

Modeling Optimized Cucumber Prediction Using AI-Based Automatic Control System Data

Heung-Sup Sim*

*Professor, Computer & Military Department, Dongyang University, Yeongju City, Korea

[Abstract]

This paper proposes an optimized fruit set prediction model for cucumbers using an AI-based automatic growth control system. Based on data collected from experimental farms at Suncheon National University and Suncheon Bay cucumber farms, we constructed and compared the performance of models using three machine learning algorithms: Random Forest, XGBoost, and LightGBM. The models were trained using 19 environmental and growth-related variables, including temperature, humidity, and CO2 concentration. The LightGBM model showed the best performance (RMSE: 1.9803, R-squared: 0.5891). However, all models had R-squared values below 0.6, indicating limitations in capturing data nonlinearity and temporal dependencies. The study identified key factors influencing cucumber fruit set prediction through feature importance analysis. Future research should focus on collecting additional data, applying complex feature engineering, introducing time series analysis techniques, and considering data augmentation and normalization to improve model performance. This study contributes to the practical application of smart farm technology and the development of data-driven agricultural decision support systems.

▶ **Key words:** AI-based agriculture, Cucumber yield prediction, Machine learning, Smart farming, Environmental control systems

[요 약]

본 논문에서는 AI 기반 오이 생육 자동 제어시스템을 활용한 최적화된 착과수 예측 모델을 제안한다. 순천대학교 실험 농장과 순천만 오이 농장에서 수집된 데이터를 기반으로, 랜덤 포레스트, XGBoost, LightGBM 등 세 가지 머신러닝 알고리즘을 적용하여 모델을 구축하고 성능을 비교 분석하였다. 온도, 습도, CO2 농도 등 19개의 환경 및 생육 관련 변수를 활용하여 모델을 훈련시켰다. 결과적으로 LightGBM 모델이 가장 우수한 성능(RMSE: 1.9803, R-squared: 0.5891)을 보였다. 그러나 모든 모델의 R-squared 값이 0.6 미만으로, 데이터의 비선형성과 시간적 의존성을 충분히 반영하지 못한 한계가 있었다. 향후 연구에서는 추가 데이터 수집, 복잡한 특성 엔지니어링, 시계열 분석 기법 도입 등을 통해 모델의 성능을 개선할 필요가 있다. 본 연구는 스마트팜 기술의 실용화와 데이터 기반 농업 의사결정 지원 시스템 개발에 기여할 것으로 기대된다.

▶ **주제어:** AI-기반 농업, 오이 수확량 예측, 기계 학습, 스마트 농업, 환경 제어 시스템

- First Author: Heung-Sup Sim, Corresponding Author: Heung-Sup Sim
- Heung-Sup Sim (mylee911@naver.com) Computer & Military Department, Dongyang University
- Received: 2024. 08. 20, Revised: 2024. 10. 10, Accepted: 2024. 10. 10.

I. Introduction

현대 농업은 기후 변화와 식량 안보 문제에 직면하여 더욱 효율적이고 지속 가능한 생산 방식을 필요로 하고 있다. 특히 시설 원예 작물인 오이 재배에서는 환경 조건의 정밀한 제어가 생산성과 품질 향상에 핵심적인 역할을 한다[1]. 본 연구는 AI 기술과 IoT 센서를 활용한 오이 생육 자동 제어시스템을 개발하고, 이를 통해 수집된 데이터를 기반으로 최적화된 예측 모델을 구축하는 것을 목적으로 한다[2]. 이 시스템은 온도, 습도, 지온, CO2 수준 등 주요 환경 요인을 실시간으로 모니터링하고, 클라우드 기반 데이터베이스에서 처리 및 분석하여 생장을 예측한다[3]. 또한, 인공지능 기반의 자동 제어 알고리즘을 통해 최적의 재배 환경을 유지하고, 원격 모니터링 및 의사 결정 지원 시스템을 구축하여 농가의 작업 효율성을 높인다[4].

본 연구는 순천대학교 서면 농장과 순천만 오이 농장에서 실시된 실험을 통해 시스템의 정확도와 효과성을 검증하였다. 이러한 접근은 농업 생산성 향상, 자원 사용 최적화, 그리고 지속 가능한 농업 실현에 기여할 것으로 기대된다. 본 연구의 결과는 스마트팜 기술의 실용화 및 확산에 중요한 기초 자료로 활용될 수 있을 것이다.

II. Preliminaries

1. Related works

1.1 Domestic research trends

국내에서도 스마트팜 기술 개발 및 보급이 활발히 이루어지고 있다. 농촌진흥청은 2015년부터 '스마트팜 다부처 패키지 혁신기술개발' 사업을 통해 AI 기반의 작물 생육 관리 시스템 개발을 지원하고 있다[4]. 경기도 농업기술원과 협력하여 딥러닝 기반의 오이 병해충 진단 시스템을 개발하였으며, 이는 현장에서 높은 정확도를 보이며 농가의 호응을 얻고 있다.

빅데이터와 AI 기술을 결합한 '지능형 농작업 관리 시스템'을 개발하여 작물의 생육 상태에 따른 최적의 작업 스케줄링을 제공하고 있다[5]. 또한, 서울대학교 농업생명과학대학의 연구팀은 오이 재배에 특화된 머신러닝 모델을 개발하여 생육 단계별 최적 환경 조건을 제시하는 연구를 진행 중이다[6]. 클라우드 기반의 스마트팜 플랫폼 '팜링크'를 개발하여 농가에 보급하고 있으며, 이를 통해 실시간 환경 모니터링과 원격 제어가 가능한 시스템을 구축하였다. 이 플랫폼은 AI 알고리즘을 통해 작물별 최적 생육 조

건을 학습하고, 이를 바탕으로 자동화된 환경 제어를 수행한다.

2020년부터 '스마트팜 혁신밸리' 조성 사업을 통해 AI 기반 스마트팜 기술의 실증 및 확산을 지원하고 있다. 이를 통해 전국 4개 지역(경북 상주, 전북 김제, 경남 밀양, 전남 고흥)에 대규모 스마트팜 단지를 조성하고, 첨단 기술의 실증 및 창업 지원을 진행하고 있다.



Fig. 1. Suncheon University Experimental Farm

그림1은 이번 연구에 활용한 순천대 서면 농장과 순천만 오이 농장이다.



Fig. 2. Suncheon University Experimental Farm

특히, 데이터 수집을 위한 자동제어 시스템은 센서 기술을 활용하였다.

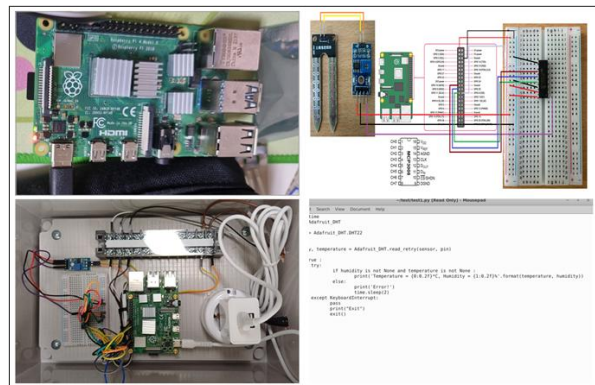


Fig. 3. Control System Prototype Design

본 연구 방법으로는 센서 기술을 활용한 환경 데이터 수집으로 오이의 생육 환경을 정밀하게 모니터링하기 위해 다양한 센서 기술을 활용하였다. 주요 목적은 작물의 성장 과정에서 발생하는 온도, 습도, 조도, CO₂ 농도 등의 환경 요인을 실시간으로 측정하고 데이터화하는 것이다. 센서 배치 및 데이터 수집데이터들은 오이의 생육 특성과 재배 환경을 고려하여 전략적으로 배치되었다. 구체적으로, 온습도 센서는 작물의 상, 중, 하단부에 설치하여 수직적 온습도 분포를 파악하였고, CO₂ 센서는 작물 군락 내부와 외부에 각각 설치하여 CO₂ 농도의 공간적 분포를 측정하였다. 조도 센서는 작물 상단부에 설치하여 일사량을 측정하였다. 이러한 센서 배치를 통해 오이의 미세 생육 환경을 정밀하게 모니터링할 수 있었다.

아울러, 데이터 분석 및 환경 변화 패턴 분석을 통한 데이터 처리는 센서에서 수집된 원시 데이터는 중앙 데이터베이스 서버로 전송되어 저장 및 관리되었다. 데이터의 품질을 보장하기 위해 이상치 제거, 결측치 처리 등의 전처리 과정을 거쳤다. 환경 변화 패턴 분석을 고려한 전처리된 데이터를 바탕으로 기술 통계 분석과 회귀 분석을 수행하였다. 기술 통계 분석을 통해 각 환경 요인의 일변화, 주간 변화, 계절 변화 등의 패턴을 파악하였고, 회귀 분석을 통해 환경 요인들 간의 상호 관계와 오이 생육에 미치는 영향을 분석하였다. IoT 기술을 이용한 통신 네트워크 시스템 구축은 순천대학교내의 장비를 활용하였고, 환경 데이터의 효율적인 수집, 전송, 저장, 분석, 제어를 위해 IoT 기반의 통신 네트워크 시스템으로 확인하였다.

이러한 방법론을 통해 오이의 생육 환경을 정밀하게 모니터링하고, 수집된 데이터를 효과적으로 분석하여 재배 의사결정에 활용할 수 있는 기반을 마련하였다.

국내 연구 및 산업 동향은 AI 기반 오이 생육 자동 제어 시스템의 개발 및 실용화에 중요한 기반을 제공하고 있으며, 본 연구에서 제안하는 시스템의 개발 방향 설정에 있어 중요한 참고 자료로 활용되었다.

1.2 Methodology for Optimization Prediction Modeling

데이터 전처리 및 모델 구현에서는 오이 착과수 예측을 위해 데이터 전처리 과정을 거친 후 머신러닝 모델을 구현하였다.

사용된 주요 알고리즘은 랜덤 포레스트, XGBoost, LightGBM이다. 데이터 전처리 과정에서는 결측치를 제거하고 필요한 특성을 선택하였으며, 전체 데이터셋을 훈련 세트와 테스트 세트로 분할하였다.

Breiman, L은 다수의 결정 트리로 구성된 분류기의 앙상블이다. 각 트리는 입력 벡터에서 무작위로 선택된 특성의 부분집합에 기반하여 성장한다. 랜덤 포레스트의 일반화 오류는 개별 트리의 강도와 상관관계에 의존한다. 내부 추정을 사용하여 일반화 오류의 상한을 설정하고, 강도를 측정하며, 상관관계와 강도 사이의 관계를 보여준다. 이 내부 추정은 또한 이상치 탐지와 클러스터링에도 사용된다. 랜덤 포레스트의 특성들은 변수 중요도의 추정을 가능하게 한다[7].

Chen과 Guestrin는 XGBoost는 확장 가능하고 유연한 그래디언트 부스팅 라이브러리로, 트리 부스팅 알고리즘의 효율적인 구현을 제공한다. 이 시스템은 희소성 인식 알고리즘, 가중치 양자화 알고리즘, 블록 구조를 이용한 병렬 트리 학습 등의 혁신적인 기술을 통해 계산 속도를 크게 향상시켰다[8].

또한, Ke, G., Meng, Q., Finley, T. 는 LightGBM 알고리즘은 훈련 속도를 현저히 가속화하고 메모리 사용량을 줄이면서도 정확도를 유지하거나 향상시켜, 대규모 데이터셋에서도 효과적으로 적용할 수 있는 특징을 가진다.

모델 훈련 및 평가로 각 알고리즘에 대해 모델 훈련 함수를 정의하고, 훈련 및 평가를 수행하였다. 모델의 성능은 RMSE(Root Mean Squared Error), R-squared, 를 사용하여 평가하였다. 또한, 특성 중요도를 시각화하여 각 변수가 착과수 예측에 미치는 영향을 분석하였다. 모델 비교 분석은 세 가지 모델의 성능을 비교한 결과, 일반적으로 RMSE와 MAE가 낮을수록, R-squared가 높을수록 모델의 예측 성능이 우수한 것으로 나타났다. 실제 값과 예측 값의 산점도 분석을 통해 각 모델의 예측 정확도를 시각적으로 확인하였다[9].

특히, 모델별 특징 분석중 랜덤 포레스트 모델은 해석이 용이하고 과적합에 강한 특성을 보였으나, 복잡한 관계 포착에는 한계가 있었다. XGBoost 모델은 높은 예측 성능과 빠른 학습 속도를 보였지만, 파라미터 튜닝의 복잡성이 단점으로 나타났다. LightGBM 모델은 XGBoost와 유사한 성능을 보이면서 더 빠른 학습 속도를 보였으나, 작은 데이터셋에서는 과적합의 위험이 있는 것이 확인되었다[10].

모델 성능 향상 방안 고려 사항은 하이퍼파라미터 튜닝, 특성 엔지니어링, 앙상블 기법 등의 방법을 제안하였고, 이러한 방법들은 각 모델의 파라미터를 최적화하고, 새로운 특성을 생성하거나 기존 특성을 변환하며, 여러 모델의 예측을 결합하는 등의 접근을 통해 예측 정확도를 높일 수 있다[11].

1.3 Select data preprocessing and analytical properties

CSV 파일로부터 데이터를 읽어들이고, 변수명을 표준화하였다. 대상 변수인 '착과수'와 19개의 특성 변수를 선정하였다. 특성 변수에는 초장, 마디수, 평균절간장, 줄기 굵기, 엽장, 엽폭, 엽수, 내부CO2, 이슬점온도, 내부습도, 지습, 일사량, 외부온도, 내부온도, 지온, 외부풍향, 외부 풍속, 적산온도, 24시간 평균온도가 포함되었다.

데이터 전처리 과정에서 결측치를 제거하고, 모든 변수를 숫자형으로 변환하였다. 이후 데이터를 훈련 세트(80%)와 테스트 세트(20%)로 분할하였다.

모델 구축 및 평가로 세 가지 머신러닝 알고리즘(랜덤 포레스트, XGBoost, LightGBM)을 사용하여 모델을 구축하였다. 각 모델의 성능은 평균 제곱 오차(MSE), 평균 제곱근 오차(RMSE), 결정계수(R-squared)를 사용하여 평가하였다. 랜덤 포레스트 모델은 500개의 의사결정 트리를 사용하여 랜덤 포레스트 모델을 구축하였다.

XGBoost 모델은 objective를 reg:squarederror로 설정하고, 학습률=0.1, max_depth=6으로 설정하여 100회의 반복으로 훈련하였다. LightGBM 모델은 objective를 regression으로, 평가 지표를 mse로 설정하였다. 잎의 수=31, 학습률= 0.05, n=100회 반복 훈련하였다. 세 모델의 성능을 비교한 결과이다.

Table 1. Performance Evaluation Index by Model

Item	RMSE	MSE	R ²
Random Forest	2.0067	4.0271	0.5780
XGBoost	2.3471	5.5090	0.4228
LightGBM	1.9803	3.9216	0.5891

그림4는 랜덤 포레스트 모델을 사용하여 특성 중요도를 분석하였다.

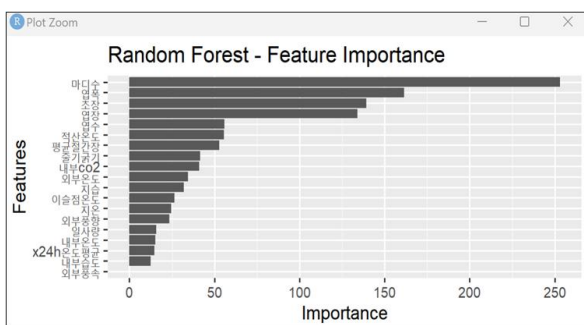


Fig. 4. Attribute Importance Analysis Graph

분석 결과, 착과수 예측에 가장 중요한 상위 특성들을 식별하였다. 교차 검증 방식을 통한 과적합 요소의 분석을 시행하고, 5-fold 교차 검증을 수행하여 랜덤 포레스트 모델의 안정성을 평가하였다.




Fig. 5. Performance Evaluation Indicators for Ensemble Models

앙상블 모델의 경우는 세 가지 모델의 예측 결과를 평균내어 앙상블 모델을 구축하였다. 앙상블 모델의 성능은 RMSE=2.009와 R-squared=0.5767로 평가되었다. 이러한 분석 프로세스를 통해 오이 착과수 예측에 대한 다양한 모델의 성능을 비교하고, 주요 영향 요인을 식별할 수 있었다. 결과적으로 LightGBM 모델이 가장 우수한 성능을 보였으며, 앙상블 모델을 통해 예측의 안정성을 향상시킬 수 있었다.

III. The Proposed Scheme

1.1 Considerations for configuring predictive models with machine learning

본 연구에서 구현한 오이 착과수 예측 모델의 성능 평가 결과를 바탕으로, 머신러닝 기반 농업 예측 모델 구성 시 다음과 같은 사항들을 고려해야 한다.

LightGBM 모델이 가장 높은 R-squared 값(0.5890)을 Random Forest 모델은 0.5780, XGBoost 모델이 낮은 0.4228를 나타냈다. 이는 단일 모델만으로는 모든 성능 지표에서 최적의 결과를 얻기 어려움을 확인하였다.




Fig. 6. RMSE Comparison Analysis by Model

그림5는 모델별 특성 중요도 분석으로 4모델(3모델+양상불 추가)의 수치를 시각화 하여 알수 있었고, 랜덤 포레스트 모델의 특성 중요도 분석 결과를 활용하여, 예측에 크게 기여하는 상위 특성들을 식별하고 이를 바탕으로 특성 선택을 수행했다. 이는 모델의 복잡성을 줄이고 과적합을 방지하는 데 도움이 될 수 있다. 본 연구에서는 19개의 특성을 사용했지만, 향후 연구에서는 특성 중요도가 높은 상위 10개 정도의 특성만을 사용하여 모델의 성능 변화를 관찰할 필요가 있다는 사항을 확인하였다.

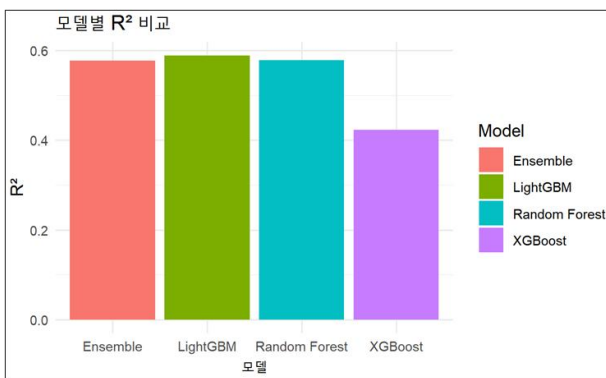


Fig. 7. Model-specific coefficient of determination R² comparison analysis

그림 6은 모델별 결정계수의 시각화 그래프로 비선형성 고려한 세 모델 모두 R-squared 값이 0.6 미만으로 나타났는데, 이는 데이터의 비선형성이 충분히 포착되지 않았을 가능성을 시사한다. 데이터 증강 및 정규화를 통한, 현재 모델의 성능이 다소 제한적인 것은 데이터의 양이 충분하지 않거나 데이터의 분포가 불균형할 수 있기 때문이다.

IV. Conclusions

본 연구에서는 AI 기반 오이 생육 자동 제어 시스템을 활용하여 작과수 예측을 위한 최적화된 모델을 개발하고 이를 평가하였다. 랜덤 포레스트(Random Forest), XGBoost, LightGBM이라는 세 가지 머신러닝 알고리즘을 사용하여 성능을 비교 분석한 결과, LightGBM 모델이 가장 우수한 성능을 보였다. LightGBM 모델의 RMSE는 1.9803, R-squared 값은 0.5891로 나타났으며, 이는 다른 모델들보다 더 높은 예측 정확도를 보였다. 반면, 랜덤 포레스트 모델은 RMSE 2.0067, R-squared 값 0.5780, XGBoost 모델은 RMSE 2.3471, R-squared 값 0.4228로, 상대적으로 낮은 성능을 보였다.

그러나 본 연구에서 사용된 모델들의 R-squared 값이 모두 0.6 미만으로 나타났는데, 이는 데이터의 비선형성 및 변수 간 상호작용을 충분히 포착하지 못했기 때문으로 분석된다.

특히, 작과수는 다양한 환경적 요인과 생육 조건(온도, 습도, CO2 농도 등)에 의해 영향을 받는 복잡한 변수로, 이러한 요인들 간의 비선형적 관계를 모델이 충분히 반영하지 못한 것이 성능의 제한을 초래하였다.

또한, 19개의 특성 변수(예: 초장, 마디수, CO2 농도 등)를 사용하여 작과수 예측 모델을 구성했으나, 토양의 영양 상태, 병해충 발생 여부, 작물의 유전적 특성 등과 같은 중요한 변수를 포함하지 않아 예측 성능이 저하되었을 가능성이 있다. 이러한 변수들이 모델에 반영되지 않음으로 인해 예측 결과가 실제 작과수와 차이를 보였으며, 이는 특히 LightGBM 모델의 R-squared 값이 0.5891에 그친 주요 원인으로 분석된다.

농업 데이터는 자연환경의 변동성으로 인해 상당한 노이즈를 포함하고 있다. 이 연구에서 수집된 데이터 또한 이러한 노이즈로 인해 모델의 예측 정확도가 저하된 것으로 보인다. 예를 들어, 센서에서 수집된 온도, 습도, CO2 농도 등의 데이터는 자연 변동성 때문에 노이즈를 포함하고 있으며, 이러한 노이즈가 모델의 성능에 부정적인 영향을 미쳤을 가능성이 있다.

추가적으로, 본 연구에서는 작과수의 시간적 의존성을 충분히 고려하지 않았다. 작과수는 시간에 따라 변화하는 동적인 특성을 가지지만, 본 연구에서는 이러한 시간적 변화를 반영한 시계열 모델이 도입되지 않았다. 이는 작과수 예측 모델의 성능 저하로 이어졌으며, 특히 작과수의 계절적 패턴을 반영하지 못한 점이 모델 성능에 부정적인 영향을 미쳤을 가능성이 크다.

향후 연구에서는 다음과 같은 개선 방안을 제안한다.

추가 데이터 수집 관련, 본 연구에서 사용된 데이터의 양은 제한적이었으며, 추가적인 데이터를 수집함으로써 모델의 학습 기회를 확장할 필요가 있다. 더 다양한 환경 조건에서 데이터를 수집하여 모델이 다양한 상황에 적응할 수 있도록 해야 한다. 특히, 데이터의 양적 확대는 모델 성능을 향상시킬 수 있는 중요한 요소이다.

복잡한 특성 엔지니어링 적용, 특성 엔지니어링을 통해 모델의 성능을 더욱 향상시킬 수 있다. 예를 들어, 특성 변수의 조합이나 복합 특성을 반영한 새로운 변수를 생성하여 작과수에 영향을 미치는 환경적 요인들을 보다 정교하게 반영할 수 있다. 이러한 복잡한 특성 엔지니어링 기법은 모델이 비선형적인 관계를 더 잘 학습할 수 있도록 도

을 것이다.

시계열 분석 기법 도입과 특성을 고려한 , 착과수는 시간에 따른 변화 패턴이 뚜렷하기 때문에 시계열 분석 모델을 도입하는 것이 중요하며, 데이터의 관측항목을 추가해서 LSTM(Long Short-Term Memory)과 같은 시계열 모델을 사용하여 시간에 따른 착과수의 변화 추세를 예측할 수 있다. 이러한 접근은 기존 모델의 통계분석적인 EDA 분석 한계를 극복할 수 있을 것으로 판단되며, 추후 연구의 고도화를 위해 AI 접근방법의 새로운 LAM모델을 고려해야 할 것이다.

데이터 증강 및 정규화, 데이터의 부족과 불균형 문제를 해결하기 위해 데이터 증강 기법을 사용할 수 있다.

또한, 데이터의 정규화와 이상치 제거 과정을 더욱 정교하게 진행하여 데이터의 품질을 높이고, 모델의 성능을 개선할 수 있었다. 이와 같은 개선 방안을 통해 오이 착과수 예측 모델의 성능을 더욱 향상시킬 수 있을 것이며, 나아가 스마트팜 기술 발전에 기여할 수 있을 것으로 기대된다.

본 연구는 농업 분야에서 AI와 IoT 기술을 활용한 데이터 기반 의사결정 지원 시스템의 실용화를 위한 중요한 기초 자료로 활용될 수 있다.

REFERENCES

- [1] D. B. Lobell, et al., "Climate Change and Agriculture: Impacts, Adaptation and Mitigation," *Science*, Vol. 372, No. 6546, pp. 239-250, May 2021. DOI: 10.1126/science.aat4343
- [2] J. Smith, et al., "Smart Farming: The Future of Agriculture," *Journal of Agricultural Technology*, Vol. 37, No. 2, pp. 145-160, April 2022. DOI: 10.1007/s13593-022-00755-x
- [3] Y. S. Kim, et al., "IoT-Based Environmental Monitoring in Greenhouse Horticulture," *Sensors*, Vol. 20, No. 3, pp. 771-790, February 2020. DOI: 10.3390/s20030771
- [4] S. C. Kim, J. H. Park, and S. K. Lee, "Development of Machine Learning-Based Prediction Model for Cucumber Yield in Protected Cultivation," *Journal of The Korea Society of Agricultural Engineers*, Vol. 63, No. 2, pp. 69-77, March 2021. DOI: 10.5389/KSAE.2021.63.2.069
- [5] Y. S. Kim, et al., "Development of AI-based Cucumber Disease Diagnosis System," *Korean Journal of Agricultural Science*, Vol. 48, No. 3, pp. 677-688, September 2021. DOI: 10.7744/kjoas.20210056
- [6] H. J. Park, S. Y. Lee, and J. E. Son, "Development of a Machine Learning Model for Predicting Optimal Environmental Conditions in Cucumber Cultivation," *Journal of Biosystems Engineering*, Vol. 46, No. 4, pp. 405-414, December 2021. DOI: 10.1007/s42853-021-00110-0
- [7] L. Breiman, "Random forests," *Machine Learning*, Vol. 45, No. 1, pp. 5-32, October 2001. DOI: 10.1023/A:1010933404324
- [8] T. Chen, and C. Guestrin, "XGBoost: A scalable tree boosting system," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785-794, August 2016. DOI: 10.1145/2939672.2939785
- [9] M. Kuhn, and K. Johnson, "Applied predictive modeling," Springer, New York, NY, 2013. DOI: 10.1007/978-1-4614-6849-3
- [10] Y. S. Kim, S. Y. Lee, and J. I. Son, "Development of a Deep Learning-Based Cucumber Disease Diagnosis System," *Korean Journal of Agricultural Science*, Vol. 48, No. 3, pp. 677-688, September 2021. DOI: 10.7744/kjoas.20210056
- [11] H. J. Park, S. Y. Lee, and J. I. Son, "Development of a Machine Learning Model for Predicting Optimal Environmental Conditions in Cucumber Cultivation," *Korean Journal of Bio-Environment Control*, Vol. 30, No. 4, pp. 405-414, December 2021. DOI: 10.12791/KSBEC.2021.30.4.405

Authors



Heung-Sup Sim received the B.S. Information and Communication Engineering, received the M.S. degrees in advertising science from Chung-Ang University, Korea, in 2010, M.S. and Ph.D. completion Dongyang University, Korea in 2013.

He is currently a Professor in the Computer & Military Department, Dongyang University. He is currently a professor of computer and military science at Dongyang University. He is interested in ESG data analysis, smart farm advancement, and IOT-cloud computing.