

Convolutional Neural Networks기반 항공영상 영역분할 및 분류

Aerial Scene Labeling Based on Convolutional Neural Networks

나종필 · 황승준 · 박승제 · 백중환*

한국항공대학교 정보통신공학과

Jong-Pil Na · Seung-Jun Hwang · Seung-Je Park · Joong-Hwan Baek*

Information & Telecommunication Engineering, Korea Aerospace University, Gyeonggi-do 412-791, Korea

[요 약]

항공영상은 디지털 광학 영상 기술의 성장과 무인기(UAV)의 발달로 인하여 영상의 도입 및 공급이 크게 증가하였고, 이러한 항공영상 데이터를 기반으로 지상의 속성 추출, 분류, 변화탐지, 영상 융합, 지도 제작 형태로 활용되고 있다. 특히, 영상분석 및 활용에 있어 딥 러닝 알고리즘은 패턴인식 분야의 한계를 극복하는 새로운 패러다임을 보여주고 있다. 본 논문은 딥 러닝 알고리즘인 ConvNet기반으로 항공영상의 영역분할 및 분류 결과를 통한 더욱더 넓은 범위와 다양한 분야에 적용할 수 있는 가능성을 제시한다. 학습데이터는 도로, 건물, 평지, 숲 총 3000개 4-클래스로 구축하였고 클래스 별로 일정한 패턴을 가지고 있어 특징 벡터맵을 통한 결과가 서로 다르게 나올 수 있다. 본 연구의 알고리즘은 크게 두 가지로 구성 되어 있는데 특징추출은 ConvNet기반으로 2개의 층을 쌓았고, 분류 및 학습과정으로 다층 퍼셉트론과 로지스틱회귀 알고리즘을 활용하여 특징들을 분류 및 학습시켰다.

[Abstract]

Aerial scene is greatly increased by the introduction and supply of the image due to the growth of digital optical imaging technology and development of the UAV. It has been used as the extraction of ground properties, classification, change detection, image fusion and mapping based on the aerial image. In particular, in the image analysis and utilization of deep learning algorithm it has shown a new paradigm to overcome the limitation of the field of pattern recognition. This paper presents the possibility to apply a more wide range and various fields through the segmentation and classification of aerial scene based on the Deep learning(ConvNet). We build 4-classes image database consists of Road, Building, Yard, Forest total 3000. Each of the classes has a certain pattern, the results with feature vector map come out differently. Our system consists of feature extraction, classification and training. Feature extraction is built up of two layers based on ConvNet. And then, it is classified by using the Multilayer perceptron and Logistic regression, the algorithm as a classification process.

Key word : Convolutional neural networks, ConvNet, Deep learning, Image segmentation, Scene labeling.

<http://dx.doi.org/10.12673/jant.2015.19.6.484>



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.

Received 26 October 2015; Revised 25 November 2015
Accepted (Publication) 26 December 2015 (30 December 2015)

*Corresponding Author; Joong-Hwan Baek

Tel: +82-2-300-0125

E-mail: jhbaek@kau.ac.kr

1. 서론

항공영상은 디지털 광학 영상 기술의 성장과 무인기(UAV)의 발달로 인하여 영상의 도입 및 공급이 크게 증가하였고, 이러한 항공영상 데이터를 기반으로 지상의 속성 추출, 분류, 변화탐지, 영상 융합, 지도 제작 형태로 활용되고 있다.

기존의 영상 분석 및 활용에 있어 최근의 기계학습 알고리즘인 딥 러닝(deep learning)은 데이터의 대용량화와 이를 처리할 수 있는 컴퓨팅 파워의 증가로 인하여 기존 패턴인식 분야의 알고리즘들의 한계를 극복하는 새로운 패러다임을 보여주고 있으며, 영상인식뿐만 아니라 음성인식을 비롯한 다양한 패턴인식 분야의 성능향상을 이끄는 중요한 인공지능 알고리즘이다 [1]. 특히, 영상 인식 분야의 딥 러닝은 필기체, 서명 및 표지판 인식을 넘어 사물 및 얼굴 인식 등 많은 분야로 적용되고 있다 [2]-[5]. 다양한 분야로 적용되는 만큼 딥 러닝은 기존의 신경망(neural networks)구조를 유지하면서 다양한 형태로 발전하고 있다[6]. 또한, 영역 분할, 분류 및 레이블링(labeling)을 위하여 ConvNet (Convolutional neural network)과 그래프 기반 영상 분할을 활용하여 이전의 딥 러닝이 갖고 있던 비교적 크기(scale)가 큰 영상에 적용하기 어려운 점을 해결하여 좋은 결과를 볼 수 있다[7]. 하지만, 기존의 딥 러닝에서 사용되는 학습 데이터는 SIFT flow dataset, Barcelona dataset 등과 같이 일반적인 영상들만 포함하고 있어 항공영상에는 적용하기 어렵다.

항공영상 영역 분할(segmentation) 및 분류(classification)는 기존의 이미지 프로세싱 기법인 그래프 기반 영상 분할(segmentation)[9]등과 같은 기법이 주를 이루고 있고, 영상의 특징(feature) 추출은 주로 SURF와 SIFT와 같은 기법들이 사용되고 있으며, 딥 러닝을 적용하기 위하여 많은 시도를 하는 것으로 나타난다[8],[10],[11].

그림 1은 SIFT flow dataset에 그래프 기반 이미지 분할 알고리즘 적용 결과로써 뛰어난 결과를 보여준다[12],[16]. Felzenszwalbs's method는 영상의 모든 엣지(edge)와 그에 인접한 가중치를 정렬하여 분할 하며, SLIC (simple linear iterative clustering)은 k 평균 군집화 방법을 슈퍼픽셀(superpixel)화하여 기존의 그래프 기반 알고리즘의 성능을 높인 것이다.




그림 1. 그래프 기반 이미지 분할
Fig. 1. Graph-based image segmentation using SIFT flow dataset.




그림 2. 항공 영상 이미지 분할
Fig. 2. Image segmentation of aerial scene.

또한, Quick-shift는 Mean-shift 알고리즘을 활용하여 이미지 분할한다. 그림 2는 항공영상에 적용한 결과로써 일반적인 데이터와 달리 좋지 못한 성능을 보여주고 있다. 이는 항공영상의 특성상 일반적인 영상과는 다르게 특징의 분포가 밀집 되어 있어 나타나는 현상이다.

따라서 본 연구는 그래프 기반 영상분할을 사용하지 않고 최근의 딥 러닝 알고리즘을 활용한 항공영상 영역분할 및 분류 결과를 보이며, 딥 러닝에 적용할 수 있는 항공영상 데이터 베이스를 구축한다. 그림 3은 본 연구의 전체 알고리즘으로 항공영상의 일부를 특징추출 후 분류하는 과정으로 전개된다. 특징 추출은 2개의 ConvNet층, 분류는 MLP (multi-layer perceptron)과 LR (logistic regression)으로 형성되어 있다. 그림 4는 학습에 사용한 데이터의 일부분이며, 도로(road) 612개, 건물(building) 1149개, 평지(yard) 589개, 숲(forest) 650개 총 3000개의 학습 데이터를 활용하여 4-클래스로 항공영상의 영역을 분류 하였다.

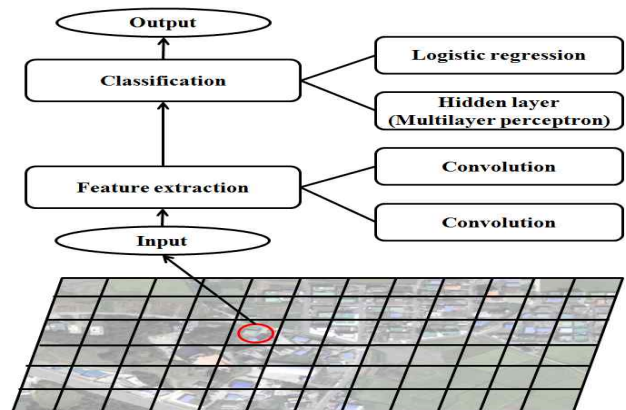


그림 3. 알고리즘 구조도
Fig. 3. Structure of the algorithm.




그림 4. 항공영상 클래스 데이터
Fig. 4. Aerial scene of classes.

II. 인공 신경망 기반 특징추출

2-1 인공 신경망

신경망 또는 인공 신경망은 분류와 예측을 위한 모형이다. 신경망은 뉴런이 상호 연결되어 있고 경험으로부터 학습하는 두뇌의 생물학적 활동의 모형에 기반한다. 신경망은 인간 전문가가 학습하는 방식을 모방한다. 신경망의 학습과 기억특성은 인간의 학습과 기억특성을 닮았으며, 개개의 사례로부터 일반화하는 능력이 있다.

인공신경망의 각각의 노드들은 강도(weights) w 와 바이어스(bias) b 로 연결 되어 있다. 식 (1)과 같이 출력노드는 각각의 입력노드들의 합과 바이어스를 추가한 뒤 선형함수인 시그모이드(sigmoid) 함수를 적용시킨다. 입력층의 값을 $[0,1]$ 사이의 값을 가지는 것이 좋으며, 시그모이드 함수를 적용시켜 출력층의 값도 역시 $[0,1]$ 사이의 값을 가지게 된다.

$$Output = sigmoid(b_j + \sum_{i=1}^n W_{ij}x_i) \quad (1)$$

강도 w 는 랜덤 값으로 초기화 하고 바이어스는 0으로 초기화 한 상태에서 알고리즘을 적용한다. 트레이닝 과정을 통하여 w 와 b 를 업데이트 시켜 입력 데이터에 대한 예측 값을 추정하는 것이 인공신경망 알고리즘이다.

2-2 컨볼루션 뉴럴 네트워크

1) 특징추출 (Feature extraction)

입력데이터의 특징을 추출하는 과정으로 식 (2)와 같이 입력 데이터 x 에 컨볼루션(convolution)을 하여 특징을 구한다. 여기서 k 는 k -th 특징 벡터를 의미하며 1층(layer)는 20개, 2층은 50

개로 구성하였다.




그림 5. 특징 맵
Fig. 5. Feature map.




그림 6. Road의 컨볼루션 결과
Fig. 6. Convolution result of road data.

이러한 과정이 뉴럴 네트워크와 비슷한 구조를 띄고 있는데 시그모이드 함수를 통하여 출력을 구하는 것이 아닌 하이퍼탄젠트(tanh)함수를 사용하여 출력노드 값의 범위를 $[-1, 1]$ 사이의 값으로 나타낸다.

$$h^{k_{ij}} = \tanh((W^{k*}x)_{ij} + b_k) \quad (2)$$

그림 5는 1층의 랜덤으로 형성한 20개의 w 매트릭스 즉, 특징 벡터 맵을 보여준다. 그림 6은 항공 영상 데이터 4개의 클래스 중 도로의 컨볼루션 결과로 서로 다른 특징을 추출하게 된다.

2) 맥스 풀링 (Max pooling)

맥스 풀링은 ConvNet에서 중요한 개념으로써 비선형(non-linear) 다운 샘플링(down sampling) 기법이다. 각 부분 영역에 대해 최대값을 갖게 함으로써 최대값이 아닌 값을 제거 하여 차원수를 감소 시켜 상위 계층에 대한 계산을 줄일 수 있다.

따라서 입력 데이터 $N*M$ 1층을 연산을 수행하면 $k*N/2*M/2$ 로 변환 된다. 맥스 풀링의 방식을 $3*3$ 혹은 그 이상으로 수행하게 되면 더 많은 차원 및 연산량이 감소 하지만 컨볼루션을 활용한 특징값을 그만큼 더 잃게 되어 알고리즘 효율이 오히려 떨어질 수 있다. 본 연구에서는 $2*2$ 맥스 풀링을 선택하여 수행하였다.

III. 신경망 기반 분류 및 학습

3-1 다층 퍼셉트론

다층 퍼셉트론은 단층 신경망의 확장된 형태로 데이터 입력에 따른 출력의 역학 관계를 나타냄으로써 데이터를 분류하는

형태를 가진다[13]. 본 논문의 2장에서 제시한 두 개의 ConvNet층과 한 개의 은닉층을 모두 포함한 입력 데이터 x 와 W, b 의 관계를 식 (3)에서 표현한다. G 는 \tanh 함수 이고, $f(x)$ 는 다음 상위층인 로지스틱 회귀층의 입력으로 활용되며, 편의상 다음 3.2절에서는 $f(x)$ 를 x 로 표현한다.

$$f(x) = G(b^{(3)} + W^{(3)} \cdot G(b^{(2)} + W^{(2)} * G(b^{(1)} + W^{(1)} * x))) \quad (3)$$

3-2 로지스틱 회귀

로지스틱 회귀는 독립변수의 선형결합을 이용하여 사건의 발생 가능성을 예측하는데 사용되는 통계기법이다[14]. 로지스틱 회귀의 목적은 일반적인 회귀 분석의 목표와 동일하게 종속변수와 독립변수간의 관계를 구체적인 함수로 나타내어 향후 예측모델에 사용하는 것이다. 독립변수의 선형 결함으로 종속변수를 설명한다는 관점에서 선형회귀분석과 유사하지만 종속변수가 범주형 데이터를 대상으로 하며 입력데이터가 주어졌을 때 해당데이터의 결과가 특정분류로 나뉘지기 때문에 일종의 분류기법으로도 볼 수 있다.

$$\Pr(Y = i|x, W, b) = \text{softmax}(Wx + b) \quad (4)$$

$$= \frac{e^{W_j x + b_j}}{\sum_j e^{W_j x + b_j}}$$

본 연구에서는 이항형 로지스틱을 확장한 다항형 로지스틱 회귀를 사용하여 식 (4)과 같이 나타내며 여기서 W 는 weights, x 는 데이터, b 는 바이어스이다. 이 결과를 토대로 가장 큰 확률 값을 선택하여 클래스 예측을 하게 된다.

3-3 경사하강법

경사하강법이란 반복적으로 업데이트하면서 지역적인 최소값(local minimum)을 찾는 알고리즘이다. 그래디언트의 특성을 이용하여 어떤 비용함수의 값을 최소화시키기 위한 파라미터 값을 점진적으로 찾는 방법이다.

표 1. 학습 알고리즘

Table 1. Training algorithm.

Want min NLL: $\lambda = 0.13$
Repeat{
$(W', b') = (W, b) - \lambda \frac{\partial}{\partial (W, b)} NLL$
}

최대가능도를 활용하여 회귀 계수 추정하는데 임의의 계수에서 시작하여 해당 계수를 반복적으로 수정해가면서 결과 모델이 개선되는지를 확인한다[15]. 로지스틱회귀를 활용하여 NLL (negative log likelihood) 추정된 뒤 표 1.의 의사코드를 통하여 전체 층의 W, b 를 업데이트한다.

IV. 실험결과 및 분석

4-1 실험환경

학습 데이터와 테스트 데이터는 국토지리정보원에서 항공영상 데이터를 발췌 하였고 영상의 크기는 700*1120 이다. 클래스는 도로, 건물, 평지, 숲 총 4개로 분류하며, 학습 데이터는 그림9와 같이 28*28 크기로 추출 하여 약 4000개의 데이터를 구축하였다. 학습과 테스트에 사용되는 컴퓨터의 CPU는 i7-3770이며, GPU는 GTX760(메모리:2GB) 이다. 주된 알고리즘은 ConvNet을 사용하며, OpenCV와 Theano 라이브러리를 활용하여 GPU 가속 기반 환경으로 구현한다.



그림 7. 데이터 추출 방법

Fig. 7. Data extraction method.

표 2. 층별 파라미터 모양

Table 2. Parameter shape of layers.

Layer #	Position	Shape
Layer_0	input	(1, 1, 28, 28)
	W	(20, 1, 5, 5)
	Conv	(1, 20, 24, 24)
	Maxpooling	(1, 20, 12, 12)
	output	(1, 20, 12, 12)
Layer_1	input	(1, 20, 12, 12)
	W	(50, 20, 5, 5)
	Conv	(1, 50, 8, 8)
	Maxpooling	(1, 50, 4, 4)
	output	(1, 50, 4, 4)
Layer_2	input	(1, 800)
	W	(800, 500)
	output	(1, 500)
Layer_3	input	(1, 500)
	W	(500, 4)
	output	(1, 4)

표 2는 입력 데이터 1개 당 전체 층의 파라미터(parameter) 모양(shape)을 나타내며, 본 연구의 실험은 입력 데이터 500개 단위로 진행하였다.

4-2 실험결과

그림 8은 테스트 데이터가 모두 포함된 상태에서 트레이닝 한 결과를 나타낸다. 트레이닝 결과는 에러율이 0.00%까지 수렴하며 4개층의 W,b가 학습되어 모든 클래스 영역을 분할하는 것을 볼 수 있다. 또한, 모든 학습 데이터가 포함된 테스트 영상 의 경우 트레이닝 하여 높은 정확도로 분류 할 수 있다는 것을 보여준다.



그림 8. 트레이닝 결과
Fig. 8. Result of training.



그림 9. 테스트 결과
Fig. 9. Result of test.




그림 10. 테스트 결과
Fig. 10. Result of test.

표 3. 클래스 별 정확도

Table 3. Class accuracy rate.

Fig. #	Class accuracy rate(%)				
	Road	Building	Yard	Forest	Average
Fig. 9	63.22	82.80	84.83	89.36	80.05
Fig. 10	84.24	91.71	80.41	99.80	89.04

표 3은 각각의 클래스 별 정확도와 그의 평균치를 나타내는데 상대적으로 빌딩과 숲의 정확도가 높게 나오며 특히 숲의 정확도가 평균 95% 이상으로 나온다. 이는 숲 영역의 패턴이 다른 클래스의 패턴보다 일정하게 학습되어 나오는 결과이며 빌딩클래스도 도로와 평지보다는 유사한 패턴을 가지고 있음을 보여준다.

도로와 평지 클래스의 경우 학습 데이터 생성 시 서로의 경계가 명확하지 않아 성능이 떨어짐을 알 수 있다. 또한 도로의 경우 서로 다른 방향성을 가지는 패턴들을 가지고 있으며, 평지의 경우 도로와 건물 사이, 숲과 건물 사이, 건물과 건물 사이 등 다양한 패턴을 가지고 있어 성능이 상대적으로 좋지 않게 나타난다.

1) 알고리즘 성능비교

그림 11은 트레이닝 횟수당 알고리즘에 따른 트레이닝 에러를 나타낸다. LR은 본 연구의 4번째 층에 해당하는 알고리즘으로써 단 한 개의 층만을 구성하여 학습한 것으로 많은 반복 처리에도 불구하고 에러율이 쉽게 수렴하지 않는 것으로 나타난다. MLP는 LR 하단에 하나의 은닉층을 추가하여 나타난 결과이며, CNN(ConvNet)은 MLP 하단의 두 개의 컨볼루션층을 추가하여 나온 에러율이다.




그림 11. 트레이닝 횟수당 에러율
 Fig. 11. Training error per number of training.

더욱더 많은 층의 형성으로 w,b의 파라미터 수가 증가하여 적은 트레이닝 횟수로 에러율이 빠르게 수렴하는 것을 알 수 있다.

그림 12는 트레이닝 시간당 알고리즘에 따른 트레이닝 에러를 나타낸다. CNN과 MLP의 경우 두 알고리즘 각각 에러가 0%로 수렴하여 LR에 비하여 높은 성능을 보이지만, MLP는 수렴하는 과정 중 갑작스럽게 증가하는 현상이 발생한다. 반면, CNN의 경우 에러율이 10% 미만으로 감소했을 때 출렁거림 없이 일정하게 수렴하는 것을 보여준다.




그림 12. 트레이닝 시간당 에러율
 Fig. 12. Training Error per training time.

표 4. 은닉층 구조

Table 4. Structure of hidden layer.

Structure of hidden layer					
Layer	Input	Hidden layer		Ouput	
CNN	800	500		4	
CNN+HL1	800	500	100	4	
CNN+HL2	800	500	300 100	4	
CNN+HL3	800	1000	500		4
CNN+HL4	800	1000	500	100	4

CNN 알고리즘 구조에서 은닉층의 구조를 변경 및 추가하여 실험하였다. 이는 딥 러닝의 과적합 (over fitting)문제와 특징 노드들의 수의 적합함을 확인하기 위함이다. 표 4에서 변경된 구조를 나타내고 있는데 HL1은 하나의 은닉층을 더 추가한 것이고, HL2는 HL1에 또 하나의 은닉층을 추가한 것이다. HL3, HL4도 마찬가지로 은닉층을 차례로 추가한 것인데 앞선 HL1, HL2와는 달리 노드의 수를 먼저 확장한 뒤에 줄여 나가는 구조를 가지고 있다.

그림 9와 10의 실험환경을 동일하게 하고 은닉층의 구조를 변경하여 정확도를 표 5, 6에 나타낸다. 노드를 확장한 형태인 HL3,4는 평균 정확도가 다소 감소하여 과적합 문제를 가지고 있으며, HL1,2는 약간의 평균 정확도가 증가함을 보인다. 건물과 숲클래스는 도로와 평지에 비하여 높은 정확도를 유지하면서 은닉층의 증가에 의해 성능도 증가하였다.

은닉층을 추가하는 것은 정확도 향상에 도움이 되지만 기존의 노드를 확장한 형태는 오히려 성능을 감소시킨다. 또한 다층구조와 많은 노드를 가지고 있는 알고리즘은 더욱더 많은 리소스를 필요로 하게 되므로 실험환경을 충분히 고려해야 한다.

그림 12는 학습데이터 3000개 기반 은닉층 구조에 따른 트레이닝 횟수당 에러율을 나타낸다. 은닉층의 구조가 HL2가 되었을 때 조금더 안정적으로 빠르게 수렴하는 것을 볼 수 있다.

표 5. 그림 9의 정확도

Table 5. Class accuracy rate of Image 9.

Class accuracy rate of image 9					
	Road	Building	Yard	Forest	Average
CNN	63.22%	82.80%	84.83%	89.36%	80.05%
CNN+HL1	59.77%	83.97%	85.35%	91.49%	80.15%
CNN+HL2	62.07%	81.05%	87.15%	91.49%	80.44%
CNN+HL3	62.07%	80.17%	84.83%	90.43%	79.38%
CNN+HL4	60.92%	82.51%	84.83%	81.49%	77.44%

표 6. 그림 10의 정확도

Table 6. Class accuracy rate of Image 10.

Class accuracy rate of image 10					
	Road	Building	Yard	Forest	Average
CNN	84.24%	91.71%	80.41%	99.80%	89.04%
CNN+HL1	85.71%	90.73%	78.35%	99.80%	88.65%
CNN+HL2	85.71%	89.76%	82.47%	99.80%	89.44%
CNN+HL3	85.71%	91.71%	77.42%	99.80%	88.66%
CNN+HL4	85.71%	92.68%	80.41%	100.00%	89.70%




그림 12. 트레이닝 횟수당 에러율
 Fig. 12. Training error per number of training.

V. 결론

본 논문에서는 콘볼루션 뉴럴 네트워크 (convolutional neural network) 기반 항공 영상 영역 분할 및 분류 방법을 제안한다. 국토지리정보원의 항공 영상 데이터를 바탕으로 도로, 빌딩, 평지, 숲 총 4개의 클래스로 분류 하였다.

먼저 학습 데이터 구축에 있어 국내의 일부 지역의 항공 영상을 선정하여 700*1120 크기로 추출 한 후 28*28 크기로 세분화 하여 학습 데이터 총 3000개를 생성하였다. 일정 크기로 구분한 학습 데이터는 각각의 클래스 별로 일정한 패턴을 가지고 있어 특징 벡터 맵을 통한 콘볼루션 결과가 서로 다르게 나올 수 있다.

본 연구의 알고리즘은 크게 두 가지로 나눌 수 있다. 먼저 항공 영상의 특징 추출은 ConvNet 기반으로 2개의 층을 쌓아 영상으로부터 클래스 별로 서로 다른 특징들을 추출하였다. 다음은 분류 및 학습의 과정으로 다층 퍼셉트론과 로지스틱회귀 알고리즘을 활용하여 특징들을 분류하였고, 경사 하강법을 이용하여 전체 층들의 가중치와 바이어스를 업데이트 하여 학습시켰다.

실험결과로 비추어 볼 때 총 4개의 클래스는 각각 서로 다른 패턴을 가지고 있어 학습을 통한 분류가 가능하다는 것을 볼 수 있으며, 본 연구에서 제시한 4개의 클래스가 아닌 5, 6개 그 이상으로 분류 할 수 있다. 또한 반대로 특정 지역만의 데이터를 활용하여 숲(forest)과 숲이 아닌 지역(non-forest) 형태로 구분하여 정확도를 높일 수 있다. 반면에 도로와 평지는 다른 클래스에 비하여 영상의 특성상 서로 교차하는 부분이 많아 패턴이 조금은 다르게 나오지만 더욱더 많은 학습 데이터를 활용하여 극복 할 수 있다.

이전의 딥 러닝은 500*500 이하의 일정한 크기의 데이터를 학습 시켜 인식 하였고, 현재의 딥 러닝은 GPU가속 및 자원의 증가로 점차 큰 스케일의 영상에 적용한 많은 연구 논문들이 나오고 있다. 하지만 일반영상이 아닌 기본적으로 데이터의 크기가 큰 항공 영상 데이터를 다룬 연구 논문은 소수에 그친다.

따라서 본 논문은 항공 영상 데이터베이스 구축하고 딥 러닝을 활용한 영상 분할 및 분류의 가능성을 제안하며 이를 확장시킨다면 더욱더 넓은 범위의 항공 영역을 분류 할 수 있을 것이다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업 2015-B03, “실감형 3D 비디오 서비스를 위한 입체 오디오 콘텐츠 개발” 지원에 의함.

참고 문헌

- [1] C. H. Yeol and M. Y. Hong, “Introduction and key issues of deep learning,” *Korea Information Processing Society*, Vol. 22, No. 1, pp. 7-21, 2015.
- [2] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278-2324, Nov. 1998.
- [3] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Advances in Neural Information Processing Systems*, pp. 1097-1105, 2012.
- [4] C. Zhang, Cha, and Z. Zhang, “Improving multiview face detection with multi-task deep convolutional neural networks,” in *Applications of Computer Vision, IEEE Conference on, Steamboat Springs, CO*, pp. 1036-1041, 2014.
- [5] D. Ciresan, U. Meier, and J. Schmidhuber, “Multi-column deep neural networks for image classification,” in *IEEE Winter Conference on Computer Vision and Pattern Recognition*, Providence: RI, pp. 3642-3649, 2012.
- [6] L. Deng, D. Yu, “Deep learning: methods and applications,” *Foundations and Trends in Signal Processing*, Vol. 7, No. 3-4, pp. 197-387, 2014.
- [7] C. Farabet, C. Couprie, L. Najman, and Y. LeCun, “Learning hierarchical features for scene labeling,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35 No. 8, pp. 1915-1929, 2013.
- [8] A. M. Cheriyyadat, “Unsupervised feature learning for aerial scene classification,” *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 52, No. 1, pp. 439-451, 2014.
- [9] I. K. Kim, S. J. Hwang, J. P. Na, S. J. Park, and J. H. Baek, “Super-pixel-based segmentation and classification for UAV image,” *The Journal of Korea Navigation Institute*, Vol. 18, No. 2, pp. 151-157, Apr. 2014.
- [10] H. Bay, A. Ess, T. Tuytelaars, and L. V. Gool, “Speeded up

robust features (SURF),” *Computer Vision and Image Understanding*, Vol. 110, No. 3, pp. 346-359, 2007.

[11] D. G. Lowe, “Object recognition from local scale-invariant features,” in *The Proceedings of the Seventh IEEE International Conference on*, Kerkyra: Greece, Vol. 2, pp. 1150-1157, 1999.

[12] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, “Slic superpixels,” EPFL-REPORT-149300, June, 2010.

[13] M. W. Gardner, and S. R. Dorling, “Artificial neural networks (the multilayer perceptron)—a review of applications in the

atmospheric Sciences,” *Atmospheric Environment*, Vol. 32, No. 14, pp. 2627-2636, 1998.

[14] D. R. Cox, “The regression analysis of binary sequences,” *Journal of the Royal Statistical Society. Series B (Methodological)*, Vol. 20, No. 2, pp. 215-242, 1958.

[15] D. W. Hosmer, S. Lemeshow, E. D. Cook, *Applied Logistic Regression*, 2nd edition, New York, NY: John Wiley & Sons, 2000.

[16] P. F. Felzenszwalb, and D. P. Huttenlocher, “Efficient graph-based image segmentation,” *International Journal of Computer Vision*, Vol. 59, No. 2, pp. 167-181, 2004.



나 종 필 (Jong-Pil Na)

2013년 8월 : 한국항공대학교 정보통신공학 (공학사)
 2015년 8월 : 한국항공대학교 정보통신공학 (공학석사)
 ※ 관심분야 : 영상처리, 물체 추적



황 승 준 (Seung-Jun Hwang)

2012년 2월 : 한국항공대학교 정보통신공학 (공학사)
 2014년 2월 : 한국항공대학교 정보통신공학 (공학석사)
 2014년 3월 ~ 현재 : 한국항공대학교 정보통신공학 박사과정
 ※ 관심분야 : 영상처리, 패턴인식



박 승 제 (Seung-Je Park)

2014년 2월 : 한국항공대학교 정보통신공학과 (공학사)
 2014년 3월 ~ 현재 : 한국항공대학교 정보통신공학 석사과정
 ※ 관심분야 : 영상처리



백 중 환 (Joong-Hwan Baek)

1981년 2월 : 한국항공대학교 항공통신공학 졸업(공학사)
 1987년 7월 : 오클라호마주립 대학원 전기 및 컴퓨터공학 (공학석사)
 1991년 7월 : 오클라호마주립대학원 전기 및 컴퓨터공학 (공학박사)
 1992년 ~ 현재 : 한국항공대학교 항공전자 및 정보 통신공학부 교수
 ※ 관심분야 : 영상처리, 패턴인식, 영상압축, 멀티미디어