

RAG 기반 다중 창 영상 분할 (I)

이 상 훈[†]

경원대학교 산업공학과

RAG-based Image Segmentation Using Multiple Windows

Sang-Hoon Lee[†]

Kyungwon University

Abstract : This study proposes RAG (Region Adjacency Graph)-based image segmentation for large imagery in remote sensing. The proposed algorithm uses CN-chain linking for computational efficiency and multi-window operation of sliding structure for memory efficiency. Region-merging due to RAG is a process to find an edge of the best merge and update the graph according to the merge. The CN-chain linking constructs a chain of the closest neighbors and finds the edge for merging two adjacent regions. It makes the computation time increase as much as an exact multiple in the increasement of image size. An RNV (Regional Neighbor Vector) is used to update the RAG according to the change in image configuration due to merging at each step. The analysis of large images requires an enormous amount of computational memory. The proposed sliding multi-window operation with horizontal structure considerably reduces the memory capacity required for the analysis and then make it possible to apply the RAG-based segmentation for very large images. In this study, the proposed algorithm has been extensively evaluated using simulated images and the results have shown its potentiality for the application of remotely-sensed imagery.

Key Words : image segmentation, RAG, CN-chain, sliding window, multi-window operation.

요약 : 본 연구는 방대한 크기 원격 탐사 영상 자료의 효율적인 분석을 위한 RAG (Region Adjacency Graph) 기반 영상 분할 기법을 제안하고 있다. 제안된 알고리즘은 계산의 효율성을 위하여 CN-chain 연결 결과 저장 기억의 효율성을 위하여 sliding 다중 창을 사용한다. RAG에 의한 지역 합병은 최선의 결합을 위한 edge를 발견과 합병에 따른 graph의 갱신의 과정이다. CN-chain 연결법은 가장 유사한 인접 지역의 연결을 형성하면서 최선의 edge를 발견하여 합병을 해 나가는 과정으로 영상 자료 크기의 증가에 따라 단지 증가 배수만큼만 분석 시간을 증가시킨다. 합병에 의해 변하는 RAG의 효율적인 갱신을 위하여 RNV (Regional Neighbor Vector)를 사용하였다. 방대한 크기 자료 분석은 막대한 기억 용량의 시스템을 필요로 한다. 제안된 수평적인 구조의 sliding 다중 창 작업은 필요한 기억 용량을 현저히 감소시켜 가능한 분석 자료의 크기를 증대시켰을 뿐 아니라 계산 시간의 감소를 초래하였다. 본 연구는 simulation 자료를 사용하여 광범위하게 제안된 알고리즘의 성능을 실험하였으며 실험 결과는 알고리즘의 효율성을 입증하였다.

2006년 11월 28일 접수 ; 2006년 12월 26일 수리.

[†]교신저자: 이상훈(shl@mail.kyungwon.ac.kr)

1. 서 론

위성 혹은 항공 관측 영상은 탐사된 지표면의 정경(scene)에 포함되어 있는 서로 다른 특성의 대상들과 부합하도록 여러 구역들로 분할될 수 있다. 이러한 영상 분할(image segmentation)은 많은 영상 분석 시스템(image analysis system)에서 상위 단계의 영상 해석(image interpretation)을 위한 하위 단계 처리 과정 혹은 과정의 일환으로 수행된다. 영상 분석에서 하위 과정은 분석 대상에 대한 사전 정보 없이 수행되며 상위 과정으로 적정한 분석 결과를 공급하여 준다고 가정된다. 상위 단계와 하위 단계 과정의 차이는 주로 각 과정에 주어진 정보에 따른 것이다. 상위 과정은 탐사된 정경의 내용물에 대한 특정한 사전 정보를 사용하는 반면 하위 과정은 분석하고자 하는 정경에 관계없이 일반적인 영상 모형을 사용한다.

영상 분할의 목적은 다소 불분명하지만 구역 내의 특성은 동일하고 서로 이웃하고 있는 구역 간에는 서로 다른 특성을 유지하도록 영상을 여러 구역으로 나누는 것이라고 정의 할 수 있다. 동질성(homogeneity)과 대조성(contrast)은 주어진 자료를 통해서 평가될 수 있는 하위 수준의 특성(예: 지역의 평균 강도)으로 측정될 수 있다. 영상 분할 문제를 위해서 많은 기법들이 제안되었다(Haralick and Shapiro, 1985; Pal and Pal, 1993). 그들을 한계(thresholding) 기법, 경계 탐색(edge detection) 기법, 지역 기반(region-based) 기법으로 크게 3개의 범주로 구분할 수 있다. 한계 기법은 영상이 잘 구별될 수 있는 동일한 강도의 대상들로 구성되어 있다는 가정아래 한계 값을 구하여 영상을 몇 개의 구역으로 분할한다(Pal and Pal, 1993; Tobias and Seara, 2002). 경계 탐색 기법은 서로 특성의 구역 간에 경계를 발견하고 대상들의 경계선을 대표하는 윤곽선(contours)을 형성함에 의해 영상을 나눈다(Torre, 1986; Canny, 1986; Jain, A., 1989). 지역 기반 기법은 미리 주어진 어떤 기준을 만족하는 연결된 화소들의 집단인 지역을 발견하는 기법으로 지역 합병(region merging)과 지역 분리(region splitting) 방법이 있다(Chen et al., 1991; Wu, 1993).

지역 확장의 일반적 과정은 한 화소 혹은 지역과 그의 공간적 이웃들을 비교하여 동질성 기준 혹은 통계적

유사 치에 근거하여 합병하는 과정을 포함하고 있다. Adams and Bishof(1994)는 동질성 모수(parameters)를 조율함 없이 여러 수의 초기 종자(seed)들에 조정되어지는 SRG (Seeded Region Growing)기법을 발표하였고 Chang and Li(1994)도 영상에 관한 사전 정보나 모수 조율이 필요하지 않고 지역적 특색 분석에 의해 좌우되어지는 지역 확장 과정을 소개하였다. Hojjatoleslami and Kittler(1998)는 지역 확장 과정을 조정하기 위해 주변 대조(peripheral contrast)와 평균 대조(average contrast)라는 두 개 다른 불연속 측정치를 사용하였다. Wand Higgins(2003)는 초기 확장 점의 선택에 영향을 받지 않고 계산 시간과 기억 용량에 대해 효율적인 SymRG (Symmetric Region Growing) 알고리즘을 제안하였다. 지역 확장과 경계 탐색을 같이 사용하는 혼성(hybrid) 기법이 영상 분할을 개선시키기 위하여 개발되어졌다. Pavlidis and Liow(1990)는 동질성 기준에 의해 구성된 경계를 수정 혹은 제거함에 의해 지역 확장을 하는 방법을 제안하였고 Fan et al.(2001)은 인접한 경계 사이의 중심점을 초기 종자로 사용하여 경계 추출과 SRG의 결과를 통합하는 혼성기법을 제안하였다. 지역 기반 기법과 관련된 또 다른 혼성 기법으로 Zhu and Yullie(1996)는 snakes/balloons 모형의 기하학적 특색과 지역 확장의 통계적 기술을 합성하는 지역 경쟁(region competition) 알고리즘을 개발하였고 Haris et al.(1998)은 watershed 분할과 RAG에 기반한 지역 합병을 사용하였다.

영상 분석에 있어 고려되어야 할 가장 중요한 제약 중의 하나는 수치 영상(digital image)이 계층 구조(hierarchical structure)를 갖고 있다는 것이다(Tanimoto and Klinger, 1990). 즉, 계층 구조에서는 하위 수준의 두 개 이상의 작은 지역(sub-region)들은 상위수준의 하나의 더 큰 지역으로 합해지고 현재의 상위수준의 지역들은 다음 상위수준에서 다시 더 큰 지역으로 합해진다. 수치 영상의 계층 구조를 고려하여 인접한 두 지역의 합병을 수행하는 RAG 기반 지역 합병 기법이 제안되어졌다. RAG 기반 지역 합병은 각 단계에서 서로 인접하고 있는 두 지역의 쌍들 중 최소 비유사성(혹은 최대 유사성)을 가진 쌍의 두 지역을 합병하면서 지역 확장을 수행하는 기법이다. 원격 탐사의 영상 자료와 같이 방대한 요소를 포함하는 분석에서는 단계

별로 두 개의 작은 집단을 하나의 큰 집단으로 결합해 가는 clustering 과정은 계산/기억 상 매우 비효율적이므로 단순한 적용은 실질적으로 적절하지 못하다. 비효율성 문제를 해소하기 위해서 Haris *et al.*(1998)은 우선 watershed 분할을 통하여 지역 합병을 위한 초기 지역 수를 감소시키고 NNG (Nearest Neighbor Graph)를 정의하여 각 단계에서의 최선의 쌍 선택을 위한 합병 후보 대상 영역을 축소하였다. 무감독 영상 분류 논문 (이상훈, 2001)은 NNG와 일치하는 MCRNP (Mutual Closest Regional Neighbor Pair)들 중에서 최선의 결합을 선택하였고 계산/기억 상의 효율성 증가를 위하여 경계 폐쇄(boundary blocking)에 의한 pyramid 계층 구조의 다중 창을 사용하였다. Lee and Crawford (2005)는 탐색된 정경에 나타나는 지역적 연속성을 반영하기 위하여 Markov Random Field에 정의된 Bayesian 측정치를 RAG 기반 지역 합병에 사용하였다. 또한 지역 확장 clustering의 각 단계에서 최선의 쌍을 검색하는 효율을 증가시키기 위하여 CN (Closest Neighbor)-chain 연결이 제안되었다(Lee, 2004).

본 연구에서는 Lee(2004)에 의해 제안 된 CN-chain 연결을 사용하는 다중 창 기법을 넓은 정경으로부터 관측된 고 해상도 혹은 초 분광 영상의 매우 방대한 자료를 동시에 분석할 수 있도록 수정 개선하였다. 각 단계에서 합병에 의해 변하는 RAG을 위하여 RNV를 정의하여 효율적인 RAG의 생성을 도모하였고 pyramid 구조의 다중 창 대신에 sliding 다중 창을 사용하여 영상 분할의 계산/기억 상 효율성을 증가시켰다. 특히 제안 된 sliding 다중 창 작업은 기억 용량의 효율적 사용으로 가능한 분석 자료의 크기를 증대시켰을 뿐 아니라 계산 시간의 감소를 초래하였다.

2. RAG 기반 지역 합병 분할

서로 연결된 동질성을 가진 화소들의 집합을 지역이라고 정의한다면 RAG 기반 지역 합병 분할은 매 단계 두 개의 서로 이웃하고 지역 간의 합병을 통하여 지역을 확장시키는 지역 확장 clustering 과정으로 결국에는 서로 이웃하고 지역들이 주어진 중지 규칙에 따른 서로 상이한 특성을 가지도록 전체 영상을 여러 지역으로 분할한다.

1) RAG과 RNV

서로 인접하고 있는 두 지역의 쌍 중에 가장 유사한 쌍을 선택하여 합병하는 전략을 위한 영상 구조는 RAG (Ballard and Brown, 1982)이다. 영상이 m 개의 지역으로 분할되었을 경우 RAG은 $RAG_m = (J_m, E_m)$ 으로 정의된다. $J_m = \{1, 2, \dots, m\}$ 은 각 지역을 대표하는 nodes의 집합이고 $E_m \subset J_m \times J_m$ 은 J_m 에 속하는 두 지역이 서로 인접하다면 존재하는 edges의 집합이다. Fig. 1은 분할의 초기 상태에서는 각 화소가 하나의 지역으로 지정되고 두 지역 간에 합병이 이루어지면서 합병 지역의 색인은 두 지역의 색인 중 적은 값으로 지정되었을 경우 4×4 크기 영상의 6 지역 분할의 예를 보여주고 있다. 1차수 RAG은 지역에 속한 화소들 간에 수직과 수평 방향의 인접성을 고려한 것이고 2차수 RAG은 대각선 방향을 포함하여 고려한 것이다. Graph의 각 edge에 두 인접 지역 사이의 비유사성을 나타내는 비용이 정해지고 최소 비용의 edge가 인접 지역 중 가장 유사한 쌍에 해당한다.

RNV는 RAG를 실제 프로그램에서 실현시키는 vector 변수이다. 이 vector는 기본적으로 각 지역에 대해서 인접 지역 색인과 지역 연결 pointer로 구성되며 첫 번째 요소로 최소 비유사성(혹은 최대 유사성)을 가진 인접 지역 색인을 가진다. R_j 는 J_m 의 소 집합(subset) $R_j \subseteq J_m, j \in J_m$ 으로 지역 j 에 이웃하고 있는 지역들의 색인 집합이라고 하면 지역 j 의 CRN (Closest Regional Neighbor)는 다음과 같이 정의된다:

$$CRN(j) = \operatorname{argmin}_{\lambda(j, k)} \{\lambda(j, k) : k \in R_j\} \quad (1)$$

$\lambda(j, k)$: 지역 j 와 지역 k 의 합병과 연관된 비유사 계수.

그러면 지역 j 의 RNV, $RNV(j)$ 는 첫 번째 요소로 $CRN(j)$ 를 가지며 마지막 요소로는 지역 합병에 따른 연결 pointer를 가진다. Figs. 2와 3에 초기 상태의 4×4 크기 영상의 RAG과 RNV이 보인다. 초기 상태에서 각 화소는 하나의 독립 지역으로 정의되고 지역 연결 pointer는 지역 연결이 없음을 표시하는 -1의 값을 갖는다. Fig. 3의 초기 RNV는 지역 $j = 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16$ 의 $CRN(j)$ 가 2, 1, 4, 8, 1, 7, 6, 12, 13, 6, 15, 8, 14, 13, 11, 15일 경우이고 RAG에서 화살표의 edge로 표시되었다. 즉 예를 들어 지역 10의 인접 지역은 7, 10, 12, 15이며 가장 유사한 인접 지역은 지역 15이다. Figs. 2와 3은 또한 Fig. 1의

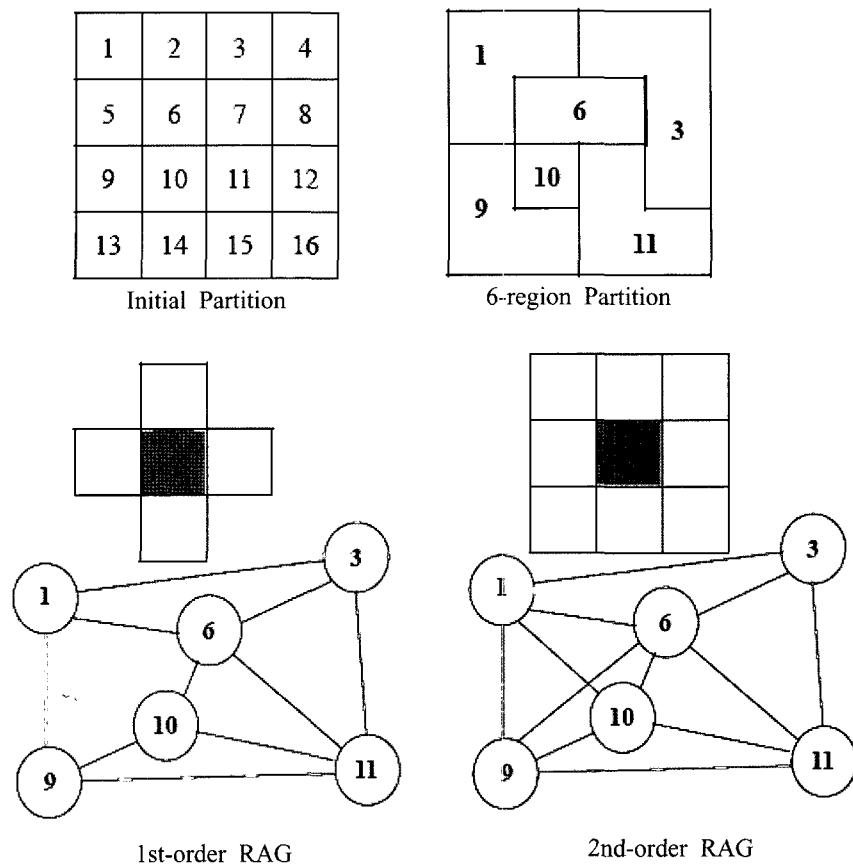


Fig. 1. Examples of RAG.

Initial RNV

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
2	1	4	8	1	7	6	12	13	6	15	8	14	13	11	15
5	3	7	3	6	5	3	7	10	9	10	11	9	10	14	12
-1	6	2	-1	9	2	8	4	9	11	12	16	-1	15	16	-1
	-1	-1		-1	10	11	-1	-1	14	7	-1		-1	-1	
							-1	-1							

6-region RNV

1		3			6		5	9	10	11					
-3	3	1	6	6	11	3	-13	10	6	3	11	-15	11	13	-1
	9	-5	-9	-1	10	1		1	9	6	-1		-1	10	
	-6				-8	-1		-1	11	-16	-1			-17	
									13						
										-1					

Fig. 2. Examples of RNV.

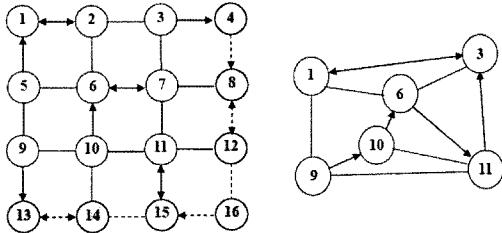


Fig. 3. Initial and 6-region RAGs.

6 지역 RAG에 해당하는 RNV와 CRN을 표시하는 화살표 edge를 가진 RAG를 보여주고 있다.

2) CN-chain 연결

RAG 기반 지역 합병 알고리즘의 계산 효율성은 RAG 크기 즉 지역의 수에 의해 결정된다. MCNRP 혹은 NNG의 Heap을 형성하여 지역 합병을 위한 최선의 쌍을 감색하고 합병에 의해 달라지는 graph를 갱신시키는 작업은 지역의 수의 증가에 따라 지수적인 증가 경향을 가지므로(Haris *et al.*, 1998; 이상훈, 2001) 방대한 자료의 분석을 위해서는 비효율적일 수 있다. Lee(2004)는 RAG의 크기에 계산 시간이 선형적으로 비례하는 CN-chain 연결 알고리즘을 제안하였다.

주어진 중지 규칙으로 비유사성 계수에 대한 동질성 기준 C_{\max} 가 주어진다면, 즉 $\lambda(j, k) > C_{\max}$ 이면 지역 j 와 k 는 동일 지역으로 합병되지 않는다면, 어떤 이의 지역에 j 에 대해서 $\lambda(j, CRN(j)) \leq C_{\max}$ 을 만족한다면 하나의 CN-chain은 다음과 같이 형성된다:

$$\begin{aligned} r_0 &= j, r_1 = CRN(r_0), \dots \\ r_{h-1} &= CRN(r_{h-2}), r_h = CRN(r_{h-1}) = r_{h-2}. \end{aligned} \quad (2)$$

식 (2)에서 chain의 마지막 연결고리는 MCRNP이다. 즉

$$r_{h-2} = CRN(r_{h-1}) \text{ and } r_{h-1} = CRN(r_{h-2}) \quad (3)$$

CN-chain 연결은 마지막 연결 고리의 MCRNP를 합병하는 과정이다. Fig 3에서 6 지역 RAG에서 지역 9에서 시작하는 CN-chain은 $9 \rightarrow 10 \rightarrow 6 \rightarrow 11 \rightarrow 3 \rightarrow 1 \rightarrow 3$ 이다.

3) 비유사 계수

영상 분할의 목적은 비유사성과 관련된 비용을 최소로 하는 지역 분할을 발견하는 것이다. 무감독 영상 분류 논문(이상훈, 2001)은 사전 정보가 주어지지 않은 하위 과정으로 비유사성 비용으로 전체 집단의 내부 표본

분산(intra-cluster sample variance)을 사용하였다. 영상 구조를 매우 적절하게 대표하는 통계 모형을 사용하여 보다 나은 해를 구할 수 있는 MRF 기반 비유사성 계수(Lee and Crawford, 2005)가 제안되었으나 계산상 복잡성을 가진다. 단일 band 영상의 경우 방대한 자료의 동시 분석을 위하여 전체 집단의 내부 표본 분산 비용은 단순하고 기본적인 지역의 특성을 잘 대표하므로 적절 할 수 있다. 그러나 다중 band의 경우 band에 따라 분산 값의 분포 구간의 크기가 다르므로 이 점을 고려해야 한다. 본 연구에서는 적정한 방법에 의해 band별 분산 값을 추정하여 Mahalanobis 거리 값의 비유사성 계수를 사용하였고 band 간 분산 표준화가 목적이므로 분산 추정을 공간적 상이성은 고려하지 않았다. 즉 모든 지역의 분산 값은 동일하다고 가정하였다.

x_k 가 k 번째 화소의 다중 band 관측 강도(intensity) vector이고 G_j 가 지역 j 에 속하는 화소들의 색인 집합이고 n_j 가 화소들의 수이라면 두 지역 r 와 s 간의 비유사성 계수는 다음과 같이 정의된다:

$$\lambda(r, s) = M_{r \cup s} - (M_r + M_s)$$

for $j = r, s, r \cup s$,

$$M_j = \sum_{k \in G_j} (x_k - \bar{x}_j)^T \hat{\Sigma}^{-1} (x_k - \bar{x}_j) \quad (4)$$

$$\bar{x}_j = \frac{1}{n_j} \sum_{k \in G_j} x_k.$$

공분산 행렬 $\hat{\Sigma}$ 은 분석 영상의 모든 화소에 대해 3×3 크기 창을 이용하여 추정할 수 있다. W_k 를 k 를 포함한 k 번째 화소를 둘러싸고 있는 8개의 화소들의 색인 집합이고 I_n 은 분석 영상의 모든 화소들의 색인 집합이고 n 은 분석 영상의 총 화소 수이라면

$$\begin{aligned} \hat{\Sigma} &= \frac{1}{n} \sum_{k \in I_n} \sum_{i \in W_k} (x_i - \bar{x}_k)^T (x_i - \bar{x}_k) \\ \bar{x}_k &= \frac{1}{9} \sum_{k \in W_k} x_k. \end{aligned} \quad (5)$$

4) 합병 중지규칙

영상 분할의 최선의 형태를 결정하기 위해 동질성 기준을 제공해야 한다. 모집단의 특성 값에 근거한 모형(parametric model)을 사용한 분석에서는 대부분 중지 규칙은 chi-squared 혹은 F 분포에 기반을 두고 있다. 그러나 원격 탐사의 영상처럼 분석 대상의 크기에 비해

서 지역 수가 적다면 모집단의 특성 값에 근거한 모형은 너무 많은 분할 지역을 생성한다. 그러므로 대체수단으로 영상 분석에서는 대부분 모형 선택을 위한 정보기준(Akaike, 1978; Won and Derin, 1992)을 사용하고 있으며 여러 저자의 실험을 통하여 영상분석을 위하여 가장 효과적인 정보 기준의 하나는 Schwarz에 의해 제안된 기준이다(Schwartz, 1978; Rissanen, 1978):

$$SIC = -\ln(\text{Maximum Likelihood}) + 0.5m_p \ln n \quad (6)$$

m_p : m 개의 지역을 가지는 분할 형태에서 추정하여지는 독립 모수의 수.

식 (6)의 기준에 의하면 매 단계 두 지역을 합병하는 알고리즘에서 합병에 의한 log-likelihood의 증가가 $0.5 \ln n$ 에 합병 전과 후의 독립모수의 차이를 곱한 값보다 적어야 한다(Lee, 2004). (4)의 비유사 계수를 사용할 경우 두 개의 평균 값과 공분산 행렬을 사용하나 공분산 행렬은 매 단계 일정하다고 가정하므로 l band 영상 자료에 대한 독립 모수의 수는 l 개 이다. 영상 분할을 상위 과정을 위한 영상 처리에서 하위 과정으로 relaxation 단계로 보았을 때 실제 활용에 있어서는 영상이 관측된 정경에 따라 혹은 상위 과정의 활용에 따라 relaxation의 수준을 조정할 필요가 있으므로 본 연구에서는 주어진 조정 계수 β 를 포함한 중지규칙을 사용하였다:

$$C_{\max} = 0.5 \beta l \ln n. \quad (7)$$

조정 계수 β 는 relaxation 수준을 나타내며 적은 분할 수를 원하면 큰 값을 사용한다.

3. 다중 창 작업

서로 공간적으로 이웃하고 있는 지역의 쌍만을 결합하는 영상 분할은 CN-chain 연결을 통하여 영상의 크기에 따라 계산 시간은 거의 크기의 배수만큼 선형적으로 증가하게 된다. 즉 CPU_n 를 화소 수 n 인 영상의 CPU 계산 시간이라 한다면 $CPU_{kn} \approx kCPU_n$ 이다. 그러나 초기에 전체 영상의 모든 화소를 하나의 지역으로 가정하여 RAG 기반 지역 확장 알고리즘을 수행한다면 막대한 기억 량이 필요하다. 이러한 기억 상의 복잡도를 완화시키기 위하여 pyramid 사분목(quad-tree) 구조의 다중 창 전략을 채택하였다(이상훈, 2001; Lee, 2004). 그러나 pyramid 구조는 여전히 매우 큰 영상 분석을 위해서

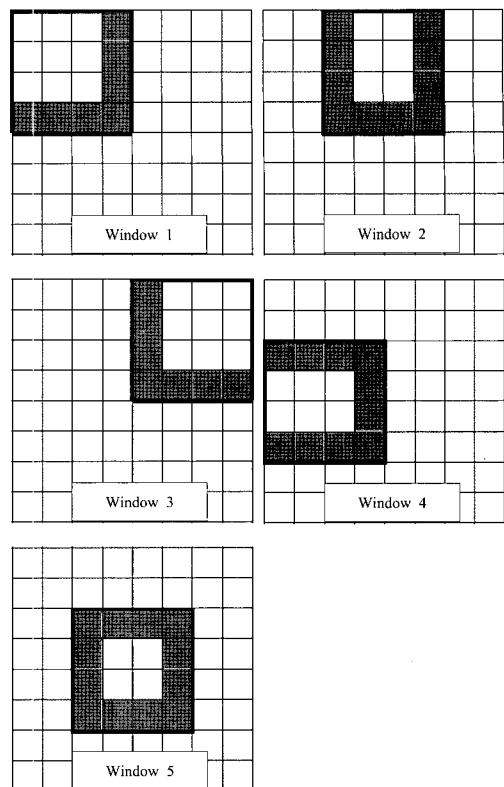


Fig. 4. Sliding multi-windows.

는 어느 정도의 기억 용량을 필요로 한다. 본 연구는 sliding 구조에 의한 새로운 다중 창 전략을 제안하고 있다. Sliding 다중 창 전략은 일정한 크기의 분석 창을 일정한 방향을 옮기면서 전체 영상을 분석하는 작업이다. Fig. 4는 sliding 전략을 도식적으로 보여주고 있다. 그러나 다중창 작업에서 개개의 창에 대해서 독립적으로 영상 분할을 수행한다면 창의 경계 지역에서 분할은 비정상적인 결과를 초래될 것이다. 이러한 문제점을 극복하기 위하여 경계 폐쇄(boundary blocking) 알고리즘이 개발되었다(Lee, 1990).

1) 기억 용량의 비교

RAG 기반 지역 확장 알고리즘 수행을 위하여 전체 화소의 수에 비례하는 지역 색인과 자료 값 변수의 저장 기억 그리고 분할 형태의 지역 수에 비례하는 RNV와 다수의 합병 과정에 필요한 변수를 위한 저장 기억이 필요하다. 화소 수 n 이고 지역 수가 m 인 분할 형태에 필요한 기억 용량은 다음과 같다:

$$RAM_n \approx \text{sizeofindexword} \times (n + \text{size}_{\text{RNV}}) + \text{sizeofdataword} \times ln + N_{\text{remain}} \times m \quad (8)$$

size_{RNV} = RNV의 요소 수

N_{remain} = 알고리즘 수행에 필요한 과정 변수들과 그 변수들의 word 크기를 곱한 값의 합.

화소 수와 일치하는 지역 수를 가지는 분할 형태로 초기화할 경우 $\text{size}_{\text{RNV}} = 5n, m = n$ 이다. 예를 들어 $n = 10K \times 10K$ ($K=1024$)이고 3-밴드 8-bit 영상의 경우 3GB (Giga Bytes)보다 훨씬 많은 기억 용량을 필요로 한다.

Pyramid 사분목 구조의 다중 창 전략은 지역 수 m 에 의존하는 size_{RNV} 와 과정 변수들의 위해 필요한 기억 용량을 현저히 감소시킬 수 있으나 모든 단계를 통하여 전체 영상의 자료 값을 저장하여야하고 각 단계마다 하위 단계의 4개의 창을 통합한 분할 형태를 위한 각 지역의 화소 색인 집합 구성과 RNV 구성은 위하여 임시 저장 용량이 더 필요로 한다. 특히 전체 영상을 고려하는 최상위 단계에서 $\text{sizeofindexword} \times 2n+n$ 의 기억 용량을 더 필요로 한다. 즉 pyramid 구조에 필요한 기억 용량은

$$RAM_n^P \approx \text{sizeofindexword} \times 3n+n + \text{sizeofdataword} \times ln + O(m) \quad (9)$$

$$O(m) \ll RAM_n^P.$$

다중 창 전략으로 지역의 수와 관련된 기억 용량은 전체 필요한 용량에 비해 매우 감소했으나 위의 예로 든 영상의 경우 여전히 GB 이상의 기억 용량을 필요로 한다:

$$RAM_n^P \approx 1.4\text{GB} + O(m).$$

제안된 sliding 다중 창 전략은 분석 창을 일정한 방향을 전체 영상위에서 sliding하면서 움직이기 때문에 분석이 이루어진 구역에서 구한 지역 특성 값을 변수에 저장하여 다음 창의 분석에 사용할 수 있으므로 전체 영상의 자료 값을 한꺼번에 저장할 기억 용량이 필요 없다. 다중 창의 구조가 수평적으로 구성되어 있어 수직 구조의 pyramid 다중 창 전략에서처럼 각 단계마다 지역의 화소 색인 집합 구성과 RNV 구성은 위한 새로운 정리에 필요한 임시 저장 용량이 필요하지 않고 연속적인 합병을 위하여 필요한 변수는 분석 구역을 확대하면서 변화하는 지역 수에 따라 기억 용량을 reallocation하면서 이미 구해진 값을 사용할 수 있다. 제안된 sliding 구조에서는 지역 색인 집합을 위하여 단지 전체 화소 수 크기의 변수가 필요하다. 새로운 다중 창 전략

을 위하여 필요한 기억 용량은

$$RAM_n^S \approx \text{sizeofindexword} \times n + \text{sizeofdataword} \times \text{size}_{\text{windowrow}} + O(m+\text{size}_{\text{window}}) \quad (10)$$

$\text{size}_{\text{window}} = \text{sliding}$ 창의 행의 크기 × 전체 영상의 열의 크기

$\text{size}_{\text{window}} = \text{sliding}$ 창의 크기(화소 수).

식 (10)에서 RAM_n^S 의 크기는 sliding 창의 크기에 따라 적절히 조절될 수 있다. 위의 예로 든 영상의 경우 $\text{size}_{\text{window}} = 1K \times 1K$ 이라면 $RAM_n^S \approx 0.43\text{GB} + O(m+\text{size}_{\text{window}})$ 이고 역시 $O(m+\text{size}_{\text{window}}) \ll RAM_n^S$.

2) 경계 폐쇄

경계 폐쇄 작업은 각 창에서 분할 작업을 수행할 때 인접한 창들과의 경계 구역에 위치해 있는 화소들을 포함한 지역들을 폐쇄-전염(blocking-contagious) node으로 지정하여 RAG를 구성하며 전염 node들 간에는 edge가 형성되지 않는다. Fig. 4는 8×8 크기의 전체 영상을 위해서 $\text{size}_{\text{window}} = 4 \times 4$ 의 sliding 창을 사용할 경우의 예를 보여주고 있으며 경계 구역은 어두운 색깔로 표시되었다. 지역 확장을 위하여 합병을 수행해 나가는 과정에서 선택된 합병 쌍 중 하나의 지역이 전염 node라면 다른 하나의 지역도 전염되어 전염 node로 바뀌며 이러한 쌍은 혼 분석 창에서 합병되지 않는다. 경계 폐쇄 영상 분할에서는 합병 중지 규칙에 의해서나 혹은 분석 영상의 모든 지역들이 전염되었을 때 합병 과정은 중지한다. Fig. 2의 초기 RAG에 대해서 Fig. 5는 경계 폐쇄 합병 과정에 따른 RNV 개신과 분할 결과 RAG를 보여준다. 이것은 Fig. 4의 첫 번째 분석 창에 해당한다. Fig. 2의 RAG에서 전염 node는 어두운 색깔로 표시되었으며 형성되지 않은 edge는 점선으로 표시되었다. Fig. 6은 네 번째 창에서 초기 RAG을 보여주고 있다. 경계 폐쇄 작업에서 실제로는 Fig. 5의 결과가 이루어지겠지만 예시를 위해서 Fig. 4의 첫 번째 창에서 Fig. 1의 6 지역 분할이 이루어 졌다는 가정을 하였다. Sliding 구조 다중 창 작업에서는 $\text{size}_{\text{windowrow}}$ 의 크기의 열 방향 sliding 창 작업이 끝날 때마다 지역 색인을 순서적인 값으로 개신한다. 예를 들어 Fig. 4에서 첫 번째 $\text{size}_{\text{windowrow}} = 4 \times 8$ 의 부분 영상을 위해서 열 방향의 창 1, 2, 3을 분할한 결과 10개의 지역으로 분할

1	2	3	5	6	7	9	10	11
2	1	4	1	7	6	13	6	15
5	3	7	6	5	3	10	9	10
-1	6	2	9	2	8	9	11	12
	-1	-1	-1	10	11	-1	14	7
				-1	-1		-1	-1

1		3	5	6	7	9	10	11
5	3	4	1	7	6	13	6	15
-3	6	7	6	5	3	10	9	10
	-1	1	9	1	8	5	11	12
		-1	10	11	-1	14	7	
			-1	-1			-1	-1

1		3		6	7	9	10	11
-3	3	4	9	7	6	13	6	15
	6	7	-1	1	3	10	9	10
-6	1			10	8	1	11	12
	-1			-1	11	-1	14	7
				-1		-1	-1	-1

1		3		6	7	9	10	11
-3	3	4	9	7	6	13	6	15
	6	7	-1	1	3	10	9	10
-6	1			10	8	1	11	12
	-1			-1	11	-1	14	7
				-1		-1	-1	-1

1		3		6		9	10	11
-3	3	4	9	1	3	13	6	15
	6	6	-1	10	8	10	9	10
-6	1			-8	11	1	11	12
	-1			-1	-1	14	6	
				-1		-1	-1	-1

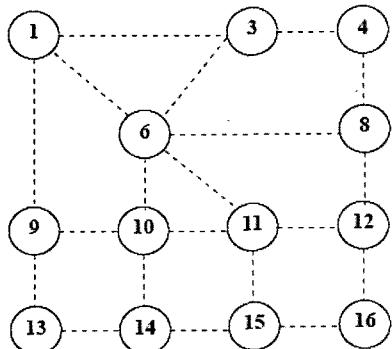


Fig. 5. RNV updates and final RAG with boundary-blocking operation in Window 1 of Fig. 4.

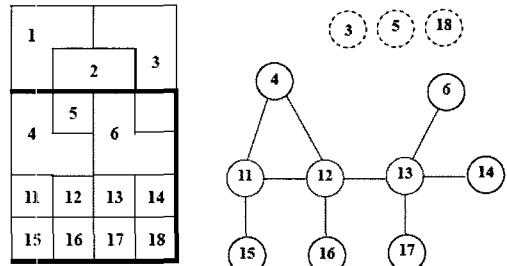


Fig. 6. RAG associated with boundaries same as Window 4 of Fig. 4 for an example of initial partition.

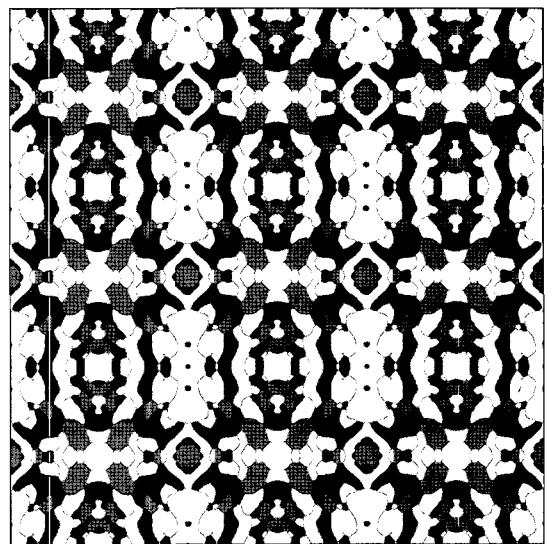


Fig. 7. 5-class pattern of 6K x 6K.

되었다면 분할 지역의 색인은 1에서부터 32사이의 값을 갖게 된다. 이 색인 값들은 1에서 10까지의 값으로 순차적으로 새로이 지정된다. Fig. 6을 위한 예에서는 지역 색인 1, 2, 3은 그대로 유지되고 9, 10, 11은 4, 5, 6으로 바뀌었다. 새로운 창의 RAG는 이미 분석된 결과의 지역들의 nodes와 분석이 되지 않은 하나의 화소로 이루어진 지역들의 nodes로 구성된다. Fig. 6의 예에서 nodes 3, 5, 18은 하나의 edge도 형성이 안 된 nodes로 해당하는 지역들은 합병의 대상이 되지 않는다.

4. 실험 결과

본 논문에서는 제안된 알고리즘에 대한 평가는

Table 1. Results of segmentation of 3-band 6K×6K simulation image.

Replication	n_s	MSE	CPUT
1	50745	5.57	163.11
2	50906	5.58	162.59
3	50661	5.58	161.94
4	50807	5.58	161.83
5	50718	5.58	161.73

simulation 자료에 대한 실험에 국한하였다. 실제 원격 탐사 자료에 적용한 실험 결과는 본 논문의 후속 편인 영상 분할의 상위 과정으로 제안된 계층 분류에 관한 논문에서 발표되었다(이상훈, 2006). 본 연구의 실험은 2 개의 Dual-core Intel Xeon 3.0GHz Processors와 8GB RAM을 장착한 Windows XP Professional64 운영체제 PC 시스템을 사용하였다. 본 실험에서는 simulation을 위하여 5 개의 클래스로 구성된 pattern 영상을 사용하였고 band별 8-bit의 단일/다중 band simulation 관측 영상 자료를 additive Gaussian 모형을 사용하여 생성하였다. Fig. 7은 6K×6K 크기의 pattern의 예가 보여준다. 각 클래스는 서로 다른 평균 강도 값(70, 100, 130, 160, 190)을 가지고 인접한 두 지역은 서로 다른 클래스를 가진다. 평가 목적 상 강도 편차는 30으로 고정 값을 사용하였고 같은 지역에서 모든 band의 평균 강도 같은 동일하도록 하였다.

본 실험에서 영상 분할의 알고리즘의 성능은 초 단위의 중앙 처리 계산 시간(CPUT)과 추정된 평균 강도의 최소 자승 오류 값(MSE)으로 측정하였다. 6K×6K 크기의 3-band 영상 자료에 대한 CN-chain 연결의 결과가 Table 1에 나타나 있다. Table에서 n_s 는 영상 분할 후 분할 결과의 지역 수이다. Table 1에서 보여주듯이 같은 자료와 입력 값에 대해서 거의 동일한 simulation

결과를 생성하였으므로 5번 반복 실험은 충분히 신뢰할 실험 결과를 생성할 것으로 예상된다. 그러므로 앞으로 모든 simulation은 5번 반복 실험을 하였고 tables나 figures에 보이는 값은 5번 반복 실험의 평균이다.

첫 번째로 Table 1에서 사용된 simulation 자료에 대해서 창의 크기를 달리하여 pyramid 구조와 sliding 구조의 다중 창을 적용하여 영상 분할을 실시하였다. Table 2는 그 결과를 갖고 있다. 이 실험에서는 정사각형 창을 사용하였으므로 Table 2에서 창 크기는 한 쪽 변의 크기이고 pyramid 구조에서는 가장 낮은 수준의 창의 크기이다. 결과에서 보듯이 다중 창을 사용한 경우가 약간의 더 나은 계산 효율성이 떨어지나 이러한 효율의 저하는 저장 기억의 효율성으로 보상된다. 어느 정도 크기 이상의 창에서는 계산 효율성이 거의 변화가 없음을 볼 수 있으나 작은 창을 사용할 경우 분할 결과의 지역 수와 MSE가 약간 증가하였다. 그러므로 기억 용량이 허용하는 한 가능한 큰 크기의 창을 사용하는 것이 가장 좋은 계산 효율성을 가지는 것을 알 수 있으며 영상의 크기에 비해서 너무 작은 창을 사용하는 것은 계산의 정확성을 떨어트릴 수 있다. 같은 지역에 속하는 화소 관측 강도 값의 평균을 그 지역의 평균 강도라고 하였을 때 MSE의 결과에서 보듯이 분할 결과의 지역 평균 강도는 관측 강도 편차의 약 20%정도이었다. Fig. 8은 3-band 6K×6K 영상의 일부분에 대한 원래 평균 강도, simulation 관측 강도 그리고 분할 결과를 보여준다. 두 다중 창 구조의 결과는 비슷하나 sliding 구조가 약간 더 좋은 계산 효율성을 보였다. 두 구조의 계산 효율성을 비교하기 위하여 2K×2K 크기의 영상부터 각 변의 크기를 2K씩 증가시키면서 동일한 크기(1K×1K)의 창을 사용하여 분할을 실시하였다. 사용된 자료는 역시 3-band 자료이다. 이 실험에서 pyramid 구조는 기억 용량의 문

Table 2. Results of segmentation of 3-band 6K×6K simulation image using pyramid and sliding window structure of different window sizes.

Window Side-Size	Pyramid Window			Sliding Window		
	n_s	MSE	CPU	n_s	MSE	CPUT
6144	50718	5.58	162.24			
3072	50859	5.58	193.35	50985	5.58	190.60
1536	50499	5.58	212.67	50508	5.58	203.82
768	50709	5.58	230.02	50396	5.58	204.63
384	51102	5.59	236.37	50808	5.58	201.70
192	51212	5.61	234.24	51825	5.61	216.19

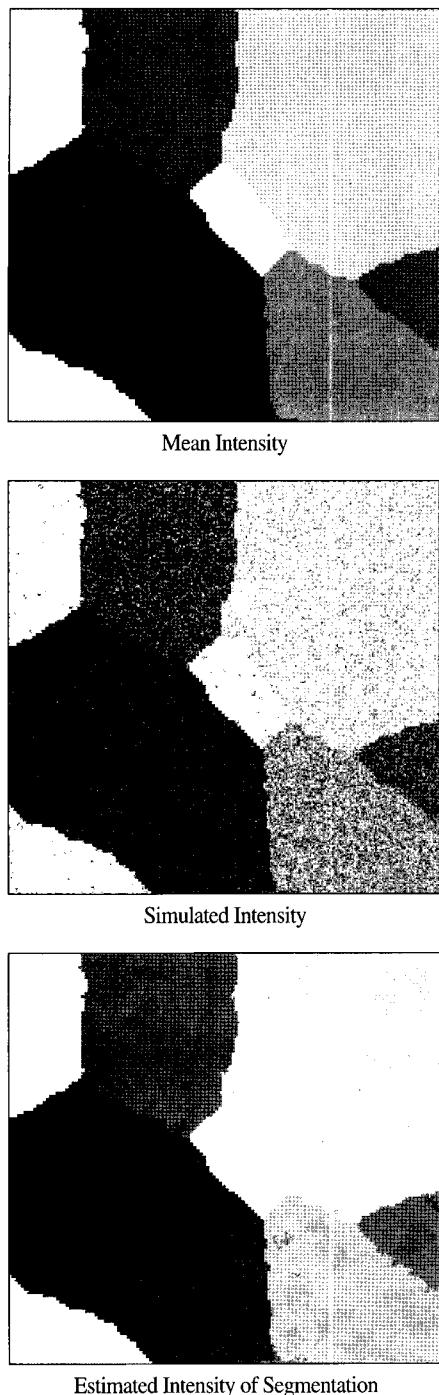


Fig. 8. Example of segmentation.

제로 $16K \times 16K$ 크기의 분석에 실패하였다. 두 구조의 CPUT을 비교한 결과가 Fig. 9에서는 보인다. 이러한 결과는 sliding 구조가 pyramid 구조 보다 계산 효율성과 저장 기억의 효율성을 보여주고 있다. Table 3은

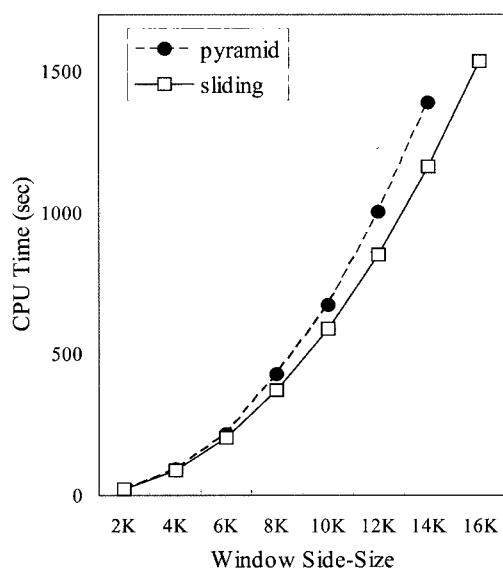


Fig. 9. Comparison of CPU times between multi-window operations of pyramid and sliding structures.

Table 3. CPU times of segmentations of 3-band simulation images of different sizes using sliding window structure of $1K \times 1K$ (image size = $S \times K^2$).

S	CPUT	CPUT/S
4	20.05	5.01
16	88.44	5.53
36	205.78	5.72
64	372.59	5.82
100	588.79	5.89
144	850.71	5.91
196	1165.09	5.94
256	1534.48	5.99

sliding 창을 사용하였을 경우 분석 영상의 크기에 따른 CPUT를 보여준다. Table 3에서 나타난 영상 크기에 대한 CPUT의 비율은 영상 크기의 증가에 따라 아주 약간씩 증가한다. 이러한 미미한 증가는 CPUT가 영상 크기의 배수만큼 대략적으로 증가함을 의미한다.

다음으로 sliding 창을 사용한 $4K \times 4K$ 크기의 영상을 사용하여 band 수 증가에 따른 분할 결과의 변화를 실험하였다. Table 4는 그 결과를 보여주고 있으며 그 결과에서 보듯이 band의 증가는 영상 크기의 증가처럼 CPUT의 증가에 많은 영향을 끼치지 않는다.

Table 4. CPU times of segmentations of $4K \times 4K$ simulation images of different numbers of bands using sliding window structure of $1K \times 1K$ (l = number of bands).

l	MSE	CPUT	CPUT/ l
1	16.39	82.82	82.82
3	5.76	88.78	29.59
5	2.68	101.74	20.35
10	1.05	138.36	13.84
20	0.72	218.16	10.91
50	0.55	471.76	9.44

5. 결 론

최근 원격 탐사 기술의 발전으로 넓은 정경으로부터 고 해상도 혹은 초 분광 영상 자료를 획득할 수 있다. Table 4의 결과에서 보듯이 band 수의 증가에 의하여 현저히 MSE의 값을 떨어뜨린다. 즉 더 많은 bands 자료는 관측 정경에 대한 더 많은 정보를 주므로 영상 분할의 정확성을 높일 수 있다. 이러한 영상 자료 분석은 효율적 분석 알고리즘이 요구된다. 특히 방대한 크기 자료의 분석을 위하여 저장 기억의 효율적 사용이 필요하다. 그러므로 본 연구는 계산의 효율성을 위한 CN-chain 연결과 저장 기억의 효율성을 위한 sliding 다중 창을 사용하는 RAG 기반 영상 분할 기법을 제안하고 있다.

매 단계 인접한 두 지역의 합병을 통한 지역 확장 영상 분할은 지역 간의 공간적 관계에 대한 정보를 공급해주는 RAG 자료 구조를 이용할 수 있다. RAG에 의한 지역 합병은 합병을 위한 최선의 edge을 발견과 합병에 따른 graph의 갱신의 과정이다. 일반적으로 최선의 결합을 위한 edge는 MCRNP의 집합 중에서 선택을 하고 있다 (Haris *et al.*, 1998; 이상훈, 2001). 그러나 자료 크기의 증가는 MCRNP의 수를 증가시키므로 합병을 위한 최선의 쌍에 대한 검색 시간은 지수적으로 증가하게 된다. 이러한 문제를 해결하기 위하여 Lee(2004)은 CN-chain 연결법을 제안하였다. CN-chain 연결법은 모든 MCRNP를 비교하여 최선의 쌍을 선택하는 대신 가장 유사한 인접 지역의 연결을 검색하여 하나의 MCRNP를 발견하여 합병을 해 나가는 과정이다. 이러한 과정은 MCRNP 검색 방법에서처럼 매 단계 최선의 분할 형태를 발견하지는 않지만 동질성 기준에 의하여

상호 인접 지역이 상이한 특성을 가지는 하나의 분할 형태를 발견하는 영상 분할의 목적에는 부합한다. Table 3의 결과에서 보여주듯이 거의 1의 기울기를 가지고 선형적으로(자료 크기의 증가 배수만큼) 검색 시간을 증가시킨다.

저장 기억의 효율적 사용을 위하여 전체 영상을 분리하여 분석하는 경계 폐쇄에 의한 다중 창 작업이 제안되었다(이상훈, 2001). 제안되었던 pyramid 구조대신 sliding 다중 창 구조를 제안하고 있다. 제안된 sliding 구조는 수직적으로 구성되어 있는 pyramid 구조와 달리 수평적으로 구성되어 있다. 수직적인 pyramid 구조에서는 모든 과정을 통하여 전체 자료 값의 저장과 매 수준 새로운 RAG의 구성을 위하여 전체 화소 수에 일치하는 크기의 변수들을 위한 임시 기억 용량이 필요하다. 그러므로 방대한 크기의 영상을 분석하기 위하여 이러한 저장 기억의 크기는 막대하다. 그러나 수평적인 구성의 sliding 창 작업은 부분적인 자료 값의 저장만이 필요하고 새로이 RAG를 구성하는 것이 아니고 갱신을 하면서 전체 영상을 분석하므로 식 (9)와 (10)에서 보듯이 pyramid 구조에 비해 현저히 필요한 기억 용량을 감소시킨다. 그러므로 고 해상도나 초 분광 자료와 같은 방대한 자료의 효율적인 분석을 위하여 제안된 알고리즘은 사용할 수 있다.

참고문헌

- 이상훈, 2001. 공간지역확장과 계층집단연결 기법을 이용한 무감독 영상분류, 대한원격탐사학회지, 17: 57-70.
- 이상훈, 2006, RAG기반 계층 분류, 대한원격탐사학회지, 22권 6호에 게재 예정.
- Adams, R. and L. Bischof, 1994. Seeded region growing, *IEEE Trans. Pattern Anal. Machine Intell.*, 16: 641-647.
- Anderberg, M. R., 1973. *Cluster Analysis for Application*, Academic Press, NY.
- Ballard, D. and C. Brown, 1982. *Computer Vision*. Englewood Cliffs, NJ: Prentice-Hall.
- Canny, J., 1986. A computational approach to edge

- detection, *IEEE Trans. Pattern Anal. Machine Intell.*, 8: 679-698.
- Chang, Y-L. and X. Li, 1994. Adaptive image region growing, *IEEE Trans. Image Process.*, 3: 868-872.
- Chen, S. W. Lin, and C. Chen, 1991. Split-and-merge image segmentation based on localized feature analysis and statistical tests, *CVGIP: Graph. Models Image Process.*, 53: 457-475.
- Fan, J., D. K. Y. Yau, A. K. Elmagarmid, and W. G. Aref, 2001. Automatic image segmentation by integrating color-edge extraction and seeded region growing, *IEEE Trans. Image Process.*, 10: 1454-1466.
- Haralick, R. and L. Shapiro, 1985. Image segmentation techniques, *CVGIP*, 29: 100-132.
- Haris, K., S. N. Efstratiadis, N. Maglaveras, and A. K. Katsaggelos, 1998. Hybrid image segmentation using watershed and fast region merging, *IEEE Trans. Image Process.*, 7: 1684-1699.
- Hojjatoleslami, S. A. and J. Kittler, 1998. Region growing: a new approach, *IEEE Trans. Image Process.*, 7: 1079-1084.
- Jain, A., 1989. *Fundamentals of Digital Image Processing*, Englewood Cliffs, NJ; Prentice-Hall.
- Lee, S., 1989. An unsupervised hierarchical clustering image segmentation and an adaptive image reconstruction system for remote sensing, *Ph.D. Thesis*, The University of Texas at Austin.
- Lee, S-H, 2004. Unsupervised image classification using region-growing segmentation based on CN-chain, *Korean Journal of Remote Sensing*, 20: 215-225.
- Lee, S. and M. M. Crawford, 2005. Unsupervised Bayesian image segmentation using multistage hierarchical clustering, *IEEE Trans. Image Process.*, 14: 312-320.
- Pal, N. and S. Pal, 1993. A review on image segmentation techniques, *Pattern Recognit.*, 26: 1277-1294.
- Pavlidis, T. and Y-T. Liow, 1990. Integrating region growing and edge detection, *IEEE Trans. Pattern Anal. Machine Intell.*, 12: 225-233.
- Sahoo, P. K., S. Soltani, A. K. C. Wong, and Y. C. Chen, 1988. A survey of thresholding techniques, *CVGIP*, 41: 233-260.
- Schwarz, G., 1978. Estimation of the Dimension of a Model, *Annal. Math., Statist.*, 6: 461-464.
- Tanimoto, S. and A. Klinger, 1980. *Structured Computer Vision*, Academic, NY.
- Tobias, O. J. and R. Seara, 2002. Image segmentation by histogram thresholding using fuzzy sets, *IEEE Trans. Image Process.*, 11: 1457-1465.
- Torre V. and T. Poggio, 1986. On edge detection, *IEEE Trans. Pattern Anal. Machine Intell.*, 8: 147-163.
- Wan, S.-Y and W. E. Higgins, 2003. Symmetric region growing, *IEEE Trans. Image Process.*, 12: 1007-1015.
- Won, C. S. and H. Derin, 1992. Unsupervised segmentation of noisy and textured images using Markov randomfields, *CVGIP*, 54: 308-328.
- Wu, Z., 1993. Homogeneity testing for unlabeled data: A performance evaluation, *CVGIP: Graph. Models Image Process.*, 55: 370-380.
- Zhu S. C. and A. Yuille, 1996. Region growing, and Bayes/MDL for multiband image segmentation, *IEEE Trans. Pattern Anal. Machine Intell.*, 18: 884-900.