

드론의 파종 성능평가를 위한 밀도추정 기반 종자 계수

성백겸¹, 이대현¹, 강영호², 이춘구³, 유승화^{3*}

¹충남대학교 바이오시스템기계공학과, ²전북특별자치도농업기술원 작물식품과, ³국립농업과학원 농업공학부

Density estimation-based seed counting for evaluating the performance of seeding drone

Baek-Gyeom Seong¹, Dae-Hyun Lee¹, Yeongho Kang², Chun-Gu Lee³, Seung-Hwa Yu^{3*}

¹Department of Biosystem Machinery Engineering, Chungnam National University

²Department of Crops and Foods, Jeonbuk State Agricultural Research and Extension Services

³Department of Agricultural Engineering, National Institute of Agricultural Science

요약 드론을 이용한 파종은 관행 방식보다 효율성이 높고 험지에 대한 접근성이 좋아, 농촌의 고령화 및 기피 현상 등으로 인한 노동력 부족 문제를 해결하기 위한 대책으로 대두되고 있다. 하지만 국내에서의 파종 드론에 관한 연구는 아직 기초 연구 수준에서만 수행되고 있으며, 파종 성능평가 방식도 전통적인 방식의 수작업 집계 방식을 사용하여 효율이 떨어지는 실정이다. 따라서 본 연구에서는 드론의 파종 성능평가 방식의 자동화를 목표로, 딥러닝 모델을 이용한 준지도 학습을 통해 영상 내에서 밀도추정을 통해 드론의 파종 성능평가를 수행하였다. 학습데이터는 다양한 개수의 볍씨 영상들로 구성되었으며, 합성곱 신경망 기반의 학습모델을 사용하여 밀도추정을 진행하였다. 학습모델의 성능평가에는 선형회귀분석을 사용하여 실제값과의 상관관계를 분석하였다. 제안된 방법을 통한 볍씨 밀도추정은 R^2 0.99의 성능을 보여주었으며, 이를 통해 촬영된 영상 내 종자의 수를 자동으로 계수할 수 있음이 확인되었다. 본 연구 결과를 통해 현장 중심의 데이터 확보 및 학습모델의 성능 정밀화로, 실제 드론 파종작업의 성능평가에 실질적인 활용이 가능할 것으로 기대된다.

Abstract Seeding using drones is more efficient than the conventional method because it offers extensive access to rough areas, making it an emerging solution to the labor shortage problem caused by the aging population and the avoidance of rural areas. On the other hand, research on seeding drones in Korea is still at the basic research level, and the method for evaluating seeding performance is also inefficient due to traditional hand-counting methods. Therefore, in this study, to automate the seeding performance evaluation method for drones, the seeding performance was evaluated through density estimation in images using semi-supervised learning with deep learning models. The training data consisted of rice seed images collected through experiments, and the training was conducted using a model based on a convolutional neural network (CNN). Linear regression was performed to assess the performance of the model and analyze the correlation with the ground truth. The proposed method achieved a rice seed density estimation performance of $R^2 = 0.99$, showing that the number of seeds could be automatically calculated in the images. The findings of this study are anticipated to facilitate the practical applications of drone seeding performance evaluations by acquiring field-oriented data and the performance enhancement of learning models.

Keywords : Convolutional Neural Network, Density Estimation, Drone, Seeding, Semi-supervised Learning

본 연구는 농촌진흥청 농업정책지원기술개발사업(과제번호:RS-2021-RD009653)의 지원에 의해 이루어진 것임.

*Corresponding Author : Seung-Hwa Yu(National Institute of Agricultural Sciences.)

email: yush6210@korea.kr

Received June 5, 2024

Revised July 12, 2024

Accepted August 2, 2024

Published August 31, 2024

1. 서론

전 세계적으로 중요한 식량 작물인 쌀은 국내뿐만 아니라 수많은 국가에서 주식으로 섭취되고 있다[1,2]. 이러한 쌀을 생산하기 위한 벼농사는 국내의 경우 모판에서 육묘 후에 논으로 옮겨심는 이앙법이 일반적으로 시행되고 있으며, 이는 직파법에 비해 병해충과 잡초 관리가 쉽고, 생산량이 증가한다는 장점이 있지만 요구되는 노동력과 비용이 많다는 단점이 있다[3].

최근 농촌은 고령화 및 기피 현상 등으로 인해 노동력 부족 문제에 직면해 있어 이앙법보다는 직파법이 권장되고 있는 현황이며, 지상 농기계보다 작업 효율이 높고, 험지에 대한 접근성이 좋은 드론(drone)을 이용하여 직파법을 수행하려는 시도가 이루어지고 있다[3-7]. 관련 연구들을 통해 드론을 이용한 파종작업 진행 시 기존 인력이나 트랙터 작업방식 대비 75~80% 정도의 작업시간 단축이 확인되었으나, 종자들의 균일 살포가 어려워 성능 개선이 요구되고 있다[4,8]. 하지만 국내에서의 농업용 드론에 관한 연구는 주로 농작물의 생육 및 병해충 예방과 방제에 관련된 연구이며, 파종 관련 연구는 드론을 활용한 벼 직파의 적정 높이 선정, 범시 항공 파종기 설계 등의 기계적 성능 향상에만 초점을 맞춘 기초 연구 수준에서 진행되고 있는 실정이다[3-5].

드론을 이용한 파종작업의 균일한 파종 성능확보를 위해서는 이에 대한 기준과 이를 정확히 평가하는 방법이 요구된다. 관행 직파 방식에서는 환경에 따라 파종량을 1 m²당 80~200개, 목표지점인 종자 골당 7~10개씩 파종하는 것이 권장되고 있다. 하지만 현재 사용되고 있는 전통적인 수작업 집계 방식의 성능평가 방법은 노동 집약적이며 느린 계산속도로 비효율적이고, 오류율도 높아 이를 개선하기 위한 연구들이 해외에서 추진되고 있다[2,7,9]. Mussadiq et al. (2015)는 Image J 등의 상용 영상분석 소프트웨어(software)들을 사용하여 종자를 자동 집계하였으며, Tan et al. (2019)는 겹치는 종자의 기하학적 특징 추출을 통해 각 개체를 인식하는 알고리즘(algorithm)을 개발하고 평가하였다. 또한, 실질적인 성능을 확보하기 위해 겹치는 종자의 영향을 고려한 추정 연구들이 추진되었으며(Sun et al., 2021), 데이터 라벨링(data labeling)의 어려움을 극복하기 위해 종자 계수 시뮬레이션(simulation) 등의 연구가 수행되었다(Liang et al., 2023)[2,10-13].

선행연구들에서 사용된 영상 기반 계수 및 분포추정에 관한 기술은 조도 변화, 다른 개체 등의 다양한 잡음

(noise)이 혼재된 영상에서 목표로 하는 개체만을 감지하는 기술로, 최근 CNN 등 딥러닝(deep learning)을 통한 영상 특징 검출 기술의 비약적인 발전과 더불어 많은 연구에서 활용되고 있다. 그중 밀도추정(density estimation)을 이용하는 방법은 잡음(noise) 제거에 강점이 있고, 포괄적인 구조를 파악하여 정확하고 필요한 정보를 얻을 수 있다는 장점이 있어 군중 계수(crowd counting) 알고리즘 개발 등의 연구에서 활용되고 있으며, 이를 종자 계수 알고리즘으로도 확장하려는 시도도 이루어지고 있다 (Feng et al., 2021)[12,14,15].

따라서 본 연구는 드론 파종의 성능평가 자동화를 위한 기초 연구로써, 기존 인력을 통한 종자 계수 방식을 딥러닝 기반의 밀도추정을 이용하여 자동화하였다. 또한, 데이터 규모의 의존성을 줄이기 위해 준 지도 학습(semi-supervised learning)을 적용하여 라벨링 작업 비용을 최소화하였다.

2. 재료 및 방법

2.1 학습데이터

2.1.1 실험설계 및 재료

범시 영상 촬영을 통한 데이터(data) 수집을 위해 Fig. 1과 같은 실험 시스템(system)을 설계하였다. 시스템은 배경과 범시가 잘 구분될 수 있도록 외부의 빛을 완전히 차단한 뒤 내부에서 손전등을 통해 빛을 제공하고, 카메라를 통해 범시가 부러져 있는 하얀색의 기준면(reference surface)을 촬영하도록 구성하였다. 범시 살포는 수작업으로 진행되었으며 동일한 개수에서 다양한 분포의 영상을 얻기 위해 기준면을 진동시키며 촬영이 진행되었다[10-12,14].




Fig. 1. Image collection system for constructing the data set in this study

- (a) The exterior of the system
(b) The internal of the system

실험 시스템의 카메라로는 인텔 Real Sense (D435i, Intel Corporation, CA, USA)가 사용되었으며, 주요 제원은 Table 1과 같다. 실험에서는 RGB 채널을 통해 촬영이 진행되었으며, 이때의 제원은 해상도(resolution) 1920×1080 , 초당 프레임은 30fps, 화각(FOV: Field Of View)은 $69^\circ \times 42^\circ$ 이다.

Table 1. Specification of camera

Item	Specification	
	RGB	Depth
Output resolution	1920×1080	1280×720
Frame rate	30 fps	Up to 90 fps
Field of view (H × V)	$69^\circ \times 42^\circ$	$87^\circ \times 58^\circ$

실험에 사용된 벼(Yechan, Rural Development Administration, Republic of Korea)는 천립중(TKW: Thousand Kernel Weight)이 약 26.9g, 벼알 길이는 평균 7.3 mm, 벼알 폭은 평균 3.32 mm로 평가된다. 이때, TKW는 벼 알곡 1,000개의 무게를 의미하며, 벼알의 크기, 품질, 수율등에 대한 평가지표 및 생산량 예측의 주요 기준으로 사용된다[1].

2.1.2 데이터 구성

학습을 위한 데이터 구성 과정은 Fig. 2와 같으며, 데이터 수집은 파종 권장량을 고려하여 10~200개까지 10개 단위로 계수 라벨(label)이 나누어 진행되었다[9]. 이때 계수 라벨은 수작업으로 계수한 종자의 개수이며, 각 라벨당 10장씩 사진 촬영이 진행되었다. 학습데이터는 라벨별로 학습용, 검증용, 평가용이 6:2:2의 비율로 설정되어 학습용(train) 120장, 검증용(validation) 40장, 평가용(test) 40장으로 총 200장의 학습데이터가 구성되었다.




Fig. 2. The process of data set construction

계수 학습을 위해 모든 데이터에는 계수 라벨링을 수행하였으며, 이 중 학습용 데이터에는 밀도추정을 위한 픽셀 단위의 객체 위치 라벨링을 추가로 진행하였다. 밀도추정 라벨은 시료의 위치 정보를 Eq. (1)과 같은 적응형 가우시안 커널 함수를 통해 Fig. 3과 같이 밀도맵을 생성하여 사용되었다. 이때, α 는 0.1, k 는 4로 설정되었다[15].

$$F(x) = \sum_{i=1}^N \delta(x - x_i) * G_{\sigma_i}(x), \text{ with } \sigma_i = \alpha \bar{d}_i \quad (1)$$

Where, x denotes position of pixel in the image, $\delta(x - x_i)$ denotes ground truth, G_{σ_i} denotes adaptive gaussian kernel, σ_i denotes standard deviation, \bar{d}_i denotes average distance of k nearest neighbors.




Fig. 3. Examples of generated density map used as ground truth

2.2 학습모델

2.2.1 학습 방법 및 모델 구조

본 연구에서는 군중 계수 알고리즘 중 맥락적 모델링(contextual modeling) 기반 준 지도 학습 프레임워크(framework)인 MRC-Crowd를 따라 학습이 진행되었으며, 전체적인 과정은 Fig. 4와 같다. 학습 과정은 동일한 아키텍처(architecture)로 구성되어 있는 학생 모델(student model)과 교사 모델(teacher model)에서 학생 모델이 라벨이 있는 데이터를 통해 지도 학습을 수행하여 가중치를 업데이트한다. 그 후, 학생 모델이 얻은 가중치의 지수 이동평균(EMA: Exponential Moving Average) 가중치를 통해 교사 모델을 업데이트시킨다.




Fig. 4. The process of contextual modeling

이후, 출력에 영향을 줄 수 있는 요소인 Fig. 5와 같은 섭동(perturbation)을 라벨이 없는 데이터에 추가하여 준 지도 학습을 진행한다. 교사 모델에는 이미지 좌우 반전과 같은 약한 섭동을 가진 데이터나 원본 데이터를 제공하여 밀도 값을 예측하고, 이를 감독(supervisor)으로 하여 학생 모델은 강한 섭동을 가진 데이터에서 상황별 단서를 통해 마스크 된 이미지의 밀도 수준을 복구하는 작업을 수행하는 방식으로 준 지도 학습이 진행된다 [15,16].




Fig. 5. Example of perturbation
 (a) Original image
 (b) Weak perturbation with flip
 (c) Strong perturbation with mask

학생 모델과 교사 모델은 Fig. 6과 같이 VGG-19를 기본 구조(backbone)로 하여 해상도 복원을 위한 업 샘플링 층(up sampling layer)과 각 픽셀의 밀도 수준에 대해 예측된 확률로 구성된 확률 맵을 출력하기 위한 밀

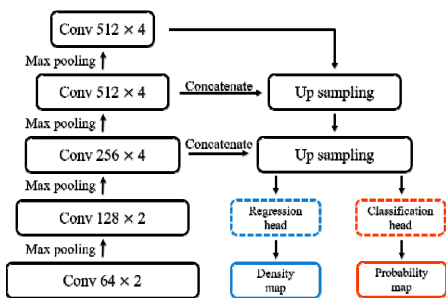


Fig. 6. The architecture design of model used in this study

도 분류 헤드(classification head), 장면의 전체적인 밀도 추정값을 출력하기 위한 밀도 회귀 헤드(regression head)로 구성되었다. 업 샘플링 층과 헤드는 모두 합성곱 신경망으로 구성되어 있으며, 업 샘플링 과정 중 결합(concatenate)을 활용하여 다양한 크기의 특징 추출 및 하향식 특징병합 구조가 이어지도록 해, 높은 수준의 의미론적 정보와 낮은 수준의 세부 정보를 통합시키고자 하였다[15].

2.2.2 손실함수

학생 모델에서 지도 학습이 수행될 때는 Eq. (2.1)과 같이 structural similarity index measure (SSIM) 손실과 변동 손실(total variation loss)이 밀도 회귀 손실함수로 사용되었으며, Eq. (2.2)와 같이 교차 엔트로피 손실함수가 밀도 분류에 대한 손실함수로 사용되었다. 최종적으로 Eq. (2.3)과 같은 손실함수가 구성되었으며, 선행연구를 따라 β 는 0.01이 사용되었다[15,17].

$$L^{s_{reg}} = 1 - SSIM(\hat{y} \odot M_{gt}, y_{gt} \odot M_{gt}) + \beta \cdot L_{tv}(\hat{y}, y_{gt}) \quad (2.1)$$

Where, \hat{y} denotes estimated density, y_{gt} denotes ground truth, M_{gt} denotes binary segmentation map that distinguishes dense and sparse regions based on a threshold value, β denotes weight factor, L_{tv} represents the total variation loss

$$L^{s_{cls}} = \frac{1}{n} \sum_{i=1}^n H(y_{gt,i}, \hat{y}_i) \quad (2.2)$$

Where, n denotes number of data, $H(x_1, x_1)$ is the cross-entropy

$$L^{s_{total}} = L^{s_{reg}} + L^{s_{cls}} \quad (2.3)$$

Where, $L^{s_{reg}}$ is the supervised regression loss, $L^{s_{cls}}$ is the supervised classification loss

교사 모델과 학생 모델에서 준 지도 학습이 수행될 때는 두 모델의 출력값에 대한 일관성 손실을 구하기 위해 L1 loss가 사용되었으며, Eq. (3.1)과같이 두 모델의 회귀 헤드에 대한 손실함수와 Eq. (3.2)와 같이 두 모델의 분류 헤드에 대한 손실함수가 구성되었다. 최종적으로 Eq. (3.3)과 같은 손실함수가 준 지도 학습에 사용되었다 [15].

$$L_{reg}^u = \frac{1}{n} \sum_{i=1}^n L_1(\hat{y}_s, \hat{y}_t) \quad (3.1)$$

Where, \hat{y}_s denotes density estimated by the student model, \hat{y}_t denotes density estimated by the teacher model.

$$L_{ds}^u = \frac{1}{n} \sum_{i=1}^n L_1(\hat{p}_s, \hat{p}_t) \quad (3.2)$$

Where, \hat{p}_s denotes probability distribution map predicted by the student model, \hat{p}_t denotes probability distribution map predicted by the teacher model.

$$L^{u_{total}} = L^{u_{reg}} + L^{u_{cls}} \quad (3.3)$$

Where, $L^{u_{reg}}$ is the semi-supervised regression loss, $L^{u_{cls}}$ is the semi-supervised classification loss

2.3 성능평가

본 연구에서 영상 내 종자 계수 성능에 대한 평가는 모델의 추정 결과에 대한 오차 계산 및 선형 회귀분석을 통해 진행되었으며, 오차 계산을 위한 평가지표로 Eq. (4.1)과 같은 평균절대오차(MAE: Mean Absolute Error)와 계수 라벨별 크기 차이를 고려하기 위한 Eq. (4.2)와 같은 평균 절대 백분율 오차(MAPE: mean absolute percentage error)가 사용되었다[18].

$$MAE = \frac{1}{n} \sum_{i=1}^n | \hat{x} - x_{gt} | \quad (4.1)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{| \hat{x} - x_{gt} |}{x_{gt}} \times 100\% \quad (4.2)$$

Where, \hat{x} denotes estimated count, x_{gt} denotes ground truth count.

지도 학습 시 데이터 규모에 따른 전체 학습 성능을 평가하기 위해 Table 2와 같이 주석 된 데이터의 사용 비율을 달리하며 학습 결과 및 모델 성능을 비교하였다. 이때, 학습 과정에 사용된 검증용 데이터 세트와 학습 결과 평가에 사용된 평가용 데이터 세트는 모든 조건에서 동일한 데이터 세트가 사용되었다[15].

Table 2. Experimental condition for evaluating the model performance by labeled data ratio in training set


Model	Labeled data ratio in training set	Number of images	
		Labeled images	Unlabeled images
A	1/6	20	100
B	2/6	40	80
C	3/6	60	60
D	4/6	80	40
E	5/6	100	20

또한, 실제 작업환경에서의 적용을 고려하여 학습데이터에는 포함되지 않은 최대 파종 권장량 5배 범위의 평가용 데이터를 구축하여 밀도추정을 진행하고 종자 계수 성능의 일반성을 확인하였다[9]. 이때, 평가용 데이터 세트는 영상 내 시료가 300~1,000개 범위에서 100개 단위로 계수 라벨이 나뉘어 구성되었으며, 밀도추정에 대한 주석 없이 계수 라벨만 포함되었다. 최종적으로 계수 라벨별로 10장씩 총 80장의 데이터가 구성되었다.

3. 결과 및 고찰

3.1 라벨 비율별 학습 결과

라벨 비율별 학습 결과는 Fig. 7과 같이 나타났다. 모든 조건에서 5% 미만의 상대오차 및 2.07~3.43 범위의 절대오차를 보여주어 밀도추정을 통한 계수 추정 학습이 원활하게 진행된 것으로 판단된다. 라벨 비율이 높아질수록 MAE는 최대 39%, MAPE는 최대 37%의 감소가 관찰되었다. 하지만 학습용 데이터에서 라벨의 비율이 50% 이상일 때부터는 오히려 성능 하락이 관찰되어, 영상 내 종자에 대한 객체 위치 정보를 모두 라벨링 하지 않더라도 준 지도 학습을 통한 계수 학습이 가능한 것으로 판단된다.






Fig. 7. Performance of seeding count by labeled images ratio to total images in training set (a) MAE (b) MAPE

3.2 라벨 비율별 모델 성능평가




Fig. 8. Performance of seeding count by labeled images ratio to total images in experiment (a) MAE (b) MAPE

평가용 데이터 세트를 통해 모델의 추정 성능을 평가한 결과는 Fig. 8과 같이 확인되었다. 상대적으로 큰 값의 MAE가 확인되었는데 이는 계수 라벨의 크기가 커졌기 때문으로 절대오차도 커진 것으로 판단되며, 상대

차인 MAPE에서는 5% 이하의 오차를 보여주어 준수한 성능을 확인하였다. 가장 많은 라벨을 가지고 학습한 모델 E에서의 계수 성능이 가장 우수한 것으로 확인되어, 모델 C는 학습데이터에 과적합 된 것으로 판단되며, 라벨의 수가 증가될수록 모델의 일반성이 증가하는 것으로 판단된다. 하지만 모델 C와 D에서 5% 이하의 준수한 성능이 확인되었기 때문에 준 지도 학습을 통한 종자 계수가 가능한 것이 확인되었다.

실험에서 가장 우수한 성능을 보여준 모델 E를 기준으로 계수 추정 성능의 상관관계를 회귀분석으로 분석하였다. Fig. 9는 선형 회귀 결과를 산점도(scatter plot)로 표현한 결과로, 결정계수(R^2)가 0.99로 나타났다. 이를 통해 모델에 의해 추정된 종자 수와 실제 종자 수가 높은 상관관계를 보여주고 있는 것으로 확인되어 모델의 추정 성능이 일반성을 가지고 있다고 판단된다.

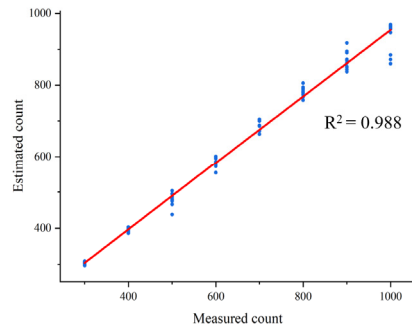


Fig. 9. Relationship between estimated and measured counts in seed images

Fig. 10은 종자 개수별 분석 결과로, 상자 도표를 통해 추정값의 분포를 분석하였다. 실제 종자 수가 많아질수록 추정값이 실제 값보다 작게 평가되었으며, 이는 종자 수가 많아져 밀도가 증가될수록 오차의 범위가 넓어지기 때문으로 판단된다. 하지만 대다수 그룹에서 이상치가 발견되지 않았으며, 종자 개수 900~1,000개를 제외하고는 추정값의 25~75% 범위가 실제값에 근접해 있는 것으로 확인되었다. 따라서 영상 내에서 파종 최대 권장량의 4배 수준인 800개까지는 밀도추정을 통한 자동 계수가 가능한 것으로 판단되며, 실제 작업환경에 적용할 시 살포 영역에 대한 일괄적인 파종 성능평가를 통해 전통적인 수작업 집계 방식을 개선할 수 있을 것으로 기대된다.




Fig. 10. Performance of seed counting by total seed counts within an image

Fig. 11은 종자 개수가 900~1,000개인 경우에 밀도 추정의 시각화 결과이다. 종자 수의 증가로 겹쳐있는 종자들이 많아져 밀도가 증가한다면 오차가 커지는 것으로 확인되며, 종자 수가 많더라도 비교적 균일하게 살포된 종자 영상에서는 높은 정확도로 계수 추정이 가능한 것으로 판단된다. 이를 통해 비교적 균일하게 살포된 영상 내에서는 제한적인 범위의 데이터와 적은 라벨로 진행된 준 지도 학습으로도 영상 내 종자 계수가 가능한 것이 확인되었으며, 밀도가 높아 겹쳐있는 종자가 많은 영상에서는 추가적인 데이터 전처리 및 라벨링 등으로 성능 개선이 가능할 것으로 기대된다.




Fig. 11. Result of density estimation

4. 결론

본 연구에서는 기존 인력 기반 종자 계수 방식의 자동화를 통해 드론 파종의 성능평가 자동화를 위한 기초 연구를 수행하고자 딥러닝을 이용한 밀도추정을 통해 영상 내 종자 자동 계수를 수행하였다. 다음은 본 연구의 주요 결과이다.

- 1) 모델 학습을 위한 데이터 수집을 위해 종자 영상 수집 실험을 설계하여 영상 데이터와 밀도 데이터

를 구성하였으며, 맥락적 모델링 기반의 준 지도 학습 프레임워크를 활용하여 학습을 수행한 뒤 성능을 분석하였다.

- 2) 학습 결과 5% 미만의 상대오차가 확인되어 모든 데이터에 라벨링을 하지 않아도 되는 준 지도 학습을 통해서도 정상적인 밀도추정 학습과 계수 추정이 가능한 것으로 판단된다.
- 3) 학습용 데이터의 범위 밖에 있는 평가용 데이터 세트에서의 추정 성능이 R^2 0.99로 확인되어 계수 성능의 일반성과 실제 환경으로의 적용 가능성이 확인되었다.

본 연구 결과를 통해 딥러닝 기반의 밀도추정으로 특정 영역 내 종자들의 자동 계수가 가능함을 알 수 있으며, 이는 준 지도 학습을 통해 효율적으로 접근할 수 있었다. 하지만 영상 내 고밀도 지역에서 종자의 겹침 등이 있을 때는 모델의 추정 성능 하락이 확인되었는데, 이는 다양한 각도의 영상 데이터 수집 및 영상처리 기반의 데이터 전처리, 추가적인 영상 내 특징 확보를 통해 개선이 가능할 것으로 판단되며, 향후 본 연구의 자동 종자 계수 기술의 성능 향상과 현장 적용 기술 개발을 통해 다양한 드론 파종 기술의 효과적인 성능평가에 활용 가능할 것으로 기대된다.

References

- [1] Y. H. Jang, J. R. Park, K. M. Kim, "Characterization of heading-and yield-related gene loci in the Cheongcheong/Nagdong doubled haploid line using rice QTLs", *The Korean Journal of Crop Science*, Vol.64, No.1, pp.1-17, March. 2019. DOI: <https://doi.org/10.7740/kjcs.2019.64.1.001>
- [2] J. Peng, Z. Yang, D. Lv, Z. Yuan, "A dynamic rice seed counting algorithm based on stack elimination", *Measurements*, Vol. 227, March. 2024. DOI: <https://doi.org/10.1016/j.measurement.2024.114275>
- [3] C. G. Lee, et al., "Development of a precision seeder prototype using drone for rice", *Proceeding of the KSAM 2023 Autumn Conference*, The Korea Society for Agricultural Machinery, Yeosu, Korea, Vol.28, No.2, pp.150-150, Nov. 2023.
- [4] S. H. Yu, et al., "Design & Production of uniform spreads type seeder for aerial seeding using agricultural drones", *Proceeding of the KSAM 2021 Autumn Conference*, The Korea Society for Agricultural Machinery, Jeju, Korea, Vol.26, No.2, pp.211-212, Oct. 2021.
- [5] Y. H. Kang, et al., "Setting the right seeding height for direct seeding rice with an agricultural drone",

Proceedings of the Korean Society of Crop Science Conference, The Korean Society of Crop Science, Jinju, Korea, pp.82-82, April. 2019.

- [6] W. Liu, et al., "Evaluation method of rowing performance and its optimization for UAV-based shot seeding device on rice sowing", *Computers and Electronics in Agriculture*, Vol. 207, April. 2023.
DOI: <https://doi.org/10.1016/j.compag.2023.107718>
- [7] Y. Li, et al., "Seeding detection and distribution evaluation using the developed automatic maize seeding machine", *Computers and Electronics in Agriculture*, Vol. 220, May. 2024.
DOI: <https://doi.org/10.1016/j.compag.2024.108872>
- [8] E. Y. Lee, Drones enable timely sowing of 'Italian ryegrass' [Internet]. Concentrated Distribution Newspapers, c2023 [cited 2023 Oct 4], Available From: <https://www.amnews.co.kr/news/articleView.html?idxno=55273> (accessed May. 31, 2024)
- [9] RDA, Agricultural Technology Guide 169:Cultivation Method By Direct Sowing, Rural Development Administration Korea, pp.33-67.
- [10] Z. Mussadiq, B. Laszlo, L. Helyes, C. Gyuricza, "Evaluation and comparison of open source program solutions for automatic seed counting on digital images", *Computers and Electronics in Agriculture*, Vol. 117, pp.194-199, Sep. 2015.
DOI: <https://doi.org/10.1016/j.compag.2015.08.010>
- [11] S. Tan, et al., "Segmentation and counting algorithm for touching hybrid rice grains", *Computers and Electronics in Agriculture*, Vol. 162, pp.493-504, July. 2019.
DOI: <https://doi.org/10.1016/j.compag.2019.04.030>
- [12] J. Sun, Y. Zang, X. Zhu, Y. D. Jang, "Deep learning optimization method for counting overlapping rice seeds", *Journal of Food Process Engineering*, Vol. 44, No. 9, Sep. 2021.
DOI: <https://doi.org/10.1111/jifpe.13787>
- [13] A. Feng, et al., "Research on a rice counting algorithm based on an improved MCNN and a density map", *Entropy*, Vol. 23, No. 6, June. 2021.
DOI: <https://doi.org/10.3390/e23060721>
- [14] N. Liang, et al., "High-throughput instance segmentation and shape restoration of overlapping vegetable seeds based on sim2real method", *Measurements*, Vol. 207, Feb. 2023.
DOI: <https://doi.org/10.1016/j.measurement.2022.112414>
- [15] Y. Qian, et al., "Semi-supervised crowd counting with contextual modeling: facilitating holistic understanding of crowd scenes", *IEEE Transactions on Circuits and Systems for Video Technology*, April. 2024.
DOI: <https://doi.org/10.1109/TCSVT.2024.3392500>
- [16] J. H. Park, S. I. Cho, "The analysis of semi-supervised learning technique of deep learning-based classification model", *Journal of Broadcast Engineering*, Vol.26, No.1, pp.79-87, Jan. 2021.

DOI: <https://doi.org/10.5909/JBE.2021.26.1.79>

- [17] B. Wang, H. Liu, D. Samaras, M. Hoai, "Distribution matching for crowd counting", *Advances in neural information processing systems*, Vol.33, pp.1595-1607, Oct. 2020.
DOI: <https://doi.org/10.48550/arXiv.2009.13077>
- [18] Y. Qian, "Segmentation assisted u-shaped multi-scale transformer for crowd counting.", *Proceeding of The 33rd British Machine Vision Virtual Conference*, The British Machine Vision Association and Society for Pattern Recognition, London, UK, pp.397, Nov. 2022.

성 백 겸(Baek-Gyeom Seong)

[준회원]




- 2019년 3월 ~ 현재 : 충남대학교 바이오시스템기계공학과 (학사 재학 중)
- 2022년 10월 ~ 현재 : 충남대학교 농업시각지능 연구실 (연구원)

<관심분야>

농업 메카트로닉스, 농업용 드론

이 대 현(Dae-Hyun Lee)

[정회원]



- 2015년 2월 : 성균관대학교 바이오메카트로닉스학과 (공학박사)
- 2011년 3월 ~ 2014년 8월 : LS엠트론(주) 중앙연구소 연구원
- 2016년 3월 ~ 2018년 2월 : 국립농업과학원 농업연구사
- 2018년 3월 ~ 현재 : 충남대학교 바이오시스템기계공학과 교수

<관심분야>

농업 메카트로닉스, 농업 로봇 시스템

강 영 호(Yeongho Kang)

[정회원]



- 2015년 2월 : 전남대학교 생물생 산기계공학과 (공학학사)
- 2022년 2월 : 전남대학교 지역바 이오시스템공학과 (박사수료)
- 2015년 10월 ~ 2017년 10월 : 고창군 농업기술센터 주무관
- 2018년 1월 ~ 현재 : 전북특별자치도농업기술원 농업연구사

<관심분야>

농작업 기계 · 자동화, 농업용 드론

이 춘 구(Chun-Gu Lee)

[정회원]



- 2009년 2월 : 서울대학교 바이오 시스템공학과 (공학학사)
- 2022년 2월 : 서울대학교 바이오 시스템공학과 (공학박사)
- 2022년 3월 ~ 2024년 2월 : 국립 농업과학원 박사후 연구원
- 2024년 2월 ~ 현재 : 국립농업과학원 농업연구사

<관심분야>

농작업 기계 · 자동화, 농업용 드론

유 승 화(Seung-Hwa Yu)

[정회원]



- 2010년 2월 : 전남대학교 농업기계전공 (공학석사)
- 2017년 2월 : 전남대학교 농업기계전공 (공학박사)
- 2016년 7월 ~ 현재 : 국립농업과학원 농업연구사

<관심분야>

농기계, 정밀농업