

질감 분석 및 인공지능 기반 토마토 과실 특징 추정 알고리즘 구현

이 정 호*, 백 정 현°, 임 동 혁*, 김 태 현°, 김 만 중*, 박 성 진*, 양 오 석*

Implementation of Texture Analysis and Artificial Intelligence-Based Tomato Fruit Features Estimation Algorithm

Jeong-Ho Lee*, Jeong-Hyun Baek°, Dong-Hyeok Im*,
 Tae-Hyun Kim*, Man-Jung Kim*, Seong-Jin Park*, Oh-Seok Yang*

요 약

스마트 온실은 ICT 기술을 온실에 적용하여 생육환경을 유지 및 관리하는 기술을 의미하며 이를 활용하여 적은 노동력으로 생산성을 증가시킬 수 있다. 최근 스마트 온실의 다양한 분야에 인공지능이 적용되고 있지만, 생산량 관리에 영향을 미치는 과실 특징인 무게와 당도 추정에 관련된 연구는 미비한 상황이다. 본 논문에서는 토마토를 재배 중인 스마트 온실에서 과실 영상을 실험실 환경에서 수집하고, 인공지능과 질감 분석을 통해 얻어진 정보를 기반으로 과실 특징인 무게와 당도를 추정하는 알고리즘을 구현한다. 질감 분석에 사용되는 Gray Level Co-occurrence Matrix(GLCM)을 적용해 얻은 특징인 Dissimilarity, Homogeneity, Energy, Correlation과 토마토 화소 수가 사용된다. 수집된 특징은 eXtreme Gradient Boosting(XGBoost), Deep Neural Network(DNN), Convolutional Neural Network(CNN) 및 머신러닝 앙상블 방법의 입력 데이터로 사용해서 무게와 당도를 추정하며 가장 최적의 방법을 도출하기 위한 평가지표로 Root Mean Square Error(RMSE)와 R²를 활용한다. 실험 결과 머신러닝 앙상블이 가장 좋은 결과값을 얻었으며 딥러닝 계열의 DNN, CNN에서 좋지 못한 결과가 나타나는 것을 확인할 수 있었다.

Key Words : Machine learning, Deep learning, Tomato, Fruit feature, Texture analysis

ABSTRACT

Smart farm refers to a technology that maintains and manages a growth environment by applying ICT technology to a greenhouse, and can increase productivity compared to labor force. Recently, artificial intelligence technology has been applied to various parts of smart farm, but research related to weight and Brix degree estimation, which are fruit features that affects production management, is insufficient. In this paper, we implement an algorithm that estimates the weight and Brix degree of tomatoes, a type of crop

※ 본 연구는 농촌진흥청 연구사업(과제번호: RS-2021-RD010195)의 지원으로 수행되었습니다.

• First Author : Division of Smart Farm Development, Department of Agricultural Engineering, National Institute of Agricultural Sciences, ljh09150915@korea.kr, 정회원

° Corresponding Author : Division of Smart Farm Development, Department of Agricultural Engineering, National Institute of Agricultural Sciences, butterfly@korea.kr, 정회원

* Division of Smart Farm Development, Department of Agricultural Engineering, National Institute of Agricultural Sciences, imdh1004@korea.kr, 정회원; thkim8205@korea.kr, 정회원; kmj0403@korea.kr, 정회원; psj8475@korea.kr, 정회원; dhtjr9596@mail.com, 학생회원

논문번호 : 202307-141-0-SE, Received June 30, 2023; Revised August 23, 2023; Accepted August 23, 2023

produced in smart farms, using texture analysis and artificial intelligence. The tomato fruit features estimation algorithm uses Dissimilarity, Homogeneity, Energy, Correlation and number of tomato pixels obtained by collecting images of tomatoes harvested in the greenhouse in a laboratory environment and applying the Gray Level Co-occurrence Matrix(GLCM) that used for texture analysis. The collected features are used as input data for eXtreme Gradient Boosting(XGBoost), Deep Neural Network(DNN), Convolutional Neural Network(CNN) and machine learning ensemble methods to estimate weight and Brix degree, and Root Mean Square Error(RMSE) and R^2 are used as evaluation indicators to derive the most optimal method. As a result of the experiment, it was confirmed that the machine learning ensemble obtained the best result, and deep learning-type DNN and CNN gave poor results.

1. 서 론

근래 농촌인구의 감소와 고령화, 시장개방 심화, 기후변화와 같은 농업에서 발생하는 문제에 대한 해결책으로 스마트팜 기술이 주목받고 있다¹⁾. 스마트팜이란 ICT, IoT, 빅데이터 등의 첨단기술을 노지, 원예시설, 축사 등에 적용하여 원격제어 및 자동으로 생육환경을 유지·관리하는 기술을 의미하며^{1,2)}, 작물을 생산하는 과정에서 필요한 시간과 공간에 대한 문제점을 해소하여 소비자에게 저렴한 가격에 식량을 제공할 수 있는 기술이다³⁾. 현재 보급된 스마트팜 기술은 개별 농가 단위로 내부 환경 제어를 원격으로 관리하는 1세대 스마트팜이 주류를 이루고 있다. 최근 4차산업의 인공지능과 빅데이터 관련 기술이 농업에 적용되면서 2세대 스마트팜에 관한 관심이 증가하고 있다. 하지만 1세대 스마트팜과 2세대 스마트팜을 구분하는 데이터 기반의 생산, 정밀, 지능화와 관련된 연구는 정확한 데이터 수집의 어려움과 분석의 난해함 때문에 연구가 미흡한 상황이다⁴⁾.

시설원에 부분의 스마트 온실은 생육 조건과 환경 조건의 상관관계 분석, 예측을 통한 재배기준 설정을 통한 생산, 정밀제어, 지능화⁴⁾를 위해서는 작물 과실 특징을 정확히 측정하는 것이 필요하다. 하지만 이러한 특징을 획득하는 과정은 많은 시간과 노동력이 필요하므로 인공지능과 영상처리를 통한 과실 특징 추정에 관한 연구가 진행되고 있으며, 대부분의 연구가 작물의 생장과 생산량 추정에 집중되어 있다^{5,6)}. 이외에 초분광 영상에 딥러닝을 적용하여 작물의 수분 스트레스 정보를 조기 검출하는 기술이 연구되고 있으나 생산량과 관련이 있는 무게와 당도를 측정하는 연구는 미흡하다. 무게 예측의 경우 국내에서 진행된 연구가 드물고, 당도 측정은 초분광 영상의 분광 특성을 사용하거나⁸⁾ 외부 기상 데이터(평균 온도, 습도, 강수량, 일사량, 평균 풍속)를 입력 데이터로 사용해 예측하였다^{9,10)}. 이러

한 연구는 고가의 장비를 사용하거나 당도 추정에 필요한 분광 특성에 대한 이해가 필요하고 재배 작물의 개체별 당도가 아닌 재배면적의 평균 당도를 예측하기 때문에 실제 농가에 적용해 재배기준 설정에 활용하기에 무리가 있다.

따라서, 기존의 방법론들이 가지는 장비 및 면적 기준의 추정적 한계를 극복하기 위해 본 연구에서는 작물 수확 개체에 초점을 두고 진행하였다. 단일 개체 측정을 위해 RGB 영상의 위치에 관한 특성은 배제하였고, 토마토의 흑백 영상에 2차적 통계량을 통해 영상의 질감 분석을 가능하게 하는 Gray Level Co-occurrence Matrix(GLCM)¹¹⁾을 적용하여 2차적 통계량을 추출해 고수준 대표성을 가지고 있는 특성으로 선정하였다. 선정된 특성값은 머신러닝의 한 종류인 eXtreme Gradient Boosting (XGBoost)¹²⁾과 머신러닝 앙상블의 입력 데이터로 사용하였다. 또한 배경을 제거한 토마토 RGB 영상 자체를 저수준 대표성을 가지고 있는 특성으로 선정하여 Deep Neural Network(DNN)과 Convolutional Neural Network(CNN)의 입력 데이터로 적용하였다. 각각의 모델은 토마토의 무게와 당도를 회귀를 통해 추정한다. 추정된 결과값은 평가지표인 Root Mean Squared Error(RMSE)와 R^2 기반으로 비교하여 토마토의 무게와 당도를 추정하는 최적의 모델을 선정한다. 제안하는 방법에 사용되는 입력 영상은 스마트폰에서 촬영한 각각의 토마토에 해당하는 RGB 영상을 사용하기 때문에 기존의 방법들이 가지는 문제점을 극복할 수 있다.

본 논문의 구성은 다음과 같다. 제 II장에서는 데이터 수집과 수집된 데이터를 학습에 사용하기 위해 진행하는 전처리에 대한 설명을 진행하고 제 III장에서는 당도, 무게 예측에 사용된 학습 모델에 대한 기본적인 내용을 설명한다. 제 IV장에서는 모델 학습에 대한 실험 방법 및 실험 결과에 대한 분석을 진행한다. 마지막으로 제 V장에는 연구에 대한 결론과 차후 연구에 대해 논의

한다.

II. 데이터 수집 및 전처리

논문에서 제안하는 방법에 사용된 데이터는 국립농업과학원 농업공학부에 위치한 첨단디지털온실 연동의 48개 샘플 구역에서 2023년 2월부터 3월까지 수확한 187개의 토마토를 아이폰 14 Pro로 [3024, 4032] 해상도로 수집하였다. 토마토의 무게와 당도 측정에 방해 요소가 포함되지 않게 동일한 광원과 높이에서 촬영을 진행하였으며, 주위 환경에 대한 영향력을 최소화하기 위해 영상의 배경을 제거하는 전처리 후, GLCM을 활용한 질감 분석을 하였다. Fig. 1은 각각 촬영한 원본 영상과 배경을 제거한 토마토 영상의 예시를 보여주고 있다.

배경을 제거한 영상은 Fig. 2에 표현된 GLCM 알고리즘을 사용해서 변환된다. 해당 그림에서 확인할 수 있듯이 GLCM 알고리즘은 화소 쌍의 지정된 화소 값 발생빈도를 행렬로 표시하는 방법이다. P는 발생빈도, D는 화소 쌍 사이의 거리, A는 화소 쌍 사이의 각도를 의미한다. 일반적인 GLCM 알고리즘은 일반적으로 배경이라고 생각되는 화소 값인 0을 연산에 사용하기 때

문에 토마토의 당도와 무게를 측정하는데 안 좋은 영향을 미칠 가능성이 크므로 GLCM에서 화소 쌍의 지정된 화소 값이 0인 행과 열의 발생빈도를 0으로 변환하는 과정을 추가한다. Table 1은 GLCM에서 얻을 수 있는 2차적 통계량에 대한 수식을 나타내고 있으며 각 통계량은 영상의 질감에 대한 정보를 포함하고 있다. Dissimilarity는 화소 간의 명암도 차이를 표현하며 명암도 차이가 크게 나는 화소가 많을수록 큰 값을 가진다. Homogeneity는 화소 값 사이의 균일한 정도를 표현하며 GLCM의 값이 대각선에 집중되어 있을 때 가장 큰 값을 가지며 Energy는 명암도의 균일함을 나타내며 영상에서 밝기 변화가 없을수록 큰 값을 가진다. 마지막으로 Correlation은 화소의 명암도가 선형적인 의존성을 가지는지를 표현하고 있다. Table 1.에서 i와 j는 화소 값을 의미하며 pij는 발생빈도, m은 GLCM 행과 열의 평균, σ는 GLCM 행과 열의 표준편차를 의미한다. GLCM 알고리즘은 화소 사이의 거리와 각도를 입력값으로 설정한다. 본 연구에서는 화소 사이의 거리를 10화소, 각도를 0°, 90°로 설정하고 각각의 GLCM에서 얻어진 2차적 통계량의 평균을 머신러닝의 입력 데이터로 사용하였다.

추가적인 특징인 화소 수는 배경을 제거한 토마토 영상에 임계값을 적용해 토마토 영역에 해당하는 부분의 화소 수만 추출해서 사용하였다. Fig. 3은 완성된 데이터프레임 예시를 보여주고 있다. 딥러닝 모델의 경우 Fig. 1의 배경이 제거된 토마토 영상을 그대로 입력 데이터로 사용하였다. 수집된 데이터는 학습과 검증을 위해 8:2 비율로 분리하여 사용하였다. 검증 데이터를 통한 하이퍼 파라미터의 조정을 추가하지 않으므로 검증 데이터를 테스트 데이터로 사용하였다. 입력 데이터는 모두 정규화를 통해 각 특징 사이의 범위 차이가 학습에 영향을 미치지 않도록 하였다.




그림 1. (왼) 원본 영상 (우) 배경 제거 영상
Fig. 1. (left) Original image (right) image without background

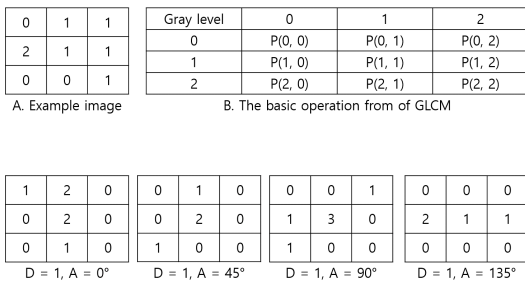


그림 2. 실험 이미지에 대한 GLCM 예시
Fig. 2. Example of GLCM for experimental images

표 1. GLCM의 통계적 특징 파라미터
Table 1. GLCM statistical characteristic parameters

Statistical characteristic parameter	Formula
Dissimilarity	$\sum_{i=1}^K \sum_{j=1}^K i-j p_{ij}$
Homogeneity	$\sum_{i=1}^K \sum_{j=1}^K \frac{p_{ij}}{1+(i-j)^2}$
Energy	$\sum_{i=1}^K \sum_{j=1}^K p_{ij}^2$
Correlation	$\sum_{i=1}^K \sum_{j=1}^K \frac{(i-m_r)(j-m_c)p_{ij}}{\sigma_r \sigma_c}$

	name	contrast	dissimilarity	homogeneity	energy	correlation	pixel_count	weight	brix
0	0210_A_1_1_1	672.620	13.908	0.126	0.014	0.820	372276	177.90	3.9
1	0210_A_15_1_1	901.051	16.193	0.120	0.013	0.814	398113	193.07	3.6
2	0210_A_16_1_2	715.069	14.258	0.130	0.015	0.824	390039	187.04	3.8
3	0210_A_17_1_1	921.630	17.120	0.112	0.012	0.798	373557	155.27	3.9
4	0210_A_18_1_1	765.356	14.656	0.138	0.016	0.791	403332	174.80	3.9

그림 3. 데이터 프레임 예시
Fig. 3. Example of data frame

III. 학습 모델

실험에는 XGBoost, 머신러닝 앙상블, DNN, CNN, ResNet 모델을 적용하였다. XGBoost는 캐글(Kaggle) 대회에서 압도적으로 우승을 많이 한 머신러닝 모델로 이진 트리의 오차를 기반으로 새로운 트리를 학습해 올바르게 예측된 값의 영향을 제거한 그래디언트 부스팅의 병렬 학습 모델로 학습 속도가 빠르며 자원의 효율이 뛰어나다. 머신러닝 앙상블은 머신러닝 모델을 다중으로 사용해서 단일 모델을 사용하는 것보다 좋은 결과를 도출하도록 설계된 알고리즘이다. 머신러닝 앙상블에는 여러 가지 방법이 존재하며 배깅(Bagging), 보팅(Voting), 스택킹(Stacking) 방법을 적용하여 비교 실험을 진행하였다. 배깅은 원본 데이터에 독립성을 보장하는 무작위 추출 방법으로 데이터 샘플을 만드는 부트스트랩 방식을 채용하여 하나의 머신러닝 모델을 다중으로 사용해 평균값을 결과값으로 사용하는 방법이다. 보팅은 배깅과는 다르게 원본 데이터에 여러 가지 머신러닝 모델을 적용한 후 결과값을 선정하는 방식으로 당도와 무게를 예측하는 본 실험에서는 분류 모델이 아닌 회귀 모델에 적용하였으므로 하드 보팅, 소프트 보팅으로 나뉘지 않고 배깅과 마찬가지로 평균값을 결과값으로 사용한다. 스택킹은 여러 종류의 머신러닝 모델의 예측 결과값을 다음으로 연결된 머신러닝 모델의 학습 데이터로 변환하여 학습시키고 결과를 예측하는 방법이다.

DNN은 Artificial Neural Network(ANN)에서 모델 내 은닉층을 2개 이상으로 늘려 결과를 도출하는 능력을 향상시킨 모델로 Fig. 4는 실험에 사용한 DNN 모델의 구조와 파라미터 수를 보여주고 있다. CNN은 컨벌루션층(Convolution layer)과 풀링층(Pooling layer)을 사용해서 입력 데이터의 특징을 추출하는 모델이다. 본 연구에서는 Fig. 6에 나타난 구조를 가지는 간단한 CNN 모델과 Fig. 5에 보이는 Residual block을 특징으로 하는 ResNet^[13]을 변형해서 학습에 사용하였다. Fig. 7은 회귀작업에 맞춰 ResNet의 변경된 부분을 보여주고 있다. ResNet은 특징 추출 부분 이후에 따라오는

부분이 기본적으로 분류작업에 적용되는 모델이기 때문에 해당 부분을 제거하고 회귀작업에 맞게 마지막 층을 출력값이 1개만 나오도록 변경하여 사용하였다.

Layer (type)	Output Shape	Param #
flatten_4 (Flatten)	(None, 150528)	0
dense_13 (Dense)	(None, 512)	77070848
dense_14 (Dense)	(None, 256)	131328
dropout_3 (Dropout)	(None, 256)	0
dense_15 (Dense)	(None, 128)	32896
dense_16 (Dense)	(None, 64)	8256
dense_17 (Dense)	(None, 32)	2080
dense_18 (Dense)	(None, 1)	33

그림 4. DNN의 구조
Fig. 4. Architecture of DNN

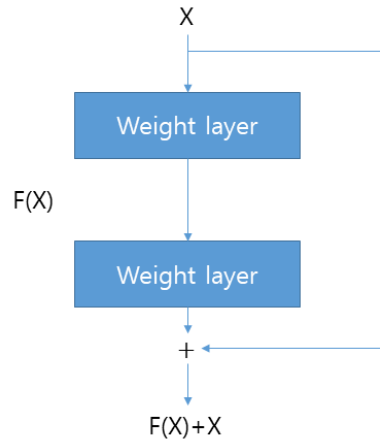


그림 5. 잔차 블록
Fig. 5. Residual block

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
conv2d (Conv2D)	(None, 222, 222, 16)	448
max_pooling2d (MaxPooling2D)	(None, 111, 111, 16)	0
conv2d_1 (Conv2D)	(None, 109, 109, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 32)	0
conv2d_2 (Conv2D)	(None, 52, 52, 64)	18496
global_average_pooling2d (GlobalAveragePooling2D)	(None, 64)	0
dense (Dense)	(None, 64)	4160
dense_1 (Dense)	(None, 64)	4160
dense_2 (Dense)	(None, 1)	65

그림 6. CNN의 구조
Fig. 6. Architecture of CNN

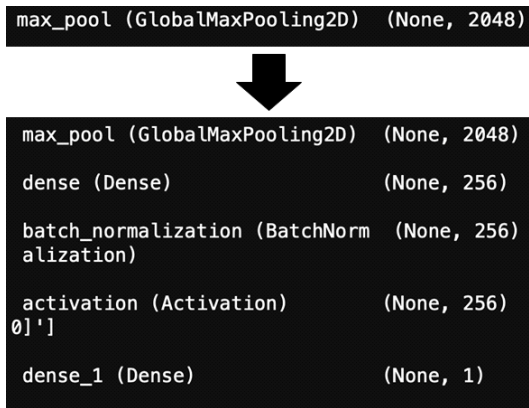


그림 7. ResNet의 변화된 부분
Fig. 7. Changed parts of ResNet

IV. 실험

4.1 실험 방법

본 연구는 토마토의 흑백 영상에서 화소 사이 명암값의 발생빈도를 행렬로 표시하는 방법인 GLCM을 활용하여 추출할 수 있는 질감 분석 특성인 Dissimilarity, Homogeneity, Energy, Correlation과 배경을 제거한 토마토 영상에서 토마토 영역의 화소 수를 계산해서 얻은 값을 XGBoost와 머신러닝 모델을 베깅, 보팅, 스테킹 방식으로 중첩하는 머신러닝 앙상블의 입력 데이터로 사용해서 무게와 당도를 예측하는 모델과 토마토 RGB 영상 자체를 저수준 대표성을 가지고 있는 특성으로 지정해 DNN, CNN, ResNet을 입력 데이터로 사용해 특징을 추출하고 당도를 예측하는 모델을 학습시켰다. 학습은 애플 실리콘 기반의 M1 MAX를 사용하였으며 언어, 프레임워크, 라이브러리는 Python 3.8, Tensorflow 2.10, xgboost 1.6.2로 진행하였다. 머신러닝 방법의 경우 라이브러리에 내장된 모델의 기본 설정을 유지한 상태로 학습을 진행하였으며 딥러닝 방법의 경우 토마토 영상을 딥러닝 모델의 입력층에 사용할 수 있도록 해상도를 [224, 224]로 변경하고 하이퍼 파라미터인 학습률은 0.001 옵티마이저는 Adam, 오차함수는 Mean Squared Error(MSE)로 설정한 상태에서 100회 반복해서 학습을 진행하고 반복이 완료된 시점에서 모델의 파라미터를 저장하도록 설정하였다. 학습에는 총 187장의 토마토 영상을 사용하였으며 최대한 외부환경의 영향력을 줄이기 위해 동일한 장소와 일정한 5,200K의 색온도를 가지는 LED 광원 아래에서 촬영하였으며 촬영 시 높이는 33.5cm로 일정하게 유지하였다. 학습이 종료된 모델 성능은 검증 데이터를 사용한 모델 추론

과정에서 얻어진 무게와 당도를 평가지표인 RMSE와 R^2 값을 사용하여 비교 실험하였다. 머신러닝의 앙상블 방법 중 서로 다른 머신러닝 모델을 사용하는 보팅, 스테킹에 적용할 머신러닝은 XGBoost와 Random Forest Regressor 등 대표적인 머신러닝 회귀 모델 19개를 사용하였으며 각 모델의 성능 순위를 RMSE 값을 기준으로 평가해 상위 5개의 모델을 앙상블할 모델로 활용하였으며 하나의 모델을 중첩해서 사용하는 베깅의 경우 RMSE 값이 가장 작은 모델을 활용하여 앙상블을 진행하였다.

4.2 실험 결과

Fig. 8과 Fig. 9는 GLCM 알고리즘에서 추출된 질감 분석 특성인 Dissimilarity, Homogeneity, Energy, Correlation과 당도·무게의 상관관계를 보여주고 있다.

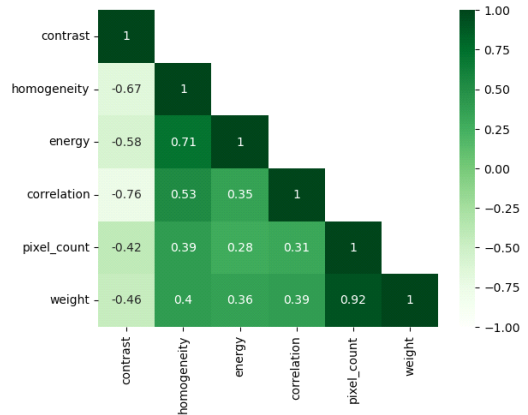


그림 8. 무게와 특징 사이의 상관관계
Fig. 8. Correlation between features and weight




그림 9. 당도와 특징 사이의 상관관계
Fig. 9. Correlation between features and Brix

Fig. 8의 무게와 질감 분석 특성 상관관계의 경우 토마토 영역의 화소 수가 0.92로 무게와의 가장 큰 값을 나타내고 있으며 1에 매우 근접한 값을 얻었으므로 유의성이 매우 높다고 할 수 있다. Fig. 9의 당도와 질감 분석 특성 상관관계의 경우 Energy와의 상관계수가 0.53으로 가장 큰 값을 나타내고 있지만, 무게와 토마토 영역의 화소 수 사이의 상관관계를 비교했을 때 유의성이 떨어지는 것을 확인할 수 있다. Table 2는 무게와 당도를 예측하는 머신러닝 앙상블 방법에 사용되는 5개의 머신러닝 모델을 보여주고 있다. 도표의 위쪽으로 갈수록 성능 비교지표인 RMSE에서 작은 값을 얻은 모델이며 앙상블 베깅의 경우 무게를 예측하는 모델에는 Gradient Boosting regressor, 당도를 예측하는 모델에는 Linear regressor를 적용하였다. Table 3과 Table 4는 실험에 사용된 학습 모델의 성능 지표를 보여주고 있다. 당도의 경우 베깅 방법에서 RMSE, R² 모두에서 가장 최적의 값이 나타났으며 무게의 경우 보팅 방법에서 RMSE, R² 모두에서 가장 최적의 값이 나타났다. 당도와 무게의 실험 결과값을 통해서 XGBoost 단일 모델을 무게 추정에 적용하는 것보다 앙상블 방법을 사용해 여러 종류의 모델을 조합해서 사용하거나 하나의 모델을 중첩해서 사용하는 것이 과실 특징인 무게와 당도를 잘 추정한다는 것을 확인할 수 있다. 학습에 사용된 당도와 무게 데이터의 표준편차는 각각 0.417, 58.117로 최적의 학습 모델 RMSE 값보다 크다. 머신러닝을 통한 회귀 모델을 학습을 할 경우 학습 결과에 대한 평가로 사용되는 최소한의 성능을 가진 모델은 학습에 사용된 데이터의 평균을 학습 데이터로 사용하는 모델로 RMSE 값은 학습에 사용된 데이터의 표준편차가 된다. 실험에서 얻은 최적의 학습 모델은 위 해석을 기반으로 최소한의 성능을 가진 모델보다 성능이 우수하다고 할 수 있다. 최적의 결과를 나타내는 무게 추정 모델의 R² 값은 0.946으로 1에 근접하여 학습이 완료된 회귀 모델이 실험에 사용된 데이터 전체를 잘 설명하고 차후 추론을 통한 무게 추정에 적합하다고 할 수 있지만, 최적의 결과를 나타내는 당도 추정 모델의 경우 R² 값은 0.505로 무게 추정 모델과는 다르게 1에 근접하지 못한 값을 얻어 학습이 완료된 회귀 모델이 실험에 사용된 전체 데이터에 대한 설명력이 다소 약하다고 할 수 있다. 이러한 결과는 차후 해당 모델을 추론 모델로 사용할 경우 원치 않은 결과값이 도출 가능성이 있다. 해당 결과는 실험에서 직접 선정된 특징(hand-crafted feature)인 GLCM 알고리즘을 통해 추출된 질감 분석 특성이 고수준 대표성을 가질 거라고 예상했으나 어느 정도 유의미한 결과는 나타내고 있지만, 당도를 나타내

표 2. 앙상블에 사용된 머신러닝 모델
Table 2. Machine learning model used in ensemble

Weight(regressor)	Brix(regressor)
GradientBoosting	Linear
ExtraTress	Lars
RandomForest	BayesianRidge
Huber	Huber
BayesianRidge	Ridge

표 3. 당도 추정 모델의 결과
Table 3. Results of Brix model

Model	RMSE	R ²
XGBoost	0.384	0.243
Bagging	0.311	0.505
Voting	0.319	0.479
Stacking	0.322	0.470
DNN	0.746	-1.826
CNN	0.431	0.059
ResNet	1.158	-5.804

표 4. 무게 추정 모델의 결과
Table 4. Results of weight model

Model	RMSE	R ²
XGBoost	22.079	0.824
Bagging	15.041	0.918
Voting	12.242	0.946
Stacking	14.093	0.928

는 뚜렷한 특징이라고 하기 어렵다고 할 수 있다. 따라서 당도 데이터만 추가로 딥러닝 모델을 사용해서 저수준 대표성을 가지는 토마토 RGB 영상에서 모델이 스스로 특징을 추출하고 회귀 모델을 학습도록 실험을 진행하였으나 Table 3에서 확인할 수 있듯이 DNN, CNN, ResNet 모두 머신러닝 방법보다 작은 값을 보여주었다. 머신러닝 방법의 결과 중 가장 안 좋은 모델인 XGBoost 단일 모델의 결과값인 0.384보다 3가지 딥러닝 모델 모두 안 좋은 결과를 보여주고 있어 GLCM 알고리즘을 통해 얻은 토마토 RGB 영상의 질감 특성을 고수준 대표성을 가지는 hand-crafted 특징으로 인정할 수 있다.

V. 결 론

본 논문에서는 토마토 RGB 영상과 GLCM 알고리

즘을 통해 추출된 질감 분석 특징을 사용하였다. 당도와 무게를 추정하기 위해 XGBoost, 머신러닝 앙상블, DNN, CNN을 학습시키고 RMSE와 R²값으로 비교하였다. 그 결과 당도 추정 모델에서는 머신러닝 앙상블 베킹 방법이 RMSE=0.311, R²=0.505, 무게 추정 모델의 경우 머신러닝 앙상블 보팅 방법이 RMSE=12.242, R²=0.946 로 가장 좋은 결과값을 획득하였다. 최적의 결과를 나타낸 두 모델 모두 모든 입력값을 평균값으로 통일하는 기본 평가 모델보다 낮은 RMSE 값을 가지고 있으며 R²값이 0.5를 넘어 데이터를 전체적으로 잘 설명한다고 할 수 있다. 이러한 결과를 통해서 단일 모델로 무게와 당도를 예측하는 것보다 여러 모델을 결합해서 사용하는 방식이 토마토의 무게와 당도를 추정하는 데 적합하다고 할 수 있다. 다만 무게 추정 모델에 비해 당도 추정 모델의 R²값이 낮아 회귀를 위해 설계된 DNN, CNN에 저수준 대표성을 가지는 RGB 영상을 입력 데이터로 활용해 당도를 추정하였으나 XGBoost, 머신러닝 앙상블 결과와 비교해서 RMSE, R²값에서 좋지 못한 결과를 보여주었다. 해당 결과를 통해서 GLCM 알고리즘에서 얻어진 질감 분석 특징이 당도와 무게에 대한 고수준 대표성을 가진 특징이라고 할 수 있다.

추후 구현된 알고리즘은 추가 데이터를 수집해 데이터 집단의 대표성을 늘리고 학습, 검증, 테스트 데이터로 분리해 머신러닝의 하이퍼 파라미터를 미세조정하는 과정이 필요하다. 이 외에 본 논문에서 제안된 질감 분석 특징 이외에 토마토 RGB 영상에서 당도를 표현할 수 있는 고수준 대표성이 인정되는 특징을 추가로 찾아 알고리즘의 데이터 설명력을 높일 필요가 있다. 마지막으로 실험실 환경이 아닌 온실 현장에서 촬영된 RGB 영상 데이터에서 무게와 당도를 예측하는 알고리즘으로 확장하기 위한 전처리가 포함된 실시간 영상처리 연구가 필요하다.

References

[1] S. H. Lee, Y. S. Park, and O. S. Kwon, "Constructing a tomato smart farm optimization model with estimated growth functions," *J. The Korean Data & Inf. Sci. Soc.*, vol. 31, no. 4, pp. 619-635, 2020. (<https://dx.dio.org/10.7465/jkdi.2020.31.4.619>)

[2] Y. J. Kim, J. Y. Park, and Y. G. Park, "An analysis of the current status and success factors of smart farms," *Korea Rural Econ.*

Inst. Report, pp. 1-74, 2016.

[3] M. J. Kim, et al., "Remote multi-control smart farm with deep learning growth diagnosis function," *J. The Korea Soc. Comput. and Inf.*, vol. 27, no. 9, pp. 49-57, Sep. 2022. (<https://doi.org/10.9708/jksci.2022.27.09.049>)

[4] S. E. Hong, et al., "A study on the prediction model for tomato production and growth using ConvLSTM," *J. KIIT*, vol. 18, no. 1, pp. 1-10, Jan. 2020. (<https://dx.doi.org/10.14801/jkiit.2020.18.1.1>)

[5] K. S. Kim, et al., "Tomato growth rate measurement system using image processing," *J. KICS*, vol. 45, no. 08, pp. 1460-1471, 2020. (<https://doi.org/10-7840/kics.2020.45.8.1460>)

[6] I. C. Hwang, et al., "Prediction of paprika yield using multiple linear regression," *J. KICS*, vol. 46, no. 11, pp. 2048-2055, 2021. (<https://doi.org/10.7840/kics.2021.46.11.2048>)

[7] H. G. Kim, et al., "Early detection of drought stress in plants using hyperspectral imaging and deep-learning method," *J. Korean Soc. for Nondestructive Testing*, vol. 42, no. 6, pp. 503-513, 2022. (<https://dx.doi.org/10-7779/JKSNT.2022.42.6.503>)

[8] A. R. Song, W. H. Jeon, and Y. I. Kim, "Study of prediction model improvement for apple soluble solids content using a ground-based hyperspectral scanner," *Korean J. Remote Sensing*, vol. 33, no. 5-1, pp. 559-570, 2017. (<https://dx.doi.org/10.7780/kjrs.2017.33.5.1.9>)

[9] D. M. Seo, "Development of artificial intelligence model for predicting citrus sugar content based on meteorological data," *J. Korea Contents Assoc.*, vol. 21, no. 6, pp. 35-43, 2021. (<https://dio.org/10.5392/JKCA.2021.21.06.035>)

[10] H. J. Lee, H. S. Chung, and C. J. Chae, "A study on the prediction of citrus sugar content based on meteorological data using machine learning," *J. Korea Contents Assoc.*, vol. 23, no. 1, pp. 74-82, 2023. (<https://dio.org/10.5392/JKCA.2023.23.01.074>)

- [11] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Texture features for image classification," *IEEE Trans. Syst., Man and Cybernetics*, vol. SMC-3, no. 6, pp. 610-621, Nov. 1973.
(<https://doi.org/10.1109/TSMC.1973.4309314>)
- [12] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proc. 22nd ACM Sigkdd Int. Conf. Knowledge Discovery and Data Mining*, pp. 785-794, Jun. 2016.
- [13] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *2016 IEEE Conf. CVPR*, Las Vegas, NV, USA, pp. 770-778, 2016.
(<https://doi.org/10.1109/CVPR.2016.90>)

이 정 호 (Jeong-Ho Lee)



2015년 2월 : 성균관대학교 생명공학과 석사
2022년 8월 : 성균관대학교 바이오메카트로닉스 박사
2022년 9월~현재 : 농촌진흥청 국립농업과학원 전문연구원

<관심분야> 영상처리, 인공지능, 스마트팜
[ORCID:0009-0003-4088-7064]

백 정 현 (Jeong-Hyun Baek)



2016년 2월 : 군산대학교 컴퓨터정보공학 박사
2020년 1월 : 농촌진흥청 국립농업과학원 전문연구원
2020년 2월~현재 : 농촌진흥청 국립농업과학원 농업연수사
<관심분야> 스마트팜, 클라우드 컴퓨팅, 데이터분석

[ORCID:0000-0002-5867-2171]

임 동 혁 (Dong-Hyeok Im)



1999년 2월 : 성균관대학교 생물기전공학과 석사
2005년 2월 : 성균관대학교 바이오메카트로닉스학과 박사
2016년 4월~현재 : 농촌진흥청 국립농업과학원 연구관
<관심분야> 객체지향시스템, 빅데이터, 스마트팜

[ORCID:0000-0003-1204-8274]

김 태 현 (Tae-Hyun Kim)



2011년 2월 : 세종대학교 컴퓨터공학과 박사수료
2019년 1월 : (주)아이앤씨테크 놀로지 책임연구원
2019년 2월~현재 : 농촌진흥청 국립농업과학원 연구사
<관심분야> HCI, 인공지능, 스마트팜

[ORCID:0000-0002-4478-667X]

김 만 중 (Man-Jung Kim)



2022년 2월 : 전북대학교 기계시스템공학과 박사
2023년 1월 : 농촌진흥청 국립농업과학원 전문연구원
2023년 2월~현재 : 농촌진흥청 국립농업과학원 연구사
<관심분야> 농업 로봇, 농업자동화, 자동화시스템

[ORCID:0000-0003-0600-489X]

박 성 진 (Seong-Jin Park)



2018년 8월 : 순천대학교 산업기계공학과 학사
2020년 2월 : 순천대학교 산업기계공학과 석사
2022년 4월~현재 : 농촌진흥청 국립농업과학원 전문연구원
<관심분야> 스마트팜, 자동화 온실, 농업로봇

[ORCID:0000-0001-8808-6686]

양 오 석 (Oh-Seok Yang)



2018년 2월 : 군산대학교 컴퓨터
정보공학과 졸업

2021년 2월 : 군산대학교 컴퓨터
정보공학과 석사

2021년 3월~현재 : 군산대학교
컴퓨터정보공학과 박사과정
<관심분야> 객체지향시스템, 빅
데이터, 스마트팜

[ORCID:0000-0001-5016-6146]