

# 밀 종자 품종 및 물성 분류를 위한 ResNet50 모델 기반의 이미지 분석

유현채, 서영욱, 김진세, 홍석주, 이아영\*  
국립농업과학원 농업공학부

## Image Analysis Based on ResNet50 Model for Classification of Wheat Seed Varieties and Physical Properties

Hyeon-Chae Yoo, Young-Wook Seo, Jin-Se Kim, Suk-Ju Hong, Ah-Yeong Lee\*  
National Institute of Agricultural Sciences, Department of Agricultural Engineering

**요약** 밀은 대표적인 식량 작물 중 하나이지만 최근 국내 밀 자급률은 1%에 불과하다. 밀의 자급량을 높이기 위해서는 밀 종자의 품종순도를 높여 고품질의 가공물을 얻을 수 있도록 품질 관리를 해야 한다. 본 연구에서는 밀의 품질을 자동으로 판정하는 기술을 마련하기 위하여 딥러닝 알고리즘을 활용하여 밀의 품종과 경질, 연질 여부를 분류하는 모델을 개발하고자 하였다. 우리나라 주요 보급 품종인 금강, 백강, 새금강, 조경, 황금알에 대하여 개발한 이미지 획득 시스템을 이용하여 총 21,256개의 밀 종자 낱알 이미지를 획득하였다. 획득한 이미지에서 낱알의 장축, 단축 길이와 RGB 각각의 평균 색상 값을 계산해 품종, 경도별로 비교하였다. 또한, ResNet50 모델을 이용하여 밀 종자 5품종과 경질, 연질을 분류하는 모델을 개발하였다. 그 결과, 학습, 검증, 테스트 그룹의 분류 정확도는 각각 98.17%, 96.68%, 96.40%를 나타냈다. 테스트 그룹의 혼동행렬을 확인한 결과, 대부분 성공적으로 분류가 이루어졌고 동일 품종에 대해서는 경질, 연질이 100% 정확도로 분류되는 것을 확인하였다. 이를 통해 딥러닝 알고리즘을 이용하여 밀 종자 품종 및 경질, 연질 여부를 판별할 수 있을 것으로 판단된다.

**Abstract** Wheat is one of the major food crops, but the domestic self-sufficiency rate is only 1%. To increase self-sufficiency, it is essential to manage the quality of wheat seeds by classifying the seed quality grades. This study used deep learning algorithms to classify wheat varieties and distinguish hard and soft wheat. Five wheat varieties used in the South were employed, and 21,256 images of individual wheat seeds were acquired using an image acquisition system. The length of the axes and the average values in the RGB channels were then calculated. Furthermore, the ResNet50 architecture was used to classify the five wheat varieties and hardness. The results revealed high classification performances for the training, validation, and test groups, with rates of 98.17%, 96.68%, and 96.40%, respectively. The confusion matrix of the test group indicated successful classification, and hardness was classified with 100% accuracy for the same varieties. Deep learning algorithms enable the determination of wheat seed varieties and hardness.

**Keywords** : Classification, Image Processing, ResNet50, Variety, Wheat

본 논문은 농촌진흥청 어젠다사업(과제번호: PJ016023022023)로 수행되었음.

\*Corresponding Author : Ah-Yeong Lee(National Institute of Agricultural Sciences)  
email: lay117@Korea.kr

Received August 7, 2023

Revised August 31, 2023

Accepted September 1, 2023

Published September 30, 2023

## 1. 서론

밀은 전 세계에서 가장 중요한 식량 작물 중 하나로 식량 안보 측면에서 필수적이다[1]. 밀 주산지는 주로 북반구 고위도에 위치하며, 연중 강우량이 적은 건조한 지역에 분포하고 있다[2]. 국내 밀가루 소비량은 약 30%의 꾸준한 소비세를 이어가고 있으나, 밀 자급률은 1%에 불과하다. 밀의 품질은 제빵과 제과에 있어서 많은 영향을 미치는데 국내의 경우, 저장 및 건조 시설이 부족하고 수확 후 관리 기술이나 처리능력이 미흡하다[3]. 수입에 의존하는 밀의 자급량을 높이기 위하여 우리나라에서는 생산 및 유통 단계에서 기후, 토양, 재배 여건, 수량, 품종, 품질 정보 등의 데이터를 지속 수집, 분석하여 밀 품질 관리를 강화하기 위한 노력을 지속하고 있다[4].

밀 품질 인자로는 크게 단백질, 회분, 수분 등의 내부 품질과 색상, 크기, 길이 등의 외부품질로 이루어진다. 국내는 작은 면적에 다양한 품종의 밀을 재배하는 특징이 있어 같은 지역에서 재배된 밀도 농가에 따라 품질 차이가 나타난다. 농산물품질관리원에서는 수매된 밀 종자에 대하여 인력과 시간을 들여 밀 품질 등급을 나누고 있다. 품질 판정에 드는 노동력과 시간을 줄이기 위해서는 자동화하여 품질을 분석하는 비파괴 기술 개발이 필요한 상황이다.

곡물 품질을 판별하기 위해 사용되는 비파괴 측정 방법으로는 크게 분광 기술[5,6]과 영상처리 기술[7,8]이 있다. 그 중, 영상처리 기술은 색상, 크기, 모양 등의 외부품질 인자를 측정할 수 있고, 판별 속도나 시스템 경제성 면에서 분광 기술보다 유리한 특징을 가진다[9]. 영상처리 기술은 컴퓨터 도입 초기 시기부터 밀의 종류, 빵가루의 부피 변화, 질병 감지 등 다양한 요인 분석에 활용되었다[10-12]. 최근에는 밀의 모양을 분석하거나[13], 인공지능망을 적용해 밀 품종을 분류하고[14], 획득된 이미지의 굴절 및 길이 예측을 통해 형태학적 매개변수를 추정하는 연구도 수행되고 있다[15]. 하지만 이미지 획득 과정에서 정적인 프로세스가 대부분이었으며, 획득 및 분석 과정에서의 전 자동화 시스템을 기반으로 한 연구 사례는 부족한 상황이다.

최근, 그래픽 처리 장치의 발달로 딥러닝과 같은 대량의 데이터 학습 모델이 개발되고 있으며 이는 농산업 분야에 다양한 방법으로 적용되고 있다. 이미지 분류 모델 중에서 CNN(Convolution Neural Network) 모델은 기존 영상처리 기술보다 분류 정확도가 높아 주목받고 있다. 밀과 관련해서는 딥러닝 모델을 적용하여 수확량

손실의 주요 원인이 되는 곰팡이, 박테리아 또는 곤충 질병 등의 감지[16]와 밀 작물의 잡초 탐지[17], 변종에 대한 분류[18] 등의 연구가 이루어지고 있다.

본 연구는 밀 종자별 품종과 경·연질 여부를 비파괴적이고 신속하게 판정하는 모델을 개발하기 위해 다음과 같이 연구를 추진하였다.

- (1) 신속한 이미지 획득이 가능한 자동화된 컨베이어 이송 시스템을 구축하였다.
- (2) 구축한 시스템을 이용하여 밀 종자 낱알 이미지를 획득하였다.
- (3) 획득한 이미지를 통해 낱알별 장·단축 길이와 RGB 색상 정보를 계산하였다.
- (4) ResNet50 모델을 적용하여 품종 및 경질·연질 분류 정확도를 확인하였다.

## 2. 재료 및 방법

### 2.1 공시 재료

밀 종자는 농촌진흥청 국립식량과학원 밀 연구팀으로부터 2023년 수확된 것을 제공받았다. 국내 주요 다섯 품종(금강, 백강, 새금강, 조경, 황금알)으로 구성되어 있으며 품종별 종자는 전문가에 의해 경질과 연질로 육안 선별되었다. 실험에 사용된 밀 종자의 개수는 금강 4,593개(경질: 2,222, 연질: 2,371), 백강 3,929개(경질: 2,105, 연질 1,924), 새금강 4,726개(경질 2,238, 연질 2,488), 조경 3,854개(경질: 2,138, 연질 1,716), 황금알 4,154개(경질: 2,159, 연질 1,995)로 총 21,256 개이다. 이미지 측정 전 밀 종자는 상온 보관하였다.

### 2.2 영상 획득 시스템

밀 종자 낱알별 이미지를 획득하기 위해 컨베이어를 이용한 벤치탑 형태의 이미지 자동 측정 시스템을 Fig. 1과 같이 제작하였다. 투입 호퍼에 밀을 담으면 일정량의 밀이 스텝 모터(Ezi-Step-PR-42M, FASTECH, Bucheon, Republic of Korea)를 통해 이송 컨베이어로 배출된다. 배출된 밀은 이송 컨베이어를 통해 운반되며 카메라를 통해 이송 상태 확인이 가능하다. 컨베이어 끝 지점에서는 낱알마다 저울 방향으로 낙하하며 카메라에서 개별 이미지가 획득된다. 이미지 획득을 위해 CCD 카메라(MV-CS004-11GM, Hikrobot Co., Ltd., Zhejiang Hangzhou, China)를 사용하였으며, 이미지의 해상도

는 720 x 540 pixel, 시야각은 111 x 84 mm이다. 균 일한 밝기의 이미지를 획득하기 위해 면발광 원형조명 (LV-IFRK-96RT3-SW, ㈜엘브이에스, Incheon, Republic of Korea)을 카메라 앞에 장착하여 확산광을 균일하게 조사하였다.




Fig. 1. Automatic wheat image acquisition system

이미지 측정 및 품질 정보 획득 과정은 Fig. 2와 같이 진행되었다. 투입 호퍼에서 스텝 모터를 통해 일렬로 정렬되어 배출된 밀은 이송 컨베이어를 통해 끝단으로 이송된다. 컨베이어 끝단에서는 낱알이 정렬되어 낱알 한 알씩 저울 방향으로 낙하하며 개별 이미지가 획득된다. 획득된 밀 종자 낱알 이미지는 장축을 기준으로 세로로 정렬된다. 정렬된 이미지는 jpg 형식으로 저장된다. 획득된 낱알 이미지에서 배경을 제외한 후 픽셀값을 통해 장축 길이와 RGB 각각의 평균 색상값을 계산된다. 계산된 품질 정보는 CSV 형태로 저장된다. 영상이 측정되는




Fig. 2. Flowchart of the image acquisition

동안 소프트웨어에는 이송 상태와 정렬된 이미지가 실시간으로 표시된다. 소프트웨어는 LABVIEW (LabVIEW NXG 5.1, National Instruments Corporation, USA)를 이용하여 제작되었다.

### 2.3 분류 모델 학습 및 성능평가

밀 이미지를 이용하여 품종과 경·연질 여부를 판별하기 위해 ResNet50 모델을 사용하였다. ResNet은 CNN 구조에서 레이어가 깊어질수록 곱해지는 미분값들이 증가함에 따라 모델 최적화에 떨어진다. ResNet50은 50개의 레이어로 구성되어 있으며 입력 이미지 크기는 224 x 224 x 3 pixel이다. 본 연구에서는 ResNet50의 레이어 구조만을 가져와 측정된 이미지를 이용하여 새로 학습하는 파인튜닝을 진행하였다.

이미지 학습을 진행하기 전 학습 데이터 숫자를 증가시키기 위하여 데이터 증강을 하였다. 데이터 증강에 사용된 파라미터로는 데이터 회전 각도 40%, 좌우 길이 이동 20%, 층밀리기 강도 20%, 줌 범위 20%, 무작위 좌우 반전 등이 있다. 모델 학습을 위해, 데이터 21,256개를 학습 60% (12,753), 검증 20% (4,251), 테스트 20% (4,252)의 비율로 랜덤하게 배분하였다. 모델 학습 데이터의 경우, 데이터 증강을 통해 개수를 16배 증가하였다.

모델 학습을 위한 최적화 알고리즘(Optimizer)으로는 Adam을 사용하였으며 손실 함수(loss)는 categorical cross entropy error를 이용하여 계산되었다. 학습은 3,000번 반복(epoch)하였으며 배치 크기(Batch size)는 16으로 설정하였고 검증 데이터의 손실 함수가 50번 이상 유의미한 변화를 나타내지 않을 경우, 학습을 조기 종결하도록 설정하였다. 학습이 끝난 후, 모델의 판별 정확도와 손실 값을 통해 학습이 제대로 이루어졌는지 확인하였으며, 개발된 모델을 테스트 데이터에 적용한 결과를 혼동행렬(Confusion Matrix)로 나타내어 성능을 평가하였다. 모델 학습을 위해 GPU (RTX 2080Ti, Nvidia Corporation, USA)가 장착된 컴퓨터를 이용하였다.

## 3. 결과 및 고찰

### 3.1 밀 종자 품종 및 물성별 길이

Fig. 3은 5가지 품종의 밀 종자에 대해 획득한 낱알 이미지에서 배경을 제외한 후 낱알 길이 정보의 평균과

표준편차를 그래프로 나타낸 것이고, Fig. 3(a)는 장축 (Length), Fig. 3(b)는 단축(Width)을 나타낸다. 품종별로 경질, 연질의 평균 길이와 표준편차는 차이가 거의 나타나지 않았다. 경질의 경우, 평균 장축, 단축 길이 모두 조경이 가장 길게 나타났으며 편차는 장축의 경우 새금강이, 단축의 경우 황금알이 가장 작게 나타났다. 연질의 경우, 장축 길이는 경질과 같이 조경이 가장 길었으나 단축 길이는 백강이 가장 길게 나타났다. 편차의 경우, 장축은 새금강이, 단축은 새금강과 황금알이 가장 작게 나타났다. 이를 통해, 낱알별 편차는 새금강 품종이 가장 적게 나타나는 것을 확인하였다. 장축과 단축의 길이의 경우, 조경 품종이 대부분 크게 나타났으나, 장축과 단축의 길이가 비례하지는 않는다는 것을 확인하였다. 대부분 동일 품종에 대해 경질이 연질보다 장·단축 길이가 크게 측정되어, 경도 차이는 길이 차이와 비례 관계일 수 있음을 확인하였다. 하지만, 그 차이가 확인하지는 않아 낱알의 길이 정보로 품종 및 경도를 구분하는 것은 어려울 것으로 판단된다.




Fig. 3. Boxplots of axial dimensions by wheat variety (a) Length (b) Width

### 3.2 밀 종자 품종 및 물성별 색상

Fig. 4는 5가지 품종의 밀 종자에 대해 획득한 RGB 각 채널의 색상 값 평균과 표준편차를 나타낸 것이다. Fig. 4(a)는 금강, (b)는 백강, (c)는 새금강, (d)는 조경, (e)는 황금알 품종 결과이다. 색상 정보는 R, G, B 값으로 추출되었고, 0~255 범위의 값을 255로 나누어 퍼센트로 환산하였다. 품종별 R, G, B 평균값은 각각 39.12~41.15, 34.12~35.35, 24.06~26.42의 비율을 나타내었으며 표준편차는 R 값, B 값에서 0.70~1.13의 범위를, G 값에서 0.17~0.33의 비율을 나타내 색상 간 차이를 보여주었다. 특히, G 값은 낱알별 표준편차가 0.33 미만으로 가장 적은 특징을 나타냈다. 색상의 경우, 길이보다 비교적 평균값이 크지만 낮은 표준편차를 나타내 품종 및 경도 분류에 있어서 가능성을 보여주었다.




Fig. 4. Boxplots of RGB color index by wheat variety (a) Keumkang (b) Baekgang (c) Saekeumkang (d) Jokyung (e) Hwanggeumal

### 3.3 밀 종자 품종 및 물성 분류 모델 성능평가

ResNet50 알고리즘을 이용하여 밀 종자 5품종 및 경·연질을 자동으로 분류하는 모델을 개발하였으며 학습 및 검증 데이터의 정확도와 손실 함수를 계산하였다. 모델 학습을 위해, 160번의 반복 학습이 이루어졌으며, 학습 및 검증 정확도는 각각 98.17%, 96.68%로 나타났고, 학습 및 검증 손실 값은 각각 0.0515, 0.1388로 나타났다. 다만 학습 그룹에 비해 검증 그룹의 정확도와 손실 값의 변동이 크게 나타나 성능 개선이 필요할 것으로 판단된다.

Fig. 3은 학습된 ResNet50 모델을 테스트 그룹의 이미지에 적용하여 분류한 결과를 혼동행렬로 나타낸 것이다. 혼동행렬의 대각선 항목은 각 클래스에 대해 올바르게 분류된 이미지 수를 나타내고, 비대각선 항목은 각 클래스에 대해 잘못 분류된 이미지 수를 나타낸다. 445개의 금강 경질 중에서 1개는 백강 경질, 3개는 백강 연질,

1개는 황금알 연질로 잘못 분류되었다. 415개의 황금알 연질은 5개가 새금강 연질로 잘못 분류되어 가장 높은 분류 정확도를 보였다. 최종적으로 테스트 그룹의 분류 정확도는 96.40%, 손실 값은 0.1383으로 좋은 결과를 나타냈다. 또한, 동일 품종에 대해서는 5개의 품종 모두 경질과 연질을 100% 정확도로 분류하였다. 따라서, 품종이 명확한 종자의 경우, 경질과 연질에 대해 딥러닝을 이용하여 분류할 수 있음을 확인하였다.

Keumkang Hard	440	0	1	3	0	0	0	0	0	1
Keumkang Soft	0	429	0	0	1	0	5	0	0	17
BaekKang Hard	1	0	454	0	2	0	0	0	3	0
BaekKang Soft	13	0	0	382	2	9	0	2	0	1
Seaekeumkang Hard	0	0	8	5	337	0	0	0	8	0
Seaekeumkang Soft	2	0	0	1	0	443	4	0	0	1
Jokyung Hard	0	3	1	0	0	10	458	0	0	0
Jokyung Soft	13	0	0	3	0	0	0	401	3	0
Hwanggeumal Hard	0	0	9	0	12	0	0	4	345	0
Hwanggeumal Soft	0	0	0	0	0	5	0	0	0	410

Predicted Value

Fig. 5. Confusion matrix of ResNet50 model test set

#### 4. 결론

본 논문에서는 이미지와 딥러닝을 이용하여 5가지 품종의 밀 종자에 대해 종자별 품종과 경·연질 여부를 비파괴적으로 판정하는 모델을 개발하였다. 모델 개발 전, 낱알별 이미지를 획득하기 위하여 컨베이어 이송 시스템을 제작하였고, 시스템을 통해 획득한 이미지를 이용하여 분류 모델을 개발하였다. 이에 관한 주요 연구 결과는 다음과 같다.

- (1) 낱알별 밀 이미지를 자동으로 측정하기 위해 이송 컨베이어, CCD 카메라 등으로 구성된 이미지 획득 시스템을 제작하였다. 또한, 이미지 획득과 동시에 밀 종자 낱알별 장·단축 길이와 RGB 색상 값을 계산하여 자동 저장되는 소프트웨어를 개발하였다. 본 시스템은 밀 품질 정보 지속 수집, 구축에 활용할 수 있다.
- (2) 밀 종자 낱알별 장·단축 길이 및 RGB 색상 정보를 이용하여 품종별 평균 및 표준편차를 계산하였다.

길이가 경도와 비례 관계일 수는 있으나 품종별 뚜렷한 차이는 나타나지 않았다. 색상 값에서는 G 값이 낱알별 표준편차가 가장 적은 특징을 나타내었고, 길이보다 비교적 평균값이 크지만 낮은 표준편차를 나타내 품종 분류 가능성을 확인하였다.

- (3) ResNet50을 이용하여 분류 모델을 개발하였다. 학습 60%, 검증 20%, 테스트 20% 비율로 데이터를 무작위로 나누어 모델 학습을 진행하였다. 학습, 검증, 테스트의 정확도는 각각 98.17%, 96.68%, 96.40%를, 손실 값은 0.0515, 0.1388, 0.1383으로 좋은 성능을 보여주었다. 테스트 그룹의 혼동행렬을 확인한 결과, 대부분 이미지에서 성공적으로 분류가 이루어졌음을 확인하였고, 품종을 알고 있는 경우, 경질과 연질의 분류는 100% 정확도로 이루어졌다.
- (4) 이미지와 딥러닝을 이용하여 밀 종자 품종 및 경·연질 판별이 가능할 것으로 판단된다. 추후 다른 딥러닝 알고리즘을 이용한 분류 모델을 개발해봄으로써 모델별 성능 비교를 통해 정확도가 높고 강건한 모델을 선정하는 연구가 필요할 것으로 보인다.

#### Acknowledgements

본 연구는 농촌진흥청 어젠다사업(과제번호: PJ016023022023)의 지원으로 수행되었음

#### References

- [1] Giraldo, P., Benavente, E., Manzano-Agugliaro, F., & Gimenez, E. (2019). Worldwide research trends on wheat and barley: A bibliometric comparative analysis. *Agronomy*, 9(7), 352. DOI: <https://doi.org/10.3390/agronomy9070352>
- [2] Trnka, M., Feng, S., Semenov, M. A., Olesen, J. E., Kersebaum, K. C., Rötter, R. P., ... & Büntgen, U. (2019). Mitigation efforts will not fully alleviate the increase in water scarcity occurrence probability in wheat-producing areas. *Science Advances*, 5(9), eaau2406. DOI: <https://doi.org/10.1126/sciadv.aau2406>
- [3] Rempelos, L., Wang, J., Sufar, E.K., Almuayrifi, M.S.B., Knutt, D., Leifert, H., Leifert, A., Wilkinson, A., Shotton, P., & Hasanaliyeva, G. (2023). Breeding Bread-Making Wheat Varieties for Organic Farming

- Systems: The Need to Target Productivity, Robustness, Resource Use Efficiency and Grain Quality Traits. *Foods* 2023, 12(6), 1209.  
DOI: <https://doi.org/10.3390/foods12061209>
- [4] Prey, L., Von Bloh, M., & Schmidhalter, U. (2019). Evaluating RGB Imaging and Multispectral Active and Hyperspectral Passive Sensing for Assessing Early Plant Vigor in Winter Wheat. *Sensors* 2018, 18, 2931. DOI: <https://doi.org/10.3390/s18092931>
- [5] Wang, X., Zhang, X., & Zhou, G. Automatic Detection of Rice Disease Using Near Infrared Spectra Technologies. *J Indian Soc Remote Sens* 45, 785-794 (2017). DOI: <https://doi.org/10.1007/s12524-016-0638-6>
- [6] Guo, J., Huang, H., He, X., Cai, J., Zeng, Z., Ma, C., ... & Liu, Y. (2023). Improving the detection accuracy of the nitrogen content of fresh tea leaves by combining FT-NIR with moisture removal method. *Food Chemistry*, 405, 134905. DOI: <https://doi.org/10.1016/j.foodchem.2022.134905>
- [7] Hameed, S., & Amin, I. (2018). Detection of weed and wheat using image processing. In 2018 IEEE 5th International Conference on Engineering Technologies and Applied Sciences (ICETAS) (pp. 1-5). IEEE. DOI: <https://doi.org/10.1109/ICETAS.2018.8629137>
- [8] Fernandez-Gallego, J. A., Kefauver, S. C., Vatter, T., Gutiérrez, N. A., Nieto-Taladriz, M. T., & Araus, J. L. (2019). Low-cost assessment of grain yield in durum wheat using RGB images. *European Journal of Agronomy*, 105, 146-156. DOI: <https://doi.org/10.1016/j.eja.2019.02.007>
- [9] Rajalakshmi, S., Dineshraj, G., Brindha Priyadarshini, R., & Divya Brindha, R. (2021). Automatic Wheat Grain Grading System Using Physical and Chemical Characteristics. In *Advances in Smart System Technologies: Select Proceedings of ICFSSST 2019* (pp. 359-374). Springer Singapore. DOI: [https://doi.org/10.1007/978-981-15-5029-4\\_30](https://doi.org/10.1007/978-981-15-5029-4_30)
- [10] Neuman, M., Sapirstein, H. D., Shwedyk, E., & Bushuk, W. (1987). Discrimination of wheat class and variety by digital image analysis of whole grain samples. *Journal of Cereal Science*, 6(2), 125-132. DOI: [https://doi.org/10.1016/S0733-5210\(87\)80049-8](https://doi.org/10.1016/S0733-5210(87)80049-8)
- [11] Rouillé, J., Valle, G.D., Devaux, M.F., Marion, D., & Dubreil, L. (2005). French Bread Loaf Volume Variations and Digital Image Analysis of Crumb Grain Changes Induced by the Minor Components of Wheat Flour. *Cereal Chemistry*, 82: 20-27. DOI: <https://doi.org/10.1094/CC-82-0020>
- [12] Jahan, N., Flores, P., Liu, Z., Friskop, A., Mathew, J. J., & Zhang, Z. (2020). Detecting and distinguishing wheat diseases using image processing and machine learning algorithms. In 2020 ASABE Annual international virtual meeting (p. 1). American Society of Agricultural and Biological Engineers. DOI: <https://doi.org/10.13031/aim.202000372>
- [13] Williams, K., Munkvold, J., & Sorrells, M. (2013). Comparison of digital image analysis using elliptic Fourier descriptors and major dimensions to phenotype seed shape in hexaploid wheat (*Triticum aestivum* L.). *Euphytica* 190, 99-116. DOI: <https://doi.org/10.1007/s10681-012-0783-0>
- [14] Khoshroo, A. L. I. R. E. Z. A., Arefi, A. R. M. A. N., Masoumiasl, A. S. A. D., & Jowkar, G. H. (2014). Classification of wheat cultivars using image processing and artificial neural networks. *Agricultural Communications*, 2(1), 17-22. <https://api.semanticscholar.org/CorpusID:110279993>
- [15] Sharma, R., Kumar, M., & Alam, M.S. (2021). Image processing techniques to estimate weight and morphological parameters for selected wheat refractions. *Sci Rep* 11, 20953. DOI: <https://doi.org/10.1038/s41598-021-00081-4>
- [16] Kumar, D., & Kukreja, V. (2022). Deep learning in wheat diseases classification: A systematic review. *Multimed Tools Appl* 81, 10143-10187. DOI: <https://doi.org/10.1007/s11042-022-12160-3>
- [17] Haq, S.I.U., Tahir, M.N., & Lan, Y. (2023). Weed Detection in Wheat Crops Using Image Analysis and Artificial Intelligence (AI). *Appl. Sci.* 2023, 13, 8840. DOI: <https://doi.org/10.3390/app13158840>
- [18] Laabassi, K., Belarbi, M. A., Mahmoudi, S., Mahmoudi, S. A., & Ferhat, K. (2021). Wheat varieties identification based on a deep learning approach. *Journal of the Saudi Society of Agricultural Sciences*, 20(5), 281-289. DOI: <https://doi.org/10.1016/j.issas.2021.02.008>
- [19] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). DOI: <https://doi.org/10.48550/arXiv.1512.03385>

유 현 채(Hyeon-Chae Yoo)

[정회원]



- 2019년 2월 : 전북대학교 생물산 업기계공학과 (공학사)
- 2021년 2월 : 전북대학교 농업기 계공학과 (공학석사)
- 2017년 2월 ~ 현재 : 국립농업과 학원 농업공학부 연구원

<관심분야>

농업, 영상처리, 품질계측

서 영 옥(Young-Wook Seo)

[정회원]



- 1999년 8월 : 경북대학교 농업기계공학과 (공학사)
- 2002년 8월 : 서울대학교 바이오시스템공학과 (공학석사)
- 2008년 8월 : 서울대학교 바이오시스템공학과 (공학박사)
- 2017년 2월 ~ 현재 : 국립농업과학원 농업공학부 농업연구사

<관심분야>

농업, 기계, 품질계측

이 아 영(Ah-Yeong Lee)

[정회원]



- 2017년 8월 : 서울대학교 바이오시스템공학과 (공학사)
- 2019년 8월 : 서울대학교 바이오시스템공학과 (공학석사)
- 2018년 9월 ~ 현재 : 국립농업과학원 농업공학부 농업연구사

<관심분야>

분광분석, 영상처리

김 진 세(Jin-Se Kim)

[정회원]



- 2000년 2월 : 고려대학교 물리학과 (물리학석사)
- 2018년 8월 : 충남대학교 농기계공학과 (농기계공학박사)
- 2013년 10월 ~ 현재 : 국립농업과학원 수확후관리공학과 농업연구사

<관심분야>

물리학, 농업공학

홍 석 주(Suk-Ju Hong)

[정회원]



- 2016년 8월 : 서울대학교 바이오시스템공학과 (공학사)
- 2022년 8월 : 서울대학교 바이오시스템공학과 (공학박사)
- 2023년 4월 ~ 현재 : 국립농업과학원 농업공학부 전문연구원

<관심분야>

농업공학, 품질계측, 수확후공정공학