

HMM 분할에 기반한 교통모니터링

남기환*, 배철수*, 정주병**, 나상동***

*관동대학교 · **KT, ***조선대학교

An HMM-Based Segmentation Method for Traffic Monitoring

Kee-hwan Nam*, Cheol-soo Bae*, Joo-Byung Jeung**, Sang-Dong Ra***

*Kwandong University, **KT, ***Chosun University

E-mail : keelight@empal.com

요 약

본 논문에서는 HMM(Hidden Markov Model)방법에 기초하여 전경과 배경영역 뿐만아니라 그림자 까지도 분할 할 수 있는 교통모니터링 방법을 제안하였다. 움직이는 물체의 그림자는 시각적 추적을 방해하기 때문에 이러한 문제점을 해결하기 위한 방법으로 각 화소나 영역을 3개의 카테고리 즉, 그림자, 전경, 배경물체로 분할하였다. 교통 모니터링 영상의 경우, 실험결과를 통해 제안된 방법의 효율성을 입증 할 수 있었다.

ABSTRACT

In this paper proposed a HMM(Hidden Markov Model)-based segmentation method which is able to model shadows as well as foreground and background regions. Shadow of moving objects often obstruct visual tracking. We propose an HMM-based segmentation method which classifies in real time each objects. In the case of traffic monitoring movies, the effectiveness of the proposed method has been proven through experimental results

키워드

traffic sign recognition, vision system, image classification

1. 서 론

고속도로와 각종 도로의 증가로 인한 사고의 위험을 감소시키고, 도로를 이용하는 사람들에게 안전성을 부각시키기 위해 도로교통에 관련된 데이터들을 분류하고 분석하는 작업의 중요성이 점점 증대되고 있다. 이동하는 물체를 분류하는데 있어서 시각적 추적을 방해하는 주된 원인은 오류를 유발시키게 하는 주변의 배경모양들이다. 예를 들어 추적하는 물체외의 기타 장애물들은 전경의 목표물체를 인지하는 것을 방해할 수 있다[1]. 따라서 정확한 목표물 추적을 위해 배경 픽셀에서 전경 픽셀을 구별하는 이미지 분할 방법으로 이동 객체의 강건성(robustness)을 증가시키는 방법이 연구되고 있다[2][3][4][5]. 그러나 교통 모니터링 시스템과 같은 응용에 있어서, 가장 큰 문제점이 차량의 그림자를 분할하는 것으로 이것은 배경영역의 강건성을 증가시키는 기술로는 잘 해결되지 않는다. 또 다른 이미지 분할 연구방법으로 배경추출과 인터

프레임(interframe) 분할이 있다[6][7]. 배경 추출방법은 배경이 전혀 움직이지 않는 다는 가정을 기초로 하기 때문에 실제 야외 시스템에는 적용이 어려우며, 차량과 같이 움직이는 물체의 그림자를 없앨 수 없다는 단점이 있다. 반면에 인터프레임 분할은 그림자가 결과 이미지의 윤곽선으로 나타난다는 이점이 있으나 차량 내부와 동질한 부분이 배경영역으로 나타나며, 이또한 그림자를 구분하기 힘들다.

이에 본 논문은 교통모니터링 시스템에 있어 차량의 그림자도 분할 할 수 있는 방법으로 HMM에 기반한 새로운 분할 방법을 제안한다. 제안된 방법은 학습과 분할의 단계로 이루어지며, 학습 단계에서는 추적과정에서 이미지의 HMM매개변수를 EM(Expectation-Maximization)알고리즘을 통해 인지한다. 또한 분할 단계에서는 실제 영상에서 전경(F), 배경(B), 그림자(S) 세 개의 영역으로 분할하게 된다.

II. 강건한 분할방법

강건한 차량 추적을 위해 제안한 방법은 배경물체와 그림자로부터 전경물체와의 분할을 정확하게 행해야 한다. 따라서 자동차의 그림자를 포함한 세 가지 다른 카테고리 즉 전경(F), 배경(B), 그림자(S) 분할하기 위하여 HMM을 적용하였다. HMM의 사용은 다음과 같은 두 가지 이점이 있다.

첫째, HMM은 순간연속성 즉, 시간주기동안 어떠한 카테고리에 속하는 픽셀을 결합하기에 적합한 모델이다. 만약 주어진 시간에서 픽셀이 전경(차량)에 속한다면 픽셀은 다음 단계에서도 전경에 속할 것이다. 또한 카테고리 속의 강도차이가 작을 때, 강도에 근거한 기존의 배경 모델은 낮은 수행율을 보인다. 각 카테고리의 순간연속성 중요하다는 것을 고려하면, 카테고리속 강도의 차이가 거의 없을 경우 시간 축에 따라 각 카테고리의 순간연속성을 결합하기 위해 HMM을 사용하게 된다. 1D HMM은 2D HMM보다 적은 표본 매개변수가 필요하고, 이로 인해 학습에 필요한 계산량을 줄일 수 있다.

둘째, 학습을 위해 특별한 데이터를 제공할 필요가 없다. 이것은 HMM가 보통의 이미지 화면에서 보이지 않는 부분의 배열 상태를 인지할 수 있기 때문이다. 이 특성은 교통 모니터링 영상에서 특히 중요하다.

배경, 전경, 그림자의 강도 분포는 서로 중복되는 부분이 상당히 많기 때문에, 이들의 분포를 개별적으로 인지하기 위한 방법을 찾기 어렵다. 따라서 HMM의 사용과 함께 세가지 카테고리를 더욱 명확하게 분할하기 위한 방법으로서 강도(intensity)와 단파 웨이블릿 계수를 사용하였다.

III. 실험

3.1 HMM에 기반한 방법

교통 모니터링에 적합한 모델을 설계하기 위하여 그림1에서처럼 주어진 픽셀에서 각각 전경(F), 배경(B), 그림자(S)의 세 가지 카테고리의 강도변화를 조사하였다. 그림1에서와 같이 혼합한 교통상황의 경우는 제외한다면, 배경분포는 주어진 픽셀에서 주된 영역을 점유하며, 그림자는 배경보다 낮은 강도(intensity)를 나타낸다. 그러나 B, S, F의 분포는 각각 분리되어있지 않고, 부분적으로 서로 중복되어 있다. 그림1을 보면, 그림자와 배경의 분포는 가우시안 값(Gaussian densities)에 의해 평가될 수 있다. 전경에 있어 가장 합리적인 모델은 일정한 확률 밀도이다. 다음으로 정확한 분류를 위해 단파 웨이블릿 계수를 이용하였다. 강도를 다뤘던 방법과 똑같이 동일한 확률 밀도로써 가우시안 밀도와 전경의 분포에 의해 배경과 그림자의 분포를 평가한다. 따라서, 각 분포는 2차원의 Gaussian 조합 밀도로써 만들어지며 이 평가는 학습 계산시간을 줄이는데 기여한다.




그림 1. 전경(F), 배경(B), 그림자(S)의 강도 값

제안된 방법은 각각의 픽셀위치에서 HMM 매개변수를 배분할 수 있다. HMM영역에서 같은 크기(k×k픽셀)의 중복되지 않는 작은 영역이 HMM매개변수를 가진다고 가정하고, 학습단계에서, 각 HMM영역의 모델 매개변수는 학습 장면으로부터 평가된다. 그리고 분할단계에서, 일련의 최적의 상태가 각 HMM 영역에서 발견되기 때문에 계산량을 줄일 수 있다. 또한 강도 관측에 있어서, 잡음을 줄이기 위해 그레이레벨 대신에 k×k의 출력값을 이용하였다. 그러나 실험에서는 오직 강도관측을 사용해서 그림자와 어두운 색상의 차량을 구별하는 것이 어려웠다.

그림자로부터 확실하게 전경의 물체를 구별하기 위해서 두 번째 관측으로 단파 웨이블릿 계수를 사용했다. 이 관측의 도입은 단파 bands속 웨이블릿 계수의 변동이 S와 B에는 작고, F에는 클 것이라는 가정에 기초한다. 이것은, 전경의 물체가 일반적으로 초점을 벗어난 배경과 그림자영역보다 뚜렷이 초점이 맞춰있고, 물체 속에 더 많은 세부영역을 가지고 있기 때문이다.

3.2 모델의 이용

HMM은 상태가 다른 모든 상태에서 하나의 단계로 도달될 수 있는 모델로 인식된다. 이 추측의 타당성은 학습매개파라미터의 검사로 실험되었다. 실험을 위하여, 모델 매개파라미터를 인지하기 위한 30초동안의 고속도로 장면(그림1d의 프레임 이미지)을 이용하였으며, 매개변수는 왼쪽 차선의 가운데(전체 장면동안 F와 S사이의 상태변화가 거의 없는 곳) HMM영역에서 평가되었다. 학습된 순간은 $\mu_{b1}=80.143, \sigma_{b1}=10.244, \mu_{s1}=68.2294, \sigma_{s1}=44.9672$ 이다. 두 개의 학습된 가우시안 밀도와 하나의 동일한 강도는 그림2a에 나타내었다. 그림2b는 각각 $\mu_{b1}, \sigma_{b1}, \mu_{s1}, \sigma_{s1}$ 에 의해 정합이 잘된 정보를 보여준다. 학습된 상태변화 행렬은 다음 식과 같다.

$$A = \begin{pmatrix} 0.986032 & 0.0129378 & 0.00102398 \\ 0.0138807 & 0.884321 & 0.101796 \\ 0.033774 & 0.0253723 & 0.941252 \end{pmatrix}$$




그림 2. 파라미터 학습결과

IV. 실험 결과

실험은 afs=0으로 고정된 모델에서 얻어졌으며, 고속도로에서 획득한 30초 연속 장면이 실험에 사용되었다. 이 연속장면의 교통량과 조명상태는 많이 변하지 않더라도, B, S, F에 쓰인 지속기간은 서로 다를 수도 있다. 실험 결과는 모든 카테고리가 관측되었던 오른쪽 차선의 영역은 무시하였다. 실험에 사용한 영역은 18×28 HMM영역으로 구성되었고, 각 영역은 4×4 픽셀 크기(그림1d)이다. 차량의 종류는 대강 밝은 색, 어두운 색, 회색으로 구분하여 적용하였다.

먼저, 밝은 색의 차량 살펴보면 그림3의 첫 번째 줄은 3픽셀 간격의 6개의 연속적인 밝은 색 차의 이미지를 나타내며, 분류 결과는 두 번의 관측이 실행된 두 번째 줄에 보여진다. 밝은 색의 차는 다른 카테고리과 확연히 구분되었는데 이것은 밝은 색의 차가 배경과 그림자로부터 명확하게 두드러져 보임을 의미한다. 어두운 색의 차도 그림자의 강도와 다르지 않은 강도의 차로 추측한다. 어두운 색의 차는 특히 추적자로 하여금 쉽게 그림자와 혼란시킬 수 있기 때문에 문제가 있을 수 있다.

오직 강도 관측만 이용하는 HMM은 거친 방법에서 밝은 색의 차의 선명도를 감안하지만, 모델은 어두운 색의 차에게는 잘 적용되지 않는다. 어두운 색의 차량 부분은 더 쉽게 그림자로 분류되기 쉽다. 그 이유는 다른 카테고리의 분포가 중복되기 때문이다. 다시 말해서, F(어두운 색의 차)에 속하는 HMM영역의 gray-value는 그림자 분포에 따라 감소하며, 전경의 확률은 아주 낮다. 두 번째 관측의 도입은 전경 물체의 분할에 공헌한다. 두 번째 관측기호로 구성된 2차원의 특징벡터로, 서로 다른 카테고리의 밀도가 중복되는 영역 비율은 1차원의 특징벡터의 영역 비율보다 작아진다. 따라서, Bayes 효율성을 입증하기 위해서 오직 강도(inte-

nsity)값만 이용한 경우와, 강도와 함께 wavelet계수를 이용한 경우의 같은 영역의 장면을 실험하였다.

어두운 색차(3번째 줄)의 1차원, 2차원 특징벡터의 결과는 각각 4번째, 5번째 줄에서 보여진다.

4번째 줄에서, 지붕이나 램프와 같은 밝은 일부 분만이 전경으로 분류되었다. 다수의 어두운 색 차들은 4번째 줄보다는 다섯 번째 줄에서 더욱 눈에 띈다. 6번째 줄은 또한 같은 이미지의 결과이다. 5번째 줄과의 차이는, 최적기준으로써 다른 값을 채택했기 때문이다.




그림 3. 실험 결과

배경중속 방법을 결합함으로써, 결과는 개선되었다. 회색차에 대한 몇몇 결과는 그림3의 나머지 이미지에 나타난 것이다. 그 이미지들은 7번째 줄에서 보여진다. 각각의 HMM영역에 근거한 결과는 8번째 줄에, HMM영역 중에서 배경중속의 결과는 마지막 줄에 나타내었다. 잘못된 분류와 유사한 문제는 회색차에서도 일어났다. 그 이유는 회색차의 분포가 배경의 분포와 중복되기 때문이다.

V. 결 론

본 논문은 차량 모니터링 방법으로 전경과 배경, 그림자를 분할할 수 있는 HMM에 기초한 영상 분할방법을 제안하였으며, 실험상에서 제안한 방법의 효율성을 입증할 수 있었다. 또한, 실제상황에서 추적자가 상태파악을 가능하게 해준다. 왜냐하면, 상태파악은 오직 지난 관측에 근거하고, 파악 기준은 반복적으로 정의되기 때문이다. 다른 접근 방법과 다른 또다른 이점은 실험중에 특별한 데이터를 제공할 필요가 없다는 것이다. HMM매개변수는 원래의 비디오 영상에서 EM 알고리즘에 의해 평가된다. 제안된 방법은 특히 전경을 추출하는데 유용하며 상태 파악 알고리즘은 배경종속 분류를 수행하려고 개발되었다. 또한 배경종속의 방법과 결합함으로써 상당히 개선된 결과를 얻을 수 있었다.

향후 연구과제로서 어두운 차량에 분할방법의 보완과 복잡한 도로교통 상황에서의 적용방법 그리고 개선된 필터의 적용방법 등을 들 수 있다.

참고문헌

[1] L.E. Baum, T. Petrie, G. Soules, and N. Weiss, "A Maximization Technique Occu-

ring in the Statistical Analysis of Probabilistic Functions of Markov Chains," *Ann. Math. Statistics*, vol. 41, no. 1, pp. 164-171, 1970.

[2] A. Baumberg and D. Hogg, Learning Flexible Models from Image Sequences," *Computer Vision-ECCV '94*, J.-O. Eklundh, ed., Springer-Verlag, vol. 1, pp. 299-308, 1994.

[3] A. Blake and M. Isard, *Active Contours*. London: Springer, p. 352, 1998.

[4] I. Daubechies, *Ten Lectures on Wavelets*. Philadelphia: SIAM, 1992.

[5] A.P. Dempster, N.M. Laird, and D.R. Rubin, "Maximum Likelihood from Incomplete Data via the EM Algorithm," *J.R. Statistics Soc.*, vol. B, no 39, pp. 1-38, 1977.

[6] G.D. Forney, "The Viterbi Algorithm," *Proc. IEEE*, vol. 61, pp. 268-278, Mar. 1973.

[7] I. Haritaoglu, D. Harwood, and L.S. Davis, "W4 -a Real Time System for Detection and Tracking People and their Parts," *Proc. Third Face and Gesture Recognition Conf.*, pp. 222-227, 1998.