

RESEARCH ARTICLE

콩 제초 자동화를 위한 약지도학습 기반 작물 검출 시스템 개발 및 검증

조수현¹, 이충열^{2,*}, 이대현^{1,*}

¹충남대학교 바이오시스템기계공학과

²한국쓰리축(주)

Development and validation of a weakly-supervised learning-based crop detection system for automated weeding in soybean cultivation

Soo-Hyun Cho¹, Chung-Yeol Lee^{2,*}, Dae-Hyun Lee^{1,*}

¹Department of Biosystems Machinery Engineering, Chungnam National University, Daejeon, Republic of Korea


²Koreatriaxle Co. Ltd., Jangseong-gun, Republic of Korea

*Corresponding author: wang2710@naver.com, leedh7@cnu.ac.kr

Abstract

In this study, a Crop Recognition System for Automated Weeding of Soybean Fields was developed. A vision camera was employed for real-time image acquisition, and considering the field of view of 110°(D) x 86°(H) x 64°(V) and the ground distance, the camera was positioned at a height of 1 meter above the ground. The dataset was constructed by designating the soybean area as the region of interest (RoI). The deep learning model was trained using a weakly supervised learning method, leveraging labeled data. Central points of crops were detected through visualization, employing a Class Activation Map (CAM). The system's performance was evaluated using a linear regression approach, yielding a mean squared error (MSE) of 6.64 cm along the X-axis and 5.09 cm along the Y-axis, with root mean square error (RMSE) values of 1.24 cm on the X-axis and 2.25 cm on the Y-axis, respectively. These results demonstrate the high detection accuracy of the proposed system. An evasion success rate test was conducted in a controlled testbed environment to assess the system's practical applicability. 300 samples were tested over five repeated trials, achieving an average success rate of 98.7%. These results validate the system's high success rate and operational stability.

Keywords: weeding robot, weakly supervised learning, class activation map, soybean, convolutional neural network



OPEN ACCESS

DOI: <https://doi.org/10.12972/jame.20240002>

Received: October 07, 2024

Revised: November 29, 2024

Accepted: November 30, 2024

Copyright: © 2024 Journal of Agricultural Machinery Engineering



This is an Open Access article distributed under the terms of

the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Introduction

농업 인구의 고령화 및 도시로의 이주 가속화로 인해 농업 노동력이 부족하지만, 그에 반해 식량 소비의 규모는 점차 늘어나고 있는 추세이다. 우리나라의 농가 인구는 매년 평균 약 3%의 감소율을 보이며 점점 감소하고 있으며, 세계 농가 인구 수 또한 1991년 기준으로 2019년에는 전체 노동인구 대비 45%에서 약 20% 정도 감소되며 매년 꾸준히 감소하는 것을 볼 수 있다(ILO, 2021; KOSIS, 2022). 세계적으로 농촌 인구 수는 꾸준히 감소하며 농업 노동력이 감소하는 것을 볼 수 있는 반면, 세계 총 인구수의 경우 2000년 61.4억 명에서 2022년 79.5억 명으로 약 30%가 증가하였다(UNPD, 2022). 이를 통해 농가 인구 수가 줄어들며 농업 노동력이 줄어들고 있으나, 총 인구 수는 증가하여 식량 소비의 규모가 커지고 있으며, 이는 식량 보급에 문제가 발생할 수 있기 때문에 농업 노동력을 대체할 수 있는 농업 무인화 및 자동화가 필요한 실정이다.

콩은 세계 인구의 증가에 따른 식량 부족에 중요한 역할을 할 것으로 기대되는 작물로, UN에서 '국제 콩의 해'를 선정하여 식량 안보와 영양원을 지속적으로 제공할 수 있는 식량 중 하나로 손꼽히는 식량이다(IYP, 2024). 하지만 이러한 콩의 재배에는 많은 기초 작업이 필요하다. 그 중 제초는 재배의 전체 작업 과정 중 토지 관리에 이어 17%의 비중을 차지하여 2번째로 큰 노동력 투입 비중을 가지고 있으므로 많은 노동력이 필요하다는 것을 알 수 있다(KOSIS, 2021). 또한 작물의 성장기부터 수확기까지 주기적으로 진행되어야 하며, 짧게는 1주일, 길게는 20일에 한 번씩 진행하여야 하기 때문에 많은 노동력이 필요하다(RDA, 2021). 제초 작업은 노동력의 투입 방식에 따라 작업 효율의 차이가 나타난다. 로봇을 이용한 무인 작업의 효율의 경우, 사람의 노동력을 이용한 유인 작업의 효율에 비해 약 98%의 노동력 절감 효과가 발생할 수 있음을 확인할 수 있다(SMGATC, 2008). 농업 노동력의 감소와 농촌 고령화가 진행됨에 따라, 제초와 같은 노동 집약적인 작업의 지속을 위해 무인화 및 자동화 기술의 도입이 필요하다는 것을 알 수 있다.

제초 로봇은 무인 자동화 시스템을 활용하여 작물과 잡초를 정확하게 구분하고, 잡초만을 제거하는 제초 작업을 수행할 수 있어야 한다. 이러한 구분 방식은 두 가지로 나눌 수 있으며, 하나는 잡초를 인식하여 이를 제거하는 방식과, 작물을 인식하여 그 외의 식물을 잡초로 간주하는 방식이다. 전자의 경우, RGB-D 카메라로 촬영한 잡초의 컬러 이미지를 기반으로 객체 검출 모델 중 하나인 Mask R-CNN을 통해 학습한 후, 객체 분할을 통해 개별적으로 감지하여 로봇 팔을 통해 제초하는 방식이 있다(Nakabayashi et al., 2024). 하지만 Mask R-CNN은 작은 객체를 탐지하는데 어려움이 있을 수 있으며, 잡초와 작물의 외관의 유사할 경우 잘못된 분류가 진행될 수 있다(Valicharla, 2021). 후자의 경우, 허프변환 방식을 이용하여 작물들의 외곽선을 인식한 후, 그 외의 영역에 대해 제초를 진행하는 방식이 있다(Pusd -Chulde et al., 2021). 하지만 잡초가 발생하는 영역은 작물의 라인 외측뿐만 아닌, 작물의 라인 내측에서도 발생하기 때문에 정밀한 제초작업에 한계가 존재할 수 있으므로 효율적인 제초 기술 개발이 필요하다.

본 연구는 콩 재배에 적합한 친환경 중소형 제초로봇 개발을 목적으로 수행되었으며, 제초 작업의 자동화를 위한 콩 작물 인식 시스템을 개발하였다. 본 시스템은 실시간 영상 수집이 가능한 비전 카메라와 작물 영역을 인식하고 모델을 학습할 수 있는 임베디드 제어기로 구성하여, 데이터 수집과 학습을 통해 실시간으로 작물 영역을 정확하게 인식하는 것을 목표로 한다. 약지도 학습(weakly supervised learning)을 적용하여, 픽셀 단위 라벨링 대신 비교적 간단하고 적은 정보의 라벨을 활용하여 학습을 진행하였다. 이는 라벨링 작업의 시간과 비용을 줄이면서도 학습 성능을 확보할 수 있다는 장점을 가지고 있어 학습에 대한 접근법으로 사용하였다(Zhou, 2018). 이를 통해 작물과 잡초를 구분하는 알고리즘을 구현하여 효율적인 제초 작업을 위한 실시간 콩 작물 인식 기능을 개발하였다.

Materials and Methods

인식시스템

본 연구에서 콩 작물 영역을 실시간 인식하기 위해 구성된 인식 시스템은 작물 영역 인식 및 모델 학습이 가능한 임베디드 제어기와 실시간 영상 수집이 가능한 비전 카메라로 구성하여 콩과 배경 영역을 구분하였으며, 구성과 사양은 Fig. 1, Table 1과 같다. 임베디드 제어기는 작물 영역 인식을 위해 이미지 분류, 객체 감지, 분할 모델의 학습 및 추론이 가능한 Jetson board (Xavier NX, NVIDIA, USA)를 사용하였다. 비전 카메라는 호환성이 높은 13.0 MP (mega pixel)의 최대 해상도와 최대 120 fps (frame per second)의 속도로 영상 수집이 가능한 카메라를 사용하였다.




Fig. 1. Composition of recognition system

Table 1. Specification of recognition system

Item	Specifications	
Embedded Controller	Jetson board (Xavier NX, NVIDIA, USA)	
	GPU	128-core Maxwell
	Pixel size	Quad-core ARM A57 @ 1.43 GHz
	Memory	4 GB 64-bit LPDDR4 25.6 GB/s
	Video encode	4K@30 fps
	Video decode	4K@60 fps
	Camera (e-CAM131_CUNX, e-con Systems, CA, USA)	
	Interface	USB 3.0, GPIO, I2C, I2S, SPI, UART
Vision Camera	Sensor	AR1335 from ON Semiconductor
	Field of view	110°(D), 86°(H), 64°(V)
	Resolution	13MP (4192 x 3120) CMOS Image Sensor
	Frames per second (fps)	13MP at 10 fps – VGA at 115 fps

비전 카메라는 양쪽 콩 열 작물 모두를 동시에 영상 수집하기 위해 제초로봇의 전면부 중심 위치와 상부에서 하부를 바라보는 방향으로 설정하였다. 비전 카메라의 시야각(field of view, FOV) $110^{\circ}(\text{D}) \times 86^{\circ}(\text{H}) \times 64^{\circ}(\text{V})$ 와 조간거리를 고려하여 지면에서 1 m 높이 위치로 설정하였으며, 관측될 수 있는 영역의 크기는 Fig. 2와 같다.




Fig. 2. Field of view for image collection

학습데이터 수집 및 구성

본 연구에서 데이터 수집을 위해 조성된 시험 장소는 대전광역시 유성구 충남대학교 시험포장지($36^{\circ}21'59.04''\text{N}$ $127^{\circ}21'10.08''\text{E}$)에서 실시하였으며 Fig. 3 (a)와 같이 테스트 베드가 구성되었다. 테스트 베드는 우리나라 기계화 콩 재배 방식의 두둑 성형 규격으로 조성되었으며, 기계 파종 간격은 Fig. 4와 같이 조간 0.65 m, 주간 0.30 m의 규격을 따르고 있다. 데이터 구성은 콩의 배치 중심으로 RoI (region of interest)를 선정하여 좌측과 우측 각각 하나씩 구성하였으며, 제초로봇이 작물 열을 주행하며, Fig. 3 (b)와 같이 수집한 영상에서 좌측과 우측 각각 160×160 (pixels) 크기의 영역을 추출하였다. 분류학습을 위해 콩(soybean)과 배경(ground) 2개 부류로 구분하여 데이터 세트를 구성하였다. 학습데이터는 총 2,905개로 구성되었으며, 이 중 모델의 학습, 검증, 평가에 각각 2,033개, 580개, 292개가 사용되었다.




Fig. 3. Data collection of soybean crops in Yuseong-gu, Daejeon




Fig. 4. Specifications of cultivation environment

콩 검출 모델 설계 및 학습

약지도 학습 기반 딥러닝 모델은 학습 데이터 구축의 효율성을 제공하며, 분류 학습 과정에서 지역화 정보(Localization)를 동시에 추출할 수 있는 특징을 가진다. 본 연구에서는 약지도 학습 기반 검출 모델을 설계하였으며, 해당 모델은 3×3 합성곱신경망층 4개로 구성되어 입력 영상에서 효과적으로 특징 정보를 추출하였다. 각 합성곱층은 비선형 활성화 함수인 ReLU 함수와 Max pooling 연산을 포함하며, 최종 단계에서는 Global average pooling (GAP)을 적용하여 지역화 정보 추출에 활용되는 특징 맵 가중치를 생성하였다. 이러한 구조를 통해 콩 영역의 인식 및 분할 작업을 수행하였으며, 추출된 지역화 정보는 CAM (Class Activation Map)을 이용하여 시각적으로 검증하였다(Zhou et al., 2016). 해당 모델의 구조는 Fig. 5과 같이 제시되어 있다.




Fig. 5. Structure of weakly supervised learning model used in this study

모델 학습 방법으로 지도학습에서 일반적으로 사용되는 Cross entropy 손실함수를 사용하여 식 (1)과 같이 계산된다.

$$loss(x, class) = -\log\left(\frac{\exp(x[class])}{\sum_j \exp(x[j])}\right) = -x[class] + \log\left(\sum_j \exp(x[j])\right) \quad (1)$$

2개의 부류로 구분되고 학습데이터셋의 크기가 불균형한 분류학습에서 장점을 가진다. 최적화기에서 수렴속도가 빠른 Adam optimizer 함수를 사용하여 식 (2)와 식 (3), 식 (4)와 같이 계산된다.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla f(x_{t-1}) \quad (2)$$

$$g_t = \beta_2 g_{t-1} + (1 - \beta_2) (\nabla f(x_{t-1}))^2 \quad (3)$$

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t}, \widehat{g}_t = \frac{g_t}{1 - \beta_2^t}, x_t = x_{t-1} - \frac{\eta}{\sqrt{\widehat{g}_t} + \epsilon} \cdot \widehat{m}_t \quad (4)$$

학습을 진행하면서 모델 복잡도에 대한 과적합(overfitting) 방지를 위해 L2-regularization을 사용하였다. 데이터 검출 방법으로 딥러닝 기반 콩 영역 검출 결과인 CAM에 대한 이진화(binary) 및 군집화(clustering)를 통해 수행하였다. 군집화는 인접한 픽셀끼리 연결하는 방식으로 쉽게 구현할 수 있는 connected-component labelling을 이용하였다. 군집 객체 중 가장 큰 면적의 객체를 콩 영역으로 선정하였으며, 영역의 무게중심을 작물의 중심점으로 결정하였다. 군집화를 통해 결정된 작물의 중심점에 대해 카메라좌표에서 계산 후, 월드 좌표로 변환을 진행하였으며, Fig. 6과 같다. 기하학적 좌표계의 관계 확인과 PnP 알고리즘과 회전행렬 및 카메라 내부 파라미터 도출을 통해 좌표계 변환하였다.




Fig. 6. The 4 coordinate systems in Image Geometry

작물 회피 알고리즘

본 연구에서 사용되는 작물 회피 알고리즘은 제초로봇 주행 시 비전 카메라를 통해 입력되는 실시간 영상에서 콩 작물 영역을 검출한 후 스텝핑 모터를 일정각도 타이밍 회전 제어하는 작물 회피 방법을 사용하였다. 시험 장소는 대전광역시 유성구 충남대학교 시험포장지에서 진행하였으며, 기계화 재배 환경과 같이 10 m길이의 두둑을 성형하고 양쪽에 0.3 m간격으로 30개의 모형 작물을 조성하여 테스트베드를 구성하였다. 스텝핑 모터에 수직으로 부착된 4엽식 +자형 굽기형 제초날의 90° 단위에 회전속도 30 rpm을 0.5 sec로 환산하였으며, 이때 제초로봇의 직진 주행에 따른 작업주행속도를 2.1 km/hr으로 설정하여 초당 0.58 m의 거리가 이동되게 하였다. 0.3 m의 간격으로 이식된 작물을 0.5 sec와 90° 단위로 스텝핑 모터를 회전시켜 작물을 회피하는 타이밍 제어 방법을 사용하였으며, 작물이 회피하면 성공으로 판단하고 작물이 이탈되면 실패로 판단하였으며, 제어 로직은 Fig. 7과 같다.




Fig. 7. Flow chart of automatic weeding control logic

성능 평가

딥러닝 모델을 활용한 콩 영역 검출 평가는 모델 성능 평가와 분류 성능 평가로 구분되었으며, 모델 성능 평가는 학습반복에 따른 손실(training loss)과 정확도(training accuracy)로 진행하였으며, 분류 성능 평가는 Fig. 8과 같은 혼동행렬을 기반으로 정밀도(precision), 재현율(recall), F1-score, 정확도(accuracy)를 계산하였다.

		Predictive Values	
		SOYBEAN	GROUND
Actual Values	SOYBEAN	TP	FN
	GROUND	FP	TN

Fig. 8. Confusion matrix

작물 영역의 중심점 검출 라벨(ground truth)은 목표지점을 육안으로 평가해서 작물의 중심점을 수동으로 지정하여 선택 하였으며, 모델의 예측값과 실제값 간의 관계를 평가하기 위해 회귀 분석의 평가 지표인 MSE, RMSE, R^2 를 이용하였으며, 식 (5)와 식 (6), 식 (7)과 같다.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad (6)$$

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} \quad (7)$$

제초 로봇의 실제 성능 파악을 위해 작물 회피 성능을 평가하였다. 평가는 실제 제초로봇에 회피형 작물 검출 시스템을 탑재하여 좌측과 우측 각각 30개의 샘플을 총 5회의 시험으로 전체 샘플 300개에 대한 회피 성공률 시험을 실시하였다. 작물 회피 성공률은 Fig. 9와 같이 작물의 중심점 검출 후 스텝핑 모터가 회전되어 작물이 회피되면 성공으로 판단하였으며, 중심점 검출 오차로 인해 회피되지 않고 작물이 이탈되면 실패로 판단하였다.




Fig. 9. Test of crop avoidance

Results and Discussion

모델 학습 및 분류 성능

콩 검출 모델의 반복 학습에 따른 학습 손실 그래프는 Fig. 10과 같이 나타났다. 총 250번의 반복 학습동안 평균 범위에서 벗어나는 결과값을 제외한 값을 확인한 결과, 학습 손실이 0.076까지 점차 감소하는 추세를 볼 수 있었다. 콩 영역과 배경의 분류학습 결과, 학습데이터 부류 간의 불균형이 존재했지만 Table 2와 같이 정확도는 약 98%의 수준을 보였으며, 정밀도와 재현율, F1-score 모두 98% 수준의 높은 성능을 보였으며, 이는 합성곱신경망으로 이진 분류가 가능하다는 것을 확인할 수 있었다.




Fig. 10. Graphs of loss of the deep learning used in this study

Table 2. Classification performance results for soybean and background

Class	Accuracy	Precision	Recall	F1-score
Soybean	0.985	0.988	0.987	0.988

콩 영역 중심 검출

콩 작물 영역의 중심점 검출은 약지도 학습 기반 검출 모델이 활용되었으며, 실시간 입력되는 RoI 범위의 객체가 인식되는 순간을 추출하여 검출되었다. 검출이 처리되는 시간은 Table 3과 같이 평균 0.05초가 소요되었으며, 20 fps의 속도로 실시간 콩 작물 영역 검출이 가능한 것으로 확인되었다. 임계치 처리된 최종영역과 무게중심인 중심좌표를 흰색과 붉은색으로 Fig. 11과 같이 표현되었으며, 중심점 검출 결과는 실제 작물의 중심과 검출된 중심이 유사한 위치로 나타났다.

Table 3. Processing time results of the deep learning model

Factor	Avg.	Max.	Min.
Processing time (s)	0.05 ± 0.008	0.16	0.04
Frame rate (fps)	20 ± 2.5	27	6




Fig. 11. Results of soybean center point detection

콩 영역 중심 검출 평가

본 연구에서의 데이터 평가는 검출된 RoI 범위의 객체 중심점 좌표값을 카메라 좌표값 변환을 통해 월드 좌표값으로 변환되었으며, 검출 좌표의 중심과 실제 작물 좌표의 중심이 Fig. 12와 같이 유사한 위치로 나타나는 것이 확인되었다. 객체의 형상에 따라 중심점 검출 오차가 발생되었으며, 거리에 대한 오차를 MSE와 RMSE로 평가되었다. RMSE 평가 결과에서의 카메라 좌표 오차는 약 9 pixels와 약 15 pixels이며 월드 좌표 오차는 1.24 cm와 2.25 cm로 Table 4와 같이 관찰되었다.



Fig. 12. Photos comparing predicted and actual soybean center points

Table 4. Results of regression methods used in this study

Item	Pixel		World	
	X axis	Y axis	X axis	Y axis
MSE	322.93	242.23	6.644	5.098
RMSE	8.983	15.563	1.243	2.257

결과의 설명력을 확인하기 위해 결정계수(R-squared, R^2)로 평가되었으며, 좌측과 우측 작물 열의 결정계수가 Fig. 13과 같이 0.75와 0.73 수준의 안정적인 성능으로 실제 사용 시 높은 신뢰의 정보가 될 것으로 판단된다.




Fig. 13. Coefficient of determinations for crop rows of world coordinates

콩 영역 회피 시험 결과

작물 회피 시험 결과, 파손 샘플은 작물의 중심점이 외곽에 검출되어 발생하는 것으로 확인되었다. Table 5와 같이 평균 성공률은 98.7%로 나타났으며, 높은 성공률과 안정성이 확인되었다. 본 시험 결과는 정형화된 시험 환경을 조성하여 실시된 것으로 실용적 활용을 위해서는 다양한 생육 상태와 필드 조건에서의 성능 검증이 필요할 것으로 판단된다.

Table 5. Test result of crop avoidance success rate

	1 st	2nd	3rd	4th	5th	Total
Samples	60	60	60	60	60	300
Success	59	60	60	58	59	296
Failure	1	0	0	2	1	4
Success rate (%)	98.3	100	100	96.7	98.3	98.7

Conclusion

본 연구는 국내 주요 밭작물인 콩 재배에 적용 가능한 친환경 중소형 제초로봇을 개발하기 위한 것으로, 콩 재배에 적합한 두둑성형 방식에 맞춰 설계된 전동 구동 궤도형 플랫폼을 기반으로 제초 자동화를 위한 콩 작물 검출 및 회피 시스템을 구현하였다. 검출 시스템은 실시간 영상 수집이 가능한 비전 카메라와 임베디드 제어기로 구성되어 있으며, 양쪽 콩 열 작물을 동시에 감지하기 위해 전면부 중심에 설치된 비전 카메라는 지면에서 1 m 높이에 위치하고, 시야각 110°(D) x 86°(H) x 64°(V)를 제공하여 실시간 영상 신호를 임베디드 제어기로 전달하여 콩과 잡초를 구분하고 검출한다.

콩 작물의 중심점 검출을 위한 과정은 데이터 수집, 학습, 중심 검출, 성능 평가의 순서로 진행되었다. 데이터 수집은 주행 플랫폼이 콩 열을 따라 이동하며 이루어졌고, 학습 단계에서는 RoI를 설정한 후 콩과 배경을 구분하는 160 × 160 픽셀의 데이터 세트를 구성하여 약지도 학습 기반의 딥러닝 모델을 활용해 학습을 수행하였다. 중심점 검출은 콩과 잡초의 경계가 모호한 경우에도 분류 학습을 통해 생성된 특징 맵의 가중합을 이용하여 콩의 중심을 정확하게 검출하는 방식이 적용되었다. 성능 평가는 검출된 중심 좌표와 실제 좌표 간의 오차를 카메라 좌표계 및 월드 좌표계로 변환한 후 MSE 및 RMSE 방식으로 평가하였으며, 카메라 좌표계에서는 약 9 pixels, 월드 좌표계에서는 2.25 cm의 오차를 나타내어 시스템의 안정성이 입증되었다.

실제 농업 환경에서의 성능 검증을 위해 대전 유성구에 위치한 충남대학교 시험포장에서 작물 회피 성공률 시험이 수행되었다. 시험에서는 10 m 길이의 두둑을 형성하고 양쪽에 0.3 m 간격으로 모형 작물을 배치한 후, 제초로봇이 5회 주행하며 좌우 각각 30개의 모형 작물에 대해 회피 성능을 시험하였다. 그 결과, 평균 98.7%의 성공률을 기록하였으며, 시스템의 높은 안정성과 실용성을 확인하였다. 다만, 본 시험은 정형화된 환경에서 진행된 것으로, 다양한 생육 조건과 필드 환경에서 추가적인 성능 검증이 필요할 것으로 판단된다.

Acknowledgments

References

- ILO (International Labour Organization). 2021. Employment in agriculture. ILOSTAT database.
- International Year of Pulses (IYP). 2024. United Nations. Assessed in <https://www.un.org/en/observances/world-pulses-day> 4 October 2024.

- KOSIS (Korean Statistical Information Service). 2021. Production cost survey of agricultural and livestock products. Labor input time by province/work. [in Korean].
- KOSIS (Korean Statistical Information Service). 2022. Population of farmers by age and period of agricultural workers (15 years or older). Agriculture and Fisheries Research. [in Korean].
- Nakabayashi T, Yamagishi K, Suzuki T. 2024. Automated Weeding Systems for Weed Detection and Removal in Garlic/Ginger Fields. *International Journal of Advanced Computer Science & Applications* 15(4).
- Pusd  -Chulde M, Robayo A, De Giusti A, Garc  a-Santill  n I. 2021. Detection of Crop Lines and Weeds in Corn Fields Based on Images Obtained from a Drone. In *Conference on Cloud Computing, Big Data & Emerging Topics*, pp. 31-45.
- RDA (Rural Development Administration). 2018. Soybean. pp. 6-15. [in Korean]
- SMGAT (Seoul Metropolitan Government Agricultural Technology Center). 2008. Development of Eco-Friendly Rice Crops (Report No. 2008_29). [in Korean]
- UNPD (United Nations Population Division). 2022. World Population Prospects.
- Zhou B, Khosla A, Lapedriza A, Oliva A, Torralba A. 2016. Learning deep features for discriminative localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2921-2929
- Zhou Z. 2018. A brief introduction to weakly supervised learning. *National Science Review* 5(1):44-53