

자율주행 농기계를 위한 경작지 세그멘테이션

배나연*, 최성균*, 한동석^o

Farmland Segmentation for Autonomous Agricultural Machinery

Na Yeon Bae*, Sung Kyun Choi*, Dong Seog Han^o

요약

스마트 농업은 정보통신기술을 농업에 접목하여 자동화하는 기술로 들어선 만큼, 기후변화와 고령화 등의 문제를 해결하는 지속 가능한 방법이다. 최근 농업의 주요 장비인 트랙터와 이앙기에 자율 주행 기술을 접목한 농업의 자동화에 관한 연구가 활발하다. 본 논문에서는 경작할 수 있는 농지를 구분하기 위한 딥러닝 구조를 제안한다. 드론으로 촬영한 경작지의 이미지를 사용하여 데이터셋을 구축하고 밭과 모서리, 도로를 경량 딥러닝 모델을 이용하여 영역 구분하고자 한다. 본 논문에서는 DG-블록(DG-block, Dilated group Convolution-block)과 픽셀 셔플(pixel shuffle)을 이용하여 이미지 영역을 세분화하는 딥러닝 모델을 제안한다. 제안 시스템은 mIOU 78.4%와 정확도 77.7%의 성능과 추론시간 50ms를 보여주었다.

키워드 : 세그멘테이션, D-블록, DG-블록, 픽셀 셔플, 시맨틱 세그멘테이션

Key Words : Segmentation, D-block, DG-block, pixel shuffle, semantic segmentation

ABSTRACT

Smart agriculture leverages information and communication technology in farming to enable automation, providing a sustainable solution to challenges such as climate change and an aging population. Recently, there has been active research on agricultural automation by integrating autonomous driving technology into key agricultural equipment, such as tractors and rice planters. This paper proposes a deep learning architecture to distinguish cultivable land. Using images of farmland captured by drones, we construct a dataset and aim to classify areas such as fields, edges, and roads with a lightweight deep learning model. This paper proposes a deep learning model that refines image regions using a DG-block (Dilated Group Convolution-block) and pixel shuffle. The proposed system demonstrates performance with an mIOU of 78.4%, an accuracy of 77.7%, and an inference time of 50ms.

1. 서론

스마트 농업이란 농업 분야에 정보통신기술을 접목하여 농축산물과 식품 생산뿐만 아니라 유통, 판매, 소

비에 이르는 농업 전 과정에 대한 생태계를 구축하기 위한 기술이다¹⁾. 스마트 농업은 지속할 수 있는 농업을 성취하게 해주는 방법의 하나다. 현재 농업이 기후변화, 고령화, 농촌 소멸 등으로 어려움을 겪고 있고 이것을

* 본 연구는 2024년 경북대학교에서 진행되는 모비루스 과제와 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(2021R1A6A1A03043144)의 연구결과로 수행되었음

♦ First Author : Kyungpook National University, School of Electronics Engineering, qoskds1@knu.ac.kr, 학생회원

° Corresponding Author : Kyungpook National University, School of Electronics Engineering, dshan@knu.ac.kr, 종신회원

* Mobilus Inc. Korea, skchoi@mobilus.co.kr

논문번호 : 202409-200-A-RN, Received September 6, 2024; Revised November 8, 2024; Accepted December 2, 2024

로봇, 드론, 자율주행 등 자동화 기술을 도입함으로써 편리하게 농작업을 할 수 있게 하고 작물에 생산성 높일 수 있다^{2,3)}.

스마트 농업에서 적용할 수 있는 다양한 기술 중에서 자율 주행 기술은 트랙터와 이앙기에서 모내기 또는 수확과 같은 노동 집약적인 작업을 처리하기 위해 광범위하게 연구되고 있다. 농업 기계의 자율주행은 정부 기준에 따라 네 가지 수준으로 분류를 할 수 있다. 단계 0 원격 제어, 단계 1 자동 조향, 단계 2 자율 주행, 단계 3 자율 작업, 단계 4 무인 자율 작업으로 나누어져 있다.

단계 1, 자동 조향은 농업 기계가 직선 주행을 자율적으로 수행할 수 있게 한다. 단계 2, 자율주행은 기계가 작업 경로에 따라 직진, 회전 및 속도를 제어할 수 있게 하여 수동 조작 없이 작업을 수행할 수 있게 한다. 단계 3, 자율 작업은 기계가 작업 경로를 따라 자율적으로 작업을 수행하며, 운전이나 작업 제어 없이 수행할 수 있게 한다. 단계 4, 무인 자율 작업은 기계가 환경 인식과 인공지능을 사용하여 무인으로 작업을 수행할 수 있게 한다⁴⁾. 현재 자율 농업 기계 기술 개발은 단계 3 자율 작업 단계까지 기술 개발되었다.

자율주행을 위한 필드 세분화 목적을 위해 이미지 분할 네트워크를 사용할 수 있다. 의료 분야에서 사용되는 U-Net⁴⁾, 자동차 자율주행을 위해 설계된 PSPNet⁵⁾, 이미지 분할에 널리 사용되는 DeepLabV3⁶⁾와 같은 다양한 세그멘테이션 모델이 있다.

본 논문에서는 드론으로 촬영한 항공 이미지를 사용하여 경작지, 경작지의 모서리 및 도로를 인식하고 분류하여 자율 주행 트랙터를 위한 필드 인식 및 주행 맵 생성을 목적으로 한다. 이미지 분할을 DG-블록(DG-block)과 픽셀 셔플(pixel shuffle)을 이용하여서 모델을 만들고 사용하여 필드의 영역을 나누고 식별하는 의미론적 분할을 수행한다.

서론에 이어 본 논문의 구성은 다음과 같다. 2장에서는 세그멘테이션에 대한 설명과 실시간과 임베디드에서의 세그멘테이션에 대해 알아본다. 3장에서는 커스텀 모델의 구조와 사용한 블록, 손실함수에 관해서 설명한다. 4장 실험 결과에서는 훈련을 위한 데이터셋과 세부적인 훈련 설정 방법과 결과를 설명한다. 마지막 5장에서 논문을 요약하며 결론을 맺는다.

II. 관련 연구

농기계 자율주행을 위한 농경작지 환경 인식 시스템에서 인식 기술은 CNN 모델인 YOLO⁷⁾, Faster R-CNN⁸⁾, PSPNet⁵⁾, PIDNet⁹⁾과 같은 딥러닝 네트워

크가 사용되고 있다.

2.1 시멘틱 세그멘테이션

시멘틱 세그멘테이션은 이미지의 각 픽셀이 속하는 객체의 범주를 분류하여 복잡한 배경 속에서도 특정 대상을 정확하게 식별하는 데 매우 유용한 기법이다. 이러한 접근 방식은 특히 농경작지 내 다양한 특징을 가진 영역을 세밀하게 인식하고 구분하는 데 적합하다.

실제 농경작지 환경인식에서 딥러닝 세그멘테이션 모델을 적용하기 위해서는 실시간성과 모델의 경량화가 필요하다. 실시간 시멘틱 세그멘테이션은 고속으로 이미지를 처리하며 높은 정확도를 유지해야 한다. 실시간 시멘틱 세그멘테이션을 위한 방법론으로는 입력 이미지의 사이즈를 줄이거나 가벼운 인코더 구조 사용, 저수준의 특징과 고수준의 문맥 정보를 사용을 위한 이중 분기 아키텍처 등을 사용한다.

농기계 자율주행 기계에서 사용하기 위해서는 모바일이나 임베디드 보드의 제한된 성능 환경 안에서 모델의 구동을 해야 한다¹⁰⁾. 이러한 환경에서는 딥러닝 객체 검출과 장면 분할을 위해서 낮은 응답 지연 시간과 연산량의 최적화 등의 모델 경량화를 할 필요가 있다. 이러한 요구사항을 맞추기 위해서 가지치기(pruning), 양자화(quantization), 깊이별 분리 합성곱(depthwise separable convolution)과 같은 최적화 방식을 사용한다¹¹⁾.

2.2 U-Net

대표적인 세그멘테이션 모델 중 하나인 U-Net은 의료 영상 분석을 위해 처음 개발된 인코더-디코더 기반의 모델이다¹²⁾참고. U-Net의 인코더는 입력 이미지에서 중요한 특징을 추출하고, 디코더는 이를 바탕으로 픽셀 단위의 분류를 수행하여 더욱 정교한 세그멘테이션을 가능하게 한다. 특히, U-Net의 주요 특징 중 하나인 스킵 연결(skip connection 영어)은 인코더에서 추출된 정보가 디코더로 전달될 때 위치 정보가 손실되지 않도록 돕는다. 이를 통해 네트워크가 더욱 정확한 위치 정보를 유지하여 픽셀 단위의 세밀한 경계 인식이 가능해진다. 이러한 구조는 조직과 조직 사이의 경계가 모호한 경우에도 높은 정확도를 보이며, 의료 영상에서 조직의 세부 구조를 파악하는 데 뛰어난 성능을 발휘한다. 이처럼 U-Net은 그 효율성과 간단한 구조로 인해 의료 영상 분야 외에도 다양한 분야에서 널리 채택되고 있으며, 특히 농경작지 영역을 구분하는 데 효과적으로 활용될 수 있다.

농경작지 데이터셋 또한 특정 대상의 경계를 정확히 식별해야 하는 과제가 있다는 점에서 U-Net이 처음 제

안된 의료 영상 데이터셋과 유사하다. 특히, 농경작지 데이터셋에서는 고해상도 이미지 내에서 다양한 형태와 크기의 구조적 경계 특징을 정확히 파악해야 하는데, 이러한 점에서도 U-Net의 구조는 농경작지 데이터를 세밀하게 분류하는 데 매우 적합하다.

III. 제안 시스템

3.1 농경작지 영상의 특징

농경작지 영상은 일반적으로 그림 1과 같이 농경작지, 농경작지 모서리, 도로, 배경의 4가지 영역으로 크게 구분된다. 경작지를 구분하는 것은 흙으로 쌓은 경작지 모서리나 흙과 잡초로 이루어진 경계 모서리로 이루어진다. 경작지와 경작지 모서리의 패턴 및 색상 등의 차이로 발생하는 경계가 경운작업을 하기 위한 주행의 기준이 된다. 본 논문에서는 이러한 토양 패턴 및 색상 등의 차이로 발생하는 경작지 모서리를 파악하는 이미지 분할 모델을 만들고자 한다.

3.2 제안 모델

본 논문에서는 트랙터 주변 환경을 인식하기 위해 단안 카메라로 수집한 데이터셋을 바탕으로 딥러닝 세그멘테이션 알고리즘을 설계하였다. 제안하는 농경작지 딥러닝 세그멘테이션 모델은 농경작지 영상

이미지를 픽셀 단위로 세분화하며, 농기계 및 다양한 임베디드 환경에서의 활용을 위해 경량화된 모델 설계에 중점을 두었다.

제안하는 모델은 모델의 전체적인 그림 2와 같다. 첫 번째와 두 번째 계층은 이미지의 크기를 줄이면서



그림 1. 농경작지 주변 환경의 풍경 및 특징
Fig. 1. Scenery and characteristics of the environment surrounding agricultural fields

특징을 추출할 수 있게 3×3 합성곱, 배치 정규화(batch normalization), ReLU를 사용한 3×3 CBR-블록(convolution batch normalization ReLU-block)을 사용하였다. 세 번째 계층에서 다섯 번째 계층까지는 적은 연산량으로 특징을 추출할 수 있는 DG-블록을 사용하여 다중 스케일의 특징을 추출한다. 인코더의 각 계층에는 맥스풀링을 사용하여 사이즈를 줄였다.

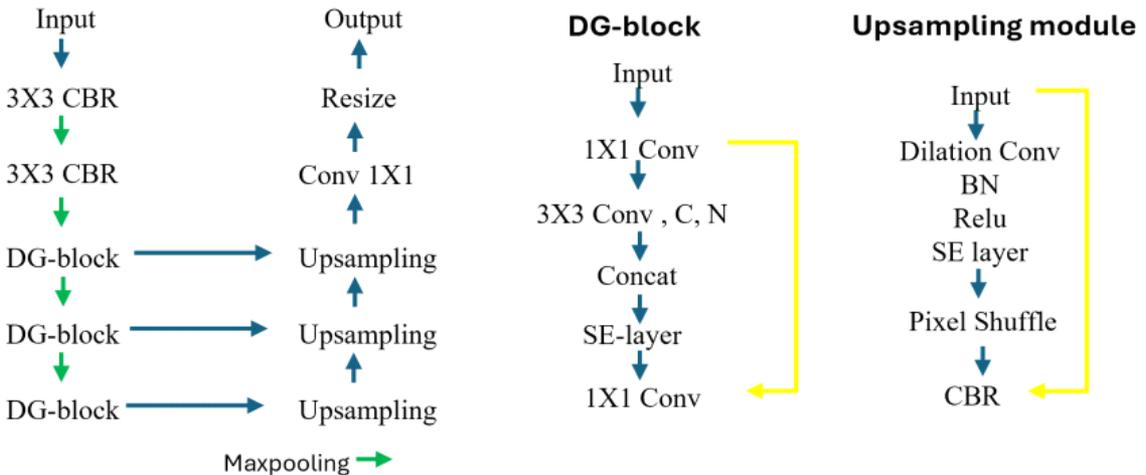


그림 2. 제안하는 세그멘테이션 모델 DG-Net와 DG-블록, 업샘플링 모듈 구조
Fig. 2. Proposed segmentation model DG-Net and DG-Block, upsampling module structure

디코더는 U-Net의 스킵 연결 사용하여 인코더의 또한 경량화를 시키기 위해 업샘플링 모듈^[11]을 사용하였다. 픽셀 셔플링을 사용하여서 차원의 커짐에 반비례하여 채널의 수를 줄여 나가며 매개변수의 개수 또한 줄여 나간다. 업샘플링 모듈을 통과한 후에 픽셀 단위의 분류를 수행한다. DG-Net에서는 256×256 입력 크기를 학습 후에 1920×1080 풀HD 해상도로 출력 크기로 출력되도록 하였다.

3.3 DG-블록

본 논문에서는 Sun 등이 제안한 SE-ResNeXt^[12] 모델의 Y-블록과 Gao 등이 제안한 Regseg^[13]의 D-블록에서 장점을 반영하여 DG-블록을 제안한다. DG-블록의 정의를 다음과 같이 정의된다.

$$F_{DG} = X \oplus Conv_{1 \times 1}(Conv_{1 \times 1}(SE(\sum_{k=3 \times 3}^n Conv_k X))) \quad (1)$$

여기서 F_{DG} 는 DG-블록을 거친 특징맵, X 는 CBR블록을 입력 특징맵 X , $Conv_{1 \times 1}$ 는 1D 합성곱 연산, $Conv_{3 \times 3}$ 는 3D 합성곱 연산, SE는 SE-레이어 연산, \oplus 요소별 곱연산을 의미한다.

F_{DG} 는 1×1 합성곱을 통해 입력 채널 수를 2^m 개수로 만든다. 입력채널은 확장 비율이 다른 N 개에 그룹으로 나누어 그룹 합성곱(grouped convolution)을 실행한다. 그룹 합성곱을 사용하면 일반 합성곱에 N 배 만큼의 매개변수의 수와 연산량을 줄일 수 있다. 또한 서로 다른 확장 비율을 사용하여서 수용영역이 다른 다중 스케일의 특징 맵을 얻을 수 있다. 추출한 다중 스케일의 특징은 연결(concatenate) 연산을 사용하여 합하며 SE-레이어를 사용하여 각 채널의 특징의 중요도를 주어 정보손실을 보완한다.

IV. 실험 및 결과

4.1 데이터셋

농경작지의 환경 분할을 위한 딥러닝 모델 개발을 위해 다음과 같이 데이터를 수집하고 데이터셋 그림 3을 구축하였다. 데이터 수집을 위한 장비로 4K 영상을 단안 카메라로 촬영할 수 있는 DJI mini 4 Pro라는 드론 모델을 사용하였다. 드론이 농경작지의 모서리 부분을 돌면서 다양한 각도에서 농경작지를 촬영한 영상으로 구성되어 있으며, 다양한 시점에서의 농경작지의 특징을 반영하고자 하였다. 영상 데이터는 10fps의 속도로

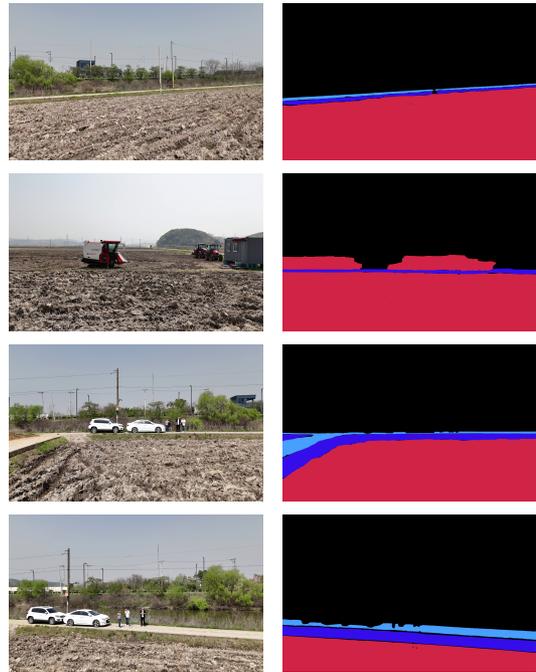


그림 3. 농경작지 이미지와 마스크 이미지 데이터셋
Fig. 3. Agricultural field image and mask image dataset

3840×2160의 해상도로 수집이 되었다.

시맨틱 세그멘테이션 모델을 학습시키기 위해서는 시맨틱 세그멘테이션 맵 필요하며, 시맨틱 세그멘테이션 맵을 만들기 위해 라벨링 툴을 사용하여 마스크 이미지를 생성할 필요가 있다. 마스크 이미지는 농경작지 환경 분할이라는 목적에 따라 농경작지와 농경작지 모서리, 도로, 배경 총 4개의 클래스로 구성하여 마스크 이미지를 생성하였다. 데이터셋은 966개로 학습 이미지 772장, 검증 97장, 테스트 97장으로 구성하였다. 훈련 중에는 256×256로 이미지의 크기를 줄여서 학습을 진행하였다.

4.2 손실 함수

농경작지 데이터셋의 이미지는 경작지에 많은 픽셀의 클래스가 몰려있어 경작지 픽셀에 비해 적은 픽셀을 가진 경작지 모서리의 경우 편향된 학습이 진행되는 문제가 발생한다. 이러한 편향된 학습을 예방하기 위해서 학습에서는 초점 손실(focal loss)^[14]사용하였다.

$$FL(p_i) = -(1 - p_i)^\gamma \log(p_i) \quad (2)$$

초점 손실은 객체 분류 확률 p_i 의 로그값에 가중치 $(1 - p_i)^\gamma$ 를 곱하여 얻을 수 있다. (1)에서 p_i 객체의 확률을 가리키며 $(1 - p_i)^\gamma$ 가중치이다. 가중치는

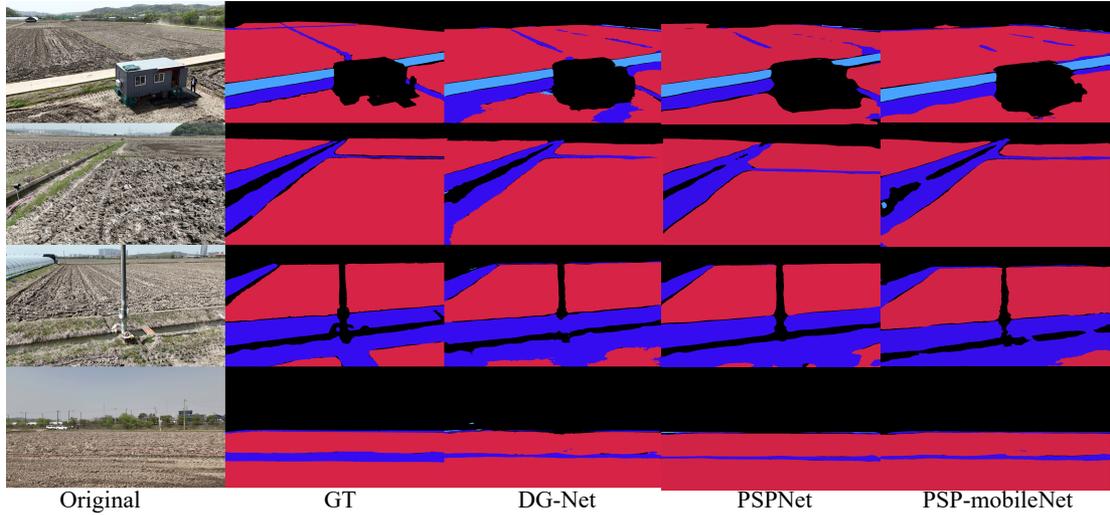


그림 4. 모델별 농경작지 이미지 세그멘테이션 결과 비교
 Fig. 4. Comparison of model agricultural field image segmentation results

$(1 - p_t)$ 의 반대의 확률을 가지고 있어 p_t 가 높은 확률을 가질 경우 손실 함수의 값을 줄여 매개변수의 가중치를 더 적게 변화시킨다. 반대로 p_t 값이 작다면 가중치를 키워 손실 함수의 값을 크게 만들어 매개변수의 가중치를 변화 폭을 크게 만들 수 있다. 매개변수 γ 는 집중 매개변수라 하며, 가중치를 영향을 증가시키거나 줄이는 역할을 한다.

4.3 환경 설정

성능 비교를 위해서 성능 비교 지표인 정확도와 mIOU 지표를 사용한다. 모델에서 사용한 초매개변수는 40 에포크(epoch), 학습률(learning rate) 0.01, 배치 크기(batch size) 4이다. 손실함수는 초점 손실(focal loss)에 감마 값 2, 옵티마이저로 아담(Adam)을 사용하였다.

모델은 파이토치(pytorch) 프레임워크를 사용하여 구현하고, NVIDIA GeForce RTX 4080 GPU(메모리 16GB)에서 훈련 및 테스트를 수행하였다.

4.4 결과

DG-Net이 농경작지 세그멘테이션 모델로 적절하다는 것을 알아보기 위해서 다른 모델들과 추론 속도 및 정확도를 비교하였다. 픽셀을 분류하고 결과 이미지를 생성까지의 시간을 측정하여 추론 속도를 측정하였다. 추론 속도의 목표는 50ms 기준은 초당 20프레임을 처리할 수 있도록 기준을 잡았다. 추론 속도의 목표의 경우 또한 추론 속도가 목표 이하라도 정확도가 만족하지 못하는 수준이라면 농경지 세그멘테이션 모델로는

사용하지 못하기에 mIOU와 정확도를 이용하여 측정하였다.

DG-Net과 다른 모델들의 농경지 세그멘테이션 추론 속도를 측정하였다. 실험한 모델들의 성능은 30fps에는 못 미치는 결과이지만 실제 과제에서 목표로 하던 20fps 가까운 성능을 모델을 확인하였다.

DG-Net의 경우 20프레임을 달성함으로써 농경작지 세그멘테이션에 적절한 모델임을 확인하였다. 표 1은 모델별 추론 시간과 fps를 나타낸 표이다.

모델별 농경작지 이미지 세그멘테이션 정확도 및 IOU 비교는 표 2와 같다. 정확도와 mIOU 성능지표에서 DG-Net이 가장 높게 나오는 것을 확인하였다. 표 3은 클래스별 정확도 및 IOU 나타내는 표이다. 여기서 성능이 높은 PSPNet과 DG-Net을 살펴보면 PSPNet 경우 배경 클래스의 IOU가 높아서 표 2의 mIOU의 성능이 높아진 것을 볼 수 있다. DG-Net의 경우 의미 있는 클래스인 농경작지와 도로에서 다른 모델들과 비교하며 좋은 성능을 가지고 있다고 보여진다.

표 1. 세그멘테이션 모델 추론시간과 fps
 Table 1. Segmentation model inference time and fps

Model	Time(ms)	FPS
U-Net	82	13
PSPNet	101	10
PSP-mobileNet	62	16
PIDNet	42	24
DG-Net (Ours)	50	20

표 2. 세그멘테이션 모델 성능 비교표
Table 2. Segmentation model inference time and fps

Model	Accuracy (%)	mIOU (%)
U-Net	75.3	74.8
PSPNet	76.5	78.2
PSP-mobileNet	75.1	77.8
PIDNet_s	59	51.5
DG-Net(Ours)	77.7	78.4

모델 별 이미지 세그멘테이션 결과를 사진으로 표현한 결과는 그림 4와 같다. DG-Net의 결과는 GT 비교하면 다른 모델들과 비교하여 잘 구분하는 것을 보여주었다. 그림 4의 첫 번째 이미지의 경우 원본이미지와 비교하여 GT에 경작지 모서리가 빠진 부분이 있는데 DG-Net의 경우 그 부분을 포함하여 이미지 세그멘테이션하는 모습을 보여주었다.

모델별 메모리량과 매개변수 수의 비교는 표 4과 같다. 메모리량과 파라미터 수는 PIDNet_s가 좋지만 PIDNet_s의 경우 다른 모델들과 비교하여 성능이 많이 떨어지는 모습을 보여주어 적합한 모델이라고 보이지 않는다. 비슷한 성능을 보여준 PSPNet 모델은 다른 모델과 비교하여 매개변수의 수가 많고 추론 시간이 좋지 않은 모습을 보인다. 반면 DG-Net은 메모리양에서는 많은 차이를 보이지 않지만 매개변수 수를 비교하였을 때 다른 모델들보다 매개변수 수가 월등히 적은 것을 보여주었다.

DG-블록의 그룹 합성곱의 개수를 변화시켜 메모리 사용량 및 파라미터의 변화를 관찰하였다. DG-블록의 그룹 합성곱 개수에 따른 메모리량 및 매개변수 비교는 표 5와 같다. 그룹 합성곱의 개수가 늘수록 파라미터가 수가 줄어들며 경량화 가능하였다.

또한 파라미터 수가 줄어 메모리량도 줄어드는 걸 보여주었다. 채널의 수에 한계가 있어서 일정 수준 이후

표 3. 클래스 별 농경지 세그멘테이션 모델 성능 비교표
Table 3. Agricultural land segmentation model performance comparison table by c

Model	Paddy Accuracy (%)	Paddy IOU (%)	Paddy edge Accuracy(%)	Paddy edge IOU(%)	Road Accuracy(%)	Road IOU (%)	Background Accuracy (%)	Background IOU (%)
U-Net	89.5	85.4	79	62	44	72	89	80
PSPNet	90.3	86.6	80	66.8	47.5	76.1	88.3	83.4
PSP-mobile Net	90	88.1	77	64.1	45.5	77	88	82
PIDNET_s	63	61	47	40	36	57	90	48
DG-Net (Ours)	93.8	88.6	80.1	65.7	48.2	79.6	91.7	77.1

표 4. 모델별 메모리 사용량과
Table 4. Agricultural land segmentation model performance comparison table by class

Model	Cache (MB)	#Params	size (MB)
U-Net	242	3.2M	38
PSPNet	416	4.9M	101
PSP-mobileNet	230	2.6M	54
PIDNET_s	110	0.7M	110
DG-Net(Ours)	160	1.17M	36

표 5. DG-블록의 그룹 합성곱 개수에 따른 메모리량 및 매개변수 비교
Table 5. Memory amount and parameters according to the number of group convolutions of DG-blocks

Group number	Cache (MB)	#Params	size (MB)
1	232	2.08M	61
2	208	1.37M	53
4	196	1.26M	47
8	178	1.20M	42
16	160	1.17M	36
32	160	1.16M	33

로는 파라미터의 감소가 크게 눈에 띄지 않고 메모리량 또한 고정되는 것을 확인하였다.

V. 결 론

본 논문에서는 드론으로 촬영한 영상을 데이터셋으로 사용하여 경작지와 경작지 모서리 및 도로를 픽셀 단위로 분류하는 딥러닝 세그멘테이션 시스템

모델을 제안하였다. 농기계에서 사용을 하기 위해서 처리 속도와 경량화된 모델을 최우선적으로 고려하

였다. 팽창 그룹 합성곱을 이용한 DG-블록을 제안하여 경량화된 모델로 속도를 높여 목적을 달성하고자 하였다.

DG-블록을 이용한 DG-Net은 경량화와 목표한 추론 속도로 이미지를 처리하는데 성공하였다. DG-Net의 정확도는 농기계에서 사용하기 무리가 없고 작은 컴퓨팅 자원을 사용하여 다른 시스템과 같이 사용해도 지장이 주지않는 이미지 세그멘테이션 모델을 제안하였다고 보여진다.

추후 연구 주제에서는 좀 더 세밀한 부분을 세그멘테이션 할 수 있도록 모듈을 추가하는 방향으로 연구를 진행하고자 한다.

References

- [1] H. Patel and B. Shrimali, "AgriOnBlock: Secured data harvesting for agriculture sector using blockchain technology," *ICT Express*, vol. 9, no. 2, pp. 150-159, Apr. 2023. (<https://doi.org/10.1016/j.ict.2021.07.003>)
- [2] A. E. Mane, K. Tatane, and Y. Chihab, "Transforming agricultural supply chains: Leveraging blockchain-enabled java smart contracts and IoT integration," *ICT Express*, vol. 10, no. 3, pp. 650-672, Jun. 2024. (<https://doi.org/10.1016/j.ict.2024.03.007>)
- [3] S. Lim, M. Kim, D. Lee, and M. Won, "Vision-based farmland boundary detection algorithm for automation of an agricultural tractor," *J. Inst. Control, Robotics and Syst.*, vol. 29, no. 3, pp. 208-216, Mar. 2023. (<https://doi.org/10.5302/J.ICROS.2023.22.0226>)
- [4] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *Medical Image Comput. and Computer-Assisted Intervention - MICCAI 2015: 18th Int. Conf.*, pp. 5-9, Munich, Germany, Oct. 2015. (https://doi.org/10.1007/978-3-319-24574-4_28)
- [5] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, "Pyramid scene parsing network," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, pp. 2881-2890, Honolulu, HI, USA, Jul. 2017. (<https://doi.org/10.1109/CVPR.2017.660>)
- [6] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," in *Proc. Eur. Conf. Comput. Vis. (ECCV)*, pp. 801-818, Munich, Germany, Sep. 2018. (https://doi.org/10.1007/978-3-030-01234-2_49)
- [7] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, pp. 779-788, Las Vegas, NV, USA, Jun. 2016. (<https://doi.org/10.1109/CVPR.2016.91>)
- [8] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137-1149, Jun. 2017. (<https://doi.org/10.1109/TPAMI.2016.2577031>)
- [9] J. Xu, Z. Xiong, and S. P. Bhattacharyya, "PIDNet: A real-time semantic segmentation network inspired by PID controllers," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, pp. 19529-19539, Vancouver, BC, Canada, Jun. 2023. (<https://doi.org/10.1109/CVPR52729.2023.01871>)
- [10] S. W. Lee, G. D. Lee, J. G. Ko, S. J. Lee, and W. Y. Yoo, "Recent trends of object and scene recognition technologies for mobile/embedded devices," *Electr. Telecommun. Trends*, vol. 34, no. 6, pp. 133-144, Dec. 2019. (<https://doi.org/10.22648/ETRI.2019.J.340612>)
- [11] H. Son and J. Weiland, "Semantic segmentation optimized for low compute embedded devices," *IEEE Access*, vol. 10, pp. 96514-96525, Aug. 2022. (<https://doi.org/10.1109/ACCESS.2022.3199418>)
- [12] K. Sun, B. Xiao, D. Liu, and J. Wang, "Deep high-resolution representation learning for human pose estimation," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*,

pp. 5693-5703, Long Beach, CA, USA, Jun. 2019.

(<https://doi.org/10.1109/CVPR.2019.00584>)

- [13] R. Gao, "Rethinking dilated convolution for real-time semantic segmentation," in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, p. E675, Vancouver, BC, Canada, June 2023.

(<https://doi.org/10.1109/CVPRW53098.2023.00349>)

- [14] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal loss for dense object detection," in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, pp. 2980-2988, Venice, Italy, Oct. 2017.

(<https://doi.org/10.1109/ICCV.2017.324>)

배 나 연 (Na Yeon Bae)



2023년 8월: 영남대학교 정보통신공학과 공학사

2023년 9월~현재: 경북대학교 전자 전기공학부 석사과정

<관심분야> 인공지능

최 성 균 (Sung Kyun Choi)



2002년: 비앤디 책임연구원

2005년: 경북대학교 전자전기공학부 공학사

2016년: 이모션 연구소장

2023년: 모비루스 인공지능 연구소장

<관심분야> 모빌리티, 자율주행, 임베디드, 인공지능

한 동 석 (Dong Seog Han)



1987년: 경북대학교 전자공학과 공학사

1989년: 한국과학기술원 전기 및 전자공학과 공학석사

1993년: 한국과학기술원 전기 및 전자공학과 공학박사

1996년~현재: 경북대학교 전자공학부 교수

<관심분야> 통신 신호처리, 자율주행자동차, 인공지능