

효과적인 다봉 배경 모델링 및 물체 검출

(Efficient Multimodal Background Modeling and Motion Detection)

박 대 용 [†] 변 헤 란 ^{**}
(Daeyong Park) (Haeran Byun)

요 약 배경 모델링 및 물체 검출 기술은 실시간 비디오 처리 기술에서 중요한 부분을 차지하고 있다. 그동안 많은 연구들이 진행되었지만 안정적인 성능을 위해서는 아직도 상당한 계산량을 요구한다. 이 때문에 고해상도 영상 처리나 객체 추적, 행동 분석 및 대상 인식 등의 알고리즘과 함께 사용되는 경우, 실시간 처리에 어려움이 있다. 본 논문에서는 가장 일반적으로 쓰이는 배경 모델링 기법 중의 하나인 혼합정규모델(mixtures of Gaussian)을 근사화한 효과적인 다봉(multimodal) 배경 모델링 및 물체 검출 방법을 제안한다. 근사화의 타당성과 각 과정들을 유도 및 검증하였고, 실험을 통해 제안하는 알고리즘이 기존 방법의 안정성과 유연성을 유지하면서 3배 이상의 처리 속도를 나타냄을 보였다.

키워드 : 다봉 배경 모델링, 물체 검출, 실시간 처리

Abstract Background modeling and motion detection is the one of the most significant real time video processing technique. Until now, many researches are conducted into the topic but it still needs much time for robustness. It is more important when other algorithms are used together such as object tracking, classification or behavior understanding. In this paper, we propose efficient multi-modal background modeling methods which can be understood as simplified learning method of

Gaussian mixture model. We present its validity using numerical methods and experimentally show detecting performance.

Key words : multimodal background modeling, motion detection, real time processing

1. 서 론

카메라 기술의 발달과 보급으로 비디오 영상 처리 기술의 중요성은 점점 더 높아지고 있다. 영상 감시나 HCI(Human Computer Interaction)등 여러 어플리케이션에서는 영상의 실시간 처리를 요구하는데 반하여 화소 수와 처리의 복잡도 증가는 실시간 처리에 어려움을 더하고 있다. 지능형 영상 감시 시스템의 경우, 물체 검출과 추적뿐만이 아닌 객체 분류나 객체 인식, 행동 분석, 카메라간 정보 변환 및 결합이 함께 이루어져야 한다[1]. 또한 저사양의 중앙처리장치를 사용하는 임베디드 기반의 환경에서는 보다 적은 연산량의 알고리즘을 필요로 한다.

배경 모델링 및 물체 검출 기술은 입력 영상을 배경과 전경 영역으로 분리하여 관심 영역을 추출하는데, 이는 추적이나 인식, 분석 등에 유용한 정보로 사용된다. 기본적으로 입력 영상들은 화소단위로 처리되는데, 각 화소값은 확률적으로 모델링된다. 이 때 특징값으로 화소 밝기 값을 사용하거나 시간에 따른 차이, 평균, 분산, 최대, 최소 등이 사용된다[2,3]. 이러한 값들로 단순 정규 분포[4]나 혼합 정규 분포[5], 비모수 밀도 추정[6], 예측기 기반[7] 등에 따라 배경 모델을 생성하게 되며, 얻어진 배경 모델에 해당하지 않는 화소 값들을 전경으로 검출하게 된다.

이 중 혼합 정규 분포를 이용한 배경 모델링은 가장 광범위하게 쓰이는 방법 중 하나이다. 그 이유는 배경 모델링과 학습 과정의 수학적 기반이 잘 닦여있고 시간의 변화에 따라 물체 검출이 안정적이며 다봉 분포를 가지는 다양한 배경들을 모델링할 수 있기 때문이다. 그러나 상당한 연산량을 가지기 때문에 해상도가 높은 영상이나 복잡한 영상 분석 알고리즘들과 함께 사용하는 데에 어려움이 있다. 연산량을 효과적으로 개선한 알고리즘들도 있지만 이러한 알고리즘들은 환경과 모델링하는 대상에 따라 학습 성능의 안정성이 낮으며, 이를 보완하기 위해서는 더 많은 연산량을 요구하는 후처리 알고리즘이 필요하다[8,9]. 본 논문에서는 혼합 정규 모델을 이용한 배경 모델링 알고리즘을 근사하여 정확도를 유지하면서도 연산을 효과적으로 줄이는 방법을 제안하고자 한다.

2절에서는 혼합 정규 모델을 학습하는 기존 방법에 대하여 요약하였고 3절에서 기존 방법을 근사화한 방법

· 본 연구는 한국과학기술원 특장기조연구(R01-2007-000-11683-0)지원으로 수행되었음

[†] 학생회원 : 연세대학교 컴퓨터과학과
daeyong@cs.yonsei.ac.kr

^{**} 종신회원 : 연세대학교 컴퓨터과학과 교수
hrbyun@yonsei.ac.kr

논문접수 : 2008년 12월 15일

심사완료 : 2009년 4월 24일

Copyright©2009 한국정보과학회 : 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지: 컴퓨팅의 실제 및 레터 제15권 제6호(2009.6)

을 제안하겠다. 4절에서는 단봉(unimodal) 배경 분포의 학습 방법을 다봉 배경 분포 학습 방법으로 확장한다. 5절에서 정수 연산만을 이용하는 방법에 대하여 고찰해 보고 6절에서 실험 결과를 보인다. 마지막으로 7절에서 결론을 맺는다.

2. 혼합 정규 모델

혼합 정규 모델은 stauffer가 제안한 이후로 가장 일반적으로 쓰이는 물체 검출 방법 중의 하나가 되었다. 각각의 화소에 대하여 배경의 분포를 여러 개의 정규 분포의 결합으로 모델링하고, 각 정규 분포를 학습 및 초기화하기 때문에 다양한 배경의 변화를 안정적으로 학습하게 된다. 높은 안정성이 장점이지만 학습 속도가 느리기 때문에 환경 변화에 신속히 적응하는데 한계를 가지고 있다. 학습 속도와 관련된 많은 연구들이 있지만 [10,11] 본 논문에서는 stauffer가 제안한 기본적인 알고리즘을 사용하였다. 학습 속도와 관련해 안정도를 유지 하면서 처리속도와 학습 속도를 높이는 방법은 5절에서 논의한다.

시간 t에 입력되는 화소값 x의 확률밀도 $\rho(x)$ 는 평균 μ 와 분산 Σ 으로 표현되는 K개의 정규 분포 η 를 각각의 비율 ω 에 따라 가중합(weighted sum)으로 표현된다.

$$p(x(t)) = \sum_{j=1}^K w_j \eta(x; \mu_j, \Sigma_j) \quad (1)$$

$$\eta(x; \mu_k, \Sigma_k) = \frac{1}{(2\pi)^2 |\Sigma_k|^2} e^{-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)} \quad (2)$$

배경 B는 K개 중 w_k/σ_k 가 큰 순서로 나열했을 때 문턱 T를 넘는 최소 개수 b개의 분포만으로 이루어진다.

$$B = \underset{b}{\operatorname{argmin}} \left(\sum_{j=1}^b w_j > T \right) \quad (3)$$

영상이 입력됨에 따라 각각의 변수들은 학습비율 α 에 따라 다음과 같은 방법으로 학습된다. 현재의 입력이 특정 정규분포에 해당되는지를 평가하는 범위 c는 2.5가 사용되었다.

$$w_k(t+1) = (1-\alpha)w_k(t) + \alpha p(w_k|x(t+1)) \quad (4)$$

$$\mu_k(t+1) = (1-\rho)\mu_k(t) + \rho x(t+1) \quad (5)$$

$$\Sigma_k(t+1) = (1-\rho)\Sigma_k(t) + \rho(x(t+1) - \mu(t))(x(t+1) - \mu(t))^T \quad (6)$$

$$\rho = \alpha \eta(x(t+1); \mu_k(t), \Sigma_k(t)) \quad (7)$$

$$p(w_k|x(t+1)) = \begin{cases} 1; & |\mu(t) - x(t+1)| \leq \alpha c \\ 0; & |\mu(t) - x(t+1)| > \alpha c \end{cases} \quad (8)$$

3. 단봉 정규 모델의 근사화

3.1 평균의 학습에 대한 근사화




그림 1 σ 이 5, α 가 0.005인 경우 Δs 에 따른 $\frac{\Delta\mu_k(t+1)}{\alpha}$ 의 변화(실선)와 근사(점선)




그림 2 σ 에 따른 $\frac{h}{\alpha}$ 의 변화

각 변수들의 학습은 기본적으로 재귀 필터(recursive filter) 형태를 지니는 가중평균에 의해 학습된다. 식 (5)를 변형하면 다음과 같이 정리된다.

$$\Delta\mu_k(t+1) = \mu_k(t+1) - \mu_k(t) = \rho(x(t+1) - \mu_k(t)) \quad (9)$$

이 때 $x(t+1) - \mu_k(t)$ 를 Δs 로 정의하고 Δs 에 따른 $\Delta\mu_k(t+1)/\alpha$ 의 변화를 살펴보면 그림 1과 같은 형태를 띠게 되는데 0을 제외한 $|x(t+1) - \mu_k(t)| < 3\sigma_k$ 의 영역에서 0이 아닌 값을 갖는다.

$\Delta\mu_k(t+1)$ 를 그림 1의 점선과 같은 펄스 모형의 그래프로 근사하기 위한 펄스의 높이 h는 해당 구간을 적분함으로써 얻을 수 있다.

$$h = \frac{1}{2} \int_{-3\sigma}^{3\sigma} |\Delta\mu_k(t+1)| d(\Delta s) \quad (10)$$

그림 2에 σ 에 따른 h값이 도시되어있는데 일정 범위 내에서는 h값이 σ 에 관계없이 일정하다. 따라서 σ 의 의미를 가지는 범위 내에서는 $h/\alpha \approx 0.132$ 으로 근사될 수 있다. 식 (5)는 다음과 같이 근사된다.

$$\mu_k(t+1) = \begin{cases} 0 < \Delta s < 3\sigma; & \mu_k(t) + H \\ -3\sigma < \Delta s < 0; & \mu_k(t) - H \\ otherwise; & \mu_k(t) \end{cases} \quad (11)$$

3.2 분산의 학습에 대한 근사화

분산에 대한 근사화도 앞 절의 평균의 학습에 대한 근사와 동일한 순서로 진행된다. 식 (6)은 다음과 같이 정리된다.

$$\Delta \Sigma_k(t+1) = \sigma(t+1)^2 - \sigma(t)^2 = \rho(\Delta s^2 - \sigma(t)^2)$$

$$\Delta \sigma^2 + 2\sigma \Delta \sigma - \rho(\Delta s^2 - \sigma(t)^2) = 0$$

이는 $\Delta \sigma$ 에 대한 2차식이므로

$$\Delta \sigma = -\sigma \pm \sqrt{\sigma^2 + \rho(\Delta s^2 - \sigma(t)^2)} \quad (12)$$

위와 같은 결과를 얻게 된다. Δs 에 따른 $\Delta \sigma$ 의 변화를 그림 3을 통해 살펴보면, 식 (5)의 그래프를 근사화한 것과 같은 방법으로 $[-3\sigma, -\sigma], [-\sigma, \sigma], [\sigma, 3\sigma]$ 구간을 나누어 펄스 형태로 근사할 수 있다.(그림4,5) 그 결과 식 (6)은 다음과 같이 정리 된다.

$$\sigma_k(t+1) = \begin{cases} -\sigma < \Delta s < \sigma & ; \sigma_k(t) - H \\ -3\sigma < \Delta s < -\sigma \text{ or } \sigma < \Delta s < 3\sigma & ; \sigma_k(t) + H' \\ otherwise & ; \sigma_k(t) \end{cases} \quad (13)$$

4. 근사화된 다봉 배경모델링 및 물체 검출

이번 절에서는 앞 절에서 근사화된 단봉 모델을 다봉 모델로 확장한다. 이는 기본적으로 K개의 단봉 모델들이 새로운 입력을 경쟁적으로 학습하는 과정으로 볼 수 있다. 식 (4)는 위의 결과를 이용해 다음과 같이 정리된다.

$$\Delta w_k(t+1) = w_k(t+1) - w_k(t) = \alpha(p(w_k|x(t+1)) - w_k(t)) \quad (14)$$

$$w_k(t+1) = \begin{cases} \Delta s < 3\sigma & ; (1-\alpha)w_k(t) + \alpha \\ otherwise & ; (1-\alpha)w_k(t) \end{cases} \quad (15)$$

새로운 입력 x(t)가 들어왔을 때 2개 이상의 분포에 해당되는 경우에는 승자독식(winner take all) 규칙을 사용하여 Δs_j 가 가장 작은 분포만을 학습시켜준다. 이렇게 학습된 w_k 들은 매 장면마다 정규화된다. 만약 새로운 입력에 대해 해당하는 분포가 없다면 w_k/σ_k 가 가장 작은 분포가 새로운 입력을 사용하여 초기화된다.

5. 정수 연산의 이용

위에서 정리한 결과에 더하여 각 식은 정수 연산에 이용함으로써 처리 속도가 향상된다. 이는 실수 연산 기능이 없는 저사양의 중앙처리장치를 가지는 환경에도 동일한 성능을 유지하게 한다.

3절의 결과를 통해 근사된 알고리즘에서는 기존의 확




그림 3 $\alpha=0.005$ 인 경우 Δs 에 따른 $\Delta \sigma$ 의 변화




그림 4 σ 에 따른 $\frac{h'}{\alpha}$ 의 변화




그림 5 σ 에 따른 $\frac{h''}{\alpha}$ 의 변화

률값에 따라 학습되던 변수들이 상수 H의 가산과 감산만으로 학습됨을 보였다. 환경 변화에 신속히 적응하기 위해서 학습 비율을 높임과 동시에 계산을 간편하게 하기 위해 모든 경우의 학습값을 1로 고정하였다. 따라서 위의 식들은 다음과 같이 정리된다.

$$\mu_k(t+1) = \begin{cases} 0 < \Delta s < 3\sigma & ; \mu_k(t) + 1 \\ -3\sigma < \Delta s < 0 & ; \mu_k(t) - 1 \\ otherwise & ; \mu_k(t) \end{cases} \quad (16)$$

$$\sigma_k(t+1) = \begin{cases} -3\sigma < \Delta s < -\sigma \text{ or } \sigma < \Delta s < 3\sigma & ; \sigma_k(t) + 1 \\ -\sigma < \Delta s < \sigma & ; \sigma_k(t) - 1 \\ otherwise & ; \sigma_k(t) \end{cases} \quad (17)$$

$$w_k(t+1) = \begin{cases} |\Delta s_k| < 3\sigma, & \\ |\Delta s_k| < |\Delta s_j| \text{ for } \forall j & ; w_k(t) + K - 1 \\ otherwise & ; w_k(t) - 1 \end{cases} \quad (18)$$

$$B(x(t)) = \begin{cases} \sum_{j=1}^K w_j > T \text{ for } j, |\Delta s_j| < 3\sigma_j & ; 1 \\ otherwise & ; 0 \end{cases} \quad (19)$$

장면당 학습값을 1로 고정시킨 식들은 3절의 방법과 비교하자면 ρ 를 7.6배 해준 경우로 볼 수 있다. 이러한 학습 속도의 증가로 인해 학습 결과가 수렴하지 못하고 불안정하게 진동할 것으로 예상할 수 있지만 1씩 변화하기 때문에 진동의 범위는 1 이하의 값을 가지며, 이는 3σ 의 범위를 벗어나지 않으므로 실제 학습과 물체 검출은 안정적으로 이루어짐을 확인할 수 있다.

기존의 방법에서 w_j 는 정규화 과정이 필요했지만 제안하는 방법에서는 하나가 증가하면 다른 쪽이 감소하

는 처리를 통해 그 합이 일정 상수를 이루도록 하였다. 예를 들어 승자의 경우 K-1 만큼 증가하게 되지만 나머지 K-1개의 분포는 1씩 감소하도록 하였다. 이때 기준 T 이상인 w_j 들만이 배경에 해당되는 분포가 된다. 이를 통해 정규화 과정과 w_k/σ_k 에 따라 순차적으로 배열하는 과정을 정수 연산만으로 처리하였다.

6. 실험 결과

실험을 통해 stauffer와 제안하는 알고리즘의 정확성과 처리속도를 비교하였다. 그림 6과 8에서 사용한 영상은 야외 공원을 웹카메라로 촬영한 것이다. 일사량의 변화와 바람에 따라 흔들리는 나뭇가지, 분수의 움직임과 행인의 이동을 포함한 실험 영상은 배경 모델링의 정확도와 물체 검출의 안정성을 드러낸다. 그림 6에 나타나있는 검출 영상들은 비교를 위해 후처리를 거치지 않은 영상이다. 이 결과들은 영상처리기술을 통해 검출 정확도를 향상시킬 수 있다. 검출 결과를 비교해볼 때 제안하는 방법은 조명변화나 그림자 변화, 물을 내뿜는 분수 및 흔들리고 있는 나뭇가지로 인한 잡음들을 다분 분포를 이용해 효과적으로 모델링하고 있음을 확인할 수 있다.

표 1은 표시된 점에서 모델링된 다분 분포를 나타내고 있다. 각각의 매개변수 값을 살펴보면 모델링된 기존의 방법으로 학습한 분산의 값을 보면 초기치인 40 근처에 머물러있는 것을 볼 수 있는데 이는 학습 속도가 느리기 때문이다. 제안하는 방법은 근사화와 더불어 학습 속도를 향상시켰기 때문에 배경의 분산의 변화를 효과적으로 학습하였고 그 결과 표준 편차값이 초기치 10부터 다양하게 분포되어있는 것을 확인할 수 있다.

그림 8과 표 2는 넓은 야외 영역에 대한 영상을 이용한 실험 결과이다. 흔들리는 나무와 조명의 변화를 포함하는 환경에서 비교적 긴 시간의 실험을 통해 물체 검출의 안정성을 검사하였다. 실험 결과 장시간의 영상에서도 안정적인 물체 검출 성능을 확인할 수 있었고 기존 방법과의 비교에서도 비슷한 성능을 나타내었다. 검출 결과를 비교해 보면 두 방법 모두 환경 변화에 강인하게 주요 물체를 검출한 것을 확인할 수 있다. 기존 방법과 비교해 볼 때 제안하는 방법은 빠른 학습 속도로 인하여 환경 변화에 더 신속히 적용하는 장점을 가진다. 그러나 동일한 이유로 인해 색상 분포가 균일한 물체의 경우 동일 입력이 계속되는 화소에서는 물체의 일부가 검출되지 않는 경우가 발생한다.

인텔 펜티엄 3GHz 환경에서 320×240 영상을 이용해서 실험한 결과 기존 알고리즘은 초당 15-20 장면을 처리하였고 제안하는 방법은 63-64 장면을 처리하였다. 물체 검출 결과를 비교했을 때 제안하는 방법은 정확도 면

에서도 기존 알고리즘과 비슷한 수준을 보인다. 그러나 물체 검출 속도에서는 3배 이상의 향상된 결과를 보였다.




그림 6 위에서부터 아래로 150, 550, 950번째 장면에서 물체 검출 영상. (열 B가 [5]의 물체 검출 결과 영상, 열 C가 제안하는 방법의 결과 영상)




그림 7 그림 6의 표시된 점에서 시간에 따른 밝기값 x(t)(점선)와 $\mu_j(t)$ (실선, K=3)의 변화

표 1 그림 6의 표시된 점에서 학습된 결과 비교(제안하는 방법의 w는 비교의 편의를 위해 정수값을 상대적 실수로 변환함)

장면 번호	기존 방법[5]			제안하는 방법		
	μ_j	σ_j	w_j	μ_j	σ_j	w_j
150						
분포 1	164.7	38.9	0.91	187	15	1
분포 2	194.9	40	0.02	-	-	-
분포 3	53.98	39.9	0.05	-	-	-
550						
분포 1	164.9	39.3	0.82	168	5	1
분포 2	194.9	40.0	0.11	-	-	-
분포 3	130.9	39.9	0.06	-	-	-
950						
분포 1	164.7	38.9	0.91	172	15	0.91
분포 2	194.9	40.0	0.025	180	3	0.05
분포 3	53.99	39.9	0.055	40	12	0.002




그림 8 위에서부터 아래로 6700, 7900, 8500번째 장면에서 물체 검출 영상. (열B가 [5]의 물체 검출 결과 영상, 열 C가 제안하는 방법의 결과 영상)

표 2 그림 8의 표시된 점에서 학습된 결과 비교(제안하는 방법의 w 는 비교의 편의를 위해 정수값을 상대적 실수로 변환함)

장면 번호	기존 방법[5]			제안하는 방법		
	μ_j	σ_j	w_j	μ_j	σ_j	w_j
6700						
분포 1	85.0	42.1	0.00	145	5	0.00
분포 2	145.1	39.8	0.01	131	3	0.99
분포 3	114.5	43.2	0.98	114	23	0.00
7900						
분포 1	83.0	40.0	0.23	53	43	0.00
분포 2	145.1	39.8	0.00	111	3	0.70
분포 3	113.8	41.4	0.76	62	3	0.30
8500						
분포 1	79.8	41.2	0.35	43	23	0.00
분포 2	45.2	40.1	0.62	111	3	0.00
분포 3	113.8	41.4	0.03	62	4	1.00

7. 결론

본 논문에는 기존의 가우시안 혼합 모델을 이용한 배경 모델링 방법의 근사하여 단순한 상수 증감연산의 형태의 효과적인 알고리즘을 제안하였다. 실험결과 제안하는 방법은 기존의 혼합 정규 분포 방법의 정확도와 안정성을 유지하면서도 현저히 상승된 처리속도를 보였다. 이는 고화질의 영상의 처리나 다른 여러 복잡한 분석 및 인식 알고리즘과 함께 사용되는 경우, 또는 실수 연산의 어려움을 갖는 환경에서 실시간 배경 모델링 및 물체 검출에 유용하게 사용될 수 있다.

그러나 제안하는 방법 향상된 학습 속도로 인하여 동일한 색을 가지는 물체의 이동이나 멈춘 물체의 경우 더 신속하게 배경으로 학습된다. 이러한 한계는 고정된

학습속도에 기인한 것이며 이는 검출 방법의 결합을 통해 개선된다.[8,12].

참고 문헌

- [1] W. Hu, T. Tan, L. Wang, S. Maybank, "A Survey on Visual Surveillance of Object Motion and Behaviors," IEEE Trans. On systems, man, and cybernetics, pp. 334-351, 2004.
- [2] R. T. Collins, A. J. Lipton, T. Kanade, H. Fujiyoshi, D. Duggins, Y. Tsin, D. Tolliver, N. Enomoto, O. Hasegawa, P. Burt and L. Wixson "A System for Video Surveillance and Monitoring," Carnegie Mellon University, 2000.
- [3] I. Haritaoglu, D. Harwood, and S. Davis, "W4: real time surveillance of people and their activities," IEEE Trans. Pattern Anal. Mach. Intell., pp. 809-830, 2000.
- [4] C. R. Wren, A. Azarbayejani, T. Darrell, and A. P. Pentland, "Pfinder: Real-time tracking of the human body," IEEE Trans. Pattern Anal. Mach. Intell., Vol.19, No.7, pp. 780-785, 1997.
- [5] C. Stauffer, W. Grimson, "Adaptive background mixture models for real-time tracking," Proc. of the IEEE International Conference on Computer Vision and Pattern Recognition, pp. 246-252, 1999.
- [6] A. Elgammal, R. Duraiswami, D. Harwood, and L. S. Davis, "Background and foreground modeling using nonparametric kernel density for visual surveillance," Proc. IEEE, Vol.90, pp. 1151-1163, 2002.
- [7] K. Toyoma, J. Krumm, B. Brumitt, and B. Meyers, "Wallflower: Principles and Practice of Background Maintenance," Proc. IEEE ICCV, pp. 255-261, 1999.
- [8] Monari, E., Pasqual, C, "Fusion of background estimation approaches for motion detection in non-static backgrounds," AVSS, pp. 347-352, 2007.
- [9] A. Manzanera, J. C. Richefeu, "A robust and computationally efficient motion detection algorithm based on $\Sigma-\Delta$ background estimation," ICVGIP, 2004.
- [10] P. KaewTraKulPong and R. Bowden, "An Improved Adaptive Background Mixture Model for Real-Time Tracking with Shadow Detection," Proc. European Workshop Advanced Video Based Surveillance Systems, Sept. 2001.
- [11] D. Lee, "Effective Gaussian Mixture Learning for Video Background Subtraction," IEEE Trans. Pattern Anal. Mach. Intell. Vol.27, pp. 827-832, 2005.
- [12] D. Park, H. Byun, "Nonstatic background modeling including high traffic region," Machine Learning and Cybernetics, pp. 3423-3427, 2008.