

# YOLOv5 및 다항 회귀 모델을 활용한 사과나무의 착과량 예측 방법

## Estimation of fruit number of apple tree based on YOLOv5 and regression model

곽희진\*, 정윤주\*\*, 전익조\*\*\*, 이철희\*\*★

Hee-Jin Gwak\*, Yunju Jeong\*\*, Ik-Jo Chun\*\*\*, Cheol-Hee Lee\*\*★

### Abstract

In this paper, we propose a novel algorithm for predicting the number of apples on an apple tree using a deep learning-based object detection model and a polynomial regression model. Measuring the number of apples on an apple tree can be used to predict apple yield and to assess losses for determining agricultural disaster insurance payouts. To measure apple fruit load, we photographed the front and back sides of apple trees. We manually labeled the apples in the captured images to construct a dataset, which was then used to train a one-stage object detection CNN model. However, when apples on an apple tree are obscured by leaves, branches, or other parts of the tree, they may not be captured in images. Consequently, it becomes difficult for image recognition-based deep learning models to detect or infer the presence of these apples. To address this issue, we propose a two-stage inference process. In the first stage, we utilize an image-based deep learning model to count the number of apples in photos taken from both sides of the apple tree. In the second stage, we conduct a polynomial regression analysis, using the total apple count from the deep learning model as the independent variable, and the actual number of apples manually counted during an on-site visit to the orchard as the dependent variable. The performance evaluation of the two-stage inference system proposed in this paper showed an average accuracy of 90.98% in counting the number of apples on each apple tree. Therefore, the proposed method can significantly reduce the time and cost associated with manually counting apples. Furthermore, this approach has the potential to be widely adopted as a new foundational technology for fruit load estimation in related fields using deep learning.

### 요 약

본 논문은 딥러닝 기반 객체 탐지 모델과 다항 회귀모델을 이용하여 사과나무에 열린 사과의 개수를 예측할 수 있는 새로운 알고리즘을 제안한다. 사과나무에 열린 사과의 개수를 측정하면 사과 생산량을 예측할 수 있고, 농산물 재해 보험금 산정을 위한 손실을 평가하는 데에도 활용할 수 있다. 사과 착과량 측정을 위해 사과나무의 앞면과 뒷면을 촬영하였다. 촬영된 사진에서 사과를 식별하여 라벨링한 데이터 세트를 구축하였고, 이 데이터 세트를 활용하여 1단계 객체 탐지 방식의 CNN 모델을 학습시켰다. 그런데 사과나무에서 사과가 나뭇잎, 가지 등으로 가려진 경우 영상에 포착되지 않아 영상 인식 기반의 딥러닝 모델이 해당 사과를 인식하거나 추론하는 것이 어렵다. 이 문제를 해결하기 위해, 우리는 두 단계로 이루어진 추론 과정을 제안한다. 첫 번째 단계에서는 영상 기반 딥러닝 모델을 사용하여 사과나무의 양쪽에서 촬영한 사진에서 각각의 사과 개수를 측정한다. 두 번째 단계에서는 딥러닝 모델로 측정된 사과 개수의 합을 독립변수로, 사람이 실제로 과수원을 방문하여 카운트한 사과 개수를 종속변수로 설정하여 다항 회귀 분석을 수행한다. 본 논문에서 제안하는 2단계 추론 시스템의 성능 평가 결과, 각 사과나무에서 사과 개수를 측정하는 평균 정확도가 90.98%로 나타났다. 따라서 제안된 방법은 수작업으로 사과의 개수를 측정하는 데 드는 시간과 비용을 크게 절감할 수 있다. 또한, 이 방법은 딥러닝 기반 착과량 예측의 새로운 기반 기술로 관련 분야에서 널리 활용될 수 있을 것이다.

*Key words : Deep Learning, Object recognition, Fruit number counting, YOLO series, Regression*

\* Dept. of Computer Engineering, Andong National University, Andong 36729, Republic of Korea

\*\* SW Expert Training Center, Andong National University, Andong 36729, Republic of Korea

\*\*\* Dept. of Smart Horticultural Science, Andong National University, Andong 36729, Republic of Korea

★ Corresponding author

E-mail : chlee@anu.ac.kr, Tel : +82-54-820-6190

※ Acknowledgment

This work was supported by a Research Grant of Andong National University

Manuscript received May.10, 2024; revised Jun.10, 2024; accepted Jun.17, 2024.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## I. 서론

과수원에서 상업적 계약이 이루어지기 전에 과일의 정확한 수확량의 추정과 저품질 과일의 검출은 큰 피해를 예방하는 측면에서 중요한 문제이다[1]. 과일 생산량의 정확한 추정은 농가와 정부 양쪽에 도움을 줄 수 있다. 농가는 수확에 필요한 노동력을 적절히 조정하거나 포장 및 운송 자원을 미리 준비할 수 있다. 정부는 예측된 생산량을 바탕으로 수급 조절 정책을 수립하여 가격 안정화를 도모할 수 있다. 또한 생산량 데이터를 농업 연구 및 개발에 필요한 중요한 기초 자료로 활용하여 사과 재배 기술의 향상, 병해충 관리 기술 개발 등에 기여할 수 있다.

현재 과일 생산량을 측정하는 방법은 대부분 수작업으로 이루어진다. 농작물재해보험에서 농작물의 피해를 측정하기 위해 손해 평가사가 직접 농가 현장에 방문하여 해당 농작물의 착과량을 직접 측정한다. 하지만 이 방법은 많은 노동력과 시간이 필요하며 예측값과 실제 생산량 사이의 차이가 크다는 단점이 있다. 따라서 보다 효율적이고 정확한 과일 생산량 측정 방법의 개발이 요구된다. 최근 기술의 발전을 통해 이미지 인식 기술, 인공지능, 드론을 활용한 모니터링 시스템 등이 농업 분야에 점차 도입되고 있다. 이러한 기술들은 사람이 직접 생산량을 예측하는 전통적인 방법에 비해 훨씬 빠르고 정확한 데이터를 제공할 수 있다.

객체 탐지에 사용되는 딥러닝 알고리즘은 과일의 크기, 수량 및 상태를 식별하는 데 중요한 역할을 한다. 이 알고리즘들은 크게 2단계(Two-stage) 알고리즘과 1단계(One-stage) 알고리즘으로 나눌 수 있다. 2단계 객체 탐지 알고리즘은 먼저 후보 영역을 제안하고, 이어서 각 후보 영역에 대해 분류 및 위치 조정을 수행한다. 대표적인 예로는 R-CNN(Regions with Convolutional Neural

Network)[2]과 그 후속 작업인 Fast R-CNN[3], Faster R-CNN[4], Mask-RCNN[5] 등이 있다. 한편, 1단계 알고리즘은 객체 탐지를 위해 단일 신경망을 사용하여 후보 영역 제안과 객체 분류를 동시에 수행한다. 대표적인 예로는 YOLO(You Only Look Once)[6]와 SSD(Single Shot MultiBox Detector)[7]가 있다. 이들은 빠른 처리 속도를 자랑하며, 더 적은 계산으로도 높은 성능을 제공한다. 농업에서의 드론 기반 모니터링 시스템과 같이 실시간 데이터 처리가 요구되는 환경에서 유용하다. 최근에는 1단계 알고리즘인 YOLO 계열 알고리즘들이 향상된 최적화 기술과 새로운 네트워크 아키텍처의 도입으로 정확도 개선은 물론 고정밀 탐지가 요구되는 환경에서도 충분히 경쟁력 있는 성능을 제공하고 있다.

본 논문에서는 YOLO계열의 객체 탐지 알고리즘과 다항회귀분석을 사용한 과수별 사과의 개수를 추정하는 방법을 제안한다. 먼저 YOLO모델을 사과 이미지 데이터 세트로 훈련시켜 표면에 보이는 사과를 계수하고 이 값을 독립변수로 활용하여 실제로 사과를 계수한 데이터를 추정하는 다항회귀 방정식을 도출하여 과수의 내부에 존재하거나, 가지나 잎에 의해 보이지 않는 사과의 수까지 추정하는 사과 착과량 예측 방법을 제시한다.

## II. 배경지식

### 1. YOLO 계열 모델

객체 인식 딥러닝 모델인 YOLO는 1단계 검출 방식이며, 2단계 검출 방식 딥러닝 모델보다 인식 속도가 빠른 것이 장점이다. YOLO는 입력 이미지를 일정한 크기( $S \times S$ )의 격자 세포(grid cell)로 나눈다. 각 격자의 중앙을 중심으로 지정된 경계 상자(bounding box)의 개수를 예측한다. 예측한 경계 상자들에 신뢰도 점수(confidence score)를 평가하여 신뢰도 점수가 높은 경계 상자만 취하고 그 외의 상자들은 제거한다. 최종적으

로 신뢰도가 높은 예측 결과만이 남게 된다.

YOLOv4는 실시간 객체 탐지를 위한 고성능 딥러닝 모델로, 빠른 처리 속도와 높은 탐지 정확도를 제공한다. 이 모델은 학습 효율과 추론 성능을 동시에 최적화하기 위해 BoF(Bag of Freebies)와 BoS(Bag of Specials)를 포함한다. BoF는 훈련 과정에서 추가적인 계산 비용 없이 학습 성능을 향상시킬 수 있는 최적화 기법이고, BoS는 추론 속도를 유지하면서 탐지 정확도를 향상시키는 여러 구조적 변경과 기술을 의미한다. 또한, CSPDarknet53 백본, 다양한 데이터 증강 기법, Anchor Box 최적화 등을 통해 다양한 산업 분야에서 실시간 객체 탐지에 탁월한 성능을 발휘한다[8].

YOLOv5는 Ultralytics에서 개발된 최신 딥러닝 모델이며, PyTorch 프레임워크를 기반으로 구현되었다. YOLO v5는 다양한 버전(S, M, L, X)을 제공하여 사용자가 모델 크기, 속도, 정확도의 균형을 필요에 따라 최적화할 수 있으며, 높은 정확도와 빠른 처리 속도를 유지하면서 Mosaic, CutMix, MixUp과 같은 다양한 데이터 증강 기술을 자동으로 적용한다. 또한, YAML 구성 파일을 사용하여 사용자가 쉽게 최적의 결과를 얻을 수 있도록 지원하며, 간소화된 학습 및 추론 프로세스, 활발한 커뮤니티 지원, 뛰어난 일반화 성능, 쉽게 사용 가능한 API, 빠른 모델 추론 속도 등의 장점을 제공한다[9].

YOLOv7은 E-ELAN(Expand, shuffle, merge cardinality) 아키텍처를 도입하여 이전 모델에 비해 더 깊고 효율적인 네트워크 구조를 구현하였다. 이 아키텍처는 연산 블록(Computational block)을 확장하여 네트워크의 표현력을 증가시키고, 피쳐 맵을 그룹으로 섞어 다양한 특성 간의 상호 작용을 촉진한다. 여러 피쳐 맵 그룹을 통합하여 네트워크의 결정력을 강화하고, 최종 출력의 정확도를 높인다[10].

### 2. 다항 회귀(Polynomial Regression)

다항 회귀는 머신러닝과 통계학 등에서 사용되는 회귀 분석 방법 중 하나이며, 독립 변수들의 다항식 형태로 종속 변수를 예측한다. 다항 회귀를 통해 데이터 간 비선형 관계를 모델링 할 수 있다. 다항 회귀 모델은 식 (1)과 같다.

$$y = w_0 + w_1x + w_2x^2 + w_3x^3 + \dots + w_nx^n \quad (1)$$

여기서 종속 변수는  $y$ 를 뜻하고 독립 변수는  $x$ 이다.  $w_0, w_1, \dots, w_n$ 은 모델의 계수이다. 다항 회귀는 주어진

데이터를 모델링 하기 위해 최소 제곱법(Least Squares)을 사용하여 독립 변수들의 계수를 추정한다. 이를 통해 실제 값과 모델의 예측값 사이의 오차를 최소화하는 계수를 찾는 과정을 거친다. 다항 회귀의 다항식의 차수를 조절하여 모델의 복잡성을 조절할 수 있다. 다만, 데이터에 따라 적절한 다항식의 차수를 선택하는 것이 중요하다. 차수가 높은 다항식을 사용할 경우에 모델이 학습 데이터에만 최적화 되어 일반화가 되지 않는 현상인 과적합(Overfitting)이 발생할 수 있다. 데이터 분석, 예측, 최적화 등 다양한 분야에서 활용할 수 있다.

## III. 본론

### 1. 착과량 예측 방법

그림 1은 본 논문에서 제안하는 착과량 예측 방법의 전체 동작 순서를 보여준다. 예측 과정은 두 단계로 나뉜다. 1단계는 영상 기반 딥러닝 모델을 활용하여 추론하는 방식이다. 한 쌍의 사과나무 이미지를 딥러닝 모델에 입력하면, 딥러닝 모델은 두 이미지에서 각각 탐지된 사과의 개수를 합을 출력한다. 2단계 추론 방식은 딥러닝 모델을 통해 도출한 값을 다항회귀분석에 적용하는 방식

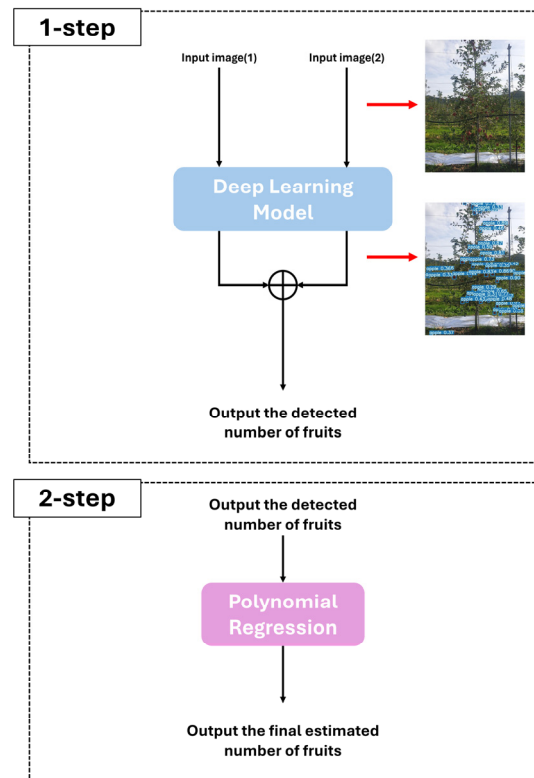


Fig. 1. Flowchart for fruit number counting. 그림 1. 제안하는 착과량 예측 방법의 흐름도

이다. 1단계 추론 방식을 거친 후 출력한 값을 독립 변수로, 실제 과수원에서 계수한 착과량의 수를 종속 변수로 지정하여 최적의 다항 회귀 방정식을 구한다. 딥러닝 모델이 한 쌍의 이미지에서 탐지한 사과 개수의 합을 다항 회귀방정식에 적용하여 산출한 값이 최종적으로 해당 사과나무에 열린 사과 개수의 예측값이 된다.

**2. 실험 및 평가**

**가. 실험을 위한 데이터 세트 구축**

사과 탐지를 위한 딥러닝 모델의 학습에 사용한 데이터는 사과가 열린 사과나무 이미지와 라벨 데이터로 구성되며, 데이터의 개수는 표 1과 같이 학습용 1,455장, 검증용 390장, 테스트용 188장으로 이루어져 있다. 다항회귀분석에 사용한 데이터 세트는 딥러닝 모델이 두 장의 사과나무 사진에서 측정한 사과 개수의 합과 과수원에서 사람이 직접 계수한 사과의 개수로 구성되어 있다. 다항회귀분석에 사용된 데이터는 학습용 93쌍과 테스트용 80으로 구성되었다.

표 2는 데이터 세트에 포함된 사과의 품종, 연생 및 이미지 데이터를 획득한 과수원의 위치 정보이다.

Table 1. Training and test dataset.

표 1. 학습 및 테스트 데이터 세트

Dataset	Training	Validation	Test
Deep Learning	1455	390	188
Regression	93		80

Table 2. Varieties and ages of apples.

표 2. 사과의 품종 및 연생 정보

No	Variety	Age	Adress
1	Fuji	6	Uiseong
2	Sinano Gold	3	Bongwha
3	Fuji	8	Andong
4	Myanmar(Fuji)	11	Cheongsong
5	Myanmar(Fuji)	8	Andong
6	Myanmar(Fuji)	5	Yeongju
7	Myanmar(Fuji)	8	Cheongsong
8	Fuji	6	Uiseong
9	Myanmar(Fuji)	15	Andong
10	Fuji, Sinano Gold	10	Cheongsong
11	Fuji	9	Andong
12	Myanmar(Fuji)	10	Mungyeong
13	Myanmar(Fuji)	5	Andong
14	Fubrax(Fuji), Miyabi(Fuji)	15	Mungyeong
15	Myanmar(Fuji)	9	Yeongju

**나. 딥러닝 모델 학습 및 평가**

딥러닝 모델 학습용 데이터는 모델이 예측을 수행하고 손실을 계산하여 가중치를 조정하는 데 사용되며, 검증용 데이터는 학습 중 모델이 학습용 데이터에 과적합이 일어나는가에 대한 여부를 확인하고 이를 조절한다. 테스트용 데이터는 학습 딥러닝 모델의 학습을 완료한 후 모델의 성능을 평가하는 과정에서 사용되는 데이터 세트이다. 딥러닝 모델의 학습과 검증에 사용되는 모든 데이터 세트는 이미지 데이터와 라벨링 데이터로 구성되었다. 이미지 데이터는 딥러닝 모델이 사과를 학습하기 위한 사과나무 사진들로 이루어져 있다. 일반적으로 JPG, PNG 등과 같은 파일 형식으로 저장된다. 딥러닝 모델은 이러한 이미지 데이터를 입력으로 받아들여 객체를 식별하고 분류한다. 라벨링 데이터는 주로 XML, JSON, 텍스트 등의 형태로 저장된다. 이미지 내 식별해야 할 객체의 종류인 클래스(Class)와, 객체의 위치를 나타내는 바운딩 박스(Bounding box)의 정보를 담고 있다. 해당 연구에서 구성된 객체의 클래스는 apple이며 사과나무 이미지 내 사과의 위치만을 찾아 바운딩 박스를 정의하고 텍스트 파일 형태로 저장하였다. 그림 2는 데이터 세트의 라벨링 과정을 보여준다. 준비된 학습용과 검증용 이미지 데이터는 YOLO mark를 사용하여 라벨링 작업을 하였다. 사과 객체에 대하여 'apple' 클래스를 정의하고, 이미지 내에서 사과나무에 달린 사과 영역만 라벨링하였다.




Fig. 2. Labeling process for training dataset.

그림 2. 데이터 세트 라벨링 과정



딥러닝 모델의 학습 및 테스트를 진행한 하드웨어 환경은 2개의 NVIDIA RTX A5000이며, 소프트웨어 환경은 Ubuntu 20.04, CUDA 12.2, CUDNN 8.9.1, OpenCV 4.8.0. Python 3.11.3이다. YOLOv4, YOLOv5, YOLOv7 세 모델 모두 동일한 환경 및 학습 조건으로 학습을 진행하였다. 딥러닝 모델을 학습한 후 모델의 성능 평가를 진행하여 각 모델의 성능을 비교하였다.

성능 평가의 기준으로 MAE, Precision, Recall, AP, F1-score을 사용하였다. MAE(Mean Absolute Error)는 예측값과 실제값의 차이를 절댓값으로 계산한 후, 이를 평균한 값이다. 예측 오차의 크기를 나타내며 모든 예측값에 대해 절댓값을 취하기 때문에 양수와 음수의 오차를 모두 고려한다는 특징이 있다. MAE가 낮을수록 모델의 예측 성능이 높다고 할 수 있다. 정밀도(Precision)는 모델이 긍정(Positive)로 예측한 것 중 실제로 긍정인 샘플의 비율을 나타낸다. 즉, 정밀도는 모델이 정답으로 클래스로 예측한 결과 중 실제로 정답인 클래스에 속하는 비율을 의미한다. 재현율(Recall)은 실제 긍정인 샘플 중 모델이 정확하게 긍정으로 예측한 비율이며, 모델이 정답 클래스에 속하는 샘플들 중에서 얼마나 많은 샘플을 식별한 것인지 측정하는 것이다. AP(Average Precision)는 객체 검출 모델의 성능을 측정하는 지표이다. Precision-Recall 곡선 아래의 면적을 계산하여 얻는다. Precision-Recall 곡선은 모델이 임계값(threshold)에 대해 얼마나 잘 수행되었는지 보여주는 그래프이다. 정밀도(Precision)는 모델이 찾은 Positive 중 실제 양성인 비율을 나타내며, 재현율(Recall)은 실제 양성 중 모델이 찾은 양성인 비율을 나타낸다. Precision-Recall 곡선은 이 두 지표 간의 트레이드오프를 시각화한다. AP가 높을수록 모델의 성능이 우수하다고 할 수 있다. F1-score는 Precision과 Recall이 균형을 이룰 때 가장 높은 값을 가지며 높을수록 모델의 성능이 좋다고 해석할 수 있다.

표 2에서 YOLOv4의 MAE는 21.66, YOLOv5는 24.91, YOLOv7이 29.35이며 YOLOv4가 가장 우수함을 보였다. 다만, Precision에서는 순서대로 각각 0.56, 0.943, 0.936으로 YOLOv5가 가장 높은 Precision을 나타냈다. Recall에서 YOLOv4가 0.83으로 가장 낮은 결과를 보여주었고 YOLOv5와 YOLOv7은 0.84로 동일한 결과를 나타내었다. AP에서는 순서대로 0.77, 0.79, 0.75이며 YOLOv5가 0.793으로 세 모델 중 가장 높은 AP를 보여주었다. 다만, 세 모델의 AP가 전체적으로 낮은 것을 확인할 수 있다. 사과나무의 사과가 지나 앞 등에 가려지는 폐색 영역이 많기 때문이다. 이는 영상 처

리 딥러닝에서 공통적으로 발생하는 문제이다. 마지막으로 F1-score도 마찬가지로 YOLOv5가 0.75로 가장 우수한 값을 도출하였다. 성능 평가 기준을 종합적으로 평가한 결과, 사과 탐지에 가장 적합한 모델은 YOLOv5임을 확인하였다.

Table 3. Result of tested YOLO models

표 3. YOLO 모델별 테스트 결과

Model	MAE	Precision	Recall	AP	F1-score
YOLOv4	21.66	0.56	0.83	0.77	0.67
YOLOv5	24.91	0.943	0.84	0.79	0.75
YOLOv7	29.35	0.936	0.84	0.75	0.74

다. 다항 회귀 적용 및 평가

사과나무 이미지 한 장과 딥러닝 모델만을 이용하여 사과나무의 착과량을 예측하는 것은 어려운 일이다. 그림 3을 보면 사과나무 이미지에서 두 사과의 간격이 좁아 겹쳐 보여 두 개가 아닌 한 개의 사과로 인식하는 경우와 딥러닝 모델이 사과로 인식할 수 없을 만큼 다른 잎들에 의해 가려지는 문제가 있다. 또한 사과가 실제로 존재하지만 과수의 내부에 있어 영상에 보이지 않거나 과수의 반대편에 존재하여 한 면을 촬영한 영상만으로는 관측하기 힘든 경우를 확인할 수 있다. 이러한 폐색 영역 요소는 사과나무 영상에서 흔하게 볼 수 있는 현상이다. 따라서, 과수의 양면을 촬영한 영상으로부터 보이는 사과의 개수를 정확히 예측할 필요가 있으며 과수 내부에 존재하여 사진으로는 보이지 않는 과일을 계수하기 위한 추가적인 예측 단계가 필요하다.




Fig. 3. When deep learning models incorrectly recognize apples.

그림 3. 딥러닝 모델이 사과를 부정확하게 인식하는 경우

따라서 본 연구에서는 가장 우수한 성능을 보인 YOLO v5 모델을 활용하여 과수별 양면 영상으로부터 각 나무의 전체 사과 개수를 예측하고, 이를 독립 변수로 사용하여 실제 계수한 사과 개수의 참값과의 관계를 다항 회귀

분석을 통하여 예측하는 방법을 제안하였다.

다항 회귀 분석에서는 독립 변수의 차수를 결정하는 것이 중요하다. 독립 변수의 차수가 너무 높다면 모델에 과적합이 발생할 수 있으며 반면에 차수가 너무 낮아지면 데이터의 비선형 관계를 정확하게 모델링을 하지 못할 수 있다. 따라서, 착과량 예측에 적합한 다항 회귀 방정식의 차수를 구하기 위해 착과량 데이터를 이용하여 2차부터 5차까지 다항 회귀를 구한 후 검증을 통해 가장 적합한 다항 회귀식을 도출하였다.

동일한 사과나무의 앞면 영상과 뒷면 영상을 각각 YOLOv5 모델에 입력하여 사과 개수 탐지를 실행한다. 앞면 영상에서 탐지된 사과 개수와 뒷면 영상에서 탐지된 사과의 개수를 합한다. 이 값을 다항 회귀의 독립 변수인  $x$ 로, 해당 사과나무의 실제 착과량 수를 종속 변수인  $y$ 로 지정하였다.

총 93개의 딥러닝 모델 탐지 수( $x$ ) 및 실제 착과량 수( $y$ ) 데이터를 통해 2차부터 5차까지 사과 착과량 예측에 관한 다항 회귀 방정식을 구한 식은 식(2)~(5)와 같으며, 다항 회귀 모형은 그림 4와 같다.

$$y = 107 - 0.259x + 0.00329x^2 \quad (2)$$

$$y = -64.4 + 2.739x - 0.01346x^2 + 0.00002997x^3 \quad (3)$$

$$y = 46.2 + 0.168x + 0.008254x^2 - 0.00004897x^3 + 0.0000001042x^4 \quad (4)$$

$$y = 1748.4 - 49.7077x + 0.577829x^2 - 0.00321781x^3 + 0.00000869483x^4 - 0.00000000908219x^5 \quad (5)$$

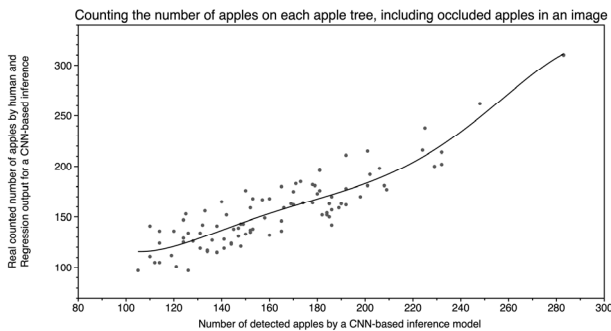


Fig. 4. Polynomial regression model for estimation of apple number.

그림 4. 착과량 예측 다항 회귀 모형

2차부터 5차까지 사과 착과량 예측에 대한 다항 회귀 방정식을 구한 후, 실제 착과량과 가장 근접한 식을 선별 하도록 성능 평가 실험을 진행하였다. 그림 5는 2차부터

5차까지 오차를 구한 후, 그 값을 표현한 그래프이다. 2차 방정식의 오차는 9.13%, 3차 방정식은 9.018%, 4차 방정식은 9.016%, 5차 방정식은 9.043%로 나타났다. 따라서, 가장 오차가 낮은 식은 4차 다항 회귀 방정식임을 확인하였다.




Fig. 5. Error ratio comparison according to degree of polynomial for regression.

그림 5. 다항 회귀를 위한 함수의 차수에 따른 오차 비교

4차 방정식에 대해 추가로 MAE와  $R^2$ -score를 이용하여 성능 평가를 진행하였다.  $R^2$ -score(R-squared)란 회귀 분석 모델의 성능을 측정하는 지표이다. 모델이 주어진 데이터에 얼마나 적합한지 측정하며, 0에서 1 사이의 값을 가진다. 결과가 1에 가까울수록 모델이 데이터에 대하여 연관성이 높다고 해석한다.

다음 표는 YOLOv5와 4차 다항 회귀 방정식을 결합한 착과량 예측 기법의 최종 성능 평가 결과이다. 제안된 기법을 오직 YOLOv5만을 사용한 방법과 성능을 비교하였다. 표 1에서 제시된 다항 회귀 데이터 세트 중에서 테스트용 데이터 세트 80개로 해당 성능 평가를 진행하였다.

Table 4. Performance evaluation of the proposed method.

표 4. 제안된 방법의 성능 평가

Model	MAE	$R^2$ -score	Accuracy(%)
YOLOv5+Polynomial Regression	13.64	0.792	90.98
YOLOv5	74.82	-3.86	52.1

제안된 기법의 MAE는 13.64를 나타내며, 이를 해석하자면 실제 착과량과 제안한 예측 기법으로 예측한 착과량 사이의 평균적인 차이가 13.64개임을 해석한다. 연구에 사용된 착과량 데이터의 평균 착과량 수가 156임을 고려하면 이는 제안된 기법이 실제 값과 유사하다고 볼 수 있다. 반면, YOLOv5만 사용하여 착과량을 예측하였을 때 MAE는 74.82이다. 제안한 방법이 딥러닝 모델만 적용하였을 때보다 오차를 현저하게 줄인 것을 확인할

수 있었다.  $R^2$ -score의 값은 각각 0.792와 -3.86을 나타내었고 이 값은 제안된 기법이 약 79%의 종속 변수 변동을 설명한다는 것을 의미한다.  $R^2$ -score가 1에 가까우므로 착과량 데이터에 관하여 제안된 기법이 연관성이 높다고 볼 수 있다. YOLOv5만으로 예측했을 때 음수의 값이 도출되는 것을 확인했다. 이는 모델이 데이터의 평균값보다도 못할 시 나타난다. 즉, YOLOv5만을 사용한다면 실제 착과량과 연관성이 매우 낮음을 알 수 있다. 정확도 평가에서 제안된 기법은 90.98%를 도출했다. 반면, 딥러닝 모델만을 사용하여 예측하였을 때 정확도는 52.1%이다. YOLOv5에 다항 회귀 기법을 활용한 기법이 오직 YOLOv5만을 사용한 기법보다 38.88% 높게 나타났다.

#### IV. 결론

농업에서 착과량은 농산물의 품질을 높이고 생산량을 예측할 수 있으며, 농산물 재해 보험으로부터 피해 손실을 파악하는 등의 중요한 정보이다. 본 논문에서는 사과 나무의 이미지 정보를 통해 사과의 착과량을 예측할 수 있는 두 단계로 설계된 방법을 제시했다. 1단계는 딥러닝 모델로 사과나무의 앞, 뒷면 이미지를 딥러닝 모델에 입력하여 각 이미지 내에 존재하는 사과의 개수를 출력 후 두 값을 더한다. 2단계는 딥러닝 모델이 출력한 값을 다항 회귀의 독립 변수로, 방정식을 통해 출력된 착과량의 예측값을 종속 변수로 정의하였다. 1단계와 2단계를 모두 거친 최종 착과량 예측값은 90.98%의 정확도를 보였다.

해당 연구를 통해 수작업으로 이루어지는 착과량 계산 방법에서 소요되는 인력과 시간 비용을 절감할 수 있으며 착과량 예측 관련 연구에서 새로운 기반 기술로 활용할 수 있음을 기대한다. 향후 연구 방향으로는 사과의 종별로 딥러닝 모델의 학습용 데이터 세트와 다항 회귀를 구성하기 위한 학습용 데이터 세트 및 다항 회귀의 성능을 도출하기 위한 테스트용 데이터 세트를 추가로 확보하여 사과의 종에 따른 착과량 예측 모델의 개발이 필요하다고 판단된다.

#### References

[1] Yıldırım, Şahin and Burak Ulu, "Deep learning based apples counting for yield forecast using

proposed flying robotic system," *Sensors* 2023, 23(13), 6171, 2023.

DOI: <https://doi.org/10.3390/s23136171>

[2] Ross Girshick, Jeff Donahue, Trevor Darrell and Jitendra Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 580-587, 2014.

DOI: <https://doi.org/10.48550/arXiv.1311.2524>

[3] Ross Girshick, "Fast R-CNN," In *Proceedings of the IEEE international conference on computer vision*, pp.1440-1448, 2015.

DOI: <https://doi.org/10.48550/arXiv.1504.08083>

[4] Shaoqing Ren, Kaiming He, Ross Girshick and Jian Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *Advances in neural information processing systems*, 28, 2015.

DOI: <https://doi.org/10.48550/arXiv.1506.01497>

[5] Kaiming He, Georgia Gkioxari, Piotr Dollár and Ross Girshick, "Mask R-CNN," In *Proceedings of the IEEE international conference on computer vision*, pp.2961-2969, 2017.

DOI: <https://doi.org/10.48550/arXiv.1703.06870>

[6] Joseph Redmon, Santosh Divvala, Ross Girshick and Ali Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.779-788, 2016.

DOI: <https://doi.org/10.48550/arXiv.1506.02640>

[7] LIU, Wei, et al. "Ssd: Single shot multibox detector," In *Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14*, Springer International Publishing, p. 21-37, 2016.

DOI: <https://doi.org/10.48550/arXiv.1512.02325>

[8] Bochkovskiy, Alexey, Chien-Yao Wang, and Hong-Yuan Mark Liao. "Yolov4: Optimal speed and accuracy of object detection," arXiv preprint arXiv:2004.10934 (2020).

DOI: <https://doi.org/10.48550/arXiv.2004.10934>

[9] "Comprehensive Guide to Ultralytics YOLOv5,"

<https://docs.ultralytics.com/yolov5/>

[10] Wang, Chien-Yao, Alexey Bochkovskiy, and Hong-Yuan Mark Liao, "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors." *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pp.7464-7475, 2023.

DOI: <https://doi.org/10.48550/arXiv.2207.02696>

## BIOGRAPHY

### Hee-Jin Gwak (Member)



2023 : BS degree in Computer Engineering, Andong National University.

2023~Present : MS student in school of Computer Engineering, Andong National University.

### Yunju Jeong (Member)



1991 : BS degree in Computer Statistics, Andong National University.

2000 : MS degree in Computer Engineering, Andong National University.

2019 : PhD degree in Computer Engineering, Kyungpook National Univ.

2019~2023 : Teaching assistant professor in SW Convergence Education Center, Andong National Univ.

2024~Present : Teaching assistant professor in SW Expert Training Center, Andong National Univ.

### Ik-Jo Chun (Member)




1995: BS degree in Horticulture, Kangwon National University.

1997: MS degree in Horticulture, Kangwon National University.

2000: PhD degree in Pomology, University of Idaho.

2003~Present : Professor, Research Pomology, Andong National University.

### Cheol-Hee Lee (Member)



1995 : BS degree in School of Electronic and Electrical Engineering, Kyungpook National Univ.

1997 : MS degree in Electronic Engineering, Kyungpook National Univ.

2000 : PhD degree in Electronic Engineering, Kyungpook National Univ.

2000~2003 : Full-time lecturer, in Dept. of Computer Engineering, Kyungwoon Univ.

2003~Present : Professor, Dept. of Computer Engineering, Andong National Univ.