

온실의 환경요인을 이용한 인공신경망 기반 수경 재배 파프리카의 증산량 추정

남두성 · 이준우 · 문태원 · 손정익*

서울대학교 식물생산과학부

Transpiration Prediction of Sweet Peppers Hydroponically-grown in Soilless Culture via Artificial Neural Network Using Environmental Factors in Greenhouse

Du Sung Nam, Joon Woo Lee, Tae Won Moon, and Jung Eek Son*

Department of Plant Science and Research Institute of Agriculture and Life Sciences,
Seoul National University, Seoul 08826, Korea

Abstract. Environmental and growth factors such as light intensity, vapor pressure deficit, and leaf area index are important variables that can change the transpiration rate of plants. The objective of this study was to compare the transpiration rates estimated by modified Penman-Monteith model and artificial neural network. The transpiration rate of paprika (*Capsicum annuum* L. cv. Fiesta) was obtained by using the change in substrate weight measured by load cells. Radiation, temperature, relative humidity, and substrate weight were collected every min for 2 months. Since the transpiration rate cannot be accurately estimated with linear equations, a modified Penman-Monteith equation using compensated radiation (Shin et al., 2014) was used. On the other hand, ANN was applied to estimating the transpiration rate. For this purpose, an ANN composed of an input layer using radiation, temperature, relative humidity, leaf area index, and time as input factors and five hidden layers was constructed. The number of perceptrons in each hidden layer was 512, which showed the highest accuracy. As a result of validation, R^2 values of the modified model and ANN were 0.82 and 0.94, respectively. Therefore, it is concluded that the ANN can estimate the transpiration rate more accurately than the modified model and can be applied to the efficient irrigation strategy in soilless cultures.

Additional Key words : black box modelling, deep learning, paprika, Penman-Monteith equation

서 론

파프리카는 대형 온실에서 고품질, 고수익을 목적으로 최근 재배 면적이 증가하고 있는 작물 중 하나이며, 농가에서는 고품질의 파프리카 생산과 생산성 향상을 위해 수경재배 시스템을 사용하고 있다. 파프리카를 수경재배 할 때에는 주로 고행배지를 사용하는데, 고행배지는 제한된 부피와 적은 보수력을 갖고 있어 급격한 수분 변화의 완충이 어렵고 작물의 수분 스트레스를 야기할 수 있다(De Boodt와 Verdonck, 1972). 수분 부족은 작물에서 칼슘 결핍과 엽 발달 저해를 발생시키고(Jolliet과 Bailey, 1992), 작물 생산량을 감소시킬 수 있다(Antony

and Singadhupe, 2004; Moreno 등, 2003; Sezen 등, 2006). 특히 파프리카는 수분 스트레스에 매우 민감한 작물이기 때문에(Smittle 등, 1994), 다른 작물에 비해 더 정밀한 관수 조절이 필요하다. 일반적으로 식물이 흡수한 수분의 1% 정도만 대사 활동에 이용되고 나머지는 증산을 통하여 공기 중으로 이동하는 것이 밝혀졌다(Salisbury와 Ross, 1992). 따라서 증산량을 추정할 수 있으면 작물의 수분요구량을 예측할 수 있기 때문에, 정확한 관수 전략 수립이 가능하다.

현재까지 알려진 증산량을 추정하기 위한 가장 효율적인 모델링 방법으로는 Penman-Monteith 식을 사용하여 추정하는 방법이다(Monteith, 1990). 실제로 Penman-Monteith 식을 사용하여 모든 생육 단계와 온실에서 재배할 수 있는 여러 작물에 대하여 하나의 일로부터 근락에 이르기까지 폭넓게 증산량 추정 방법이 연구되고 있

*Corresponding author: sjeenv@snu.ac.kr

Received September 08, 2017; Revised October 21, 2017;

Accepted October 23, 2017

다(Stanghellini, 1987; Jolliet과 Bailey, 1992; Boulard와 Jemaa, 1993; Hamer, 1996). 그러나 Penman-Monteith 식과 관련된 연구는 대부분 노지 작물의 증산량 추정에 초점이 맞추고 있지만, 온실 내의 증산은 온실 내의 수증기압을 변화시키고, 변화된 온실 내 수증기압은 다시 증산에 영향을 미치는 것으로 알려져 있다(Aubinet 등, 1989). 이러한 증산량은 Penman-Monteith 식에 사용된 환경 요인 이외에도 재배 조건 등의 다양한 요인과 관련이 있기 때문에, 온실 환경이 조절되고 있음에도 불구하고, 여러 관련 변수들과 증산량 간의 관계를 해석하는 것은 쉽지 않다.

최근 각광받고 있는 인공신경망(Artificial neural network, ANN)은 복잡한 비선형 데이터로부터 의미 있는 결과들을 얻을 수 있는 유용한 도구로 알려져 있다(Vaidyanathan 등, 2015; Taormina와 Chau, 2016; Wang 등, 2016). ANN은 가공되지 않은 데이터로부터 신뢰할 만한 추정 값을 이끌어낼 수 있기 때문에 최근 다양한 분야에 적용되고 있다(LeCun 등, 2015). ANN은 2009년 이후로 우수한 계산 능력을 갖춘 빅 데이터 및 하드웨어의 발전으로 다양한 분야에 적용되어 왔으며, 특히 환경인자와 같이 기본적인 데이터들이 많은 농업 분야에서 유용한 도구로 사용 될 수 있다. 특히 Penman-Monteith 식으로 추정된 증산량은 수경재배 관련 변수들의 반영이 어렵다.

본 연구의 목적은 온실 내에서 특정 환경 인자들뿐만 아니라 수경재배에서의 다양한 조건을 포함한 환경 인자와 증산량 간의 관계를 ANN으로 추정하여 정확한 증산량을 실시간으로 추정하는 것이다.

재료 및 방법

1. 재배조건

실험은 서울대학교 실험농장(37.3°N, 127.0°E)에 위치한 벤로형 온실에서 수행되었다. 온실의 측창과 천창은 온도가 26°C 이상일 때 열리게 설정되었으며, 파프리카(*Capsicum annuum* L. cv. Fiesta)를 재배하였다. 2017년 7월 5일에 암면 큐브에 파종하였고, 육묘 챔버 내에서 15일 후 암면 블록(15 × 10 × 6cm)에 이식하였다. 육묘 챔버에서 15일 동안 육묘한 후 2017년 8월 4일에 암면 블록을 거터(200 × 20 × 10cm) 위에 놓인 암면 슬라브(Rock wool, Grotop, Grodan, Roermond, Netherlands)에 정식하였다. 재식밀도는 m² 당 4 개체이며 2개 암면 슬라브에 각각 5개체씩 총 10개체의 파프리카를 정식하였고 1주당 2개의 줄기를 유인하였다.

2. 관수 시스템 설정

관수시스템은 Shin 등(2014)에 의해 보정된 누적 일사량에 의해 조절되며 누적 일사량이 50W·cm⁻²에 도달 할

때마다 한 개의 드리퍼 당 100mL의 양액을 관수하였다. 누적 일사량은 pyranometer(SQ-110-L10, Apogee, Logan, USA)를 사용하여 측정하였고 측정된 데이터들은 데이터 로거(CR1000, Campbell Scientific, Logan, USA)를 이용하여 수집 및 제어하였다. 이때 양액의 전기전도도(EC)는 2.6 - 3.0dS·m⁻¹, pH는 5.5 - 6.5사이였으며, 배액의 EC는 3.5 - 4.1dS·m⁻¹로 유지하였다.

3. Penman-Monteith 식을 이용한 증산량 추정

Penman-Monteith 식은 에너지 수지를 기반으로 작성된 식으로 일반적으로 광도, 엽면적 지수, 포차를 사용하여 계산한다(Monteith, 1965). 본 연구에서는 Penman-Monteith 모델식에 보정 광도(RAD')를 사용한 증산량(Tr) 모델(Shin 등, 2014)로 추정하였다(식 1).

$$Tr = \alpha * [1 - \exp(-k * LAI)] * RAD' + b * LAI * VPD \quad (1)$$

여기서 k 는 흡광계수(0.848), LAI 는 모델식으로 추정된 엽면적지수(m²·m⁻²), VPD 는 수증기압포차(kPa), a , b 는 계수이며 각각 4.250, 0.009, 0.840 이었다, VPD 는 파프리카 재배의 온실환경 관리 기준에 따라 식 (2)를 이용하여 계산하였으며, 범위는 약 100 - 800kPa이었다.

$$VPD = 610.7 * [(100 - RH) / 100] * 107.5^{T / (237.3 + T)} \quad (2)$$

여기서 RH 는 상대습도, T 는 기온(°C)이다. ANN에 사용되었던 입력변수로는 파프리카 재배 온실에서 측정된 실내온도, 상대습도, 수증기포차(VPD), 일사량을 사용하고 각 변수의 범위는 Table 1과 같다.

4. 장치를 통한 증산량 계산

증산량은 로드셀(FSC-1520, Woosung Hitec, Yangsan, Korea)을 사용하여 측정하였다. 식물생장과 유인줄에 걸린 무게를 포함하기 위해서 직사각형 모양의 알루미늄 프로파일 위에 2개의 암면 슬라브를 올려 놓고 밑에 배액과 급액 무게를 재는 로드셀을 설치하였고 매 분마다 측정 및 저장하였다. 증산량(Tr)은 식 (3)을 사용하여 계산하였다.

Table 1. Average ranges of input factors of the artificial neural network.

Environmental factor	Range
Temperature (°C)	17.2 - 46.1
Relative humidity (%)	25.7 - 94.1
Vapor pressure deficit (kPa)	59.6 - 872.5
Solar radiation (W·m ⁻²)	0.0 - 628.4

$$Tr = \Delta Irr - \Delta Dra - \Delta Sub \quad (3)$$

여기서 Tr 은 증산량, Irr 은 급액 무게, Dra 는 배액 무게, Sub 는 배지 무게이다.

5. 인공신경망(Artificial neural network, ANN)을 통한 증산량 추정

ANN은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 이루어진다. 본 연구에는 10분당 평균 일사량, 온도, 습도, LAI , 시간 총 5개의 환경변수를 입력변수로 사용하였고, 최적 개수인 512개의 퍼셉트론들로 이루어진 5개의 은닉층과 1개의 증산량 출력층

으로 구성하였다(Fig. 1). 활성화함수 $f(x)$ 는 Rectified Linear Unit (ReLU) 함수가 사용되었다. 이때 x 는 각 퍼셉트론에 주어지는 입력값에 해당한다. ANN의 추정값의 정확도를 확인하기 위해 결정계수를 사용하였다. ANN 학습에는 현재 사용되고 있는 Adam 최적화 방식을 사용하였으며(Kingma and Ba, 2014), 학습하기 전 계수들은 Adam 최적화 방식에서 일반적으로 통용되는 값으로 설정하였다(Table 2). 증산량을 추정하기 위해서 수집한 총 6,200개의 데이터를 4,500개의 학습데이터와 1,700개의 테스트 데이터로 분류한 후에 학습을 진행하였다. 학습데이터는 은닉층의 뉴런에 대한 함수를 통해 오차가 줄어드는 방식으로 ANN을 일반화하는 역할을




Fig. 1. Structure of an artificial neural network including the input layer (I), hidden layers (H₁, H₂, H₃, H₄, H₅), and output layer (O). Input layer includes radiation (RAD), relative humidity (RH), days after transplanting (DAT), and leaf area index (LAI) Each hidden layer has 128 perceptrons.

Table 2. Parameters used in the artificial neural network in which Adams optimizing method was used. Dropout was set 1.0 in the test to use the entire neural network.

Parameter	Value	Description
Minibatch size	5000	Number of training cases over which each stochastic gradient descent update is computed
Learning rate	0.001	Learning rate used by Adams optimizing method
β_1	0.9	Exponential decay rate for the moment estimates
β_2	0.999	Exponential decay rate for the moment estimates
ϵ	1e-0.8	A constant for numerical stability
Dropout probability	0.7	Probability of dropping out units in the neural network
Training epoch	Various	Number of training iteration
Training data size	10000	Size of data set used for training
Test data size	4881	Size of data set was used for test.

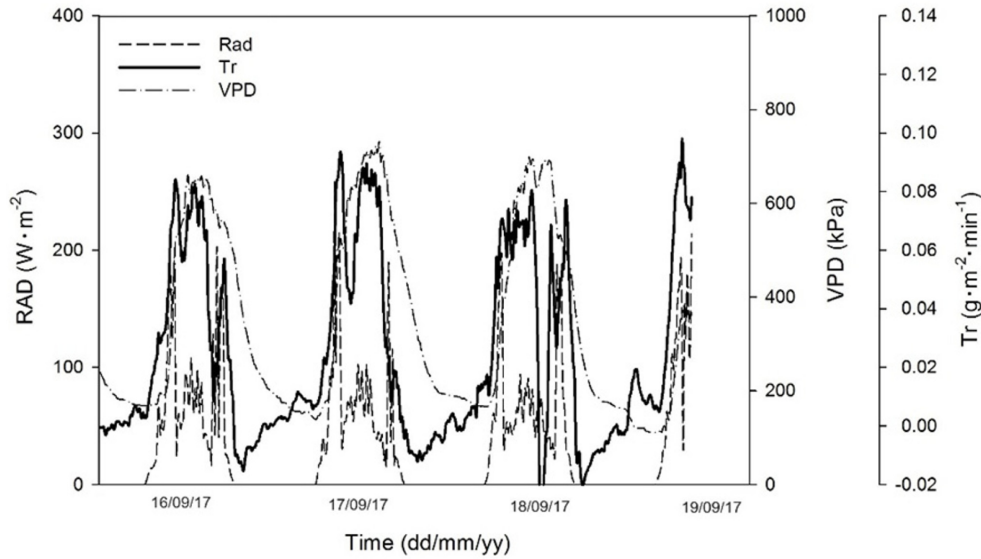


Fig. 2. Changes in radiation (*RAD*), vapor pressure deficit (*VPD*), and transpiration (*Tr*) from 16 to 18 Sept, 2017.

수행하였고, 테스트 데이터는 ANN의 정확도를 확인하는데 사용되었다. 테스트 데이터의 경우 특정 기간에 몰려 있는 상황을 피하기 위해 난수를 통해 무작위로 배분하였고, 학습은 Python 언어 기반 수치 계산 라이브러리인 Tensorflow(v.1.2.1, Menlo Park, CA, USA)를 사용하였다.

결과 및 고찰

1. 증산량과 환경요인 간의 관계 분석

일중 일사량 변화와 유사한 형태로 변화하였으며, 온도와 상대습도의 식으로 구성된 Eq. 2로 계산된 *VPD*의 경우에도 동일한 경향을 나타냈다(Fig. 2). 일반적으로 공기의 포화수증기 함량은 온도에 따라 지수적으로 증가하고 잎 외부와 내부의 수분포텐셜의 차이를 증가시키기 때문에 엽온의 변화는 증산속도에 현저한 영향을 미치게 된다(Bange, 1953). 엽온의 변화는 특정한 시간 동안 특정 면적에 도달하는 광량의 양에 의해 추정되기 때문에, 마찬가지로 증산속도는 일사량 변화에 유사한 형태로 변화하였다.

2. 보정된 Penman-Monteith에 의한 증산량 추정 계산

측정된 엽면적 지수는 Boltzman sigmoid equation (Motulsky와 Christopoulos, 2003)을 참고하여 *DAT*에 따른 식으로 모델을 만들었고, 정식후 50일 전까지 0.99의 결정계수를 보였다(Fig. 3). 엽면적 지수는 시간에 따라 증가량의 기울기가 점점 감소하는 경향을 보였지만, 전




Fig. 3. Estimation of leaf area index (*LAI*) by using leaf length and leaf width with days after transplanting (*DAT*) Vertical bars represent the standard error ($n=40$).

체적으로 *DAT*에 따라 증가하는 경향을 보였다. 높은 결정계수로 인해 시간에 따른 증산량을 계산할 수 있었다. 10분 간격의 보정된 광량으로 추정한 증산량의 결정계수는 0.82이며 일일 누적증산량의 경우 보정된 식과 측정된 식이 유사하였다(Fig. 4) 포차와 일사량의 변화에 따라 증산량도 유사한 변화를 보이지만 대체적으로 보정된 Penman-Monteith식에 의해 추정된 값이 측정된 값보다 더 작게 예측되었다. 그 이유로는 증산량에 영향을 미치는 인자가 광도, 포차, 엽면적지수 이외에 다른 인자가 있음을 알 수 있고, 또한 증산량은 급작스러운 자극에 바로 반응하는 식물 반응이 아니라 누적된 자극에 대한




Fig. 4. Comparison of transpirations (Tr) measured and estimated by the compensated model with days after transplanting (DAT).




Fig. 6. Comparison of transpirations (Tr) measured and estimated by the artificial neural network ($n=1700$).




Fig. 5. Trained accuracies of artificial neural networks depending on the number of perceptrons.

반응으로 급격한 환경변화에 대한 추정값은 바로 추정이 가능하였지만 실제적으로는 추정값보다 더 작게 나타났다. DAT 23일 경에 측정값에 비해 추정값이 매우 높은 경향을 보인 이유로는 DAT 23일에 늦은 밤까지 기온이 25°C 이상이었으며 측창과 천창이 모두 열린 상태로 환기가 일어났을 것으로 판단된다. 이는 VPD 값을 증가시켜서 VPD 와 양의 상관관계에 있는 Penman-Monteith식은 증산량을 높게 추정하였다.

3. ANN을 이용한 증산량 추정

ANN을 사용하여 데이터를 분석한 결과 증산량을 추정하기 위해 사용된 최적의 퍼셉트론 개수는 512개였다 (Fig. 5). 퍼셉트론 개수가 점점 증가함에 따라 결정계수

값도 점점 증가하는 경향을 보였으나, 퍼셉트론 개수에 따른 결정계수 값은 무한적으로 증가하지는 않았다. 데이터 수에 비해 과도한 퍼셉트론 수를 가진 ANN으로 학습하면, ANN은 데이터를 일반화 하지 못하고 학습데이터만을 맞추어 수 있도록 조절된다(Tetko, 1995). 이를 과적합이라고 하는데, 퍼셉트론 수를 512개보다 더 늘리면 학습 정확도는 높아지지만 테스트 정확도가 떨어지는 과적합 현상이 일어나는 것을 확인할 수 있다. 그렇기 때문에 512개의 퍼셉트론에서 가장 높은 결정계수 0.94의 정확도를 가지고 퍼셉트론 개수가 점점 증가함에 따라 감소하는 것을 볼 수 있다.

10분간격의 데이터를 각각 처리하고 시간변수에 입력값과 출력값을 맞추어 총 6200개의 데이터를 얻었고, 그 중 4500개의 데이터를 통해 가공된 5가지 환경변수에 대한 증산량 추정을 학습하였다. 학습이 완료된 ANN에 학습에 사용하지 않은 나머지 1700개의 데이터의 증산량에 대하여 추정한 값과 실제 측정값 사이의 연관성을 확인하였다(Fig. 6). ANN 학습결과 측정값과 실제 측정값의 결정계수는 0.94로 보정된 광을 이용한 회귀모델에 비해 높은 결정계수를 보였다.

ANN을 이용한 증산량 추정의 경우 짧은 시간 동안 변화하는 증산량을 사용하여 정확한 관수 계획을 수립할 수 있다. 이는 관수와 관수 사이에 뿌리의 영양분 섭취로 표면 근처에서 영양분이나 수분이 고갈되는 구역이 형성되는 것을 방지해 주고, 뿌리 표면과 뿌리 간의 농도 구배를 감소시켜 작물의 생육에 긍정적인 영향을 미칠 수 있다(Silber 등, 2003). 또한 ANN의 구조가 커질수록 더 복잡한 관계를 추정할 수 있다. 따라서 다양한 변수가 작용하는 증산량과 입력 간의 비선형 관계를 정확하게 추정하기 위해서 ANN의 적용도 가능할 것으로 판단된다.

적 요

광도, 포차와 같은 환경요인과 엽면적 지수와 같은 생육요인은 증산 속도를 변화시키는 중요한 변수이다. 본 연구에서는 Penman-Monteith의 증산 모델과 인공신경망(ANN)에 학습에 의한 증산속도 추정값을 비교하는 것을 목표로 하였다. 파프리카(*Capsicum annuum* L. cv. Fiesta)의 증산속도 추정은 로드셀을 이용한 배지의 중량 변화를 통해 계산하였다. 온도, 상대습도, 배지 중량 데이터는 1분 단위로 2개월간 수집하였다. 증산량은 일차 식으로는 정확한 추정이 어렵기 때문에, 기존의 Penman-Monteith식에 보정 광도를 사용한 수정식 Shin 등(2014)을 사용하였다. 이외는 별개로 ANN을 사용하여 증산량을 추정 비교하였다. 이를 위하여 광도, 온도, 습도, 엽면적지수, 시간을 사용한 입력층과 5개의 은닉층으로 구성된 ANN을 구축하였다. 각 은닉층의 퍼셉트론 개수는 가장 정확성이 높은 512개로 하였다. 검증 결과, 보정된 Penman-Monteith 모델식의 $R^2 = 0.82$ 이었고, ANN의 $R^2 = 0.94$ 로 나타났다. 따라서 ANN은 일반적인 모델식에 비해 정확한 증산량 추정이 가능한 것으로 나타났다. 추후 수경재배의 효율적인 관수전략 수립에 있어 적용 가능할 것으로 판단되었다.

추가 주제어 : 블랙박스 모델링, 딥러닝, 파프리카, Penman-Monteith 방정식

사 사

본 연구는 농림식품기술기획평가원에서 지원하는 “수경재배 과채류 생산성 및 양액 제어기술 향상을 위한 정밀 관수제어 기반 보급형 식물생산시스템 개발 과제 (115104-3)”의 일환으로 수행되었음.

Literature Cited

Antony, E. and R.B. Singandhupe. 2004. Impact of drip and surface irrigation on growth, yield and WUE of capsicum (*Capsicum annuum* L.). *Agric. Water Manage.* 65:121-132.

Aubinet, M., J. Deltour, D. De Halleux, and J. Nijskens. 1989. Stomatal regulation in greenhouse crops: analysis and simulation. *Agric. Forest. Meteorol.* 48:21-44.

Bange, G.G.J. 1953. On the quantitative explanation of stomatal transpiration. *Acta Bot. Neer.* 2:255-297.

Boulard, T. and R. Jemaa. 1992. Greenhouse tomato crop transpiration model application to irrigation control. In *International Symposium on Irrigation of Horticultural Crops* 335:381-388.

Bryla, D.R., T.J. Trout, and J.E. Ayars. 2010. Weighing lysimeters for developing crop coefficients and efficient irrigation practices for vegetable crops. *HortScience* 45:1597-1604.

de Boodt, M.A.V.O. and O. Verdonck. 1971. The physical properties of the substrates in horticulture. In *III Symposium on Peat in Horticulture* 26:37-44.

Gadissa, T. and D. Chemed. 2009. Effects of drip irrigation levels and planting methods on yield and yield components of green pepper (*Capsicum annuum*, L.) in Bako, Ethiopia. *Agric. Water Manage.* 96:1673-1678.

Gercek, S., N. Comlekcioglu, and M. Dikilitas. 2009. Effectiveness of water pillow irrigation method on yield and water use efficiency on hot pepper (*Capsicum annuum* L.). *Sci. Hortic.* 120:325-329.

Hamer, P.J. 1993. Validation of a model used for irrigation control of a greenhouse crop. In *International Symposium on Water Quality & Quantity-Greenhouse* 458:75-82.

Jolliet, O. and B.J. Bailey. 1992. The effect of climate on tomato transpiration in greenhouses: measurements and models comparison. *Agric. Forest. Meteorol.* 58:43-62.

Montieth, J.L. and M.H. Unsworth. 1990. *Principles of environmental physics.* Edward Arnold, London, 291.

Moreno, M.M., F. Ribas, A. Moreno, and M.J. Cabello. 2003. Physiological response of a pepper (*Capsicum annuum* L.) crop to different trickle irrigation rates. *Span. J. Agric. Res.* 1:65-74.

Motulsky, H. and A. Christopoulos. 2004. *Fitting models to biological data using linear and nonlinear regression: a practical guide to curve fitting.* GraphPad Software Inc. San Diego, CA., USA.

Medrano, E., P. Lorenzo., M.C. Sánchez-Guerrero, and J.I. Montero. 2005. Evaluation and modelling of greenhouse cucumber-crop transpiration under high and low radiation conditions. *Sci. Hortic.* 105:163-175.

Nguyen, H.T., J. Park, T.I. Ann, J.H. Lee, D.J. Myoung, Y.Y. Cho, and J.E. Son. 2010. Analysis of relationship among growth, environmental factors and transpiration in soilless culture of paprika plants. *Korean J. Hortic. Sci.* 28:59-64.

Sezen, S.M., A. Yazar, and S. Eker. 2006. Effect of drip irrigation regimes on yield and quality of field grown bell pepper. *Agric. Water Manage.* 81:115-131.

Shin, J.H., E.H. Noh, and J.E. Son. 2012. Transpiration, growth, and water use efficiency of paprika plants (*Capsicum annuum* L.) as affected by irrigation frequency. *Hortic. Environ. Biotechnol.* 53:129-134.

Shin, J.H., J.S. Park, and J.E. Son. 2014. Estimating the actual transpiration rate with compensated levels of accumulated radiation for the efficient irrigation of soilless cultures of paprika plants. *Agric. Water Manage.* 135:9-18.

Shin, J.H., T.I. Ahn, and J.E. Son. 2011. Modeling of transpiration of paprika (*Capsicum annuum* L.) plants based on radiation and leaf area index in soilless culture. *Hortic.*

- Environ. Biotechnol. 52:265
- Silber, A., M. Bruner, E. Kenig, G. Reshef, H. Zohar, I. Posalski et al. 2005. High fertigation frequency and phosphorus level: Effects on summer-grown bell pepper growth and blossom-end rot incidence. *Plant Soil* 270:135-146.
- Smittle, D.A., W.L. Dickens, and J.R. Stansell. 1994. Irrigation regimes affect yield and water use by bell pepper. *J. Amer. Soc. Hortic. Sci.* 119:936-939.
- Salisbury, F.B. and C.W. Ross. 1992. *Plant physiology*. Fourth edition. Wadsworth Publishing Company, Belmont, California.
- Seginer, I. 1994. Transpirational cooling of a greenhouse crop with partial ground cover. *Agric. Forest. Meteorol.* 71:265-281.
- Stanghellini, C. 1987. Transpiration of greenhouse crops. *An aid to climate management*. Ph.D. Diss. Wageningen Agricultural Univ., Wageningen, 150pp.
- Tetko, I.V., D.J. Livingstone, and A.I. Luik. 1995. Neural network studies. 1. Comparison of overfitting and overtraining. *J. Chem. Inf. Comput. Sci.* 35:826-833.
- Taormina, R. and K.W. Chau. 2015. Neural network river forecasting with multi-objective fully informed particle swarm optimization. *J. Hydroniform.* 17:99-113.
- Vaidyanathan, S. 2015. 3-cells cellular neural network (CNN) attractor and its adaptive biological control. *Int. J. Pharmtech. Res.* 8:632-640.
- Wang, T., H. Gao, and J. Qiu. 2016. A combined adaptive neural network and nonlinear model predictive control for multirate networked industrial process control. *IEEE Trans. Neural Netw. Learn. Syst.* 27:416-425.