

# 스마트팜 데이터를 활용한 오이 출하량 예측 시계열 모델 연구

(A Study on Time Series Models for Predicting Cucumber Shipment Using Smart Farm Data)

이혜경\*, 신창선\*\*

(Hye Kyung Lee, Changsun Shin)

## 요약

본 연구는 스마트팜 현장에서 수집한 농촌진흥청 데이터를 활용해 오이 출하량에 영향을 미치는 주요 변수를 확인하고, 다양한 예측 모델을 비교 분석하여 최적의 예측 모델을 제안한다. 연구 데이터는 36개의 작기별로 수집된 기상 조건, 재배 환경, 관리 활동 등의 변수를 포함하며, 예측 모델로는 다중회귀분석, ARIMA, LSTM, SARIMA를 사용했다. 성능은 RMSE와 MAE로 평가되었으며, SARIMA 모델이 가장 우수한 성능을 보였다. 하이퍼파라미터 조정을 통해 SARIMA 모델의 예측 정확도가 향상되었으며, 이는 오이 출하량이 계절성에 크게 의존하는 특성을 효과적으로 반영한 결과이다.

■ 중심어 : 오이 출하량 예측 ; SARIMA 모델 ; 시계열 예측 ; 계절성

## Abstract

This study utilizes data collected by the Rural Development Administration from smart farm sites to identify key variables affecting cucumber shipment and proposes the most accurate prediction model through comparative analysis of various forecasting models. The dataset includes daily weather conditions, cultivation environments, and management activities from 36 different crop seasons. The predictive models used in this study include Multiple Regression, ARIMA(Auto Regressive Integrated Moving Average), LSTM(Long Short-Term Memory), and SARIMA(Seasonal Auto Regressive Integrated Moving Average). Model performance was evaluated using RMSE and MAE, with SARIMA demonstrating the best results. By optimizing the hyperparameters, SARIMA's prediction accuracy improved significantly, effectively capturing the strong seasonality in cucumber shipments.

■ keywords : Cucumber Shipment Prediction ; SARIMA Model ; Time series forecasting ; seasonality

## I. 서론

최근 농업 분야에서는 정보통신기술(ICT)을 접목한 스마트팜 기술이 농작물의 생산성을 향상시키는 데 중요한 역할을 하고 있다. 스마트팜은 농작물의 생육 환경을 실시간으로 모니터링하고 제어하는 시스템을 통해, 농업의 효율성을 높이고 품질 좋은 농산물을 안정적으로 생산할 수 있게 한다[1]. 이러한 기술의 발전은 농가의 수익 증대에도 기여하고 있으며, 특히 데이터 기

반의 농업 의사결정이 그 중심에 있다.

기존 스마트팜 연구들은 주로 농작물의 생육 환경을 최적화하여 수익을 극대화하는 데 집중되어 왔다. 하지만 농작물의 생산량을 보다 정확하게 예측하기 위해서는 다양한 환경 변수와 생육 데이터 간의 관계를 분석할 필요가 있다[2]. 이를 통해 생산량 예측의 정확도를 높이고, 농가의 운영 효율성을 극대화할 수 있다. 특히, 스마트팜에서 수집된 데이터는 다양하고 복잡하기

\* 학생회원, 순천대학교 스마트농업전공 석사과정

\*\* 종신회원, 순천대학교 인공지능공학부 교수

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역지능화혁신인재양성사업임 (IITP-2024-2020-0-01489)

접수일자 : 2024년 08월 28일

게재확정일 : 2024년 09월 13일

교신저자 : 신창선 e-mail : csshig@scnu.ac.kr

때문에 이를 활용한 예측 모델 개발은 더욱 중요하다.

스마트팜에서 수집된 데이터는 크게 환경 데이터와 생육 데이터로 나뉘며, 이들 데이터는 서로 다른 시간 단위로 측정된다. 환경 데이터는 시간 단위로 자동 측정되지만, 생육 데이터는 주마다 수기로 측정되어 시간 단위가 일치하지 않는 문제가 발생한다. 이러한 데이터의 특성을 고려하여, 본 연구에서는 일 단위로 환경 데이터의 평균값을 산출하여 분석에 활용하였다[3]. 이러한 환경 데이터를 기반으로 오이 출하량을 예측하는 다양한 모델을 개발하고 평가하는 것이 본 연구의 주요 목표이다.

출하량 예측 모델로는 다중회귀분석(Multiple Linear Regression)과 시계열 분석에 적합한 ARIMA(Auto Regressive Integrated Moving average), 장기 의존성을 잘 학습하는 LSTM(Long Short-Term Memory), 그리고 계절성을 반영할 수 있는 SARIMA(Seasonal Auto Regressive Integrated Moving Average)를 활용하였다. 특히 오이 출하량은 계절적 요인에 크게 영향을 받기 때문에, 계절성을 반영한 SARIMA 모델이 가장 적합한 예측 모델로 기대된다[4]. 또한, 모델의 성능은 RMSE와 MAE 지표를 통해 평가되며, 최적의 하이퍼파라미터 조정을 통해 성능을 개선하는 방안을 제시한다.

오이와 같은 농작물은 온도와 습도 변화에 민감하여 생육 및 생산량이 환경 요인에 큰 영향을 받는다. 따라서 시설 유형, 지역, 재배 시기, 영농 기술에 따라 생육 패턴과 생산량에 차이가 발생할 수 있다[5]. 또한, 우리나라는 사계절이 뚜렷하여 자연 기후의 변동성이 크기 때문에, 생산량을 예측하고 최적화하기 위한 체계적인 환경 관리가 필요하다[6].

본 연구에서는 스마트팜에서 수집한 시계열 데이터를 바탕으로 다양한 독립 변수를 고려하여 오이 출하량을 예측하는 모델을 개발하고, 그 성능을 평가한다. 이를 통해, 스마트팜 환경에서의

농작물 생산량 예측 모델의 개선 가능성을 탐구하고, 보다 정확한 예측을 위한 최적의 변수 및 모델을 제안하는 것을 목표로 한다.

## II. 오이 생산량 예측 모델

### 1. 데이터 수집 및 변수 결정

본 연구에서는 농촌진흥청의 현장 농가 데이터를 이용하여 오이 출하량을 예측하였다. 데이터는 오이 농가로부터 2021년 17개, 2020년 11개, 2019년 8개의 수집된 자료를 이용하였다. 각 농가의 일별에 따른 오이 출하량, 기상 조건(온도, 습도 등), 재배환경(토양 습도, CO2 농도 등) 등은 각 농가의 센서를 통해 자동수집 되었으며 수집된 데이터를 바탕으로 모델링을 수행하였다. 그중에서 2019년도 2개, 2020년도 3개의 데이터를 이용하여 데이터를 분석하였다.

환경 데이터는 매시간마다 측정되었고 생산 정보는 출하량과 판매 금액으로 제시되어 있어 재배 정보의 식부면적을 1000m<sup>2</sup>로 일원화하여 출하량을 계산하였다. 데이터에 대한 구체적인 내용은 표1과 같다.

표1 스마트팜 데이터

Table 1, Data of Smart Farm

	Data Name	Provided information	Unit
Information Service Data	Environmental Information	Internal/External Information	time
	Growth information	Growth Information by Item	day
	Cultivation information	Planting area	m <sup>2</sup>
	Production information	Sales rate	개
Provide Service Data	Identity information	Item and Location Information	-
	Cultivation Period Details	Matching Farmhouse ID	day
	Environmental Information	Facility gardening Environmental Information	time
Inside environment	mean temp_in	inside mean temperature	℃
	GDD temp_in	Effective cumulative inside temperature	℃
	hum_in	Average inside humidity	%
Outside environment	temp_out	outside temperature	℃

수집된 데이터는 여러 농가로부터 수집된 만큼, 데이터의 신뢰성을 확보하기 위해 전처리 과정을 거쳤다. 결측치는 선형보간법으로 대체하여 이상치는 제거하거나 보정하고 분석에 사용하였다.

유효적산온도(GDD)는 오이의 성장과 발달에 중요한 영향을 미치는 환경 요인 중에 하나로 생육에 필요한 최소 온도를 적산한 값이다. 생산 지역의 환경에 따른 재배작물 생육 진행 상황을 평가하고 작물의 수확시기 등을 예측할 수 있도록 한다. 오이의 기저온도(Tbase, base temperature)는 최저 생육온도인 15.5℃로 설정되었다. 여기서 기저온도는 오이의 생육을 정지하는 기본온도를 설정한 것이다[4].

$$GDD = \sum \left( \frac{Maxtemp - Mtemp}{2} - Tbase, 0 \right)_{max, Tbase = 15.5} \quad (1)$$

## 2. 최적 모델 구축

본 연구에서는 전처리 된 데이터셋을 이용하여 환경정보와 오이의 출하량과의 관계를 파악하고 단수 생산성 예측 모형을 개발하기 위해 선형 분석 방법인 다중회귀분석과 시계열 예측이 용이한 ARIMA, 시계열 데이터의 장기 의존성을 잘 학습하는 LSTM, 계절성 시계열 데이터에 적합한 SARIMA를 활용하고 예측을 진행하였다 [3].

### 2.1 출하량과 환경요인 간의 상관관계 분석

상관계수는 -1에서 1 사이의 값에서 두 변수 간의 양의 상관관계 1에 가까울수록 강하며 음의 상관관계는 -1에 가까울수록 강해진다.




그림 1 출하량과 데이터 간의 그래프  
Fig 1. Graph between shipments and data

출하량과 환경 데이터 간의 상관관계는 그림1로 나타냈다. 출하량과의 상관계수에서 외부온도는 0.29, 내부온도는 0.34, 상대습도는 0.2, 유효적산온도는 0.43의 상관관계가 있음을 보여준다. 출하량과 상관관계를 보이는 변수는 유효적산온도로 양의 상관관계를 보인다. 사용한 데이터에서는 상대습도는 출하량과의 상관관계가 낮아 출하량 예측에 중요한 변수로 작용하지 않은 것으로 보인다.

### 2.2 다중선형회귀 모델을 활용한 출하량 예측 및 성능 분석

오이의 생산량 예측을 위해 다중선형회귀 모델을 사용하여 독립변수인 환경요인의 변화에 따라 종속변수인 출하량의 변화를 예측했다. 선형회귀(Linear regression)는 하나 이상의 독립변수 x와 종속변수 y사이의 선형관계를 나타내는 회귀분석 기법이다[7].

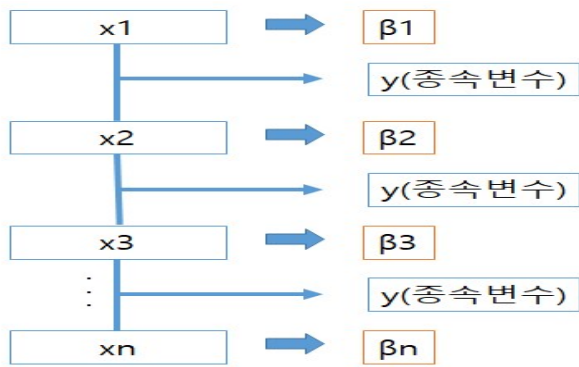


그림 2. 다중회귀 모델

Fig 2. Multiple regression model

각  $x_1, x_2, x_3, \dots, x_n$ 은 독립변수  $x$ 에 영향을 미친다. 각  $\beta_1, \beta_2, \beta_3, \dots, \beta_n$ 과 결합하여 종속 변수  $y$ 에 기여한다.

이 모델은 회귀분석을 통해 예측된 값을 나타내며 종속변수 값을 추정하는 것으로 모델의 정확성을 평가하고, 예측값과 실제값이 얼마나 일치하는지 분석하는 선형회귀 모델이다[7]. 계절성을 가진 데이터를 바탕으로 다중회귀 모델을 사용하여 생산량을 예측할 때 단순성과 해석 가능성으로 독립변수가 종속변수에 미치는 영향을 명확하게 보여준다. 이는 특정 계절적 요소가 생산량에 미치는 영향을 설명해준다.

그림3은 다중회귀를 이용한 출하량에 대한 예측값 및 실제값 그래프이다.




그림 3 출하량에 대한 예측값과 실제값(다중회귀)

Fig 3. Predicted and actual values for shipments (multiple regression)

특정 구간에서 예측된 출하량이 실제 출하량보

다 일관되게 낮거나 높은 경향을 보인다. 실제 출하량이 급격히 증가하거나 감소하는 구간에서 예측된 출하량이 이러한 변동을 제대로 따라가지 못하고 비교적 평탄한 경향을 보인다. 전반적으로 예측된 출하량이 실제 출하량의 큰 흐름을 따라가긴 하지만, 일부 구간에서 예측 성능이 떨어지는 것을 고려할 때, 추가적인 변수의 고려나 모델 개선이 필요하다. 이를 위해 비선형 패턴을 더 잘 반영할 수 있도록 비선형 회귀 모델이나 딥러닝 기반의 예측 모델(예: LSTM)을 적용하는 것도 고려할 수 있다. 또한, 예측 성능을 향상시키기 위해서는 데이터의 이상치를 제거하거나 정규화하는 등 전처리 작업을 개선하고, 교차검증을 통해 모델의 과적합을 방지하는 방법도 유용할 수 있다.

### 2.3. ARIMA 모델을 통한 출하량 예측 및 한계 분석

데이터의 패턴 예측은 기존에 통계 수학 모델이 주로 사용되었으나 장기간의 데이터를 예측하기 어렵고 정확도 측면에서 한계가 있다. 머신러닝은 복잡한 데이터를 학습하여 미래의 값을 예측하거나 분류하는데 있어 뛰어난 성능을 보인다[8].

ARIMA 모델은 비계절성 시계열 데이터를 예측하는데 적합하여 출하량 데이터가 계절적 패턴이 없거나 계절성을 제거한 후의 데이터를 예측할 때 사용한다. 성능을 측정할 때 RMSE(Root Mean Square Error)나 MAE(Mean Absolute Error)등이 많이 사용된다 [9,10].

ARIMA 모델은 시계열 데이터의 트렌드와 자기 상관을 분석하고 예측하는데 매우 유용하다. 시간이 지남에 따라 발생하는 패턴을 효과적으로 모델링 할수 있다. 데이터가 계절적이거나 트렌드를 갖고 있을 때 차분을 통해 효과적으로 처리할 수 있다.




그림 4. 생산량에 대한 예측값 및 실제값(ARIMA)  
Fig 4. Forecasts and actuals for production (ARIMA)

그림4는 다중회귀를 이용한 출하량에 대한 예측값 및 실제값 그래프이다. 예측된 출하량과 실제 출하량 간에 일부 구간에서 유사한 패턴을 보이지만 대부분의 구간에서는 예측이 부정확하게 이루어져 있다. 실제 출하량이 급격하게 변동하는 구간에서 모델이 이를 제대로 포착하지 못하고 있으며 이로 인해 예측의 정확도가 떨어지는 것으로 보인다. 시계열 모델인 ARIMA가 주로 선형적 패턴을 잘 반영하는 데 반해 비선형적이거나 복잡한 패턴을 다루는데는 한계가 있는 것으로 보인다.

#### 2.4. LSTM 모델을 활용한 출하량 예측 및 학습 성능 분석

LSTM은 Hochreiter & Schmidhuber(1997)이 제안하고 다양한 문제에 적용하여 많은 분야에서 사용되고 있다. 시계열 데이터를 효과적으로 모델링 할 수 있는 LSTM은 RNN에서 발생하는 그라디언트 소실 문제를 해결할 수 있는 독특한 신경망 구조를 가지고 있다[11]. LSTM의 핵심 요소인 셀 스테이트는 LSTM에서 정보를 유지하고 전달하는 역할을 함으로써 정보의 손실을 최소화한다. 그림5는 RNN을 기반으로 Input gate, Output gate, Forget gate를 추가하여 구성된 LSTM 구조를 나타낸다[12].




그림5. LSTM 구조  
Fig 5. LSTM architecture

LSTM은 비선형성과 복잡한 패턴을 학습할 수 있다. 출하량 데이터는 계절성 및 트렌드와 예측하기 어려운 변동성 등을 포함할 수 있어 LSTM은 이러한 복잡한 특성을 처리하는데 효과적인 모델이다. 복잡한 비선형 관계를 학습하여 출하량 예측에서 필요한 다양한 변동 요인을 더 잘 반영할 수 있다.




그림 6. 출하량 데이터 시각화  
Fig 6. Shipment data visualization

그림6은 초기 데이터 608개 중 출하량이 0인 데이터를 제거하여 남은 439개의 데이터를 시각화했다. 출하량이 0인 데이터를 제거한 이유는 분석의 정확성을 높이고 신뢰성 높은 예측과 분석을 위해 실제 출하가 이루어진 데이터만을 대상으로 수행하였다. 출하량 데이터는 매우 변동성이 크고 특정 시기에 집중되어 있다. 이러한 요인을 이해하고 분석하기 위해 계절성, 기후 등과 같은 다양한 외부 요인과의 관계에 대한 추가 연구가 필요해 보인다. 출하량이 없는 구간과 급격한 변동성을 고려하여 모델을 수행할 때 여러

요인들을 반영한 비선형 모델이나 외부 변수를 포함한 모델을 적용하여 분석한다면 출하량 데이터의 특성을 잘 반영할 수 있을 것이다.




그림 7. 출하량에 대한 예측값 및 실제값(LSTM)  
Fig 7. Predicted and actual values for shipments (LSTM)

그림7은 LSTM 모델을 이용한 출하량 예측값 및 실제값 그래프이다. 실제 출하량 데이터는 시간에 따라 매우 불규칙한 변동을 나타낸다. 특히 특정 시기에 급격한 증가와 감소를 나타내고 있다. LSTM 모델을 통해 예측된 출하량은 실제 출하량과 비슷한 패턴을 보이지만 예측값이 일정 시점에서 실제 값보다 과도하게 높거나 낮은 경우가 보여진다.

모델 학습에서 학습과 검증 데이터셋에 대해 각각의 손실과 평균 절대 오차가 에포크(epoch)에 따라 어떻게 변하는지를 보여주기 위해 그림8에서는 모델 학습 과정에서 손실과 평균 절대오차를 시각화한 그래프로 나타냈다.

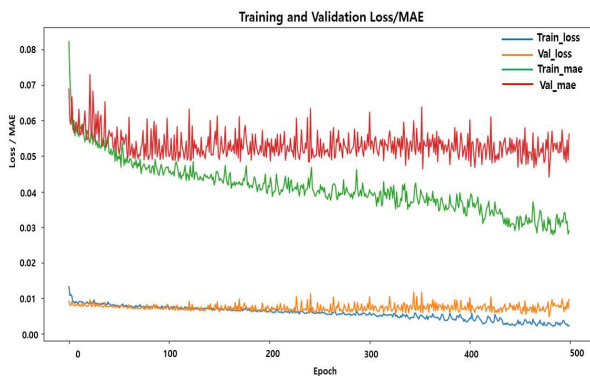


그림 8. 학습 데이터셋과 검증 데이터셋의 Loss와 MAE  
Fig 8. Loss and MAE of training and validation datasets

Train Loss(파란색)은 학습 데이터에 대한 손실 함수 값이다. 초기에는 상대적으로 높은 값을

보였으나 학습이 진행됨에 따라 점차 감소하였다. 이 결과는 모델이 학습 데이터의 패턴을 점차 더 정확하게 학습하고 있음을 뜻한다.

Validation Loss(주황색 선)은 검증 데이터에 대한 손실 함수값이다. Train Loss와 유사한 패턴을 보이며 학습 초기에 급격히 감소한 후 점차 안정화 되었다. 그러나 학습이 진행됨에 따라 Validation Loss가 Train Loss와 비교해 다소 높은 값을 유지하고 있으며 이는 모델이 학습 데이터에 비해 검증 데이터에서 더 높은 오류를 발생시키고 있음을 보여준다.

Train MAE(초록색 선)은 Train Loss와 마찬가지로 학습 초기에 급격히 감소한 후 안정화 되는 모습을 보인다.

Validation MAE(빨간색 선)은 Validation Loss와 유사하게 학습 초기에 감소하였으나 이후 상당히 높은 변동성을 보인다. Validation MAE가 Train MAE에 비해 상대적으로 높은 값을 유지하고 있다는 점은 모델이 검증 데이터에 대해 적합하지 않을 수 있음을 나타낸다. 모델의 성능을 개선하기 위해 검증 데이터셋의 크기를 조정하거나 정규화 기법 등을 추가하여 일반화 성능을 높일 수 있다.

## 2.5. SARIMA 모델을 활용한 출하량 예측 및 계절성 분석

SARIMA 모델은 ARIMA 모델을 기반으로 시계열 데이터 분석에 계절성을 고려한 예측을 수행하는 데 널리 사용되는 통계적 모델이다[13]. 이 모델은 주기적으로 반복되는 패턴을 가진 시계열 데이터에 적합하다.

주기적인 변동성을 고려한 시계열 데이터 분석 시 SARIMA 모델은 필수적인 분석 도구로 사용되어지고 있다. SARIMA 모델 성능에 중요한 영향을 미치는 적절한 파라미터 설정은 데이터의 계절성을 확실히 이해하고 모델에 반영하는 과정이 필요하다.




그림 9. 출하량에 대한 예측값 및 실제값(SARIMA)  
Fig 9. Forecasts and actuals for shipments (SARIMA)

그림9는 SARIMA 모델을 사용하여 출하량 예측값과 실제 출하량을 비교한 그래프이다. SARIMA 모델은 오이 출하량의 계절성을 잘 반영하여 전반적인 예측 경향을 따라갔다. 10월 중순에 출하량이 급격히 증가하는 시기에는 실제 출하량과 유사한 패턴을 보였으며 계절적 특성을 효과적으로 예측하였다. SARIMA 모델은 대부분의 기간 동안 출하량의 예측값과 실제값 간의 유사한 패턴을 보여 모델의 안정성을 확인하였다. 그러나 출하량이 급격히 변동하는 일부 구간에서는 예측 오차가 다소 발생하였는데 이러한 현상은 모델이 모든 비계절적 변화를 완벽하게 반영하지 못한 것으로 보여진다. 급격한 변동 구간에서의 예측 오차를 줄이기 위해 추가적인 연구가 필요해 보인다.

### 3. 시계열 데이터 예측 모델 비교 분석

본 연구에서는 다중회귀, ARIMA, LSTM, SARIMA 모델을 활용하여 주어진 시계열 데이터를 분석하고 각 모델에 대해 예측 성능을 비교 분석했다. 이들 지표는 모델의 예측 정확도를 평가하는 데 중요한 역할을 하며, 값이 작을수록 모델의 성능이 우수함을 나타낸다.

표2는 위 4가지 모델의 성능을 나타내는 RMSE와 MAE 값을 정리한 표이다.

표 2. 출하량 예측 모델 성능 비교

Table 2. Comparison of shipment forecast model performance

Classification	다중회귀	ARIMA	LSTM	SARIMA
RMSE	331.64	176.23	531.69	136.60
MAE	205.17	90.31	369.99	83.86

다중회귀 모델의 RMSE 값은 331.64, MAE는 205.17로 예측 성능이 상대적으로 낮게 나타났다. 이는 다중회귀 모델이 복잡한 시계열 데이터를 충분히 반영하지 못하기 때문으로 판단된다.

ARIMA 모델의 RMSE 값은 176.23, MAE가 90.31로, 다중회귀 모델에 비해 훨씬 나은 성능을 보였다. 이는 ARIMA 모델이 시계열 데이터의 장기상관성을 잘 반영하기 때문으로 파악된다.

LSTM 모델의 RMSE는 531.69, MAE는 369.99로 예상보다 낮은 성능을 보였다. 이는 데이터에 따라 과적합되거나, 적절한 학습이 이루어지지 않은 결과로 보여진다. LSTM 모델은 일반적으로 장기적인 패턴을 학습하는데 유리하지만, 시계열 데이터의 특성에 따라 성능이 달라질 수 있음을 시사한다.

SARIMA 모델은 RMSE 136.60, MAE 83.86으로 수행한 4개 모델 중 가장 우수한 성능을 보였고 이는 SARIMA 모델이 계절성과 경향 등을 모두 반영할 수 있는 모델로 보여진다.

## III. 결 론

본 연구에서 다양한 예측 모델을 비교 분석한 결과, SARIMA 모델이 오이 출하량 예측에 가장 적합한 모델임을 확인하였다. SARIMA 모델은 계절성이 강한 시계열 데이터를 효과적으로 분석하고 예측하는 데 뛰어난 성능을 발휘하였다. 오이 출하량은 계절적 요인에 크게 영향을 받는 특성이 있으며, SARIMA 모델은 이러한 계절적 변동성을 정확하게 반영함으로써 높은 예측 정확도를 제공할 수 있었다.

SARIMA 모델을 통해 얻어진 예측 결과는 단

순히 출하량 예측에 국한되지 않는다. 이 모델은 농업 생산 환경의 변화와 그에 따른 출하량의 변동성을 예측하는 데에도 유용하게 활용될 수 있다. 이를 통해 농업 생산 과정에서의 의사결정을 지원하고, 생산 계획을 더욱 효율적으로 수립하는 데 기여할 수 있다. 또한, SARIMA 모델은 계절적 패턴을 포함한 다양한 환경 요인을 통합적으로 고려할 수 있기 때문에, 향후 스마트팜의 생산환경 예측에도 적용 가능성을 가진다.

결론적으로, SARIMA 모델은 오이 출하량의 계절적 변동성을 잘 반영하며, 농업 분야에서의 실질적인 예측 및 의사결정 지원 도구로 활용될 수 있을 것이다. 향후 연구에서는 SARIMA 모델을 더욱 발전시켜, 생산환경의 다양한 요인과의 상호작용을 고려한 예측 모델을 개발하는 방향으로 나아갈 필요가 있다.

## REFERENCES

- [1] 김세원, 김영희, “작물 생산량 예측을 위한 머신러닝 기법 활용 연구,” *한국산학기술학회논문지*, 제22권, 제7호, 403-408쪽, 2021년
- [2] 오정원, 김행곤, 김일태, “머신러닝 적용 과일 수확 시기 예측시스템 설계 및 구현,” *스마트미디어저널*, 제8권, 제1호, ISSN 2287-1322, 2019년 3월
- [3] 김서연, 김송연, 한규림, 조인아, 경재영, “스마트팜 딸기 생산량 예측 모델: 시계열 데이터의 변수 선정을 중심으로,” *한국정보기술학회 추계 종합학술대회 논문집*, 744-748쪽, 2023년 11월
- [4] 이규빈, 김송연, 안동희, “개체 탐지 모델을 활용한 전기 아크 위험성 예측 시스템 개발,” *스마트미디어저널*, 제9권, 제1호, 38-44쪽, 2020년 3월
- [5] 이지은, 김송연, 한규림, 조인아, 경재영, 최예림 “시설오이의 생육에 영향을 미치는 최적 환경요인에 관한 연구,” *한국자료분석학회지*, 제21권, 제6호, 2913-2920쪽, 2019년 12월
- [6] 전명희, “오이 최적 생육 및 생산을 위한 빅데이터 적용 온실 환경관리 모델 개발,” *건국대학교 박사학위 논문*, 2021년 5월
- [7] J.Y. Parke, M.H. Yoo, T.M. Nho, D.K. Shin and S.K. Kim, A study of Battery User Pattern Change tracking method using Linear Regression and ARIMA Model, *Journal of the KIECS*. vol. 17, no. 3, pp. 423-432, Jun. 30. 2022
- [8] 김동현, 김민우, 이병준, 김경태, 윤희용, “ARIMA 모델을 이용한 데이터 흐름 예측 기법,” *한국컴퓨터정보학회 하계학술대회 논문집*, 제26권, 제2호, 2018년 7월

- [9] J. Choi, “Performance Comparison of Machine Learning in the Prediction for Amount of Power Market,” *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 5, pp. 943-950, 2019.
- [10] G. Bak and C. Bae, “Performance Comparison of Machine Learning in the Various Kind of Prediction,” *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 14, no.1, pp. 169-178, 2019.
- [11] 김종화, 최종후, 강창완, “순환신경망 모델을 활용한 시계열 비교예측,” *Journal of the Korean Data Analysis Society*, 제21권, 제4호, 1771-1779쪽, 2019년 8월
- [12] 이현조, 김용기, 구현정, 채철주, “농업 공공 빅데이터를 이용한 머신러닝 기반 생산량 및 판매 수익금 예측,” *스마트미디어저널*, 제11권, 제4호, 19-29쪽, 2022년 8월
- [13] E.H. Etuk, “The Fitting of a SARIMA Model to Monthly Naira-Euro Exchange Rates,” *Mathematical Theory and Modeling*, Vol. 3, No. 1, pp. 17-26, 2013.

## 저자 소개



이혜경(학생회원)

2001년 국립순천대학교 전자공학과 학사 졸업.  
2024년 국립순천대학교 스마트농업 전공 석사 과정.

<주관심분야 : 스마트팜, 농업IoT, 데이터분석>



신창선(정신회원)

1996년 우석대학교 전산학과 학사 졸업.  
1999년 한양대학교 컴퓨터교육과 석사 졸업.  
2004년 원광대학교 컴퓨터교육과 공학 박사 졸업.  
2005년 국립순천대학교 인공지능공학부 교수

<주관심분야 : 분산컴퓨팅, 실시간 객체모델, 농업 IoT>