

다중 클래스 아다부스트를 이용한 엘리베이터 내 군집 밀도 추정

김대훈*, 이영현**, 구분화**, 고한석*

Crowd Density Estimation with Multi-class Adaboost in elevator

Dae-Hun Kim*, Young-Hyun Lee**, Bon-Hwa Ku**, Han-Seok Ko *

요약

본 논문에서는 다중 클래스 아다부스트 기반의 분류기를 이용하여 엘리베이터 내 군집 밀도를 추정하는 방법을 제안한다. SOM을 사용하는 기존의 방법은 재현성이 떨어지며 충분한 성능을 내지 못한다. 제안한 방법은 GLDM(Grey-Level Dependency Matrix)과 GGDM(Grey-Gradient Dependency Matrix)의 텍스처 특징과 다중 클래스 아다부스트 기반의 분류기를 통해 실내 군집 밀도를 추정한다. 다중 클래스를 분류하기 위해 기존의 아다부스트 알고리즘에서 웨이트 업데이트 식을 변형하여 더 높은 성능의 약한 분류기를 생성하도록 하였다. 군집 밀도는 인원수에 따라 0명, 1~2명, 3~4명, 5명 이상 등 네 가지 클래스로 구분하였다. 엘리베이터 내 영상을 이용한 모의 실험 결과 제안된 방법은 기존의 방법보다 약 20% 정도의 검출률 향상을 나타내었다.

▶ Keyword : 다중 클래스 아다부스트, 군집 밀도 추정, 텍스처 특징

Abstract

In this paper, an crowd density in elevator estimation method based on multi-class Adaboost classifier is proposed. The SOM (Self- Organizing Map) based conventional methods have shown insufficient performance in practical scenarios and have weakness for low reproducibility. The proposed method estimates the crowd density using multi-class Adaboost classifier with texture features, namely, GLDM(Grey-Level Dependency Matrix) or GGDM(Grey-Gradient Dependency Matrix). In order to classify into multi-label, weak classifier which have better performance is generated by modifying a weight update equation of general Adaboost algorithm. The crowd density

• 제1저자 : 김대훈 • 교신저자 : 고한석

• 투고일 : 2012. 02. 01, 심사일 : 2012. 03. 21, 게재확정일 : 2012. 05. 16.

* 고려대학교 전기전자전파공학부(Dept. of Electrical Engineering , Korea University)

** 고려대학교 영상정보처리학과(Dept. of Visual Information Processing, Korea University)

※ 본 연구는 서울시 산학연 협력사업(WR080951)의 연구결과로 수행되었습니다.

is classified into four categories depending on the number of persons in the crowd, which can be 0 person, 1-2 people, 3-4 people, and 5 or more people. The experimental results under indoor environment show the proposed method improves detection rate by about 20% compared to that of the conventional method.

▶ Keyword : multi-class Adaboost, crowd density estimation, texture feature

1. 서 론

현대 사회에서 폭행, 유괴, 테러 등의 다양한 위협 요소는 나날이 증가하고 있다. 사회 곳곳에서 발생할 수 있는 위협 상황에 대응하기 위해 CCTV 기반의 영상 감시 보안 시스템이 널리 보급되고 있다. 그러나 기존의 감시 보안 시스템은 CCTV를 관찰하는 운용자의 대응에 전적으로 의존하기 때문에 동시에 관찰해야 할 모니터의 수가 많아지거나 감시 업무가 오랜 시간 지속되면 발생하는 위협 상황을 즉시 인지하지 못하여 빠른 대처가 어려워진다. 이러한 문제점을 해결하기 위하여 관찰된 영상에 대해 자동적으로 위협 상황을 인지하여 실시간으로 운용자에게 알려줌으로써 보다 능동적이고 효율성이 높은 지능형 감시 보안 시스템에 대한 연구가 활발하게 진행되고 있다[1]. 지능형 감시 보안 시스템 개발에 관한 연구는 사람이나 차량 같은 개별 객체를 검출, 추적하고 인지하는 모듈에 대한 연구가 많이 진행되고 있으며, 개별 객체의 모임 집단인 군중에 대한 분석도 함께 연구되고 있다[2-4]. 공공장소와 같이 다수의 사람이 있는 장소에서 사고가 발생한다면 사람들이 급격히 모일 가능성이 높으며 모인 군중에 의한 추가적인 사고 발생의 위험도 높아지게 된다. CCTV로부터 얻어지는 군집 밀도 정보는 이러한 잠재적인 위험 요소를 가지고 있는 군집 밀집 상황에 대해 효과적인 대처가 가능하도록 도움을 줄 수 있다. 또한 장소에 대한 군집 밀도의 통계 자료를 구축하여 경우에 따라 위험 사건 발생에 대한 가능성을 예측하여 운용자의 감시의 집중도를 높이거나 보행자의 수를 조절할 수도 있다.

군집 밀도를 자동적으로 추정하는 방법은 크게 두 가지 접근법이 있다. 첫 번째는 카메라로부터 얻어지는 영상에서 각각의 사람을 찾고 그 수를 세는 방법이다[5-8]. 그러나 이러한 방법들은 전체 사람을 한명씩 세야하기 때문에 사람의 수가 많은 환경에서는 심각한 겹침(occlusion) 문제로 인해 성능이 저하된다. 이러한 겹침 문제를 해결하기 위해 Haar 웨이블릿 변환(Haar wavelet transform)이나 서포트 벡터

머신(support vector machine)을 이용하여 얼굴 모양 윤곽을 인식하는 방법이 제안되었으며[9], 사람의 몸을 부분 부분으로 나누어 검출기를 학습시키는 방법이 제안되었다[10-12]. 또한 겹침 문제를 해결하기 위한 다른 방법으로 사람들의 이동 경로를 추적하는 방법도 제안되었다[13]. 그러나 추적 방법은 사람의 수가 증가할수록 연산량이 증가하는 문제점을 가지고 있다. 군집 밀도를 추정하는 두 번째 방법은 입력 영상으로부터 특징을 추출하고, 미리 정해놓은 기준이 되는 밀도와 유사도를 비교 한다. 이 방법은 정확한 사람의 수를 세지 않고 거시적인 관점에서 군집의 밀도를 구한다. GLDM(Grey-Level Dependency), 푸리에 스펙트럼(Fourier spectrum), 민코프스키 프랙탈 차원(Minkowski fractal dimension) 등을 특징으로 하여 텍스처 정보를 비교하는 방법이 제안되었다[14-16]. 텍스처 특징 정보를 학습시키는 방법으로는 자가 조직화 신경망 방법(self organizing neural maps)이 적용되었다. 단일 영상에서 텍스처 정보를 뽑는 방법 외에도 연속된 영상에서 중요한 특징들을 추가적으로 추출하여 신경망 방법으로 밀도에 대한 모델링을 하는 방법도 제안되었다[17]. SOM 트레이닝 방식 이외에도 SVM(Support Vector Machine)을 이용하여 군중 밀도를 추정하는 방법이 제안되었다[18]. 그러나 이러한 특징 비교 방법들은 기준 밀도 설정을 위해 많은 샘플들을 통한 오랜 훈련 과정을 필요로 한다. 군집 밀도의 수준에 따른 텍스처 특징이 배경에 따라 달라질 수 있기 때문에 다른 배경에 대해서는 추가적인 훈련 과정을 요구하기도 한다.

기존의 자가 조직화 신경망 방법은 훈련 데이터 입력 순서에 따라 클러스터링 결과가 다르게 나타나기 때문에 재현성이 낮다는 단점을 가지고 있다. 또한 사용하는 특징의 차원이 높아질수록 학습 및 검출 시간이 크게 증가하는 단점이 존재한다. 본 논문에서는 학습 방법의 용이성 및 시간을 고려하여 아다부스트 알고리즘을 적용한 접근법을 제안한다. 아다부스트 학습 방법은 훈련 데이터의 순서에 독립적인 학습 결과를 보이며, 구현 및 학습 속도가 기존의 방법 보다 빠른 장점을 지닌다. 훈련 특징으로는 GLDM 과 더불어 GGDM(Grey-Gradient Dependency Matrix)의 텍스처

특징을 사용하였다. 제안된 방법은 GLDM과 GGDM의 텍스처 정보와 다중 클래스 아다부스트 훈련 기법을 통해 정의된 네 가지 클래스의 군집 밀도를 추정한다.

본 논문의 구성은 다음과 같다. 2장에서는 영상의 텍스처 특징으로 사용할 GLDM과 GGDM에 대해서 설명하며, 3장에서는 멀티 클래스 아다부스트 알고리즘에 대해서 다룬다. 4장에서는 모의 실험을 통해 제안한 방법의 효용성을 입증한 후 결론을 맺는다.

II. 텍스처 특징 추출 기법

1. GLDM

GLDM(Grey-Level Dependency Matrix)은 원래 위성 사진이나 항공사진, 현미경 사진에서 텍스처 정보를 측정하기 위해 사용되었다[2,19]. GLDM은 주어진 영상에서 픽셀 짝의 확률에 해당하는 결합 조건부 확률 밀도 함수(joint conditional probability density function)로 간주될 수 있다. $N \times M$ 의 크기의 그레이 레벨 영상 P 에서 GLDM을 구하는 방법은 식 (1)과 같다. GLDM은 d 만큼 떨어져있는 인근 픽셀 사이 관계에서 그레이 레벨 i 와 그레이 레벨 j 의 상대적 발생빈도를 표현한다. 영상에서의 그레이 레벨의 상호 발생빈도는 텍스처 정보를 의미한다.

$$C(i, j|d, \theta) = \sum_{x=1}^N \sum_{y=1}^M (\delta(P(x, y) - i) \times \delta(P(x', y') - j)) \quad (1)$$

여기서 $i, j = 0, 1, \dots, 255$, $x' = x + d \cos(\theta)$, $y' = y + d \sin(\theta)$ 이다.

본 논문의 모의실험에서 GLDM은 $d=1$, $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ\}$ 와 $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ 을 사용하였다.

2. GGDM

GGDM(Grey-Gradient Dependency Matrix)은 GLDM과 마찬가지로 텍스처 인식에 사용되는 텍스처 정보이다[3]. GLDM이 영상의 그레이 레벨 정보만을 이용하는 것과는 달리 GGDM은 영상의 기본적인 그레이 레벨 정보와 영상의 기울기 정보를 함께 사용한다. $N \times M$ 크기의 그레이 레벨 영상 P 와 기울기 영상 G 가 주어졌을 때 GGDM을 구하

는 방법은 식 (2)와 같다. g_{max} 는 기울기 영상에서 최대 픽셀값으로 정의한다. GGDM은 d 만큼 떨어져있는 인근 픽셀 사이 관계에서 그레이 레벨 i 와 기울기 크기값 j 의 상대적 발생 빈도를 표현한다.

$$C(i, j|d, \theta) = \sum_{x=1}^N \sum_{y=1}^M (\delta(P(x, y) - i) \times \delta(G(x', y') - j)) \quad (2)$$

여기서 $i = 0, 1, \dots, 255$, $j = 0, 1, \dots, g_{max}$

$x' = x + d \cos(\theta)$, $y' = y + d \sin(\theta)$ 이다.

본 논문의 모의실험에서 GLDM은 GGDM과 같이 $d=1$, $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ\}$ 와 $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ 을 사용하였다. 그림 1의 (e)와 (f)는 $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$, $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ\}$ 가 주어졌을 때 픽셀 짝을 찾는 방법을 표현하였다. 적색 픽셀이 $P(x, y)$ 의 위치라면 녹색 픽셀이 $P(x, y)$ 와 짝을 이루는 $G(x', y')$ 의 가능한 위치를 나타낸다.

3. GLDM / GGDM으로부터 특징 추출

GLDM과 GGDM의 특징값의 범위는 영상의 최대값의 제곱이 된다. 이 특징을 바로 사용하는 것은 연산량 증가를 불러일으키며, 이를 해결하기 위해 정규화 과정을 거치게 된다. 식 (3)은 영상 레벨 값을 정규화 하는 과정이다[3].

$$F(x, y) = INT \left[\frac{f(x, y) \cdot f_{nor}}{f_{max}} \right] + 1 \quad (3)$$

식 (3)에서 INT는 반올림 함수이며 f_{max} 는 영상 f 가 가질 수 있는 그레이 레벨 최대값이고, f_{nor} 은 정규화 후 영상이 가질 최대값이다. 그림 1에서 (b)와 (d)는 각각 (a)와 (c)의 영상 레벨 값을 10으로 정규화 과정을 거친 결과 영상이다. 그림 1에서 보는 바와 같이 정규화 이후에도 정보의 손실은 크게 일어나지 않는 것을 알 수 있다.

GLDM과 GGDM이 추출되는 패치 영상(patch image)은 40×40 크기와 20×20 크기를 사용하였으며 패치 영상은 패치 영상 한 번의 절반 길이만큼 이동하며 매 위치마다 GLDM과 GGDM을 추출한다. 추출된 GLDM과 GGDM의 특성을 파악하기 위해 식 (4)~(7)과 같은 대비(Contrast),

동질성(Homogeneity), 에너지(Energy), 엔트로피(Entropy) 지표를 사용하였다[2,20].

Contrast:

$$Con(d, \theta) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i-j)^2 C(i, j|d, \theta) \quad (4)$$

$$Homogeneity: Ho(d, \theta) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{C(i, j|d, \theta)}{1 + (i-j)^2}$$

$$Energy: E(d, \theta) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} C(i, j|d, \theta)^2$$

Entropy:

$$H(d, \theta) = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} C(i, j|d, \theta) \log C(i, j|d, \theta)$$

위와 같은 특징 추출 방법으로 한 영상 당 얻어지는 특징 벡터의 차원은 4*(패치의 개수)*(θ의 개수)*(d의 개수)로 결정된다.

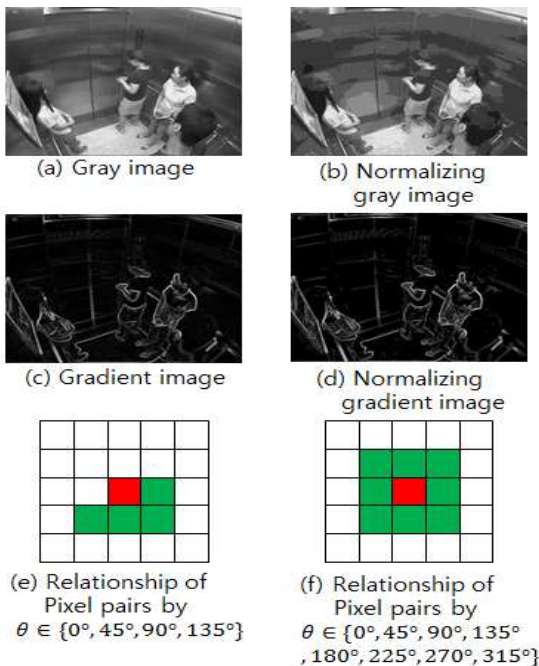


그림 1. GGDM 계산 과정
Fig. 1. Procedure of GGDM calculation

III. 다중 클래스 아다부스트 훈련 및 분류

1. 아다부스트 알고리즘을 통한 훈련과정

아다부스트 알고리즘은 단순한 가설에 근거한 약한 분류기를 선형 결합하여 강한 분류기를 생성하는 방법이다[20]. 약한 분류기를 이용하여 샘플들을 인식하고, 정확히 인식된 샘플에 대해 가중치를 감소시키고, 오인식된 샘플에 대해서는 가중치를 증가시켜 다음 약한 분류기에 반영시킨다. 최종적인 강한 분류기는 각 단계에서 생성된 약한 분류기들의 조합으로 구성된다. 일반적인 강한 분류기의 결과는 임계값과의 비교를 통해 0 또는 1의 값을 갖게 되어 이진 분류기의 역할을 수행한다. 하지만 우리가 분류해야 할 대상은 2개 이상의 클래스로 분류해야 한다. 그래서 이 강한 이진 분류기를 조합하여 멀티 클래스 분류기를 구성한다. 클래스가 $C \in \{1, \dots, C\}$ 으로 구성되어 있다면 우선 기본적인 아다부스트 알고리즘을 이용하여 C개의 강한 분류기를 만든다. 각각의 강한 분류기를 만들 때는 하나의 클래스의 샘플을 양성의 샘플(positive sample)로 선정하고 나머지 모든 클래스에 대한 샘플을 음성의 샘플(negative sample)로 선정하여 분류기를 만든다. 각각의 클래스에 대한 약한 분류기를 선형 결합을 함으로써 해당 클래스의 강한 분류기를 만들어 낸다.

다중 클래스를 분류하게 위해서는 약한 분류기의 성능이 기존의 방법보다 정확성을 가져야 한다. 기존의 아다부스트 알고리즘에서는 약한 분류기의 오차율이 1/2보다 더 작은 약한 분류기로 구성을 하였다. 그러나 C개의 클래스를 구분하기 위해서는 정확도가 1/C보다 우수한 약한 분류기로 구성을 해야 한다. 그러기 위해서는 음성의 샘플에 대해서 비중을 더 주어 해당 음성의 샘플을 잘 분리할 수 있는 약한 분류기를 구성하도록 해야 한다.

$$\alpha^{(m)} = \log\left(\frac{1 - err^{(m)}}{err^{(m)}}\right) \quad (8)$$

$$\alpha^{(m)} = \log\left(\frac{1 - err^{(m)}}{err^{(m)}}\right) + \log(C - 1) \quad (9)$$

식 (8)은 기존의 아다부스트 알고리즘에서의 $\alpha^{(m)}$ 계산식이다. 약한 분류기의 성능을 더 향상시키기 위하여 식 (9)와

같이 $\alpha^{(m)}$ 계산식을 바꾸어 주었다[21]. 다중 클래스 아다부스트 알고리즘에서의 k번째 클래스와 k를 제외한 클래스를 분류하는 강한 분류기를 구성하는 방법은 표 1과 같다.

표 1. 강한 분류기의 슈도코드
Table 1. Pseudo code of strong classifier

<p>● k번째 클래스 강한 분류기</p> <p>I. 라벨링 이진화</p> <ul style="list-style-type: none"> • If $c_i = k$ $\Rightarrow c_i = +1$ (positive sample) • If $c_i \neq k$ $\Rightarrow c_i = -1$ (negative sample) <p>II. 가중치 초기화</p> $w_i = \frac{1}{n}, i = 1, 2, \dots, n$ <p>III. Iteration for $m = 1$ to M :</p> <p>A. 가중치 w_i를 이용하여 약한 분류기 $T^{(m)}(x)$를 구함</p> <p>B. 약한 분류기의 오차를 구함</p> $err^{(m)} = \sum_{i=1}^n w_i I(c_i \neq T^{(m)}(x_i)) / \sum_{i=1}^n w_i$ <p>C. $\alpha^{(m)}$을 구함</p> $\alpha^{(m)} = \log\left(\frac{1 - err^{(m)}}{err^{(m)}}\right) + \log(C - 1)$ <p>D. 가중치 w_i를 갱신</p> $w_i \leftarrow w_i \exp(\alpha^{(m)} I(c_i \neq T^{(m)}(x_i)))$ <p>E. 가중치 w_i를 정규화</p>

2. 아다부스트 알고리즘을 통한 분류과정

아다부스트 알고리즘으로 구성된 강한 분류기는 약한 분류기들과 그에 해당하는 가중치로 이루어져 있다. 약한 분류기는 입력으로 특징을 받으면 0 또는 1을 출력으로 하고, 가중치는 0과 1사이의 실수 값이다. 즉, 강한 분류기는 0보다 큰 실수 값을 가진다. 각 클래스에 대한 강한 분류기의 결과가 높을수록 해당 클래스에 대해 신뢰도가 높음을 뜻하고 해당 클래스일 확률이 가장 크다는 것을 나타낸다[22]. 다중 클래스 아다부스트 알고리즘의 분류기는 식 (10)과 같이 정의된다.

$$C(x) = \arg \max_k \sum_{m=1}^M \alpha^{(m)} I(T^{(m)}(x_i) = k) \quad (10)$$

입력된 영상으로부터 2장에서 설명한 방법으로 GLDM / GGDM에서 특징벡터를 추출한다. 추출한 특징을 C개의 각 클래스에 대한 강한 분류기에 각각 넣는다. 이때 계산되는 값이 최대가 되는 강한 분류기의 양성 클래스가 입력 영상이 분류될 클래스가 된다. 그림 2는 다중 클래스 아다부스트 알고리즘을 이용한 분류 과정을 표현한다.

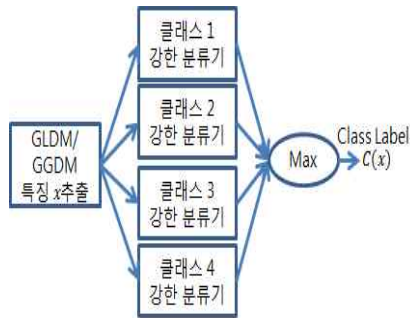


그림 2 다중 클래스 아다부스트 분류기
Fig. 2. Classifier based on multi-class adaboost

IV. 모 의 실험

본 논문에서 제안한 방법의 효용성을 보이기 위하여 모의 실험을 하였다. 실험 DB는 엘리베이터 내부 환경에서의 CCTV영상으로 구성하였다. CCTV는 엘리베이터 왼쪽 상단 구석에 설치하였으며 CCTV로부터 수집된 영상의 해상도는 320x240 크기이다. 군집 밀도 분류를 위해 엘리베이터 문이 닫힌 상태일 때 엘리베이터 내부의 사람 수를 기준으로 실험 DB를 나누었다. 클래스 분류는 총 4개의 클래스로 나누었으며 각각 엘리베이터 내부에 사람이 0명 / 1~2명 / 3~4명 / 5명 이상이 있을 경우로 나누었다. 각 클래스마다 학습 DB로 2000장과 테스트 DB로 500장을 사용하였다. 그림 3은 DB의 클래스 분류에 관한 예제 사진이다.

학습 및 분류를 위한 특징은 GLDM과 GGDM에 대해 각각 실험을 진행하였다. 분류기는 제안한 멀티 클래스 아다부스트 기법을 이용한 분류기와 자가 조직화 신경망 방법[14]을 이용한 분류기와 SVM을 이용한 분류기의 성능을 비교 실험하였다. 성능평가는 학습 시간, 검출 속도, 검출률에 대해

이루어 졌다. 트레이닝 속도와 검출 속도는 2.67GHz 듀얼 코어 CPU, 4GB RAM의 컴퓨터에서 Matlab2010a를 이용하여 측정하였다.



그림 3. 클래스 분류의 예
Fig. 3. Example of classification

표 2는 실험에 사용한 DB에서 추출한 특징 벡터의 차원 수를 파라미터에 따라 표현한다. 표 3와 표 4와 표 5는 동일한 DB에 대하여 GLDM과 GGDM으로 특징을 추출해서 다중 클래스 아다부스트와 자가 조직화 신경망과 SVM으로 만든 분류기에 대한 성능 평가이다.

표 2. 실험에 사용된 특징벡터의 차원 수
Table 2. number of feature vector in this experiment

θ 의 개수	패치영상크기	특징벡터의 차원 수
4	40x40	2640
	20x20	11408
8	40x40	5280
	20x20	22816

표 3. 다중 클래스 아다부스트 성능 평가
Table 3. Performance of multi class Adaboost

특징	θ 의 개수	패치 영상 크기	학습 시간 (s)	검출 속도 (ms/frame)	검출률
GLDM	4	40x40	573	2.53	86.9%
		20x20	2000	3.25	87.3%
	8	40x40	1251	2.51	82.7%
		20x20	3972	2.85	87.3%
GGDM	4	40x40	471	2.03	87.8%
		20x20	1920	2.56	80.9%
	8	40x40	1080	2.42	80.7%
		20x20	4430	3.13	82.5%

표 4. 자가 조직화 신경망 성능 평가
Table 4. Performance of self organizing map

특징	θ 의 개수	패치 영상 크기	학습 시간 (s)	검출 속도 (ms/frame)	검출률
GLDM	4	40x40	873	0.68	64.1%
		20x20	9467	5.35	58.6%
	8	40x40	2441	1.89	60.4%
		20x20	42532	17.03	58.8%
GGDM	4	40x40	785	0.59	59.4%
		20x20	9467	5.35	58.6%
	8	40x40	2392	1.71	60.3%
		20x20	43910	16.69	60.8%

표 5. SVM 성능 평가
Table 5. Performance of support vector machine

특징	θ 의 개수	패치 영상 크기	학습 시간 (s)	검출 속도 (ms/frame)	검출률
GLDM	4	40x40	1301	1.87	78.1%
		20x20	5433	5.33	82.1%
	8	40x40	2665	3.83	78.3%
		20x20	12355	10.05	82.1%
GGDM	4	40x40	1308	0.73	70.2%
		20x20	2801	3.26	67.7%
	8	40x40	1884	1.26	70.3%
		20x20	6469	6.50	68.0%

학습에 소요된 시간이 다중 클래스 아다부스트 알고리즘이 자가 조직화 신경망 알고리즘과 SVM보다 전반적으로 적은 것을 알 수 있다. 또한 자가 조직화 신경망 알고리즘은 특징의 개수가 증가할수록 학습에 소요되는 시간이 크게 증가하는 것을 알 수 있다. 프레임 당 검출 속도에서는 다중 클래스 아다부스트 알고리즘은 거의 고르게 실시간 처리가 가능한 2~3ms/frame의 속도를 가졌으나, 자가 조직화 신경망 알고리즘과 SVM 알고리즘은 특징의 개수에 따라 크게 차이를 보였다. 전체 평균 검출률도 제한한 방법이 자가 조직화 신경망 알고리즘보다 약 20%정도 더 높게 나타났으며 SVM 알고리즘보다는 약 10%정도 더 높게 나타났다.

자가 조직화 신경망 알고리즘은 특징 데이터 입력 순서에 따라 군집화 결과가 다르게 나타나서 재현성이 낮다는 단점을 지니고 있다. 반면에 아다부스트 알고리즘은 특징 데이터 입력 순서에 크게 결과가 변하지 않는다.

표 6와 표 7는 각각 θ 의 개수가 4일 때 GLDM특징과 GGDM특징에서의 다중 클래스 아다부스트 알고리즘의 실험 결과에 해당하는 분류 행렬이다. 표 5의 실험에서는 패치 영상 크기가 20이고, 표 7의 실험에서는 패치 영상 크기가 40이다.

표 6와 표 7에서 보듯이 3~4명 클래스 분류 성능이 떨

어졌지만 나머지 클래스에 대해서는 90%이상의 높은 정확도를 보였다.

표 6. GLDM을 사용한 다중 클래스 아다부스트의 분류행렬
Table 6. Confusion matrix of multi class Adaboost using GLDM

	0명	1~2명	3~4명	5~ 명
0명	99.8%	0.2%	0%	0%
1~2명	4.6%	93.8%	1.6%	0%
3~4명	5%	10.6%	55.6%	28.8%
5~ 명	0%	0%	0%	100%

표 7. GGDM을 사용한 다중 클래스 아다부스트의 분류행렬
Table 7. Confusion matrix of multi class Adaboost using GGDM

	0명	1~2명	3~4명	5~ 명
0명	100%	0%	0%	0%
1~2명	0%	97.8%	2.2%	0%
3~4명	8.4%	7.6%	62.6%	21.4%
5~ 명	1%	2%	8%	90.8%

V. 결 론

본 논문에서는 다중 클래스 아다부스트를 이용한 실내 군집 밀도 추정 알고리즘을 제안하였다. 제안한 방법의 효율성을 위해 기존의 자가 조직화 신경망 방식의 검출기와 비교 평가하였다. 제안한 방법의 검출률은 기존의 방법보다 약 20% 정도 향상된 결과를 보였다. 또한 기존의 방법은 특징의 개수가 증가함에 따라 검출 속도가 급격히 저하되는 모습을 보였지만, 제안한 방법의 검출 속도는 특징의 개수 변화에 강인한 모습을 나타내었다. 향후 연구 계획은 본 논문의 훈련 방법을 바탕으로 더 많은 장소의 DB를 이용하여 추가 실험을 할 것이며 군집 밀도 추정에 적합한 새로운 특징 추출 연구를 수행할 예정이다.

참고문헌

[1] W. Hu, T. Tan, L. Wang and S. Maybank, "A survey on visual surveillance of object motion

and behaviors", IEEE transactions on Systems, Man and Cybernetics - Part C, Vol. 34, No. 3, pp. 334-352, 2004

[2] H. Rahmalan, M. S. Nixon, and J. N. Carter. "On crowd density estimation for surveillance." In International Conference on Crime Detection and Prevention, pp.540C-545C, 2006.

[3] N. Dong, F. Liu and Z. Li, "Crowd Density Estimation Using Sparse Texture Features," Journal of Convergence Information Technology, vol. 5, pp. 125-137, 2010.

[4] J. C. S. J. Junior , S. R. Musse and C. R. Jung "Crowd analysis using computer vision techniques: A survey", IEEE Signal Process. Lett., vol. 27, no. 5, pp.66 - 77 , 2010.

[5] B. Zhan, D. N. Monekosso, P. Remagnino, S. A. Velastin, and L. Xu. "Crowd analysis: A survey.," Journal of Machine Vision and Applications, vol.19, pp.345-357, 2008.

[6] P. Viola, M. Jones, and D. Snow, "Detecting pedestrians using patterns of motion and appearance", International Journal of Computer Vision, Springer US, vol.63, no.2, pp.153-161, 2005.

[7] H. Tao, D. Kong, D. Gray, "Counting Pedestrians in Crowds Using Viewpoint Invariant Training", In Proceedings of the British Machine Vision Conference, pp.1-8, 2005.

[8] T. Zhao and R. Nevatia, "Bayesian human segmentation in crowded situations", In Proceedings of the Conference on Computer Vision and Pattern Recognition, pp.459 - 466, 2003.

[9] S.F. Lin, J.Y. Chen, and H.X. Chao, "Estimation of number of people in crowded scenes using perspective transformation", IEEE Trans. System, Man, and Cybernetics, IEEE, vol.31, no.6, pp.645-654, 2001.

[10] A. Mohan, C. Papageorgiou, and T. Poggio, "Example-Based Object Detection in images by Components", IEEE Trans on PAMI, IEEE, vol.23, no.4, pp.394-361, 2001.

[11] K. Mikolajczyk, C. Schmid, and A. Zisserman, "Human Detection Based on a Probabilistic Assembly of Robust Part Detector", In Proceedings of the European Conference on Computer Vision, pp.69-82, 2004.

[12] B. Wu and R. Nevatia, "Detection of multiple, partially occluded humans in a single image by bayesian combination of edgelet part detectors", In Proceedings of the International Conference on Computer Vision, pp.90-97, 2005.

[13] V. Rabaud and S.J. Belongie, "Counting crowded moving objects", In Proceedings of the Conference on Computer Vision and Pattern Recognition, pp.705-711, 2006.

[14] A.N. Marana, M.A. Cavenaghi, R.S. Ulson, and F.L. Drumond, "Real-Time Crowd Density Estimation Using Images", Lecture Notes in Computer Science, Springer, no.3804, pp.355-362, 2005.

[15] A.N. Marana, L.F. Costa, R.A. Lotufo, and S.A. Velastin, "On the efficacy of texture analysis for crowd monitoring", In Proceedings of the Computer Graphics, Image Processing, and Vision, pp.354-361, 1998.

[16] A.N. Marana, L. Da F. Costa, R.A. Lotufo, S.A. Velastin, "Estimating crowd density with Minkowski fractal dimension", In Proceedings of the Conference on Acoust., Speech, Signal Processing, pp.3521-3524, 1999.

[17] S.Y. Cho, T.W.S. Chow, and C.T. Leung, "A neural-based crowd estimation by hybrid global learning algorithm", IEEE Trans. Syst, Man, Cybern, IEEE, vol.29, no.3, pp.535-541, 1999.

[18] WL Hsu, KF Lin and CL Tsai, "Crowd density estimation based on frequency analysis", 7th IHH-MSP, pp. 348-351, 2011

[19] R.M. Haralick, "Statistical and structural approaches to texture", Proceedings of the IEEE, volume 67, pp. 786-804, 1979.

[20] P. Viola, M. Jones, "Rapid object detection using a boosted cascade of simple features.", CVPR, vol. 1, pp. 511-518, 2001

[21] J. Zhu, S. Rosset, H. Zou, and T. Hastie. Multi-class adaboost. Technique Report, 2005.

[22] R.E. Schapire and Y. Singer, "Improved Boosting Algorithms Using Confidence-Rated Predictions", Machine Learning, vol. 37, no. 3, pp. 297-336, 1999.

저 자 소개



김 대 훈
 2011: 고려대학교 전기전자전파공학부 공학사
 현 재: 고려대학교 전기전자전파공학과 석박사통합과정
 관심분야: 영상신호처리
 Email : dhkim@ispl.korea.ac.kr



이 영 현
 2007: 고려대학교 전기전자전파공학부 공학사
 현 재: 고려대학교 영상정보처리학과 석박사통합과정
 관심분야: 신호처리, 개체검출, 영상인식
 Email : yhlee@ispl.korea.ac.kr



구 분 화
 2000: 광운대학교 제어계측공학과 공학사
 2002: 고려대학교 전자공학과 공학석사
 2008: 고려대학교 영상정보처리학과 공학박사
 현 재: 고려대학교 연구 교수
 관심분야: 표적 탐지/추적, 데이터 융합
 Email : bhku@ispl.korea.ac.kr



고 한 석
 1982: Carnegie-Mellon University 전기공학 공학사
 1988: Johns Hopkins University 전자공학 공학석사
 1992: Catholic Univ. of America 전자공학 공학박사
 현 재: 고려대학교 전기전자전파공학부 교수
 관심분야: 영상 및 음성 신호처리, 패턴 인식
 Email : hsko@korea.ac.kr