



CNN을 이용한 대기차량 카운팅 알고리즘 구조에 관한 연구

정호진^a, 조민수^a, 김기범^{a*}

Counting Algorithm Structure for Waiting Vehicles by using CNN

Hojin Jeong^a, Minsu Jo^a, Gibom Kim^{a*}^a Department of Mechanical System Design Engineering, Seoul National University of Science and Technology

ARTICLE INFO

Article history:

Received	6	April	2020
Revised	28	April	2020
Accepted	6	May	2020

Keywords:

Convolutional neural network

Vehicle counting

Sensitivity analysis

Classification

ABSTRACT

Increased computing power and advanced deep learning technology have enabled computers to effectively deal with problems that cannot be solved by ordinary people. Many attempts have been made to utilize deep learning technology to analyze road images and efficiently control crossroad vehicle flow. In this research, a new methodology is proposed for identifying the number of vehicles on the road using CNN (convolution neural network), deep learning technology that specializes in image classification. Unlike previous studies that used regression methods and video frames as input, this study determined the number of vehicles using real-time photographic images and classification methods for one lane. An experiment was conducted to find the optimal combination of variables using sensitivity analysis. The optimal network determined the number of vehicles on one lane with a high accuracy of 98.31%.

1. 서론

1.1 이론적 배경

대도시의 큰 문제 중의 하나가 교통체증 문제일 것이다. 교통체증으로 인한 불필요한 연료 소비, 경제활동 인력의 시간 낭비 등 경제적인 비효율성뿐만 아니라 매연으로 인한 환경적인 문제, 정신건강적인 문제 등 국가경쟁력을 저하시키는 큰 요인이 되고 있다.

교통체증을 해결하기 위한 방법으로, 지하철 및 버스 등 대중교통의 활성화, 도로확장 등을 추진하고 있으나, 대규모 투자를 필요로 한다. 대규모 투자 없이 교통체증을 완화시키는 방법의 하나로 교차로에서 교통상황에 따라 교통신호 주기를 제어하는 방법이 주목받고 있다. 미국 캘리포니아 주에서는 도로에 루프신호검출기를 매립하여, 도로의 교통상황을 감지하여 체증이 발생하는 방향의 신호주기를 길게 하고, 한가한 방향의 신호주기를 짧게 하여, 교차

로에서의 교통체증을 완화시키고 있다.

루프 신호검출기를 교차로의 전 차선에 매립하는 비용 및 교통신호기를 교체하는 비용이 상당하며, 도로공사가 잦은 우리나라의 현실에는 맞지 않는다. 교차로에 카메라를 설치하여 차량의 차량정체 정도를 파악하는 것이 가장 경제적인 방법이다^[1,10]. 카메라 이미지로부터 정체 정도를 판단하기 위하여, 이미지 프로세싱 연구가 많이 수행되었으며, 낮과 밤의 밝기, 비 또는 눈 등의 계절적 요인에 대한 이미지 처리, 자동차 색에 따른 오차 등을 처리하기 위하여 복잡한 이미지 프로세싱 알고리즘이 필요하다.

차량 수 카운팅(vehicle counting) 분야는 배경 차감(background subtraction)이나 블럽 추적(blob tracker) 알고리즘과 같은 영상처리 방식과 SVM, SST-LBP와 같은 분류기(classifier)를 사용하여 영상 내 차량의 수를 파악하였고 현재는 AI 분야 중 딥러닝(deep learning)을 이용한 많은 연구가 진행되고 있다.

* Corresponding author. Tel.: +82-2-970-6342

E-mail address: gbkim@seoultech.ac.kr (Gibom Kim).

본 논문에서는 도로위에 차량 수를 기반으로 새로운 교통통제 시스템을 개발하기 위해 딥러닝을 이용한 차량 수 파악 알고리즘을 제안한다. 딥러닝은 다수의 입력 데이터를 학습하여 데이터에 존재하는 패턴을 스스로 파악하는 장점을 가지고 있으며, 날씨나 조도에 따라 복잡한 알고리즘을 개발하여야 한다는 문제점을 해결할 수 있다.

1.2 관련 연구

AI가 등장하기 이전에는 개체 밀집도 추정분야에선 SIFT (scale invariant feature transform)와 HOF (histogram of oriented gradient) 등 전통적인 영상특징을 추출하여 개체 밀집도를 계산하며, 느린 속도와 낮은 정확도를 보인다. CNN (convolution neural network)은 이미지 특징 추출을 효과적으로 수행하는 인공신경망으로 사진 이미지의 분류뿐만 아니라 사진, 영상 이미지 내 밀집되어 있는 개체의 수를 파악하는 개체 수 카운팅(crowd counting)에도 많이 이용된다. 딥러닝과 이미지 처리에 특화된 CNN이 등장함에 따라 복잡한 이미지에 대해서도 빠르고 정확하게 객체의 수를 파악할 수 있게 되었는데, Sindagi^[1]는 CNN을 이용하여 객체의 숫자를 헤아린 연구들을 네트워크 구성 방식, 이미지 학습 방식으로 구분하여 분류하였다.

CNN이 초기에 등장했을 때 Min Fu^[2]는 간단한 CNN 네트워크 구조와 분류(classification)방법을 이용해 사진 이미지 내의 사람의 밀집도를 구하였으며, 사진 속사람들의 밀집도를 5개의 클래스(very low, low, medium, high, very high)로 분류하였고, 기존의 방식보다 5%정도 향상된 정확도를 얻었다. 한편 Wang Chuan^[3]은 간단한 CNN 구조를 이용하여 이미지 내의 밀집된 사람의 수를 파악하였으며, 회귀(regression)방식을 이용하여 객체 수를 추정했다는 점에서 Min Fu와 다르다. Wang은 건물이나 나무와 같이 카운팅되면 안 되는 배경 사물에 대한 오류를 피하기 위해 배경 사진에 대해서 0명이라고 학습시켰다.

학습된 장소의 사진이 아닌 다른 장소의 사진의 경우, 기존에 존재하는 기법으로 분석하면 정확도가 많이 떨어지는데, Zhang Cong^[4]는 전환이 가능한 Crowd CNN모델을 설계하여, 정확도를 향상시켰다. 학습 이미지에서 추출한 패치를 입력데이터로 이용하고 3개의 컨벌루션 층과 3개의 전결합층으로 구성하여, 학습된 장소 이외의 장소에서도 정확하게 군중 수를 파악하였다.

Walach와 Wolf^[5]는 계층 부스팅(layered boosting)과 선별 샘플링(selective sampling)을 접목시켜 연구하였다. 이미지 학습을 시킬 때, 매 반복마다 모델에 CNN 모델을 추가시키는 방법인 계층 부스팅 방식을 이용하여, 전체 추정오류를 20% 정도 줄였으며, 추정 정확도를 높였다. 사전에 정확하게 분류되었거나 판단 가치가 없는 표본 및 잘못 라벨링된 표본을 제외하고 학습을 진행하는

선별 샘플링 방식을 이용하여 전체 학습시간을 50% 단축시켰다.

Zhang Yingying^[6]은 입력데이터의 크기에 상관없이 안정적으로 높은 추정 정확도를 얻기 위하여 MDNNs (multi-column deep neural networks) 모델을 제안했다.

Onoro Rubio^[7]는 차량이나 사람의 밀집도를 나타내는 이미지인 밀도 맵(density map)을 이용하여 회귀방식을 통해 차량 수 혹은 사람의 수를 파악하였다. 원근법과 같은 다른 기하학적 정보 없이 밀집도 지도를 얻어 높은 정확도를 보이나, 새로운 CNN을 학습시켜야한다.

Zhao Zhuoyi^[8]는 입력데이터로 정지이미지 대신 동영상을 사용하여 군중의 객체 수를 추정하였으며, LOI (line-of-interest)방식을 활용하여 객체 수를 정확하게 추정하였다.

Maojin Su^[9]는 VCN (vehicle counting network)을 이용하여 정지 영상을 학습시켰으며, 회귀 및 분류 기법을 사용하여 이미지 분할구역 내에서 차량의 수를 파악하는 다중처리 알고리즘을 제안하였다.

Jiyong Chung^[10]은 회귀기법 및 이미지 워핑(image warping) 기술을 이용하여, 교차로 도로의 일부분을 직사각형 모양으로 추출하여 학습시키고, 7개의 층으로 이루어진 CNN 네트워크를 통해 차량 수를 파악하였다.

2. 분류기법을 이용한 차량 수 카운팅

2.1 학습데이터 수집

교통신호 주기를 제어하기 위하여 교차로 각 방향의 차량수를 카운팅하여야 한다. 각 방향의 전 차선의 차량수를 카운팅하는 것보다, 각 차선의 차량수를 카운팅하여 합산하는 것이 정확도 측면에서 유리하며, 이미지 크기가 작아짐에 따라 계산 및 학습시간이 감소한다는 이점이 있다. 또한 직진 및 좌우 회전 차량을 각각 카운팅함으로써 교통신호 주기 결정에 도움이 된다.

대부분의 연구는 회귀기법을 사용하여 차량수를 카운팅하였으나, 본 연구에서는 이미지 내의 차량수가 줄어들어 분류기법으로 차량수를 카운팅하였다. 각 차선별 이미지에서 차량수를 카운팅하는 클래스 수가 적어짐으로, 분류기법 적용이 용이하다.

학습 및 실험에 사용되는 데이터 세트를 위하여, 실제 도로의 16,000장의 이미지를 Fig. 1과 같이 구하였다. Wang^[3]은 전 차선을 추출하였으나, 본 연구에서는 Fig. 1과 같이, 이미지 워핑 기법을 사용하여, 한 차선만의 이미지를 추출하고 50×300 픽셀 이미지를 획득하였다. 한 차선의 이미지에서 차량수를 0에서 7대, 8대 이상의 8개 클래스로 분류하여 데이터 세트를 구축하였다. 학습데이터 세트와 실험데이터 세트를 8:2로 나누어, 학습 및 실험을 수행하였다. 타 연구에서는 이미지 전체 또는 도로 전체를 학습데이

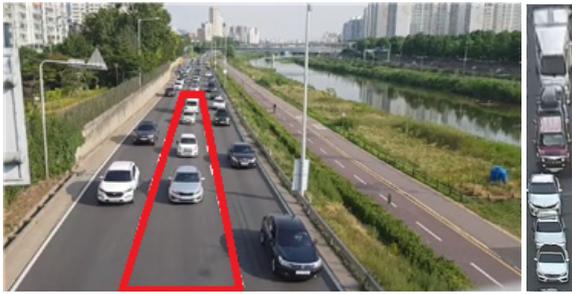


Fig. 1 Image data cropped

터로 사용하였으나, 본 연구에서는 한 차선으로 이미지를 국한하여 차량 수 카운팅이 매우 정확하다.

2.2 CNN (convolutional neural network)

CNN은 심층신경망 구조 중 하나로 입력 유닛의 일부 값만이 다음 층의 유닛으로 전달된다는 특징을 가진 신경망이다. 1989년에 LeCun^[11]이 최초로 발표하였으며, 2006년 이후부터 빠르게 발전한 신경망 구조다.

CNN의 전형적인 구조는 Fig. 2와 같으며, 전결합층과 차이점을 가지고 있다. 전결합층은 아핀(affine) 계층을 이루고 있지만, CNN의 경우 합성곱층과 풀링층이 반복되고 마지막에 전결합층을 이용하여 결과 값을 얻어내는 구조이다.

전결합층을 통한 연산을 하게 되면 이미지의 3차원 데이터가 1차원 데이터로 변환되지만, 합성곱층은 3차원 구조의 필터를 이용하여 연산을 하기 때문에 입력된 형태와 동일한 형태의 출력 값을 얻어낼 수 있다는 특징을 가지고 있으며, 합성곱층 연산을 통해 특징 맵(feature map)이 얻어진다. 합성곱층을 통해 연산하게 되면 주변 값들을 고려하여 학습한다는 특징이 있어 이미지의 특징이 부각되는 장점이 있어, CNN은 이미지를 분류하는 문제를 해결할 때 효과적이다. 특히 ILSVRC-2012에서 CNN기반 딥러닝 알고리즘 AlexNet^[12]이 우승을 차지한 이후 영상인식에서 가장 많이 쓰이게 되었다.

따라서 본 연구에서는 이미지의 특징 추출에 강점을 가지고 있는 CNN을 이용하여 도로 이미지에 포함되어 있는 차의 특징을 추출하고 추출된 차량의 특징을 이용하여 차량 수의 클래스를 구분하는 분류작업을 한다.

2.3 민감도 분석

민감도 분석이란 하나의 변수를 미세하게 변화시킬 때 목적함수의 결과값 변화를 통해 최적 해를 도출해내는 방식이다. 주로 변수 값을 바꿨을 때 결과에 어떤 영향을 미치는지 파악하기 위해 사용된다. 또한, 결과 값을 극대화시키는 방향으로 변수 값들을 변화시켜 최대값을 찾아내기 위해 민감도 분석을 사용하기도 한다. 민

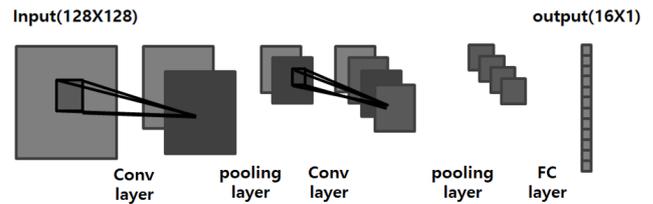


Fig. 2 Structure of a typical CNN

감도 분석을 이용하면 목적함수에 영향을 미치는 변수가 가지는 결과에 대한 민감도를 바탕으로 최대의 결과 값을 보이는 변수들의 조합을 찾아낼 수 있다.

본 논문에서는 차량 수를 파악하기 위한 분류 문제에서의 가장 높은 정확도를 보이는 딥러닝 모델을 찾기 위해 민감도 분석을 사용했으며 이를 위해서 정확도에 영향을 주는 CNN 모델의 구성 성분을 실험 변수로 선정하였다.

3. 실험 및 결과 분석

3.1 민감도 분석을 위한 실험변수

본 실험에서는 이미지 내의 차량 수를 카운팅 하는 최적의 딥러닝 모델을 찾기 위해 예측 정확도에 영향을 줄 수 있는 5가지 실험 변수에 대해서 민감도 분석을 진행하였다. 실험에서 고려한 변수는 학습률(learning rate), 필터 수(filter number), 패치 크기(patch size), CNN 깊이(depth) 및 이미지 크기(image size)이며, 학습 가중치(weight)를 최적화하는 옵티마이저(optimizer)로는 NAG (nesterov accelerated gradient)와 Adam 옵티마이저의 개념을 합한 Nadam 옵티마이저를 사용하였다.

학습률은 한번 가중치 파라미터를 변화시킬 때 어느 정도의 크기로 변화시키는지 나타내는 지표이다. 학습률을 너무 크게 하면 정확도가 수렴하지 못하고 발산하는 오버슈팅(overshooting) 현상이 발생하여 학습이 안될 수 있다. 만약 학습률이 너무 작다면 최소값으로 수렴하기 위해 많은 단계(step)를 이동해야 한다는 문제점이 발생할 수 있다. 이러한 이유로 실험을 통해 적절한 학습률 값을 찾는 것이 중요하다.

필터 수는 한 층(layer)에서 출력하는 특징 맵의 수를 의미한다. CNN에서의 필터는 커널(kernel)과 같은 의미를 가지며 이미지의 특징을 찾아내기 위한 파라미터라고 할 수 있으며, 특징 맵의 수가 늘어날수록 가중치의 수가 증가하여 복잡한 문제에 대한 예측 정확도가 증가한다. 보통 연산 시간을 일정하게 유지하는 방향으로 필터 수를 정하는데, 본 실험에서는 모든 합성곱층에서 필터 수를 같게 하여 동일한 필터 수를 가졌을 경우 예측 정확도의 경향을 파악하였다. 따라서 모델의 복잡성을 고려하여 예측 정확도가 가장 높은 필터 수를 선정할 필요가 있다.

Table 1 Initial conditions of sensitivity analysis

	Condition 1	Condition 2	Condition 3	Condition 4
Learning Rate	0.005 ± 0.002			
Filters	16	32	48	64
Patch size	2×2	3×3	4×4	5×5
CNN depth	1+1+1	2+2+1	3+3+1	4+4+1
Image size	120×20	180×30	240×40	300×50

패치 크기(patch size)는 합성곱층에서 합성곱을 수행하는 필터 사이즈를 뜻한다. CNN의 특성은 일부분에 대하여 주변 값을 고려하는 필터를 적용시켜 특징 맵을 얻어낸다는 것이다. 여기서 필터 크기가 너무 커지게 되면 전결합층과 비슷한 효과를 갖게 되어 CNN의 특성을 잘 살리지 못한다. 또한, 연산량이 늘어난다는 문제점도 있다. 필터 크기가 작아질 경우 고려해야 할 범위에 못 미치는 문제가 생길 수 있으므로 데이터 세트에 따른 적절한 필터 크기를 찾아서 시험 정확도를 높이고자 한다.

CNN 깊이는 기본적으로 층이 깊어질수록 복잡한 문제를 잘 해결하게 됨에 따라 정확도가 높아진다. 하지만 층이 깊어짐에 따라 학습에 적용되는 기울기가 0에 수렴하여 학습에 영향을 못주는 기울기 소실(gradient vanishing) 문제와 학습 데이터에 대해서는 높은 정확도를 보이지만 Test 데이터에 대해서는 낮은 정확도를 보이는 과적합문제가 발생한다. 따라서 실험을 통하여 가장 정확하게 차량의 수를 파악할 수 있는 CNN 깊이를 찾아야 한다.

이미지 크기는 입력 데이터인 도로 이미지의 픽셀 단위 크기를 뜻한다. 원본 데이터 세트의 이미지 크기는 300×50이지만 이미지의 크기를 축소시키게 되면, 같은 패치 크기를 사용해 특징 맵을 추출하여도 결과가 달라 예측 정확도에 영향을 주게 된다. 따라서 우리가 해결하는 문제에 가장 높은 정확도를 보이는 이미지 크기를 선정하는 것이 필요하다.

민감도 분석 실험은 정확성을 위해 다른 초기조건으로 4번 진행하였다. Table 1은 실험에서 쓰인 4가지 초기조건에서의 각 실험변수들의 조합을 나타낸 표이다. 각 실험변수 값은 0.005를 시작으로 제한 없이 커지고 작아질 수 있는 학습률을 제외하고는 전부 4개의 변수 값을 지정하였다. 선정된 각 변수의 값은 다음과 같다.

합성곱층을 이루는 필터 개수는 16, 32, 48, 64로 지정하였고 패치 크기는 2×2, 3×3, 4×4, 5×5, CNN 깊이의 실험조건은 합성곱층, 풀링층 각 1층, 2층, 3층, 4층과 전결합층 1층 그리고 이미지 크기는 120×20, 180×30, 240×40, 300×50으로 지정하여 실험을 진행하였다.

3.2 실험 방법

실험은 선정된 다섯 가지 변수의 여러 가지 조합 중 가장 높은

정확도를 나타내는 조합을 찾기 위해 진행된다. 실험은 변수들에 대한 초기조건을 선정하고 각각의 변수를 초기조건에서 미세하게 변화시켜 정확도를 얻는다. 그리고 변수들을 변화시켜 얻은 정확도 중 가장 높은 값을 보이는 변수들의 조합을 다음 실험의 초기값으로 선정한다. 그리고 앞서 진행한 과정을 반복한다. 각각의 변수들을 변화시켰을 때 나오는 정확도들이 기준이 되는 초기 변수들의 조합으로 구성된 모델의 정확도보다 낮을 때 해당 초기값에 대한 최적해라고 판단한다.

민감도 분석의 가장 초기단계에서 설정한 실험변수의 초기값을 변화시켜 초기값에 따라 다르게 나오는 가장 최적조건을 확인할 수 있다. 그중 가장 높은 정확도를 보이는 최적조건을 차량 수에 따라 분류하는 문제를 해결하는 가장 정밀도가 높은 모델의 최적조건이 된다.

3.3 실험 결과

초기값은 4개로 정하여 실험을 진행하였다. 초기값 표기 방식은 (a,b,c,d,e)로 표현되며, 그 의미는 다음과 같다. a는 학습률의 값, b, c, d, e는 순서대로 필터 수, 패치 크기, CNN 깊이, 이미지 크기의 조건번호이다.

초기값은 (0.005,1,1,1,1), (0.005,2,2,2,2), (0.005,3,3,3,3) 그리고 (0.005,4,4,4,4)로 총 4개로 정하고 Fig. 3과 Table 2에서 각각의 실험을 Trial 1~4로 표기하였다. 그리고 실험을 통해 초기값에서 도달하는 최적의 조건을 찾았다.

초기값을 (0.005,1,1,1,1)로 설정하고 실험을 진행했을 때는 (0.001,1,1,1,3)에서 98.28%의 정확도를 보였다. 그리고 (0.005,2,2,2,2)를 초기값으로 정했을 때는 (0.003,2,3,2,1)에서 97.94%, (0.005,3,3,3,3)을 초기값으로 정했을 때, (0.001,3,3,4,4)에서 98.31%로, 각 초기값에서 가장 높은 정확도를 보였다. 마지막으로 (0.005, 4,4,4,4)를 초기값으로 설정하였을 때는 모든 변수를 변화시켰음에도 정확도가 20%대를 벗어나지 못했다(Fig. 3). 각각의 step에서 가장 높은 정확도를 보이는 조건은 Table 2를 통해 확인할 수 있다.

이렇게 초기값이 달라질 때마다 가장 높은 정확도의 CNN 모델이 달라지는 이유는 비선형 모델에서는 국소 최소값이 여러 개 존재할 수 있기 때문이며, 각 초기값마다 최대 정확도를 가지는 모델로 수렴하였다. Table 2에서 사용되는 acc는 분류 평가 지표 중에서 정확도 값을 백분율로 환산한 값을 나타낸다. 정확도는 정답 값과 예측 값이 일치하는 경우의 횟수를 전체 횟수로 나눈 값이다.

실험을 통해 얻은 최적의 모델로 실제 교차로에서 차량 수를 세는데 걸리는 시간을 계산해 보았다. 시간 확인에는 Python내의 time함수를 했으며, 확인 결과 CPU i5에 RAM 8 GB의 사양의 컴퓨터로 100개의 차선 이미지를 분류하는데 약 3.4초가 걸리는

Table 2 Condition shifting progress in sensitivity analysis

Trial 1	Learning Rate	Filters	Patch size	CNN depth	Image Size	acc (%)	Trial 2	Learning Rate	Filters	Patch size	CNN depth	Image Size	acc (%)
step 0	0.005	1	1	1	1	96.05	step 0	0.005	2	2	2	2	95.13
step 1	0.003	1	1	1	1	97.07	step 1	0.003	2	2	2	2	97.50
step 2	0.001	1	1	1	1	97.37	step 2	0.003	2	2	2	1	97.74
step 3	0.001	1	1	1	2	98.04	step 3	0.003	2	3	2	1	97.94
step 4	0.001	1	1	1	3	98.28							
Trial 3	Learning Rate	Filters	Patch size	CNN depth	Image Size	acc (%)	Trial 4	Learning Rate	Filters	Patch size	CNN depth	Image Size	acc (%)
step 0	0.005	3	3	3	3	96.56	step 0	0.005	4	4	4	4	19.73
step 1	0.003	3	3	3	3	97.54	step 1	0.005	4	3	4	4	20.54
step 2	0.001	3	3	3	3	97.81							
step 3	0.001	3	3	3	4	98.08							
step 4	0.001	3	3	4	4	98.31							

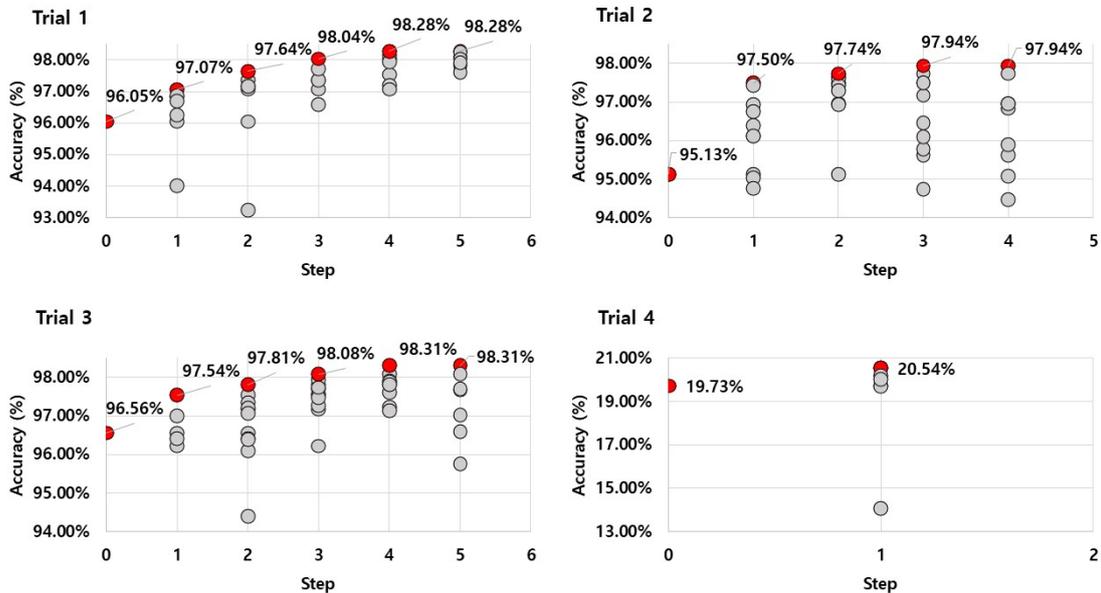


Fig. 3 Experiment result

것으로 확인됐다. 이는 왕복 4차선 도로에서 이 모델을 적용시켰을 때 1초에 7프레임을 연산할 수 있는 속도이며 실시간 신호처리 시스템에 충분히 적용할 수 있는 결과라고 판단된다.

4. 결론

교차로에서 대기차량 검출을 효율적으로 하기 위해 단일차선에 대해 검출하는 방법을 사용하여 차량 수를 파악하였다. 본 연구의 결론은 다음과 같다. 먼저, 차량 수를 파악하기 위해서 전체 이미지로부터 차량 수를 파악하는 것이 아닌 단일 차선을 이용하여 차량 수를 파악하는 기법을 제안하여, 높은 정확도를 가진 분류기를 도출하였다. 또한, CNN 카운팅 알고리즘에 영향을 미치는 학습률,

패치수, 패치 크기, CNN 깊이 및 이미지 크기를 패러미터로 설정하여, 민감도 해석을 통하여 가장 정확도가 높은 패러미터를 찾아냈다. 시행착오로 CNN 구조를 결정하는 방법이 아닌, 최적 패러미터의 CNN 구조를 도출하였다. 그리고 도출된 최적 패러미터를 이용하여 차선 대기차량을 카운팅한 결과, 98.31%의 높은 정확도로 차량 수 별 클래스를 분류하였다.

향후 교차로의 신호주기 결정에 본 연구결과를 활용할 수 있으며, 루프 신호검출기에 비하여 적은 투자 및 높은 정확도로 교통문제를 해결할 수 있다. 마지막으로 민감도 해석을 통하여 최적의 CNN 구조를 결정할 수 있으며, 추후 다른 패러미터에 대한 최적 설계를 통하여, 계산시간 절감 및 정확도 향상을 얻을 수 있는 CNN 모델의 구조를 결정할 수 있다.

후 기

본 연구는 서울과학기술대학교 교내 일반과제 연구비 지원으로 수행되었습니다.

References

- [1] Sindagia, V., Patel, V., 2017, A Survey of Recent Advance in CNN-based Single Image Crowd Counting and Density Estimation, Pattern Recognition Letters., 107 3-16, <https://doi.org/10.1016/j.patrec.2017.07.007>.
- [2] Fu, M., Xu, P., Li, X., Liu, Q., Ye, M., Zhu, C., 2015, Fast Crowd Density Estimation With Convolutional Neural Networks, Engineering Applications of Artificial Intelligence, 43 81-88, <https://doi.org/10.1016/j.engappai.2015.04.006>.
- [3] Zhang, C., Li, H., Wang, X., Yang, X., 2015, Deep People Counting in Extremely Dense Crowds, Proc. ACM international Conference on Multimedia. Autumn conf., 1299.
- [4] Zhang, C., Li, H., Wang, X., Yang, X., 2015, Cross-scene Crowd Counting via Deep Convolutional Neural Networks, IEEE Conference on Computer Vision and pattern Recognition, 1 833.
- [5] Walach, E., Wolf, L., 2016, Learning to Count With cnn Boosting, Proc. Computer Vision-ECCV. Autumn conf., 660.
- [6] Zhang, Y., Zhou, D., Chen, S., Gao, S., Ma, Y., 2016, Single Image Crowd Counting via Multi-column Convolutional Neural Network, IEEE Conference on Computer Vision and Pattern Recognition, 589.
- [7] Onoro-Rubio, D., L'opez-Sastre, R. J., 2016, Towards Perspective-free Object Counting With Deep Learning, Proc. Computer Vision - ECCV, 615.
- [8] Zhao, Z., Li, H., Zhao, R., Wang, X., 2016, Crossing-line Crowd Counting With Two-phase Deep Neural Networks, Proc. Computer Vision - ECCV 2016, 712.
- [9] Sun, M., Wang, Y., Li, T., Lv, J., Wu, J., 2017, Vehicle Counting in Crowded Scenes With Muliti-channel and Multi-task Convolutional Neural Networks, Journal of Visual Communication and Image Representation, 49 412-419, <https://doi.org/10.1016/j.jvcir.2017.10.002>.
- [10] Chung, J., Sohn, K., 2018, Image-Based Learning to Measure Traffic Density Using a Deep Convolutional Neural Network, IEEE Transactions on Intelligent Transportation Systems, 19:5 1670-1675, <https://doi.org/10.1109/tits.2017.2732029>.
- [11] LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W., Jackel, L., 1989, Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation winter 1989, 1:4 541-551, <https://doi.org/10.1162/neco.1989.1.4.541>.
- [12] Krizhevsky, A., Sutskever, I., Hinton, G., 2017, ImageNet Classification with Deep Convolutional Neural Networks, Communications of the ACM, 60:6 84-90, <https://doi.org/10.1145/3065386>.



Hojin Jeong

B.Sc. candidate in the Department of Mechanical System Design Engineering, Seoul National University of Science and Technology.

His research interest is Computer Vision.

His research interest is Artificial Intelligence.

E-mail: hojin.jeong@gmail.com



Minsu Jo

B.Sc. candidate in the Department of Mechanical System Design Engineering, Seoul National University of Science and Technology.

His research interest is Computer Vision.

His research interest is Artificial Intelligence.

E-mail: whalstn098@naver.com



Gibom Kim

Professor in the Department of Mechanical System Design Engineering, Seoul National University of Science and Technology.

His research interest is computer vision.

E-mail: gbkim@seoultech.ac.kr