

# 많은 통행량과 조명 변화에 강인한 빠른 배경 모델링 방법

이광국<sup>†</sup>, 김재준<sup>‡‡</sup>, 김회율<sup>\*\*\*</sup>

## 요 약

배경 제거를 위한 많은 연구가 있어왔음에도 기존의 방법들을 실제 환경에 효과적으로 적용하기에는 아직도 많은 어려움이 있다. 본 논문에서는 배경 제거를 실제 환경에 적용하면서 만나게 되는 다양한 문제들을 해결하기 위해 기존의 가우시안 혼합 모델 방법을 개선하는 배경 제거 방법을 제안한다. 첫째로 제안한 방법은 낮은 계산량을 얻기 위하여 고정 소수점 연산을 이용하였다. 배경 모델링 과정은 변수들의 높은 정밀도를 요구하지 않기 때문에 제안한 방법에서는 고정 소수점 변수를 이용함으로서 정확도를 유지한 채 연산 속도를 크게 향상시킬 수 있었다. 두 번째로 보행자들의 높은 통행량 하에서 흔히 발생되는 전경 객체가 배경으로 학습되는 문제를 피하기 위하여 각 화소의 정적인 정도를 이용하여 배경 모델의 학습 속도를 동적으로 조절하였다. 즉 최근 화소 값에 큰 차이가 발생한 화소들은 배경 영역이 아닐 가능성이 높으므로, 이에 대해 낮은 학습 비율을 적용함으로써 높은 통행량을 보이는 영상에서도 유효한 배경 모델을 유지하는 것이 가능했다. 마지막으로 영상의 빠른 밝기값 변화에 대응하기 위하여 연속한 두 프레임 간의 밝기 변화를 선형 변환으로 추정하였으며, 훈련된 배경 모델을 이 선형 변환에 의해 직접적으로 변환시켜 주었다. 제안한 고정 소수점 연산에 의해 기존의 가우시안 혼합 배경 모델링 방법을 구현한 결과 배경 제거에 기존 방법의 약 30%의 연산시간 만을 필요로 하였다. 또한 제안한 방법을 실제 환경의 영상에 적용한 결과 기존의 배경 제거 방법에 비해 검출률이 약 20% 향상되었으며, 오검률은 5~15% 가량 낮아지는 것을 확인하였다.

## A Fast Background Subtraction Method Robust to High Traffic and Rapid Illumination Changes

Gwang-Gook Lee<sup>†</sup>, Jae-Jun Kim<sup>‡‡</sup>, Whoi-Yul Kim<sup>\*\*\*</sup>

## ABSTRACT

Though background subtraction has been widely studied for last decades, it is still a poorly solved problem especially when it meets real environments. In this paper, we first address some common problems for background subtraction that occur in real environments and then those problems are resolved by improving an existing GMM-based background modeling method. First, to achieve low computations, fixed point operations are used. Because background model usually does not require high precision of variables, we can reduce the computation time while maintaining its accuracy by adopting fixed point operations rather than floating point operations. Secondly, to avoid erroneous backgrounds that are induced by high pedestrian traffic, static levels of pixels are examined using shot-time statistics of pixel history. By using a lower learning rate for non-static pixels, we can preserve valid backgrounds even for busy scenes where foregrounds dominate. Finally, to adapt rapid illumination changes, we estimated the intensity change between two consecutive frames as a linear transform and compensated learned background models according to the estimated transform. By applying the fixed point operation to existing GMM-based method, it was able to reduce the computation time to about 30% of the original processing time. Also, experiments on a real video with high pedestrian traffic showed that our proposed method improves the previous background modeling methods by 20% in detection rate and 5~10% in false alarm rate.

**Key words:** Video Surveillance(영상 감시), Background Subtraction(배경 제거), Foreground Detection (전경 검출)

\* 교신저자(Corresponding Author) : 김회율, 주소 : 서울시 성동구 행당동(133-791), 전화 : 02)2220-0351, FAX : 02)2292-6316, E-mail : wykim@hanyang.ac.kr

접수일 : 2009년 8월 3일, 수정일 : 2009년 10월 23일

완료일 : 2010년 2월 19일

\* 준회원, 한양대학교 전자통신컴퓨터공학과 박사과정

(E-mail : gglee@vision.hanyang.ac.kr)

\*\* 정회원, 한양대학교 건축공학부 교수

(E-mail : jjkim@hanyang.ac.kr)

\*\*\* 종신회원, 한양대학교 전자컴퓨터통신공학부 교수

\* 본 연구는 2009년도 한국건설교통기술평가원 연구비 지원에 의해 수행되었음. 과제번호: 06건설핵심D06

## 1. 서 론

입력 영상에서 정지된 배경과 움직이는 객체를 분리하는 배경 제거는 다양한 영상 감시 응용에 전처리 과정으로 이용되는 매우 중요한 기술이다. 배경 제거를 위한 가장 원시적인 방법은 전경 객체가 포함되어 있지 않은 참조 영상(reference image)을 등록하여 두고 입력 영상과 그 참조 영상의 차를 계산하는 방법이다. 하지만, 이 방법은 적절한 참조 영상을 사용자가 입력하여 주어야 하며 또한 배경에 변화가 발생했을 경우에 그 변화에 대응하지 못하는 문제점이 있다. 이러한 문제를 해결하기 위하여 배경 모델(background model)을 이용하는 방법들이 제안되었다.

배경 모델링을 통한 배경 제거 방법에서는 연속한 매 입력 영상을 이용하여 배경 모델을 생성하고 생성된 배경 모델과 입력 영상을 비교하여 움직이는 객체를 검출한다. 이 방법들은 입력 영상의 통계적 특성을 이용하여 배경 모델을 자동으로 생성하고 갱신하기 때문에 사용자의 개입을 필요로 하지 않으며 배경의 변화에도 대응이 가능하다. 지금까지 효과적인 배경 제거를 위해 다양한 배경 모델링 방법이 제안된 바 있다. 기존의 배경 모델링 방법들에서는 밝기값[1], 색상값[2,3], 경계[4], 질감[5], 깊이[6], 코너점[7] 또는 이들의 조합이 특징으로서 이용된 바 있으며, 배경 모델의 변화는 자기 회기(auto regression)[8], 순서 통계량(order statistics)[1], 도수분포(histogram)[4,9], 가우시안 분포(Gaussian distribution)[2,6]등에 의해 표현되었다. 이처럼 다양한 연구가 진행되었음에도 기존의 배경 제거 연구들을 실험실 환경이 아닌 실제 환경에 적용하기 위해서는 아직도 많은 문제들이 해결되어야 한다. 기존의 배경 제거 방법들을 실제 환경에 적용할 때 발생하는 문제점 가운데에는 다음과 같은 것들이 있다.

- 높은 계산량: 배경 제거 과정은 대부분의 영상 감시 응용에서 필수적으로 실시간 처리가 요구된다. 연산 속도의 문제는 특히 수십 대 이상의 카메라가 이용되는 대규모 영상 감시 시스템이나 하드웨어의 계산 성능이 비교적 낮은 경우에 더욱 중요한 문제가 된다. 하지만, 기존의 배경 제거 방법들은 일반적으로 다수의 소수점 연산을 모든 화소들에 대하여 반복적으로 수행하기 때문에 높은 연산량을 요구하는 문

제가 있다.

- 지속적인 객체 이동에 대한 대응: 통행량이 많은 통로 또는 출입문 근처에서는 끊임없이 객체의 이동이 발생한다. 이러한 지역에서 지속적으로 객체의 움직임이 발생되는 경우에는 종종 전경 객체가 배경보다도 더 자주 관찰되어 결과적으로 전경 객체의 일부가 배경으로 학습되는 문제가 발생하게 된다.

- 빠른 조명 변화에 대한 대응: 대부분의 배경 모델링 방법은 매 입력 프레임에 의해 배경 모델을 지속적으로 갱신하기 때문에 배경 영상의 변화에 대응할 수 있다. 하지만, 이러한 모델 갱신 과정은 그 적용 속도가 다소 느리기 때문에 태양을 가리는 구름이나 카메라의 자동 노출 조절 등과 같이 비교적 빠르게 발생되는 영상의 전역적 밝기 변화에는 대응하기 어려운 문제점이 있다.

본 논문에서는 이와 같은 기존 배경 제거의 문제점을 해결하기 위하여 기존의 가우시안 혼합 모델(Gaussian mixture model)에 기반한 배경 모델링을 개선한 방법을 제안한다. 제안한 방법에서는 빠른 연산을 위하여 부동소수점 연산 대신 정수형 변수를 이용한 고정 소수점 연산을 이용하였다. 또, 지속적인 객체의 이동에 의해 잘못된 배경 모델이 생성되는 것을 피하기 위하여 화소 값의 단시간 통계량을 이용하여 배경 모델의 학습 속도를 동적으로 조절한다. 마지막으로 빠른 조명 변화에 대응하기 위하여 연속한 프레임 사이의 조명 변화를 추정하며, 추정된 조명 변화에 의해 배경 모델을 직접적으로 조정한다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 제안한 방법의 기반이 되는 가우시안 혼합 모델 기반 배경 모델링 방법에 대해 간략히 소개하며, 3장에서는 제안된 배경 모델링 방법에 대한 설명이 이어진다. 4장에서는 실험 결과를 보이며 마지막으로 5장에서 결론을 맺는다.

## 2. 가우시안 혼합 모델 기반 배경 모델링 방법

본 논문에서 제안하는 배경 모델링 방법은 Stauffer 등에 의해 제안된 가우시안 혼합 모델 기반 배경 모델링 방법[2]에 기반하고 있다. 따라서, 이 장에서는 가우시안 혼합 모델 기반 배경 모델링 방법에 대해 간략히 소개한다. Stauffer 등의 방법에서는 각

화소의 배경 모델이  $K$ 개 가우시안 분포로 구성된 혼합 모델로서 표현되었다. 이 가우시안 혼합 모델에 의하여 어떤 화소가 시간  $t$ 에서  $X_t$ 의 값을 가질 확률은 다음의 수식 (1)과 같이 표현된다.

$$P(X_t) = \sum_{i=1}^K w_{k,t} g(X_t; \mu_{k,t}, \Sigma_{k,t}). \quad (1)$$

수식 (1)에서  $w_{k,t}$ ,  $\mu_{k,t}$ ,  $\Sigma_{k,t}$ 은 각각 시간  $t$ 에서  $k$ 번째 가우시안 분포의 가중치, 평균, 공분산행렬을 나타낸다. 매 입력 프레임에 대하여 배경 모델의 매개 변수들은 online  $K$ -means 방법에 의하여 다음 수식 (2)와 같이 갱신된다.

$$\Theta_{k,t}(x) = (1-\alpha)\Theta_{k,t-1}(x) + \alpha I_t(x), \Theta_{k,t-1}(x)). \quad (2)$$

수식 (2)에서  $\Theta_{k,t}(x)$ 는 시간  $t$ 에서의 어떤 화소  $x$ 에 대한 배경 모델의  $k$ 번째 가우시안 분포를 나타내며,  $I_t(x)$ 는 시간  $t$ 의 입력 영상에서 해당 화소의 값을 나타낸다. 각 가우시안 모델은 새로운 입력값  $I_t(x)$ 에 대한 예측치  $A()$ 에 의해서 그 매개변수를 갱신하게 된다. 즉, 정합된 가우시안 모델 가운데 입력치와 가장 가까운 모델의 매개변수만이 갱신되게 되며, 나머지 모델들은 매개변수 값은 그대로 유지된 채 가중치  $\alpha_k$ 만  $1-\alpha$  만큼 감소하게 된다. 여기에서  $\alpha$ 는 배경모델의 학습 속도를 결정하는 상수로서 Stauffer의 연구에서는 0.002의 값이 사용되었다. 새로운 입력 영상에 대해서 배경 모델의 갱신이 이루어진 이후에는 각 분포의 가중치의 합이 1이 되도록 가중치 값이 정규화 된다.

$K$ 개의 가우시안 분포 가운데 해당하는 모델을 결정하기 위해서, 우선 각 가우시안 모델이 가중치 크기 순으로 정렬되며, 가중치의 합이 주어진 임계값  $T$ 를 넘는 최소 개수의 가우시안 모델들이 배경 모델로 선택된다.

### 3. 제안한 방법

본 논문에서 제안하는 배경 모델링 방법은 2장에서 설명된 Stauffer등의 가우시안 혼합 배경 모델링 방법에 기반하며, 1장에서 설명된 문제점을 개선하기 위하여 Stauffer등의 방법을 개선한다. 그림 1은 제안한 배경 모델링 방법의 구성을 보여준다. 제안한 방법은 그림 1에 나타난 것과 같이 연속된 입력 영상들로부터 단시간 통계량을 구성하며, 이를 이용

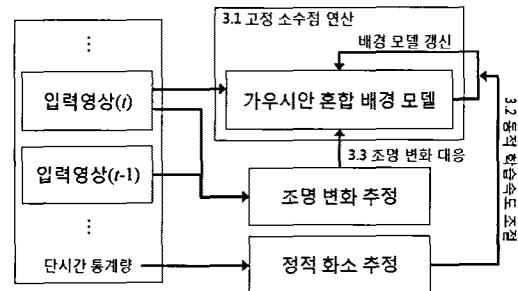


그림 1. 제안한 배경 모델링 방법의 구성도

하여 영상 내의 정적 화소와 비정적 화소를 구분한다. 이후 비정적 화소에 대해서는 학습 속도를 낮추어 줌으로써 혼잡한 환경에서도 유효한 배경 모델을 유지한다. 또 제안한 방법에서는 인접한 두 프레임 간의 조명 변화를 추정하고 배경 모델을 추정된 조명 변화에 대해 적절적으로 변환시킴으로써 영상 내의 빠른 조명 변화에 효과적으로 대응한다. 마지막으로 빠른 연산 속도의 향상을 위하여 배경 모델의 갱신 및 배경 제거 과정과 단시간 통계량 갱신 과정은 정수형 변수를 이용한 고정 소수점 연산에 의해서 이루어진다.

#### 3.1 정수형 변수를 이용한 고정 소수점 연산

배경 모델링 방법은 일반적으로 영상 내 모든 화소에 대해 반복적으로 소수점 연산을 수행하기 때문에 많은 연산량을 요구한다. 그런데 배경 모델링은 객체 추적 또는 이벤트 감지와 같은 상위 프로세스의 전처리로서 사용되는 경우가 많기 때문에 빠른 계산 속도가 요구된다. 또한 실제 환경에서는 실험실 환경과는 달리 수십대 이상의 카메라가 동시에 이용되거나 낮은 연산 능력을 가진 장비들이 이용되는 경우가 많기 때문에 배경 제거의 계산량을 낮추는 것은 매우 중요하다.

배경 제거의 기존 연구 가운데에는 정수형 변수를 이용하여 배경 모델링을 수행함으로서 계산 속도 향상을 얻고자 한 연구들이 있었다. Kumar 등은 큐 (Queue)를 이용하여 최근 화소들의 통계량을 추정하는 배경 모델링 방법을 제안하였다[9]. Kumar 등의 방법에서는 배경 모델이 큐 내 화소 값의 도수분포의 최대값에 의해 계산되기 때문에 배경 모델이 매우 적은 연산만으로 계산될 수 있었다. 하지만, 이 방법은 영상의 모든 화소에 대하여 큐를 필요로 하기 때-

문에 많은 메모리를 요구하며 또한 배경 모델이 단일 최빈수(mode)로서 표현되기 때문에 지속적으로 변하는 복잡한 배경에는 적합하지 않은 단점이 있었다. Apewokin 등은 배경 모델의 표현에 정수만을 이용하는 다중 최빈수 평균(multi-modal mean, MM) 배경 모델을 제안한 바 있다[10]. 그들의 방법에서는 배경 화소의 평균값을 화소값의 합계와 발생 횟수를 이용하여 정수를 통해 나타내었다. 하지만, 그들의 방법은 모델 감쇠 과정이 낮은 학습 비율에 의해 지속적으로 일어나는 기존 배경 모델링 방법과 달리 일정 주기마다 모델의 감쇠가 절반씩 이루어지기 때문에 배경 모델이 갱신 과정이 불안정한 문제점이 있었다. 본 논문에서는 배경 모델링 방법의 속도 향상을 위해 고정 소수점 연산을 이용한 빠른 배경 모델링 방법을 제안한다. 제안한 방법은 가우시안 혼합 배경 모델링 방법이 부동소수점 자료형에 의해 지원되는 정밀도에 비하여 비교적 낮은 정밀도만을 요구한다는 관찰에 기반하고 있다. 따라서, 기존의 배경 모델링 방법에 고정 소수점 연산을 적용함으로서 정확도를 유지하면서 계산 속도를 향상 시킬 수 있다.

이를 위해 우선 고정 소수점 변수의 정수부와 소수부에 각각  $m, n$  비트(bit)가 할당되었다고 가정한다. 그러면, 정수형 변수를  $n$  비트만큼 비트 이동(bit shift)시킴으로서 이를 고정 소수점 변수로 손쉽게 변환할 수 있다. 정수형 변수  $d$ 의 고정소수점 변수로의 변환은 다음수식 (3) 같이 표현된다. 여기에서  $d$ 는 임의의 정수형 변수이며,  $f$ 는  $d$ 를  $n$ 비트만큼 비트이동하여 얻어진 고정소수점 변수이다.

$$f = d \cdot 2^n = d \ll n \quad (3)$$

고정 소수점 변수의 덧셈과 뺄셈 연산은 정수형 변수의 가산과 감산 연산에 의해 직접적으로 계산이 가능하다. 하지만, 곱셈과 나눗셈 연산의 경우에는 연산 결과가 다시 고정소수점 변수에 의해 표현되도록 주의해야 할 필요가 있다. 두 고정소수점 변수를 정수형 변수의 곱셈 연산을 통해 곱하게 되면 연산 결과에는  $2^n$ 이 곱해지게 되어 결과적으로 고정 소수점 변수에  $2^n$ 을 곱한 형태가 된다. 따라서, 곱셈 연산 시 수식 (4)와 같이 연산 결과를  $2^n$ 으로 나누어 주어야 연산 결과를 다시 고정 소수점형 변수로 얻을 수 있다. 이와 유사하게 나눗셈의 경우에는 연산 결과에  $2^n$ 을 곱해주어야 한다. 이 때 실제 연산은 정수형 변

수를 통해서 일어나게 되므로, 계산 과정에서 유효자리수를 확보하기 위하여 수식 (5)에 나타난 것과 같이 피연산자에 미리  $2^n$ 을 곱해준 후 정수형 변수의 나눗셈 연산을 이용하여 나눗셈을 하게된다.

$$f_1 \cdot f_2 / 2^n = (d_1 \cdot 2^n) \cdot (d_2 \cdot 2^n) / 2^n = (d_1 \cdot d_2) \cdot 2^n \quad (4)$$

$$f_1 / f_2 \cdot 2^n = (d_1 \cdot 2^n) \cdot 2^n / (d_2 \cdot 2^n) = (d_1 / d_2) \cdot 2^n \quad (5)$$

고정 소수점 변수형의 연산에 있어서 비트 이동의 양  $n$ 의 값은 매우 중요하다. 비트 이동량  $n$ 이 너무 작으면 연산의 유효자리수가 작아지며, 반대로  $n$ 이 너무 크면 계산 과정에서 넘침(overflow)이 발생할 수 있다. 본 논문에서는 고정 소수점 변수의 표현을 위해 32비트 정수를 이용했으며, 이 가운데 한 비트는 부호를 나타내기 위하여 이용하였다. 따라서 고정 소수점 변수의 정수부와 소수부에는 총 31비트가 이용될 수 있다. 수식 (4)에서 넘침이 발생하지 않기 위해서는  $(d_1 \cdot 2^n) \cdot (d_2 \cdot 2^n)$ 의 값이 정수형 변수에 의해 표현 가능해야 하기 때문에 정수부의 비트수  $m$ 과 소수부의 비트수  $n$ 은  $2(m+n) \leq 31$ 을 만족해야 한다는 것을 알 수 있다. 유사하게 나눗셈 과정에서 넘침이 발생하지 않기 위해서는 수식 (5)에 의해  $m+2n \leq 31$ 을 만족해야 한다. 그런데, 화소값은 0에서 255 사이의 범위를 가지므로  $m$ 의 값은 8로서 고정이 되기 때문에  $n$ 을 7로 선택하면 연산에서 넘침이 발생하지 않으면서 최대의 정밀도를 확보하는 것이 가능하다. 이 때 고정 소수점형 변수의 정밀도는  $1/2^7 \approx 0.008$ 이 된다.

가우시안 혼합 모델의 가중치  $w_k$  또는 배경 모델의 학습 속도  $a$ 는 화소값에 의해 변화하는 가우시안 모델의 평균과 분산에 비해 매우 높은 정밀도를 필요로 한다. 가중치  $w_k$ 와 학습속도  $a$ 는 0에서 1 사이의 값을 가지게 되므로 소수부에 더 많은 비트를 할당하는 것이 가능하다. 따라서, 본 논문에서는 가중치  $w_k$ 와 학습속도  $a$ 의 소수부에 15비트를 할당하였다. 이 때의 정밀도는  $1/2^{15} \approx 0.3 \times 10^{-4}$ 이 된다.

### 3.2 혼잡한 환경을 위한 동적 학습 속도 조절

가우시안 혼합 모델 기반의 배경 모델링 방법은 증량적 학습(incremental learning)에 의해 입력 영상으로부터 배경 모델을 갱신하며, 이러한 학습 과정은 현재 프레임으로부터 과거  $L$ 개의 프레임을 포함

하는 시간적 윈도우를 통해 최근 화소값들의 통계치를 계산하는 것으로 해석될 수 있다. 이 시간적 윈도우는 현재 프레임에서 가까운 프레임에 높은 가중치를 부여하며 지수적으로 감소하는 가중치를 가지며, 윈도우의 길이  $L$ 은 배경 모델의 학습 속도  $\alpha$ 에 반비례한다. 2장에서 소개된 가우시안 혼합 배경 모델의 중량적 학습 과정은 길이  $L$ 의 시간적 윈도우 내에서 배경 화소의 발생 빈도가 다른 전경 화소들의 발생 빈도에 비해 현저히 높을 것이라는 가정에 기반하고 있다. 그러나, 이러한 가정은 통행량이 많은 환경을 관찰할 때 성립하지 않는 경우가 쉽게 발생한다. 예를 들어 영상 내에서 보행자의 움직임이 계속적으로 발생하게 되면 전경 화소가 최근 화소의 통계치에서 차지하는 비중이 커지게 되어 그림 2에 나타난 것과 같이 오염된 배경 모델이 잘못 생성되는 경우가 발생 한다.

이러한 문제를 해결하기 위해서 본 논문에서는 배경 화소가 가장 높은 빈도로 발생한다는 기준의 가정 이외에 배경 화소는 또한 정적이어야 한다는 가정을 추가하였다. 즉 각 화소의 정적인 정도(static level)에 따라서 학습 비율을 변경하여 배경 모델을 갱신하였다. 예를 들어 어떤 화소가 최근 몇 프레임 동안에 큰 변화를 보였다면, 이 화소는 전경 객체에 속할 가능성이 높으며 따라서 배경 모델의 갱신에 낮은 학습 비율을 적용한다. 제안한 방법에는 어떤 화소가 정적 인지 아닌지 판단하기 위해 각 화소의 단시간 통계를 이용하였다. 어떤 화소의 단시간 분산값이 매우 작은 값을 갖는다면, 이는 그 화소가 최근 매우 적은 값의 색상 변화만을 경험하였다는 것을 의미하며 해당 화소는 배경일 가능성이 높다고 할 수 있다. 반면 어떤 화소의 단시간 분산이 크다면, 해당 화소의 값은 전경 객체의 움직임에 의해 많은 변화를 가진 것으로 생각할 수 있다.



그림 2. 많은 통행량을 보이는 영상의 예. (a) 입력 영상, (b) 많은 통행량에 의해 잘못 생성된 배경 모델

단시간 분산은 수식 (6)과 (7)에 나타난 것과 같이 가우시안 혼합 배경 모델의 매개변수 갱신 과정과 유사하게 반복적으로 계산된다. 여기에서  $\mu_{st}$ 는 단시간 평균이며  $\sigma_{st}$ 는 단시간 분산을 나타낸다. 또한  $\alpha_{st}$ 는 단시간 통계량의 갱신을 속도를 조절하는 학습비율이며, 보행자의 이동에 의해서 발생하는 짧은 기간 동안의 영상 변화만을 반영하기 위하여 배경 모델의 학습 비율에 비해 상대적으로 큰 값이 이용되었다. 학습 비율과 시간적 윈도우의 길이 사이에는 반비례 관계가 성립하는 것이 이미 알려져 있으며[2,3], 1초 이내의 짧은 시간상의 변화만을 고려하기 위하여  $\alpha_{st}$ 의 값을 실험적으로 0.1로 선택하였다.

$$\mu_{st}(x, t) = (1 - \alpha_{st})\mu_{st}(x, t - 1) + \alpha_{st}I(x, t) \quad (6)$$

$$\sigma_{st}^2(x, t) = (1 - \alpha_{st})\sigma_{st}^2(x, t - 1) + \alpha_{st}(I(x, t) - \mu_{st}(x, t))^2 \quad (7)$$

이렇게 얻어진 단시간 분산을 임계값  $T_{st}$ 와 비교하여 각 화소가 정적 화소(static pixel)인지 아닌지 판단하게 된다. 그림 3은 이러한 정적 화소 분류의 예를 보여준다. 그림 3 (a)는 입력 영상이며, 그림 3 (b)는 정적 화소의 분류 결과를 나타낸다. 그림 3 (b)에서 임계값보다 작은 단시간 분산을 갖는 정적 화소는 검은색으로, 그렇지 않은 비정적 화소는 흰색으로 표시되어 있다.

빠르게 이동하는 객체의 주변부에서는 단시간 분산이 큰 값을 갖기 때문에 이를 쉽게 비정적 영역으로 구분할 수 있다. 하지만, 정지되어 있는 물체 또는 천천히 이동하는 물체들의 내부 화소들은 종종 매우 낮은 단시간 분산값을 갖기도 한다. 이러한 예가 그림 3 (b)의 하단의 정지한 사람과 상단의 군중 부분에 직사각형으로 표시되어 나타나 있다. 이러한

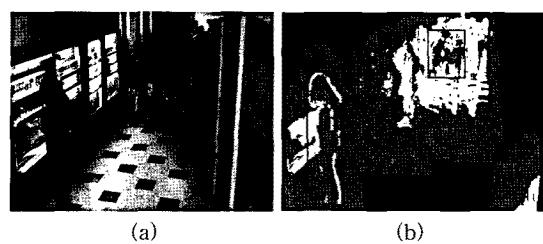


그림 3. 정적 화소 구분의 예: (a) 입력 영상, (b) 정적 화소 판단 결과. 검은색 화소는 정적 화소를, 흰색 화소는 비정적 화소를 나타내며, 회색 화소는 객체 크기를 고려한 모폴로지 연산을 통하여 확장된 비정적 화소를 나타낸다.

정지된 또는 천천히 움직이는 객체 내부의 화소들은 매우 낮은 단시간 분산을 갖기 때문에 객체 내부의 화소들은 정적 화소로 구분되었다.

이렇게 정적 화소로 분류된 전경 화소가 배경 모델의 간신에 기여하는 것을 방지하기 위하여 제안한 방법에서는 모폴로지 연산을 통하여 정적 화소 분류 결과를 확장하였다. 모폴로지 연산을 위한 마스크의 크기는 각 화소 위치에서 예측되는 사람의 크기에 의해 결정되었다. 즉  $(x, y)$  위치에서 예측되는 사람의 너비와 높이를 각각  $W, H$ 라 했을 때, 영역 확장을 위한 마스크의 크기는  $\frac{1}{2}W \times \frac{1}{2}H$ 로 선택된다. 각 화소 위치에서 예측되는 사람의 크기는 [11]에서 제안된 방법에 의해 초기화 단계에서 자동으로 설정되었다. 이 방법에서는 영상 내 각 화소 위치에서 객체의 크기를  $y$  좌표의 선형 함수로서 표현하며,  $y$  좌표 값과 해당 위치에서 사람의 크기  $W \times H$ 의 관계는 단일 객체의 크기를 지속적으로 누적시킴으로써 얻어진다.

그림 3 (b)에서 회색 화소는 모폴로지 연산에 의해 확장된 정적 화소들을 나타낸다. 그림에 나타난 것과 같이 모폴로지 연산에 의해 정지된 객체 내부의 비정적 화소들이 정적 화소로 다시 구분된 것을 볼 수 있다. 영역 확장에 의해 이동 객체 주변에 위치한 배경 영역의 화소들까지 비정적 화소로 구분된 것을 볼 수 있지만, 비정적 화소로 분류된 배경 영역은 학습 속도가 낮아질 뿐이므로 배경 제거 과정의 정확도에 큰 영향을 끼치지 않는다.

본 논문에서는 모폴로지 연산의 빠른 계산을 위하여 적분 영상(Integral image)를 이용하였다[12]. 적분 영상을 이용할 경우 마스크 내의 모든 화소를 참조해야 하는 일반적인 모폴로지 연산과 달리, 한 화소 위치에 대해 마스크 주변의 네 점만을 참조함으로서 모폴로지 연산이 가능하여 연산 속도가 크게 줄어들게 된다. 특히 제안한 방법의 경우 영상 확장을 위한 마스크가 객체의 크기에 의해서 정의되기 때문에 영상의 하단 부분에서 마스크의 크기가 크게 증가하게 되는데 적분 영상을 이용하여 모폴로지 연산을 수행함으로써 이러한 문제를 피하고 연산량을 크게 줄이는 것이 가능하다.

### 3.3 빠른 밝기 변화에 대한 대응

가우시안 혼합 배경 모델링 방법은 온라인 학습에 의해 배경 모델을 지속적으로 갱신하기 때문에 배경

영상의 변화에 적응적으로 대응할 수 있다. 하지만, 이러한 적응 과정은 다소 느리게 진행되기 때문에 빠르게 발생되는 영상의 변화에는 대응하지 못하는 경우가 종종 발생한다. 예를 들면, 카메라 앞을 통과하는 다수의 보행자는 카메라의 자동 노출 조정을 유발시켜 영상에 전역적인 밝기 변화를 가져온다. 또, 실외 영상에서 태양 앞으로 지나가는 구름도 마찬가지로 짧은 시간에 영상 전체의 밝기 변화를 유발시킬 수 있다.

이러한 빠른 밝기 변화의 예가 그림 4에 나타나 있다. 그림 4 (a)와 (b)는 약 2초 (60 프레임)의 시간 차를 갖는 입력 영상이며, 그림 4 (c)는 그림 4 (b)의 배경제거 결과이다. 그림에서 배경으로 판단되어 제거된 화소는 흰색으로 표시되어 있다. 어두운 색상을 갖는 이동 객체가 카메라 앞에 갑자기 나타났기 때문에 카메라의 노출 자동 조정에 의해 영상의 밝기가 변화하였으며, 이에 따라 배경 영역의 많은 부분이 전경으로 잘못 분류된 것을 볼 수 있다. 그림 4 (d)는 그림 4 (a)와 (b) 사이의 밝기 차를 보여준다. 그림 4 (d)에서 어두운 회색, 밝은 회색, 흰색으로 나타난 화소들은 각각 두 영상에서 5, 10 그리고 15 이상의 밝기값 차이를 갖는 화소들을 나타낸 것이다. 그림 4 (d)에서 비교적 같이 짧은 시간 동안 대부분의 화소에서 10 이상의 밝기 값 차이가 발생되는 것을 볼 수 있다.

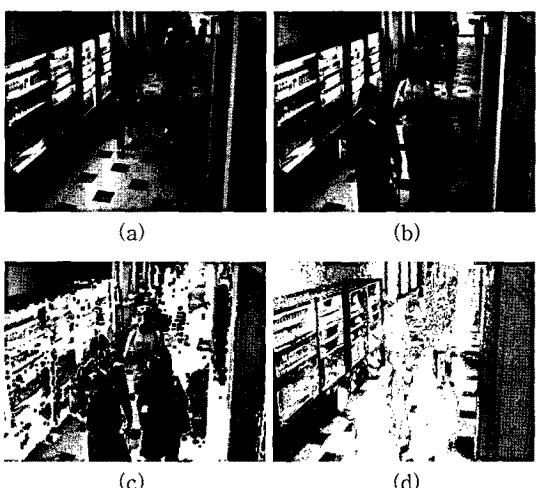


그림 4. 빠른 밝기 변화를 갖는 영상의 예. (a)와 (b)는 약 2초의 시간 차를 갖는 입력 영상, (c)는 혼합 Gaussian 배경 모델에 의한 배경 제거 결과, (d)는 두 입력 영상 사이의 밝기값 차이를 3단계로 구분하여 나타낸 영상.

영상의 빠른 밝기 변화에 대응하기 위하여 제안한 방법에서는 우선 연속한 두 프레임 사이의 밝기 변화를 선형 변환으로 추정하였으며, 얻어진 밝기 변환을 배경 모델에 적용하여 배경 모델이 직접적으로 영상의 밝기 변화에 대응하도록 하였다. 두 프레임 간의 밝기 변환을 올바르게 추정하기 위해서는 객체에 의해 값의 변화한 화소들은 제외하고 영상의 밝기 변화에 의해 값이 변화한 화소들만이 이용되어야 한다. 이를 위해 객체의 변화가 거의 발생하지 않는 영역에서 조정점(control points)들이 선택되었다. 조정점의 선택을 위하여 우선 초기 훈련 기간 동안에 연속한 프레임 사이의 밝기 변화가 임계값 이상인 화소들을 기록하여 화소 변화 빈도 지도(pixel change frequency map)을 생성하였다. 그림 5는 생성된 화소 변화 빈도 지도의 예를 보여준다. 그림 5(a)에서 밝은 값을 갖는 화소들은 어두운 값을 갖는 화소들에도로 발생했음을 의미한다. 그림 5(b)는 그림 5(a)를 이진화한 결과이며, 이진화된 결과 가운데 랜덤하게 선택된 C개의 조정점이 밝기 변환의 추정에 이용된다. 조정점은 배경의 변화가 거의 발생하지 않는 영역에서 선택되기 때문에, 최소자승법을 통하여 인접한 두 프레임 사이에서 조정점들의 밝기값 변화로부터 두 프레임 사이의 선형 밝기 변환을 쉽게 추정될 비해 훈련 기간 동안에 임계값의 변화가 더 높은 빈

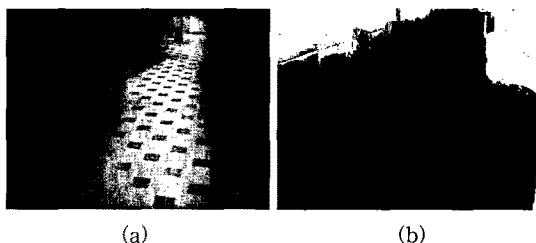


그림 5. 화소 변화 빈도 지도의 예. (a) 초기 훈련 기간에 발생한 임계치 이상의 밝기값 변화 횟수를 누적한 결과, (b) (a)를 이진화한 결과

수 있다.

이후 배경 모델의 개선에 앞서 추정된 밝기 변환에 따라 기존 배경 모델이 변환된다. 즉, 2장의 수식 (2)에 나타난 배경 모델 개선 과정이 다음의 수식 (8)에 나타난 것처럼 변경된다.

$$\Theta_{k,t}(x) = (1-\alpha)\Theta_{k,t-1}(x) + \alpha A(I_t(x), \Theta'_{k,t-1}(x)). \quad (8)$$

여기에서  $\Theta_{k,t}(x)$ 는 수식 (9)와 같이 기존 배경 모델  $\Theta_{k,t}(x)$ 를 추정된 선형 밝기 변환에 따라 보정하여 얻어진 배경 모델을 나타내며,  $a$ 와  $b$ 는 각각 프레임 간 밝기 변환의 매개변수이다.

$$\Theta'_{k,t}(x) = a\Theta_{k,t}(x) + b. \quad (9)$$

#### 4. 실험 및 결과

이 장에서는 제안한 방법의 성능을 검증하기 위한 실험 내용 및 결과를 제시한다. 제안한 방법의 검증을 위하여 고정 소수점 연산에 의한 속도 향상과 빠른 조명 변화 및 많은 통행량을 포함한 실제 환경의 영상에서의 배경 제거 정확도가 각각 측정되었다.

##### 4.1 고정 소수점 연산에 의한 속도 향상

고정 소수점형 변수를 이용한 연산에 의한 속도 향상을 측정하기 위하여 우선 임의로 생성된 데이터에 대하여 각각 부동 소수점형 변수와 고정 소수점형 변수를 이용하여 online K-means 알고리즘을 적용하여 군집화를 수행하였다[2]. 실험을 위하여 표 1에 나타난 것과 같이 각각 다른 평균과 분산을 갖는 4개의 Gaussian 분포에 대하여 전체 100,000개의 데이터 샘플이 생성되었다. 실험 결과 부동 소수점형 변수를 이용한 연산과 고정 소수점형 변수를 이용한 연산의 결과가 거의 동일한 것을 확인할 수 있다. 반면에 연산 시간은 표 2에 나타난 것과 같이 고정 소수

표 1. 부동 소수점 변수와 고정 소수점 변수를 이용한 군집화 결과

Gaussian Model	Synthetic Data			Floating Point			Fixed Point		
	$\omega$	$\mu$	$\sigma$	$\omega$	$\mu$	$\sigma$	$\omega$	$\mu$	$\sigma$
1	0.4	50	5.0	0.42	49.53	4.51	0.42	49.60	4.71
2	0.3	150	8.0	0.29	149.51	7.35	0.29	149.27	7.45
3	0.2	100	3.0	0.18	99.53	2.67	0.19	99.43	2.85
4	0.1	200	4.0	0.11	199.50	3.58	0.10	199.46	3.67

표 2. 군집화에 소요된 시간

	부동 소수점 연산	고정 소수점 연산
군집화에 걸린 시간	240.7ms (100%)	82.9ms (34.41%)

표 3. 부동 소수점 연산과 고정 소수점 연산을 이용한 배경 제거 속도 측정 결과

	부동 소수점 연산	고정 소수점 연산
2,000 프레임의 처리에 걸린 시간	250,313 ms	75,969 ms
프레임 당 연산 시간	125.16 ms (100%)	37.98 ms (30.35%)

점형 변수를 이용한 경우에 82.9ms, 부동 소수점형 변수를 이용한 경우 240.7ms가 소요되어 고정 소수점형 변수를 이용한 연산이 부동 소수점형 변수를 이용한 연산에 비해 약 34%만의 계산 시간만을 필요로 하였다.

또 2장에서 설명된 Stauffer등에 의해 제안된 혼합 Gaussian 배경 모델링 방법을 부동 소수점 변수와 고정 소수점 변수를 이용하여 구현하였으며, 각각의 방법에 대하여 동일한 2,000 프레임에 대한 연산 속도를 측정하였다. 다음 표 3은 그 속도 측정 결과를 보여준다. 실험 결과 고정 소수점 연산을 이용하여 구현한 방법이 부동 소수점 연산을 이용하여 구현한 방법의 약 30%만의 연산시간을 필요로 하였다.

#### 4.2 배경 제거 정확도 측정

제안한 방법의 배경 제거 정확도 측정을 위하여 직접 촬영된 두 개의 비디오 시퀀스를 이용하여 실험이 이루어졌다. 실험에 사용된 비디오 영상은 모두 빈번한 통행량이 발생되는 통로에서 촬영하였으며, 그림 6은 실험에 사용된 비디오의 예를 보여준다. 두 영상은 모두 Sony HDR-SR7 캠코더를 이용하여 획득하였으며, 320×240의 해상도에 30 fps로 인코딩되었다. 두 실험 영상 가운데 'Library' 영상은 영상 가운데 위치한 출입구로 지속적인 보행자의 이동이 발생하며, 'Corridor' 영상은 영상 내에서 통행량의 크기가 낮은 정도부터 매우 높은 정도까지 크게 변하는 특성이 있다. 또한 Corridor 영상에서는 촬영 장소의 좌측에 위치한 창의 영향과 큰 통행량 변화로 인한

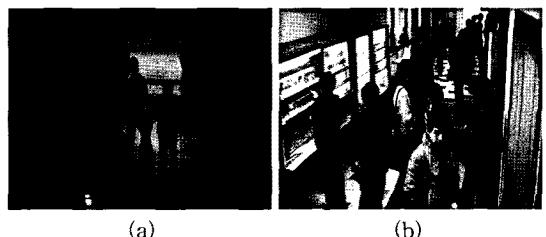


그림 6. 실험에 사용된 비디오 영상의 예. (a) Library, (b) Corridor

카메라의 자동 노출 조절로 인해 영상 내에서 빠른 밝기값 변화가 빈번히 발생한다.

제안한 방법의 정량적 성능 측정을 위하여 수작업으로 전경 영역을 분할하여 지상 검증(ground truth) 영상을 구성하였고, 영상 분할 결과를 지상 검증 영상과 비교하여 전경 분할의 검출률(DR, detection ratio)과 오검률(FAR, false alarm rate)을 측정하였다. 검출률과 오검률은 각각 수식 (10)과 (11)에 의해서 정의된다. 수식 (10)은 검출률을 나타내며 여기에서  $N_C$ 는 정확하게 검출된 전경 화소의 수를,  $N_{FN}$ 은 배경 화소로 잘못 분류된 전경 화소의 수를 나타낸다. 수식 (11)은 오검률을 나타내며 여기에서  $N_{FP}$ 는 전경으로 잘못 분류된 배경 화소의 수를 나타낸다.

$$DR = \frac{N_C}{N_C + N_{FN}} \quad (10)$$

$$FAR = \frac{N_{FP}}{N_C + N_{FP}} \quad (11)$$

제안한 방법의 성능 비교를 위해 Stauffer의 방법 [2], Tang의 방법[13], Lee의 방법[14]이 이용되었다. Stauffer의 방법은 제안한 배경 모델링 방법의 기반이 되는 혼합 Gaussian 모델 방법이며, Tang의 방법과 Lee의 방법은 제안한 방법과 마찬가지로 Stauffer의 방법에 기반한 배경 모델링 방법이다. 이 가운데 Tang의 방법은 Stauffer의 방법에 색상 채널마다 독립된 분산값을 이용함으로서 정확도를 높인 방법이며, Lee의 방법은 혼잡한 상황에서 전경 객체가 배경 모델로 생성되는 문제를 피하기 위해 프레임 수준 분석을 통해 학습 속도를 동적으로 조절하는 방법이다.

그림 7과 그림 9는 각각 두 실험 영상에 대한 배경 제거 결과의 예를 나타내며, 그림 7과 9의 각 행은 각각 (a) 원영상, (b) 지상 검증 영상, (c) Stauffer의 방법에 의한 결과, (d) Tang의 방법에 의한 결과, (e)

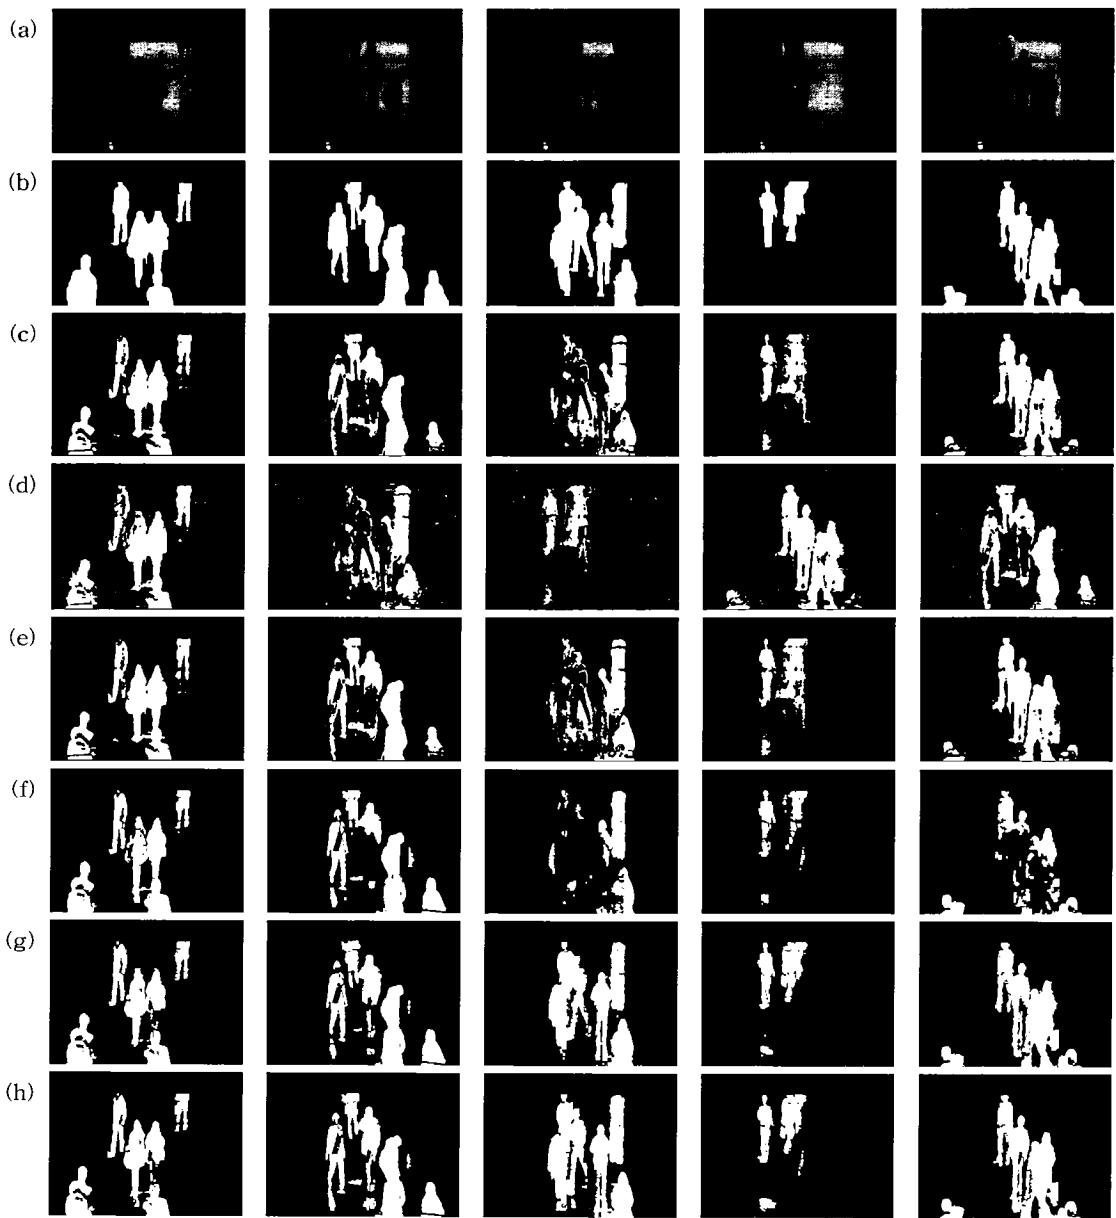


그림 7. 'Library' 영상에 대한 성능 측정 결과. (a) 입력영상, (b) 지상 검증 영상, (c) Stauffer의 방법, (d) Tang의 방법, (e) Lee의 방법, (f) 제안한 조명 변화 보정 방법을 적용한 결과, (g) 제안한 혼잡도에 따른 동적 학습속도 보정을 적용한 결과, (h) 조명 변화 보정과 동적 학습 속도 조절 모두를 적용한 결과

Lee의 방법에 의한 결과, (f) 가우시안 혼합 배경 모델에 제안한 빠른 조명 변화에 적응 방법을 적용한 결과, (g) 가우시안 혼합 배경 모델에 제안한 혼잡한 상황을 위한 동적 학습속도 조절 방법을 적용한 결과, (h) 가우시안 혼합 배경 모델에 빠른 조명 변화 적응 방법과 동적 학습 속도 조절 방법을 모두 적용

한 결과를 나타낸다. 그림 8과 그림 10은 성능 측정 결과를 그래프로 나타낸 것으로 그림 7과 9의 (c)에서 (h)의 방법들에 대하여 각각 검출률과 오검률을 측정 결과를 보여준다.

그림 7의 3번째 열에 나타난 것과 같이 기존의 방법들은 지속적인 보행자의 이동이 발생할 경우 배경

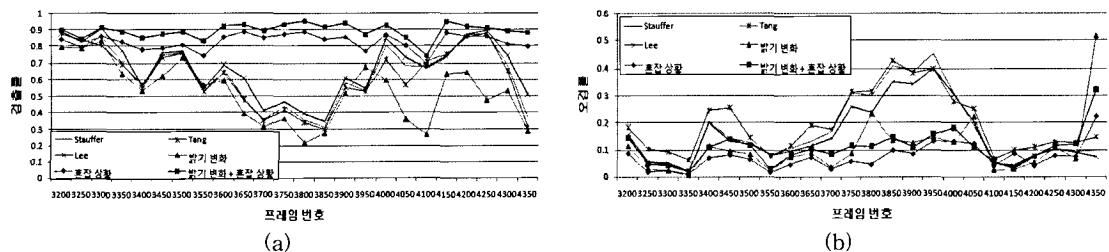


그림 8. 'Library' 영상에 대한 성능 측정 결과. (a) 검출률, (b) 오검률



그림 9. 'Corridor' 영상에 대한 성능 측정 결과. (a) 입력영상, (b) 지상 검증 영상, (c) Stauffer의 방법, (d) Tang의 방법, (e) Lee의 방법, (f) 제안한 조명 변화 보정 방법을 적용한 결과, (g) 제안한 흔잡도에 따른 동적 학습속도 보정을 적용한 결과, (h) 조명 변화 보정과 동적 학습 속도 조절 모두를 적용한 결과

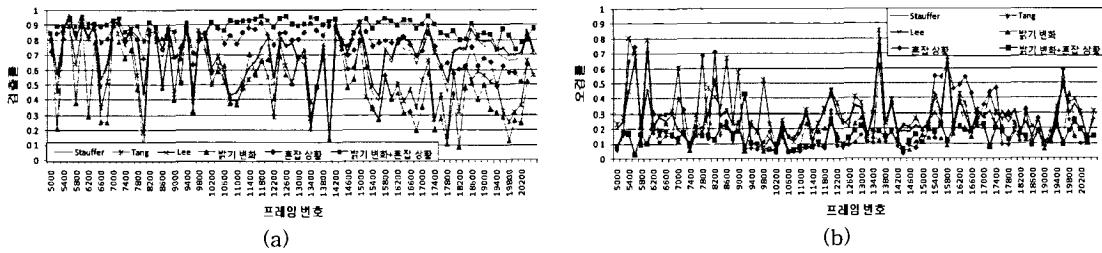


그림 10. 'Corridor' 영상에 대한 성능 측정 결과. (a) 검출률, (b) 오검률

제거를 제대로 수행할 수 없었는데, 이는 이동 객체가 배경보다 더 자주 발생하여 전경이 배경으로 잘못 훈련되었기 때문이다. 반면 제안한 동적 학습속도 조절 방법이 적용된 그림 7의 (g)와 (h) 행의 결과에서는 영상에서 지속적인 객체의 움직임이 발생했음에도 배경 제거가 올바르게 수행된 것을 볼 수 있다. 또 그림 9의 4, 5번째 열의 그림에서도 이와 유사한 결과를 볼 수 있는데 영상의 좌하단에 존재하는 거의 정지한 사람들이 기존의 방법들에 의해서는 시간이 지남에 따라 배경으로 분류되었지만, 그림 9의 (g)와 (h) 행의 결과에서는 동적 학습속도 조절에 의해서 거의 정지한 사람도 전경으로 계속 검출되는 것을 볼 수 있다. 영상에 전체적인 밝기 변화가 발생한 결과의 예는 그림 9의 3번째 열에서 찾아볼 수 있다. 영상 전체의 밝기 변화 발생 시 기존의 방법들에서는 배경 모델이 영상의 빠른 변화를 쫓아가지 못해 배경 영역 대부분이 전경으로 검출된 것을 볼 수 있다. 하지만, 학습된 배경 모델을 직접적으로 변환시키는 제안한 방법이 적용된 (f)와 (h) 행에서는 이러한 영상 내 빠른 밝기 변화에 영향을 거의 받지 않음을 알 수 있다.

정확도 측정 결과를 그래프로 나타낸 그림 8에서는 지속적인 통행량이 발생하는 3,500에서 4,100 프레임 사이의 구간에서 혼잡 상황을 고려한 동적 학습 속도 조절을 이용한 방법이 다른 방법보다 높은 검출률을 보이는 동시에 낮은 오검률을 보이는 것을 확인 할 수 있다. 'Corridor' 실험 영상에서는 빠른 조명 변화가 자주 발생하기 때문에 그림 10에 나타난 기존의 방법들의 그래프에서는 성능이 급격히 변화하는 모습을 쉽게 관찰할 수 있다. 하지만, 제안한 밝기 변화에 대응하는 방법을 적용한 결과의 그래프에서는 급격히 성능이 저하되는 현상 없이 전체적으로 비교적 고른 성능을 보이는 것을 확인할 수 있다.

표 4는 두 실험 영상에 대한 성능 측정 결과의 평균치를 보여준다. 성능 측정 결과 제안한 방법이 기존의 방법과 비교하여 검출률을 약 20% 가량 향상시키면서 5~15% 정도 낮은 오검률을 보이는 것을 확인할 수 있었다. Stauffer의 방법과 Tang의 방법은 혼잡한 상황이나 빠른 조명 변화가 발생하는 상황을 고려하지 않고 있으므로 통행량이 많고 조명 변화가 자주 발생하는 본 논문의 실험 영상에서 비교적 낮은 성능을 나타내었다. 특히 Tang의 방법은 빠른 조명 변화가 자주 발생하는 상황에서 Stauffer의 방법보다도 낮은 성능을 보였는데, 이는 Tang의 방법에서는 분산 값이 색상 채널별로 다르게 계산되기 때문에 조명 변화 발생 시 색상의 변화가 크게 발생하기 때문인 것으로 해석된다. Lee의 방법은 혼잡 환경에 대응하기 위하여 학습속도를 동적으로 조절하는 방법이며, 따라서 Stauffer의 방법이나 Tang의 방법에 비해 더 검출률 면에서 더 나은 성능을 보였다. 하지만, Lee의 방법은 배경 모델의 학습속도 조절을 위해 객체의 크기를 이용하는 제안한 방법과 달리 학습속도의 조절이 전체 프레임 단위로 이루어지기 때문에, 제안한 방법에 비하여 혼잡한 환경에 대해 다소 낮은 성능을 보이는 것을 확인할 수 있었다.

표 4. 실험 영상에 대한 평균 검출률과 오검률

	Library		Corridor	
	검출률	오검률	검출률	오검률
Stauffer의 방법	63.67%	17.04%	56.23%	16.55%
Tang의 방법	61.83%	19.61%	56.57%	31.06%
Lee의 방법	67.13%	15.52%	72.23%	26.67%
밝기 변화 적용	52.79%	10.78%	51.35%	16.36%
혼잡 환경 적용	82.70%	7.26%	77.91%	23.58%
밝기 변화 + 혼잡 환경	89.35%	10.74%	88.09%	15.24%

## 5. 결 론

본 논문에서는 배경 제거 방법들을 실제 환경에 적용할 때 흔히 만나게 되는 문제점인 (1) 낮은 연산량에 대한 요구, (2) 많은 통행량에 대한 대응, (3) 영상의 빠른 밝기 변화에 대한 적응을 해결하기 위하여 기존의 가우시안 혼합 모델에 기반한 배경 제거 방법을 개선하는 방법을 제안하였다. 제안한 방법에서는 배경 모델링 방법이 부동 소수점 변수에 의해 제공되는 것에 비해 상대적으로 낮은 정밀도를 요구한다는 관찰에 기반하여 정수형 변수를 이용한 고정 소수점 연산을 이용하여 계산 속도를 향상시켰다. 또한 혼잡한 환경에서 전경 객체가 배경으로 잘못 분류되는 문제를 피하기 위해 화소값의 단시간 통계량을 이용하여 배경 모델의 학습 속도를 동적으로 조절하였다. 마지막으로 영상의 빠른 밝기값 변화에 대응하기 위하여 연속된 입력 영상 사이의 밝기 변화를 선형 변화으로 추정하였으며, 얻어진 밝기값 변화율을 통해 배경 모델을 직접 변화시킴으로서 영상에서 발생되는 빠른 밝기값 변화에 대응하였다.

제안한 방법의 검증을 위하여 혼잡한 상황에서 얻어진 영상을 이용하여 실험을 진행하였으며, 실험 결과 제안한 방법이 기존의 배경 모델링 방법들과 비교하여 약 20% 가량 검출률을 향상시키면서 5~15% 정도 낮은 오검률을 얻을 수 있었으며, 효과적으로 배경 제거를 수행할 수 있음을 확인하였다. 또한 고정 소수점 연산으로 구현된 가우시안 혼합 배경 모델은 부동 소수점 연산을 이용한 구현에 비하여 약 30%의 연산시간만을 필요로 하여, 제안한 방법에 의해 연산 속도가 크게 향상될 수 있음을 확인하였다. 제안한 방법이 다양한 영상 감시 응용을 실제 환경에 적용하는 데 많은 도움이 될 것으로 기대되며, 이러한 응용의 개발이 향후 연구로서 진행될 예정이다.

## 참 고 문 헌

- [1] I. Haritaoglu, D. Harwood, L. Davis, I. Center, and C. San Jose, "W 4: real-time surveillance of people and their activities," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.22, pp. 809-830, 2000.
- [2] C. Stauffer and W. Grimson, "Adaptive background mixture models for real-time tracking," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Vol.2, pp. 246-252, 1999.
- [3] P. KaewTraKulPong and R. Bowden, "An improved adaptive background mixture model for real-time tracking with shadow detection," *European Workshop on Advanced Video Based Surveillance Systems*, Vol.5308, 2001.
- [4] M. Mason and Z. Duric, "Using histograms to detect and track objects in color video," *Applied Imagery Pattern Recognition Workshop*, pp. 154-159, 2001.
- [5] M. Heikkila and M. Pietikainen, "A texture-based method for modeling the background and detecting moving objects," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.28, pp. 657-662, 2006.
- [6] M. Harville, G. Gordon, and J. Woodfill, "Foreground segmentation using adaptive mixture models in color and depth," *IEEE Workshop on Detection and Recognition of Events in Video*, pp. 3-11, 2001.
- [7] Q. Zhu, S. Avidan, and K. Cheng, "Learning a sparse, corner-based representation for time-varying background modelling," *IEEE International Conference on Computer Vision*, Vol.1, pp. 678-685, 2005.
- [8] K. Brumitt and B. Meyers, "Wallflower: Principles and practice of background maintenance," *International Conference on Computer Vision*, pp. 255-261, 1999.
- [9] P. Kumar, S. Ranganath, and W. Huang, "Queue based fast background modelling and fast hysteresis thresholding for better foreground segmentation," *the Fourth International Conference on Information, Communications and Signal Processing*, Vol.2, pp. 743-747, 2003.
- [10] S. Apewokin, B. Valentine, L. Wills, S. Wills, and A. Gentile, "Multimodal Mean Adaptive Backgrounding for Embedded Real-Time

Video Surveillance," IEEE Conference on Computer Vision and Pattern Recognition, pp. 1-6, 2007

- [11] 가기환, 이광국, 윤자영, 김재준, 김희율, "군중 밀도 측정을 위한 자동 특징량 정규화 방법," 대한 전자공학회 추계학술대회 논문집, pp. 669-670, 2007.
- [12] P. Viola and M. Jones, "Rapid Object Detection using a Boosted Cascade of Simple Features," IEEE Conference on Computer Vision and Pattern Recognition, pp. 8-14, 2001.
- [13] Z. Tang and Z. Miao, "Fast Background Subtraction and Shadow Elimination Using Improved Gaussian Mixture Model," IEEE International Workshop on Haptic Audio Visual Environments and their Applications, pp. 38-41, 2007.
- [14] G.-G. Lee, S. Song, J.-Y. Yoon, J.-J. Kim, and W.-Y. Kim, "Adaptive Learning of Background Model for Crowd Scenes," International Conference on Multimedia, Information Technology and its Application, pp. 77-80, 2008.



이 광 국

- 2002년 한양대학교 전자전기공학부 학사
- 2004년 한양대학교 전자통신전파공학과 석사
- 2004년~현재 한양대학교 전자컴퓨터통신공학과 박사과정

관심분야 : 영상 감시, 패턴 인식, 내용기반 멀티미디어 분석



김 재 준

- 1983년 한양대학교 건축공학과 학사
  - 1985년 Univ. of Illinois at Urbana-Champaign 건설관리 석사
  - 1992년 Univ. of Illinois at Urbana-Champaign 건설경영/관리 박사
  - 1993년~현재 한양대학교 건축공학부 교수
- 관심분야 : Building Information Modeling(BIM), 시스템경영, 건설자동화



김 희 율

- 1980년 한양대학교 전자공학과 졸업 (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