

딥러닝을 이용한 소규모 지역의 영상분류 적용성 분석 : UAV 영상을 이용한 농경지를 대상으로

Applicability of Image Classification Using Deep Learning in Small Area : Case of Agricultural Lands Using UAV Image

최석근¹⁾ · 이승기²⁾ · 강연빈³⁾ · 성선경⁴⁾ · 최도연⁵⁾ · 김광호⁶⁾

Choi, Seok-Keun · Lee, Soung-Ki · Kang, Yeon-Bin · Seong, Seon-Kyeong
· Choi, Do-Yeon · Kim, Gwang-Ho

Abstract

Recently, high-resolution images can be easily acquired using UAV (Unmanned Aerial Vehicle), so that it is possible to produce small area observation and spatial information at low cost. In particular, research on the generation of cover maps in crop production areas is being actively conducted for monitoring the agricultural environment. As a result of comparing classification performance by applying RF(Random Forest), SVM(Support Vector Machine) and CNN(Convolutional Neural Network), deep learning classification method has many advantages in image classification. In particular, land cover classification using satellite images has the advantage of accuracy and time of classification using satellite image data set and pre-trained parameters. However, UAV images have different characteristics such as satellite images and spatial resolution, which makes it difficult to apply them. In order to solve this problem, we conducted a study on the application of deep learning algorithms that can be used for analyzing agricultural lands where UAV data sets and small-scale composite cover exist in Korea. In this study, we applied DeepLab V3 +, FC-DenseNet (Fully Convolutional DenseNets) and FRRN-B (Full-Resolution Residual Networks), the semantic image classification of the state-of-art algorithm, to UAV data set. As a result, DeepLab V3 + and FC-DenseNet have an overall accuracy of 97% and a Kappa coefficient of 0.92, which is higher than the conventional classification. The applicability of the cover classification using UAV images of small areas is shown.

Keywords : Deep Learning, UAV, Image Classification, Random Forest, Semantic Classification

초 록

최근 UAV (Unmanned Aerial Vehicle)를 이용하여 고해상도 영상을 편리하게 취득할 수 있게 되면서 저비용으로 소규모 지역의 관측 및 공간정보 제작이 가능하게 되었다. 특히, 농업환경 모니터링을 위하여 작물생산 지역의 피복지도 생성에 대한 연구가 활발히 진행되고 있으며, 랜덤 포레스트와 SVM (Support Vector Machine) 및 CNN (Convolutional Neural Network) 을 적용하여 분류 성능을 비교한 결과 영상분류에서 딥러닝 적용에 대하여 활용도가 높은 것으로 나타났다. 특히, 위성영상을 이용한 피복분류는 위성영상 데이터 셋과 선행 파라미터를 사용하여 피복분류의 정확도와 시간에 대한 장점을 가지고 있다. 하지만, 무인항공기 영상은 위성영상과 공간해상도와 같은 특성이 달라 이를 적용하기에는 어려움이 있다. 이러한 문제점을 해결하기 위하여 위성영상 데이터 셋이 아닌 UAV를 이용한 데이터 셋과 국내의 소규모 복합 피복이 존재하는 농경지 분석에 활용이 가능한 딥러닝 알고리즘 적용 연구를 수행하였다. 본 연구에서는 최신 딥러닝의 의미론적 영상분류인 DeepLab V3+, FC-DenseNet (Fully Convolutional DenseNets) , FRRN-B (Full-Resolution Residual Networks) 를 UAV 데이터 셋에 적용하여 영상분류를 수행하였다. 분류 결과 DeepLab V3+와 FC-DenseNet의 적용 결과가 기존 감독분류보다 높은 전체 정확도 97%, Kappa 계수 0.92로 소규모 지역의 UAV 영상을 활용한 피복분류의 적용가능성을 보여주었다.

핵심어 : 딥러닝, 무인항공기, 영상분류, 랜덤 포레스트, 의미론적 영상분류

Received 2020. 02. 01, Revised 2020. 02. 13, Accepted 2020. 02. 25

1) Member, Professor, Dept. of Civil Engineering, Chungbuk National University (E-mail: skchoi@cbnu.ac.kr)

2) Member, Researcher, Terrapix (E-mail: iruril@chungbuk.ac.kr)

3) Dept. of Civil Engineering, M.S. student, Chungbuk National University (E-mail: dusqls4708@naver.com)

4) Dept. of Civil Engineering, M.S. student, Chungbuk National University (E-mail: skseong@cbnu.ac.kr)

5) Member, Researcher, Terrapix (E-mail: jedgoh@naver.com)

6) Corresponding Author, Member, Dept. of Civil Engineering, Ph.D. student, Chungbuk National University (E-mail : kgh7759@naver.com)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서 론

최근 UAV (Unmanned Aerial Vehicle)를 이용한 고해상도 영상취득이 편리하게 되면서 소규모지역의 정확한 공간정보 제작이 가능하게 되었다. 이렇게 취득된 영상을 이용한 토지 피복분류는 최신의 공간정보를 저비용으로 제작할 수 있는 장점이 있어 이에 대한 다양한 연구가 수행되고 있다.

토지피복은 표면의 물리적 구성을 의미하며, 이를 과학적 기준에 따라 분류하여 동질의 특성을 지닌 구역을 표현한 주제도가 토지피복지도이다(Fisher *et al.*, 2005). 최근 농업환경 모니터링을 위하여 작물 피복지도에 대한 연구가 활발히 진행되고 있으며, 이와 같이 분류된 지도는 생산량의 예측, 생육 모델링 등에 활용되고 있다(Zhong *et al.*, 2014; Murugan *et al.*, 2017). 특히 원격탐사에 의해 획득되는 자료는 현장조사 자료보다 주기적으로 정보를 취득할 수 있어 그 활용도가 매우 높다(Park and Park, 2015; Hall *et al.*, 2018; Ishida *et al.*, 2018).

기존의 분류기법으로는 SVM, RF 등의 기계학습 알고리즘이 적용·연구되고 기존의 방법에 비하여 높은 정확도를 확보하고 있지만 상대적으로 무감독 분류에 비하여 제작 및 갱신에 많은 시간과 비용이 요구되는 한계가 있다(Kwak *et al.*, 2017; Onojeghuo *et al.*, 2018; Torbick *et al.*, 2018; Xu *et al.*, 2018). 이와 같은 한계를 극복하기 위하여 입력자료를 바탕으로 자료를 변형하고 추상화된 특징을 스스로 학습 할 수 있는 딥러닝 방법을 적용하는 연구가 진행되고 있다(LeCun and Bengio, 2015).

최근에는 피복 분류 정확도와 속도를 높이기 위하여 기존의 선행자료를 활용하고 기계학습과 딥러닝 알고리즘을 적용하고 있다(Kwak *et al.*, 2017; Onojeghuo *et al.*, 2018; Torbick *et al.*, 2018; Xu *et al.*, 2018; Kussul *et al.*, 2017; Kamilaris and Prenafeta-Boldú, 2018). 일반적으로 영상처리 및 신호분석 등의 분야에서 기계학습보다 시공간정보를 고려하는 딥러닝의 분류 성능이 우수한 것으로 알려져 있으며(Karpathy *et al.*, 2014; Ji *et al.*, 2018), 특히 인접한 화소 간의 공간 상관성을 고려하는 CNN을 이용한 피복분류 연구가 많이 수행되고 있다(Castro *et al.*, 2017; Dang *et al.*, 2018; Gao *et al.*, 2018). Zhong *et al.* (2017)는 고해상도 위성영상분류에 수정된 CNN을 적용한 결과 99.54%의 높은 분류 정확도를 확보하였고, Song and Kim (2017)은 RF와 SVM 및 CNN을 적용하여 분류 성능을 비교한 결과 영상분류에서 딥러닝 적용에 대한 유의미한 결과를 도출하였다. Scott *et al.* (2017)은 딥러닝 적용시 사전학습 파라미터와 데이터중시 작업을 통하여 고해상도 위성영상의 분류정확도를 증가시켰고, Joe *et al.* (2019)는 사전

학습 파라미터(ImageNet)를 사용하여 위성영상을 이용한 한국 토지피복분류의 학습속도와 정확도를 높였다.

국내외 연구동향에서 확인할 수 있는 것과 같이, 사전학습된 데이터를 이용하여 위성영상과 대규모 지역에 대한 피복분류에 관한 연구는 많이 진행되었다. 그러나, 위성영상과 공간 해상도와 같은 특성이 달라 위성영상 데이터를 사용하면 분류정확도가 낮아질 수 있다. 이러한 문제점을 해결하기 위하여 위성영상 데이터 셋이 아닌 UAV를 이용한 데이터 셋과 국내의 소규모 복합 피복이 존재하는 농경지 분석에 활용이 가능한 딥러닝 알고리즘 적용 연구가 필요하다.

따라서, 본 연구는 소규모 농경지에 대하여 촬영한 UAV 영상을 이용하여 데이터 셋을 생성하고, 이를 활용하여 각각의 딥러닝 알고리즘별 훈련 파라미터를 생성하였다. 비교 실험에는 기계학습인 RF와 의미론적 영상 분류에서는 최신의 기법인 DeepLab V3+, FC-DenseNet (Fully Convolutional DenseNets) 및 FRRN-B (Full-Resolution Residual Networks)을 적용하여 분석함으로써 소규모 지역의 영상분류 적용성 분석을 수행하였다.

2. 실험지역 및 자료

2.1 실험자료의 제원

대상지역의 작물분류에는 RGB (Red-Green-Blue)데이터를 획득할 수 Zenmuse X3 카메라가 탑재된 회선익 Inspire 1을 사용하였다. Inspire 1은 GNSS(Global Navigation Satellite System), IMU(Inertial Measurement Unit) 등을 탑재하여 사용자가 사전에 입력한 영역을 계획에 따라 자동비행하는 시스템을 포함하고 있으며, 고정익 UAV와 비교하여 소규모 지역을 제한없이 빠른 시간에 촬영할 수 있는 장점을 가지고 있다. 또한, 본 연구에서 분류 및 탐지하고자 하는 대상물질이 농경지이기 때문에, 효과적인 분류를 위한 고해상도 자료가 요구된다. 따라서 Zenmuse X3를 활용하여 고해상도 정사영상을 제작하여 활용하고자 하였다. Fig. 1 및 Table 1은 실험에 사용한 UAV 및 카메라의 특성을 나타낸다.




Fig. 1. Description of UAV and camera used for experiment

Table 1. Specification of Inspire 1 and Zenmuse X3

Inspire 1		Zenmuse X3	
Size	438x451x301 mm	Resolution	12 megapixel
Weight	2,935 g	Sensor size	6.17 x 4.55 mm
Maximum flight time	18 min	ISO range	100~3200
Mounting sensor	GNSS, IMU	Diagonal FOV	94 degree

2.2 실험지역의 선정 및 자료 취득

연구 대상 지역은 식생, 나지, 아스팔트 및 콘크리트 도로가 혼합되어 있는 Fig. 2(a)의 소규모 농경지, Fig. 2(b)의 옥수수 지역, Fig. 2(c)의 벼 지역을 대상으로 선정하였다. 또한 옥수수 및 벼의 생육주기를 고려하여 2019년 7월에 촬영된 영상을 사용하였다. 대상 지역에서는 식생으로 옥수수 외에 벼를 함께 재배하고 있으며 주변에 비닐하우스, 아스팔트 및 콘크리트 도로 등이 존재하고 있어 이에 식생, 나지, 콘크리트 도로, 아스팔트 도로 및 비닐에 대한 분류를 수행하였다. Table 2는 연구 대상 지역들의 특성치를 나타내고 있다.

딥러닝에 적용하기 위하여 Fig. 2(d)와 Fig. 2(e)처럼 Site2 및 Site3의 지역에서 취득된 이미지(307장)에서 중복되는 사진을 제외한 300장의 라벨링 작업을 수행하고 네트워크로 입력하기 위하여 256x256사이즈 패치를 생성하여 훈련데이터(training data) 및 평가데이터(validation data)를 생성하였다. 생성된 데이터는 딥러닝 훈련 및 평가를 위하여 80%는 훈련 데이터로 20%는 평가자료로 사용하였다.

RF와 딥러닝 알고리즘을 비교 평가하기 위하여 Site1의 정사영상을 Test 데이터로 선정하여 GT (Ground Truth) 및 GT를 이용한 ROI (Region Of Interest)를 취득하였다(Fig. 2(f)).

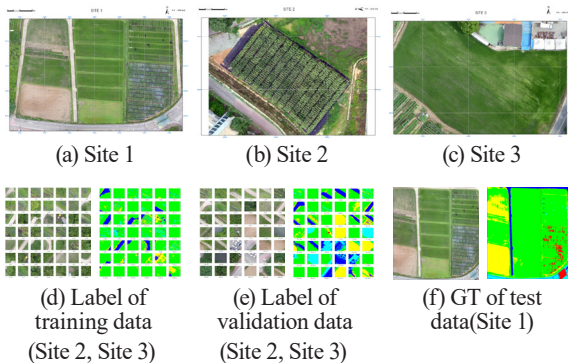


Fig. 2. Image of sites and data

Table 2. Specifications of acquisition data

	Site 1	Site 2	Site 3
Date	2019.07.12.	2019.07.17.	2019.07.19
Area	13,435m ²	1,103m ²	4,950m ²
Image size	4608x3456	4608x3456	4608x3456
Number of image	221	63	244
Altitude	70m	70m	70m
Location	36°37'25.4"N 127°27'16.5"E (Field cultivation practice)	36°37'16.9"N 127°27'14.9"E	36°37'36.7"N 127°27'10.4"E

3. 실험방법

본 대상지역의 피복분류 흐름은 Fig.3과 같이 딥러닝 알고리즘의 학습데이터 추출을 위하여 Site 2와 Site 3 취득된 영상(150장)에 대한 라벨링 작업을 수행하였다. 라벨링된 이미지를 이용하여 80%는 학습데이터 셋으로 20%는 평가 데이터 셋으로 적용하였다. 각 알고리즘 별 전체정확도, IoU (Intersection over Union), loss를 평가하였다. 이후 실제 적용성 분석을 위하여 각각의 알고리즘에 대한 epoch별 모델변수를 저장하고(텐서플로우 ckpt파일) 이를 Site 3의 test 영상에 적용하여 RF 방법과 비교-평가하였다.

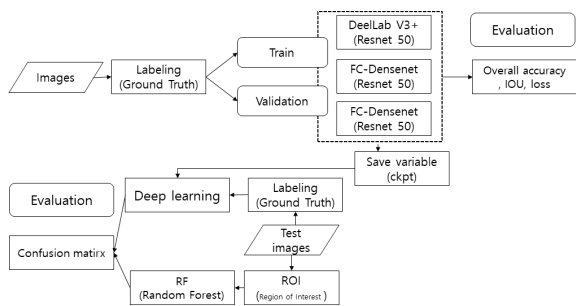


Fig. 3. Flow chart of classification process

3.1 RF 분류자

RF 기법은 대표적인 기계학습 알고리즘으로 결정나무(decision tree) 기법을 이용하여 훈련자료에 대하여 높은 분류정확도의 결과를 확보할 수 있는 기법이다. 규칙 기반 분류

(rule-based classification)의 형태를 나타내는 결정나무 기법은 노드(훈련자료를 정확하게 구분할 수 있는 규칙)로 설정하여 분류결과를 생성하는 방법이다. 첫 번째로, 독립적인 결정나무를 생성하기 위해 필요한 N개의 세부 훈련자료를 생성한다. 이후, 독립적인 결정나무들의 노드를 생성하기 위하여 영상(M 개의 밴드)에서 무작위 X 개의 밴드를 추출한다. 추출된 무작위의 밴드(X 개)와 훈련자료를 이용하여 독립적인 결정나무(N 개)를 생성하고, 최종적으로 결정나무(N 개)에서 가장 높은 확률의 클래스로 자료의 분류를 수행한다.

RF 기법은 결정나무 생성과정에서의 다양한 데이터를 활용하여 강건한 특성을 보인다. 본 연구에서는 영상분류를 위하여 개발된 EnMAP (Environmental Mapping and Analysis Program)-Box의 RF 분류자를 이용하여 실험을 수행하였다 (Jhonneric *et al.*, 2016). 훈련자료가 충분히 존재하고 있기 때문에, 총 100개의 결정나무를 생성하고, 이를 이용하여 RF 분류자를 구성하였다.

3.2 의미론적 영상 분류

영상분류란 각 물체를 경계선 단위로 나누어 물체의 위치, 종류 또는 연관성 등을 아는 것이 목적이다. 여기서 영상분류의 종류는 직접영상분류(instance classification)와 의미론적 영상분류(semantic classification)로 나뉜다. 직접영상분류의 경우 각 물체마다 픽셀의 라벨을 부여하는 것을 말하며, 의미론적 영상분류의 경우는 각 물체의 클래스마다 픽셀에 라벨을 부여하는 것으로 Fig. 4와 같은 차이가 있다.




Fig. 4. Difference between semantic image classification and instance image classification




Fig. 5. Unpooling process after maxpooling (Long *et al.*, 2015)

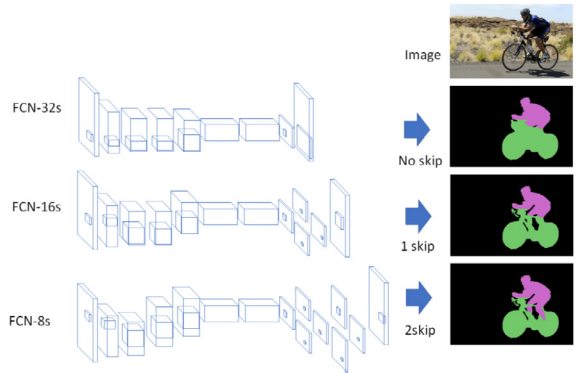


Fig. 6. Skip-connection structure and result of FCN (Long *et al.*, 2015)

의미론적 영상분류의 가장 기초적이면서 대표적인 방법은 FCN(Fully Convolution Network)이 있다. FCN(Long *et al.*, 2015)은 의미론적 영상분류에서 간단하지만 뛰어난 성능을 보여 주었으며, 특히 CNN을 이용한 방법은 의미론적 영상분류 연구의 시발점이 되었다.

버클리대학교에서는 기존의 FCN을 사용하면 1차원 벡터로 입력을 변경해줘야 한다는 점과 물체의 위치가 변경시 소멸 되는 단점이 있으며, 이와 같은 기존의 fully connected layer를 단점을 보완하기 위하여 fully convolution Layer(1×1 convolution으로 구성)로 변경하여 다양한 사이즈의 입력을 받을 수 있고, 대상물의 위치를 보존하여 Fig. 5와 같이 unpooling을 이용하여 분할을 수행한다. 픽셀단위로 클래스를 예측되어야 하는 의미론적 영상분류는 convolution 연산과 max pooling 연산을 통하여 사이즈가 작아지므로 특징도 같이 작아지며, 작아진 특징들을 원 사이즈로 다시 복원하는 과정이 필요하다. 이러한 복원을 위해 FCN에서는 Fig. 6과 같이 skip-connection 기법과 unpooling을 반복적으로 사용한다. Skip-connection을 많이 사용할수록 세부항목에 대하여 보다 자세히 분류할 수 있다.

3.3 DeepLab V3+

DeepLab-V3+은 DeepLab-V3의 개선된 버전이며, 이 세분화 모델은 FCN 프레임 워크를 따르지 않는 분류모델이다 (Chen *et al.*, 2018).

DeepLab 모델과 FCN을 구분하는 가장 큰 특징은 컨볼루션과 완전 연결된 계층에서 정밀한 위치 파악 정확도를 위한 확률적 기계 학습 모델인 조건부 랜덤 필드(CRF:Conditional Random Field)의 적용여부이다.

초기 DeepLab은 Deep Convolutional Nets와 Fully Connected CRFs를 사용하여 분할을 하는 방법을 제안한 모델이다. 그러나 Feature Resolution이 줄어드는 현상과 이미지의 분할을 정확히 얻지 못하는 문제점을 가지고 있었으며, 이를 해결한 DeepLab V2가 발표되었다. 이후 기존 ResNet 구조에 Atrous Convolution을 활용해 좀 더 조밀한 특징 맵을 얻는 방법을 제안한 Deep Lab V3가 발표되었다. 나아가 Fig. 7과 같이 Atrous Separable Convolution을 활용한 Deep Lab V3+ 순서로 발전하면서 DeepLab 모델은 의미론적 영상 분류 분야에 가장 수준 높은 성능을 보여주는 모델로 발전하였다.




Fig. 7. Architecture of Deeplab v3+ (Chen et al., 2018)

3.4 FC-DenseNet (Fully Convolutional DenseNets)

FC-DenseNet 알고리즘은 FCN 접근법을 기초로 하는 DenseNet CNN을 인코더로 사용한다(Huang et al., 2018). DenseNet 아키텍처의 특성으로 각 레이어가 피드-포워드 방식으로 다른 모든 레이어에 연결된 블록이 존재한다. Fig. 8은 블록 단위로 표시되는 FC-DenseNet의 아키텍처를 나타내고 있다.

의미론적 영상분류 분야에서는 성능의 지표로 IoU를 사용하게 되는데, 다운샘플링 단계에서 특징 정보가 사라지게 되면 업샘플링 단계에서 스킵 계층, 특징 지도 연쇄 메소드 등을 통하여 오브젝트의 디테일을 보강해도 IoU를 충분히 확보하지 못한다는 문제가 있다. 이러한 문제의 해결을 위하여 Fig. 8과 같이 다운샘플링 및 업샘플링 과정에 밀집 연결성(dense connectivity)이라는 전체 아키텍처의 계층 간 완전한 연결 개념을 추가함으로써 오브젝트의 디테일을 보강하였다. 이러한 DenseNet은 이전 계층에서 얻어낸 정보를 네트워크가 깊어짐에 따라 계속해서 쌓아나가는 밀집 블록(dense block)을 아키텍처에 포함함으로써 이전에 지니고 있었던 특징이 사라지거나 희미해지는 문제점을 해결할 수 있었다(Jégou et al., 2017).




Fig. 8. Architecture of FC-DenseNet (Huang et al., 2017)

3.5 FRRN-B(Full-Resolution Residual Networks)

기존의 의미론적 분류 모델은 FCN을 기반으로 ResNet 또는 VGG16과 같은 기존 분류 네트워크를 인코더로 사용한다. 그러나 이러한 FCN 기반의 분류 방법은 인코더 부분의 결과 네트워크 출력 (특히 풀링 작업 후)의 해상도가 낮아지면서 전체 모델의 지역화 성능이 저하된다. Pohlen et al. (2017)은 입력 이미지를 처리하는 두 개의 병렬 네트워크 스트림(풀링 및 잔여 스트림)을 갖춤으로써 이를 해결하도록 제안하였다(Fig. 9).

풀링 스트림은 연속적인 풀링을 수행하여 보다 나은 결과를 얻는 역할을 하고, 잔여 스트림은 전체 이미지 해상도에서 잔차를 계산하여 객체 픽셀 위치가 네트워크 출력으로 전파될 수 있도록 한다. 각각의 블록은 전체 해상도 잔차 단위에서 동작하며, 동시에 풀링 및 잔여 스트림에서도 적용되고, 이들 연구에서 FRRN-A와 FRRN-B의 아키텍처를 제안하였으나, FRRN-B가 의미론적으로 구성된 도시 이미지 분류 평가에 활용되는 Cityscapes 벤치 마크 데이터 세트에서 FRRN-A 비하여 우수한 성능을 나타냈다. 따라서 본 연구에서는 FRRN-B 아키텍처를 적용하여 분류를 수행하였다.




Fig. 9. The architecture of FRRN-B (Pohlen et al., 2017)

4. 실험결과

본 연구에서의 실험 대상지역은 수목, 밭, 논, 콘크리트, 아스팔트 등이 혼재되어 있어 RGB 영상에서 분류가 가능한 5개의 클래스(식생, 나지, 콘크리트, 비닐, 아스팔트)로 훈련데이터를 생성하였다.

4.1 실험환경 및 학습방법

실제 학습과 테스트가 진행된 컴퓨터의 사양과 소프트웨어

환경은 Table 2와 같다. 딥러닝에서 학습속도를 높이기 위하여 CUDA 9.0과 cuDNN 7.5.0을 이용하여 GPU 연산을 수행하였다.

Table 2. Experimental conditions

CPU	Intel(R) Core(TM) i7-9700 CPU @ 3.6.0 GHz
RAM	128GB
GPU	NVIDIA GeForce RTX 2080 super
SW	CUDA 9.0 & cuDNN 7.5.0
	Python 3.5
	TensorFlow 1.12.0

본 학습에 사용된 Backbone은 DeepLab V3+, FC-DenseNet 및 FRRN-B에 동일하게 ResNet50을 사용하였으며, 학습 횟수는 500회 진행하였다. 패치 크기는 네트워크에 적용하기 위하여 256x256으로 적용하였으며, Batch size는 실험 환경의 자원을 고려하여 1로 적용하였다.

4.2 실험 검증 및 결과 평가

딥러닝을 이용한 학습의 정확도 평가는 일반적으로 평가자료를 이용한 오차 행렬(confusion matrix), IoU 및 loss 평가를 통하여 이루어진다. 오차 행렬은 참이라고 간주되는 관측값과 평가를 위해 추출된 샘플간의 비교를 위한 행렬이며, 이를 통하여 정밀도와 재현율(recall) 등을 추출할 수 있으며, 1에 가까울수록 정확도가 높다. IoU는 분류 정확도를 평가하기 위하여 딥러닝 학습에 많이 사용되고 있는 지표이고, Fig. 10에서 보는 것과 같이 예측된 분류 면적과 실제 분류 면적이 겹치는 비율이며, 0에서 1사이의 값으로 1에 가까울수록 정확도가 높다고 판단한다. 손실함수는 정답에 대한 오류를 숫자로 나타내는 것으로 오답에 가까울수록 큰 값이 정답에 가까울수록 작은 값이 나오게 된다. 가장 많이 활용되는 교차 엔트로피 오차(cross entropy error)의 경우 Eq. (1)으로 계산된다.

$$-\sum_{i=1}^n \ln(Y_i) t_i \tag{1}$$

Y_i : output of result, t_i : comparison table




Fig. 10. Intersection over Union

4.3 딥러닝 분류 결과

대상 실험지역의 분류결과는 Figs. 11 ~ 13과 같고, 500 epoch의 평가 정확도는 FC-Densenet이 90%로 가장 높으며, FRRN-B의 정확도는 85%로 가장 낮은 정확도를 보였다(Fig. 11). 평균 IOU에서도 DeeplabV3+와 FC-Densenet은 비슷한 결과를 보이고 있으나, FRRN-B의 경우 다른 모델과 다르게 낮은 IOU를 보이고 있다(Fig. 12). 평균 loss의 경우 DeeplabV3+가 가장 빠르게 0.1이하로 수렴하고 있으며, FC-Densenet과 FRRN-B의 순으로 수렴하고 있다(Fig. 13).

평균 loss를 기준으로 epoch별 분류 결과를 정성적으로 비교하였다(Figs. 14~16). Fig. 14는 기존 훈련 파라미터를 test 이미지에 적용한 DeeplabV3+의 epoch에 따른 분류 결과를 나타내고 있으며, epoch가 증가할수록 피복분류의 결과가 향상되는 것을 보여주고 있다. Fig. 15는 FC-Densenet의 epoch 증가에 따른 피복분류이고, DeeplabV3+의 결과와 같이 epoch 증가에 따라 분류 결과가 향상되며, DeeplabV3+에 비교하여 세부 분류가 좀더 자세하게 나타나는 것을 알 수 있다. Fig. 16은 FRRN-B의 분류 결과이며 앞선 결과와 같이 epoch 증가에 따라 정확도가 증가하고 있으나 세부 분류의 결과가 가장 낮은 것을 볼 수 있다.




Fig. 11. Results of average validation accuracy by model according to epoch




Fig. 12. Results of average IOU by model according to epoch




Fig. 13. Results of average loss by model according to epoch

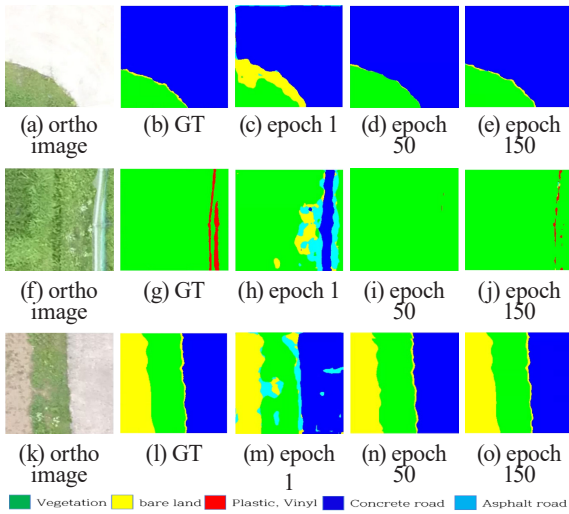


Fig. 14. Results of DeeplabV3+ by classification according to epoch of test images

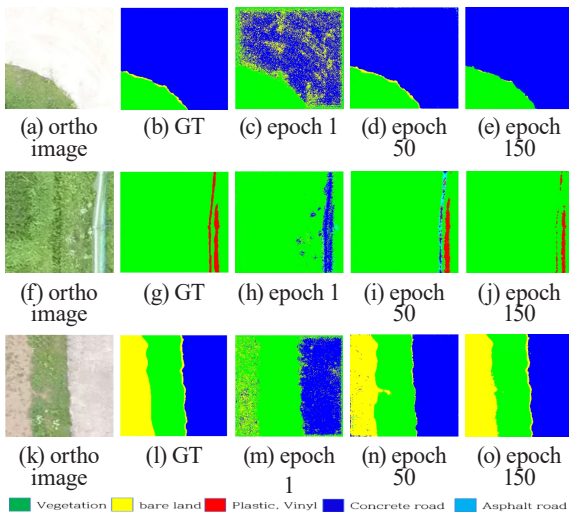


Fig. 15. Results of FC-Densenet by classification according to epoch of test images

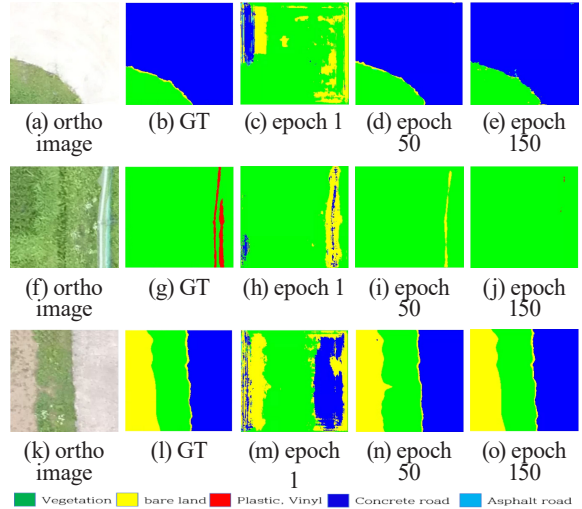


Fig. 16. results of FRRN-B by classification according to epoch of test images

4.2 기존감독분류와 비교평가

딥러닝 모델과 기존 감독분류의 정량적인 비교를 위해 5개 피복에 대해 오차행렬(Confusion matrix)을 비교하였다. 오차행렬은 참조자료와 분류결과의 정확도를 산정하는 방법으로 분류결과의 클래스별로 정확도 산출이 가능하며, 전체 정확도를 산출하여 영상별 비교가 가능하다. 본 연구에서 산출된 분류결과의 전체분류정확도와 클래스별 정확도를 산출한 결과는 다음 Table 3~6과 같고, Deeplabv3+과 FC-Densenet의 전체정확도(OA:Overall Accuracy)의 경우 가장 높은 정확도를 보였으며($OA_{Deeplab} = 97\%$, $K_{Deeplab} = 0.92$, $OA_{FC} = 96\%$, $K_{FC} = 0.92$) 감독분류인 RF의 경우 전체정확도는 89%, Kappa는 0.78로 나타났다. FRRN-B는 비교모델에 비하여 가장 낮은 정확도를 보였다($OA_{FRRN} = 88\%$, $K_{FRRN} = 0.67$). FC-Densenet에서는 나지가 콘크리트로 FRRN-B에서는 나지가 식생으로 오분류된 것을 볼 수 있는데, Fig. 16에서 보는 것과 같이 다른 알고리즘에 비하여 FRRN-B의 초기 학습에의 오류가 크고 추후 학습에서 이와 같은 오류가 보정되지 않는 현상으로 판단된다. 이와 같은 오류는 추가 특성 밴드와 데이터 증식을 추가하여 초기 학습을 진행하면 해결될 것으로 판단된다. 또한, 사용된 backbone 데이터의 네트워크 깊이 또한 이와 같은 학습에 영향을 주었을 것으로 판단되며, 현재 사용된 Resnet 50 보다 깊은 Resnet 102로 깊이를 증대한다면 초기 학습에 대한 오류 또한 줄일 수 있을 것이다.

Table 3. Confusion matrix of classification results (Deeplabv3+)

Deeplabv3+	Reference data				
	Concrete road	Asphalt road	Plastic	Bare land	Vegetation
Concrete road	1,773,126	7,804	2,433	39,812	13,162
Asphalt road	9,013	1,132,132	2,447	18,409	37,410
Plastic	2,747	4,617	1,180,264	8,739	90,032
Bare land	69,796	3,616	18,523	6,737,362	655,095
Vegetation	8,879	42,772	57,375	256,900	33,047,375
Overall accuracy(%)		97.01	Kappa		0.92

Table 4. Confusion matrix of classification results (FC-Densenet)

FC-Densenet	Reference data				
	Concrete road	Asphalt road	Plastic	Bare land	Vegetation
Concrete road	1,775,297	9,896	2,172	31,389	17,583
Asphalt road	9,156	1,117,209	7,417	19,432	46,197
Plastic	2,795	4,627	1,170,610	7,697	100,670
Bare land	111,178	7,987	24,199	6,617,134	723,894
Vegetation	8,960	33,028	96,223	231,127	33,043,963
Overall accuracy(%)		96.69	Kappa		0.92

Table 5. Confusion matrix of classification results (FRRN-B)

FRRN-B	Reference data				
	Concrete road	Asphalt road	Plastic	Bare land	Vegetation
Concrete road	1,718,583	16,402	3,065	72,727	25,560
Asphalt road	26,968	1,086,966	7,257	9,640	68,580
Plastic	2,868	3,862	1,125,229	7,002	147,438
Bare land	39,113	4,607	17,372	2,866,712	4,556,588
Vegetation	4,396	15,568	40,962	280,684	33,071,691
Overall accuracy(%)		88.16	Kappa		0.67

Table 6. Confusion matrix of classification results (RF)

RF	Reference data				
	Concrete road	Asphalt road	Plastic	Bare land	Vegetation
Concrete road	1,771,145	3,069	7,821	44,353	9,949
Asphalt road	279,142	788,942	35,614	92,940	2,773
Plastic	169,326	64,750	967,306	81,960	3,057
Bare land	153,013	2,934	20,539	7,166,168	141,738
Vegetation	1,335,790	28,070	364,587	1,725,514	29,959,340
Overall accuracy(%)		89.90	Kappa		0.78

Fig. 17은 RF분류와 딥러닝 모델별 분류를 수행한 결과이고, 오차행렬의 결과와 마찬가지로, FC-Densenet과 Deeplabv3+의 분류 결과가 GT와 가장 유사한 형태로 나타났으며, FRRN-B의 경우 나지를 식생으로 오분류하는 경향이 크게 나타나고 있다. 감독분류인 RF의 경우 GT와 유사한 경향을 보이고 있으나 국지적인 부분에 대하여 오분류되는 것을 알 수 있다.

콘크리트 도로는 모든 분류방법이 모두 효과적으로 분류하였으며, 나지의 경우 FC-Densenet과 RF의 분류자가 GT와 가장 유사한 형태로 추출하였다.

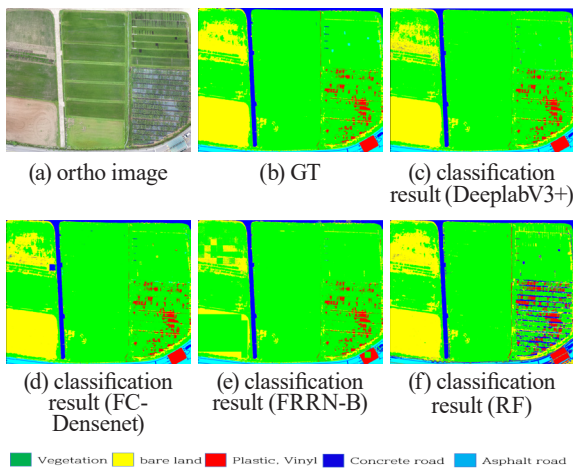


Fig. 17. Images of results by classification

5. 결론

딥러닝을 이용한 피복분류는 충분히 확보된 데이터셋과 선형 파라미터를 활용하여 높은 정확도를 빠른 시간에 확보할 수 있는 장점이 있으나, 기존의 연구는 위성영상을 대상으로 하여 이를 UAV에서 취득된 영상을 활용한 피복분류에 바로 적용하기에는 어려움이 있었다.

본 연구는 UAV에서 취득된 영상을 활용하여 대표적인 의미론적 분류 알고리즘에 적용하고 각 모델별 취득된 선형 파라미터를 적용하여 기존의 감독분류인 RF와 비교한 결과 다음과 같은 결론을 얻었다.

첫째, 분류정확도를 분석한 결과 Deeplabv3+에서 가장 높은 전체 정확도 97%, kappa 0.92가 나타났으며, FC-Densenet은 정확도 96%, kappa 0.92로 비슷한 정확도를 보여주고 있다. 기존의 방법인 RF방법은 전체정확도 89%, kappa 0.78로 나타났으며, FRRN-B의 경우 가장 낮은 전체 정확도 88%,

kappa는 0.67로 나타났다.

둘째, 딥러닝 모델별 평균 loss를 분석한 결과 150 epoch 이상에서는 평균 정확도와 IOU가 크게 증가하지 않는 것을 알 수 있으며, Deeplabv3+이 가장 빠르게 평균 loss가 감소하는 것을 알 수 있었다.

마지막으로, 정성적 분석의 결과 FC-Densenet과 Deeplabv3+이 GT와 가장 유사한 분류 결과를 보여주고 있다.

소규모 지역에서 딥러닝 모델을 적용하여 피복분류를 수행한 결과 기존의 감독분류 방법인 RF에 비하여 높은 정확도를 보여주고 있어 그 적용성이 확인할 수 있었다. FC-Densenet 및 Deeplabv3+에 UAV 데이터 셋으로 사전 학습된 파라미터를 생성할 수 있었으며, 이를 활용한 test 영상 피복분류를 수행할 수 있었다. 차후, 피복분류의 활용도를 높이기 위하여 분류 클래스를 추가하여야 할 필요가 있다. 이를 위해 네트워크 깊이를 증가시켜야 하며, 이에 따른 과적합은 데이터 증식 기법 등을 통해 해결하고자 한다.

감사의 글

본 연구는 2019학년도 충북대학교 학술연구지원사업에 의하여 연구되었고, 한국연구재단 (교육부) 기초과학연구프로그램 지원사업에 의해 수행된 연구임(NRF-2018R1D1A1B07048841).

References

- Castro, J.D.B., Feitosa, R.Q., Rosa, L.C.L., Diaz, P.M.A., and Sanches, I.D.A. (2017), A comparative analysis of deep learning techniques for sub-tropical crop types recognition from multitemporal optical/SAR image sequences, *Proceedings of 2017 30th SIBGRAPI Conference on Graphics, Patterns and Images*, IEEE, 17-20 october, Niteroi, Brazil, pp. 382-389.
- Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H. (2018), Encoder-decoder with atrous separable convolution for semantic image segmentation, *In Proceedings of the European conference on computer vision (ECCV)*, pp. 82-92.
- Dang, L.M., Hassan, S.I., Suhyeon, I., kumar Sangaiah, A., Mehmood, I., Rho, S., Seo, S.H., and Moon, H. (2018), UAV based wilt detection system via convolutional neural networks. *Sustainable Computing*, pp.1-20.

- Fisher, P.F., Comber, A.J., and Wadsworth, R. (2005), *Land Use and Land Cover: Contradiction or Complement*, Representing GIS, Wiley, Chichester, pp. 85-98.
- Gao, Q., Lim, S., & Jia, X. (2018), Hyperspectral image classification using convolutional neural networks and multiple feature learning. *Remote Sensing*, Vol. 10, No. 2, pp.1-18.
- Hall, O., Dahlin, S., Marstorp, H., Archila Bustos, M.F., Öborn, I., and Jirstrom, M. (2018), Classification of maize in complex smallholder farming systems using UAV imagery, *Drones*, Vol. 2, No. 3, pp.1-8.
- Huang, G., Liu, S., Van der Maaten, L., and Weinberger, K. Q. (2018), Condensenet: An efficient densenet using learned group convolutions, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2752-2761.
- Ishida, T., Kurihara, J., Viray, F.A., Namuco, S.B., Paringit, E.C., Perez, G.J., and Marciano Jr, J.J. (2018), A novel approach for vegetation classification using UAV-based hyperspectral imaging, *Computers and Electronics in Agriculture*, Vol.1 44, pp. 80-85.
- Jégou, S., Drozdal, M., Vazquez, D., Romero, A., and Bengio, Y. (2017), The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation, *In Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, pp. 11-19.
- Jhonnerie, R., Siregar, V. P., and Nababan, B. (2017), Comparison of random forest algorithm which implemented on object and pixel based classification for mangrove land cover mapping, *ICST 2016*, Vol.1, pp. 292-302.
- Ji, S., Zhang, C., Xu, A., Shi, Y., and Duan, Y. (2018), 3D convolutional neural networks for crop classification with multi-temporal remote sensing images, *Remote Sensing*, Vol. 10, No. 1, pp. 1-17.
- Joe, W., Lim, Y., and Park, K.H. (2019), Deep learning based Land Cover Classification Using Convolutional Neural Network: a case study of Korea, *Journal of the Korean Geographical Society*, Vol. 54, No. 1, pp. 1-16. (in Korean with English abstract)
- Kamilaris, A. and Prenafeta-Boldú, F.X. (2018), Deep learning in agriculture: A survey, *Computers and Electronics in Agriculture*, Vol. 147, pp. 70-90.
- Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., and Fei-Fei, L. (2014), Large-scale video classification with convolutional neural networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1725-1732.
- Kussul, N., Lavreniuk, M., Skakun, S., and Shelestov, A. (2017), Deep learning classification of land cover and crop types using remote sensing data, *IEEE Geoscience and Remote Sensing Letters*, Vol. 14, No. 5, pp. 778-782.
- Kwak, G.H., Park, S., Yoo, H.Y., and Park, N.W. (2017), Updating land cover maps using object segmentation and past land cover information, *Korean Journal of Remote Sensing*, Vol. 33, No. 6_2, pp. 1089-1100. (in Korean with English abstract)
- LeCun, Y., Bengio, Y., and Hinton, G. (2015), Deep learning, *Nature*, Vol. 521, pp. 436-444.
- Long, J., Shelhamer, E., and Darrell, T. (2015), Fully convolutional networks for semantic segmentation, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440.
- Murugan, D., Garg, A., and Singh, D. (2017), Development of an adaptive approach for precision agriculture monitoring with drone and satellite data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 10, No. 12, pp. 5322-5328.
- Onojeghwo, A.O., Blackburn, G.A., Wang, Q., Atkinson, P.M., Kindred, D., and Miao, Y. (2018), Mapping paddy rice fields by applying machine learning algorithms to multi-temporal Sentinel-1A and Landsat data, *International Journal of Remote Sensing*, Vol. 39, No. 4, pp. 1042-1067.
- Park, J.K. and Park, J.H. (2015), Crops classification using imagery of unmanned aerial vehicle (UAV), *Journal of the Korean Society of Agricultural Engineers*, Vol. 57, No. 6, pp. 91-97. (in Korean with English abstract)
- Pohlen, T., Hermans, A., Mathias, M., and Leibe, B. (2017), Full-resolution residual networks for semantic segmentation in street scenes, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4151-4160.
- Scott, G. J., England, M. R., Starms, W. A., Marcum, R. A., and Davis, C. H. (2017), Training deep convolutional neural networks for land-cover classification of high-

- resolution imagery, *IEEE Geoscience and Remote Sensing Letters*, Vol. 14, No. 4, pp. 549-553.
- Skakun, S., Franch, B., Vermote, E., Roger, J.C., Becker-Reshef, I., Justice, C., and Kussul, N. (2017), Early season large-area winter crop mapping using MODIS NDVI data, growing degree days information and a Gaussian mixture model, *Remote Sensing of Environment*, Vol. 195, pp. 244-258.
- Song, A. and Kim, Y. (2017), Deep learning-based hyperspectral image classification with application to environmental geographic information systems, *Korean Journal of Remote Sensing*, Vol. 33, No. 6, pp. 1061-1073. (in Korean with English abstract)
- Sung, S.M. and Lee, J.O. (2016), Accuracy of parcel boundary demarcation in agricultural area using UAV-photogrammetry, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 34, No. 1, pp. 53-62. (in Korean with English abstract)
- Torbick, N., Huang, X., Ziniti, B., Johnson, D., Masek, J., and Reba, M. (2018), Fusion of moderate resolution earth observations for operational crop type mapping, *Remote Sensing*, Vol. 10, No. 7, pp. 1-16.
- Xu, X., Ji, X., Jiang, J., Yao, X., Tian, Y., Zhu, Y., Cao, W., Cao, Q., Yang, H., Shi, Z., and Cheng, T. (2018), Evaluation of one-class support vector classification for mapping the paddy rice planting area in Jiangsu Province of China from Landsat 8 OLI imagery, *Remote Sensing*, Vol. 10, No. 4, pp. 1-23.
- Zhong, Y., Fei, F., Liu, Y., Zhao, B. and Jiao, Jial. H. (2017), SatCNN: satellite image dataset classification using agile convolutional neural networks, *Remote Sensing Letters*, Vol. 8, No. 2, pp. 136-145.
- Zhong, L., Gong, P., and Biging, G.S. (2014), Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery, *Remote Sensing of Environment*, Vol. 140, pp. 1-13.