

동적 베이지안 네트워크를 이용한 동영상 기반의 화재연기감지

준회원 이인규*, 정회원 고병철*, 남재열*

Fire-Smoke Detection Based on Video using Dynamic Bayesian Networks

In-gyu Lee* Associate Member, ByungChul Ko*, Jae-yeol Nam* Regular Members

요약

본 연구는 CCD카메라로부터 입력된 영상을 분석하여 특징값을 추출하고, 패턴인식기술을 이용하여 화재연기영상을 감지하는 방법을 제안한다. 우선 CCD카메라로부터 획득된 영상들간의 차영상을 이용하여 움직임 영역만을 검출하고, 이후 연기색상모델을 적용하여 후보영역을 생성한다. 연기영역은 유사색상의 군집화를 이루고, 주변에 비해 단순한 질감을 가지며, 시간에 따른 모션정보의 상승 방향성을 가지는 특징을 가진다. 본 논문에서는 연기영역의 이러한 특성을 이용하여 학습영상으로부터 연기의 밝기, 웨이블릿 고주파 성분, 모션 벡터 등의 특징 값을 추출하고 이들 특징 값들에 대해 가우시안 확률 모델을 생성한다. 이렇게 추출된 확률모델은 연기영역의 시간적 연속성을 고려하기 위해 본 논문에서 새롭게 구성한 동적 베이지안 네트워크의 관찰노드에 적용된다. 본 논문에서 제안하는 방법은 산불을 비롯한 다양한 연기를 감지하였으며, 기존의 알고리즘에 비해 우수한 성능을 보여주었다.

Key Words : Fire-smoke detection; Gaussian mixture models; Dynamic bayesian Networks; Wavelet Transforms; 3 step search algorithm.

ABSTRACT

This paper proposes a new fire-smoke detection method by using extracted features from camera images and pattern recognition technique. First, moving regions are detected by analyzing the frame difference between two consecutive images and generate candidate smoke regions by applying smoke color model. A smoke region generally has a few characteristics such as similar color, simple texture and upward motion. From these characteristics, we extract brightness, wavelet high frequency and motion vector as features. Also probability density functions of three features are generated using training data. Probabilistic models of smoke region are then applied to observation nodes of our proposed Dynamic Bayesian Networks (DBN) for considering time continuity. The proposed algorithm was successfully applied to various fire-smoke tasks not only forest smokes but also real-world smokes and showed better detection performance than previous method.

I. 서론

건물의 대형화와 인구의 도시집중화는 다양한 안전사고에 대한 예방의 필요성을 증대시키고 있으며,

이를 자동으로 처리하기 위한 여러 공학적 연구들이 활발히 진행되어 오고 있다. 특히, 최근에는 대형 화재 사고가 빈번하게 발생하고 이에 따른 인명 및 재산 피해가 급속도로 증가함에 따라, 화재를 미

※ 본 연구는 교육과학기술부와 한국산업기술재단의 지역혁신인력양성사업으로 수행된 연구결과임

* 계명대학교 컴퓨터공학과({threecolorhair, niceko, jynam}@kmu.ac.kr)

논문번호 : KICS2009-02-041, 접수일자 : 2009년 2월 3일, 최종논문접수일자 : 2009년 4월 6일

연에 감지하여 조기진화가 가능하도록 할 수 있는 무인 자동 감지 장치에 대한 연구의 필요성이 증대되고 있다.

화재는 그 특성상 불꽃이 발생하기 전에 연기가 발생함으로 조기 화재감지를 위해서는 연기를 감지하는 센서의 개발이 필수적이다. 현재 대부분의 화재 감지 시스템은 광학(optical)센서와 이온(ion)센서를 통해 연기를 감지한다. 하지만 이러한 방법은 건물의 실내와 같이 공간이 폐쇄적이어야 하며 공간의 특정부분에 장착된 센서에 연기가 확산될 때까지 감지가 불가능하고, 야외와 같이 열린 공간의 경우는 바람이나 날씨 등에 의해 연기의 농도가 약해지게 되어, 감지 자체가 불가능해 질 수도 있다는 단점이 있다. 또한 산불과 같이 넓은 영역의 공간에서의 연기 감지에 있어서도 연기가 특정 위치에서 가동 중인 센서에 도달하기 어렵기 때문에 감지가 늦어지거나 오 감지를 하게 되는 문제점이 있다. 따라서 이러한 단점들을 보완하고 보다 신뢰성 있는 연기 감지를 위해서 최근 CCD 카메라에서 입력되는 영상을 분석하여 연기를 감지하는 방법들이 연구되고 있다^{1,2,3,4,8,9,10}.

화재를 감지하는 연구는 크게 불꽃과 연기를 감지하는 두 가지 방법으로 나눌 수 있다. 이중에서도 연기를 감지하는 방법은 초기단계의 화재를 감지하거나 산불연기와 원거리에 위치한 화재를 감지할 수 있다는 이점이 있어 실질적인 화재예방에 도움을 줄 수 있다. 화재 연기감지와 관련된 기존의 연구 동향을 살펴보면 다음과 같다.

Chen¹¹등은 규칙기반에 의한 연기감지방법을 제안하였다. RGB/HSI 색공간을 이용하여 연기의 색깔이 회색을 띠고 있다는 사실과 연기가 발생할 때 그 움직임이 불규칙한 모양으로 확산된다는 특성을 경험적 임계값에 적용하여 연기영역을 판단하였다.

Töreyin¹²등은 외곽성분을 이용한 연기감지방법을 제안하였다. 화재의 초기 단계에서 연기가 반투명하게 보인다는 사실에 기반을 두어 웨이블릿 변환 후 고주파성분의 변화를 특징으로 사용하였다. 또한 HMM(Hidden Markov Model)을 이용하여, 연기경계에서 고주파성분이 주기적으로 깜빡거리는 상태를 파악하여 연기영역임을 검증하였다.

Yuan¹³등은 연기영역은 위쪽 방향으로 상승한다는 사실을 이용하여, 영상으로부터 움직임벡터를 측정하고 이를 방향 히스토그램으로 변환하여 상대적으로 위쪽 방향의 움직임 벡터가 많은 경우 연기영역으로 판단하는 방법을 사용하였다.

Vezzani¹⁴등은 웹 기반의 대용량 비디오 감시 시스템을 제안하였다. 이 시스템은 연기이외에도 일반 객체의 움직임들을 구별하여 판단하고, 연기영역에서의 웨이블릿 에너지가 급감하는 특성을 확률 모델로 나타내어 이를 베이저안 추론에 적용하는 방법을 사용하였다.

공통적으로 기존 관련연구들은 일반 CCD카메라로부터 획득된 영상을 이용하였고, 급격한 조명의 변화가 없는 실내 및 주간 실외환경으로 실험을 제한하고 있으며, 야간 영상에 대해서는 아직 연구가 이루어지지 않고 있다. 본 연구에서도 기존 연구와 비슷한 환경에서 촬영된 동영상을 이용하여 제안한 방법에 대한 실험결과를 도출하였다.

불꽃과 연기를 감지하는 방법은 움직임의 불규칙성을 갖는다는 점에서 비슷한 특성을 가지지만, 확산의 속도 및 연기 색상의 농도변화 등 많은 부분에서 다른 점을 가지고 있다. 또한, 일반 연기와 산불 연기는 연기 확산의 속도 면에서 대조되는 특징을 가지는 데, 이는 산불 감지를 위해 설치된 CCD 카메라가 그 특성상 원거리의 초점거리를 가지게 됨으로 일반 연기의 움직임에 비해 현저하게 움직임이 느린 영상으로 획득된다는 점이다. 본 논문에서는 이렇게 서로 다른 특징을 가지는 근거리 연기뿐만 아니라 원거리 산불연기도 모두 감지 할 수 있도록 키 프레임(Key frame)을 이용하여 초기 움직임영역을 검출하고, 후보 영역에 포함된 일반 객체 및 구름의 움직임 등의 연기 유사 물체와의 구분을 위해 시간적 흐름에 따른 모션정보를 관찰하였다. 위 과정에서 추출된 특징들을 이용하여 가우시안 확률밀도함수(Probability Density Function)를 생성하고, 각 특징들의 확률 값을 동적 베이저안 네트워크(Dynamic Bayesian Networks)에 적용하여 최종 연기 영역을 판단하는 알고리즘을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 느린 연기와 빠른 연기를 모두 감지하기 위한 방법으로 키프레임을 이용하여 차영상을 추출하고 이를 가우시안 혼합 모델링에 적용하여 연기 색상에 적합한 영역들을 후보영역으로 검출하는 방법을 설명한다. 3장에서는 각 특징 값들에 대한 가우시안 확률 모델 생성 방법과 이를 동적 베이저안 네트워크에 적용하는 방법을 설명한다. 4장에서는 제안된 알고리즘과 기존의 알고리즘간의 성능을 비교분석하고 5장에서는 본 논문에 대한 결론을 서술한다.

II. 연기 후보영역 검출

2.1 키프레임과 차영상을 이용한 연기후보영역 결정
우선 CCD 카메라로부터 입력된 영상으로부터 실시간으로 연기 후보영역을 검출하기 위해 영상을 MxN의 블록으로 나누고 이후의 작업은 블록단위로 처리된다. 본 논문에서는 다양한 크기의 영상에 동일한 알고리즘이 적용될 수 있도록 하기 위해 MPEG 동영상의 비율을 고려하여 32x24개의 블록으로 나누었다.

일반 실내에서 발생하는 연기와는 다르게 산불연기의 경우, 연기를 관측하기 위해 설치된 CCD카메라가 실제 산불 연기가 발생하여도 육안으로는 식별이 어려울 만큼 멀리 떨어져 있게 된다. 그러므로 CCD카메라의 초점거리가 길어질 수 밖에 없고, 따라서 실제보다 느리게 움직이는 산불연기의 움직임을 처리해야 한다. 하지만 기존의 배경모델링방법과 같이 매 프레임마다 차영상을 생성하게 되면 느린 움직임 특성 때문에 움직임이 거의 검출되지 않는 문제점이 발생한다. 이러한 문제점을 해결하기 위해, 본 연구에서는 비디오 인덱싱(indexing) 연구에서 사용되는 키프레임 검출 아이디어를 이용하여 수식(1)과 같이 움직임 변화가 심하게 발생하는 영역을 키프레임으로 선택하고 이들에 대해서만 특징 값을 추출하는 방법을 사용한다.

$$\begin{aligned} & \text{if } (|Kframe[k] - frame[i]| > \theta_1) \\ & \text{Then } Kframe[k+1] = frame[i]; k++; i++; \\ & \text{Else } i++; \end{aligned} \quad (1)$$

$$B_b = \begin{cases} 1 & \sum_{x,y \in b} |Kframe[k](x,y) - Kframe[k+1](x,y)| > \theta_2 \\ 0 & \text{Otherwise} \end{cases} \quad (\text{단, } k \geq 1)$$

식(1)에서 k는 키프레임 번호, i는 프레임 번호를 의미하며, B_b는 현재 키프레임과 다음 키프레임의 변화 값을 반영하는 이진 블록을 의미한다. 임계값

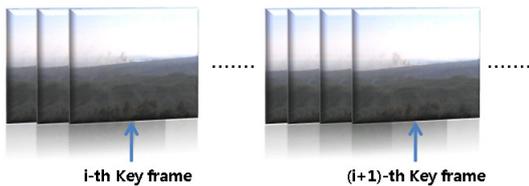


그림 1. 산불 연기의 느린 움직임을 고려한 키프레임 생성

θ_1 과 θ_2 는 가변적인 값으로 산불연기와 실내연기의 확산 특성이 다르므로 사용자에게 의해 조절될 수 있다. 그림 3-(a)는 키프레임간의 차영상을 이용한 움직임 영역의 검출 결과를 보여주고 있다.

2.2 색상모델링을 이용한 연기후보영역 결정

화재 연기는 실제로 여러 가지 색상을 포함하고 있으므로 RGB색공간에서 화재 색상을 분석해 보면, 전체 공간에서 불규칙적으로 넓게 분포하게 된다. 따라서 RGB색공간을 HSB색공간으로 변화 시키고 색상 값을 포함하는 휘도(H: Hue)값을 제외한 채도(S: Saturation)와 명도(B: Brightness)값들을 분석한 결과 색상의 변화보다는 채도 값과 밝기 값의 변화에 더 영향을 받는 것을 알게 되었다. 이러한 성질을 이용하여 본 논문에서는 HSB색공간에서 H를 제외한 S와 B값을 학습데이터로부터 추출하고 EM(Expectation-Maximization)방법을 적용하여 가우시안 혼합 모델(GMM: Gaussian Mixture Model)^[5]을 생성한다.

SB색상을 EM방법에 의해 확률값으로 모델링하면 그림 2와 같이 k개의 GMM을 만들 수 있다. 본 논문에서는 실험결과 k가 4일 때 가장 좋은 성능을 보여주는 가우시안 확률 모델을 생성할 수 있었다.

다음단계로 가우시안 모델을 배경모델링에서 검출된 후보 블록을 식(2)에 적용하여, 임계값 이상의 확률을 가지는 블록을 연기 후보영역으로 판단한다.

$$p(cp|S) = \sum_{i=1}^K w_i N(sb_{cp} | \mu_i \sigma_i) \quad (2)$$

식(2)에서 cp는 후보블록을 나타내며, sb_{cp} 는 후

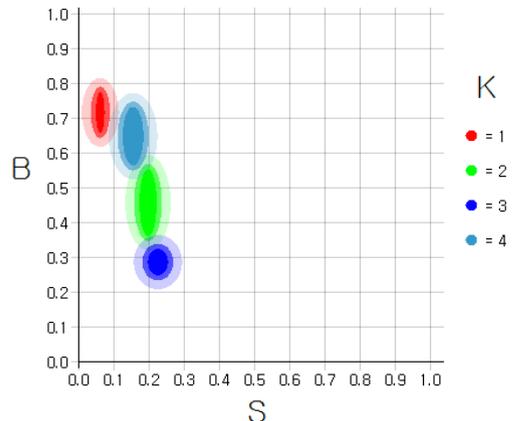


그림 2. 학습데이터로 추출한 S와 B값에 대한 GMM(K=4)

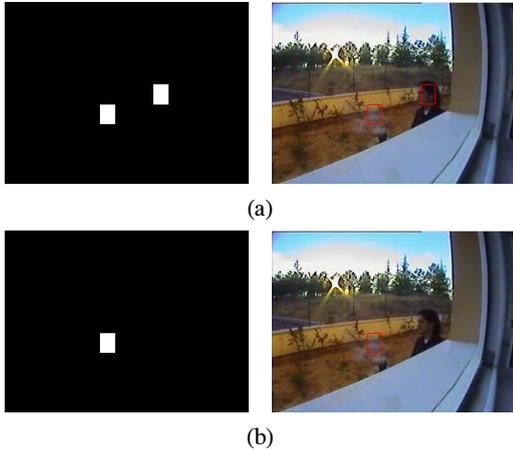


그림 3. (a) 차영상과 키프레임을 이용하여 검출된 움직임 영역 (b) 색상에 대한 가우시안 혼합 모델링을 이용하여 검출된 연기 후보 영역

보 블록의 S와 B값을 나타낸다. 또한, u_i 와 σ_i 는 i 번째 가우시안 모델의 평균과 표준편차를 나타내며, w_i 는 i 번째 가우시안 모델의 가중치를 나타낸다. 최종적으로 가중치가 곱해진 각 가우시안 모델에 대한 확률 값의 합을 통해 추정값(likelihood) $p(cpl|S)$ 을 구하고 그 값이 임계값 이상일 경우 연기 후보영역으로 판단한다. 수식(2)에 의해 검출된 연기 후보 영역은 그림3-(b)와 같다.

III. 동적 베이지안 네트워크를 이용한 연기 영역의 판단

배경모델링과 색상모델링을 이용하여 검출된 연기후보영역에서 각 블록들에 대한 YUV색공간에서 Y값에 대한 엔트로피, 웨이블릿 계수, 시간에 따른 모션정보에 의한 방향성분 등의 특징값을 추출하고 이를 가우시안 확률값으로 모델링하여 동적 베이지안 네트워크의 관찰노드에 적용한다.

3.1 동적 베이지안 네트워크(DBN: Dynamic Bayesian Network)

베이지안 네트워크는 기본적으로 이산확률 변수들의 조건부 확률 관계를 방향성 비순환 그래프(DAG: Directed Acyclic Graph)와 조건부 확률 테이블로 가지고 있으며 이 확률 테이블은 파라미터간의 확률적 의존 관계를 나타내는 그래프와 각 파라미터별 조건부 확률로 구성된다. 이에 반해 동적 베이지안 네트워크(DBN: Dynamic Bayesian Network)는 시간의 연속성을 고려한 정적 베이지안 네트워크의 확장된

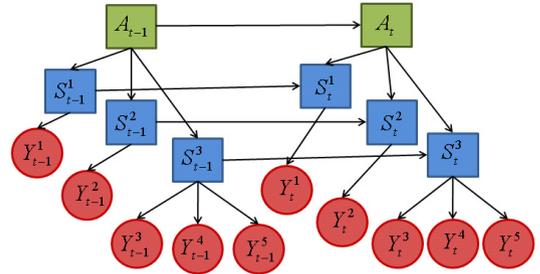


그림 4. 제안된 동적 베이지안 네트워크 구조도(2TDBN)

형태이다. 동적 베이지안 네트워크에서는 각 시간에서의 정적 베이지안 네트워크가 먼저 설정 되고 완벽한 동적네트워크는 각 시간에서의 정적 네트워크 간에 상호연결(arc)을 추가함으로써 형성된다^[6].

현재의 시간만을 고려하는 정적 베이지안 네트워크는 지식 노드들의 결합 확률 값만으로 최상위 노드의 상태를 결정하지만, 이전시간의 상태에 따른 변화를 고려하지 않기 때문에 화재와 같이 동적으로 변화하는 데이터에는 부적합하다. 화재는 일단 발생이 되면 그 상태가 일정시간 이상 지속되는 것이 보통이다. 따라서 이전시간의 상태가 연기라면 현재시간에서의 상태도 연기일 확률이 더 높고, 반대로 이전시간에서의 상태가 연기가 아니었다면, 현재시간에서의 상태가 연기일 확률은 낮아진다. 따라서 필수적으로 이전시간에서의 상태가 현재시간에서의 상태에 영향을 미치게 되는 동적 베이지안 네트워크를 적용하였다. 제안된 동적 베이지안 네트워크의 구성도는 그림 4와 같다.

그림에서 보는 것처럼 관찰노드 $Y^F (F=[1, N])$ 는 최종노드 A의 서브노드 S에 각각 개별적으로 연결되어 있다. 관찰노드는 각 블록들로부터 추출된 엔트로피, 웨이블릿 계수에 대한 확률 값을 입력으로 갖는다. 관찰노드에 필요한 확률 값을 구하기 위해, 본 논문에서는 실험을 통해 연기영역의 특징 값이 유니모달(uni-modal)한 가우시안 분포를 보인다는 것을 알아내고 이를 확률모델로 생성하였다. 각 특징 값의 확률 밀도함수는 그림 5-(a),(b)와 같다.

모션정보의 경우 연기는 특성에 의해 위쪽방향으로 이동한다는 Yuan[3]의 아이디어를 적용하여 수식(6)을 만들고, 이로부터 확률 값을 얻는 방법을 사용하였다. 관찰노드를 위한 특징벡터와 확률모델은 3.2장에 자세히 설명되어 있다.

각 블록으로부터 추출된 3개의 특징 값은 각각 추정값(likelihood)으로 변환되어 관찰노드 Y^F 에 입력되고 각 관찰노드들은 자신의 부모노드인 S^F 로

맵핑된다. 최종적으로 최상위 노드 A의 사후 확률 값은 중간노드들의 확률 값들의 결합 확률로 구할 수 있다. 이때, 각 중간노드와 최상위 노드는 각각 2가지 상태 값을 가지게 되는데, 중간노드인 S^F 는 각 노드별로 smoke-like, non-smoke-like의 2가지 상태 값을 가지게 되고, 최상위 노드인 A는 smoke, non-smoke의 2 가지 상태 값을 갖게 된다. 각 중간 노드 중 S^3 의 확률 값은 3개의 자식 관찰노드 Y^3, Y^4, Y^5 를 가짐으로 수식(3)과 같이 이들의 결합 확률로 구할 수 있다.

$$\begin{aligned}
 &P(Y^{3:5}, S^3) \\
 &= P(Y^3|S^3) \cdot P(Y^4|S^3) \cdot P(Y^5|S^3) \\
 &= \prod_{F=3}^5 P(Y^F, S^3)
 \end{aligned} \tag{3}$$

수식(3)에서 Y^3 은 LH성분의 확률 밀도를 나타 내며, Y^4 와 Y^5 는 각각 HL, HH성분의 확률밀도를 나타낸다.

동적 베이지안 네트워크에서 각 상태 값을 갖는 현재 노드(t)들은 이전 네트워크(t-1)에서 동일 노드의 상태 값에 영향을 받게 된다. 표 1은 중간노드 S^F 와 최상위 노드 A의 시간에 따른 상태전이 (State-transition) 값을 명시하고 있다. 표 1의 상태 전이 값은 실험에 의해 경험적으로 계산된 수치이다.

각 노드의 확률 값이 계산된 후, 수식(4)와 표 1의 상태전이 값을 적용하여 최종적으로 현재 시간 t에서의 사후 확률 값을 구할 수 있다.

$$\begin{aligned}
 &P(A_{t-1,t}, S_{t-1,t}^1 \dots S_{t-1,t}^3, Y_{t-1,t}^1 \dots Y_{t-1,t}^5) \tag{4} \\
 &= P(A_{t-1}) \cdot \prod_{F=1}^3 P(S_{t-1}^F | A_{t-1}) \\
 &\quad \cdot \prod_{F=1}^2 P(Y_{t-1}^F | S_{t-1}^F) \cdot \prod_{F=3}^5 P(Y_{t-1}^F | S_{t-1}^3) \\
 &\quad \cdot P(A_t | A_{t-1}) \cdot \prod_{F=1}^3 P(S_t^F | S_{t-1}^F, A_t) \\
 &\quad \cdot \prod_{F=1}^2 P(Y_t^F | S_t^F) \cdot \prod_{F=3}^5 P(Y_t^F | S_t^3)
 \end{aligned}$$

수식(4)에서 $P(A_t | A_{t-1})$ 는 A노드에서 이전상태와 현재상태의 전이 값을 의미하며, $P(S_t^F | S_{t-1}^F, A_t)$ 는 다시 $P(S_t^F | S_{t-1}^F) \cdot P(S_t^F | A_t)$ 로 풀어 쓸 수 있다.

수식에서 나타나듯이 동적 베이지안 네트워크의 노드에 표현되는 모든 변수들 간의 결합확률로 표현되는데, 크게 t-1일 때의 정적 베이지안 네트워크 연산과 t일 때의 정적 베이지안 네트워크 연산으로 나타낼 수 있다. 관찰노드와 중간노드간의 조건부확

표 1. 중간노드 S^F 와 최상위 노드 A에 대한 상태전이표

t-1 \ t	smoke-like	non-smoke-like
smoke-like	0.7	0.3
non-smoke-like	0.3	0.7

(a) S^F 의 상태전이표

t-1 \ t	smoke	non-smoke
smoke	0.7	0.3
non-smoke	0.3	0.7

(b) A의 상태전이표

률을 구할 때 $\prod_{F=1}^2 P(Y^F | S^F)$ 와 $\prod_{F=3}^5 P(Y^F | S^3)$ 과 같이 나누어 계산하는 것은 앞서 설명한 바와 같이 엔트로피 정보와 모션벡터 정보를 가지는 중간노드 S^1, S^2 는 관찰노드가 하나이기 때문에 1대1로 대응되지만 웨이블릿 정보를 가지는 중간노드 S^3 은 LH, HL, HH와 같이 3개의 관찰노드를 가지기 때문이다.

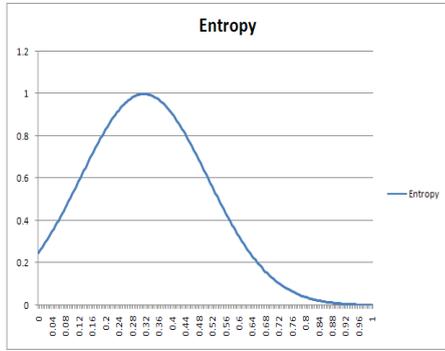
동적 베이지안 네트워크는 정적 베이지안 네트워크에 비해 이전상태를 고려함으로 그 정확성이 뛰어나지만, 이전의 N개 프레임의 상태를 고려해야 함으로 N의 설정에 따라 시간이 많이 걸리는 문제점이 있었다. 본 논문에서는 움직임 변화 분석을 키 프레임단위로 처리하고 있음으로 변화가 작은 프레임들은 배제하고 2개의 키프레임만을 고려하는 2-Time 동적 베이지안 네트워크(2TDBN)를 사용하여 검출 속도 및 성능을 향상시켰다.

3.2 특징 벡터 추출

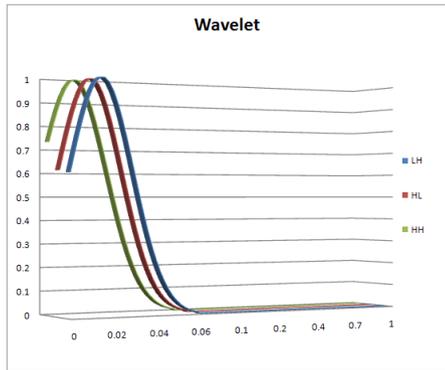
앞 절에서 제안한 동적 베이지안 네트워크의 관찰노드는 크게 세 가지로 나뉜다. 첫 번째는 YUV 색공간에서의 Y값에 대해 수식(5)와 같이 엔트로피정보를 얻는 것이다. 이것은 연기영역의 경우 전체적으로 유사한 밝기 값을 가짐으로 낮은 엔트로피를 나타내기 때문이다.

$$Entropy = - \sum_{i=1}^n p(x_i) \log_n p(x_i) \tag{5}$$

여기서, $p(x_i)$ 는 Y값을 N개의 집단으로 양자화시켰을 때의 히스토그램에 대한 확률로 log함수를 취함으로서, 최댓값이 1을 넘지 않는 엔트로피 값을 얻을 수 있다. 엔트로피 값에 대한 확률 값을 생성하기 위해 학습데이터로부터 엔트로피 값을 추출하고, 이를 가우시안 확률 분포로 모델링한 결과, 그림 5-(a)와 같은 분포를 얻을 수 있었다.



(a) 엔트로피에 대한 확률밀도함수



(b) 웨이블릿 LH, HL, HH 성분에 대한 확률밀도함수

그림 5. 학습 집합으로부터 추출한 특징벡터들을 이용하여 생성한 확률밀도함수

두 번째 확률모델은 웨이블릿 변환을 이용한 고주파정보를 추출하여 생성한다. 이것은 Töreyn^[2]의 논문에서 언급된 대로, 연기영역의 경우 배경에 비해 낮은 고주파 성분을 보인다는 특성을 이용한 것이다. 웨이블릿 계수를 구하기 위해 학습 영상에 웨이블릿 변환을 적용하고, 학습데이터로부터 고주파 성분에 해당하는 LH, HL, HH의 계수를 측정하여 가우시안 확률 모델링을 생성한다. 연기영역에서는 연기에 의해 배경이 가려짐으로 웨이블릿 계수가 거의 0에 가까운 값을 가짐으로, 그림 5-(b)에서 보듯이 LH, HL, HH계수 모두 비슷한 평균과 분산 값을 가진다는 것을 알 수 있다.

마지막으로 시간에 따른 모션정보의 방향성에 대한 확률 값을 구하기 위해, 본 논문에서는 조명의 변화에 민감하고 속도가 빠른 3단계 탐색 알고리즘(3-step Searching)^[7]을 이용하여 모션벡터를 측정하였다. 우선 후보영역에 속하는 블록에 대해 모션벡터를 구한 후, 아래 수식(6)과 같이 8방향의 모션벡터들의 방향을 구할 수 있다.

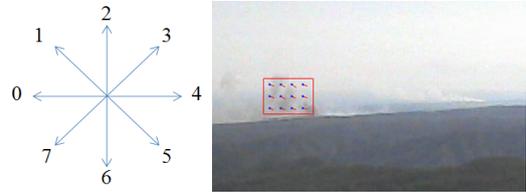


그림 6. 모션벡터 추출 후 정규화 시킬 8 방향(좌측)과 화면에 표현된 모션 벡터(우측)

$$M_dir = \frac{[\arctan(mv_y/mv_x) + \pi]}{8} \quad (6)$$

수식에서 mv_x 는 x방향의 변위, mv_y 는 y방향의 변위를 나타내며, 각각 구해진 모션벡터는 $0 \sim 2\pi$ 로 변환된 후, 그림 6과 같이 8개의 방향으로 정규화된다. 연기는 열의 특성상 상승하여 확산되는 경향을 보임으로 각 후보영역에 속한 블록들에서 M_dir 을 구한 후, 이로부터 히스토그램 H_b 를 생성하고, 아래 수식에 의해 해당영역의 확률 값을 구하게 된다.

$$P(M_dir) = \frac{\sum_0^3 H_b}{\sum_0^7 H_b} \quad (7)$$

수식에서와 같이 8개의 방향 중 상승방향을 나타내는 1~3번의 방향에 대한 전체방향의 비율을 후보영역의 확률 값으로 사용한다.

IV. 실험결과

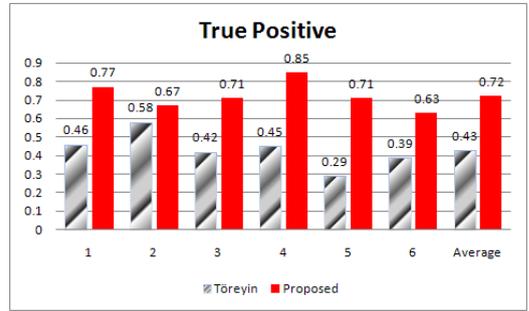
제안된 알고리즘의 성능을 평가하기 위해서 본 논문에서는 기존의 알고리즘들 중 가장 우수한 성능을 보여주는 Töreyn^[2,8]의 알고리즘과 성능을 비교하였다. Töreyn의 알고리즘은 화재의 초기 단계에서 연기가 반투명하게 보인다는 사실에 기반을 두어 웨이블릿 변환 후 고주파성분의 변화를 특징으로 사용하고, HMM(Hidden Markov Model)을 이용하여, 연기경계에서 고주파성분이 주기적으로 깜빡거리는 상태를 파악하여 연기영역임을 검증하였다. 실험을 위해서는 본 논문의 서론부분에서 밝힌 바와 같이 급격한 조명의 변화가 없는 실내의 영상에 대해서만 알고리즘을 적용하여 실험을 진행하였고, 실험에 사용된 영상은 객관적 성능평가를 위해 Töreyn의 실험영상과 동일한 영상만을 사용하였으



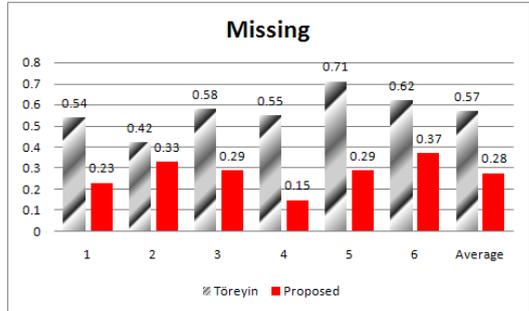
그림 7. 제안된 알고리즘을 이용한 연기감지결과화면. (a)~(d) 일반연기영상, (e)~(f)산불연기영상

며, 그 중에서 시각적으로 판단했을 때 연기영역이 나타나는 영상만을 선택하였다. 세부적으로 특징이 대조되는 일반연기영상 4개와 산불연기영상 2개를 가지고 비교하였으며, 영상의 연기영역 감지여부에 따른 확률적 성능을 그림 8의 그래프로 나타내었다. 그래프에서 알 수 있듯이 제안된 알고리즘은 평균 오검출율(False Positive)에서 Töreyin의 알고리즘과 거의 비슷한 수치를 나타내지만, 평균검출율(True Positive)과 평균 미검출율(Missing)에서 기존의 알고리즘에 비해 우수한 성능을 보여주었다.

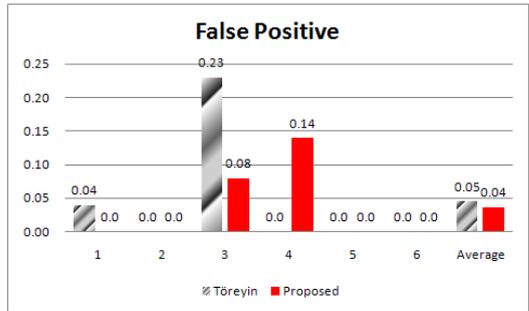
기존 알고리즘은 이전프레임과 현재프레임의 차 영상만을 이용한 배경모델링방법을 사용하는데 비해 제안된 알고리즘은 느린 움직임의 영상도 모두 추출하기 위해 키프레임을 이용한 배경모델링방법을 제안하였는데, 차영상만을 이용한 배경모델링방법에서는 검출이 어려웠던 산불연기를 그래프와 같은 높은 평균 검출율을 근거로, 기존 알고리즘보다 더 우수하다는 것을 확인할 수 있었다. 하지만 움직임이 많이 검출되는 연기영상일수록 움직임이 적은 산불연기영상에 비해 많은 키프레임이 설정되었는



(a) 연기 검출율(True Positive)



(b) 연기 미검출율(Missing)



(c) 연기 오검출율(False Positive)

그림 8. 제안된 알고리즘과 기존 알고리즘간의 실험영상에 따른 성능비교

데, 이로 인해 다소 많은 처리시간이 발생하였다.

평균 오검출 부분에서 기존의 Töreyin 알고리즘이 Movie 3에서 0.23이라는 높은 오검출율로 좋지 않은 성능을 보이는 것은, 이 영상에서 연기의 움직임 이외에 잦은 사람의 움직임들이 발생하는데, 이를 연기영역으로 판단하는 경우가 많았기 때문이다. 이것은 기존의 알고리즘이 연기영역을 최종 판단하는 과정에서 휴리스틱한 방법을 제안하고 있는데 비해, 제안된 알고리즘은 연기 영역을 최종판단하기 위해 이전 프레임의 상태와 현재 프레임의 상태를 모두 고려하여 접근하는 동적 베이지안 네트워크 기반의 확률적인 방법을 사용하였기 때문에 기존 알고리즘

보다 연기영역을 신뢰성 있게 최종판단하고, 0.08의 낮은 오검출율을 보여주었다. 하지만 Movie 4에서는 기존의 알고리즘이 0의 오검출율을 보여주는 데 비해, 제안된 알고리즘은 0.14라는 다소 높은 오검출율을 보여주었다. 이는 영상에서 연기가 주기적으로 나타났다 사라지는 양상을 보이는데, 이것은 동적 베이지안 네트워크의 특성상 과거의 상태를 현재 상태에 반영함으로 이미 사라진 연기를 뒤늦게 검출하는 경우가 다소 발생하였기 때문이다.

제안된 알고리즘을 이용한 실제 검출화면을 그림 8을 통해 나타내었다.

V. 결 론

화재를 감지하기 위한 여러 가지 방법들 중에서 본 논문에서는 CCD카메라에서 획득된 영상의 특징 값들을 추출하여, 가우시안 혼합 모델과 동적 베이지안 네트워크를 적용한 연기 감지방법을 제안하였다. 일반연기영상과는 대조되는 산불연기영상을 처리하기 위해 키프레임간의 차영상을 검출하는 배경 모델링방법을 사용하였고, 이 방법으로 일반연기와 산불연기 모두를 감지할 수 있었다. 또한 동적 베이지안 네트워크를 적용함으로써, 기존의 정적인 알고리즘의 한계점을 극복하고 연기특성에 해당하는 연기의 지속성 대한 문제를 해결하는 해답을 제시하였다. 특히 본 논문에서는 2TDBN을 이용하여, 성능과 속도 모든 면에서 기존의 알고리즘보다 우수함을 증명하였다.

연기의 특징이 자연현상임으로 확률적으로 계산할 수 없는 부분도 많겠지만, 제안된 알고리즘은 기존의 알고리즘들에 비해 보다 신뢰성 있는 결과를 보여주었다. 하지만 움직임이 빈번한 영상에서 많은 키프레임이 설정되고, 이에 따른 많은 연산이 요구되는 것을 해결하기 위해 움직임이 빠른 영상과 느린 영상을 모두 적응적으로 해결할 수 있는 가변적 키프레임 설정방법을 연구해야 할 것이며, 특수한 상황이나 새로운 환경의 연기도 즉각적으로 감지하기 위해서는 학습 데이터만에 의존하지 않고, 기존의 데이터에서 감지된 연기를 추적하고, 이를 바탕으로 학습데이터를 갱신하는 새로운 확률모델링방법을 개발해야 할 것이다. 또한, 야간의 경우에는 일반 CCD카메라로부터 획득된 영상이 카메라의 성능에 따라 연기의 식별이 많이 좌우되므로 일반 CCD카메라와 적외선 카메라를 융합하여 주야간에 모두 강한 연기 감지 알고리즘을 개발할 것이다.

참 고 문 헌

- [1] T. Chen, Y. Yin, S. Huang and Y. Yen, "The Smoke Detection for Early Fire-Alarm System Base on Video Processing.", *Intelligent Information Hiding and Multimedia Signal*, pp.427-430, 2006.
- [2] B.U. Töreyn, Y. Dedeoglu. and A. E. Cetin, "Contour based smoke detection in video using wavelets.", *14th European Signal Processing Conference EUSIPCO*, pp. 1-5, 2006.
- [3] F. Yuan, "A fast accumulative motion orientation model based on integral image for video smoke detection", *Pattern Recognition Letter* 29, pp.925-932, 2008.
- [4] R Vezzani, S Calderara, P Piccinini, R Cucchiara, "Smoke detection in video surveillance: the use of ViSOR (video surveillance on-line repository)", *Proceedings of the 2008 international conference on Content*, pp.289-298, 2008.
- [5] L Xu, MI Jordan, "On Convergence Properties of the EM Algorithm for Gaussian Mixtures", *Neural Computation*, Vol. 8, No. 1, pp. 129-151, 1996.
- [6] A. Dielmann and S. Renals, "Automatic Meeting Segmentation Using Dynamic Bayesian Networks.", *IEEE Trans. on Multimedia*, vol. 9, no.1 pp. 25-36, 2007.
- [7] X. Jing, L. Chau, "An efficient three-step search algorithm for block motion estimation.", *IEEE Trans. on Multimedia*, vol. 6, no.3 pp. 435-438, 2004.
- [8] T. Chen, P. Wu and Y. Chiou , "An early fire detection method based on image processing", *International Conference on Image Processing*, pp. 1707-1710, 2004.
- [9] B.U. Töreyn, Y. Dedeoglu. U. Gudukbay and A. E. Cetin, "Computer vision based method for real-time fire and flame detection", *Pattern Recognition Letter* 27, pp.49-58, 2006.
- [10] D. Han and B. Lee, "Development of Early Tunnel Fire Detection Algorithm Using the

Image Processing”, *International Symposium on Visual Computing*, pp.39-48, 2006.

- [11] R. O. Duda, P. E. Hart, D. G. Stork, “Pattern Classification”, *Wiley-Interscience second ed*, 2001.

이 인 규 (In-gyu Lee)

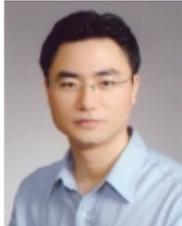
준회원



2008년 2월 계명대학교 컴퓨터 공학과 졸업
2008년 3월~현재 계명대학교 컴퓨터공학과 석사과정
<관심분야> 컴퓨터비전, 패턴인식, 데이터베이스

고 병 철 (ByungChul Ko)

정회원



2000년 2월 연세대학교 컴퓨터 과학과 석사
2004년 2월 연세대학교 컴퓨터 과학과 박사
2005년 3월~현재 계명대학교 컴퓨터공학과 교수
<관심분야> 내용기반 영상검색, 컴퓨터 비전, 패턴인식

남 재 열 (Jae-yeol Nam)

정회원



1985년 2월 경북대학교 전자공학 석사
1991년 2월 University of Texas at Arlington 박사
1995년 3월~현재 계명대학교 컴퓨터공학과 교수
<관심분야> 동영상/정지영상 압축/전송, 정지영상/동영상 검색