

Conditional Random Fields 구조에서 궤적군집화를 이용한 혼잡 영상의 이동 객체 검출

김형기[†], 이광국^{††}, 김희율^{†††}

요 약

본 논문은 궤적을 군집화하여 혼잡한 영상에서 이동 객체를 검출하는 방법을 제안한다. 제안하는 방법은 객체의 외형 정보에 기반한 기존의 방법들과는 달리 객체의 움직임 정보만을 이용해 이동 객체를 검출한다. 이를 위하여 입력 영상의 매 프레임에서 특징점을 추출하며, 인접한 프레임간의 추적 과정을 통하여 특징점을의 궤적을 생성한다. 동일 객체에서 얻어진 궤적들은 유사한 움직임을 보일 것이라는 가정 하에 군집화 과정을 통하여 이동 객체를 검출한다. 궤적들의 군집화를 위하여 특징점 간의 위치, 움직임, 연속성에 기반한 에너지 함수로 궤적 간 유사도를 측정하였으며, conditional random fields (CRFs)를 이용하여 최적의 군집을 결정하였다. 기존의 궤적 군집화를 통한 이동 객체 검출 방법이 군집화 과정에서 한번 잘못 분류된 궤적은 잘못된 결과를 생성하는 것과는 달리, 제안한 방법에서는 군집화가 CRFs 상에서 에너지 최소화에 의해 수행되기 때문에 잘못 분류된 궤적이 반복 과정에서 다시 올바른 군집으로 재배열되는 것이 가능하다. 제안한 방법의 성능 측정을 위하여 서로 다른 혼잡도를 가지는 세 개의 영상을 이용하였으며, 약 94%의 검출률과 7%의 허위 경보율을 나타내었다.

Detection of Moving Objects in Crowded Scenes using Trajectory Clustering via Conditional Random Fields Framework

Hyeong-ki Kim[†], Gwang-Gook Lee^{††}, Whoi-Yul Kim^{†††}

ABSTRACT

This paper proposes a method of moving object detection in crowded scene using clustered trajectory. Unlike previous appearance based approaches, the proposed method employs motion information only to isolate moving objects. In the proposed method, feature points are extracted from input frames first and then feature tracking is followed to create feature trajectories. Based on an assumption that feature points originated from the same objects shows similar motion as the object moves, the proposed method detects moving objects by clustering trajectories of similar motions. For this purpose an energy function based on spatial proximity, motion coherence, and temporal continuity is defined to measure the similarity between two trajectories and the clustering is achieved by minimizing the energy function in CRFs (conditional random fields). Compared to previous methods, which are unable to separate falsely merged trajectories during the clustering process, the proposed method is able to rearrange the falsely merged trajectories during iteration because the clustering is solved by energy minimization in CRFs. Experiment results with three different crowded scenes show about 94% detection rate with 7% false alarm rate.

Key words: Moving object detection (이동 객체 검출), trajectory clustering (궤적 군집화), Conditional random fields (Conditional random fields)

* 교신저자(Corresponding Author): 김희율, 주소: 서울 성동구 행당동 산17 (133-791), 전화: 02)2220-0561, FAX : 02)2292-6316, E-mail : wykim@hanyang.ac.kr
접수일 : 2009년 10월 8일, 수정일 : 2010년 2월 15일

완료일 : 2010년 5월 11일
[†] 정희원, (주) 만도 ADAS 사업실 SYSTEM3팀 연구원

(E-mail : hkkim82@mando.com)

^{††} 정희원, 한양대학교 전자컴퓨터통신공학과 박사과정
(E-mail : gglee@vision.hanyang.ac.kr)

^{†††} 종신희원, 한양대학교 전자통신컴퓨터공학부 정교수
(E-mail : wykim@hanyang.ac.kr)

1. 서 론

최근 공공장소에서의 안전관리에 대한 관심이 높아지면서 지능형 영상감시 시스템에 대한 요구가 크게 증가하고 있다. 지능형 영상감시 시스템은 영상처리 기술을 이용하여 CCTV 입력 영상으로부터 관심사건을 자동으로 인지하여 사건의 발생을 예방하고 감시자에게 상황 파악을 용이하게 하는데 도움을 주는 것을 목적으로 한다. 이러한 영상 감시의 응용 예로는 객체 추적[1], 군중의 밀도 측정[2,3], 보행자 행동 분석[4], 이상 행동 감지[5], 그리고 통행량 감시[6] 등을 들 수 있다. 영상에서 사람을 자동적으로 검출하는 기술은 위와 같은 지능형 영상감시의 다양한 응용에 활용될 수 있기 때문에 매우 중요하다고 할 수 있다.

사람 검출(human detection)에 대한 기존의 연구들은 대부분 객체의 외형적 특징에 기반하고 있다. 이러한 외형 기반 검출(appearance-based detection) 방법에서는 관심 객체를 검출하거나 구분하기 위하여 객체들의 픽셀값, 픽셀값들의 통계적 분포 또는 그 형태적 특징에 초점을 맞춘다. Utsumi 등은 사람이 존재하는 영상들의 기하학적 구조를 이용하여 사람을 검출하는 방법을 제안하였다[7]. 이 방법에서는 영상 내에 사람의 색상 및 영상을 서브블록(sub-block)으로 나누고 모든 서브블록 사이의 색상 및 텍스처(texture) 값의 차이를 계산하여 거리 지도(distance map)를 생성한다. 그리고 사람 영상 세트(set)와 배경 영상 세트으로부터 각각 생성한 거리 지도를 이용하여 입력 이미지에서 사람을 검출하였

다. Yang 등은 사람의 외형 정보에 대한 능동적인 학습에 기반을 둔 방법을 제안하였다[8]. 이 방법은 각각의 영상을 이용하여 훈련시킨 약한 분류기(weak classifier)를 연결하여 강한 분류기(strong classifier)를 생성함으로써 다양한 환경 변화에도 적응적으로 사람을 검출하였다. 또한 Viola 등은 사람의 외형 정보와 움직임 정보를 조합하여 훈련시킨 분류기를 이용하여 사람의 자세 변화를 고려한 검출 방법을 제안하였다[9]. 하지만 사람의 형태적 특징에 기반을 둔 이러한 방법들은 적은 수의 보행자가 있는 단순한 영상에 대해서는 높은 정확도를 보이지만, 많은 수의 보행자가 존재하는 혼잡한 영상에서는 보행자의 자세나 형태, 크기 등의 변화가 다양하고 특히 보행자 간의 가려짐이 심하게 발생하기 때문에 높은 정확도를 얻기에 어려운 문제가 있다.

최근에는 외형 기반 검출 방법들이 혼잡한 영상에서 겪는 이러한 문제점을 극복하기 위하여 관심 객체의 형상 정보를 이용하지 않고, 영상 내의 움직임 정보만을 이용하여 이동 객체를 검출하고자 하는 방법들이 제안된 바 있다[10-12]. 이러한 방법들에서는 영상 내 이동 객체들의 강체운동(rigid body motion)을 가정하고, 유사한 움직임을 보이는 특징점들을 동일한 객체에서 발생한 것으로 판단함으로써 객체의 외형적 특징이 아닌 특징점의 움직임 정보만을 이용하여 이동 객체를 검출하였다. 그림 1은 이러한 강체 운동의 예를 보여준다. 그림 1(a)는 입력 영상이며 그림 1(b)는 궤적 생성 결과를 나타낸다. 그림 1(a)에서의 흰색 점들은 전경 영역 상에서 추출된 특징점을 나타내며, 그림 1(b)에 나타난 흰색 선들은 매 프

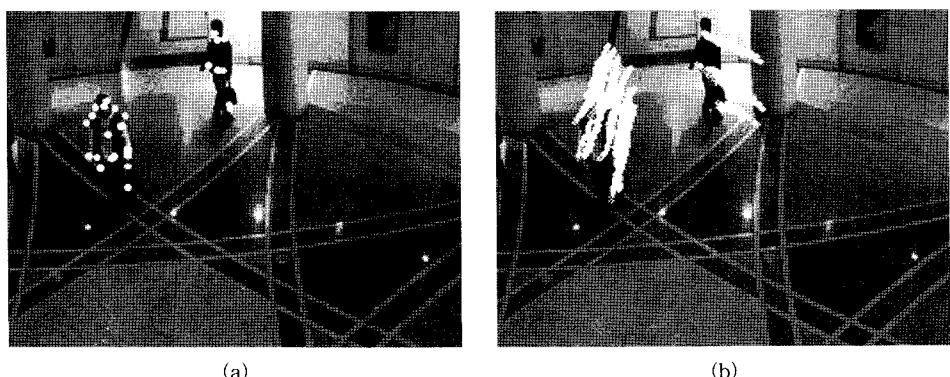


그림 1. 강체운동의 예: (a) t 프레임에서 특징점 추출 결과, (b) $t-T$ 프레임에서 t 프레임까지 특징점을 추적해서 얻은 특징점 궤적

레임 검출된 특징점을 시간에 따라 추적하여 얻은 궤적을 나타낸다. 그림 1(b)에서 나타난 바와 같이 동일한 객체에서 발생한 궤적들은 서로 간에 유사한 움직임 형태를 가지는 것을 볼 수 있다.

특징점의 움직임에 기반을 둔 이동 객체 검출 방법들은 공통적으로 특징점 추출, 특징점 추적, 궤적 군집화의 세 가지 단계로 이루어진다. 특징점 추출 과정에서는 FAST 특징 검출자(FAST feature detector)[13,14], Tomasi-Kanade feature[15] 등을 이용하여 입력 영상의 매 프레임에서 특징점을 획득 한다. 이후 추출된 특징점을 연속된 프레임 사이에서 추적함으로써 궤적(trajectory)을 생성하는 특징점 추적 과정이 뒤따른다[16,17]. 마지막으로 생성된 궤적들 간의 유사성을 이용하여 동일 객체에 속한 궤적들을 분류하는 군집화(clustering)과정이 이어진다. 이 가운데 생성된 궤적들로부터 구분된 이동 객체들을 생성해 내는 군집화 과정은 전체 알고리즘의 성능을 결정하는 가장 중요한 과정이라고 할 수 있다. Gabriel 등은 베이지안 구조(Bayesian framework)를 이용하여 궤적 간의 유사도를 측정하는 군집화 방법을 제안하였다[10]. 이 방법은 궤적 간의 거리 분산을 이용하여 우도(likelihood)를 측정하고, 최소 신장 트리를 통해 사전 확률(prior probability)을 계산한다. 그리고 베이지안 구조를 통해 얻은 궤적 간의 유사도를 이용하여 집적적으로 군집화(agglomerative clustering) 하였다. Vincent 등은 RANSAC 알고리즘과 연결성 그래프(connectivity graph)를 이용한 군집화 방법을 제안하였다[11]. 이 방법에서는 연결성 그래프를 이용하여 궤적 간의 공간적 응집도를 평가하고, 궤적 집합에 RANSAC 알고리즘을 적용하여 어파인 움직임(affine movement)을 추정하고 이를 통해 궤적 간의 움직임 유사도를 측정하였다. 그리고 이를 바탕으로 점진적으로 궤적들을 군집화 하였다. Yuan 등은 지도 학습(supervised learning)으로 훈련된 에너지 함수를 이용하는 군집화 방법을 제안하였다[12]. 이 방법에서는 궤적의 움직임 유사도, 공간적 응집도, 시간적 연속성을 측정하는 세 가지 요소로 구성된 에너지 함수를 정의하여 궤적 간의 유사도를 측정하였고, 계층적 군집화(hierarchical clustering) 방법을 이용하여 점진적으로 궤적들을 군집화 하였다. Yuan 등이 제안한 군집화 방법은 [10]과 [11]에서 제안된 방법에 비해 훈련 과정

이 필요하다는 단점이 있지만, 군집화에 소요되는 시간이 매우 적기 때문에 실시간 연산이 가능하다는 장점이 있다. 그러나 앞에서 설명된 기존의 방법들은 군집화 과정에서 잘못 구분된 궤적 집합들이 군집화가 진행됨에 따라 오차를 전파하게 된다는 문제점이 있다. 기존의 방법들은 작은 군집들을 연속적으로 병합하여 나가는 집적적 또는 계층적 군집화 방법을 이용하기 때문에 한번 잘못 구분된 유사 궤적들은 계속적으로 유사 궤적들을 병합시켜 최종 객체 검출 결과에 영향을 미치게 된다.

본 논문에서는 혼잡한 영상 내에서 움직임 정보를 이용하여 이동 객체를 검출하는 방법을 제안한다. 제안한 방법에서는 영상에서 추출된 궤적들 가운데 유사한 궤적들을 서로 군집화 함으로써 이동 객체를 검출하며, 궤적을 군집화 하는 문제를 각 궤적에 라벨을 할당하는 라벨링 문제로 해석하였다. 이렇게 정의된 라벨링 문제를 Conditional Random Fields (CRFs) 구조에 적용하여 에너지 최적화 문제에 의해 군집화를 수행하였다. 이를 위해 궤적들 간의 유사도를 나타내는 에너지 함수는 궤적의 공간적 응집도, 움직임 유사도, 시간적 연속성을 측정하는 요소들로 표현되었다. 제안한 방법에서는 유사한 궤적들끼리 점진적으로 군집화가 이루어지는 것이 아니라 에너지 함수를 최소화하는 최적의 군집이 군집화 과정의 반복을 통해 결정되도록 하였기 때문에 기존의 방법들과 달리 군집화 과정에서 궤적이 잘못 구분되었다 하더라도 군집화가 지속적으로 수행됨에 따라 잘못 구분된 궤적이 수정되는 것이 가능하다.

본 논문의 구성은 다음과 같다. 2장에서는 궤적의 군집화에 대한 문제를 정의하고, 3장에서는 궤적 간의 유사도를 측정하기 위한 에너지 함수를 정의하며, 역추적 과정이 포함된 군집화 방법에 대하여 설명한다. 그리고 4장에서는 제안한 방법에 대한 실험 결과를 제시하고, 5장에서 결론을 맺는다.

2. 문제 정의

이 장에서는 제안하는 방법의 전체적인 구성에 대하여 설명한 후, 군집화 과정을 위한 확률 모델에 대해 소개한다. 그림 2는 영상 내에서 이동 객체를 검출하기 위한 제안하는 방법의 흐름도를 나타낸다. 제안하는 방법에서는 우선 연속된 입력 영상에 대하여

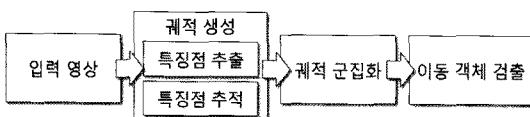


그림 2. 제안하는 방법의 흐름도

특징점을 검출하며, 얻어진 특징점을 추적하여 궤적을 생성한다. 이후 CRFs를 기반으로 하는 군집화 과정을 통하여 유사도가 높은 궤적들끼리 군집을 형성함으로써 최종적으로 영상 내의 이동 객체를 검출한다.

그림 3은 제안하는 방법의 각 단계의 예시를 보여준다. 그림 3(a)는 특징점 검출 결과이며 그림 3(b)는 얻어진 특징점을 추적하여 궤적을 생성하는 예이다. 그림 3(c)와 그림 3(d)는 각각 궤적군집화와 이를 통해 검출된 이동 객체의 예를 나타낸다.

군집화 과정을 위한 확률 모델을 정의하기 위하여 먼저 시간 t 에서 $2w$ 만큼의 길이를 가지는 시간 윈도

+우 내의 특징점 x 의 궤적 X^t 를 $X^t = \{x^{t-w}, x^{t-w+1}, \dots, x^{t+w-1}, x^{t+w}\}$ 로 나타낸다. 그리고 시간 t 에서 이러한 궤적들의 총 집합은 $D^t = (X_1^t, X_2^t, \dots, X_{n-t}^t, X_n^t)$ 로 정의하였다. 여기서 n 은 추출된 궤적들의 총 개수를 나타낸다. 추출된 궤적들의 총 집합 D^t 에서 유사한 형태를 가지는 궤적들끼리 구분하는 과정은 각각의 궤적에 라벨(label)을 부여하는 문제로 생각할 수 있다. 즉, 동일한 객체에서 발생한 특징점 궤적들에는 동일한 라벨을 할당하고, 반대로 서로 다른 객체에서 나온 특징점 궤적들에는 서로 다른 라벨을 할당하여 궤적 집합 D^t 의 군집화가 가능하다. 따라서 각각의 특징점 궤적에 대응되는 라벨들의 집합 Y^t 를 $Y^t = \{y_1^t, y_2^t, \dots, y_{n-t}^t, y_n^t\}$ 로 정의하였다.

라벨 집합 Y^t 에서 각각의 원소 y_i^t 간의 관계는 그림 4와 같이 동일한 라벨을 갖는 원소들끼리 연결된 무방향 그래프(undirected graph) $G = [V, E]$ 로 표현할 수 있다. 여기서 V 는 라벨 집합 Y^t 의 원소 y_i^t 들로

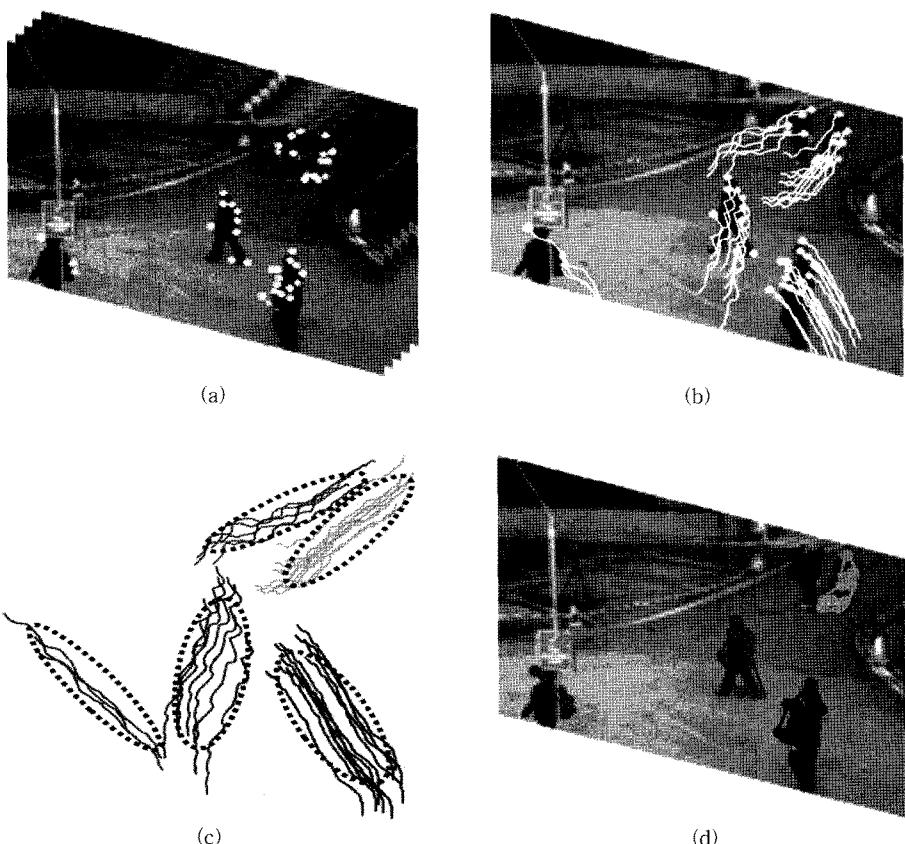


그림 3. 제안하는 방법: (a) 특징점 추출, (b) 특징점들을 추적하여 얻은 특징점 궤적, (c) 군집화, (d) 이동 객체 검출

이루어진 점(vertex)들을 나타내고, V 의 위치는 대응하는 궤적 집합 D^t 의 원소 X_i^t 의 시간 t 에서의 위치와 같다. 그리고 E 는 동일한 라벨을 갖는 원소 y_i^t 간에 서로 연결된 선(edge)들을 의미한다. 그럼 4는 두 명의 보행자로부터 추출된 특징점 궤적 집합 D^t 와 이에 대응하는 라벨 집합 Y^t 를 무방향 그래프 G 로 표현한 것이다. 라벨 집합 Y^t 의 각 원소 y_i^t 는 각각의 대응하는 궤적 집합 D^t 의 원소 X_i^t 와 동일한 위치에 존재하며, 동일한 보행자로부터 나온 y_i^t 간에는 서로 연결된다. 이와 같이 y_i^t 간에 연결선들은 y_i^t 에 대응하는 X_i^t 가 동일한 보행자로부터 추출된 것임을 의미하며, 연결된 y_i^t 간에는 이웃(neighbors) 관계에 있음을 나타낸다.

무방향 그래프 G 상에서 라벨 집합 Y^t 에 관한 확률 모델을 정의하기 위하여 라벨 집합 Y^t 의 원소 y_i^t 를 확률 변수(random variable)로 나타내었다. 확률 변수 y_i^t 는 $\{0, \dots, k\}$ 범위의 라벨값을 가질 수 있으며 k 는 영상 내에 존재하는 이동 객체의 수가 된다. 따라서 라벨 집합 $Y^t = \{y_1^t, y_2^t, \dots, y_{n-1}^t, y_n^t\}$ 은 확률 변수 y_i^t 로 이루어진 n 차원 확률 벡터(random vector)로 나타낼 수 있다. 그러면 궤적 집합 D^t 에 대응하는 n 차원 확률 벡터 Y^t 는 각각의 확률 변수 y_i^t 가 가질 수 있는 모든 라벨값에 대한 경우의 수를 가지게 되며 이에 대한 확률 분포는 $p(Y^t | D^t)$ 가 된다. 하지만 궤적 집합 D^t 는 이동 객체에서 나온 특징점을 시간에 따라 추적하여 얻어지기 때문에, 이에 대응하는 확률 벡터 Y^t 도 시간에 대한 연속성을 가진다. 즉, 시간 $t-1$ 에서 무방향 그래프 G 상의 동일한 객체에 존재했던 확률 변수 y_i^t 들은 시간 t 에서도 동일한 객체에 존

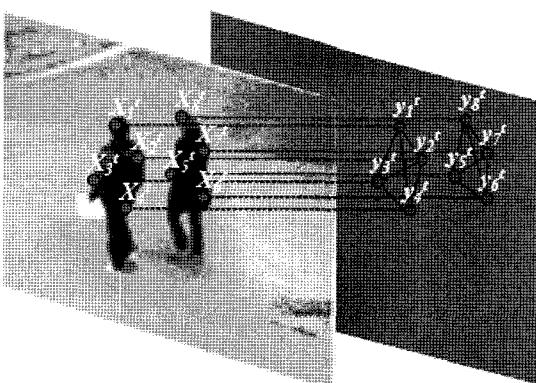


그림 4. D^t 를 조건으로 하는 레이블 집합 Y^t 의 무방향 그래프 표현

재할 확률이 높다. 이러한 시간에 따른 연속성을 적용하기 위해서 확률 벡터 Y^t 에 대한 조건부 확률을 $p(Y^t | D^t, Y^{t-1})$ 로 정의하였다. 따라서 궤적 집합 D^t 의 군집화 문제는 수식 (1)과 같이 조건부 확률 질량 함수(conditional probability mass function) $p(Y^t | D^t, Y^{t-1})$ 를 최대화하는 최적의 확률 벡터 Y_{opt}^t 를 찾는 문제로서 정의 된다.

$$Y_{opt}^t = \arg \max_{Y^t} (p(Y^t | D^t, Y^{t-1})) \quad (1)$$

3. 제안하는 방법

이 장에서는 II 장에서 정의된 확률 모델에 기반하여 궤적들을 군집화하는 제안 방법이 소개된다. 제안하는 군집화 방법은 궤적간의 유사도를 측정하기 위하여 공간적 응집도, 움직임 유사도, 시간적 연속성 측정 요소로 구성된 에너지 함수를 정의하였으며, CRFs를 이용한 비지도 군집화 방법으로 에너지 함수를 최소로 하는 최적의 군집을 결정한다.

3.1 특징점 추출과 추적

특징점 궤적들의 집합 D^t 를 생성하기 위하여 매프레이밍마다 FAST 특징 검출자[13,14]를 이용하여 영상 내의 특징점을 추출하며, 이후 추출된 특징점에 KLT 추적자(KLT tracker)[16,17]를 적용하여 특징 점의 궤적을 생성한다. 하지만 이렇게 얻어진 특징점들은 이동 객체에서 발생한 특징점 뿐만 아니라 배경 영역의 특징점들을 함께 포함하게 된다. 제안하는 방법은 영상 내의 이동 객체를 검출하는 것을 목적으로 하고 있기 때문에 배경 영역에서 나온 특징점들은 제거되는 것이 바람직하다. 이를 위해 배경 제거 방법 [19]을 이용하여 영상에서 전경 영역을 추출하였으며, 최종적으로 전경 영역 내의 특징점들만을 특징 점 추적에 이용하였다. 그럼 5는 제안하는 방법에서 사용한 궤적 생성 방법을 나타낸다. 그림 5(b)는 입력 영상에서 추출된 특징점을 나타내고, 그림 5(c)는 배경 모델링을 통해 얻은 전경 영역 마스크를 보여준다. 그림 5(d)는 전경 영역 마스크를 이용하여 얻은 특징점들만을 추적하여 생성된 특징점 궤적을 보여준다. 이러한 특징점 선택 방법은 군집화 과정에서 계산량을 줄여주며, 배경 영역에서 추출된 궤적들 사이의 움직임 모호성으로 인해 발생할 수 있는 군집화

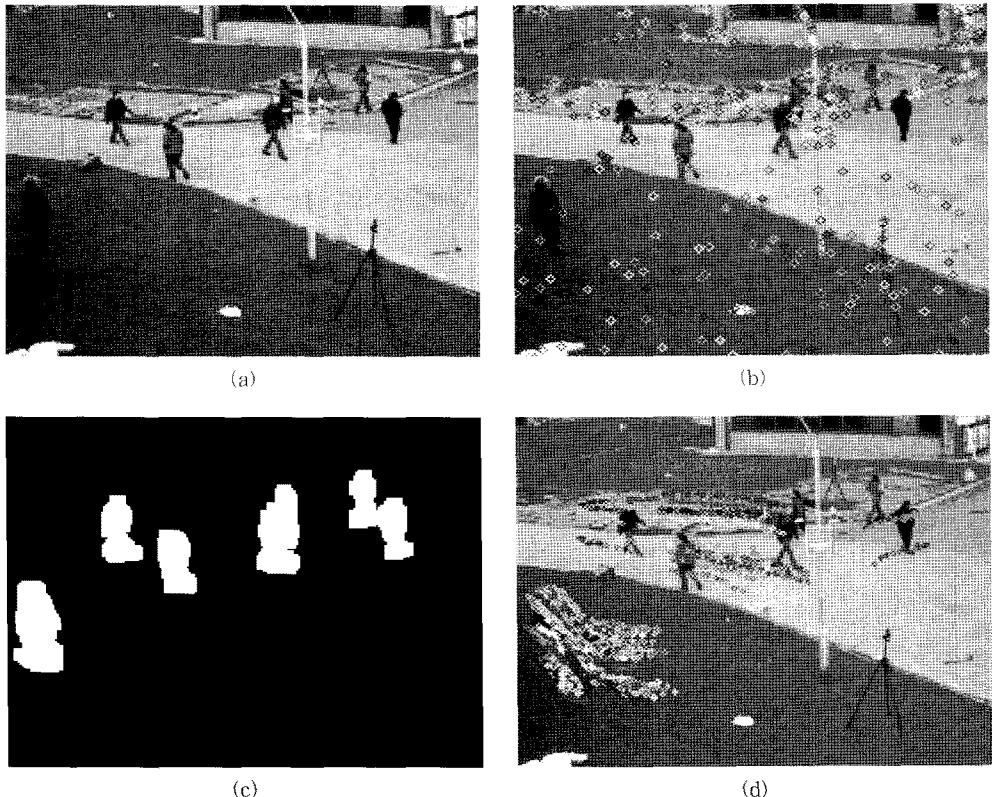


그림 5. 특징점 추출과 추적의 예시: (a) 입력 영상, (b) 특징점 추출, (c) 전경 영역 마스크 생성, (d) 전경 영역 상에 존재하는 특징점을 추적하여 얻은 특징점 궤적

오류를 방지해 준다.

3.2 목적 함수

II 장에서는 궤적의 군집화를 위한 확률 모델을 조건부 확률 질량 함수 $p(Y^t|D^t, Y^{t-1})$ 가 최대가 되는 최적 확률 벡터 Y_{opt}^t 로 나타내었다. 그리고 궤적 집합 D^t 와 확률 벡터 Y^t 와의 관계를 표현하기 위한 무방향 그래프 G 에서는 동일 객체에서 발생한 확률 변수 y_i^t 와 y_j^t 가 동일한 라벨값을 가져야 하며, 서로 이웃 관계에 있음을 나타내었다. 이웃 관계에 있는 확률 변수 y_i^t 와 y_j^t 간의 이러한 연관성을 이웃하는 두 확률 변수 y_i^t 와 y_j^t 간의 종속성(dependence)이 존재함을 의미하며, 따라서 확률 벡터 Y^t 에서 각각의 확률 변수 y_i^t 는 Markov 특성 따를다고 할 수 있다. 그러므로 무방향 그래프 G 상에서 궤적 집합 D_t 와 확률 벡터 Y_t 는 CRFs를 정의하게 된다 [18]. CRFs 상에서 확률 벡터 Y_t 에 대한 조건부 확률 질량 함수 $p(Y^t|D^t, Y^{t-1})$ 는 수식 (2)와 같이 무방향 그래프 G 상에서 점을 구

성하는 확률 변수 y_i^t , 이웃 관계에 있는 y_j^t , 확률 변수 y_i^t, y_j^t 에 대응하는 궤적 집합 X_i^t, X_j^t , 그리고 시간 $t-1$ 에서 확률 변수 y_i^{t-1}, y_j^{t-1} 로 표현된다. 수식 (2)에서 N_i 는 i 와 이웃 관계에 있는 확률 변수 y_j^t 의 집합을 나타낸다.

$$p(Y^t|D^t, Y^{t-1}) \propto \prod_{i \in V} p(y_i^t | X_i^t, X_j^t, y_j^t, y_i^{t-1}, y_j^{t-1}, j \in N_i) \quad (2)$$

제안하는 방법에서는 수식 (2)로부터 Y_{opt}^t 를 추정하기 위하여 반복법(iterative method)을 이용하였다. 반복법의 매 단계에서는 하나의 확률 변수 y_i^t 만이 고려되며, y_i^t 를 제외한 다른 확률 변수의 값은 변하지 않는다고 가정하여 선택된 확률 변수 y_i^t 에 대한 최적의 라벨값 $y_{i,opt}^t$ 를 수식 (3)을 통해 계산하게 된다.

$$y_{i,opt}^t = \arg \max \left(p(y_i^t | X_i^t, X_j^t, y_j^t, y_i^{t-1}, y_j^{t-1}, j \in N_i) \right) \quad (3)$$

수식 (3)에서 $p(y_i^t | X_i^t, X_j^t, y_j^t, y_i^{t-1}, y_j^{t-1}, j \in N_i)$ 는 항상 양수값(nonnegative)을 가지며, Markov 특성을 가지기 때문에 이미 잘 알려진 바와 같이 수식 (4)에

나타난 Gibbs 분포[20]의 형태로 표현할 수 있다. 따라서 수식 (3)과 같이 조건부 확률을 최대화하는 문제는 Gibbs 분포로의 표현을 통해 궤적 y_i^t 와 y_j^t 의 이웃 궤적들 사이의 에너지를 최소화하는 문제로 정의할 수 있다.

$$p(y_i^t | X_i^t, X_j^t, y_i^{t-1}, y_j^{t-1}, j \in N_i) \propto \exp\left(-\sum_j E(y_i^t, X_i^t, X_j^t, y_j^t, y_i^{t-1}, y_j^{t-1})\right) \quad (4)$$

제안하는 방법에서 에너지 함수 $E(\cdot)$ 는 수식 (5)에서와 같이 하나의 특징점 궤적 X_i^t 와 그 이웃 궤적인 X_j^t 와의 포텐셜(potential)들의 합으로 정의하였다. 그리고 이러한 궤적 간의 포텐셜들은 각각의 궤적들 간의 공간적 응집도, 움직임의 유사도, 시간적 연속성에 의해 정의되는 $E_S(\cdot)$, $E_M(\cdot)$, $E_T(\cdot)$ 의 세 가지 성분으로 구성된 포텐셜들의 합을 통해 얻어진다.

$$\begin{aligned} & \sum_j E(y_i^t, X_i^t, X_j^t, y_j^t, y_i^{t-1}, y_j^{t-1}) = \\ & \sum_j (E_s(y_i^t, x_i^t, y_j^t, x_j^t) + E_M(X_i^t, y_i^t, X_j^t, y_j^t) + \\ & E_T(y_i^t, y_j^t, y_i^{t-1}, y_j^{t-1})) \end{aligned} \quad (5)$$

3.2.1 공간적 응집도

동일한 객체에서 추출된 특징점들은 서로 다른 객체로부터 얻어진 특징점들에 비하여 상대적으로 가깝게 위치해 있으며 그림 6(a)와 같이 동일한 객체 상에서 타원 형태로 분포하게 된다. 영상 내에서 추출된 특징점들의 이러한 분포 형태는 군집화 과정에서 중요한 정보로 사용될 수 있다. 제안하는 방법에서는 보행자의 형태를 그림 6(b)와 같이 파라미터 w , h 를 가지는 타원으로 가정하고, 이를 통해 수식 (6)에



(a)

나타난 것과 같이 공간적 응집도의 포텐셜을 정의하였다. 파라미터 w , h 는 x_i^t 의 위치에서 보행자의 크기를 의미하며 이는 영상 내 보행자들의 일반적인 크기를 측정함으로써 얻어진다. 여기에서 매개변수 w 와 h 는 카메라의 원근왜곡(perspective distortion) 때문에 영상 내의 모든 위치에서 달라진다. 따라서 제안하는 방법에서는 영상 내의 몇몇 위치에서 보행자의 크기를 수동으로 측정한 후, 선형 보간법(linear interpolation)을 이용하여 영상 내의 모든 위치에 대하여 파라미터 w , h 를 계산하였다.

수식 (6)에 의하여 계산되는 공간적 응집도 포텐셜 $E_S(\cdot)$ 는 x_i^t , x_j^t 에 대응하는 확률 변수 y_i^t , y_j^t 의 값에 따라서 다른 특성을 보인다. 즉, 확률 변수 y_i^t , y_j^t 가 동일한 라벨값을 가지고 있을 경우에는 c 가 작을수록 낮은 포텐셜값을 가지지만 y_i^t , y_j^t 가 다른 라벨값을 가질 경우에는 c 가 클수록 낮은 포텐셜값을 가진다. 따라서 공간적 응집도 포텐셜 $E_S(\cdot)$ 는 서로 가까이 위치하는 궤적에 대해 동일한 라벨값이 부여될 수 있는 가능성을 높여주며, 반대로 서로 멀리 위치한 궤적에 대해서는 다른 라벨값이 할당될 수 있도록 해준다.

$$E_s(y_i^t, x_i^t, y_j^t, x_j^t) = \begin{cases} 1 - \frac{1}{c^2 + 1} & \text{if } y_i^t = y_j^t \\ \frac{1}{c^2 + 1} & \text{else} \end{cases}$$

$$c^2 = \frac{(x_{j,x}^t - x_{i,x}^t)^2}{w^2} + \frac{(x_{j,y}^t - x_{i,y}^t)^2}{h^2} \quad (6)$$

3.2.2 움직임 유사도

객체가 강체운동을 한다고 가정하면 동일 객체에서 생성된 궤적 사이의 거리는 객체가 이동을 하여도

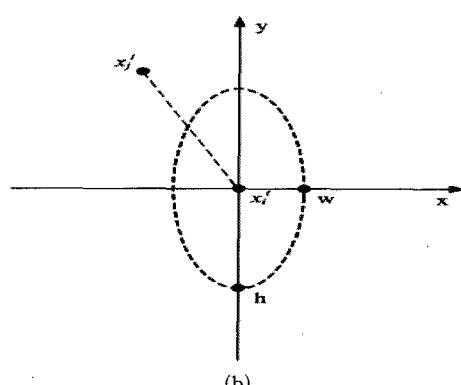


그림 6. 공간적 응집도: (a) 특징점의 위치 특성의 예, (b) 보행자 모델(타원)

변하지 않고 동일하게 유지될 것이다. 때문에 두 궤적의 각 특징점 사이의 거리의 분산은 이상적으로는 0에 가까운 값을 가지게 될 것이다. 제안하는 방법에서는 이러한 가정에 기반하여 움직임 유사도 포텐셜 $E_M(\cdot)$ 를 수식 (7)과 같이 두 궤적의 특징점 사이의 거리의 분산을 이용하여 정의하였다. 수식 (7)에서 X_i^t, X_j^t 는 시간 t 에서 $2w$ 만큼의 길이를 가지는 시간 윈도우 내에 존재하는 특징점들의 궤적을 나타내며, $Var(\cdot)$ 는 두 특징점 궤적 X_i^t, X_j^t 간의 거리에 대한 분산을 의미한다. 수식 (7)에 따라서 움직임 유사도 포텐셜 $E_M(\cdot)$ 은 확률 변수 y_i^t, y_j^t 가 동일한 라벨값을 가지면 두 궤적 간의 거리의 분산이 작을수록 낮은 포텐셜을 가지며, 반대로 다른 라벨값을 가지면 두 궤적 간의 분산이 커질수록 낮은 포텐셜을 가진다.

$$E_M(X_i^t, y_i^t, X_j^t, y_j^t) = \begin{cases} 1 - \frac{1}{1 + Var(X_i^t, X_j^t)} & \text{if } y_i^t = y_j^t \\ \frac{1}{1 + Var(X_i^t, X_j^t)} & \text{else} \end{cases} \quad (7)$$

3.2.3 시간적 연속성

II 장에서 제시된 바와 같이 동일 객체 상에서 발생한 궤적은 그 객체가 영상 내에서 사라질 때까지 계속적으로 추적되며, 따라서 각 궤적의 라벨 값은 추적이 끝날 때까지 서로 동일한 라벨값을 유지해야 할 것이다. 이는 즉 확률 모델 상에서 이전 프레임에서 동일한 라벨값을 가진 궤적들은 현재 시간에서도 서로 같은 라벨값을 가지는 것이 바람직함을 의미한다. 따라서 제안하는 방법에서는 시간적 연속성 포텐셜 $E_T(\cdot)$ 를 수식 (8)에 나타난 것과 같이 정의하였다. 수식 (8)에서 a 는 시간적 연속성에 의한 에너지 포텐셜의 크기를 나타내는 상수로써 특징점의 라벨값이 유지될 때 낮은 포텐셜을 가질 수 있도록 하기 위하여 0.5보다 작은 값이 선택되어야 한다. 본 논문에서는 0에서 0.5사이의 값 가운데 0.3을 사용하였으며, 이는 실험적으로 결정되었다. 시간적 연속성 포텐셜은 군집화 과정에서 아래와 같은 두 가지 역할을 한다.

- 1) 궤적의 레이블이 갑자기 변하는 것을 방지한다.
- 2) 군집화 과정의 수렴 속도를 빠르게 해 준다.

$$E_T(y_i^t, y_j^t, y_i^{t-1}, y_j^{t-1}) = \begin{cases} \alpha & \text{if } y_i^t = y_j^t \text{ and } y_i^{t-1} = y_j^{t-1} \\ & \text{or } y_i^t \neq y_j^t \text{ and } y_i^{t-1} \neq y_j^{t-1} \\ 1 - \alpha & \text{else} \end{cases}$$

$$\alpha = \{\alpha | 0 \leq \alpha \leq 0.5\}$$

$$(8)$$

3.3 군집화

3.3.1 군집화 알고리즘

특징점 추적에 의해 얻어진 궤적 집합에 대하여 수식 (1)을 만족하는 최적의 확률 벡터 Y_{opt}^t 을 계산하기 위하여 제안하는 방법에서는 CRFs를 이용하였으며, CRFs 상에서 Y_{opt}^t 는 반복법을 통해 $y_{i,opt}^t$ 를 모든 확률 변수에 대하여 계산함으로써 점진적으로 추정하였다. 군집화의 각 단계에서 $y_{i,opt}^t$ 는 무방향 그래프 G 내에서 X_i^t 의 이웃 궤적 X_j^t 를 이용하여 수식 (9)와 같이 에너지 함수를 최소화하는 라벨값으로 결정되며, 이웃 궤적 X_j^t 를 결정하기 위하여 제안하는 방법에서는 임의성(randomness)에 기반을 둔 이웃 궤적의 선택 방법을 이용하였다. 즉, 이웃 궤적을 찾기 위해 추출된 전체 궤적 개수에 대하여 미리 정의한 비율 r 만큼의 궤적을 임의로 선택하고, 임의로 선택한 이웃 궤적을 이용하여 최적의 라벨값 $y_{i,opt}^t$ 을 계산하였다. 그리고 그 다음 반복 단계에서는 이전 단계에서 계산된 Y_{opt}^t 을 기반으로 군집화 과정을 반복하였다. 이러한 군집화 방법은 Y_{opt}^t 이 더 이상 변하지 않을 때인 즉 수렴 상태까지 반복된다. 이러한 이웃 궤적 선택 방법은 임의로 생성된 샘플 스페이스에서 지역적 최적 값은 샘플 스페이스의 선택이 반복될수록 점차적으로 모집단의 최적 값으로 접근한다는 가정을 바탕으로 하고 있다[21].

$$y_{i,opt}^t = \arg \min_{y_i^t} \left(\sum_j E(y_i^t, X_i^t, X_j^t, y_j^t, y_i^{t-1}, y_j^{t-1}) \right) \quad (9)$$

표 1은 군집화 과정의 pseudo code이다. 군집화 과정이 시작되면 모든 궤적들은 1부터 n 까지 임의로 라벨값을 가진다. 여기서 n 은 궤적의 총 개수이다. 각각의 궤적들에 대한 최적의 라벨값 $y_{i,opt}^t$ 는 수식

표 1. 군집화 알고리즘

```

Initialization:
assign label numbers {1, 2, ..., n} to
 $Y^t = \{y_1^t, y_2^t, \dots, y_n^t\}$  randomly

do
    for each  $y_i^t$ 
        select  $r$  neighbors randomly
        calculate optimal label  $y_{i,opt}^t$  by (9)
        for  $y_j^t = y_{i,opt}^t$ , If  $c^j \leq 1$  then update  $y_i^t = y_{i,opt}^t$ 
    until  $Y^t$  converge

```

(9)와 같이 임의로 선택된 이웃 궤적들을 이용하여 y_i^t 가 가질 수 있는 모든 라벨값들 중에 에너지 함수를 최소화하는 라벨값을 선택함으로써 결정된다. 그런 다음 에너지 함수를 최소화하는 라벨값을 가진 이웃 궤적의 특징점 x_j^t 가 공간적 응집도에서 언급하였던 보행자 모델(타원) 안에 존재하면 y_i^t 는 $y_{i,opt}^t$ 으로 갱신된다. 이러한 군집화 방법은 기존의 방법들이 사용한 점진적 군집화 방법과는 다르게 각각의 궤적에 대하여 에너지 함수를 최소화하는 라벨값을 선택함으로써 군집화를 이루는 방법이기 때문에 y_i^t 이 잘못된 라벨값을 가진다 하더라도 군집화 과정이 반복되면서 y_i^t 는 올바른 라벨값으로 새롭게 갱신될 수 있다.

그림 7은 구분 과정의 예를 보여준다. 그림 7(a)~(d)는 구분 과정이 반복됨에 따라 모든 궤적이 점차적으로 올바르게 군집을 이루어 가는 것을 보여준다. 그림 7(c)에서는 일부 궤적의 군집화가 잘못 이루어졌지만 군집화 과정이 반복되면서 그림 7(d)에서와 같이 이전 단계에서 잘못된 군집화 결과가 수정되어 올바르게 군집화가 이루어진 결과를 볼 수 있다.

3.3.2 이웃 궤적 선택 비율

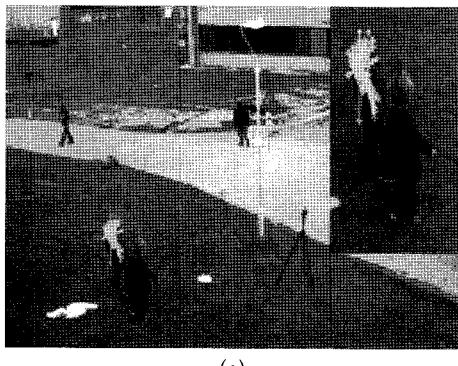
군집화 과정에서 이웃 궤적 선택 비율 r 은 이웃 궤적의 개수를 결정하는 값이며, 군집화 시간 및 성능에 영향을 미치게 된다. 본 논문에서는 r 의 변화에 따른 군집화 시간 및 성능 변화를 알아보기 위하여 PETS2009_S2_L1 세트에 대하여 r 을 0.1부터 0.5까지 변화시켜 가면서 군집화 시간 및 성능 변화를 살펴보았다. 그럼 8에서와 같이 검출률은 r 의 변화에도 차이가 없지만 허위 경보율은 급격히 감소한 후 일정하게 유지되는 것을 볼 수 있다. 이는 r 의 변화에 미검출(miss detection)은 변화가 없지만, 허위 경보(false alarm)는 큰 폭으로 감소하는 것을 보여주며, 이는 이웃 궤적 선택 개수가 일정 값보다 작으면 군집이 이루어지기 전에 수렴한다는 것을 뜻한다. 군집화 시간은 군집화 과정의 반복 횟수와 이웃 궤적의 개수가 작을수록 작은 값을 가지게 되는데, r 값이 증가할수록 군집화 과정의 반복 횟수는 감소하기 때문에 그림 8과 같이 $r=0.25$ 일 때에 최소값을 갖고 $r=1$



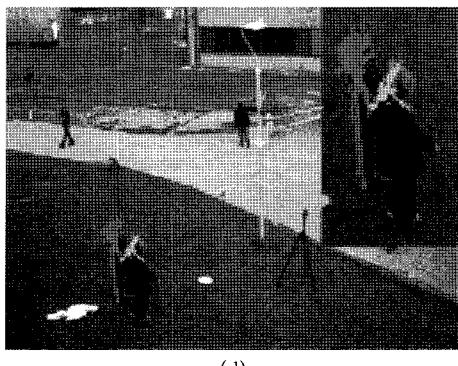
(a)



(b)

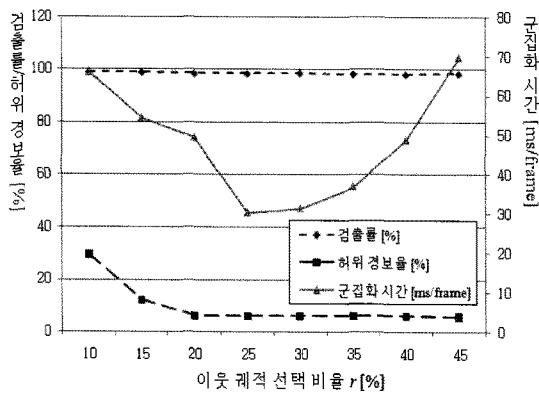


(c)



(d)

그림 7. 군집화 과정의 예: (a) 2회 반복, (b) 4회 반복, (c) 10회 반복, (d) 15회 반복 (군집화 과정 종료)

그림 8. r 값에 따른 군집화 시간 및 성능

변함에 따라 증가하게 된다. 따라서 실험에서는 최적의 r 값으로 0.25를 사용하였다.

4. 실험 결과

제안하는 방법의 성능 측정을 위한 실험은 Pentium core2 duo 컴퓨터 환경에서 수행되었으며 특징 점의 궤적을 생성하기 위한 특징 점 추출 및 추적 과정, 그리고 군집화 과정은 모두 Visual C++ 6.0을 이용하여 구현하였다. 그리고 실험 영상에는 세 개의 영상 세트가 사용되었다. 실험에 사용된 두 개의 영상 세트는 PETS2009에서 선택하였고, ROAD 영상 세트는 BBC Motion Gallery에서 수집하였다. 세 개의 세트는 공통적으로 낮은 각도(shallow view)로 촬영되었지만 혼잡도는 서로 다르다. PETS2009_S2_L1 세트는 영상 내에서 최대 7명의 보행자가 겹쳐짐 없이 독자적으로 보행하는 영상 세트이며,

PETS2009_S2_L2 세트는 최대 15명의 보행자가 그룹을 지어 이동한다. 그리고 ROAD 영상은 최소 8명에서 최대 30명 사이의 보행자가 영상에 등장하는 가장 극심한 혼잡도를 보여준다.

보행자 검출 결과에 대한 정확도 측정은 10 프레임마다 수동으로 얻어진 실제값(ground truth)과 비교하여 추정하였다. 표 2의 정확도 측정을 보면, 세 개의 영상 세트에 대하여 검출률이 모두 90% 이상이다. 하지만 ROAD 영상 세트의 허위 경보율은 9.74%로 다른 세트에 비하여 다소 높다. 이는 ROAD 영상 세트에서의 보행자의 움직임이 제안하는 방법에 적용한 가정을 따르고 있지 않기 때문이다. 제안한 방법에서는 모든 객체는 강체운동을 하고 있으며 따라서 하나의 객체에서 나온 궤적들은 서로 같이 움직인다고 가정을 하고 있다. 하지만 ROAD 영상 세트에서 보행자는 다른 영상 세트에 비하여 가까이 촬영되었으며, 이로 인하여 손과 발에서 궤적이 많이 추출되었다. 이와 같이 손과 발에서 나온 궤적은 몸통의 진행 방향 움직임 외에 좌우로 흔드는 추가적인 움직임이 있기 때문에 손과 발에서 나온 궤적이 보행자의 몸에서 나온 궤적과는 움직임 유사도가 떨어지게 된다. 그림 9(a)를 보면 하나의 보행자가 왼쪽 팔 부분과 오른쪽 팔 부분으로 나뉘어 구분된 것을 볼 수 있다. 또한 그림 9(b)를 보면 보행자의 몸통과 다리 사이의 상대적인 움직임으로 인하여 움직임 유사도가 낮아졌기 때문에 하나의 보행자가 두 부분으로 나뉜 것을 볼 수 있다. 그림 10는 각 실험 영상에 대해 제안한 방법에 의한 객체 검출 결과의 예시를 나타낸다.

표 2. 실험 결과 요약

내 용	Dataset	PETS2009_S2_L1	PETS2009_S2_L2	ROAD
총 프레임 수		790	430	1,000
궤적 생성 시간(ms/frame)		58.29	137.37	169.25
군집화 시간 (ms/frame)		31.77	95.29	557.2
총 보행자 (명)		361	415	2,361
올바른 검출 (명)		357	378	2,174
비검출 (명)		4	37	187
허위경보수 (명)		21	26	230
검출률 (%)		98.89	91.08	92.08
허위경보율 (%)		5.82	6.27	9.74

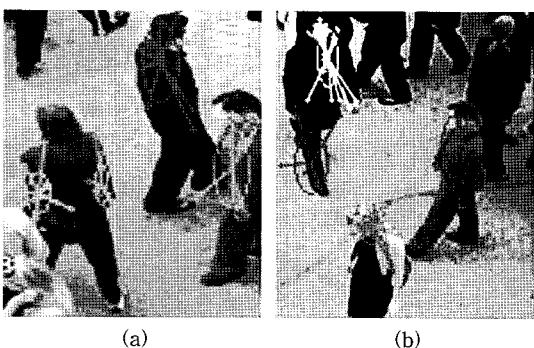


그림 9. 혀위 경보의 예: (a) 보행자의 두 손 사이의 서로 다른 움직임, (b) 보행자의 몸과 다리 사이의 서로 다른 움직임

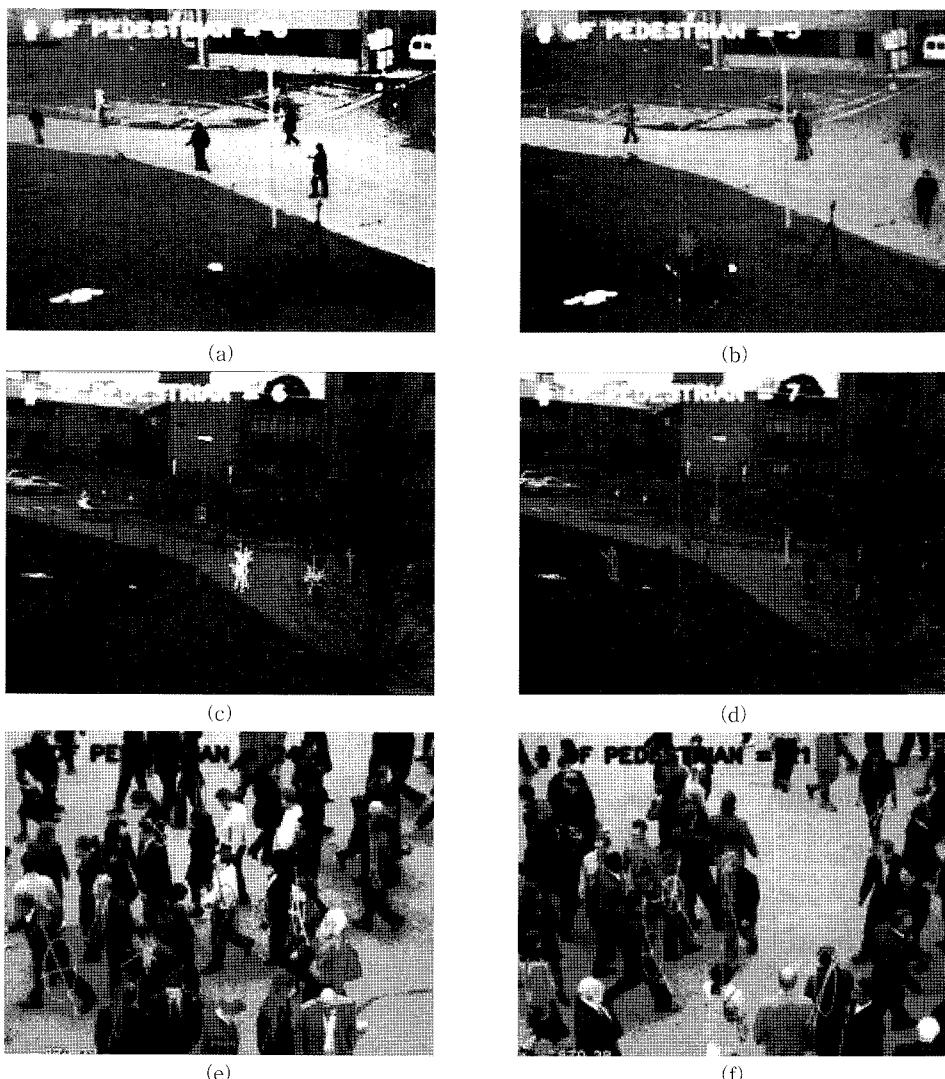


그림 10. 실험 결과의 예: (a)(b) PET52009_S2_L1, (c)(d) PET52009_S2_L2, (e)(f) ROAD

제안한 방법의 성능을 기존의 궤적 군집화 방법들과 성능을 비교하는 것은 중요한 일이지만, 기존 방법들은 각각 서로 다른 영상에 대해 성능 측정이 이루어져 서로 정확한 성능을 비교하기에는 어려운 문제가 있다. 때문에 본 논문에서는 기존의 연구에서 제시된 정확도를 통해 간접적으로 그 성능을 비교하였다. Gabriel 등에 의해 제안된 방법 [10]은 약 94%의 검출률로 제안한 방법과 유사한 성능을 보인 것으로 보고되어 있다. 하지만, 해당 방법의 오검률은 약 23%로써 본 논문에서 제안한 방법에 비해 매우 높은 오검률을 보였다. 이는 하나의 객체에서 발생한 궤적이 여러 군집으로 나뉘어진 경우가 제안한 방법에

비해 매우 많음을 의미한다. Vincent 등이 제안한 방법[11]에서는 측정값과 실제값의 차이로 나타나는 절대오차가 정확도 척도로서 사용되었으며, 약 12.77 %의 오차율을 보인 것으로 나타나 있다. Yuan 등이 제안한 방법[12]에서는 정확도가 군집화 매개변수의 변화에 따른 ROC 곡선으로 제시되어 있다. Yuan등의 방법은 지도학습을 이용하기 때문에 매우 빠른 계산 시간을 얻을 수 있었으나, 그들의 방법은 약 80%의 검출률을 보이는 상황에서 45%의 매우 높은 오검률을 기록한 것으로 나타나 있다. 이와 같이 기존의 방법들은 공통적으로 제안한 방법에 비해 오검률이 매우 높은 것을 알 수 있다. 이는 기존의 방법들이 군집화 과정에서 한번 잘못 발생한 결과를 다시는 되돌릴 수 없는 집적적인 또는 계층적인 군집화 방법을 이용하고 있기 때문이다. 이와 대조적으로 제안한 방법에서는 군집화가 매 반복 회수마다 이전 반복 단계에서 발생한 결과를 수정하는 것이 가능한 에너지 최소화에 의해 이루어지기 때문에 상대적으로 오검률이 크게 낮은 것으로 해석된다.

제안하는 방법의 처리 시간은 표 2에 제시되어 있는 것과 같이 영상 내에 추출된 궤적의 수에 비례하는 것을 볼 수 있다. PETSc2009_S2_L1에 대한 처리 시간은 궤적 추출 및 군집화 과정에 소요된 시간을 모두 포함해서 총 90 ms/frame로 가장 빨랐다. 이는 영상 내에 보행자의 수가 적고 카메라의 위치가 보행자에게서 멀리 떨어져 있어서 영상 내의 각각의 보행자에게서 추출되는 궤적의 수가 적었기 때문이다. 그리고 영상 내의 조명의 변화가 없어 배경 모델이 매우 안정적이었기 때문에 배경 영역에서 궤적이 잘못 추출되는 경우도 없었다. 반면에 ROAD 영상 세트의 전체 처리 시간은 약 726 ms/frame이었다. 이는 극심한 혼잡도로 인하여 추출된 궤적의 수가 다른 세트에 비하여 매우 많았기 때문이다. ROAD 영상 세트에서는 매 프레임당 약 1,000 개의 궤적이 생성되었으며, 반면에 PETSc2009_S2_L1 세트에서는 매 프레임당 약 150 개의 궤적이 생성되었다.

5. 결 론

본 논문에서는 혼잡한 영상 내에서 이동 객체를 검출하기 위하여 CRFs 기반의 비지도 궤적 군집화 방법이 제안되었다. FAST 특징 검출자와 빠른 배경

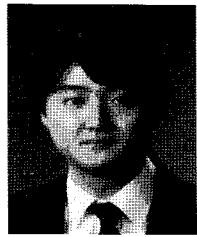
모델링 방법을 이용하여 영상 내의 전경 영역에서 특징점을 추출하였고, KLT tracker를 이용하여 추출된 특징점을 추적하여 궤적을 생성하였다. 궤적의 유사도 측정을 위하여 객체의 강체운동 가정 하에 에너지 함수를 정의 하였고, 각각의 궤적은 CRFs 기반의 비지도 군집화 과정을 통해 에너지 함수를 최소화하는 최적의 라벨값으로 결정하였다. 제안한 방법에서 제시된 군집화 과정은 기존의 방법들의 점진적인 군집화 방법과는 달리 에너지 최소화에 의해 군집화가 이루어지기 때문에 군집화 과정 내에서 잘못 구분된 궤적들이 올바른 군집으로 재구분되는 것이 가능하다. 따라서 제안한 방법은 기존 방법들에 비교하여 오검률이 낮은 장점이 있으며, 보행자 수 측정 또는 이동 경로에 의한 이벤트 검출 등과 같은 영상 감시의 응용에 다양하게 활용될 수 있을 것이다.

실험에는 서로 혼잡도가 다른 세 개의 영상 세트를 사용하였다. 실험 결과 약 94%의 검출률을 보여주었으며 7%의 허위 경보율을 보여주었다. 대부분의 허위 경보율은 봄, 팔, 다리 등과 같은 인간의 부분들 간에 서로 다른 움직임에 의하여 발생되었다. 이는 제안하는 방법이 동일한 보행자 내에 발생할 수 있는 서로 다른 움직임은 해결 할 수 없음을 보여준다. 따라서 이에 대한 추가 연구가 진행 중이며 궤적의 개수가 많을 때에 처리 시간을 향상시키는 방법에 대한 연구가 추가적으로 진행되어야 할 것이다.

참 고 문 헌

- [1] S. J. McKenna, S. Jabri, Z. Duric, A. Rosenfeld, and H. Wechsler, "Tracking Groups of People," *Computer Vision and Image Understanding*, Vol.80, pp. 42–56, 2000.
- [2] S. A. Velastin, J. H. Yin, A. C. Davies, M. A. Vicencio-Silva, R. E. Allsop, and A. Penn, "Automated Measurement of Crowd Density and Motion using Image Processing," *Seventh International Conference on Road Traffic Monitoring and Control*, pp. 127–132, April 1994.
- [3] H. Celik, A. Hanjalic, and E. A. Hendriks, "Towards a Robust Solution to People Counting," *Proc. of International Conference*

- of Image Processing, pp. 2401–2404, October 2006.
- [4] C. R. Wren, A. Azarbayejani, T. Darrell, and A. Pentland, “Pfinder: Real-time Trakcking of the Human Body,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol.19, No. 7, pp. 780–785, 1997.
- [5] G. Medioni, I. Cohen, F. Bremond, S. Hongeng, and R. Nevatia, “Event detection and analysis from video streams,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol.23, pp. 873–889, August 2001.
- [6] G.-G. Lee, B. Kim, and W.-Y. Kim, “Automatic Estimation of Pedestrian Flow,” First International Conference on Distributed Smart Cameras, pp. 291–296, September 2007.
- [7] A. Utsumi and N. Tetsutani, “Human detection using geometrical pixel value structures,” Fifth IEEE International Conference on Automatic Face and Gesture Recognition, pp. 34–39, May 2002.
- [8] T. Yang, J. Li, Q. Pan, C. Zhao, and Y. Zhu, “Active learning based pedestrian detection in real scenes,” 18th International Conference on Pattern Recognition, Vol.4, pp. 904–907, 2006.
- [9] P. Viola, M.J. Jones, and D. Snow, “Detecting pedestrians using patterns of motion and appearance,” Ninth IEEE International Conference on Computer Vision, Vol.2, pp. 734–741, October 2003.
- [10] G.J. Brostow and R. Cipolla, “Unsupervised bayesian detection of independent motion in crowds,” IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol.1, pp. 594–601, June 2006.
- [11] V. Rabaud S. Belongie, “Counting crowded moving objects,” IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol.1, pp. 705–711, June 2006.
- [12] Y. Li and H. Ai, “Fast detection of independent motion in crowds guided by supervised learning,” IEEE International Conference on Image Processing, Vol.3, pp. 341–344, October 2007.
- [13] E. Rosten and T. Drummond, “Fusing points and lines for high performance tracking,” Tenth IEEE International Conference on Computer Vision, Vol. 2, pp. 17–21, October 2005.
- [14] E. Rosten and T. Drummond, “Machine learning for high-speed corner detection,” European Conference on Computer Vision, Vol.1, pp. 430–443, May 2006.
- [15] C. Tomasi and T. Kanade, “Detection and tracking of point features,” Carnegie Mellon University, CMU_CS_91-132, 1991.
- [16] C. Tomasi and J. Shi, “Good features to track,” IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 593–600, June 1994.
- [17] S. Birchfield, “Source code of the klt feature tracker,” <http://www.ces.clemson.edu/~stb/klt/>, 2006.
- [18] A. McCallum, J. Lafferty, and F. Pereira, “Conditional random fields: Probabilistic models for segmenting and labeling sequence data,” Eighteenth International Conference on Machine Learning, pp. 282–289, June 2001.
- [19] 김형기, 이광국, 윤자영, 김재준, 김희율, “고정 소수점 연산을 이용한 빠른 배경 모델링,” 제 21 회 영상처리 및 이해에 관한 워크샵 논문집(II), pp. 345–348, 2009.
- [20] P. Perez, “Markov random fields and images,” *Centrum voor Wiskunde en Informatica Quarterly*, Vol. 11, pp. 413–437, 1998.
- [21] Y. Yuan and C.T. Li, “Unsupervised clustering of gene expression time series with conditional random fields,” Digital EcoSystems and Technologies Conference, pp. 571–576, February 2007.



김 형 기

2008년 한양대학교 기계공학부
학사
2010년 한양대학교 전자통신전파
공학과 석사
2010년~현재 (주) 만도 ADAS
사업실 SYSTEM3팀 연
구원

관심분야: 패턴 인식, 영상감시, Smart Vehicle

이 광 국

2002년 한양대학교 전자전기공학
부 학사
2004년 한양대학교 전자통신전파
공학과 석사
2004년~현재 한양대학교 전자컴
퓨터통신공학과 박사과정

관심분야: 영상 감시, 패턴 인식, 내용기반 멀티미디어
분석



김 회 율

1980년 한양대학교 전자공학과 졸
업(공학사)
1983년 Pennsylvania State
University 전기공학과
졸업(공학석사)
1989년 Purdue University 전기
공학과 졸업(공학박사)

1989년 9월~1994년 2월: University of Texas 조교수
1994년~현재 한양대학교 전자통신컴퓨터공학부 정교수
관심분야: 영상처리, 컴퓨터비전, 패턴인식, 머신비전,
MPEG-7등