한국시뮬레이션학회 논문지
Vol. 30, No. 2, pp. 41-48 (2021. 6)

http://doi.org/10.9709/JKSS.2021.30.2.041
ISSN 1225-5904

CNN을 활용한 새싹삼의 품질 예측 모델 개발

이충구 · 정석봉 †

A Quality Prediction Model for Ginseng Sprouts based on CNN

Chung-Gu Lee · Seok-Bong Jeong†

ABSTRACT

As the rural population continues to decline and aging, the improvement of agricultural productivity is becoming more important. Early prediction of crop quality can play an important role in improving agricultural productivity and profitability. Although many researches have been conducted recently to classify diseases and predict crop yield using CNN based deep learning and transfer learning technology, there are few studies which predict postharvest crop quality early in the planting stage. In this study, a early quality prediction model is proposed for sprout ginseng, which is drawing attention as a healthy functional foods. For this end, we took pictures of ginseng seedlings in the planting stage and cultivated them through hydroponic cultivation. After harvest, quality data were labeled by classifying the quality of ginseng sprout. With this data, we build early quality prediction models using several pre-trained CNN models through transfer learning technology. And we compare the prediction performance such as learning period and accuracy between each model. The results show more than 80% prediction accuracy in all proposed models, especially ResNet152V2 based model shows the highest accuracy. Through this study, it is expected that it will be able to contribute to production and profitability by automating the existing seedling screening works, which primarily rely on manpower.

Key words : convolutional neural network (CNN), Ginseng Sprouts, Quality Prediction, Image Recognition

요 약

농촌 인구의 감소와 고령화가 지속되면서 농업 생상성 향상의 중요성이 높아지고 있는 가운데, 농작물 품질에 대한 조기 예측은 농업 생산성 및 수익성 향상에 중요한 역할을 할 수 있다. 최근 CNN 기반의 딥러닝 기술 및 전이 학습을 활용하여 농작물의 질병을 분류하거나 수확량을 예측하는 연구가 활발하게 진행되고 있지만, 수확 후 농작물의 품질을 식재단계에서 조기에 예측하는 연구는 찾아보기 힘들다. 본 연구에서는 건강 기능성 식품으로 주목받고 있는 새싹삼을 대상으로, 수확 후 새싹삼의 품질을 식재단계에서 조기에 예측하는 모델을 제안한다. 이를 위하여 묘삼의 이미지를 촬영한 후 수경재배를 통해 새싹삼을 재배하였고, 수확 후 새싹삼의 품질을 분류하여 실험 데이터를 수집하였다. 다수의 CNN 기반의 사전 학습된 모델을 활용하여 새싹삼 조기 품질 예측 모델을 구축하고, 수집된 데이터를 이용하여 각 모델의 학습 및 예측 성능을 비교 분석하였다. 분석 결과 모든 예측 모델에서 80% 이상의 예측 정확도를 보였으며, 특히 ResNet152V2 기반의 예측 모델에서 가장 높은 정확도를 보였다. 본 연구를 통해 인력에 의존하던 기존의 묘삼 선별 작업을 자동화하여 새싹삼의 품질을 높이고 생산량을 증대시켜 농가의 수익창출에 기여할 수 있을 것으로 기대된다.

주요어 : 합성곱신경망, 새싹삼, 품질예측, 이미지 인식

Received: 25 February 2021, **Revised**: 7 May 2021, **Accepted**: 9 May 2021

† **Corresponding Author**: Seok-Bong Jeong
E-mail: sbjung@kiu.kr
Professor, Dept. of Railway, Kyungil University, Kyeongbuk-do, Korea

1. 서론

최근 건강에 대한 소비자들의 관심이 증가하면서 식생활에서도 기능성 및 건강 관련 식품들이 선호되고 있다. 이에 따라 새싹채소에 대한 소비자의 관심도 커지고 있

는데 새싹채소란 일반적으로 종자로부터 발아하여 떡잎이 전개되거나, 그전 단계에서 모든 부위를 이용하는 채소를 일컫는다(Jun 등, 2012). 식물체의 종자에는 다당류, 탄닌 및 사포닌 등의 비소화성 성분이 다량 함유되어 있어, 이를 발아시켜 새싹채소로 키우면 기능성 물질을 생성하게 되어 영양성분이 증가된다(Lee 등, 2014).

한편 인삼은 아랄리아과의 다년생 식물로써, 특히 아시아에서는 2,000년 이상 전통 한약재로 널리 사용되어 왔다. 또한 최근에는 항산화나 항염증을 포함한 다양한 생물학적 기능이 있음이 밝혀져 건강식품으로도 관심과 소비량이 증가되고 있다(Lee 등, 2020).

인삼은 토경방식으로 묘삼 식재 후 5~6년간 재배하여 수확한 다음 뿌리부분을 식용으로 사용하는 것이 일반적이지만, 최근에는 묘삼을 새싹채소 방식으로 재배한 후 전 부위를 섭취하는 새싹삼의 소비가 증가하고 있다(Seong 등, 2019). 새싹삼의 잎과 줄기 등 지상부에는 뿌리보다 진세노이드 함량이 최대 12배가 높아 우수한 건강기능 식품으로 간주되며, 기존 인삼대비 재배기간이 짧고 재배가 용이하여 관련 시장이 빠르게 성장하고 있다(Kang 등, 2016). 새싹삼과 관련된 공식적인 통계는 찾아보기 어려우나 새싹삼의 재료인 묘삼의 국내 시장 규모는 200~300억 원으로 추정되며, 향후 1000억 원대의 성장이 예상된다(Cho, 2018).

새싹삼은 모밭에서 최대 24개월간 재배한 묘삼을 수경 또는 토경방식으로 25~40일 정도 재배하여 수확하는 것이 일반적이다(Chang 등, 2020). 따라서 일반적으로 종자를 직접 파종해서 수확하는 다른 새싹채소들과는 달리, 묘삼의 품질이 새싹삼의 품질에 미치는 영향이 크다고 할 수 있다(Suh 등, 2018; Zhang 등, 2018; Park 등, 2011). 즉, 양질의 묘삼을 식재해야 고품질의 새싹삼을 수확할 수 있는데, 현재 농가에서의 묘삼 선별 작업은 주로 인력에 의존하고 있고 선별자 교육에 많은 시간과 노력이 요구되고 있다(Oh 등, 2011).

한편 농업 분야에서 Convolution Neural Network (CNN) 기반의 딥러닝 기술을 활용하여 질병 진단 및 수확량 예측 등을 자동화하는 하는 연구와 기술개발이 활발히 이루어지고 있다. Sladojevic 등(2016)은 CNN 분류기를 활용하여 13종의 농작물의 질병 분류 모델을 최초로 개발하였고, Picon 등(2018)은 ResNet 기반의 CNN을 활용하여 모바일 단말기로 촬영된 농작물의 질병 분류기를 개발하였다. Ferentinos(2018)는 58종의 질병을 포함한 농작물 데이터 세트에 대하여 VGG 기반의 CNN 분류기를 개발하여 99.53%의 높은 분류 정확도를 보였다. Jeong 등(2020)은 VGG16을 활용하여 사전에 학습되지 않은 미학습 농작물의 질병 여부를 진단하는 모델을 구축하였으며, 이외에도 다수의 연구들이 농작물의 질병 분류 및 수확량 예측 정확도를 높이기 위해 수행되었다(Sun 등 2019; Li 등 2020: Khaki 등, 2020: Liu 등 2020).

한편 농업 분야에 CNN 기반 딥러닝 기술을 적용한 기존 연구에서는 농작물의 생산성 및 수익성을 높이기 위한 조기 품질 예측과 관련된 연구는 찾아보기 힘들다. 본 연구에서는 수확 이후 새싹삼의 품질을 묘삼의 이미지 분석을 통해 예측할 수 있는 모델을 제안한다. 이를 위해 다수의 사전 학습된 CNN 모델을 기반으로 새싹삼의 품질 예측 모델을 구축하고, 이들의 성능 비교를 통해 가장 좋은 예측 모델이 무엇인지 규명하고자 한다. 이러한 품질 예측 기법을 통해 인력에 의존하던 기존의 묘삼 선별 작업을 자동화하여 생산성 향상에 기여할 수 있을 것으로 기대한다.

본 논문은 다음과 같이 구성된다. 2장에서는 본 연구에서 수집한 데이터 세트를 소개하고 새싹삼의 품질 예측 모델의 구축 방법에 대하여 설명한다. 3장에서는 제안된 품질 예측 모델의 성능을 살펴보고, 끝으로 4장에서는 제안된 모델의 활용방안 및 추후 연구 방향에 대하여 기술한다.

2. 새싹삼의 품질 예측 모델

새싹삼은 토경방식으로 재배한 1년생 묘삼을 상토나 수경재배 장치에 이식하고 약 25~40일 재배한 후 수확하는 것이 일반적이다. 본 연구에서는 묘삼의 형태 및 외관적 특성이 수확한 새싹삼의 품질에 영향을 미칠 것이라는 가정을 바탕으로 한다. 즉, 수확 이후의 새싹삼의 품질을 재배 전 묘삼의 이미지 분석을 통해 조기에 예측하는 모델을 제안하고자 한다.

2.1 데이터 수집

본 연구에서는 데이터 수집을 위해 1년생 묘삼을 수경재배 방식으로 재배하였다. 식물을 수경 재배하는 방식에는 물 또는 영양분이 포함된 양액에 뿌리부분이 잠기게 하여 재배하는 담액식과 재배틀에 일정한 경사각을 인위적으로 부여하여 물 또는 양액이 뿌리부분에 흐르게 하여 재배하는 박막식, 물 또는 양액을 작은 입자형태로 뿌리에 직접 살포하는 방식의 분무식 수경재배방식이 있다(Park 등, 2014; Ko 등, 2019).

본 연구에서는 Fig. 1과 같이 재배시설을 실내에 구축하고 분무식 수경재배방식을 통하여 실험을 진행 하였다. 구체적으로 800x400x150mm 크기의 플라스틱 소재의 재배상을 3단으로 총 9개를 설치하였고, 각각의 재배상 내에는 노즐 12개를 균등 설치하여 일정한 분무환경이 조성되도록 하였다. 별도 양액 없이 수돗물을 사용하여 재배하였으며, 40분 간격으로 매회 30초씩 수분을 공급하여 묘삼의 지하부가 습윤 상태가 유지되도록 하였다. 묘삼은 20mm 간격으로 총 894주를 정식하였다. 또한 생육환경에 영향을 미치는 외부 환경요인의 영향을 최소화하기 위하여 재배공간의 실내온도를 20~24℃로 유지하고, 광원은 각각의 재배상 상단 500mm 높이에 적색과 청색 LED를 4:1비율로 설치하여 매일 10시간씩 균등 조사하였다.

Fig. 1. Hydroponic facilities

이러한 재배 환경 하에서 본 실험에서는 경기도 강화군에서 2020년 3월 초순에 수확한 894개의 묘삼을 같은 해 6월 1일에 이식하여 30일 동안 수경 재배하였고, 총 894주를 수확하여 실험 데이터를 확보하였다.

각 묘삼은 수경재배 장비에 이식하기 전 사진 촬영을 하여 분석 이미지로 활용하였고, 30일간 재배 후 수확한 새싹삼의 품질을 기준으로 라벨링(labeling) 하였다. 새싹삼의 품질은 전문가의 도움을 받아 분류 기준을 수립하였는데, 실험 데이터의 개수가 한정된 관계로 세분화 하지 않고 단순히 고품질과 저품질로 구분하였다. 고품질의 새싹삼은 지상부 잎의 크기가 엽장 3㎝ 이상, 엽폭 1㎝ 이상으로 개체 당 총 15개 이상의 잎이 출현되고, 지상부의 경장이 10㎝ 이상인 개체로 정의하였다. 지하부의 근장과 근직경은 개체별로 차이가 크지 않아 품질분류의 기준에서 배제하였다. 또한 이러한 고품질의 기준에 적합하지 않은 개체는 저품질의 새싹삼으로 분류하였다.

Fig. 2와 Fig. 3은 본 실험에서 사용한 묘삼 및 수확한 새싹삼의 샘플 이미지를 보여주고 있다. Fig. 2(a)는 수확 후 고품질의 새싹삼으로, Fig. 2(b)는 수확 후 저품질의 새싹삼으로 분류된 묘삼의 샘플 이미지이며, Fig. 3(a)는 고품질의 새싹삼, Fig. 3(b)는 저품질의 새싹삼의 샘플 이미지이다.

(a) hight quality (b) low quality

Fig. 2. Samples of ginseng seedling

(a) high quality (b) low quality

Fig. 3. Samples of ginseng sprout

Table 1에는 실험에 사용한 총 894개의 묘삼에 대한 정보가 제시되어 있다. 수확 이후 고품질로 분류된 새싹삼은 전체의 59.2%, 저품질로 분류된 새싹삼이 40.8%에 해당된다.

한편 본 연구에서 제안하는 CNN 기반의 품질 예측 모델을 학습하고 성능을 평가하기 위하여, 전체 데이터를 학습과 검증, 테스트 데이터 세트로 각각 6:2:2로 분할하였다.

Table 1. Data summary

quality	count	percent
high quality	529	59.2%
low quality	365	40.8%
total	**894**	**100%**

2.2 품질 예측 모형 구축 방법

본 연구에서는 수확된 새싹삼의 품질을 묘삼 단계에서 조기에 예측하는 모형을 구축하기 위하여 CNN 기반의 품질 예측 모델(Quality Prediction Model for Ginseng Sprouts, G-QPM)을 제안한다.

G-QPM을 신규로 구축하는 것은 많은 학습 데이터 및 컴퓨팅 자원이 요구되기 때문에 기존의 연구들과 유사하게 본 연구에서도 사전 학습된 모델(pre-trained model)을 이용하였다. 본 연구에서 사용한 사전 학습된 모델들이 Table 2에 제시되어 있다. Table 2에 제시된 7가지의 모델들은 이미지 분류에서 널리 쓰이는 CNN 기반의 모델들로써 ImageNet 데이터 세트(Jia 등, 2009)를 기반으로 학습되었으며, 이미지 인식 경연대회인 ILSVRC 대회에서 우승하였거나 탁월한 성능을 보인 모델들이다(http://www.image-net.org). 이후 기술에서는 Table 2의 사전 학습된 모델을 G-QPM 구축에 근간이 되는 모델이라는 의미에서 '기초 모델(base model)'이라고 지칭한다.

Table 2. Pre-trained (base) models

pre-trained (base) model	published in	Accuracy
VGG19	2014	0.713
ResNet152V2	2015	0.78
InceptionV3	2016	0.779
Xception	2017	0.79
InceptionResNetV2	2017	0.803
DenseNet201	2017	0.773
MobileNetV2	2018	0.713

한편, 기초 모델은 1,400만개의 레이블된 이미지와 1,000개의 클래스로 이루어진 ImageNet 데이터세트에서 동작하기 때문에 이를 그대로 G-QPM에 적용할 수는 없다. 따라서 본 연구에서는 일반적인 전이학습 방법에 따라 기초 모델을 이용한 G-QPM을 Fig. 4와 같이 구축하였다.

본 연구에서 구축한 G-QPM은 사전 훈련된 기초 모델에 3개의 완전연결(fully connected, FC) layer를 추가한 것으로, 각 FC layer 사이에는 과적합(overfitting)을 막기 위한 dropout(rate = 0.1)과 batch normalization이 추가되어 있다. 또한 기초 모델이 새싹삼의 품질 예측 학습 과정 중 추가 학습되는 것을 최소화하기 위해 기초 모델의 가중치가 갱신되는 것을 동결(freezing)하고 일부 상위 layer(상위 3개 layer)의 가중치만 업데이트 되도록 미세조정(fine-tunning)을 허용하였다. 이를 통해 기초모델이 ImageNet을 통해 학습한 표현들이 G-QPM 학습 과정 중 수정되어 훼손되는 것을 막고 새로운 문제(품질 예측)에 재활용 되도록 학습할 수 있다(Chollet, 2017).

또한, 묘삼의 샘플 수의 한계로 인하여 본 연구에서는 데이터 증식(data augmentation)을 사용하여 모델이 학습 데이터 세트에 과적합 되는 것을 방지하였다.

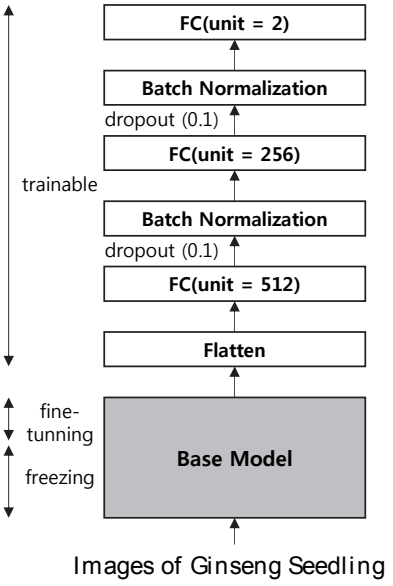

Fig. 4. Architecture of the proposed model

3. 성능 평가

각 기초 모델을 활용하여 구축된 G-QPM의 성능은 학습과 검증, 테스트 데이터 세트에서의 예측 정확도 및 학습에 소요되는 시간 등을 측정하여 평가할 수 있다.

Table 3에 각 기초 모델에 따른 G-QPM의 성능이 요약되어 나타나 있다.

본 연구에서는 각 기초 모델별 G-QPM을 총 30 epochs의 기간 동안 학습 데이터 세트를 통해 학습시키고, 검증 및 테스트 데이터 세트를 통해 예측 정확도를 측정하였

다. 실험 환경은 Intel i7-7700 2.80GHz CPU, 16GB RAM, GeForce GTX 1060 GPU로 구성하였다.

Table 3의 duration은 각 기초 모델 별로 epoch 당 소요되는 평균 학습 시간을 초단위로 보여주고 있다. 주어진 실험 환경에서는 약 30초 안팎의 시간이 소요되며 기초 모델 별로 큰 차이는 없는 것을 알 수 있다.

Table 3. Performance summary of G-QPM

base model	duration (s)	Accuracy of		
		training	validation	test
VGG19	35.3	0.774	0.800	0.826
ResNet152V2	33.5	**0.857**	**0.837**	**0.865**
InceptionV3	31.8	0.828	0.800	0.809
Xception	33.7	0.855	0.781	0.809
InceptionResNetV2	33.7	**0.865**	**0.831**	**0.860**
DenseNet201	**30.3**	0.836	**0.837**	0.837
MobileNetV2	**29.6**	**0.868**	0.800	**0.865**
average	**32.6**	**0.840**	**0.813**	**0.839**

Table 3에 표기된 학습 및 검증 데이터 세트에서의 예측 정확도는 각 기초 모델 별로 30 epochs의 학습 기간 동안 가장 높은 정확도를 나타내고 있다. Table 3에서 보듯이 학습 데이터 세트에서는 평균 84.0%, 검증 데이터 세트에서는 81.3%의 정확도를 보이고 있다.

한편 Table 3의 테스트 데이터 세트에 대한 예측 정확도는 30 epochs의 학습 기간 중 가장 높은 검증 정확도를 보이는 G-QPM의 가중치를 이용해 테스트 세트에 대해 측정한 값이다. Table 3에서 보듯이 ResNet152V2와 MobileNetV2를 기초 모델로 구축한 G-QPM이 86.5%로 가장 높은 정확도를 보이고 있으며, 다른 모델들도 80% 초반의 정확도를 나타내고 있다.

Fig. 5는 학습 기간 동안 G-QPM의 학습 및 검증 데이터 세트에 대한 예측 정확도의 변화를 보여주고 있다. 지면상의 제약으로 인해 테스트 데이터에 대해 가장 높은 예측 정확도를 보인 ResNet152V2, InceptionResNetV2 및 MobileNetV2 기반의 G-QPM에 대해서만 제시하였다. 실험 데이터 수의 한계로 인해 변동성이 크게 나타나고 있지만 대략 10 epochs 이후부터는 다소 안정적인 모습을 보여주고 있다.

한편 각 분류 클래스별 실험 데이터 수의 불균형을 감안한 성능 평가 결과를 Table 4에 제시하였다. Table 1에서 보듯이 본 실험에서 고품질과 저품질의 데이터 수의 비율은 약 6:4로 비대칭적이다. 따라서 테스트 데이터에 대한

(a) G-QPM based on ResNet152V2

(b) G-QPM based on InceptionResNetV2

(c) G-QPM based on MobileNetV2

Fig. 5. Training and validation accuracy of G-PQM

Table 4. Precision, recall and f1-value of G-QPM

base model	precision	recall	F1-value
VGG19	0.888	0.779	0.795
ResNet152V2	0.873	0.844	**0.854**
InceptionV3	0.843	0.767	0.781
Xception	0.901	0.831	0.848
InceptionResNetV2	0.901	0.831	0.848
DenseNet201	0.862	0.803	0.817
MobileNetV2	0.901	0.831	0.848
average	**32.6**	**0.812**	**0.827**

분류 결과를 바탕으로 각 클래스별 정확도(precision)와 재현율(recall), F1 값을 계산하고 그 평균을 Table 4에 제시하였다.

Table 4에 따르면 F1 값은 ResNet512V2 기반의 G-QPM이 가장 높아(0.854) 새싹삼의 품질예측 모델로 가장 적합함을 알 수 있다. 이 모델의 테스트 데이터에 대한 상세 분류 결과는 Table 5에 제시하였다.

Table 5. Confusion matrix of G-QPM with ResNet152V2

		prediction	
		low quality	high quality
actual	low quality	52	18
	high quality	6	102

이상의 결과를 요약해 볼 때, 본 연구에서 제안하는 새싹삼의 품질 예측 모델은 기초 모델에 따라 차이는 있지만 테스트 데이터에 대해 80% 이상의 예측 정확도를 갖으며, 학습소요 시간도 사전 훈련된 모델을 사용함으로써 크게 단축시킬 수 있음을 알 수 있다. 특히 ResNet152V2 기반의 모델이 가장 좋은 성능을 보이고 있다.

4. 결론

본 연구는 CNN 기반의 딥러닝 기법을 활용하여 농작물의 질병 분류 및 수확량을 예측하던 기존 연구들과는 달리 수확 후 농작물의 품질을 식재 단계에서 조기에 예측하는 기법을 제안하였다. 이러한 조기 품질 예측은 농업 생산성 및 수익성 향상에 중요한 역할을 할 수 있다.

본 연구에서는 건강 기능식품으로 주목받고 있는 새싹삼을 대상으로 CNN 기반의 사전 학습된 모델들을 이용하여 7개의 품질 예측 모델을 구축하였고, 각 모델의 예측 성능을 비교 분석하였다. 분석 결과 모든 예측 모델은 80% 이상의 예측 정확도 보이며, 특히 ResNet152V2와 MobileNetV2 기반의 예측 모델이 가장 높은 정확도를 보였다. 클래스별 데이터 수의 불균형을 감안한 성능 평가에서도 ResNet512V2 기반의 예측 모델이 가장 높은 성능을 보여 새싹삼의 조기 품질 예측 모델로 가장 적합한 것을 알 수 있었다.

이러한 결과는 식재 단계에서의 조기 이미지 분석을 통해 수확 후 농산물의 품질을 일정 부분 예측할 수 있다는 것을 보여준다. 특히 인력에 의존하던 기존 묘삼 선별 작업을 자동화하여 새싹삼의 품질을 높이고 생산량을 증대시켜 농가의 수익창출에 기여할 수 있을 것으로 기대된다.

한편, 본 연구는 새싹삼 이미지 데이터 수집의 제약으로 인해 제안된 모델의 성능 향상에 한계가 있었다. 향후 추가적인 학습 데이터를 축적하고 묘삼의 외관적 특징 외에 다른 여러 특성을 포함하여 분석한다면 품질 예측 모델의 성능 향상을 기대할 수 있을 것이다.

References

1. Chang, E. H., Lee, J. H., Choi, J. W., Shin, I. S., and Hong, Y. P., “Effects of Film Packaging and Gas Composition on the Distribution and Quality of Ginseng Sprouts”, Korean Journal of Medicinal Crop Science, Vol. 28, NO. 2, pp. 152-166, 2020.
2. Cho, D. H., “Development of Stable Production Technology for Sprout Ginseng”, Korea Institute of Agricultural Technology, 2018.
3. Chollet, F., “Deep Learning with Python”, Manning Publications, Inc. USA, 2017.
4. Jia, D., et al., “ImageNet: A Large-scale Hierarchical Image Database”, Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition, pp. 248-255, 2009.
5. Ferentinos, K. P., “Deep Learning Models for Plant Disease Detection and Diagnosis”, Comput. Electron. Agric. Vol. 145, pp. 311-318, 2018.
6. Jeong, S. B., and Yoon, H. S., “An Efficient Disease Inspection Model for Untrained Crops Using VGG16”, J. of the Korea Society for Simulation, Vol. 29, No. 4, pp. 1-7, 2020.
7. Jun, S. Y., Kim, T. H., and Hwang, S. H., “The Consumption Status and Preference for Sprouts and Leafy Vegetables”, Korean J. Food Preserv, Vol. 19, No. 5, pp. 783-791, 2012.
8. Kang, O. J., and Kim, J. S., “Comparison of ginsenoside contents in different parts of Korean ginseng (Panax ginseng C.A. Meyer)”, Prev. Nutr. Food Sci, pp. 389-392, 2016.
9. Khaki, S., Wang, L., and Archontoulis, S. V., “A CNN-RNN Framework for Crop Yield Prediction”, Front. in Plant Science, 2020.
10. Ko, J. H., and Kim, H. C., “PLC Automatic Control

for IOT Based Hydroponic Plant Factory", J. of IKEEE, Vol. 23, No. 2, pp. 487-494, 2019.
11. Lee, K. S., and Park, G. S., "Studies in the Consumption and Preference for Sprout Vegetables", J. East Asian Soc Dietary Life, Vol. 24, No. 6, pp. 896-905, 2014.
12. Lee, J. Y., Yang, H., Lee, T. K., Lee, C. H., Seo, J. W., Kim, J. E., Kim, S. Y., Yoon, J. H., and Lee, K. W., "A short-term, hydroponic-culture of ginseng results in a significant increase in the anti-oxidative activity and bioactive components", Food Sci Biotechnol, Vol. 29, No. 7, pp. 1007-1012, 2020.
13. Li, Y., Nie, J., and Chao, X., "Do we really need deep CNN for plant diseases identification?", Computers and Electronics in Agriculture, Vol. 178, 2020.
14. Liu, J., and Wang, X., "Tomato Diseases and Pests Detection Based on Improved Yolo V3 Convolutional Neural Network", Front. Plant Sci, 2020.
15. Oh, H. K., Lee, S. O., Chung, H. S., and Cho, B. K., "Study on the Development of Auto-classification Algorithm for Ginseng Seedling using SVM (Support Vector Machine)", J. of Biosystems Eng Vol. 36, No. 1, pp. 40~47, 2011.
16. Park, H. W., Kim, Y. C., Kim, J. U., Kim, Y. B., Kang, S. W., Cha, S. W., Kim, S. M., and Hyun, D. Y., "The Effect of Chemical Properties of Growing Media on Production of Ginseng Seedling", The Korean Society of Ginseng. pp. 158-158, 2011.
17. Park, J. S., Kim, S. J., Kim, H. J., Choi, J. M., and Lee, G. I., "Photosynthetic characteristics and growth analysis of Angelica gigas according to different hydroponics methods", CNU Journal of Agricultural Science, Vol. 41, No. 4, pp. 321-326, 2014.
18. Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., and Johannes, A., "Deep Convolutional Neural Networks for Mobile Capture Device-based Crop Disease Classification in the Wild", Comput. Electron. Agric. Vol. 138, pp. 200-209, 2018.
19. Seong, J. B., Kim, S. I., Jee, M. G., Lee, H. C., Kwon, A. R., Kim, H. H., Won, J. Y., and Lee, K. S., "Changes in Growth, Active Ingredients, and Rheological Properties of Greenhouse-cultivated Ginseng Sprout during its Growth Period", Korean Journal of Medicinal Crop Science, Vol. 27, No. 2, pp. 126-135, 2019.
20. Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., and Stefanovic, D., "Deep neural networks based recognition of plant diseases by leaf image classification", Computat. Intelligence Neurosci, pp. 1-11, 2016.
21. Suh, S. J., Yu, J., Jang, I. B., Moon, J. W., and Lee, S. W., "Effects of Storage Temperature and Seed Treatment on Emergence and Growth Properties of Panax ginseng at Spring-sowing", Korean Journal of Medicinal Crop Science, Vol. 26, NO. 5, pp. 401-407, 2018.
22. Sun, J., Di, L., Sun, Z., Shen, Y., and Lai, Z., "County-Level Soybean Yield Prediction Using Deep CNN-LSTM Model", J. Sensors, Vol. 19. No. 20, 2019.
23. Zhang, H., Xua, S., Piao, C., Zhao, X., Tian, Y., Cui, D., Sun, G., and Wang, Y., "Post-planting performance, yield, and ginsenoside content of Panax ginseng in relation to initial seedling size", Industrial Crops and Products, Vol. 125, pp. 24-32, 2018.

이 충 구 (ORCID : https://orcid.org/0000-0003-3519-3941 / dkfranchise1@naver.com)

1994 대구한의대학교 식품과학과 학사
2016 경북대학교 경영학과 석사
2017~ 현재 ㈜세종경영연구소 대표이사

관심분야 : 스마트팜, 도시농업, 딥러닝, 수경재배

정 석 봉 (ORCID : https://orcid.org/0000-0002-6209-1935 / sbjung@kiu.kr)

1999 한국과학기술원(KAIST) 산업경영학과 학사
2001 한국과학기술원(KAIST) 산업공학과 석사
2005 한구과학기술원(KAIST) 산업공학과 박사
2011~ 현재 경일대학교 경영학부 부교수

관심분야 : 이미지 인식, 딥러닝, 스마트팜, 사회네트워크분석