

An In-Tunnel Traffic Accident Detection Algorithm using CCTV Image Processing

Baek JungHee[†] · Min Joonyoung^{**} · Namkoong Seong^{***} · Yoon SeokHwan^{****}

ABSTRACT

Almost of current Automatic Incident Detection(AID) algorithms involve the vulnerability that detects the traffic accident in open road or in tunnel as the traffic jam not as the traffic accident. This paper proposes the improved accident detection algorithm to enhance the detection probability based on accident detection algorithms applied in open roads. The improved accident detection algorithm provides the preliminary judgment of potential accident by detecting the stopped object by Gaussian Mixture Model. Afterwards, it measures the detection area is divided into blocks so that the occupancy rate can be determined for each block. All experimental results of applying the new algorithm on a real incident was detected image without error.

Keywords : CCTV Image Processing, In-tunnel Accident Detection, Automatic Incident Detection Algorithm

CCTV 영상처리를 이용한 터널 내 사고감지 알고리즘

백정희[†] · 민주영^{**} · 남궁성^{***} · 윤석환^{****}

요 약

현존하는 자동 사고감지 알고리즘의 대부분은 개방도로 혹은 터널 내에서 사고 발생 시 이것을 사고로 감지하지 못하고 혼잡으로 감지하는 경우가 많다는 문제점을 가지고 있다. 본 논문에서는 개방도로에서의 사고감지 알고리즘을 기반으로 터널 내에서의 사고감지 알고리즘을 개선하여 감지율을 높일 수 있는 알고리즘을 제안하였다. 개선된 알고리즘은 가우시안 혼합모델을 이용하여 픽셀의 변화량을 판단하여 터널 내 사고로 인한 정지차량을 우선 감지한 후 도로를 블록화하여 블록 간 점유율의 편차를 분석하여 최종 판단을 한다. 실제 사고영상에 알고리즘을 적용한 실험에서 모두 오류 없이 감지하였음을 확인하였다.

키워드 : CCTV 영상처리, 터널 내 사고감지, 자동 사고감지 알고리즘

1. 서 론

오스트리아 도로안전청의 연구 보고에 의하면, 터널 내에서의 교통사고 건수는 개방된 도로에서의 교통사고 건수보다 적지만 터널 내에서의 사고로 사망할 위험은 개방된 도로에서의 사고로 사망할 위험의 두 배에 이른다[1-2]. 또한, 터널과 같은 어두운 공간을 가로지르는 운전은 터널 내에서의 치명적 위험성을 증가시키는 원인이 된다는 점을 밝히고 있다[2]. 국내 터널 내부 발생 교통사고 건수는 경찰청 집계에 의하면, 매년 150~450건 정도로 전체 교통사고의 0.094%

정도로 나타나고 있다. 2013년 12월 말 기준 전국의 터널 수는 1,659개소로, 2003년 말 603개소와 비교하면 1,056개소(175%)가 증가하였으며, 연장은 390km에서 1,208km로 818km(209%) 증가하였다. 또한 도로 종류별로는 고속국도 793개(48%), 일반국도 461개(28%)로 나타나 고속국도와 일반국도의 터널이 전체 터널의 75% 이상, 즉 3/4 이상을 차지하는 것으로 나타나고 있다. 이러한 국내 터널 증가 원인은 자연환경 파괴 최소화 등 환경 친화적인 도로 건설과 도로이용자의 안전을 고려한 선형개량 등이 주요인이다[3]. 특히, 우리나라는 산지가 많은 지형적 특성으로 인하여 터널 건설이 필수적이다. 터널 내의 사고를 신속히 감지함으로써 2차사고의 피해를 줄일 필요가 있다.

터널 내 사고감지 시스템으로는 루프 감지 시스템(Loop Detection System), 레이더 감지기, CCTV 감지기 등을 고려할 수 있는데, 이 중에서 가장 많이 쓰이는 시스템은 CCTV를 이용한 자동사고감지시스템(Automatic Incident Detection,

[†] 준 회 원: 숭실대학교 미디어학과 박사과정수료
^{**} 비 회 원: 상지영서대학교 국방정보통신과 교수
^{***} 비 회 원: 한국도로공사 도로교통연구원 교통연구실장
^{****} 중신회원: 세명대학교 컴퓨터학부 교수
Manuscript Received: March 3, 2014
First Revision: December 22, 2014
Accepted: January 5, 2015
* Corresponding Author: Yoon SeokHwan(ysh1213@semyung.ac.kr)

AID)이다. 독일, 스페인, 프랑스, 영국, 노르웨이 등에서는 터널 내 CCTV를 법적으로 의무 설치하도록 하고 있다[5]. 국내에서는 위험도지수기준등급이 2등급 이상의 터널에 설치하는 것을 원칙으로 하고 있다[6].

이러한 배경하에서, 본 논문은 우선 터널 내 사고감지 알고리즘의 특징을 분석하고, 개방도로(open road)에서의 사고감지 알고리즘[7]을 기반으로 터널 내에서의 사고감지 알고리즘을 개선하여 사고 감지율을 높일 수 있도록 알고리즘을 제안한다. 본 논문의 구성은 다음과 같다. 2절에서 터널 내 사고감지 알고리즘의 특징과 기존의 연구를 살펴보고, 3절에서 개선된 터널 내 사고감지 알고리즘을 제안한다. 4절에서는 제안한 알고리즘에 대한 실험과 그 결과를 제시하고 5절에서 결론 및 향후 연구방향을 제시하였다.

2. 관련 연구

2.1 터널 내 사고감지 알고리즘 기존 연구

터널 내 사고감지를 위하여 목표물체(차량)를 감지하는 방법, 차량의 궤적을 추적하는 방법과 통계적인 방법 등이 제안되고 있다. 또한 여러 컴퓨터 비전 알고리즘의 조합을 통해 터널 내 정지차량, 저속 교통 흐름, 개별차량의 속도와 차량 분리(vehicle classification) 등 사고 발생과 관련된 여러 데이터에 대한 분석 및 감지를 하고 있다[8].

국내 연구로 가우시안 혼합모델(Gaussian Mixture Model, GMM)과 수학적 형태학 처리(Mathematical Morphological Processing, MMP) 기법을 적용한 차량 감지 알고리즘[4]이 제안되었다. 이 방법은 프레임 간 GMM 배경 추정을 적용함으로써 터널 내에 설치된 일정한 간격의 조명과 영상잡음에 대하여 효과적인 배경을 추정하며, GMM 배경 추정과 차영상(difference image)으로부터 검출된 객체(차량)가 정확히 한 대씩 레이블링(labeling)이 안 되는 것을 해결하기 위해 MMP를 통하여 2개 이상의 분리된 객체를 하나의 객체로 분리(segmentation)함으로써 차량객체의 검출 오류를 감소시키는 방법을 제안하였다. 그러나 이 방법은 교통량이 적은 터널 내에서는 효과적일 수 있으나, 혼잡한 상황에서는 오히려 2대의 차량을 각각 분리하는 데 한계가 있어 실영상에 발생하는 모든 경우에 적용하기에는 어려움이 있다.

국의 연구로 [2]에서는 가장 보편적인 방법으로 사고차량을 감지하였는데, 터널 내 낮은 조도로 인한 차량 감지의 어려움을 해결하기 위하여 전처리(pre-processing)로 영상에서 고주파 영역(high-pass domain)만 통과시켜 차량의 윤곽을 추출하고, 이 전처리 영상과 배경영상과의 차영상을 구하고 모폴로지(Morphology) 연산을 통하여 1차 차량을 검출하였고 여기에 블롭 그룹핑(blob grouping)과 차량인지의 검증을 통해 사고차량을 감지하는 방법을 제안하였다. 그러나 이 방법은 실험 결과 배경 영상에서 노이즈가 많이 발생하여 차량 감지의 정확도가 20% 정도 저하되는 문제가 있었다.

Traficon N.V사[9,10]는 영상을 통한 교통자료를 수집하는 방법으로 CCATS(Camera & Computer Aided Traffic Sensor), CCIDS(Camera & Computer aided Incident Detection Sensor), CTRACK(Camera Tracking)의 알고리즘을 사용하고 있다. 이 중 CCIDS는 일반구간 및 터널구간에서 영상감지기를 이용하여 사고 상황을 신속히 발견할 수 있다는 사실을 이용하여, 터널 내를 주행하는 차량의 흐름을 분석하여 터널 내 교통사고 및 정지차량, 화재 상황을 실시간으로 검출하는 터널교통사고 조기경보 시스템에 활용하고 있다. CCATS 알고리즘이 감지영역을 설정한 방식을 응용하여 CCIDS 알고리즘은 감지선(detection line)을 차로와 평행하게 설정하고 감지선을 지나가는 차량이 변화시키는 회색도(Gray Level)를 측정하는 방식으로 정지차량, 역주행차량을 감지할 수 있으며 필요에 따라 감지라인을 따라 이동하는 차량을 분석하여 속도측정이 가능하다.

유럽에서는 매년 50,000명 이상이 교통사고로 사망하고 있는데 이에 대한 개선을 위해 EU는 이동성과 함께 안전을 목표로 한 교통 환경 개선 정책을 실시하고 있다. 특히 유럽의 도로 시설 중 터널은 국가 간 연결과 교통 및 물류 흐름을 담당하는 중요한 시설로서 1km 이상의 터널이 567개 이상 존재한다. VITUS-1(Video Image Analysis for Tunnel Safety)은 VITUS-2의 근간이 되는 연구로, 터널 내 영상 기반 돌발 상황 감지 시스템 도입을 위해 총 6개 분야(Work Package: WP1~WP6)에 대해 연구를 진행하였다[8-9]. 이 중 WP2는 영상 기반 돌발 상황 감지 시스템에 적용 가능한 최적의 영상 센서에 대한 장단점을 분석하고, 돌발 상황과 관련된 영상을 DB화하여 VITUS-1에서 개발한 알고리즘을 시험 및 검증하기 위한 기초자료로 사용하기 위한 연구를 수행하였다. 특히 영상 센서의 분석을 위해 영상 프레임률, 해상도, 빛에 의한 감도, 신호-노이즈율(signal-to-noise rate), 영상 번짐(smearing) 또는 흐려짐(blurring) 등의 요소를 고려하여 CCD와 CMOS 센서에 대해 분석하였으며, 분석 결과 터널 조명 등의 환경조건을 고려하여 영상센서를 선택적으로 도입해야 한다는 결론을 내렸다. 2011년 현재 VITUS-2는 VITUS-1에서 정의한 사고감지 알고리즘을 적용한 프로토타입(Prototype)시스템을 Plabutsch 터널에서 운영하고 있다. 테스트베드의 운영을 위해 시스템은 기본적으로 터널 내에서 발생하는 돌발 상황을 자동으로 감지하고, 터널 운영자 및 도로 이용자에게 경고 메시지를 전송하여 터널 내 상황을 인지하게 하며 이벤트 영상을 자동으로 저장하는 기본 기능을 충족하도록 개발하였으며, 시스템 정확도 및 오류율 등의 분석을 수행하고 있다[9, 11].

[7]의 연구에서는 사고감지에 관련한 다양한 factor를 분석하여 감지의 정확도를 높였는데, 우선 GMM으로 배경영상에서 정지차량을 감지하고 이 차량이 사고로 인하여 정차한 것인지 아니면 정체로 인하여 정차한 것인지를 속도의 변화, 개별차량의 궤적, 도로를 일정 간격의 블록으로 나누

어 이 블록 간의 차량 점유율을 3가지 요소로 검증하여 사고의 오감지를 감소시킬 수 있는 알고리즘을 제시하였다. 그러나 이 방법은 외부도로에서는 적용이 가능하나, 조도가 낮은 터널 내에서는 감지율이 낮아질 수 있다.

2.2 터널 내 사고감지 알고리즘의 특징

터널과 개방도로에서의 영상처리에 차이점이 있다. 개방도로는 다양한 외부 조건(낮과 밤의 변화 등)을 만족할 수 있는 알고리즘이 요구되는 반면 터널 내에서는 터널 벽면에서 나오는 반사광, 낮은 조명 및 터널 따라 달라지는 조도로 인하여 변화에 대한 반응이 늦어져 사고 또는 차량 감지가 즉각적으로 이루어지지 않는 환경이 된다[8]. 현존하는 자동 사고감지(AID) 알고리즘의 대부분은 개방도로 혹은 터널 내에서 사고 발생 시 이것을 사고로 감지하지 못하고 혼잡으로 감지하는 경우가 많다는 문제점을 가지고 있다[12]. 자동 사고감지시스템은 감지율(Detection probability)이 높아야 함과 동시에, 오감지율(False alarm probability)은 낮아야 한다[1]. 이것은 사고가 아닌 경우를 사고로 판단하여 경고를 자주 하게 되면(wrong call) AID 시스템의 신뢰도가 떨어져 사고감지의 효율성이 떨어지게 되기 때문이다.

Reijmers[13]는 사고를 판단하는 기준으로 다음의 방법을 제시하였다.

- (1) 감지기 사이의 점유율 변화량(measurement of the changes in detector occupancy)
- (2) 차두 시간 분석(analysis of time headway)
- (3) 속도 변화량 분석(analysis of the changes in speed)
- (4) 평균통행시간(measuring the average travel time)

이 기준에 추가적으로 판단할 수 있는 기준으로 정차 차량의 감지와 개별 차량의 이동궤적을 포함하여 판단할 수 있다[7]. 그러나 이러한 사고 판단 기준은 영상을 이용할 경우 대부분 개방도로에 적용될 수 있는 기준이며 터널 내에 적용하기에는 어려운 기준들이 있다. 예를 들어 개별차량 속도 변화량 분석과 이동궤적 분석은 협소한 터널 내 CCTV영상만으로는 정확한 데이터를 산출하기 어려워 사고 판단 기준으로는 활용하기 어려운 요소가 된다. 특히, CCTV의 주시방향이 일반적인 영상감지기 방향과 반대방향으로 설치된 것이 대부분이어서 Reijmers의 사고 판단 기준에서 차두 시간 분석, 속도 변화량 분석과 평균통행시간으로는 터널 내에서 사고를 판단하기에 어려움이 있다. 또한 터널 내 공간이 협소하여 CCTV영상의 사각이 많이 존재하므로 이러한 영상에서 획득할 수 있는 정보의 범위가 제한적일 수밖에 없다는 단점이 있다. 반면에, 내부 환경이기 때문에 햇빛이나 구름의 영향을 덜 받아 노이즈가 많지 않고, 조도의 변화가 크지 않으며, 그림자와 날씨의 변화 등에 덜 민감하다는 장점도 있다.

따라서 본 논문에서는 터널 내 사고 판단 기준을 다음과

같이 설정하고 이를 기반으로 사고를 감지하도록 하였다.

- (1) 사고로 인한 정지차량 감지
- (2) 사고 후 파편의 심각도 분석
- (3) 블록 간 점유율의 편차분석

이는 터널 내 CCTV 영상 데이터 중 정보의 신뢰도가 높은 요소만을 추출하여 제시한 것이다.

3. 개선된 터널 내 사고감지 알고리즘

3.1 터널 내 사고감지 알고리즘 개요

본 연구의 터널 내 사고감지 알고리즘은 가우시안 혼합 모델(GMM, Gaussian Mixture Model) 알고리즘을 이용한 배경영상 시퀀스로 정차차량을 감지하는 1차 사전감지 단계와 이 정차차량이 사고로 인한 정차인지를 판단하는 블록 간 점유율 편차에 의한 1차 사고확정 판단 단계로 구성되어있다. 또한 1차 사전감지 단계의 정확도를 높이기 위해 사고 후 차량 파편의 심각도를 고려하였다. 본 알고리즘의 흐름은 Fig. 1과 같다.

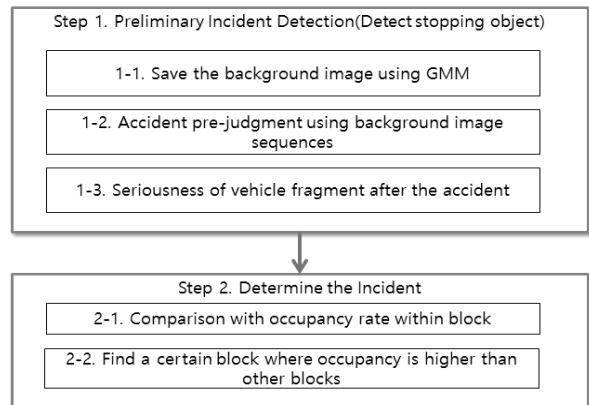


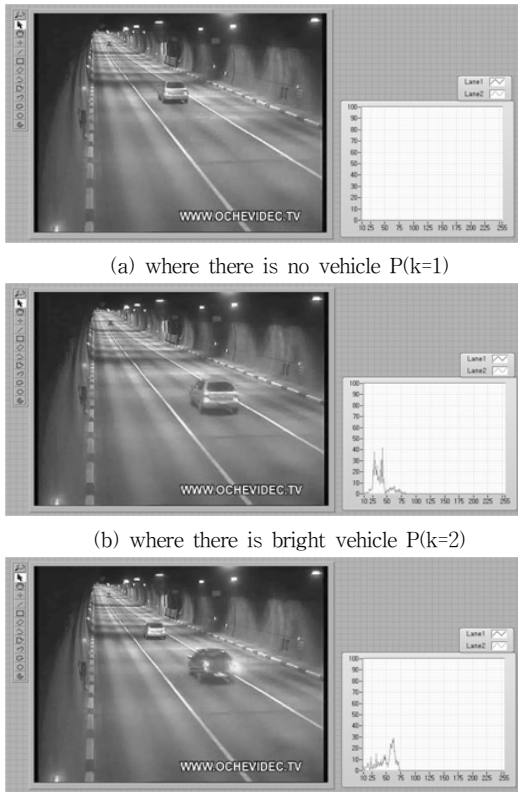
Fig. 1. An in-tunnel traffic accident detection algorithm

3.2 사고로 인한 도로 정차차량 검지

1) 가우시안 혼합모델(GMM)을 이용한 배경영상 추출

GMM은 영상 내 픽셀의 변화량이 이전 프레임을 통한 분포를 가지며 그 분포는 일반적으로 일정한 평균값과 표준편차의 가우시안 분포를 따른다는 전제하에, 프레임 시퀀스에 따라 픽셀값의 상태가 다양하게 변화하고 이 분포가 가우시안 분포를 따른다고 가정한다.

프레임 시퀀스에서 픽셀의 k번째 상태의 사전 확률(prior probability)을 $\gamma_k(k = 1, 2, \dots, K)$ 라고 할 때, $\sum_{k=g_1}^{k=g_2} \gamma_k = g_2 - g_1 + 1$ 이를 영상에 적용하여 얻은 픽셀값의 분포는 Fig. 2와 같다.



(a) where there is no vehicle P(k=1)
 (b) where there is bright vehicle P(k=2)
 (c) where there is dark vehicle and back-light is on P(k=3)
 Fig. 2. Distribution examples of pixel values applied to images

여기서 각 상태가 서로 독립적이라고 했을 때 X_k 는 GMM의 합 Equation (1)이 된다.

$$f_X(X|\mu, \Sigma) = \sum_{k=1}^K p(k) f_{X|k}(X|\mu_k, \Sigma_k) \quad (1)$$

여기서, $p(k)$ 는 한 픽셀의 k번째 상태 확률로 $p(k) = \mu_k$ 로 표기한다. μ_k, Σ_k 는 각각 $p(k)$ 의 평균과 분산을 의미하며 이 값들은 픽셀값 X 로부터 추정(estimation)이 가능하다.

만약 이 pixel process가 안정적으로 변하는 경우, 기댓값 최대화 알고리즘(expectation maximum algorithm)으로 최대우도함수(maximum likelihood function)를 구할 수 있다. Stauffer와 Grimson[14]는 K-means 근사값으로 파라미터를 추정하였다.

우선 현재 상태를 추정하기 위한 사후확률(posterior probability)은 Equation (2)와 같다.

$$p(k|X, \Phi) = \frac{p(k) f_{X|k}(X|\mu_k, \Sigma_k)}{f_X(X|\Phi)} \quad (2)$$

여기서, Φ 는 k번째 상태 확률의 시퀀스로 $\Phi = \{\omega_1, \dots, \omega_K, \theta_1, \dots, \theta_K\}$, $\theta_k = \{\mu_k, \Sigma_k\}$ 이고, $p(k|X, \Phi)$ 가 최대가 되는 k(이를 [14]에서는 match라 하였음)를 MAP(maximum a posterior probability)라고 하고 이것을 현재 상태로 결정한다.

새로운 영상 X_{t+1} 은 현재까지의 K , 가우시안 분포에서 match가 될 때까지(일반적으로 match는 가우시안분포의 표준편차가 2.5 이내일 경우로 정의한다[14]) 조정을 해주는데, 우선 w 는 Equation (3)의 방법으로 학습을 시킨다.

$$w_{k,t+1} = (1-\alpha)w_{k,t} + \alpha(M_{k,t+1}) \quad (3)$$

여기서, α 는 학습률(learning rate), $M_{k,t+1}$ 는 match일 경우 1, 아닐 경우 0으로 한다. 새로운 프레임의 확률값이 이전 배경과 동일한 match인 경우는 이전 배경값을 계속 갖도록 1을 부여하고, 새로운 프레임이 배경이 아닌 다른 값으로 들어오는 non-match인 경우는 0을 부여하여 학습률 만큼 변경하도록 한다.

또한, 새로운 영상이 입력될 때 μ, Σ 는 Equation (4)와 Equation (5)에 의하여 갱신된다.

$$\mu_{t+1} = (1-\rho)\mu_t + \rho X_{t+1} \quad (4)$$

$$\Sigma_{t+1}^2 = (1-\rho)\Sigma_t^2 + \rho(X_{t+1} - \mu_{t+1})^T(X_{t+1} - \mu_{t+1}) \quad (5)$$

$$\rho = \alpha \times p(X_{t+1}|\mu_k, \Sigma_k) = \alpha \times w_{k,t+1}$$

위 방법을 이용하여 최종적으로 배경영상을 추정하는 방법은 다음과 같다. Equation (2)의 분포에는 이동물체와 배경이 같이 존재하며, 배경과 전경을 구분하기 위하여 μ_k, Σ_k 또는 μ_k^2, Σ_k^2 을 계산하여 각 k 상태별 ($k=1, \dots, K$) 랭킹(Ranking)을 계산한 다음 큰 값을 배경영상으로 간주한다. 즉, μ_k 가 큰 값이나 Σ_k 가 작은 값을 가질 때 배경영상이 확률이 높다고 보고, Equation (6)과 같이 w_k 의 누적으로 전체 사전확률(overall prior probability) T 와 비교하여 클 때 이를 배경영상으로 판단한다.

$$B = \text{argmin}_b \left(\sum_{k=1}^b w_k > T \right) \quad (1 \leq b \leq K) \quad (6)$$

Fig. 3은 위 가우시안 혼합모델(GMM) 방법으로 배경영상을 추정하는 과정이다.

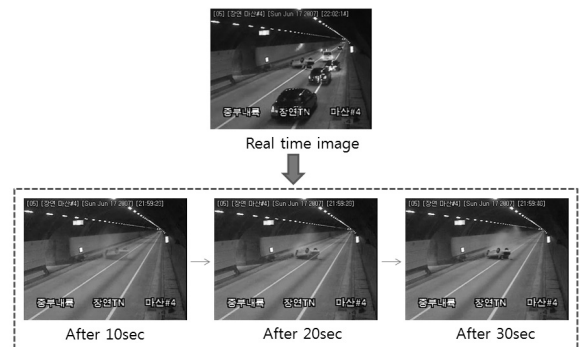


Fig. 3. Traffic accident detection using GMM (Gaussian Mixture Model)

2) 추정된 배경영상에서의 사고감지

경미한 사고나 또는 대형사고 모두 사고가 발생한 지점에는 사고차량이 정차하게 되는 경우 가우시안 혼합모델을 이용하면 사고차량 역시 배경영상으로 저장된다. 이를 개선하기 위해 본 연구에서는 배경영상 이미지 $I(X, Y)$ 만의 시퀀스를 n 초 간격으로 만들어 버퍼에 저장한 후 일정시간 간격의 배경영상 이미지간의 차이를 구해 임계값이 넘는 영역에 대해 사고차량이라고 감지하였다(이미지 I_k 와 I_{k-1} 는 n 초 간격으로 생성된다. $(0 \leq k \leq N)$).

$$B_0, B_1, \dots, B_N = \{I_k(x, y) : 1 \leq x \leq X, 1 \leq y \leq Y\} \quad (7)$$

사고 발생 이후 일정시간이 지나면 이동차량을 제외한 사고차량을 포함한 정차차량 모두가 배경영상으로 포함되며, 최초의 배경영상(B_0)으로부터 사고차량이 포함된 배경영상(B_N)까지 버퍼에 저장되고, $(B_N - B_0)$ 을 계산하면 사고차량의 전경이 추출되어 사고지점 및 사고차량을 감지할 수 있다. Fig. 4는 10초 간격($n = 10$)으로 배경영상을 저장한 다음 1분 전 영상과 비교하여 사고지점을 감지하는 과정을 나타내고 있다.

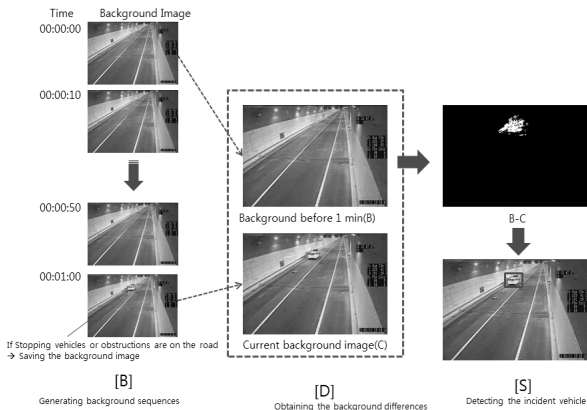


Fig. 4. detection process analyzing difference images of background images

앞의 과정에서는 심한 정체인 경우도 차량의 이동이 없어 사고 발생인 경우와 같이 판단할 수 있게 된다. 이를 해결하기 위해 다음의 방법을 적용한다. 개방도로와 비교할 때, 터널 내 사고는 터널이라는 협소한 공간에서 사고가 발생하므로 사고 후 차량의 파편이 도로에 널리 퍼져있는 경우가 많이 발생한다. 이러한 특징을 이용하여 정체로 인한 정지차량을 사고차량으로 감지되는 것을 보완할 수 있다. 이를 위해 차량 파편 분포의 심각도를 산출하여 사고임을 판단하는 알고리즘을 제안한다. 차량 파편 분포의 심각도는 배경영상의 사고차량 감지 방법에서 차선을 제외한 차량 파편의 정도를 계산하며, 이것이 일정 임계값을 넘을 경우 사고로 판단하게 된다. Fig. 5에서 보는 바와 같이 사고 후 차량 파편의 심각도를 분석하여 사고유무를 판단할 수 있다.

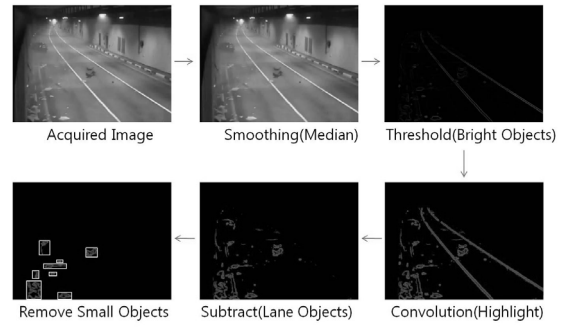


Fig. 5. Detection via analyzing the seriousness degree of distribution on vehicle fragments after accident

3.3 블록별 점유율의 편차 분석에 의한 사고감지

사고 발생 후 특징은 사고 지점을 중심으로 후방은 교통량과 점유율이 높고 전방은 교통량과 점유율이 떨어지게 된다. 감지영역을 N 개의 블록으로 나누어 각 블록별 점유율을 비교하여 점유율의 편차가 크면 사고 지점으로 간주할 수 있다.

블록별 교통 정보는 within블록(블록 내)과 between블록(블록 간)의 상관관계로 판단하고, 사고인 경우 within블록의 점유율은 높거나 또는 낮은 반면, between블록 점유율은 크게 나타나는 것으로 판단한다. 즉, Fig. 6과 같이 감지영역을 여러 개의 블록으로 나누었을 때 사고지점을 기준으로 그 이전까지의 블록 b_1 과 b_2 의 내부점유율(within 블록)은 높을 것이고, 블록 b_1, b_2 와 b_3 간의 점유율(between 블록)은 크게 차이가 날 것이기 때문에 이러한 공간정보를 사고감지에 활용할 수 있다.




Fig. 6. occupancy of blocks in accident area

블록별 점유율의 편차 분석에 의한 사고감지 처리 절차는 다음과 같다. 감지영역을 N 개의 블록(B_1, B_2, B_3, \dots)으로 나누어 준비한다.

(1) within블록 점유율(WithinBlockOcc, WBOcc) 계산은 Equation (8)을 이용한다.

$$WBOcc(B_j) = \frac{\sum_{k=1}^n S_k}{B_j} \times 100 > \theta_{Occ} (= 90\%) \quad (8)$$

여기서, $B_j(j=1,2,3,\dots)$ 는 감지영역 내 블록별 면적이며 $\sum_k S_k$ 는 블록 내 모든 차량(총 k 대)의 면적의 합이다. 모든 블록의 점유율이 90% 이상인 경우는 감지 영역 전체

가 점유율이 높기 때문에 정체라고 판단하고, 어느 특정 블록 이전부터 점유율이 높으면 사고로 인한 정체로 판단한다.

(2) between블록 점유율 편차(BetweenBlock Difference, BBD)는 블록 간 점유율의 차이가 크면 사고일 가능성이 높고 블록 간 점유율의 차이가 작으면 정체일 가능성이 높다고 판단하는 방법으로 Equation (9)에 의해 블록 간 점유율의 차이를 산출한다.

$$BBD = Diff(WBOcc(j)) = |Occ(B_j) - Occ(B_{j-1})| < \theta_{Occ} (= 10\%) \quad (9)$$

$(j = 2, 3, \dots, N)$

Between블록은 이전 블록과의 차이를 구하는 것으로, j 번째 블록의 점유율과 j-1 번째 블록의 점유율의 편차가 10% 이내이면 정체이고 그 이상이면 사고로 판단한다(Fig. 7).




Fig. 7. accident detection via analyzing the differences in detector occupancy between blocks

4. 실험 및 분석

실제 터널 내 사고영상 총 10건(Table 1)을 대상으로 본 알고리즘을 적용하여 사고감지를 실험하였다. 실험에 사용한 사고영상은 한국도로공사(EX)에서 제공한 사고영상과 한국터널공학회(KTA)에서 제공한 터널 내 Traficon 영상감지기기를 통한 유고감지 성능 현장실험 영상 등이다. 실험 결과 모든 영상에 대하여 사고를 감지하였다.

Table 1. Experimental Data List

No.	Tunnel Name	Accident Date	Accident Type	Experimental Results
1	Bongan Tunnel ¹⁾	2008.07.09 18:00	stop	Detected
2	Bongan Tunnel ¹⁾	2008.08.17 14:08	collision	Detected
3	Bongan Tunnel ¹⁾	2008.09.06 17:57	collision	Detected
4	Bongan Tunnel ¹⁾	2008.09.15 14:09	collision	Detected
5	Jangyeon Tunnel ²⁾ (Jungbu Naeryuk Expressway)	2007.06.17 21:59	car overturned	Detected
6	Keumnam Tunnel ²⁾	2013.03.20 20:38	collision	Detected
7	Keumnam Tunnel ²⁾	2013.03.27 19:18	clash	Detected
8	Pankyo Tunnel ¹⁾	2011.01.10 12:42	collision	Detected
9	Pankyo Tunnel ¹⁾	2011.01.21 19:10	collision	Detected
10	Pankyo Tunnel ¹⁾	2010.12.28 22:24	collision	Detected

¹⁾ Excerpted From KTA(Korean Tunnelling and Underground Space Association)

²⁾ Excerpted From EX(Korea Expressway Corporation)

(1) 봉안터널에서 발생한 실제 사고영상(Fig. 8)에 본 알고리즘을 적용한 결과 모든 경우에 대하여 감지를 하여 사고를 표출하였다. Fig. 8의 봉안터널 4건은 Traficon 영상감지기에서 획득한 영상으로 CCTV와는 달리 카메라의 주시각이 도로의 근거리를 주시하고 있어 사고감지가 좀 더 용이한 영상이었다.



Fig. 8. accident detection result in BongAn Tunnel

(2) 사고영상 Fig. 9는 CCTV에서 촬영한 영상이다. CCTV 카메라에서 멀리 떨어진 지점에서 사고가 났을 경우 정차차량의 크기가 작게 나타나 사고차량으로 감지하는 데 어려움이 있다. 본 연구에서 제시한 알고리즘 적용한 결과에서는 사고가 감지되었다.



Fig. 9. Accident image(remote accident image from camera)

(3) 사고영상 Fig. 10는 한쪽 차로에 정차된 차량들이 존재한다. 이 정차된 차량은 사고차량이 아니라 공사 준비를 위한 정지차량이고 사고는 다른 차로에서 발생한 경우이다. 이런 경우 정체로 인한 정차와 사고로 인한 정차를 구분하지 못하고 사고감지를 하는 오감지가 발생하는 경우가 많다. 본 알고리즘을 적용한 실험에서는 사고로 판단하였다.



Fig. 10. Accident image (stopped vehicle where one-way is under construction)

(4) Fig. 11에서 보는 바와 같이 실험에 사용한 사고영상 중 2건은 사고로 인한 차량 파편이 도로에 있는 경우이다. 차량 파편의 심각도 분석을 통하여 배경영상에서의 사고차량 감지 방법에서 차선을 제외한 차량 파편의 정도를 계산하여 이것이 일정 임계값을 넘을 경우 사고로 판단하는 경우로 실험한 결과 모두 사고로 판단하여 감지할 수 있었다.



Fig. 11. detection via analyzing the seriousness degree of distribution on vehicle fragments in background images after accident

5. 결론

터널 내 사고를 감지하기 위하여 각종 감지기가 터널 안에 설치되어 있으나, 그중에서도 가장 많이 쓰이는 CCTV 영상 시스템을 중심으로 터널 내에서의 차량 감지와 사고감지 알고리즘을 제안하였다. 본 논문에서 제안한 알고리즘은 GMM을 이용하여 픽셀의 변화량을 판단하여 터널 내 사고로 인한 정지차량을 우선 감지하였다. 특히 이 과정에서 개방도로와 달리 터널 내 사고에서는 차량의 파편이 많이 발생한다는 특징을 고려하여 도로의 파편을 감지하여 사고 판단 여부에 적용하였다. 일정 시간 단위별로 배경영상 시퀀스에 저장하여 사고차량인지를 확인하는 사전 판단 단계 후 최종 판단 단계로 블록 간 점유율의 편차를 분석하여 최종적으로 사고여부를 판단하는 기준으로 적용하였다. 이 방법을 적용하여 사고가 아닌 경우를 사고로 판단하는 오감지를 방지할 수 있도록 하였다. 본 연구에서 제시한 알고리즘을 구현하여 터널 내 사고영상에 적용한 실험에서 모든 영상에 대하여 사고를 감지하였음을 확인하였다. 사고지점이 카메라에서 먼 경우 사고차량이 작게 나타나 사고감지가 어려우나 이 경우도 사고로 감지하였으며, 정체로 인한 정차와 사고로 인한 정차를 구별하여 사고로 감지하였다.

본 실험은 터널 내 사고영상을 직접 구할 수가 없어 기존의 실험 영상과 한국도로공사에서 수집한 영상만을 대상으로 실험하여 다양한 경우를 반영했다고 보기는 어렵다. 사고감지의 정확도를 높이기 위해서는 다양한 터널 내 환경과 사고 유형에 적용할 필요가 있으므로 빅데이터 기반의 사고영상을 수집하여 알고리즘을 적용할 필요가 있다.

References

- [1] C. Naussbaumer, "Comparative analysis of safety in tunnels," in Young Researchers Seminar 2007, *European Conference of Transport Research Institutes*, 2007.
- [2] F. Andres, O. N. Jorge, J. Vedran, P. Aleksandra and P. Wilfried, "A Mathematical Morphology based Approach for Vehicle Detection in Road Tunnels," in *Proceedings of SPIE, the International Society for Optical Engineering*, Vol.8135, 2011.
- [3] e-Narajipyo, Statistics of Road bridges and tunnels in Korea[internet], http://www.index.go.kr/potal/main/EachDtlPageDetail.do?idx_cd=1213.
- [4] H. T. Kim, G. H. Lee, J. S. Park, and Y. S. Yu, "Vehicle Detection in Tunnel using Gaussian Mixture Model and Mathematical Morphological Processing," *Journal of the Korea Institute of Electronic Communication Sciences*, Vol.7, No.5, pp.967-974, 2012.
- [5] B. Martín, S. Vogler, C. Diers, M. Martens, J. Lacroix, M. Steiner, P. Schmitz, and M. Serrano, "Recommendations for the enhancement of Preventive Tunnel safety," SafeT Work package 2 Final Report, 2005.
- [6] Ministry of Land, Infrastructure and Transport, "The National Guideline for the Installation and Management of Road Tunnel Fire Safety Facilities," Seoul: Ministry of Land, Infrastructure and Transport, 2009.
- [7] J. Oh, J. Y. Min, "Gaussian background mixture model based automatic incident detection system for real-time tracking," *Canadian Journal of Civil Engineering*, Vol.38, pp.1158-1169, 2011.
- [8] H. Schwabach, M. Harrer, W. Holzmann, H. Bischof, G. Fernández Domínguez, M. Nöolle, R. Pflugfelder, B. Strobl, A. Tacke, and A. Waltl, "VIDEO BASED IMAGE ANALYSIS FOR TUNNEL SAFETY - VITUS-1: A TUNNEL VIDEO SURVEILLANCE AND TRAFFIC CONTROL SYSTEM," in *Proceedings of the 12th World Congress on Intelligent Transport Systems*, 2005.
- [9] Korea Expressway Cooperation, "A Study on Constructing Evaluation method of Video Incident Detection system in Freeway Tunnels and Extended application plans," Vol.1~Vol.4, 2012.
- [10] J. Versavel, B. Boucké, "Operational Traffic Management by Using Video Detection," ITS America. Meeting (8th: 1998: Detroit, Mich.), Transportation technology for tomorrow: conference proceedings. 1998.
- [11] B. Strobl, M. Harrer, G. Zoffmann, H. Bischof, A. Tacke, A. Waltl, C. Beleznaï, M. Dittrich, H. Grabner, H. Schwabach, and G. Fernández Domínguez, "VITUS-TUNNEL SAFETY THROUGH VIDEO BASED IMAGE ANALYSIS," *Proceedings Of The 13th ITS WORLD CONGRESS*, London, 8-12th, Oct., 2006.

- [12] H. Rakha, B. Hellinga, and M. V. Aerde, "Testbed for Evaluating Automatic Incident Detection Algorithms," in Intelligent Transportation System Safety and Security Conference, Miami, 24-25th Mar., 2004.
- [13] J. J. Reijmers, Traffic Guidance System[internet] <http://www.pn.ewi.tudelft.nl/education/et-024/notes/h12.pdf>
- [14] C. Stauffer, W. Grimson, "Adaptive background mixture models for real-time tracking," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp.246-252, 1999.




백 정 희

e-mail : junghee.baek@gmail.com
 1989년 아주대학교 전자계산학과(학사)
 1989년 아주대학교 컴퓨터공학과(석사)
 2011년~현 재 숭실대학교 미디어학과
 박사과정
 관심분야: 멀티미디어, 모바일 컴퓨팅, 클
 라우드서비스



민 주 영

e-mail : joonym@hanmail.net
 1982년 아주대학교 산업공학과(학사)
 1989년 성균관대학교 정보처리전공(석사)
 1995년 성균관대학교 전산통계전공(박사)
 1993년~현 재 상지영서대학교 국방정보
 통신과 교수
 관심분야: 영상처리, ITS



남 공 성

e-mail : jakenamkoong@gmail.com
 1988년 한양대학교 도시공학과(학사)
 1990년 한양대학교 도시공학과(석사)(교통
 전공)
 1996년 한양대학교 도시공학과(박사)(교통
 전공)

2002년~2004년 미국 버지니아주립대학 Smart Travel Lab/Research
 Scientist

2007년~2013년 아주대학교 ITS대학원 겸임교수

2004년~현 재 한국도로공사 도로교통연구원 교통연구실장

관심분야: ITS, 인공지능, 교통정책



윤 석 환

e-mail : ysh1213@semyung.ac.kr
 1996년 아주대학교 정보시스템전공(공학
 박사)

1986년~1997년 한국전자통신연구원 책임
 연구원

1998년~2005년 정보통신연구진흥원 책임
 연구원

2005년~2012년 숭실대학교 IT대학 겸임교수

2008년~2012년 연세대학교 정보대학원 겸임교수

2008년~2013년 (주)오롬원 대표

2013년~현 재 세명대학교 컴퓨터학부 교수

관심분야: 정보시스템 설계 및 운영, 개발방법론, 클라우드컴퓨
 팅 등