

배경분리를 위한 개선된 적응적 가우시안 혼합모델에서의 동적 학습률 제어

김영주*

*신라대학교 컴퓨터공학과

Dynamic Control of Learning Rate in the Improved Adaptive
' Gaussian Mixture Model for Background Subtraction

Young-ju Kim*

*Dept. of Computer Engineering, Silla University

E-mail : yjkim@silla.ac.kr

요 약

연속 영상을 이용하여 실시간으로 움직임 객체를 추출하고 추적하기 위해 배경분리(Background Subtraction) 기법을 주로 사용한다. 외부 환경에서는 조명의 변화, 나무의 흔들림과 같은 반복적인 움직임 그리고 급격히 움직이는 객체 등과 같이 고려해야 할 많은 환경 변화 요인들이 존재한다. 이러한 외부 환경의 변화를 적응적으로 반영하여 배경을 분리할 수 있는 배경 모델로는 주로 가우시안 혼합 모델(GMM: Gaussian Mixture Model)이 적용되고 있으며, 실시간 성능 등을 개선시킨 적응적 가우시안 혼합 모델 등이 사용되고 있다. 본 논문은 개선된 적응적 가우시안 혼합 모델을 적용하고 고정된 학습률 α (일반적으로 작은 값)을 사용함으로써 물체의 갑작스러운 움직임 등에 빠르게 적응하지 못하는 문제점을 해결하기 위해 가우시안 분포 수의 적응적 조절 기능과 픽셀 값의 분산을 이용하여 학습률 α 값을 동적으로 제어하는 방법을 제안하고 성능을 평가하였다.

ABSTRACT

Background subtraction is mainly used for the real-time extraction and tracking of moving objects from image sequences. In the outdoor environment, there are many changeable factors such as gradually changing illumination, swaying trees and suddenly moving objects, which are to be considered for the adaptive processing. Normally, GMM(Gaussian Mixture Model) is used to subtract the background adaptively considering the various changes in the scenes, and the adaptive GMMs improving the real-time performance were worked. This paper, for on-line background subtraction, applied the improved adaptive GMM, which uses the small constant for learning rate α and is not able to speedily adapt the suddenly movement of objects. So, this paper proposed and evaluated the dynamic control method of α using the adaptive selection of the number of component distributions and the global variances of pixel values.

키워드

Background subtraction, Background Model, GMM, recursive parameter update, MAP(Maximum A Posteriori)

1. 서 론

외부 환경에서는 조명의 점진적이거나 급격한 변화 또는 객체의 갑작스러운 등장 등 여러 가지 변화가 존재하며, 이에 적용하여 연속 영상으로부터 움직임 객체를 실시간으로 추출하고 추적하기 위하여 픽셀 기반의 배경 분리(Background Subtraction) 기법이 주로 사용되고 있다[1~4]. 이

를 위해 여러 가지 접근법이 연구되었으나 뛰어난 적응성을 보이는 가우시안 혼합모델이 주로 사용되고 있으며[2], 실시간 처리 능력 및 안정성 등을 향상시킨 적응적인 가우시안 혼합모델 등이 제안되었다[5,6].

본 논문에서는 기존의 적응적 가우시안 혼합모델의 문제점을 개선하기 위해 가우시안 혼합모델에서 가우시안 분포 수를 적응적으로 조절할 수

있는 개선된 적응적인 가우시안 혼합모델[7]을 적용하고, 초기화에 따른 안정화를 개선하면서 고정된 학습률을 사용함으로써 발생하는 낮은 학습 속도 문제점을 해결하기 위해 픽셀값의 분산을 이용하여 학습률을 동적으로 제어하는 방법을 제안하고 성능을 평가하였다.

II. 가우시안 혼합모델 기반의 배경 분리

가우시안 혼합모델 기반의 배경분리 기법은 대부분 참고문헌 [2]에서 제시된 적응적 가우시안 혼합모델을 주로 사용하고 있다.

연속 영상에서 t 시간에 측정된 한 픽셀의 값을 \vec{x} 라 하고, \vec{x} 가 M 개의 가우시안 분포를 갖는 가우시안 혼합 분포를 따른다고 하면 가우시안 혼합모델은 식 (1)과 같이 나타낼 수 있다.

$$p(\vec{x}, \vec{\theta}) = \sum_{m=1}^M \pi_m N(\vec{x}; \vec{\mu}_m, C_m) \text{ with } \sum_{m=1}^M \pi_m = 1 \quad (1)$$

여기서, $\vec{\theta} = \{\pi_1, \dots, \pi_M, \vec{\mu}_1, \dots, \vec{\mu}_M, C_1, \dots, C_M\}$ 이며, $\vec{\mu}_m$ 과 C_m 은 m -번째 가우시안 분포의 평균과 공분산 행렬을 의미하고, π_m 은 m -번째의 가우시안 분포의 혼합 가중치로서 양의 값을 갖는다. 그리고 계산 복잡도를 고려하여 픽셀값을 구성하는 요소들은 상호 독립이라고 가정한다. 즉, 공분산 행렬에 대해 $C_m = \sigma_m^2 I$ 이고, I 는 단위행렬임을 가정한다.

$(t+1)$ 시간에 새로운 픽셀값 $\vec{x}^{(t+1)}$ 이 주어지면 가우시안 혼합모델의 파라미터를 다음 식들에 의해 재귀적으로 갱신한다.

$$\hat{\pi}_m^{(t+1)} = \hat{\pi}_m^{(t)} + \alpha(o_m^{(t)}(\vec{x}^{(t+1)}) - \hat{\pi}_m^{(t)}) \quad (2)$$

$$\hat{\mu}_m^{(t+1)} = \hat{\mu}_m^{(t)} + o_m^{(t)}(\vec{x}^{(t+1)})(\alpha/\hat{\pi}_m^{(t)})\vec{\delta}_m \quad (3)$$

$$\hat{\sigma}_m^{(t+1)} = \hat{\sigma}_m^{(t)} + o_m^{(t)}(\vec{x}^{(t+1)})(\alpha/\hat{\pi}_m^{(t)})(\vec{\delta}_m^T \vec{\delta}_m - \hat{\sigma}_m^{(t)}) \quad (4)$$

여기서, $\vec{\delta}_m = \vec{x}^{(t+1)} - \hat{\mu}_m^{(t)}$ 이고, α 는 오래된 데이터의 영향을 제한하기 위해 사용하는 학습률 변수로서 일반적으로 상수값 $1/T$ 로 근사시킨다(T 는 혼합모델에 반영하는 픽셀 데이터의 수). $\vec{x}^{(t+1)}$ 에 대한 ownership $o_m^{(t)}$ 은 픽셀값이 m -번째 가우시안 분포에 근접하는지 여부를 나타내는 값으로 m -번째 가우시안 분포에 대한 Mahalanobis 거리값 $D_m^2(\vec{x}^{(t)}) = (\vec{\delta}_m^T \vec{\delta}_m) / \hat{\sigma}_m^{(t)}$ 을 계산하고 식 (5)를 만족하면 1이 되고, 그렇지 않으면 0이 된다. 그리고 κ 값은 주로 2와 3 사이 값을 적용한다.

$$D_m^2(\vec{x}^{(t)}) < \kappa \sigma \quad (5)$$

$\vec{x}^{(t+1)}$ 에 대해 근접하는 가우시안 분포가 존재하지 않으면 픽셀값을 평균으로 하고 임의의 분산을 갖는 새로운 가우시안 분포를 추가한다. 그리고 가우시안 혼합모델이 M 개의 분포를 갖는 경우는 혼합 가중치가 제일 작은 가우시안 분포를 제거하고 새로운 가우시안 분포를 추가한다.

가우시안 혼합모델은 배경과 전경에 대한 분포를 모두 포함하고 있어 배경모델을 추정하기 위해 가우시안 분포들을 π_m/σ 값에 대해 내림차순으로 정렬하고 식 (6)을 만족하는 처음 B 개의 분포를 배경모델로 근사한다.

$$B = \arg \min_b \left(\sum_{m=1}^b \hat{\pi}_m > (1 - T_f) \right) \quad (6)$$

여기서, T_f 는 전경에 속하면서 배경모델에 영향을 미치지 하는 픽셀값들의 최대 비율을 의미한다. 식 (4)와 (6)을 고려할 때 새로운 나타난 픽셀값이 배경에 속하기 위해서는 식 (7) 만큼의 프레임이 경과하여야 한다. 예를 들어, $T_f = 0.1$ 이고 $\alpha = 0.001$ 이면 하나의 픽셀이 배경이 되기 위해서는 105 프레임 동안 고정되어 있어야 한다.

$$F = \log(1 - T_f) / \log(1 - \alpha) \quad (7)$$

III. 제안된 배경 분리 기법

참고문헌 [2]에 기반한 배경분리 기법은 다음과 같은 주요한 문제점을 가지며, 이에 대한 해결책으로 여러 가지 연구 결과가 제시되었다[3,5].

첫째, 배경 모드에 따라, 또는 실내외 여부에 따라 픽셀별로 가우시안 혼합모델을 구성하는 가우시안 분포의 수가 각각 다른데, 일반적으로 최대 개수 $M(=3\sim 5)$ 을 적용함으로써 실행 부하를 가중시킨다.

둘째, 2장에서 제시된 파라미터 추정 방법은 휴리스틱 기법을 적용함으로써 가우시안 분포의 초기화 조건에 크게 영향을 받지 않지만 초기화 조건의 정확도가 혼합모델의 안정성과 성능에 영향을 미친다.

셋째, 파라미터 추정에 적용되고 있는 학습률에 일반적으로 적은 상수값을 적용함으로써 초기 화면의 변화나 갑작스러운 환경 변화가 발생하는 경우에 학습 속도가 늦어 혼합모델이 안정화될 때까지 오랜 시간을 요구한다.

본 논문은 위에서 제시된 문제점에 대해 각각의 해결책을 제시하고 통합함으로써 개선된 적응적 가우시안 혼합모델 기반의 배경분리 기법을 제안한다.

3.1 가우시안 분포 수의 적응적 조절

본 논문은 첫 번째 문제점을 해결하기 위해 가우시안 혼합모델에서 가우시안 분포 수를 파라미터의 사전확률분포를 이용하여 적응적으로 조절하는 참고문헌 [7]의 기법을 사용한다.

혼합 가중치 π_m 은 m -번째 가우시안 분포에 속하는 데이터의 비율을 나타내는 것으로 하나의 샘플 데이터가 m -번째 가우시안 분포에서 나올 확률로 고려할 수 있다. 이는 M 개의 π_m 가 다항 분포(multinomial distribution)를 정의할 수 있음

을 의미한다. 다항 분포의 공액 사전확률분포인 Dirichlet 사전 확률분포($P = \prod_{m=1}^M \pi_m^{c_m}$)는 일반적으로 적용되는 모델 선택 기준(e.g. MML)에서의 패널티 함수의 특성을 가지면서 최적의 구조적 모델에 대한 편중 정도(bias)를 나타냄으로 이를 반영하여 혼합 가중치를 추정하면 동시에 가우시안 분포의 수를 적응적으로 조절할 수 있다.

또한 추정 과정에서 Dirichlet 사전확률분포의 계수 c_m 에 음수인 $-c$ 값을 적용하는데, 이는 클래스 m 의 존재에 대해 충분한 증거가 있는 경우에만 클래스 m 을 인정하는 것을 의미하는 것으로 추정값이 음수가 되면 클래스 m 은 무의한 클래스가 되어 제거 가능하다. 혼합 가중치 π_m 에 대해 사전확률분포를 고려하여 MAP(Maximum A Posteriori) 추정치를 구하면 식 (8)과 같다.

$$\hat{\pi}_m^{(t)} = \frac{1}{K} \left(\sum_{i=1}^t o_m^{(i)} - c \right) \quad (8)$$

여기서, $K = \sum_{m=1}^M \left(\sum_{i=1}^t o_m^{(i)} - c \right) = t - Mc$ 이다. 식 (8)을 다시 작성하면 식 (9)와 같다.

$$\hat{\pi}_m^{(t)} = \frac{\hat{\Pi}_m - c/t}{1 - Mc/t} \quad (9)$$

여기서, $\hat{\Pi}_m = \frac{1}{t} \left(\sum_{i=1}^t o_m^{(i)} \right)$ 는 혼합 가중치 π_m 의 ML(Maximum Likelihood) 추정치이며, 사전확률 분포에 의한 편중 정도는 c/t 항에 의해 반영된다. c/t 항을 충분히 큰 상수 T 에 대한 $c_T = c/T$ 값으로 고정하고 통계적 근산법을 적용하여 식 (8)을 재귀적인 수식으로 바꾸면 식 (10)과 같다.

$$\hat{\pi}_m^{(t)} = \hat{\pi}_m^{(t-1)} + \frac{1}{t} \left(\frac{o_m^{(t)}}{1 - Mc_T} - \hat{\pi}_m^{(t-1)} \right) - \frac{1}{t} \frac{c_T}{1 - Mc_T} \quad (10)$$

M 과 c_T 가 매우 작은 값이므로 $1 - Mc_T \approx 1$ 을 만족하고, $\alpha = 1/t$ 로 설정함으로써 식 (11)과 같은 혼합 가중치의 갱신 수식이 정의된다.

$$\hat{\pi}_m^{(t)} = \hat{\pi}_m^{(t-1)} + \alpha(o_m^{(t)} - \hat{\pi}_m^{(t-1)}) - \alpha c_T \quad (11)$$

만약 식 (11)에 의해 혼합 가중치의 값이 음수가 되면 대응하는 가우시안 분포는 의미 없는 것이 되어 제거한다. 또한 이는 혼합 가중치가 양수이어야 한다는 조건을 보장한다.

현재의 가우시안 혼합모델로 표현할 수 없는 새로운 픽셀값에 대해서는 새로운 가우시안 분포를 생성하여 추가하고, 사전확률분포를 반영한 혼합 가중치 갱신을 통해 중요하지 않는 가우시안 분포를 선별하여 제거함으로써 가우시안 분포의 수를 적응적으로 결정할 수 있다.

3.2 초기화 파라미터의 갱신

참고 문헌 [2]나 3.1절에서 제시한 기법은 가우시안 분포의 초기화 조건에 크게 영향을 받지 않지만 초기화 조건의 정확도는 가우시안 혼합모델의 안정성과 학습 속도 등의 성능에 영향을 미친다. 본 논문은 임의적으로 초기화하기 보다는 파

라미터 갱신 과정에서 식 (12)와 (13)을 적용하여 픽셀값에 대한 전체적인 분산값을 계산하고 이를 가우시안 분포를 초기화할 때에 적용하도록 한다.

$$\hat{\mu}_0^{(t+1)} = \hat{\mu}_0^{(t)} + \alpha \delta_0 \quad \text{with } \delta_0 = \bar{x}^{(t+1)} - \hat{\mu}_0^{(t)} \quad (12)$$

$$\hat{\sigma}_0^{(t+1)} = \hat{\sigma}_0^{(t)} + \alpha (\delta_0^T \delta_0 - \hat{\sigma}_0^{(t)}) \quad (13)$$

본 논문은 실제 구현 시에 계산 부하를 줄이기 위해 식 (14)와 같이 연속적인 두 개의 픽셀값의 차이 $\|\bar{x}^{(t)} - \bar{x}^{(t-1)}\|$ 에 대한 중간값 med 을 이용한 분산 추정값을 사용하였다.

$$\sigma_0 = 0.2 \frac{med}{0.68\sqrt{2}} \quad (14)$$

3.3 학습률의 동적 제어

기존의 가우시안 혼합모델은 파라미터 갱신 과정에서 적은 상수값의 학습률을 적용하는데, 이는 혼합모델의 학습 속도가 떨어지는 결과를 초래한다. 장면의 초기 상태가 변하거나 갑작스러운 장면 변화가 발생하여 천천히 변화가 일어나는 경우에 움직임 객체의 잔상이 지속되는 현상이 발생하며, 이로 인해 불필요한 계산량이 증가할 뿐만 아니라 객체 추적과 같은 다음 단계의 처리에 영향을 미친다.

가우시안 분포 수의 적응적 조절 기법을 적용하는 경우, 장면 변화에 의한 혼합모델의 변화 시점을 알 수 있다. 즉, 향상된 적응적 가우시안 혼합모델은 갑작스러운 장면 변화에 대해 새로운 가우시안 분포를 생성하고 가우시안 분포 제거를 통해 장면 변화가 안정되었음을 나타내는데, 이 기간 동안에 장면 변화의 속도를 고려하여 학습률을 동적으로 제어함으로써 가우시안 혼합모델의 안정화를 빠르게 유도할 수 있다. 본 논문은 파라미터의 재귀적 갱신 과정과 장면 변화 정도를 포괄적으로 내포하는 픽셀의 분산값을 고려하여 식 (15)와 같이 재귀적으로 학습률을 갱신하는 수식을 적용한다.

$$\alpha^{(S)} = \alpha_0, \quad \alpha^{(S+t+1)} = \alpha^{(S+t)} + \left(\exp \left(- \frac{(\sigma_0^{(S)})^2}{2\kappa} \right) \right)^t \quad (15)$$

여기서, S 는 새로운 가우시안 분포가 생성된 시점, α_0 는 안정 상태에서 적용되는 초기 학습률을 의미하고, κ 는 잡음에 의한 분산 요소를 제거하기 위한 상수로 식 (5)에서 적용된 값과 동일하다. 학습률의 전체적인 동적 제어 과정은 다음과 같다.

step 1: 가우시안 분포 수에 변동이 없으면 학습률을 그대로 유지하고, 새로운 가우시안 분포가 생성되면 학습률의 동적 제어를 시작한다.

step 2: 식 (15)을 사용하여 학습률을 점차적으로 증가시켜 파라미터 갱신에 적용한다.

step 3: 가우시안 분포 제거가 발생하는지를 검사하고, 만약 제거가 발생하면 학습률을 초기화하여 동적 제어 과정을 중지한다.

IV. 성능평가

본 논문은 제안된 배경분리 기법의 성능을 평가하기 위해 혼합모델의 안정화 속도와 평균 프레임 처리 시간을 참고문헌 [2]와 [7]에서 제시된 기법과 비교하여 분석하였다. 실험은 Pentium-IV 2.4GHz CPU, 512RAM을 가진 IBM 호환 PC에서 320 * 240 크기의 연속 영상을 사용하였다.

혼합모델의 안정화 속도를 비교하기 위해 그림 1과 같이 차량이 갑자기 나타나서 차량의 잔상이 없어지고 장면이 안정화될 때까지의 프레임 수를 참고문헌 [7]의 기법과 비교하였다.

표 1. 혼합모델의 안정화 속도 비교

배경분리기법	안정화까지 경과된 프레임 수
제안된 배경분리 기법	186
참고문헌 [7]의 기법	227

표 1에서 제시된 결과와 같이 제안된 기법에서 혼합모델의 안정화 속도는 기존의 기법보다 훨씬 빠름을 알 수 있으며, 이는 학습률 동적 제어를 통해 학습 속도가 증가하였음을 의미한다.




그림 1. 혼합모델 안정화 속도 비교 실험 화면

제안된 기법의 장면 변화에 대한 적응 능력을 단순히 픽셀별로 생성된 가우시안 분포 수로 비교하기보다는 초기화 조건 사용 등 다른 요인들을 고려하여 평균 프레임 처리 시간을 비교하였다. 비교 실험에 사용된 연속 영상은 넓은 배경에 빠른 움직임 객체를 갖는 경우(영상-1), 일정한 조명 조건과 많은 움직임을 갖는 실내 영상(영상-2) 그리고 위의 실험에서 적용한 영상(영상-3)이다. 각각의 경우에 대해 평균 프레임 처리 시간을 비교한 결과는 표 2와 같다.

표 2. 평균 프레임 처리 시간 비교

배경분리기법	영상-1	영상-2	영상-3
제안된기법	11.3 ms	12.8 ms	14.5 ms
참고문헌[2]	18.2 ms	18.7 ms	19.1 ms
참고문헌[7]	13.5 ms	14.8 ms	17.7 ms

표 2에서 제시된 결과에서 제안된 기법이 평균 프레임 처리 시간이 짧음을 알 수 있는데 이는 픽셀별로 적응적으로 가우시안 분포 수를 조절할 뿐만 아니라 학습률 제어를 통해 학습 속도 증가에 따라 불필요한 연산량이 줄었기 때문이다.

V. 결론

본 논문은 기존의 가우시안 혼합모델 기반의 배경분리가 가지는 문제점을 정의하고, 이를 해결하기 위해 가우시안 분포 수의 적응적 조절, 초기 파라미터 갱신 및 학습률 동적 제어 기법을 적용한 향상된 적응적 가우시안 혼합모델을 제안하고 성능을 평가하였다. 성능 평가를 통해 기존 기법보다 학습 속도가 빠르고 전체 처리 시간이 빨라졌음을 알 수 있었다. 본 논문에서는 고정된 카메라를 가정하였으며, 향후에는 능동적인 카메라에 대해 배경분리 기법을 연구할 예정이다.

참고문헌

- [1] N. Friedman and S. Russell, "Image segmentation in video sequences: A probabilistic approach," In Proceedings Thirteenth Conf. on Uncertainty in Artificial Intelligence, 1997.
- [2] C. Stauffer and W. Crimson, "Adaptive background mixture models for real-time tracking," in Proceedings CVPR, Vol. 2, pp.246-252, 1999.
- [3] T. Horparasert, D. Harwood and L. A. Davis, "A statistical approach for real-time robust background subtraction and shadow detection," In Proceedings ICCV'99: Frame Rate Workshop, pp. 1-19, 1999.
- [4] A. Elgammal, D. Harwood and L. S. Davis, "Non-parametric background model for background subtraction," In Proceedings 6-th ECCV, 2000.
- [5] P. KaewtraKulPong and R. Bowden, "An improved adaptive background mixture model real-time tracking with shadow detection," 2nd European Workshop an Advanced Video Based Surveillance System, AVBS01, 2001.
- [6] E. Hayman and J. Eklundh, "Statistical Background Subtraction for a Mobile Observer," In Proceedings ICCV, 2003.
- [7] Z. Zivkovic, "Improved Adaptive Gaussian Mixture Model for Background Subtraction," In Proceedings ICPR, 2004.