 모형의 보정결과, 총오차는 0.307~0.709의 범위를 보였

Table 1 Result of LARS-WG Q-Test (monthly mean values)

Item		JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
Rainfall (mm)	Obs.	27.3	23.9	57.7	85.9	91.3	158.5	265.4	265.4	158.6	69.4	46.6	27.0
	Sim.	22.1	23.5	44.6	76.9	95.7	136.8	323.3	279.6	139.8	49.8	46.9	23.1
Min. Temp (°C)	Obs.	-7.2	-5.4	0.3	5.9	11.4	17.0	21.2	21.5	15.9	8.5	1.5	-4.6
	Sim.	-7.6	-5.6	-0.4	5.6	11.5	17.1	21.5	21.8	16.0	8.4	1.4	-4.7
Max. Temp (°C)	Obs.	2.4	4.7	11.0	17.2	22.4	26.2	28.7	29.4	25.5	19.7	12.1	5.1
	Sim.	2.1	4.6	10.4	17.7	22.7	26.6	28.7	29.7	25.8	20.0	12.0	4.9
Solar Rad. (MJ/m <sup>2</sup> /day)	Obs.	7.7	10.2	12.5	15.0	16.7	15.8	13.2	14.0	12.9	10.7	8.0	7.0
	Sim.	7.8	10.4	12.9	15.5	16.7	15.8	12.9	13.7	13.1	11.4	8.1	7.0

**Table 2 Characteristics of generated weather data from LARS-WG**

Month		2011-2030 (2020s)				2046-2065 (2055s)				2080-2099 (2090s)			
		a*	b**	c***	d****	a	b	c	d	a	b	c	d
JAN	Min	-19.5	-7.1	0.0	0.2	-17.6	-5.4	0.0	0.2	-15.2	-2.8	0.0	0.2
	Mean	-4.8	4.9	1.1	7.4	-3.0	6.7	1.6	7.2	-0.4	9.3	1.4	7.0
	Max	11.8	17.8	28.8	14.1	13.8	19.4	41.6	13.6	16.5	22.0	44.6	13.2
FEB	Min	-17.0	-6.4	0.0	0.4	-14.5	-4.1	0.0	0.4	-11.6	-1.3	0.0	0.4
	Mean	-3.2	6.8	0.7	10.0	-0.8	9.3	1.1	9.7	2.0	12.1	1.5	9.5
	Max	8.2	21.4	30.0	17.8	10.7	23.7	38.5	17.8	13.3	26.4	53.6	17.4
MAR	Min	-11.0	-2.0	0.0	0.2	-8.9	0.0	0.0	0.2	-7.3	1.8	0.0	0.2
	Mean	1.4	12.1	2.4	11.7	3.3	13.9	1.9	12.2	4.6	15.2	2.1	12.1
	Max	14.1	24.9	94.3	22.4	15.9	26.7	68.0	23.4	17.0	27.8	77.4	23.4
APR	Min	-3.5	4.6	0.0	1.2	-1.7	6.4	0.0	1.3	-0.5	7.6	0.0	1.3
	Mean	6.7	18.0	3.2	14.1	8.5	19.8	3.4	14.7	9.8	21.1	3.5	14.7
	Max	18.8	30.9	133.2	26.2	20.6	32.6	138.5	27.5	21.9	33.9	147.9	27.5
MAY	Min	2.7	11.8	0.0	1.1	4.4	13.6	0.0	1.2	5.6	14.8	0.0	1.2
	Mean	12.4	23.4	2.9	16.2	14.2	25.1	3.1	17.3	15.4	26.4	2.7	17.1
	Max	21.1	33.2	97.6	29.4	23.1	35.1	112.2	30.5	24.4	36.4	100.0	30.8
JUN	Min	9.0	17.5	0.0	1.2	11.0	19.6	0.0	1.2	12.3	20.8	0.0	1.2
	Mean	18.4	27.7	4.0	16.4	20.6	29.9	5.9	16.3	21.9	31.2	5.4	16.8
	Max	25.3	36.6	172.0	31.3	27.4	38.7	275.3	30.8	28.8	40.0	254.8	31.9
JUL	Min	15.3	23.5	0.0	0.7	17.4	25.4	0.0	0.6	18.7	26.7	0.0	0.6
	Mean	23.1	30.4	9.1	13.4	24.9	32.3	17.1	11.9	26.2	33.6	15.4	12.4
	Max	28.5	38.6	376.7	30.0	30.2	40.4	726.7	27.6	31.6	41.7	656.7	28.7
AUG	Min	10.7	21.7	0.0	1.2	12.9	23.9	0.0	1.1	14.7	25.7	0.0	1.2
	Mean	23.0	30.8	11.4	13.2	25.1	33.0	17.5	12.4	26.9	34.7	15.0	13.1
	Max	28.5	37.6	298.1	26.3	30.7	39.6	491.1	24.1	32.5	41.4	429.0	25.3
SEP	Min	3.6	15.9	0.0	0.5	5.4	17.5	0.0	0.5	7.1	19.2	0.0	0.5
	Mean	17.1	26.8	4.4	12.8	19.3	29.0	7.3	12.6	21.0	30.7	5.6	13.0
	Max	26.1	35.4	217.3	24.6	28.4	37.6	365.6	23.7	30.1	39.4	282.1	24.7
OCT	Min	-3.5	7.9	0.0	0.1	-2.4	9.0	0.0	0.1	-0.4	10.9	0.0	0.1
	Mean	9.9	21.1	1.9	10.6	11.0	22.2	2.2	11.0	12.8	24.0	1.9	11.2
	Max	21.3	31.1	117.3	20.8	22.8	32.6	166.1	21.1	24.5	34.3	131.6	21.7
NOV	Min	-13.2	-3.4	0.0	0.3	-11.4	-1.5	0.0	0.3	-9.1	0.8	0.0	0.3
	Mean	2.9	13.5	1.7	7.6	4.5	15.0	1.4	8.1	6.8	17.3	2.0	7.7
	Max	16.7	24.9	83.6	16.0	17.9	26.1	78.8	16.8	20.0	28.2	92.6	16.7
DEC	Min	-21.8	-6.5	0.0	0.1	-19.5	-4.3	0.0	0.1	-17.4	-2.1	0.0	0.1
	Mean	-2.8	7.0	0.9	6.8	-0.4	9.3	1.1	6.7	1.6	11.4	1.3	6.6
	Max	10.7	18.4	40.7	12.2	12.8	20.6	36.9	12.3	15.0	22.7	52.3	11.9

\* a: Min. Temp (°C)  
 \*\* b: Max. Temp (°C)  
 \*\*\* c: Rainfall (mm)  
 \*\*\*\* d: Solar radiation (MJ/m<sup>2</sup>/day)

으며, 결정계수 ( $R^2$ )은 0.658~0.832로 0.6 이상의 값을 나타내어 모형의 적용성이 인정되었다. 평균제곱근오차 (Root Mean

Square Error, RMSE)는 0.275~0.658 mm/day, 상대평균절대오차 (Relative Mean Absolute Error, RMAE)는 0.098~

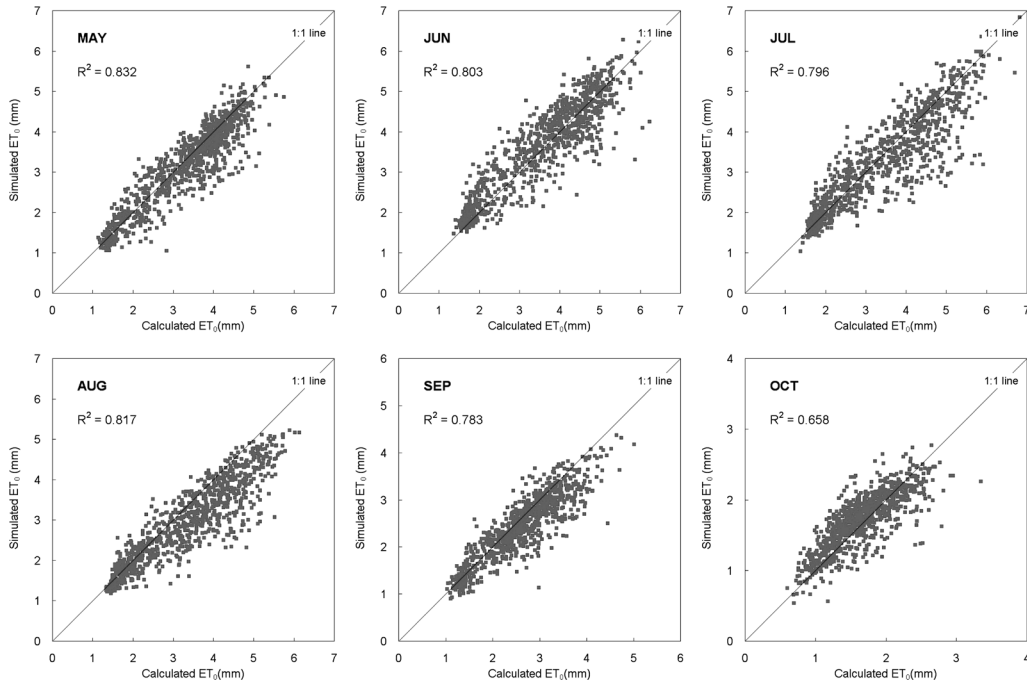


Fig. 2 Scatter plots comparing calculated  $ET_0$  by Penman-Monteith method and simulated  $ET_0$  by ANN for calibration data (May~October)

Table 3 Number of nodes in hidden layer and calibration and validation statistics for each month

Month	$n_h^*$	TE**	Calibration			Validation		
			$R^2$	RMSE (mm/day)	RMAE (mm/day)	$R^2$	RMSE (mm/day)	RMAE (mm/day)
MAY	10	0.423	0.832	0.443	0.098	0.895	0.377	0.080
JUN	19	0.605	0.803	0.536	0.115	0.886	0.611	0.143
JUL	14	0.709	0.796	0.602	0.125	0.882	0.563	0.145
AUG	19	0.629	0.817	0.658	0.148	0.919	0.404	0.085
SEP	18	0.307	0.783	0.393	0.110	0.857	0.352	0.095
OCT	4	0.187	0.658	0.275	0.132	0.724	0.301	0.133

\* Number of nodes in hidden layer

\*\* Total error

0.148 mm/day의 값을 나타냈다. 은닉층의 최적 노드수는 5월은 10개, 6월과 8월은 19개, 7월은 14개, 9월은 18개, 10월은 4개로 결정되었다. Fig. 2는 월별 잠재증발산량 예측모형에 의한 예측치와 기준 잠재증발산량을 1:1 그래프로 표시한 것이다. 모형의 보정결과 월별 잠재증발산량 예측모형 모두 학습이 효과적으로 이루어졌음을 알 수 있다.

2003년부터 2008년까지의 기상자료 및 Penman-Monteith 식에 의해 산정된 기준 잠재증발산량 값을 이용하여 모형을 검증하였다. Table 3과 Fig. 3은 모형의 검증결과를 나타낸다. 5월~10월까지 각각의 모형의  $R^2$ 은 0.724~0.919, RMSE는

0.301~0.611 mm/day, RMAE는 0.080~0.145 mm/day로 모의치가 실측치를 잘 반영하는 것으로 나타났다. 다만 10월의 경우 학습에 이용된 잠재증발산량 자료의 범위를 벗어나는 자료로 인해 모형의 적용성이 다른 모형에 비해 낮게 나타났다.

### 3. 장래 잠재증발산량 추정

HadCM3 A1B 시나리오를 적용하여 발생시킨 장래 기상자료와 월별로 구성된 잠재증발산량 예측모형을 이용하여 미래의 잠재증발산량을 모의하였다. LARS-WG 모형을 통해 생성된 2011-2030년 (2020s), 2046-2065년 (2055s), 2080-2099년 (2090s)의 100회분 기상자료를 이용하여 잠재증발산량을 모의하였으며, 모의된 5월~10월까지의 일별 잠재증발산량을 1년 단위로 합산하여 연간 잠재증발산량을 산정하였다. 선정된 연간 잠재증발산량 및 실측기간 (1973~2008년) 동안의 잠재증발산량의 평균은 다음 Table 4와 같다. 현재 1973~2008년까지 연 잠재증발산량 평균은 549.7 mm/yr로 나타났으며, 기후변화가 진행될수록 잠재증발산량이 증가하여 2020s에는 558.1 mm/yr로 과거에 비해 1.5 %, 2055s에는 593.0 mm/yr로 과거에 비해 7.9 %, 2090s에는 641.1 mm/yr로 과거에 비해 16.6 % 증가하는 것으로 예측되었다. Hong et al. (2009)은 우리나라 9개 지역의 잠재증발산량을 분석한 결과 기후변화로 인해 잠재증발산량이 지속적으로 증가할 것으로 예상하였으며,

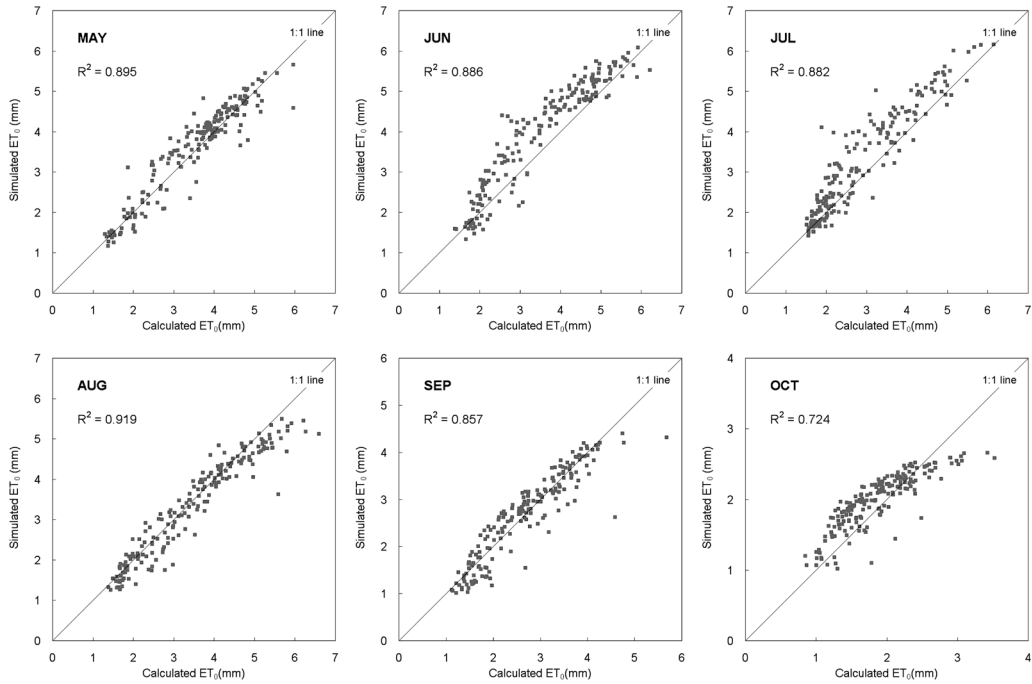


Fig. 3 Scatter plots comparing calculated  $ET_0$  by Penman-Monteith and simulated  $ET_0$  by ANN for validation data (May~October)

Table 4 Mean values of potential evapotranspiration ( $ET_0$ )

	1973-2008	2011-2030 (2020s)	2046-2065 (2055s)	2080-2099 (2090s)
$ET_0$ (mm/yr)	549.7	558.1	593.0	641.1

증가율은 기준년도 (1971-2000년) 대비 2011-2040년 (2025s)에는 4.5 %, 2041-2070년 (2055s)에는 10.4 %, 2071-2100년 (2085s)에는 16.4% 로 예상한 바 있다.

#### IV. 결 론

본 연구에서는 오류역전파 알고리즘을 이용한 잠재증발산량 예측모형을 5월부터 10월까지 총 6개의 모형을 월별로 구성하였다. 구성된 모형을 이용하여 기후변화에 따른 장래 잠재증발산량을 예측하였다. 연구결과를 요약하면 다음과 같다.

1. 수원기상대에서 제공하는 1973년~2008년까지 일별 최고/최저/평균기온, 평균풍속, 상대습도, 강수량, 태양복사량 및 일조시간 자료를 수집하고, FAO Penman-Monteith 식을 통해 일별 잠재증발산량을 산정하였다.

2. 수원기상대의 실측 일별 최고기온, 최저기온, 강수량, 태양복사량 자료를 이용하여 일기상발생기인 LARS-WG 모형을 통해 HadCM3의 A1B 시나리오를 적용하여 2011-2030년

(2020s), 2046-2065년 (2055s), 2080-2099년 (2090s)의 일별 기상자료를 발생시켰다. 기후변화가 진행될수록 최고기온, 최저기온은 올라가고, 강수량은 증가하며 태양복사량은 감소하는 것으로 나타났다.

3. 일 최고/최저기온, 강수량, 태양복사량 자료로부터 잠재증발산량을 예측하기 위해 인공신경망 기법을 이용하여 잠재증발산량 예측모형을 구성하였으며, 5월부터 10월까지 총 6개의 모형을 구성하였다. 1973~2002년 자료를 모형의 보정에 사용하였으며, 모형의 보정결과 은닉층의 최적 노드수는 5월은 10개, 6월과 8월은 19개, 7월은 14개, 9월은 18개, 10월은 4개로 결정되었다. 2003~2008년 자료를 이용하여 모형을 검증하였으며, 검증 결과 모의치가 실측치를 잘 반영하는 것으로 나타났다.

4. HadCM3 A1B 시나리오를 적용하여 발생시킨 장래 기상자료와 월별로 구성된 잠재증발산량 예측모형을 이용하여 미래의 잠재증발산량을 모의하였다. 모의된 5월~10월까지의 일별 잠재증발산량을 1년 단위로 합산하여 연간 잠재증발산량을 산정하였으며, 1973~2008년 (baseline period)의 연 잠재증발산량 평균은 549.7 mm/yr, 2020s에는 558.1 mm/yr, 2055s에는 593.0 mm/yr, 2090s에는 641.1 mm/yr로 기후변화가 진행됨에 따라 잠재증발산량이 증가하는 것으로 나타났다.

본 연구는 21세기 프론티어 연구개발 사업인 수자원의 지속적 확보기술개발 사업단의 연구비지원 (과제번호 4-5-3)에 의해 수행되었습니다.

## REFERENCES

1. Allen, R. G., L. S. Periera, D. Raes, and M. Smith, 1998. Crop evapotranspiration: Guidelines for computing crop requirements, Irrigation and Drainage Paper Vol. 56. Food and Agriculture Organization of the United Nations.
2. Bae, D. H., I. W. Jung, and W. T. Kwon, 2007. Generation of high resolution scenarios for climate change impacts on water resources(I): Climate scenarios on each sub-basins. *Journal of Korea Water Resources Association* 40(3): 191-204 (in Korean).
3. Blaney, H. F., and W. D. Criddle, 1962. Determining consumptive use irrigation water requirements. *USDA. Tech. Bul.* 1275: 59.
4. Chung, S. O., 2009. Climate change impacts on paddy irrigation requirement in the Nakdong River Basin. *Journal of the Korean Society of Agricultural Engineers* 51(2): 35-44 (in Korean).
5. FAO, 1998. Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56.
6. Gorka L., O. Amaia, and J. Jose, 2008. Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country. *Agricultural Water Management* 95: 553-565.
7. Harvey, R. L., 1994. Neural Network Principles. *Prentice Hall*, NewJersey.
8. Hong, E. M., J. Y. Choi, S. H. Lee, S. H. Yoo, and M. S. Kang, 2009. Estimation of Paddy Rice Evapotranspiration Considering Climate Change Using LARS-WG. *Journal of the Korean Society of Agricultural Engineers* 51(3): 25-35 (in Korean).
9. Huynh, N. P. and S. Sureerattanan, 2000. Neural networks for filtering and forecasting of daily and monthly streamflows. *Water Resources Publications*, LLC, WEESHE, Hydrologic modeling, 203-218.
10. Intergovernmental Panel on Climate Change (IPCC), 2007. Fourth Assessment Report.
11. Intergovernmental Panel on Climate Change (IPCC), 2008. Technical Paper on Climate Change and Water.
12. Jain, S. K., P. C. Nayak, and K. P. Sudheer, 2008. Models for estimating evapotranspiration using artificial neural networks and their physical interpretation. *Hydrological Processes* 22: 2225-2234.
13. Jensen, M. E., R. D. Burman, and R. G. Allen, 1990. ASCE Manual and reports on Engineering Practices 330-331. No. 70. NewYork: Evaporation and irrigation water requirements.
14. Jung, S., 2004. Artificial Intelligence system I - Structure and instruction of neural network. *Chungnam National University Press*, Daejeon (in Korean).
15. Kang, M. S., and S. W. Park, 2003. Short-term flood forecasting using artificial neural networks. *Journal of the Korean Society of Agricultural Engineers* 45(2): 45-57 (in Korean).
16. Kumar, M., N. S. Raghuvanshi, and R. Singh, 2009. Development and validation of GANN model for evapotranspiration estimation. *Journal of Hydrologic Engineering* 41(2): 131-140.
17. Ministry of Construction & Transportation (MOCT), 2006. National Water Resources Plan update (in Korean).
18. Odhiambo, L. O., R. E. Yoder, D. C. Yoder, and J. W. Hines, 2001. Optimization of fuzzy evapotranspiration model through neural training with input-output examples. *Trans. ASAE* 44: 1625-1633.
19. Penman, H. L., 1948. Natural evaporation from open water, bare soil, and grass. *The Royal Society* 193: 120-145.
20. Richardson, C. W., and D. A. Wright, 1984. WGEN: A Model for Generating Daily Weather Variables, United States Department of Agriculture Research Service, ARS-8.
21. Semenov, M. A., and E. M. Barrow, 2002. LARS-WG: A Stochastic Weather Generator for Use in Climate Impact Studies, Harpenden.
22. Son, G. T., 2003. Introduction of Computation Statistics (3th ed). *Freedom Academy*, Seoul.
23. Sudheer, K. P., A. K. Gosain, and K. S. Ramasastri, 2003. Estimating actual evapotranspiration from limited



- climatic data using neural computing technique. *Journal of Irrigation and Drainage Engineering* 129(3): 214-221.
24. Xiaoqin, D., S. Haibin, L. Yunsheng, O. Zhu, and H. Zailin, 2009. Artificial neural network models for estimating regional reference evapotranspiration based on climate factors. *Hydrological Processes* 23: 442-450.
25. Zanetti, S. S., E. F. Sousa, V. P. S. Oliveira, F. T. Almeida, and S. Bernardo, 2007. Estimation evapotranspiration using neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering* 133(2): 83-89.