

딥러닝 모델 기반 시멘틱 세그멘테이션을 이용한 벼 도복 추정

김병준¹, 박근호¹, 안형근², 김기연², 정성환^{1*}

¹한국전자기술연구원, ²국립종자원

Estimation of Rice Lodging Using Semantic Segmentation Based on Deep Learning Model

Byoungjun Kim¹, Keunho Park¹, Hyung-geun Ahn², Kee-yeun Kim², Sunghwan Jeong^{1*}

¹Korea Electronics Technology Institute

²Korea Seed & Variety Service

요약 벼 도복은 매년 태풍 및 장마로 인해 벼 생산에 막대한 피해를 주는 원인이며, 조기 발견을 통해 벼 수확량 및 수발아와 관련된 피해를 예방하기 위한 효과적인 방법이 필요하다. 본 논문에서는 무인 항공기를 이용하여 촬영된 영상에서 벼 도복을 추정하는 방법을 제안한다. 제안하는 방법은 ResNetV2 101백본 네트워크 기반 DeepLabV3+ 시멘틱 세그멘테이션 모델로, 도복(lodging), 일반 벼(non-lodging), 그리고 배경(background) 영역에 대해 추정한다. 제안한 모델의 학습 및 평가를 위해 경상도, 전라도, 충청도 일대에서 무인 항공기를 이용하여 벼 도복 관련된 816장 영상을 수집하였다. 수집한 데이터는 748개의 학습 데이터, 40개의 검증 데이터, 28개의 평가 데이터로 나눈 후, 추정 성능 향상을 위해 전이학습, Focal Loss 손실 함수 등 다양한 방법을 적용하였다. 평가 데이터 28장에 대해 성능을 평가한 결과, Focal Loss 손실 함수를 적용한 DeepLabV3+ 시멘틱 세그멘테이션 모델이 93.16%의 픽셀 정확도와 87.75%의 mIoU로 좋은 결과를 보였다. 추정된 결과를 통해 도복과 일반벼의 분포를 파악할 뿐만 아니라, 도복의 확산 경향과 피해, 형태 등을 분석하는데 사용할 수 있다고 사료된다.

Abstract Rice lodging is an annual occurrence that causes enormous damage to rice production by typhoons and rainy seasons. Therefore, it is necessary to find an effective method to prevent the damage to rice yield and pre-harvest sprouting through early detection. This paper proposes an estimation method for rice lodging based on RGB images captured by unmanned aviation vehicles. The proposed method constructs the DeepLabV3+ semantic segmentation model based on ResNetV2 101 backbone network and estimates the area of lodging, non-lodging, and background. To train and evaluate the proposed model, we captured 816 images related to rice lodging using an unmanned aerial vehicle in Gyeongsang-do, Jeolla-do, and Chungcheong-do. The collected dataset was divided into 748 training data, 40 validation data, and 28 evaluation data, which were then used in various methods such as transfer learning and focal loss function for the improved estimation performance. The evaluation of performance using 28 evaluation data shows that the DeepLab V3+ semantic segmentation model, to which the focal loss function was applied, yields the best results with 93.16% pixel accuracy and 87.75% mIoU. Furthermore, the estimation result can be used to find the distribution of lodging and non-lodging and analyze the trend of spreading lodging, damage, and shape.

Keywords : Deep Learning, Rice Lodging, Semantic Segmentation, Unmanned Aviation Vehicle, RGB Image

본 논문은 농림축산식품부의 재원으로 농림식품기술기획평가원의 첨단생산기술개발사업의 지원을 받아 연구되었음(320019-2).

*Corresponding Author : Sunghwan Jeong(Korea Electronics Technology Institute)

email: shjeong@keti.re.kr

Received July 6, 2021

Accepted September 3, 2021

Revised August 26, 2021

Published September 30, 2021

1. 서론

우리나라의 벼농사에서 냉해, 한해, 침관수 피해 등 여러 가지 기상재해가 있으나, 그중에서도 수확량 감소에 크게 영향을 주는 것은 집중 호우나 태풍에 의하여 도복 피해가 발생한다. 도복 피해는 바람과 강우가 주된 원인이 되지만, 품종특성, 기상조건, 시비량, 물 관리, 재배 방법, 재식밀도, 병충해 등에 따라서도 영향을 크게 받는다[1]. 특히, 벼가 도복 되어 벼 이삭에 썩이 트는 현상인 수발아 피해가 발생하여 벼의 수량과 미질에 큰 영향을 미치기 때문에 벼 도복 면적 피해를 조기에 신속하게 탐색하는 것은 필수적이다[2]. 도복 피해 면적 산정 방법은 전문가가 직접 피해 지역을 방문하여 조사하는 방식으로 많은 시간과 비용이 요구되는 문제점이 있다.

최근 드론 및 인공지능 기술 발전으로 벼 도복 피해 면적을 추정하는 연구들이 진행되고 있다. [2]는 Marvic pro 드론을 이용하여 김제시, 부안군 군산시 일대의 농지를 대상으로 5m, 10m, 그리고 20m 촬영 기준을 통해 가로 3000, 세로 300 크기의 RGB 영상을 수집하였다. 딥러닝 모델의 학습을 원활히 진행하기 위해 수집된 영상은 가로 128, 세로 128 크기로 분할 후 딥러닝 모델 중 CNN(Convolutional Neural Network)을 통해 도복과 일반 벼로 분류하였다. [3]은 GLCM(Gray Level Co-occurrence Matrix), LBP(Local Binary Pattern) 및 Gabor 필터를 이용하여 공간적인 특징을 추출 후 SVM(Support Vector Machine) 분류기를 통해 도복과 일반 벼를 분류하는 방법을 제안하였다. [4]는 가로 9492, 세로 8340 크기의 영상을 가로 64, 세로 128 크기로 분할 후 CNN을 통해 추출된 공간적인 특징과 GLCM 및 LBP 특징들과 결합 후 softmax 분류기를 통해 도복과 일반 벼를 분류하는 모델을 제안하였다.

이러한 연구들은 일정 크기로 분할된 영상을 기반으로 도복과 일반 벼를 분류하는 방법으로 농지 내 도복의 면적을 간접적으로 추정할 수 있다. 하지만, 일정 크기로 분할된 영상을 기반으로 도복과 일반 벼를 분류하기 때문에 농지 외 영역이 포함된 영상인 경우 오분류 하는 문제가 존재한다.

본 논문에서는 드론을 이용하여 농지를 촬영한 RGB 영상을 기반으로 도복 내 주변 환경 및 농지 외 영역으로 인한 오 분류 감소 및 성능 개선에 대한 방법을 제안한다. 제안한 방법에서는 주변 환경 및 영역 추정의 오류를 최소화하기 위해 도복, 일반 벼, 그리고 배경 영역으로 세 개의 클래스를 구성하고, 공개 데이터 집합 중 Pascal

VOC 데이터 집합[5]에 대해 픽셀 정확도 89%를 보유한 ResNet 101 백본 네트워크를 이용한 DeepLab V3+ 시멘틱 세그멘테이션 모델[6]을 사용한다.

드론으로 수집한 데이터는 총 816장으로 딥러닝 모델을 학습하기에 충분하지 않기 때문에 과적합 문제가 발생한다. 이에 대해 공개 데이터 집합인 ImageNet 데이터[7]를 사용하여 ResNetV2 101구조를 사전 학습한 결과를 이용하는 전이학습(Transfer Learning) 방법[8]을 적용하였다. 또한, 과적합 방지를 위해 매 epoch마다 학습 데이터를 무순위로 재구성하는 방법과 클래스 불균형 문제 및 성능 개선에 대한 focal loss 손실 함수[9]를 적용하여 학습을 진행하였다. 평가 데이터 28장을 이용하여 픽셀 정확도(Pixel Accuracy)와 mIoU(mean Intersection over Union)에 대해 성능평가 결과 93.16%와 87.75%의 성능을 나타내었다. 실험결과를 통해 다양한 환경을 포함한 영상에 강건하게 도복 주변 환경의 오류를 최소화할 수 있으며, 촬영 지역의 도복 비율과 경향을 분석하는 데 적합하다고 판단된다.

본 논문의 구성은 다음과 같다. 2장에서는 데이터 세트와 DeepLabV3+ 모델, 그리고 모델 학습 및 최적화에 관해 기술한다. 3장에서는 평가 방법 및 실험결과를 제시하고, 마지막 4장에서는 결론 및 향후 연구를 기술한다.

2. 본론

2.1 DeepLab V3+ 기반 영역 추정 모델

일반적으로 도복은 정도에 따라 완전 도복과 반 도복으로 나누어지고, 형태에 따라 좌절형, 만곡형, 뿌리, 그리고 개장형 도복으로 분류되고, 도복 방향에 따라 주간 방향, 조간방향, 그리고 복합적인 도복 등으로 나누어진 다[10].

드론 촬영 높이에 따라 도복 영역은 다양한 형태와 크기를 나타내며, 일정한 형태를 가지고 있지 않기 때문에 도복 영역을 추정하는 것은 어려운 문제이다. Fig. 1은 20m, 40m, 그리고 135m 비행 높이에서 촬영한 도복 영역의 일부분을 보여준다.

도복 영역의 형태와 면적을 추정하기 위해서는 주변 환경의 다양성에 대한 오류의 최소화가 필수적이다. 본 논문에서는 도복, 일반 벼, 그리고 배경 영역으로 구성한 세 개의 클래스 기반 DeepLab V3+ 시멘틱 세그멘테이션 모델을 구성하였다. Fig. 2는 제안한 방법의 구조를 보여준다.




Fig. 1. Sample rice lodging images for the flight height: (a), (b), and (c) are 20m, 40m, and 135m, respectively.




Fig. 2. The Deeplab V3+ semantic segmentation structure for rice lodging prediction.

Fig. 2와 같이 드론으로 촬영한 RGB 영상은 Encoder 구조에서 separable convolution atrous convolution을 결합한 atrous separable convolution을 통해 다양한 크기에 대한 주변 환경의 공간적인 특징들까지 고려한 특징들을 추출한다. 추출된 공간적인 특징들은 Decoder 구조에서 concatenate와 up-sampling을 통해 재구성한 후 도복, 일반 벼, 그리고 배경 영역에 대해 추정한다.

2.2 도복 데이터

2020년 가을, 강한 바람과 비를 동반한 ‘마이삭’과 ‘하이선’ 태풍으로 벼가 도복 되는 피해가 발생하여, 2020년 09월 09일부터 10월 14일까지 경상도, 전라도, 그리고 충청도 일대 농지를 대상으로 DJI사 Marvic 2 Pro 드론을 이용하여 20m, 30m, 40m, 50m, 120m, 그리고 135m 등 다양한 비행 높이에서 촬영하였다. 촬영된 영상은 가로 5472, 세로 3648 크기인 RGB 영상으로 수집한 데이터의 정보는 Table 1과 Fig. 3에 제시한다.

Table 1. The dataset information

Area	Collection date	Number of data
Gyeongsang-do	2020.09.14.~2020.09.16	233
Jeolla-do	2020.09.21.~2020.10.14	335
Chungcheong-do	2020.09.09.~2020.09.29	248
Total		816




Fig. 3. Sample images for the collection rice lodging

DeepLab V3+ 시멘틱 세그멘테이션 모델을 학습하기 위해서는 추정하고자 하는 영역 내 픽셀에 대해 클래스를 부여해야 한다. Fig. 1과 Fig. 3을 통해 수집한 데이터들은 벼의 생육 단계에 따라 색상 차이가 존재하며, 도복 피해 정도에 따라 형태가 다르다는 것을 알 수 있다. 또한, 드론 비행 높이에 따라 농지 외의 도로, 비닐하우스, 주택 등과 같은 다양한 환경을 포함하기 때문에 도복 영역만 레이블링할 경우 도복 주변 환경 영역 및 도복

외 영역을 오분류하여 추정 성능이 저하될 수 있다.

이를 해결하기 위해 본 논문에서는 빨간, 파란, 그리고 노란색을 사용하여 Fig. 4와 같이 도복, 일반 벼, 그리고 배경 영역으로 구분 후 레이블링을 수행하였다.




Fig. 4. The processing procedure of labeling process for background, lodging, and non-lodging classes.

2.3 모델 학습 및 최적화

딥러닝 모델은 양질의 대량 데이터를 사용하여 학습할 경우 최적의 성능을 나타내지만, 수집한 데이터의 수는 816장으로 데이터 부족과 과적합으로 인한 모델 학습 및 최적화의 어려움이 존재한다.

이에 대해 공개 데이터 중 ImageNet을 사용하여 ResNetV2 101 구조를 사전 학습한 결과를 이용하여 공간적인 특징을 추출하는 전이학습 방법과 과적합을 방지하기 위해 매 epoch마다 학습 데이터의 순서를 무순위로 재구성하는 방법을 적용하였다. Fig. 3과 같이 촬영 높이와 환경에 따라 도복, 일반 벼, 그리고 배경 영역의 비율이 일정하지 않기 때문에 클래스 불균형 문제를 해결하기 위해 focal loss 손실 함수를 적용하였다.

focal loss 손실 함수는 클래스의 불균형 문제를 해결하기 위한 것으로 매 epoch마다 잘 분류되는 클래스의 가중치를 낮추고, 어렵게 분류되는 클래스의 가중치를 높이는 방법으로 다음과 같다.

$$Focal\ loss = -\alpha_t(1-p_t)^\beta \log(p_t) \quad (1)$$

Where, p_t denotes probability of prediction, α and β parameters denote adjusting the weight between classes

제안한 모델에 대해 학습, 검증, 그리고 평가를 위해 수집한 데이터 816장 중 학습 748장, 검증 40장, 그리고 평가 28장으로 구성하였다. 학습 및 검증에 사용된 컴퓨터 환경은 Intel Xeon(r) 6230R 2.10GHz, 128 RAM, Geforce RTX 2080Ti 2대이며, python 3.6.8, opencv 4.5, 그리고 Tensorflow 1.14 개발환경에서 진행하였다.

모델 학습에 사용된 매개변수는 epoch 210, batch size 5, start learning rate 0.007, end learning rate 0.000001, weight decay 0.0002, momentum 0.9, SGD(Stochastic Gradient Descent), polynomial learning rate policy, output stride 16, batch normalization 방법을 사용하였다. 또한, 전이학습 적용 및 도복 일반 벼, 그리고 배경 영역을 강건하게 추정하기 위해 0.5~2.0배 크기 조절하여 가로 513, 세로 513 크기로 분할한 RGB 패치 영상을 사용하였다.

3. 실험 및 결과

3.1 손실 함수에 따른 모델 성능 결과

본 논문에서는 손실 함수에 따른 모델 성능을 측정하기 위해 학습 및 검증에 사용하지 않은 28개의 평가 데이터를 사용하였다. 모델의 신뢰성 있는 결과가 도출되었는지 확인하기 위해 픽셀 정확도와 mIoU를 Eq. (2)와 Eq. (3)을 통해 도출하였다.

픽셀 정확도는 분할된 픽셀 수가 레이블링된 픽셀 수를 정확하게 예측한 비율 정도로 클래스가 균형일 때 효과적이다. mIoU는 예측된 분할 영역과 레이블링된 영역에 대해 정확하게 겹치는 비율로, 영역 분할 성능을 평가할 때 사용한다.

$$Pixel\ accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (2)$$

$$mIoU = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i + FN_i} \quad (3)$$

Where, TP denotes true positive, TN denotes true negative, FP denotes false positive, FN denotes false negative, N denotes number of classes

Table 2를 통해 손실 함수에 따른 모델 성능 비교를 분석할 수 있다. 분석 결과, 픽셀 정확도는 최소 92.20%

부터 최대 93.16%로 도복, 일반 벼, 그리고 배경 영역의 픽셀을 강건하게 분류할 수 있음을 알 수 있다. 또한, mIoU는 영역 예측에 대해 최소 85.31%부터 최대 87.75%로 다양한 환경을 포함하더라도 도복, 일반 벼, 그리고 배경 영역의 공간적인 특징을 추출하고 주변 환경의 오류 최소화 및 추정하는 성능이 우수하다는 것을 알 수 있다.

손실 함수 비교를 통해 softmax cross entropy loss 함수를 사용할 경우 focal loss 함수(매개변수 $\alpha=0.25\sim0.75$, $\beta=2.0$)와 비교할 경우 softmax cross entropy loss 함수를 사용하는 것이 평균 픽셀 정확도 2.01%, mIoU 0.98%의 높은 성능을 나타내는 것을 알 수 있다. 반면, 픽셀 정확도와 mIoU를 통해 가장 성능이 높은 방법은 focal loss 함수(매개변수 $\alpha=1.0$, $\beta=2.0$)를 적용하였을 때이며, 픽셀 정확도 0.96%, mIoU 0.81%의 높은 성능을 나타낸 것을 확인할 수 있다.

Table 2. The accuracy for validation datasets base loss function(softmax cross entropy loss, focal loss) analysis

index	loss	α	β	pixel accuracy(%)	mIoU(%)
1	softmax cross entropy			92.20	86.94
2	focal loss	0.25	2.0	89.96	85.97
3		0.5		89.23	85.31
4		0.75		91.39	86.58
5		1.0		93.16	87.75

focal loss 함수(매개변수 $\alpha=1.0$, $\beta=2.0$)를 적용할 경우 다양한 비행 높이에서 복잡한 환경을 포함하여 촬영한 영상일지라도 클래스 불균형 해결 및 도복, 일반 벼, 그리고 배경 영역의 주변 환경 오류를 최소화할 뿐만 아니라 강건하게 영역을 추정할 수 있다고 판단된다.

3.2 벼 도복 영역 추정 가시화

Table 2에서 우수한 성능을 나타낸 focal loss 함수(매개변수 $\alpha=1.0$, $\beta=2.0$)를 사용한 모델을 통해 일부 평가 데이터를 추정한 결과는 Fig. 5와 같다. 그림에서 알 수 있듯이 도복과 일반 벼, 그리고 배경 영역의 정확한 위치와 형태를 얻어낼 수 있음을 알 수 있다.

한편 Fig. 5(b)의 영상에서 추정하고자 하는 배경 영역의 면적이 작거나 일반 벼와 유사한 공간적인 특징을 가질 경우 잘못 추정한 영역들이 존재하지만, 입력 영상

과 추정한 결과를 비교할 경우 도복의 위치와 형태를 잘 분별해서 보여주며 촬영 지역의 도복의 비율과 일반 벼의 면적과 경향을 확인할 수 있다.




Fig. 5. DeepLabV3+ sementic segmentation model result; (a) and (b) are input images, and predict results, respectively.

4. 결론

벼 도복은 매년 벼 생산에 막대한 피해를 주는 원인으로 조기 발견을 통해 벼 수확량 감소 및 기타 질병을 예방할 수 있다. 본 논문에서는 무인항공기로 촬영한 RGB 영상을 딥러닝 모델 중 ResNetV2 101 구조 기반 DeepLab V3+시멘틱 세그멘테이션을 이용하여 도복, 일반벼, 그리고 배경 영역을 추정한다.

수집한 도복 데이터가 충분하지 않기 때문에 공개 데이터셋인 ImageNet 데이터로 ResNetV2 101 구조를 사전 학습한 결과를 이용하는 전이학습을 적용하고, 학습 성능을 개선하기 위해 focal loss 손실 함수와 매 epoch마다 학습 데이터 무순위 구성을 적용하여 학습하였다. 평가 데이터 28장을 통해 성능을 평가한 결과, focal loss 함수(매개변수 $\alpha=1.0$, $\beta=2.0$)를 적용할 때 픽셀 정확도 93.16%, mIoU 87.75%의 성능이 도출되었다.

제안한 방법의 성능 결과를 통해, 무인 항공기로 농지를 촬영한 RGB 영상에 대해 도복, 일반 벼, 그리고 배경 영역 추정이 가능하다고 판단된다. 이번 연구를 통해 다양한 환경에서 촬영된 농지 영상에 대해 도복 및 일반 벼의 영역의 주변 환경에 대한 오류를 완화할 수 있으며, 촬영 해당 지역의 도복과 일반 벼의 면적과 경향을 확인할 뿐만 아니라 피해 상황을 쉽게 알아볼 수 있다고 사료된다. 향후 위성 정보와 결합하여 도복과 일반 벼의 면적 산정과 정확도 개선에 관한 연구를 진행할 예정이다.

References

- [1] M.H. Lee, Y.J. Oh, and R.K. Park, "Mechanisms of Lodging and Reducing Techniques of Lodging Damage of Rice Plant," *Korean Journal of Crop Science*, Vol.36, No.5, pp.383-393, Oct, 1991.
- [2] Ho-Young Ban, Jae-Kyeong Baek, Wan-Gyu Sang, Jun-Hwan Kim and Myung-Chul Seo, "Estimation of the Lodging Area in Rice Using Deep Learning," *Korean Journal of Crop Science*, Vol.66, No.2, pp.105-111, June, 2021.
DOI: <https://doi.org/10.7740/kjcs.2021.66.2.105>
- [3] S. Rajapaksa, M. Eramian, H. Duddu, M. Wang, S. Shirliffe, S. Ryu, A. Josuttis, T. Zhang, S. Vail, C. Pozniak, and I. Parkin. "Classification of crop lodging with gray level co-occurrence matrix," *In 2018 IEEE Winter Conference on Applications of Computer Vision*, pp.251-258, March, 2018.
DOI: <https://doi.org/10.1109/WACV.2018.00034>
- [4] Sara Mardanisamani, Farhad Maleki, Sara Hosseinzadeh Kassani, Sajith Rajapaksa, Hema Duddu, Menglu Wang, et. al, "Crop Lodging Prediction From UAV-Acquired Images of Wheat and Canola Using a DCNN Augmented With Handcrafted Texture Features," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, June, 2019.
DOI: <https://doi.org/10.1109/CVPRW.2019.00322>
- [5] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam. "Encoder-decoder with atrous separable convolution for semantic image segmentation," *Proceedings of the European conference on computer vision (ECCV)*, pp.801-818, Oct, 2018.
DOI: https://doi.org/10.1007/978-3-030-01234-2_49
- [6] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks," *Communications of the ACM*, Vol.60, No.6, pp.84-90, Jun, 2017.
DOI: <https://doi.org/10.1145/3065386>
- [7] Pan, Sinno Jialin, and Qiang Yang, "A survey on transfer learning", *IEEE Transactions on knowledge and data engineering*, Vol.22, No.10, pp.1345-1359, Oct, 2009.
DOI: <https://doi.org/10.1109/TKDE.2009.191>
- [8] Shruti Jadon, "A survey of loss functions for semantic segmentation", *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*, pp.1-7, Oct, 2020.
DOI: <https://doi.org/10.1109/CIBCB48159.2020.9277638>
- [9] Hoengseong agricultural technology center, reducing techniques of lodging damage of rice plant, agricultural technology information, Hoengseong agricultural technology center, Korea, Available From: <https://www.hsg.go.kr/life/agri/00000656.web?amode=view&idx=80993&gcode=2012&> (accessed July, 24, 2021)
- [10] Everingham, M., Van Gool, L., Williams, C. K., Winn, J., & Zisserman, A. "The pascal visual object classes (voc) challenge", *International journal of computer vision*, Vol.88, No.2, pp.303-338, Sep, 2010.
DOI: <https://doi.org/10.1007/s11263-009-0275-4>

김 병 준(Byoungjun Kim)

[정회원]



- 2015년 2월 : 전북대학교 컴퓨터 공학부 (공학사)
- 2017년 2월 : 전북대학교 전자정보공학부 (공학석사)
- 2021년 2월 : 전북대학교 전자정보공학부 (공학박사)
- 2021년 3월 ~ 현재 : 한국전자기술연구원 박사후과정

<관심분야>

인공지능, 딥러닝, 데이터 분석

박 근 호(Keunho Park)

[정회원]



- 2015년 2월 : 전북대학교 전자정보공학부 (공학석사)
- 2019년 8월 : 전북대학교 전자정보공학부 (공학박사)
- 2019년 12월 ~ 2020년 12월 : 한국전자기술연구원 박사후과정
- 2021년 1월 ~ 현재 : 한국전자기술연구원 선임연구원

<관심분야>

머신비전, 인공지능, 딥러닝

안 형 근(Hyung-Geun Ahn)

[정회원]



- 1995년 8월 : 경북대학교 원예학과 (농학석사)
- 1998년 8월 : 경북대학교 원예학과 (농학박사)
- 2001년 6월 ~ 2011년 9월 : 국립종자원 연구사, 연구관
- 2011년 9월 ~ 2020년 1월 : 농림축산식품부 연구관
- 2020년 2월 ~ 현재 : 농림축산식품부 국립종자원 품종보호과장

〈관심분야〉

품종보호제도, 스마트팜, 작물 특성 영상처리, 인공지능

정 성 환(Sung-Hwan Jeong)

[정회원]



- 2004년 2월 : 전주대학교 컴퓨터공학과 (공학사)
- 2006년 2월 : 전북대학교 의용생체공학과 (공학석사)
- 2012년 8월 : 전북대학교 컴퓨터공학과 (공학박사)
- 2012년 5월 ~ 현재 : 한국전자기술연구원 선임연구원

〈관심분야〉

스마트팜, 자율주행, 교통정보수집 및 예측, 로봇응용기술, 영상처리, 인공지능

김 기 연(Kee-Yeun Kim)

[정회원]



- 1996년 2월 : 경북대학교 농과대학원 농학과 (농학석사)
- 2000년 8월 : 충남대학교 자연과학대학 생물학과 (이학박사)
- 2000년 9월 ~ 2003년 10월 : 삼양제넥스 생명공학연구소 책임연구원
- 2005년 5월 ~ 2012년 3월 : 특허청 생명공학분야 심사관
- 2012년 3월 ~ 현재 : 농림축산식품부 국립종자원 식량종자과장

〈관심분야〉

생명공학, 농업, 빅데이터