

GLCM 기반 UAV 영상의 감독분류를 이용한 저수구역 내 농경지 탐지

Detection of Cropland in Reservoir Area by Using Supervised Classification of UAV Imagery Based on GLCM

김규문¹⁾ · 최재완²⁾

Kim, Gyu Mun · Choi, Jae Wan

Abstract

The reservoir area is defined as the area surrounded by the planned flood level of the dam or the land under the planned flood level of the dam. In this study, supervised classification based on RF (Random Forest), which is a representative machine learning technique, was performed to detect cropland in the reservoir area. In order to classify the cropland in the reservoir area efficiently, the GLCM (Gray Level Co-occurrence Matrix), which is a representative technique to quantify texture information, NDWI (Normalized Difference Water Index) and NDVI (Normalized Difference Vegetation Index) were utilized as additional features during classification process. In particular, we analyzed the effect of texture information according to window size for generating GLCM, and suggested a methodology for detecting croplands in the reservoir area. In the experimental result, the classification result showed that cropland in the reservoir area could be detected by the multispectral, NDVI, NDWI and GLCM images of UAV, efficiently. Especially, the window size of GLCM was an important parameter to increase the classification accuracy.

Keywords : Cropland, Gray Level Co-occurrence Matrix, Random Forest, Reservoir Area

초 록

저수구역은 계획된 홍수위에 의하여 둘러싸인 지역 혹은 댐의 계획된 홍수위 내에 있는 지역으로 정의된다. 본 연구에서는 저수구역 내 농경지를 탐지하기 위하여, 대표적인 기계학습 기법인 RF (Random Forest) 기반의 감독 분류 방법을 적용하였다. 저수구역 내의 농경지를 효과적으로 분류하기 위하여, 질감정보를 정량화하기 위한 대표적인 기법인 GLCM (Gray Level Co-occurrence Matrix)과 NDWI (Normalized Difference Water Index), NDVI (Normalized Difference Vegetation Index)를 추가적인 입력자료로 활용하였다. 특히, 질감정보를 생성하는데 사용된 윈도우 크기가 농경지의 분류 정확도에 미치는 영향을 분석하여, 저수구역 내의 농경지를 효과적으로 분류하기 위한 방법론을 제시하였다. 실험결과, UAV 영상을 이용한 분류결과를 통하여 취득된 다중분광영상과 NDVI, NDWI, GLCM 영상들을 이용하여 저수구역 내의 농경지를 효과적으로 탐지할 수 있음을 확인하였다. 또한, GLCM의 윈도우 크기가 분류정확도를 향상시키기 위한 중요한 변수임을 확인하였다.

핵심어 : 농경지, 명암도 동시발생 행렬, 랜덤 포레스트, 저수구역

Received 2018. 08. 02, Revised 2018. 08. 17, Accepted 2018. 12. 05

1) Korea Water Resources Corporation (gyumk@kwater.or.kr)

2) Corresponding Author, Member, School of Civil Engineering, Chungbuk National University (E-mail: jaewanchoi@chungbuk.ac.kr)

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. 서론

저수구역은 계획된 홍수위에 의하여 둘러싸인 지역이나 댐의 계획홍수의 내에 존재하는 지역으로 정의된다. 법적으로는 하천법에 따른 하천구역으로 지정·고시된 지역을 의미하며, 다목적댐의 계획홍수위 아래에 있는 토지를 말한다. 일반적으로 댐을 관리함에 있어서 저수구역 내 불법행위 및 수질 오염을 유발하는 행위에 대하여 필요한 조치를 취하도록 하고 있다. 그러나 국내 여건상 대부분의 저수구역들은 일정 수위 이상이 외부에 상시 노출되어 일반인들에게는 유해지로 인식될 수 있다. 이로 인하여, 저수구역의 무단점유에 의한 영농행위가 빈번하게 발생하고 있다. 따라서 저수구역 내의 농경지를 파악하는 것은 댐 관리에 있어서 중요한 사항이다. 그러나 댐 저수구역의 관리면적이 광범위하여 많은 인력과 예산이 필요하며, 일반 항공영상촬영으로 모니터링을 하는 경우에도 촬영주기의 한계 등으로 인한 문제들이 발생하고 있는 실정이다. UAV (Unmanned Aerial Vehicle)는 기존 항공영상촬영과 비교하여 고해상도의 영상을 저비용으로 빠르게 취득할 수 있는 장점을 가지고 있기 때문에 댐 저수구역 내 농경지의 유무를 파악함에 있어서 많은 장점을 가지고 있다. 따라서 본 연구에서는 UAV 영상을 활용하여 댐 저수구역 내 농경지역을 분석하기 위한 방법론을 제안하였다.


UAV 영상을 이용한 토지피복정보의 생성 혹은 유역모니터링과 관련한 국내의 연구들이 다양하게 이루어지고 있다. 국내의 경우, Sung and Lee (2016)은 UAV 영상의 처리를 통하여 생성한 정사영상을 지척현황측량 성과와 비교하여 농경지 필지경계점의 정확도를 분석하였다. Kim *et al.* (2017)은 UAV 영상을 이용하여 생성한 정사영상과 DSM (Digital Surface Model)을 이용하여 고해상도 토지피복지도를 생성하기 위한 방법을 제안하였으며, Choi *et al.* (2017)은 해안사구 지역에 대한 식생피복 비율을 UAV 영상으로 분석한 바 있다. 또한, 유역모니터링을 위하여 UAV를 통하여 취득된 다중분광영상의 분광특성 혹은 영상처리기법을 이용하여 하천 내 부유쓰레기를 탐지하기 위한 활용기법과 하천의 구간별 허용 저수량 산정을 위한 알고리즘도 연구되었다(Kim *et al.*, 2017; Kim *et al.*, 2018). 국외의 경우에는 지형 내 식생 및 토지피복 모니터링을 위한 연구들이 활발하게 진행되고 있다. Su and Gibeaut (2017)은 UAV을 이용하여 해안가 지역에 대한 분류영상을 생성하기 위한 방법론을 제안하였으며, Feng *et al.* (2015)는 UAV 영상에 질감정보를 기반으로 하는 RF (Random Forest) 분류 기법을 이용하여 RGB 영상 내에 식생을 효과적으로 추출하기 위한 연구를 진행하였다. 특

히, Feng *et al.* (2015)은 도심지역의 지형지물에 대하여 UAV를 이용하여 취득한 RGB 영상과 질감(texture) 정보를 추가하여 분류를 수행할 경우, 기존의 화소 기반의 분류 기법 및 객체 기반의 분류 기법보다 우수한 분류 결과를 얻을 수 있음을 확인한 바 있다. 국내의 연구동향에서 확인할 수 있는 것과 같이, 식생 및 도심지 지역에 대한 모니터링을 위한 연구는 많이 진행되었으나, 토지피복 내에 존재하는 농경지 분석에 중점을 둔 연구는 상대적으로 부족한 실정이다. 또한, UAV 활용에 관한 연구에 있어서 수자원 분야에 관한 연구는 허용 저수량 측량, 부유물질 분석 등에 국한되어 있는 상태이다. 이에 따라서 본 연구에서는 댐 저수구역 주변에 대하여 촬영한 UAV 영상을 이용하여 정사영상(orthoimage)을 생성하고, 대표적인 기계학습(machine learning) 기법인 RF 분류기법을 이용하여 저수구역 주변의 농경지를 추출하기 위한 방법론을 제안하였다. 특히, 본 연구에서는 저수구역 주변에 존재하는 농경지를 탐지하기 위하여, 2개의 클래스로 훈련자료를 구성할 경우에 있어서 UAV에서 취득된 정사영상으로 농경지를 효과적으로 분류할 수 있는지를 분석하였다. 이를 위하여, 다중분광영상에서 추출할 수 있는 대표적인 영상정보인 NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index), GLCM (Gray Level Co-occurrence Matrix)를 이용하여 농경지 유역에 대한 분류 정확도를 증대시켰다. 또한, GLCM을 생성함에 있어서 윈도우 크기가 농경지 분류에 미치는 영향을 분석하여, 수자원 분야에 대한 UAV 영상의 활용가능성을 분석하였다.

2. 실험지역 및 자료

2.1 실험자료의 재원

실험에 사용한 UAV는 senseFly사에서 제작한 eBee이다. 고정익 UAV인 eBee는 GNSS (Global Navigation Satellite System), IMU (Inertial Measurement Unit) 등을 탑재하여 사용자가 사전에 입력한 영역을 계획에 따라 자동비행할 수 있으며, 상대적으로 넓은 면적을 빠른 시간에 촬영할 수 있는 장점을 가지고 있다. 또한, 본 연구에서 분류 및 탐지하고자 하는 대상물질이 농경지이기 때문에, 유역주변의 효과적인 식생 분류를 위한 자료가 요구된다. 따라서 eBee에 탑재 가능한 다중분광카메라인 multiSPEC 4C를 이용하여 녹색(green), 적색(red), 적색 경계(red-edge), 근적외선(NIR: Near-InfraRed)의 총 4개 분광밴드의 정보를 획득하여 활용하였다. Fig. 1 및 Table 1은 실험에 사용한 UAV 및 카메라의 특성을 나타낸다.



(a) eBee UAV (b) multiSPEC 4C camera


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

Table 1. Specification of eBee and multiSPEC 4C

eBee		multiSPEC 4C	
size	960 mm ×800 mm ×140 mm	resolution	1.2 megapixel
weight	< 0.69 kg	weight	~ 160 g
maximum flight time	50 min	wavelength	green : 530 ~ 570 nm
mounting sensor	GNSS, IMU, camera		red : 640 ~ 680 nm
			red-edge : 730 ~ 740 nm
			NIR : 770 ~ 810 nm

2.2 실험지역의 선정 및 자료 취득

실험지역은 전남 보성군의 주암 다목적댐의 상류지역에 위치한 저수구역으로 선정하였다. 해당 지역의 경우에는 지반고가 계획홍수위 부근에 위치하기 때문에 연중 수몰되는 기간이 상대적으로 짧아서 대부분의 지면이 노출된 상태인 경우가 빈번하여 저수구역 내에 각종 농작물의 무단정착이 빈번하게 일어나는 지역이다.



(a) flight path (b) orthoimage of study area

Fig. 2. Experimental area

한편, 농경지를 구성하고 있는 논과 밭 중에서 밭의 경우에는 초지와 유사한 특성이 있으므로 4밴드의 고해상도 영상을 이용하여 밭과 초지를 분류하는 데에 한계점이 발생할 수 있다. 따라서 본 논문에서 탐지하고자 하는 저수구역 내 농경지는 논으로 가정하였다. Fig. 1의 eBee를 이용하여 2017년 9월 18일 오전 11시~12시에 해당지역을 촬영하여 약 292매의 영상을 취득하였으며, Pix4D 소프트웨어를 이용하여 정사영상을 생성하였다. Fig. 2는 실험대상지역의 촬영을 위한 촬영계획에 의하여 촬영된 영상의 위치이며, 영상의 공간해상도는 12 cm이다.

3. 농경지 탐지를 위한 감독분류

3.1 RF 분류자

전통적인 원격탐사 자료의 감독분류 기법들은 분류하고자 하는 각 클래스에 대한 훈련자료(training data)에 대한 통계적인 특성을 추출하고, 이를 기반으로 각 화소들을 유사한 통계적인 특성을 가지는 클래스로 분류한다. 그러나 고해상도 원격탐사 자료들의 활용도가 높아짐에 따라서, 훈련자료들이 일정한 통계적인 특성을 가지지 않는 자료들을 분류해야 하는 경우가 발생한다. 이러한 문제점을 해결하고 분류정확도를 향상시키기 위하여 다양한 기계학습 기반의 분류기법들이 개발되고 있다. RF 기법은 결정나무(decision tree) 기법을 확장한 대표적인 기계학습 알고리즘으로써 양질의 훈련자료에 대하여 높은 분류정확도의 결과를 생성할 수 있는 기법이다. 일반적인 결정나무 기법은 규칙 기반 분류(rule-based classification)의 형태를 나타내며, 훈련자료를 효과적으로 구분할 수 있는 규칙을 노드(node)로 설정하여 이상적인 분류 결과를 생성하는 방법이다. RF 알고리즘의 전체적인 흐름도는 Fig. 3과 같다. 첫 번째로, RF 기법에서 사용할 N 개의 독립적인 결정나무를 생성하기 위하여 훈련자료로부터 N 개의 세부 훈련자료를 생성한다. 또한, RF 기법에서 생성할 독립적인 결정나무들의 노드를 결정하기 위하여 M 개의 밴드로 이루어진 영상에서 X 개의 밴드를 무작위 추출한다. 무작위 추출된 X 개의 밴드와 세부 훈련자료를 이용하여 총 N 개의 독립적인 결정나무를 생성한다. 최종적으로 N 개의 결정나무에서 분류된 결과 중 가장 높은 확률을 보이는 클래스로 해당 자료의 분류를 수행한다. RF 기법은 다수의 분류결과를 활용하기 때문에 결정나무 생성과정에서의 변수 설정에 강건한 특성을 보인다. 본 연구에서는 초분광 영상의 처리를 위하여 톨박스 형태로 개발된 EnMAP (Environmental Mapping and Analysis Program)-Box의 RF 분류자를 이용하여 실험을 수

행하였다(Van der Linden *et al.*, 2015). 충분한 개수의 훈련 자료가 존재한다고 가정하여, 총 100개의 결정나무를 생성하고, 이를 바탕으로 RF 분류자를 구성하였다. 영상 내 밴드의 무작위 추출을 위해서는 영상 개수의 제곱근을 활용하여 밴드를 선정하였다.

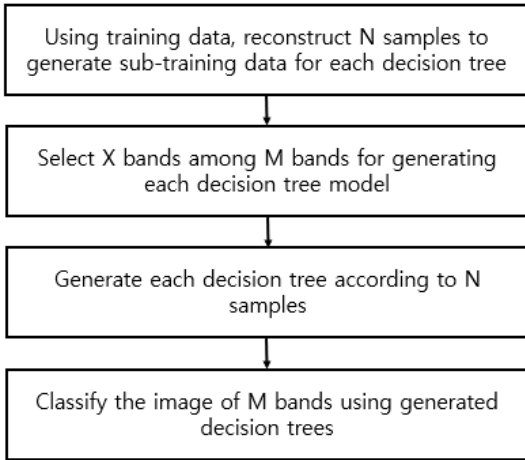


Fig. 3. Workflow of RF algorithm

3.2 분류를 위한 입력자료의 생성

UAV를 통하여 취득된 다중분광 영상은 높은 공간해상도에 비하여 상대적으로 적은 밴드수를 지닌다. 특히, 저수구역 내 농경지를 효과적으로 분류하기 위해서는 저수구역 내에 존재하는 식생 및 초지를 효과적으로 구분하는 방법이 필요하다. 이를 위하여, 본 연구에서는 총 3 종류의 입력영상을 생성하고, 이를 다중분광밴드에 추가하여 분류정확도를 증대시켰다. 첫 번째로 저수구역 내에 존재하는 식생지역의 효과적인 분류를 위하여 Eq. (1)을 이용하여 NDVI 영상을 생성하였다.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

where *NIR* represent the near-infrared band, and *RED* means the red band of UAV imagery.

NDVI 영상은 -1~1의 범위를 가지며, 1에 가까울수록 활력도가 높은 식생임을 의미한다(Rouse *et al.*, 1974). 두 번째로 저수구역 내에 존재하는 수계지역을 효과적으로 분류하기 위하여 NDWI를 생성하였다. 일반적으로 NDWI는 SWIR (Short Wave InfraRed) 밴드를 가지고 있는 다중분광영상에

서 추출할 수 있는 영상지수이며, 수계지역은 1에 가까운 화소값을 가지는 특징을 지닌다. 그러나 본 연구에서 사용한 다중분광카메라는 SWIR 분광과장대에 해당하는 영상을 취득할 수 없으므로, Eq. (2)를 이용하여 NDWI를 생성하였다 (Mcfeeters, 1996; Xu, 2006).

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (2)$$

where *GREEN* represent the green band of UAV imagery.

Fig. 4는 실험지역에 대하여 생성된 NDWI 영상의 예이며, 식생 및 나지지역들은 낮은 값을 가지지만, 수계영역은 높은 NDWI 값을 가지는 것을 확인할 수 있다. 따라서 NDWI 영상을 추가하여 식생 및 나지지역과 수계지역을 효과적으로 구분할 수 있음을 알 수 있다. 그러나 도로 부분과 일부 건물에 대해서도 높은 NDWI 값을 가지는 경향을 보이는데, 이는 SWIR 밴드를 사용하지 못하고, 다중분광영상의 녹색 밴드를 사용하였기 때문이다. 그러나 본 연구에서는 농경지를 분류하는 것이 목적이기 때문에, 해당지역에서 발생하는 NDWI 영상의 오차는 본 연구의 결과에 영향을 미치지 못할 것으로 판단하였다.





Fig. 4. Example of NDWI image by UAV

한편, NDVI와 NDWI 영상을 이용하여 저수구역 내에 존재하는 식생지역과 수계지역의 분류를 효과적으로 수행할 수 있지만, 식생지역 내에 존재하는 농경지를 분류하기 위해서는 논과 기타 식생지역을 구분할 수 있는 기준이 필요하다. Fig. 5는 영상 내에 존재하는 농경지와 초지지역의 예이다. Fig. 5에서 확인할 수 있는 것과 같이 농경지 지역은 상대적으로 균일한 화소값을 가지고 있는 것을 볼 수 있으며, 이러한 특성을 이

용하여 높은 NDVI 값을 가지는 식생지역 내에 존재하는 농경지를 효과적으로 구분할 수 있다.



(a) cropland (b) grass
Fig. 5. Example of cropland and grass area

따라서, 본 연구에서는 원격탐사 자료에서 추출할 수 있는 대표적인 질감정보인 GLCM을 이용하여 논을 추출할 수 있는 추가적인 정보를 생성하였다. GLCM은 기준 화소와 이웃하는 화소의 밝기 값의 관계에 대한 행렬을 산출하고 이를 통계량으로 변환하여 질감정보를 생성하는 방법이다(Wood *et al.*, 2012). 입력 영상의 양자화(quantization) 단계, 이웃하는 화소를 정의하기 위한 윈도우의 크기에 따라서 GLCM 내 공간관계 행렬의 결과가 변화한다.



(a) subset of study area (b) GLCM by variance

Fig. 6. GLCM result by study area

또한, 생성된 공간관계 행렬을 기준으로 하여 평균(mean), 분산(variance), 균질성(homogeneity), 대비(contrast), 각 이차 모멘트(angular second moment), 비유사도(dissimilarity), 엔트로피(entropy) 등의 다양한 통계치를 기반으로 하는

GLCM을 생성할 수 있다. 본 연구에서는 식생지역 내에 존재하는 균일한 질감정보를 가지는 농경지를 추출하는 것이 목적이기 때문에 식생지역을 잘 반영할 수 있는 NIR 밴드에 대한 질감정보를 생성하였으며, 균일지역에 대한 특성을 잘 반영할 수 있는 분산 기반의 GLCM을 RF 분류에 대한 추가적인 개체자료로 활용하였다. Fig. 6은 근적외선 밴드에 적용된 분산 기반의 GLCM의 결과이며, 균일한 패턴을 가지고 있는 농경지 지역과 비교하여 도로, 초지, 산림 지역은 상대적으로 높은 화소값을 가지고 있는 것을 볼 수 있다. 한편, GLCM은 공간관계 행렬을 계산할 때, 이웃화소간의 관계를 정의하는 윈도우 크기에 따라서 생성결과가 달라질 수 있다. 본 연구에서는 GLCM 영상을 농경지 탐지를 위한 입력 자료로 활용하는 경우, 윈도우의 크기가 농경지 탐지 정확도에 어떠한 영향을 미치는지를 분석하였다.

4. 실험결과

4.1 훈련자료 및 참조자료의 생성

본 연구에서의 실험 대상지역인 다목적댐 저수구역 내에는 일반 수목, 밭, 논 등이 혼재되어 있으며, 2.2절에서 언급한 바와 같이 농경지 중에서 밭보다는 일반 수목 및 초지와와의 분류가 용이한 논을 분류하였다. 이를 위하여 논과 그 외의 지역의 2가지 클래스로 나누어 분류를 수행하고자 하였으며, 총 9,728 화소를 훈련자료로 추출하였다. RF 기반 감독 분류의 평가를 위하여 생성한 참조자료는 1,151,301화소(농경지 : 25 지역, 비농경지 : 55지역)로 구성하였다. 향후 활용을 위하여 상대적으로 적은 훈련자료를 이용하여 농경지를 효과적으로 분류할 수 있는지를 확인하기 위하여 훈련자료 대비 많은 수의 참조자료를 구축하였다.



(a) cropland (b) non-cropland

Fig. 7. Example of ground truth data

또한, 훈련자료 중 비농경지의 경우에는 수계, 초지, 도로, 건물지붕 등 실험지역에 존재하는 대부분의 지형지물을 포함

하고 있도록 추출하였다. 한편, 본 연구에서 사용한 RF는 감독 분류 기법이지만, 본 연구에서는 농경지 탐지가 목적이기 때문에, 촬영 영상 내의 대부분의 농경지를 참조자료로 구성하였다. 실험 지역의 농경지는 현장방문을 통하여 확인하고, 이를 바탕으로 생성하였으며, 구축된 참조자료 영상의 예는 Fig. 7과 같다.

4.2 농경지 탐지 결과의 비교 평가

본 연구에서는 저수구역 내 농경지 탐지 정확도를 향상시키기 위하여 NDVI, NDWI, NIR 밴드의 분산 기반 GLCM 밴드를 추가 입력자료로 활용하여 RF 분류자를 적용하였다. 그러나 3장에서 언급한 바와 같이 질감정보를 생성하기 위한 GLCM의 특성은 윈도우 크기에 영향을 받기 때문에, 최소 윈도우 크기인 3을 기준으로 윈도우 크기가 증가함에 따라서 농경지 탐지 결과의 변화양상을 분석하였다. Table 2~9는 GLCM의 윈도우 크기에 따른 농경지 탐지 결과의 오차행렬을 의미하며, Fig. 8은 각 실험 결과별 탐지율(detection rate), 오탐지율(false alarm rate), 전체정확도(overall accuracy)를 정리한 것이다. Fig. 8에서 확인할 수 있는 것과 같이, GLCM을 생성하기 위하여 적용된 윈도우의 크기가 증가할수록, 오탐지율은 유사하나 탐지율 및 정확도가 향상되는 것을 확인할 수 있다. 그러나 윈도우의 크기가 63이 되는 경우에 오탐지율이 약 11.98%로 크게 증가되는 것을 볼 수 있다. 이는 농경지의 질감정보를 추출하는 과정에 있어서, 적절한 크기의 윈도우 크기를 지정하지 못할 경우에는 농경지를 효과적으로 분류할 수 없음을 의미한다.

Table 2. Confusion matrix of classification results using multispectral image

result \ reference	cropland	non-cropland
cropland	123,162	16,889
non-cropland	451,665	559,585

Table 3. Confusion matrix of classification results using multispectral, NDVI and NDWI images

result \ reference	cropland	non-cropland
cropland	135,845	17,307
non-cropland	438,982	559,167

Table 4. Confusion matrix of classification results using multispectral, NDVI, NDWI and GLCM images (window size of GLCM : 3)

result \ reference	cropland	non-cropland
cropland	271,974	25,737
non-cropland	302,853	550,737

Table 5. Confusion matrix of classification results using multispectral, NDVI, NDWI and GLCM images (window size of GLCM : 5)

result \ reference	cropland	non-cropland
cropland	313,521	27,538
non-cropland	261,306	548,936

Table 6. Confusion matrix of classification results using multispectral, NDVI, NDWI and GLCM images (window size of GLCM : 7)

result \ reference	cropland	non-cropland
cropland	549,803	28,673
non-cropland	25,024	547,801

Table 7. Confusion matrix of classification results using multispectral, NDVI, NDWI and GLCM images (window size of GLCM : 15)

result \ reference	cropland	non-cropland
cropland	559,447	29,430
non-cropland	15,380	547,044

Table 8. Confusion matrix of classification results using multispectral, NDVI, NDWI and GLCM images (window size of GLCM : 31)

result \ reference	cropland	non-cropland
cropland	568,949	25,185
non-cropland	5,878	551,289

Table 9. Confusion matrix of classification results using multispectral, NDVI, NDWI and GLCM images (window size of GLCM : 63)

result \ reference	cropland	non-cropland
cropland	568,695	69,085
non-cropland	6,132	507,359


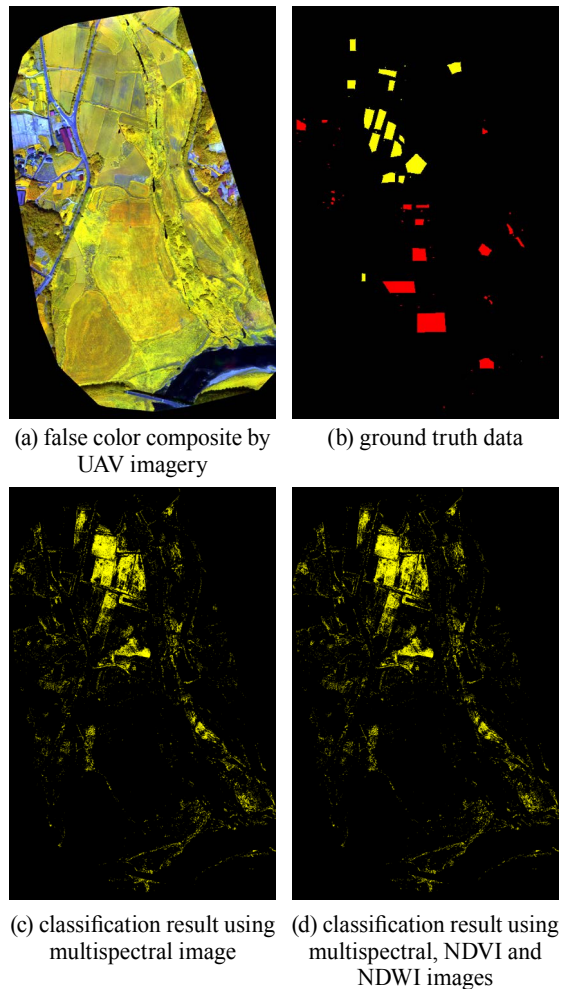



Fig. 8. Classification results according to window size of GLCM image


Fig. 9는 GLCM의 각 윈도우 크기에 대하여 RF 분류자 기반의 감독분류를 수행한 결과이다. Fig. 8의 결과와 마찬가지로, 윈도우 크기가 증가할수록, 탐지율이 증가되는 경향을 나타내었다. 또한, 비농경지를 오분류하여 발생하는 노이즈와 유사한 경향이 전체적으로 감소하고 있는 것을 확인할 수 있다. 그러나 윈도우의 크기가 과도하게 증가한 경우(윈도우 크기 : 63)에는 초지지역들이 농경지로 오탐지되는 경향이 발생했다. 농경지의 탐지 정확도는 유사하지만, 오탐지율이 증가하기 때문에 전체정확도도 감소되었다. Figs. 10 and 11은 Fig. 9의 결과를 세부적으로 분석하기 위하여 윈도우 크기 3, 31, 63에 대한 농경지 탐지 결과를 나타낸 그림이다. Fig. 10에서 확인할 수 있는 것과 같이 윈도우 크기가 작은 경우에는 비농경지를 오탐지하는 경우와 농경지를 탐지하지 못하는 경우가 동시에 발생하며, 이로 인하여 전체정확도가 상대적으로 낮게 나타났다. 윈도우 크기가 커지는 경우에는 대부분의 농경지를 효과적으로 탐지하였다. 따라서, 일정 크기 이상의 윈도우 크기를 가지는 GLCM 영상을 활용할 경우에는 초지 내의 논 지역을 효과적으로 분류할 수 있음을 확인하였다(Feng *et al.*, 2015). 그러나 Fig. 11에서 확인할 수 있는 것과 같이, 윈도우 크기가 과도하게 커질 경우에는 일부 초지를 농경지로 오탐지하는 경우가 크게 발생하였다. 이러한 현상은 논은 일반적으로 선형형태와 유사한 공간적인 특성을 지니는데, GLCM을 생성하기 위한 윈도우 크기가 작은 경우에는 선형의 공간적인

특성이 반영이 안되며, 윈도우 크기가 증가되는 경우에는 일부 선형형태를 나타내는 밭 지형과 갈대 등의 초지 지역들이 농경지로 추정된 것으로 분석되었다. 상대적으로 논과 매우 상이한 공간특성을 보이는 산림지역에서는 오탐지 지역이 발생하지 않는 점을 미루어 볼 때, 유사한 공간형태를 보이는 지역에 대해서만 윈도우 크기에 의한 영향이 발생한다고 판단된다. 따라서, UAV 영상을 이용하여 저수구역 내의 농경지를 탐지하기 위해서는 오탐지율을 최소화할 수 있는 최대 크기 이하의 윈도우 크기를 활용해야 함을 알 수 있다. 한편 윈도우 크기는 영상의 공간해상도와 연관되어 있다. 본 연구에서는 12 cm 공간해상도를 가지는 영상을 활용하였으나, 활용지역 및 촬영계획에 따라서 영상의 공간해상도는 달라질 수 있기 때문에, 영상의 공간해상도에 대한 오탐지율을 최소화할 수 있는 GLCM 영상의 공간해상도를 결정해야 할 것으로 판단된다.







(e) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 3)




(f) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 5)




(g) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 7)



(h) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 15)




(i) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 31)




(j) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 63)

Fig. 9. Detection results of cropland by classification according to window size of GLCM



(a) detailed false color composite by UAV imagery



(b) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 3)




(c) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 31)




(d) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 63)


Fig. 10. 1st Detailed images of detection results by classification according to window size of GLCM



(a) detailed false color composite by UAV imagery



(b) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 3)



(c) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 31)



(d) classification result using multispectral, NDVI, NDWI and GLCM images (window size : 63)

Fig. 11. 2nd Detailed images of detection results by classification according to window size of GLCM

4. 결론

본 연구에서는 저수구역 내에 존재하는 농경지를 탐지하기 위하여 UAV 영상을 활용한 방법론을 제안하였다. 이를 위하여, UAV 영상을 이용하여 취득한 다중분광밴드로 이루어진 정사영상을 이용하여 농경지와 비농경지에 대한 훈련자료를 취득하고, 이를 기반으로 감독분류를 수행하였다. 특히, 저수구역 내에 일반적으로 존재하는 초지, 농경지, 수계지역을 효과적으로 분류하기 위하여 NDVI, NDWI, GLCM의 분산을 추가 입력자료로 활용하여 농경지의 논외 분류 정확도를 향상시켰다. 또한, 감독분류의 경우에는 대표적인 기계학습으로 알려진 RF 분류자를 이용하여 훈련자료의 통계적인 특성이 정규분포를 나타내지 않는 고해상도 UAV 영상 내의 농경지를 탐지하였다. 댐 지역 주변의 UAV 영상을 이용한 실험결과, 다중분광 영상을 이용하여 RF 분류자를 이용한 감독분류 결과, 저수구역 주변의 논 지역을 효과적으로 탐지할 수 있음을 확인하였다. 특히, 논 지역의 탐지정확도는 감독분류에 사용된 GLCM 영상을 생성하는 데에 적용된 윈도우 크기에 영향을 받음을 확인하였다. 윈도우 크기가 작은 경우에는 농경지 탐지의 정확도가 낮은 경우가 발생하였으며, 윈도우 크기가 과도하게 큰 경우에는 농경지의 오탐지율이 증가하는 것을 확인하였다. 본 연구에서 제시한 방법론을 이용하여 UAV 영상을 이용하여 저수구역 내의 농경지를 탐지하는 데에 활용할 수 있을 것으로 판단되며, UAV 영상의 공간해상도에 따라서 최적의 GLCM 윈도우 크기는 변화될 수 있기 때문에 향후 연구에서는 공간해상도에 따른 GLCM 윈도우 크기의 상관관계를 분석하고자 할 계획이다.

감사의 글

이 논문은 2017년도 정부(교육부)의 제원으로 한국연구재단의 지원을 받아 수행되었음(NRF-2017R1D1A3B03034602).

References

- Choi, S.K., Kim, G.H., Choi, J.W., Lee, S.K., Jung, S.H., and Chun, S.J. (2017), UAV-based land cover mapping technique for monitoring coastal sand dunes, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 35, No. 1, pp. 11-22.
- Feng, Q., Liu, J., and Gong, J. (2015), UAV remote sensing for urban vegetation mapping using random forest and texture, *Remote Sensing*, Vol. 7, No. 1, pp. 1074-1094.
- Kim, G.H. and Choi, J.W. (2017), Land cover classification with high spatial resolution using orthoimage and DSM based on fixed-wing UAV, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 35, No. 1, pp. 1-10.
- Kim, H., Kim, J., Yoon, S., and Kim, T. (2018), Development of a method for calculating the allowable storage capacity of rivers by using drone images, *Korean Journal of Remote Sensing*, Vol. 34, No. 2-1, pp. 203-211. (in Korean with English abstract)
- Kim, H., Yoon, H., Jang, S., and Chung, Y. (2017), Detection method of river floating debris using unmanned aerial vehicle and multispectral sensors, *Korean Journal of Remote Sensing*, Vol. 33, No. 5-1, pp. 537-546. (in Korean with English abstract)
- Mcfeters, S. (1996), The use of normalized difference water index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, Vol. 17, No. 7, pp. 1425-1432.
- Rouse, J.W., Haas, R.H., Schell, J.A., and Deering, D.W. (1974), Monitoring vegetation systems in the great plains with ERTS, *Proceedings of the third Earth Resource Technology Satellite (ERTS) Symposium*, NASA, 10-14 December, Washington, D.C, USA, Vol. 1, pp. 309-317.
- Su, L. and Gibeaut, J. (2017), Using UAS hyperspatial RGB imagery for identifying beach zones along the South Texas coast, *Remote Sensing*, Vol. 9, No. 2, p. 159.

- 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)
- Van Der Linden, S., Rabe, A., Held, M., Jakimow, B., Leitão, P.J., Okujeni, A., Schwieder, M., Suess, S., and Hostert, P. (2015), The EnMAP-Box— A Toolbox and application programming interface for EnMAP data processing, *Remote Sensing*, Vol. 7, pp. 11249-11266.
- Wood, E.M., Pidgeon, A.M., Radeloff, V.C., and Keuler, N.S. (2012), Image texture as a remotely sensed measure of vegetation structure, *Remote Sensing of Environment*, Vol. 121, pp. 516-526.
- Xu, H. (2006), Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery, *International Journal of Remote Sensing*, Vol. 27, No. 14, pp. 3025-3033.