

CutMix 알고리즘 기반의 일반화된 밀 머리 검출 모델

여주원^o, 박원준^{*}

^o서강대학교 대학원 컴퓨터공학과,

^{*}한양대학교 대학원 인공지능학과

e-mail: judaily@sogang.ac.kr^o, dnjswns2280@naver.com^{*}

Generalized wheat head Detection Model Based on CutMix Algorithm

Juwon Yeo^o, Wonjun Park^{*}

^oDept. of Computer Science and Engineering, Graduate School, Sogang University,

^{*}Dept. of Artificial Intelligence, Graduate School, Hanyang University

● 요약 ●

본 논문에서는 밀 수확량을 증가시키기 위한 일반화된 검출 모델을 제안한다. 일반화 성능을 높이기 위해 CutMix 알고리즘으로 데이터를 증식시켰고, 라벨링 되지 않은 데이터를 최대한 활용하기 위해 Fast R-CNN 기반 Pseudo labeling을 사용하였다. 학습의 정확성과 효율성을 높이기 위해 사전에 훈련된 EfficientDet 모델로 학습하였으며, OOF를 이용하여 검증하였다. 최신 객체 검출 모델과 IoU(Intersection over Union)를 이용한 성능 평가 결과, 제안된 모델이 가장 높은 성능을 보이는 것을 확인하였다.

키워드: 딥 러닝(Deep learning), 데이터 증강(Data augmentation), 비지도 학습(Unsupervised learning), 지도 학습(Supervised learning), 객체 탐지(Object detection)

I. Introduction

밀은 쌀과 옥수수와 함께 식량 공급의 핵심적인 역할을 하는 곡물이지만 최근 밀 수확량은 둔화하고 있다. 이에 따라 다양한 분야에서 밀의 수확량을 높이고자 하는 연구들이 진행되고 있다[1]. 밀의 수확량을 높이기 위한 방법으로는 밀의 머리를 분석하여 농부가 향후 관리를 결정하는 방법이 있다. 하지만 농부가 모든 밀을 일일이 확인하기에는 한계가 있으며, 변수가 많은 외부 환경으로 인하여 분석의 정확성도 떨어진다[2]. 이러한 문제를 해결하기 위해서는 자동으로 밀의 머리를 검출하는 방법이 필요하다.

Ubbens 등은 딥 러닝을 사용하여 식물의 잎사귀에서 돌연변이 여부를 분류하고, 식물의 나이를 회귀하는 연구를 진행하였다[3]. Singh 등은 식물의 잎사귀 상태에 따른 질병의 종류를 분류하는 작업에 딥 러닝을 사용하였다[4]. 또한 Pound 등은 딥 러닝을 사용하여 들관에서 밀을 분류함으로써 밀의 수확량을 예측하였다[5].

하지만 상기 언급한 연구들은 수작업으로 라벨을 지정해야 했기 때문에 비용과 시간이 많이 소요되며 다양한 형태와 특성에 대응하기 어렵다는 단점이 있다. 따라서 본 논문에서는 보다 일반화된 밀 머리 검출 모델을 제안한다.

II. The Proposed Scheme

2.1 데이터셋

본 논문의 데이터셋은 유럽과 북아메리카에서 수집한 3,422개의 밀 머리 데이터를 학습 데이터로 사용하였고, 호주, 일본, 중국에서 수집된 1,000개의 밀 머리 데이터를 테스트 데이터로 사용하여 실험을 진행하였다.




Fig. 1. World Wheat Head Dataset

2.2 데이터 증식

다중 레이블 문제에 적용할 수 있는 CutMix 알고리즘을 사용하여 이미지를 증식시키는 과정은 식(1)과 같다. $x \in R^{W \times H \times C}$ 는 학습 이미지를 나타내며, R은 이미지의 배치크기, W는 가로 차원, H는 세로 차원, C는 채널의 수를 나타낸다. y는 해당 이미지의 레이블을 나타낸다. $M \in \{0,1\}^{W \times H}$ 은 두 학습 이미지에서 삭제되거나 채워지는 마스크의 위치를 나타내며 이미지의 크기에 따라 형성된다. λ 는 두 이미지의 결합 비율을 조정하는 변수를 의미한다.

$$\begin{aligned} x' &= M \cdot x_1 + (1 - M) \cdot x_2 \\ y' &= \lambda y_1 + (1 - \lambda) y_2 \end{aligned} \quad (1)$$

본 논문에서는 λ 의 범위를 [0.25, 0.75]로 조정하여 객체를 생성하고, 채워진 마스크에 대한 다중 레이블 맵핑을 진행하였다. 맵핑 시 레이블의 손실이 있는 부분에 대해서는 이미지의 전체 크기를 고려하여 삭제 처리 해주었다. 또한 라벨이 없는 422개에 밀 머리 데이터에 대하여 Fast R-CNN 기반의 Pseudo labeling을 적용해주었다.

생성된 데이터는 사전 학습된 EfficientDet D5 모델에 넣어 학습을 진행하였고, 입력 이미지의 크기를 맞추기 위하여 1024 layer를 앞부분에 추가해 주었으며, compound scaling 값은 width scaling, depth scaling, resolution scaling을 1.0:2.0:1.3 비율로 맞추는 뒤 학습을 진행하였다. 또한 학습 과정에 학습용 데이터를 8:2로 나누어 OOF(Out of Fold)를 진행해 주었다.

2.3 평가 방법

본 논문에서는 모델의 성능을 평가하기 위해 Intersection over Union(IoU)을 사용하였다. 이 지표는 예측된 경계 상자와 레이블 경계 상자의 겹치는 영역을 총면적으로 나눈 값으로 정의되며 식(2)과 같이 나타낼 수 있다[6]. 본 논문에서는 다중 레이블 문제를 해결하기 때문에 IoU 값의 임계치를 0.5로 설정한 뒤, 평균을 취하여 최종 결과를 도출하였다.

$$IoU(A,B) = \frac{A \cap B}{A \cup B} \quad (2)$$

III. Conclusions

표 1은 Faster R-CNN 모델, Yolo 모델, EfficientDet 모델을 사용하여 성능을 평가한 결과이다.

Table 1. Performance of the proposed model

Model	Augmentation	IoU(%)
Faster R-CNN		70.87%
Faster R-CNN	CutMix	71.82%
Yolo v4		68.42%
Yolo v4	CutMix	69.94%
EfficientDet D5		72.45%
EfficientDet D5	CutMix	74.21%

Faster R-CNN 모델은 70.87%의 IoU값을 보였고 CutMix 알고리즘을 사용하였을 때 0.95%의 성능향상을 보였다. Yolo v4 모델은 68.42%의 IoU값을 보였고 CutMix 알고리즘을 사용하였을 때 1.52%의 성능향상을 보였다. EfficientDet 모델은 72.45%의 IoU값을 보이며 세 모델 중 가장 성능이 높았고 CutMix 알고리즘을 사용했을 때 1.75%의 성능향상을 보였다. 이 수치는 모델의 정확도를 나타내는 지표인 Intersection over Union (IoU)에서의 개선 정도를 의미한다. 본 논문에서 제안하는 검출 모델의 IoU값과 CutMix 알고리즘을 적용했을 때의 성능향상 값이 가장 높은 것을 확인할 수 있었다.

IV. Conclusions

[Fig 2]는 제안하는 모델을 테스트한 결과이다. 유럽과 북아메리카에서 수집된 밀 머리를 학습하여 호주, 일본, 중국의 밀 머리를 높은 정확도로 검출해 내는 결과를 볼 수 있다. 또한 밀 머리가 잘리는 가장자리에서도 높은 정확도로 밀 머리를 검출한다.

제안된 모델을 통해 지역에 국한되지 않고 밀 머리를 검출하여 밀 수확량을 예측하거나 질병을 사전에 예방할 수 있다. 이를 통해 밀의 수확량을 높이는 데 기여할 수 있을 것이라고 기대된다.




Fig. 2. Experiment result

Metric and a Loss for Bounding Box Regression." *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 658-666, 2019

REFERENCES

- [1] B. Schauburger, T. Ben-Ari, D. Makowski, T. Kato, H. Kato, & P. Ciaia. "Yield Trends, Variability and Stagnation Analysis of Major Crops in France Over More Than a Century." *Scientific Reports*, 8(1), pp. 1-12, 2018.
- [2] S. Madec, X. Jin, H. Lu, B. De Solan, S. Liu, F. Duyme et al. "Ear Density Estimation From High Resolution RGB Imagery Using Deep Learning Technique." *Agricultural and Forest Meteorology*, 264, pp. 225-234, 2019.
- [3] J.R. Ubbens, & I. Stavness. "Deep Plant Phenomics: A Deep Learning Platform for Complex Plant Phenotyping Tasks." *Frontiers in Plant Science*, 8, pp. 1190, 2017.
- [4] A.K. Singh, B. Ganapathysubramanian, S. Sarkar, & A. Singh. "Deep Learning for Plant Stress Phenotyping: Trends and Future Perspectives." *Trends in Plant Science*, 23(10), pp. 883-898, 2018.
- [5] M.P. Pound, J.A. Atkinson, D.M. Wells, T.P. Pridmore, & A.P. French. "Deep Learning for Multi-Task Plant Phenotyping." *In Proceedings of the IEEE International Conference on Computer Vision Workshops*, pp. 2055-2063, 2017.
- [6] H. Rezaatofghi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, & S. Savarese. "Generalized Intersection Over Union: A