

감시 영상에서의 장면 분석을 통한 이상행위 검출

정희원 배 건 태*, 어 영 정*, 곽 수 영**, 변 혜 린*^o

Detection of Abnormal Behavior by Scene Analysis in Surveillance Video

Guntae Bae*, Youngjung Uh*, Sooyeong Kwak**, Hyeran Byun*^o *Regular Members*

요 약

지능형 감시 분야에서 이상행위를 검출하는 것은 오랫동안 연구되어온 주제로 다양한 방법들이 제안되어 왔다. 그러나 많은 연구가 움직이는 객체의 개별적인 추적이 가능하다는 것을 전제로 하여 잦은 가려짐이 발생하는 실 생활에 적용하는데 한계가 있다. 본 논문에서는 객체 추적이 어려운 복잡한 환경에서 장면의 주된 움직임을 분석하여 비정상적인 행위를 검출하는 방법을 제안한다. 먼저, 입력영상에서 움직임 정보를 추출하여 Visual Word와 Visual Document를 생성하고, 문서 분석 기법 중 하나인 LDA(Latent Dirichlet Allocation) 알고리즘을 이용하여 장면의 주요한 움직임 정보(위치, 크기, 방향, 분포)를 추출 한다. 이렇게 분석된 장면의 주요한 움직임과 입력영상에서 발생한 움직임과의 유사도를 분석하여 주요한 움직임에서 벗어나는 움직임을 비정상적인 움직임으로 간주 하고, 이를 이상행위로 검출하는 방법을 제안한다.

Key Words : Abnormal behavior, Scene analysis, Intelligent surveillance system, 이상행위 검출, 장면 분석, 지능형 감시 시스템

ABSTRACT

In intelligent surveillance system, various methods for detecting abnormal behavior were proposed recently. However, most researches are not robust enough to be utilized for actual reality which often has occlusions because of assumption the researches have that individual objects can be tracked. This paper presents a novel method to detect abnormal behavior by analysing major motion of the scene for complex environment in which object tracking cannot work. First, we generate Visual Word and Visual Document from motion information extracted from input video and process them through LDA(Latent Dirichlet Allocation) algorithm which is one of document analysis technique to obtain major motion information(location, magnitude, direction, distribution) of the scene. Using acquired information, we compare similarity between motion appeared in input video and analysed major motion in order to detect motions which does not match to major motions as abnormal behavior.

I. 서 론

요즘 다양한 범죄로 인해 백화점, 음식점, 주차장

등은 물론이고 주요 도로와 평범한 도심 속에도 감시 카메라 설치가 대폭 확대 되고 있다. 날이 갈수록 증가하는 감시카메라의 수와 감시영상의 양에 비해 감

※ 이 논문은 2010년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(2010-0013737)

* 연세대학교 컴퓨터과학과 (gtbae@yonsei.ac.kr, sheldon@yonsei.ac.kr, hrbyun@yonsei.ac.kr), (°: 교신저자)

** 한밭대학교 제어계측공학과 (sykwak@hanbat.ac.kr)

논문번호 : KICS2011-08-344, 접수일자 : 2011년 8월 11일, 최종논문접수일자: 2011년 11월 12일

시카메라를 보고 분석할 인력과 시간은 턱없이 부족하며, 특히 감시영상은 일반적으로 반복되는 내용이 많기 때문에 사람의 집중력에 한계로 인해 각종 손실이 발생한다. 그 비용과 손실을 감축하기 위하여 비디오 영상을 자동으로 분석하는 연구가 활발히 진행되고 있다. 본 논문에서는 다양한 연구 중 비정상적인 행위가 발생하는 경우 자동으로 알람을 알려주는 비디오 분석 기술을 제안하고자 한다.

비정상적인 상황을 자동으로 분석하는 방법은 움직임 인식하고 표현하는 방법에 따라 객체추적 기반 방법과 저수준(low level) 특징 기반 방법으로 나눌 수 있으며, 정상/비정상을 구분하는 기준을 세우는 방법에 따라 규칙기반 방법과 학습기반 방법으로 나눌 수 있다.

일반적으로 비정상행위는 정상행위에 비해 희소하며 평소와 다르다는 특징이 있다. 이러한 특징은 컴퓨터가 이해하기에는 모호하기 때문에 주어진 영상이 정상인지 비정상인지를 판단하기 위해서는 구체화된 기준이 필요한데, 그 기준을 세우는 방법에 따라 크게 두 가지 방법이 있다. 규칙기반 방법은 검출하고자 하는 사건이 단순한 경우 주로 사용되며, 영상에서 발생해야 하는 규칙을 사람이 직접 입력하는 방법이다. 사용자가 자신의 의도대로 규칙을 정의할 수 있다는 점에서 좋은 방법이기도 하지만 일반적으로 사건이 단순하지 않고, 의도하지 않은 비정상사건을 검출할 수 없다는 것이 큰 단점이다. 그 반면 학습기반 방법은 평소의 영상을 입력으로 하여 기준을 학습하는 방법이다. 이 경우 사용자가 자신의 의도를 반영하기는 어렵지만 ‘평상시와 다르다’라는 애매한 조건을 명백한 기준으로 만들 수 있다는 장점이 있기 때문에 최근에는 학습을 통해 기준을 생성하는 방법이 주목받는 상황이다.

움직임을 인식하고 표현하는 방법에 따른 분류 중 객체 추적 기반 방법은 동영상에서 배경과 전경을 분리해낸 후 전경에 포함된 객체들을 검출한다. 검출된 객체를 추적하여 경로를 계산하고 그 경로가 기준을 벗어나는지 검사하는 것이다. C. Stauffer^[1]는 움직임 추적을 통해 공간에서 일어나는 행동을 학습하는 방법을 다루었다. 각 픽셀을 mixture of Gaussian 모델링하는 적응적 배경 제외 방법으로 움직임을 조각내서 안정적인 추적자를 생성했지만 유사한 움직임이 존재할 때 그들을 구분하여 추적하지 못하여 인식이 떨어진다. X. Wang^[2]은 궤적 비교 함수를 제안하여 궤적을 군집화하고, 군집화 된 궤적을 독립된 행동이라 정의하고 비정상사건을 검출했다. 하지만 긴 궤적

이 등장하거나 여러 가지의 객체를 대상으로 할 때 올바르게 동작하지 못한다. 하지만 감시영상은 불특정 다수를 촬영한 결과물이기 때문에 가려짐 또는 지나치게 많은 추적결과가 나타날 수 있다. 이러한 경우 객체를 추적하기가 대단히 어려우며 그 추적 결과를 기반으로 한 해결방법도 무용지물이 된다. 이러한 연구에서 벗어나 다른 방법을 강구하게 되었는데 그것이 저수준 특징기반 방법이다.

둘째로 저수준 특징 기반 방법은 먼저 동영상의 각 프레임에서 광류(optical flow) 등의 저수준 특징을 추출하여 영상을 표현한다. 추출된 특징은 앞의 방법과 같이 규칙기반 또는 학습기반에 따라 정상/비정상을 판단할 수 있는데, 저수준특징은 사람이 이해하기 쉽도록 표현된 정보가 아니기 때문에 학습에 기반하여 규칙을 학습하는 방법이 주를 이루고 있다. 기존 동영상에서 추출한 저수준특징을 토대로 학습된 규칙을 보고 입력된 동영상에도 같은 저수준특징을 추출하여 그 규칙을 따르는지 확인하는 방법이다. 이러한 방법을 취하는 연구로서 여러 가지가 있다. H. Zhong^[3]은 여러 가지 단순한 특징추출을 한 뒤 영상을 일정한 길이의 조각으로 잘라 특징을 표준형으로 분류하고, 표준형과 비디오조각의 관계를 파악하여 비정상사건을 찾았다. 이 방법은 여러 가지 복잡한 비정상사건을 찾아낼 수 있지만, 추출된 특징이 많지 않은 부분에서 비정상사건을 찾지 못한다. P. Smith^[4]는 검출하고자 하는 사건에 대하여 고차원분석을 한 뒤 사건을 sub-task로 나누어 그에 특화된 특징을 정의했다. 이러한 방법은 사용자가 정의한 사건에 대해서는 정확한 면모를 보이지만 의도하지 않은 비정상사건은 검출할 수 없다. T. Xiang^[5]은 정규 유사도행렬의 고유벡터에 따라 자동으로 특징선택과 모델선택이 이루어지는 행동패턴을 자동으로 그룹화 하는 방법을 제안했다. 행동패턴의 클래스 개수가 없어도 사용할 수 있지만 지역특징만을 사용하여 클래스가 잘못 분류될 수 있다. Y. Wang^[6]은 비교사학습에 의하여 사람의 행동을 클래스의 집합으로 표현하는 방법을 다루었다. 모든 프레임 쌍 사이에서 사람형태의 성긴 모형에 기반하여 그 거리를 측정했다. 이 논문의 방법에서 영감을 얻어 본 논문에서는 영상에서 출현한 Visual Word에 따라 영상을 클래스로 분류한다. 본 논문에서 이상행위를 검출하는 방법으로 제안한 알고리즘은 다음과 같다.

1. 장면의 주요 움직임 분석 : 감시영상에서 움직임 특징을 추출하여 Visual Word 와 Visual Document

를 생성하고, 문서분석기법을 사용하여 주요 움직임을 분석한다.

2. 이상행위 검출 : 분석된 주요흐름에 따라 감시 비디오를 작은 단위의 비디오로 분할하고, 분할된 단위로 분석된 주요 움직임과의 유사도를 비교하여 이상행위를 검출한다.

본 논문의 구성은 다음과 같다. 2장에서는 감시 영상에서 지역 움직임을 특징으로 추출하고 LDA(Latent Dirichlet Allocation)^[7]를 이용하여 주된 움직임을 모델링하는 방법을 소개한다. 3장에서는 분석된 주요 움직임 모델을 기반으로 장면을 분석하고, 이를 바탕으로 이상행위를 검출하는 방법을 설명한다. 4장에서는 제안하는 방법에 대하여 실제 감시 영상에 적용한 결과를 보여 성능을 평가하였으며 5장에서는 결론 및 향후 연구에 대하여 기술한다.

II. 주된 움직임 분석

본 논문에서는 영상에서 발생하는 주된 움직임을 분석하여 장면(Scene)을 분류하고, 이를 바탕으로 비정상 움직임을 검출한다. 장면을 분류하기 위한 학습 방법은 문석 분석 기법인 LDA(Latent Dirichlet Allocation)^[7]를 이용한다. 그림 1은 본 논문에서 제안한 장면 분석을 통한 이상행위를 검출하는 방법의 전체적인 흐름도 나타낸 것이다.

2.1 지역 움직임 추출

영상 감시의 분석에 있어서 움직이는 객체의 움직임은 아주 중요한 특징으로 이용된다. 움직임 정보 추출에 대한 연구는 오래된 연구 분야로 다양한 방법들^[1-6]이 존재한다. 일반적으로, 영상에서 움직이는 객체를 검출하고, 검출된 객체를 추적하여, 시간에 따른 객체의 위치 정보인 궤적(trajecory)를 추출한다. 그러나 이러한 객체 단위 추적 방법의 경우 객체의 움직임

많지 않은 한적한 감시 환경에서는 효과적이거나, 혼잡한 환경(공항, 기차역 등)에서는 객체의 가려짐(occlusion)이 자주 발생하여 정확한 추적이 불가능하기 때문에 다양한 응용분야에는 적용하기에는 한계가 있다.

본 논문에서는 이러한 문제점을 극복하기 위하여 지역 움직임(local motion)을 특징으로 사용한다. 지역 움직임이란 특정한 영역에서 발생하는 이전 프레임($t-1$)과 현재 프레임(t)의 위치 변화를 말한다. 이는 객체단위의 궤적분석에 비해 추적의 정확성에 대한 부담이 적어 혼잡한 환경에서도 적용이 가능하다는 장점이 있다. 또한 객체 단위가 아닌 특징점 단위로 움직임 정보를 추출함으로써 객체 가려짐 문제의 해결에 대한 부담을 줄였다. 지역적 움직임을 위해 해리스 코너(Harris Corner) 검출방법^[8]을 이용하여 특징점을 추출하였으며, KLT알고리즘^[9]을 이용하여 특징점을 추적하였다. 하지만 특징점 단위의 움직임 추출은 영상 잡음에 민감하게 반응하는 단점이 있다. 본 논문에서는 이러한 문제점을 보완하기 위하여 추적 결과의 연속성(위치, 방향, 거리)을 이용하여 잡음의 영향으로 발생한 움직임 정보를 제거하였다.

2.2 지역 움직임의 양자화

문서 분석 기법인 LDA알고리즘을 이용하여 주된 움직임 정보를 분석하기 위해서는 추출된 움직임 특징들을 단어와 문서의 개념으로 변환하는 과정이 필요하다. 이를 위해 움직임 정보($M = \langle x, y, d, v \rangle$)를 Visual Word로 표현하고, 일정 시간(α) 동안 발생한 Visual Word들의 집합으로 Visual Document로 표현한다. 이는 아래 수식 1과 같이 나타낼 수 있다.

$$VD_{t-\alpha,t} = \{vw_1, vw_2, \dots, vw_n\} \quad (1)$$

위의 수식에서 n 은 $t-\alpha$ 에서 t 사이에 감시 영상에서 발생한 움직임 즉, Visual word들의 수를 나타낸다. 이때 움직임 정보의 특징 공간(feature space) 크기를 고려하여, 양자화를 통해 Visual Word의 수를 조절하였다. 우선 움직임의 발생 위치에 대한 공간적 좌표(x, y)를 블록 단위(10x10)로 양자화 하고, 움직임의 방향(d)을 4방향($\rightarrow \leftarrow \downarrow \uparrow$)으로 양자화 하여 Visual Word로 변환하였다. 그림 2는 양자화를 위한 공간적 기준과 방향의 구간을 나타낸 것이다. 발생 가능한 Visual Word의 집합은 Visual Vocabulary로 표현할 수 있으며, 그 집합의 크기는 영상의 해상도에

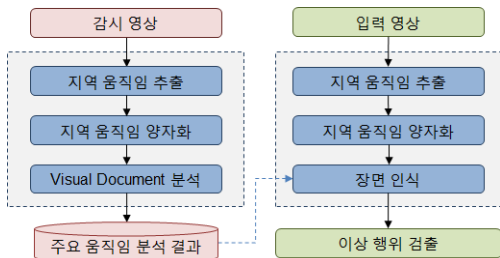


그림 1. 제안하는 장면 분석을 통한 이상행위 검출 방법의 흐름도




그림 2. 지역 움직임의 양자화 기준 (a)발생 위치에 따른 공간적 기준 (b)방향에 따른 구분

의해 결정된다. 해상도가 640x480인 영상의 경우 Visual Vocabulary의 크기는 12,288(64x48x4)가 된다.

2.3 Visual Document 분석

본 논문에서는 다수의 Visual Document를 분석하기 위하여 문서 분석 기법인 LDA 알고리즘을 이용하였다. LDA 알고리즘은 다수의 문서를 분석하여, 주요 주제와 주제별 단어의 분포를 알아내기 위한 방법이다. Visual Document의 경우 LDA 분석을 통하여 주요 장면(Scene)에 대한 발생 확률 P_S 와 주요 장면별 Visual Word의 분포 P_{WS} 를 구할 수 있다. P_S 는 수식 2와 같이 $1 \times k$ 차원의 행벡터이다.

$$P_S = [P(S_1) P(S_2) \dots P(S_k)] \quad (2)$$

이때 k 는 주요 장면의 수를 나타내며, LDA 학습시 영상에 따라 설정해 줄 수 있다. P_{WS} 는 수식 3과 같이 $N \times k$ 차원의 벡터이다.

$$P_{WS} = \begin{bmatrix} P(W_1|S_1) & P(W_1|S_2) & \dots & P(W_1|S_k) \\ P(W_2|S_1) & P(W_2|S_2) & \dots & P(W_2|S_k) \\ \vdots & \vdots & \ddots & \vdots \\ P(W_N|S_1) & P(W_N|S_2) & \dots & P(W_N|S_k) \end{bmatrix} \quad (3)$$

위의 수식에서 N 은 Visual Dictionary의 크기를 나타낸다. 그림 3은 6개의 주요 장면으로 분석된 P_{WS} 를 그림으로 나타낸 것으로, 임계값(0.0001) 이상인 Visual Word만을 나타내었다. 신호에 따른 자동차의 주요 흐름에 따라 주요 장면들이 분리된 모습을 알 수 있다. 이러한 주요 장면들은 장면 인식 기반의 비정상 움직임을 검출하는데 이용된다.

그림 4는 학습된 장면에 따른 움직임 분포를 이용하여 각 방향별 움직임 지도(Motion Map)를 나타낸 것이다. 움직임 지도는 움직임의 방향에 따라 발생 확률이 높은 영역을 나타낸 것이며, 이는 주요 움직임 발생 영역(Motion Block) 분석에 이용된다.

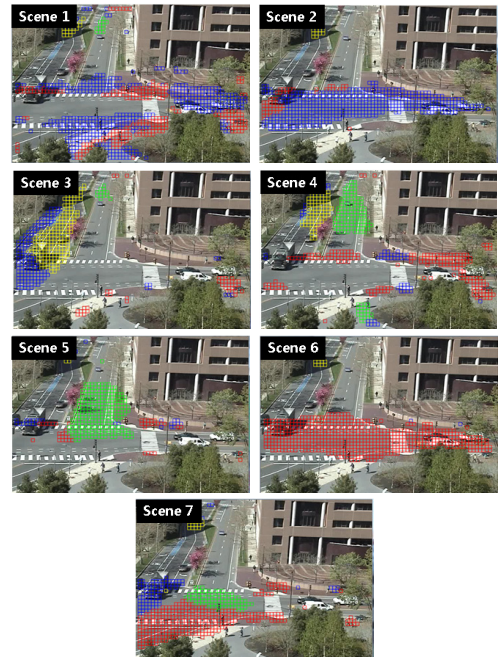


그림 3. 장면 별 움직임 분포 결과




그림 4. 방향별 움직임 지도 (움직임 방향 → ↑ ← ↓)

III. 이상행위 검출

3.1 이상행위의 정의

이상행위란 일정한 기준에서 일탈되어 있음을 뜻하는 용어로 감시 비디오에서의 이상행위란 일반적이지 않은 움직임이라고 정의 할 수 있다. 본 논문에서는 이상행위 즉, 비정상 움직임을 크게 절대적 비정상 움직임(Unconditional Abnormal Motion)과 상대적 비정상 움직임(Conditional Abnormal Motion)으로 정의하였고 이를 구분하여 검출하였다. 절대적 비정상 움직임이란 움직임이 자주 발생하지 않는 영역(Non-Motion Block)에서 발생한 움직임으로, 제한 구역의 침입과 같은 행동으로 인해 발생하는 움직임을 말한

다. 상대적 비정상 움직임이란 움직임이 주로 발생하는 영역(Motion Block)에서 발생한 움직임이나, 주변 상황에 따라 비정상적으로 간주되는 움직임을 말한다. 기차역의 출입구와 같은 곳에서 주변의 흐름을 역행하는 행동과 같은 움직임이 이에 해당한다.

절대적 비정상 움직임의 경우 Non-Motion Block을 이용하여 검출이 가능하다. 반면, 상대적 비정상 움직임을 검출하기 위해서는 주변의 상황을 인식하는 과정을 필요로 한다. 본 논문에서는 영상에서 발생한 움직임과 LDA를 통하여 학습한 P_{WS} 를 이용하여 장면을 인식하고, 이를 바탕으로 상대적 비정상 움직임을 자동으로 검출하도록 하였다.

3.2 장면 인식(Scene Classification)

우선, P_{WS} 를 이용하여 장면을 인식하기 위해서는 일정 시간 동안 발생한 움직임을 Visual Document의 형태로 표현한다. 이때 Visual Document $VD_{t-\alpha,t}$ 가 장면 S_k 에서 발생했을 확률은 수식 1을 이용하여 수식 4와 같이 구할 수 있다.

$$P(S_k|VD_{t-\alpha,t}) = P(S_k|vw_1, vw_2, vw_3, \dots, vw_n) \quad (4)$$

이는 다시 각 Visual Word 별 사후 확률(posterior probability)의 합으로 수식 5와 같이 구할 수 있다.

$$P(S_k|vw_1, vw_2, vw_3, \dots, vw_n) = \frac{1}{n} \sum_i^n P(S_k|vw_i) \quad (5)$$

이는 다시 베이즈 정리(Bayes' theorem)을 이용하여 아래 수식 6과 계산할 수 있다.

$$P(S_k|vw_i) = \frac{P(S_k)P(vw_i|S_k)}{P(vw_i)} \quad (6)$$

위의 수식에서 분자는 P_S 와 P_{WS} 를 이용하고, $P(vw_i)$ 는 Visual Word의 주변 확률(marginal probability)로 수식 7과 같이 계산할 수 있다.

$$P(vw_i) = \sum_k^K P(S_k)P(vw_i|S_k) \quad (7)$$

3.3 이상행위 검출

본 논문에서는 주변의 상황에 따라 이상행위의 여부를 판단하기 위하여, 발생 움직임을 바탕으로 장면을 인식하였다. 인식된 장면 정보를 이용하여 상황에

따른 Visual Word의 발생 확률 구한다. 이상행위의 판단은 수식 8과 같이 계산할 수 있다. 수식 8의 확률이 높을수록 이상행위일 가능성이 높다고 볼 수 있다.

$$P_{Abnormal}(vw_i) = 1 - P(S_k|VD_{t-\alpha,t})P(vw_i|S_k) \quad (8)$$

위의 수식에서 S_k 는 인식된 장면을 나타낸다.

IV. 실험 및 분석

4.1 실험 환경 및 데이터

본 논문에서 제안하는 이상행위 검출 알고리즘의 성능을 평가하기 위하여 MIT^[10], 서울역, 신촌, 연세대 데이터를 이용하였으며, 실험은 Intel CPU 3.0GHz, 메모리 2GB의 하드웨어에서, MS Windows 7 운영체제에서 Visual C++를 이용하여 수행하였다.

실험 데이터는 자동차와 사람을 주요 대상으로 촬영한 영상이다. 교차로와 같이 교통 신호에 따른 교통 흐름의 변화가 있으며, 차도와 보도 같이 움직임이 주로 발생하는 위치가 정해진 구조적 환경 데이터(MIT, 신촌, 연세대)와 움직임 발생 영역에 대한 구분이 없는 비구조적 환경 데이터(서울역)로 구성되어 있다. 실험 데이터에 대한 해상도, 재생시간 및 주요 대상을 표 1에 정리하여 나타내었으며, 그림 5는 각 실험 데

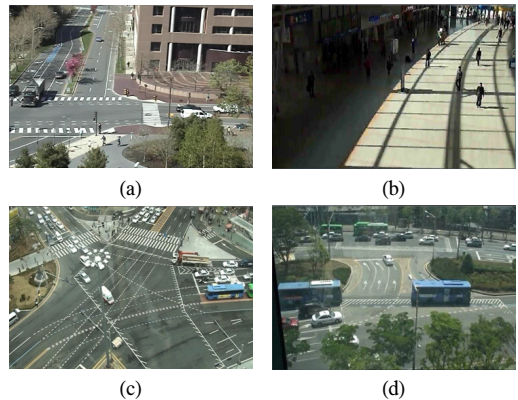


그림 5. 실험 데이터의 대표 영상 (a) MIT (b) 서울역 (c) 신촌 (d) 연세대

표 1. 실험 데이터

데이터	해상도	재생시간	주요 대상
MIT	720x480	01:32:14	자동차, 사람
서울역	360x240	00:30:24	사람
신촌	360x240	00:10:53	자동차
연세대	360x240	00:51:14	자동차

이터에 대한 대표 영상을 나타낸 것이다.


4.2 주요 장면 움직임 학습 결과

본 논문에서 제안된 방법을 이용하여 그림 3과 같은 교차로뿐만 아니라 사람들이 많이 모이는 기차역의 대합실 영상에 대하여 주요 움직임 발생 영역 분석 결과와 주요 장면 움직임을 학습한 결과를 그림 6과 그림 7에 나타내었다.

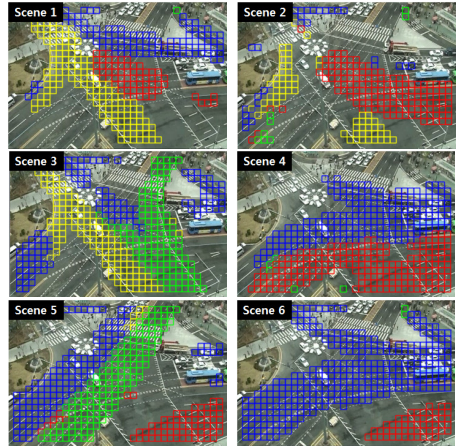
그림 6은 각 실험 데이터가 촬영된 영상에서 움직임이 자주 발생하는 영역과 자주 발생하지 않는 영역을 분석한 결과를 나타낸 것이다. 그림 6-b의 경우 비구조적 환경의 특성상 영상 전체에서 움직임 자주 발생하는 것을 확인할 수 있으며, 그림 6-d의 경우 차도에서의 자동차의 움직임이 주로 관찰되는 구조적 환경의 특성을 확인할 수 있다.

주요 장면 움직임에 대한 학습결과인 그림 7-a를 살펴보면, 사람들이 출입구(화면 외쪽 중앙)로 들어가는 장면 움직임(Scene1)과 출입구에서 나오는 장면 움직임(Scene4)이 분리되어 학습되었음을 확인할 수 있다. 또한 그림 7-b와 c의 경우 교통 신호에 따른 자동차의 흐름 변화가 각 장면 별로 분리되어 학습되었음을 확인할 수 있다. 특히 그림 7-c의 경우 직진 신호에 대한 장면 움직임(Scene1)과 유턴 신호에 대한 장면 움직임(Scene2)로 정확하게 학습되었음을 확인할 수 있다.


각 실험데이터에서 주요 장면 움직임 학습을 위한 장면의 수는 LDA 학습 시 입력으로 지정해주는 것이 가능하며, 본 논문에서는 실험으로 통하여 학습의 빠른 수렴을 위하여 임의로 지정해주었다.(MIT: 7, 서울역: 4, 신촌: 6, 연세대: 2)



(a)



(b)



(c)

그림 7. 장면 별 움직임 분포 결과 (a) 서울역 (b) 신촌 (c) 연세대




그림 6. 실험 데이터 별 주요 움직임 발생 영역 (a) MIT (b) 서울역 (c) 신촌 (d) 연세대

4.3 장면 인식 결과

장면 인식은 장면 학습과 같은 움직임 추출 및 양자화 과정을 거친 후 수식 5를 통하여 입력된 Visual Document에 대한 장면 별 발생확률을 계산하여, 가장 확률이 높은 장면으로 인식한다. 이때 Visual Document는 현재 프레임(t)을 기준으로 이전 프레임($t-a$)까지의 움직임을 모아 생성하며, 슬라이딩 윈도우(sliding window) 방식으로 매 프레임 재 생성하였다. 그림 8은 각 실험 데이터에서의 시간의 흐름에 따른 장면 발생 확률의 변화를 그래프로 나타낸 것이다. 그림 8-d의 경우 Scene1과 Scene2가 주기적으로 변화하는 모습을 확인할 수 있다.

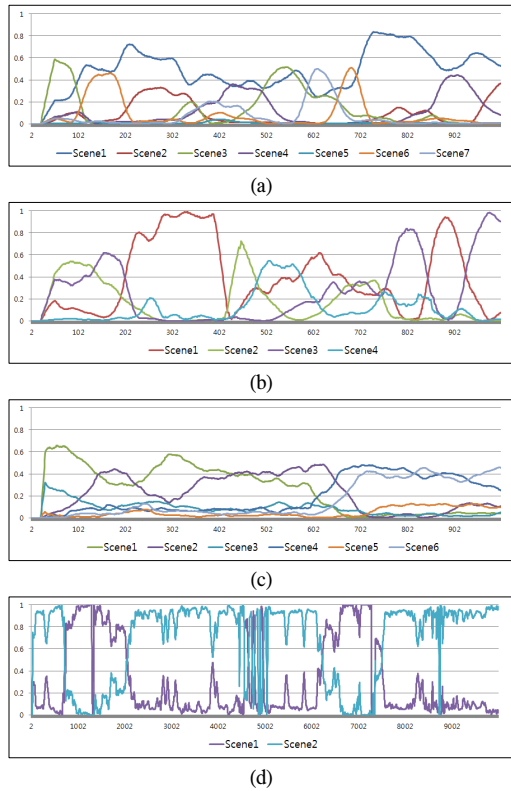


그림 8. 장면 인식 결과 (a) MIT (b) 서울역 (c) 신촌 (d) 연세대

4.4 이상행위 검출 결과

본 논문에서 제안하는 방법을 이용하여 절대적 비정상 움직임과 상대적 비정상 움직임을 검출한 결과를 그림 9와 그림 10에 나타내었다.

절대적 비정상 움직임의 경우 그림 9에서 보는 바와 같이 학습된 감시 영상에서 자주 발생하지 않은 움직임들이 검출된 것을 확인할 수 있다. 대부분 주로 관찰되는 자동차의 움직임 방향과는 다른 방향으로 움직이는 물체(사람, 자동차)에 의한 움직임이 비정상적으로 검출되었음을 알 수 있다. 그러나 그림 9-d의 경우 나무의 가려짐으로 인하여 움직임 정보가 지속적으로 관찰되지 않은 영역에서의 움직임이 비정상적으로 검출되었다.

장면 인식 기반의 상대적 비정상 움직임 검출의 경우 그림 10에서 보는 바와 장면의 주요 흐름과는 다른 방향으로 움직이는 물체가 비정상적으로 검출되었음을 확인할 수 있다. 그림 10-b의 경우 출입구에서 대부분 사람들의 흐름(Scene2, Scene4)과 반대되는 방향으로 움직이는 사람을 적절하게 검출하였음을 확인할 수 있다. 또한 그림 10-d의 경우 유티 신호에서의 흐름

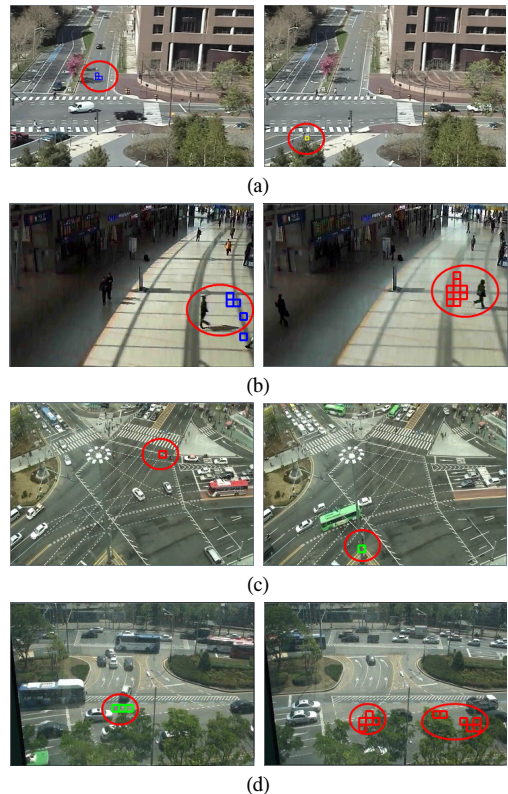


그림 9. 절대적 비정상 움직임 검출 결과 (a) MIT (b) 서울역 (c) 신촌 (d) 연세대

(Scene1)과 직진 신호에서의 흐름(Scene2)에서, 다른 방향으로 움직이는 자동차의 움직임이 비정상적으로 검출되었음을 확인할 수 있다. 그림 10에서 검출된 상대적 비정상 움직임에 대한 프레임 번호와 장면 인식 결과 및 신뢰도를 표 2에 나타내었다. 신뢰도는 수식 5를 이용한 계산된 Visual Word별 사후 확률의 합을 말한다.

표 2. 이상행위 검출 프레임 별 장면 인식 결과 및 신뢰도

데이터	프레임	장면 인식	신뢰도
MIT	4602	Scene4	0.69
	5937	Scene1	0.54
서울역	8857	Scene2	0.58
	25873	Scene4	0.75
신촌	14242	Scene4	0.50
	17389	Scene3	0.57
연세대	6838	Scene1	0.99
	51119	Scene2	0.87

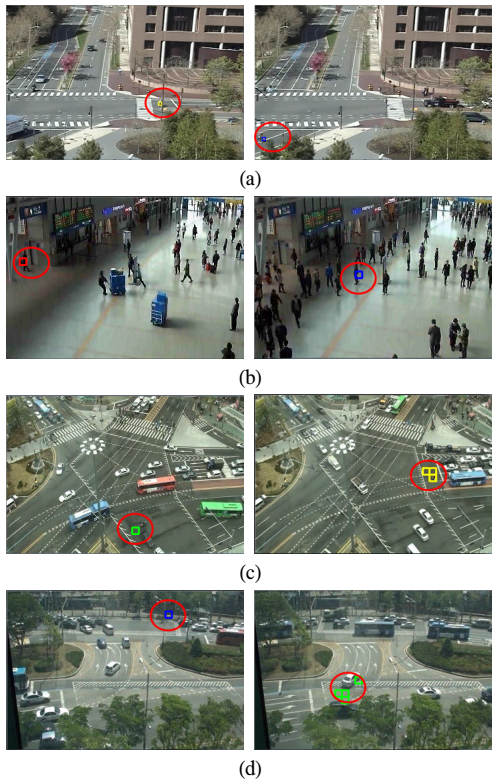


그림 10. 상대적 비정상 움직임 검출 결과 (a) MIT (b) 서울역 (c) 신촌 (d) 연세대

V. 결론 및 향후 연구

본 논문에서는 기존의 움직이는 객체를 추적하여 이상행위를 검출하는 방법과 달리 지역 움직임 정보를 특징으로 추출하고, 분석 분석 기법을 이용하여 주요 움직임을 분석하고, 이를 바탕으로 이상행위를 검출하는 방법을 제안하였다. 제안된 방법에 대하여 실제 환경에서 촬영된 실험데이터를 이용하여 제안한 방법의 성능을 증명하였다. 또한, 지능형 감시 시스템에 이상행위 검출 방법을 적용하기 위해서는 처리시간이 중요한 이슈이다. 본 논문에서 제안한 방법은 이상행위를 검출하는 알고리즘이 초당 30프레임 이상 처리가 가능하기 때문에 실시간 감시 시스템에 적용하기에 적합하다고 판단한다.

그러나 학습된 주요 장면 움직임의 갱신에 대한 문제와 카메라의 흔들림이나 잠음으로 인한 비정상 움직임의 오 검출 등의 문제는 향후 과제로 남아있다.

참고 문헌

- [1] C. Stauffer and E. Grimson, "Learning Patterns of Activity Using Real-Time Tracking," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 22, pp. 747-757, 2000.
- [2] X. Wang, K. Tieu, and E. Grimson, "Learning Semantic Scene Models by Trajectory Analysis," *Proc. Ninth European Conf. Computer Vision*, 2006.
- [3] H. Zhong, J. Shi, and M. Visontai, "Detecting Unusual Activity in Video," *Proc. IEEE Int'l Conf. Computer Vision and Pattern Recognition*, 2004.
- [4] P. Smith, N.V. Lobo, and M. Shah, "Temporalboost for Event Recognition," *Proc. Int'l Conf. Computer Vision*, 2005.
- [5] T. Xiang and S. Gong, "Video Behaviour Profiling and Abnormality Detection without Manual Labelling," *Proc. Int'l Conf. Computer Vision*, 2005.
- [6] Y. Wang, T. Jiang, M.S. Drew, Z. Li, and G. Mori, "Unsupervised Discovery of Action Classes," *Proc. IEEE Int'l Conf. Computer Vision and Pattern Recognition*, 2006.
- [7] David M. Blei, Andrew Y. Ng, Michael I. Jordan, "Latent dirichlet allocation", *The Journal of Machine Learning Research*, Volume 3, pp 993-1022, 2003.
- [8] C. Harris and M.J. Stephens. A combined corner and edge detector. In *Alvey Vision Conference*, pages 147-152, 1988.
- [9] Carlo Tomasi, Takeo Kanade, "Detection and tracking of point features", *Technical Report CMU-CS-91-132*, Carnegie Mellon University, April 1991.
- [10] <http://www.ee.cuhk.edu.hk/~xgwan/MITtraffic.html>

배 건 태 (Guntae Bae)

정회원



2005년 2월 한남대학교 컴퓨터
멀티미디어학과 졸업
2008년 2월 연세대학교 컴퓨터
과학과 석사
2008년 3월~현재 연세대학교
컴퓨터과학과 박사과정
<관심분야> 영상처리, 컴퓨터
비전 및 패턴 인식

곽 수 영 (Sooyeong Kwak)

정회원



2010년 2월 연세대학교 컴퓨터
과학과 박사
2010년 3월~2011년 1월 삼성
전자 영상디스플레이사업부
책임연구원
2011년 2월~현재 한밭대학교
제어계측공학과 전임강사
<관심분야> 영상처리, 컴퓨터 비전 및 패턴 인식

어 영 정 (Youngjung Uh)

정회원



2010년 2월 연세대학교 컴퓨터
과학과 졸업
2010년 3월~현재 연세대학교
컴퓨터과학과 석박통합과정
<관심분야> 스테레오 비전, 영
상 감시

변 혜 란 (Hyeran Byun)

정회원



1980년 2월 연세대학교 수학과
졸업
1987년 2월 연세대학교 수학과
석사
1987년 6월 Univ. of Illinois
at Chicago Computer
Science, M.S.
1993년 12월 Purdue Univ. Computer Science, Ph. D.
2004년 3월~현재 연세대학교 컴퓨터과학과 정교수
<관심분야> 영상처리, 컴퓨터 비전 및 패턴 인식