

養液재배를 위한 培養液管理 支援시스템의 開發

II. 神經回路網에 의한 電氣傳導度(EC)의 推定

孫禎翼·金文基·南相運

서울대학교 農業生命科學大學 農工學科

Development of a Supporting System for Nutrient Solution Management in Hydroponics

II. Estimation of Electrical Conductivity(EC) using Neural Networks

Son, Jung-Eek · Kim, Moon-Ki and Nam, Sang-Woon

Dept. of Agr. Eng., Coll. of Agr. & Life Sciences, Seoul Nat'l Univ., Suwon 441-744

Summary

As the automation of nutrient solution management proceeds in the field of hydroponics, effective supporting systems to manage the nutrient solution by computer become needed. This study was attempt to predict the EC of nutrient solution using the neural networks.

The multilayer perceptron consisting of 3 layers with the back propagation learning algorithm was selected for EC prediction, of which nine variables in the input layer were the concentrations of each ion and one variable in the output layer the EC of nutrient solution. The meq unit in ion concentration was selected for input variable in the input layer.

After the 10,000 learning sweeps with 108 sample data, the comparison of predicted and measured ECs for 72 test data showed good agreements with the correlation coefficient of 0.998. In addition, the predicted ECs by neural network showed relatively equal or closer to the measured ones than those by current complicated models.

키 워 드 : 배양액, 신경회로망, 양액재배, 역전파회로망, 전기전도도예측

Key words : back propagation, EC prediction, hydroponics, neural networks, nutrient solution

序 論

양액재배에 따른 배양액 관리의 자동화가 진행될수록, 배양액을 효율적으로 관리할 수 있는 지원시스템이 필요하다. 임의의 생육단계에 따른 배양액의 배합후, 전체적인 배양액의 전기전도도(EC) 예측이 가능하다면 사전에 EC의 허용한계를 만족하는 추가량을 결정할 수 있기 때문에 배양액관리에 유효하다^{13,14}.

단일 무기화합물 수용액에 대한 이론적 예측은

어느정도 가능하지만¹⁰, 무기화합물의 종류가 증가하면 수용액이 비선형적인 성격을 나타내기 때문에 근사적인 예측방법이외에는 불가능한 것이 사실이다^{2,9,15}. 따라서 배양액과 같은 복합 무기화합물 수용액의 경우, 예측모델 및 실험에 의한 근사 예측방법이 이용되고 있다¹⁰. 그러나 예측모델의 경우, 배양액의 물리화학적 특성을 완벽하게 표현할 수 없고, 모델화하는 과정에서 많은 어려움을 내포하고 있다^{4,6}.

최근 시설원예의 환경관리등에 AI 수법이 도입

되고 있고 양액배배에도 예외는 아니다. 신경회로망은 인간의 뇌에서 일어나는 신경세포의 움직임을 단순화하여 컴퓨터에 근사적으로 실현시킨 것으로써 패턴인식, 최적화 등의 분야에서 유력한 수법으로 인정되고 있다^{1,11)}. 특히 다층 퍼셉트론(multi-layer perceptron)에 의거한 역전파회로망(back propagation) 학습방법은 여러방면에서 그 성과가 인정되어 실용화되고 있고^{1,12)}, 농업분야에도 실용화를 위한 연구가 진행되고 있다^{3,6,7,9,10,17)}.

기본적으로 신경회로망은 입력층, 출력층 및 미지층으로 구성되어 있어서 내부구조에 해당하는 중간층을 정확히 기술하지 않더라도 적절한 학습방법에 의해서 역으로 중간층을 구성할 수 있는 장점이 있기 때문에 복잡하고 비선형적인 관계에 대해서 신경회로망의 적용은 효율적이라고 사료된다.

본 연구는 종합적인 배양액 관리의 기초가 되는 배양액의 전기전도도 예측방법을 검토하기 위하여 각 이온의 농도를 입력, 전기전도도를 출력으로 하는 역전파 다층 회로망을 이용하여 배양액의 전기전도도 추정 및 신경회로망의 적용 효과를 검토하였다.

材料 및 方法

1. 신경회로망의 선택

신경회로망은 인간의 뇌에서 일어나는 신경세포의 움직임을 단순화하여 컴퓨터에 근사적으로 실현시킨 것으로써 최적화, 시스템제어, 음성 및 영상인식, 패턴분류 등의 분야에서 유력한 수법으로 인정되고 있다. 현재 연구발표된 신경회로망 가운데 일반적으로 적용성이 높은 대표적인 모델들중의 하나로 Fig.1의 역전파 다층회로망이 있다.

다층 퍼셉트론이라고 불리우는 이러한 모델은 하부의 입력층(input layer), 상부의 출력층(output layer) 및 중간부분의 미지층(hidden layer)으로 구성되어 있고 각 층은 여러개의 처리요소(processing element)를 가진다. 근접층의 요소들간에는 서로 연결되어 있고 연결강도로써 정보전달의 가중치가 결정된다. 또한 각 요소는 S자형(sigmoid) 형태의 전달함수(transfer function)를 이용하여 입력정보를 전달시킨다. 입력층 요소에 입력되는 정보는 전달함수를 통하여 변환되고 다시 가중치가 곱하여 다시 미지층의 각 요소로 입력된다. 목적에 따라서 전

달함수의 형태를 변화시킬 수 있으나 본연구에서는 일반적인 시그모이드 함수를 이용하였다. 전달함수의 내용은 식(1) 과 같다.




Fig.1. A typical structure of a multilayer perceptron neural network.

$$f(x) = 1/(1 + e^{-x}) \quad (1)$$

여기서, x 는 입력값, f 는 전달함수를 나타낸다. 본연구에서 사용한 신경회로망은 역전파 신경회로망을 수정한 형태를 사용하였고¹¹⁾, 학습 및 검증 자료의 입출력 과 오차의 평가를 위하여 C 언어를 사용하여 부 프로그램을 작성하였다.

2. 신경회로망의 구성

1) 학습방법

본연구에 사용한 역전파 알고리즘의 기본 원리는 다음과 같다. 입력층의 각 요소에 입력패턴을 주면 이 신호는 각 요소에서 변환되어 미지층에 전달되고 출력층의 각 요소를 통해 신호를 출력하게 된다. 이 출력치와 목표치를 비교하여 상위층에서 하위층으로 역전파하여 그 차이를 줄여나가는 방향으로 연결강도를 조절해 나간다.

본연구에서는 모멘텀을이용한 역전파 학습방법을 이용하였다. 이 방법은 연결강도의 수정에 있어서 이전의 수정량을 고려함으로써 오차의 진동을 방지하고 신속하게 수렴이 가능하도록 한다. 실제로 입력 패턴에 대해서 학습회수가 n 일 경우, 상위층의 j 요소와 하위층의 i 요소사이의 연결강도($W_{ji} = W_{ji}$)는 다음 식에 의하여 구할 수 있다.

$$W_{ji}(n) = W_{ji}(n-1) + \Delta W_{ji}(n) \quad (2)$$

$$W_{ij}(n) = \alpha * \Delta W_{ij}(n-1) + \eta * \delta_j * o_i \quad (3)$$

여기서, δ_j 는 출력층의 출력치에 대한 일반화된 오차, o_i 는 i 유닛의 출력치를 나타낸다. α 와 η 는 각각 모멘텀 계수와 학습이득으로써 0.6 과 0.9를 적용하였다. 학습시의 오차함(E)은 다음식과 같이 p 번째 자료에 대한 출력층의 k 번째 요소의 목표치와 출력치로써 나타낼 수 있다.

$$E = \sum_p E_p = \sum_p \left[\frac{1}{2} \sum_k (D_{pk} - O_{pk})^2 \right] \quad (4)$$

여기서, N 은 입력자료수, M 은 출력층의 요소수, D_{pk} 는 목표치, O_{pk} 는 출력치이고 $p=1 \sim N, k=1 \sim M$ 범위이다. 본연구에서는 108개의 자료를 이용하여 학습을 시행하였다. 매 입력에 대하여 오차를 계산하여 연결강도를 수정하였다. 이때 입력치의 편기성을 배제하기 위하여 초기가중치는 난수발생기를 사용하여 설정하였다. 또한 허용오차는 0.001로 설정하였다.

2) 입력변수, 중간층 및 요소수의 결정

입력변수는 각 이온의 농도를 대표하는 변수인 mol(몰) 과 meq(당량)중에서 학습시 오차가 적은 변수를 선택하였다. 입력층의 입력 요소는 9개으로써 $K^+, Ca^{2+}, Mg^{2+}, NH_4^+, Na^+, NO_3^-, SO_4^{2-}, PO_4^{3-}, Cl^-$ 의 농도를 사용하였고 출력층의 요소는 1개으로써 EC(mS/cm)를 사용하였다. 또한 미지층이 1층(9 요소) 및 2층(9*9 요소)인 2 종류의 신경회로망에 대하여 적용하였다. 입력변수의 선정을 위해서 3,000회 정도의 학습범위내에서 오차가 최소인 경우의 입력변수를 적합 입력변수으로써 선택하였다.

또한 미지층 및 요소수의 결정을 위하여 1층, 2층 및 3층의 미지층에 대하여 유닛수가 다른 5종류의 각각의 모델에 대하여 검토하여 오차가 최소인 경우의 중간층수를 결정하고 이 경우에 대하여 오차가 최소가 되는 요소의 수를 결정하였다.

학습 및 검정을 위하여 EC 및 각 이온의 농도가 측정된 180개의 자료중 임의 선별한 108 개를 학습자료로 사용하였고 나머지 72개 자료를 검정용으로 사용하였다. 이때 사용된 학습자료는 $K^+, Ca^{2+}, Mg^{2+}, NH_4^+, Na^+, NO_3^-, SO_4^{2-}, PO_4^{3-}, Cl^-$ 의 농도으로써 각각 약 0~35 meq의 범위으로써 EC는 약 0~6 mS/cm 범위의 농도이었다. 입력층은 0~1 사이의 범위로 하기 위하여 입력정보에 1/35 을 곱하였고, 출력층의 경우는 실제의 농도범위를 만족시키기 위하여 출력정보에 10을 곱하였다.

3. 학습 및 검정방법

결정된 신경회로망에 대하여 (5)식의 오차를 최소로 하는 학습회수 결정을 위하여 100,000회 정도 충분히 실시하여 적절한 학습회수의 범위를 결정하였다. 또한 학습결과의 검정을 위하여 충분히 학습된 신경회로망을 이용하여 0~4 mS/cm의 범위인 72개의 자료에 대한 검정을 실시하였다. 신경회로망에 의한 EC 추정방법의 일반성을 확인하기 위하여 이미 개발되어 있는 모델에 의한 추정치와 비교하였다. 본 비교에 사용된 모델은 배양액의 EC 추정을 위해서 개발된 선형 근사식, 비선형 근사식 및 그 확장식을 사용하였다²¹⁾.

結果 및 考察

1. 신경회로망의 구성

1) 입력변수, 미지층 및 요소수의 결정

미지층의 수가 1층(9 요소), 2층(9*9 요소) 인 모델에 대하여 meq농도와 mol농도를 사용한 결과는 Fig.2와 같다. 미지층에 관계없이 meq농도를 사용한 경우가 mol농도를 사용한 경우보다 상대적으로 오차 및 수렴속도면에서 좋은 결과를 보였다. 이 결과는 일반 수용액에 대하여 meq농도가 mol농도 보다 EC 추정에 더 유용하다는 실험적 결과를 반증하고 있다¹⁵⁾.




Fig.2. Relations among kinds of ion concentration and error.

미지층이 각각 1층, 2층 및 3층에 대하여 요소수가 다른 5종류를 대표하는 각각의 모델에 대하여 검토한 결과는 Fig. 3과 같다. meq농도의 입력에 대하여 미지층이 1, 2인 경우에 양호한 것으로 나

타났다. 본 보에서는 생략했지만 미지층수가 동일할 경우, 학습회수에 대한 오차의 추이는 거의 비슷한 경향으로써 학습회수가 3,000일 경우, 3층이 0.2내외, 2층이 0.02~0.03, 1층이 0.01~0.02로 나타났다.




Fig.3. Relations among number of hidden layers and error.

미지층이 1층인 경우에 대하여, 요소의 수에 따른 오차의 변화는 Fig.4 와 같다. 요소수가 가 9, 11인 경우에 신속하게 수렴하는 경향을 나타냈다. 본연구에 한해서 요소수가 9 이상은 불필요한 요소로써 11의 경우는 불필요한 2개의 요소가 존재하는 것을 의미한다. 위와 같은 결과에 근거하여 EC 추정을 위하여 경험적으로 설정한 신경회로망의 개요는 Fig. 5와 같다.

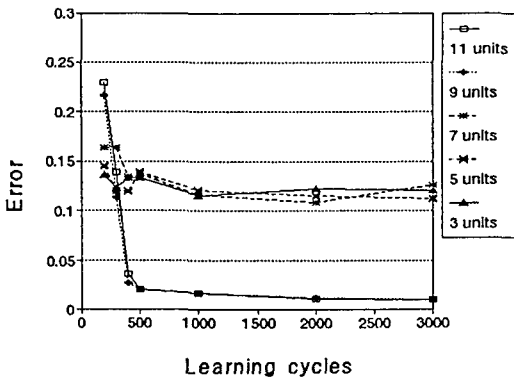


Fig.4. Relations among number of units and error for 1 hidden layer.




Fig.5 A selected neural network for EC prediction.

2. 학습 및 검정결과

결정된 신경회로망에 대하여 허용오차 범위내에서 오차를 최소로 하는 충분한 학습회수의 결정을 위하여 100,000회 정도 충분히 실시한 결과, 5,000가 10,000회 정도에서 오차의 변동이 거의 없었고 이때 오차는 0.001 이하 이었다. 따라서 10,000회 정도의 학습으로 충분한 학습이 이루어 졌다고 판정되었다.

또한 최대오차를 발생시키는 입력정보 패턴을 조사하기 위하여, 72개의 검정자료에 대하여 오차 분포에 따른 사용 비료염의 종류(9개의 입력정보중 사용된 정보)를 조사한 결과 큰 특징은 발견되지 않았다.

검정용으로 선발된 72개 입력자료에 대하여 학습회수가 200, 1,000, 3,000, 5,000, 10,000회에 대한 추정치와 목표치의 관계는 Fig.6과 같다. 200회의 경우, 목표치(직선)로부터 우측으로 이탈되어 있지만 학습이 진행되면서 목표치에 접근하는 경향이 뚜렷하였고 10,000회 정도에서는 거의 목표치에 가까운 근사치를 나타냈다. 이때, $Y=0.987X+0.023$, $R=0.998$ 의 높은 상관관계를 보였다. 72개 자료에 대한 검정결과 의 상세내역은 Table 1과 같다.

2) 기존모델에 의한 추정치와 비교

신경회로망에 의한 EC 추정방법의 일반성을 확인하기 위하여 기존 모델에 의한 추정치와 비교한 결과는 Table 2와 같다. 본 비교에 사용된 모델은 배양액의 EC 추정을 위해서 개발된 선형 근사방법,




Fig.6. Comparisons among desired EC and trained one after 200, 1000, 3000, 5000 and 10000 learning cycles.

Table 1. The details of error for 72 test samples after 10000 learning cycles.

Desired output	Trained output	Error	Desired output	Trained output	Error
0.170	0.225	-0.055	2.487	2.337	0.150
0.488	0.483	0.005	1.264	1.270	-0.006
0.593	0.555	0.38	1.086	1.004	0.082
0.165	0.225	-0.060	1.302	1.270	0.032
0.410	0.432	-0.022	1.634	1.567	0.067
0.560	0.540	0.020	0.557	0.624	-0.067
0.704	0.674	0.030	1.704	1.627	0.077
0.987	0.932	0.055	0.501	0.624	-0.123
0.465	0.490	-0.025	1.470	1.431	0.039
0.713	0.695	0.018	1.938	1.841	0.097

(Continued)

Desired output	Trained output	Error	Desired output	Trained output	Error
0.911	0.837	0.074	1.559	1.668	-0.109
1.102	1.017	0.085	2.439	2.444	-0.005
0.390	0.402	-0.012	3.664	3.608	0.056
0.682	0.617	0.065	1.342	1.308	0.034
0.718	0.647	0.071	2.797	2.717	0.080
1.096	1.003	0.093	1.604	1.668	-0.064
0.460	0.490	-0.030	2.060	2.061	-0.001
0.590	0.593	-0.003	0.668	0.756	-0.088
0.882	0.807	0.075	2.060	1.994	0.066
0.307	0.358	-0.051	0.668	0.756	-0.088
0.908	0.868	0.040	1.771	1.755	0.016
0.309	0.358	-0.049	1.982	2.051	-0.069
0.793	0.767	0.026	3.085	2.997	0.088
1.744	1.621	0.120	1.663	1.599	0.064
0.900	0.883	0.017	2.572	2.577	-0.005
1.356	1.284	0.072	2.005	2.051	-0.046
0.758	0.706	0.052	0.795	0.888	-0.093
2.023	1.872	0.151	2.450	2.354	0.096
0.908	0.883	0.025	3.322	3.208	0.114
1.147	1.085	0.062	0.796	0.888	-0.092
1.660	1.499	0.161	2.157	2.073	0.084
1.999	1.852	0.147	2.699	2.659	0.040
0.457	0.490	-0.033	2.439	2.429	0.010
0.456	0.490	-0.34	1.995	1.885	0.110
1.165	1.096	0.069	2.328	2.429	-0.101
2.173	2.050	0.123	2.982	2.994	-0.012

비선형 근사방법 및 그 확장형태로써, 상세한 유도과정 및 입력자료의 전처리 방법등은 前報를 참조하기 바란다^{2,15)}. 신경회로망에 의한 EC 추정 결과와 기존의 복잡한 예측모델에 의한 방법과의 비교결과 상대적으로 동일 또는 부분적으로 우수한 결과를 나타냈다. 따라서 신경회로망의 적용가능성은 충분하다고 판단된다.

Table 2. Comparisons among measured EC and predicted ones; f_m , f_1 , f_2 , f_2' and f_n indicate the measured, the predicted by linear regression, by non-linear regression using Robinson & Stokes equation¹⁶⁾ by its extension equation, and by neural network, respectively.

f_m	Predicted EC(mS/cm)				Error(mS/cm)			
	f_1	f_2	f_2'	f_n	f_1	f_2	f_2'	f_n
1.40	1.38	1.32	1.47	1.36	-0.02	-0.08	0.07	-0.04
1.86	1.73	1.67	1.88	1.76	-0.13	-0.19	0.02	-0.10
2.15	2.09	2.04	2.28	2.11	-0.06	-0.11	0.13	-0.04
2.43	2.30	2.24	2.58	2/32	-0.23	-0.29	0.15	-0.11
2.63	2.72	2.62	2.85	2.76	0.09	-0.01	0.22	0.13
5.08	5.09	5.09	5.80	5.07	0.01	0.01	0.72	-0.01

結論 및 요약

양액재배에 따른 배양액 관리의 자동화가 진행될수록, 배양액을 효율적으로 관리할 수 있는 지원시스템이 필요하다. 본 연구는 배양액 관리의 기초가 되는 배양액의 전기전도도 예측방법을 검토하기 위하여 각 이온의 농도를 입력, 전기전도도를 출력으로 하는 다층신경회로망을 이용하여 배양액의 전기전도도 추정 및 신경회로망의 적용효과를 검토하였다.

사용한 신경회로망은 역전과 학습방법을 사용한 다층 퍼셉트론 모델로써, 미지층이 1층으로써 9개의 처리요소로 구성하였고, 입력층은 9개의 입력변수 그리고 출력층으로 전기전도도를 나타내도록 하였다. 입력층의 입력변수가 이온의 meq농도를 사용한 경우가 가장 좋은 결과를 보였다.

108개의 자료에 의하여 10,000회의 학습후, 72개의 검정자료에 의하여 추정치와 측정치를 비교한 결과, 상관계수 0.998의 높은 상관관계를 보였다. 또한 기존의 복잡한 예측모델에 의한 방법과 비교한 결과 상대적으로 동일한 또는 우수한 결과를 나타냈다. 따라서 이러한 신경회로망의 적용연구는 양액재배분야등을 비롯한 여러분야에서 활발히 추진할 필요가 있다고 사료된다.

마지막으로 본연구에 대하여 많은 조언을 아끼지 않은 성균관대학교 황 현 박사에게 감사의 뜻을 표한다.

參考文獻

- 1) 金大洙. 1992. 神經網理論과 應用(I). 하이테크情報.
- 2) 孫禎翼, 金文基. 1992. 養液栽培를 위한 培養液管理 支援시스템의 開發, 1. 培養液의 配合 및 電氣傳導度(EC)의 豫測. 生物生產施設環境 1 : 52-60.
- 3) 黃憲, 李忠鎬. 1992. 컴퓨터 視覺에 의거한 測定技術 및 測定誤差의 分析과 補正. 韓國農業機械學會誌 17 : 65-78.
- 4) Adams, F. 1977. Ionic concentration and activities in soil solutions. Soil Sci. Soc. Amer. Proc. 35 : 420-426.
- 5) Bard, A.J. 1985. Chemical equilibrium(松田·小倉譯). 化學同人 : 101-112.
- 6) Hirahuji, M. 1992. A plant growth model based on interference between organs and the method of identification. J. Agr. Met. 48 : 285-293.
- 7) Honjo, T. and T. Takakura. 1991. Identification of water and nutrient supply to hydroponic tomato plants by using neural net. Proc. IFAC/ISHS workshop on mathematical and control application in agriculture and horticulture : 285-288.
- 8) McNeal, B.L., J.D. Oster, and J.T. Hatcher. 1970. Calculation of electrical conductivity from solution composition data as an aid to in-situ estimation of soil salinity. Soil Science. 110 : 405-414.
- 9) Morimoto, T. and Y. Hashimoto. 1991. Application of fuzzy logic and neural networks to the process control of solution pH in deep hydroponic culture. Proc. IFAC/ISHS workshop on mathematical and control application in agriculture and horticulture : 147-152.
- 10) Murase, H., R. Yamauchi, and N. Honami. 1992. Simultaneous control of temperature and humidity in a confined space using Kalman filter neural networks - system identification-. Environ. Control in Biol.(Japan). 30 : 37-44.
- 11) Neural Ware. 1989. Neural computing. NeuralWare, Inc.
- 12) Rumelhart, D.E., G.E. Hinton and R.J. William. 1986. Learning representations by backpropagating errors. Nature 323 : 533-536.
- 13) Son, J.E. and T. Takakura. 1987. A study on automatic control of nutrient solutions in hydroponics. J. Agr. Met. 43 : 147-151.
- 14) Son, J.E. 1988. A study on environmental control in factory-style production of lettuce. PhD thesis, University of Tokyo, Tokyo.

- 15) Son, J.E. and T. Okuya. 1991. Prediction of electrical conductivity of nutrient solution in hydroponics. J. Agr. Met. 47 : 159-163.
- 16) Tanji, K.K. 1960. Predicting specific conductance from electrolytic properties and ion association in some aqueous solution. Soil Sci. Soc. Amer. Proc. 33 : 887-889.
- 17) Zuang, X. and B.A. Engel. 1990. Neural networks for applications in agriculture. Paper No. 90-7024. ASAE. St. Joseph, Chicago, IL.
- 18) 水野直治. 1984. 水溶液の電氣傳導度に關する各種イオン濃度の影響. 土肥誌 55 : 103-108.

학 회 광 고

한국생물생산시설환경학회에서는 본 학회지의 취지에 찬동하는 개인 및 단체 (구독, 찬조)회원을 아래와 같이 접수하고 있사오니 많은 참여를 바랍니다.

- 아 래 -

1. 회원가입접수 : 수시접수
2. 회원가입방법 : 학회지에 삽입된 입회원서에 기재
3. 회비(입회비) : 정회원 10,000원(준회원은 제외)
(년회비) : 정회원 15,000원(20,000원), 준회원 5,000원(10,000원)
구독회원 20,000원(40,000원), 종신회원 150,000원(200,000원)
찬조회원 1구좌이상 「1구좌 100,000원(150,000원)」
* () : 4월 1일부터 인상예정의 금액
4. 접 수 처 : 본 학회 사무국