

Faster R-CNN 기반의 관심영역 유사도를 이용한 후방 접근차량 검출 연구

Rear-Approaching Vehicle Detection Research using Region of Interesting based on Faster R-CNN

이 영 학*, 김 중 수*, 심 재 창*[★]

Yeung-Hak Lee*, Joong-Soo Kim, Jae-Chnag Shim*[★]

Abstract

In this paper, we propose a new algorithm to detect rear-approaching vehicle using the frame similarity of ROI(Region of Interest) based on deep learning algorithm for use in agricultural machinery systems. Since the vehicle detection system for agricultural machinery needs to detect only a vehicle approaching from the rear. we use Faster R-CNN model that shows excellent accuracy rate in deep learning for vehicle detection. And we proposed an algorithm that uses the frame similarity for ROI using constrained conditions. Experimental results show that the proposed method has a detection rate of 99.9% and reduced the false positive values.

요 약

본 논문에서는 농업 기계 시스템에서 사용하기 위한 딥러닝 알고리즘 기반의 프레임 내의 관심 영역 유사성을 이용한 새로운 후방 접근 차량 검출 알고리즘을 제안한다. 농업 기계 시스템은 후방에서 접근하는 차량만 검출해야 한다. 지나가는 자동차가 검출되면 혼란을 야기할 수 있다. 논문에서는 차량 검출을 위해 딥러닝에서 뛰어난 검출률을 나타내는 Faster R-CNN 모델을 사용하였다. 딥러닝은 뒤에서 접근하는 차량뿐만 아니라 지나가는 차량도 검출하므로 긍정오류 차량을 배제해야 한다. 본 논문에서 이를 해결하기 위해 검출된 프레임에서 관심 영역에 대한 유사성과 평균 에러를 피라미드 형태로 이용하여 접근하는 자동차만 검출하는 알고리즘을 제안하였다. 실험을 통하여 제안된 방법이 평균 98.8%의 높은 검출률을 나타내었다.

Key words : Deep learning, Faster r-cnn, Agricultural machine, Vehicle detection, Structure similarity

1. 서론

많은 농기계 시스템들이 산업 발전으로 인해 성능이 점점 향상되고 있다. 농작물 재배에 대한 농

기계의 의존도가 증가하고 있습니다. 현재 사용 중인 대부분의 농기계는 자동차보다 느리게 움직인다는 특성을 가지고 있다. 농촌 지역뿐 아니라 도시 교외 지역에서도 농기계가 빈번하게 사용되기

* Dept. of Computer Engineering, Andong National University

★ Corresponding author

E-mail : jcshim@andong.ac.kr, Tel : +82-54-820-5645

※ Acknowledgment

This work was supported by a grant from 2016 Research Funds of Andong National University.

Manuscript received Mar. 13, 2019; revised Mar. 22, 2019; accepted Mar. 22, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

때문에 매년 많은 충돌 사고와 심각한 부상이 발생한다. 본 논문에서는 농기계 사고를 예방하기 위한 농기계의 후방 접근 차량 탐지를 위한 새로운 알고리즘을 제안한다.

차량 검출은 공공의 안전 및 감시, 지능형 교통 제어, 자율 주행 등 다양한 목적으로 사용되고 있다. 차량 검출은 앞면 검출과 뒷면 검출 2종류가 있다. 앞면 검출은 주행 중인 차량의 전방을 주행하고 있는 차량을 검출하는 것이다. 뒷면 검출은 후방에서 접근하고 있는(또는 고정카메라에 접근) 차량을 감지하는 것이다. 후방 접근 차량 검출 방법은 비전 기반 및 소리(또는 주파수) 기반으로 나눌 수 있다. 오디오 기반 연구는 Chen[1]이 자동차 고유 진동수 분석을 사용하여 뒷면에서 접근하는 차량을 감지했다. Ananthanarayanan[2]는 측정 입력 데이터로 다양한 소리(회화, 음악, 바람, 자동차 등)를 사용하여 여러 종류의 특징을 추출하고, 그 특성을 분석하여 후방에서 접근하는 차량 감지 시스템을 개발했다. 이 시스템의 장점은 제조 비용이 낮고 계산량이 적은 것입니다. 그러나 소리(주파수)를 사용하므로 노이즈의 영향에 매우 취약하며, 주파수의 강도가 약한 경우, 후방에 접근하는 차량이 매우 근접하여 검출되므로 위험하게 될 수 있다.

비전 기반 자동차 검출 연구는 자율 주행 차량에서 사용하기 위한 차량 주행 탐지에 중점을 두고 있다. 차량 탐지 장치(정면)에 대한 연구는 많지 않다. 일반적으로 차량 검출 시스템에서 사용하는 물체 특징 추출 알고리즘은 SIFT(Scale Invariant Feature Transform), HOG(Histogram of Oriented Gradients) 히스토그램, SURF(Haar cascade), Bigaussian Edge Detection(BED), Adaboost, SVM(Support Vector Machine) 및 K-Nearest Neighbor(KNN)은 차량 및 기타 객체를 분류하는 데 사용된다. 물체의 특징 추출은 복잡하고 다양한 조명 변화, 카메라 각도 및 이미지 복잡성 등에 영향을 받는다. 잘못된 특징 추출은 객체 탐지 속도를 감소시킬 수 있으며 시스템 저하로 인해 실시간으로 적용하기 어려울 수 있다.

비전 기반 후방 접근 차량 검출 연구는 차량 주행 중 사각 지대에 들어오는 자동차 검출에 초점을 맞추고 있다. Chen[3]은 일차원 거리 정보와 두 교차 시간을 사용하여 사각지대에 접근하는 차량을 감지했다. 논문[4]은 수정된 센서스 변환 특징 벡터

기반의 Adaboost 학습을 통한 캐스케이드 분류를 사용하여 사각지대의 차량을 검출했다. 위의 연구에서 차량은 비슷한 속도와 짧은 거리에서 주행하고 접근하는 차량으로 감지되었으므로 본 연구와 다소 거리가 있다.

딥러닝 기술은 인공 지능 분야에서 점점 더 대중화되고 있다. 특히 Convolutional Neural Network(CNN)은 영상 인식, 음성 인식, 보행자 검출, 얼굴 인식 등 다양한 분야에서 널리 사용되고 있다. CNN은 일반 이미지 추출 시스템과는 달리 원본 이미지를 입력으로 사용하여 높은 유연성 및 일반화 기능을 가지고 있으며 많은 양의 학습을 통해 특징들을 추출하므로 기존의 특징 추출 방법보다 객체 분류 정확도가 현저히 높다. R-CNN [5] 모델은 CNN 모델에 대해 영역기반으로 특징을 추출하는 것으로서, 기존의 특징 추출 모델보다 정확도가 크게 향상된 모델이다. R-CNN은 물체가 있는 영역으로부터 획득된 영역을 관심 영역으로 잘라서 사용한다. 그런 다음 선택적 검색 방법을 사용하여 가장 적합한 위치의 경계 상자를 찾는다. 그러나 R-CNN의 문제는 CNN을 일일이 작성하고 SVM을 사용하여 객체를 분류하며 모든 경계 상자에 대해 선형 회귀를 실행해야 한다는 것이다. 그리고 각 스텝의 유효성 검사에 많은 시간이 소요되는 단점이 있다.

Fast-RCNN [6]은 R-CNN의 문제점을 해결하였다. Fast-RCNN 영역 추출은 CNN을 통과하면서 경계 상자 정보를 유지하고 최종 CNN 특성 맵에서 해당 영역을 추출하는 RoI 풀링 방법을 사용하여 수행된다.

R-CNN 기반 자동차 검출 연구는 다음과 같다. Fan 등 [8]은 모델의 기본 구조와 다양한 실험을 종합적으로 분석하여 Faster R-CNN 모델을 이용한 자동차 검출의 우월성을 입증하였다. Hsu 등[9]은 학습 과정을 가속화하기 위해 탐지된 객체 영역에서 불필요한 부분을 제거한 알고리즘을 사용하였다.

앞서 언급된 알고리즘들은 주행 자동차와 목표 물체 사이의 거리가 매우 가까우므로 우리의 목표와는 거리가 멀다. 본 연구에서는 여러 가지 거리에 대해 그리고 다양한 카메라 각도 영상과 다양한 형태 형상 자동차에 대하여 연구를 수행하였다. 농기계는 접근하는 자동차가 있을 경우 빨간색 LED 경광등이 깜박이게 된다. 그러나 너무 자주 그리고

접근 차량 가까워서 깜박이게 되면 뒤따라오는 자동차의 운전자는 피로도가 높아지게 된다. 그러므로 본 연구에서는 농기계 후미에서 접근하는 차량만이 있을 경우 경광등이 켜도록 기존의 딥러닝 알고리즘과 프레임 관심 영역 유사도를 이용하여 긍정요율을 줄이는 새로운 알고리즘을 제안한다. 제안된 알고리즘의 개요는 그림 1에 나타내었다.

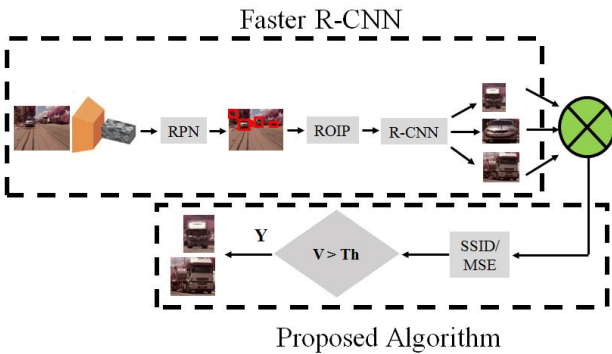


Fig. 1. The architecture of proposed algorithm.
그림 1. 제안된 알고리즘 구조도

II. 본론

1. Faster R-CNN

영상을 분류하는 것보다 영상 내에 있는 객체를 구별하는 것이 어려운 경우가 많다. 기본적으로 딥러닝의 R-CNN은 여러 단계를 거친다. 우선, R-CNN은 객체 존재가 가능한 영역에 대해 영역 선택(region proposal) 또는 바운딩 박스를 생성한다. 바운딩 박스들은 선택적 검색 알고리즘을 사용하여 찾는다. 이것은 비슷한 색상, 밝기, 패턴 등의 인접한 픽셀을 결합하여 찾는 방법이다. 두 번째 방법은 추출된 바운딩 박스를 CNN의 입력으로 사용하기 위해 크기의 단일화이다. 세 번째는 SVM을 사용하여 선택한 영역을 분류하는 것이다. 마지막으로, 분류된 객체의 바운딩 박스가 정확한 좌표를 설정하도록 선형 회귀 모델을 사용한다.

Faster R-CNN은 단순히 영역 제안을 생성하는 부분을 모델내에서 통합하는 영역제안 네트워크(RPN)라는 새로운 방법을 적용하는 방법이다. 이 방법은 객체를 탐지하기 위한 RPN 네트워크의 새로운 응용 프로그램이다. RPN의 역할은 입력 이미지에서 객체를 제안하는 부분의 사각형과 객체 스코어를 출력하는 것이다. 이것은 완전 연결된 네트워크이며 Faster R-CNN과 함께 convolutional 계

층을 공유하도록 설계되었다. 훈련된 RPN은 영역 제안 부분의 품질 향상과 물체 검출의 정확도를 향상시킨다. 일반적으로 Faster R-CNN은 외부의 느린 선택 검색(CPU에 의해 계산 됨)을 사용하지만, 내부의 빠른 RPN(GPU에 의해 계산 됨)을 사용하여 속도를 향상시킨다. RPN는 마지막 convolutional 계층 다음에 위치한다. 그 이후에 ROI Pooling, 분류 그리고 바운딩 박스 가 위치하며, 그림 2와 같다.

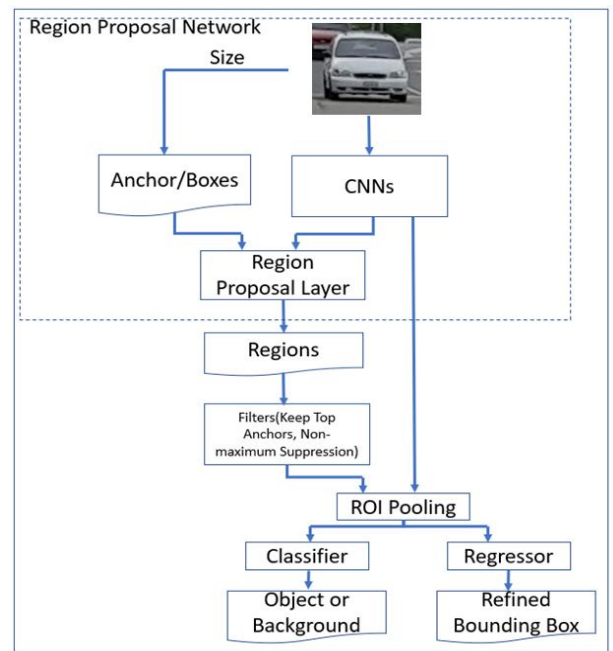


Fig. 2. The Architecture of Faster R-CNN.
그림 2. Faster R-CNN 구조도

RPN은 3×3 윈도우를 이용한 컨볼루션 계산에 의해 입력 영상을 256 또는 512 크기의 특징을 추출한다. 여기서 얻어진 결과는 box classifier 계층과 box regress 계층으로 사용된다. box regression은 미리 정의된 참조 box 이름들을 사용하며, 이 box는 슬라이딩 창의 각 위치에서 바운딩 박스 후보로 사용된다. 이것은 같은 크기의 슬라이딩 윈도우를 움직이는 중심 위치를 이용하여 미리 정의된 다양한 비율 / 크기의 앵커 박스를 적용하여 특징들을 추출한다. 9 개의 앵커 박스(3 가지 크기와 3 가지 비율)가 사용된다. 앵커 박스는 슬라이딩 윈도우의 각 위치에서 바운딩 박스의 후보로 사용된다.

라벨링된 영상 데이터는 앞에서 기술한 Faster R-CNN 모델을 사용하여 처리되고, .meta 파일은 학습 결과로서 생성된다. 최종적으로 얻어진 그래프 파일(“.pb”파일)은 이전 단계에서 얻은 “.meta:” 파

일을 사용하여 생성된다. 마지막으로 “.pb”파일을 사용하는 개체 감지 결과(바운딩 박스 및 개체 점수)가 입력 이미지의 모니터에 표시됩니다.

2. 유사도 계산

SSIM(Structural Similarity)[10]은 압축과 변환으로 인한 왜곡과 원본 이미지의 유사도를 측정하는 방법이며, 이것은 MSE(Mean Square Error)와 Peak Signal 노이즈 비율(PSNR) 방법 보다 높은 정밀도를 나타낸다. 이것은 시각적 유사성을 정량화하기 위한 원본 영상(Y)에 대한 테스트 영상(X)의 평가이다. 1.0에 가까운 값은 테스트 영상이 원본 영상과 비슷함을 의미하며, 0.0에 가까운 값은 테스트 영상이 원본 영상과 매우 다르다는 것을 의미한다. SSIM 수식은 아래와 같이 정의된다.

$$l(x,y) = (2\mu_x\mu_y + C1)/(\mu_x^2 + \mu_y^2 + C1) \quad (1)$$

$$c(x,y) = (2\sigma_x\sigma_y + C2)/(\sigma_x^2 + \sigma_y^2 + C2) \quad (2)$$

$$r(x,y) = (\sigma_{xy} + C3)/(\sigma_x\sigma_y + C3) \quad (3)$$

여기서 μ_x 와 μ_y 는 평균 픽셀 값, σ_x 와 σ_y 는 표준편차 그리고 σ_{xy} 는 x와 y의 공분산 값이다. C1, C2 그리고 C3는 분모와 분자가 0이 되는 것을 막기 위한 상수이다. $l(x,y)$ 는 밝기 차이의 관계, $c(x,y)$ 는 대비 차이의 관계 그리고 $r(x,y)$ 는 x와 y 사이의 구조적 변화에 대한 유사도이다. 이들을 이용한 구조적 유사도는 식 (4)와 같다.

$$SSIM = [l(X,Y)]^\alpha [c(X,Y)]^\beta [r(X,Y)]^\gamma \quad (4)$$

여기서 α, β, γ 는 각 항의 중요도를 나타내는 것으로써 본 논문에서는 1.0을 사용하였다.

III. 실험 및 결과

본 논문은 경운기 운전자 보호를 위해 차량 감지 시스템에서 후방 접근차량 검출에 적용되는 딥러닝 기반 및 프레임내의 관심영역 유사성을 이용한 새로운 알고리즘을 제안하였다. 연구에서 사용된 시스템은 Intel Core i7-7700(3.5 GHz), 메모리 16G, Geforce TITAN-X이며, 주요 프로그램은 OpenCV 및 Python 3.5 이다. 본 연구에 사용된 자동차 데이터베이스는 일반 거리에서 직접 녹화된 비디오를 사용하였다(100 미터가 넘는 차량도 포함). 비디오

녹화 장치는 RaspberryPi 및 NoIR 카메라를 이용하였다.

제안 된 알고리즘을 구현하기 위해 다음과 같은 과정을 수행하였다. 첫 번째, 라벨링 데이터 작업이다. 비디오로부터 프레임 단위로 영상을 추출 한 후, 각각의 영상으로부터 자동차에 해당 부분들을 LabelImg 프로그램을 사용하여 라벨링을 한다. 라벨링 영역의 예를 그림 3에 나타내었다. 본 논문에서 사용된 자동차는 승용차, SUV, 승합차, 버스(중대형) 및 트럭(중소형 및 대형)과 같은 다양한 차종을 훈련 및 실험 대상으로 하였다. 라벨링 결과는 이미지 이름과 함께 각 사각형의 네 점 좌표와 객체의 이름이 포함되어 .xml 파일에 저장된다.



Fig. 3. Example of Labeling area for dataset image.

그림 3. 영상 데이터의 라벨링 영역 예

둘째, 라벨링된 영상들에 대한 훈련과정이다. 레이블링 결과의 .xml 파일은 텐서플로의 학습 데이터 형식으로 변환되어야 합니다. 훈련 과정에서 입력 영상은 JPEG 또는 PNG 파일입니다. 이러한 영상의 메타 데이터 및 레이블은 별도의 파일에 저장되므로 훈련 데이터를 읽을 때 메타 데이터 또는 레이블 파일과 별도로 이미지 파일을 읽어야하기 때문에 코드가 복잡해집니다. 또한 영상을 JPG 또는 PNG 형식으로 읽고 매번 디코딩하면 성능이 저하될 수가 있다. TFRecord 파일 형식을 사용하면 위의 성능 저하를 방지하고 보다 쉽게 개발할 수 있다. TFRecord 파일 형식은 이미지의 높이와 너비, 파일 이름, 인코딩 형식, 이미지 바이너리, 영상에서 대상 물체의 위치를 나타내는 레이블 사각형 위치 값을 저장한다. 이 과정을 통해 전체 학습 데이터는 70% 훈련 데이터와 30% 유효성 검증데이터로 분류되어 저장된다. 훈련에 사용된 모델은 FAST

R-CNN ResNet (Deep Residual Network) 선택하였으며, 적은 종류의 물체와 검출율이 높은 것이 특징이다. 차량 1 종류의 물체만 검출하면 되므로 카테고리는 1로 설정하였으며, 학습 단계는 20,000으로 설정하였다.

세 번째, 훈련된 모델의 추출하는 것이다. 학습 프로세스는 소정의 포인터마다 학습 결과를 나타내는 체크 포인터를 저장한다. 각각 체크 포인터는 Tensorflow 모델 파일 형식의 모델에 대한 meta 정보를 가지고 있으며, 다시 학습 할 수 있다. 그러나 메타 파일에는 많은 불필요한 정보가 있기 때문에 실제 모델을 사용하기 위해서는 메타 파일을 개선해야할 점이 많다. 최종적으로 메타 데이터를 제외한 모델과 가중치를 결합하는 “.pb”파일이 생성된다.

이 논문에서, 실험 데이터는 중앙 분리대가 없는 도로에서 촬영된 비디오 영상을 사용하였다. 그림 3은 실험에 사용된 비디오의 프레임 예를 나타내었다.



Fig. 4. Example of the frame sequences of test videos.
그림 4. 테스트 비디오의 연속 프레임 예

FAST R-CNN 모델을 기반으로 완성된 “.pb”파일을 사용하여 비디오 실험을 수행하였다. 그림 5와 표 1은 일반적인 딥러닝 알고리즘(Faster R-CNN)을 적용한 비디오 실험 결과를 나타내었다.




Fig. 5. The frame sequence result of the Faster R-CNN,
(a) the result of true positive,
(b) the result of false positive.
그림 5. Faster R-CNN의 연속 프레임 결과 (a) true positive 결과, (b) false positive 결과

Table 1. Faster R-CNN results for video images (Frames).

표 1. Faster R-CNN 비디오 테스트 결과

Input Video	Ground Truth	True Positive	False Positive
Video 1	4528	4463	65
Video 2	50052	45549	4503

표 1에서 Video1의 정밀도는 98.5%를 나타내며, Video 2의 정밀도는 91.0%를 나타내었다. 정밀도 계산식은 식 (5)와 같다. 표 1에서 Ground Truth는 차량이 감지된 전체 이미지의 프레임 수를 나타낸다. True Positive(TP)는 후방 접근 차량 검출 경우를 나타내고, False positive(FP)는 카메라로부터 멀어지는 차량(농기계를 지나가는 차량) 검출 경우를 나타낸다.

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

일반적인 딥러닝 방법은 그림 4(b)처럼 정상적으로 접근하는 차량 검출(true positives)과 많은 긍정오류(false positive)이 검출된다. 이것은 학습 과정에서 객체의 특징을 추출할 때, 물체의 모양을 다양한 각도에 이용하기 때문이다. 경운기에 장착된 시스템이 경고등과 경보음을 자주 발생하면 농기계 운전자는 방해받을 수 있다. 따라서 농기계 운전자에게 방해가 되는 신호를 제거할 필요성이 있다. 입력 프레임 영상에서 제거 대상은 주차된 차량(움직이지 않으므로 불필요) 및 후방 카메라를 통과하는 차량(자동차의 뒷면이 보임)이다. 본 논문에서는 입력 영상으로부터 딥러닝을 이용하여 자동차가 검출되면 프레임에서 관심 영역으로 저장되며, 다른 프레임과의 비교는 SSIM 지수와 평균 제곱(MSE) 오차를 이용하여 긍정오류 여부를 판별하게 된다. 긍정오류로 추출된 거짓 정보를 제거하기 위한 피라미드 형태로 비교를 수행하였다. 주차된 차량은 프레임 유사성 비교에서 높은 가치를 나타내며 통과하는 차량은 소형 차량으로 인해 유사성이 매우 낮다. 실험에서 하나의 배열에 20장의 프레임 영상이 저장되며, 1, 10, 20 번째 프레임 영상을 이용하였다. 농기계에 접근하는 차량은 시간이 지날수록 자동차의 크기는 커지게 되며, 반대로 지나가는 자동차는 점점 작아지게 된다. 본 논문에서는 3가지 크기를 사용하였으며, 실험 결과를 표

2에 나타내었다. 첫째, 차량이 심층 학습을 통해 감지되면 20 개의 연속 프레임이 배열에 저장된다. 검출된 차량 영역(바운딩 박스 영역)과 동일한 위치에서 동일한 크기로 각각 1 번째, 10 번째 및 20 번째 프레임의 f_b (이전 프레임), f_c (현재 프레임) 및 f_f (다음 프레임)에 저장된다. 그런 다음 SSIM 지수와 평균 자승 오차 (MSE)를 사용하여 유사성을 계산하며 차량의 최종적 판단은 식(10)을 이용하여 결정하게 된다.

$$S_k^p = ssim(f_i, f_j) \quad avg_{s1,s2} = (S_1^p + S_2^p) / 2 \quad (6)$$

$$M_k^p = MSE(f_i, f_j) \quad (7)$$

$$V_S^p = \begin{cases} 1, & \text{if } avg_{s1,s2}^p > S_3^p, S_3^p < 0.5 \\ 0, & \text{else} \end{cases} \quad (8)$$

$$V_M^p = \begin{cases} 1, & \text{if } M_{1,2,3}^p > Th \\ 0, & \text{else} \end{cases} \quad (9)$$

$$V^p = \begin{cases} 1, & \text{if } V_S^p = 1 \text{ and } V_M^p = 1 \\ 0, & \text{else} \end{cases} \quad (10)$$

여기서 k 는 1, 2, 3이며, p 는 Py_1, Py_2, Py_3를 나타낸다. 논문에서 Py_1은 현재 검출된 바운딩 박스 보다 작은 영역($x-10, y-10$), Py_2는 현재 검출된 바운딩 박스 영역(x, y), Py_3는 현재 검출된 바운딩박스 보다 큰 영역($x+10, y+10$)를 의미한다.

Table 2. Proposed algorithm results for video images (Frames).

표 2. 제안된 알고리즘을 적용한 video 테스트 결과

Input Video		Ground Truth	True Positive	False Positive
Video 1	Py_1	2277	2260	17
	Py_2	1719	1715	4
	Py_3	1406	1404	2
Video 2	Py_1	14230	13915	315
	Py_2	14754	14444	316
	Py_3	18182	17888	302

제안된 알고리즘은 주차된 차량 그리고 반대 방향으로 움직이는 차량(후방 카메라를 통과하는 차량)을 제거한다. 표 2에서 비디오 1의 정확도는 평균 99.7%이고 비디오 2의 정확도는 98.6%이다. 그리고 그림 6 (a)와 (b)는 제안된 알고리즘이 많은 긍정오류 자동차를 제거했음을 보여준다. 표 2는 긍정오류(false positive)을 포함한 모든 프레임이 제안된 알고리즘을 통해 제거되었기 때문에 Ground

Truth 개수가 다르게 나타났다. 표 2에서 영역이 커질수록(Py_3) 긍정오류 검출이 잘 된다는 것을 알 수 있다. Video1에서는 99.9% 그리고 Video 2에서는 98.3%를 각각 나타내었다. 그림 6 (a)는 제안된 알고리즘을 적용하여 차량 검출이 잘된 경우를 나타낸 것이다. 반면에 그림 6 (b)는 일부의 긍정오류는 제거되었지만, 여전히 긍정오류(빨간색 원)가 존재하며, 추가적인 알고리즘 개선이 필요하다.



Fig. 6. The result of adapted proposal algorithm using video files, (a) good result, (b) bad result.

그림 6. 제안된 알고리즘이 적용된 비디오 파일 실험 결과, (a) 좋은 검출 결과, (b) 나쁜 검출 결과

IV. 결론

본 논문은 농기계 운전자 보호 시스템에 사용되는 새로운 후방 접근 차량 검출 알고리즘을 제안한다. 농기계와 차량 충돌은 운전자를 비롯하여 모든 승객이 아주 심각한 부상이 야기된다. 일반적인 방법에 의한 자동차 특징 추출은 영상 일부 가림, 카메라 각도, 날씨 등에 의해 영향을 받는다. 이 문제를 해결하기 위해 우리는 현재 딥러닝 방법을 많이 사용하고 있다. 그러나 딥러닝 방법은 후방 접근 차량뿐만 아니라 통과 차량 및 정지 차량 모두를 검출하므로 불필요한 차량 탐지 발생이 많다. 본 논문에서는 Faster R-CNN에 의해 검출된 차량 영상 영역에 대해 인접 프레임과의 유사도 및 평균 제곱 오차 방법을 사용하여 불필요한 차량(주차 또는 정지 차량과 통과하는 차량)을 제거하였다. 기존의 일반적인 딥러닝만을 적용했을 때 보다 제안된 알고리즘의 긍정오류 확률이 현저히 줄어든다는 것을 실험을 통해 알 수 있었다. 제안된 알고리즘의 정확도는 평균 98.2%를 나타내었다. 추후 과

제로씨는 긍정오류를 좀 더 줄이기 위해 자동차의 움직임 분석과 프레임의 상관관계를 이용한 실험 및 딥러닝 모델 연구가 필요하다.

References

- [1] C. Chen, "Rear Approaching Vehicle Detection with Microphone," Bachelor's Thesis, Halmstad University, 2013.
- [2] V. K. Ananthanarayanan, "Audio Based Detection of Rear Approaching Vehicle on a Bicycle," *Graduate School Thesis*, Rutgers University, 2012.
- [3] C. T. Chen and Y. S. Chen, "Real-time approaching vehicle detection in blind-spot area," *12th Internal IEEE Conference on intelligent Transportation Systems*, 2009.
DOI: 10.1109/ITSC.2009.5309876
- [4] H. W. Kang, J. W. Baek, and Y. S. Jeong, "Real-Time Side-Rear Vehicle Detection Algorithm for Blind Spot Warning Systems," *KIISE Transactions on Computing Practice*, vol. 23, no. 7, pp. 408-416, 2018. DOI: 10.4271/2012-01-0293
- [5] J. Dobahue, R. Girshick, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," *IEEE Internal Conference on Computer Vision and Pattern Recognition*, pp. 580-587, 2014.
- [6] Ross Girshick, "Faster-RCNN," *IEEE International Conference on Computer Vision*, pp. 1440-1448, 2015. DOI: 10.1109/ICCV.2015.169
- [7] S. Ren, K. He, R. Gishick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol. 38, no. 6, pp. 1137-1149, 2017.
DOI: 10.1109/TPAMI.2016.2577031
- [8] F. Quanfu, B. Lisa, and S. Hohn, "A Closer Look at Faster R-CNN for Vehicle Detection," *2016 Intelligent Vehicle Symposium*, pp. 124-129, 2016. DOI: 10.1109/IVS.2016.7535375
- [9] S. C. Hsu, C. L. Huang, and C. H. Chuang, "Vehicle Detection using simplified Fast R-CNN," *International Workshop on Advanced Image*

Technology, 2018.

DOI: 10.1109/IWAIT.2018.8369767

- [10] H. S. Kim and J. S. Park, "intensity-based efficient Video Quality Assessment for Variable bitrate Streaming," *Korean Institute of Next Generation Computing*, vol. 11, no. 5, pp. 63-71, 2015.

BIOGRAPHY


Yeung-Hak Lee (Member)



1988 : BS degree in Electronic Engineering, Yeungnam University.
1991 : MS degree in Electronic Engineering, Yeungnam University.
2003 : PhD degree in Electronic Engineering, Yeungnam University.

1991~1995 : Research Engineer, LG Precision.
2005~2006 : Postdoc, Cardiff University.
2010~2016 : Professor, Kyungwoon University.
2017~ : Research Engineer, Andong National University.

Joong-Soo Kim (Member)



1982 : BS degree in Electronic Engineering, Kyungpook National University.
1984 : MS degree in Electronic Engineering, Kyungpook National University.

1996 : PhD degree in Electronic Engineering, Kyungpook National University.
2001~2002 : Visiting Professor, University of Texas at Arlington.
1987~ : Professor, Andong National University

Jae-Chang Shim (Member)



1987 : BS degree in Electrical Engineering, Kyungpook National University.
1990 : MS degree in Electrical Engineering, Kyungpook National University.
1993 : PhD degree in Electrical Engineering, Kyungpook National University.

1994~ : Professor, Andong National University.