



## 인공신경망모형을 이용한 기온기반 기준증발산량 산정

### Estimating Reference Crop Evapotranspiration Using Artificial Neural Network and Temperature-based Climatic Data

이성학<sup>a</sup> · 김마가<sup>b</sup> · 최진용<sup>c,†</sup> · 방재홍<sup>d</sup>

Lee, Sung-Hack · Kim, Maga · Choi, Jin-Yong · Bang, Jehong

#### Abstract

Evapotranspiration (*ET*) is one of the important factor in Hydrological cycle and irrigation planning. In this study, temperature-based artificial neural network (ANN) model for daily reference crop *ET* estimation was developed and compared with reference crop evapotranspiration ( $ET_0$ ) from FAO-56 Penman-Monteith method (FAO-56 PM) and parameter regionalized Hargreaves method. The ANN model was trained and tested for 10 weather stations (5 inland stations and 5 costal stations) and two input climate factors, maximum temperature ( $T_{max}$ ), minimum temperature ( $T_{min}$ ), and extraterrestrial radiation ( $RA$ ) were used for training and validation of temperature-based ANN model. Monthly reference *ET* by the ANN model also compared with parameter regionalized Hargreaves method for ANN model applicability evaluation. The ANN model evapotranspiration demonstrated more accordance to FAO-56 PM evapotranspiration than the  $ET_0$  from parameter regionalized Hargreaves method(R-Hargreaves). The results of this study proposed that daily reference crop *ET* estimated by the ANN model could be used in the condition of no sufficient climate data.

**Keywords:** Artificial neural network; evapotranspiration; FAO-56 Penman Monteith modthod; Hargreaves method

## 1. 서 론

농업용수의 효율적인 관리와 공급계획의 수립을 위해서는 농업용수 수요분석이 반드시 필요하며, 작물의 증발산량의 산정은 농업용수 수요분석의 핵심적인 요소 중 하나이다. 작물의 증발산량 산정은 증발산계를 이용하여 관측하거나 물수지 기법 혹은 기상변수를 이용하여 추정한다. 국제식량 농업기구 (United Nations Food and Agriculture Organization, 이하 FAO)는 기준증발산량 (reference crop evapotranspiration,  $ET_0$ )을 산정하기 위한 기준 방법으로 FAO-56 Penman-Monteith법(이하 FAO-56 PM법)을 제시하고 있다 (Allen et al., 1994).

FAO-56 PM법은 기후에 상관없이 전 세계 대부분의 지역에 적용할 수 있는 장점이 있지만 기준증발산량 산정을 위해서는 많은 기상인자가 필요한 단점이 있다. 기상자료가 제한된 경우 FAO는 기온자료만을 이용하여 기준증발산량을 산정할 수 있는 Hargreaves법을 추천하고 있다 (Allen et al., 1994). Hargreaves법은 기상인자 중 기온만을 활용하여 적용할 수 있는 장점이 있으나 (Hargreaves et al., 1985), 최소 주단위 이상의 기간에서만 사용이 가능하고 바람에 따른 이류(advection)에 의해 과대/과소 산정되는 특성이 있어 이를 보완하기 위하여 사용되는 매개변수를 지역화 하여야 하는 단점이 있다.

Hargreaves법의 단점을 극복하기 위하여 Moon et al.(2013)은 우리나라의 기후특성을 고려하여 70개 지점에 대한 Hargreaves법의 지역화 매개변수를 제시한 바 있으며, 기존 Hargreaves법보다 지역화 매개변수를 적용한 Hargreaves법(이하 R-Hargreaves)을 적용하는 것이 성능이 우수함을 보인 바 있다.

기상자료가 제한되어 있는 경우 기존의 경험식 기반의 기준증발산량 산정방법을 대체하기 위하여 데이터 기반의 방법론인 인공신경망을 활용한 기준증발산량 산정 연구가 2000년대 들어 활발하게 수행되어 왔다 (Kumar et al., 2011). 인공신경망모형은 미리 측정된 자료들 속에서 의미 있는 패턴과 규칙을 탐색하고 분석하여 일정한 규칙을 찾아내는 기계적 알

<sup>a</sup> PhD Student, Department of Rural Systems Engineering, Seoul National University

<sup>b</sup> MS Student, Department of Rural Systems Engineering, Seoul National University

<sup>c</sup> Professor, Department of Rural Systems Engineering, Research Institute of Agriculture and Life Sciences, Seoul National University

<sup>d</sup> PhD Student, Department of Rural Systems Engineering, Seoul National University

† Corresponding author

Tel.: +82-2-880-4583 Fax: +82-2-873-2087

E-mail: iamchoi@snu.ac.kr

Received: April 10, 2017

Revised: November 8, 2018

Accepted: November 8, 2018

고리증이다. 인공신경망모형을 이용하여 기상 인자가 제한된 경우 기준증발산량을 산정하는 가용한 기상 인자의 조합에 따라 인공신경망모형을 적용하고 결과를 FAO-56 PM법과 비교하는 연구가 여러 연구자들에 의하여 수행된 바 있다 (Sudheer et al., 2003; Trajkovic, 2005; Zanetti et al., 2007; Wang and Kerh, 2008; Trajkovic and Kolakovic, 2009; Gocic and Trajkovic, 2010; Lee et al., 2010). 인공신경망모형을 활용한 기준증발산량 산정연구는 인공신경망을 구성하는 요소의 변화에 따른 방법론에 중점을 둔 연구와 기상인자가 제한된 경우 기준증발산량을 산정하는 하는 연구로 크게 나눌 수 있으며, 기준증발산량의 산정결과 평과는 FAO-56 PM법의 결과와 비교하는 점에서는 동일하다고 할 수 있다.

본 연구에서는 일 최고/최저기온을 활용하여 기온기반 기준증발산량을 산정하기 위해위해 인공신경망모형을 구성하고 내륙과 해안지역의 기상관측소를 각각 선정하여 FAO-56 PM법과 기준증발산량을 산정결과를 비교하였다. 또한 기온기반 기준증발산량 산정 방법인 R-Hargreaves법, 인공신경망모형과 FAO-56 PM법의 기준증발산량 산정결과를 비교하고 적용성을 평가하였다.

## II. 연구방법

### 1. 대상지역

본 연구에서는 기준증발산량을 산정하기 위하여 내륙지역 5개, 해안지역 4개의 총 9개 기상관측소의 최고/최저기온, 평균기온, 일조시간, 상대습도, 이슬점, 평균풍속자료를 수집하였다. 대상 기상관측소 재원과 인공신경망모형 및 R-Hargreaves법의 적용에 사용된 자료기간을 Table 1과 같다. 대상 기상관측소 자료 기간은 일별 기준증발산량 산정 인공신경망 모형의 학습을 위하여 관측시점~2010년 까지의 일별

기상자료를 활용하였으며, 인공신경망 모형의 검증과 R-Hargreaves법의 비교를 위하여 2011년~2015년 까지 5개년의 자료를 활용하였다.

### 2. 기준증발산량 (ET<sub>0</sub>) 산정 방법

#### 가. FAO-56 Penman-Monteith법 (FAO-56 PM)

증발산량은 수문순환의 중요한 요소이며, 정확한 증발산량의 산정은 관개계획 수립, 관개시스템 설계 및 운영에 있어 필수적이다. 작물의 실제증발산량은 기준작물증발산량 (reference crop evapotranspiration)과 작물계수 (crop coefficient)를 곱하여 산정된다. FAO에서는 FAO-56 PM법을 표준적인 기준증발산량 산정 및 평가방법으로 제시한바 있다(Allen et al., 1994). FAO-56 PM법은 Penman 공식의 공기동역학 조건에 작물형에 따른 기공저항 포함하여 수정한 방법이며, FAO-56 Penman-Monteith법에서 기준증발산량을 산정하기 위해서는 최고/최저기온, 최고/최저 상대습도, 복사량 (또는 일조시간) 및 평균풍속 (2 m 높이)의 자료가 사용되며 식 (1)을 이용하여 산정할 수 있다.

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

여기서,  $ET_0$ =기준기준증발산량 (mm/day),  $\Delta$ =증기압 곡선의 기울기 (kPa/°C),  $R_n$ =지구(작물)표면에서 순수하게 축적되는 에너지(순일사량)(MJm<sup>-2</sup>day<sup>-1</sup>),  $G$ =토양 열 유속 밀도(MJm<sup>-2</sup>day<sup>-1</sup>),  $\gamma$ =건습계 상수 (kPa/°C),  $T$ =2 m 높이에서 일평균기온 (°C),  $u_2$ =2 m 높이에서 풍속 (m/s),  $e_s$ =포화 증기압 (kPa)을 나타낸다.

Table 1 Description of weather stations used in this study

Weather Station	Latitude	Longitude	Elevation(m)	Artificial Neural Network		R-Hargreaves
				Train	Validation	
Inland	Daegu	35° 53'	128° 37'	57.3	1962-2010	2011-2015
	Daejeon	26° 22'	127° 22'	62.6	1969-2010	
	Suwon	37° 16'	126° 59'	34.5	1964-2010	
	Jeonju	35° 49'	127° 09'	61.0	1962-2010	
	ChunCheon	37° 54'	127° 44'	145.5	1966-2010	
Costal	Gangneung	37° 45'	128° 53'	26.1	1962-2010	
	Mokpo	34° 49'	126° 22'	37.4	1962-2010	
	Ulsan	35° 33'	129° 19'	34.6	1962-2010	
	SeongSan	33° 23'	126° 52'	18.4	1973-2010	

나. Hargreaves법

Hargreaves법은 온도와 지표면에 도달하는 일사량 (solar radiation, 이하  $RS$ )에 기반하여 기준증발산량을 산정하도록 Hargreaves가 1975년에 제안한 경험식(Hargreaves, 1975)으로 식 (2)와 같다.

$$ET_0 = 0.0135 \times RS(TC + 17.8) \quad (2)$$

여기서,  $RS$ 는 지표면에 도달하는 일사량에 상응하는 물의 양,  $TF$ 는 섭씨 (Celsius)의 단위를 갖는 평균기온으로 최고기온과 최저기온의 평균을 통해 산정되는 값이다. Hargreaves법이 제시된 이후 수행된 연구결과 (McVicker, 1982; Jesen, 1974; Slih, 1984; Salih and Sendil, 1984)는 대부분의 지역에서 평균온도와 일사량 자료만으로 기준 기준증발산량을 충분히 추정할 수 있음을 나타낸다 (Hargreave and Samani, 1985). Hargreaves법은 바람에 의한 이류 (advection) 효과가 강하게 나타나는 지역에서는 해당 지역에 맞도록 보정하여 사용해야 한다.

또한, 일사량값 ( $RS$ )을 실제 관측으로 구하기 어려운 지역의 경우 관측소 재원자료를 이용하여 대기권 밖 일사량 (extraterrestrial radiation, 이하  $RA$ )를 산정한 후 이를 통하여  $RS$ 값을 구할 수 있는 관계식을 식 (3)과 같이 제시하였다 (Hargreave and Samani, 1985).

$$RS = K_{RS} \times RA \times TD^{0.50} \quad (3)$$

여기서,  $K_{RS}$ 는 보정계수 (calibration coefficient)이며,  $TD$ 는 최고기온과 최저기온의 차이를 나타낸다. Hargreaves and Samani (1985)는  $RS$ 를 직접 구하기 어려운 지역에서 사용할 수 있도록 식 (3)를 식 (2)에 대입하여 아래 식 (4)를 제시하였다.

$$ET_0 = K_{ET} \times RA \times (TC + 17.8) \times TD^{0.50} \quad (4)$$

여기서,  $K_{ET}$ 는 Hargreaves 공식의 매개변수이다. Hargreaves and Samani (1985)는 미국 California Davis의 8년간 라이시미터 (lysimeter) 측정자료를 사용하여  $K_{ET}$ 를 0.0023로 제시하였다.

국내에서는 Moon et al.(2013)이 전국 70개 기상관측소자료를 활용하여 각각의 관측소별  $K_{ET}$ 값과 식 (2)의  $TD$ 항 지수 (exponent)값을 0.50에서 0.58로 수정하여 제시한 바 있다.

3. 인공신경망(Artificial neural network)모형

인공신경망모형은 인간 두뇌의 정보처리방식을 컴퓨터로 모방하여 단순한 계산 연산을 수행하는 아주 많은 연산기와 그들 간의 연결을 통해 지능적인 일을 달성하려는 계산 모형이다 (Oh, 2008). 인공신경망모형은 크게 입력층 (input layer), 은닉층 (hidden layer), 출력층 (output layer)로 나눌 수 있으며, 각 층은 1개 이상의 노드 (node)로 구성된다. Fig. 1과 같이 각 층의 노드는 다른 층의 노드와 가중치 (weight)로 연결되어 있다. 훈련 집합이 주어지면 가중치를 자동으로 추정하여 신경망을 구성하며, 이러한 과정을 학습 (training)이라 한다. 이러한 측면에서 인공신경망모형은 일종의 블랙박스모형으로 간주할 수 있다. 인공신경망모형은 입력변수와 출력변수 간의 정확한 인과관계를 표현하지 못한다는 단점이 있어 변수 간의 명백한 규칙을 규명하기는 어렵다는 한계가 있으나, 특이치가 있거나 불규칙한 모형에서도 우수한 예측력을 지니는 특징이 있다 (Makridakis et al., 1998).




Fig. 1 Structure of typical multi-layer neural network

인공신경망모형은 은닉층과 출력층을 구성하고 있는 노드들은 합산함수 (summing function)와 활성화함수 (activation function)를 가지고 있으며, 은닉층의 활성화함수로는 시그모이드함수 (sigmoid function), 쌍곡선 탄젠트함수 (hyperbolic tangent function, tanh) 등의 비선형 함수가 주로 이용된다. 신경망모형의 학습을 위해서는 최적화 기법이 이용되며, 목적함수는 델타법칙 (delta rule)에 기초하고 있다. 인공신경망모형의 훈련은 주어진 훈련집합에 대해 전방계산으로 오류를

추정한 후 출력층에서 시작하여 반대방향으로 오류를 반대방향으로 전파하는 방법을 이용하며, 이를 오류 역전파 알고리즘 (error back-propagation algorithm) 이라 한다. 인공신경망모형의 훈련은 실측치와 모의치의 최소 자승인 가중합수를 최소화하는 것으로서 교사훈련 (supervised training)이라고 하며 (Kang et al., 2003), 식 (5)와 같이 표현된다.

$$E = \frac{1}{2} \sum_{p=1}^n \sum_{k=1}^m (y_{pk} - P_{pk})^2 \quad (5)$$

여기서,  $E$ = 총오차,  $n$ =실측치의 패턴 수,  $m$ =총 출력단위,  $y_{pk}$ = 실측된 반응인 목표 출력값으로서 FAO-56 Penman-Monteith법에 의해 산정된 기준증발산량,  $P_{pk}$ =모형에 의한 모의 출력값으로서 인공신경망모형 모형에 의해 모의된 기준증발산량을 나타낸다. 인공신경망모형의 훈련 알고리즘은 경사하강법 (gradient descent algorithm), 공액경사하강법 (conjugate gradient descent method), Levenber-Marquardt 알고리즘 등이 사용된다.

#### 4. 기준증발산량(ET<sub>0</sub>) 산정 인공신경망모형의 구성

기준증발산량 산정을 위한 인공신경망모형의 입력자료는 각 기상관측소의 최저/최고기온 및 대기권 밖 일사량 자료를 적용하였다. 본 모형의 입력자료 구성은 Hargreaves법의 입력자료와 동일하며, 대기권 밖 일사량은 재원정보를 활용하여 산정하였다.

인공신경망모형은 자료의 범위 내에서 훈련(Learning)을 수행하는 내삽법(interpolation)에 해당하므로 훈련에 이용되는 자료의 기간이 길수록 좋다. 따라서 각 관측소의 관측시작 시점부터 2010년까지를 훈련 데이터로 하였으며, 2011년부터 2015년까지를 인공신경망모형 검증 (Validation)기간으로 설정하여 자료를 구축하였다.

증발산은 작물의 생육기간, 관개기간 등이 고려되어 산정되어야 하므로 작물 생육기간과 관개기간인 5월부터 10월까지를 대상 기간으로 하여 자료를 구축하였다.

인공신경망모형의 입력자료가 결정되면 모형 적용을 위한 은닉층 (hidden layer)의 최적노드 수, 활성화함수 (activation function), 학습 (learning)방법, 손실함수 (loss function)을 결정하여야 한다. 은닉층 (hidden layer)의 최적 노드 수는 입력층에 사용되는 기상인자의 수, 출력층의 노드수, 활성화함수 종류, 훈련 알고리즘 등에 따라 달라진다 (Kumar et al., 2011). Lee et al.(2010)이 인공신경망모형을 수원기상관측소에 대하여 관개기인 5월부터 10월까지 월별로 적용한 결과 입력층 노드가 4개 (최저/최고기온, 강수량, 일사량)일 때 최적의 은닉층 수

는 4개에서 19개 까지 월별로 상이하다고 하였으며, Kumar et al.(2002)는 인공신경망모형을 이용한 기준증발산량 산정 시 은닉층 최적 노드수는 입력층 노드수 (I)에 따라 변하며, 그 범위는 I+1과 I×2사이라고 하였다. 따라서 본 연구에서 은닉층 최적 노드수는 모형을 대상지역에 적용한 후 검증결과에 따라 과적합을 피하는 최적의 은닉층 노드수로 결정하였다. 최적 은닉층 노드수는 갯수를 1에서 20까지 변화시키면서 1000회 반복 수행을 실시하고 본 모형과 FAO-56 PM 법에 의한 기준증발산량 추정결과를 비교하여 최적의 노드수를 결정하였다.

최적의 노드수를 결정하기 위한 성능평가지표는 절대평균오차 (Mean absolute error, MAE), 평균제곱근오차 (Root mean square error, RMSE), 결정계수 (Coefficient of determination, R<sup>2</sup>) 값을 사용하였다.

은닉층의 활성화함수 (activation function)은 일반적으로 사용되는 시그모이드함수 (sigmoid function)을 사용하였다. 인공신경망모형은 입력자료의 절대적인 크기에 매우 민감하다 (Kumar et al., 2011). 따라서 입력자료의 절대적 크기에 영향을 줄이기 위하여 입력자료 정규화 (normalization)을 수행하였다. 입력자료 정규화방법에는 입력자료의 최대치, 표준편차, 최대 및 최소치의 차이 등을 활용하는 방법이 있으며, 본 연구에서는 Kisi (2009)이 제시한 식 (6)과 같은 정규화 방법을 사용하였다.

$$x_{norm} = 0.5 \times \left( \frac{x_0 - \bar{x}}{x_{max} - x_{min}} \right) + 0.5 \quad (6)$$

여기서,  $x_{norm}$ 은 정규화 후의 입력자료 값,  $x_0$ 는 정규화 이전 입력값,  $\bar{x}$ 는 평균,  $x_{max}$ 는 최대값,  $x_{min}$ 은 최소값이다. 식 (6)를 통하여 입력자료는 0에서 1사이의 값으로 정규화 된다.

본 모형의 학습을 위하여 Levenberg-Marquardt 학습 알고리즘을 적용하였다. Levenberg-Marquardt 알고리즘은 수렴속도가 빠르고 경사하강법 (gradient descent method) 비하여 학습율 (learning rate)을 설정하지 않아도 되는 장점이 있다.

### III. 연구결과

#### 1. 인공신경망모형 기반 기준증발산량 산정

본 연구에서 구축된 일별 기준증발산량 산정 인공신경망모형을 활용하여 9개 지점(내륙 5개 지점, 해안 4개 지점)의 기상자료 (최저/최고기온, 대기권 밖 일사량)에 대하여 인공신경망모형의 훈련(training)과 검증(validation)을 수행하였다. 인

**Table 2** Number of nodes in hidden layer and calibration and validation stats for each stations(observation start time~2010)

Weather station		$N_h^*$	Training			Validation		
			MAE (mm/day)	RMSE (mm/day)	R <sup>2</sup>	MAE (mm/day)	RMSE (mm/day)	R <sup>2</sup>
Inland	Daegu	9	0.502	0.584	0.760	0.501	0.575	0.778
	Daejeon	9	0.426	0.510	0.786	0.415	0.441	0.838
	Suwon	6	0.391	0.466	0.793	0.437	0.498	0.787
	Jeonju	5	0.365	0.447	0.818	0.403	0.489	0.808
	ChunCheon	7	0.367	0.455	0.829	0.362	0.429	0.850
Costal	Gangneung	11	0.545	0.655	0.733	0.569	0.647	0.756
	Mokpo	7	0.487	0.534	0.695	0.464	0.458	0.736
	Ulsan	4	0.483	0.549	0.735	0.495	0.584	0.728
	SeongSan	6	0.544	0.542	0.604	0.567	0.566	0.578

\* Number of nodes in hidden layer

공신경망 모형에 사용된 훈련 및 검증자료는 FAO-56 PM법의 기준증발산량 산정결과를 활용하였다. Table 2는 관개기 (5월-10월)기간에 대한 9개 지점의 기준증발산량 산정을 위한 인공신경망모형의 최적 은닉층 노드수 ( $N_h$ ), 모형의 훈련 및 검증 결과를 나타낸다.

일별 기준증발산량 산정 인공신경망 모형의 훈련결과 절대평균오차 (MAE)는 0.365~0.545사이 값을 나타냈다. 내륙지역의 경우 0.365~0.502범위의 값이 나타났으며, 해안지역에서는 0.483~0.545의 범위를 나타내었다. 평균제곱근오차 (RMSE)는 전체 지점에 대하여 0.447~0.655의 범위를 나타내었으며, 내륙지역은 0.447~0.584, 해안지역은 0.531~0.655의 범위를 나타내었다. 결정계수 ( $R^2$ )은 0.604~0.829의 범위를 나타내었으며, 내륙지역은 0.760~0.829, 해안지역은 0.604~0.735의 범위를 나타내었다. 결정계수 ( $R^2$ )는 0.6이상의 값을 나타내어 모형의 적용성이 인정되었으며, 인공신경망 훈련결과 최적 은닉층 노드수는 4-11개로 나타났으며, 내륙지역이 해안지역에 비해 FAO-56 PM법에 의한 기준증발산량 산정 결과에 가까운 값을 나타내어 상대적으로 높은 적용성을 보였다.

Fig. 2는 9개 지점에 대해 FAO-56 PM방법과 인공신경망기반 일별 기준증발산량 산정결과를 1:1 그래프로 나타낸 것이며 인공신경망에 의한 기준증발산량 산정결과가 FAO-56 PM법의 기준증발산량 산정결과를 효과적으로 모의하고 있는 것을 알 수 있다.

일별 기준증발산량산정 인공신경망모형의 검증결과 각 지점의 절대평균오차 (MAE)는 0.362~0.569의 범위를 나타냈으며, 내륙지역은 0.362~0.501, 해안지역은 0.464~0.569의 범위를 나타냈다. 평균제곱근오차 (RMSE)는 전체 지점에 대해

서 0.429~0.647의 범위를 나타냈으며, 내륙지역은 0.429~0.575, 해안지역은 0.458~0.647의 범위로 나타났다. 결정계수 ( $R^2$ )는 전체 지점에 대해서 0.578~0.850의 범위를 나타냈으며, 내륙지역은 0.778~0.850, 해안지역은 0.578~0.756의 범위를 나타냈다. 성산관측소를 제외하고 모두 결정계수 0.6이상의 값을 나타내어 FAO-56 법의 기준증발산량을 잘 모의하는 것으로 나타났다. 다만, 성산관측소의 경우 결정계수 값이 낮게 나타난 것은 기준증발산량에 영향을 미치는 요소 중 하나인 평균 풍속이 섬이라는 지역적 특성에 따라 다른 지역에 비해 크고, 변화가 심하기 때문인 것으로 판단된다.

Fig. 3는 9개 기상관측소의 검증기간(2011년~2015년)에 대한 일별 기준증발산량 산정 결과를 인공신경망 모형 기반 기준증발산량 산정 결과를 1:1 그래프로 비교하여 나타낸 것이다. 9개 지점에 대한 기준증발산량 산정 인공신경망모형의 학습이 효과적으로 이루어졌음을 알 수 있으며, 검증기간에 대해서도 내륙지역이 해안지역에 비해 상대적으로 학습이 효과적임을 그래프 상에서도 확인할 수 있다.

## 2. 인공신경망모형과 매개변수지역화 Hargreaves (R-Hargreaves)법 기준증발산량 산정결과 비교

R-Hargreaves법법의 경우 최소 주단위 이상의 기간에 적용 가능도록 권장하고 있으며, 일반적 월단위 증발산량 산정에 주로 활용하고 있다. 따라서 R-Hargreaves법과의 비교를 위해서는 일단위가 아닌 월단위로 비교하는 것이 타당하다. 이를 위하여 일단위로 산정된 기준증발산량 산정 인공신경망 모형과 FAO-56 PM법의 결과를 월단위 증발산량으로 변환하고 이를 R-Hargreaves법의 월단위 기준증발산량 산정결과와 비교하였다.

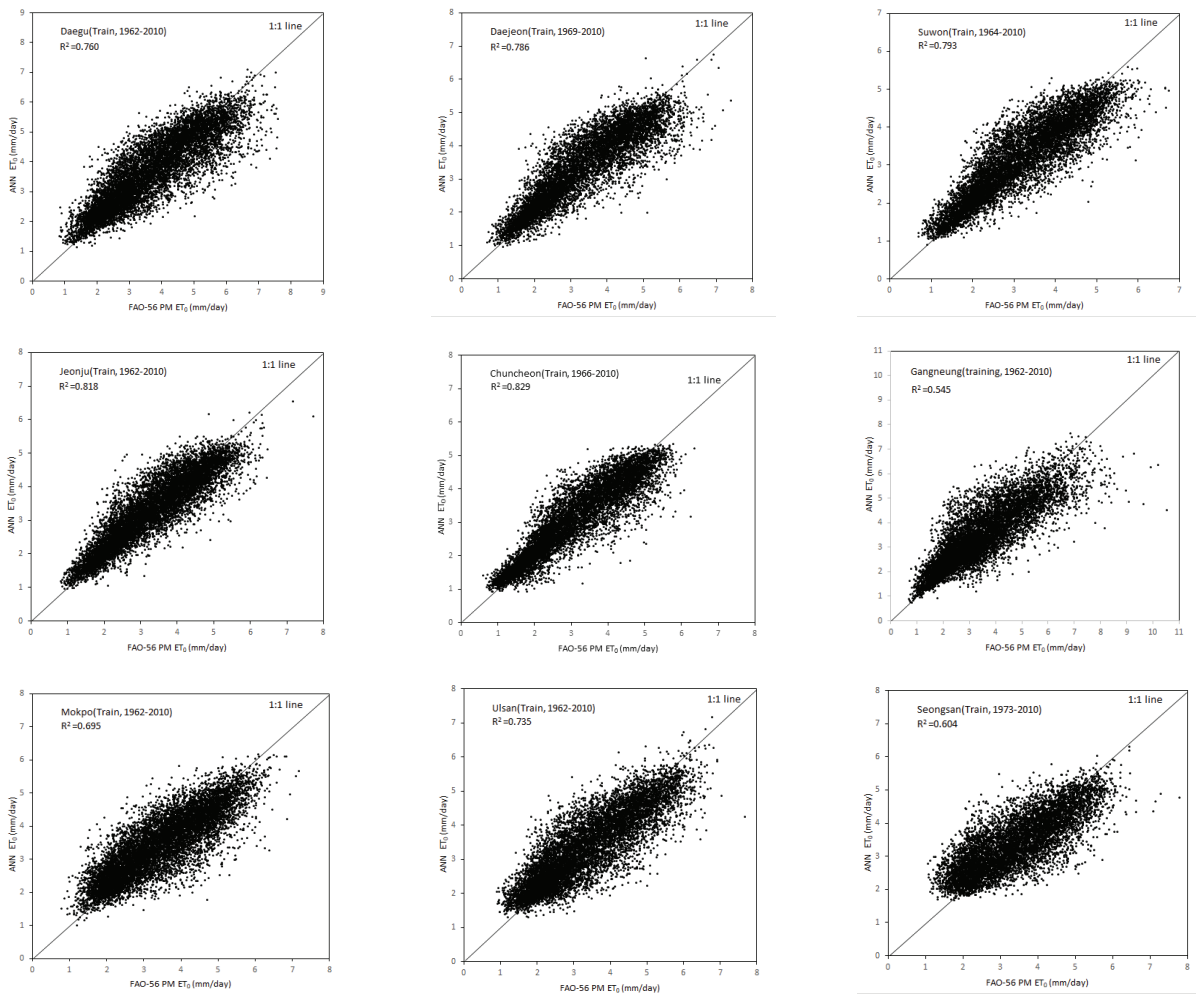


Fig. 2 Scatter plots comparing calculated daily  $ET_0$  by FAO-56 PM method and simulated  $ET_0$  by artificial neural network method for training data

Table 3 Statics of monthly evapotranspiration estimated by ANN and adjusted Hargreaves method for each stations during test period (2011~2015)

Weather station	Artificial Neural Network			R-Hargreaves			
	MAE (mm/month)	RMSE (mm/month)	R <sup>2</sup>	MAE (mm/month)	RMSE (mm/month)	R <sup>2</sup>	
Inland	Daegu	4,720	5,869	0,951	9,533	11,809	0,949
	Daejeon	3,995	4,759	0,991	6,137	7,909	0,942
	Suwon	4,340	5,317	0,955	4,116	5,041	0,960
	Jeonju	4,872	5,973	0,940	5,419	6,489	0,933
	Chuncheon	3,985	4,907	0,982	4,785	5,883	0,966
Costal	Gangneung	8,211	10,169	0,909	8,242	10,356	0,855
	Mokpo	6,057	7,271	0,890	13,322	15,158	0,736
	Ulsan	6,097	7,080	0,916	7,074	9,014	0,871
	SeongSan	5,905	7,367	0,839	9,310	10,653	0,672

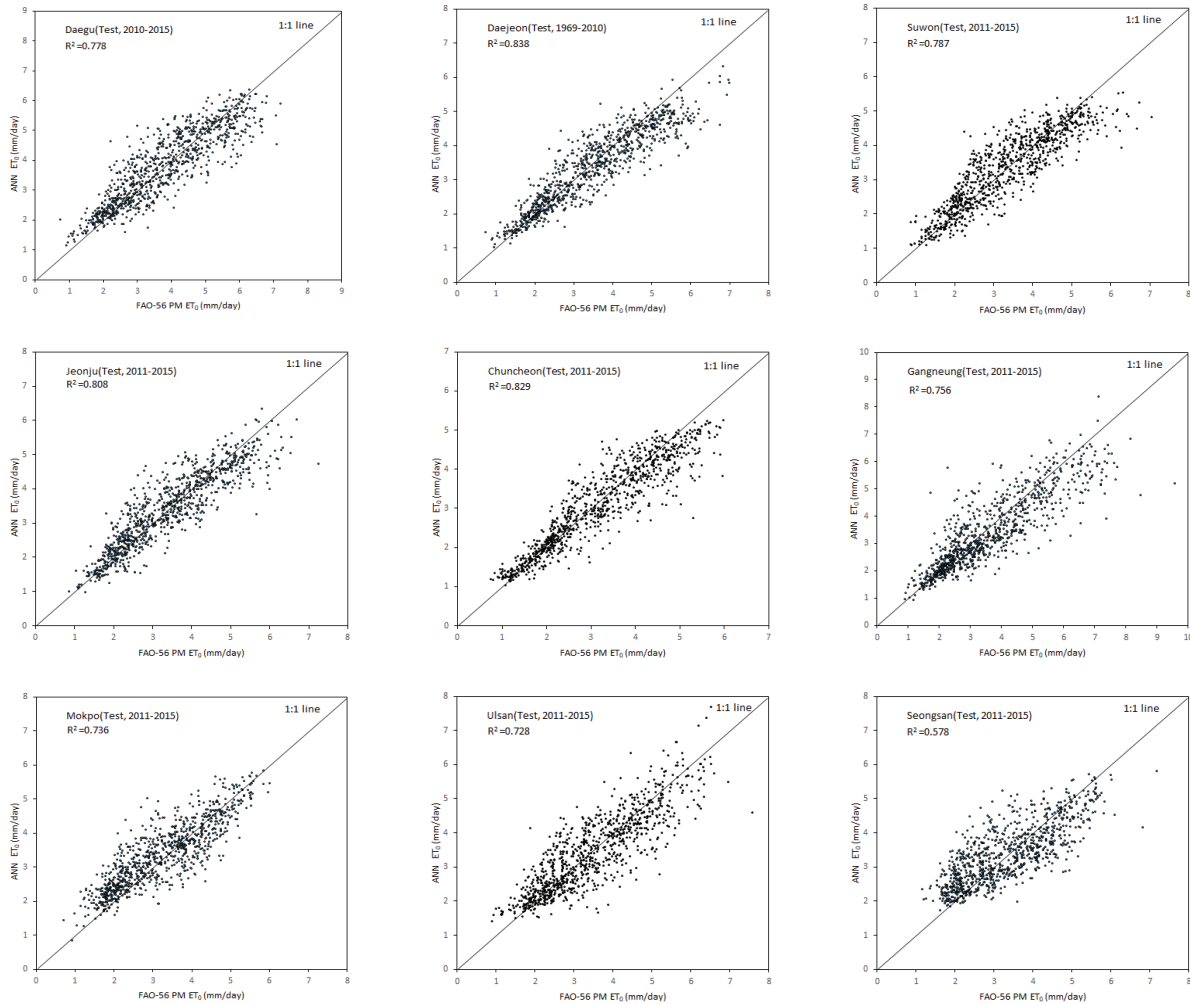


Fig. 3 Scatter plots comparing calculated daily  $ET_0$  by FAO-56 PM method and simulated  $ET_0$  by artificial neural network method for validation data

Table 3는 9개 기상관측소의 2011년부터 2015년 범위의 관개기 (5월-10월) 기상자료만을 활용하여 인공신경망모형과 R-Hargreaves법의 월별 기준증발산량 산정결과를 FAO-56 PM법 기준증발산량 산정결과와 각각 비교한 결과를 나타낸 것이다.

FAO-56 PM법과 인공신경망모형의 비교 결과 절대평균오차 (MAE)는 전체 지점에 대해 3.985~8.211사이의 값을 나타냈다. 내륙지역의 경우 3.985~4.872의 범위였으며, 해안지역에서는 5.357~8.211의 범위였다. 평균제곱근오차 (RMSE)는 전체 지점에 대해 4.907~10.169의 범위를 나타내었으며, 내륙지역은 4.907~5.973, 해안지역은 7.080~10.169의 범위를 나타내었다. 결정계수 ( $R^2$ )은 전체 지점에 대해 0.839~0.991의 범위를 나타내었으며, 내륙지역은 0.940~0.991, 해안지역은 0.839~0.909의 범위를 나타내었다. 위의 3가지 통계지표

를 고려할 때 내륙지역이 해안지역에 비해 상대적으로 높은 적용성을 나타내었다.

FAO-56 PM법과 R-Hargreaves법의 월별 기준증발산량 비교 결과 전체 지점에 대한 절대평균오차 (MAE)는 4.116~13.322사이의 값을 나타냈으며, 내륙지역은 4.116~9.533, 해안지역은 7.074~13.322의 범위로 나타났다. 전체 지점에 대한 평균제곱근오차 (RMSE)는 5.041~15.158의 범위를 나타내었으며, 내륙지역은 5.041~11.809, 해안지역은 9.014~10.653의 범위를 나타내었다. 결정계수 ( $R^2$ )은 전체 지점에 대해 0.672~0.966의 범위를 나타내었으며, 내륙지역은 0.933~0.966, 해안지역은 0.672~0.855의 범위를 나타내었다. 기상관측소 월별 기준증발산량 산정 결과 인공신경망 모형을 산정한 결과가 R-Hargreaves법에 비해 전체적으로 우수한 성능을 보였다. 기존의 관측자료가 존재하는 경우 R-Hargreaves법보

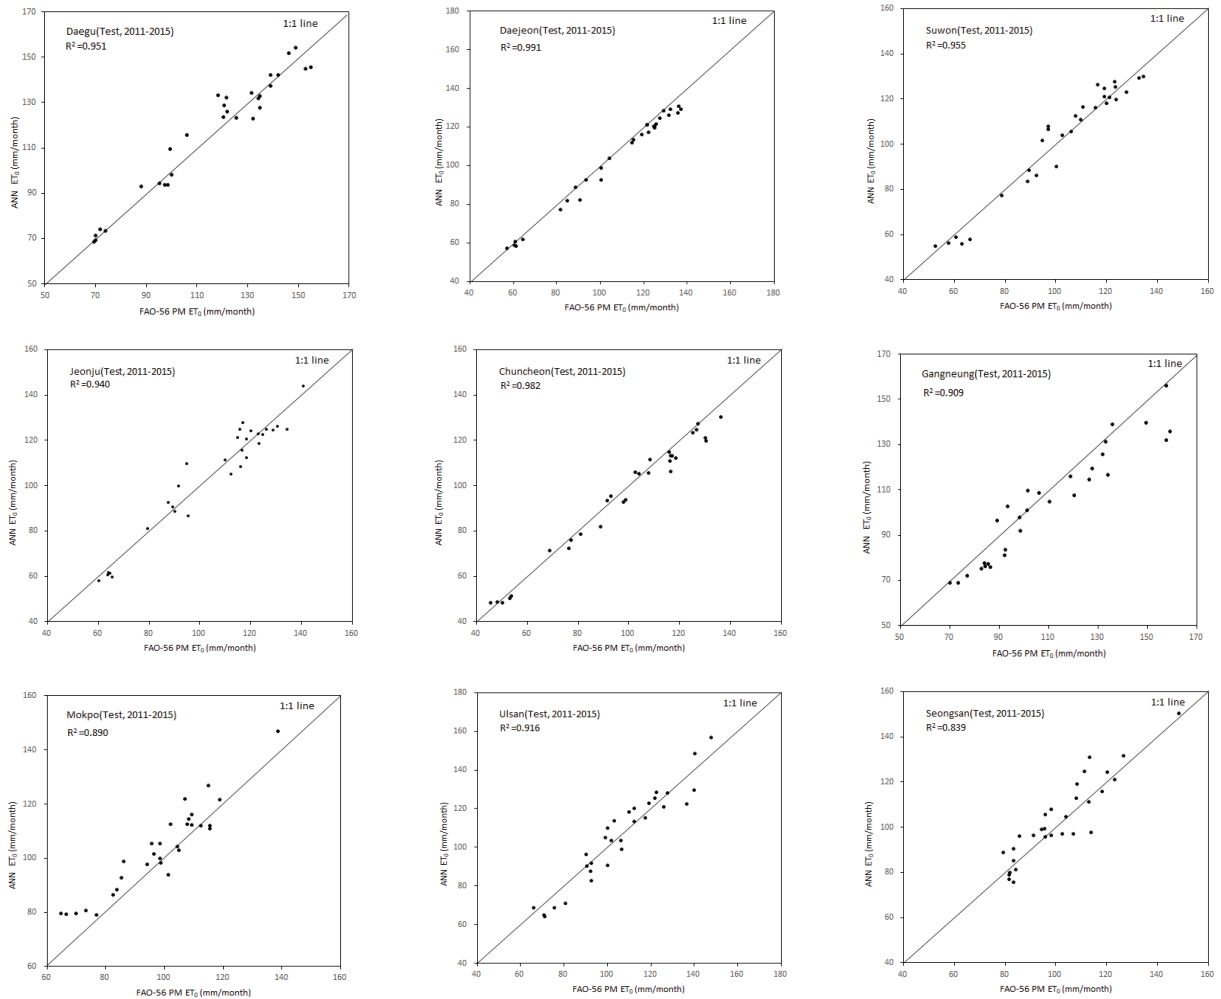


Fig. 4 Scatter plots comparing calculated monthly  $ET_0$  by FAO-56 PM method and simulated  $ET_0$  by artificial neural network method (2011~2015)

다 인공신경망 모형을 적용하여 기준증발산량을 산정하는 것이 유리하다고 판단된다.

다음의 Fig. 4는 인공신경망모형을 적용하여 산정한 월별 기준증발산량과 FAO-56 PM법을 적용한 월별 기준증발산량 산정결과를 1:1 그래프로 표현한 것이며, Fig. 5는 R-Hargreaves법을 적용한 월별 기준증발산량 산정결과를 FAO-56 PM법을 적용한 월별 기준증발산량 산정결과와 1:1 그래프로 나타낸 것이다. Fig. 4와 Fig. 5을 그림으로 비교하면 Fig.4의 결과가 Fig. 5의 결과에 비해 우수한 것을 알 수 있다. 따라서 월별 증발산량 산정 시 인공신경망모형과 Moon et al.(2013)이 제시한 매개변수 지역화 Hargreaves법을 비교한 결과 인공신경망모형이 전반적으로 우수하고 안정적인 것으로 평가되었다. 또한 인공신경망에 의한 기준증발산량 산정방법은 일단위에도 적용할 수 있는 장점이 있어 일단위 유출모형

이나 필요수량 산정 모형에 적용이 용이할 것으로 판단된다.

#### IV. 결 론

본 연구에서는 제한된 기상자료를 활용하는 온도기반 기준증발산량 산정 인공신경망모형을 9개 기상관측소 기상자료를 활용하여 구축하였다. 구축된 인공신경망 모형의 유효성을 확인하기 위하여 FAO-56 PM법에 의한 기준증발산량 산정과 비교하여 성능을 평가하였다. 또한 온도기반 기준증발산량 산정 인공신경망모형과 동일한 온도기반 입력자료를 활용하는 매개변수 지역화 Hargreaves(R-Hargreaves)법을 이용하여 월별 기준증발산을 각각 산정하고 그 결과를 비교하였다.

1. 대상자료는 9개 기상관측소(내륙 5개, 해안 4개)의 관측



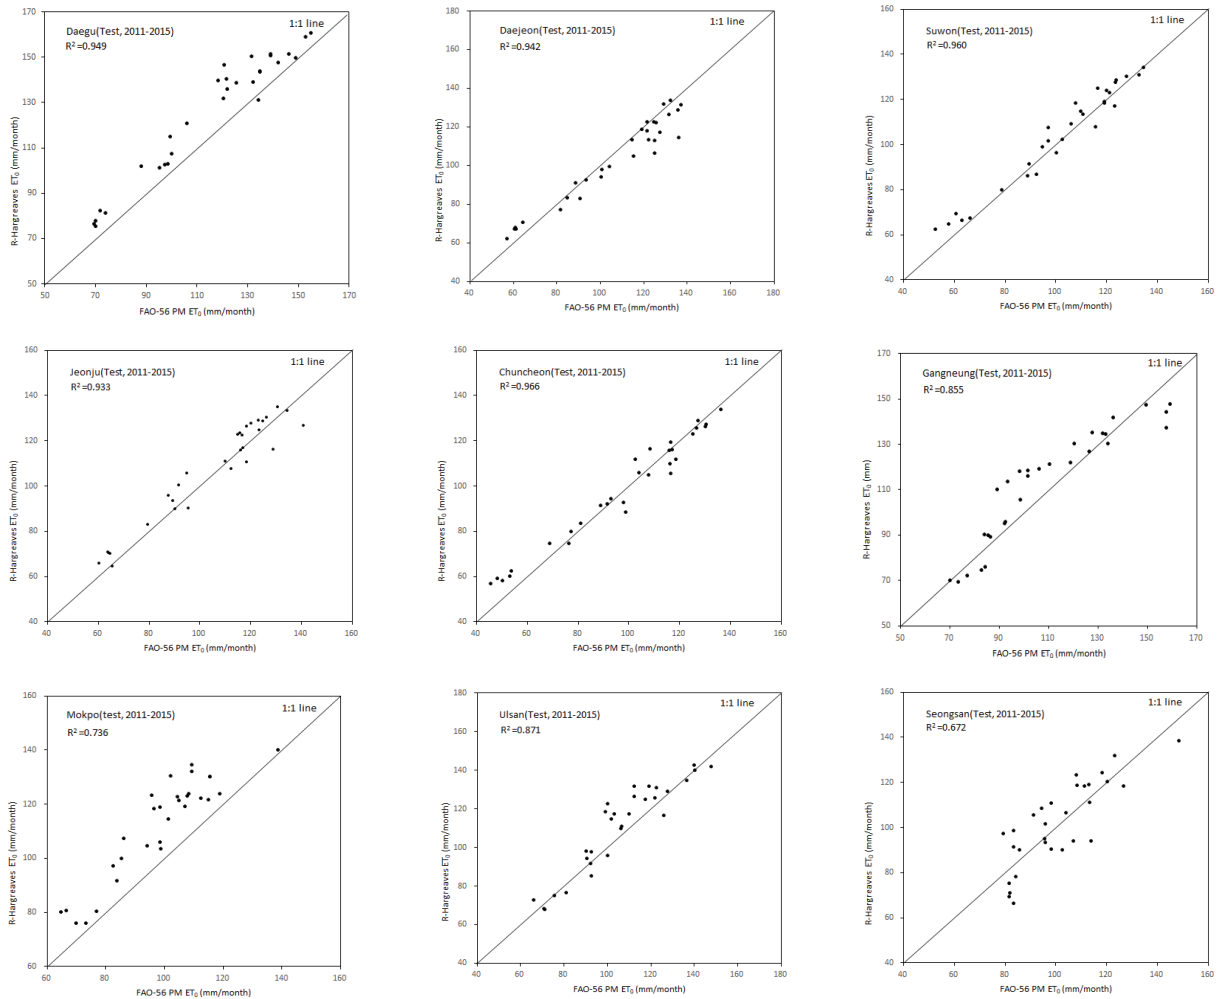


Fig. 5 Scatter plots comparing calculated  $ET_0$  by FAO-56 PM method and calculated  $ET_0$  by R-Hargreaves method (2011-2015)

- 일로부터 2015년까지 최고/최저/평균기온, 평균풍속, 상대습도, 강수량, 일사량 및 일조시간 자료를 수집하였으며, FAO-56 PM법에 의한 기준증발산량을 산정하였다.
2. 인공신경망모형의 입력자료 기상인자 중 최저/최고기온 및 대기권 밖 일사량 자료를 이용하여 온도기반 기준증발산량 산정 인공신경망모형을 구축하였으며, 인공신경망모형 훈련 (training)자료는 각 기상관측소 기상관측일 ~ 2010년까지의 자료, 검증 (validation)자료는 2010년 ~ 2015년까지의 자료를 사용하였다. 작물의 생장시기 및 관개기를 고려하여 각 해의 5월~10월까지의 자료만을 인공신경망모형의 학습과 훈련에활용하였다.
  3. 인공신경망모형의 구축 시 활성화수는 시그모이드함수 (sigmoid function)을 사용하였으며, 최적화 기법은 Levenberg-Marduardt 알고리즘을 사용하였다. 또한 각 관측소별로 1000회 반복수행하여 최적의 은닉층 노드수

- 를 산정하였다.
4. 구축된 인공신경망모형을 대상 관측소에 적용하여 훈련을 수행한 결과 은닉층의 최적노드 수는 4개~11개 범위로 대구 9개, 대전 9개, 수원 6개, 전주 5개, 춘천 7개, 강릉 11개, 목포 7개, 울산 4개, 성산 6개로 나타났다. 모형의 훈련과 검증기간에 대한 성능평가 지표로 절대평균오차 (MAE), 평균제곱오차 (RMSE), 결정계수 ( $R^2$ )를 적용하여 FAO-56-PM법과 인공신경망모형의 일별 기준증발산량 산정결과를 비교한 결과 인공신경망모형의 기준증발산량이 FAO-56 PM법의 기준증발산량을 잘 반영하는 것으로 나타났다. 내륙지역이 해안지역에 비해 상대적으로 좋은 성능지표를 나타냈으며, 이는 해안지역이 내륙지역에 비하여 상대적으로 풍속의 영향을 많이 받기 때문으로 판단된다.
  5. 인공신경망모형의 성능을 동일한 입력자료를 활용하는

매개변수 지역화 Hargreaves(R-HArgreaves)법 월별 기준 증발산량 산정결과와 비교하였다. 비교결과 대상 관측소 전체에서 인공신경망 모형이 매개변수 지역화 Hargreaves (R-Hargreaves)법 보다 나은 결과를 나타내었다.

본 연구에서 구축된 온도기반 기준증발산량 산정 인공신경망 모형은 과거자료를 기반으로 하고 있어 기존 관측자료가 풍부하지 못한 지역에서는 사용할 수 없는 단점이 있다. 하지만 제한적 기상인자가 제공되는 기후변화 자료를 활용하여 대상 관측소의 미래 기준증발산량을 산정하거나 기상자료 누락으로 인한 일정기간 기상자료가 제한되는 조건에서 활용할 수 있을 것으로 판단된다.

## 감사의 글

이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2017R1E1A1A01077413).

## REFERENCES

- Allen, R. G., M. Smith, A. Perroer, and L. S. Preira, 1994. An update for the calculation of reference evapotranspiration. *ICID Bull* 43(2): 35-92.
- APEC Cliamte Center, Clipped CMIP5 data, <http://adss.apcc21.org/DataSet/CMIP5/cmip5.jsp>. Accessed 31 Mar. 2017.
- Gocic, M., and S. Trajkovic, 2010. Software for estimating reference evapotranspiration using limited weahter data. *Computers and Electronics in Agriculture* 71: 158-162. doi:10.1016/j.compag.2010.01.003.
- Hargreaves, G. H., 1975. Moisture availability and crop production. *Transactions of ASAE* 18(5): 980-984. doi: 10.13031/2013.36722.
- Hargreaves, H. G., and A. Z. Samani, 1985. Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture* 1(2): 96-99. doi:10.13031/2013.26773.
- Jesen, M. E. (Ed), 1974. Consumptive use of water and irrigation water requirements. *Rep. Tech, Comm. on Irrigation*, p. 277.
- 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).
- Kisi, O., 2009. Daily pan evaporation modelling using multi-layer perceptions and radial basis neural networks. *Hydrological Processes* 23: 213-223. doi:10.1002/hyp.7126.
- Kumar, M., N. S. Raghuvanshi, and R. Singh, 2011. Artificial neural networks approach in evapotranspiration modelling: a review. *Irrigation Science* 29: 11-25. doi:10.1007/s00271-010-0230-8.
- Kumar, M., N. S. Ranghuwanshi, S. Singh, W. W. Wallender, and W. O. Pruitt, 2002. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage* 128(4): 224-233. doi:10.1061/(ASCE)0733-9437 (2002)128:4(224).
- Lee, E. J., M. S. Kang, J. A. Park, J. Y. Choi, and S. W. Park, 2010. Estimation of future reference crop evapotranspiration using artificial neural network. *Journal of Korean Society of Agricultural Engineers* 52(5): 1-9 (in Korean). doi:10.5389/KSAE.2010.52.5.001.
- Makridakis, S., S. C. Wheelwright, and R. J. Hyndman, 1998. *Forecasting-methods and application* (Third Ed.). Wiley, New York, pp. 42-50.
- McVicker, R., 1982. The effects of model complexity on ther predictive accuracy of soil moisture accounting models M.S. Thesis, Utah State University, Logan, Utah.
- Moon, J. W., C. G. Jung, and D. R. Lee, 2013. Parameter regionalization of Hargreaves equation based on climatological characteristics in Korea. *Journal of Korea Water Resources Association* 46(9): 933-946. doi:10.3741/JKWRA.2013.46.9.933.
- Oh, S. K., 2008. *Pattern recognition*. Kyobo Moongo, Seoul, p. 98.
- Salih, A. M. A., and U. Sendil, 1984. Evapotranspiration under extremely arid climates. *Journal of Irrigation and Drainage* 110(3): 289-303. doi:10.1061/(ASCE)0733-9437 (1984)110:3(289).
- Shih, S. F., 1984. Data requirement for evapotranspiration estimation. *Journal of Irrigation and Drainage* 110(3): 263-274. doi:10.1061/(ASCE)0733-9437(1984)110:3(263).
- Sudheer, K. P., A. K. Gosain, and K. S. Ramasatri, 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of Irrigation and Drainage* 129(3): 214-218. doi:10.1080/09715010.2009.10514929.
- Trajkovic, S., 2005. Temperature-based approaches for estimating reference evapotranspiration. *Journal of Irrigation*

- and Drainage* 131(4): 316-323. doi:10.1061/(ASCE)0733-9437(2005)131:4(316).
20. Trajkovic, S., and S. Kolakovic, 2003. Estimating reference evapotranspiration using limited weather data. *Journal of Irrigation and Drainage* 45(2): 45-57. doi:10.1061/(ASCE)IR.1943-4774.0000094.
21. Wang, Y. M., S. Traore, and T. Kerh, 2008. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. *WSEA Transactions on Computers* 6(7): 704-713.
22. Zanetti, S. S., E. F. Sousa, W. P. S. Oliveira, F. T. Almeida, and S. Bernardo, 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of Irrigation and Drainage* 133(2): 83-89. doi:10.1061/(ASCE)0733-9437(2007)133:2(83).