

UAV를 활용한 실시간 교통량 분석을 위한 딥러닝 기법의 적용 Application of Deep Learning Method for Real-Time Traffic Analysis using UAV

박홍련¹⁾ · 변성훈²⁾ · 이한성³⁾

Park, Honglyun · Byun, Sunghoon · Lee, Hansung

Abstract

Due to the rapid urbanization, various traffic problems such as traffic jams during commute and regular traffic jams are occurring. In order to solve these traffic problems, it is necessary to quickly and accurately estimate and analyze traffic volume. ITS (Intelligent Transportation System) is a system that performs optimal traffic management by utilizing the latest ICT (Information and Communications Technology) technologies, and research has been conducted to analyze fast and accurate traffic volume through various techniques. In this study, we proposed a deep learning-based vehicle detection method using UAV (Unmanned Aerial Vehicle) video for real-time traffic analysis with high accuracy. The UAV was used to photograph orthogonal videos necessary for training and verification at intersections where various vehicles pass and trained vehicles by classifying them into sedan, truck, and bus. The experiment on UAV dataset was carried out using YOLOv3 (You Only Look Once V3), a deep learning-based object detection technique, and the experiments achieved the overall object detection rate of 90.21%, precision of 95.10% and the recall of 85.79%.

Keywords : UAV(Unmanned Aerial Vehicle), ITS(Intelligent Transportation System), Traffic Analysis, Deep Learning, Object Detection

초 록

급격한 도시화로 인해 출퇴근 시간의 차량 정체, 상시 정체지역 발생 등 다양한 교통문제들이 발생하고 있다. 이러한 교통문제들을 해결하기 위해서는 신속·정확한 교통량 예측 및 분석이 필요하다. ITS (Intelligent Transportation System)는 최신 ICT (Information and Communications Technology) 기술들을 활용하여 최적의 교통관리를 수행하는 시스템이며, 다양한 기법을 통해 신속·정확한 교통량을 분석하기 위한 많은 연구가 수행되었다. 본 연구에서는 높은 정확도로 실시간 교통량 분석을 위해 UAV (Unmanned Aerial Vehicle) 동영상을 활용한 딥러닝(deep learning) 기반의 차량탐지기법을 제안하고자 한다. 이를 위해, UAV를 활용하여 다양한 차량이 통행하는 교차로에서 학습 및 검증에 필요한 정사 동영상 촬영을 수행하였으며, 승용차(sedan), 트럭(truck), 버스(bus)로 분류하여 차량을 학습시켰다. 딥러닝 알고리즘은 대표적인 객체탐지 알고리즘 중의 하나인 YOLOv3 (You Only Look Once V3)를 이용하였으며, 실험결과 전체 차량 검출율은 90.21%이며, 정확도와 재현율은 각각 95.10%와 85.79%이다. 본 연구를 통하여, 드론을 이용한 영상으로부터 차량 탐지를 통한 실시간 교통량 분석이 가능함을 확인하였다.

핵심어 : 무인항공기, 지능형 교통 체계, 교통량 분석, 딥러닝, 객체탐지

Received 2020. 07. 21, Revised 2020. 08. 10, Accepted 2020. 08. 19

1) Member, School of Drone & Transportation Engineering, Professor, Youngsan University (E-mail: hlpark@ysu.ac.kr)

2) School of Computer Engineering, Undergraduate student, Youngsan University (E-mail: tjdgns5332@naver.com)

3) Corresponding Author, Member, School of Computer Engineering, Professor, Youngsan University (E-mail: mohan@ysu.ac.kr)

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.

1. 서론

최근 급격한 도시화는 인구밀도의 상승을 야기 시키면서, 도심지에서는 출퇴근 시간의 차량 정체, 상시 정체지역 발생 등의 교통문제들이 발생하고 있다. 가구 당 보유 차량대수와 물류산업의 증가 또한 교통문제 발생의 원인이 되면서 도시 개발에 있어 교통량 예측 및 분석의 중요성이 대두되고 있다. ITS는 교통 분야에 ICT기술을 적용하여 교통 정보 및 자료를 수집하고 가공하여 교통이용자들에게 제공함으로써 효과적인 교통 체계를 구축하기 위한 기술이다. ITS는 서비스에 따라 5가지로 분류할 수 있으며, 이 중 ATMS (Advanced Traffic Management System)는 교통정보를 실시간으로 분석하고, 이를 통해 최적의 도로 교통 관리 역할을 수행한다. 최적의 도로 교통 관리를 위해 가장 중요한 교통정보 중의 하나는 교통량이다. 전통적인 교통량 조사 방법들은 지하에 매설하는 루프센서, 적외선 검지기 등 센서를 활용한 방법들이었다. 하지만 이러한 방법들은 획득한 정보들에 대해 가공이 필요하여 실시간으로 교통량 분석을 수행하기에 한계가 존재한다.

최근에는 교통정보를 수집하기 위한 CCTV (Closed Circuit TeleVision)의 보급이 확산되면서 영상처리기법들을 활용한 교통량 분석방법에 대한 연구가 활발히 수행되고 있다. Ha *et al.* (2001)은 CCTV를 활용한 차량 검출 정확도를 향상시키기 위해 영상 내의 배경 제거 및 에지 검출을 통한 차량 그림자를 제거하는 방법을 제안하였으며, 국부 검지 영역만으로 초기 차량을 검지하고 PVI (Panoramini View Image)와 EPI (Epipolar Plane Image)를 생성하여 교통정보를 산출하는 영상 기반 교통량 분석기법이 개발되기도 하였다(Lee and Park, 2004). 최근에는 영상처리 기법들이 발전함에 따라 교통량뿐만 아니라 차량을 추적하여 교통의 흐름까지 분석할 수 있는 기법들이 제안되고 있다. Lee and Jang (2005)는 단 위시간 별 차량의 위치정보를 취득할 수 있는 룰(rule) 기반의 차량추적기법을 제안하였으며, Nizar *et al.* (2014)는 기계학습 기반 객체추출 기법을 차량의 탐지 및 추적에 활용하여 교통량 분석을 수행하였다. 교통량 조사에서 차종의 분류는 교통흐름을 분석하는데 중요한 요소 중의 하나이다. Hong *et al.* (2011)은 교통량 분석 및 감시를 위해서 CCTV 영상에 객체탐지 및 그림자 제거 등의 영상처리 기법을 적용하여 차량을 탐지하고 차종을 대형 및 소형으로 분류하여 교통량을 분석하는 기법을 제안하였다. Jo *et al.* (2018)은 CCTV 동영상에 차 영상(difference image)을 활용한 변화탐지 기법을 적용하여 교통량 분석을 수행하는 방법을 개발하였다. 최근에는 기존의 객체탐지 기법들 보다 우수한 탐지 성능을 보이고 있는 딥

러닝(deep learning) 기반의 객체탐지 기법들이 개발되고 있으며, 교통량 분석에도 활용되고 있다(Zhao *et al.* 2019). Peppas *et al.* (2018)은 CCTV 동영상에 CNN (Convolution Neural Networks) 기반의 차량탐지 기법을 제안하였으며, Seong *et al.* (2019)은 교차로에 설치된 CCTV 동영상에 YOLOv3 (You Only Look Once V3) 기법을 적용하여 차량 탐지 및 추적하는 방법을 개발하였다. 하지만 도로에 기 설치된 CCTV들은 영상의 공간해상도가 낮고, 촬영 각 및 위치를 변경하기 어려움이 있다. 때문에 다양한 장소에서 촬영이 가능하며, 고화질의 영상취득이 용이한 UAV를 활용하여 교통량을 분석하는 연구들이 수행되어지고 있으며(Seo and Lee, 2018), Ke *et al.* (2016)은 UAV 동영상 기반 실시간 교통량, 차량속도를 분석할 수 있는 방법을 개발하였다.

본 연구에서는 딥러닝 알고리즘을 활용한 UAV 영상 기반의 교통량 분석 방법을 제안하고자 한다. 제안하는 방법은 UAV를 통해 교통량 측정 대상이 되는 지역을 촬영하고, 실시간으로 입력되는 영상에서 차량을 종류별로 탐지하여 교차로 등 교통량 분석의 대상 지역으로 얼마나 많은 차량이 지나갔는지 확인 하는 방법이다. UAV를 사용하여 교통량 측정을 할 경우의 장점은 다양한 지역을 CCTV 등의 별도 설비 없이 측정할 수 있다는 점과 교통량 측정 조사 지점을 상황에 따라 자유롭게 이동할 수 있다는 점이다. 본 연구에서는 제안하는 방법의 타당성을 보이기 위하여, 교차로에서 UAV를 통해 정사 동영상을 취득하였으며 딥러닝 기반의 객체탐지 기법인 YOLOv3를 기반으로 실시간 차량 탐지를 수행하였다. 또한, 교통량 조사와 함께 차종의 분류를 위해 승용차, 트럭, 버스로 분류하여 학습을 수행하고 차량 탐지 및 차종 분류의 정확도를 평가하여 교통량 분석에 최신 딥러닝 기반의 알고리즘 적용 가능성을 분석하였다. 본 연구에서 제안한 기법의 정확도는 교통량 분석의 대상이 되는 도로상의 주행 차량에 대한 객체 탐지 성능평가를 통해 검증하였으며, 평가결과를 통해 드론을 이용한 영상으로부터 차량 탐지를 통한 실시간 교통량 분석이 가능함을 확인하였다.

2. 실험장비 및 자료

본 연구에서는 딥러닝 기반의 객체탐지 기법 중의 하나인 YOLOv3를 활용하여 교통량 및 차종 분석을 수행하였으며, 이를 위해 UAV를 활용하여 학습자료 및 정확도 검증을 위한 동영상을 취득하였다. 사용 장비는 DJI 사의 Mavic PRO를 활용하였으며(Fig. 1), 수동 비행으로 교차로 중심 고도 50 m에 호버링(hovering) 하여 정사 동영상을 촬영하였다. Mavic

PRO의 제원은 Table 1과 같다.



Fig. 1. Mavic Pro

Table 1. Specification of Mavic Pro

Type	Rotary Wing (Quad copter)
Size	H83 mm × W83 mm × L198 mm
Weight	734 g
Accuracy of GPS hovering	Vertical 0.5 m Horizontal 1.5 m
Receiver coverage	7 km
Max. speed	65 km/h
Max. altitude	5000 m
Max. flight time	27 minutes
Camera FOV	78.8°
Number of Video pixels	1280 × 720

딥러닝 기법을 적용하기 위해서는 학습자료 제작을 위한 영상과 검증을 위한 영상이 필요하다. 차량학습을 위한 영상 촬영 지역은 경상남도 양산시 일원의 교차로이며, 대상지역은 주변에 산업단지과 주거지역이 혼합되어 있어 승용차, 버스뿐만 아니라 화물트럭의 운행이 잦은 지역이므로 다양한 차종에 대한 학습을 위해 자료 취득지역으로 선정하였다. 차량탐지의 검증을 위한 영상은 강원도 횡성군 일원의 교차로를 선정하였으며, 두 지역 모두 50 m 고도에서 10분 동안 동일한 조건으로 촬영을 수행하였다(Fig. 2).

3. 교통량 분석을 위한 딥러닝 기반 차량 검출 방법

본 절에서는 UAV 영상을 기반으로 교통량 분석을 위한 딥러닝 기반의 객체 탐지 방법에 대하여 설명한다. 객체 탐지는 이미지에서 관심 객체를 배경과 구분하여 식별하는 기술로, 이미지상의 객체의 분류 클래스뿐만 아니라 이미지상의 객체 위치를 동시에 추론하는 방법이다. 딥러닝 기반의 객체 인



(a)



(b)

Fig. 2. Video acquired using UAV: (a) video for training, (b) video for verification

식 방법은 객체의 후보 영역을 찾고 해당 후보 영역의 이미지 분류를 수행하는 과정으로 구성된다. 전통적인 방법은 객체의 후보 영역을 찾기 위하여 슬라이딩 윈도우 방식을 사용하였으나, 너무나 많은 객체 후보 영역에 대해 분류를 수행함으로 매우 많은 계산량을 요구하고 속도가 느리다는 단점을 가지고 있다. 딥러닝 기반 방법론 중 회귀분석을 통한 객체의 위치와 분류를 위한 방법으로 R-CNN (Regional-based Convolutional Neural Network) 계열의 방법론이 소개된 바 있으며(Girshick *et al.*, 2014), 속도 개선을 위하여 Fast-RCNN(Girshick, 2015), Faster-RCNN(Ren *et al.*, 2017)으로 발전하였다. 특히, Faster-RCNN은 검출 속도를 개선시켰을 뿐만 아니라 딥러닝 구조 안에 객체 후보 영역을 생성하는 기능을 통합하여, 객체 탐지 속도를 향상시켰으며, 딥러닝만을 이용하여 객체 탐지를 수행할 수 있도록 하였다. 하지만, R-CNN 계열의 알고리즘이 딥러닝 기반의 객체 탐지 방법론의 발전을 이끌었으나, 실시간 처리 속도를 필요로 하는 분야에 적용하기에는 부족한 부분이 있었다. 이러한 문제를 해결하기 위하여 실시간에 가까운 처리를 위한 보다 빠른 딥러닝 기반의 알고리즘인 YOLO가 개발 되었다(Redmon *et al.*, 2016). 본 연구에서는 UAV 영상을 이용한 교통량 분석에 관

한 것으로 실시간에 가까운 빠른 객체 탐지를 요구한다. 이에 YOLO의 성능을 개선한 고속의 알고리즘인 YOLOv3를 객체 탐지를 위하여 채택하였다.

3.1 YOLO 알고리즘

YOLO 알고리즘은 객체 탐지 문제를 공간적으로 분리된 객체 후보 영역의 경계 상자(bounding box)와 해당 객체의 분류 클래스 모델의 회귀 문제로 정의한다. 단일 신경망으로 단 한번의 평가로 전체 이미지에서 직접 경계 상자와 분류 클래스의 확률을 예측하므로 탐지 성능에 따라 종단 간(end-to-end) 최적화를 직접 결정할 수 있다는 장점을 가지고 있다. 이미지를 $S \times S$ 개의 격자로 나누고 각 격자 셀에 대해 B 개의 경계 상자들과 해당 경계 상자들의 신뢰도, 그리고 C 개의 분류 클래스 확률을 예측한다. 객체 탐지 모델은 24개의 합성곱 계층(convolutional layer)과 2개의 완전 연결 계층(fully connected layer)으로 구성된다. 최종 계층에서는 선형 활성화(linear activation) 함수를 사용하였으며, 다른 모든 계층에서는 Eq. (1)의 누출 정류 선형 활성화(leaky rectified linear activation) 함수를 사용하였다.

$$h(x) = \begin{cases} x & , \text{if } x > 0 \\ 0.1x & , \text{otherwise} \end{cases} \quad (1)$$

학습 단계에서는 하나의 경계 상자 예측 모델이 각 객체를 담당하도록 한다. 어떤 ground truth의 가장 높은 IoU (Intersection over Union)를 갖는지를 기반으로 객체를 예측하기 위하여 하나의 예측 모델을 할당한다. 결과적으로 각 예측 모델은 특정 크기, 종횡비 또는 분류 클래스를 보다 잘 예측하도록 하여 전체적인 재현율(recall)을 향상시킨다. 학습을 위해서 Eq. (2)의 로스 함수(loss function)를 사용한다.

$$\begin{aligned} L(x) = & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{i,j}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \\ & + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{i,j}^{obj} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] \quad (2) \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{i,j}^{obj} (c_i - \hat{c}_i)^2 + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{i,j}^{noobj} (c_i - \hat{c}_i)^2 \\ & + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2 \end{aligned}$$

여기에서 1_i^{obj} 는 만약 객체가 셀 i 에 존재함을 의미하고, 1_i^{noobj} 는 i 번째 셀에 있는 j 번째 결정 상자 예측 모델이 해당

측을 담당하는 모델임을 의미한다.

3.2 YOLOv3 알고리즘

YOLOv3 알고리즘은 기존 YOLO 버전을 일부 수정하여 배포한 모델이다. 기존 모델은 차원 클러스터(dimension cluster)를 앵커박스(anchor boxes)로 사용하여 경계 상자를 예측한다. 네트워크는 각 경계 상자에 대해 t_x, t_y, t_w, t_h 의 4개의 좌표를 예측한다. 셀이 이미지의 왼쪽 상단에서 c_x, c_y 만큼 변위차를 가지고 있고, 경계 상자의 너비와 높이가 p_w, p_h 인 경우 예측은 Eq. (3)과 같다.

$$\begin{aligned} b_x &= \sigma(t_x) + c_x \\ b_y &= \sigma(t_y) + c_y \\ b_w &= p_w e^{t_w} \\ b_h &= p_h e^{t_h} \end{aligned} \quad (3)$$

기존의 경계 상자 예측과 차이점은 각각의 경계 상자마다 해당 경계 상자에 객체가 있을 정도를 예측하는 점수인 objectness score를 로지스틱 회귀 방법으로 예측하고 가장 높은 IoU를 갖는 경계 상자를 선택하도록 하였다. 분류 클래스 예측을 위해서는 다중 라벨(multi label)을 고려하여 softmax를 사용하지 않고 대신 independent logistic 분류기를 사용하였다. 학습을 위한 로스 함수로 binary cross-entropy를 사용하였다. YOLOv3는 3가지의 서로 다른 스케일로 경계 상자를 예측한다. 특징 피라미드 네트워크(feature Pyramid Network)와 유사한 개념으로 해당 스케일에서 특징을 추출한다. 기본 특징 추출기로부터 여러 개의 합성곱 계층을 추가하였다. 예측의 최종 결과는 경계 상자, objectness score, 그리고 분류 클래스 예측 결과가 3차원 텐서로 산출된다.

4. 실험결과 및 분석

4.1 실험 환경 및 제약 조건

본 논문에서는 드론을 통하여 수집된 영상으로 부터 교통량 분석을 위한 딥러닝 기반의 차량탐지를 수행하였고, 제안된 방법의 성능을 실험적으로 검증하기 위하여 2절에서 수집한 교차로의 차량 주행 영상을 대상으로 실험을 수행하였다. 딥러닝 기반의 객체 인식을 위하여 YOLOv3 알고리즘을 사용하였으며, 영상 사이즈는 608×608 픽셀로 정규화 하였다. 필터의 개수는 총 27개를 사용하였다. 인식 대상은 승용차, 트럭, 버스의 3개의 클래스로 나누어 객체 인식 모델을 학습하

고 추론하였다. Fig. 3은 본 연구에서 사용한 학습 데이터와 테스트 데이터의 예시이다. 학습에 사용한 데이터는 경상남도 양산 일대의 산업단지에서 수집하였으며, 테스트에 사용한 데이터는 강원도 횡성군 일대의 교차로에서 수집하였다. 제안된 방법의 일반화 성능 및 범용적 활용 가능성을 확인하기 위하여 학습에 사용한 데이터와 테스트에 사용 데이터의 수집 지역을 달리하였다. 학습을 위해서는 수집된 학습 영상을 프레임단위로 정지 영상을 추출하여 라벨링(labeling)을 수행하고 정지 영상을 기반으로 학습하였다. 실제 차량 검출은 동영상상을 대상으로 수행하나, 성능 검증을 위하여 수집된 테스트 동영상에서 정지 영상을 추출하여 성능을 평가하였다. Fig. 3(a)는 학습에 사용된 영상의 일부이며, Fig. 3(b)는 학습 데이터의 라벨(label)이며, Fig. 3(c)와 Fig. 3(d)는 각각 테스트에 사용된 영상의 일부와 ground truth이다. 본 연구는 교통량 분석이 목적이므로, 실험 결과를 분석할 때는 도로상의 차량에 대해서만 포함하였다. 수집된 영상에서 도로 이외의 영역은 수동으로 지정하였으며 도로를 제외한 이면 도로의 주정차 또는 건물주차 등 도로 밖의 차량에 대해서는 평가에서 제외하였다.

4.2 차량 검출 결과 및 분석

학습된 모델에 의한 차량 검출 결과 영상은 Fig. 4와 같다. 4.1절에서 언급한대로 본 연구에서는 성능평가 대상으로 도로상의 주행 중인 차량에 대해서만 한정하고, 도로 밖 주정차 되어 있는 차량에 대해서는 성능평가 대상에서 제외하였다.

실험결과 영상 분석결과, 도로상의 차량은 대부분 정확히 탐지를 하지만, 일부 도로 색과 유사한 승용차에 대해서는 검출 자체를 못하는 경우가 발생하였다. Fig. 5는 오분류된 결과의 예시이다. 또 다른 오분류의 예로 YOLOv3의 다중 라벨 분류기 특성으로 인해 하나의 차량을 두 가지 종류로 동시에 탐지하는 경우가 발생하였다. 이는 Fig. 5(b)의 오른쪽 위치 화살표에서 확인할 수 있으며, 소형 트럭을 트럭과 승용차로 동시에 인식하는 경우이다. Fig. 5(b)의 왼쪽 위치 화살표와 Fig. 5(c)와 같이 운전석과 적재함의 경계가 모호한 다수의 소형 트럭이 승용차로 분류되는 경우도 발생하였다. 특이한 사항으로 Fig. 5(d) 영상의 경우, 위쪽 도로 주변의 가건물의 경우 바로 옆에 주차되어 있는 차량과 함께 트럭으로 오분류 되는 경우가 발생했다. 영상의 해당 객체를 보면 마치 대형 트레일러트럭처럼 보인다. 비록 본 연구의 성능 평가 대상에서 제외된 영역이기는 하지만, 추후 불법 주정차 단속 등으

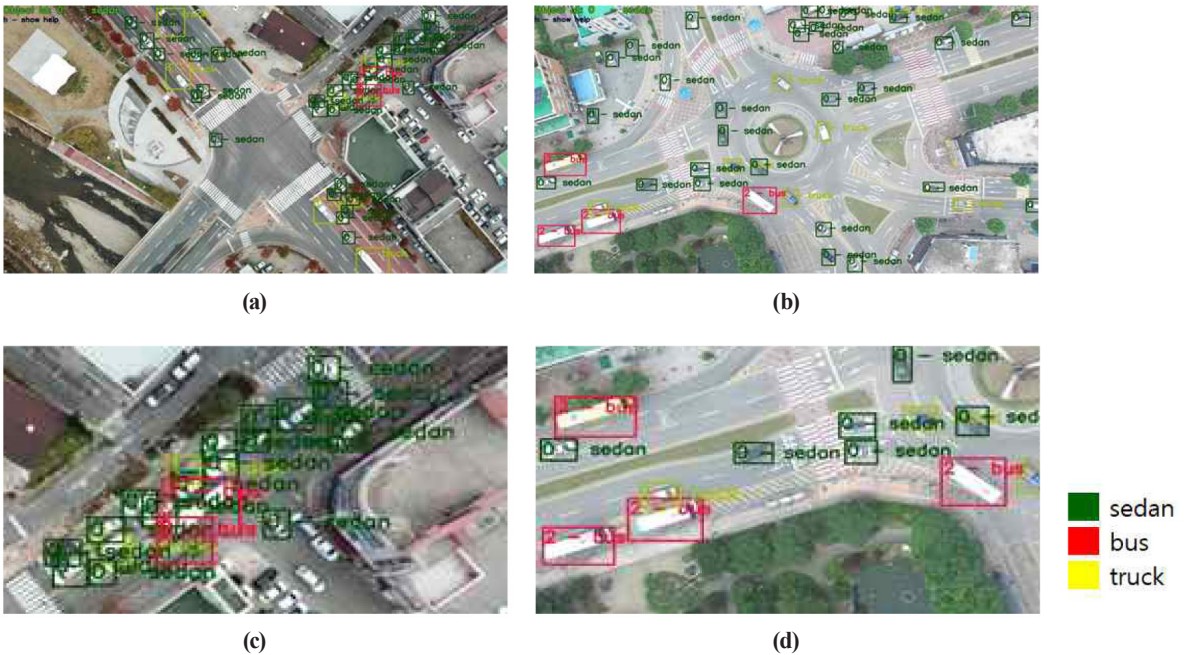


Fig. 3. Ground truth for experiments: (a) ground truth of training dataset, (b) ground truth of test dataset, (c) detailed image of (a), (d) detailed image of (b)



Fig. 4. Results of experiment: (a) and (b) Vehicle detection results, (c) and (d) detailed images of vehicle detection result

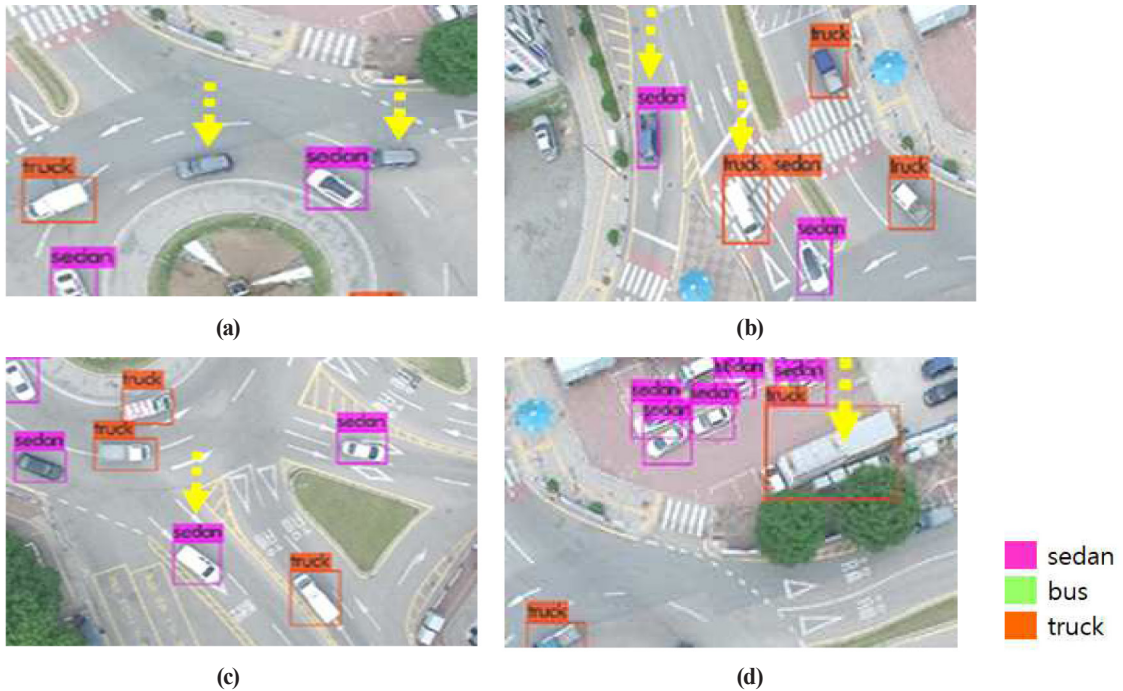


Fig. 5. Example of wrong detection: (a) undetected sedan (b) wrong detection and multi-label, (c) wrong detection (d) wrong detection of two object

로 응용 영역을 확대할 경우를 고려하면 시스템 설계 시 고려해야 할 사항이다.

YOLOv3 알고리즘에 적용한 실험결과에 대해 승용차, 트럭, 버스에 대한 탐지결과를 분석하고 정확도평가를 수행하였다. 탐지결과는 활용된 동영상을 1초당 20프레임으로 분할하여 정지 영상을 제작하고, 이중 차량 통행이 거의 없거나 중복되는 차량으로 구성된 영상을 제외하고 차량이 활발히 통행하는 총 111장의 정지영상을 추출하여 산출하였다. 탐지결과에 대한 오차행렬은 Table 2와 같다.

Table 2. Confusion Matrix

Classes	Sedan	Truck	Bus
Sedan	1,991	11	0
Truck	126	398	0
Bus	0	8	424

Table 2의 행은 테스트 데이터에 대한 ground truth를 의미하며, 열은 모델에 의해 예측된 분류 클래스를 의미한다. 탐지결과, 전체 객체는 3,279개이고, 이중 승용차, 트럭, 버스가 각각 2,287개, 578개, 432개인 것으로 나타났다. 이를 통해, 트럭을 승용차로 오인식 하는 경우가 특히 많이 발생하는 것을 알 수 있었다. 소형 트럭 중 운전석과 적재함 사이의 경계가 모호한 일부 영상에 대해서 오인식이 발생하는 것으로 분석되었으며, 소형 트럭을 승용차로 오분류 하는 문제를 해결하기 위해서는 더 많은 학습 데이터를 수집하여 문제를 해결할 수 있을 것으로 판단된다. 승용차의 경우 전체 2,287개 객체 중, 시스템에 의해 오분류 포함 검출된 객체의 수는 2,002개(87.54%)인 것으로 나타났다. 트럭의 경우는 578개의 객체 중 524개(90.66%)의 객체를 검출하였으며, 버스의 경우는 432개의 객체 전체를 정확히 검출하였다. 결과적으로, 총 3,279개의 차량 객체 중 2,958개(90.21%)의 객체를 탐지하였다. 탐지결과에 대해 정확도 평가를 수행하였다. 정확도 평가는 정확도(Precision)와 재현율(Recall)을 각 클래스별로 수행하였

다.(Lee *et al.*, 2015). 정확도는 시스템에 의해 탐지된 객체 중 정확하게 인식된 객체의 비율로 Eq. 4와 같이 정의된다.

$$Precision = \frac{Detected}{Detected + Mis - detected} \quad (4)$$

재현율은 전체 객체 중에서 시스템에 의해 정확하게 인식된 객체의 비율로 Eq. 5와 같다.

$$Recall = \frac{Detected}{No. of Objects} \quad (5)$$

정확도 평가 결과는 Table 3과 같다. 정확도 평가 결과, 전체 차량 객체에 대한 정확도와 재현율은 각각 95.10%와 85.79%이며, 클래스별로는 버스의 경우 정확도 100%와 재현율 98.15%로 계산되어 높은 정확도를 보였다. 트럭의 경우는 정확도 95.44%와 재현율 68.86%로 다른 차량 종류에 비해서 상대적으로 낮은 정확도를 보였다. 이는 트럭의 학습량이 다른 클래스에 비해 적고, 앞서 Fig. 5에서 언급한 것과 같이 영상에서 운전석과 적재함의 경계가 모호한 다수의 소형 트럭이 승용차로 분류된 것에서 야기한 결과로 분석된다.

5. 결론

최근 급격한 도시화로 인해 다양한 교통문제들이 발생하고 있으며, 이를 해결하기 위한 신속·정확한 교통량 예측 및 분석 방법에 대한 요구가 늘어나고 있다. ICT 기술의 발전과 더불어 최적의 교통관리를 수행하기 위한 ITS의 도입이 증가하고 있으며, 다양한 기법을 통해 신속·정확한 교통량을 분석하기 위한 연구들이 수행되어지고 있다. 본 연구에서는 기존의 CCTV 보다 자료취득이 용이하고 고화질 영상 취득이 가능한 UAV 영상을 활용한 딥러닝 기반의 교통량 분석 방법을 제안하였다. 본 연구에서 제안한 방법론을 검증하기 위하여 교차로에서 UAV를 통해 정사 동영상을 취득하였으며 딥러

Table 3. Experimental results

Classes	No. of Object	Detected	Mis-detected	Precision	Recall
Sedan	2,287	1,991	126	94.05%	87.06%
Truck	578	398	19	95.44%	68.86%
Bus	432	424	0	100%	98.15%
Total	3,279	2,813	145	95.10%	85.79%

닝 기반의 객체탐지 기법인 YOLOv3를 기반으로 실시간 차량 탐지를 수행하였다. 또한, 교통량 분석의 대상이 되는 도로상의 주행 차량에 대한 객체 탐지 성능평가를 수행하였으며, 드론을 이용한 영상으로부터 차량 탐지를 통한 실시간 교통량 분석이 가능함을 확인하였다. 차량 자체에 대한 검출은 90.21%의 결과를 얻었으며, 전체 차량에 대한 차량 정확도 평가 결과 95.15%의 정확도와 85.79%의 재현율을 보였다. 본 연구를 통해 딥러닝 객체 탐지 알고리즘을 이용하여 UAV 영상에서의 차량 탐지를 통해 실시간 교통량 분석의 가능성을 확인하였다. 추후 연구로는 차량 자체에 대한 검출율과 정확도 및 재현율을 높이기 위한 딥러닝 기반의 객체 탐지 알고리즘의 성능 고도화를 진행하고, 추가적으로 객체 추적 알고리즘을 적용하여 단순한 통행량 분석뿐만 아니라 측정 지역의 차량 이동 속도 등 종합적인 분석 방법에 대한 연구를 수행할 예정이다.

감사의 글

이 논문은 2020학년도 영산대학교 교내연구비의 지원에 의하여 이루어진 것임.

References

- Girshick, R., Donahue, J., Darrell, T., and Malik, J. (2014), Rich feature hierarchies for accurate object detection and semantic segmentation, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 23-28 June, Columbus, USA, pp. 580-587.
- Girshick, R. (2015), Fast R-CNN, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7-13 December, Santiago, Chile, pp. 1440-1448.
- Ha, D.M., Lee, J.M., and Kim, Y.D. (2001), A study on the image based traffic information extraction algorithm, *Journal of Korean of Transformation*, Vol. 19, No. 6, pp. 161-170.
- Hong, G.S., Eom, T.J., and Kim, B.G. (2011), Development of vision-based monitoring system technology for traffic analysis and surveillance, *Journal of Information and Security*, Vol. 11, No. 4, pp. 59-66. (in Korean with English abstract)
- Jo, S.H., Kim, C.G., Lim, H.Y., and Shin, Y.T. (2018), A study on the traffic flow analysis method based on change detection for traffic video data, *Journal of Information Technology and Architecture*, Vol. 15, No. 13, pp. 373-382. (in Korean with English abstract)
- Ke, R., Li, Z., Kim, S., Ash, J., Cui, Z., and Wang, Y. (2016), Real-time bidirectional traffic flow parameter estimation from aerial videos, *IEEE Transaction of Intelligent Transportation System*, Vol. 18, No. 4, pp. 890-901.
- Lee, D.H. and Park, Y.T. (2004), Robust traffic monitoring system by spatio-temporal image analysis, *Communications of the Korea Information Science Society*, Vol. 31, No. 11, pp. 1534-1542. (in Korean with English abstract)
- Lee, H.S., Moon, D.S., Kim, I.K., Jung, H.S., and Park, D.H. (2015), Anomaly intrusion detection based on hyper-ellipsoid in the kernel feature space, *KSIIT Transactions on Internet and Information Systems*, Vol. 9, No. 3, pp. 1173-1192.
- Lee, K.Y. and Jang, M.S. (2005), Development of vision-based vehicle tracking for extracting microscopic traffic information, *Journal of Korean of Transformation*, Vol. 23, No. 7, pp. 137-148. (in Korean with English abstract)
- Nizar, T.N., Anbarsanti, N., and Prihatmanto, A.S. (2014), Multi-object tracking and detection system based on feature detection of the intelligent transportation system, *2014 IEEE 4th International Conference of System Engineering and Technology (ICSET)*, 24-25 November, Bandung, Indonesia, pp. 1-6.
- Peppas, M.V., Bell, D., Komar, T., and Xiao, W. (2018), Urban traffic flow analysis based on deep learning car detection from CCTV image series, *The international Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*, Vol. XLII-4, pp. 499-506.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016) You only look once: unified, real-time object detection, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 26 June - 1 July, Las Vegas, USA, pp. 779-788.
- Ren, S., He, K., Girshick, R., and Sun, J. (2016) Faster R-CNN: towards real-time object detection with region proposal networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 39, No. 6, pp. 1137-1149.
- Seo, S.H. and Lee, S.B. (2018), A study on traffic data

collection and analysis for uninterrupted flow using Drones, *Journal of The Korean Institute of Intelligent Transportation Systems*, Vol. 17, No. 6, pp. 144-152. (in Korean with English abstract)

Seong, S.K., Song, J.H., Yoon D.H., Kim J.Y., and Choi, J.W. (2019), Determination of vehicle trajectory through optimization of vehicle bounding boxes using a convolution neural network, *Sensors*, Vol. 19, No. 19, pp. 4263-4281.

Zhao, Z.Q., Zheng, P., Xu, S.T., and Wu, X. (2019), Object detection with deep learning: a review, *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 30, No. 11, pp. 3212-3232.