

경량화된 의미론적 분할 모델을 이용한 임베디드 보드 구동 가능한 벼 도복률 산출 연구

박근호, 이규원, 최주환

한국전자기술연구원

root@keti.re.kr, rbdnjs704@keti.re.kr, netside@keti.re.kr

A Study for Calculating Rice Lodge Rate That can be Driven by Embedded Boards Using a Lightweight Semantic Segmentation Model

Keunho Park, Gyuwon Lee, Juhwan Choi

Korea Electronics Technology Institute

요약

벼 생산량 감소에 주된 요인 중 벼 도복은 벼의 생육 및 발육기에 발생하는 혼한 생리적 장애로, 벼 이삭에 짹이 트는 현상인 수발아 피해가 발생하여 벼의 수량과 미질에 큰 영향을 제공한다. 벼 도복 발생률의 객관적 측정을 위해서는 검사자 그리고 피검사자의 주관이 개입되지 않고 판독의 근거가 되는 데이터를 입력하면 판독 결과물을 출력하는 블랙박스와 같은 형태의 기술이 필요하다. 이러한 시스템을 구현하기 위해서는 딥러닝 경량화 모델을 이용하여 임베디드 보드 내에서 영상을 입력받으면 도복률을 계산하여 출력하는 방식이 효율적이다. 본 논문에서는 실제 임베디드 보드 환경에서 분할 알고리즘을 운영한 결과를 도출하여 벼 도복률 산출의 모바일 블랙박스화 가능성에 대한 검증을 실시하였다. 성능 비교를 위해 MobileNet version 1부터 3까지를 backbone으로 하는 U-Net과 LR-ASPP구조를 가지는 모델 5개를 구성하여 비교하였다. 최종 결과 MobileNetV3_LR-ASPP (small)이 4.98초로 가장 빠른 처리 속도를 보였고 벼 도복률 산출의 블랙박스화 가능성을 입증하였다.

I. 서 론

벼 생산량 감소에 주된 요인 중 벼 도복은 벼의 생육 및 발육기에 발생하는 혼한 생리적 장애로, 품종특성, 재배 기술, 시비량, 물 관리, 재배방법, 재식밀도, 병해충, 그리고 집중 호우나 태풍과 같은 기상조건과 밀접한 관련이 있다. 벼 도복으로 인해 벼 이삭에 짹이 트는 현상인 수발아 피해가 발생하여 벼의 수량과 미질에 큰 영향을 제공한다 [1]. 벼 도복 발생한 위치와 면적 등의 정보를 신속하고 정확하게 분석하는 것은 벼 재배재해평가, 농업재해보험, 정부의 재해관리대책, 이에 따른 보조금 지원 등에 중요한 근거가 된다. 벼 도복 피해 분석을 위한 전통적인 방법은 일반적으로 광범위한 전문 지식과 경험이 요구되는 조사원을 파견하여 실시하기 때문에 주관적인 경향이 있으며, 조사에 많은 시간과 인력이 투입되는 문제점이 있다.

기존 연구들은 분류 또는 분할 기술을 이용하여 영상 전체에 나타난 도복 특성을 분석하거나 수동으로 구획화한 특정 부분의 도복 특성을 분석하는 방식으로 검출 결과를 출력한다 [2-4]. 영상 전체를 분석하는 방법은 특성 분석 이후 관심 분석 필지를 수동으로 구획화해야 하며, 분석 전 수동으로 구획화하는 방법은 효율성이 떨어지며 두 방법 모두 수동 구획화하는 과정에서 주관적인 견해가 포함되어 도복 분석의 객관성을 훼손할 우려가 있다. 벼 도복 발생률의 객관적 측정을 위해서는 측정 알고리즘 성능의 우수성뿐만 아니라 검사자 그리고 피검사자의 주관이 개입되지 않고 판독의 근거가 되는 데이터를 입력하면 판독 결과물을 출력하는 블랙박스와 같은 형태의 기술이 필요하다. 이러한 시스템을 구현하기 위해서는 딥러닝 경량화 모델을 이용하여 임베디드 보드 내에서 영상을 입력받으면 도복률을 계산하여 출력하는 방법이 효율적이다.

따라서 본 논문에서는 실제 임베디드 보드 환경에서 분할 알고리즘을

운영한 결과를 도출하여 벼 도복률 산출의 모바일 블랙박스화 가능성에 대한 검증을 실시하였다.

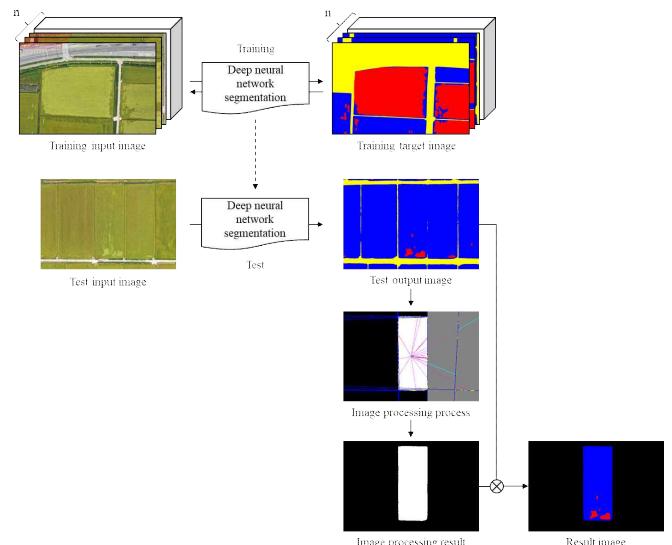


그림 1. 완전 자동화된 벼 도복률 산출 과정

II. 본론

그림 1과 같은 완전 자동화된 벼 도복률 산출을 임베디드 보드의 연산자 원으로 처리할 수 있도록 deep neural network segmentation 모델을 차용하였다. 자세한 구조는 그림 2, 3과 같이 MobileNet을 백본으로 하는 U-Net과 LR-ASPP구조이고, 기존 deep neural network segmentation 모델의 입력영상의 가로, 세로 크기인 224×224를 대체하여 1,920×1,280 크기의 영상을 분할 없이 한번에 처리 할 수 있도록 model parameter를

연구 방향에 부합하도록 수정하였다.

제안된 의미론적 분할 모델은 'MobileNetV1-UNet' (MobileNetV1 백본에 U-Net segmentation head를 결합한 모델), 'MobileNetV1-LR-ASPP' (MobileNetV1 백본에 LR-ASPP large segmentation head를 결합한 모델), 'MobileNetV2-LR-ASPP' (MobileNetV2 백본에 LR-ASPP large segmentation head를 결합한 모델), 'MobileNetV3-LR-ASPP (small)' (MobileNetV3 백본에 LR-ASPP small segmentation head를 결합한 모델), 그리고 'MobileNetV3-LR-ASPP (large)' (MobileNetV3 백본에 LR-ASPP large segmentation head를 결합한 모델) 5가지이다. 모델은 Adam 알고리즘을 사용하여 훈련되었으며 learning rate은 MobileNetV1-UNet은 0.001, MobileNetV1-LR-ASPP, MobileNetV2-LR-ASPP, MobileNetV3-LR-ASPP (small), MobileNetV3-LR-ASPP (large)는 0.00005, mini batch 크기는 2, 학습 반복은 200 epochs로 설정하였다.

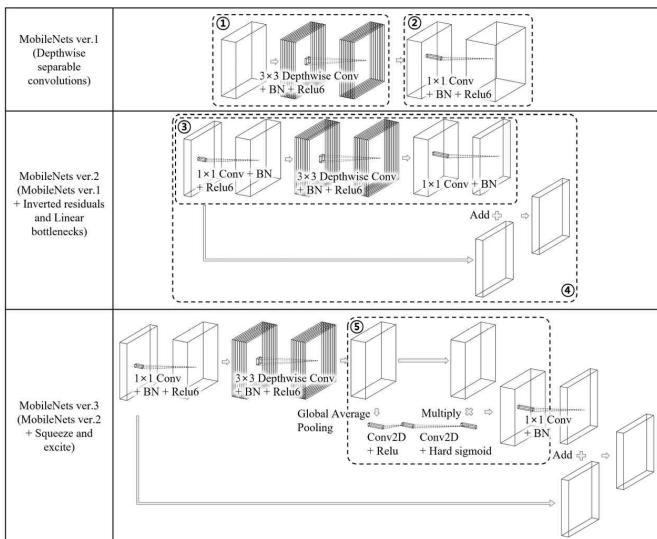


그림 2. MobileNets 각 버전별 블록 구조

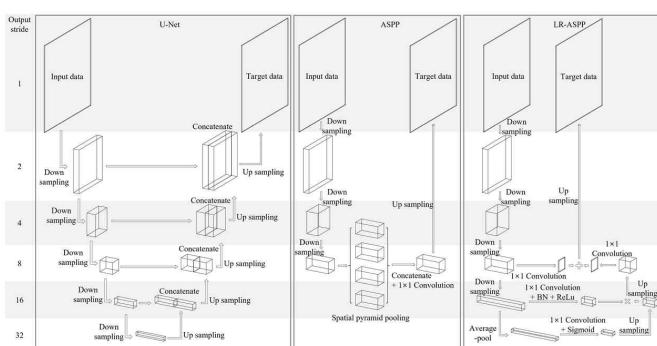


그림 3. U-Net, atrous spatial pyramid pooling (ASPP), lite residual ASPP (LR-ASPP)의 기본 구조

모바일 운영 잠재성을 알아보기 위해 다섯 가지 모델 각각의 파라미터 개수를 비교하고 임베디드 보드 Raspberry Pi 4에서의 도복 영상 한 장당 처리 시간인 latency값을 측정하였다. 표 1은 각 모델별 파라미터 개수를 기록한 결과이다. U-Net 구조를 가지고 있는 MobileNetV1_U-Net 모델이 다른 모델과 비교하여 파라미터의 개수가 압도적으로 많은 것을 볼 수 있다. 다섯 가지 모델 각각을 6-fold validation을 위해 데이터를 바꿔가며 6번 반복 학습하였다. 따라서 표 2는 다섯 가지 모델 각각의 평균 latency 값을 나타낸다. 다섯 가지 모델 모두 Raspberry Pi 4의 CPU에로

딩이 가능하여 임베디드 보드 상에서 분석 결과를 낼 수 있었다. 다섯 가지 모델 중 모델 MobileNetV3_LR-ASPP (small)이 4.9844초로 가장 빠른 처리 속도를 보였다.

표 1. 각 모델별 파라미터 개수

모델 명	비학습 파라미터 개수	학습 파라미터 개수	전체 파라미터 개수
MobileNetV1-UNet	7,820,547	3,230,784	11,051,331
MobileNetV1-LR-ASPP	1,745,862	14,976	1,760,838
MobileNetV2-LR-ASPP	568,102	16,384	584,486
MobileNetV3-LR-ASPP (small)	203,782	4,880	208,662
MobileNetV3-LR-ASPP (large)	822,182	11,408	833,590

표 2. 임베디드 보드에서의 데이터 처리 속도

모델 명	Latency (초)
MobileNetV1-UNet	17.9806
MobileNetV1-LR-ASPP	8.2923
MobileNetV2-LR-ASPP	9.8714
MobileNetV3-LR-ASPP (small)	4.9844
MobileNetV3-LR-ASPP (large)	9.4764

III. 결론

논문에서는 실제 임베디드 보드 환경에서 분할 알고리즘을 운영한 결과를 도출하여 벼 도복률 산출의 모바일 블랙박스화 가능성에 대한 검증을 실시하였다. 성능 비교를 위해 MobileNet version 1부터 3까지를 backbone으로 하는 U-Net과 LR-ASPP구조를 가지는 모델 5가지를 구성하여 비교하였다. 최종 결과 MobileNetV3_LR-ASPP (small)이 4.9844초로 가장 빠른 처리 속도를 보였다. 본 연구 결과는 벼에 대한 대규모 도복 모니터링과 정확한 도복 발생률 산출을 위한 효과적인 방법을 제공할 수 있으며, 벼 재배, 국가 보조금 지원, 농업 재해 보험 청구 분야에서 객관적인 의사결정 지원을 제공할 수 있음을 보여준다.

ACKNOWLEDGMENT

이 논문은 과학기술정보통신부의 재원으로 정보통신산업진흥원(NIPA)에서 지원한 AI융합 지능형 농업 생태계 구축 사업으로 수행된 연구임 (S0103-24-1001).

참 고 문 헌

- [1] Su, Z., Wang, Y., Xu, Q., Gao, R., and Kong, Q. "LodgeNet: Improved rice lodging recognition using semantic segmentation of UAV high-resolution remote sensing images," Computers and Electronics in Agriculture, 196, 106873, 2022.
- [2] Rajapaksa, S., et al. "Classification of Crop Lodging with Gray Level Co-occurrence Matrix," 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), pp. 251–258, 2018.
- [3] Mardanisamani, S., et al. "Crop Lodging Prediction From UAV-Acquired Images of Wheat and Canola Using a DCNN Augmented With Handcrafted Texture Features," 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp. 2657–2664, 2019.
- [4] Yang, B., Zhu, Y., and Zhou, S. "Accurate Wheat Lodging Extraction from Multi-Channel UAV Images Using a Lightweight Network Model," Sensors, 21(20), 6826, 2021.