

논문 2009-46SC-6-1

그래프 이론 기반의 클러스터링을 이용한 영상 감시 시스템 시야 내의 출입 영역 검출

(Detection of Entry/Exit Zones for Visual Surveillance System using
Graph Theoretic Clustering)

우 하 용*, 김 경 환**

(Hayong Woo and Gyeonghwan Kim)

요 약

여러 대의 카메라를 이용한 감시 시스템이 정확하고 효율적으로 동작하기 위하여 카메라 시야 간의 연결 관계를 아는 것이 필수적이다. 카메라들의 연결 관계를 파악하기 위하여 카메라 시야 내의 출입 영역을 검출하는 일이 선행되어야 한다. 본 논문에서는 카메라 시야에서 객체의 등장 및 퇴장으로부터 얻은 데이터에 그래프 이론 기반의 클러스터링(clustering)을 적용하여 시야 내의 출입 영역을 검출하는 방법을 제안한다. 데이터 포인트들 사이의 관계를 조사하여 최소신장트리를 구성하고, 트리의 에지들 중 일관성을 갖지 않는 것들을 삭제하여 well-formed 클러스터를 얻는다. 본 논문에서는 클러스터의 형태를 설명하는 두 가지 특징을 정의하고 이를 클러스터의 분할 조건으로 사용하였다. 실험결과를 통하여 데이터 포인트의 분포가 조밀하지 않은 경우 expectation maximization(EM)에 기반을 둔 방법에 비하여 제안하는 방법이 보다 효과적으로 클러스터링을 수행함을 확인하였다. 또한 EM 기반 방법들에 비하여 안정적인 결과를 얻기 위해 필요한 데이터 포인트의 개수가 적으므로 출입영역에 대한 학습시간을 단축할 수 있다.

Abstract

Detecting entry and exit zones in a view covered by multiple cameras is an essential step to determine the topology of the camera setup, which is critical for achieving and sustaining the accuracy and efficiency of multi-camera surveillance system. In this paper, a graph theoretic clustering method is proposed to detect zones using data points which correspond to entry and exit events of objects in the camera view. The minimum spanning tree (MST) is constructed by associating the data points. Then a set of well-formed clusters is sought by removing inconsistent edges of the MST, based on the concepts of the cluster balance and the cluster density defined in the paper. Experimental results suggest that the proposed method is effective, even for sparsely elongated clusters which could be problematic for expectation-maximization (EM). In addition, comparing to the EM-based approaches, the number of data required to obtain stable outcome is relatively small, hence shorter learning period.

Keywords: visual surveillance, clustering, camera topology, minimum spanning tree, entry/exit zones detection

I. 서 론

카메라로부터 얻은 영상의 해석 결과를 이용하여 특정 영역에 대한 감시를 수행하는 시스템은 많은 인력을 필요로 하는 기존의 감시 시스템들에 비해 효율적이기

때문에 연구뿐만 아니라 상업적인 영역에서 많은 관심을 받고 있다^[1]. 이러한 카메라 기반 감시 시스템은 객체가 카메라 시야 안에 등장하면서부터 퇴장할 때까지 일관된 추적을 수행하는 것을 기본적인 목적으로 한다. 이 때, 객체의 위치만을 추적하는 것뿐만 아니라 객체의 행동 양상에 대한 해석을 통하여 보다 적극적인 감시를 수행할 수 있다. 객체의 행동 양상 해석의 예로 객체의 등장 또는 퇴장이 일어나는 영역에 대한 정의를 내리는 일이나 객체의 주된 이동 경로를 파악하는 것

* 학생회원, ** 정회원, 서강대학교 전자공학과
(Dept. of Electronic Engineering, Sogang Univ.)
{stiller99, gkim}@sogang.ac.kr
접수일자: 2009년4월9일, 수정완료일: 2009년10월26일

등을 들 수 있다. 이러한 부가적인 정보를 수동으로 입력하는 데에는 한계가 있다. 사람의 눈을 통한 장면의 해석이나 행동 양상에 대한 판단 기준이 주관적이기 때문에 부정확한 정보가 될 수 있기 때문이다. 또한, 보다 넓고 복잡한 영역에 대한 감시를 수행하기 위하여 여러 대의 카메라를 사용하는 시스템의 경우 수십대 이상의 카메라 시야에 대한 정보를 입력하는 것이 쉽지 않다. 그러므로 객체에 대한 적극적인 추적을 수행하기 위하여 객체 행동 양상 분석이 자동으로 이루어져야 한다.

따라서 본 연구에서는 한 시야 내에서 객체가 등장하거나 퇴장하는 영역을 검출하는 방법을 제안한다. 시야 내에서 객체들이 자유로이 움직이는 환경에서 객체가 등장하거나 퇴장하는 시점의 위치가 분석의 대상으로 사용되었다. 객체가 등장하거나 퇴장하는 영역, 즉 출입 영역을 검출하여 시야 내의 객체 이동 경로를 예측하는 데 활용할 수 있다. 그리고 객체들이 시야 내의 특정 영역을 통하여 출입하므로 추적 실패를 보완하기 위한 정보로써 사용될 수 있다. 또한 멀티 카메라 감시 시스템에서 객체의 카메라 간 이동 경로를 예측하는 일에 활용할 수 있다. 왜냐하면 객체가 시야에 등장하거나 시야로부터 사라지는 것은 객체의 카메라 간 이동을 의미하기 때문이다^[2].

본 논문에서는 그래프 이론 기반의 클러스터링을 이용한 시야 내의 출입 영역 검출 방법을 제안한다. 카메라 시야 내의 출입 영역을 검출하는 것에 대한 몇몇 연구가 선행되었다. Makris 와 Ellis^[3]은 비디오 스트림 내의 객체 행동의 분석을 통하여 출입 영역뿐만 아니라 객체의 경로, 교차로와 같은 시야 내의 객체 움직임을 모델링하고자 하였다. 그들은 한 시야 내의 출입 영역들을 혼합 가우시안으로 가정하고 EM을 적용하여 각 가우시안의 파라미터들을 추정하였다. Stauffer^[4]는 출입 영역을 추출함과 동시에 객체 추적을 실패한 구간에 대한 보완 및 보정을 수행하고자 하였다. 상기 두 연구는 모델의 파라미터를 추정하기 위하여 EM을 적용하였고, 이는 최종 클러스터의 개수를 지정해 주어야 함을 의미한다. 그러나 시야 내의 출입 영역 개수는 단순히 시야 내 감시 환경의 구조에 의해 명백히 정해지지 않을 뿐만 아니라 각기 다른 시야에서 동일한 값을 갖지 않는다. Stauffer의 연구에서는 클러스터의 개수, 즉 출입 영역의 개수 또한 최적화 되어야 할 파라미터로 설정되었다. Makris와 Ellis는 최종 클러스터의 개수를 비교적 크게 설정하여 학습을 수행한 후 전체 데이터에

비해 비중이 작은 클러스터들을 삭제하는 방식을 사용하였다. 이 경우, 최종 클러스터 개수가 시야 내의 구조 또는 데이터 포인트의 분포 양상과 무관하게 설정되므로 실제 클러스터 개수가 추정 값보다 적을 경우 원치 않는 클러스터 분할이 발생할 가능성이 높다. 즉, 시야 내의 출입 영역들의 실제 형태가 보존되지 않게 된다.

이러한 단점을 보완하기 위하여 클러스터 분할을 기반으로 한 하향식(top-down)의 클러스터링 방법을 제안한다. 최종 클러스터 개수의 설정은 필요하지 않으며 클러스터 분할 여부를 결정하는 두 가지의 기준을 제안하였다. 실험을 통하여 데이터의 분포가 일정한 형태를 가지고 있으나 그 밀집도가 떨어지는 경우에도 분포 형태가 고려된 출입 영역 추출을 제대로 수행함을 확인하였다. 또한 EM에 기반을 둔 방법과의 비교를 통하여 효율성과 안정성이 보다 뛰어남을 확인하였다.

제안하는 클러스터링 방법은 주어진 데이터 포인트들을 이용하여 최소 신장 트리(MST: minimum spanning tree)를 구성하는 것에서부터 시작된다. 최소 신장 트리의 에지 중에서 이웃하는 에지들에 비해 특이성을 갖는 것들을 삭제하여 최소 신장 트리의 부분 트리를 얻게 된다. 최소 신장 트리의 각 부분 트리가 하나의 클러스터가 된다. 모든 클러스터가 well-formed가 될 때까지 클러스터의 분할을 반복한다.

Ⅱ장에서 그래프 이론 기반의 클러스터링에 관해 소개한 후 에지의 비일관성을 결정하는 방법과 클러스터의 특징을 설명한다. Ⅲ장에서는 클러스터의 제한적인 분할에 관해 다룬다. 마지막으로 실험 결과와 결론을 서술한다.

II. 그래프 이론 기반 클러스터링

그래프 이론을 바탕으로 하는 클러스터링 방법들은 일반적이지 않고 복잡한 형태의 데이터 분포를 다루는데에 적합하다^[5]. 그럼 1에서 우리가 다루려고 하는 데이터 포인트의 예를 볼 수 있다. 이 데이터 포인트들은 객체의 등장 시점 또는 퇴장 직전 시점의 객체 위치에 대응된다. 그림에서 실제 출입구의 위치를 고려할 때 데이터 포인트들이 크게 세 그룹으로 구분되는 것이 바람직한 결과이다. 이 때 각 포인트 그룹의 밀도와 분포 형태가 다른 것을 볼 수 있다. 또한 하단에 가로 방향의 성긴 형태로 위치한 그룹의 경우 그 분포를 설명할 수 있는 모델을 찾기 어렵다. 그러나 하단의 포인트들은

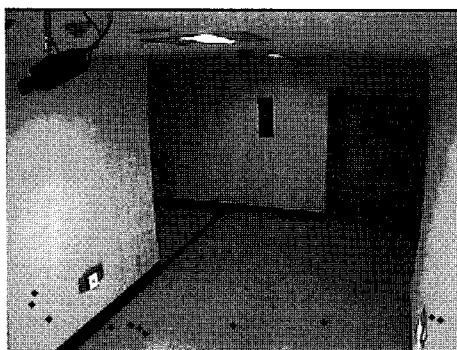


그림 1. 데이터 포인트의 예
Fig. 1. Example of data points.

출입 영역 검출이라는 측면에서 보면 하나의 그룹으로 인지될 필요가 있다. 그래프 이론 기반의 클러스터링은 특정 모델을 데이터 포인트에 맞추기 보다는 포인트들의 분포 형태를 고려하여 적절한 그룹의 배치를 하도록 동작한다.

Foggia 등^[6]의 실험 결과에 따르면 여러 그래프 이론 기반의 클러스터링 방법 중 최소 신장 트리 기반의 방법이 가장 효과적으로 동작한다. Zahn^[7]은 최소 신장 트리에 포함된 에지 가운데 일관성을 갖지 않는 에지들을 제외하는 방식의 클러스터링 방법을 제안하였고 이는 다양하게 변형, 확장 되었다^[8]. 본 연구에서도 Zahn의 방법을 기본으로 한 클러스터링 방법을 제안한다. 그래프 이론 기반의 클러스터링을 수행하기 위하여 각 데이터 포인트들을 그래프의 정점으로 설정하며 각 정점 사이의 유사도는 정점들을 연결하는 에지와 그 가중치로 표현한다. 본 논문에서는 정점 사이의 유clidean 거리를 유사도 판단의 기준으로 사용하였다.

1. 최소 신장 트리

연결 그래프의 신장 트리는 그 그래프의 모든 정점을 포함하고 순환이 없는 부분 그래프를 말한다. 그래프의 최소 신장 트리는 에지 가중치의 합이 최소인 신장 트리를 말한다. 주어진 그래프에서 최소 신장 트리를 찾는 알고리즘 가운데 Kruskal의 알고리즘과 Prim의 알고리즘이 널리 사용되고 있다. 본 연구에서는 Kruskal의 알고리즘을 이용하였다. 최소 신장 트리는 네트워킹, 영상 분할, 클러스터링 등 다양한 분야에서 사용되고 있다^[9].

주어진 데이터 포인트를 사용하여 구성한 최소 신장 트리의 예를 그림 2에서 볼 수 있다. 각 포인트 사이의 유사도가 에지의 가중치로 나타나므로 어떤 에지의 가

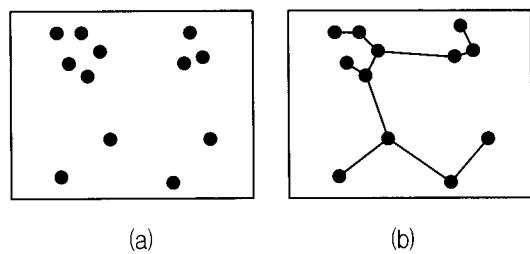


그림 2. (a) 데이터 포인트, (b) 최소 신장 트리
Fig. 2. (a) Data points, (b) Minimum spanning tree.

중치와 주변 에지들의 평균적인 가중치 값 사이의 차이가 작을 경우에는 그 에지를 형성하는 두 정점이 같은 클러스터에 속할 확률이 높다. 반면 에지 가중치와 평균적인 가중치 사이의 차이가 클 경우에는 두 정점이 다른 클러스터에 속하게 될 확률이 높다. 따라서 최소 신장 트리를 사용한 클러스터링 방법이 타당함을 알 수 있다.

2. 에지 일관성 판단

최소 신장 트리와 그 부분 트리에 포함된 에지의 일관성을 판단하는 과정은 전역적인 과정과 국부적인 과정으로 나누어진다. 이와 같이 두 단계를 거치는 것은 전체 데이터 포인트의 분포 형태를 고려한 클러스터링 결과를 얻기 위함이다.

주어진 데이터 포인트들을 이용하여 최소 신장 트리를 구성한 후에 그 에지들에 대한 전역적 일관성 판단을 수행한다. 이 때, 전체적인 분포의 구조를 살피기 위하여 최소 신장 트리를 구성하는 모든 에지를 대상으로 한다. 최소 신장 트리에 포함된 m 번째 에지가 다음 식을 만족하면 일관성을 갖지 않는다고 판단한다.

$$l_m - \mu_{m,d} > r\sigma_{m,d} \quad (1)$$

식 (1)에서 l_m 은 m 번째 에지의 가중치이고, $\mu_{m,d}$ 와 $\sigma_{m,d}$ 는 각각 이웃 에지들의 가중치 평균 및 표준편차이다. r 은 비일관성 판단의 임계값을 정하기 위하여 표준 편차 $\sigma_{m,d}$ 에 곱하는 상수 값이며 첨자 d 는 이웃 영역의 깊이를 결정하는 파라미터이다. 식 (1)에 의해 일관성이 부족한 것으로 판단된 에지들을 제거하고 그 결과 최소 신장 트리의 부분 트리들을 초기 클러스터로 얻게 된다. 그림 3은 비디오 시퀀스에서 얻은 데이터 포인트와 그를 이용해 구성한 최소 신장 트리를 보여준다. 최소 신장 트리의 에지들 가운데 일관성을 갖지 않는 것들을 점선으로 표시하였으며 이 에지들을 제거함

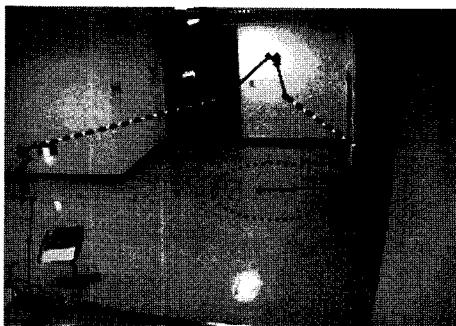


그림 3. 실제 데이터와 최소 신장 트리

Fig. 3. Data points acquired from a video sequence and its MST.

으로써 타당한 초기 클러스터들을 얻을 수 있다는 것을 직관적으로 알 수 있다.

초기 클러스터를 얻은 후 각 클러스터에 포함된 에지들 가운데 가장 가중치가 큰 것들에 대해서 지역적인 일관성 판단을 수행한다. i 번째 클러스터의 최대 가중치를 갖는 에지가 식(2)과 같은 조건을 만족할 때 일관성을 갖지 않는다고 판단한다.

$$L_i - \mu_i > r_L \sigma_i \quad (2)$$

여기서, L_i 는 최대 가중치이고 μ_i 와 σ_i 는 i 번째 클러스터에 속하는 에지들의 평균 가중치와 표준 편차를 각각 의미한다. 또한 r_L 은 식(1)의 r 값과 같이 비일관성 판단의 임계값을 정하기 위해 표준 편차 σ_i 에 곱하는 상수이다. 지역적 일관성 판단 결과는 클러스터들의 분할 여부를 결정하는 조건이 될 뿐 아니라 그림 3에서 점선으로 된 타원 안의 포인트와 같은 outlier를 제거하는 데에 사용될 수 있다. 따라서 최종 클러스터의 형태가 보다 간결하고 정확해진다.

3. 클러스터 특징과 well-formed 클러스터

이 절에서는 클러스터의 특징 두 가지를 설명한다. 각 클러스터를 타원으로 표현하고 클러스터의 균형비와 밀도를 정의한다. 또한 이와 같은 클러스터의 특징들이 well-formed 클러스터를 정의하는 데에 어떻게 사용되는지 설명한다.

각 클러스터를 표현하는 타원은 클러스터에 포함된 포인트들의 중심과 그 공분산 행렬로 정의할 수 있으며 이는 식(3)과 같다. 식(3)에서 \mathbf{x} 는 각 데이터 포인트를 의미하고 n_i 는 i 번째 클러스터에 포함된 포인트의 개수를 의미한다.

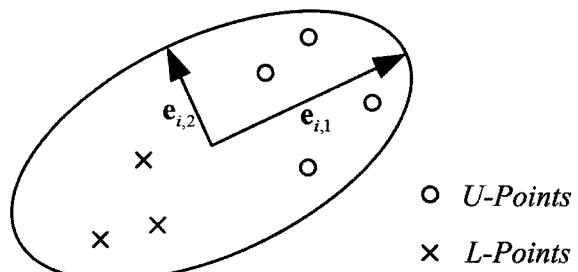


그림 4. 클러스터의 타원 표현

Fig. 4. Elliptic representation of a cluster.

$$\begin{aligned}\mu_i &= \frac{1}{n_i} \sum_{x \in C_i} x \\ \Sigma_i &= \frac{1}{n_i} \sum_{x \in C_i} (x - \mu)(x - \mu)^t\end{aligned} \quad (3)$$

각 클러스터에 포함된 포인트들의 중심이 타원의 중심을 표시하고 공분산 행렬의 두 고유값 $\lambda_{i,1}, \lambda_{i,2}$ ($\lambda_{i,1} \geq \lambda_{i,2}$)와 그에 대응되는 고유 벡터 $e_{i,1}, e_{i,2}$ 가 타원의 축을 결정한다. 그림 4에서 클러스터의 타원 표현에 대한 예를 볼 수 있다.

Well-formed 클러스터를 결정짓는 두 조건 중 하나는 클러스터의 균형 비율이다. 일반적인 지각에 의해 인식할 수 있는 클러스터는 대부분 균형을 이루고 있다. 즉, 한 클러스터 내의 포인트 밀도가 균일하다. 클러스터의 균형 비를 결정하기 위하여 우선 한 클러스터에 속한 각 포인트를 L -point 또는 U -point로 구분한다.

$$\begin{aligned}U-point &\text{ if } e_{i,1} \cdot x_{i,k} \geq 0 \\ L-point &\text{ if } e_{i,1} \cdot x_{i,k} < 0\end{aligned} \quad (4)$$

여기서 L -point와 U -point는 공분산 행렬의 고유 벡터 $e_{i,2}$ 에 대한 각 포인트의 상대적인 위치에 따라서 식(4)와 같이 정의된다. 식(4)에서 $x_{i,k}$ 는 i 번째 클러스터에 속한 k 번째 포인트를 의미하며 U -point와 L -point의 예를 그림 4에 도시하였다. i 번째 클러스터의 균형 비 B_i 는 U -point의 개수와 L -point의 개수의 비로 식(5)과 같이 정의하며 그 값이 0과 1 사이의 범위로 제한되도록 하였다.

$$B_i = \frac{\min(U_i, L_i)}{\max(U_i, L_i)} \quad (5)$$

Well-formed 클러스터를 정의하는 두 번째 기준은

클러스터의 밀도이다. 한 클러스터의 밀도는 식 (6)과 같이 쓸 수 있다.

$$\begin{aligned} D_i &= \frac{S_i}{E_i} \\ E_i &= \pi \sqrt{\lambda_{i,1} \lambda_{i,2}} \end{aligned} \quad (6)$$

식 (6)에서 S_i 는 i 번째 클러스터에 포함되는 에지 가중치의 합이고 E_i 는 그 클러스터를 표현하는 타원의 면적이다. 밀도를 정의하는 데에 가중치의 합을 사용하는 것은 타원의 면적이 밀도 값에 미치는 영향을 줄이기 위함이다. 특히 그림 1의 하단에서와 같이 데이터 포인트의 분포가 길게 늘어진 경우 타원의 면적이 넓으므로 밀도가 작아지지만 문자가 가중치의 합으로 구성되므로 분포 형태가 고려된 밀도 값을 얻는다.

위에서 설명한 클러스터의 두 가지 특징을 사용하여 well-formed 클러스터를 정의할 수 있다. Well-formed 클러스터는 균형을 이루고 있으며 조밀한 분포를 가져야 한다. 클러스터가 균형을 이루고 있다면 $U-point$ 와 $L-point$ 의 개수가 비슷하다는 것을 의미한다. 따라서 클러스터가 well-formed이기 위해서는 균형 비가 1에 가까운 값을 가져야 한다. 또한 well-formed 클러스터는 높은 밀도 값을 가져야 한다. 예를 들어 어떤 클러스터의 균형비가 1이고 클러스터에 포함된 데이터 포인트의 수가 2라고 가정하자. 이러한 경우 균형비가 1이므로 두 개의 포인트 중 하나는 $U-point$ 이고 나머지 하나는 $L-point$ 이다. 이 클러스터는 완벽하게 균형을 이루지만 well-formed 클러스터로 구분되기에는 밀도가 충분히 높지 못하다. 반면, 클러스터의 밀도가 높은 경우 클러스터의 균형비가 1에 가까울 것이라고 단정 지을 수 없다. $U-point$ 와 $L-point$ 개수의 차이가 크다면 그 클러스터에 속하는 포인트들이 같은 출입영역에 속할 확률이 적다. 따라서 클러스터 균형비와 밀도는 서로 상보적인 조건이며 well-formed 클러스터를 정의하기 위한 필요조건이다.

III. 클러스터의 제한적 분할

제안하는 클러스터링 방법은 클러스터의 분할에 기반을 둔(divisive) 방식이다. 전역적 비일관성 판단에 의해 에지들을 삭제하여 초기 클러스터를 얻은 후, 클러스터들은 다음과 같이 처리된다.

모든 클러스터는 분할을 수행하기에 적절한지에 대

한 판단을 거치게 된다. 첫 번째 조건은 해당 클러스터의 최대 가중치를 갖는 에지가 일관성을 갖지 않아야 한다는 것이다. 두 번째 조건은 클러스터의 균형 비와 밀도 값이 일정 임계값 이하이어야 한다는 것이다. 이 두 조건은 식 (7)과 같이 표현된다.

$$(I_i = (true)) \wedge \{(B_i < B_{TH}) \vee (D_i < D_{TH})\} \quad (7)$$

위 식에서 I_i 는 i 번째 클러스터의 비일관성을 표시하며 B_{TH} 는 균형 비 임계값이고 D_{TH} 는 밀도 임계값이다. 클러스터의 분할은 well-formed가 아니며 일관성을 갖지 않는 에지를 가지는 클러스터에만 적용된다. 또한 더 이상 분할할 수 있는 클러스터가 없을 때까지 분할 과정을 반복하게 된다.

분할 과정이 멈춘 후에 중요도가 떨어지는 클러스터들을 삭제한다. 이러한 클러스터는 하나의 데이터 포인트가 하나의 클러스터를 이루는 경우이거나 또는 식 (8)과 같이 정의되는 클러스터 퍼센트 밀도^[3]가 작은 경우이다.

$$P_i = \frac{W_i}{E_i} \quad (8)$$

식 (8)에서 W_i 는 전체 데이터 포인트 수와 i 번째 클러스터에 속한 포인트의 수의 비를 퍼센트로 나타낸 것이다.

IV. 실험 결과

제안한 방법의 타당성을 확인하기 위하여 하나 이상의 출입 영역을 포함하는 6개의 시야에 대해 출입 영역 검출 실험을 수행하였다. 사용한 데이터 포인트들은 비디오 시퀀스 내에서 추출한 객체의 등장과 퇴장 위치이다. 모든 데이터 집합에 대한 실험에 동일한 파라미터를 사용하였다. ($r = 2.5$, $r_L = 2.5$, $B_{TH} = 0.65$, $D_{TH} = 0.01$)

그림 5의 (a)~(f)는 각 시야의 출입영역 검출 결과를 도시하고 있다. 각 그림에 데이터 포인트와 최소 신장 트리가 도시되어 있으며 타원으로 최종 클러스터들을 표시하였다. 최소 신장 트리의 에지를 가운데 점선으로 표시된 것은 일관성을 갖지 않는 것들이다.

각 시야에 대해 사용한 데이터 포인트의 수와 검출된 출입영역의 수, 실제 출입영역의 수는 표 1과 같다. 6개의 시야에서 실제 출입 영역에 해당하는 영역을 모두

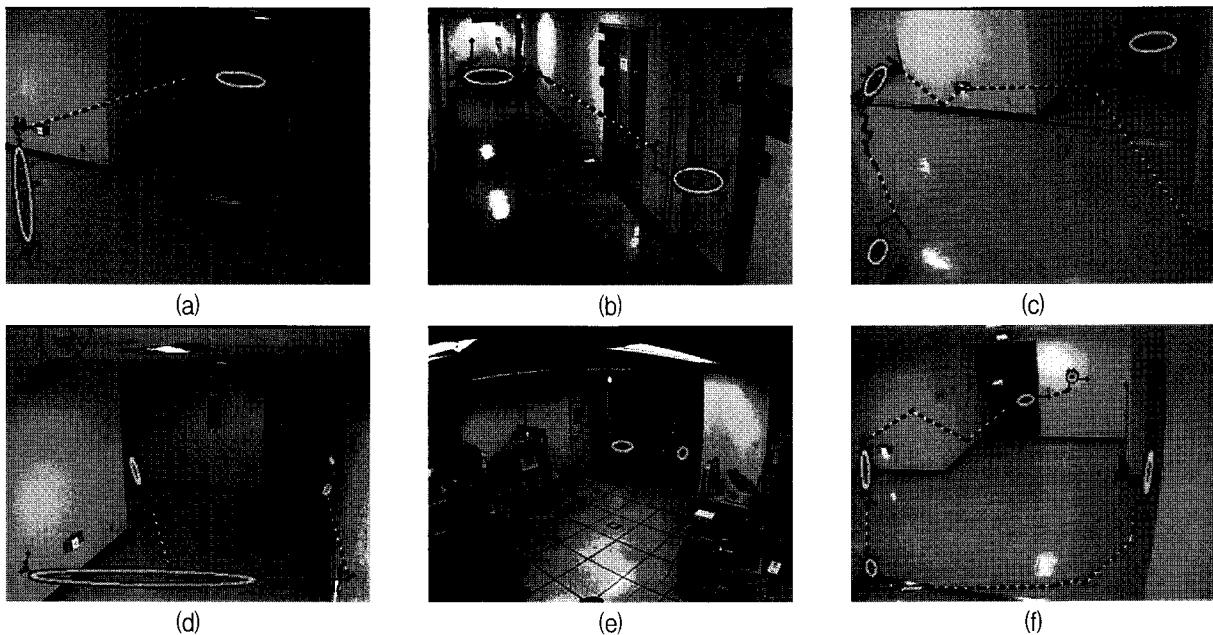


그림 5. 제안하는 방법을 사용한 출입 영역 검출 결과: (a),(b) 데이터 그룹이 명백하게 구분되는 경우 (c),(d) 복잡한 형태의 데이터 분포의 경우, (e),(f) 잡음에 기인한 데이터 포인트가 존재하는 경우

Fig. 5. Detection results of entry/exit zones using proposed method: (a),(b) data points with obvious groupings, (c),(d) data points with complicated distribution, and (e),(f) data points with noise.

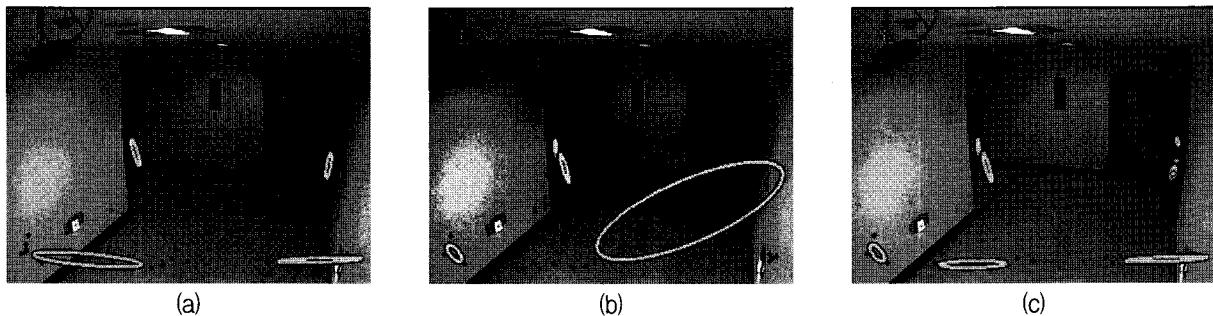


그림 6. EM 기반 방법을 사용한 출입 영역 검출 결과: 지정된 최종 클러스터의 개수 (a) 4개, (b) 4개, (c) 10개

Fig. 6. Detection results of entry/exit zones using EM-based method: Predefined number of clusters (a) 4, (b) 4, (c) 10.

표 1. 출입 영역 검출 결과

Table 1. Detection results of entry/exit zones.

	데이터 포인트의 개수	검출된 출입 영역	실제 출입 영역
(a)	128	2	2
(b)	292	2	2
(c)	143	3	3
(d)	72	4	3
(e)	106	2	1
(f)	155	6	4

검출하였다. 그러나 몇 개의 시야에서 하나의 출입 영역이 두 개의 클러스터로 표현되거나 잡음에 의해 추가적인 클러스터가 형성된 경우가 발생하였다.

그림 5의 (a)와 (b)에서 각각 두 개의 명백한 출입영역이 성공적으로 검출되었다. 실제 출입영역의 수와 동일한 개수가 검출되었으며 클러스터 개수의 사전 지정 없이 자동으로 검출한 결과이다. 그림 5의 (c)~(d)는 보다 복잡한 구조를 갖는 영상에 대한 결과를 보여준다. 그림 5의 (c)에서 역시 실제 출입 영역의 개수와 동일한 개수의 출입 영역이 검출되었고 검출 결과 또한 타당하다. 그림 5의 (d)에서는 데이터 포인트 수가 비교적 적고 그 분포가 다소 성기게 형성되었으나 클러스터링 결과는 만족할만하다. 그림 5의 (e)~(f)는 객체 추적의 실패에 기인한 잡음이 포함된 데이터에 대한 실험 결과이다. 그림 5의 (e)에서 책꽂이 부근의 복잡한 배경

에 의해 객체 추적에 실패하여 불필요한 클러스터가 형성되었고 실제의 출입 영역에 의해 발생한 클러스터와 구분되어 검출된 것을 확인할 수 있다. 그림 5의 (f)의 경우 벽면에 반사된 조명에 의해 실제 출입 영역이 아닌 클러스터가 형성되었으나 이 경우 또한 실제 출입 영역에 의해 형성된 클러스터와는 구분되어 검출되었다. 이러한 추가적 클러스터들이 생성된 경우에도 실제 출입영역에 대응되는 클러스터들은 모두 검출되었으며 추가적인 클러스터에 대한 처리 방안을 본 장의 후반부에 언급하였다.

그림 6에서는 제안하는 방법과의 비교를 위해 그림 5의 (d)에서 사용한 데이터에 대하여 EM에 기반을 두고 시야 내의 출입영역을 가우시안 혼합 모델로 모델링한 결과를 보여준다. 그림 6의 (a)~(c)은 최종 클러스터의 개수를 각각 4, 4, 10으로 지정했을 때의 결과이다. 최종 클러스터의 개수를 달리 지정함에 따라 결과가 달라지는 것을 확인할 수 있다. 또한 그림 6의 (a)와 (b)에서와 같이 동일한 데이터에 대해 동일한 최종 클러스터 개수를 지정하였음에도 불구하고 클러스터링 결과는 상이한 것을 볼 수 있다. 특히 그림 6의 (b)에서의 결과는 포인트 분포 형태를 바르게 고려하지 못하였다.

이처럼 잘못된 결과가 도출되는 것은 각 가우시안의 파라미터 초기화가 무작위로 이루어지기 때문이다. 또한 데이터 포인트의 수가 적기 때문에 EM을 사용한 클러스터링 결과가 안정적으로 수렴하기 어렵다. 그림 6의 (c)에서는 지정된 최종 클러스터 개수가 실제 출입 영역의 개수에 비해 매우 크기 때문에 데이터 분포의 총체적 형태가 고려되지 않은 결과를 얻게 된다.

출입 영역의 검출 결과를 그림 7과 같이 객체의 출입이 이루어지는 영역과 대응시키는 것으로 타당성을 확인하였다. 객체의 등장이나 퇴장이 일어났을 때 객체

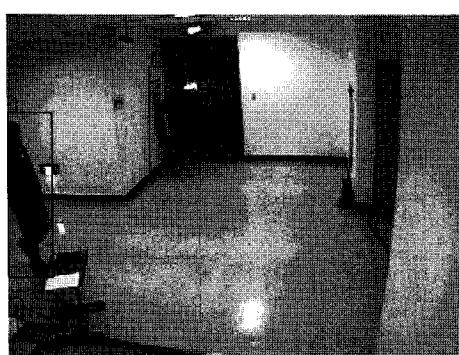


그림 7. 객체의 출입 상황 예
Fig. 7. Objects entering a camera view.

의 위치와 각 출입 영역 사이의 마할라노비스 (Mahalanobis) 거리를 측정한다. 해당 출입은 최소 거리를 갖는 출입 영역에서 일어난 것으로 판단한다. 대부분의 경우 최소 거리를 갖는 출입 영역이 실제 출입이 일어난 영역과 일치하였다. 그림 5의 (e)나 (f)에서와 같이 잡음에서 기인한 데이터 포인트에 의해 형성된 클러스터에 대한 후처리를 수행하기 위하여 검출된 출입 영역들의 유효성을 판단하였다. 각 출입 영역에 포함된 데이터 포인트에 대응되는 객체의 평균 lifetime 즉 객체가 시야에 등장해서 퇴장하기까지의 시간이 비교적 긴 출입 영역을 유효한 것으로 판단하였다.

V. 결 론

본 논문에서는 카메라 시야 내의 출입영역을 검출하기 위한 그래프 이론 기반의 클러스터링 방법을 제안하였다. 검출한 출입영역은 멀티 카메라 감시 시스템의 효율과 정확성을 향상시킬 수 있는 정보가 된다. 제안하는 방법은 효과적으로 출입영역을 검출하며 최종 클러스터의 개수를 사전 지정해주는 과정이 필요하지 않기 때문에 다양한 상황의 시야에 적용적으로 적용할 수 있다. 또한 주어진 데이터 포인트의 분포가 조밀하지 못한 경우에도 분포의 형태를 검출할 수 있다. EM 기반 방법을 사용한 출입영역 검출 결과와의 비교를 통하여 제안하는 방법이 적은 수의 데이터 포인트를 다루는데에 보다 안정적으로 동작함을 확인하였다. 데이터 포인트의 수가 적은 경우 혼합 가우시안으로 출입영역을 모델링하게 되면 각 가우시안의 무작위 초기화로 인하여 일관된 결과를 얻기 어렵다. 따라서 제안하는 방법이 보다 정확한 결과를 도출하며 짧은 학습시간을 요구한다는 장점을 갖는다.

실험에 사용한 데이터 집합들은 동일한 임계값 설정에 대하여 타당한 클러스터링 결과를 보였으나 이 임계값들을 자동으로 설정하는 것에 대한 추후 연구가 필요하다. 또한 본 논문에서 사용한 데이터 포인트는 객체가 위치한 카메라 평면상의 x, y 좌표인데 3차원 좌표로의 변환을 통하여 보다 복잡한 시야에 대한 해석이 가능할 것으로 예상된다. 객체 추적 과정에서 얻을 수 있는 부가적인 정보들 역시 이러한 발전에 기여할 것으로 생각한다. 본 연구의 내용을 적용하여 출입영역의 자동 검출을 수행한 후 그 결과를 멀티 카메라 감시 시스템의 카메라 연결 관계 도출에 활용하는 일이 필요하다.

참 고 문 헌

- [1] W. Kang and F. Deng, "Research on Intelligent Visual Surveillance for Public Security," in *Proceedings of the IEEE/ACIS International Conference on Computer and Information Science*, pp. 824-829, 2007.
- [2] D. Makris, T. Ellis, and J. Black, "Bridging the gaps between cameras," in *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol.2, pp. II 205-II 210, 2004.
- [3] D. Makris and T. Ellis, "Automatic learning of an activity-based semantic scene model," in *Proceedings of IEEE Conference on Advanced Video and Signal Based Surveillance*, pp.183-188, 2003.
- [4] C. Stauffer, "Estimating Tracking Sources and Sinks," in *Proceedings of the Conference on Computer Vision and Pattern Recognition Workshop*, pp.35-35, 2003.
- [5] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*, 2nd ed. NewYork: Wiley, 2001.
- [6] P. Foggia, G. Percannella, C. Sansone, and M. Vento, "Benchmarking graph-based clustering algorithms," *Image and Vision Computing*, vol. 27, pp.979-988, 2009.
- [7] C. T. Zahn, "Graph-Theoretical Methods for Detecting and Describing Gestalt Clusters," *IEEE Transactions on Computers*, vol. 20, pp.68-86, 1971.
- [8] G. Oleksandr, Z. Yan, and J. Zach, "Minimum Spanning Tree Based Clustering Algorithms," in *Proceedings of IEEE International Conference on Tools with Artificial Intelligence*, pp. 73-81, 2006.
- [9] D. J. Marchette, *Random graphs for statistical pattern recognition* Hoboken, N.J.: Wiley-Interscience, 2004.

저 자 소 개



우 하 용(학생회원)
2008년 서강대학교 전자공학과
학사 졸업
2009년 현재 서강대학교
전자공학과 석사과정
<주관심분야 : 영상신호해석, 컴퓨터 비전, 패턴인식>

김 경 환(정회원)
대한전자공학회 논문지
제 46권 SP편 제 2호 참조