

적응적 파라미터 추정을 통한 향상된 블록 기반 배경 모델링

김한준*, 이영현**, 송태엽*, 구분화***, 고한석***

Improved Block-based Background Modeling Using Adaptive Parameter Estimation

Hanj-Jun Kim*, Young-Hyun Lee**, Tae-Yup Song*, Bon-Hwa Ku***, Han-Seok Ko***

요약

본 논문에서는 모델 히스토그램 개수를 적응적으로 조절하는 블록기반의 배경 모델링 방법을 제안한다. 기존의 블록 기반의 배경 모델링 방법은 각 블록에 대한 모델 히스토그램의 개수를 고정한다. 따라서 조명변화와 움직이는 객체에 대해 오검출이 발생하는 문제가 있고 움직이지 않는 객체에 대해서는 검출이 되지 않는 문제가 있다. 또한 입력영상의 종류마다 달라질 수 있는 최적의 모델 히스토그램의 개수를 수동적으로 찾아야 하는 문제가 있다. 본 논문에서는 실험을 통해 엘리베이터 내에서 조명변화가 있고 객체가 움직이는 상황과 조명변화가 없고 객체가 정지해 있는 상황에 대해 기존의 방법과 성능을 비교하여 제안한 알고리즘의 효용성을 입증한다.

▶ 키워드 : 블록-기반, 배경 분리, 적응적

Abstract

In this paper, an improved block-based background modeling technique using adaptive parameter estimation that judiciously adjusts the number of model histograms at each frame sequence is proposed. The conventional block-based background modeling method has a fixed number of background model histograms, resulting to false negatives when the image sequence has either rapid illumination changes or swiftly moving objects, and to false positives with motionless objects. In addition, the number of optimal model histogram that changes each type of input image must have found manually. We demonstrate the proposed method is promising through representative performance evaluations including the background modeling in an elevator environment that may have situations with rapid illumination changes, moving objects, and motionless objects.

▶ Keyword : Block-based, Background Subtraction, Adaptive

• 제1저자 : 김한준 • 교신저자 : 고한석

• 투고일 : 2011-01-01, 심사일 : 2011-01-20, 게재확정일 : 2011-01-26

* 고려대학교 바이오마이크로시스템공학과(Dept. of Biomicrosystem Engineering)

** 고려대학교 영상정보처리학과(Dept. of Visual Information Processing)

*** 고려대학교 전기전자전파공학부(School of Electrical Engineering)

※ This research work was supported by the STW-KU Research Center Program.

I. 서론

대부분의 지능적 보안 및 감시 시스템은 감시카메라를 이용하여 영상 처리 기술과 운영자의 상황 판단에 의존하여 운영하고 있다. 배경 분리(Background Subtraction) 기법은 입력 영상으로부터 배경을 모델링해서 객체영역을 찾아내는 방법으로 모든 지능적 보안 및 감시 시스템의 영상 처리 기술에서 가장 첫 번째로 이뤄져야 하는 기법이다. 배경 분리는 현재의 입력 프레임과 모델링된 배경과의 차 영상을 이용하는 방법이 주로 사용되고[1,2,3,4,5,6] 좋은 성능을 내기 위해서는 배경의 모델링이 중요하다. 배경을 모델링하는 방법에는 크게 픽셀 기반 방법(Pixel-based Background modeling)[1,2,3]과 블록기반 방법(Block-based Background modeling)[4,5,6]이 있다. 픽셀기반 배경 모델링 방법은 입력 영상의 각 픽셀마다 배경을 모델링 하는 것으로 움직이는 구름이나 흔들리는 잎 등으로 인한 장기간 조명변화(Long-term illumination change)에 강인한 특성이 있다. 블록기반 배경 모델링 방법은 입력 영상을 블록으로 나누어 블록마다 배경을 모델링 하는 방법으로 날씨 변화 등 점진적으로 픽셀 값이 변하는 단기간 조명변화(Short-term illumination change)에 강인한 특성이 있다.[6] Grimson[1]은 픽셀기반 배경 모델링 방법으로 일정시간 동안 각 픽셀 값의 확률 분포를 고정된 개수의 가우시안 분포로 모델링하는 GMM(Gaussian mixture model)방법을 적용하였다. Zivkovic[2]은 물체의 빠른 움직임에 대해 기민하게 적응하지 못하는 Grimson 방법의 문제점을 해결하기 위해 GMM의 가우시안 분포수를 적응적으로 조절하는 방법을 제안하였다. 블록기반 배경 모델링 방법은 입력 영상의 각 블록에 대해 텍스처(Texture) 특징 값에 대한 히스토그램을 생성하고 일정시간동안 얻은 정보를 통해 고정된 개수의 가중 히스토그램(weighted histograms)의 조합으로 배경을 모델링 한다. 블록기반 배경 모델링 방법은 각 블록의 텍스처 특징을 사용하기 때문에 각 픽셀의 화소 값만을 이용하는 픽셀기반 배경 모델링 방법보다 전체적 조명변화에 강인한 장점이 있다. 그러나 기존의 블록기반 배경 모델링 방법은 각 블록에 대한 모델 히스토그램 개수를 고정하였기 때문에 조명 변화와 움직이는 객체에 대해 오검출이 발생하고 움직임이 없는 객체에 대해서는 검출하지 못하는 문제가 있다. 또한 입력 영상의 종류마다 달라질 수 있는 최적의 모델 히스토그램의 개수를 수동적으로 찾아야 하는 문제가 있다.

본 논문에서는 기존의 블록 기반 배경 모델링 방법의 모델 히스토그램의 개수를 각 블록마다 적응적으로 조절하는 방법

을 제안한다. 실험을 통해 엘리베이터 내에서 조명변화가 있고 객체가 움직이는 상황과 조명변화가 없고 객체가 가만히 있는 상황에 대해 기존의 방법과 성능을 비교하여 제안된 알고리즘의 효용성을 입증한다.

본 논문의 나머지 부분은 다음과 같이 구성된다. 2장에서 기존의 블록기반 배경 모델링 방법에 대하여 소개하고 기존의 블록기반 배경 모델링 방법의 문제점을 언급한다. 3장에서는 본 논문에서 제안하는 각 블록마다 배경 모델 히스토그램의 개수를 적응적으로 조절하는 방법에 대하여 소개하고, 엘리베이터 환경 내에서 실험과 성능평가가 4장에서 이루어지며, 마지막으로 5장에서 결론을 맺는다.

II. 블록기반 배경 모델링

기존의 블록기반 배경 모델링을 이용한 배경 분리 방법의 개요는 다음과 같다. 하나의 이미지를 여러 개의 블록으로 나누고 각 블록에 대해 텍스처 특징 값에 대한 히스토그램을 생성한다. 그리고 시간에 따른 각 블록의 히스토리를 일정 수의 가중된 히스토그램의 조합으로 배경을 모델링을 한 후, 각 블록마다 현재 입력 영상의 히스토그램과 배경으로 모델링된 히스토그램과의 유사성을 파악하여 전경과 배경을 분리하게 된다.[4]

이후에 설명되는 각 단계는 각 블록별로 처리되는 블록 프로세스(Block Process)가 이루어진다.

1. LBP(Local Binary Pattern) 히스토그램 생성

LBP는 하나의 코드로 픽셀 주변의 텍스처를 표현하는 방법이며 가운데 픽셀과 주변의 픽셀들의 값을 비교하여 코드화한다.[7] 일반적으로 3*3 커널을 많이 사용하며 LBP 코드를 구하는 방법은 다음과 같다.

$$LBP(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \dots\dots\dots (1)$$

g_c 는 가운데 픽셀 좌표인 (x_c, y_c) 의 그레이 값(gray value)이고, g_p 는 가운데 픽셀 주위 P개의 이웃 픽셀의 그레이 값이다. 함수 $s(x)$ 는 다음과 같이 정의된다.

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \dots\dots\dots (2)$$

블록내의 각 픽셀들이 가지는 LBP 코드를 위의 방법으로

구한 후 히스토그램을 생성한다. 따라서 하나의 이미지의 블록의 개수만큼 히스토그램이 생성이 되며 각 블록마다 계산된 LBP 코드의 히스토그램은 해당 블록의 텍스처를 표현한다.

2. 블록기반 배경 모델링 방법

2.1 모델 히스토그램 생성

앞 절에서 구한 시간 t 에서의 블록 히스토그램을 \vec{x}_t 라고 하면 블록의 히스토리는 $\{\vec{x}_1, \dots, \vec{x}_t\}$ 와 같이 표현할 수 있다. 이러한 블록의 히스토리를 M 개의 가중된(weighted) LBP 히스토그램으로 모델링을 한다. 시간 t 에서의 m 번째의 가중치를 $w_{k,t}$ 로 표현하면 모델링된 M 개의 가중된 LBP 히스토그램은 다음 그림과 같다.




그림 1. 각 블록의 히스토리를 M 개의 가중된 LBP 히스토그램으로 모델링
 Fig. 1. The history of each block is modeled by a group of M weighted LBP histograms

2.2 히스토그램 비교

현재 프레임에서 입력된 새로운 블록 히스토그램 \vec{x}_t 와 기존에 생성되어있는 M 개의 모델 히스토그램과 유사(match)한지를 판단하기 위해 비교를 한다. 히스토그램 간에 비교를 위해서는 두 히스토그램간의 거리측정(distance measure)를 이용해야 하는데 그 방법으로 히스토그램 인터섹션(intersection)을 이용한다. 두 개의 정규화 된 히스토그램 \vec{x}_1 과 \vec{x}_2 의 히스토그램 인터섹션 방법은 다음과 같다.

$$H(\vec{x}_1, \vec{x}_2) = \sum_i \min(x_{1,i}, x_{2,i}) \dots\dots\dots (3)$$

i 는 히스토그램의 빈 인덱스(bin index)를 말한다. 위의 $H(\vec{x}_1, \vec{x}_2)$ 값에 대하여 역치(threshold) 값 T_D 를 설정하여 두 히스토그램의 유사도를 판단한다.

2.3 모델 히스토그램 업데이트

M 개의 모델 히스토그램 중에서 새로운 히스토그램 \vec{x}_t 와 유사한 모델 히스토그램이 있는 경우 그 모델 히스토그램을 업데이트하며 모델 히스토그램 중 \vec{x}_t 와 유사하지 않은 모델 히스토그램은 업데이트를 하지 않는다. 이를 다음과 같은 수식으로 정리할 수 있다.

$$\vec{x}_{m,t} = \vec{x}_{m,t-1}[i] + o_m^{(t)} \alpha_b (\vec{x}_t[i] - \vec{x}_{m,t-1}[i]) \dots\dots\dots (4)$$

$o_m^{(t)}$ 는 유사한 히스토그램에 대해서는 1, 유사하지 않은 히스토그램에 대해서는 0을 갖는 함수이며 α_b 는 사용자 정의 학습률(user-defined learning rate)로 0과 1 사이의 상수이다.

만약 새로운 히스토그램 \vec{x}_t 이 모든 모델 히스토그램과 유사하지 않는 경우에는 \vec{x}_t 를 새로운 모델 히스토그램으로 추가하거나 모델 히스토그램 개수 M 을 초과할 경우에는 모델 히스토그램들 중에 가장 낮은 가중치를 갖는 것을 \vec{x}_t 로 교체한다. 교체된 히스토그램에 대해서는 낮은 초기치의 가중치를 할당한다.

2.4 모델 가중치 업데이트

모델의 가중치는 다음 식과 같이 새로운 히스토그램 \vec{x}_t 와 유사한 모델 히스토그램의 가중치는 증가하고 유사하지 않은 모델 히스토그램의 가중치는 감소한다.

$$w_{m,t} = (1 - \alpha_w)w_{m,t-1} + \alpha_w o_m^{(t)} \dots\dots\dots (5)$$

α_w 는 사용자 정의 학습률로 0과 1 사이의 상수이다.

모델 가중치 업데이트 후에는 반드시 m 개의 가중치들의 합이 1이 되도록 정규화(normalization)해야 한다.

2.5 배경 모델 결정

M 개의 모델 히스토그램 중에 배경에 해당되는 모델을 선택해야 한다. 가중치 업데이트 과정을 통해 배경으로 추정되는 모델은 가중치가 커지므로 가중치가 큰 모델은 배경 모델에 확률적으로 가장 근접하다. 따라서 가중치의 크기에 따라 M 개의 모델을 내림차순으로 정렬하고 다음 식을 만족하는 처음 B 개의 히스토그램을 배경 모델로 선택한다.

$$w_{1,t} + \dots + w_{B,t} > T_B \quad T_B \in [0, 1] \dots\dots\dots (6)$$

T_B 는 사용자 정의 역치 값이다.

3. 객체 검출

새로운 히스토그램 x_t 와 B개의 배경 히스토그램을 비교하여 B개의 배경 히스토그램 중에 유사한 히스토그램이 있는 경우에는 해당 블록을 배경으로 결정하고 유사한 히스토그램이 없는 경우에는 객체로 최종 결정한다.

4. 기존 블록기반 배경 모델링의 문제점

기존의 블록기반 배경 모델링 방법은 모든 블록의 모델 히스토그램의 개수를 M으로 고정된 사용자 정의 값을 사용함으로써 다음과 같은 문제가 발생한다.

입력영상의 한 부분이 비슷한 값이 지속적으로 들어오면, M개의 모델 히스토그램 중에 하나의 히스토그램만 필요하고 나머지 M-1개의 모델 히스토그램은 불필요하다. 따라서 모델 히스토그램의 개수가 필요 이상으로 크게 되어 전경으로 구분되어야 할 객체가 나머지 M-1개의 모델 히스토그램에 포함된다. 그 결과 객체가 배경으로 적용되어 미검출(False Negative) 비율이 증가한다.

반대로 입력영상의 한 부분이 움직이는 객체로 인해 자주 변화하면, 미리 정의된 모델 히스토그램의 개수 M이 배경 모델을 추정하는데 충분치 않다. 따라서 M이 너무 작으면 배경을 전경으로 오검출(False Positive)하게 된다.

즉 필요이상으로 많은 모델 히스토그램의 개수는 오버피팅(over-fitting)을 유발하고, 반대로 너무 적은 모델 히스토그램의 개수는 언더피팅(under-fitting)을 유발하여 미검출과 오검출을 증가시킨다.[8] 이러한 예를 그림 2에서 볼 수 있다.




그림 2 (a)원본 영상, (b)언더피팅의 예(M=2), (c)오버피팅의 예(M=10)
 Fig. 2 (a)Original image, (b)Example of under-fitting(M=2), (c)Example of over-fitting(M=10)

따라서 위와 같이 모델 히스토그램 개수의 부적절함으로 인하여 생기는 문제를 해결하기 위해 고정된 모델 히스토그램 개수가 아닌 각 블록마다 서로 다른 모델 히스토그램 개수를 적응적으로 추정할 필요가 있다.

III. 모델 히스토그램 개수 추정

1. 가중치 추정

가중치 w_m 은 m번째 모델 히스토그램에 속하는 데이터의 비율을 나타내는 것으로 하나의 샘플 데이터가 m번째 모델 히스토그램에서 나올 확률로 고려할 수 있다. 이는 M개의 w_m 가 다항 분포(multinomial distribution)를 정의할 수 있음을 의미한다.

t개의 데이터 샘플을 가지고 있고 각각의 샘플들은 하나 이상의 모델 히스토그램과 유사하다고 가정하면 m번째 히스토그램에 속한 샘플의 수는 다음 식과 같다.

$$n_m = \sum_{i=1}^t o_m^{(i)} \quad 0 < n_m < t \dots\dots\dots (7)$$

n_m 이 주어졌을 때, 다항 분포로부터 가중치의 우도함수(Likelihood function)를 정의할 수 있다.

$$L = \prod_{m=1}^M w_m^{n_m} \dots\dots\dots (8)$$

가중치의 총 합이 1이라는 제한조건에 의해 라그랑지 승수(Lagrange multiplier) λ 를 이용하여 최대우도법(Maximum Likelihood Estimation)을 하면 다음 식과 같다.

$$\frac{\partial}{\partial w_m} \left(\log L + \lambda \left(\sum_{m=1}^M \hat{w}_m - 1 \right) \right) = 0 \dots\dots\dots (9)$$

(9)식을 풀면 (10)식을 얻을 수 있다.

$$\sum_{m=1}^M \sum_{i=1}^t o_m^{(i)} - \frac{n_m}{\hat{w}_{m,t}} = 0 \dots\dots\dots (10)$$

여기서 $\sum_{m=1}^M o_m^{(i)}$ 의 의미는 어떤 i번째 시점에서 입력된 샘플 데이터가 M개의 모델 히스토그램들과 비교했을 때 유사

한 모델 히스토그램의 개수로 각각의 샘플들은 하나 이상의 모델 히스토그램과 유사하다는 앞선 가정에 의해 다음 식과 같이 정리된다.

$$\sum_{m=1}^M o_m^{(i)} = 1 + e \quad e \leq M-1 \dots\dots\dots (11)$$

따라서 (10)식에 (11)의 결과를 대입하여 풀면 (12)의 가중치 추정 식을 얻을 수 있다.

$$\widehat{w}_{m,t} = \frac{1}{t(1+e)} \sum_{i=1}^t o_m^{(i)} \dots\dots\dots (12)$$

이를 재귀적인 수식으로 바꾸면 다음 식과 같다.

$$\widehat{w}_{m,t} = \widehat{w}_{m,t-1} + \frac{1}{t(1+e)} (o_m^{(t)} - \widehat{w}_{m,t-1}) \dots\dots\dots (13)$$

2. 모델 히스토그램 개수의 적응적 조절

2.1 모델 히스토그램 개수의 선택 기준

(8)식에서 정의된 우도함수를 최대로 하는 모델 히스토그램의 개수 M을 찾아야 한다. 하지만 M이 커질수록 항상 우도함수의 값이 증가하게 된다. 따라서 $P(M)$ 이란 패널티 항을 적용하여 다음과 같이 모델 히스토그램 개수의 선택 기준(Criterion)을 만든다.[8,9]

$$J(M) = \log L(M) - P(M) \dots\dots\dots (14)$$

여기서 $P(M)$ 는 증가함수이므로 복잡한 모델(M이 큰 모델)에 대해 높은 패널티를 주는 함수이다.

2.2 모델 히스토그램 개수 추정

(14)식에서 패널티 항 $P(M)$ 대신 다항분포의 공액 사전 확률 분포(conjugate prior)인 디리클레 사전정보(Dirichlet prior)를 적용하면 다음과 같다.[8,9]

$$J(M) = \log L + \log P \dots\dots\dots (15)$$

$$P = \prod_{m=1}^M w_m^{c_m} \quad : \text{Dirichlet prior} \dots\dots\dots (16)$$

식 (16)의 디리클레 사전정보는 최적의 확률모델을 찾기 위해 적용되는 모델 선택 기준에서 복잡한 모델에 대해서는

높은 패널티를 가하는 패널티 함수의 특성을 가지면서 최적의 구조적 모델에 대한 편중 정도(bias)를 나타낸다.[3] 따라서 이러한 특성을 반영하여 가중치를 추정하면 동시에 모델 히스토그램의 개수를 적응적으로 조절할 수 있다.

또한 가중치의 추정 과정에서 디리클레 사전정보의 계수 c_m 은 m번째 모델 히스토그램의 사전 증거(prior evidence)로 (15)식에서 패널티 항으로서 역할을 하기 위해 음수인 $-c$ 값을 적용한다. 이는 m번째 모델 히스토그램의 존재에 대해 충분한 증거가 있는 경우에만 m번째 모델 히스토그램을 인정하는 것을 의미하는 것으로 가중치 추정과정에서 추정된 값이 음수가 되면 m번째 모델 히스토그램은 무의미하게 되어 제거가 가능하다.

적합한 모델 히스토그램의 개수 M을 선택하는 과정을 정리해보면 먼저 M을 크게 초기화하고 디리클레 사전정보를 적용한 선택기준을 최대로 하는 M을 최대사후법(Maximum A Posteriori estimation)을 통해서 구한다. 이때 디리클레 사전정보는 필요 없는 히스토그램을 없애는 역할을 하여 최종적으로 최적의 모델 히스토그램 개수 M을 구할 수 있다.

최대사후법을 이용하여 식 (15)의 선택기준을 최대화 시키는 M을 찾는 과정은 다음 식과 같다.

$$\frac{\partial}{\partial \widehat{w}_m} \left(\log L + \log P + \lambda \left(\sum_{m=1}^M \widehat{w}_m - 1 \right) \right) = 0 \dots\dots\dots (17)$$

$$\text{where} \quad P = \prod_{m=1}^M w_m^{-c} \dots\dots\dots (18)$$

(11)을 이용하여 (17)식을 풀면 (19)식을 얻을 수 있다.

$$\widehat{w}_{m,t} = \frac{\frac{1}{t(1+e)} \sum_{i=1}^t o_m^{(i)} - \frac{c}{t(1+e)}}{1 - M \frac{c}{t(1+e)}} \dots\dots\dots (19)$$

$\frac{c}{t(1+e)}$ 는 바이어스(bias) 항으로서 t가 커지면 바이어스가 줄어든다. 만약 바이어스가 작은 경우 $c_T = \frac{c}{T(1+e)}$ (T는 큰 값)로 고정 가능하여 다음 식으로 간단히 정리된다.

$$\widehat{w}_{m,t} = \frac{\frac{1}{t(1+e)} \sum_{i=1}^t o_m^{(i)} - c_T}{1 - M c_T} \dots\dots\dots (20)$$

이를 재귀적인 수식으로 바꾸면 다음과 같다.

$$\widehat{w}_{m,t} = \widehat{w}_{m,t-1} + \frac{1}{t(1+e)} \left(\frac{o_m^{(t)}}{1-Mc_T} - \widehat{w}_{m,t-1} \right) - \frac{1}{t(1+e)} \frac{c_T}{1-Mc_T} \dots\dots\dots (21)$$

(21)식을 좀 더 간략하게 나타내기 위해 다음과 같은 가정을 한다. 보통 모델 히스토그램의 개수 M이 작고 c_T 가 작기 때문에 $1 - Mc_T \approx 1$ 이며, 새로운 샘플에 의한 영향을 고정시키기 위해 $\frac{1}{t(1+e)}$ 를 고정된 상수 α 로 치환한다. 따라서 간략화 된 재귀적인 수식을 다음 식과 같이 구할 수 있다.

$$\widehat{w}_{m,t} = \widehat{w}_{m,t-1} + \alpha(o_m^{(t)} - \widehat{w}_{m,t-1}) - \alpha c_T \dots\dots\dots (22)$$

식(5)를 식(22)로 변경하여 추정된 가중치의 값이 음수가 되면 대응하는 모델 히스토그램은 의미가 없으므로 제거하면 최적의 모델 히스토그램의 개수 M을 유지하게 된다.

IV. 실험

1. 데이터베이스(DB)

엘리베이터 환경은 문이 열리고 닫힐 때 조명 변화가 심한 특성이 있고 객체의 이동과 정지 상황이 반복적으로 발생한다. 본 논문에서는 실험을 위해 엘리베이터 왼쪽 상단 구석에 CCTV 카메라를 설치하고 일정시간 동안 영상을 취득하여 데이터베이스를 구축하였다. 다양한 상황에 대해 제안하는 배경 분리 알고리즘의 성능 평가를 위해서 취득한 영상을 조명 변화가 있고 객체가 이동하는 상황과 조명변화가 없고 객체가 정지해 있는 상황으로 분류하였다. 본 논문에서 실험에 사용한 영상의 해상도는 320*240 이며 DB1, DB2, DB3 세 가지의 영상을 사용하였다. 각각 영상의 순서는 그림 3과 같이 사람이 들어온 후 엘리베이터가 이동하고 도착한 후 사람이 밖으로 나가는 순서로 구성된다.

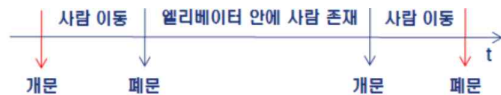


그림 3. 영상의 순서
Fig. 3. A Sequence of the image

2. 성능 평가 방법

엘리베이터 안의 두 가지 상황에 대해서 본 논문에서 제안한 알고리즘과 기존의 블록기반 배경모델링 방법[4]을 비교하였다. 첫 번째 상황은 조명변화와 사람의 움직임이 발생하는 경우이다. 두 번째 상황은 조명변화가 없고 사람이 가만히 움직이지 않는 경우이다.

성능평가 방법은 다음과 같다. 총 3개의 데이터베이스(DB1:305프레임, DB2:335프레임, DB3:233프레임)에 대해 수작업으로 원본 이미지에서 객체라고 판단되는 영역을 1로, 배경이라고 판단되는 영역을 0으로 레이블링(labeling)하였다. 수작업을 통해 레이블링 된 영상(Ground Truth)과 알고리즘을 통해 얻은 결과의 모폴로지(morphology) 영상을 픽셀별로 비교하여 성능을 분석하였다. 입력 영상의 각 프레임마다 TP(True Positive), TN(True Negative), FP(False Positive), FN(False Negative)를 구한 뒤, 식(23)-(24)과 같이 정의된 지표를 사용하여 최종 성능을 평가하였다.[1]

$$Precision(\%) = \frac{TP}{TP+FP} \times 100 \dots\dots\dots (23)$$

$$Recall(\%) = \frac{TP}{TP+FN} \times 100 \dots\dots\dots (24)$$

3. 실험 결과

DB1, DB2, DB3 중에 조명변화와 사람의 움직임이 발생하는 상황은 그림 4, 그림 5, 그림 6과 같은 결과를 가진다.




그림 4. DB1 상황: 조명변화와 객체 이동 (a)원본영상, (b)수작업을 통해 얻은 영상, (c)기존 방법, (d)제안한 방법
Fig. 4. DB1 Situation1: Illumination change and moving object (a)Original image, (b)Ground Truth, (c)Conventional method, (d)Proposed method




그림 5. DB2 상황1: 조명변화와 객체 이동 (a)원본영상, (b)수작업을 통해 얻은 영상, (c)기존 방법, (d)제안한 방법
 Fig. 5. DB2 Situation1: Illumination change and moving object (a)Original image, (b)Ground Truth, (c)Conventional method, (d)Proposed method




그림 7. DB1 상황2: 객체의 움직임이 없는 상황 (a)원본영상, (b)수작업을 통해 얻은 영상, (c)기존 방법, (d)제안한 방법
 Fig. 7. DB1 Situation2: Motionless object (a)Original image, (b)Ground Truth, (c)Conventional method, (d)Proposed method




그림 6. DB3 상황1: 조명변화와 객체 이동 (a)원본영상, (b)수작업을 통해 얻은 영상, (c)기존 방법, (d)제안한 방법
 Fig. 6. DB3 Situation1: Illumination change and moving object (a)Original image, (b)Ground Truth, (c)Conventional method, (d)Proposed method




그림 8. DB2 상황2: 객체의 움직임이 없는 상황 (a)원본영상, (b)수작업을 통해 얻은 영상, (c)기존 방법, (d)제안한 방법
 Fig. 8. DB2 Situation2: Motionless object (a)Original image, (b)Ground Truth, (c)Conventional method, (d)Proposed method

그림 4는 DB1의 231번째 프레임 영상으로 엘리베이터 안에 있던 사람이 문이 열리자 갑자기 나가는 상황이다. 그림 5는 DB2의 163번째 프레임 영상으로 사람이 들어온 후 문이 닫히는 상황이다. 그림 6은 DB3의 63번째 프레임 영상으로 문이 열리고 두 명이 안으로 들어오는 상황이다. 세 개의 DB에 대해 모두 제안한 방법이 기존 방법보다 TP비율이 더 높고 FN비율이 더 낮다.

DB1, DB2, DB3 중에 조명변화가 없고 사람이 가만히 움직이지 않는 상황은 그림 7, 그림 8, 그림 9와 같은 결과를 가진다.

그림 7은 DB1의 157번째, 그림 8은 DB2의 211번째, 그림 9는 DB3의 171번째 프레임 영상이다. 엘리베이터 안에 사람이 움직이지 않고 가만히 정지해 있는 상황이다. 세 개의 DB에 대해 모두 제안한 방법이 기존의 방법보다 TP비율이 더 높고 FN비율이 더 낮다.



그림 9. DB3 상황2: 객체의 움직임이 없는 상황 (a)원본영상, (b)수작업을 통해 얻은 영상, (c)기존 방법, (d)제안한 방법
 Fig. 9. DB3 Situation2: Motionless object (a)Original image, (b)Ground Truth, (c)Conventional method, (d)Proposed method

표 1-3은 각 DB에 대해 상황별로 20프레임을 선별하여 식(23)-(24)을 통해 Precision과 Recall 값의 평균을 구한 것이다. TP가 증가할수록 Precision와 Recall은 모두 증가하며 검출률을 나타내는 지표이다. 오검출(FP)이 낮을수록 Precision은 증가하고, 미검출(FN)이 낮을수록 Recall은 증가하는 특성이 있다.

표 1. DB1: 기존 방법과 제안한 방법의 성능 지표
 Table 1. DB1: Precision and recall of traditional and proposed method

DB1	상황 1		상황 2	
	기존[4]	제안	기존[4]	제안
Precision	76.82	68.5	76.01	69.01
Recall	78.18	97.57	58.09	97.69

표 2. DB2: 기존 방법과 제안한 방법의 성능 지표
 Table 2. DB2: Precision and recall of traditional and proposed method

DB2	상황 1		상황 2	
	기존[4]	제안	기존[4]	제안
Precision	63.74	56.48	87.28	64.06
Recall	76.14	98.63	16.95	97.56

표 3. DB3: 기존 방법과 제안한 방법의 성능 지표
 Table 3. DB3: Precision and recall of traditional and proposed method

DB3	상황 1		상황 2	
	기존[4]	제안	기존[4]	제안
Precision	59.09	56.34	70.27	64.94
Recall	90.38	97.98	48.09	97.69

제안한 방법은 엘리베이터 안의 반사면에 의해 반사되는 영역까지 전경으로 검출하여 오검출(FP)값이 증가하였기 때문에 Precision 지표가 기존의 방법에 비해 다소 감소하였다. 반면 미검출(FN)이 크게 작아지고 TP가 증가하여 제안한 방법에서 Recall 지표가 크게 증가하는 것을 확인할 수 있다. 또한 기존의 방법은 객체의 움직임이 없는 상황에서 모델 히스토그램의 개수가 필요 이상으로 크게 되어 전경으로 구분되어야 할 객체가 나머지 모델 히스토그램에 포함된다. 그 결과 객체가 배경으로 적용되어 미검출(FN) 비율이 증가한다. 따라서 Recall 지표가 크게 감소하여 성능이 저하된다. 반면 제안한 방법은 객체의 움직임이 많은 상황뿐만 아니라 움직임이 없는 정지한 상황에서도 항상 최적의 모델 히스토그램의 개수를 유지하여 어떤 상황에서도 약 98%의 Recall 지표를 나타내 높은 성능을 가지는 것을 확인할 수 있다.

V. 결론

본 논문에서는 블록기반 배경 모델링 방법의 모델 히스토그램의 개수를 각 블록별로 매 프레임마다 적응적으로 조절하면서 최적의 모델 히스토그램의 개수를 유지하는 방법을 제안하였다. 따라서 기존의 블록기반 배경 모델링 방법에서 배경에 대한 모델 히스토그램의 개수를 고정하기 때문에 조명변화와 움직이는 객체, 정지해있는 객체에 대해 정확히 배경 분리하지 못하는 문제를 해결하였다. 또한 제안한 알고리즘을 조명이 자주 변하고 객체의 이동과 정지상황이 반복적으로 발생하는 엘리베이터 환경에 적용하여 실험하였다.

그 결과 어떠한 상황에서도 객체를 검출하지 못 하는 비율이 거의 없이 약 98%의 Recall 지표를 유지하여 높은 성능을 가지는 것을 확인하였다. 따라서 본 논문에서 제안한 알고리즘은 기존 알고리즘 보다 배경 분리 후 객체 분류나 모션 분석의 높은 성능을 내기 위해 적합하다고 할 수 있다. 향후 연구에서는 반사면이나 그림자가 있는 환경에서 오검출을 줄이는 방법을 모색하여 제안한 방법의 성능을 검증할 것이다.

참고문헌

- [1] C. Stauffer and W.E.L. Grimson, "Adaptive background mixture models for real-time tracking", Proc. IEEE Computer Society Conf. Computer Vision and Pattern Recognition, vol. 2, pp.246-252, 1999
- [2] Z. Zivkovic and F. van der Heijden, "Efficient

adaptive density estimation per image pixel for the task of background subtraction”, Pattern Recognition Letters, 2006

- [3] Kim Young-Ju, “An Improved Adaptive Background Mixture Model for Real-time Object Tracking based on Background Subtraction ”, Journal of the Korea Society of Computer and Information, v.10, no.6, pp.187-194, December 2005
- [4] M. Heikkila, M. Pietikainen and J. Heikkila, “A Texture-based Method for Detecting Moving Objects”, Proc. British Machine Vision Conf., vol. 1, pp.187-196, 2004
- [5] M Heikkila and M Pietikainen, “A Texture-Based Method for Modeling the Background and Detecting Moving Objects”, IEEE Computer Society Pattern Analysis and Machine Intelligence, vol. 28, pp657-662, 2006
- [6] A. Shimada and R. Taniguchi, “Hybrid Background Model using Spatial-Temporal LBP”, IEEE Computer society, 2009
- [7] Ojala, T., Pietikainen, M. and Maenpaa, T., “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns.”, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, pp.971 - 987, 2002
- [8] Z. Zivkovic and F. van der Heijden, “Recursive Unsupervised Learning of Finite Mixture Models”, IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 26, pp651-656, 2004
- [9] M. Figueiredo and A.K. Jain, “Unsupervised Learning of Finite Mixture Models” IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 24, pp.381-396, 2002



이 영 현
 2007년 2월: 고려대학교
 전기전자전파공학부 (공학사)
 2007년 3월~현재: 고려대학교
 영상정보처리학과 석박사통합과정
 관심분야: 신호처리, 개체검출, 영상인식
 Email : yhlee@ispl.korea.ac.kr



송 태 엽
 2009년 2월 : 대전대학교
 전자공학(공학사), 물리학과 (이학사)
 2009년 3월~현재: 고려대학교
 바이오마이크로시스템기술공학과
 석박사통합과정
 관심분야: 신호처리, 개체검출, 영상인식
 Email : tysong@ispl.korea.ac.kr



구 본 화
 2000년 2월: 광운대학교
 제어계측 공학과 (공학사).
 2002년 2월: 고려대학교
 전자공학과 (공학석사)
 2008년 2월: 고려대학교
 영상정보처리학과 (공학박사)
 2009년 6월~현 재: 고려대학교 연구 교수
 관심분야: 표적 탐지/추적, 데이터 융합
 Email : bhku@ispl.korea.ac.kr



고 한 석
 1982년 5월: Carnegie-Mellon University
 전기공학 (공학사)
 1988년 5월: Johns Hopkins University
 전기공학 (공학석사)
 1992년 5월: Catholic University
 of America 전기공학 (공학박사)
 1983년 9월~1995년 2월:
 White Oak 연구소
 Principal Engineer
 1992년 9월~1995 2월:
 University of Maryland
 Part-time Assistant Professor
 1995년~현재: 고려대학교
 전기전자전파공학부 교수
 관심분야: 영상 및 음성&음향 신호처리, 패턴
 인식
 Email : hsko@korea.ac.kr

저 자 소 개



김 한 준
 2010년 2월: 경희대학교
 동서의료공학과 (공학사).
 2010년 3월~현재: 고려대학교
 바이오마이크로시스템기술공학과
 석사과정
 관심분야: 신호처리, 개체검출, 영상인식
 Email : hjkim@ispl.korea.ac.kr