

<https://doi.org/10.7236/JIIBC.2018.18.1.223>

JIIBC 2018-1-30

지속적 호몰로지를 이용한 이미지 세그멘테이션 기법 제안

Proposal of Image Segmentation Technique using Persistent Homology

한희일*

Hee Il Hahn*

요약 본 논문에서는 이미지에서 검출된 각 연결성분들의 위상적 지속구간 정보를 그래프 기반 이미지 세그멘테이션에 결합하여 보다 안정적인 이미지 세그멘테이션 기법을 제안한다. 이미지의 밝기 또는 색상정보 등을 이용하여 모스 함수를 정의하고 이의 레벨셋으로부터 각 연결성분의 위상적 지속구간을 구한다. 각 연결성분이 생성되고 긴 지속구간을 갖는 연결성분에 적절히 병합되는 과정을 영 차원 호몰로지 군의 관점에서 설명한다. 다양한 특성을 갖는 이미지들에 대하여 짧은 지속구간을 갖는 연결성분들을 지속구간이 긴 인근 성분에 적절히 병합시키는 과정을 통하여 보다 안정적인 이미지 세그멘테이션 결과를 얻을 수 있음을 실험으로 확인한다.

Abstract This paper proposes a robust technique of image segmentation, which can be obtained if the topological persistence of each connected component is used as the feature vector for the graph-based image segmentation. The topological persistence of the components, which are obtained from the super-level set of the image, is computed from the morse function which is associated with the gray-level or color value of each pixel of the image. The procedure for the components to be born and be merged with the other components is presented in terms of zero-dimensional homology group. Extensive experiments are conducted with a variety of images to show the more correct image segmentation can be obtained by merging the components of small persistence into the adjacent components of large persistence.

Key Words : Image segmentation, Graph-based image segmentation, Topological persistence, Persistent homology

1. 서론

이미지 세그멘테이션은 이미지를 유의미한 여러 영역으로 분할하는 기법으로서 이미지처리와 컴퓨터비전 등에서 가장 기초적이고 수많은 연구가 진행된 고전적인 분야에 속한다. 현재까지 발표된 방대한 연구결과에도 불구하고 아직까지 완벽하게 동작하는 알고리즘은 존재하지 않을 만큼 이 분야는 지속적인 연구가 요구되는 난

제로 인식되고 있다^[1, 4, 6, 7, 9, 11]. 이를 해결하기 위하여 다양한 이론과 기법들이 최근에 제안되고 활용되고 있는데, 특히 머신러닝과 위상수학적 기법들이 가장 대표적인 예라 볼 수 있다.

머신러닝 기법은 이미지 내의 객체에 대한 방대한 지식을 축적하여 기계를 학습시킴으로써 사람이 손으로 영역분할하는 과정을 모방하도록 한다. 하지만 안정적이고 강력한 지식과 경험을 기계에 전수시키는 것은 쉬운 일

*정희원, 한국외국어대학교 정보통신공학과
접수일자: 2018년 1월 3일, 수정완료: 2018년 2월 3일
게재확정일자: 2018년 2월 9일

Received: 3 January, 2017 / Revised: 3 February, 2018

Accepted: 9 February, 2018

*Corresponding Author: hihahn@hufs.ac.kr

Dept Information and Communications Eng. Hankuk University of Foreign Studies, Korea

이 아니다. 현재로서는 기술의 한계로 인해 제한된 특정 분야에 적용가능한 수준에 있다. 이에 대한 대표적인 예로 딥러닝을 이용한 SegNet^[1]가 있다. 다른 축으로는 빅데이터, 패턴인식 등의 연구분야에 위상수학 기법을 접목시키고자 하는 연구가 진행되고 있다. 순수수학 중에서도 가장 추상적 범주에 속하는 위상수학 특히 대수적 위상수학은 컴퓨터로 계산 가능케 하는 이론들 (computational topology)의 개발로 인하여 공학의 여러 분야에 응용되기 시작하였고, 이들을 컴퓨터 비전, 이미지 처리, 빅데이터 분석 등에 응용하고자 하는 연구가 크게 증가하고 있다. 위상수학 이론들이 다양한 분야에서 응용되기 시작한 것은 호몰로지 군(homology group)을 효과적으로 계산할 수 있는 툴이 개발되면서 부터이다^[2]. 호몰로지 군은 위상공간이 갖고 있는 다양한 차원의 홀(hole)의 수를 계산함으로써 위상구조를 분석한다. Chasal, et al^[4]는 이미지에서 히스토그램을 추출하여 이를 모스(Morse) 함수^[5]로 지정하고 이로부터 지속적 호몰로지(persistent homology)를 구하여 위상적 지속구간 (topological persistence)이 짧은 영역을 병합시킴으로써 과도한 영역분할(over-segmentation)을 억제시키는 기법을 제안하였다. 이 방식은 기본적으로 영 차원 호몰로지를 이용한다. 반면에, Kurlin은 일 차원 호몰로지를 이용한 기법을 제안하였다^[6]. 이 기법은 이미지에서 에지를 구한 다음 이로부터 충분한 양의 표본을 추출하여 점 집합(point cloud)으로 간주하고, 델라네이(delaunay) 삼각화 기법 등을 이용하여 필터레이션(filtration)을 구성하여 일 차원 호몰로지의 랭크(rank)가 줄어드는 시점의 객체를 추출한다. 이 방식은 에지가 폐곡선 형태를 가져야 제대로 동작하는 단점이 있다.

본 논문에서는 그래프 기반 영역분할 기법^[7]에 위상수학적 개념을 접목하여 성능을 향상시키는 방식을 제안한다. 즉, 이미지의 각 화소를 노드로 정하여 인근 화소와 연결되었다고 가정하고 그 에지에 가중치를 부여하는 무방향 그래프(undirected weighted graph)로 간주하여 이로부터 최소신장트리(minimum spanning tree)를 구는 알고리즘을 이용하여 영역을 분할한다. 그런 다음, 분할된 각 영역의 지속구간을 구하고 짧은 지속구간을 갖는 영역을 인근 영역에 병합시킴으로써 안정적인 영역분할을 얻는다.

본 논문의 구성은 다음과 같다. 2절에서는 그래프 기반 영역분할, 지속적 호몰로지, 모스함수를 이용한 위상

적 지속구간에 대한 이론을 간략히 소개하고 이를 구하는 방식을 설명한다. 3절에서는 지속적 호몰로지 이론을 그래프 기반 영역분할에 접목시켜 이미지를 세그멘테이션하는 제안 알고리즘을 설명한다. 4절에서는 여러 테스트 이미지에 대하여 제안 알고리즘을 이용하여 이미지 세그멘테이션을 수행하였을 때의 결과를 확인하고 널리 알려진 알고리즘들을 적용하였을 때의 결과와 성능을 비교하고 분석한다. 마지막으로 5절에서는 결론을 맺고 향후 연구 진행방향에 대하여 논의한다.

II. 배경 이론

1. 그래프 기반 영역 분할

그래프 $G=(V, E)$ 는 노드 $v_k \in V$ 가 이미지의 각 화소이고 인근 노드 간의 짝에 해당되는 각 에지 $(v_i, v_j) \in E$ 의 가중치는 다음과 같이 정의한다.

$$w((v_i, v_j)) = |I(v_i) - I(v_j)| \quad (1)$$

여기서 $I(v_k)$ 는 화소 v_k 의 밝기를 나타낸다. 컬러 이미지인 경우에는 두 화소 간의 유클리드 거리로 정의된다. $w((v_i, v_j))$ 는 인근 두 화소 간의 밝기 차이지만 관점을 달리 하면 기하적인 거리로 인식할 수도 있다. 동일한 연결성분(connected component)에 속한 노드들 간의 에지 가중치는 작은 값을 갖고 서로 다른 성분에 속한 노드 간의 가중치는 큰 값을 갖도록 노드의 집합 V 를 여러 개의 연결성분으로 분할하면 결국 이미지 세그멘테이션 결과를 얻을 수 있다.

연결성분 $C \subseteq V$ 의 내부 거리 $d_{intr}(C)$ 를 C 의 모든 노드로 구성된 최소신장 트리 $MST(C, E)$ 내의 최대 가중치로, 두 연결성분 C_i 와 C_j 간의 거리 $d(C_i, C_j)$ 는 두 성분을 연결시키는 에지들 중에서 최소 가중치라고 각각 정의하면, $d(C_i, C_j)$ 가 $f(C_i, C_j)$ 보다 크면 C_i 와 C_j 간에 경계선이 있는 것으로 판정하고 그렇지 않으면 C_i 와 C_j 를 병합시킨다. 여기서 $f(C_i, C_j)$ 는 다음과 같이 정의된다.

$$f(C_i, C_j) = \min(d_{intr}(C_i) + \tau(C_i), d_{intr}(C_j) + \tau(C_j)) \quad (2)$$

위 식에서 임계값 τ 는 다음과 같이 주어지는데,

$$\tau(C) = \frac{k}{|C|} \quad (3)$$

$|C|$ 는 성분 C 내에 속하는 화소 수이고 k 는 이미지에 따라 결정되는 상수이다. 이 알고리즘에 의하면, 인근의 두 성분 C_i 와 C_j 간의 거리 $d(C_i, C_j)$ 가 충분히 크면 크기가 작은 성분도 허용된다. 본 논문에서는 Felzenszwalb, et al^[7]의 제안 내용을 기반으로 알고리즘을 구현한다.

2. 지속적 호몰로지

지속적 호몰로지는 형태와 함수 등의 위상적 특징 정보를 측정하기 위한 대수적 알고리즘이다. 기하구조의 연결성에 대한 모든 정보를 명확히 알면 호몰로지를 이용하여 그 구조의 위상특성을 구할 수 있다. 하지만, 어떤 기하구조에서 무작위로 추출된 객체로 주어지면 이들이 어떻게 연결되어 있는지 정확히 알 수 없어 호몰로지를 바로 적용하는데 어려움이 발생한다. 이를 위하여 지속구간 개념이 도입된다. 지속적 호몰로지를 구하기 위해서는 우선 필터레이션 $0 = K^0 \subseteq \dots \subseteq K^m = K$ 을 생성하여야 한다. 여기서 K^i 는 인자 i 에 따른 객체군을 나타낸다. 지속적 호몰로지란 필터레이션을 따라 계산한 호몰로지를 말한다. 여기서 객체 $\sigma \in K^i$ 를 만족시키는 인자 i 의 최소값은 σ 의 필터레이션 인자로 정의되는데, σ 가 k 차원 홀을 필터레이션 인자 s 에서 생성하고 t 에서 소멸시킬 때, 그 구간 $[s, t) = \{x | s \leq x < t\}$ 를 k 차원 홀의 지속구간이라고 부른다. K^s 의 p 지속구간 k 차원 호몰로지 군은 다음과 같은 상군(quotient group)으로 정의되는데^[3, 8],

$$H_k^{s,p} = Z_k^s / (B_k^{s+p} \cap Z_k^s) \quad (4)$$

여기서, $p = t - s$ 이고, Z_k^s 는 K^s 의 k -순환 군(cycle group)을, B_k^{s+p} 는 K^{s+p} 의 k -경계 군(boundary group)을 각각 나타낸다. 이와 같이 매개변수에 따라 위상적 특징이 출현하고 사라짐이 발생하는데, 이들의 쌍은 유일하게 존재하고 호몰로지 군의 준동형 맵(homomorphism)을 이용하여 정의된다. 여기서 지속구간이 짧으면 사슬이 발생한 후 곧 내부가 채워져 사라지는 형상을 나타내므로 위상 잡음으로 간주되는 반면, 긴 구간은 큰 사슬을

의미하므로 중요한 위상 특징을 제공한다. 모스 함수나 단순 복합체 등, 대상에 따라 지속적 호몰로지를 구하는 방식이 많이 다르나 본 논문에서 활용하는 모스 함수에 국한시켜 설명하기로 한다.

3. 모스 함수를 이용한 위상적 지속구간 연산

m 차원 다양체 \mathbb{X} 에 대하여, 모스함수 $f: \mathbb{X} \rightarrow \mathbb{R}$ 는 매끄러운 함수(smooth function)이고 $f'(x) \neq 0$ 인 서로 다른 유한개의 극점만을 갖고 있다고 가정한다. 모든 $t \in \mathbb{R}$ 에서 레벨세트(super-level set) $\mathbb{S}^t = f^{-1}([t, \infty))$ 를 정의하고, 임의의 $x \in \mathbb{X}$ 와 $\alpha \in \mathbb{R}$ 에 대하여 $C(x, \alpha) \subseteq \mathbb{S}^\alpha$ 는 x 를 포함하는 연결성분을 표기한다고 정의한다. t 를 ∞ 에서부터 연속적으로 감소시키면 f 의 국소 극대점 p_{\max} 에서 $C(p_{\max}, \alpha)$ 가 \mathbb{S}^α 에 생성된다. 이때, $\alpha = f(p_{\max})$ 이다. t 를 계속 감소시키면 레벨세트의 연결성이 그대로 유지되다가 극점에서 연결성이 변함을 알 수 있다. 즉, 국소 극대점 p_{\max} 에서 레벨세트의 연결성분이 한 개 증가하다가 국소 극소점 p_{\min} 에서 서로 다른 두 연결성분이 만나게 되고, $p_{\max} \leq q_{\max}$ 이면 $C(p_{\max}, \alpha)$ 는 $C(q_{\max}, \alpha)$ 에 병합된다. 이때 $C(p_{\max}, \alpha)$ 의 지속구간은 $f(p_{\max}) - f(p_{\min})$ 으로 정의되고, 이차원 평면상의 점 $p = (f(p_{\max}), f(p_{\min}))$ 으로 매핑시켜 표현할 수 있는데, 이를 지속구간 다이어그램(persistence diagram)이라고 부른다^[8]. 이 다이어그램에서 각 짝에 해당되는 모든 점은 이차원 평면의 대각선 위에 존재함을 알 수 있다. 즉, 각 점은 임계값을 감소시키면서 생겨난 레벨세트의 각 연결성분이 태어난 시점($f(p_{\max})$)과 소멸 시점($f(p_{\min})$)을 좌표로 표시한 것이고 각 연결성분의 지속구간은 이에 해당되는 점과 대각선의 수직 거리로 표현된다. 예를 들어, 그림 2에서 좌표 (27, 56)에 존재하는 점은 $56 - 27 = 29$ 의 지속구간을 갖는데, 이 값이 클수록 위상적으로 중요한 연결성분으로 간주된다.

두 개의 임계값 $\alpha > \beta$ 에 해당되는 레벨세트는 $\mathbb{S}^\alpha \subseteq \mathbb{S}^\beta$ 를 만족한다. α 에서부터 β 로 진행하면서 \mathbb{S}^α 내의 연결성분들은 병합되기도 하고 새로 태어나기도 한다. 여기서 α 이전에 태어나서 \mathbb{S}^β 에서 개별적인 연결성분으로 남아 있는 연결성분의 수 $\beta_0^{\alpha, \beta}$ 를 지속적 베타 수(PBN: persistence betty number)라고 부르며, $f(x) \geq \alpha > \beta > f(y)$ 를 만족하는 점 (x, y) 의 개수와 동일한 값을 갖는다. 그런데 클러스터링이나 영역분할

등의 응용에서는 임계값 $\tau \geq 0$ 의 개념이 도입된다. 즉, 지속구간이 τ 보다 작은 연결성분들은 위와 같은 방식으로 병합되는 과정을 겪으면서 소멸되기도 하고, 한편으로는 주위의 지속구간이 작은 연결성분들을 병합시켜 가면서 자신의 지속구간을 증가시키는 대표 연결성분들도 발생한다. 이러한 과정을 거쳐 일단 지속구간이 τ 보다 커지면 더 이상 다른 연결성분에 병합되지 않고 자신의 독립성을 유지하게 된다.

III. 제안 알고리즘

1. 필터레이션 생성과 지속구간 측정

등고선 지도만으로 그 지대의 기하구조를 충분히 정확하게 파악할 수 있는 것과 마찬가지로 이미지의 밝기 정보를 해당 영역의 고도라고 간주하면 이미지의 등고선 정보만을 활용하여도 이미지의 영역 분할이 가능하다는 것이 본 논문의 핵심 개념이다. PBN을 이용하면 이러한 개념을 효과적으로 구현할 수 있는데, 이를 위하여 다음과 같이 레벨세트를 정의한다.

$$K^\alpha \equiv K(\phi \geq \alpha) = \{x \in K : \phi(x) \geq \alpha\} \quad (5)$$

위 식에서 K 는 이미지를, x, α 는 화소와 밝기의 임계값을 각각 나타낸다. 이를 기반으로 필터레이션 $0 = K^{\alpha_{-1}} \subseteq K^{\alpha_0} \subseteq K^{\alpha_1} \subseteq \dots \subseteq K^{\alpha_m} = K$ 을 먼저 생성한다. 여기서 $\alpha_{-1} > 255 \geq \alpha_0 > \dots > \alpha_m \geq 0$ 는 단조 감소 수열이다. 준동형 맵 $\pi_q^{(\alpha, \beta)} : H_q(\phi \geq \alpha) \rightarrow H_q(\phi \geq \beta)$ 는 포함 맵(inclusion map) $i^{(\alpha, \beta)} : K(\phi \geq \alpha) \rightarrow K(\phi \geq \beta)$ 에 의해 유도된다고 가정한다. 여기서 $q \in \mathbb{Z}$, $\alpha \geq \beta$ 이고 H_q 는 q 차원 호몰로지 군을 나타낸다. 이때, q 차원 PBN은 $\pi_q^{(\alpha, \beta)}$ 의 치역의 랭크로 정의된다. 그림 1은 Lena 이미지에서 구한 필터레이션의 일부를 보여준다.



(a) (b) (c)



(d) (e) (f)

그림 1. Lena 이미지의 필터레이션

(a) K^{218} (b) K^{203} (c) K^{170} (d) K^{155} (e) K^{126} (f) K^{82}

Fig 1. Filtration generated using Lena image

(a) K^{218} (b) K^{203} (c) K^{170} (d) K^{155} (e) K^{126} (f) K^{82}

이와 같이 필터레이션이 주어지면 그림 2에 제시한 바와 같이 PBN에 대한 지속구간 다이어그램을 구할 수 있다. 그림 1에서 볼 수 있는 바와 같이 α 가 크면 동일한 영역인데도 불구하고 연결성분들이 불연속적인 형태로 나타난다. 하지만 α 가 점차 감소함에 따라 불연속적인 연결성분들이 병합되기 시작하고 새로운 연결성분들이 등장하기 시작한다. 이 때, 연결성분들이 병합되는 시점은 화소의 밝기로 주어지는 모스함수의 극소점에 해당된다. 또한, 동일 영역에 속하는 연결성분들은 α 가 약간만 감소해도 병합되기 시작하지만 서로 다른 영역에 속하는 영역일수록 병합하려면 α 가 크게 감소해야 함을 알 수 있다. 이러한 현상은 그림 2에 주어진 지속구간 다이어그램에 반영되어 있다. 즉, 동일영역에 속해 지속구간이 짧은 연결성분들은 대부분 대각선 근처의 점으로 나타나지만 서로 다른 영역에 속하는 유의미한 연결성분들은 대각선에서 멀리 떨어진 점으로 표현된다. 따라서 앞 절에서 설명한 방식으로 지속구간이 짧은 연결성분들을 병합시켜 가면서 멀리 떨어진 점에 해당되는 영역들을 조합하면 이미지 세그멘테이션 결과를 얻을 수 있다.




그림 2. 그림 1의 필터레이션에서 구한 지속구간 다이어그램

Fig. 2. Persistence diagram calculated from the filtration given in Fig. 1.

예를 들어, 그림 1(a)의 우측 상단에 있는 모자에 해당 되는 두 개의 연결성분 중에서 역 c 자 형태의 성분은 K^{229} 에서 생성되고 대각선 형태의 성분은 K^{223} 에서 태어나서 K^{199} 에서 병합되어 사라진다. 따라서 대각선 형태의 성분은 $\alpha = 223$ 일 때 태어나서 $\alpha = 199$ 즉, K^{199} 까지 생존하고 있으므로 이의 지속구간은 $223 - 199 = 24$ 가 된다. 이는 그림 2에 제시한 지속구간 다이어그램 상의 한 점 $p = (p_x, p_y)$ 으로 표현된다. 이 때, 그 점의 좌표 값들은 각각 $p_x = 246 - 223 = 23$, $p_y = 246 - 199 = 47$ 이다. 여기서 246은 Lena 이미지 화소의 최대값을 나타낸다. 즉, 대각선 형태의 성분은 그림 2의 좌표 (23, 47)에 한 점으로 나타난다. 반면에 역 c 자 형태의 성분은 계속 생존해서 K^{182} 에서 얼굴의 이마 부분을 병합하지만 K^{143} 에서 그림 1(a)의 최우측 상단에 있는 배경영역에 병합된다. 따라서 역 c 자 형태의 성분은 그림 2의 점 (17, 103)에 한 점으로 표시되고 86의 지속구간을 갖는다. 본 논문에서는 이미지에 따라 적절한 임계값을 찾는 후에 임계값보다 큰 지속구간을 갖는 성분만을 고려한다.

2. 제안 알고리즘

본 논문에서 제안하는 알고리즘은 다음과 같이 크게 두 단계로 구성된다. 첫 단계에서는 우선 입력 이미지에서 화소 밝기의 최대값 α_0 와 최소값 α_m 을 각각 구한 다음, 이를 기반으로 필터레이션을 생성한다. α_0 에서부터 시작하여 각 레벨세트(K^{α_k})마다 연결성분들을 검출한 후, 각 성분 $C(p, \alpha_k)$ 에 대하여 그 이전 레벨세트($K^{\alpha_{k-1}}$)에서 검출된 성분 $C(q, \alpha_{k-1})$ 과 연결되어 있으면 $C(p, \alpha_k)$ 의 루트 $r(C(p, \alpha_k))$ 를 $r(C(q, \alpha_{k-1}))$ 로 지정한다. 그렇지 않으면 $C(p, \alpha_k)$ 는 처음으로 태어난 것이므로 $r(C(p, \alpha_k)) \leftarrow C(p, \alpha_k)$ 로 지정하고 $r(C(p, \alpha_k))$ 는 α_k 를 그 값으로 갖는다. 만일 $C(p, \alpha_k)$ 가 서로 다른 성분 $C(q, \alpha_{k-1})$ 와 $C(s, \alpha_{k-1})$ 등에 연결되어 있으면, $r(C(q, \alpha_{k-1}))$ 와 $r(C(s, \alpha_{k-1}))$ 의 값들을 비교하여 $r(C(q, \alpha_{k-1}))$ 가 더 큰 값을 가지면 $r(C(p, \alpha_k)) \leftarrow r(C(q, \alpha_{k-1}))$ 로 지정함과 동시에 $r(C(s, \alpha_{k-1}))$ 는 $r(C(s, \alpha_{k-1}))$ 의 값에서 α_{k-1} 를 뺀 값을 지속구간으로 갖는다. 이 때, $C(q, \alpha_{k-1})$ 와 $C(s, \alpha_{k-1})$ 는 자동적으로 $C(p, \alpha_k)$ 로 병합됨을 알 수 있다. 이와 같은 과정을 α_m 에 이르기 까지 반복수행하고 앞 절에서 설명한 방식대로 지속구간 다이어그램을 구한다^[4].

두 번째 단계에서는 위에서 구한 지속구간 다이어그램을 관찰하여 이의 대각선에서 크게 떨어진 점들의 개수와 이들의 지속구간을 분석하여 최소값을 임계값 τ 로 지정한 다음, 2.1 절에서 설명한 그래프 기반 영역분할을 이용하여 이미지의 영역을 분할하고 각 영역의 지속구간을 구한 다음, τ 보다 작은 지속구간을 갖는 연결성분들을 인근의 연결성분과 병합시킴으로써 이미지를 세그멘테이션한다.

IV. 실험 및 결과

제안 알고리즘의 동작을 확인하기 위하여, 우선 Lena 이미지에서 필터레이션 내에 존재하는 각 연결성분의 지속구간을 위에서 설명한 대로 구한다. 실험에서는 그림 2에 주어진 지속구간 다이어그램의 대각선에서 일정거리 이상 떨어진 점만을 고려하는데, 그러한 점의 수가 분할된 영역의 개수와 일치한다. 그림 3은 지속구간의 임계값의 변화에 따른 Lena 이미지의 세그멘테이션 결과를 보여준다. 이 그림에서 세그멘테이션된 각 영역은 의사 색상(pseudo color)으로 매핑하여 표현하였기 때문에 매 결과마다 동일 영역이라도 다른 색상으로 표현된다. 이 그림을 통해 알 수 있듯이, 이미지 데이터의 위상정보를 활용하면 보다 개선된 세그멘테이션 결과를 얻을 수 있다.



그림 3. 지속구간 임계값 τ 의 변화에 따른 Lena 이미지의 세그멘테이션 결과.

(a) 입력이미지, (b) $\tau = 20$, (c) $\tau = 30$, (d) $\tau = 50$

Fig. 3. Results of segmentation corresponding to the values of the threshold τ .

(a) Input image, (b) $\tau = 20$, (c) $\tau = 30$, (d) $\tau = 50$

기존에 발표된 타 알고리즘과의 성능비교를 위하여, 동일한 이미지에 대하여 워터셰드 기법을 이용한 알고리즘^[9]과 평균이동(mean shift) 알고리즘^[10]으로 이미지 세그멘테이션한 결과 이미지를 그림 4에 제시한다.




그림 4. 워터셰드와 평균이동 알고리즘의 이미지 세그멘테이션 결과.

(a) 워터셰드, (b) 평균이동 알고리즘

Fig. 4. Results of segmentation using the watershed and mean shift algorithms.

(a) Watershed, (b) Mean shift algorithm

이 그림을 보면 두 알고리즘 모두 입력 이미지에 최적으로 튜닝된 결과는 아닐지라도 전체적으로 여러 영역이 병합된 형태(under segmentation)의 결과를 보여 준다. 특히, 평균이동 방식은 영역에 따라 과분할(over segmentation) 현상도 혼재되어 있음을 볼 수 있는데, 이는 이미지의 제한된 데이터로부터 매끄러운 히스토그램을 검출하지 못함으로 인해 발생된 것으로 분석된다. 이러한 문제는 지속적 호몰로지를 이용하면 크게 개선될 수 있음이 발표된 바 있다^[4]. 제안 알고리즘을 다양한 형태의 이미지에 적용하더라도 비교적 정확하게 영역을 분할하고 있음을 확인하였는데, 그 일부를 그림 5에 제시한다.


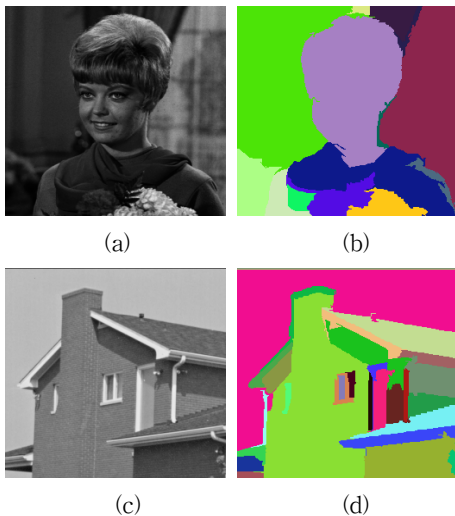


그림 5. 제안 알고리즘의 이미지 세그멘테이션 결과.

(a) (c) (e) 입력 이미지 (b) (d) (f) 결과 이미지

Fig. 5. Results of segmentation using the proposed method.

(a) (c) (e) Input images (b) (d) (f) Segmentation results

V. 결론

본 논문에서는 이미지의 레벨셋을 이용하여 필터레이션을 구한 다음, 필터레이션의 추이에 따라 각 레벨셋의 연결성분들이 새로 생성되고 병합되는 과정들을 영차원 호몰로지 군의 관점에서 분석하여 이를 기반으로 이미지를 세그멘테이션하는 기법을 제안하였다. 이 알고리즘은 검출된 각 연결성분의 위상적 지속구간을 이용하여 과분할을 억제하는 이득을 얻을 수 있었다. 하지만 이미지에 따라 적절한 임계값을 구하여야 하는 어려움이 있어 이에 대한 연구가 앞으로 더 지속되어야 할 것이다. 또한, 현 수준에서는 영 차원 호몰로지만 구현하여 사용하고 있으나 향후에는 일 차원 호몰로지를 구하는 알고리즘을 추가하여 이미지 내의 홀(hole)의 존재유무와 개수를 주요한 위상정보로 활용할 계획이다.

References

- [1] A. Garcia-Garcia, S. Orts-Escolano, S.O. Oprea, V. Villena-Martinez, and J. Garcia-Rodriguez, "A review on deep learning techniques applied to semantic segmentation," arXiv:1704.06857v1 [cs.CV] 22, Apr. 2017.
- [2] H. Edelsbrunner, D. Letscher and A. Zomorodian, "Topological persistence and simplification," Discrete Computational Geometry 28, pp. 511-533, 2002. DOI: 10.1007/s00454-002-2885-2
- [3] A. Zomorodian and G. Carlsson, "Computing

- persistent homology,” Discrete Computational Geometry, Vol. 33, Issue 2, pp. 249-274, 2005. <https://doi.org/10.1007/s00454-004-1146-y>
- [4] F. Chazal, L. Guibas, S. Oudot, and P. Skraba, “Persistence-based clustering in riemannian manifolds,” Technical report, <https://hal.inria.fr/inria-00389390/document>, 2009.
- [5] J.W. Milnor, Morse theory, Princeton university press, 1963.
- [6] V. Kurlin, “A fast persistence-based segmentation of noisy 2D clouds with provable guarantees,” Pattern Recognition Letters 83, pp. 3-12, 2016. DOI: <https://doi.org/10.1016/j.patrec.2015.11.025>.
- [7] P. Felzenszwalb and D. Huttenlocher, “Efficient graph-based image segmentation,” International Journal of Computer Vision, Vol. 59, No. 2, pp. 167-181, September 2004 DOI: <https://doi.org/10.1023/B:VISI.0000022288.19776.77>
- [8] H. Edelsbrunner, and J. Harer, “Persistent homology—a survey,” In Twenty Years After, AMS, 2007.
- [9] R. Bandara, “Image segmentation using unsupervised watershed algorithm with an over-segmentation reduction technique,” <https://www.codeproject.com/Articles/751744/Image-Segmentation-using-Unsupervised-Watershed-AI>
- [10] D. Comaniciu and P. Meer, “Mean shift: a robust approach toward feature space analysis,” IEEE Trans. Pattern Analysis and Machine analysis, Vol. 24, No. 5, May, 2002. DOI: 10.1109/34.1000236
- [11] H. Ying and J. Song, “Recognition Model of Road Signs Using Image Segmentation Algorithm,” The Journal of The Institute of Internet, Broadcasting and Communication (JIIBC), Vol. 13, No. 2, pp. 233-237, April, 2013. DOI: <https://doi.org/10.7236/JIIBC.2013.13.2.233>.

저자 소개

한 희 일(정회원)



- 1984년 : 서울대학교 제어계측공학과 학사 졸업.
- 1988년 : 서울대학교 제어계측공학과 석사 졸업.
- 1995년 : University of Arizona 전기 및컴퓨터공학과 박사 졸업.
- 2015년 현재 : 한국외국어대학교 정보통신공학과 교수.

<주관심분야 : 신호처리, 컴퓨터비전, 패턴인식, 기하학 및 토폴로지>