

고해상도 영상의 분류결과 개선을 위한 최적의 Shape-Size Index 추출에 관한 연구

한유경 · 김혜진 · 최재완 · 김용일[†]

서울대학교 공과대학 건설환경공학부

A Study on Optimal Shape-Size Index Extraction for Classification of High Resolution Satellite Imagery

You Kyung Han · Hye Jin Kim · Jae Wan Choi · Yong Il Kim[†]

Department of Civil&Environmental Engineering, Seoul National University

Abstract : High spatial resolution satellite image classification has a limitation when only using the spectral information due to the complex spatial arrangement of features and spectral heterogeneity within each class. Therefore, the extraction of the spatial information is one of the most important steps in high resolution satellite image classification. This study proposes a new spatial feature extraction method, named SSI(Shape-Size Index). SSI uses a simple region-growing based image segmentation and allocates spatial property value in each segment. The extracted feature is integrated with spectral bands to improve overall classification accuracy. The classification is achieved by applying a SVM(Support Vector Machines) classifier. In order to evaluate the proposed feature extraction method, KOMPSAT-2 and QuickBird-2 data are used for experiments. It is demonstrated that proposed SSI algorithm leads to a notable increase in classification accuracy.

Key Words : Classification Accuracy, High Resolution Satellite Image, Spatial Feature Extraction, SSI(Shape-Size Index).

요약 : 고해상도 위성영상이 갖는 공간 객체의 복잡성과 다양성에 의해 기존 중·저해상도 영상에서 사용하던 분류 방식을 고해상도 영상에 그대로 적용하기에는 한계가 있다. 이러한 문제를 극복하기 위하여 영상의 공간적인 특성을 추가적으로 추출하여 분광정보와 결합하여 분류를 수행하는 방식의 연구가 진행되고 있다. 본 연구의 목적은 고해상도 영상의 분류정확도를 개선하기 위하여 새로운 공간 객체(spatial feature)인 SSI(Shape-Size Index)를 제안하는데 있다. SSI feature는 영역 확장(Region Growing) 기반의 영상 분할(Image Segmentation)을 수행한 후, 세그먼트 내에 공간 속성값을 할당하여 공간정보를 추출한다. 추출된 공간정보를 고해상도 영상의 다중분광 밴드와 결합하여 Support Vector Machine(SVM)을 이용한 분류를 수행하였다. SSI를 구성하는데 필요한 두 매개변수인 분할변수와 가중치변수의 최적값을 얻기 위해서 고해상도 위성영상인 KOMPSAT-2와 QuickBird-2에 반복적으로 적용하였다. 결과적으로 고해상도 영상의 공간특성을 표현하는데 적합한 매개변수를 통하여 도출된 SSI와 고해상도 분광 밴드를 결합하여 분류를 수행한 결과가 분광밴드만을 이용하여 분류를 수행한 결과에 비해 높은 분류정확도를 도출함을 확인하였다.

접수일(2009년 4월 11일), 수정일(1차 : 2009년 4월 22일), 게재확정일(2009년 4월 22일).

[†]교신저자: 김용일(yik@snu.ac.kr)

1. 서 론

고해상도 위성영상을 이용한 기술은 종래의 지상측량 및 항공사진 측량에 비해 광역지역을 빠른 시간에 효과적으로 처리할 수 있으며 비용이 저렴하고 주기적인 데이터 획득이 가능하기 때문에 수치지도의 제작 및 개선, 변화탐지 등의 분야에서 장점을 가진다. 특히 고해상도 위성 영상을 이용한 분류(classification)를 수행할 경우, 기존 중·저해상도의 영상에서는 불가능했던 도시 지역이나 식생의 종류 구별과 같은 세부지역에 대한 처리, 대축척 분류지도의 개선 등이 가능하다.

그러나 고해상도 위성영상에 존재하는 공간 객체의 복잡성 및 다양성 때문에 기존의 중·저해상도 영상에서 사용하던 방식인 최소거리(minimum distance), 최대우도(maximum likelihood) 분류 등과 같이 분광정보(spectral information)만을 토대로 분류를 수행하는 방법을 그대로 적용하기에는 무리가 있다(Jenson, 1996, Davis 등, 2002). 이러한 한계를 극복하기 위해서는 분광 정보뿐만 아니라 새로운 정보를 추가적으로 추출하거나 다른 방법을 혼합하여 분류를 수행하여야 한다(Myint 등, 2004). 특히 고해상도 영상의 공간적 특성인 spatial feature를 추출하여 분광정보와 혼합하여 분류를 수행하는 것이 분류 결과를 개선하는데 도움을 줄 수 있다고 알려져 있다(Dell' Acqua 등, 2004). 일반적으로 GLCM(Gray Level Co-occurrence Matrix)을 이용한 텍스쳐 정보나(Puissant 등, 2005) 중심화소와 주변화소의 관계를 이용한 PSI(Pixel Shape Index) feature를 추출한 후(Zhang, 2006), 고해상도 영상의 다중분광밴드와 결합하여 분류를 수행한다. 하지만 GLCM의 통계값은 윈도우기반에 의한 단점이 나타나며 PSI의 경우에는 표현이 불가능한 객체가 존재하는 단점이 있다(Hodgson, 1998).

본 논문에서는 기존 방식이 가지는 단점에 착안하여 새로운 spatial feature인 SSI(Shape-Size Index)를 추출하여 고해상도 영상의 분류정확도를 개선하고자 한다. SSI는 이웃화소 간에 같은 세그먼트로 묶어주는 기준인 분할변수와 객체의 모양과 크기의 비중을 결정할 수 있는 가중치변수로 구성된다. 반복적인 실험을 통하여 최적의 매개변수를 구하고 그들의 관계를 규명함으로써 SSI 알고리즘의 일반화를 이루고자 하였다. 추출

된 SSI feature를 분광 밴드와 결합하여 SVM(Support Vector Machine) 분류자를 이용하여 분류를 수행한 결과를 단순히 고해상도의 분광정보만을 이용하여 생성한 분류 결과와의 비교평가를 통해 제안한 알고리즘이 갖는 우수성을 평가해 보고자 하였다.

2. SSI feature 추출 방법

본 연구에서는 고해상도 영상의 공간특징을 간단하면서도 효율적으로 표현할 수 있는 feature인 SSI를 추출한다. 알고리즘은 크게 3 단계로 구성된다. 전처리 단계, 영상분할 단계, 그리고 속성값 할당 단계를 거쳐서 결과적으로 최종 SSI feature를 생성할 수 있다(Fig. 1).

1) 전처리 단계

SSI 알고리즘을 적용하기 위해서는 고해상도 멀티스펙트럴 영상을 흑백 영상으로 변환시켜주는 과정이 필요하다. 본 논문에서는 주성분분석을 통해 정보의 손실을 최소화한 주성분 제 1요소를 추출하여 알고리즘을 적용하였다. 추출된 첫 번째 주성분영상을 0에서 255까지의 범위로 변환하는 정규화(normalization)과정을 거친다. 자동차나 미소 건물과 같은 객체는 분류 대상에서 제외되므로, 이러한 노이즈를 제거하기 위하여 중앙값 필터를 적용하였다. 작은 객체에 대한 영향을 줄이기 위한 목적으로 원영상의 변형을 최소한으로 하는 3×3 크기

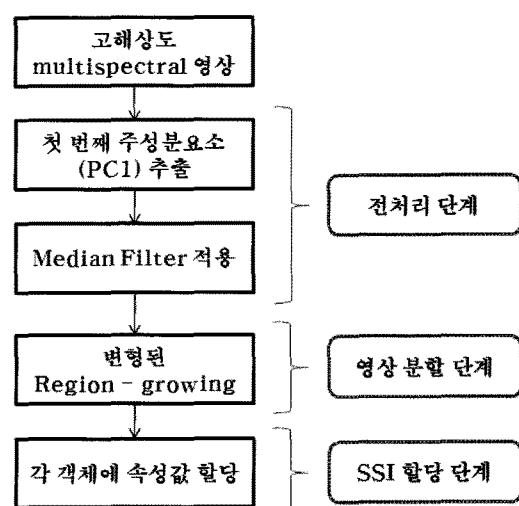


Fig. 1. Flow chart of whole SSI extraction algorithm.

의 필터를 설정하여 첫 번째 주성분영상에 적용하였다.

2) 영상 분할 단계

전처리 과정을 수행한 대상 영상을 화소의 밝기값이 유사한 동질지역을 하나의 세그먼트로 결합하는 region-growing 기반의 영상 분할을 수행하였다. 기존의 region-growing 기법은 초기 위치를 지정해주면 그 점을 중심으로 주변 화소를 탐색하여 화소값의 차이를 임계치와 비교를 통하여 확장해 나간다(Fu 등, 1981). 본 논문에서는 전체 영상에 대한 분할을 수행하기 위해서 초기점을 모든 화소에 대하여 순차적으로 할당하는 방식으로 알고리즘을 변형하였다. 또한 영역의 중복을 피하기 위하여 이미 분할 세그먼트로 할당된 화소는 초기점 및 새로운 세그먼트의 할당에서 제외되는 방식으로, 전체 영상에 대한 분할을 수행하였다.

세그먼트 영역을 확장하기 위해서는 중심화소와 주변 화소의 화소값 비교를 위한 임계치인 분할변수가 필요하다. 주변화소와 중심화소의 차이가 분할변수보다 작으면 같은 영역으로 할당되고 동시에 중심화소와의 평균을 구하여 새로운 중심화소 값이 생성된다. 새로 생성된 중심화소 값은 다음 이웃화소와 비교대상이 된다.

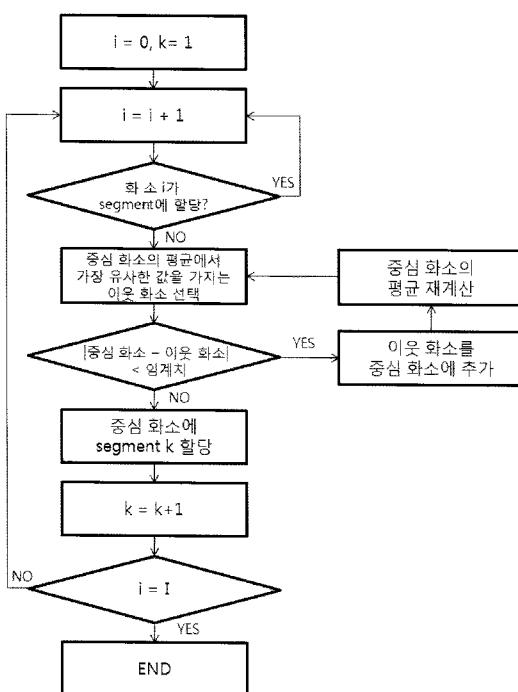


Fig. 2. Flow chart of image segmentation step.

이웃화소는 중심 화소에 대하여 총 8방향으로 탐색하며 이러한 과정을 반복하여 세그먼트 영역이 생성된다. 영상분할 단계에 대한 순서도는 Fig. 2와 같다. 총 I 개의 전체 화소에서 중심 화소 i 에 대하여 영상분할을 수행하여, 총 k 개의 세그먼트가 생성된다.

3) SSI 할당 단계

전체 영상에 대한 분할이 수행되고 나면 각 분할 영역에 대하여 속성값을 할당해 주어야 한다. 어떤 속성값을 할당하느냐에 따라서 차후에 수행할 분류결과에 영향을 미치게 된다.

본 논문에서는 세그먼트 속성값으로 세그먼트의 크기와 모양을 가중치변수를 통해 조절하여 공간정보를 생성할 수 있도록 하였다. 세그먼트의 크기를 판단하기 위해서는 세그먼트의 면적, 즉 세그먼트 내에 존재하는 화소의 개수를 계산하여 준다. 세그먼트의 모양에 관한 정보는 세그먼트의 둘레(perimeter)의 길이를 구함으로써 구할 수 있다. 두 정보에 대하여 가중치를 적용하여 필요에 따라 어떤 정보를 더 큰 영향력을 주는 계수로 판단할 것인지를 결정할 수 있고 이러한 정보를 해당 화소의 SSI 값으로 할당하게 된다. 그 식은 다음과 같다.

$$SSI = \frac{Perimeter}{Area^w}, (w \geq 0)$$

여기서,

Perimeter = 분할 세그먼트의 둘레

Area = 분할 세그먼트의 면적

w = 가중치변수

가중치 w 의 값이 커질수록 할당되는 속성값에 있어서 세그먼트의 면적에 대한 영향이 둘레에 대한 영향에 비해 높은 비중을 가지게 되고, 따라서 분류 결과에 있어서 면적이 더 중요한 변수가 됨을 뜻한다. w 의 값이 0 일 경우 분모가 1이 되어, 할당되는 SSI의 속성값은 둘레에 의해서만 결정된다. w 가 1이 되면 단순히 둘레와 면적의 비의 값을 속성값으로 할당하게 되며 w 가 커지면 커질수록, 할당되는 속성값이 세그먼트의 면적에 의해 크게 좌우된다.

제안한 알고리즘은 객체의 크기에 대한 영향과 모양에 대한 영향을 사용자가 설정함으로 인해 영상에 따라 적절하게 가중치를 줄 수 있다는 장점이 있다. 예를 들어 대상영상이 면적이 일정하지만 다양한 모양을 갖는

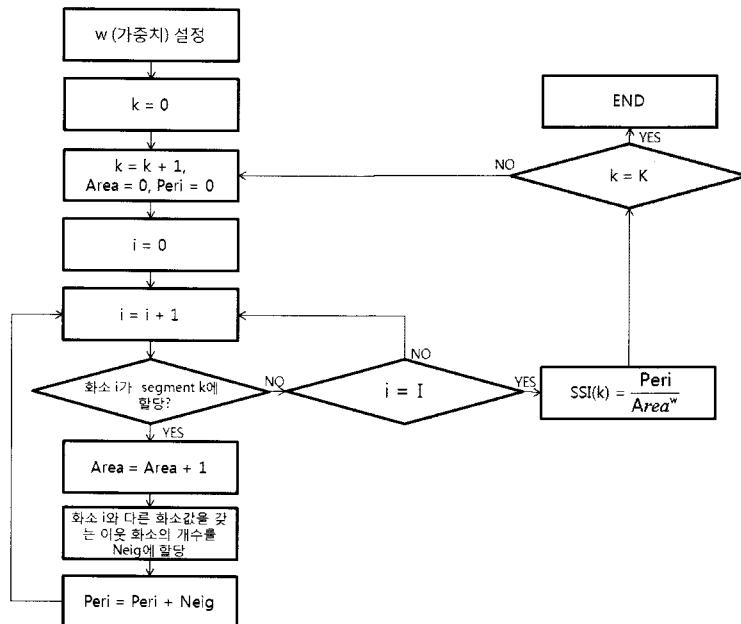


Fig. 3. Flow chart of allocating SSI step.

같은 객체들이 다수 존재하는 지역일 경우에는 가중치 w 의 값을 크게 줌으로써 같은 클래스로 할당이 되도록 해줄 수 있다. 반면에 크기는 다르지만 모양이 일정한 아파트 지역이나, 비슷한 모양의 객체로 이루어진 논밭과 같은 경우에는 가중치를 작게 줘서 같은 모양이 비슷한 클래스에 비슷한 값이 할당되도록 조정할 수 있다. Fig. 3은 1에서 k 까지 총 K 개의 세그먼트로 이루어진 크기 I 의 분할영상이 있을 때, 최종적으로 각 세그먼트

에 SSI값을 할당하는 방법을 보여준다.

3. 실험

1) 실험지역 및 사용데이터

본 연구에서는 동일한 대전지역에 대한 이종의 고해상도 위성영상인 KOMPSAT-2와 QuickBird-2 영상



Fig. 4. Study site 1 (KOMPSAT-2).



Fig. 5. Study site 2 (QuickBird-2).

을 이용하여 본 연구에서 제안한 알고리즘을 적용하였다. KOMPSAT-2 영상은 485×485 pixels의 크기로 약 $1.9\text{km} \times 1.9\text{km}$ 의 면적을 대상으로 하고(Fig. 4), QuickBird-2의 경우에는 550×550 pixels의 약 $1.3\text{km} \times 1.3\text{km}$ 면적을 대상지역으로 선정하였다(Fig. 5). 수계(water), 산림(tree), 식생(grass), 건물(built-up), 도로(road), 나대지(bare soil), 그림자(shadow) 총 7개의 클래스로 분류를 수행하였다. 특히 분광적인 특성이 유사한 수계-그림자 클래스에 대한 구분과 건물-도로 클래스에 대한 구분에 있어서 분류정확도를 개선하는데 초점을 두었다. 이 두 영상에 대하여 제안한 알고리즘의 매개변수를 변화시키면서 반복적인 실험을 수행하여 SSI feature를 생성하는데 있어서 최적의 매개변수 값을 선정하였다.

2) 실험 방법

본 연구는 고해상도 멀티스펙트럴 영상의 네 밴드로부터 추출된 첫 번째 주성분 영상을 이용하여 SSI feature를 추출한 뒤, 추출된 SSI를 고해상도 멀티스펙트럴 영상의 분광 밴드와 결합하여 SVM 기반의 분류를 수행한다. 생성된 분류 결과를 고해상도 영상의 멀티스펙트럴 영상만으로 생성된 SVM 기반의 분류결과와 비교평가를 수행하였다. 전체 연구에 대한 흐름도는 Fig. 6과 같다.

최적의 매개변수를 결정하고 일반화하기 위해서 k-cross validation 기법을 이용하였다(Kohavi, 1995). K-cross validation 기법은 전체 training 데이터를 임의의 k개의 set으로 나눈 후 k-1 개의 데이터를 이용하여 분류를 수행하고, 나머지 한 개의 데이터로 검증을 수행한다. 이러한 과정을 모든 조합에 대하여 k번 반복

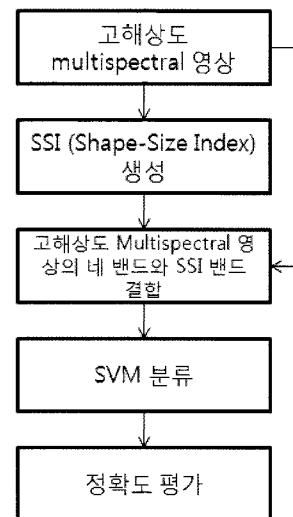


Fig. 6. Workflow of this approach.

한 후 평균 정확도가 가장 높을 때를 최적의 결과로 도출한다. 이 기법은 분류과정에 있어서 training 데이터의 overfitting을 막기 위하여 개발된 것으로 최적의 training 데이터를 찾기에 적합하다(Browne, 2000).

본 연구에서는 $k = 3$ 일 때의 k-cross validation 기법을 두 매개변수인 분할변수와 가중치변수의 최적값을 결정하는데 이용하였다. 우선 분할변수와 가중치변수를 설정한 후 training 데이터를 3개로 나누고 두 개의 데이터로는 분류를 수행하였고 나머지 하나를 이용하여 정확도평가를 수행하였다. 같은 방법으로 모든 조합에 대하여 실험을 반복하였다. 매개변수를 변화시키면서 실험을 반복수행한 후 가장 높은 평균 분류정확도를 보일 때의 매개변수를 최적의 값으로 선정하였다. 실험을 위하여 추출된 각 클래스별 training 데이터의 화소 수와 이 것을 임의의 3 세트로 나눈 화소 수는 Table 1과 같다.

Table 1. The number of training pixels for k-cross validation ($k = 3$)

	대상지역 1 (KOMPSAT-2)				대상지역 2 (QuickBird-2)			
	training 1	training 2	training 3	합계 (pixels)	training 1	training 2	training 3	합계 (pixels)
산림	179	170	191	540	264	272	246	782
식생	196	196	208	600	255	265	259	779
수계	191	171	174	536	277	256	256	789
그림자	218	200	214	632	255	320	264	839
도로	200	201	201	602	245	245	257	747
건물	185	198	173	556	272	242	289	803
나대지	214	252	231	697	245	213	239	697
합계	1,383	1,388	1,392	4,163	1,813	1,813	1,810	5,436

4. 실험 결과

1) 분할 변수 설정

먼저 영상 분할을 수행하기 위한 기준인 분할변수 값을 설정하기 위하여 방사해상도를 8비트로 정규화 시킨 첫 번째 주성분영상에 또 다른 매개변수인 가중치변수를 임의의 값인 1.2와 0.8로 고정시킨 후 분할변수를 변화시키면서 정확도를 측정하였고, 그 결과를 그래프로 표현하였다(Fig. 7, Fig. 8). 가중치변수가 1.2일 때는 두 대상지역 모두 분할변수가 30 ~ 40 부근에서 높은 분류정확도를 나타냈다(대상지역 1 : 분할변수가 40일 때 95.1957%, 대상지역 2 : 분할변수가 30일 때 96.7172%). 가중치변수가 0.8일 때는 대상지역 2의 경우 가중치변수가 1.2일 때의 결과와 마찬가지로 분할 변수가 30에서 40사이에서 높은 분류정확도를 도출한 반면, 대상지역 1에서는 분할변수가 55일 때 가장 높은 분류정확도결과를 도출하였다(93.1537). 하지만 가중치변수가 0.8일 때의 대상지역 1의 분류결과가 다른 조건일 때에 비해 전반적으로 낮은 분류정확도를 보여주고 있

고 따라서 0.8의 분할 변수는 분류정확도를 높여주는 최적의 변수가 아닐 것이라고 판단하였다. 또한 가중치변수의 값을 다른 수로 고정하여 같은 실험을 수행한 경우에도 분할변수의 값이 30 ~ 40 근처에서 높은 분류정확도가 나오는 비슷한 결과를 도출하였다. 따라서 결과적으로 분할변수의 범위가 30에서 40 사이의 값일 때 일반적으로 높은 분류정확도를 도출한다고 판단하였다.

2) 가중치 변수 설정

다음으로 가중치변수가 분류정확도에 미치는 영향을 알아보기 위하여 분할변수를 각각 30과 40으로 고정하여 분할 영상을 만든 뒤 각 세그먼트에 가중치변수를 변화시키면서 SSI 값을 할당하였다. 각 세그먼트에 SSI 계수를 할당한 후 분광밴드와 함께 분류를 수행한 후 평균 분류정확도를 측정한 결과가 Fig. 9.와 Fig. 10.과 같다. 그래프에서 알 수 있듯이 분할변수에 크게 상관없이 두 대상지역 모두 가중치 변수가 1.0에서 1.2 사이일 때 가장 높은 분류정확도를 도출하였다. 분할변수의 값을 다르게 설정한 후 같은 실험을 수행하였을 때도 대부분이 가중치 변수가 1.0 ~ 1.3 사이에서 가장 높은 분류

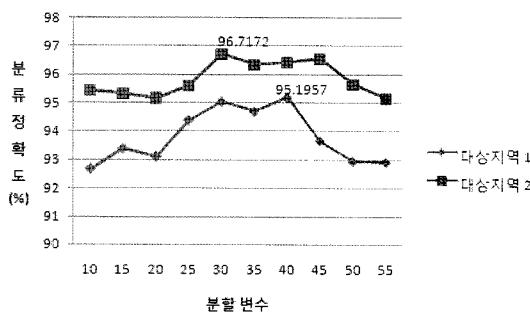


Fig. 7. Average classification accuracy of training data (weight parameter = 1.2).

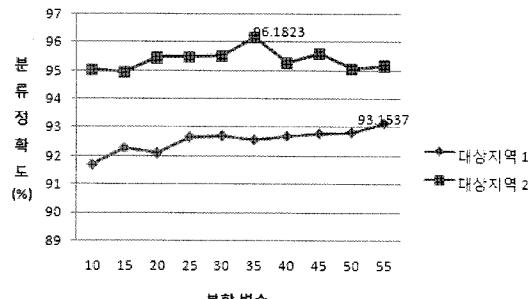


Fig. 8. Average classification accuracy of training data (weight parameter = 0.8).

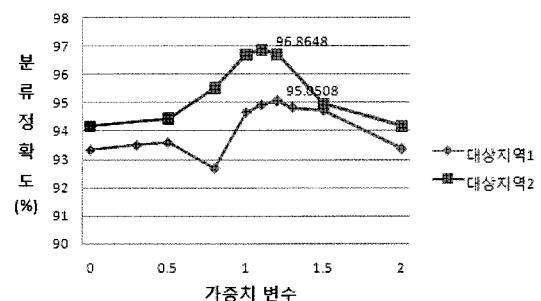


Fig. 9. Average classification accuracy of training data (segmentation parameter = 30).

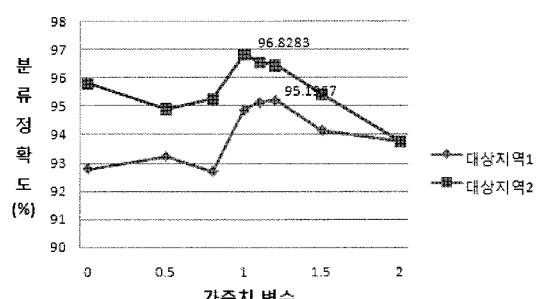


Fig. 10. Average classification accuracy of training data (segmentation parameter = 40).

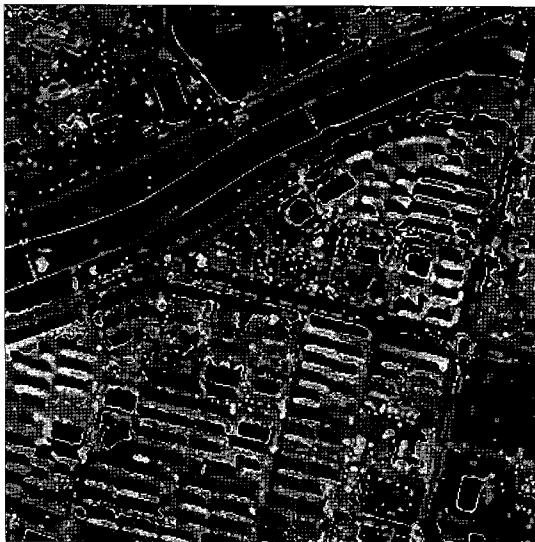


Fig. 11. Extracted SSI (study site 1).



Fig. 12. Extracted SSI (study site 2).

정확도 결과를 나타냈다. 가중치 변수가 1.5 이상일 경우에는 분류정확도가 급격하게 감소하였으며 2가 넘어 갈 경우에는 단순히 분광밴드만을 가지고 분류를 수행한 결과의 정확도와 비슷한 수준의 결과를 도출하였다. 이러한 결과에 비추어, 가중치 변수가 유의미한 구간은 0.0 ~ 2.0 사이로 판단하였고 최적의 결과를 도출하는 범위는 1.0 ~ 1.2로 결론지었다.

앞선 실험을 통해서 분류정확도 향상을 위한 최적의 매개변수 값은 분할변수는 30 ~ 40 사이, 가중치변수는 1.0 ~ 1.2임을 도출하였다. 분할변수가 30, 가중치변수가 1.1일 때 추출한 SSI feature 영상은 Fig. 11, Fig. 12와 같다.

분광정보가 유사한 수계-그림자 클래스와 건물-도로 클래스를 위주로 SSI 추출 영상을 시각적으로 평가를 해보면, 우선 건물 클래스와 도로 클래스의 밝기값의 차이가 확연하게 드러나는 것을 알 수 있다. 건물 클래스가 갖는 면적의 크기가 도로 클래스에 비해 작을 뿐만 아니라 모양도 다양하기 때문에 평균적으로 SSI feature 값이 크게 나타나는 것을 알 수 있다. 대부분의 도로는 다른 클래스에 의한 중첩이나 방해가 없는 한 같은 세그먼트로 구성되기 때문에 건물에 비해 큰 면적을 갖게 된다. 따라서 면적이 분모로 할당되는 SSI feature에는 작은 값이 할당된다. 반면, 수계 클래스와 그림자 클래스의 경우에는 육안으로 보았을 때는 두 클래스 모두 어둡게 보일 뿐 큰 차이는 느껴지지 않는다.

SSI feature 영상의 히스토그램이 전반적으로 낮은 밝기값에 치우쳐 있기 때문에 시각적인 평가로 두 클래스를 구분하기는 한계가 있다. 따라서 SSI feature가 두 클래스에 미치는 영향을 정량적으로 평가해보기 위해서 각 클래스에 따른 training 데이터의 밴드별 평균 화소값을 그래프로 표현하였다(Fig. 13, Fig. 14).

분광 밴드(B, G, R, NIR)의 클래스별 평균 화소값을 살펴보면 수계-그림자 클래스와 도로-건물 클래스의 분광정보 형태가 비슷한 것을 알 수 있고, 이것은 그만큼 분광정보만으로는 이들을 구분해내기가 어렵다는 것을 뜻한다. 추가적으로 추출된 SSI feature 평균 화소값을 보면, 수계 클래스의 경우 두 대상지역 모두 0의 화소값을 갖는 것을 알 수 있다. 이것은 수계 클래스를 대표하는 training 데이터가 다른 클래스에 비해 큰 세그먼트를 갖는다는 것을 말해 준다. 반면 그림자 클래스 역시 전반적으로 작은 평균 화소값을 갖기는 하지만 세그먼트의 크기가 크지 않아 수계 클래스와는 확연히 구분이 가능하다.

도로-건물 클래스에서는 SSI feature 값의 차이가 더욱 확연히 드러난다. 건물 클래스의 SSI 평균 화소값(대상지역 1 : 95, 대상지역 2 : 92)이 도로 클래스의 평균 화소값(대상지역 1 : 40, 대상지역 2 : 26)에 비해 약 60 이상 큰 값을 갖는다. 특히 대상지역 1의 경우 도로와 건물 클래스가 거의 유사한 분광 특성을 보이므로, 이러한 지역에서 SSI feature를 추출하여 분류에 함께 사용

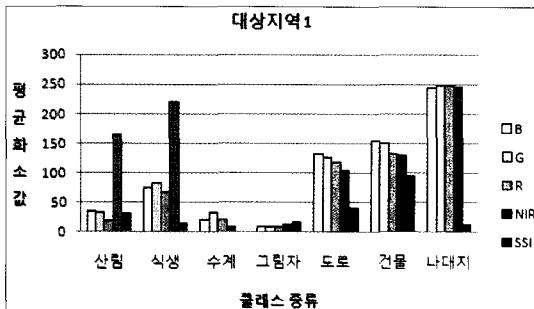


Fig. 13. Average pixel values at each training class (study site 1).

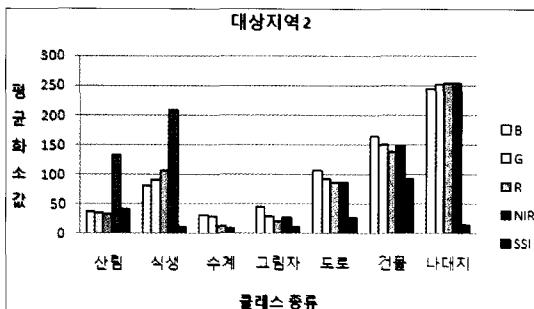


Fig. 14. Average pixel values at each training class (study site 2).

하는 것이 특히 정확도의 향상에 도움을 줄 수 있다.

3) 분류 결과 및 정확도 평가

고해상도 멀티스펙트럴 영상을 SVM 분류자로 분류를 수행한 결과와 SSI feature를 결합하여 분류를 수행한 결과는 각각 Fig. 15와 Fig. 16과 같다. 멀티스펙트럴 영상만을 이용하여 분류를 수행한 결과는 특히 분광적으로 유사한 그림자-수계 클래스와 도로-건물 클래스를 구분하는데 있어서 많은 오류가 보이는 것을 알 수 있다. 반면 분광정보에 SSI를 결합한 후에 분류를 수행한 결과에서는 분광정보가 유사한 클래스 간에도 분류가 원활히 이루어진 것을 볼 수 있다. 분광정보가 유사

Table 2. Overall classification accuracy

분류 정확도(%)	분광정보만을 이용한 결과	분광정보와 SSI를 결합한 결과
대상지역1	84.16	91.71
대상지역2	87.53	93.99



(a) spectral bands



(b) spectral bands with SSI

색	클래스
black	산림
light gray	식생
medium gray	수계
dark gray	그림자
white	도로
white	건물
white	나대지

Fig. 15. Classification results (study site 1).



(a) spectral bands



(b) spectral bands with SSI

색	클래스
black	산림
light gray	식생
medium gray	수계
dark gray	그림자
white	도로
white	건물
white	나대지

Fig. 16. Classification results (study site 2).

Table 3. Producer's and user's accuracy

	분광정보만을 이용한 결과				분광정보와 SSI를 결합한 결과			
	대상지역 1		대상지역 2		대상지역 1		대상지역 2	
	생산자 정확도	소비자 정확도	생산자 정확도	소비자 정확도	생산자 정확도	소비자 정확도	생산자 정확도	소비자 정확도
산림	96.28	99.29	99.80	97.99	96.66	99.20	98.04	97.77
식생	98.37	97.73	94.31	100.0	99.65	97.36	98.97	97.51
수계	97.64	86.82	89.38	73.44	100.0	99.06	94.63	99.93
그림자	87.86	94.43	73.13	88.56	99.25	96.63	97.01	93.05
도로	84.24	66.24	80.99	81.32	78.22	86.29	84.92	88.56
건물	52.92	75.81	71.48	66.00	84.19	79.20	86.57	80.60
나대지	99.39	98.86	90.80	91.99	99.66	100.0	96.73	99.89

한 클래스들 사이에서 SSI를 통해서 공간적인 특징이 가미되어 이러한 클래스들을 구분하는데 효과적으로 작용한 것으로 보인다.

분류정확도를 정량적으로 평가해 보기 위해서 training 데이터를 추출한 지역을 배제한 나머지 실험 지역에 대해서 test 데이터를 임의로 추출하였고 그에 따른 분류정확도를 측정하였다(Table 2) 제안한 기법이 단순히 분광정보만을 이용하여 분류를 수행한 결과에 비해 높은 분류정확도를 보였음을 알 수 있다.

각 클래스에 대한 생산자정확도와 소비자정확도는 Table 3과 같다. 분광정보만을 이용한 결과의 경우 그림자의 생산자정확도와 수계의 소비자정확도가 낮게 나온 것을 알 수 있다. 이것은 대부분의 그림자가 수계로 오분류되는 경향을 보이고 있음을 뜻한다. 도로와 건물 클래스의 경우에는 소비자와 생산자정확도 모두 낮음을 알 수 있다. 반면 SSI를 추출하여 분류를 수행한 경우에는 수계와 그림자 클래스 대부분이 95%이상의 분류정확도를 도출하였다. 도로와 건물 클래스의 생산자와 소비자정확도 모두 상승한 것으로 보아, 결과적으로 SSI를 추출하여 분류를 수행한 것이 분광정보만으로는 분류하기가 어려운 클래스간의 분류를 효과적으로 수행하였다고 판단할 수 있었다.

5. 결 론

본 연구에서는 고해상도 위성영상의 분류정확도 개선을 위한 spatial feature 추출 알고리즘을 제시하였다. 제안한 SSI feature는 객체의 크기와 모양을 모두

고려할 수 있는 공간 정보 추출 기법으로 추출된 SSI feature와 분광 벤드를 혼합하여 SVM 분류를 수행하였다. 분류 결과, 분광정보만을 이용하여 분류를 수행한 결과보다 높은 정확도를 도출함을 확인하였다.

제안한 SSI feature 추출 기법은 단순하면서도 기존 화소 기반의 공간 정보 추출 기법이 갖는 공간 표현 능력의 단점을 효과적으로 보완하였다. 또한 두 매개변수의 조절을 통해서 영상에 따른 최적의 결과를 도출할 수 있는 장점이 있다.

하지만 이러한 분할변수와 가중치변수를 효과적으로 조절하여 사용하기 위해서는 일반화과정을 위한 실험이 추가적으로 필요하다. 따라서 향후 연구에서는 분류 클래스가 다양한 대상지역에 추가적으로 실험을 해보고자 한다. 또한 GLCM이나 PSI 등, spatial feature를 추출하는 기준의 다른 방법과의 비교를 통해 본 알고리즘이 가지는 우수성을 평가해 보고자 한다.

참고문헌

- Browne, M., 2000. Cross-validation methods, *Journal of Mathematical Psychology*, 44(1): 108-132.
- Davis C. H. and X. Wang, 2002. "Urban land cover classification from high resolution multi-spectral IKONOS imagery," in Proc. IGARSS, Vol. 2, Toronto, ON, Canada, June 24-28 2002, pp. 1204-1206.
- Dell'Acqua F., P. Gamba, A. Ferari, J. A. Palmason, J. A. Benediktsson, and K. Arnason, 2004.

- Exploiting spectral and spatial information in hyperspectral urban data with high resolution, *IEEE Geoscience and Remote Sensing Letters*, 1(4): 322-326.
- Fu K. S. and J. K. Mui, 1981. A survey on image segmentation, *Pattern Recognition*, 13(1): 3-16.
- Hodgson, M. E., 1998. What size window for image classification? A cognitive perspective, *Photogrammetric Engineering & Remote Sensing*, 64(8): 797-807.
- Jenson J. R., 1996. Introductory Digital Image Processing: A Remote Sensing Perspective, 2nd ed. Upper Saddle River, NJ: Prentice-Hall.
- Kohavi R., 1995. A study of cross-validation and bootstrap for accuracy estimation and model selection, International Joint Conference on Artificial Intelligence, pp. 1137-1143.
- Myint S. W., N. S. N. Lam, and J. M. Tylor, 2004. Wavelets for urban spatial feature discrimination: Comparisons with fractal, spatial autocorrelation, and spatial co-occurrence approaches, *Photogrammetric Engineering & Remote Sensing*, 70(7, July): 803-812.
- Puissant A., J. Hirsch, and C. Weber, 2005. The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery, *International Journal of Remote Sensing*, 26(4, February): 733-745.
- Zhang L., X. Huang, B. Huang, and P. Li, 2006. A pixel shape index coupled with spectral information for classification of high spatial resolution remotely sensed imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 44(10, October): 2950-2961.