

YOLOv3을 이용한 과일표피 불량검출 모델: 복숭아 사례

Detection Model of Fruit Epidermal Defects Using YOLOv3: A Case of Peach

이 희 준 (Hee Jun Lee)	계명대학교 대학원 경영정보학과 석사과정
이 원 석 (Won Seok Lee)	계명대학교 대학원 경영정보학과 석사과정
최 인 혁 (In Hyeok Choi)	계명대학교 대학원 경영정보학과 석사과정
이 충 권 (Choong Kwon Lee)	계명대학교 경영정보학전공 교수, 교신저자

요 약

농가를 운영함에 있어서 수확한 작물에 대한 품질을 평가하여 불량품을 분류하는 작업은 매우 중요하다. 그러나, 농가는 부족한 자본과 인력으로 인하여 품질평가에 소요되는 비용과 시간을 감당하는데 어려움이 있다. 이에 본 연구는 인공지능 기술인 딥 러닝 알고리즘을 이용하여 과일의 표피를 분석함으로써 불량을 검출하고자 한다. 과일을 촬영한 동영상 이미지에 대하여 영역기반 합성곱 신경망(Region Convolutional Neural Network)을 기반으로 한 YOLOv3 알고리즘을 적용하여 표피를 분석할 수 있는 모델을 개발하였다. 총 4개의 클래스를 정해서 학습을 진행하였고, 총 97,600번의 epoch을 통해서 우수한 성능의 불량검출 모델을 얻을 수 있었다. 본 연구에서 제안한 농작물 불량검출 모델은 데이터 수집, 분석된 데이터를 통한 품질평가, 그리고 불량검출에 이르는 과정의 자동화에 활용될 수 있다. 특히, 농작물들 중에서도 외상에 가장 취약한 복숭아를 대상으로 분석모델을 개발하였기 때문에, 다른 작물에도 적용될 수 있을 것으로 기대된다.

키워드 : 복숭아, 불량검출, 스마트 팜, 영역기반 합성곱 신경망, YOLO

I. 서 론

4차 산업혁명이 도래하면서 생산은 노동이나 자본 집약적 구조에서 기술 중심으로 변화하고 있다. 특히, 제조업에서는 빅데이터와 인공지능 기술을 이용한 스마트 팩토리가 등장하면서 노동력에 의존했던 공정에서 다양한 형태의 자동화가 가능하게 되었다. 이러한 스마트 팩토리는 공정에서

컴퓨터 제어, 빅데이터, 인공지능, 로봇 등을 적용하여 생산성을 향상시키는 것이다. 제조업에서 주로 활용되고 있는 스마트 팩토리 기술을 농업에 적용한 스마트 팜이 최근에 부각되고 있다.

현재 한국의 농업분야는 농촌인구의 고령화와 감소로 인하여 심각한 노동력 부족에 직면하고 있고, 장필성(2017)은 대량의 데이터를 수집, 분석함으로써 데이터 기반 농업으로의 전환이 필요하다고

하였다. 농업분야에도 4차 산업혁명의 자동화 기술들을 이용하여 스마트 팜을 구축하면 노동력 부족 문제를 해결할 수 있을 것이라 기대되고 있다. 제조업과 마찬가지로 생산의 전 과정에서 완전한 자동화가 아닌 농부의 작업이나 판단을 보조하는 형태로 기술의 발전이 나타나고 있다.

본 연구에서는 인공지능의 딥 러닝 기술을 활용하여 농작물의 품질관리 활동을 개선하고자 하였다. 농가에 있어서 수확물에 대한 품질평가는 매우 중요한 활동이지만, 부족한 자본과 인력 때문에 소요되는 비용과 시간을 감당하기 어려운 상황이다. 농가에서 재배되는 농작물은 매우 많고 작물마다 발생하는 불량률의 종류 또한 다양하다. 본 연구에서는 여러 가지 농작물들 중에서 복숭아 불량률 검출하는 모델을 만드는 것을 목표로 하였다. 딥 러닝 알고리즘들 중에서 영역기반 합성곱 신경망 (Region Convolution Neural Network, R-CNN)을 기반으로 한 YOLOv3 알고리즘을 이용하여 복숭아의 불량률 검출할 수 있는 모델을 개발함으로써 농작물의 품질관리에 도움이 되고자 한다.

II. 관련 연구

2.1 농업과 정보기술의 융합

농업과 정보기술의 융합은 제조업보다 기술발전의 초기 단계에 있지만, 최근에 가장 연구가 활발한 분야는 스마트팜 분야이다. 농업공동체에서 정보기술 수용에 대한 요인 분석 연구가 이루어지고 있으며, 4차 산업 혁명과 같이 급변하는 인터넷 환경이 정보기술 수용에 영향을 주고 있다(윤철호, 박창희, 2018).

농업에서 발생하는 데이터를 수집, 분석하여 생산성을 향상하려는 시도가 진행되고 있고, 스마트팜을 구현한 사례들도 제시되고 있다(김상철, 2017; 김영상, 유성민, 2017). 예를 들어, 비닐하우스로부터 발생하는 빅데이터를 학습하고 인공지능을 이용하여 최적온도를 예측하여 관리함으로

써 사용되는 전력을 절약할 수 있는 지능형 그린하우스 제어시스템을 개발하였다(신현엽 등, 2018).

세계 1위의 농기계 제조업체인 미국의 John Deere는 치열해지는 농기계 시장에서 경쟁력을 확보하기 위하여 네트워크로 연결된 농기계 개념을 도입하여 농기계에 부착된 센서를 통해 다양한 정보를 실시간으로 수집하여 축적된 데이터를 이용한 서비스를 제공하기 시작했고, 트랙터에서 수집되는 이미지를 분석하여 잡초를 판별하는 기술을 선보이기도 하였다(최영찬, 장익훈, 2019).

IT Portfolios를 농업에 적용한 연구도 이루어지고 있다(Kim *et al.*, 2017). 곡물 농장, 과일 농장, 채소 농장 등에서 수집한 데이터를 바탕으로 IT Portfolios를 적용하여 연구한 결과, 높은 수확량을 보이는 과일 농가에서 정보와 품질 향상이 중요한 요소인 것으로 나타났다.

과일 분야에서는 과일의 색과 크기를 측정하여 그 과일이 오렌지인지 자몽인지를 알아내는 데 인공지능 기술이 활용되고 있다(문성은 등, 2016). 과일의 색상과 무게 데이터를 사물인터넷 센싱 기술을 사용하여 수집하고, 빅 데이터 기술을 사용하여 수확과 상관관계가 높은 인자를 파악하여 영역별 불량 정도를 판단함으로써 검색된 불량영역을 집중적으로 관리할 수 있는 아키텍처 모델을 제시하였다(오정원, 김행근, 2017). 빛의 세기를 전기신호로 바꾸어 주는 CCD(Charge Coupled Device) 카메라를 이용하여 과일의 외부 품질인 크기 및 색상을 판단하는 실시간 분류 시스템을 구성하였다(Kamilaris *et al.*, 2017).

과일 중에서도 복숭아는 다른 작물에 비해 외상에 취약하여 발생할 수 있는 불량률의 종류가 다양하다. 따라서 수확된 복숭아의 품질을 유지하고 관리하기 위하여 환경변화(이혜림, 윤광섭, 2012), 화학적 처리(엄향란 등, 2009), 저장(장주희 등, 2012; 정미진 등, 2013), 포장(권기만 등, 2013) 등과 같은 다양한 연구가 있었다. 이러한 연구에도 불구하고 외상에 취약한 복숭아의 특성 때문에 완벽한 품질관리는 불가능에 가깝고 유통되기 전에

불량품을 확인하는 것이 매우 중요하다.

2.2 객체 인식 연구


기존의 객체 인식에 관한 연구는 SIFT(Scale Invariant Feature Transform), SURF(Speeded-Up Robust Features) 등과 같이 객체의 특징을 통해 검출하는 방식으로 진행되었다(Bay *et al.*, 2006; Lowe, 2004). 2012년 ImageNet Challenge에서 합성곱 신경망(CNN: Convolutional Neural Network)이 기존 알고리즘보다 뛰어난 성능을 보이면서 DNN(Deep Neural Network)을 활용한 연구가 활발히 진행되었다(Krizhevsky *et al.*, 2012). 초기 딥러닝을 활용한 객체 검출 방식은 Sliding Window 방식으로 다양한 Scale의 Window를 차례대로 이동시키며 DNN으로 객체가 있을 만한지에 대한 점수를 계산하였다(Szegedy *et al.*, 2013). 그러나 Sliding window 방식에는 연산량이 많고 시간이 오래 걸리는 단점이 존재한다. R-CNN(Region with CNN)은 이미지로부터 객체가 존재할 적절한 위치를 Bounding Box Proposal을 생성하고 이를 CNN에 적용하는 방식을 사용하면서 Sliding window 방식의 모든 경우의 수를 생각하는 것보다 연산량이 다소 줄어들게 되었다(Girshick *et al.*, 2014). 그 이후에도 R-CNN이 모든 Region Proposal을 CNN에 넣어 연산하는 병목현상(Bottleneck)을 해결하기 위해 Fast R-CNN, Faster R-CNN이 등장하였다(Girshick, 2015; Ren *et al.*, 2015). 또한 YOLO(You Only Look Once)는 객체 인식 속도를 실시간에 가깝게 발전시켰다(Redmon *et al.*, 2016). YOLO의 첫 번째 모델이 제시된 이래로 YOLOv2(YOLO9000: Better, Faster, Stronger), YOLOv3

까지 제시되었다(Redmon and Farhadi, 2017; Redmon, 2018). YOLOv2에서는 기존 YOLO가 고해상도의 이미지에서 작동하기 어려운 점을 Classification net을 먼저 학습시키는 방식으로 해결하였다. 또한, Bounding Box를 예측할 때 처음부터 직접 예측하지 않고 초기 학습 데이터로부터 적당한 Anchor Box의 조깃값을 사용하여 예측함으로써 성능을 향상했다. YOLOv3는 YOLOv2를 바탕으로 향상된 모델로 YOLOv2가 이미지 내 크기가 작은 객체를 검출하기 어려운 점을 해결하기 위해 3개의 다른 스케일의 예측 Bounding Box를 사용하여 예측한다. 그리고 예측할 때 Softmax Cross Entropy 대신 Binary Cross Entropy를 Multi-Classification에 적용함으로써 좀 더 복잡한 Domain에 대한 예측성능을 높였다(Benjdira *et al.*, 2019).

III. 연구방법

3.1 YOLO 모델

본 연구에서는 YOLO Model 중에서 가장 최근에 제시된 YOLOv3를 사용하였다. YOLO Model은 다양한 R-CNN 알고리즘 중에서 뛰어난 처리 속도와 준수한 성능을 보여준다(Redmon *et al.*, 2016; Mandal *et al.*, 2019). 본 연구에서는 과일 표피로부터 불량을 검출하는 모델을 통해 농업 종사자들에게 불량을 검출하는데 소요되는 시간과 비용을 줄이는 데 도움을 주고자 하였다. 따라서 추후 과일 선별기와 시스템 연동에 대한 필요성도 있기 때문에 실시간에 가까운 처리속도를 위해 YOLOv3를 사용하였다. <그림 1>은 YOLOv3가



<그림 1> 객체 검출 과정

객체를 검출하는 과정을 나타낸 것이다. YOLOv3는 입력된 이미지에 대하여 격자 모양의 $S \times S$ 의 그리드 사각형으로 영역을 구분하고 한 개의 사각형 당 총 B개의 영역을 지정하고, 각 영역에 대하여 클래스의 확률을 예측한다.

각 영역은 식 (1)과 같은 confidence score를 가지고, 식 (2)과 같이 검출하고자 하는 클래스들에 대한 조건부 확률을 가지고 있다. 최종 학습된 모델은 지정한 임계치보다 높은 confidence score를 가지는 영역에 대해서 조건부 확률이 제일 높은 클래스로 분류하게 되는 것이다. YOLO model에 weight가 학습되는 방식은 오차함수를 나타내는 식 (3)으로 설명할 수 있다. 식 (3)에서 (x, y) 는 예측 영역의 중심 좌표를 의미하고 (w, h) 는 예측 영역의 넓이와 높이를 의미한다. $l_{i,j}^{obj}, l_{i,j}^{nobj}, l_i^{obj}$ 에

서 $obj, nobj$ 는 객체가 존재함과 존재하지 않음을 의미하고 i, j 는 각각 그리드 사각형과 예측 영역을 의미한다. C_i 는 confidence score를 $\lambda_{coord}, \lambda_{nobj}$ 는 loss의 균형을 맞추기 위한 balancing 파라미터로 각각 balance rate coord, balance rate nocoord를 나타내고 $P_i(c)$ 는 그리드 사각형 i 에 대한 클래스 c 의 조건부 확률을 의미한다. 오차함수를 통해 YOLO는 검출하고자 하는 객체의 실제 영역과 예측 영역 간의 중심 좌표와 넓이와 높이의 차가 최소가 되도록 하며 객체가 존재하는 영역과 존재하지 않는 영역의 confidence score 차가 최소가 되도록 가중치를 학습함을 알 수 있다. YOLOv3에서 사용된 Net 아키텍처는 Darknet-53으로 YOLOv2에서 사용하던 Darknet-19에서 확장된 구조이다. Darknet-53은 총 53개 층으로 이루어져 있으며 아키

〈표 1〉 Darknet-53 아키텍처

	Type	Filters	Size	output
	Convolutional	32	3×3	256×256
	Convolutional	64	3×3/2	128×128
1×	Convolutional	32	1×1	
	Convolutional	64	3×3	
	Residual			128×128
	Convolutional	128	3×3/2	64×64
2×	Convolutional	64	1×1	
	Convolutional	128	3×3	
	Residual			64×64
	Convolutional	256	3×3/2	32×32
8×	Convolutional	128	1×1	
	Convolutional	256	3×3	
	Residual			32×32
	Convolutional	512	3×3/2	16×16
8×	Convolutional	256	1×1	
	Convolutional	512	3×3	
	Residual			16×16
	Convolutional	1024	3×3/2	8×8
4×	Convolutional	512	1×1	
	Convolutional	1024	3×3	
	Residual			8×8
	Avgpool		Global	
	Connected		1000	
	Softmax			

텍처의 구조는 <표 1>과 같다. 기존의 Darknet-19에서 최신 알고리즘이 반영된 요소가 부족함을 판단하여 Residual Block에 대한 부분이 추가된 구조이다. Residual Block은 ResNet에서 제시된 방법으로 Layer를 통과한 값에 Layer에 입력되는 값을 직접적으로 더해줌으로써 Layer를 통과하면서 발생하는 정보의 손실을 줄여주는 방법이다(He *et al.*, 2016). YOLOv3에서는 Darknet-53의 아키텍처를 두 개를 쌓아 총 106개의 Layer를 활용하여 학습하게 된다. Model내에 사용된 Net의 크기가 이전보다 훨씬 복잡하고 커지면서 성능이 향상되었으나 속도가 조금 느려진 면이 있다.


본 연구에서는 YOLOv3를 구현한 많은 프로그램들(Tensorflow, Keras, Pytorch 등) 중에서 YOLO 공식 홈페이지(<https://pjreddie.com/darknet/yolo/>)에서 공개하고 있는 Darknet 프로그램을 사용했다.

$$\text{Confidence Score: } \Pr(\text{Object}) \times IOU_{pred}^{truth} \quad (1)$$

Conditional Class Probability:

$$\Pr(\text{Class}_i | \text{Object}) \quad (2)$$

$$\begin{aligned} \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B \Pi_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \\ + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B \Pi_{ij}^{obj} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] \\ + \sum_{i=0}^{S^2} \sum_{j=0}^B \Pi_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B \Pi_{ij}^{noobj} (C_i - \hat{C}_i)^2 \end{aligned} \quad (3)$$



<그림 2> IOU 계산 예시

3.2 평가방법

객체검출 모델의 성능을 평가하기 위한 여러 지표들 중에서 본 연구에서는 IOU(Intersection Of Union), 재현율(Recall), AP(Average Precision), MAP(Mean Average Precision)의 지표를 사용하였다. IOU는 사물에 존재하는 실제 위치를 나타내는 실제 영역과 모델이 객체가 있다고 예측한 영역 간에 겹치는 정도가 얼마나 되는지를 평가한다. IOU가 계산되는 방식은 식 (4)으로 나타낼 수 있다. B_{gt} 는 객체가 있는 실제 영역, B_q 는 모델이 예측한 영역을 나타낸다. 식 (4)를 통해서 B_{gt} 와 B_q 의 넓이를 합한 것 중에서 겹치는 영역이 얼마나 되는지 계산한다. <그림 2>는 IOU가 계산되는 과정을 표현한 것이다.

$$IOU = \frac{B_{gt} \cap B_q}{B_{gt} \cup B_q} \quad (4)$$

재현율과 정밀도는 실제 검출 대상 중에서 검출에 성공한 비율이 얼마나 되는지와 검출 대상과 모델이 예측한 객체가 실제와 일치하는 정도를 나타낸다. 재현율과 정밀도는 반비례 관계에 있기 때문에, Threshold 조정에 값이 바뀐다. 따라서 모델의 전반적인 성능을 구하기 위해서 AP와 MAP를 사용한다. AP는 각 검출 Class마다 Threshold를 조정하면서, 재현율-정밀도 그래프를 그린 후 그 면적을 계산한다. MAP는 Class마다 구한 AP에 대해서 전체 평균을 낸 것을 의미한다.

3.3 실험

3.3.1 데이터 수집 및 전처리

경상북도 상주에 위치한 복숭아 농가에서 복숭아 사진 1,230장(3GB)과 동영상 12개(523MB)를 수집하였다. 전문가의 의견을 바탕으로 수집된 복숭아 사진에 대하여 총 4개의 클래스를 정의하였다. 4개의 클래스는 불량을 의미하는 부패, 스크래치, 변색과 복숭아 꼭지로 구성된다. 부패는 병충해로 인하여 발생하고, 스크래치는 외상에 의해 발생하는 상처이며, 변색은 부패 또는 스크래치가 생긴 과일에서 나오는 과즙에 의해 색이 변한 것을 의미한다. 복숭아 꼭지는 생김새가 부패와 유사하여 학습된 모델이 오분류를 일으킬 가능성이 있기 때문에 검출할 클래스로 포함시켰다. <그림 3>은 각 클래스에 대한 복숭아 상태를 나타내는데, 좌측 상단은 꼭지, 우측 상단은 부패, 좌측 하단은 스크래치, 그리고 우측 하단은 변색이 발생한 사진을 보여주고 있다.



<그림 3> 검출 클래스 예시

R-CNN모델은 지도학습의 일종으로서 각 이미지에 대하여 영역에 대한 검출과 클래스에 대한 예측을 동시에 수행한다. 모델 학습 전에 각 이미지에 대해, 검출할 영역에 대한 좌표를 정의해야

하고, 정의된 영역에 대한 클래스를 설정해야 한다. Annotation은 지도학습을 위해 이미지에 대하여 검출할 부분의 클래스와 영역을 직접 표시해주는 데이터 전처리 작업이다. 본 연구에서는 수집한 모든 이미지에 대하여 Annotation을 진행하였다.

전체 수집된 데이터 중 사진 1,230장은 훈련용 데이터로 사용하였고 동영상 12개로부터 500장의 사진을 추출하여 검증용 데이터로 사용하였다. 훈련용과 검증용 데이터 모두 Annotation작업을 적용하였고 각 데이터의 검출 클래스에 대한 비율은 <표 3>과 같다.

<표 2> 훈련용 데이터셋

훈련용 : 1230장		
Class	개수	비율
꼭지	696	28.95%
변색	382	15.89%
부패	922	38.35%
스크래치	404	16.81%
합계	2,404	100.00%

<표 3> 검증용 데이터셋

검증용 : 500장		
Class	개수	비율
꼭지	165	26.57%
변색	147	23.67%
부패	240	38.65%
스크래치	69	11.11%
합계	621	100.00%

3.3.2 파라미터 설정

본 연구에서 <표 4>와 같이 YOLOv3 모델에 대한 파라미터를 설정하였다. Batch size는 YOLO 모델이 한 번에 학습 할 때 즉, 1 iteration 때 사용할 데이터의 양을 의미한다. Subdivision(mini-batch)은 한 Batch size내의 데이터를 지정된 수만큼 분할하여 GPU로 보내서 나누어 처리 하는 것을 의미한다. 본 연구에서는 Batch size를 64, Subdivision

(mini-batch)은 8로 지정했다. 예를 들어, 훈련 데이터의 수가 128개일 때, 1 epoch 과정에 총 2번의 iteration을 수행하고 1 iteration을 처리할 때 Batch size 64개를 8등분으로 나누어 GPU로 보내서 처리하는 것이다. Max epoch size는 모델을 학습할 때에 최대 epoch 횟수를 제한하는 데 사용된다. Max epoch size를 100,000으로 제한하고, 학습 도중 recall과 IOU가 97,600 epoch에서 일정 수준으로 수렴하여 학습을 중단하였다. 모델 학습 시 GTX Titan×12G GPU를 통해 97,600 epoch 동안 86시간이 소요되었다. Momentum은 딥러닝 모델의 경사하강법(gradient descent)을 통한 학습과정을 최적화해주는 방법으로 누적된 과거 gradient가 지향하고 있는 어떤 방향을 현재 gradient에 일부를 적용하여 올바른 방향으로 학습되도록 도와주는 역할을 한다. Momentum은 0.9로 과거의 누적된 gradient가 반영된 비율을 제한해 주었다. Learning rate는 딥러닝 모델이 학습과정에 계산된 gradient가 반영되는 비율을 정해주는 역할을 한다. 너무 높을 경우 모델이 최적점을 찾지 못할 수 있으며 낮을 경우 학습에 다소 오랜 시간이 걸릴 수 있다. Learning rate는 0.001로 지정하였다. 본 연구의 모델에서는 각각의 이미지에 대하여 98개의 영역을

〈표 4〉 파라미터 설정

파라미터 이름	파라미터 값
Batch size	64
Subdivision(mini-batch)	8
Max epoch size	100,000
Momentum	0.9
Decay	0.0005
Learning rate	0.001
Classes	4
Activation function	Leaky rectified linear activation
Balance_rate_coord	5
Balance_rate_noobj	0.5
Dropout	0.5

추출한다. 98개의 영역 중 검출할 대상이 포함된 영역과 포함되지 않는 영역이 존재한다. 98개의 영역 중 검출할 대상이 포함된 영역의 수는 그렇지 않은 영역의 수 보다 적기 때문에 Balance_rate_coord (λ_{coord}), Balance_rate_noobj(λ_{noobj})를 각각 5와 0.5로 주어 loss의 균형을 맞춘다.


3.3.3 검증

훈련용 데이터 1,230장의 사진을 이용하여 모델을 학습하였고, 검증용 데이터 500장의 사진을 통해 모델의 성능을 검증하였다. 최종 모델의 검증 결과는 <표 5>와 같다. 총 97,600번의 epoch을 수행한 후 검증용 데이터로 평가한 결과, Average IOU는 0.6398로 모델이 예측한 객체의 영역과 실제 영역의 일치하는 영역이 평균적으로 64% 수준인 것으로 나타났다. 또한 평균 Recall이 0.81667로, 평균 81% 수준에서 객체를 검출하였다. 모델의 전반적인 성과지표를 보여주는 MAP@50은 66.53%로 나타났다.

〈표 5〉 검증 결과

Class	AP(Average Precision)
꼭지	72.02%
변색	61.05%
부패	52.52%
스크래치	80.51%
MAP@50(Mean Average Precision): 66.53%	
Average Recall : 81.67%	
Average IOU : 63.98%	

<그림 4>는 최종 학습된 모델이 실제 복숭아 불량에 대한 검출을 수행한 결과를 보여주는 예시이다. 왼쪽 사진에서 볼 수 있듯이 변색된 부분과 부패한 부분을 찾아서 각각 colorchange와 black으로 표시하였다. 오른쪽 사진은 상처난 부분을 scar로 인지하여 표시하고, 꼭지에 해당하는 부분을 정확하게 분류하여 top으로 표시할 수 있음을 확인하였다.



〈그림 4〉 검출 결과 예시

IV. 결 론

본 연구에서는 R-CNN 기반의 YOLOv3 알고리즘을 이용하여 농작물의 사진을 분석하여 불량을 검출할 수 있는 모델을 개발하고자 하였다. 외상에 취약한 복숭아를 대상으로 총 4개의 검출 클래스를 설정하고 1,230장의 사진과 12개의 동영상을 수집하여 불량을 검출하는 모델을 개발하였다. 총 97,600번의 epoch을 통해 생성된 모델을 실제로 검증한 결과는 0.6398의 IOU와 0.81667의 Recall을 보여주었다. 이러한 결과는 비교적 우수한 것으로 평가할 수 있다. 여러 각도에서 촬영한 사진과 동영상을 더 많이 수집하고 수작업으로 진행된 Annotation 기법을 개선하면 더욱 우수한 성능을 가진 불량검출 모델을 개발할 수 있을 것으로 판단된다.

본 연구는 복숭아 농가를 직접 방문하여 실제 데이터를 수집하고 농업 분야에 최신 딥러닝 기법을 적용하여 복숭아 표피 불량검출의 가능성을 보여주고 있다. 각 농작물 마다 사전에 정의한 클래스 별로 추가 데이터를 수집하고 모델의 재학습 과정을 거쳐 농작물 불량이 검출된 자료를 농가에 제공한다면, 농업 종사자들에게 품질관리 측면에서 도움을 줄 수 있을 것이다.

본 연구는 복숭아의 표피 불량검출 모델을 생성했지만, 다음과 같은 한계점을 가지고 있다. 첫째, 본 연구는 선행 연구에서 다른 모델과 비교했을 때 검출 성능과 처리속도가 뛰어난 YOLOv3 알고리즘만 사용하고 있다. 그러나 복숭아 표피 불량

검출에서 다른 검출 모델의 성능이 뛰어날 수도 있다. 향후 연구에서는 검출 모델 간 성능 비교를 통해 최적의 모델을 제시할 필요가 있다. 둘째, 본 연구에서는 YOLOv3 알고리즘의 기본 파라미터를 참고하여 사용하고 있다. YOLOv3 알고리즘은 입력 이미지 크기에 의해 검출 성능의 차이를 보이기 때문에(Redmon et al., 2016; Mandal et al., 2019) 향후 연구에서는 입력 이미지 크기를 조절하며 최적의 입력 이미지 크기를 찾을 필요가 있다. 셋째, 본 연구에서 불량으로 정의한 클래스가 외상에 한정되어 있고, 농작물의 등급을 분류하지 못했다는 한계가 있다. 향후에는 농작물의 외상뿐만 아니라 내상과 농작물의 등급을 분류할 수 있는 모델에 대한 연구가 필요하다.

참 고 문 헌

- [1] 권기만, 김재원, 윤광섭, “전처리 및 포장방법이 냉풍감압건조 복숭아의 품질에 미치는 영향”, *한국식품저장유통학회지*, 제20권, 제3호, 2013, pp. 317-322.
- [2] 김상철, “4차 산업혁명과 스마트팜 기술 개발”, *한국농공학회지*, 제59권, 제2호, 2017, pp. 10-18.
- [3] 김영상, 유성민, “4차 산업혁명과 IoT-AI 플랫폼”, *한국정보기술학회지*, 제15권, 제1호, 2017, pp. 1-7.
- [4] 문성은, 장수범, 이정혁, 이종석, “기계학습 및 딥러닝 기술동향”, *한국통신학회지(정보와 통신)*, 제33권, 제10호, 2016, pp. 49-56.
- [5] 신현엽, 임효균, 김원태, “전력 소모 절감을 위한 딥 러닝기반의 지능형 그린 하우스 제어 시스템”, *전기전자학회논문지*, 제22권, 제1호, 2018, pp. 53-60.
- [6] 엄향란, 황대근, 홍운표, 이승구, “복숭아 ‘미백도’의 유통 중 품질유지를 위한 일산화질소 처리 효과 및 시기 결정”, *원예과학기술지*, 제27권, 제4호, 2009, pp. 618-624.

- [7] 오정원, 김행근, “IoT 기반 Apache Spark 분석 기법을 이용한 과수 수확 불량영역 모니터링 아키텍처 모델”, *스마트미디어저널*, 제6권, 제4호, 2017, pp. 1-7.
- [8] 윤철호, 박창희, “농업경영체의 온라인 직거래 마케팅 수용에 관한 실증적 연구”, *Information Systems Review*, 제20권, 제1호, 2018, 41-59.
- [9] 이해림, 윤광섭, “냉풍 및 적외선 건조에 따른 건조 복숭아의 품질 특성”, *한국식품저장유통학회지*, 제19권, 제4호, 2012, pp. 485-491.
- [10] 장주희, 박재희, 반기은, 이경행, “Ultraviolet-C 조사에 의한 복숭아의 저장 중 품질변화”, *한국식품영양과학회지*, 제41권 제12호, 2012, pp. 1798-1804.
- [11] 장필성, “4차 산업 혁명의 기술적 특징과 농업 적용 기술”, *세계농업*, 제200호, 2017, pp. 167-188.
- [12] 정미진, 안덕순, 박우포, 이동선, “농산물 유통 과정에서 복숭아의 품질유지를 위한 마스터 포장 시스템”, *한국포장학회지*, 제19권 제1호, 2013, pp. 7-10.
- [13] 최영찬, 장익훈, “4차 산업혁명시대의 스마트팜”, *한국통신학회지(정보와통신)*, 제36권, 제3호, 2019, pp. 9-16.
- [14] Bay, H., T. Tuytelaars, and L. Van Gool, “Surf: Speeded up robust features”, *European Conference on Computer Vision*, Springer, Berlin, Heidelberg, 2006, pp. 404-417.
- [15] Benjdira, B., T. Khursheed, A. Koubaa, A. Ammar, and K. Ouni, “Car detection using unmanned aerial vehicles: Comparison between faster r-cnn and yolov3”, *IEEE 1st International Conference on Unmanned Vehicle Systems-Oman (UVS)*, 2019, pp. 1-6.
- [16] Girshick, R., J. Donahue, T. Darrell, and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 580-587.
- [17] Girshick, R., “Fast r-cnn”, *Proceedings of the IEEE International Conference on Computer Vision*, 2015, pp. 1440-1448.
- [18] He, K., X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770-778.
- [19] Kamilaris, A., A. Kartakoullis, and F. Prenafeta-Boldú, “A review on the practice of big data analysis in agriculture”, *Computers and Electronics in Agriculture*, No.143, 2017, pp. 23-37.
- [20] Kim, J., C. Rhee, and J. Moon, “Gaining insight into IT investment in the agriculture industry: Comparison of IT portfolios by type of crops”, *Asia Pacific Journal of Information Systems*, Vol.27, No.4, 2017, pp. 233-244.
- [21] Krizhevsky, A., I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks”, *Advances in Neural Information Processing Systems*, 2012, pp. 1097-1105.
- [22] Lowe, D. G., “Distinctive image features from scale-invariant keypoints”, *International Journal of Computer Vision*, Vol.60, No.2, 2004, pp. 91-110.
- [23] Mandal, M., M. Shah, P. Meena, and S. K. Vipparthi, “SSSDet: Simple short and shallow network for resource efficient vehicle detection in Aerial Scenes.”, *IEEE International Conference on Image Processing (ICIP)*, 2019, pp. 3098-3102.
- [24] Redmon, J., S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 779-788.
- [25] Redmon, J. and A. Farhadi, “YOLO9000: Better,

- faster, stronger”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 7263-7271.
- [26] Redmon, J. and A. Farhadi, “Yolov3: An incremental improvement”, arXiv preprint arXiv:1804.02767, 2018.
- [27] Ren, S., K. He, R. Girshick, and J. Sun, “Faster r-cnn: Towards real-time object detection with region proposal networks”, *Advances in Neural Information Processing Systems*, 2015, pp. 91-99.
- [28] Szegedy, C., A. Toshev, and D. Erhan, “Deep neural networks for object detection”, *Advances in Neural Information Processing Systems*, 2013, pp. 2553-2561.

Detection Model of Fruit Epidermal Defects Using YOLOv3: A Case of Peach

Hee Jun Lee* · Won Seok Lee** · In Hyeok Choi*** · Choong Kwon Lee****

Abstract

In the operation of farms, it is very important to evaluate the quality of harvested crops and to classify defective products. However, farmers have difficulty coping with the cost and time required for quality assessment due to insufficient capital and manpower. This study thus aims to detect defects by analyzing the epidermis of fruit using deep learning algorithm. We developed a model that can analyze the epidermis by applying YOLOv3 algorithm based on Region Convolutional Neural Network to video images of peach. A total of four classes were selected and trained. Through 97,600 epochs, a high performance detection model was obtained. The crop failure detection model proposed in this study can be used to automate the process of data collection, quality evaluation through analyzed data, and defect detection. In particular, we have developed an analytical model for peach, which is the most vulnerable to external wounds among crops, so it is expected to be applicable to other crops in farming.

Keywords: *Peach, Defect Detection, Smart Farm, Region Convolutional Neural Network, YOLO*


* MS, Department of Management Information Systems, Keimyung Univeristy

** MS, Department of Management Information Systems, Keimyung Univeristy

*** MS, Department of Management Information Systems, Keimyung Univeristy

**** Corresponding Author, Professor, Department of Management Information Systems, Keimyung Univeristy

◎ 저 자 소 개 ◎



이 희 준 (hjlee@stu.kmu.ac.kr)

2019년 계명대학교에서 경영정보학 전공과 비즈니스데이터분석 부전공으로 학사학위를 취득하고 계명대학교 경영정보학과에서 석사과정에 재학 중이다. 연구분야는 딥러닝, 머신러닝, 추천시스템이다.



이 원 석 (ifu.seok@stu.kmu.ac.kr)

계명대학교 통계학/비즈니스데이터분석 복수전공으로 학사학위를 취득하고 경영정보학과에서 석사과정에 재학 중이다. 연구분야는 머신러닝과 딥러닝, 이미지 분석이다.



최 인 혁 (ih.choi@stu.kmu.ac.kr)

계명대학교에서 경영정보학/비즈니스데이터분석 복수전공으로 학사학위를 취득하고 경영정보학과에서 석사과정에 재학 중이다. 연구분야는 머신러닝과 딥러닝이다.



이 총 권 (cklee@kmu.ac.kr)

2006년 계명대학교에 부임하여 2016년부터 빅데이터 인력양성사업을 맡고 있다. University of Nebraska-Lincoln에서 박사학위를 받았고, Georgia Southern University에서 가르친 경험이 있다. IT직무능력분석과 빅데이터를 주제로 연구 활동을 전개하고 있다.

논문접수일 : 2019년 08월 17일

게재확정일 : 2019년 12월 02일

1차 수정일 : 2019년 11월 11일

2차 수정일 : 2019년 12월 01일