

드론영상과 인공지능 기반 교통량 추정을 위한 데이터 구축 가이드라인 도출 연구

Guidelines for Data Construction when Estimating Traffic Volume based on Artificial Intelligence using Drone Images

한동권¹⁾ · 김두표²⁾ · 김성보³⁾

Han Dongkwon · Kim Doopyo · Kim Sungbo

Abstract

Recently, many studies have been conducted to analyze traffic or object recognition that classifies vehicles through artificial intelligence-based prediction models using CCTV (Closed Circuit TeleVision) or drone images. In order to develop an object recognition deep learning model for accurate traffic estimation, systematic data construction is required, and related standardized guidelines are insufficient. In this study, previous studies were analyzed to derive guidelines for establishing artificial intelligence-based training data for traffic estimation using drone images, and business reports or training data for artificial intelligence and quality management guidelines were referenced. The guidelines for data construction are divided into data acquisition, preprocessing, and validation, and guidelines for notice and evaluation index for each item are presented. The guidelines for data construction aims to provide assistance in the development of a robust and generalized artificial intelligence model in analyzing the estimation of road traffic based on drone image artificial intelligence.

Keywords : Drone Images, Artificial Intelligence, Object Recognition, Traffic, Deep Learning, Guidelines for Data Construction

초 록

최근 CCTV (Closed Circuit TeleVision)나 드론영상을 활용하여 인공지능 기반 예측 모델을 통해 차량을 분류하는 객체인식이나 교통량 분석을 하는 많은 연구들이 수행되고 있다. 정확한 교통량 추정을 위한 객체인식 딥러닝 모델을 개발하기 위해서는 체계적인 데이터 구축이 요구되는데 이와 관련된 표준화된 가이드라인은 미흡한 실정이다. 본 연구에서는 드론영상을 활용한 인공지능 기반 교통량 추정 학습데이터 구축 가이드라인 도출을 위하여 선행 연구를 분석하고 사업보고서나 기존 인공지능 학습용 데이터 구축 및 품질관리 가이드라인을 참고하였다. 데이터 구축 가이드라인은 크게 데이터 획득, 가공, 검증으로 분류되며, 항목 별 유의사항 및 평가지표 가이드라인을 제시하였다. 본 연구의 결과물인 데이터 구축 가이드라인은 드론 영상 인공지능 기반 도로교통량 추정 분석을 하는데 강건하고 일반화된 인공지능 모델 개발에 도움을 제공하고자 한다.

핵심어 : 드론영상, 인공지능, 객체인식, 교통량, 딥러닝, 데이터 구축 가이드라인

Received 2022. 02. 08, Revised 2022. 02. 18 Accepted 2022. 06. 21

1) Member, Dept. of Future Energy Engineering, Division of Environmental and Energy Engineering, Dong-A University (E-mail: dkhan@donga.ac.kr)

2) Member, Dept. of Civil Engineering, Dong-A University (E-mail: ksosdkgk@donga.ac.kr)

3) Corresponding Author, Member, Dept. of Drone & Spatial Information Engineering, Youngsan University (E-mail: tamsabo@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

지능형교통체계(ITS: Intelligent Transportation System)는 다양한 교통 상황 및 교통 관리 모드와 관련된 혁신적인 서비스를 제공하기 위해 전자제어 및 통신 등 첨단기술을 접목하여 사용자가 보다 나은 정보를 획득하거나 발전된 교통 네트워크를 통해 안정성을 향상시키는 것을 목적으로 하는 운영시스템이다. ITS 서비스는 크게 교통관리, 대중교통, 전자 지불, 교통정보 유통, 여행정보 제공, 지능형 차량도로, 화물운송 7개로 나뉘며 이 중 교통관리 부분에서 도로의 원활한 흐름을 파악 및 제어하기 위해 교통량 분석을 수행한다. 교통 모니터링에 대한 빅데이터 구축은 시내도로나 고속도로의 원활한 교통 흐름을 예측하거나 교통정책과 전략 등을 개발하는데 중요한 작업이다. 이중 교통량 측정은 도로에 매설하는 직접적인 측정방법인 루프검지기와 적외선 센서, 최근에는 CCTV (Closed Circuit Television)나 UAV (Unmanned Aerial Vehicle) 등에서 촬영된 영상데이터를 이용하는 방법이 있다(Coifman, 2006; Kenney, 2011; He *et al.*, 2020). 검지기를 통해 직접 측정하는 방식은 Time lag 현상 발생 문제, 돌발상황 감지, 차량 별 세부적인 주행의 형태를 획득하기 어려운 단점이 있다.

최근 디지털 영상 기술의 발전으로 인해 CCTV를 활용한 교통정보 수집이나 교통 모니터링을 위한 다양한 연구들이 수행되고 있다. Lee *et al.*(2018)은 CCTV 영상 데이터를 통해 차량 및 보행자를 검출하는 객체 인식 CNN (Convolutional Neural Networks) 알고리즘을 활용한 연구를 수행하였고, Seo and Kim(2020)은 단일 CCTV 영상의 차량 탐지 성능의 한계를 극복하기 위해 스테레오 CCTV 데이터를 이용하여 YOLO (You Only Look Once)v3 알고리즘을 이용하여 모델의 개선효과를 확인하였다. Jung and Jung (2020)은 루프 센서를 통한 교통량 수집방식의 오류를 해결하기 위해 도로에 열화상 카메라를 설치하여 영상이미지를 수집하고 이를 이용하여 만든 딥러닝 기반의 이미지 인식 CNN 알고리즘을 활용하였다. 개발 모델을 통해 1종과 3종 차량을 구분할 수 있는 새로운 시도를 적용하였다. 노후된 CCTV 카메라 해상도가 낮거나 원하는 촬영 각도와 방향을 자유자재로 변경하기 어려울 때는 신규 설치해야 하는데 교통분야 활용 시 추가적인 비용 부담이 따른다(Choi and Yoo, 2017; Han *et al.*, 2019; Kim *et al.*, 2018). 구체적으로 도로교통공학 관점에서 드론활용의 장점을 살펴보면, 교통관리 측면에서는 드론이 가변정보 표지판(VMS: Variable Message Sign)의 정보제공자가 되어 돌발상황 정보나 우회도로 안내 등 광범위한 지역의 차량 분

석을 통해 정보를 공급할 수 있고, 교통안전 측면에서는 사고 발생 지점의 차량 및 보행자의 행태를 분석할 수 있으며, 교통 계획 분야에서는 교통량, 속도, 기하구조 등을 획득 시 드론의 고도를 높여 촬영하여 광범위한 지역의 데이터 획득이 가능하고, 교통운영 측면에서는 상습 정체구간에서의 접근로별, 방향별 포화교통류율을 정확하게 산정이 가능하다. 마지막으로 교통모형 연구 분야에서는 드론이 설계자 관점에 의해 다양하게 측정된 도로의 기하구조, 방향별 교통량 등 시뮬레이션에 입력되는 자료의 획득에 용이하여 모든 부분에서 경제적, 시간적, 분석적으로 활용도가 높다. 그리하여 교통량 분석하고자 하는 지역과 측정하고자 하는 교통량 영상 인식 모델 계획에 따라 이동이 자유로운 드론을 이용하여 교통정보 영상을 수집하는 연구들이 수행되었다.

Seo and Lee (2018)는 다양한 교통정보 수집의 추출 및 분석의 타당성을 검증하였고 드론을 이용한 교통정보 수집 및 추출의 방법론을 제안하였다. 드론을 이용하여 객체를 인식할 때 자동으로 차량 탐지 및 분류하는 것은 교통량이나 차량속도를 측정하는데 있어 필수작업 중 하나로서 움직이는 물체를 정확하게 식별하여 추적하는 기법을 적용하였다. Hamid *et al.* (2018)은 영상의 이전 프레임 이동평균값과 칼만필터를 이용하여 차량을 추적한 결과보다 정확한 차량속도를 산출하였다. Park *et al.*(2020)은 딥러닝 이미지 인식 YOLOv3 알고리즘을 이용하여 실시간 교통량 분석이 가능함을 확인하였다.

교통량 분석을 위해 드론촬영 영상데이터를 이용하여 인공지능 기반 영상인식 기법 적용 시 우선적으로 학습 데이터 구축이 중요하다. 올바른 데이터 구축 개요에 따라 문제를 정의하고, 데이터 획득 및 정제, 가공, 분석을 수행하는 것이 영상 인식 모델의 정확도 향상 및 계획에 따른 적합한 교통량 추정을 수행할 수 있다. 2021년 2월 과학기술정보통신부 산하 기관인 한국지능정보화사회진흥원에서 4차 산업혁명 시대에 맞서 대규모 인공지능 학습용 데이터를 구축하고 오픈데이터로 개방하고 있다. 그리하여 '인공지능 학습용 데이터 품질관리 가이드라인'과 '인공지능 학습용 데이터셋 구축 안내서'를 2021년 2월에 처음 배포하였으며, 인공지능 모델을 구축하는 수행기관에서 연구 및 사업 초기에 수립해야 할 유형별 데이터 구축 및 품질관리에 대한 가이드라인을 제시하고 있다. 하지만 상기 안내서는 텍스트, 음성, 광학 문자 인식, 영상 이미지와 같은 포괄적인 범주에서 데이터 유형에 맞는 구축 계획을 설명하고 있다. 하지만 드론영상을 활용하여 교통량 분석 시 필요한 데이터 구축 가이드라인은 상세하게 나와 있지 않은 실정이다. 드론 영상을 이용하여 인공지능 기반의 교통량 추정 시 적합한 데이터 구축 가이드라인에 따라 학습데이터

를 생성해야 객체인식 모델의 정확성과 일반화 성능을 충족할 수 있다. 따라서 본 연구에서 데이터 구축 가이드라인을 도출하고자 한다. 도출 절차는 우선적으로 국내 인공지능 학습용 데이터 품질관리 가이드라인과 데이터 구축안내서, 드론영상 분석 관련 사업보고서를 참고하였고, 관련 선행연구를 분석하였다. 이를 통해 교통량 분석 인공지능 모델에서의 데이터 획득, 가공, 검증과 관련된 주요 요소들을 정리하여 각 과정별 고려사항과 평가지표를 제안하였다.

림자에 의해 정확한 영상 취득이 어려운 경우 90도 이하의 다양한 각도 촬영이 요구된다.

2. 드론영상과 인공지능 기반 교통량 추정 기술

2.1 영상촬영

교통량 정보를 수집하기 위해서는 교차로 및 도로상공에서의 드론에 장착된 카메라를 이용하여 영상 촬영이 필요하다. 과업지시서와 연구목적에 따라 영상촬영 계획을 수립하는 것이 우선적으로 요구된다. 다량의 도로정보와 객체의 식별 데이터를 확보하기 위해서는 100m 이상의 고고도 촬영이 요구되고, 검출하려는 객체가 오토바이나 자전거 등 이륜차가 추가될 경우나 단순 교통흐름이나 유량을 분석하고자 할 때에는 100m 미만의 저고도 촬영이 필요하다. 촬영 각도는 일반적으로 카메라와 직각인 90도가 일반적이나, 햇빛의 반사나 그

2.2 인공지능 기반 이미지 분석

교통량 분석 시 정지영상과 동영상에서 객체 검출을 통해 차량의 인식과 관련된 교통 데이터를 수집하는데 인공지능 기반 이미지 분석 기법이 중요하다. CNN은 대표적인 이미지로부터 위상 특성을 추출하여 분류기를 통해 추출된 특징들을 분류하는 알고리즘이다. CNN은 합성곱 연산을 통해 픽셀 정보의 지역적 특성을 모사하는 장점이 있지만 다수 객체인식 및 위치 검출에 한계가 있다. Girshick *et al.*(2014)이 제안한 R-CNN (Region-based Convolutional Neural Networks)은 딥러닝 알고리즘에 회귀문제를 적용하여 검출에 필요한 모듈과 후보 영역에서 도출한 특징 벡터를 추출하여 선형 SVM(Support Vector Machine)을 이용하여 객체를 분류하는 시스템이다. R-CNN은 CNN과 SVM을 분리하여 회귀학습을 수행하므로 연산시간이 많이 소요되는 단점이 존재한다. 이를 보완하기 위해 Fast R-CNN(Girshick, 2015), Faster R-CNN(Ren *et al.*, 2017)이 제안되었으며 Fast R-CNN은 Fig. 1에서 인식하고자 하는 이미지를 CNN에 통과시켜 Conv feature map을 추출하고, Roi projection 시킨 다음 Roi pooling을 진행하여 고정된 크기의 feature vector를 얻는다.




Fig. 1. System structure for Fast R-CNN algorithm




Fig. 2. System structure for YOLO algorithm(Redmon *et al.*, 2016)

feature vector는 FC layer를 통과하며 softmax 통과층은 객체인식을, bbox regressor에서는 경계박스의 위치를 조정한다. Fast R-CNN은 다양한 크기의 물체를 효과적으로 감지할 수 있는 것으로 입력 이미지를 하나의 후보 영역으로 인식하여 학습을 수행하므로 시간을 절약할 수 있다. 또 다른 객체 검출 방법인 YOLO(Redmon *et al.*, 2016)는 분류 대상의 객체를 경계박스(bounding box)를 다차원으로 분리하여 24개의 CNN layer와 2개의 FC layer를 R-CNN과 달리 한 번만 통과시키며, 이를 통한 클래스 확률을 하나의 회귀문제로 접근하여 빠르게 계산이 가능하다(Fig. 2). 후보 영역을 추출하기 위해 별도의 네트워크 적용이 필요하지 않다. R-CNN 계열의 알고리즘은 정확도는 YOLO보다 높고 처리시간은 약간 낮은 것으로 알려져 있으나 최근에 나온 YOLOv4나 YOLOv5는 속도와 정확도면에서 아주 높은 성능을 발휘하는 것으로 알려져 있다(kim *et al.*, 2020). ITS 시스템에서 교통량 정보제공을 위해서는 실시간 처리를 통한 빠른 객체 검출이 가능한 YOLO 알고리즘이 유리하다.

2.3 교통량 추정

드론영상 기반의 인공지능 모델을 이용하여 교통량을 추정하는 방법은 다음과 같다. 통행량은 교차로의 경우 네 방향의 출구 지점에 파란색 사각형모양 박스를 표시하여, 각 차량이 박스를 지나치는 지점을 검출하여 통행량을 계산한다(Fig. 3). 평균속도는 통행량 계산 시 속도를 계산하고 전체 차량의 통행량 나누기 전체 차량 속도의 합을 통해 산출한다. 교통량은 1시간 전 15분간 최고 통행량을 검출하여 교통량으로 표시한다.




Fig. 3. Estimation of traffic volume using object recognition model

2.4 드론영상 학습데이터

도로교통량 정보 수집을 위한 인공지능 학습용 데이터 구

축은 영상기반 분석을 통해 도로의 객체인 차량을 인지하기 위한 딥러닝 알고리즘 학습에 필수적인 과정이다. 효율적인 학습을 수행하기 위해서는 다양한 도로 환경 및 객체 정보에 대한 배경지식을 바탕으로 데이터 구축 프로세스에 따라 진행하여야 한다. 2021년 2월 한국지능정보사회진흥원은 인공지능 학습용 데이터 구축 사업 및 연구를 진행하는 기관에서 유형별 데이터 구축 가이드라인 작성을 돕기 위한 목적으로 '인공지능 학습용 데이터셋 구축 안내서'를 배포하고 있다. 데이터를 구축하기 전 목적을 명확히 정의하고 분석을 진행하는 것은 인공지능 기술 분야에 따라 적합한 이미지 데이터 획득을 통해 신뢰성 있는 모델을 구축할 수 있으므로 전체 공정 중 매우 중요한 작업이다. 일련의 구체적인 인공지능 모델의 학습 데이터 구축 유의사항과 특징을 안내서에 정리하고 있다.

3. 드론영상 데이터 구축 가이드라인 도출

드론영상과 인공지능 알고리즘을 이용하여 도로교통량 정보를 수집하기 위해서는 인공지능 모델 개발을 위한 적합한 학습용 데이터의 구축이 필수적이다. 아래의 절을 통해 데이터 구축 가이드라인 도출 절차 및 각 항목 별 상세한 설명을 기술하고, 최종적으로 데이터 구축 가이드라인을 도출하였다.

3.1 절차와 방법

본 연구는 드론영상과 인공지능 알고리즘을 이용하여 도로교통량 추정을 위한 학습데이터 구축 가이드라인을 도출하기 위해 절차는 Fig. 4와 같다. 첫째, 국내 인공지능 학습 데이터 구축 안내서, 품질관리 가이드라인에서 영상 객체인식 관련 인공지능 모델 데이터 구축 시 유의사항 항목과 평가지

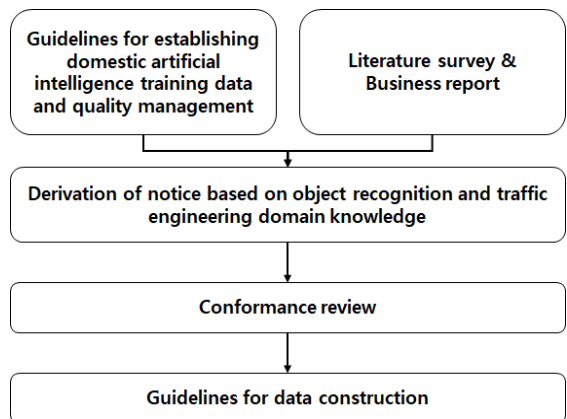


Fig. 4. Procedures for deriving guidelines for data construction

표를 도출한다. 둘째, 드론영상을 이용한 교통량 추정 사업보고서나, 선행연구를 통해 도출된 문제점이나 유의사항을 분석한다. 셋째, 앞서 분석한 가이드라인, 보고서, 선행연구에서 교통공학, 인공지능 객체인식 도메인지식의 유의사항을 분석한다. 넷째, 도출된 항목의 적합성을 고려하여 데이터 구축 가이드라인을 도출한다.

3.2 주요 내용

인공지능 모델을 이용하여 도메인지식의 문제를 해결하기 위해서는 일반적으로 데이터준비, 인공지능 모델링, 시뮬레이션과 테스트, 배포 및 유지보수 등 4가지 단계를 통해 모델 개발이 이루어진다. 하지만 정확성, 일반화가 겸비한 모델을 개발하기 위해서는 인공지능 모델의 고도화에 해당하는 모델링, 시뮬레이션, 테스트 과정에 집중하기보다 데이터 준비과정을 통해 데이터전처리나 양질의 학습데이터 획득과 같이 데이터 생성에 집중하는 편이 낫다. 교통량 추정을 위해서는 인공지능 기법 중 객체인식이 활용되며, 여기서는 데이터 준비과정에서 분석 목적에 적합한 데이터를 구축하는 것이 필요하다. 데이터 구축단계는 크게 데이터 획득, 데이터 가공, 데이터 검증, 3단계로 나뉜다.

3.2.1 데이터 획득

교통량 분석 시 활용되는 교통량 데이터는 1차적인 목적인 조사시간, 조사지점에 따라, 또는 차종과 도로유형 별 분류를 통해 교통상황을 확인할 수 있다. 2차적인 목적은 원활한 교통흐름, 도로통행 수요 추정, 교차로 분석 등 도로교통 수요관리 측면과 화물차량, 특수차량 등에 따른 도로 계획 설계 등 다양한 교통공학 분야에 활용이 가능하다. 특히 교통량 조사는 교통시설 평가지침에서 정의한 침두, 비침두시간으로 구분하여 통행배정에 사용하고 있다. 교통량 분석을 위한 인공지능 학습 데이터 획득 시 구조, 형태, 규모 별 주의해야 할 점은 다음과 같다. 드론을 이용하여 영상을 촬영 시 촬영각도 및 고도, 시간, 날씨 등 다양한 환경에서 데이터 수집이 요구된다. 딥러닝 알고리즘 학습 시 다양한 환경의 학습데이터를 반영하여 일반화 된 모델을 구축할 필요가 있다. 예를 들어 주간 시간과 맑은 날의 교통영상을 통해 학습한 모델의 경우 야간 시간, 흐림 또는 우천 시 교통량 정보를 인식하는데 정확도가 현저히 낮아지는 문제가 발생할 수 있다. 또한 교통량, 차량속도와 같은 정보를 분석하기 위해서는 유입량과 유출량의 차이가 있는 위치를 선정해야 하는데(Ke *et al.*, 2016), 이는 Fig. 5와 같이 영상의 각도 및 드론 촬영 위치에 따라 획득되는 이미지가 상이하므로 사전촬영이나 분석계획 수립을 통한 적절

한 촬영 위치선정이 필요하다.



Fig. 5. Orthographic image using drone at intersection

학습 데이터 정제에서 가장 중요한 것은 화질 측면에서 원하는 품질의 영상이 녹화가 되었는지 확인하는 절차가 우선적으로 요구된다. 이후 계획된 객체가 분포하는지 확인하는 과정을 통해 파일명명법에 의거하여 저장한다. 원시데이터의 정제 절차는 크게 2단계로 나뉘는데, 1단계에서는 원시데이터 획득 후 영상을 확인하는 것으로, 객체 존재 여부 및 계획된 장소에 따른 균일한 비율로 촬영이 되었는지 여부를 고려한다. 2단계는 가공데이터 가공 후 Fig. 6 (a),(b)와 같이 비식별화 도구를 이용하여 영상에 대한 개인정보(사람, 차량번호판)를 개인정보보호법에 의거하여 비식별화 처리한다.

획득 정제 기준은 데이터 획득 시 실제 계획한 촬영에 따라 객체가 인식이 될 수 있는 고도에 맞추어 영상을 촬영하고 데이터를 취득하게 된다. 인공지능 기반 영상인식 모델의 경우 동일한 장소에서 오전, 오후와 같은 다양한 시간대나 맑음, 흐림, 우천 등 영상 인식을 저해하지 않는 요소에서 다양한 상황의 학습 데이터를 확보하여 모델 강건성을 향상 시키도록 한다. 획득 정제 조직의 구성은 영상촬영 부분에서 고려할 점은 드론조종자격증을 소지한 엔지니어가 작업지시서에 따라 기계 작동 및 영상 촬영을 수행하고, 작업지시서에 계획된 데이터의 종류가 원천데이터와 동일인지 여부를 확인하는 작업을 이행한다. 데이터 가공 및 모델 개발 엔지니어의 경우 원천데

이터 영상시청을 통해 의도한 객체가 촬영되었는지 확인과 수집대상에 개인정보보호법 위반이나 허가받은 장소에서 촬영되었는지 문제여부를 검토한다. 드론 비행 영상 수집 장비는 흔들림 방지 gimbal이 포함된 카메라를 장착하여 수집하거나, 카메라가 포함된 드론을 이용하여 수집 목적에 따라 카메라 각도변경이 가능한 장비를 활용할 수 있다. IMU (Inertial Measurement Unit)나 GPS (Global Positioning System) 센서가 부착된 카메라를 이용할 경우 녹화 중 바람이나 비행환경 변화에 따라 고도가 바뀌는 경우가 있는데 이미지 스케일의 고정을 위해 IMU 센서가 드론이 기울어지거나 움직임을 감지하여 균형을 잡아준다. GPS의 경우 정확한 위치 정보를 획득할 수 있다.



(a) Face de-identification (b) License plate de-identification

Fig. 6. Example of De-identification

3.2.2 데이터 가공

앞서 데이터 획득 부분에서 취득한 원시 데이터로부터 학습 설계 및 어노테이션(annotation) 정책 및 데이터셋 구축 가이드라인에 따라 도로교통량 분석 영상인식 모델을 구축하기 위한 데이터 전처리를 수행한다. 그런 다음 체계화된 프로세스를 통해 높은 정확도의 데이터 가공 작업을 수행하여야

한다. 교통량 분석에서 인지해야하는 차종은 승용차(SUV나 VAN 포함)와 버스, 트럭(트럭은 트레일러나 덤프트럭, 상용차 등), 그리고 자전거나 오토바이와 같은 이륜차, 차량 이외의 보행자 등 분류 목적에 따라서 구체화할 수 있다. 데이터 어노테이션이란 데이터셋에 태그형식으로 인식해야하는 목적값에 따라 주석을 다는 형태로, 본 연구에서 트럭이나, 승용차, 버스 등이 예가 될 수 있다. 데이터 어노테이션 절차는 Fig. 7과 같이 1단계로 인공지능 학습 데이터셋 가공이 가능한 소프트웨어를 이용하여 자동 또는 수동으로 어노테이션 작업을 수행하고, 2단계로 생성된 어노테이션 결과에 보정 작업을 수행하여 학습 데이터의 정확성과 품질을 높인다. 이 작업은 오프라인에서 가공 전문가를 통한 보정뿐만 아니라 온라인이나 클라우드 기반 작업 환경에서 클라우드 소스를 통해 작업자를 모집하여 보정을 수행하는 경우도 있다. 이것은 협의된 주기의 개수나 데이터셋 구축 분량과 시간에 따라 구체화하여 분석할 필요가 있다. 2단계 어노테이션 과정에서 가장 중요한 점은 학습 데이터의 1단계 가공 공정에서 탐지하지 못했거나, 라벨링 및 태그 오류가 있는 객체들의 보정 작업을 수행하는 것이다.

어노테이션 도구는 딥러닝 학습 모델 구축 전 이미지의 해당 객체들에 대한 특정 값을 부여 해주는 것으로 기본적인 기능은 객체의 경계박스와 라벨링 작업을 수행하는 것이다. 어노테이션 도구는 아마존 AWS나 IBM Watson Studio 등 클라우드 상에서 작업을 수행하는 도구와 오픈소스 기반으로 개인이나 회사가 만든 GUI (Graphical User Interface) 기반의 사용자의 편리성을 위한 경계박스나 라벨링을 수동 또는 자동으로 해주는 기능들을 탑재하고 있다. Fig. 8은 CVAT (Computer Vision Annotation Tool)으로 컴퓨터 비전을 위한

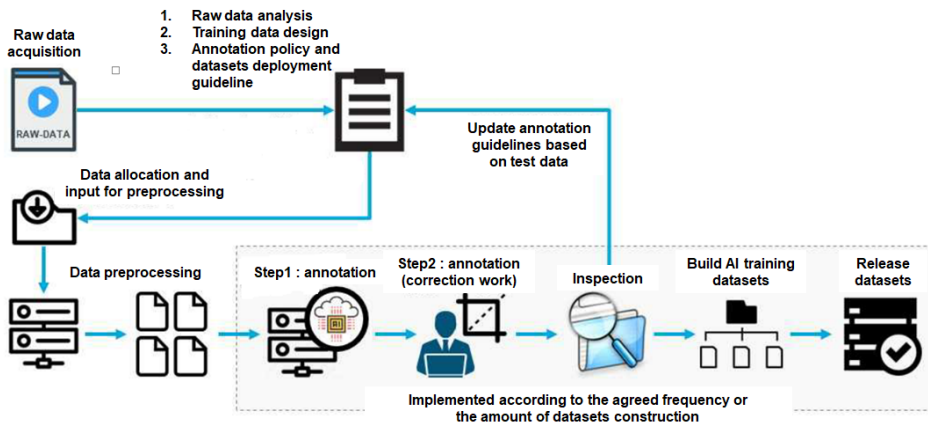


Fig. 7. Detailed procedure for data annotation

무료 이미지 어노테이션 도구로 기존의 라벨링 도구를 활용하거나, 사용자가 커스텀화 하여 모델링 목적에 맞는 데이터 가공이 가능하다.

구체적인 교통량 분석 이미지 라벨링 방식 기준은 다음과 같다. 경계박스는 대상 객체의 상하좌우를 맞추어 최대한 빈공간이 없이 어노테이션을 수행한다. 대상 객체를 확대하였을 때 해당 객체의 정확한 경계가 빛 번짐, 그림자로 인한 어두운 경우, 저화질로 인한 경계가 모호함, 경계 구분이 명확하지 않은 경우 등이 있으므로 1-2픽셀 정도 여유를 두어 경계박스를 구성하여도 무방하다. 경계박스는 보이는 부분만 구성하며, 일부가 가려진 경우에는 대략적인 객체를 추측하여 어노테이션 한다. 사람의 경우 차량 위에 있는 사람은 어노테이션 하지 않으며 오토바이나 자전거를 타고 가는 사람은 사람을 포함한 전체이미지를 경계박스로 인식한다. Fig. 9(a)는 승용차의 경계를 지나치게 크거나 작게 어노테이션 한 잘못된 예이며, Fig. 9(b)와 같이 차량의 경계에 맞게 경계박스나 폴리곤(polygon)을 이용하여 구분하는 작업이 필요하다. 또한 차량이 영상에서 겹칠 경우 객체에 대해 각각 어노테이션 하는 것이 원칙이며 Fig. 10과 같이 경계박스나 폴리곤 구분을 작업

한다. Fig. 11은 횡단보도나 가로등, 신호등 같은 도로구조물과 차량이 겹치는 상황으로, 어노테이션 작업 시 최대한 겹치지 않도록 고려하는 방법과 어노테이션 도구에 따라 구조물을 폴리곤이나 포인트 구분을 통해 제거하는 옵션을 통해 작업을 수행할 수 있다. 작업자에 의해 판단이 어려운 경우 계획된 어노테이션 정책을 고려하여 추가적인 검수작업을 수행할 필요가 있다.




Fig. 10. Annotations on vehicle overlapping phenomena




Fig. 11. Vehicle overlap between crosswalks and road structures

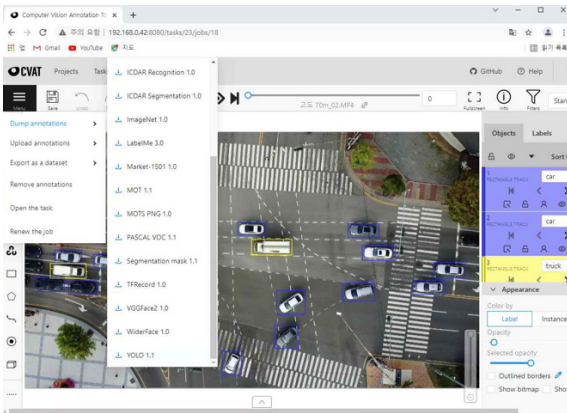



Fig. 8. Data annotation tool



(a) correct example (b) wrong example

Fig. 9. Bounding box example for data annotation

3.2.3 데이터 검증

객체인식 딥러닝 알고리즘을 학습하기 전 데이터 분석, 설계 수집, 정제 및 가공 단계 별 데이터 품질을 확인하기 위해 데이터 구축 작업 별 검수 프로세스를 적용한다. 데이터 분석은 대상 식별과 관련된 검수사항을, 데이터 설계는 품질관리 측면에서 규칙정의, 데이터 가공은 측정, 분석, 개선, 통제, 4단계의 검수 절차에 따라 데이터를 검증한다. 데이터 분석에서 검수할 사항은 업무별 품질관리 요구사항 확인과 품질관리의 범위 및 대상을 명시하고 문서화해놓으며, 데이터 설계 단계에서는 품질관리 대상에 대한 프로파일링 구현 및 품질측정 및 관리를 위한 참조 지표를 설정하는데 이는 '인공지능 학습용 데이터 품질관리 가이드라인'을 참조하여 검수한다. 어노테이션 가이드라인 및 예외처리 방안의 구체적인 예시로는 경계박스의 경우 어노테이션 영역이 대상 객체 상하좌우 모든 부분이 10 픽셀 안쪽, 바깥쪽으로 영역을 벗어날 때, 폴리

곤 구분은 사이드미러나 바퀴 형상을 포함하지 않는 등 자동차 형상에 필요한 어노테이션 범위를 포함하지 않는 경우 불량으로 판단한다.

데이터 품질 검증은 다양성, 정확성, 유효성 3가지가 있으며, 품질특성에 따라 검증 절차와 방법에 의거하여 수행한다. 첫째, 다양성은 획득된 영상 데이터 구축량과 과제 유형별 객체 분포가 있다. 예를 들어 버스, 승용차, 트럭과 같은 3가지 교통객체를 인식할 경우 각 객체의 분포가 균등해야 인공지능 모델의 정확성과 신뢰성을 확보할 수 있다. 또한 날씨나 시간대 등 다양한 환경에서 취득한 영상데이터를 학습자료로 활용해야 일반화된 모델을 생성할 수 있다. 둘째, 정확성에는 구문적, 의미적 정확성으로 두 가지 검증 지표가 있다. 구문적 정확성은 어노테이션 포맷이 완전한지 여부와 어노테이션 항목별 형식이 올바른지 여부에 대해 판단한다. 진단방법은 학습데이터에서 생성한 어노테이션 JSON 데이터를 대상으로 비정형 데이터 품질 진단 도구를 활용하여 진단을 수행한다. 그리고 어노테이션 포맷 완전성과 항목별 형식 정확도를 측정한다. 구문의 완전성과 정확성은 일반적으로 99% 이상을 목표로 설정하고 있다. 의미적 정확성은 가공 결과물에 대한 1차 검수 과정을 통해 이미지 내 태깅 오류에 대한 검사를 수행하는 것으로 가공엔지니어와 피드백을 통해 작업의 오류를 최소화하는 것을 목적으로 하고 정확성은 80% 이상을 목표로 한다. AQM (Annotation Quality Manager)의 2차 검수를 통해 1차 검수 단계에서의 미흡한 점을 보완하여 정확도를 향상시킨다. AQM은 오류를 유형화하여 작업자 및 데이터 엔지니어 가이드 생성 시 업데이트 자료로 활용한다. 이를 통해 데이터의 품질 확보 노하우를 획득한다. 셋째, 유효성에는 이미지 분류에서 실제 클래스와 일치 여부를 비교한다. 객체인식에서는 경계박스를 기준으로 객체의 위치를 찾으며, 이를 통해 실제 객체의 클래스와 일치하는 여부를 비교한다. IoU (Intersection over Union)는 두 경계박스 간 겹치는 면적을 평가하는 자카드지표 (Jaccard index)를 기반으로 하는 측정기법으로 Eq. (1)과 같으며, 객체의 실제 경계박스 (B_{gt})와 예측된 경계박스(B_p)의 교차영역 넓이($area(B_{gt} \cap B_p)$)를 합한 영역($area(B_{gt} \cup B_p)$)의 값으로 나눈 값을 뜻한다. IoU는 평가지표에 따라 일반적으로 50%, 75%, 95%로 설정한다. mAP (Mean Average Precision)라고 하는 이진 분류기의 성능 지표는 정밀도(Precision)와 재현율(Recall)을 이용하여 계산하는 지표인데, 정밀도는 머신러닝 모델이 참(True)이라고 분류한 것 중($TP + FP$) 실제 참(TP)인 것의 비율을 뜻하는 것으로 실제로 분류하고 싶은 지표를 얼마나 잘 분류하는지 확인하기 위해 사용하며 Eq. (2)과 같이 정의한다. 재현

율은 실제 정답이 참인 것 중($TP + FN$)에서 머신러닝 모델이 참(TP)이라고 예측한 비율을 말하며, Eq. (3)로 정의한다. 분류성능평가지표를 이해하기 위해서는 Fig. 12와 같이 실제 True, False에 대한 정답을 정확히 예측하였는지에 따라 TP (True Positive)는 실제 True인 정답을 True라고 예측한 정답, FP (False Positive) 실제 False인 정답을 True라고 예측한 오답, FN (False Negative)는 실제 True인 정답을 False라고 예측한 오답, TN (True Negative)는 실제 False인 정답을 False라고 예측한 정답으로 나뉘며, 이것을 통해 분류 모델의 성능을 평가한다. 여기서 mAP는 1개 객체 당 하나의 AP (Average Precision)값을 구하고 여러 객체 탐지결과에 대해 보간법 (Interpolation)을 이용하여 AP의 평균값을 구하는 것으로 여러 개 물체 검출 및 이미지 분류 알고리즘에 대한 성능을 1개의 값으로 표현한 것으로 기존 모델보다 85% 이상을 대체적으로 정량적인 목표로 설정한다.

$$IoU = \frac{area(B_{gt} \cap B_p)}{area(B_{gt} \cup B_p)} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} = \frac{TP}{All\ Positive\ Detections} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} = \frac{TP}{All\ Actual\ Results} \quad (3)$$

		Predicted class	
		Class = Yes	Class = No
Actual Class	Class = Yes	True Positive	False Negative
	Class = No	False Positive	True Negative

Fig. 12. Classification model performance evaluation index

3.4 활용 방안

드론영상 이미지를 통한 인공지능 학습용 데이터를 구축함에 있어 데이터 획득, 가공, 검증 단계에서 고려해야할 사항을 기존의 선행연구와 안내서를 통해 가이드라인 항목을 도출하였다. 수행하는 단계 별 고려사항과 평가지표는 Table 1과 같다. 이 연구에서 제시한 가이드라인을 통해 드론영상 기반 인공지능 모델을 이용하여 교통량추정 작업을 수행할 경우 예측 모델의 강건성 향상과 일반화 된 결과를 획득할 수 있다. 구체적인 가이드라인 단계에서 데이터 획득 부분에서는 영상촬영에 있어 추가적인 촬영일정에 따른 시간을 절약할 수 있다. 그리고, 데이터 가공에서는 어노테이션 오류들에 의한 교통량 인자의 부정확한 측정을 예방할 수 있다. 마

Table 1. Guidelines for data construction of AI-based traffic estimation

Data construction		Notice	Evaluation
Index	Criterion		
Data acquisition	Video recording	- Lens shot angle - Shot altitude - Day & Night - Weather	- Check the traffic volume analysis data considered in the work order
	Quality	- Check the image after acquiring raw data	- Check the traffic volume analysis data considered in the work order
	De-identification of personal information	- Person - License plate	- Personal information protection act
	Position coordinates	- IMU - GPS	- Check recording location information
Data preprocessing	Annotation	- Bounding box - Polygon	- Check the annotation policy considered in the work order
Data validation	Analysis	Target identification	- Check the quality control requirements for each task - Specify and document the scope and targets of quality control
	Design	Rule definition	- Implementation of profiling for quality control targets - Set reference indicators for quality measurement and control
	pre processing	Diversity	Data homogeneity
		Accuracy	- Syntactic(Performance index:99%) - Semantic((Performance index:80%)
Effectiveness		- IoU(Performance index:50%,75%,95%) - mAP(Performance index:85%)	

지막으로, 데이터 검증에서는 데이터 품질을 유지하고 개선하는데 보다 체계적인 과정을 통해 과업지시서 상 목표를 초과 달성할 수 있다.

4. 요약 및 결론

드론영상 이미지를 학습자료로 하여 인공지능 기반 교통량 추정하는 예측모델을 개발하기 위해서는 객체인식, 테라벨링, 인공지능, 교통공학적 도메인지식을 고려한 학습데이터 구축이 필요한데 우리나라는 이와 관련된 표준화된 절차나 가이드라인이 미흡한 실정이다. 본 연구는 국내 인공지능 학습용 데이터 구축 안내서 및 품질관리 가이드라인과 드론교통량 측정 사업보고서, 선행연구 분석을 통해 학습 데이터 구축 단계별 유의사항을 도출하였으며, 교통량 추정 시 데

이터 구축 절차에 따른 주요 요소별 가이드라인과 평가지표를 도출하였다. 데이터 구축 가이드라인은 데이터 획득, 가공, 검증으로 구성되었으며 각 단계 별 유의사항 항목과 평가지표를 통해 인공지능 기반 교통량 분석 시 체계적인 데이터 구축과 견고하고 일반화된 인공지능 모델을 개발할 수 있다. 이를 통해 모델 개발 및 데이터구축 시 발생하는 시행착오나 분석 시간을 감소시킬 수 있어 엔지니어에게 도움이 될 것으로 기대된다. 향후, 본 연구에서 도출한 데이터 구축 가이드라인을 바탕으로 실제 도로에서의 드론영상 자료를 취득하고 인공지능 기반 교통량 분석을 수행하고자 한다. 본 연구는 2022년 1월 기준으로 수집된 방법론과 데이터 구축 프로세스에 관한 지침서를 참고한 것으로, 빠르게 발전하는 ITS 기술 및 객체인식, 데이터 가공 기술 변화에 따른 지속적인 가이드라인 수정이 필요하다.

References

- Coifman, B. (2006), Vehicle level evaluation of loop detectors and the remote traffic microwave sensor, *Journal of Transportation Engineering*, Vol. 132, pp. 213–226. [https://doi.org/10.1061/\(ASCE\)0733-947X\(2006\)132:3\(213\)](https://doi.org/10.1061/(ASCE)0733-947X(2006)132:3(213)).
- Choi, I.K. and Yoo, J.S. (2017), Object detection in road environment CCTV images using deep learning. *The Institute of Electronics and Information Engineers*, 24-25 November, Incheon, Korea, pp. 627-629.
- 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. <https://doi.org/10.48550/arXiv.1311.2524>.
- Girshick, R. (2015), Fast R-CNN, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7-13 December, Santiago, Chile, pp. 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>.
- Hamid, K.R., Talukder, A., and Islam, A.E. (2018), Implementation of fuzzy aided kalman filter for tracking a moving object in two-dimensional space, *International Journal of Fuzzy Logic Intelligent Systems*, Vol. 18, No. 2, pp. 85–96. <https://doi.org/10.5391/IJFIS.2018.18.2.85>.
- Han, S.H., Shin, Y.S., and Lee, J.Y. (2019), A study on the evaluation technique of intelligent security technology based on spatial information : multi-CCTV collaboration technology, *The Journal of the Korea Academia-Industrial cooperation Society*, Vol. 20, No. 7, pp. 111–118. (in Korean with English abstract) <https://doi.org/10.5762/KAIS.2019.20.7.111>.
- He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2020), Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 42, pp. 386–397. <https://doi.org/10.48550/arXiv.1703.06870>.
- Jung, Y.S. and Jung, D.Y. (2018), Class 1-3 vehicle classification using deep learning and thermal image, *Journal of The Korean Institute of Intelligent Transportation Systems*, Vol. 19, No. 6, pp. 96-106. (in Korean with English abstract) <https://doi.org/10.12815/kits.2020.19.6.96>.
- Kenney, J.B. (2011), Dedicated short-range communications (DSRC) standards in the United States, *Proceeding of the IEEE*, Vol. 99, No. 7, pp. 1162–1182. <https://doi.org/10.1109/JPROC.2011.2132790>.
- 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. <https://doi.org/10.1109/TITS.2016.2595526>.
- Kim, J., Sung, J., and Park, S. (2020). Comparison of Faster-RCNN, YOLO, and SSD for Real-Time Vehicle Type Recognition. *IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia)*, pp. 1-4. <https://doi.org/10.1109/ICCE-Asia49877.2020.9277040>.
- Kim, Y.M., Lee, J.Y., Yoon, I.L., Han, T.J., and Kim, C.Y. (2018), CCTV object detection with background subtraction and convolutional neural network. *The Korean Institute of Information Scientists and Engineers*, Vol. 24, No. 3, pp. 151–156. (in Korean with English abstract) <https://doi.org/10.5626/KTCP.2018.24.3.151>.
- Lee, T.H., Kim, K.J., Yun, K.S., Kim, K.J., and Choi, D.H. (2020), A method of counting vehicle and pedestrian using deep learning based on CCTV, *Journal of Korean Institute of Intelligent Systems*, Vol. 28, No. 3, pp. 219-224. (in Korean with English abstract) <https://doi.org/10.5391/JKIIS.2018.28.3.219>.
- Park, H.L., Byun, S.H., and Lee, H.S. (2020), Application of deep learning method for real-time traffic analysis using UAV. *Journal of Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 4, pp. 353–361. (in Korean with English abstract) <https://doi.org/10.7848/ksgpc.2020.38.4.353>.
- 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. <https://doi.org/10.48550/arXiv.1506.02640>.
- Ren, S., He, K., Girshick, R., and Sun, J.(2015), 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.

<https://doi.org/10.48550/arXiv.1506.01497>.

Seo, H.D. and Kim E.M. (2020), Estimation of traffic volume using deep learning in stereo CCTV image. *Journal of Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 38, No. 3, pp. 269–279. (in Korean with English abstract)

<https://doi.org/10.7848/ksgpc.2020.38.3.269>.

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)

<https://doi.org/10.12815/kits.2018.17.6.144>.