

혼합분류기 기반 영상내 움직이는 객체의 혼잡도 인식에 관한 연구

정회원 안태기*, 안성제**, 박광영***, 종신회원 박구만****

A Study on Recognition of Moving Object Crowdedness Based on Ensemble Classifiers in a Sequence

Tae-ki An*, Seong-je Ahn**, Kwang-young Park*** *Regular Members*,
Goo-man Park**** *Lifelong Member*

요 약

혼합분류기를 이용한 패턴인식은 약한 분류기를 결합하여 강한 분류기를 구성하는 형태이다. 본 논문에서는 고정된 카메라를 통해 입력된 영상을 이용하여 특징을 추출하고 이것들을 이용한 약한 분류기의 결합으로 강한 분류기를 만들어 낸다. 제안하는 시스템 구성은 차영상 기법을 이용해서 이진화된 전경 영상을 얻고 모폴로지 침식연산 수행으로 얻어진 혼잡도 가중치 영상을 이용해 특징을 추출하게 된다. 추출된 특징을 조합하고 혼잡도를 판단하기 위한 모델의 훈련 및 인식을 위한 혼합분류기 알고리즘으로 부스팅 방법을 사용하였다. 혼합 분류기는 약한 분류기의 조합으로 하나의 강한 분류기를 만들어 내는 분류기로서 그림자나 반사 등이 일어나는 환경에서도 잠재적인 특징들을 잘 활용할 수 있다. 제안하는 시스템의 성능실험은 “AVSS 2007”의 도로환경의 차량 영상과 철도환경내의 승강장 영상을 사용하였다. 조명변화가 심한 야외환경과 승강장과 같은 복잡한 환경에서도 시스템의 우수한 성능을 보여주었다.

Key Words : 혼잡도, 패턴인식, 혼합분류기, AdaBoost, Crowdedness, Pattern Recognition, Ensemble Classifier

ABSTRACT

Pattern recognition using ensemble classifiers is composed of strong classifier which consists of many weak classifiers. In this paper, we used feature extraction to organize strong classifier using static camera sequence. The strong classifier is made of weak classifiers which considers environmental factors. So the strong classifier overcomes environmental effect. Proposed method uses binary foreground image by frame difference method and the boosting is used to train crowdedness model and recognize crowdedness using features. Combination of weak classifiers makes strong ensemble classifier. The classifier could make use of potential features from the environment such as shadow and reflection. We tested the proposed system with road sequence and subway platform sequence which are included in "AVSS 2007" sequence. The result shows good accuracy and efficiency on complex environment.

※ 본 연구는 국토해양부 도시철도표준화 2단계 연구개발사업의 연구비지원(07도시철도표준화A01)에 의해 수행되었습니다.

* 한국철도기술연구원 도시철도표준화연구단 책임 연구원, ** 서울과학기술대학교 NID융합기술대학원, *** 하이트론씨스템즈(주), **** 서울과학기술대학교 전자IT미디어공학과 교수, (gmpark@seoultech.ac.kr), (° : 교신저자)

논문번호 : KICS2011-12-636, 접수일자 : 2011년 12월 28일, 최종논문접수일자 : 2012년 2월 14일

I. 서 론

오늘날 실생활에 사용되는 컴퓨터 비전의 가장 대표적인 분야는 지능형 보안 감시분야이다. 폐쇄회로 감시시스템이 최근 일련의 사건 사고를 해결하기 위한 감시데이터 제공자로 활용됨으로서 그 중요도가 점점 높아지고 있다. 하지만 이러한 수동적인 감시시스템은 거의 사후 처리용으로 사용되는 경우가 많으며, 사전 예방 및 사고확산 방지를 위한 기능을 수행하는 데는 한계를 가지고 있다. 또한 모니터를 지켜보는 감시시스템 운영자의 집중력은 20분을 넘지 못한다는 것이 연구결과를 통해 널리 알려져 있다. 그렇기 때문에 컴퓨터 시스템이 사람의 역할을 보완하는 지능형 감시시스템의 중요성이 부각되고 있다. 현재 이러한 지능형 감시시스템의 정확도는 완벽한 단계까지 발전되지 못했다. 그렇기 때문에 군중의 집중에 따른 사건, 사고의 발생 위험도와 연관된 혼잡도 인식이나 사람계수의 중요성이 부각되었다. 본 논문에서는 혼합 분류기 알고리즘을 적용한 혼잡도 인식 모델을 제안하였다. 혼잡도 인식 모델은 특징 추출과 혼잡도 인식부분으로 구성되어 있다. 특징 추출 단계에서는 영상 내의 속성을 나타낼 수 있는 특징 값을 추출하며, 혼잡도 인식단계에서는 미리 훈련된 모델의 특징벡터와 현재영상의 특징벡터를 비교하여 현재 영상의 혼잡도를 판단한다. 특징 추출과정에서 추출하는 특징은 차영상을 이용하여 얻어진 공간적인 특징의 이진 전경영상과 모폴로지 기법을 이용한 혼잡도 가중치 영상을 사용하였다. 이 두 가지 특징을 서로 연결시킴으로써 복잡한 환경과 환경의 변화에도 강인한 시스템을 구현할 수 있도록 하였다. 제안된 시스템에서 사용된 특징은 하나의 객체나 변화보다는 영상의 전체적인 변화와 특징의 조합에 집중하고 있다. 본 논문의 구성은 다음과 같다. 2장에서는 기존 연구들에 대해서 설명하고, 3장에서는 제안하는 알고리즘에 대해서 설명하고, 4장에서는 실험 및 결과에 대한 고찰을 한 후, 마지막으로 5장에서 결론에 대해서 언급한다.

II. 기존 연구

기존의 혼잡도 인식 알고리즘은 혼잡도 자체의 연구보다는 추적 또는 계수(Counting) 분야에 초점이 맞추어져 왔다. 또 하나의 카메라가 아니라 여러 개의 카메라를 이용한 방법도 사용되었다. 인간 객체의 계

수를 위해서 머리 부분에 초점을 맞춘 연구도 있었고 움직이는 인간의 인식을 위해 다수의 객체가 아닌 단 한사람의 운동량을 표본화하는 방법도 연구되었다. 컬러 영상을 이용한 방법 중 아파트 통로 또는 지하도 통로에 설치된 여러 대의 카메라를 이용하여 움직임 영역을 구하는 방법도 있었다. 이를 위하여 각 카메라 영상 별로 얻은 정보를 비교 분석하는 HSI 히스토그램이 사용되기도 하였다. 이러한 연구들의 공통점은 다수의 객체 계수 보다 특정 환경과 상황에서 소수의 객체 수를 인식하는 방법이라는데 있다. 기존 연구들이 일반적으로 사용한 특징으로는 윤곽선^[1-3], 광류^[4,5], 분포도^[6,7] 등의 다양한 성질들을 이용하거나, 그 조합을 이용하고 있다. 그렇기 때문에 혼잡한 환경이나 상대적으로 넓은 지역을 감시하는 영상의 경우는 변화량이 많고 복잡하기 때문에 혼잡도 인식을 위한 객체 인식에 어려움이 따른다. 본 논문에서는 혼합 분류기 알고리즘을 적용한 혼잡도 인식 모델을 제안하였다. 혼잡도 인식 모델은 특징 추출과 혼잡도 인식부분으로 구성되어 있다. 특징 추출 단계에서는 영상 내의 속성을 나타낼 수 있는 특징 값을 추출하며, 혼잡도 인식단계에서는 미리 훈련된 모델의 특징벡터와 현재영상의 특징벡터를 비교하여 현재 영상의 혼잡도를 판단한다. 기존의 연구들이 객체 하나하나에 대한 검지 및 추적에 초점을 맞추므로 인하여 환경이 비교적 단순하고 조도와 같은 변화량이 적으며 객체의 수가 상대적으로 적은 경우 이용할 수 있다는 한계를 가지고 있다는 것과 달리 본 논문에서 제안된 모델은 환경의 변화도 포괄적으로 수용하여 판단할 수 있으며, 실제 생활에 더욱 가까운 모델이다.

III. 제안하는 알고리즘

3.1. 시스템 구성

제안하는 시스템은 그림1에 나타난 바와 같이 크게 특징추출과 혼잡도 인식의 두 부분으로 구성된다. 특징추출은 혼잡도를 표현하기 위한 중요한 정보를 추출하는 과정으로서 움직이는 객체를 검출하고 분석한다. 객체 간 중첩 현상이 많이 발생하지 않고 객체의 수가 적은 환경에서는 좋은 특징 추출 결과를 얻을 수 있지만 실제 환경에서는 움직이는 객체와 반사, 그림자에 의한 변화가 자주 발생한다. 이러한 환경에서는 정확하게 객체를 검지하고 객체의 특징을 찾아내는 것이 어렵다. 이러한 문제를 해결하기 위하여 본 논문에서는 복잡한 환경의 공간적 에너지의 변화를 고려한다.

제안된 시스템은 움직이는 객체를 분류해 내기 위해 정적인 카메라에서 정의된 배경과 차영상을 이용하여 공간적 에너지 변화를 하나의 특징으로 정의하였다. 그리고 객체간의 중첩을 고려하기 위하여 차영상에서 얻어진 이차원 영상을 모폴로지 침식연산을 통하여 중첩도가 큰 부분만을 남겨진 영상을 혼잡도 가중치 영상으로 정의하였다. 이렇게 제안된 시스템은 차영상을 통해 얻어진 공간적 에너지 변화와 모폴로지 침식연산을 이용한 혼잡도 가중치, 이렇게 두 가지 영상의 특징을 사용하도록 하였다. 다음으로 혼잡도 인식은 이전단계인 특징추출에서 얻어진 특징들을 이용하여 혼잡도를 파악하게 된다. 이 단계에서는 미리 정의된 혼잡도 모델을 이용하여 학습된 시스템을 가지고 실험데이터를 분석해서 혼잡도를 추정하게 된다. 이 단계에서는 보편적으로 사용되는 AdaBoost 알고리즘을 사용하여 혼잡도를 추정하게 된다. 기존 AdaBoost 알고리즘은 이전에 Viola 등에 의해 이미지 내의 얼굴영역 인식에 사용되었다.



그림 1. 시스템 구조
Fig. 1. System Structure

3.2. 특징추출

특징은 크게 두 가지 기준에 대해 우수해야한다. 첫 번째는 분별력(discriminatory power)이다. 좋은 특징은 서로 다른 부류를 잘 분별해 주어야 하는 것이다. 두 번째는 차원(dimensionality)이다. 특징 벡터의 차원이 낮을수록(즉, 특징의 개수가 적을수록) 계산 효율이 좋고 오류발생 확률이 낮아진다. 그리고 이외에 특징 추출에서 고려해야할 사항은 외부환경에 맞추어 설계해야한다는 점이다. 외부환경에 따라 특징 설계

과정이 매우 다양해지기 때문이다.



그림 2. 정의된 배경 영상
Fig. 2. Defined Background image




그림 3. 현재영상
Fig. 3. Current image



그림 4. 차영상 처리후 이진화 영상
Fig. 4. Binary image from difference image




그림 5. 추상화를 위한 영상분할
Fig. 5. Image segmentation for abstraction

3.2.1. 차영상을 이용한 공간적 특징

이 시스템에서 첫 번째로 사용한 특징은 차영상을 이용한 공간적 특징이다. 차영상 기법은 배경 영상 $I_B(x,y)$ 에서 현재 영상 $I_t(x,y)$ 의 차가 임계치(threshold) 값인 T 보다 클 경우 전경(background)을 구하는 방식이다. 전경을 $F(x,y)$ 라 할 때 식 (1)와 같이 값이 구해진다.

$$F(x,y) = \begin{cases} 1 & \text{if } |I_B(x,y) - I_t(x,y)| > T \text{ for } \forall (x,y) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

차영상 기법을 사용한 이유는 가우시안 혼합 모델링이 일반적으로 우수한 성능을 갖는 알고리즘으로 보편적으로 많이 사용하지만 각 픽셀당 K 개의 가우시안 분포를 갖고 있기 때문에 상대적으로 연산량이 많다. 그리고 실험데이터에서 정확한 배경 모델을 정의할 수 있기 때문에 차영상을 이용한 공간적 특징을 선택하였다. 정의된 배경은 실내 환경에서 영상내에 객체가 없는 영상을 선택하여 사용하였다. 그림 2는 차영상을 위해 정의된 배경영상이다.

그림 3은 현재영상이고 그림 4는 그림 2의 배경 영상을 이용해서 차영상 기법에 의해 얻어진 이진 영상이다. 그림 4를 보면 배경과 전경이 유사한 색을 띠는 영역은 부분적으로 손실되어 구분이 제대로 되지 않은 일부분을 제외하면 전경 분리가 제대로 된 것을 확인 할 수 있다.

차영상 처리후 이 영상을 특징으로 추상화하기 위해서 이 논문에서는 공간분할 방식을 사용하였다. 여기서 추상화란 실제세계의 값이나 특징을 수학적 처리가 가능한 값으로 변환시키는 것을 말한다. 영

상을 64개의 영역으로 분리하여 각 영역내 픽셀값의 평균을 각 영역의 특징벡터로 분리하는 방식이다. 그림 5는 차영상 처리후 공간분할을 시각적으로 표현한 이미지이다.

720×572 크기의 실험영상을 64개로 분할했을 때 각 영역의 크기는 각 90×72 이다. 각 영역은 감시영역에 따라 사람이 등장하거나 열차가 등장하는 부분처럼 서로 다른 변화를 가진다. 이렇게 각 영역별로 하나씩의 특징벡터를 얻게 되고 차영상을 이용하여 총 64개의 특징벡터를 얻게 된다.

3.2.2. 중첩도를 이용한 가중치 특징

중첩도를 이용한 가중치는 감시 영역내에서 많은 사람들이 중첩되어 있다면 차영상만을 이용한 특징만으로는 정확한 혼잡도를 측정하는데 어려움이 따른다. 그래서 이 논문에서는 모폴로지를 이용한 중첩도 가중치를 이용한 특징을 사용한다. 중첩도 가중치란 사람들이 많이 중첩되어있는 영역은 모폴로지의 침식연산을 수행했을 때 중첩도가 낮은영역보다 전경영역이 많이 남게 된다. 그림 3에서 그림6까지는 이전 차영상을 통해 얻어진 이진영상에 대해 모폴로지 침식연산을 수행한 영상이다.




그림 6. 모폴로지 침식연산 후 이진화 영상
Fig. 6. Result image after morphological erosion




그림 7. 분할된 혼잡도 가중치 영상
Fig. 7. Segmentation of weighted crowdedness image

이전의 차영상과 같이 영상을 특징벡터로 변환하는 추상화를 위해 64개의 블록으로 분리하였다. 이렇게 얻어진 특징은 차영상 특징과 연결되고 총 128개의 특징이 혼잡도 인식에 사용된다. 이렇게 나누어진 블록에 대해 블록 내 화소 값의 평균을 구하게 된다. 그림 8.은 혼잡도 인식에 사용될 특징 벡터를 시각적으로 표현한 것이다.




그림 8. 영상내의 특징벡터
Fig.8. Feature vectors in an image

3.2.3. 혼잡도 인식

이전 특징추출단계에서 얻어진 128개의 특징을 이용해서 혼잡도 인식을 위한 학습 및 실험을 수행하게 된다. 실험에 사용된 "AVSS 2007" 영상의 도로환경영상의 차량혼잡도 영상과 철도환경의 승객혼잡도 영상은 혼잡도에 따라 Low, Medium, High로 분류되고 라벨링되어 있다.

혼잡도 분류와 추정을 위해서는 이전에 혼잡도가 라벨링된 데이터를 학습데이터와 실험데이터로 분류하고 시스템을 학습시키고 학습된 시스템이 실험 데이터를 얼마나 정확하게 분류하는지를 확인하여 오

류를 측정한다. 이때 오류는 기존에 데이터들이 포함되어 있는 혼잡도 라벨과 실험에서 나온 결과를 비교하여 측정 하도록 한다. 혼잡도 분류 시스템은 AdaBoost 알고리즘을 사용한다.

AdaBoost알고리즘은 이전의 부스팅 알고리즘이 실제 사용할 수 있는 알고리즘으로 발전시킨 알고리즘으로 Freund와 Schapire^[8]에 의하여 제안되었다. 이 알고리즘은 입력단계, 초기화단계, 단일 분류기 추출 단계, 강인한 분류기 출력단계의 4 단계로 구성되어있다. 입력단계에서는 N개의 훈련데이터 입력출력쌍 $\langle (x_1, y_1), \dots, (x_N, y_N) \rangle$, N개의 훈련데이터에 대한 분포 D, 약한 분류기에 사용할 약한 분류기 학습 알고리즘, 반복 횟수 T를 결정한다. 초기화 단계에서는 가중치 벡터

$w_i^1 = D(i)$ for $i = 1, \dots, N$ 를 초기화 한다. 단일 분류기 추출 단계에서는 T번의 반복을 통하여 T개의 단일 분류기를 추출한다. 각 반복단계 내에는 다섯 개의 소단계가 포함되어 있다. 첫 번째 소단계에서는 현재 가중치를 식(2)를 이용하여 정규화된 가중치를 얻는다.

$$p^t = \frac{w^t}{\sum_{i=1}^N w_i^t} \quad (2)$$

두 번째 소단계에서는 가중치 p^t 를 적용한 훈련데이터에 약한 분류기 학습 알고리즘을 적용하여 작은 오류율을 가진 가설 h_t 를 생성한다. 세 번째 소단계에서는 가설 h_t 에 의하여 발생하는 오류율 ϵ_t 를 식(3)을 이용하여 계산한다.

$$\epsilon_t = \sum_{i=1}^N p_i^t |h_t(x_i) - y_i| \quad (3)$$

네 번째 소단계에서는 오류율을 이용하여 가중치를 갱신하기 위해 사용되는 인자 β_t 를 식(4)를 이용하여 계산하고, 다섯 번째 소단계에서는 다음 반복단계에서 사용할 가중치를 식(5)를 이용하여 갱신한다.

$$\beta_t = \frac{\epsilon_t}{(1 - \epsilon_t)} \quad (4)$$

$$w_i^{t+1} = w_i^t \beta_t^{1 - |h_i(x_i) - y_i|} \quad (5)$$

세 번째 단계에서 T개의 가설을 생성하여 단일 분류기들을 추출하고, 네 번째 단계에서는 이러한 가설을 조합하여 강인한 최종 혼합 분류기를 생성하며, 최종 혼합 분류기는 식(6)과 같이 나타난다.

$$h_f(x) = \begin{cases} 1 & \text{if } \sum_{t=1}^T (\log \frac{1}{\beta_t}) h_t(x) \geq \frac{1}{2} \sum_{t=1}^T (\log \frac{1}{\beta_t}) \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

AdaBoost의 특성을 요약하면 다음과 같다. 첫째, 우수한 분류 성능 및 과적합에 대한 강인성 그리고 상대적으로 적은 연산량을 가지는 분류기 설계, 마지막으로 사용자의 사전 지식을 포함한 어떠한 가설들이라도 조합할 수 있는 능력이다. 따라서 이러한 장점들로 인하여, AdaBoost는 단순하거나 혹은 복잡한 패턴 분류 문제에 있어서 가장 적합한 방법이고, 현재 많은 분야에서 그 역할을 하고 있다. AdaBoost는 순차적으로 약한 분류기를 추가하는 과정을 거치면서 성능이 우수한 강한 분류기를 구성하는 학습 기법이다. 연속적으로 약한 분류기를 추가함으로써 학습 오차를 줄이며, 동시에 일반화 오차를 줄일 수 있는 장점을 갖고 있다.

IV. 실험 및 결과 고찰

4.1. 실험환경 및 조건

실험에서는 3단계의 혼잡도(낮음, 중간, 높음)를 갖는 데이터를 5개 부류로 나누고 4개 부류는 훈련 데이터로 나머지 1개는 실험데이터로 사용하는 방식을 사용하였고, 그렇게 되면 5개의 오류율이 계산되는데 최종적으로 5개의 오류율의 평균값을 대표 오류율로 사용하였다. 그리고 AdaBoost의 분류 특징 선택 반복은 200회까지 수행하였다.

표 1. 실험 입력 영상 데이터
Table 1. Input data for experimentation

	도로환경 차량 혼잡도	철도환경 승객 혼잡도
낮은 혼잡도	875	861
중간 혼잡도	1005	1101
높은 혼잡도	1565	126

실험데이터는 ‘AVSS 2007’ 도로환경 영상과 철도환경 영상을 사용하였다. 실제 영상들에서 혼잡도 측정 기준을 세우고 그 기준에 따라 영상을 분류하였다. 실제로 AVSS 영상의 데이터는 양이 더 많지만 혼잡도가 부정확한 영상은 실험데이터에서 제외하였다. 하지만 조명의 변화가 있는 영상은 조명이 변화하는 환경에서 알고리즘의 성능을 측정하기 위해서 실험데이터로 포함시켰다. 그렇기 때문에 각 혼잡도별 상황별 데이터양이 동일하지 않게 분류되었다.

4.2. 실험결과

4.2.1. 도로환경에서 차량 혼잡도 인식




그림 9. 도로환경에서 낮은 혼잡도 오류율
Fig. 9. Error rate at low crowdedness image on street




그림 10. 도로환경에서 중간 혼잡도 오류율
Fig. 10. Error rate at intermediate crowdedness image on street




그림 11. 도로환경에서 높은 혼잡도 오류율
Fig. 11. Error rate at high crowdedness image on street

그림 9부터 그림 11은 도로환경에서 측정한 혼잡도 오류율을 나타낸 그래프이다. 먼저 그림 9의 낮은 혼잡도 측정에서 발생한 오류율 그래프를 보면 초기에는 0.10의 오류율을 갖지만 반복수행이 진행될수록 오류율이 감소해서 72회에 도달했을 때 0.000581이란 오류율에 도달하게 되고 200회까지 진행되면서 계속 유지 되는 것을 확인 할 수 있다. 오류율이 지속적으로 감소하지 않는 이유는 오분류되는 데이터들의 가중치가 높아져도 오분류된 데이터들을 제대로 분류할 수 있는 약한 분류기 대신에 매 반복에서 최소한의 오류를 갖는 약한 분류기가 선택되기 때문이다. 그림 10의 중간 혼잡도 오류율 그래프를 보면 전체적인 그래프 형태가 감소하는 것을 볼 수 있다. 초기 오류치는 0.19로 시작하여 반복이 진행되면서 최저 0.2903 오류율을 갖게 된다. 하지만 최저 오류율을 갖는 순간은 반복횟수가 200회가 진행될 때가 아니다. 이처럼 오류율이 계속 감소하거나 유지되지 않고 증가하게 되는 원인은 오분류된 데이터의 분류를 위해 데이터의 가중

치가 증가하게 되면 오분류 데이터를 분류하기 위해 선택된 약한 분류기가 다른 더 많은 데이터를 오분류 하게 되어 이전보다 오류율이 증가하게 되는 것이다. 그림 11의 높은 혼잡도 오류율을 보게 되면 초기에 오류율이 0.17이었다가 반복수행 횟수가 지나면서 감소하여 작아지지만 중간 오류율 실험에서처럼 오류율이 지속적으로 감소하지 않고 오류율이 작은 폭의 증가, 감소가 일어나는 것을 알 수 있다.

4.2.2. 철도환경에서 승객 혼잡도 인식




그림 12. 철도환경에서 낮은 혼잡도 오류율
Fig. 12. Error rate at low crowdedness image at subway station




그림 13. 철도환경에서 중간 혼잡도 오류율
Fig. 13. Error rate at intermediate crowdedness image at subway station




그림 14. 철도환경에서 높은 혼잡도 오류율
Fig. 14. Error rate at high crowdedness image at subway station

그림 12부터 그림 14는 철도환경에서 각각의 혼잡도 분류에서 발생하는 오류율 그래프이다. 그림 12는 낮은 혼잡도 측정시 발생하는 오류율이다. 그래프에서 알 수 있듯이 낮은 혼잡도 측정시 오류율은 초기 0.053의 오류율에서 15번 수행이후에는 오류율이 0으로 일정하게 유지됨을 알 수 있다. 이것은 초기에 선택된 약한 분류기가 우수한 성능으로 데이터들을 분류했기 때문이다. 다음으로 그림 13의 중간 혼잡도 측정시 발생 오류율은 낮은 혼잡도 측정시와 비슷하게 0.000959의 낮은 초기 오류율에서 14번의 반복수행 이후에 0.00048의 오류율로 유지되는 것을 확인 할 수 있다. 이는 낮은 혼잡도 측정시와 동일한 현상으로 볼 수 있다. 마지막 높은 혼잡도 분류시 오류율도 0.039의 초기오류율에서 16번 반복수행 이후에는 오류율이 0으로 유지되는 것을 확인 할 수 있다. 이것도 이전의 낮은 혼잡도와 중간 혼잡도 측정시 오류율과 같은 이유 때문이다. 철도환경에서도 도로환경에서처럼 오류율이 계속 감소하거나 유지되지 않고 증가하게 되는 원인은 오분류된 데이터의 분류를 위해 데이터의 가중치가 증가하게 되면 오분류 데이터를 분류하기 위해 선택된 약한 분류기가 다른 더 많은 데이터를 오분류 하게 되어 이전보다 오류율이 증가하게 되는 것이다.

4.2.3. 실험결과 분석

표2와 표3은 도로환경과 철도환경에서 각각의 혼잡도 측정에서 발생한 오류율을 분석한 표이다. 여기서 초기 오류율은 첫 번째 반복수행 했을 때의 오류율이고 최종 오류율은 200번 반복수행 했을 때의 오류율이다. 그리고 평균 오류율과 오류 표준편차는 200번 반복 수행된 오류율들의 평균과 표준편

차이다. 그리고 최소 오류율은 200번 반복 수행된 오류율 중 최소 오류율이다.

표 2. 도로환경에서 혼잡도 오류율
Table 2. Error rate of crowdedness on street

	낮은 혼잡도	중간 혼잡도	높은 혼잡도
초기 오류율	0.106241	0.190711	0.176778
최종 오류율	0.000581	0.003483	0.001161
평균 오류율	0.003251	0.022308	0.007607
오류 표준편차	0.012754	0.033576	0.020623
최소 오류율	0.000581	0.002903	0.000871

표 3. 철도환경에서 혼잡도 오류율
Table 3. Error rate of crowdedness at subway station

	낮은 혼잡도	중간 혼잡도	높은 혼잡도
초기 오류율	0.053161	0.000959	0.039272
최종 오류율	0	0.000480	0
평균 오류율	0.000582	0.000506	0.000570
오류 표준편차	0.004298	0.000109	0.003854
최소 오류율	0	0.000480	0

도로환경과 철도환경에서 동일하게 가장 높은 오류율을 보이는 것은 중간 혼잡도 측정이다. 중간 혼잡도 측정에서 상대적으로 높은 오류율이 나타나는 이유는 낮은 혼잡도 측정에서 높은 혼잡도로 측정되는 오분류가 일어날 확률이 적고 반대로 높은 혼잡도 측정에서 낮은 혼잡도로 오분류가 일어날 확률이 적지만 중간 혼잡도 측정에서는 낮은 혼잡도와 높은 혼잡도로 오분류될 확률이 있기 때문이다.

오류율 표를 보면 최소 오류율이 최종 오류율이 같은 값이 나오지 않는 경우가 있는 것을 알 수 있다. 이것은 반복수행 횟수와 분류기의 성능이 비례하지 않는다는 것을 의미한다. 결국 오류율이 계속 감소하거나 유지되지 않고 증가하게 되는 원인은 오분류된 데이터의 분류를 위해 데이터의 가중치가 증가하게 되면 오분류 데이터를 분류하기 위해 선택된 약한 분류기가 다른 더 많은 데이터를 오분류 하게 되어 이전보다 오류율이 증가하게 되는 것이다.

그리고 도로환경의 오류율이 철도환경의 오류율보다 상대적으로 높은 이유는 도로환경에서는 조명

의 변화나 환경적 요인의 오류요소가 많고 실내 환경에서는 우수한 약한 분류기가 존재하기 때문으로 볼 수 있다.

V. 결 론

본 논문에서는 혼합 분류기를 이용하여 실내·외 환경에서 다양한 객체의 혼잡도를 측정하는 방법을 제안하였다. 제안하는 시스템 구성은 특징추출, 분류기 학습, 강한 분류기 생성, 혼잡도 인식으로 크게 4단계로 구성된다. 특징 추출단계에서는 혼합분류기를 학습하기 위해 영상내의 영역별 특징을 추출하고 혼잡가중치로 모폴로지 영상을 사용하였다. 얻어진 특징을 이용해서 분류기를 학습시키고 성능을 업데이트하게 된다. 이렇게 반복 수행단계를 거쳐 우수한 성능을 갖는 분류기를 생성한다. 이 때 사용된 알고리즘이 AdaBoost 알고리즘이다. AdaBoost 기반의 혼합분류기는 여러 개의 약한 분류기들을 조합하여 강한 분류기를 생성해서 우수한 성능을 만드는 기법이다. 이 알고리즘에서 사용된 단순한 특징은 각각 독립적으로 사용될 경우에는 좋은 성능을 발휘 할 수 없지만 특징간의 관계를 연결시킴으로써 복잡한 환경과 환경의 변화에도 강인한 시스템을 구현할 수 있다는 장점이 있다. 또한 혼합 분류기 알고리즘을 사용함으로써 그림자나 반사, 조명변화 등이 일어나는 환경에서도 잠재적 특징들을 잘 활용할 수 있다. 이러한 장점으로 인해서 실험에서 사용된 'AVSS 2007'의 도로환경내의 자동차 혼잡도와 철도환경내의 승객 혼잡도 측정을 우수하게 수행하였다.

참 고 문 헌

- [1] T. Brox, A. Bruhn, J. Weickert, Variational motion segmentation with level sets, in: European Conference on Computer Vision, pp. 471 - 483, 2006.
- [2] M. Yokoyama, T. Poggio, A contour-based moving object detection and tracking, in: IEEE International Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance, pp. 271 - 276, 2005.
- [3] W. Fang, K.L. Chan, Using statistical shape

priors in geodesic active contours for robust object detection, in: International Conference on Pattern Recognition, pp. 304 - 307, 2006.

- [4] A.A. Stocker, An improved 2d optical flow sensor for motion segmentation, Proceedings of IEEE International Symposium on Circuits and Systems 2 (2002) 332 - 335, 2002.
- [5] S.P.N. Singh, P.J. Csonka, K.J. Waldron, Optical flow aided motion estimation for legged locomotion, in: IEEE International Conference on Intelligent Robots and Systems, pp. 1738 - 1743, 2006.
- [6] C. Stauffer, W.E.L. Grimson, Adaptive background mixture models for real-time tracking, in: Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1999.
- [7] T. Yu, C. Zhang, M. Cohen, Y. Rui, Y. Wu, Monocular video foreground/background segmentation by tracking spatial-color gaussian mixture models, in: IEEE Workshop on Motion and Video Computing, 2007.
- [8] Yoav Freund, "Boosting a weak learning algorithm by majority", Information and Computation, 121(2):256 - 285, 1995.

안 태 기 (Tae-ki An)

정회원




1993년 2월 경북대학교 전자공학과 학사
 1996년 2월 경북대학교 전자공학과 석사
 2011년 2월 성균관대학교 전자전기컴퓨터공학과 박사
 1996년 3월~현재 한국철도기술연구원 책임연구원

<관심분야> 멀티미디어 통신, 영상분석, 인공지능

안 성 제 (Seong-je Ahn)

정회원



2008년 8월 서울과학기술대학교 매체공학과 졸업
2011년 8월 서울과학기술대학교 NID융합기술대학원 석사 졸업
<관심분야> 컴퓨터 비전, 패턴 인식

박 구 만 (Goo-man Park)

종신회원



1991년 2월 연세대학교 전자공학과 박사
1991년 3월 ~ 1996년 9월 삼성전자 신호처리연구소 선임 연구원
1996년 9월~1999년 7월 호남대학교 전자공학과 조교수
1999년 8월~현재 서울과학기술대학교 전자IT미디어공학과 교수
2006년1월~2007년 8월 Georgia Institute of Technology Dept.of ECE, Visiting Scholar
<관심분야> 컴퓨터비전, 멀티미디어 통신

박 광 영 (Kwang-young Park)

정회원



2000년 2월 서강대학교 경제대학원 석사
1996년 12월~현재 (주)하이트론씨시스템즈 정보통신사업본부 팀장
<관심분야> 멀티미디어 통신, 영상인식, IT정책