

신경회로망을 이용한 오이 배양액의 배액내 이온농도 예측

최성문 · 최영수*

전남대학교 지역바이오시스템공학과 생물산업기계공학전공

Prediction of Ion-concentrations in Discharged Nutrient Solution for Cucumber Using a Neural Network

Sung. Mun Choi and Young Soo Choi*

*Department of Rural and Biosystems Engineering
Chonnam National University*

**Corresponding author: y-choi@chonnam.ac.kr*

ABSTRACT

A closed recycling system has been considered as the most effective system in hydroponics because the system helps plants absorb fertilizer in nutrient solution and can contribute environmental pollution by deducing direct discharging of surplus fertilizer in fields. For the development of a closed recycling system, an automatic control system of discharged nutrient solution by monitoring real-time absorption is necessary in order to control inorganic ions individually and exclude surplus inorganic ions in nutrient solution. But, the real-time monitoring system has not been put to practical use because of high price and low accuracy of sensors such as ion-selective electrodes. A model for predicting ion-concentrations in discharged nutrient solution can be a alternative method to replace the real-time monitoring system. This study was carried out to develop a model for the prediction of ion-concentrations in discharged nutrient solution using an artificial neural network with the backpropagation learning algorithm. Experiment results showed that the neural network showed excellent trained results with training data for all macronutrients of NO_3^- , Ca^{2+} , Mg^{2+} , K^+ , SO_4^{2-} and PO_4^{2-} . Coefficients of determination (R^2) were over 0.99 for all ions. Also, the trained neural network showed good prediction performance with verification data for macronutrients of NO_3^- , Ca^{2+} , Mg^{2+} . The developed neural network can be applied to the prediction of ion-concentrations for other hydroponic plants and the replacement of a real-time monitoring system for a closed recycling system in hydroponics.

Additional key words: Prediction, Ion-concentrations, Neural network, Backpropagation, Cucumber

서 론

우리나라의 양액재배 면적은 작업의 편의성과 생산성의 증대, 품질의 고급화 등의 이유로 2000년 700ha에서 2008년 1,107ha, 그리고 2012년 3,089ha로 재배면적이 급속히 증가하고 있으며(농진청, 2008), 특히 최근 FTA 및 DDA의 체결로 친환경 작물에 대한 소비자들의 선호도가 증가함에 따라 양액재배 면적은 계속 증가 할 것으로 예상된다.

이러한 양액재배 면적의 증가에도 불구하고 순환식 양액재배 방식으로 재배 되고 있는 곳은 전체 양액재배 면적의 10%에 불과한 상태이다. 더욱이 순환식 재배 방식의 대부분은 장미, 국화 등 화훼작물 위주로 재배 되고 있으며, 양액재배 면적의 대부분을 차지하고 있는 채소 작물에서는 대부분 비순환식 양액 재배 시스템을 이용하고 있는 상태이다. 이렇게 국내외적으로 양액재배면적이 계속 증가하고 있음에도 불구하고 아직까지 완전한 순환식 양액재배시스템이 사용되는 사례는 거의 없으며, 일부 순환식 양액재배 장비를 갖춘 곳에서도 단지 회수된 배액에 EC를 기준으로 미리 조성된 농축양액을 첨가해 일정한 농도로만 유지시키고 있는 실정이다.

그러나 EC만으로 배양액을 조성하여 배액을 재사용할 경우 배양액내 특정 성분이 저하되거나 높아져서 성분의 심한 불균형을 초래하며, 배지나 양액을 폐기하지 않고 재사용함으로써 병충해가 시스템 전반으로 확산될 가능성이 매우 크다. 최근 이온센서를 사용하여 배액의 각 이온을 측정할 후 기준농도 만큼 각 이온을 보정해 주는 방법이 사용되고는 있지만, 이온센서는 pH센서나 EC센서에 비해 그 내구성이 우수하지 않아 배양액 속에 오랫동안 담가 둘 수 없는 형편이며, 각 센서의 가격이 너무 비싸 농가에 공급하는데 어려움이 많다.

따라서 배양액 관리시스템의 양액 이온농도 실시간 계측 및 자동제어 시스템은 폐쇄계시스템의 유효한 방법이나 실시간 계측 시스템의 구현이 현재로서는 어려움이 많으므로, 생육일수별 배액의 이온농도를 예측함으로써 실시간 배양액 자동제어 시스템을 보완할 수 있을 것으로 판단하였다.

배양액의 생육일수별 예측에 있어서 Morimoto 등(1991)은 단일 무기화합물의 생육단계별 예측은 어느 정도 가능하지만, 무기화합물의 종류가 증가하면 수용액이 비선형적인 성격을 보이기 때문에 근사적인 예측방법 이외에는 불가능하다고 하였다. 또한 Hirahuji 등(1992)은 배양액의 경우 물리 화학적 특성을 완벽하게 모델에 적용할 수 없을 뿐만 아니라, 모델화하는 과정에서도 여러가지 변수가 많아 근사적 예측방법으로 배양액의 생육단계별 흡수 패턴을 예측하는 데에도 현실적으로 어려움이 많다고 보고 하였다.

그러나 최근 환경관리나 시설원예, 그리고 주식이나 날씨 등의 비선형적 성격을 보이는 변수들도 신경회로망(neural network) 등의 인공지능 기법을 통해 예측이 가능한 것으로 보고되고 있으며, 특히 역전파 알고리즘(back propagation)을 이용하여 성 등(2005)이 토양 화학성으로 벼 수확량을 예측하였으며, 김 등(1998)은 백삼의 등급을 자동으로 판정하는데 있어 신경회로망을 이용하여 백삼의 등급을 판정하였다. 또한, 양 등(2003)은 저온저장고의 제어시스템에 뉴로-퍼지 이론을 적용하였고, 김 등(2004)은 인공신경망을 이용하여 목재건조 중 발생하는 음향방출 신호 패턴분류를 시도하는 등 농업분야에서도 실용화를 위한 연구가 이미 활발히 진행되고 있다. 양액재배에서는 손 등(1992)이 신경회로망을 이용한 배양액의 EC를 예측하였고, 김 등(2001)은 순환식 펄라이트재배에서 생육단계에 따른 오이의 양수분 흡수 특성을 구명한 경우는 있었지만 아직까지 생육단계별 작물의 이온흡수 패턴을 예측한 경우는 없었다.

본 연구는 오이의 생육일수별 이온 데이터를 이용하여 생육일수별 배액 내의 다량이온 농도를 위한 신경회로망 모델을 개발하고자 수행되었다. 이를 위해 신경회로망은 다층 퍼셉트론구조를 갖도록 구성되었으며, 신경회로망의 학습을 위해 역전파 알고리즘을 사용하였다

재료 및 방법

1. 시료

사용된 오이의 품종은 남부 청장이며, 재배 실

험은 전남 구례에 위치한 오이시험장의 유리온실에서 190×15cm(3600주/10a)의 재배 규모로 수행되었다. 오이 파종일은 1월 20일, 재식일은 2월 25일, 수확은 3월 27일부터 6월 20일 까지 수행되었다. 배양액은 오이전용액(10수염, 원예연구소)을 사용하였고, 펄라이트 배지가 들어간 성형스트로폼(1,000L×240W×250H, mm)베드를 사용하였다.



Fig. 1. Bed and sampler of discharged nutrient solution.

배양액의 조성은 Table 1에 나타난 바와 같이 각 비료염을 A액, B액의 두 가지로 나누어 양액 조성표의 비율대로 투입하였으며, 배양액의 EC와 pH는 각각 1.5~2.0 mS/cm와, 5.5~7.0사이가 되도록 조정하였다. 오이 재배 실험을 통해 채취된 배액 이온 농도는 DIONEX사의 이온크로마토그래프(양이온: DX-100, 음이온: DX-120)를 이용하여 분석하였다. 이는 실제 양액재배에 있어 배액에 포함된 이온의 정확한 농도를 분석하기 위하여 실시하였으며, 분석 항목은 다량원소인 K^+ , Ca^{2+} , Mg^{2+} , NO_3^- , PO_4^{3-} 와 SO_4^{2-} 이었다. 다량원소와 함께 SO_4^{2-} 성분을 분석한 이유는 오이 배양액의 경우 SO_4^{2-} 성분이 다량원소인 PO_4^{3-} 보다도 농도가 높기 때문이었다. 다량원소는 작물이 공기나 물에서 흡수 가능한 C, H, O의 3가지를 제외하면 식물생육에 꼭 필요한 원소이며, EC로만 제어할 경우 이온성분의 불균형을 초래하는 성분일 뿐 아니라 이들 이온의 농도 변화가 커 배액의 이온농도 예측이 필요한 것으로 판단되어 다량원소들의 이온농도 변화를 예측하는 모형 개발을 시도하였다.

2. 신경회로망 학습

가. 신경회로망의 기본 구성

배액 이온농도 예측을 위해 개발된 알고리즘은 MATLAB 프로그램(ver. 7.1, Mathworks, USA)을 이용하여 프로그래밍 하였으며, 오이의 생육일수를 입력 값으로 설정하고 생육일수에 따른 배액

Table 1. Compositions of fertilizer used in nutrient solution for cucumber

	Fertilizer	g/ton		Fertilizer	g/ton
A Solution	5(Ca(NO ₃) ₂ ·2H ₂ O)NH ₄ NO ₃	540	B Solution	KNO ₃	436
	KNO ₃	200		MgSO ₄ ·7H ₂ O	246
	Fe-EDTA	20		KH ₂ PO ₄	91
	NH ₄ NO ₃	16		H ₃ BO ₃	3.00
				MnSO ₄ ·4H ₂ O	2.00
				ZnSO ₄ ·7H ₂ O	0.22
				CuSO ₄ ·5H ₂ O	0.05
				Na ₂ MoO ₄ ·2H ₂ O	0.02

이온농도를 출력 값으로 설정하여 오이의 배액 이온농도 예측을 위한 신경회로망을 학습시켰다. 학습 시 입력층과 은닉층, 그리고 출력층 사이에는 각각의 처리 요소인 활성화함수(Activation function)를 거쳐 목표값과의 차이를 비교하게 되는데, 본 연구에서는 역전파 알고리즘에 사용되는 일반적인 활성화함수 3가지를 사용하였다. logsgmoid 함수와 tansigmoid 함수는 은닉층의 활성화함수로 사용되었고 pureline 함수는 출력층의 활성화함수로 사용되었다.

입력 자료들은 전처리 과정을 통해 0~1사이의 값으로 정규화시켰는데, 이 과정은 신경회로망의 수렴속도를 빠르게 하고 잡음(noise)이나 왜곡(skewness)에 의해 변형되는 것을 바로잡는 기초적인 연산 처리과정이다. 또한 은닉층에 사용된 sigmoid 함수는 그 최소값과 최대값이 0.0~1.0의 사이를 변동하는 특성을 가지므로 신경회로망에 입력되는 데이터를 변환하여 sigmoid 함수의 특성에 맞도록 전처리를 할 필요가 있다. 데이터의 정규화는 다음의 식 (1)을 이용하였다.

$$x_{tran} = \frac{1}{x_{max} - x_{min}} \times (x_i - x_{min}) \quad (\text{수식 1})$$

where, x_{tran} : normalized input value

x_{max} : maximum value of inputs

x_{min} : minimum value of inputs

x_i : actual input value

다량이온 농도 측정을 위한 양액채취는 정식 이후 10주 동안 수행되었으며, 양액공급은 매주 화요일과 목요일 2번 조제되어 순환공급하였다. 시료 채취는 배액통에서 매일 12~13시 사이에 이루어졌으며, 3회 측정값의 평균치를 모델개발에 사용하였다. 결과적으로 일주일에 6일, 10주 동안 60회의 시료를 채취하여 신경망을 이용한 배액 다량이온 농도 예측모델 개발에 사용하였다. 신경회로망의 입력값은 생육일수에 따른 배액이온농도를 예측하고자 하였기 때문에 정식 후 일수를 사용하였고, 출력은 6개의 다량이온 농도를 사용하였다. 시료 채취는 매회 3회 실시하였으므로 전체 데이터는 180개 데이터이며, 이중 학습에는 70%인 126개를

무작위 추출하여 사용하였으며, 나머지 54개는 모형검증에 사용하였다. 즉, 모형개발에 사용된 데이터는 각 수준에서 반복 평균값이 아닌 개별 데이터를 모두 사용하였다.

나. 신경회로망의 구조 및 학습

신경회로망을 학습시키기 위해서는 우선 은닉층의 개수와 각 층의 노드수를 결정해야하는데, 여기서 은닉층은 입력층과 출력층 사이에 존재하며, 은닉층의 개수와 노드 수, 그리고 활성화함수의 종류에 따라 신경회로망의 특성이 변하게 된다. 본 연구에서는 은닉층과 노드 수, 그리고 반복횟수를 시행착오법(trial and error method)을 통해 MSE(mean square error)를 기준으로 각 요소를 결정하였다. MSE는 목표값(target value)과 입력층의 값이 은닉층의 전이함수를 통해 출력층으로 통과할 때 목표값과 신경회로망의 출력값을 비교하여 산출하게 되므로, MSE값이 낮을수록 신경회로망의 학습효과가 뛰어나다고 판단 할 수 있다. Table 2는 본 신경회로망의 은닉층 수에 따른 MSE값을 나타낸 것이다. 본 신경회로망에서는 은닉층의 수가 3개일 때 MSE의 값이 가장 작으며, 은닉층수가 더욱 많아지면 오히려 MSE가 높아져 최적 은닉층수를 3개로 결정하였다. 개발된 신경회로망의 구조는 Fig. 2에서 보는 바와 같이 입력층, 은닉층, 출력층을 가진 다층퍼셉트론 구조이다.

신경회로망의 학습방법중에 경사하강법(Gradient decent method)은 최소 에러 값을 찾아가는 기법 중의 하나이지만, 반드시 가장 에러가 작은 곳(global minimum)에 이르는 방법이 아니라 현지점에서 가까운 급경사만을 따라 내려가는 것이므로 목표값과 훈련값과의 오차가 0이 아닌 지역최소점(local minimum)에 머물러 시스템이 안정화되지 못하는 경우가 있다.

따라서, 이 문제를 해결하기 위해 모멘텀 방법과 학습율을 조정하는 방법을 사용하였는데, 신경회로망의 학습 후 MSE가 클 경우 각 노드의 연결강도를 재조정해 다시 훈련할 때 재조정된 노드로부터 구해진 값들의 오차가 오버 스포트해 오히려 지역최소점에 빠지거나 시스템의 안정화하는데 오랜 시간이 걸리는 오류를 모멘텀과 학습율 조정을




Fig. 2. Structure of the neural network used in this study.

Table 2. Mean square error of developed neural network related to hidden layer's numbers.

Number of hidden layers	Epochs		
	2000	5000	10000
1	5.95E+01	1.13E+01	8.68E+00
2	1.24E+01	8.87E-03	7.05E-02
3	1.76E-02	3.25E-03	6.80E-02
4	9.12E+02	4.18E+03	6.40E+03
5	4.18E+03	6.40E+03	6.40E+03

where, training rate; 0.01, momentum; 0.9

Table 3. Structure of developed neural network

Hidden layer numbers	3
Epochs	5000
Node numbers of hidden layers	10, 16, 20
Training rate	0.01
Momentum	0.90
Learning function(MATLAB)	learngdm, traingdm

통해 최소화하였다. Table 3은 본 신경회로망의 학습에 사용된 주요 변수들을 나타낸 것이다.

결과 및 고찰

1. 오이의 생육일수별 배액 이온농도 변화

배액 이온 농도를 예측하기 위해 약 2달간 오이 재배에 사용된 배양액에서 채취한 배액의 주간 이




Fig. 3. Weekly ion-concentrations of macronutrients in discharged nutrient solution for cucumber.

온농도 변화 추이는 Fig. 3과 같다. 일주일 간격의 이온농도 변화를 알아보기 위해 정식 후 배액 이온농도를 처음 측정한 날을 0일로 정하고 일주일 단위로 10주 동안 매주 새로운 배양액을 조제한 월요일 다음날인 화요일 12~13시 사이에 배액통에서 양액을 채취하였다. (새로운 양액은 매주 화요일과 목요일 두 번 조제하여 공급함). 각 측정은 3 반복 실시하여 그 평균값을 이용하였다.

오이의 생육일수별 무기이온인 다량원소의 농도는 생육일수에 따라 각 이온 간의 차이를 보였다. Mg²⁺과 PO₄³⁻이온은 생육후기까지 일정한 형태로 지속되는 경향을 보였으나, SO₄²⁻는 생육중반 시기에 이온농도가 약간 증가하였다가 생육후기에 다소 감소하였다. 그러나 K⁺과 Mg²⁺, 그리고 NO₃⁻은 생육 중반까지 증가했다가 감소하였으며, 중반이후 급격히 증가했다가 다시 감소하는 경향을 보였다.

2. 오이의 생육일수별 배액 이온농도 예측

가. 신경회로망 학습

Table 4는 개발한 신경회로망을 이용해 생육일

수를 입력으로 하는 배액 이온농도 예측에 대한 학습결과를 결정계수로 나타낸 것이다. 전반적으로 모든 이온에 대하여 생육일수별 배액 이온농도 학습 결과는 우수한 것으로 나타났다.


나. 배액 이온농도 예측성능 검증

Table 5는 검증용 데이터를 입력으로 사용하여 예측한 신경회로망의 결과를 나타낸 것이다. 대부분 검증데이터를 이용한 모델 예측 성능이 우수하게 나타났으나, K⁺이온의 경우 오차가 110ppm까지 차이가 나는 것을 확인 할 수 있었다. 이는 생육일수별 이온농도 변화에서도 확인하였듯이 생육일수에 따른 K⁺이온의 농도변화가 심했을 뿐 아니라 학습과 검증에 사용된 데이터의 변화추이가 달랐기 때문으로 판단된다.


Fig. 4는 신경회로망의 예측성능을 평가하기 위해 검증 데이터를 이용한 신경회로망의 결과와 검증데이터의 원 값과의 선형관계를 그래프로 나타낸 것이며, 신경회로망의 성능은 일차 회귀식의 결정계수로 나타내었다.

Table 4. Trained results of developed neural network


Index	NO ₃ ⁻	K ⁺	Mg ²⁺	Ca ²⁺	SO ₄ ²⁻	PO ₄ ³⁻
R ²	0.9998	0.9998	0.9958	0.9992	0.9993	0.9926




(a) NO_3^-




(b) K^+




(c) Mg^{2+}



(d) Ca^{2+}



(e) SO_4^{2-}



(f) PO_4^{3-}

Fig. 4. Prediction performance of developed neural network.

Fig. 4와 같이 예측성능의 평가결과에서 NO_3^- 와 Ca^{2+} , Mg^{2+} 이온의 경우 결정계수가 0.86 이상으로 예측성능이 매우 우수한 것으로 나타났으며, K^+ 와 SO_4^{2-} 이온의 경우는 결정계수가 0.53이상으로 배액 이온농도의 예측 가능성을 보여주었으나,

PO_4^{3-} 이온의 예측성능은 결정계수가 낮아 배액 이온농도 예측이 가능하지 못한 것으로 나타났다. Fig. 5는 개발된 신경회로망의 검증 결과를 그래프로 나타낸 것이다.

Table 5. Errors for verification results after 5,000 iterations

	Day after transplanting	1	7	14	22	29	35	42	50	56
NO ₃ ⁻	Real value	50.8	115.5	141.9	87.5	100.5	104.6	234.6	222.3	126.9
	Predictive output	49.9	129.3	135.0	74.3	99.1	95.2	256.8	250.1	113.6
	Error (%)	1.8	-11.9	4.9	15.1	1.4	9.0	-9.5	-12.5	10.5
K ⁺	Real value	80.2	202.0	330.5	286.8	248.9	241.0	323.2	253.5	212.4
	Predictive output	65.8	289.7	304.5	278.3	224.9	238.3	339.9	363.7	163.6
	Error (%)	18.0	-43.4	7.9	3.0	9.6	1.1	-5.2	-3.5	23.0
Mg ²⁺	Real value	12.4	26.8	34.2	26.2	26.3	26.1	44.4	44.9	26.2
	Predictive output	9.8	35.2	32.3	23.3	24.0	24.6	51.2	40.4	22.6
	Error (%)	21.0	-31.3	5.6	11.1	8.7	5.7	-15.3	10.0	13.7
Ca ²⁺	Real value	46.3	95.0	93.0	61.4	80.0	72.1	179.8	189.3	131.0
	Predictive output	34.5	99.6	93.8	52.4	69.8	70.7	203.9	183.4	106.9
	Error (%)	25.5	-4.8	-0.9	14.7	12.8	1.9	-13.4	3.1	18.4
SO ₄ ²⁻	Real value	28.3	50.0	80.0	95.8	82.9	67.9	72.3	92.5	45.0
	Predictive output	23.3	75.0	72.3	101.8	68.7	75.3	89.9	59.7	37.4
	Error (%)	17.7	-50.0	9.6	-6.3	17.1	-10.9	-24.3	35.5	16.9
PO ₄ ³⁻	Real value	7.0	9.7	13.1	5.4	5.2	8.9	15.4	5.4	9.2
	Predictive output	6.3	15.2	15.6	6.8	6.7	7.7	6.0	8.9	9.4
	Error (%)	10.0	-56.7	-19.1	-25.9	-28.8	13.5	61.0	-64.8	-2.2

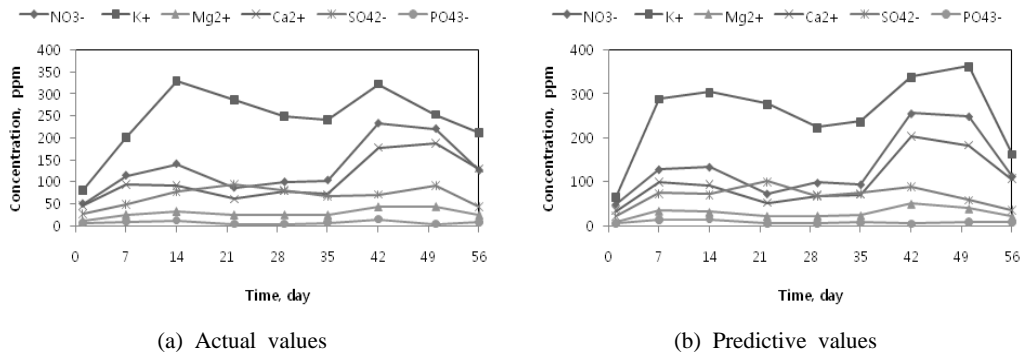


Fig. 5. Plots of actual and predicted values for verification of the developed model.

그림에서 보는 바와 같이 배액 이온농도 변화는 개발된 신경회로망을 통해 생육일수별 배액 내 다량이온농도를 예측할 수 있는 것으로 판단되었으며, 보다 많은 실험 데이터가 확보할 수 있다면 본

연구에서 개발된 신경회로망은 더 많은 작물의 양액재배 제어시스템에 있어 효과적인 배액 이온농도변화 예측 모델로 활용될 수 있을 것으로 기대되었다.

오이의 생육일수별 배액내의 다량 이온농도 예측을 위한 인공신경회로망을 개발하였다. 오이 재배실험에서 얻은 데이터를 이용하여 신경회로망의 입력값으로는 생육일수를, 학습 목표값으로는 실제 재배실험에서 얻은 배액 내 다량이온농도를 적용해 개발된 신경회로망을 학습하게 하였으며, 학습된 신경회로망은 검증데이터를 이용해 그 예측성을 평가하였다.

- (1) 개발된 신경회로망은 다층퍼셉트론의 역전파 알고리즘을 사용하였으며, 은닉층은 3개, 반복 횟수는 5000회, 학습율은 0.01, 모멘텀은 0.9를 적용해 신경회로망의 학습에 적용하였다. 학습에 사용된 활성함수는 입력층에서 은닉층간 계산을 위해 *logsigmoid* 함수를 사용하였으며, 은닉층간 함수는 *tansigmoid*, *logdigmoid* 함수를 사용하였다. 은닉층에서 출력층간 활성함수는 *pureline* 함수를 사용하였다.
- (2) 개발된 신경회로망은 학습결과 결정계수가 0.98 이상으로 나타나 학습성능이 매우 우수한 것으로 나타났다.
- (3) 학습된 신경회로망의 예측 성능은 NO_3^- , Mg^{2+} 와 Ca^{2+} 이온의 경우 결정계수가 0.86 이상으로 예측성능이 매우 우수한 것으로 나타났다. K^+ 와 SO_4^{3-} 이온의 경우는 결정계수가 0.53이상으로 배액 이온농도의 예측 가능성을 보여주었으나, PO_4^{3-} 이온의 예측성능은 결정계수가 낮아 배액 이온농도 예측이 가능하지 못한 것으로 나타났다.
- (4) 본 연구에서 개발된 신경회로망은 예측성능이 우수하여 타작물의 적용이 가능할 것으로 판단되며, 양액재배 자동화시스템의 실시간 배액 이온농도변화 예측 모델로 활용될 수 있을 것으로 기대된다.

1. Hirahuji, M. 1992. A plant growth model based on interference between organs and the method and the method of identification. *J. Agr. Met.* 48: 285-293.
2. Kim, K. B., H. Y. Kang, D. J. Yoon and M. Y. Choi. 2004. Pattern classification of acoustic emission signals during wood drying by artificial neural network. *J. of Biosystems Engr.* 29(3): 261-266.
3. Kim, C. S., C. H. Lee, S. J. Park and M. H. Kim. 1998. Automatic grading algorithm for white Ginseng. *J. of Biosystems Engr.* 23(6): 607-614.
4. Kim, H. J., J. H. Kim, Y. H. Woo and Y. I. Nam. 2001. Nutrient and Water Uptake of Cucumber Plant by Growth Stage in Closed Perlite Culture. *Journal of Bio-Environment Control.* 10(2): 125-131.
5. Morimoto, T., Y. Hashimoto. 1991. Application of fuzzy logic and neural networks to the process control of solution pH in deep hydroponic culture. *Proc. IFAC/SSHS workshop on mathematical and control application in agriculture and horticulture:* pp. 147-152.
6. Son, J. H., Lim, M. K., Nam, S. W. 1992. Estimation of Electrical Conductivity(EC) using Neural Networks. *The Korean Society for Bio-Environment Control.* 1(2): 162-168.
7. Sung, J. H., Lee, D. H. 2005. Rice Yield Prediction Based on the Soil Chemical Properties Using Neural Network Model. *Journal of Biosystems Engineering.* 30(6): 360-365.
8. Yang, G. M., H. K. Koh and J. H. Hong. 2003. Development of neuro-fuzzy system for cold storage facility. *J. of Biosystems Engr.* 28(2): 117-126.