

차량 감시영상에서 그림자 제거를 통한 효율적인 차종의 학습 및 분류

신 욱 선[†] · 이 창 훈^{††}

요 약

일반적으로 감시영상에서 움직이는 물체들은 배경빼기 혹은 프레임 차를 이용하여 추출된다. 하지만 객체에 의해서 만들어지는 그림자는 심각한 탐지의 오류를 야기시킬 수 있다. 특히, 도로 상에 설치된 감시카메라로부터 획득된 영상으로부터 차량 정보를 분석할 때, 차량에 의해서 생성되는 그림자로 인하여 차량의 모양을 왜곡시켜 부정확한 결과를 만든다. 때문에 그림자의 제거는 감시 영상 내에서의 정확한 객체 추출을 위해서 반드시 필요하다. 본 논문은 도로감시영상 내에서 움직이는 차량의 차종판별 성능을 향상시키기 위한 움직이는 객체 내에 만들어지는 그림자를 제거한다. 제거된 객체의 영역은 소실점을 이용하여 3차원 객체로 피팅(Fitting)한 후 추정된 데이터를 감독 학습하여 원하는 차종 판별결과를 얻는데 사용한다. 실험은 3가지 기계학습 방법(IBL, C4.5, NN(Neural Network))을 이용하여 그림자의 제거가 차종의 판별성능에 미치는 결과의 평가한다.

키워드 : 그림자 제거, 주성분 분석, 지능화된 교통시스템, 차종분류, 배경빼기, 기계학습

Efficient Learning and Classification for Vehicle Type using Moving Cast Shadow Elimination in Vehicle Surveillance Video

Wooksun Shin[†] · Changhoon Lee^{††}

ABSTRACT

Generally, moving objects in surveillance video are extracted by background subtraction or frame difference method. However, moving cast shadows on object distort extracted figures which cause serious detection problems. Especially, analyzing vehicle information in video frames from a fixed surveillance camera on road, we obtain inaccurate results by shadow which vehicle causes. So, Shadow Elimination is essential to extract right objects from frames in surveillance video. And we use shadow removal algorithm for vehicle classification. In our paper, as we suppress moving cast shadow in object, we efficiently discriminate vehicle types. After we fit new object of shadow-removed object as three dimension object, we use extracted attributes for supervised learning to classify vehicle types. In experiment, we use 3 learning methods (IBL, C4.5, NN(Neural Network)) so that we evaluate the result of vehicle classification by shadow elimination.

Key Words : Shadow Elimination, PCA, ITS, Vehicle Classification, Background Subtraction, Machine Learning

1. 서 론

최근 들어 무인 감시 시스템, 보안 출입 관리, 공장 자동화, 지능형 교통 시스템과 같이 이동 물체를 탐지하는 영상 처리 기술의 응용 분야가 확장되면서 동영상으로부터 이동하는 물체를 검출하여 분석하고 이를 추적하는 응용 분야의 필요성이 점점 증대되고 있다. 특히, 경제 성장, 산업사회의 고도화와 함께 교통량이 급속히 증가함에 따라 현존하는 교

통자원을 효율적으로 활용할 수 있는 지능화된 교통 시스템(ITS: Intelligent Transports System)에 대한 관심 또한 높아지고 있다[1]. 하지만 고성능의 ITS는 추출한 객체로부터 교통 혼잡도나 차량에 관련된 정보 등 보다 고차적인 정보를 얻을 수 있어야 한다. 도로상에 설치된 감시 카메라로부터 얻어진 영상에는 많은 유용한 정보를 포함하고 있고, 이러한 정보를 자동으로 추출하여 이용하는 것은 교통정보 자동화 시스템에서 매우 중요하다[2]. 즉, 교통 감시 영상으로부터 차량의 올바른 주행, 차선 변경 및 사고 유무 탐지 등 유용한 정보를 얻기 위해서는 차선, 차량, 차량의 이동 방향 등 이외의 다양한 요소의 정보의 추출이 필요하다. 도로상

[†] 준 회원 : 건국대학교 컴퓨터공학과 박사수료

^{††} 종신회원 : 건국대학교 컴퓨터공학과 교수

논문접수 : 2007년 8월 20일, 심사완료 : 2007년 11월 20일

의 차량의 차종 판별은 차량의 소통량과 더불어 중요한 정보로서 사용될 수 있어 기하학적인 형태를 이용한 정확한 차량의 차종 판별은 중요하다[3].

감시영상 내의 차량 객체는 정확한 차량 및 차종의 판별을 위해서 진행방향, 차량의 폭, 길이, 높이를 추정하기 위해서 육면체 형태의 3차원 모델을 이용하여 차량의 피팅을 수행한다. 이를 통하여 차량을 기하학적으로 표현할 수 있는 추상화된 형태의 객체로 표현할 수 있어 차량의 입체적인 모양을 추정할 수 있다. 피팅을 위해서는 소실점과 차량의 진행방향을 계산하여야만 하고, 소실점은 차량의 이동궤적과 차선의 검출을 통해서, 그리고 차량의 진행방향은 영상 프레임간의 분석을 통해서 추정이 가능하다. 하지만 그림자가 올바르게 제거되지 않는다면, 차량의 객체에 포함되어있는 그림자가 다른 차량의 객체와 겹쳐질 경우 하나의 객체로 판별될 수 있기 때문에 차량의 판별을 어렵게 만들고, 차량 내에 포함된 그림자는 왜곡된 객체를 만들어 피팅을 통한 객체의 모양도 부정확해지기 때문에 차량의 분석을 어렵게 만든다[4-6]. 따라서 그림자 제거는 특히 영상 기반의 차량 분석 관련 응용에 있어 중요하다.

배경프레임으로부터 객체를 추출해 내는 방법은 오래 전부터 많은 연구를 해왔고, 동영상으로부터 움직이는 객체를 얻어내는 가장 일반적인 방법이다[7]. 추출된 객체의 내부에 그림자를 제거하기 위해 불확실성에 관점으로 접근하는 통계적인 방법[8-10]을 이용하였다[11-13]. 추출된 객체는 색 정보를 가지는 전경(Foreground)과 배경(Background) 영상에 대한 객체 영역의 내의 픽셀에 대한 RGB색 공간의 특성을 분석한다. RGB색 공간의 3개의 색 요소들은 서로 연관성을 가지므로 이들 간의 연관성을 최소화 할 수 있는 새로운 색 공간을 만들기 위해서 KLT(Karhunen Løve Transform)를 이용하는 주성분분석(PCA: Principle Component Analysis) 기법을 사용한다[14]. 그림자, 배경, 전경 영상의 특징들 간의 중요한 정보는 주성분 분석에 의해서 추출된다. 주성분을 분석하면 그림자와 배경이 유사한 방향성을 가지며 거의 일직선 상에 놓여지지만 날씨의 조건과 차량의 색에 따라 색 공간상에서 약간 다른 분포의 특징들을 보임을 발견할 수 있고 이런 분포의 패턴을 이용하여 효율적인 그림자 제거가 가능하다. 그리고, 동영상으로부터 추출된 도로상의 차량 객체는 정확한 차량 및 차종의 판별을 위해서 진행방향, 차폭, 길이, 높이를 추정할 수 있는 육면체 형태의 3차원 모델을 이용하여 2차원 상의 x-y평면상에 6개의 점으로 차량 객체를 기하학적으로 표현하기 위한 피팅을 수행한다[5,15].

본 논문은 추출된 객체에 대하여 그림자를 제거하여 피팅한 후 얻어진 데이터를 학습하여 효율적으로 차종을 분류한다. 추출된 모델의 속성 값들을 감독 학습시켜 각 차종 별 특성을 찾아내어 차종 분류에 사용할 수 있다. 학습에 사용된 알고리즘은 C4.5[16], IBL(Instance-based Learning)[17] 그리고 NN(Neural Network)[18]을 사용하여 비교하였다. 논문의 구성은 2장에서는 그림자 제거에 관련된 알고리즘에 대하여 논의하고, 3장에서는 차량모형을 위한 피팅 방법에

대하여 논하고, 4장에서는 이것을 학습하여 차종 분류에 적용한 실험의 결과를 평가하고, 5장에서는 결론과 향후 개선 사항에 대해 논의한다.


2. 그림자 제거

2.1 객체영역의 전경과 배경 영상

고정 설치된 카메라로부터 얻어진 감시동영상에서 움직이는 차량 객체에 대한 영역을 추출하기 위해서 배경빼기(Subtraction) 방법을 이용할 수 있다. 배경빼기는 동영상의 과거 프레임들로부터 배경프레임을 추정한 후, 현 동영상 프레임과의 차를 이용하여 움직이는 차량 객체의 영역을 얻어낼 수 있다. 효율적인 배경빼기를 위해서는 우선, 대상 동영상의 배경프레임을 정확하게 추정하는 것이 필요하다. 하지만 추정된 배경프레임은 시간에 따른 날씨의 변화와 동영상 내의 고정 물체의 이동 등에 의해서 적응적인 배경프레임의 추정법을 사용한다[19]. 또한 현 프레임에서 객체 분할을 위해 사용되는 차영상은 카메라의 흔들림과 주변 밝기의 변화에 따른 많은 잡음을 포함한다. 때문에 적절한 문턱치(threshold value)에 의한 이진화와 불필요한 객체의 제거를 위한 모폴로지(morphology) 연산 등의 처리(processing)가 필요하다.

분할된 차량객체의 영역에 속하는 두 가지의 영상 데이터를 얻을 수 있다. 하나는 전경 영상으로 현재 프레임에서 분할된 객체 영역에 해당하는 픽셀들로 구성되며 차량과 그림자의 영상을 포함한다. 다른 하나는 배경 영상으로 배경프레임에서 분할된 객체 영역에 해당하는 픽셀들로 구성되며 차량이 없는 도로 영상을 보여준다. 전경과 배경 영상은 그림자, 도로, 차량에 대한 특징을 분석하기 위해서 사용된다.

아래 보여지는 (그림 1)의 (a)는 분할된 차량 객체 영역에 대한 전경 영상과 배경 영상의 예를 각각 보여주고 있고, (그림 1)의 (b)는 전경과 배경 영상에 대한 RGB색 공간 상의 분포를 보여준다. 즉, 이 분포도는 전경과 배경 영상의 픽셀(Pixel)들의 색 구성 요소로써 R(Red), G(Green), B(Blue) 세 개의 축을 가지는 3차원상의 그래프로 데이터를 표현한 것이다. 밝은 점으로 표현된 부분은 전경 영상 중 차량 영역을 구성하는 픽셀의 RGB 값의 분포를 나타내고, 중간 밝



(a) 전경/배경 영상 (b) RGB 색 공간

(그림 1) 추출된 영상과 RGB분포


기의 점은 그림자 영역을 구성하는 픽셀의 분포를, 그리고 어두운 점으로 표현된 부분은 배경 영상을 구성하는 픽셀의 RGB값의 분포를 보여준다.

(그림 1)의 (b)에서 보는 것과 같이 배경 영상 내에 주로 보여지는 도로는 차량에 의해 만들어지는 그림자보다는 밝은 색을 가지며, 전체적으로 색의 변화가 적기 때문에 픽셀들의 RGB값이 좁고 짧은 영역에 분포하지만, 전경 영상에서 나타나는 차량과 그림자는 상대적으로 RGB 공간 상에 넓게 분포하므로 배경의 분포에 비하여 큰 분산 값을 가진다는 특징을 알 수 있다. 그리고 RGB 모델의 각 색 요소에 의해서 결합되는 표현되는 영상은 요소간에 서로 독립이지만, 연관성을 가진 픽셀로 구성된다. 즉, 하나의 픽셀은 RGB 세 요소의 결합에 의해서만이 표현이 가능하고, 어느 한가지 요소라도 과소평가하거나 제거할 수 없다. 때문에 특정 영역 내 픽셀의 그림자 탐지와 제거를 용이하게 하기 위해서 각 색 요소간의 연관성을 최소화 할 수 있는 새로운 색 모델로의 변환이 필요하다.

2.2 그림자 특성 및 탐지

그림자는 객체의 일부분에 만들어지는 셀프-쉐도우(Self-shadow)와 객체에 의해 객체 외부에 만들어지는 캐스트 쉐도우(Cast shadow)로 구분할 수 있다. 셀프-쉐도우는 객체의 일부로 인식되어야만 하지만, 캐스트 쉐도우의 경우는 객체의 일부는 아니지만 움직이는 객체로서 함께 추출되기 때문에 제거되어야만 한다. 이러한 움직이는 캐스트 쉐도우는 직접적으로 가리워진 부분인 전그림자(Umbra)와 부분적으로 가리워진 반그림자(Penumbra)에 의해서 그림자의 밝기의 차이가 생기기 때문에 그림자의 효과적 제거가 어렵다. 이러한 그림자는 배경과 유사한 분포 특성을 가진다. 아래 (그림 2)는 햇빛의 강도에 따른 배경(도로)과 그림자영상의 RGB 분포 특성을 보여주고 있다. 배경과 그림자가 같은 방향으로 직선상에 분포하고 있음을 알 수 있다. 때문에 그림자를 탐지할 수 있는 중요한 특징은 배경 영상의 분포의 방향이라는 것을 알 수 있다.

RGB색 모델은 서로 관련성이 있는 3개의 색 요소에 의해서 표현되기 때문에, 그림자제거를 위해서 RGB 중 어느 한 요소만으로는 그림자와의 연관성을 찾기가 쉽지 않다. 때문에 용이한 분석을 위해서 RGB 색 공간의 3개의 색 요소(Red, Green, Blue)들의 연관성을 최소화 할 수 있는 새로운



밝은 날씨 (b) 구름이 낀 날 (그림 2) 배경(도로)와 그림자 영상의 RGB 색 분포

색 모델이 필요하다. 새로운 색 모델은 주성분분석을 이용하여 RGB각 요소에 대한 새로운 특징을 추출한 후 선형 변환하여 새로운 주성분공간에 대한 $Y_1Y_2Y_3$ 모델을 만든다.


우선 전경과 배경 영상에 대한 M개의 각 픽셀의 RGB성분들로 관측벡터(observation vector)인 X 로 표현하고, 각 성분에 대한 평균 μ_x 과 공분산 C_x 을 계산한다. 배경 영상의 공분산 C_x 의 고유치(eigenvalue)를 각각 구하여 큰 순서로 $\lambda_1, \lambda_2, \lambda_3$ 이라 하고, 이에 대응하는 고유벡터 e_1, e_2, e_3 로 이루어진 변환행렬 A^B 를 구하여 다음 식(1)와 같이 배경 영상의 RGB성분을 변환한다.

$$Y^B = A^B (X^B - \mu_X^B), A^B = [e_1 e_2 e_3]^T \quad (1)$$

그리고, 전경 영상의 각 RGB성분들을 다음 식(2)에 의해서 배경 영상의 Y^B 공간으로 사상(mapping)시킨다. (그림 3)의 (a)는 이들의 분포와 주성분 축을 보여주고 있다.

$$Y^F = A^B (X^F - \mu_X^B) \quad (2)$$

RGB공간 상의 배경 데이터는 각 축 상의 데이터의 평균 값을 빼서 새로운 공간 Y^B 상에 다시 표시 하였기 때문에 좌표 $(y_1 y_2 y_3) = (0 0 0)$ 에 배경 분포의 중심이 위치하게 된다. 그림자는 배경 영상인 차도의 밝기 보다 어둡기 때문에 배경을 중심으로 그림자의 위치를 추정할 수 있다. (그림 3)의 (b)에서 보는 것과 같이, 그림자의 영역 위치는 주성분 $Y_1Y_2Y_3$ 의 공간에서 Y_1 축에 대한 배경(도로)의 평균보다 작은 공간 쪽으로 위치하게 된다. 하지만, 추정된 영역에는 그림자 만이 있는 것이 아니라 차의 일부 영역 혹은 전부를 포함하고 있을 수 있다. 즉, 차량의 유리창과 같이 어두운 부분이나, 차량의 밝기가 도로 보다 어둡거나 유사한 경우 차량이 그림자로 인식될 수 있다.

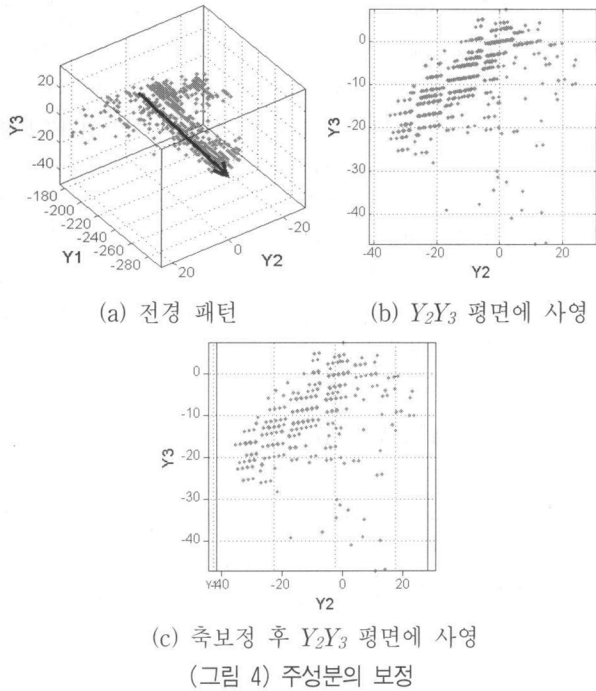


(a) 전경과 배경의 주성분 (b) 그림자의 가능 추정영역

(그림 3) RGB 색 공간과 주성분벡터

2.3 주성분의 보정

전경과 배경 영상의 RGB성분에 대한 통계적인 분포특성을 이용하여 KLT 변환된 공간상의 데이터는 (그림 4)의 (a)에서 보여지는 것 같이 특정한 방향 패턴을 가지게 된다. 즉, 배경 영상과 마찬가지로 그림자를 포함하는 전경 영상



역시 동일한 방향 패턴 - 배경과 같은 Y_2Y_3 평면상의 위치와 Y_1 방향으로 그림자가 존재할 가능성이 높다-을 가진다고 생각할 수 있다. 즉, 같은 재질이나 질감을 갖는 물체는 외부의 광원으로부터 발생할 수 있는 반사되는 빛에 의한 밝기의 차이가 선형적으로 변한다고 할 수 있다. 주성분 공간의 Y_1 축과 전경의 패턴 방향은 유사하지만 정확히 일치하지는 않는다. 때문에 좌표 축을 변환하여, 변환된 Y_1 축과 전경의 패턴 방향이 일치하도록 투영된 점의 수를 최소화하는 방법으로 축을 수정하였다. $Y_1Y_2Y_3$ 공간의 데이터를 Y_2Y_3 평면에 사영(projection)시키면 (그림 4)의 (b)와 같이 분포의 패턴이 Y_1 축과 일직선상에 있지 않기 때문에 서로 어긋나 보이게 된다. 만약 Y_1 축 수정의 통해서 정확한 패턴의 방향을 찾게 된다면 (그림 4)의 (c)와 같이 정확히 각 패턴이 Y_2Y_3 평면에 일치되어 사영된다.

전경 영상에 포함된 그림자의 특성을 관찰해 보면 차량의 색에 따라서 다르다는 것을 알 수 있다. 차량의 색에 따른 밝기에 따라 다른 그림자의 분포 모양을 가지기 때문에 그림자의 분포 위치의 추정이 어렵다. 때문에 차량의 색에 따른 밝기와 관계없이 그림자의 탐지가 가능하게 하려면, 분포 모양의 보정이 필요하다. 보정을 위해 필요한 특징은 $Y_1Y_2Y_3$ 공간 상의 데이터에 Y_2Y_3 평면에 대한 2차원 히스토그램을 이용한다. 즉, (그림 5)에서 보여지는 것과 같이, Y_2Y_3 평면에서의 가장 높은 누적 값, $Peak_1$ 을 가지는 좌표와 2번째 높은 누적 값, $Peak_2$ 을 가지는 위치를 찾는다. Y_2Y_3 평면을 서브 영역들로 나누어 각 영역에 대한 누적 값을 계산하여 피크 값을 찾는다. 가장 높은 누적 값을 가지는 영역은 배경 분포의 중심인 원점과 거의 일치한다. 두 번째로 높은 누적 값은 그림자의 중심 영역에 위치하고, 차량의 밝기 값에 따라 다르게 위치한다. 차량의 밝기가 다른 차량의 분포는 원점을 중심으로 서로 다르게 기울어져 있기 때문에 이

두 피크 값은 Y_2Y_3 평면의 보정에 이용될 수 있다. Y_2 축과 일치되도록, 두 피크 값에 의해서 연결되는 선과 Y_2 축과의 사이 각을 구한 후 Y_1 축을 중심으로 회전시켜 Y_2Y_3 평면을 보정한다. 차량 밝기에 따른 보정된 분포들은 거의 비슷한 분포상의 모양과 방향을 가지기 때문에 그림자의 위치를 쉽게 추정할 수 있다.

2.4 그림자 제거

그림자와 배경(도로)의 분포는 같은 방향을 가지며 거의 일직선 상에 놓여지지만 날씨의 조건과 차량의 밝기에 따라 색 공간상에서 다른 분포의 특징들을 보인다. 그림자의 Y_2Y_3 면상의 점들의 분포는 Y_3 보다는 Y_2 방향으로 더 큰 분산을 보인다. 때문에 그림자 영역을 포함 시킬수 있는 적절한 타원을 이용해 그림자 영역의 제거에 사용한다. 그리고 그림자는 배경의 Y_1 축에 대하여 일직선 상에 놓이므로 타원은 기둥 모양으로 만들어져야 된다. 타원은 그림자 분포의 중심에 위치해야 하기 때문에 보정에 사용했던 두 피크 $Peak_1, Peak_2$ 을 이용해서 분포의 중심을 구하고 타원을 Y_2 축방향으로 이동한다. 하지만, Y_3 축에 대한 타원의 이동은 이미 Y_1 축의 회전에 의한 보정에 의해서 필요하지 않다. 그리고 $Y_1Y_2Y_3$ 공간의 Y_2, Y_3 두 축에 대한 분산 값의 비율을 구하여 타원의 파라미터로 사용한다. 그러나, 햇빛의 강도가 낮은 경우 두 피크 $Peak_1, Peak_2$ 의 거리는 짧아지게 되어 0에 가까워 진다. 이럴 경우 그림자를 제거하기 위한 타원을 생성할 수 없다. 때문에 거리가 τ 보다 작은 경우는 D_{peak} 의 값을 τ 로 사용한다. 사용된 타원의 방정식은 다음 식(5)와 같다. 그림자의 제거는 타원의 내부에 포함되어 있는 점들을 Y_1 축을 따라서 삭제함으로써 수행되어진다.


$$\lambda = \sqrt{\frac{\text{variance}_{Y_2}(Y)}{\text{variance}_{Y_3}(Y)}}, \quad \tau = \text{variance}_{Y_2}(Y) \quad (3)$$

$$D_{peak} = \max(|Peak_2 - Peak_1|, \tau) \quad (4)$$

$$Y_2 = \lambda \sqrt{(D_{peak}^2 - Y_3^2)} - \frac{D_{peak}}{2} \quad (5)$$

(그림 5)의 (a)는 그림자 제거를 위한 입력 영상을 보여주고 있고, (그림 5)의 (b)는 그림자로 추정되는 영역을 제거한 후의 결과 영상이다.

$$X^F = (A^F)^T Y^F + \mu_X^B \quad (6)$$





(a) 입력영상 (b) 결과영상
(그림 5) 그림자제거

3. 차량 모형

3.1 소실점(Vanishing Point)

도로 위에 설치된 감시 카메라는 주로 근거리로부터 원거리의 포함하는 도로 영상을 포함하고 있기 때문에 감시 영상 내의 원근에 의해서 만들어지는 차량의 기하학적인 구조를 추정하기 위해서 소실점은 반드시 필요하다. 소실점을 구하기 위해서는 원근을 추정할 수 있는 교차점을 만들 수 있는 직선 성분이 필요하다. 주로 차선을 이용한 방법과 차량의 이동 궤적을 이용한 방법의 이용이 가능하다. 차선은 이미 배경프레임으로부터 외곽선을 추출한 후 허프 변환(Hough Transform)을 이용해서 추출이 가능하고, 이 차선들의 교차점을 찾는 것에 의해서 소실점을 찾아 낼 수 있다. 그리고 차량의 이동 궤적으로부터 얻어진 궤적 선들의 교점을 통해서도 차선에 대한 정보의 유추가 가능하기 때문에 소실점의 획득이 가능하다.

도로상의 차선은 보통 다중의 선을 가지며 원거리일수록 작은 선으로 표현되기 때문에 선 자체의 탐지가 쉽지 않다. 또한 도로 주변은 움직이는 구조물에 의해서 많은 잡음을 발생시키기 때문에 소실점을 찾기 위한 직선의 검출이 어려울 수 있다. 하지만, 배경프레임의 추출과 동시에 차선을 구할 수 있기 때문에 수행 속도 면에서 빠르다. 그리고, 차량의 이동 궤적 선을 이용하는 경우 차량의 움직임에 의해서 픽셀의 밝기 값의 변화 특성을 찾아내기 때문에 차량의 소통이 적은 도로 상에서는 소실점의 탐지 속도가 늦지만, 통계 값을 이용하기 때문에 동영상 내의 도로나 차선 이외의 잡음에 대하여 강하다.




(c) 차량 모형화
(그림 7) 소실점을 이용한 객체 피팅

따라서 6개의 직선으로 표현 될 수 있다. (그림 7)은 소실점과 피팅을 이용하여 객체를 피팅시킨 이미지를 보여주고 있다. 객체 피팅은 먼저 (그림 7)의 (a) 에서와 같이 추출된 객체의 4점(R_1, R_2, R_3, R_4)으로 사각영역을 정의하고 소실점으로부터 만들어지는 직선의 객체와 인접하는 두 점을 찾는다. 이때 소실점과의 직선과 사각영역의 접점을 이용해서 피팅을 하게 된다. 최종적으로 만들어지는 피팅의 결과는 (그림 7)의 (b)에서 보여주는 것과 같이 6개의 점($A_1, A_2, A_3, A_4, A_5, A_6$)로 구성되는 6각형의 결과가 만들어진다. (그림 7)의 (c)는 실제 영상에 적용한 예이다.

4. 실험결과

본 연구에서 제안하는 그림자 제거 방법을 실험하기 위해 MS Windows XP Professional 환경에서 MS Visual C++.NET과 DirectShow를 사용하여 구현하였고, 하드웨어는 인텔 Dual Xeon CPU 2.8Ghz 시스템을 이용하였다.

구현된 프로그램은 우선 동영상에서 영상프레임을 추출한 후, 배경프레임을 추정한다. 최초의 배경 프레임을 추정하기 위해서 차량의 소통량과 진행속도에 따라 다소 차이가 나는데 약 10초 정도의 시간이 소요된다. 추정된 배경 프레임은 배경빼기를 이용한 차영상을 구하고 모폴로지, 라벨링(labeling), 영역화(blobbing)등의 처리를 수행하여 움직이는 개체의 영역을 분할한다. 분할된 영역의 전경, 배경 영상에 대하여 주성분 분석을 수행한 후 그림자 성분을 제거한다. 그림자가 제거되어 축소된 영역을 대상으로 차량 모형에 대한 피팅을 수행하여 차량의 기본 속성 값을 얻는다. 그리고 WEKA[20]를 이용하여 차종 학습과 테스트를 수행하였다. 사용된 동영상은 실제 도로상에서 촬영된 초당 15 프레임의 24비트 컬러 동영상으로 320x240의 해상도를 갖는다. 다음 <표 1>는 각 영상의 처리단계별 수행시간을 보여준다. 전체적인 처리시간은 500ms정보 소요됨을 알 수 있다. 차량의 검지점 통과 시 차량의 차종 판별이 필요하므로 초당 2대의 처리가 가능하다.




(a) 차선이용 (b) 궤적이용
(그림 6) 소실점을 얻기 위한 두 가지 방법

3.2 모형 피팅 (Model Fitting)

추출된 객체를 차량의 추상화된 모형에 적용시켜 차량 식별과 더불어 모형에 적용된 속성 값을 근거로 하여 차종의 판별을 위한 데이터로 사용할 수 있다. 차량의 정해진 모형에 적용시켜 추상화 시키는 과정을 피팅이라고 부르는데 이는 차량의 추상화된 모양을 직선들을 이용한 다각형으로 간단히 표현하는 것이다. 프레임 내의 객체는 x와 y축에 의해서 정의된 2차원 상의 픽셀들의 집합으로 표현된다. 그리고 객체 내의 픽셀들을 모두 포함할 수 있는 최소의 점으로 그 모양을 적절히 추상화시킬 수 있어야 한다. 차량의 모양은 직육면체 모양으로 추상화할 수 있고 객체의 이동 방향에

〈표 1〉 영상처리 단계 별 소요시간

처리 단계	수행시간(milli second)
배경 빼기	6.332
모폴로지	4.868
라벨링&영역화	23.221
주성분분석&그림자제거	441.580
차량객체피팅	3.564



(a) 피팅된 차량모형

구분	차종
1	승용차, SUV
2	승합차
3	트럭, 버스

(b) 차량의 종류

(그림 8) 차량 모형 및 분류

실험은 그림자를 제거한 경우와 그렇지 않은 경우의 특징값들을 추출한 후, 학습에 사용하고, 차종의 판별결과를 평가한다. 피팅된 차량을 3가지 종류로 구분하여 감독 학습을 시킨 후, 학습된 데이터를 기반으로 차종을 구분하였다. 실제 구분에 사용된 차종은 크게 3종류(승용차/SUV, 승합차, 트럭/버스)로 구분하였다. 차종 분류를 위해서 사용된 학습 알고리즘은 C4.5, IBL, Neural Network 등 세 가지에 대하여 시험하였다. 학습과 평가를 위해서 같은 위치에서 촬영된 동영상 2개를 이용하였다. C4.5의 학습결과와 형태는 C4.5를 사용하였고, IBL의 학습에는 4가지 버전 중 가장 간단한 IB1을 이용하여 학습시켰고 NN(Neural Network)은 역전파(Back-propagation) 알고리즘을 사용하였다. 학습을 위한 속성값들로는 (그림 8)의 (a)에서 보여지는 것같이 피팅된 차량의 모델로부터 추정된 차량의 폭, 높이, 길이와 주행 차선의 위치에 대한 정보를 이용하였다.

〈표 2〉는 피팅된 차량 모델들에 대한 차종 별 속성값들에 대한 평균값의 변화를 보여주고 있다. 그리고 속성값들은 그림자를 제거하지 않았을 때보다 실제 차에 더 가깝게 모형화할 수 있음을 알 수 있다.

피팅 모델의 체적을 비교했을 때, 그림자 제거 이전보다 평균 35%정도 감소했음을 알 수 있어 과도한 크기로 모형화되지 않는다. 특히, 그림자를 포함하고 있을 때, 시간에 따른 그림자 길이의 변화에 따라 속성의 값이 변화하기 때문에 그림자가 제거된 차량의 경우 일정한 속성값을 가질 수 있기 때문에 더 정확한 차량의 모형화가 가능하다고 할 수 있다. 학습에는 100개의 차량 객체를 사용하였고 테스트에는 123개의 객체를 사용하여 실험하였다. 〈표 3〉의 결과는 그림자 제거 전과 후의 C4.5, IB1, NN을 이용하여 학습한 후, 차종의 판별 결과를 보여준다.

〈표 2〉 속성값들의 비교

차종	구분	그림자 포함			그림자 제거		
		폭	높이	길이	폭	높이	길이
1		52.7	22.9	86.7	38.5	23.6	59.6
2		53.5	30.2	105.2	40.9	30.5	67.3
3		72.3	42.3	116.8	46.2	42.4	73.4

〈표 3〉 그림자에 따른 차종 학습 결과

구분	차종	1	2	3	전체
		C4.5	96.3%(79/81)	89.3%(25/28)	100%(14/14)
그림자 제거	IB1	99.8%(80/81)	89.3%(25/28)	71.4%(10/14)	93.5%(115/123)
	NN	96.3%(79/81)	89.3%(25/28)	92.9%(13/14)	94.4%(117/123)
	C4.5	96.3%(78/81)	64.3%(18/28)	71.4%(10/14)	86.2%(106/123)
그림자 포함	IB1	95.1%(77/81)	71.4%(20/28)	64.3%(9/14)	86.2%(106/123)
	NN	93.8%(76/81)	64.3%(18/28)	64.3%(9/14)	83.7%(103/123)

〈표 3〉에서 보여지는 결과에 따르면 그림자를 제거하였을 경우 차량 분류율은 전체적으로 95.2%로 C4.5가 가장 높고, NN이 94.4%, IB1이 93.5%의 결과를 얻었다. 그림자를 제거하기 전의 분류율에서 7~11%의 성능향상을 보이고 있다. 각 학습알고리즘의 결과에 약간의 차이가 발생하는 이유는 학습에 사용한 데이터에 대한 알고리즘의 특성이 서로 다른데 기인한 것으로 생각할 수 있다. C4.5가 훈련 데이터 집합의 공통성 추출에 의존하는 데 비해 IBL은 훈련 데이터 집합과 인식된 개체 간의 거리를 측정하는 방법을 사용한다. 즉, 판별을 위한 데이터가 어떤 명확한 규칙에 의해서 구분될 수 있는 경우 C4.5의 학습 효과를 기대할 수 있다. 하지만 IB1의 경우, 훈련 데이터 집합의 양이 적은 경우, 잡음에 영향을 받기 쉬워 성능을 떨어뜨리는 요인으로 작용할 수 있다. IBL의 경우 본래 4가지 버전 중에서 모든 훈련 집합을 저장하는 IB1보다 잡음 등을 제거하는 IB3가 우수하나 이 실험의 경우 훈련 집합의 크기가 크지 않아 IB1을 사용하였다. 만약 훈련 집합의 크기가 충분히 크면 IB3를 이용한 학습의 효과가 더 높을 것으로 예상된다. 차종1의 경우 그림자의 제거 전과 제거 후의 결과의 차이가 크지 않은 반면 차종2와 차종3의 경우는 상당한 성능의 향상을 보임을 알 수 있다. 이는 차량의 높이가 높을수록 그림자 크기의 증가로 인한 객체의 왜곡이 심해지기 때문에 식별율이 낮아지게 된다. 반면, 그림자 제거 시의 성능이 상대적으로 증가하였다.

5. 결론


본 논문은 교통감시 영상으로부터 획득한 프레임영상 내에 포함된 차량의 객체 정보를 추출하고 차량의 객체 정보를 분석하여 차량의 종류를 효율적으로 분류하기 위해 객체 내에 포함된 그림자를 제거하는 알고리즘을 이용하여 실험하였다. 그림자는 동영상 프레임에서 객체를 추출할 때 객체의 모양을 왜곡시켜 인식에 있어 많은 문제를 발생시킨다. 때문에 동영상으로부터의 객체에 의해서 만들어지는 그림자의 탐지와 제거는 정확한 감시영상의 분석을 위한 응용에 있어 매우 중요하다. 사용된 그림자제거 알고리즘은 배경 영상과 그림자 영상의 통계적 분석을 통하여 새로운 색 모델을 만들고 이를 이용하여 그림자의 탐지하고 제거한다. 그림자는 시간, 날씨에 따라서 다양한 크기와 강도로 나타나기 때문에, 차량의 차종 판별과 같은 응용에 있어 많은 정확도를 떨어뜨리는 중요 요인으로 작용할 수 있다. 추출

된 객체내의 그림자를 제거함으로써 차종 판별을 위한 객체의 피팅을 보다 정확히 할 수 있어 차종 판별률을 높일 수 있었다.

하지만, 진행하는 차량의 중첩으로 인해서 차량의 객체가 겹쳐 보이게 될 경우, 추출되는 객체는 과도하게 커져버리는 문제점이 발생할 수 있다. 때문에 이에 대한 해결방안이 필요하고, 소실점과 일직선으로 진행되는 차량의 피팅 시, 부정확한 차량 높이와 길이가 피팅 시에 적용되어 차종판별의 정확도를 떨어뜨리는 현상 또한 해결해야 할 문제로 아직 남아있다. 향후 이러한 문제를 해결한다면 보다 고급의 정보를 비전 시스템으로부터 교통감시시스템으로 전달하여 지능적인 교통 관리에 기여할 수 있을 것으로 본다.

참 고 문 헌

- [1] Palen, J., "The need for surveillance in Intelligent Transportation Systems," *Intellimotion*, vol. 6, no. 1, pp.1-16, 1997.
- [2] 하동문, 이종민, 김용득, "비전 기반 차량 검출 및 교통 파라미터 추출", 정보과학회논문지, 시스템 및 이론 제30권 제11호, pp.610-620, 2003.
- [3] 김경옥, "도로 영상에서의 차량 인식 및 차종 식별에 관한 연구", 전북대학교 석사학위논문, 2003.
- [4] Cucchiara, R., Grana, C., Prati, A., and Piccardi, M., "Effective detection of moving objects, shadows and ghosts in surveillance videos", *Australia-Japan Advanced Workshop on Computer Vision*, 2003.
- [5] Yoneyama, A., Yeh, C.H., Kuo, C.-C.J., "Moving cast shadow elimination for robust vehicle extraction based on 2D joint vehicle/shadow models," in *Proceedings of IEEE Conference on Advanced Video and Signal Based Surveillance*. 2003, 21-22 July 2003, pp.229-236.
- [6] J.M Wang, Y.C. Chung, C.L. Chang and S.W. Chen, "Shadow Detection and Removal for Traffic Image," in *Proceedings of the 2004 IEEE International Conference on Networking, Sensing & Control*, Taipei, Taiwan, 2004.
- [7] Lai, A.H.S., Yung, N.H.C. "A fast and accurate scoreboard algorithm for estimating stationary backgrounds in an image sequence" *IEEE Circuits and Systems*, Volume 4.
- [8] Haritaoglu, I., Harwood, D., and Davis, L.S., "W4: real-time surveillance of people and their activities," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no.8, pp.809-830, 2000.
- [9] Horprasert, T., Harwood, D., Davis, L. S., "A statistical approach for real-time robust background subtraction and shadow detection," in *Proceedings of IEEE ICCV'99 FRAME-RATE Workshop*, 1999.
- [10] Mikic, I., Cosman, P., Kogut, G., and Trivedi, M.M., "Moving shadow and object detection in traffic scenes," in *Proceedings of Int'l Conference on Pattern Recognition*, pp.321-324, 2000.
- [11] W. S. Shin, J. S. Um, D. H. Song, and C. H. Lee, "Moving Cast Shadow Elimination Algorithm using Principal Component Analysis in Vehicle Surveillance Video", in *Proceedings of International Workshop on Advanced Multimedia Technology and Applications*, 2006.
- [12] 김정대, "감시용 비디오 카메라 영상에서의 신경망을 사용한 그림자 제거", 대구대학교 석사학위논문, 2005.
- [13] 이정원, "에지 기반의 객체 분류와 그림자 제거 방법", 경북대학교 석사학위논문, 2005.
- [14] Jolliffe, I. T., "Principal component analysis," New York: Springer-Verlag, 1996.
- [15] W. S. Shin, D. H. Song, and C. H. Lee, "Cast Shadow Elimination of Vehicles for Efficient Vision-based Traffic Monitoring system," in *Proceedings of Int'l Conference on Multimedia Information Technology and its Application (2006)*.
- [16] Quinlan, J. R., "C4.5: Programs for Machine Learning," Morgan Kaufmann 1993.
- [17] Aha, D.W., "A Study of Instance-Base Algorithms for Supervised Learning Task: Mathematical, Empirical, and Psychological Evaluations," Ph.D. Dissertation, University of California, Irvine, 1990.
- [18] Anderson, J.A., "Teaching Arithmetic to a Neural Network, In *Introduction to Neural Network*."
- [19] 남석우, 오해석, "동영상에서 배경프레임을 이용한 차량 프레임 검출", 정보처리학회논문집B, 제10-B권 제6호, pp.705-710, 2003.
- [20] Weka Machine Learning Project, <http://www.cs.waikato.ac.nz/ml/weka/>



신 옥 신

e-mail : wsshin@konkuk.ac.kr

1998년 건국대학교 전자계산학과(학사)

2000년 건국대학교 컴퓨터공학과(공학석사)

2002년~현재 건국대학교 컴퓨터공학과
박사과정 수료

관심분야: 컴퓨터비전, 영상처리,
지능형시스템 등



이 창 훈

e-mail : chlee@konkuk.ac.kr

1980년 연세대학교 수학과(학사)

1977년 한국과학기술원 전산학과(석사)

1993년 한국과학기술원 전산학과(박사)

1996년~2000년 건국대학교 서울캠퍼스

정보통신원 원장

2000년~2002년 건국대학교 정보통신대학원 원장

2001년~2002년 건국대학교 정보통신대학 학장

1980년~현재 건국대학교 컴퓨터공학과 교수

관심분야: 지능시스템, 운영체제, 보안, 전자상거래 등