

랜덤포레스트와 서포트벡터머신 기법을 적용한 포인트 클라우드와 실감정사영상을 이용한 객체분류

Object Classification Using Point Cloud and True Ortho-image by Applying Random Forest and Support Vector Machine Techniques

서홍덕¹⁾ · 김의명²⁾

Seo, Hong Deok · Kim, Eui Myoung

Abstract

Due to the development of information and communication technology, the production and processing speed of data is getting faster. To classify objects using machine learning, which is a field of artificial intelligence, data required for training can be easily collected due to the development of internet and geospatial information technology. In the field of geospatial information, machine learning is also being applied to classify or recognize objects using images and point clouds. In this study, the problem of manually constructing training data using existing digital map version 1.0 was improved, and the technique of classifying roads, buildings and vegetation using image and point clouds were proposed. Through experiments, it was possible to classify roads, buildings, and vegetation that could clearly distinguish colors when using true ortho-image with only RGB (Red, Green, Blue) bands. However, if the colors of the objects to be classified are similar, it was possible to identify the limitations of poor classification of the objects. To improve the limitations, random forest and support vector machine techniques were applied after band fusion of true ortho-image and normalized digital surface model, and roads, buildings, and vegetation were classified with more than 85% accuracy.

Keywords : Artificial Intelligence, Machine Learning, Geospatial Information, Digital Map, True Ortho-image, Normalized Digital Surface Model, Band Fusion

초 록

정보통신기술의 발달로 인하여 데이터의 생산과 처리 속도가 빨라지고 있다. 인공지능의 한 분야인 머신러닝을 이용하여 객체를 분류하기 위해, 학습에 필요한 데이터는 인터넷과 공간정보기술의 발달로 인하여 손쉽게 수집할 수 있게 되었다. 공간정보 분야에서도 머신러닝은 영상, 포인트 클라우드 등을 이용하여 객체를 분류 또는 인식하는 것에 적용되고 있다. 본 연구에서는 기 구축된 수치지도 버전 1.0을 활용하여 학습 데이터를 수동으로 구축하는 문제점을 개선하고 영상과 포인트 클라우드를 이용하여 도로, 건물, 식생을 분류하는 기법을 제안하였다. 실험을 통해서 RGB 밴드만을 갖고 있는 실감정사영상을 사용하였을 경우 색상을 뚜렷하게 구분할 수 있는 도로, 건물, 식생의 분류가 가능하였지만 색상이 유사한 경우에는 분류가 잘 되지 않는 한계를 확인할 수 있었다. 이를 개선하기 위해 실감정사영상과 정규수치표면모델을 밴드 퓨전한 후 랜덤포레스트와 서포트벡터머신 기법을 적용하였으며 이를 통해 85%이상의 정확도로 도로, 건물, 식생을 분류하였다.

핵심어 : 인공지능, 머신러닝, 공간정보, 수치지도, 실감정사영상, 정규수치표면모델, 밴드 퓨전

Received 2019. 08. 12, Revised 2019. 10. 15, Accepted 2019. 10. 25

1) Department of Spatial Information Engineering, Namseoul University (E-mail: seoing23@gmail.com)

2) Corresponding Author, Member, Department of Spatial Information Engineering, Namseoul University (E-mail: kemyoung@nsu.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

정보통신기술의 발달로 인하여 데이터의 생산과 처리 속도가 빨라지고 있다. 인공지능, 머신러닝(machine learning)을 위해서는 방대한 양의 데이터를 수집하고 이를 학습(training)시키는 것이 중요한데 인터넷의 발달로 데이터를 손쉽게 수집할 수 있는 환경이 조성됨에 따라 사람이 수행하는 지능적인 작업을 자동화하기 위한 다양한 연구 활동이 이루어지고 있다 (Biamonte *et al.*, 2017; Jeong and Jeong, 2019).

머신러닝은 인공지능의 한 분야로 데이터와 이 데이터로부터 기대되는 해답을 입력하여 규칙을 알아내는 것으로 이를 위해서는 입력된 데이터를 학습시키는 것이 중요하다. 공간정보 분야에서 머신러닝은 영상, 포인트 클라우드(point cloud) 등을 이용하여 객체를 분류 또는 인식하는 것에 적용되고 있다(Liu, 2015; Hong, 2017; Lee and Yom, 2018)

RGB 밴드 기반의 객체 분류 연구들을 살펴보면 UAV(Unmanned Aerial Vehicle) 영상을 RF(Random Forest)에 적용하여 농업 작물을 분류한 연구(Jónsson, 2019), 지상 카메라 영상을 의사결정트리(decision tree)에 적용하여 손상되지 않은 식물을 탐지 하는 연구(Yamamoto *et al.*, 2014), UAV 영상을 RF에 적용하여 영상 내 수목 이상을 감지하는 연구(Yu *et al.*, 2019) 등이 수행되었다. 그러나 이러한 연구들은 RGB 밴드에 의존하여 객체를 분류하기 때문에 다양한 조명 조건 및 환경으로 인하여 오분류되는 결과가 발생할 수 있는 문제점이 있었다 (Liu and Xia, 2010). 또한, 개별 화소를 객체분류의 기본 단위로 사용하기 때문에 노이즈가 민감하고, RGB (Red, Green, Blue) 밴드 기반 분류를 수행할 시 동일한 분류 내에서 큰 변동성을 발생시켜 낮은 분류정확도를 갖는 한계가 존재하였다(Schöpfer *et al.*, 2010; Liu and Xia, 2010).

이를 개선하기 위해서 영상기반의 RGB 밴드 뿐만 아니라 추가적인 밴드 정보를 생성하고 이를 퓨전(fusion)하여 RGB 밴드 기반 객체분류의 한계를 극복하고자 하는 연구들이 수행되고 있다. 이를 살펴보면 UAV 영상에서 기준화소와 이웃하는 화소의 밝기 값의 관계를 GLCM(Gray Level Co-occurrence Matrix)으로 변환하여 RF를 적용하여 저수구역 내의 농경지를 탐지한 연구(Kim and Choi, 2018), UAV 영상과 질감정보를 퓨전하여 학습 데이터를 구축하고 이를 RF에 적용해 식생을 효과적으로 추출하는 연구(Feng *et al.*, 2015), Landsat-8 위성 영상과 수치표고모델, 가뭄 정보를 이용하여 RF를 적용한 재난예측(Park and Lee, 2019), 식생의 높이 정보와 영상을 SVM(Support Vector Machine)에 적용하여 잡초를 인식하는 연구(Wang and Li, 2016), 항공영상과 LiDAR(Light Detection

And Ranging)를 이용하여 제작한 DSM(Digital Surface Model)과 DTM(Digital Terrain Model)을 퓨전하여 학습 데이터를 구축하고 이를 SVM에 적용하여 층위를 분류한 연구 등이 수행되었다(Daneshmand and Rastiveis, 2017; Kwon *et al.*, 2019). 그러나, 이러한 연구들은 밴드를 퓨전할 경우 센서를 추가적으로 장착하여야 하며, 머신러닝을 이용한 객체 분류를 수행할 경우 학습을 위한 데이터를 수동으로 구축해야 하는 단점이 있다(Jo *et al.*, 2019; Park and Bae, 2019).

머신러닝은 어떠한 작업과 관련된 많은 데이터를 제공하면 이 데이터에서 통계적 구조를 찾아 그 작업을 자동화하기 위한 규칙을 만들어내는 것인데, 기존의 연구사례에서 알 수 있듯이 공간정보 분야에서 이러한 학습 데이터를 자동으로 구축할 수 있는 방법이 있다면 머신러닝을 위한 작업의 효율성이 높아질 수 있다. 또한 객체 분류를 위하여 주로 영상과 포인트 클라우드를 사용하고 있는데 이러한 데이터는 드론을 이용하여 취득한 영상과 이를 데이터 처리하여 생성할 수 있다.

이에 본 연구에서는 공간정보 분야에서 활용도가 높은 도로, 건물, 식생을 분류하기 위해 드론 영상을 이용하여 생성한 포인트 클라우드와 실감정사영상(true ortho-image)을 이용하여 객체를 분류할 수 있는 기법을 제안하는 것으로 객체 분류를 위해서 머신러닝 기법을 적용하고, 학습 데이터를 효율적으로 구축하기 위해서 국토지리정보원에서 제공하는 1:5,000 축척의 수치지도 버전 1.0을 활용하는 방안을 제시하는 것을 목적으로 하였다.

2. 연구방법

2.1 제안한 방법론

본 연구에서는 머신러닝을 이용하여 도로, 건물, 식생을 분류하기 위해서 드론을 이용하여 취득한 데이터를 활용하는 방법과 학습 데이터의 구축을 기존의 수치지도를 활용하는 방법을 Fig. 1과 같이 제안하였다.

Fig. 1에 나타난 것과 같이 먼저 분류하고자 하는 대상지역의 드론 영상을 이용하여 포인트 클라우드와 실감정사영상을 생성한다. 두 번째는 실감정사영상 제작을 위해서 선행적으로 생성하게 되는 중간 결과물인 포인트 클라우드는 지면과 비지면으로 분류한 후 지면이 0으로 정규화된 수치표면모델(NDSM : Normalized Digital Surface Model)을 생성한다.

세 번째는 실감정사영상의 RGB 밴드에 새로운 NDSM 밴드를 추가하여 퓨전을 수행한다. 네 번째로 머신러닝 기법을 적용하여 객체를 분류하기 위해서 분류의 대상이 되는 학습 데이터

를 구축하는 것이 필요한데 이러한 학습 데이터는 1:5,000 축척의 수치지도 버전 1.0을 편집하여 수행한다. 다섯 번째는 수치 지도를 편집하여 만든 도로, 건물, 식생 레이어와 RGB, NDSM 밴드를 이용하여 학습 데이터를 구축하고 마지막으로 머신러닝을 통해 도로, 건물, 식생을 분류한다.

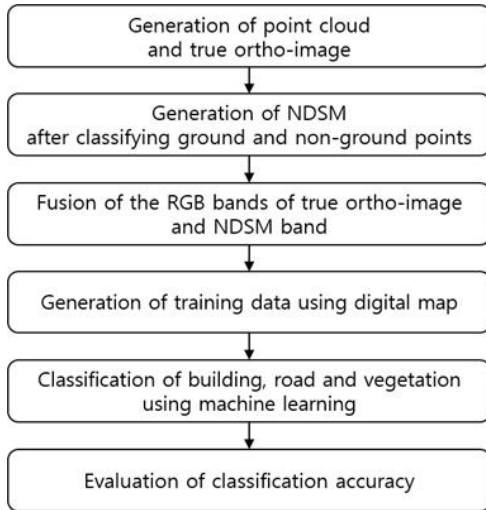


Fig. 1. Research flow chart

2.2 드론영상을 통한 포인트 클라우드와 실감정사 영상 생성

드론을 이용하여 촬영한 영상에서 포인트 클라우드와 실감정사 영상을 생성하는 방법은 사진측량 소프트웨어 또는 컴퓨터 비전에 기반한 소프트웨어를 이용할 수 있다. 최근에는 소프트웨어의 가격과 자료처리의 효율성 등으로 인하여 컴퓨터 비전에 기반한 Pix4D, Photoscan, ContextCapture 등의 소프트웨어를 주로 이용하고 있다. 본 연구에서는 Pix4D를 이용하였으며 그 절차는 다음과 같다(Kim *et al.*, 2017).

Fig. 2에 나타난 것과 같이 드론 영상에서 카메라의 내·외부표정요소를 결정하기 위해서 입력된 모든 영상에 대해 SIFT(Scale Invariant Feature Transform) 알고리즘을 적용하여 특징점을 추출하고 에피폴라 영상을 생성한다. 스테레오 영상에 대해 에피폴라 기하를 적용하여 영상정합을 수행한 후 상호표정요소(relative orientation parameters)와 카메라의 내부표정요소(interior orientation parameters)를 추정한다. 추정된 내부표정요소와 상호표정요소를 이용하여 정합된 영상점에 대한 가상의 3차원 좌표를 생성하고 이를 이용하여 번들블록조정(bundle block adjustment)을 수행하여 카메라의 내·외부표정요소를 최종적으로 결정한다(Schonberger and Frahm, 2016).

이렇게 결정된 3차원 좌표는 초기 포인트 클라우드 데이터가 되며 이를 조밀영상정합(dense image matching)을 수행하여 최종 포인트 클라우드를 생성하고 정사영상을 만들기 위해 3D 메시(3D Mesh)를 생성한다(Marčič *et al.*, 2016). 실감정사영상은 카메라의 내·외부표정요소와 3D 메시를 이용하여 생성한다(Choi and Kim, 2017).

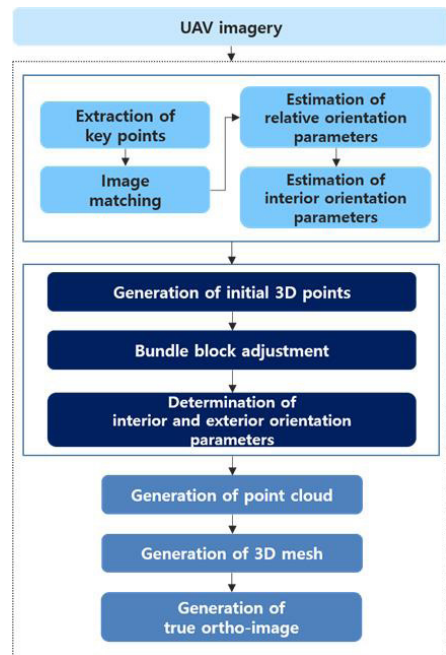


Fig. 2. Flowchart of the generation of point cloud and true ortho-image

2.3 NDSM 생성

드론 영상을 이용하여 생성한 3차원 포인트 클라우드는 지면 및 비지면의 3차원 점군 데이터로 구성된다. 이때 비지면의 3차원 점들을 지면점에서의 높이값을 갖는 점들로 구성하기 위해서 Eq. (1)을 이용하여 NDSM을 생성한다. DSM을 사용할 경우 지면이 낮은 위치의 높은 객체와 지면이 높은 위치의 낮은 객체는 비슷한 높이 정보를 가질 경우가 발생하여 학습 정확도를 저하시킬 수 있다. 따라서, NDSM을 사용할 경우 지면 높이를 정규화함으로써 객체에 대한 높이 정보만을 이용하기 때문에 DSM의 한계를 극복할 수 있다(Cho and Kim, 2010).

$$NDSM = DSM - DEM \quad (1)$$

포인트 클라우드에서 NDSM을 생성하기 위해서는 건물, 수

목 등이 포함되어 있는 비지면점을 제거하고 이를 보간하여 DEM(Digital Elevation Model)을 생성하여야 한다. 이를 위해 본 연구에서는 CSF(Cloth Simulation Filter)기법을 적용하여 지면점과 비지면점으로 분류하였다. CSF 기법은 Fig. 3과 같이 3차원 점군 데이터를 거꾸로 뒤집어 중력 방향으로 천을 떨어뜨리는 천 시뮬레이션(cloth simulation) 방법을 이용하여 지면과 비지면점을 분류한다(Zhang *et al*, 2016; Hong and Kim, 2018).

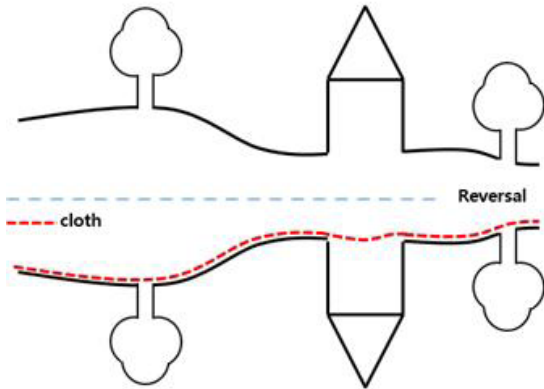


Fig. 3. CSF Algorithm

2.4 밴드 퓨전

밴드 퓨전을 수행하기 위해 실감정사영상과 NDSM의 공간해상도는 동일하다고 가정한다(Daneshtalab and Rastiveis, 2017). 기존 실감정사영상은 RGB 3개의 밴드로 구성되어 있지만, Fig. 4와 같이 NDSM 밴드를 퓨전함으로써 4개의 밴드로 구성되는 것을 알 수 있다. 밴드 퓨전을 위한 자료처리는 QGIS 3.2.0 소프트웨어를 사용하였다. 밴드를 퓨전하게 되면 NDSM이 새로운 밴드로 추가되기 때문에 RGB 정보 뿐만 아니라 높이 값에 대한 정보를 추가적으로 갖게 되는 것을 알 수 있다.




Fig. 4. Fusion of bands

2.5 학습 데이터를 구축하기 위한 수치지도 편집

포인트 클라우드와 실감정사영상 데이터를 이용하여 머신러닝 기법을 적용하여 도로, 건물, 식생을 분류하기 위해서는 학습 데이터를 구축해야 한다. 이를 위해 본 연구에서는 기 구축

된 1:5,000 축척의 수치지도를 활용하였고 수치지도 편집을 위한 자료처리는 QGIS 3.2.0 소프트웨어를 이용하였다. 수치지도와 객체분류에 사용할 포인트 클라우드와 실감정사영상 데이터는 시간 해상도가 유사하다고 가정한다.

도로, 건물, 식생을 분류하기 위해서 Table 1과 같이 도로 중심선, 건물, 지류계인 지형지물 표준 레이어 코드를 사용하였다. 도로를 분류하기 위해서 도로 중심선에서 버퍼 6m를 적용하여 편도 2차로의 도로가 포함되도록 하였다. 건물 데이터는 (건물경계)미분류, 주택외건물, 주택, 연립주택, 아파트, 무벽건물, 가건물을 고려하였으며 공사중 건물과 온실은 레이어코드에서 제외하였다. 또한, 식생 데이터는 활엽수, 침엽수, 혼합림 등이 모두 포함되어있는 지류계를 이용하였다.

Table 1. Standard layer codes for 1:5,000 digital map

Major category	Middle category	Type	Code
Road	Road centerline	(Road centerline) Unclassified	A0023210
Building	Building	(Building boundary) Unclassified	B0014110
		Building but house	B0014111
		House	B0014112
		Town house	B0014113
		Apartment	B0014115
		Non-walled building	B0014116
	Tabernacle	B0014118	
Vegetation	Tributary	Tributary	D0025111

Table 1의 수치지도 레이어 코드를 기반으로 학습 데이터와 평가 데이터를 추출하였으며, 추출한 데이터를 랜덤으로 학습 데이터(80%)와 평가 데이터(20%)로 나누었다. 또한, 평가 데이터는 속성 정보를 모두 NULL 타입으로 변경하여 실험을 통해 분류하였다.

2.6 머신러닝을 이용한 객체분류

머신러닝을 이용한 객체분류를 수행하기 위해 Erdas Imagine 2016 소프트웨어와 프로그래밍 언어인 Python 3.7.3을 이용하였다.

2.6.1 SVM

SVM은 분류문제를 해결하기 위해 서로 다른 범주에 속한 데이터 간에 분류를 수행할 때 선형의 회귀식을 이용하여 초평면(hyperplane)을 최대화하여 객체를 분류하는 기법이다(Park

et al., 2011). Fig. 5는 학습 데이터를 두 개의 범주에 대응하는 영역으로 나누는 결정경계를 나타낸 것이다.

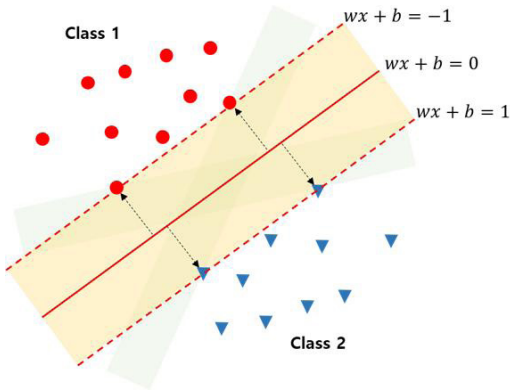


Fig. 5. Decision boundary of SVM

객체를 구분하는 초평면은 여러 개가 존재하지만 객체 사이의 거리를 최대화하는 초평면은 유일하며 최적의 초평면은 Eq. (2)와 같이 나타낼 수 있다. \vec{w} 는 초평면의 중심선에 대해 직교하는 벡터이며, \vec{x} 는 초평면상의 한 점, b 는 절편이다(Hong and Kim, 2018).

$$(\vec{w} \cdot \vec{x}) + b = w^T x + b = 0 \tag{2}$$

where, \vec{w} represents the normal vector of a hyper plane and \vec{x} represents a point in hyper plane, and b represents a bias.

Fig. 5와 Eq. (2)을 통해 $w^T x + b$ 이 -1보다 작은 경우에 Class 1, 1보다 큰 경우에 Class 2로 분류되는 것을 알 수 있다. 따라서 두 조건을 Eq. (3)과 같이 나타낼 수 있다.

$$\begin{aligned} y_i &= +1 \text{ when } (\vec{w} \cdot \vec{x}_{class1}) + b \geq +1 \\ y_i &= -1 \text{ when } (\vec{w} \cdot \vec{x}_{class2}) + b \geq -1 \\ y_i(\vec{w} \cdot \vec{x}_i + b) - 1 &= 0 \end{aligned} \tag{3}$$

where, \vec{x}_{class1} represents points in class 1 and \vec{x}_{class2} represents points in class 2.

SVM은 Eq. (3)과 같이 두 객체 사이의 거리를 최대화하기 위한 것으로 목적함수를 Eq. (4)와 같이 나타낼 수 있고 이는 다시 수학적 계산의 편의를 위해서 Eq. (5)와 같이 나타낼 수 있다.

$$\frac{\vec{w}}{\|\vec{w}\|} \cdot (\vec{x}_{class1} - \vec{x}_{class2}) = \frac{2}{\|\vec{w}\|} \tag{4}$$

$$\max \frac{2}{\|\vec{w}\|} \Rightarrow \min \left(\frac{1}{2} \|\vec{w}\|^2 \right) \tag{5}$$

where, $\frac{2}{\|\vec{w}\|}$ denotes a distance from class 1 to class 2.

2.6.2 RF

RF 기법은 Fig. 6과 같이 결정트리 학습에 기초한 것으로 무작위로 추출한 집합들을 이용하여 많은 수의 의사결정트리를 생성한다. 생성된 의사결정트리의 판별 클래스들을 가중 투표하여 최종 클래스를 결정하는 방법이다(Yun and Yi, 2008; Kim and Choi, 2018).

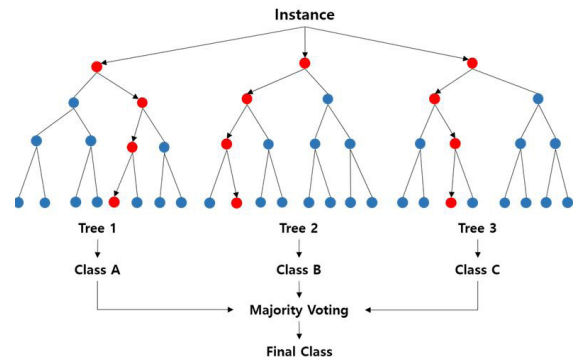


Fig. 6. RF algorithm

클래스를 분할하기 위한 식은 Eq. (6)과 같다(Wikipedia, 2019).

$$\begin{aligned} \varnothing &= (\theta, \tau) \\ h_l(\varnothing) &= h(\theta) < \tau \end{aligned} \tag{6}$$

$$h_r(\varnothing) = h \setminus h_l(\varnothing)$$

where, θ is feature parameters, τ is thresholds, h is the total number of data, h_l is a left node, h_r is a right node.

매개변수의 최적값(θ^*)은 정보 획득량이 가장 큰 매개변수 값을 노드의 분할 조건으로 결정한다(Kim et al., 2017). 정보 획득량은 새넨 엔트로피(shannon entropy)로 결정되며 Eq. (7)과 같다.

$$H(S) = - \sum p \log(p(c)) \tag{7}$$

where, S is a dataset that reaches one node, c is the total number of classes, $p(c)$ is a probability mass function for each class.

Eq. (7)을 통해 새넨 엔트로피가 최소화가 되면 정보 획득량이 최대가 되며, 가장 적합한 매개변수가 된다는 것을 알 수 있다. 따라서 매개변수를 통한 분할 조건은 Eq. (8)과 같다.

$$\varnothing^* = \operatorname{argmax} I(\varnothing) \tag{8}$$

$$I(\varnothing) = H(\varnothing) - \sum \frac{|\varnothing_i|}{|\varnothing|} H(\varnothing_i)$$

where, \varnothing^* is an optimum parameter, I is an information gain, H is a shannon entropy.

3. 실험

3.1 연구대상지

본 연구의 대상지는 충남 천안시에 소재한 성환읍 일대이며 DJI사의 Matrice 100 드론과 젤뮤즈(Zenmuse) X3 카메라를 이용하여 702장의 영상을 취득하였으며 촬영된 면적은 약 707m×1050m이다. Table 2는 촬영에 사용된 카메라의 영상크기, 초점거리, 지상해상도(GSD : Ground Sampling Distance)를 나타낸다.

Table 2. Image size and GSD

Company	Model	Image size(pixel)		Focal length (mm)	GSD (cm/pixel)
		Width	Height		
DJI	Zenmuse X3	4000	3000	13.485	3.39

드론을 이용하여 촬영된 702장의 영상에 대해 GNSS을 이용하여 측량한 9점의 지상기준점을 이용하여 번들블록조정(BBA : Bundle Block Adjustment)을 통해서 내·외부표정요소와 정합점의 3차원 좌표를 결정하였다. 드론 영상의 자료처리는 Pix4D 소프트웨어를 이용하였다. 번들블록조정의 정확도는 8개의 검사점을 이용하여 Table 3과 같이 평균제곱근오차(RMSE: Root Mean Square Error)를 계산하였다. GSD를 고려할 때 수평위치는 약 2픽셀, 높이는 약 4픽셀의 오차가 발생하였으나 도로, 건물, 식생을 분류하기 위해서 사용한 1:5,000 수치지도의 오차를 고려하였을 때 양호한 산출물임을 알 수 있다

(Choi et al., 2002).

Table 3. Accuracy of BBA using checkpoints

	X(m)	Y(m)	Z(m)
RMSE	0.074185	0.061703	0.138416
	X(pixel)	Y(pixel)	Z(pixel)
RMSE	2.188348	1.820147	4.083068

BBA를 수행한 후 포인트 클라우드를 생성하기 위해서 조밀 영상정합을 수행하였고 생성된 포인트 클라우드를 3D 메쉬로 만든 후 이를 이용하여 실감정사영상을 생성하였다. Fig. 7(a)는 연구대상지역의 포인트 클라우드를 나타내고 Fig. 7(b)는 실감정사영상을 나타낸다. 포인트 클라우드는 3차원 좌표 뿐만 아니라 조밀영상정합을 수행하여 생성하였기 때문에 RGB값도 같이 있다.



(a) Point cloud (b) True ortho-image

Fig. 7. Point cloud and true ortho-image

3.2 NDSM 생성 및 밴드 퓨전

포인트 클라우드에서 지면점과 비지면점의 분류는 CSF 기법을 이용하였으며 분류 결과는 Fig. 8과 같다. 포인트 클라우드에서 지면점과 비지면점은 각각 23,283,170점(40.84%)과 33,727,964점(59.16%)으로 나타났다.

CSF기법으로 분류된 지면점은 최근린보간법을 이용하여 Fig. 9(a)와 같이 DEM을 생성하였다. 그리고 비지면점을 이용하여 Fig. 9(b)와 같이 DSM을 생성한 후 DSM과 DEM을 차분하여 Fig. 9(c)와 같이 NDSM을 생성하였다. 다음으로 생성된 NDSM을 색상 정보에 대한 밴드만을 가진 실감정사영상에 추가하여 밴드 퓨전을 수행하였다.




Fig. 8. Ground and non-ground points




Fig. 9. DEM, DSM and NDSM

3.3 수치지도를 이용한 학습 데이터 구축

머신러닝을 이용한 객체 분류 연구의 대부분은 학습 데이터와 평가 데이터를 수동으로 구축하기 때문에 많은 비용과 시간이 소요된다(Jo *et al.*, 2019). 이러한 문제점을 개선하기 위해서 본 연구에서는 학습 데이터와 평가 데이터를 1,500 축척의 수치지도를 활용하여 구축하였으며 학습 데이터는 Fig. 10, 평가 데이터는 Fig. 11과 같다.




Fig. 10. Training data




Fig. 11. Test data

도로, 건물, 식생을 분류하기 위해 사용된 수치지도의 객체 수는 총 1,750개이며, 학습 및 실험 데이터에 사용된 각 클래스 별 데이터 수는 Table 4와 같다.

Table 4. Number of training and test data

	Number of training data	Number of test data
Road	78	19
Building	1,237	309
Vegetation	86	21
Sum	1,401	349

추출한 수치지도의 객체와 702장의 영상을 이용하여 생성한 실감정사영상 및 NDSM을 퓨전한 두 영상을 중첩하여 Fig. 12와 같이 도로, 건물, 식생 클래스를 포함한 영역에 속하는 각 밴드의 평균, 최댓값, 최솟값, 표준편차를 이용하여 학습 데이터를 구축하였다.




Fig. 12. Construction process of training data

본 연구에서는 실감정사영상의 RGB 밴드만 사용했을 경우와 포인트 클라우드를 통해 제작된 NDSM을 새로운 밴드로 추가하여 퓨전하였을 경우의 두 가지로 실험을 수행하였다. 이를 위해 학습 데이터도 실감정사영상의 RGB 밴드를 사용하는 경우와 NDSM을 퓨전하는 두 가지로 구축하였다.

학습 데이터의 구축은 실감정사영상 또는 NDSM과 수치지도를 중첩하여 도로, 건물, 식생에 속하는 각 밴드의 평균, 최댓값, 최솟값, 표준편차를 이용하였다.

Table 5는 RGB 밴드와 학습 데이터에 사용될 수치지도를 중첩하여 생성한 학습 데이터의 일부를 나타낸다. Case 1에서 건물의 RGB 밴드별 평균값은 약 124.934, 117.973, 116.154이며, 도로는 124.060, 117.966, 117.252로 두 객체는 다른 객체임에 불구하고 비슷한 영역대에 존재하는 것을 알 수 있었다. 또한, Case 2의 건물의 RGB 밴드별 평균값은 113.923, 128.194, 141.280이며, 식생의 평균값은 120.035, 125.765, 138.812로 Case

1과 동일하게 서로 다른 객체이지만 비슷한 영역 내에 존재하는 것을 알 수 있었다. 이러한 유사한 정보를 가진 두 데이터를 학습하면 객체 간의 특징을 구별할 수 있는 근거가 부족해서 객체 분류를 수행할 경우 오분류가 발생할 수 있다.

Table 5. Part of the training data built using RGB bands

		Case 1		Case 2	
Class		Building	Road	Building	Vegetation
Max	R	255	234	251	228
	G	253	255	254	218
	B	248	218	252	219
Min	R	26	30	19	50
	G	39	33	49	53
	B	41	48	68	66
Mean	R	124.9336	124.0600	113.9233	120.0353
	G	117.9725	117.9664	128.1940	125.7647
	B	116.1537	117.2518	141.2800	138.8118
Std	R	46.2363	35.7582	38.0653	52.5591
	G	42.4988	34.4751	46.4496	47.9565
	B	35.7324	30.6098	48.3649	42.7174

Table 6. Part of training data built using fusion bands

		Case 1		Case 2	
Class		Building	Road	Building	Vegetation
Max	R	253	253	238	253
	G	253	252	231	255
	B	253	244	226	246
	Z	17.9294	4.4760	12.1820	2.2705
Min	R	33	39	55	52
	G	37	44	55	56
	B	50	15	65	70
	Z	1.1908	0.1945	0.2867	0
Mean	R	136.8765	134.3138	153.3643	159.5732
	G	130.4821	133.8105	138.4917	144.7652
	B	137.8722	132.6601	125.4925	124.7498
	Z	14.3506	0.4998	10.0523	0.1877
Std	R	65.3889	30.7674	27.9836	40.9687
	G	62.2738	29.8951	25.1292	34.0640
	B	52.5551	27.1676	19.9672	22.2933
	Z	2.4074	0.4777	2.6963	0.1211

Table 6은 RGB 밴드와 NDSM 밴드를 퓨전하여 생성한 영상과 학습 데이터에 사용될 수치지도를 중첩하여 생성한 학습 데이터

의 일부를 나타낸다. Case 1의 경우 건물의 RGB와 NDSM 밴드별 평균값은 136.877, 130.482, 137.872, 14.351이며, 도로는 134.314, 133.811, 132.660, 0.500이다. 또한, Case 2의 경우 건물의 RGB와 NDSM 밴드별 평균값은 153.364, 138.492, 125.493, 10.052이며, 식생은 159.573, 144.765, 124.750, 0.188이다. 두 가지 모두 Table 5와 유사하게 색상 정보가 비슷한 영역대에 존재하는 것을 알 수 있으나, NDSM을 통해 정규화된 높이 정보가 추가되었기 때문에 객체를 구별할 수 있는 특징이 추가된 것을 알 수 있었다.

3.4 머신러닝을 이용한 도로, 건물, 식생 분류

구축된 학습 데이터를 이용하여 실감정사영상의 RGB 밴드를 이용하는 경우와 NDSM을 추가하여 밴드를 퓨전한 경우에 대해 SVM과 RF의 머신러닝 기법을 적용하여 실험 데이터 전체를 이용하여 객체를 분류한 후, 분류정확도에 대한 검증을 수행하였다.

분류정확도에 대한 검증은 평가 데이터 전체를 원본 수치지도와 비교하여 각 기법에 대하여 전체정확도, 원본 데이터와 분류 정확도의 척도를 나타내는 생산자 정확도와 분류된 데이터 중 실제 원본 데이터와 일치하는 척도를 나타내는 사용자 정확도와 Kappa 계수를 사용하였다. Kappa 계수란 두 데이터 간의 측정 범주 값에 대한 일치도를 나타내는 방법으로 Eq. 9와 같이 계산하며 Kappa 계수 값이 클수록 높은 일치도로 판단한다(Han, 2016).

$$K = \frac{P_0 - P_C}{1 - P_C} \tag{9}$$

where, K is a kappa coefficient, P_0 is the relative observed agreement among raters, P_C is the hypothetical probability of chance agreement, using the observed data to calculate the probabilities of each observer randomly seeing each category.

3.4.1 SVM의 분류정확도

Table 7은 SVM 기법을 이용하여 RGB 밴드를 학습하고 도로, 건물, 식생을 분류한 결과를 나타내고, Table 8은 동일한 SVM 기법을 밴드 퓨전을 수행한 데이터를 학습하고 도로, 건물, 식생을 분류한 결과값을 나타낸다.

Table 7에 나타난 것과 같이 SVM 기법으로 RGB 밴드만을 이용하여 도로, 건물, 식생을 분류한 경우 Kappa 계수값은 0.459로 낮은 일치도를 보였다. 이를 좀 더 자세히 살펴보면 도로 객체 수가 19개이나 18개의 오분류가 발생하였으며, 건물은 309개 중에서 6개의 오분류가 발생하였다. 또한 식생 객체 수

가 21개이나 7개의 오분류가 발생하여 전반적으로 분류 정확도가 낮게 나타났다.

Table 7. Classification of SVM using RGB band

SVM	Reference data			Number of data
	Road	Building	Vegetation	
Road	1	2	0	3
Building	18	303	7	328
Vegetation	0	4	14	18
Number of data	19	309	21	349
Accuracy	0.911		Kappa	0.459
	Producer's accuracy		User's accuracy	
Road	5.263 %		33.333 %	
Building	98.058 %		92.378 %	
Vegetation	66.667 %		77.778 %	

이에 반해 실감정사영상의 RGB 밴드에 높이정보를 가지고 있는 NDSM 밴드를 추가하여 밴드 퓨전을 수행한 데이터를 학습하고 SVM 기법을 통해 객체를 분류한 경우는 Table 8에 나타난 것과 같이 Kappa 계수가 0.914로 분류정확도가 높은 것을 알 수 있다. 특히, 오분류가 심한 도로의 분류 정확도가 크게 개선되고 건물, 식생의 오분류도 개선된 것을 확인할 수 있다.

Table 8. Classification of SVM using band fusion

SVM	Reference data			Number of data
	Road	Building	Vegetation	
Road	18	0	0	18
Building	1	308	4	313
Vegetation	0	1	17	18
Number of data	19	309	21	349
Accuracy	0.983		Kappa	0.914
	Producer's accuracy		User's accuracy	
Road	94.737 %		100 %	
Building	99.676 %		98.403 %	
Vegetation	80.952 %		94.444 %	

3.4.2 RF의 분류정확도

Table 9는 RGB 밴드를 학습하고 도로, 건물, 식생을 분류한 결과를 나타내고, Kappa 계수값은 0.687로 나타나 SVM을 이용한 방법보다는 다소 높은 분류정확도를 보였다. 이를 좀 더 자세히 살펴보면, RF는 SVM에 비해 도로를 오분류한 경우가 1개, 건물을 오분류한 경우가 2개로 분류정확도가 높은 것을 알

수 있었고 식생은 21개 중에서 16개를 오분류하여 식생을 잘 구분하지 못한 것을 알 수 있었다. 오분류는 건물의 옥상면이 녹색인 경우 식생과 색상값이 매우 유사하여 발생하였다.

Table 9. Classification of RF using RGB band

RF	Reference data			Number of data
	Road	Building	Vegetation	
Road	18	0	0	18
Building	1	307	16	324
Vegetation	0	2	5	7
Number of data	19	309	21	349
Accuracy	0.946		Kappa	0.687
	Producer's accuracy		User's accuracy	
Road	94.737 %		100 %	
Building	99.353 %		94.753 %	
Vegetation	23.810 %		71.429 %	

이에 반해 Table 10과 같이 밴드 퓨전을 수행한 데이터를 학습하고 RF 기법을 통해 도로, 건물, 식생을 분류한 경우 Kappa 계수가 0.870으로 나타나 RGB 밴드만을 사용할 때 보다 분류정확도가 향상되었다. 특히, 오분류가 심했던 식생의 분류를 크게 개선한 것을 알 수 있었다.

도로, 건물, 식생을 분류하기 위해서 밴드 퓨전한 데이터를 이용하여 머신러닝 기법인 RF 기법과 SVM 기법을 적용하였을 경우 Kappa 계수값이 각각 0.870과 0.914로 나타나 85% 이상의 분류정확도가 나타난 것을 알 수 있었다. 이와 같이 같은 데이터 임에 불구하고 각 기법의 특징이 달라 진단이나 예측의 정확도가 차이가 날 수 있다(Park and Bae, 2019).

Table 10. Classification of RF using band fusion

RF	Reference data			Number of data
	Road	Building	Vegetation	
Road	18	1	0	19
Building	1	307	6	314
Vegetation	0	1	15	16
Number of data	19	309	21	349
Accuracy	0.974		Kappa	0.870
	Producer's accuracy		User's accuracy	
Road	94.737 %		94.737 %	
Building	99.353 %		97.771 %	
Vegetation	71.429 %		93.750 %	

3.4.3 결과 비교

Fig. 13은 SVM 기법을 통해 RGB 밴드와 NDSM을 추가하여 밴드를 퓨전한 경우를 이용하여 실험 데이터 전체를 분류한 결과 중 도로 클래스만 추출한 것이다. Fig. 13(a)는 수치지도 원본 데이터이며, Fig. 13(b)는 RGB 밴드, Fig. 13(c)는 밴드 퓨전을 수행한 결과를 나타낸다. RGB 밴드의 경우 도로의 대부분 지역에서 오분류가 나타난 반면 밴드 퓨전을 수행한 경우 정확도가 크게 향상된 것을 확인할 수 있다.

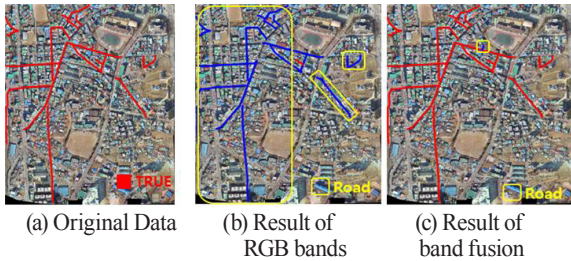


Fig. 13. Road classification using SVM

Fig. 14는 SVM 기법을 통해 RGB 밴드와 NDSM을 추가하여 밴드를 퓨전한 경우를 이용하여 실험 데이터 전체를 분류한 결과 중 건물 클래스만 추출한 것을 나타낸다. Fig. 14(a)는 수치지도 원본 데이터이며, Fig. 14(b)는 RGB 밴드, Fig. 14(c)는 밴드 퓨전을 수행한 결과이다. RGB 밴드의 경우 도로 및 식생을 건물로 분류하는 것을 확인할 수 있으며, 밴드 퓨전을 수행한 경우 도로를 건물로 추정하는 현상을 개선할 수 있었다.





Fig. 14. Building classification using SVM

Fig. 15는 RF 기법을 통해 RGB 밴드와 NDSM을 추가하여 밴드를 퓨전한 경우를 이용하여 실험 데이터 전체를 분류한 결과 중 식생 클래스만 추출한 것을 나타낸다. Fig. 15(a)는 수치지도 원본 데이터이며, Fig. 15(b)는 RGB 밴드, Fig. 15(c)는 밴드 퓨전을 수행한 결과이다. RGB 밴드의 경우 오분류가 심한 것을 확인할 수 있으며, 밴드를 퓨전할 경우 분류의 정확도가 크게 향상된 것을 확인할 수 있다.



(a) Original Data (b) Result of RGB bands (c) Result of band fusion

Fig. 15. Vegetation classification using RF

4. 결론

본 연구는 드론 영상에서 포인트 클라우드와 실감정사영상 데이터를 만들고 이로부터 도로, 건물, 식생을 머신러닝 기법인 SVM과 RF를 적용하여 분류하는 것으로 다음과 같은 결론을 도출하였다.

첫째, 드론 영상에서 도로, 건물, 식생을 머신러닝을 이용하여 분류하기 위해서 포인트 클라우드를 만들고 가공하여 NDSM을 생성한 후 실감정사영상과 밴드 퓨전을 수행한 후 기존의 수치지도를 활용하여 학습 데이터를 구축하는 새로운 방법론을 제시하였다.

둘째, RGB 밴드만을 갖고 있는 실감정사영상을 사용하였을 경우 색상을 뚜렷하게 구분할 수 있는 도로, 건물, 식생의 분류가 가능하였지만 색상이 유사한 경우에는 분류가 잘 되지 않는 한계를 확인할 수 있었으며 이를 보완하기 위해서 객체에 대한 높이값의 정보를 갖고 있는 NDSM을 사용하는 것이 효율적이었다.

셋째, 도로, 건물, 식생의 객체분류를 위해서 머신러닝 기법을 적용하기 위해서 기 구축된 1:5,000 수치지도를 활용하여 학습 데이터를 구축함으로써 수작업으로 학습 데이터를 구축하는 불편함을 해소할 수 있었다.

넷째, 실감정사영상과 NDSM을 밴드 퓨전한 후 SVM과 RF 기법을 이용하여 도로, 건물, 식생을 분류하였을 때, SVM 기법이 RF 기법보다 비교적 식생을 잘 추정하였으며, 높은 kappa 계수를 나타내었다. 또한, 두 기법 모두 객체를 구별할 수 있는 특징이 추가됨으로서 정확도 향상에 크게 기여하였다. 그러나, 높은 식생이 밀집된 지역과 건물의 옥상면이 녹색인 경우는 색상과 높이값이 매우 유사하여 분류의 한계가 있었다.

향후 머신러닝 기법인 SVM 및 RF는 딥러닝을 적용하기 전에 학습 데이터를 스스로 구축하여 객체를 분류할 때 주로 활용되는 방법이므로 다양한 학습 데이터가 구축될 경우 딥러닝 기법을 적용하여 객체분류를 수행하고 이를 비교분석하는 연구가 필요하다고 사료된다.

감사의 글

이 논문은 2019년 정부(국토교통부)의 재원으로 공간정보 융복합 핵심인재 양성사업의 지원을 받아 수행된 연구임 (2019-02-01).

References

- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., and Lloyd, S. (2017), Quantum machine learning. *Nature*. Vol. 549, pp. 195–202.
- Cho, D.Y. and Kim, E.M. (2010), Extraction of spatial information of tree using LIDAR data in urban area. *The Journal of Korean Society for Geospatial Information Science*, Vol. 18, No. 4, pp. 11–20. (in Korean with English abstract)
- Choi, S.P., Yang, I.T., and Cong, J.H. (2002), Evaluation of horizontal position accuracy of facilities in digital map. *The Journal of Korean Society for Geospatial Information Science*, Vol. 10, No. 4, pp. 95–103. (in Korean with English abstract)
- Daneshtalab, S. and Rastiveis, H. (2017), Decision level fusion of orthophoto and LIDAR data using confusion matrix information for land cover classification, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-4/W4, 2017 Tehran's Joint ISPRS Conferences of GI Research, SMPR and EOEC 2017*, 7–10 October, Tehran, Iran, pp. 59–64.
- 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.
- Han, S.H. (2016), *Introduction to Photogrammetry and Remote Sensing*, Goomibook, Seoul.
- Hong, I.Y. (2017), Land use classification using LBSN(Location-Based Social Network) data and machine learning technique, *Journal of the Korean Cartographic Association*, Vol. 17, No. 3, pp. 59-67. (in Korean with English abstract)
- Hong, S.P. and Kim, E.M. (2018), Classification of 3D road objects using machine learning. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 36, No. 6, pp. 535–544. (in Korean with English abstract)
- Jeong, D.H. and Jeong, W.T. (2019), Prediction of rolling noise based on machine learning technique using rail surface roughness data, *Journal of the Korean Society for Railway*, Vol. 22, No. 3, pp. 209-217. (in Korean with English abstract)
- Jo, W.H., Lim, Y.H., 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)
- Jónsson, Sigurbjörn. (2019), *RGB and multispectral UAV image classification of agricultural fields using a machine learning algorithm*, Master's thesis, Lund University, Lund, Sweden, 88p.
- Jung, I.G., Sung, J.H., Lee, C.K., Kim, S.C., and Lee, Y.B. (2004), The prediction of spatial variability for soil information in Paddy field, *Journal of Biosystems Engineering*, Vol. 29, No. 1, pp. 65-70. (in Korean with English abstract)
- Kim, G.M. and Choi, J.W. (2018), Detection of cropland in reservoir area by using supervised classification of UAV imagery based on GLCM. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 36, No. 6, pp. 433–442. (in Korean with English abstract)
- Kim, E.M., Cho, H.S., and Park, J.H. (2017), Analysis of applicability of orthophoto using 3D mesh on aerial image with large file size, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 35, No. 3, pp. 155–166. (in Korean with English abstract)
- Kim, J.K., Lee, K.B., and Hong, S.G. (2017), ECG-based biometric authentication using random forest. *Journal of the Institute of Electronics and Information Engineers*, Vol. 54, No. 6, pp. 100-105. (in Korean with English abstract)
- Kwon, S.K., Lee, Y.S., Kim, D.S., and Jung, H.S. (2019), Classification of forest vertical structure using machine learning analysis, *Korean Journal of Remote Sensing*, Vol. 35, No. 2, pp. 229-239. (in Korean with English abstract)
- Lee, G.W. and Yom, J.H. (2018), Design and implementation of web-based automatic preprocessing system of remote sensing imagery for machine learning modeling. *The Journal of Korean Society for Geospatial Information Science*, Vol. 26, No. 1, pp. 61–67. (in Korean with English abstract)
- Liu, D. and Xia, F. (2010), Assessing object-based classification: advantages and limitations, *Remote Sensing*, Vol. 1, No. 4, pp. 187-194.
- Liu, P. (2015), A survey of remote-sensing big data. *Frontiers in*

- Environmental Science*, Vol. 3, No. 45, pp. 1-6.
- Park, G.M. and Bae, Y.C. (2019), Performance comparison of machine learning in the various kind of prediction. *The Journal of the Korea Institute of Electronic Communication Sciences*, Vol. 14, No. 1, pp. 169–178. (in Korean with English abstract)
- Park, H.K. and Lee, D.K. (2019), Disaster prediction and policy simulation for evaluating mitigation effects using machine learning and system dynamics: case study of seasonal drought in gyeonggi province. *Journal of the Korean Society of Hazard Mitigation*, Vol. 19, No. 1, pp. 45–53. (in Korean with English abstract)
- Park, S., Kim, K.J., Lee, J.S., and Lee, S.R. (2011), Red tide prediction using neural network and SVM, *The Institute of Electronics Engineers of Korea-Signal Processing*, Vol. 48, No. 5, pp. 39-45. (in Korean with English abstract)
- Schonberger, J.L. and Frahm, J.M. (2016), Structure-from-motion revisited. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, CVPR, 27-30 June, Las Vegas, USA, pp. 4104-4113.
- Schöpfer, E., Lang, S., and Strobl, J. (2010), Segmentation and object-based image analysis. *Remote sensing of urban and suburban areas*, Vol. 10, pp. 181-192.
- Wang, C. and Li, Z. (2016), Weed recognition using SVM model with fusion height and monocular image features. *Transactions of the Chinese Society of Agricultural Engineering*, Vol. 32, No. 15, pp. 181-192.
- Wikipedia. (2019), Random forest, *Wikimedia Foundation, Inc.*, URL: https://en.wikipedia.org/wiki/Random_forest(last date accessed: 26 June 2019).
- Yamamoto, K., Guo, W., Yoshioka, Y., and Ninomiya, S. (2014). On plant detection of intact tomato fruits using image analysis and machine learning methods. *Sensors*, Vol. 14, No. 7, pp. 12191-12206.
- Yu, B.H., P, H.C., and Lee, S.M. (2019), Improvement of random-forest OBIA algorithm for tree anomaly detection in UAV imagery: Focused on the Birobong-Peak Area of Sobaeksan National Park. *The Korean Society of Environment and Ecology*, 26 April, Wonju, Korea, pp. 54-54.
- Yun, T.G. and Yi, G.S. (2008), Application of random forest algorithm for the decision support system of medical diagnosis with the selection of significant. *The transactions of The Korean Institute of Electrical Engineers*, Vol. 57, No. 6, pp. 1058–1062. (in Korean with English abstract)
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., and Yan, G. (2016), An easy-to-use airborne LiDAR data filtering method based on cloth simulation, *Remote Sensing*, Vol. 8, No. 6, pp. 501.