

Outside Temperature Prediction Based on Artificial Neural Network for Estimating the Heating Load in Greenhouse

Kim Sang Yeob[†] · Park Kyoung Sub^{**} · Ryu Keun Ho^{***}

ABSTRACT

Recently, the artificial neural network (ANN) model is a promising technique in the prediction, numerical control, robot control and pattern recognition. We predicted the outside temperature of greenhouse using ANN and utilized the model in greenhouse control. The performance of ANN model was evaluated and compared with multiple regression model(MRM) and support vector machine (SVM) model. The 10-fold cross validation was used as the evaluation method. In order to improve the prediction performance, the data reduction was performed by correlation analysis and new factor were extracted from measured data to improve the reliability of training data. The backpropagation algorithm was used for constructing ANN, multiple regression model was constructed by M5 method. And SVM model was constructed by epsilon-SVM method. As the result showed that the RMSE (Root Mean Squared Error) value of ANN, MRM and SVM were 0.9256, 1.8503 and 7.5521 respectively. In addition, by applying the prediction model to greenhouse heating load calculation, it can increase the income by reducing the energy cost in the greenhouse. The heating load of the experimented greenhouse was 3326.4kcal/h and the fuel consumption was estimated to be 453.8L as the total heating time is 10000°C/h. Therefore, data mining technology of ANN can be applied to various agricultural fields such as precise greenhouse control, cultivation techniques, and harvest prediction, thereby contributing to the development of smart agriculture.

Keywords : Artificial Neural Network, Facility Horticulture, Heating Load, Regression, Support Vector Machine

인공신경망 기반 온실 외부 온도 예측을 통한 난방부하 추정

김 상 엽[†] · 박 경 섭^{**} · 류 근 호^{***}

요 약

최근, 인공신경망 모델은 예측, 수치제어, 로봇제어, 패턴인식 등의 분야에서 촉망되는 기술이다. 본 연구에서는 인공신경망 모델을 이용하여 온실 외부 온도를 예측하고 이를 온실제어에 활용하는데 목적이 있다. 예측 모델의 성능 평가를 위해 다중회귀모델과 SVM 모델과의 비교분석을 수행하였다. 평가 방법으로는 10-Fold Cross Validation을 사용하였으며, 예측 성능 향상을 위해 상관관계분석 통해 데이터 축소를 수행하였고, 측정 데이터로부터 새로운 Factor 추출하여 데이터의 신뢰성을 확보하였다. 인공신경망 구축을 위해 Backpropagation algorithm을 사용하였으며, 다중회귀모델은 M5 method로 구축하였고, SVM 모델을 epsilon-SVM으로 구축하였다. 각 모델의 비교분석 결과 각각 0.9256, 1.8503과 7.5521로 나타났다. 또한 예측모델을 온실 난방부하 계산에 적용함으로써 온실에 사용되는 에너지 비용 절감을 통한 수입증대에 기여할 수 있다. 실험한 온실의 난방부하는 3326.4kcal/h이며, 총 난방시간이 10000°C/h일 때 연료소비량은 453.8L로 예측된다. 아울러 데이터 마이닝 기술 중 하나인 인공신경망을 정밀온실제어, 재배기법, 수확예측 등 다양한 농업 분야에 적용함으로써 스마트 농업으로의 발전에 기여할 수 있다.

키워드 : 인공신경망, 시설원예, 난방부하, 회귀모델, 서포트 벡터 머신

1. 서 론

전 세계적으로 온실의 면적이 증가하고 있고, 그중 한국의

1인당 온실면적이 세계 1-2위를 차지할 정도로 온실 재배가 널리 이루어지고 있으며, 이중에 시설재배 면적이 나날이 증가하였다. 시설재배는 노지재배와 다르게 재배 환경을 조절할 수 있기 때문에 기상환경조건 등 재배환경의 분석을 통해 생산성의 증대와 품질 향상을 달성할 수 있기 때문에 시설재배 면적에서 난방을 하는 온실이 증가하고 있는 추세이다.

온실에 사용되는 에너지 비용 중 대부분을 난방비가 차지하며, 기후이변에 따른 저 일조 및 한파에 따른 난방비용이 증가하는 추세이다. 이는 농가의 수입과 직결되어 이를 줄이는 것이 최대의 비용 절감 효과를 나타낼 수 있다. 이를 위해

※ 이 논문은 2017년도 미래창조과학부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2017R1A2B4010826).

† 준 회 원 : 한국기계연구원 정경연료발전연구소 선임연구원

** 정 회 원 : 국립원예특작과학원 농업연구관

*** 중 심 회 원 : 충북대학교 전기전자정보컴퓨터학부 교수

Manuscript Received : January 29, 2018

First Revision : March 19, 2018

Accepted : April 4, 2018

* Corresponding Author : Ryu Keun Ho(khryu@dblab.chungbuk.ac.kr)

온실 내의 온도, 습도 및 환기, 냉·난방, 제습 등을 제어하는 온실의 정밀한 환경제어가 필요하다. 온실 내의 온도와 습도는 시설온실의 환기뿐만 아니라 난방 및 제습에 민감하게 영향을 받는다. 특히 온실 난방 설계를 할 때 필요한 최대난방 부하는 외부 온도가 가장 큰 요인이므로 외부 온도의 예측은 중요하다[1].

다양한 환경 조건하에서 온실을 제어하여 수익을 증대시키고 에너지 소비를 줄이는 방향으로 많은 연구들이 수행되었다. 인공지능망을 이용한 온실 난방 에너지 소비를 예측한 연구에서는 회귀모델과의 비교를 통해 타당성을 검증하였다[2]. 온실의 온도 예측을 위해 LSSVM(Least Squares Support Vector Machine) 모델을 구축하여 SVM과 인공지능망과의 비교 분석을 수행하였다[3]. 퍼지이론과 인공지능망을 접목하여 딸기의 수확 예측모델을 제안하였으며, 기존의 인공지능망 기법과 비교 분석을 하였다[4]. 온실 환경제어를 위한 내부 온도 예측모델은 통계적 접근이나 복잡한 데이터마이닝 기법까지 여러 방법으로 구축될 수 있으나, 정확한 예측을 데이터 전처리와 같은 측정된 데이터의 신뢰성 확보 과정이 필요하다.

따라서 본 연구에서 정밀한 온실 환경제어를 위해 인공지능망을 이용한 온실 외부 온도의 예측모델을 제안한다. 데이터 전처리 단계에서 예측모델의 정확성 향상을 위해 상관관계분석을 통해 데이터의 차원을 축소하고, 새로운 요인을 추출하여 트레이닝 데이터에 반영하였다[5]. 또한, 난방이 되지 않은 온실의 데이터를 활용하여 다중회귀모델 및 SVM 모델을 구축하고 비교분석을 통해 예측모델의 타당성 검증하였다. 온실의 난방부하 예측에 제안한 모델을 적용함으로써 효율적인 온실 에너지 관리가 가능하며, 온실에 사용되는 에너지 비용의 절감 효과를 기대할 수 있다.

2. 재료 및 방법

본 연구는 대한민국 경상남도 함안의 시설원예연구소 내에 위치한 온실에서 실험을 수행하였다. 온실 내·외에 설치되어 있는 각 센서로 부터 다양한 유형의 데이터가 수집되며 이를 바탕으로 온실 제어가 수행된다.

2.1 온실 조건

함안 시설원예연구소에 위치한 벤로형 온실(Venlo-type Greenhouse)에서 수집한 데이터를 바탕으로 실험을 진행하였다. 난방조건은 주간(09 - 18시)을 기준으로 20℃, 야간(18 - 09시)은 18℃를 유지하게 설정하였으며, 온수를 이용한 난방을 하였다. 작물은 파프리카(품종: 쿠푸라)와 토마토(품종: 테프니스)를 재배하였으며, 환기는 천창 환기창은 28℃ 이상이면 열리도록 설정하였고, 고온기에는 측창 환기창은 수동으로 열어 두었다. 온실 주 난방기는 경유 보일러로 온수난방을 하고, 보조 냉난방기로 GHP(Gas engine Heat Pump)를

사용하였다. 데이터 수집을 위해 차광통 조건 하에서 온도 및 습도센서(Jauntering Int., 111N & 222N, Taiwan), CO₂센서(소하테크, VT-250, 한국), 일사량 센서(KIPP&ZONEN, CNR4, 네덜란드), 데이터 로거(캠벨社, CR1000, 미국)를 사용하였다.

2.2 데이터 전처리

환경 측정 데이터는 외부기상(온도, 습도, 풍향, 풍속)을 비롯한 일사량, 감우, 지표하 온도, 외부 CO₂, 온실 내 온도, 상대습도, 내부 CO₂ 등 총 29개의 항목을 수집하였다(Table 1). 데이터는 2016년 1년간 수집된 데이터를 사용하였으며, 데이터의 변화가 적기 때문에 10분 평균값으로 구성하였다.

Variable subset selection 기법에는 filter 방식, wrapper 방식, embedded 방식이 있는데 이 논문에서는 상관관계를 이용한 filter 방식을 선택하였고, 이러한 이유는 최종 모델링을 실제 환경에서 사용할 경우 발생하는 다중공선성 문제를 해결하기 위해서이다[6].

Table 1. Collected Data of Greenhouse

Attribute of Data(Unit)	Contents
AirTemp(℃)	Temperature in Greenhouse
RH(%)	Relative Humidity in Greenhouse
TgtAirTemp(℃)	Target Temperature
SurfTempHigher(℃)	Temperature of Intro Heating Pipe
SurfTempLower(℃)	Temperature of Outro Heating Pipe
HeatPumpAccLength(Sec)	Operating Time of Heat Pump
AirTemp_aws(℃)	External Temperature
RH_aws(%)	External Relative Humidity
sum_10m(min.)	Radiation Value over 120W/m ²
wet_10m(min.)	Condensation Value under 150Kohm
SlrW(W/m ²)	Solar Radiation
SlrW_Max(W/m ²)	Maximum Solar Radiation (AVG. 10min)
WS(m/s)	Wind Speed
WD(°)	Wind Direction
ws_gust(m/s)	Maximum Wind Speed (AVG. 10min)
wd_gust(°)	Direction of Maximum Wind Speed
PAR_Flux_Density(umol/m ²)	Intensity of Radiation
bar_pressure_kpa(kpa)	Air Pressure
Rain_mm(mm)	Rainfall
Under_10, 30, 50cm, 1, 1.5m(℃)	Subsurface Temperature - 10, 30, 50cm, 1, 1.5m
soilheat_10, 30, 50cm(W/m ²)	Subsurface Thermal Flux - 10, 30, 50cm
CO2_aws(ppm)	External CO2

1) 상관관계 분석

예측 모델의 정확성 향상을 위해 온실 외부 온도와 수집된 데이터의 상관관계 분석을 통해 입력변수의 축소를 수행하였다 (Dimension reduction). 상관관계 분석에 Pearson correlation coefficient 방법을 적용하였으며, 상관계수 값이 같거나 중복되는 변수는 하나만 선택하였다. 상관계수가 0.3이상, -0.3이하로 나타난 변수를 선택하여 총 29개 변수 중에 17개의 입력변수를 선정하였다.

2) 새로운 Factor 추출

선정한 입력변수 중 상대습도는 통계적 분석이나 온실 제어에 많이 사용되지 않으며, 수증기압 포차(Vapor Pressure)나 수증기 포차(Vapor Deficit)를 온실제어에 활용하고 있다. 이에 온실 내·외부 수증기 포차를 계산하여 각 모델의 입력변수로 반영하였다. 수증기 포차를 계산하는 수식은 다음과 같다.

Vapor Deficit Equation	(1)
$VD = SV - AH$	VD: Vapor Deficit
$SV = 0.6219 \times SVP / (1013.25 - SVP) \times 1000$	SV: Saturated Vapor
$AH = 0.6219 \times VP / (1013.25 - VP) \times 1000$	AH: Absolute Humidity
$VP = SVP \times RH$	RH: Relative Humidity
$SVP = 6.1078 \times 10^{\wedge}(7.5 \times T)/(237.3 + T)$	VP: Vapor Pressure
	SVP: Saturated Vapor Pressure
	T: Temperature

일련의 과정을 통해 인공신경망 모델의 Training data set을 구성하였으며, 작물 재배시기를 고려하여 6, 7월을 제외한 나머지 데이터를 Training에 사용하였다. 총 18개의 입력 변수로 구성되며 43,932개의 열로 구성하였다. Training data set을 이용하여 Cross validation 방법에 적용하여 각 모델의 비교 분석을 수행하였다[7]. Target 변수는 실외 온도이며, 2017년 1월 데이터를 이용하여 실측값과 예측값을 비교하였다.

Table 2. Training Data Set for Prediction Model

Attribute of Data(Unit)	Contents
AirTemp(°C)	Internal Temperature
TgtAirTemp(°C)	Target Temperature
VD(g/kg)	Vapor Deficit
HeatPumpAccLength(Sec)	Operating Time of Heat Pump
VD_aws(g/kg)	External Vapor Deficit
CO2_aws(ppm)	External CO2
sum_10m(min.)	Radiation Index over 120W/m ²
SlrW(W/m ²)	Solar Radiation
WS(m/s)	Wind Speed
PAR_Flux_Density(umol/m ²)	Intensity of Radiation
bar_pressure_kpa(kpa)	Air Pressure
Under_10, 30, 50cm, 1m(°C)	Subsurface Temperature - 10, 30, 50cm, 1m
soilheat_10, 30, 50cm(W/m ²)	Subsurface Thermal Flux - 10, 30, 50cm

2.3 예측모델 구축

인공신경망의 예측을 증대를 위해 Supervised Learning 기법중의 하나인 Backpropagation algorithm을 이용하여 인공신경망 모델을 구축하였다(Fig. 1).




Fig 1. Backpropagation Concept

인공신경망의 은닉층 개수는 입력 데이터가 n개 일 때, n/2, n, 2n과 2n+1로 결정하였다[8]. 각 구조의 평균제곱근 오차(RMSE)를 비교하여 가장 작은 값의 구조를 선택하였다(Table 3).

Table 3. Comparison of RMSE for ANN structures

Structure of ANN	RMSE
18 - 9 - 1	0.869
18 - 18 - 1	0.727
18 - 36 - 1	0.643
18 - 37 - 1	0.629

인공신경망 구축에 사용된 은닉층의 개수는 37개이며, 입력 변수는 18개이고 출력 변수는 온실 외부 온도이다.

인공신경망의 입력 개수에 따른 성능 평가를 위해 측정된 데이터 모두를 입력변수로 하고 온실 외부 온도를 예측값으로 하여 모델을 구축하였다. 구축 시간은 제안한 모델보다 1.5배 이상 걸렸으며, 예측 성능은 비슷하였다(Table 4). 하지만, 온실에 사용되는 제어시스템(PLC: Programmable Logic Controller)는 일반적인 제어 컴퓨터보다 저사양이므로 이를 고려하였을 때 속도가 빠르고 가벼운 제안한 모델이 적합하다고 판단된다.

Table 4. Comparison of ANN based on Input Features

	Proposed ANN	ANN with all input
Correlation coefficient	0.9959	0.9968
MAE	0.7009	0.6112
RMSE	0.9256	0.8337
Total number of instances	43,932	52,716

MAE: Mean Absolute Error

구축된 인공신경망의 성능비교를 위해 다중회귀모델(M5 method)을 구축하였으며, 동일한 Training data set을 활용하였다[9]. Target 변수는 온실 외부 온도이고 독립변수로는 나

머지 변수를 적용하였다. SVM 모델(epsilon-SVM) 역시 동일한 Training data set을 활용하여 온실 외부 온도 예측 모델을 구축하였다[10].

3. 결과 및 고찰

3.1 예측모델 비교분석

구축된 예측 모델의 성능비교 분석을 위해 10-Fold cross validation 방법을 이용하였다. 교차검증은 Training data를 기반으로 Training/test data의 비율과 선택을 다르게 하여 10번의 검증을 수행하는 방법이다. 비교 결과는 다음과 그림2와 같으며, 인공신경망 모델이 가장 좋은 성능을 나타낸다.

예측값과 실측값을 비교한 결과 ANN과 다중회귀모델은 실측값과 비슷한 패턴을 보였지만, SVM 모델은 온도가 급격히

변하는 구간에서 예측이 어렵다는 것을 알 수 있다(Fig. 3).

3.2 난방부하 예측

온실에서 방출되는 총 열량 중에서 난방용 설비로 공급하여야 하는 열량을 난방부하라 한다. 난방부하를 미리 예측함으로써 온실에 사용되는 에너지 소비를 최소화함으로써 비용을 절약할 수 있다. 난방부하는 다음과 같은 식으로 구할 수 있으며, 예측된 실외 온도를 적용하여 난방부하 예측이 가능하다.

실험을 수행한 온실의 면적은 72m²이고 유리온실이며, 예측된 최저온도는 -5.4℃이다. 온실을 10℃로 유지하려고 했을 때 위의 식을 이용하면, 난방부하는 3326.4kcal/h이며, 총 난방시간이 10000℃/h 일 때 연료소비량은 453.8L로 예측된다. 미리 온실에 소비되는 에너지를 예측함으로써 비용을 절약할 수 있다.




Fig 2. Analysis of 10-fold Cross Validation

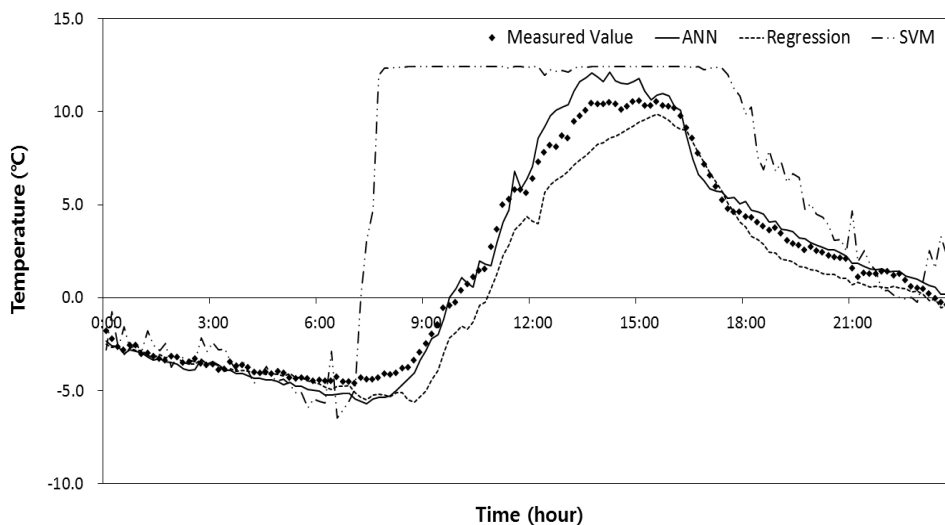


Fig 3. Comparison of Prediction Models with Measured Data

Heating Load Equation (2)

$$\begin{aligned}
 Q &= A_w \cdot U_f (T_i - T_o) \\
 U_f &= U(1-f_r) \\
 Q_m &= \phi f Q \\
 Q_t &= A_w \cdot U_f \cdot dh \\
 V &= Q_r / H \cdot N
 \end{aligned}$$

Q : 난방부하($kcal \cdot h^{-1}$)
 A_w : 온실표면적(m^2)
 U : 난방부하계수($kcal \cdot m^{-2} \cdot h^{-1} \cdot ^\circ C^{-1}$)
 U_f : 난방부하계수(열절감율 고려)
 f_r : 보온피복에 따른 열절감율
 Q_m : 난방기용량($kcal \cdot h^{-1}$)
 ϕ : 안전계수(통상적으로 1.1 사용)
 f : 난방방식에 따른 보정계수
 Q_r : 시간난방부하($kcal \cdot h^{-1}$)
 dh : heating degree hour(총 난방시간)
 V : 연료소비량(L)
 H : 연료평균발열량($kcal \cdot L^{-1}$)
 N : 난방기효율(온풍 0.8, 온수 0.7)

4. 결 론

본 연구에서는 벤로형 온실에서 수집된 데이터를 기반으로 인공신경망을 이용하여 온실 외부의 온도를 예측하고 예측한 결과와 다중회귀모델 및 SVM 모델과 비교분석하여 모델의 타당성을 검증하였다. 또한 예측된 데이터를 온실 난방부하 예측에 활용함으로써 보다 효율적인 온실 제어를 가능케 하였다.

데이터 마이닝 기법을 농업에 적용함으로써 재배, 온실 제어, 에너지 관리 등 다양한 분야에서 이를 활용하는데 기여하였다[11]. 또한 온실 환기제어에 인공신경망 모델을 활용하여 환기 제어를 함으로써 에너지를 보다 효율적으로 관리할 수 있게 하였다.

기존 연구들에서는 센서로 부터 측정된 데이터를 사용하였지만, 측정 오차, 수동/자동 조작의 예러 및 측정 오류에 대해서 고려하지 않았다. 데이터의 신뢰성 확보를 위해 상관관계 분석을 통해 데이터 축소를 수행하였으며, 새로운 factor의 추출을 통해 데이터의 신뢰성을 확보하였다. 인공신경망과 다중회귀모델 및 SVM을 비교한 결과 RMSE 값이 각각 0.9256, 1.8503과 7.5521로 인공신경망의 RMSE 값이 가장 작기 때문에 예측 정확도가 높다고 판단된다. 또한 예측된 온실 외부 온도를 난방부하 계산에 적용하여 미리 예측을 함으로써 온실에 사용되는 에너지 비용을 절약할 수 있다.

향후 연구로 예측 모델과 작물 재배를 위한 피지 이론을 접목하여 정밀한 온실 제어 및 에너지를 보다 효율적으로 관리함으로써 비용 감소와 수익 창출이 가능할 것으로 예상된다.

References

[1] S. W. Nam, H. H. Shin, and D. W. Seo "Comparative Analysis of Weather Data for Heating and Cooling Load Calculation in Greenhouse Environmental Design," *Protected Horticulture and Plant Factory*, Vol.23, No.3, pp.174-180, 2014.

[2] M. Trejo-Perea, G. Herrera-Ruiz, J. Rios-Moreno, R. C. Miranda, and E. Rivas-Araiza, "Greenhouse Energy Consumption Prediction using Neural Networks Models," *International Journal of Agriculture & Biology*, Vol.1, No.1, p.1-6, 2009.

[3] H. Yu, Y. Chen, S. G. Hassan, and D. Li, "Prediction of the temperature in a Chinese solar greenhouse based on LSSVM optimized by improved PSO," *Computers and Electronics in Agriculture*, Vol.122, pp.94-102, 2016.

[4] B. Khoshnevisan, S. Rafiee, and H. Mousazadeh, "Application of multi-layer adaptive neuro-fuzzy inference system for estimation of greenhouse strawberry yield," *Measurement*, Vol.47, pp.903-910, 2014.

[5] S. Y. Kim, S. M. Lee, K. S. Park, K. H. Ryu, "Prediction Model of Internal Temperature using Backpropagation Algorithm for Climate Control in Greenhouse," *Horticultural Science and Technology*, to be submitted, 2018.

[6] I. Guyon, and A. Elisseeff, "An Introduction to Variable and Feature Selection," *Journal of Machine Learning Research*, pp.1157-1182, 2003.

[7] R. Kohavi, "A study of Cross-Valiation and Bootstrap for Accuracy Estimation and Model Selection," *International Joint Conference on Artificial Intelligence*, 1995.

[8] G. Zhang, B. E. Patuwo, and M. Y. Hu, "Forecasting with artificial neural networks: The state of the art," *International Journal of Forecasting*, 1998.

[9] L. ŠTravs, and M. Brilly, "Development of a low-flow forecasting model using the M5 machine learning method," *Hydrological Sciences Journal*, Vol.52, no. 3, pp.466-477, 2007.

[10] R. Pelossof, A. Miller, P. Allen, and T. Jebara, "An SVM learning approach to robotic grasping," *IEEE International Conference*, Vol.4, pp.3512-3518, 2004.

[11] A. Mucherino, P. Papajorgji, and P. M. Pardalos, "A survey of data mining techniques applied to agriculture," *Operational Research*, Vol.9, No.2, pp.121-140, August 01, 2009.



김 상 엽

<https://orcid.org/0000-0002-5174-2464>

e-mail : k1224kims@naver.com

2008년 충북대학교 컴퓨터공학부(공학사)

2010년 충북대학교 전자계산학과(공학석사)

2014년 충북대학교 컴퓨터학과

(공학박사수료)

2010년~2013년 한국에너지기술연구원 신재생에너지자원센터 연구원

2014년~현 재 한국기계연구원 청정연료발전연구실 선임연구원

관심분야: 지식기반 정보검색(Knowledge-Based Information Retrieval), 데이터마이닝(Data Mining), 시설원예 (Controlled Horticulture)



박 경 섭

<https://orcid.org/0000-0001-6039-496X>

e-mail : unicos75@korea.kr

2001년 서울대학교 식물생산과학부
(농학석사)

2016년 서울대학교 식물생산과학부
(농학박사)

2002년~현 재 국립원예특작과학원 농업연구관

관심분야: 시설원예학



류 근 호

<https://orcid.org/0000-0003-0394-9054>

e-mail : khryu@dblab.chungbuk.ac.kr

1976년 숭실대학교 전자계산학과(공학사)

1980년 연세대학교 전자계산학과(공학석사)

1988년 연세대학교 전자계산학과(이학박사)

1976년~1986년 육군 3군수 지원사 전산실

(ROTC 장교), 한국전자통신연구원(연구원), 한국방송
통신대전산학과(조교수)

1989년~1991년 미국 Univ. of Arizona Research Staff

(TempIS 연구원, Temporal DB)

1986년~현 재 충북대학교 전기전자정보컴퓨터학부 교수

관심분야: 시공간 데이터베이스(Spatiotemporal Database),

지식기반 정보검색(knowledge-based Information

Retrieval), 데이터마이닝(Data Mining), 데이터보안

(Data Security), 바이오메디칼 및 바이오인포매틱스

(Biomedical and Bioinformatics)