

## 다중분광 카메라 탑재 드론 영상 기반 토지피복도 제작 및 활용성 평가

### Land Cover Mapping and Availability Evaluation Based on Drone Images with Multi-Spectral Camera

서춘욱<sup>1)</sup> · 임재형<sup>2)</sup> · 김형매<sup>3)</sup> · 윤희천<sup>4)</sup>

Xu, Chun Xu · Lim, Jae Hyung · Jin, Xin Mei · Yun, Hee Cheon

#### Abstract

The land cover map has been produced by using satellite and aerial images. However, these two images have the limitations in spatial resolution, and it is difficult to acquire images of a area at desired time because of the influence of clouds. In addition, it is costly and time-consuming that mapping land cover map of a small area used by satellite and aerial images. This study used multispectral camera-based drone to acquire multi-temporal images for orthoimages generation. The efficiency of produced land cover map was evaluated using time series analysis. The results indicated that the proposed method can generated RGB orthoimage and multispectral orthoimage with RMSE (Root Mean Square Error) of  $\pm 10\text{mm}$ ,  $\pm 11\text{mm}$ ,  $\pm 26\text{mm}$  and  $\pm 28\text{mm}$ ,  $\pm 27\text{mm}$ ,  $\pm 47\text{mm}$  on X, Y, H respectively. The accuracy of the pixel-based and object-based land cover map was analyzed and the results showed that the accuracy and Kappa coefficient of object-based classification were higher than that of pixel-based classification, which were 93.75%, 92.42% on July, 92.50%, 91.20% on October, 92.92%, 91.77% on February, respectively. Moreover, the proposed method can accurately capture the quantitative area change of the object. In summary, the suggest study demonstrated the possibility and efficiency of using multispectral camera-based drone in production of land cover map.

Keywords : Land Cover Map, Multispectral, Orthoimage, Pixel-Based, Object-Based, Time Series

#### 초 록

토지피복도는 지금까지 주로 위성영상과 항공영상을 이용하여 제작되어 왔지만 이 두 영상은 공간적 해상도의 한계가 따르고 구름의 영향으로 원하는 시점에 원하는 지역의 영상을 취득하기에는 역부족이다. 또한, 소규모 지역에 대한 토지피복도를 제작하기에는 시간적 및 경제적 측면에서 비효율적이다. 이에 본 연구에서는 다중분광 카메라 기반의 드론을 사용하여 다중시기 영상을 취득하고 정사영상을 생성한 후 토지피복도를 제작하여 시계열 분석을 통해 활용성을 평가 하였다. 그 결과 RMSE (Root Mean Square Error)가 X, Y, H에서 각각  $\pm 10\text{mm}$ ,  $\pm 11\text{mm}$ ,  $\pm 26\text{mm}$ 인 RGB 정사영상과  $\pm 28\text{mm}$ ,  $\pm 27\text{mm}$ ,  $\pm 47\text{mm}$ 인 다중분광 정사영상을 생성할 수 있었다. 픽셀기반 및 객체기반 분류로 각각 제작된 토지피복도의 정확도를 분석한 결과 전체 정확도와 Kappa 계수에서 객체기반 분류가 시기별로 각각 7월 93.75%, 92.42%, 10월 92.50%, 91.20%, 2월 92.92%, 91.77%로 더 높게 나타났으며 시계열 분석 결과 특정 객체의 면적 변화량을 정량적으로 정확하게 파악할 수 있었다. 이를 통해 다중분광 카메라 기반의 드론을 활용한 효율적인 토지피복도 제작 가능성과 활용성을 확인하였다.

핵심어 : 토지피복도, 다중분광, 정사영상, 픽셀기반, 객체기반, 시계열

Received 2018. 11. 23, Revised 2018. 12. 04, Accepted 2018. 12. 11

1) Member, Dept. of Civil Engineering, Chungnam National University (E-mail: seochoonwook@naver.com)

2) Member, Dept. of Civil Engineering, Chungnam National University (E-mail: set4rise@naver.com)

3) Dept. of Landscape Architecture, Chonbuk National University (E-mail: siskim1987@naver.com)

4) Corresponding Author, Member, Dept. of Civil Engineering, Chungnam National University (E-mail: hcyoon@cnu.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

토지피복이란 산림, 도로, 물, 농작물, 습지 및 인공구조물 등과 같은 지형에 존재하는 물질들의 종류를 뜻한다. 토지피복도는 이러한 토지피복들이 지표면에 분포되어 있는 형태를 일정한 기준에 따라 동질성을 갖는 구역들로 분류하여 지도의 형태로 제작한 것이다. 지표를 구성하고 있는 토지피복도는 형상과 특성이 변화되는 토지의 현황들을 공간적으로 파악할 수 있기 때문에 정부에서는 환경정책, 국토 및 도시계획 수립과 분석에 있어서 기초적인 자료로 활용하고 있고, 학술분야에서는 생태계를 조사하고 시기별 변화를 분석하기 위한 다양한 연구 자료로 활용되고 있다.

토지피복도의 제작은 지금까지 주로 위성영상과 항공영상을 이용한 원격탐사 기법이 사용되어 왔다. 토지피복들의 일부는 상당히 정적으로 시간의 경과에 따라 거의 변하지 않는 반면 생물 물리화학적 물질이나 인공구조물은 역동적이고 급격하게 변화하며 이를 정확하게 조사하고 정성적 및 정량적으로 분석하는 것이 매우 중요하다(Jensen *et al.*, 2012; Kit and Ludeke, 2013). 따라서 토지피복들에 대한 보다 신속한 파악과 정량화가 필요하지만 위성영상과 항공영상은 취득에서부터 사용되기까지 소규모 특정 지역에 대해서는 공간해상도의 한계가 따르고 시간적 및 경제성 측면에서 비효율적이다.

위성영상의 공간해상도는 종류에 따라 0.55m~100m로 다양하지만 대축척 정밀지도 제작에는 한계가 있다. 주기해상도는 3일~28일로 높은 위성도 있지만 소규모 지역에 사용하려면 영상 구입부터 보정 및 분석에 많은 비용이 소요됨으로 경제성이 떨어지는 문제점을 갖고 있다(Feng *et al.*, 2015). 항공영상은 공간해상도가 20cm~50cm로 위성영상보다 높지만 구름의 영향을 많이 받아 쾌청일 수가 약 50일에 불과한 기상 여건을 감안하면 소규모 지역을 짧은 주기해상도로 원하는 시점에 촬영하기에는 역부족이다. 또한, 촬영 및 영상 분석 비용이 높아 위성영상과 마찬가지로 경제성 면에서 비효율적이다. 그리고 환경부에서 제작하고 있는 토지피복도는 위치 정확도와 표현 정밀도가 낮고 갱신 주기가 길어 보다 정확하고 정밀한 대축척 공간정보의 수요와 수준 높은 변화탐지 자료의 갱신에 대한 요구를 만족시키지 못하고 있는 실정이다.

이에 반해 4차 산업혁명의 중심에 놓이게 되면서 다양하게 활용되고 있는 드론은 소규모 특정 지역에 대한 영상을 사용자의 목적 및 성능에 따라 원하는 주기해상도로 높은 공간해상도의 고품질 영상을 취득할 수 있다(Gay *et al.*, 2009). 또한, 초경량화된 다중분광, 열적외선, 라이다 등과 같은 센서들의 등장으로 드론을 이용한 원격탐사의 적용 범위가 확대되고 있다

(Colomina and Molina, 2014). 이러한 센서들은 정밀농업 분야를 시작으로 현재 환경 공간정보 분야에서도 활용도가 높아지고 있다. 따라서 기존에 위성영상과 항공영상으로 구축하던 공간정보를 시간과 비용 면에서 경제적이고 효율성이 높은 드론을 이용한 방법에 대한 연구가 활발히 진행되고 있다.

국내·외적으로 드론 영상을 이용한 토지피복도 제작에 관한 연구들은 아직까지 초기단계에 머물러 있다. Kim (2015)은 약 8cm급의 드론 영상으로 객체기반 토지피복도를 제작하고 작물 분류를 하였고, Park (2017)은 간척지와 산림 지역의 드론 영상으로 무감독분류 기반 토지피복도를 제작하여 표토의 특성을 평가하였으며, Lee *et al.* (2017)은 드론으로 갯벌 지역의 DEM (Digital Elevation Model)을 추출하고 픽셀기반 토지피복도를 제작하여 해수의 변화량을 파악하였다. 국외의 경우 Fuyi *et al.* (2012)은 학교 캠퍼스 드론 영상으로 픽셀기반 분류 기법의 토지피복도 제작 가능성을 확인하였고, Gini *et al.* (2013)은 드론으로 RGB 및 근적외선 영상을 취득하여 초목 분류를 위한 토지피복도를 무감독분류와 감독분류로 각각 제작하였으며, Torres-Sanchez *et al.* (2014)은 드론으로 저고도에서 취득된 근적외선 영상을 포함한 자료로 해바라기 밭의 모니터링을 위한 객체기반 토지피복도를 제작하였다.

이상의 선행 연구들을 보면 드론을 활용한 토지피복도 제작에 다양한 기법들이 사용되고 있지만 최적의 분류 기법에 대한 제시와 시계열 분석에 관한 연구는 아직 미비한 실정이다.

이에 본 연구에서는 드론과 다중분광 카메라를 이용하여 연구 대상지의 다중시기 고해상도 RGB 및 다중분광 영상을 취득하고 정사영상을 생성하여 위치 정확도를 분석한 후 픽셀기반 및 객체기반 분류 기법으로 토지피복도를 제작하여 분류 정확도 평가를 통해 소규모 지역에 적합한 최적의 분류 기법을 제시하고자 한다. 또한, 계절의 변화에 따른 시계열 모니터링을 통해 변화 양상을 정성적 및 정량적으로 파악하여 위성영상과 항공영상의 한계점을 보완하면서 공간정보의 갱신이 용이한 드론 원격탐사 기법의 효율적인 토지피복도 제작과 활용성을 평가하고자 한다.

## 2. 자료취득 및 처리

### 2.1 자료취득

본 연구에서는 토지피복을 분류 하고자 하는 항목들이 다양하게 분포되어 있고 지형이 비교적 평탄하여 GCP (Ground Control Point) 측량에도 접근이 용이한 지역을 연구 대상지로 선정하였고 촬영 면적은 가로×세로 약 500m×600m이다. 또한, 연구 대상지는 비행 및 촬영 허가 구역임으로 주기적인 영

상 취득에도 용이하다.

자료취득에 사용된 장비는 중국 DJI사의 Phantom 4 Advanced 회전익 드론과 근적외선 외 4개 밴드가 포함된 초경량 모델인 프랑스 Parrot사의 SEQUOIA 다중분광 카메라, 그리고 일본 Sokkia사의 GRX2 모델인 GNSS (Global Navigation Satellite System) 수신기를 사용하였다.

2.1.1 GCP 측량

드론에 내장된 저가의 GNSS 수신기와 IMU (Inertial Measurement Unit)는 정확도가 낮고 기체의 자세가 크게 변하는 요소들로 인하여 취득되는 외부표정 요소를 그대로 사용하면 정확도가 크게 떨어진다. 따라서 항공삼각측량 수행 시 정확한 절대좌표를 부여하기 위해서는 GCP 측량이 필수적으로 선행되어야 한다.

GCP 측량에 앞서 GNSS 수신기의 정확도 검증을 확인하기 위해 연구기관 근처의 통합기준점을 Network 기반 RTK (Real-Time Kinematic) 방식 중 VRS (Virtual Reference Station) 방법으로 300번의 관측을 통해 좌표 값을 취득하여 고시된 성과와 비교하였다. 결과 X, Y, H 방향에서 각각 -2mm, 3mm, 5mm 로 나타났다.

GCP는 영상에서 식별이 용이한 맨홀 중앙, 우수 유입구, 도로, 주차장 및 인공구조물의 모서리 부분으로 선정 하였고 총 23개 GCP에 대해 VRS 측량으로 위치정보를 취득하였다. Fig. 1은 연구 대상지의 GCP 분포 현황을 나타내고, Table 1에 23개 측량 성과를 정사영상 제작 및 정확도 분석에 사용한 GCP와 CP (Check Point)로 구분하여 나타내었다.



Fig. 1. GCP locations in study area

Table 1. The acquired GCP coordinates

| No.    | X(m)       | Y(m)       | H(m)   |
|--------|------------|------------|--------|
| GCP 1  | 408093.729 | 192045.927 | 6.685  |
| GCP 2  | 407957.781 | 192116.141 | 6.562  |
| GCP 3  | 408218.484 | 192195.513 | 8.422  |
| CP 4   | 408170.603 | 192194.923 | 8.096  |
| GCP 5  | 408008.674 | 192192.614 | 7.346  |
| CP 6   | 408009.766 | 192277.131 | 8.023  |
| CP 7   | 408012.498 | 192296.470 | 8.334  |
| GCP 8  | 408038.457 | 192295.858 | 8.426  |
| GCP 9  | 407963.630 | 192292.391 | 7.914  |
| CP 10  | 407954.523 | 192298.784 | 7.606  |
| GCP 11 | 407954.718 | 192192.825 | 7.502  |
| GCP 12 | 408174.831 | 192216.134 | 8.304  |
| GCP 13 | 408287.804 | 192250.683 | 9.579  |
| GCP 14 | 408287.536 | 192294.631 | 10.702 |
| CP 15  | 408293.561 | 192173.690 | 9.228  |
| GCP 16 | 408290.800 | 192154.152 | 9.134  |
| GCP 17 | 408103.145 | 192272.545 | 8.741  |
| CP 18  | 408056.880 | 192295.809 | 9.165  |
| GCP 19 | 408205.275 | 192385.136 | 14.279 |
| CP 20  | 408271.291 | 192274.530 | 9.549  |
| CP 21  | 408249.841 | 192235.593 | 8.966  |
| CP 22  | 408263.292 | 192232.211 | 9.014  |
| CP 23  | 408254.083 | 192209.400 | 8.795  |

2.1.2 영상취득

영상취득을 위한 자동비행 설정 값은 중형 중복도 85%/80%, 비행고도와 속도는 150m와 6m/s, 다중분광 카메라는 25m 간격으로 촬영 하도록 설정하였다. Table 2는 자동비행을 위한 데이터 입력 값을 나타내고, Fig. 2에 한 시기에 취득된 RGB와 근적외선 영상만 도시하였다. 최종적으로 7월, 10월, 2월 다중시기의 GSD (Ground Sample Distance)가 약 4cm 인 RGB 영상 135매와 약 14cm인 다중분광 영상 540매를 취득하였다.

Table 2. The input values for automatic flight

| Index   | Values                  |
|---|-------------------------|
| End lap·Side lap                                  | 85% · 80%               |
| Flight altitude                                   | 150m                    |
| Flight speed                                      | 6m/s                    |
| Flight time                                       | 16minutes               |
| Acquired image area                               | 0.3km <sup>2</sup>      |
| Image acquired intervalle of multispectral camera | GNSS mode/25m intervals |
| Number of batteries required                      | One                     |



(a) RGB band (b) Near-Infrared band


Fig. 2. The acquired sample image

2.2 정사영상 생성

본 연구에서는 SIFT (Scale-Invariant Feature Transform) 알고리즘과 SfM (Structure from Motion) 알고리즘이 내장된 러시아 Agisoft사의 Photoscan을 사용하여 토지피복도 제작에 앞서 자동으로 정사영상을 생성하였다. Photoscan의 가장 큰 특징은 여러 각도에서 촬영된 불규칙한 임의의 한 쌍의 입체사진만으로 multi-view 3D 재구성 기술로 영상 처리가 가능하며 GCP 입력을 제외한 모든 작업이 자동으로 진행 된다는 것이다(Lucicic et al., 2014).


Photoscan을 이용한 정사영상 생성은 크게 SIFT 기법으로 영상들의 특징점 매칭을 통해 정합하는 단계, GCP를 입력하여 광속조정법에 의한 항공삼각측량 및 정밀 포인트 클라우드를 생성하는 단계, 영상에 색상이나 질감을 표현해주기 위한 텍스처 매핑 작업과 DEM 및 정사영상을 생성하는 단계 등 3가지로 나눌 수 있다(Marčič et al., 2016).

위와 같은 단계를 통해 10개의 GCP를 사용하여 최종적으로 다중시기 RGB 및 다중분광 정사영상을 생성하고 Figs. 3 and 4에 2월 한 시기의 결과만 도시하였다.



(a) DEM (b) Orthoimage

Fig. 3. February RGB DEM and orthoimage



(a) DEM (b) Orthoimage

Fig. 4. February multispectral DEM and orthoimage

2.3 위치 정확도 분석

본 연구에서는 정사영상 생성 시 사용된 GCP에 대한 결과 정확도와 10개의 CP를 선정하여 영상좌표와 상호 비교하는 방식으로 2월의 정사영상 위치 정확도를 분석하였다. 다른 시기 정사영상은 똑같은 방식으로 생성 되었기에 정확도 분석에서 배제해도 무방하다고 판단하였다.

Table 3. RGB orthoimage accuracy analysis result

| No.       | CP coordinates |            |       | RGB orthoimage coordinates |            |       | Error  |        |        |
|-----------|----------------|------------|-------|----------------------------|------------|-------|--------|--------|--------|
|           | X(m)           | Y(m)       | H(m)  | X(m)                       | Y(m)       | H(m)  | X(m)   | Y(m)   | H(m)   |
| CP 4      | 408170.603     | 192194.923 | 8.096 | 408170.616                 | 192194.930 | 8.055 | 0.013  | 0.007  | -0.041 |
| CP 6      | 408009.766     | 192277.131 | 8.023 | 408009.761                 | 192277.122 | 8.029 | -0.005 | -0.009 | 0.006  |
| CP 7      | 408012.498     | 192296.470 | 8.334 | 408012.516                 | 192296.493 | 8.345 | 0.018  | 0.023  | 0.011  |
| CP 10     | 407954.523     | 192298.784 | 7.606 | 407954.536                 | 192298.795 | 7.632 | 0.013  | 0.011  | 0.026  |
| CP 15     | 408293.561     | 192173.690 | 9.228 | 408293.554                 | 192173.694 | 9.209 | -0.007 | 0.004  | -0.019 |
| CP 18     | 408056.880     | 192295.809 | 9.165 | 408056.876                 | 192295.817 | 9.198 | -0.004 | 0.008  | 0.033  |
| CP 20     | 408271.291     | 192274.530 | 9.549 | 408271.301                 | 192274.548 | 9.591 | 0.010  | 0.018  | 0.042  |
| CP 21     | 408249.841     | 192235.593 | 8.966 | 408249.857                 | 192235.592 | 9.002 | 0.016  | -0.001 | 0.036  |
| CP 22     | 408263.292     | 192232.211 | 9.014 | 408263.286                 | 192232.225 | 9.041 | -0.006 | 0.014  | 0.027  |
| CP 23     | 408254.083     | 192209.400 | 8.795 | 408254.094                 | 192209.394 | 8.803 | 0.011  | -0.006 | 0.008  |
| RMSE      |                |            |       |                            |            |       | ±0.010 | ±0.011 | ±0.026 |
| RMSE(Pix) |                |            |       |                            |            |       | 28     | 29     | -      |

Table 4. Multispectral orthoimage accuracy analysis result

| No.       | CP coordinates |            |       | Multispectral orthoimage coordinates |            |       | Error  |        |        |
|-----------|----------------|------------|-------|--------------------------------------|------------|-------|--------|--------|--------|
|           | X(m)           | Y(m)       | H(m)  | X(m)                                 | Y(m)       | H(m)  | X(m)   | Y(m)   | H(m)   |
| CP 4      | 408170.603     | 192194.923 | 8.096 | 408170.641                           | 192194.934 | 8.131 | 0.038  | 0.011  | 0.035  |
| CP 6      | 408009.766     | 192277.131 | 8.023 | 408009.824                           | 192277.170 | 8.096 | 0.058  | 0.039  | 0.073  |
| CP 7      | 408012.498     | 192296.470 | 8.334 | 408012.526                           | 192296.469 | 8.291 | 0.028  | -0.001 | -0.043 |
| CP 10     | 407954.523     | 192298.784 | 7.606 | 407954.569                           | 192298.754 | 7.637 | 0.046  | -0.030 | 0.031  |
| CP 15     | 408293.561     | 192173.690 | 9.228 | 408293.588                           | 192173.707 | 9.306 | 0.027  | 0.017  | 0.078  |
| CP 18     | 408056.880     | 192295.809 | 9.165 | 408056.919                           | 192295.790 | 9.199 | 0.039  | -0.019 | 0.034  |
| CP 20     | 408271.291     | 192274.530 | 9.549 | 408271.267                           | 192274.578 | 9.574 | -0.024 | 0.048  | 0.025  |
| CP 21     | 408249.841     | 192235.593 | 8.966 | 408249.813                           | 192235.626 | 8.913 | -0.028 | 0.033  | -0.053 |
| CP 22     | 408263.292     | 192232.211 | 9.014 | 408263.333                           | 192232.263 | 9.076 | 0.041  | 0.052  | 0.062  |
| CP 23     | 408254.083     | 192209.400 | 8.795 | 408254.102                           | 192209.428 | 8.882 | 0.019  | 0.028  | 0.087  |
| RMSE      |                |            |       |                                      |            |       | ±0.028 | ±0.027 | ±0.047 |
| RMSE(Pix) |                |            |       |                                      |            |       | 107    | 104    | -      |

GCP에 대한 결과 정확도에서 RGB 정사영상 RMSE는 X, Y, H 방향에서 각각  $\pm 0.010\text{m}$ ,  $\pm 0.007\text{m}$ ,  $\pm 0.014\text{m}$ 로 나타났고, 다중분광 정사영상 RMSE는 X, Y, H 방향에서 각각  $\pm 0.019\text{m}$ ,  $\pm 0.025\text{m}$ ,  $\pm 0.032\text{m}$ 로 나타났다.

CP와의 비교를 통해 정확도를 분석한 결과 RGB 정사영상에서의 최대 오차는 X, Y, H 방향에서 각각 0.018m (51pix), 0.023m (65pix), 0.042m로 나타났고, RMSE는 X방향  $\pm 0.010\text{m}$  (28pix), Y방향  $\pm 0.011\text{m}$  (29pix), H방향에서  $\pm 0.026\text{m}$ 로 나타났다. 다중분광 정사영상에서의 최대 오차는 X, Y, H 방향에서 각각 0.058m (219pix), 0.052m (196pix), 0.087m로 나타났고, RMSE는 X방향  $\pm 0.028\text{m}$  (107pix), Y방향  $\pm 0.027\text{m}$  (104pix), H방향에서  $\pm 0.047\text{m}$ 로 나타났다. Tables 3 and 4는 정확도 분석 결과를 나타낸다.

이상의 결과는 항공사진측량 작업규정의 세부도화 묘사오차 허용범위 안에 들어오는 것을 확인할 수 있었고, 세분류 토지피복도 제작에 요구되는 최소 해상도가 1m인 것을 감안하면 충분히 토지피복도 분류 및 제작에 사용이 가능하다.

### 3. 토지피복도 제작 및 활용성 평가









#### 3.1 토지피복도 제작

본 연구에서는 픽셀기반 및 객체기반 두 가지 방식으로 토지피복도를 제작하였고 모두 감독분류 기법을 사용하였다. 픽셀기반 방식에는 최대우도 분류 기법(maximum likelihood classification)과 SVM 분류 기법(Support Vector Machine classification)을 사용하였고, 객체기반 방식에는 우선 최적의 가중치 선정과 식생지수를 이용한 영상 분할을 수행한 후 최근린 분류 기법(nearest-neighbor classification)을 사용하여

토지피복을 분류하였다. 이를 위해 미국 Harris사의 ENVI와 Trimble사의 eCognition 소프트웨어를 사용하였다.

토지피복 분류에 앞서 환경부에서 규정한 세분류 항목 및 색상체계를 기준으로 연구 대상지 특성에 맞게 총 8가지 분류 항목과 색상체계를 설정하였다. 여기서 내륙습지는 연잎이 피는 시기를 기준으로 식생과 비 식생 지역으로 구분하게 됨으로 이를 감안해야 한다. Table 5는 본 연구에서 설정한 토지피복 분류 항목과 색상체계를 나타낸다.

Table 5. Classification and color system

| No. | Class            | Color system  |           |
|-----|------------------|---|-----------|
| 1   | Lake             |  | Blue      |
| 2   | Mixed forest     |  | Sea Green |
| 3   | Road             |  | Red       |
| 4   | Residential area |  | White     |
| 5   | Other bare land  |  | Cyan      |
| 6   | Other grass land |  | Green     |
| 7   | Farm land        |  | Sienna    |
| 8   | Inland wetland   |  | Orange    |

#### 3.1.1 식생지수 산정

식생지수는 현재 여러 가지가 존재하는데 그 중에서 1974년에 개발된 정규화식생지수(NDVI: Normalized Difference Vegetation Index)가 가장 대표적이고 널리 사용되고 있다. 본 연구에서는 대상지의 식생 상태를 보다 정확하게 파악하고자 NDVI를 추출하였다. NDVI 값은 -1에서 1 사이에 분포하는데 일반적으로 수분상태를 고려하지 않을 경우 0.1에서 0.7 사이를 식생이 존재하는 영역으로 판단한다. Fig. 5는 생

성된 NDVI 영상을 나타낸다.

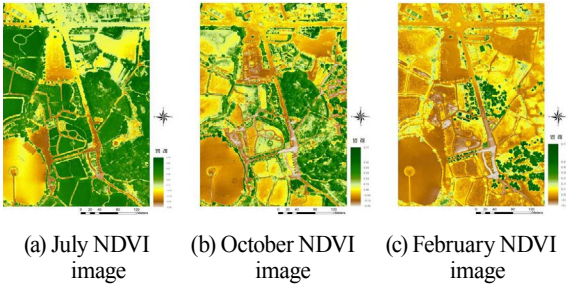




Fig. 5. NDVI generation result

### 3.1.2 픽셀기반 분류


픽셀기반 분류 방식은 영상에 존재하는 픽셀들의 특정한 분광 값에 기반하여 분류하는 방식이다. 본 연구에서는 영상에서 토지 피복 분류의 클래스를 선정하고 관심지역(RoI : Region of Interest)을 수집한 후 최대우도 및 SVM 분류 기법으로 다중시기의 토지 피복 분류를 수행하였다. 최대우도 분류 기법은 정규 분포를 기준으로 하는 확률 밀도 함수를 사용하여 통계적인 확률 분포에 따라 대상 픽셀이 특정 클래스에 포함될 확률을 계산하는 방식이고 (Foody *et al.*, 1992), SVM 분류 기법은 클래스의 분광 값을 이용하여 선형 분류 함수식을 계산하고 분류 클래스를 가능한 멀리 그룹화하여 분리시키는 최적의 초평면(hyper plane)을 찾아 분류되지 않은 클래스를 결정하는 방식이다 (Vapnik, 1995).



(a) RGB orthoimage (b) Maximum likelihood (c) SVM  
Fig. 6. July pixel-based classification result



(a) RGB orthoimage (b) Maximum likelihood (c) SVM  
Fig. 7. October pixel-based classification result




(a) RGB orthoimage (b) Maximum likelihood (c) SVM  
Fig. 8. February pixel-based classification result

본 연구에서는 시기별로 ROI 참조자료를 수집하여 픽셀기반 방식의 각 기법별로 토지피복을 분류하고 결과를 Figs. 6, 7 and 8에 RGB 정사영상과 함께 도시하였다.

### 3.1.3 객체기반 분류

객체기반 분류 방식은 분류에 앞서 픽셀들을 하나의 영상 객체(image object)로 분할하는 작업을 먼저 수행해야 한다. 영상 분할은 선정한 가중치에 따라 객체의 크기 및 형태가 달라지기 때문에 신뢰성을 높이기 위해서는 가장 적절한 단위로 분할 될 때까지 작업을 반복해야 한다.


본 연구에서는 Multi Resolution Segmentation 모듈을 사용하여 분할 축척, 공간정보 및 조밀도에 대한 변수들의 최적의 가중치를 선정하여 객체기반 분류에 앞서 영상을 분할하였다. 우선 조밀도는 값의 변화가 극히 미세하여 기본 값인 0.5로 선정하였고, 공간정보는 기본 값인 0.5에서 축척의 가중치에 따라 분할된 영상의 객체가 다시 세부적으로 분할되는 것을 확인 하였다. 이는 오히려 토지피복 분류 결과 정확도에 영향을 미칠 수 있으므로 기본 값보다 높은 0.8로 선정하였다. 분할 축척에서는 100보다 낮은 값은 불필요한 부분까지 분할되어서 100을 기준으로 20씩 순차적으로 값을 높이면서 확인 하였고 200에서 객체들의 경계가 비로소 불필요한 분할 없이 대체적으로 뚜렷하게 분할되는 것을 확인할 수 있었다.




(a) RGB orthoimage (b) Nearest-neighbor  
Fig. 9. July object-based classification result

그 다음 10픽 높이면서 확인한 결과 250일 때 최적이라 판단하여 250으로 선정하였다. 최종적으로 분할 축척 250, 공간정보 0.8, 조밀도 0.5로 가중치를 선정하였다.

분할된 영상은 감독분류 방법 중 정규분포를 사용하지 않고 각 밴드의 훈련자료 밝기 값을 사용하여 수집된 참조자료로 분류하는 비매개변수 방식인 최근린 기법으로 토지피복 분류를 수행하였다. Figs. 9, 10 and 11은 각 시기별로 분류된 결과를 RGB 영상과 함께 도시하였다.



(a) RGB orthoimage (b) Nearest-neighbor  
**Fig. 10. October object-based classification result**



(a) RGB orthoimage (b) Nearest-neighbor  
**Fig. 11. February object-based classification result**

3.1.4 토지피복 분류 결과

객체기반 및 픽셀기반 방식으로 분류된 토지피복의 결과를 육안 상으로 정상영상과 비교해 보면 대체적으로 양호하게 분류되었지만 10월과 2월의 최대우도 분류 결과는 SVM 분류 결과와 비교해 볼 때 일부분의 기타초지가 내륙습지로 오분류된 것을 알 수 있다. 이는 두 기법의 알고리즘 특성상 확률적 방법과 통계적 방법의 차이가 초래한 결과로 사료된다. 최대우도 분류 알고리즘은 각각의 픽셀이 확률이 가장 크게 계산된 클래스로 분류가 되는데 이때 선정된 훈련 자료가 정규분포 형태를 따른다면 정확하게 분류가 되는데 반해 SVM 분류 알고리즘은 근본적으로 서로 다른 클래스를 최대한 가장 멀리 분리하

는 것이 목표이고 각 픽셀이 분광 값에 의해서 해당되는 클래스에 할당되는 방식이어서 최대우도 분류보다 오분류가 적은 것으로 판단된다.

또한, 각 기법별 면적 분포를 상호 비교해보면 대체적으로 비슷하게 나타났는데 7월의 경우 혼효림과 내륙습지에서 픽셀기반의 최대우도 분류 결과가 타 분류 결과에 비해 약 4%의 차이가 있었다. 10월의 경우는 기타나지에서 최대우도 분류 결과가 약 3% 상이하게 나타났고 논·밭에서는 객체기반 분류 결과가 약 7% 상이하게 나타났다. 마지막으로 2월의 경우에는 도로와 내륙습지에서 최대우도 분류 결과가 약 3%로 타 분류에 비해 차이를 보였으며 논·밭에서는 객체기반 분류가 약 5% 상이하게 나타났다. 이는 픽셀기반 분류에서의 유사한 분광특성을 띠는 곳과의 오분류와 객체기반 분류에서의 영상분할 과정에서 미세한 경계파악이 가능했기 때문에 나타난 차이로 사료된다.

3.2 분류 정확도 분석

토지피복도는 그 정보를 사용하여 생태계 및 농작물 모니터링, 도시계획, 보건 평가 등에 활용되며 때에 따라 중요한 결정이 내려지기 때문에 정확성은 반드시 확보되어야 한다. 토지피복 분류 정확도 분석은 일반적으로 참조자료에 기초한 모집단의 통계적 특성들을 추론하는 원리인 오차행렬(error matrix)에 의해 평가된다. 오차행렬을 이용하여 추출할 수 있는 정확도는 생산자 정확도(producer accuracy), 사용자 정확도(user accuracy), 전체 정확도(overall accuracy), Kappa 계수 등이 있다.

본 연구에서는 토지피복 분류 정확도 분석을 객체기반 방식과 픽셀기반 방식에서 최대우도 및 SVM 기법으로 분류한 결과의 오차행렬을 이용하여 생산자, 사용자 및 전체 정확도와 Kappa 계수를 산정하여 상호 비교하는 방식으로 평가하였다. 정확도 평가에 사용된 참조자료는 픽셀기반 방식에서는 층화임의 표집(stratified random sampling) 방법을 이용하여 무작위로 추출하였고, 객체기반 방식에서는 각 클래스별로 TTA (Training and Test Area) mask를 제작하는 방법을 이용하여 무작위로 참조자료를 추출하였다. 그리고 참조자료와 분류 결과를 이용하여 오차행렬을 산정하고 분류 기법별로 산출된 각각의 정확도를 시기별로 Table 6에 나열하였다.

전체적으로 가장 높은 정확도와 가장 낮은 정확도를 산출하였으며 8개 분류 항목에 대해 상호 비교하였다. 그 결과 생산자 정확도에서 객체기반 분류는 가장 높은 정확도가 15개, 가장 낮은 정확도가 4개로 산출되었고, 최대우도 분류와 SVM 분류는 가장 높은 정확도가 각각 2개와 5개, 가장 낮은 정확도는 모두 10

**Table 6. Classification accuracy analysis by error matrix**

| Index  | Object-based |          | Pixel-based        |          |              |          |
|--|--------------|----------|--------------------|----------|--------------|----------|
|  |              |          | Maximum likelihood |          | SVM          |          |
| Class  | Producers(%) | Users(%) | Producers(%)       | Users(%) | Producers(%) | Users(%) |
| <b>July land cover classification accuracy</b>     |              |          |                    |          |              |          |
| Lake   | 99.80        | 100      | 99.67              | 100      | 100          | 100      |
| Mixed forest                                       | 97.98        | 89.98    | 98.78              | 100      | 100          | 100      |
| Road   | 90.00        | 95.77    | 78.16              | 94.06    | 88.14        | 91.56    |
| Residential area                                   | 93.86        | 95.33    | 67.48              | 79.55    | 81.03        | 90.88    |
| Other bare land                                    | 94.89        | 90.60    | 83.89              | 68.57    | 61.54        | 66.49    |
| Other grass land                                   | 69.06        | 87.16    | 73.82              | 69.46    | 75.39        | 75.00    |
| Farm land  | 93.06        | 90.87    | 83.57              | 78.33    | 89.14        | 71.11    |
| Inland wetland                                     | 76.20        | 100      | 97.79              | 59.38    | 75.74        | 69.13    |
| Overall accuracy                                   | 93.75        |          | 84.12              |          | 85.62        |          |
| Kappa  | 92.42        |          | 81.23              |          | 82.86        |          |
| <b>October land cover classification accuracy</b>  |              |          |                    |          |              |          |
| Lake   | 98.93        | 100      | 100                | 95.19    | 100          | 85.34    |
| Mixed forest                                       | 97.48        | 86.10    | 88.12              | 94.35    | 95.85        | 90.00    |
| Road   | 93.52        | 91.60    | 73.49              | 87.14    | 79.00        | 84.38    |
| Residential area                                   | 83.72        | 98.32    | 80.38              | 72.99    | 70.89        | 100      |
| Other bare land                                    | 90.36        | 87.54    | 94.39              | 86.31    | 94.59        | 86.01    |
| Other grass land                                   | 89.34        | 87.94    | 81.16              | 84.53    | 92.75        | 88.28    |
| Farm land  | 82.52        | 89.33    | 79.15              | 73.22    | 73.08        | 84.74    |
| Inland wetland                                     | 96.80        | 98.68    | 92.61              | 75.14    | 79.23        | 78.40    |
| Overall accuracy                                   | 92.50        |          | 85.03              |          | 86.90        |          |
| Kappa  | 91.20        |          | 81.86              |          | 83.94        |          |
| <b>February land cover classification accuracy</b> |              |          |                    |          |              |          |
| Lake   | 100          | 94.28    | 99.39              | 99.69    | 100          | 98.79    |
| Mixed forest                                       | 90.49        | 90.97    | 71.84              | 81.49    | 71.26        | 86.23    |
| Road   | 96.75        | 92.43    | 80.89              | 97.60    | 90.37        | 91.98    |
| Residential area                                   | 84.55        | 92.86    | 73.18              | 89.17    | 70.60        | 90.85    |
| Other bare land                                    | 96.10        | 90.78    | 77.97              | 55.85    | 54.70        | 53.38    |
| Other grass land                                   | 98.86        | 81.26    | 78.97              | 80.30    | 89.35        | 76.36    |
| Farm land  | 79.88        | 99.10    | 67.98              | 76.31    | 65.21        | 69.24    |
| Inland wetland                                     | 93.46        | 99.67    | 94.44              | 60.47    | 90.43        | 74.18    |
| Overall accuracy                                   | 92.92        |          | 79.20              |          | 80.54        |          |
| Kappa  | 91.77        |          | 75.79              |          | 77.17        |          |

객체 산출되었다. 같은 방식으로 사용자 정확도를 분석한 결과도 객체기반 분류는 17개의 가장 높은 정확도와 3개의 가장 낮은 정확도로 산출되었고, 최대우도 분류와 SVM 분류는 가장 높은 정확도가 각각 3개와 2개, 가장 낮은 정확도가 각각 10개씩 산출되었다. 따라서 생산자 및 사용자 정확도 분석에서는 객체기반 분류 기법이 타 기법에 비해 높은 정확도를 확보하였다.

정확도 분석의 마지막으로 전체 정확도와 Kappa 계수를 산


출하고 상호 비교한 결과 전체 정확도에서 객체기반 분류가 7월 93.75%, 10월 92.50%, 2월 92.92%로 타 분류 기법과 비교해 최소 약 5%에서 최대 약 13%로 높게 나타났고, Kappa 계수도 7월 92.43%, 10월 91.20%, 2월 91.77%로 객체기반 분류가 최소 약 7%에서 최대 약 15%로 타 기법에 비해 높게 나타났으며, 최대우도 분류 기법의 정확도가 가장 낮았다. 이를 통해 드론 원격탐사에서는 분광학적인 성격보다 공간학적인 성격을 우선시



하는 객체기반 분류 기법이 정확도가 높다는 것을 다시 한 번 확인하였다.


### 3.3 활용성 평가

본 연구에서는 분류 정확도 분석에서 가장 높은 정확도를 확보한 객체기반 분류 기법으로 제작된 토지피복도를 이용하여 피복의 면적 변화량을 파악하는 시계열 분석을 통해 활용성을 평가하였다. 분류 항목 중 내륙습지는 연구 대상지 특성상 여름이 되면 연잎 분포지로 변화되기 때문에 계절에 따라 식생지와 습지로 구분되며 시간이 변해도 거의 정적인 토지피복에 비해 면적 비율의 변화가 뚜렷하다는 특징이 있다. 따라서, 내륙습지의 변화가 시기별로 토지피복들에 미치는 영향을 분석하기 위해서 Figs. 12, 13 and 14와 같이 내륙습지와 혼효림을 시기별로 추출하여 RGB 정사영상과 중첩시켜 NDVI 영상과 상호 비교할 수 있도록 도시하였다.




(a) NDVI image (b) Mixed forest (c) Inland wetland

Fig. 12. July inland wetland and mixed forest



(a) NDVI image (b) Mixed forest (c) Inland wetland

Fig. 13. October inland wetland and mixed forest



(a) NDVI image (b) Mixed forest (c) Inland wetland

Fig. 14. February inland wetland and mixed forest

육안 상으로도 확인할 수 있듯이 NDVI 영상에서 수목인 지역은 시간의 변화에도 그대로지만 내륙습지의 경우 연잎이 피는 시기인 7월에서 10월, 2월로 가면서 식생지수가 뚜렷하게 변화되는 것을 알 수 있었고, 추출한 시기별 혼효림과 내륙습지 영상을 비교해 볼 때 면적의 변화량이 상호 반비례 하는 것을 확인 할 수 있었다. 또한, 내륙습지의 일부분은 2월이 되면 연잎의 가치가 완전히 사라져 호소로 변화되는 것으로 나타났다.

Table 7. Comparison of area percentage by period

| Class            | July(%) | October(%) | February(%) |
|------------------|---------|------------|-------------|
| Lake             | 8.92    | 8.81       | 12.81       |
| Mixed forest     | 48.01   | 23.73      | 10.69       |
| Road             | 18.29   | 18.04      | 18.61       |
| Residential area | 3.63    | 3.91       | 3.18        |
| Other bare land  | 6.44    | 6.32       | 6.98        |
| Other grass land | 2.98    | 7.53       | 18.65       |
| Farm land        | 6.86    | 8.88       | 10.45       |
| Inland wetland   | 4.87    | 22.78      | 18.63       |
| Total            | 100     | 100        | 100         |




Fig. 15. Comparison graph of area percentage by period

Table 7과 Fig. 15는 시기별 토지피복의 면적 비율을 나타내며 변화량을 분석한 결과 7월의 경우 혼효림이 48.01%로 가장 높았고, 기타초지가 2.98%로 가장 낮았다. 10월은 혼효림과 내륙습지가 각각 23.73%와 22.78%로 비슷하게 높았고, 이번에는 단독주거지가 3.91%로 가장 낮게 나타났다. 마지막 2월의 경우 도로, 기타초지, 내륙습지가 각각 18.61%, 18.65%, 18.63%로 가장 높았고, 이번에도 단독주거지가 3.18%로 면적 비율이 가장 낮았다.

계절에 따른 각 분류 항목별 변화량을 분석해 보면 호소는 7월과 10월의 면적 비율이 8.92%와 8.81%로 변화가 없다고 할 수 있지만 2월의 경우 12.81%로 나타났다. 이는 내륙습지의 일부분이 겨울이 되면서 표면이 노출되어 호소로 분류된 결과이다. 두 번째로 도로와 기타초지의 면적은 7월, 10월, 2월 모두 대체적으로 변화가 없는 것으로 나타났다. 세 번째로 단독주거지

의 면적은 7월 3.63%, 10월 3.91%, 2월 3.18%로 10월의 비율이 조금 높게 나타났는데, 이는 특정 행사로 인하여 주차장에 설치한 천막이 건물로 분류가 되어 초래된 결과이다. 네 번째로 기타초지와 논-밭은 7월, 10월, 2월에 각각 2.98%, 7.53%, 18.65%와 6.86%, 8.88%, 10.45%로 나타났는데 기타초지의 면적이 겨울로 갈수록 늘어나는 것은 혼효림 중 활엽수의 엽록소가 빠지면서 식생지가 아닌 초지로 분류되어 나타난 결과로 보이며, 논-밭의 경우도 초지와 마찬가지로 분류된 결과라고 판단된다. 마지막으로 계절에 따라 가장 큰 폭의 면적 변화량을 보인 혼효림과 내륙습지의 7월, 10월, 2월 면적 비율 분포는 각각 48.01%, 23.73%, 10.69%와 4.87%, 22.78%, 18.63%로 나타났다. 이는 앞에서 언급한 바와 같이 연구 대상지에 존재하는 내륙습지는 여름이면 연잎으로 덮여 있다가 가을과 겨울에는 연잎이 사라져 정상적인 습지나 호소로 분류 되어 초래된 결과이다.

이상의 토지피복 분류와 시계열 분석으로부터 다중분광 카메라 기반 드론 영상을 이용한 토지피복 분류 시 최적의 방법을 제시할 수 있었으며, 시기별 정확한 면적 변화량을 파악하는 것으로 활용 가능성을 확인 할 수 있었다.

#### 4. 결론

본 연구에서는 위성영상과 항공영상으로는 비효율적인 소규모 지역에 대해 다중분광 카메라를 탑재한 드론으로 다중시기 고해상도 영상을 취득하여 정사영상을 생성하고 위치 정확도를 분석한 후 최적의 분류 방법을 도출 하고자 픽셀 및 객체기반 방식으로 토지피복 분류를 수행하여 정확도를 분석하였다. 또한, 시계열 분석을 통해 면적 변화량을 파악하여 효율적인 토지피복도 제작 가능성과 활용성을 평가하고자 하였으며 그 결과 다음과 같은 결론을 얻었다.

정사영상의 위치 정확도를 분석한 결과 RGB 정사영상에서 RMSE는 X, Y, H에서 각각  $\pm 10\text{mm}(28\text{pix})$ ,  $\pm 11\text{mm}(29\text{pix})$ ,  $\pm 26\text{mm}$ 로 나타났고, 다중분광 정사영상에서는 각각  $\pm 28\text{mm}(107\text{pix})$ ,  $\pm 27\text{mm}(104\text{pix})$ ,  $\pm 47\text{mm}$ 로 나타났으며, 이를 통해 저가의 드론과 센서로도 높은 정확도의 고품질 정사영상 생성이 가능함을 확인하였다.

픽셀 및 객체기반 방식으로 분류된 토지피복의 정확도를 분석한 결과 객체기반 분류가 생산자 및 사용자 정확도가 가장 높았고, 전체 정확도와 Kappa 계수를 상호 비교한 결과도 시기별로 각각 7월 93.75%, 92.42%, 10월 92.50%, 91.20%, 2월 92.92%, 91.77%로 객체기반 분류가 타 분류 기법에 비해 최소 약 5%에서 최대 약 15%로 가장 높게 나타났다. 이 결과는 드론을 이용한 원격탐사에서는 분광학적인 성격보다는 공간학적인

성격을 우선시 하는 객체기반 분류 방식이 정확도면에서는 더 효율적이라는 사실을 입증하였다.

객체기반 방식으로 제작된 토지피복도에 대한 시기별 면적 변화량을 분석한 결과 도로, 단독주거지, 기타나지에서는 변화가 거의 없었고 기타초지와 논-밭은 7월에서 2월로 갈수록 각각 약 5%~11% 및 약 2%씩 증가하였는데 이는 겨울로 갈수록 활엽수가 기타초지와 논-밭으로 분류되어 나타난 결과이다. 호소의 경우 7월과 10월은 비슷한 반면 내륙습지의 일부분이 겨울이 되면서 표면이 노출되어 2월에는 약 4%로 증가한 것을 알 수 있었다. 마지막으로 면적 비율이 가장 크게 나타난 혼효림과 내륙습지의 경우 비율 분포는 각각 7월 48.01%, 10월 23.73%, 2월 10.69%, 내륙습지는 4.87%, 22.78%, 18.63%로 나타났다. 이는 연구 대상지의 내륙습지는 여름이면 연잎으로 덮여 있다가 가을과 겨울에는 연잎이 떨어져서 정상적인 습지나 호소로 분류가 되어 초래된 결과이다.

본 연구에서는 포인트 클라우드 생성에 SfM 알고리즘만 사용하였지만 향후 SGM (Semi-Global Matching) 알고리즘을 사용하면 좀 더 정밀하고 정확한 DEM 및 정사영상 제작이 가능할 것으로 기대된다. 또한, 방대한 양의 영상자료들의 수집이 가능해 지고 기계학습 분야를 토지피복 분류에 적용시킨다면 보다 정확도가 향상된 토지피복도 제작이 가능할 것이고 활용성도 더욱 높아 질 것으로 사료된다.

#### References

Colomina, I. and Molina, P. (2014), Unmanned aerial systems for photogrammetry and remote sensing: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 92, pp. 79-97.

Feng, Q.L., Liu, J.T., and Gong, J.H. (2015), UAV remote sensing for urban vegetation mapping using random forest and texture analysis, *Journal of Remote Sensing*, Vol. 7, No. 1, pp. 1074-1094.

Foody, G.M., Campbell, N.A., Trodd, N.M., and Wood, T.F. (1992), Derivation and applications of probabilistic measures of class membership from the maximum-likelihood classification, *Photogrammetric Engineering & Remote Sensing*, Vol. 58, No. 9, pp. 1335-1341.

Fuyi, T., Chun, B.B., Mat Jafri, M.Z., Lim, H.S., Abdullah, K., and Tahrin, N.M. (2012), Land cover/use mapping using multi-band imageries captured by cropcam unmanned

- aerial vehicle autopilot(UAV) over Penang Island, Malaysia, *Proceedings of SPIE*, The International Society for Optics and Photonics, 8 November 2012, Edinburgh, United Kingdom, Vol. 8540, pp. 1-6.
- Gay, A., Stewart, T.P., Angel, R., Easey, M., Eves, A.J., Thomas, N.J., Pearce, D. A., and Kemp, A.I. (2009), Developing unmanned aerial vehicles for local and flexible environmental and agricultural monitoring, *Proceedings of the Remote Sensing and Photogrammetry Society Conference*, Remote Sensing and Photogrammetry Society, 8-11 September 2009, Leicester, UK, pp. 471-476.
- Gini, R., Passoni, D., Pinto, L., and Sona, G. (2013), Use of unmanned aerial systems for multispectral survey and tree classification: a test in a park area of northern Italy, *European Journal of Remote Sensing*, Vol. 47, No. 1, pp. 251-269.
- Jensen, J.R., Guptill, S., and Cowen, D. (2012), *Change Detection Technology Evaluation*, Task T007 Report, Bureau of the Census, U.S., 232p.
- Kim, B.S. (2015), *Crop classification using unmanned aerial vehicle imagery and object-based classification method*, Master's thesis, Chungbuk National University, Cheongju, Korea, 76p.
- Kit, O. and Ludeke, M. (2013), Automated detection of slum area change in hyderabad, India using multitemporal satellite imagery, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 83, pp. 130-137.
- Lee, H.S., Kim, D.J., Oh, J.H., Shin, J.G., and Jung, J.S. (2017), Tidal flat DEM generation and seawater changes estimation at hampyeong bay using drone images, *Korean Journal of Remote Sensing*, Vol. 33, No. 3, pp. 325-331. (in Korean with English abstract)
- Lucieer, A., Steven, M., and Turner, D. (2014), Mapping landslide displacements using structure from motion(SFM) and image correlation of multi-temporal UAV photography, *Progress in Physical Geography*, SAGE, Vol. 38, No. 1, pp. 97-116.
- Marčíš, M., Barták, P., Valaška, D., Fraštil, M., and Trhan, O. (2016), Use of image based modelling for documentation of intricately shaped objects, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 12-19 July, Prague, Czech Republic, Vol. XLI-B5, pp. 327-334.
- Park, J.S. (2017), *Soil classification and characterization using unmanned aerial vehicle and digital image processing*, Ph.D. dissertation, Seoul National University, Seoul, Korea, 191p.
- Torres-Sanchez, J., Pena, J.M., De Castro, A.I., and Lopez-Granados, F. (2014), Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV, *Computers and Electronics in Agriculture*, Vol. 103, pp. 104-113.
- Vapnik, V.N. (1995), *The Nature of Statistical Learning Theory*, Springer-Verlag, New York, N.Y.