

## 딥러닝 영상인식 기반의 도로교통량 자동 수집 모델

# Automatic Road Traffic Collection Model based on Deep Learning Image Recognition

정도영<sup>1</sup>

Do-Young Jung<sup>1</sup>

요 약

교통량 조사는 도로상을 주행하고 있는 차량의 종류(차종)에 관한 정보는 첨단교통관리시스템(ATMS) 및 각종 교통 분야에서 다인승 전용차로의 단속체계, 중차량 구성비, 도로용량 분석, 신호제어, 도로 설계 및 유지관리 등의 각종 교통 분석 및 지표로 활용될 수 있는 기초 정보이며 이 정보에 오류가 있을 경우 이를 바탕으로 한 각종 시스템 및 정책이 잘못된 결과를 산출하게 된다. 현재 인력 중심으로 진행되는 조사방식을 자동화할 필요가 있으며, 본 연구에서는 영상장비를 활용한 교통량 검지모형을 개발하였으며, 승용차, 버스(소형, 대형), 화물(소형, 중형, 대형) 총 6종에 대한 분류가 가능하도록 하였다. 총 20만 장 이상의 차종별 차량 이미지를 레이블링하여, 차종별·시간대별 교통량 정보를 자동으로 생성할 수 있도록 하였다. 정확도는 주간 95% 이상의 교통량 검지 정확도를 목표로 하였다. Human Counting 결과를 정답지로 해석하였으며, 비교 결과 95%이상의 정확도를 나타내어 교통량 조사의 자동화가 가능하다고 판단된다. 비록 본 연구에서 개발된 모델과 Human Counting 방식 중 어느 것이 정확한지는 판단할 수 없지만, 개발된 모델을 적용할 시 국가 교통량 조사에 소요되는 인력 및 비용을 크게 감소시킬 수 있을 것이며, 조사지점을 다양화 할 수 있다.

핵심어 : 도로교통량, 국도, 딥러닝, 영상인식

### Abstract

In the traffic volume survey, information on the types of vehicles traveling on the road is provided by the advanced traffic management system and multi-seater lane enforcement system, heavy vehicle composition ratio, road capacity analysis, signal control, road design and maintenance, etc. It is basic information that can be used as various traffic analysis. If there is an error in this information, various systems and policies based on it will produce incorrect results. There is a need to automate the research method that is currently being conducted mainly by manpower. In this study, a traffic volume detection model using video equipment was developed, allowing classification of a total of six types of passenger cars, buses (small, large), and cargo (small, medium, large). By labeling more than 200,000 vehicle images by vehicle type, traffic volume information can be automatically generated. Accuracy was aimed at more than 95% weekly traffic detection accuracy. The results of Human Counting were interpreted as correct answers, and the comparison results showed an accuracy of more than 95%, so it is judged that it is possible to automate the traffic volume survey. Although it is not possible to determine which of the

<sup>1</sup> Department of Highway and Transportation Research, KICT, Gyeonggi-do, Korea [Research Specialist/PH.D.]  
e-mail: jdy@kict.re.kr

Received(August 30, 2022), Review Result(1st: September 24, 2022), Accepted(October 14, 2022), Published(October 31, 2022)



© 2022 The Authors. Published by NCIS.  
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.  
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

model developed in this study and the human counting method is accurate, applying the developed model will greatly reduce the manpower and cost required for national traffic volume surveys, and diversify the survey points.

Keyword : Road Traffic, Highway, Deep Learning, Image Recognition

## 1. 서론

현재 다양한 교통정보 서비스와 소통수준 제고를 목표로 국내 여러 도시에서 첨단교통관리시스템(ATMS)이 운영 또는 구축 중에 있으며, 도로상의 교통정보를 보다 정확히 수집하기 위해 다양한 종류의 차량검지 시스템이 도입되고 있다. 특히 도로상을 주행하고 있는 차량의 종류(차종)에 관한 정보는 첨단교통관리시스템(ATMS) 및 각종 교통 분야에서 다인승 전용차로의 단속체계, 중차량 구성비, 도로용량 분석, 신호제어, 도로 설계 및 유지관리 등의 각종 교통 분석 및 지표로 활용될 수 있는 기초 정보이며 이 정보에 오류가 있을 경우 이를 바탕으로 한 각종 시스템 및 정책이 잘못된 결과를 산출하게 된다. 따라서, 차종에 관한 정보의 신뢰도를 확보하는 것이 매우 중요하다 [1].

교통관리시스템에 설치되는 차량 검지기는 정보수집방식에 따라 지점검지 방식과 공간검지 방식이 있으며 지점검지방식의 장비는 검지센서 종류, 검지원리, 매설여부 등에 따라 구분할 수 있다. 또한 비컨, 차량 영상인식장치 등을 이용한 통행시간을 기반으로 정보를 얻는 AVI(Automatic Vehicle Identification)로 통칭되는 구간검지 방식에는 GPS(Global Positioning System), PVD(Probe Vehicle Data) 등이 존재한다.

교통흐름과 관련된 교통정보 수집에 있어서는 지점식 차량검지기가 주로 사용되며 지하에 매설하는 루프 검지기, 누름식 검지기과 같은 매립형 검지센서를 주로 사용하고 있다. 그러나, 이러한 센서로부터 획득한 신호의 대부분은 직접 사용할 수 없고 하드웨어적인 장치를 이용하여 사람이 바로 인지할 수 있는 데이터 형태로 변환하는 과정이 반드시 수반되어야 한다. 이와는 대조적으로, 영상 처리 시스템에서는 폐쇄회로텔레비전(CCTV) 시스템을 통해서 수집된 데이터를 분석하는데 컴퓨터 비전(Computer Vision) 기술을 사용한다. 센서를 이용하는 다른 시스템과 비교했을 때, 영상 기반 시스템은 한 대의 카메라와 프로세서로 여러 차로를 처리하는 것이 가능하며, 차량의 종류에 관한 정보를 얻을 수 있다는 장점이 존재한다.

하지만 이러한 장점에도 불구하고 폐쇄회로텔레비전(CCTV)를 활용한 교통 데이터를 구축하여 연구에 활용하기에는 여러 어려움이 있다. 먼저, 대량의 차종별 정보가 필요한데 이를 제공하는 차량 이미지가 확보되어야 한다. 그리고 대량의 차종별 차량 이미지를 확보한 후에도 개별 이미지에 대한 데이터 라벨링이 선행되어야 한다. 본 연구에서는 총 20만 장 이상의 차종별 차량 이미지를 확보하였으며, 개별 이미지에 대한 데이터 라벨링을 진행하였다. 확보한 데이터를 AI 영상인식 기

술인 Grid Counting Model을 적용하여 차종별·시간대별 교통량 정보를 자동으로 생성할 수 있도록 하였다.

주간 6종, 야간 1종에 대한 교통량 검지를 목표로 한다. 이때 정확도는 주간 95% 이상의 교통량 검지 정확도를 목표로 하였다. 차종은 6종 구분을 원칙으로 하며, 6종은 승용차, 버스(소형, 대형), 화물(소형, 중형, 대형)로 구성되어 있다. 다만, 야간은 영상 데이터의 조도가 낮은 관계로 1종 구분을 목표로 모델을 개발하였다.

## 2. 관련연구

### 2.1 영상정보 기반의 교통량 검지

영국의 TULIP(Traffic Analysis Using a Low-cost Image Processing) 시스템에서는 그레이 수준 비교를 통한 차량 검출에 관한 연구를 수행하였다. 그리고 WADS(Wide-Area Detection System), 영국의 TRIP(Traffic Research using Image Processing) 그룹, CATS(Computer-Aided Traffic Sensor) 등의 연구에서는 배경 빼기를 이용하여 차량을 검출하고자 하였다 [2].

이처럼 영상 기반의 차량 검출은 교통량 검지의 기본 요소로서, 서로 다른 다양한 접근 방법으로 구현되어왔다. 영상 기반 차량 검출을 위한 접근 방법에는 그레이 수준 비교(Gray-level coparison), 프레임간 빼기(Inter frame subtraction), 배경 빼기(Background subtraction) 등이 있다 [3].

특히, 단일 카메라의 영상 정보를 사용하는 교통량 검지 시스템은 사회 안전망, 유동인구, 재난 방지 대책 등에서도 쓰일 수 있는 핵심기술로 주목받고 있다 [4]. 이러한 교통량 검지 시스템은 객체가 특정 영역(e.g. ROI)을 통과할 때 카운팅되는 방식이다. 따라서 각 개인을 감지하고 추적하여 특정 영역을 통과하는 인구 수를 카운팅하는 유동인구 분석에도 광범위하게 적용되어 왔다 [5]. 최근에는 영상 기반의 차량 검지 문제로 확대되어 차량을 추적하고 재식별하는 것이 새로운 도전으로 대두되고 있다.

최근 연구에서는 다양한 교통 환경에서 정보를 얻기 위해 객체를 감지, 추적, 궤도 처리 등 세 가지 구성 요소를 포함하는 차량 카운팅 프레임워크를 제안했다 [6]. 다중 객체 이동을 카운팅하는 방법으로 가상 루프 및 감지 라인을 그리는 것을 채택했다 [7]. 그러나 12종과 같은 다양한 차량의 종류에 대한 감지 및 추적과 서로 다른 영상 환경에서 객체 카운팅 방법은 여전히 미해결된 연구 주제이다.

### 2.2 객체 인식 및 추적 방법론

최근에는 진보된 객체 인식 및 추적 알고리즘을 통해 얼굴 인식, 자율주행차, 비상 경보시스템

등 다양한 산업 분야에서 이러한 영상 인식 기술이 활용되고 있다. 객체 인식 분야에서는 CNN(Convolutional Neural Network) 기반 방법론을 주로 사용하고 있다 [8]. 딥러닝을 활용한 객체 인식은 크게 Two-stage와 Single-stage로 분류할 수 있다.

먼저, Two-stage 방법론에는 R-CNN 계열 모델들이 속한다. Two-stage라고 명명된 이유는 이미지 하나에서 여러 후보 영역을 뽑아내는 Region Proposal 단계와 이 후보들을 사용한 Detector의 학습 단계로 구분되기 때문이다. 이들은 Fast R-CNN, R-FCN 그리고 Mask R-CNN으로 발전되었고, 알고리즘의 비효율적인 병목 현상을 개선해 나가며 점점 빠르고 정확해졌다.

반면, Single-stage 방법론은 객체 인식 문제에서 객체의 위치를 찾는 Localization 문제와, 객체를 식별하는 Classification 문제를 동시에 행하는 방법이다. 대표적으로 YOLO(You Only Look Once) 계열과 SSD 계열 등이 포함된다. 따라서 Single-stage가 비교적 빠르지만 정확도가 낮고, Two-stage가 비교적 느리지만 정확도가 높다는 특성을 지니고 있다.

객체 추적 알고리즘과 관련해서 SORT는 다중 객체 추적(MOT) 벤치마크에서 최고의 오픈소스로 선정된 대표적인 알고리즘이다. 칼만필터와 헝가리안 알고리즘으로 이루어져 있으며, 최근에는 탐지된 객체를 추적하기 위해 딥러닝 피쳐(Re-Id)를 추가로 반영하는 DeepSort가 유망한 접근법으로 부상하고 있다.

### 2.3 객체 카운팅 방법론

이동 차량에 대한 카운팅 방법론은 밀도를 활용한 방법과 감지된 객체를 특정 궤적에서 인식하는 방법으로 분류할 수 있다. 밀도를 활용한 방법론은 이동 차량에 대한 카운팅 결과를 근사화하기 위해 객체의 특징을 학습한다. 그러나 이러한 방법론은 객체의 정확한 개수를 카운팅하기 보다는 객체의 수가 무수히 많은 경우에 대략적인 객체의 개수를 추정하는데 적합한 방법론이다. 반면, 감지된 객체를 특정 궤적에서 인식하는 방법론은 모든 객체를 감지하고 추적하여 카운팅하는 방법론이다. 따라서, 밀도를 활용한 방법론 대비 보다 복잡한 계산 과정이 필요하다. 예를 들어, 미리 정의된 궤적 정보에 따른 특성(for example, 이동 길이, 방향 등)을 고려하며 연속적인 프레임을 유지하면서 개별 객체가 정의된 궤적에 있는지에 대해 개별 프레임별로 감지와 추적에 대한 계산 과정이 필요하다.

## 3. 연구 방법론


본 연구에서는 One Stage, Two Stage Detecting 방법론들을 사전에 검토하여, 가장 적합한 방법론 및 파라미터를 계산하였으며, 이에 따른 Tracking 파라미터들도 최적화를 완료하였다. 또한, Counting 솔루션에 있어서는 기존의 박스 영역, 궤도 추적, ROI 등의 방법론들 대비 보다 효과적이

라고 생각하는 Grid Counting 솔루션을 개발 및 적용하였다. 기존의 방법론들은 미리 정의된 이동에 대한 대상 차량의 이동 경로를 먼저 식별하여 이러한 계산 복잡성 문제를 해결하고자 하였다. 하지만, 이동 경로를 미리 식별하여 박스 및 Line Assignment를 사람이 직접 설정하는 것은 인적 요소가 들어가는 문제점이 발생한다. 따라서, 영상 내에서 개별 사람마다 이동 경로의 시작점 및 끝점 설정에 대한 모호성이 발생할 수 있다.

이러한 문제점을 해결하고자 Grid Counting Method를 적용하여, 기존 Counting 방법론들 대비 높은 정확도를 구현할 수 있는 솔루션을 개발하였다. 개발한 Grid Counting 솔루션은 기존 인적요소가 들어가는 Counting 방법론들을 대체할 수 있으며, Detecting에 있어서 검지 정확도가 떨어지는 프레임에 있어서의 문제점도 보완할 수 있다. 이를 통해, 주간 교통량 조사 검증 정확도를 기존 90% 목표치에서 95% 이상으로 상향할 수 있게 되었다.

### 3.1. 영상 검지 방법론

영상 내 객체를 검출하기 위한 소프트웨어 개발에 YOLO 알고리즘을 활용하였다. YOLO 알고리즘은 대표적인 One Stage 검출 알고리즘으로 최종 출력단에서 경계박스의 중심좌표와 클래스 분류가 동시에 이뤄진다. 따라서 실시간 처리에 적합한 처리 속도를 가지고 처리 정확성 또한 뛰어나다고 평가를 받고 있다. 대표적인 2016년 Redmon et al.에 의해 제시된 다음의 YOLO 아키텍처를 응용하여, 본 연구에서는 Conv. Layer를 구성하여 객체 검지에 활용하였다. 다음 [그림 1]은 YOLO 알고리즘의 개념을 정리하였다.



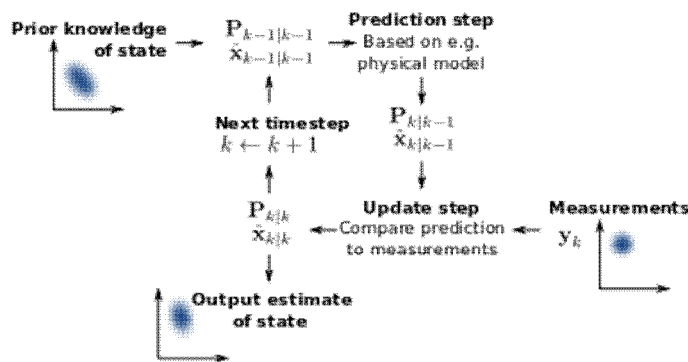
[그림 1] x, y, w, h, class, confidence 개념

[Fig. 1] Concepts of x, y, w, h, class, confidence

YOLO 알고리즘은 각 프레임당 차량의 정보를 검출하고, 검출된 차량의 정보는 다음과 같은 형식으로 생성된다.  $\langle x, y, w, h, class, confidence \rangle$   $x$ 와  $y$ 는 검출된 객체의 중심좌표를 나타내고,  $w$ 와  $h$ 는 중심좌표를 기준으로 넓이와 높이를 나타낸다.  $class$ 는 해당 객체가 어떤 객체에 속하는지를 의미하며,  $confidence$ 는 객체가 존재할 확률을 나타낸다.  $confidence$ 를 최적화하여 설정된 임계치 이상의 객체들만을 추적에 사용하였다.

### 3.2. 영상 추적 방법론

영상 내 객체 추적에는 DeepSORT를 사용하였다. DeepSORT는 Deep Learning과 SORT가 합쳐진 말로 기존 SORT 알고리즘에 Deep Learning을 활용한 객체 검출기를 사용한다. SORT는 헝가리안 알고리즘과 칼만필터의 조합으로 칼만필터로 객체의 위치에대한 보정값을 도출하고 헝가리안 알고리즘을 이용하여 현재 프레임과 이전 프레임간의 가장 근사한 객체를 매칭시킨다. 다음 [그림 2]는 객체 추적의 개념을 설명하는 것이다.



[그림 2] 객체 추적 개념도

[Fig. 2] Concepts of object tracking

칼만 필터는 예측과 업데이트 두 단계로 이루어진다. 예측 단계에서는 현재 상태 변수의 값과 정확도를 예측한다. 현재 상태 변수의 값이 실제로 측정된 이후, 업데이트 단계에서는 이전에 추정 한 상태 변수를 기반으로 예측한 측정치와 실제 측정치의 차이를 반영해 현재의 상태 변수를 업데이트하게 된다. 칼만 필터의 예측은 시스템 모델을 기반으로 한다. 시스템 모델은 문제를 수학적 식으로 표현해 놓은 것을 말하며 칼만 필터는 다음과 같은 선형 상태의 모델로 구성되어 있다. 본 프로그램에서는 할당 문제 최적화 알고리즘으로 헝가리안을 이용 검출된 객체의 현재 프레임과 이전 프레임 간의 IOU(Intersection Over Union)를 비용으로 사용하였으며, 객체별 인덱스를 매칭의 결과물로 보았다. 다음 [그림 3]은 칼만 필터의 개념을 정리 한 것이다,



하지만 위의 방식의 경우에는 문제점이 존재한다. 박스형식의 MOI 설정에는 사용자가 사전에 정의를 해야하기 때문에 여러 지역의 경우 각각에 맞는 최적의 박스 크기, 위치를 정해야 문제점이 존재한다. 더불어 다양한 위치에 적용하기 힘들고 박스영역 내에 차량이 존재하는지를 지속적으로 계산해야 하기 때문에 불필요한 컴퓨팅 자원이 소모된다.

본 연구에서 개발한 Grid Counting Method는 기존 다른 방법론들에서 부족했던 사용자의 사전 설정이 필요하지 않고 일정 간격을 두고 객체의 방향을 검증하기 때문에 감지된 객체를 특정 궤적에서 인식하는 방법보다 계산량이 적습니다. 기존 객체 검출 프로세스의 경우 개별 프레임마다 모든 객체를 검출하기 때문에 어려움이 존재합니다. 하지만, Grid Counting Method의 경우 프레임 내에서 매우 조밀한 간격으로 Counting을 진행하기 때문에 기존 방법론들 대비 높은 정확도와 신뢰성을 갖고 있습니다. 다음 [그림 4]는 Grid Counting Method 개념을 나타냈다.

## 4. 분석 결과

### 4.1 분석데이터

S/W 검증을 위해 ‘2021년 도로교통량 수시조사’ 영상 정보를 바탕으로 실제 조사원들에 의해 수기로 검증한 도로교통량과 본 연구에서 개발된 모델을 통해 분석한 도로교통량 결과를 분석하였다. 분석에 사용한 지점은 수시조사에서 진행한 공간적 범위에서 임의로 설정된 지점을 활용하였다. 지정된 범위는 왕복 2차로 도로로 차량의 이동속도는 평균 60km/h 이상으로 확인되었다.

다음 [그림 5]은 영상자료의 예시를 보여준다.



[그림 5] 영상자료 예시

[Fig. 5] Sample of video data




#### 4.1.1 분석 결과

왕복 2차로 영상에 대한 분석 결과는 다음의 엑셀 Sheet와 같다. 개발된 모델 특성상 차량의 종류를 6종(승용차, 버스(소형,대형), 화물(소형,중형,대형))으로 구분함으로 비교를 위해서 시간대별 사람에 의한 수기조사 합계와 모델을 통해 조사된 합계를 MAE(Mean Absolute Error), MSE(Mean Squared Error), MAPE(Mean Absolute Percentage Error) 지표를 활용해 분석하였다.

[표 1] 주간 교통량 분석 결과

[Table 1] Result of traffic analysis in the daytime

구분	상행			지표			구분	하행			지표		
	시간	Model Counting	Human Counting	MAE	MSE	MAPE		시간	Model Counting	Human Counting	MAE	MSE	MAPE
주간	6:00	51	54	3	27.85	0.94		6:00	60	63	3	51.92	0.95
	7:00	76	76	0		1.00		7:00	103	112	9		0.92
	8:00	80	88	8		0.91		8:00	157	170	13		0.92
	9:00	104	111	7		0.94		9:00	101	109	8		0.93
	10:00	114	117	3		0.97		10:00	94	106	12		0.89
	11:00	97	100	3		0.97		11:00	129	132	3		0.98
	12:00	113	115	2		0.98		12:00	107	116	9		0.92
	13:00	144	149	5		0.97		13:00	134	138	4		0.697
	14:00	135	139	4		0.97		14:00	127	130	3		0.98
	15:00	143	148	5		0.97		15:00	114	122	8		0.93
	16:00	174	178	4		0.98		16:00	111	113	2		0.98
	17:00	140	146	6		0.96		17:00	91	94	3		0.97
	18:00	110	120	10		0.92		18:00	70	74	4		0.95
	결과			5	27.85	0.96		결과			6	51.92	0.95



[그림 6] 교통량 분석결과 비교

[Fig. 6] Comparison of traffic analysis results

주간에 대한 상행/하행 분석 결과는 다음 [표 1], [그림 6]과 같다. MAPE(%)는 주간에 96%, 95%로 ITS 성능평가 기준 ‘최상급’수준을 만족하는 것으로 나타났다.

## 5. 결론

본 연구에서는 총 20만 장 이상의 차종별 차량 이미지를 레이블링하여, 차종별·시간대별 교통량 정보를 자동으로 생성할 수 있도록 하였다.

주간 6종, 야간 1종에 대한 교통량 검지를 목표로 한다. 이때 정확도는 주간 95% 이상의 교통량 검지 정확도를 목표로 하였다. 차종은 6종 구분을 원칙으로 하며, 6종은 승용차, 버스(소형, 대형), 화물(소형, 중형, 대형)로 구성되어 있다. 다만, 야간은 영상 데이터의 조도가 낮은 관계로 1종 구분을 목표로 모델을 개발하였다. Human Counting 결과를 정답지로 해석하였으며, 비교 결과 95%이상의 정확도를 나타내어 교통량 조사의 자동화가 가능하다고 판단할 수 있다.

비록 본 연구에서 개발된 모델과 Human Counting 방식 중 어느 것이 정확한지는 판단할 수 없지만, 개발된 모델을 적용할 시 국가 교통량 조사에 소요되는 인력 및 비용을 크게 감소시킬 수 있을 것이며, 조사지점을 다양화 할 수 있다.

한계점으로는 야간에는 성능이 떨어지는 것으로 나타났다. 모델의 한계보다는 조도가 낮을 시 정확한 촬영이 불가능한 영상장비의 한계로 판단되며, 향후 적외선 카메라를 통한 야간 데이터 수집 및 모델 학습을 진행하여 주야간 모든 시간대에 대한 정확한 교통량 검지가 필요하다.

## References

- [1] D. H. Kim, S. I. Kim, “A study on testing the ability of vehicle detection system in ATMS”, Journal of Korean Society of Transportation, vol. 20, no. 5, October 2002, pp. 231-244.
- [2] A. Rourke, M. G. Bell, “Traffic analysis using low cost image processing”, PTRC Summer Annual Meeting, 16th, September 3-5, 1988, Bath, United Kingdom.
- [3] D. M. Ha, J. M. Lee, Y. D. Kim, “A Study On the Image Based Traffic Information Extraction Algorithm”, Korean Society of Transportation, vol. 19, no. 6, December 2001, pp. 161-170.
- [4] D. M. Kang, A. B. Chan, “Beyond counting: Comparisons of density maps for crowd analysis tasks-counting, detection, and tracking” IEEE Transactions on Circuits and Systems for Video Technology, vol. 29, no. 5, October 2018, pp. 1408-1422, doi: 10.1109/TCSVT.2018.2837153.
- [5] S. Kanagamalliga, S. Vasuki, “An efficient algorithm for tracking and counting pedestrians based on feature points in video surveillance applications”, Journal of Intelligent & Fuzzy Systems, vol. 36, no. 1, February 2019, pp. 67-78, doi: 10.3233/JIFS-172257.
- [6] Z. Dai, H. Song, X. Wang, Y. Fang, X. Yun, Z. Zhang, H. Li, “Video-based vehicle counting framework”,

- IEEE Access, vol. 7, May 2019. pp. 64460-64470, doi: 10.1109/ACCESS.2019.2914254.
- [7] F. Liu, Z. Zeng, R. Jiang, "A video-based real-time adaptive vehicle-counting system for urban roads", PloS one, vol. 12, no. 11, November 2017 pp. 1-16, doi: 10.1371/journal.pone.0186098.
- [8] L. Jiao, F. Zhang, F. Liu, S. Yang, L. Li, Z. Feng, R. Qu, "A survey of deep learning-based object detection", IEEE access, September 2019, vol. 7, pp. 128837-128868, doi: 10.1109/ACCESS.2019.2939201.