

# 딥러닝을 이용한 번호판 검출과 인식 알고리즘

## License Plate Detection and Recognition Algorithm using Deep Learning

김정환\*, 임준홍\*

Jung-Hwan Kim\*, Joonhong Lim\*

### Abstract

One of the most important research topics on intelligent transportation systems in recent years is detecting and recognizing a license plate. The license plate has a unique identification data on vehicle information. The existing vehicle traffic control system is based on a stop and uses a loop coil as a method of vehicle entrance/exit recognition. The method has the disadvantage of causing traffic jams and rising maintenance costs. We propose to exploit differential image of camera background instead of loop coil as an entrance/exit recognition method of vehicles. After entrance/exit recognition, we detect the candidate images of license plate using the morphological characteristics. The license plate can finally be detected using SVM(Support Vector Machine). Letter and numbers of the detected license plate are recognized using CNN(Convolutional Neural Network). The experimental results show that the proposed algorithm has a higher recognition rate than the existing license plate recognition algorithm.

### 요약

최근 지능형 교통관제 시스템에 관한 다양한 연구가 진행되고 있는 가운데 번호판 검출과 인식 알고리즘은 가장 중요한 요소 중에 하나로 대두되고 있다. 번호판은 차량의 고유 식별값을 가지고 있기 때문이다. 기존의 차량 통행 관제 시스템은 정차를 기반으로 하고 있으며 차량의 입출입 인식 방법으로 루프 코일을 사용하고 있다. 이러한 방법은 교통 정체를 유발하고 유지보수 비용이 상승하는 단점을 가지고 있다. 본 논문에서는 이러한 문제점을 해결하기 위해서 차량의 입출입 인식 방법으로 카메라 영상을 사용한다. 차량 통행 관제 시스템의 특성상 카메라가 고정되어 있다. 이에 차량이 접근하면 카메라의 배경화면이 달라진다. 이 특징을 이용하여 배경화면의 차분영상을 구하면 차량의 입출입을 인식할 수 있다. 입출입 인식 후 한국 번호판의 형태학적 특성을 이용하여 후보 이미지를 추정한다. 그리고 선형 SVM(Support Vector Machine)을 이용해서 최종 번호판을 검출한다. 검출한 번호판의 글자와 숫자 인식 방법으로는 CNN(Convolutional Neural Network) 알고리즘을 사용한다. 제안한 알고리즘은 기존의 시스템과 달리 검출 위치를 기준으로 글자와 숫자를 인식하기 때문에 번호판의 규격이 변해도 인식할 수 있다. 실험한 결과 기존의 번호판 인식 알고리즘들 보다 제안한 알고리즘이 더 높은 인식률을 가진다.

*Key words : License Plate, SVM, Machine Learning, Deep Learning, Intelligent Transportation System*

\* Dept. of Electronic Engineering, Hanyang University

★ Corresponding author

E-mail : [jhlim@hanyang.ac.kr](mailto:jhlim@hanyang.ac.kr), Tel : +82-31-400-4043

※ Acknowledgment

This research was supported in part by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (Grant No.2017R1D1A1B03033806).

Manuscript received Jun. 4, 2019; revised Jun. 26, 2019; accepted Jun. 26, 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.

I. 서론

최근 지능형 차량 관제 시스템에 관한 다양한 연구가 활발히 이루어지고 있다. 이 가운데 번호판 검출과 인식 알고리즘은 가장 중요한 요소 중에 하나로 대두되고 있다. 번호판은 고유 식별값을 가지고 있어 차량과 운전자의 정보를 수집할 수 있기 때문이다. 기존의 차량 통행 관제 시스템은 그림1과 같이 번호판 정보를 수집할 목적으로 차량을 정차시킨다. 또한 차량의 입출입을 인식하기 위해서 루프 코일을 사용하고 있다. 이러한 방법은 교통정체를 유발시키고 유지보수의 비용이 상승하는 단점을 가지고 있다[1].




Fig. 1. The traffic control system based on vehicle stop. 그림 1. 차량 정차 기반의 통행 관제 시스템

본 논문에서는 이러한 문제점들을 해결하기 위해서 차량의 입출입 인식 방법으로 카메라 영상을 이용한다. 차량 통행 관제 시스템의 특성상 카메라가 고정되어 있다. 이에 차량이 접근하면 카메라의 배경화면이 달라지는 특징이 있다. 이점을 이용하여 배경화면의 차분영상을 구하면 차량의 입출입을 인식할 수가 있다. 연산 수행 시간을 줄이기 위해서 차분할 배경화면에 ROI(Region Of Interest)를 설정한다. 입출입이 인식되면 카메라 영상을 이미지로 저장하고 렌즈에 의해서 가지는 왜곡을 보정한다. 이후 한국 번호판의 형태학적 특성과 수정한 Canny 알고리즘을 이용해서 후보 이미지들을 선출한다[2]. 번호판의 형태학적 제원은 불변하기 때문이다. 선출된 후보들의 이미지에 SVM(Support Vector Machine)을 적용해서 최종 번호판을 검출한다. SVM은 사전에 지도학습을 먼저 시킨다. 번호판이 검출되면 가로세로 영역의 히스토그램을

구하고 글자와 숫자들을 각각의 위치에 맞게 분할한다. 이러한 방법은 기존에 중횡비를 기반으로 하는 알고리즘과 달리 검출 위치를 기준으로 인식하기 때문에 번호판의 규격이 변해도 인식할 수 있다. 이후 분할된 글자와 숫자를 인식하기 위해서 CNN(Convolutional Neural Network) 알고리즘을 사용한다. 본 논문에서는 기존의 번호판 인식 알고리즘들과 비교를 했다[2-4]. 실험한 결과 기존 알고리즘들 보다 제안한 CNN 알고리즘이 더 높은 인식률을 가졌다. 제안한 알고리즘의 블록다이어그램은 그림 2와 같다.

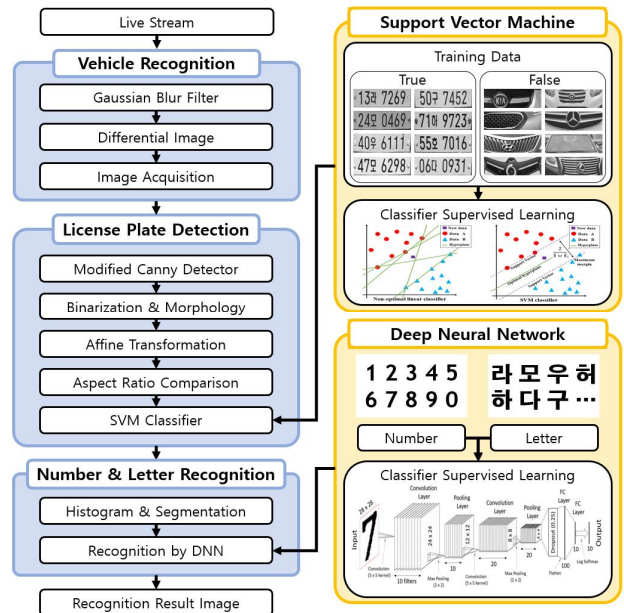


Fig. 2. License plate detection and recognition algorithm. 그림 2. 차량 번호판 검출 및 인식 알고리즘

II. 차량 인식

일반적으로 루프 코일을 사용해서 차량의 입출입을 인식한다. 이 방식은 초기 설치비용이 저렴한 장점이 있지만 도로에 매설하기 때문에 유지보수의 어려움이 있고 교체 시 높은 비용이 발생한다. 본 논문에서는 이러한 단점을 보완하고자 카메라를 이용한 입출입 인식 알고리즘을 제안한다. 차량 통행 관제 시스템의 특성상 카메라가 고정되어 있으므로 차량이 접근하면 배경화면이 달라진다. 이러한 점을 이용하여 배경화면의 차분영상을 구하면 차량의 입출입을 인식할 수가 있다.

차분영상을 구하기 위해서 입력되는 영상의 모든

영역에 대해서 차분을 수행하면 번호판 인식에 불필요한 이미지도 포함되기 때문에 ROI를 지정해야 한다. ROI 지정은 연산량을 줄일 수 있어서 영상 처리 속도를 증가시킬 수 있다. 번호판을 검출하는 것이 목적이므로 영상의 우측 하단 부분을 관심 영역으로 지정한다. 카메라의 내부적 또는 외부적 요인에 의해서 실시간으로 입력되는 영상에는 노이즈가 포함될 수 있다. 이러한 노이즈는 차분될 때에 신호가 증폭될 수 있으며 이로 인해 차량에 대한 인식률이 저하될 수도 있다. 그러므로 본 논문에서는 ROI를 지정한 후 입력되는 영상에 가우시안 스무딩(Gaussian Smoothing) 필터를 적용한다. 또한 주변 환경의 변화에 의해서 배경화면이 항상 일정할 수는 없다. 이에 가중치를 이용해서 이동평균을 계산해야 한다. 가중치  $\alpha$ 를 이용한 차분영상의 공식은

$$d(x,y) = (1-\alpha) \times d(x,y) + \alpha \times s(x,y) \quad (1)$$

와 같이 나타낼 수 있다. 여기서  $d(x,y)$ 는 이동평균영상이고  $s(x,y)$ 은 현재의 입력영상이다.  $\alpha$ 가 0에 가까우면 과거의 이동평균 영상에 가중치가 높아진다. 반대로 1에 가까우면 현재의 입력영상을 중요하게 생각하는 것이다. 본 논문에서는 주변 환경의 변화에 강인하기 위해서  $\alpha$ 값을 0에 가깝게 설정한다. 최종적으로 가중치  $\alpha$ 를 통해서 계산한 차분영상이 95% 이상의 변화율을 가진다면 차량의 입출입으로 인식한다. 입출입이 인식되면 입력영상을 PNG 이미지로 저장한다.

### III. 차량 번호판 검출

차량 번호판은 직사각형 형태로 불변하다는 특징이 있다. 그러므로 형태학적 특징을 이용한다면 번호판을 검출할 수 있다. 본 논문에서는 형태학적 특징을 찾기 위해서 저장한 PNG 이미지에 수정한 Canny 에지(Edge) 검출기를 사용한다. 기존의 Canny 에지 알고리즘에서 수정한 점은 영상에서 세로 에지만을 검출한다는 것이다[2]. 세로 에지만 검출하기 위해 마스크  $G_y$ 를

$$G_y = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (2)$$

와 같이 설계한다. 에지를 그리기 위한 그래디언트 방향  $s(x,y)$ 은

$$D(x,y) = \arctan(d_x/d_y) \quad (3)$$

와 같고 그래디언트  $\nabla f$ 는

$$\nabla f = \left( \frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right) = (d_x, d_y) \quad (4)$$

와 같이 나타낼 수 있다. 에지 강도  $s(x,y)$ 는

$$S(x,y) = \sqrt{d_x^2 + d_y^2} \quad (5)$$

와 같이 구할 수 있다. 이렇게 구한 세로방향 에지는 두께가 두껍다. 그러므로 비최대 억제를 적용하여 얇은 두께의 에지 맵을 만든다. 이후 두 개의 임계값  $T_{low}$ 와  $T_{high}$ 를 사용하는 이력 임계값을 적용하여 거짓 긍정을 제거한다. 여기서 거짓 긍정이란 노이즈로 인하여 실제로 에지가 아닌데 에지로 판정되는 경우를 말한다.

차량 번호판은 다른 물체와 달리 길이가 가로 방향으로 길다. 그러므로 세로 에지만 검출된 이진 이미지에 가로 방향의 모폴로지를 수행하면 번호판을 하나의 영역으로 묶을 수 있다. 인접한 객체를 이어지게 해야 하므로 닫힘 연산의 모폴로지를 수행한다. 닫힘 연산의 모폴로지는

$$f \bullet S = (f + S) - S \quad (6)$$

와 같이 팽창(Dilation) 연산으로 객체가 확장되고 내부의 빈 공간이 채워진 후에 침식 연산(Erosion)으로 원래의 크기로 축소되어 인접한 객체를 연결한다. 여기서 팽창과 침식 연산은

$$f + S = \bigcup_{x \in f} S_x, \quad (7)$$

$$f - S = \bigcap_{x \in f} S_x, \quad (8)$$

와 같다. 모폴로지 닫힘 연산을 수행한 후 번호판의 후보 이미지들을 구하기 위해서 객체들의 외곽선을 찾고 이를 포함하는 사각형 영역을 검출한다.




Fig. 3. Korean License plate specification.

그림 3. 한국 차량 번호판 규격

번호판은 도로교통법에 따라 그림 3과 같이 1.1:5.2의 종횡비 규격을 가지고 있다. 이에 검출된 사각형의 종횡비와 면적을 계산한다. 종횡비와 면적 규격에 일치한 사각형 객체들만 번호판 후보 이미지들로 판별된다. 판별된 번호판의 후보 이미지들은 카메라와 차량의 위치, 렌즈 화각 등 내외부적인 요인에 의해서 이미지가 왜곡될 수 있다. 그러므로 정규화 과정과 왜곡 보정을 통해서 번호판의 검출률을 높일 필요가 있다. 본 논문에서는 왜곡 보정을 위해서 Affine 변환을 사용한다. Affine 변환은

$$\begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \alpha & 0 \\ 0 & \beta \\ 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} 10t_x \\ 01t_y \\ 001 \end{bmatrix} \quad (9)$$

와 같이 표현할 수 있다. 여기서  $\alpha$ 와  $\beta$ 는 크기 조정 행렬이고  $\sin\theta$ 와  $\cos\theta$ 는 회전 행렬이다.  $t_x$ 와  $t_y$ 는 평행이동 행렬이다. 번호판 후보 이미지들의 회전각과 중심좌표를 식 8에 대입해서 그림 4와 같이 왜곡된 이미지를 보정한다.




Fig. 4. Affine transformation of License plate.  
그림 4. 차량 번호판의 Affine 변환

Affine 변환과 정규화 과정을 거친 후보 이미지들 중에서 차량 번호판 이미지를 최종적으로 선출한다. 본 논문에서는 선형 SVM을 선출 알고리즘으로 사용한다. SVM은 그림 5와 같이 데이터 그룹

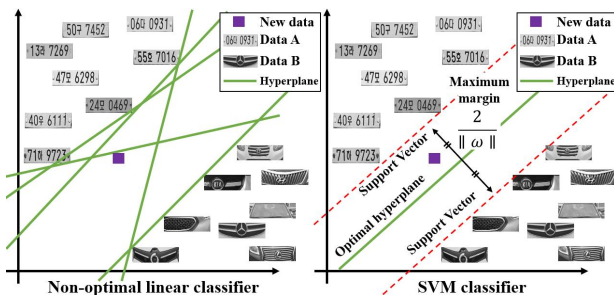


Fig. 5. Non-optimal linear classifier and SVM classifier.  
그림 5. 비최적 선형 분류기 및 선형 SVM 분류기

간에 최대의 거리 마진(Margin)을 갖는 초평면(Hyperplane)으로 분류하는 알고리즘이다[2].

서포트 벡터들 사이의 거리 마진은

$$margin = \frac{2d(x)}{\|W\|} = \frac{2}{\|W\|} \quad (10)$$

와 같이 구할 수 있으며 최대 마진을 갖는 초평면을 찾는 것은 조건부 최적화 문제로

$$\max \frac{2}{\|W\|} \rightarrow \min \frac{1}{2} \|W\|^2 \quad (11)$$

와 같이 나타낼 수 있다. 여기서  $W$ 는 초평면에 수직인 법선 벡터이고 서포트 벡터는 결정 영역까지의 가장 가까운 데이터들을 의미한다.  $d(x)$ 는  $W^T X^+ + b - (W^T X^- + b)$ 이고  $b$ 는 바이어스이다.  $X$ 는 초평면에서의 점이다.

사전에 지도학습을 통해서 최대 마진을 갖는 SVM의 파라미터를 찾는다. 이후에는 후보 이미지들을 입력하여 번호판을 최종적으로 검출한다.

#### IV. 숫자 및 문자 인식

일반적으로 차량 통행 관계 시스템은 야외에 설치되어 있으므로 외부환경에 많은 영향을 받는다. 이에 최종적으로 검출한 차량 번호판 이미지에서 글자와 숫자를 인식하기 위해서는 이진화와 영역 분할의 전처리 과정이 필요하다. 본 논문에서는 외부환경에 강인하기 위해서 일반적인 Otsu 방법의 이진화가 아닌 적응형 이진화 알고리즘을 사용한다. 입력된 영상 전체에 대해서 임계값을 설정하는 Otsu 방법과 달리 적응형 이진화는 주변의 이웃 화소값에 따라서 임계값이 결정된다. 이에 그림 6과 같이 그림자가 드리워진 번호판 이미지에 강인하다. 적응형 이진화의 임계값은

$$T(x,y) = \frac{1}{n} \sum_{x_i} \sum_{y_i} I(x+x_i, y+y_i) - C \quad (12)$$

와 같이 표현할 수 있다. 여기서  $n$ 은 주변 영역의 크기이고  $C$ 는 상수이다. 주변 영역의 크기  $n \times n$ 과 상수  $C$ 를 설계하는 것에 따라서 적응형 이진화의 성능이 달라진다.




Fig. 6. Otsu and adaptive threshold.  
그림 6. 외부 환경에 강인한 적응형 이진화 알고리즘

번호판 이미지에 적응형 이진화를 적용한 다음에는 숫자와 문자 객체를 검출하여 영역분할을 수행한다. 객체 검출과 영역을 분할하는 방법으로는 번호판 규격을 이용하는 알고리즘, 윤각선 검출을 이용하는 방법, 신경망 알고리즘 등 다양하게 있다 [4-7]. 본 논문에서는 히스토그램을 이용해서 객체를 검출하고 분할한다.

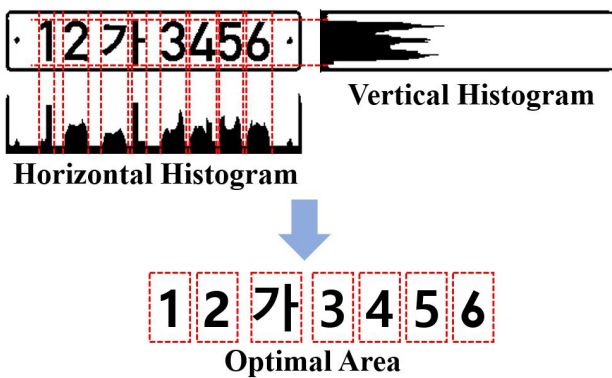


Fig. 7. Individual division of number and letter.  
그림 7. 숫자와 문자의 개별 영역분할

번호판 이미지의 수평과 수직 영역의 히스토그램을 나타내면 그림 7과 같다. 수직 방향의 상하부분에는 번호판 테두리가 있으므로 히스토그램의 값이 크다. 수평 방향의 경우에는 양끝에 번호판 테두리가 있으므로 히스토그램 값이 크다. 반대로 번호판을 고정시키는 볼트부분은 히스토그램 값이 작다. 이러한 특징을 이용해서 적절한 임계값을 설정하면 번호판의 테두리와 볼트부분을 제거할 수 있다. 이후 영역분할을 통해서 개별 객체로 검출한다. 이때 번호판의 오염으로 영역분할의 정확도 낮



Fig. 8. Skeletonization processing result.  
그림 8. 골격화 처리 결과

아 질 수 있으므로 개별 객체의 중첩비와 면적을 계산해서 검증하여 검출한다.

영역분할을 통해서 얻은 개별 객체의 이미지에 그림 8과 같이 골격화를 수행한다. 인식하는 과정에서 객체의 두께는 방해요소가 될 수 있기 때문이다. 객체의 연결성은 유지하고 선으로 표현하는 세션화 과정은

$$A \ominus kB = ((A \ominus B) \ominus B) \dots \ominus B, \quad (13)$$

$$S_k = (A \ominus kB) - (A \ominus kB) \circ B, \quad (14)$$

$$S(A) = \bigcup_{k=1}^K S_k(A) \quad (15)$$

와 같이 구할 수 있다. 여기서  $A$ 는 입력 영상이고  $k$ 는 수행 횟수를 의미한다.  $B$ 는 형태소이다. 객체의 두께가 1을 가지도록 반복 수행한다.

세션화 처리 후 객체 이미지의 인식률을 높이기 위해서  $28 \times 28$  크기의 이미지로 정규화 과정을 거친다. 이후 CNN을 수행하여 최종적으로 이미지를 인식한다. 그림 9는 번호판의 숫자와 문자를 인식하기 위해서 설계한 CNN 구조를 나타낸다.




Fig. 9. CNN structure designed for license plate recognition.  
그림 9. 번호판 인식을 위해 설계한 CNN 구조

설계한 CNN의 첫번째 컨벌루션 층에서는 입력되는 객체 이미지에  $5 \times 5$  커널을 적용하여 컨벌루션 연산을 수행하고 총 64개의 필터를 적용하여 특징 맵을 추출한다. 스트라이드(Stride)는 1이다. 여기서 스트라이드는 커널이 움직이는 간격을 의미한다. 일정한 간격으로 커널이 순회하며 컨벌루션을 수행한 특징 맵은 입력 이미지보다 크기가 작다. 특징 맵이 작아지게 되면 입력 이미지의 정보가 소실될 수 있으므로 사전에 패딩(Padding)을 통해서 보완한다. 본 논문에서는 입력 이미지의 가장자리 부분에 0을 채워 넣는 방식의 제로 패딩(Zero Padding)을 사용한다.



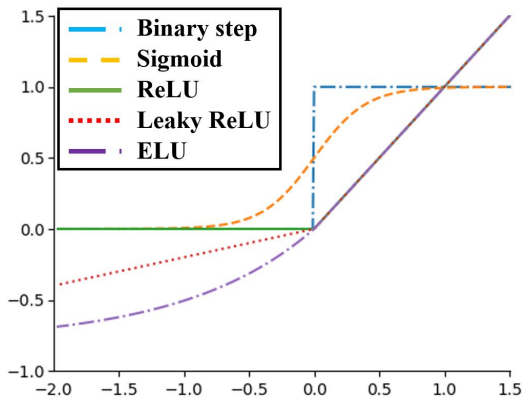


Fig. 10. Activation function comparison graph.  
그림 10. 활성화 함수 비교 그래프

필터를 통해서 특징 맵이 추출되면 그림 10과 같은 활성화 함수들을 적용하여 활성화 맵을 구한다. Binary step 활성화 함수의 경우에는 0과 1의 값만을 가지므로 이진 분류만을 수행하는 단점이 있다. Sigmoid의 경우에는 0과 1사이의 값을 가질 수 있지만 양쪽 끝으로 다가갈수록 기울기가 0으로 수렴하여 학습이 잘 안되는 단점이 있다. 이점을 극복하기 위한 활성화 함수로는 ReLU(Rectified Linear Unit)가 있다. ReLU는 양수일 때 기울기가 1이어서 기존에 0으로 수렴하는 문제점을 해결하였으나 음수일 때 기울기가 0이라는 것이 단점이다. 이를 해결하기 위해서 음수일 때 기울기가 0이 아닌 ELU (Exponential Linear Unit)함수와 Leaky ReLU 함수도 있다.

활성화 맵을 구한 후에는 두번째 단계인 풀링 (Pooling) 층으로 이동한다. 풀링은 차원을 축소하는 것으로 연산량을 감소시키는 장점과 이미지에 서 특징이 강한 것만을 추출시키는 특징 선별 효과를 가지고 있다. 풀링의 종류로는 그림 11과 같이 최대값, 최소값, 평균값 풀링 등이 있다. 본 논문에서는 최대값 풀링과 ELU 활성화 함수를 사용한다.




Fig. 11. Pooling method comparison.  
그림 11. 풀링 기법 비교

컨볼루션과 풀링 층을 반복해서 추출한 특징들로 객체 이미지를 분류하기 위해서는 차원을 줄이는 단계가 필요하다. 이에 플랫튼(Flatten) 층을 통해서 3차원 데이터를 1차원 배열로 변환해준다. 이후 완전연결(FC:Fully-connected) 층으로 이동하여 1차원 배열 전체를 심층 신경망으로 연결하고 소프트맥스(Softmax)를 통해서 객체 이미지를 분류한다. 여기서 소프트맥스는 출력값들의 합을 1로 만들어주는 표준화(Normalization) 함수로

$$Softmax(\vec{x})_i = \frac{e^{x_i}}{\sum_{j=1}^j e^{x_j}} \tag{16}$$

와 같이 정의할 수 있다.

설계한 CNN 모델을 가지고 지도학습을 진행할 때에는 신경망의 가중치를 조절해서 학습 데이터에 대한 손실값(Loss)을 최소화하도록 한다. 여기서 손실값이란 실제값과 학습한 예측값의 차이를 말한다. 손실값은 손실 함수(Loss Function)로 구할 수가 있다. 일반적으로 손실 함수는

$$H_y(y) = -\sum_i y'_i \log(y_i) \tag{17}$$

와 같은 크로스 엔트로피(Cross Entropy) 함수를 많이 사용한다.  $y'$ 는 참값이고  $y$ 는 모델의 예측값을 의미한다. 최적화(Optimizer) 함수를 이용해서 손실값을 최소화하는 가중치와 편향값을 구할 수가 있다. 최적화 함수로는 SGD, NAG, Adam, Momentum 등 다양한 알고리즘이 있다. 본 논문에서는 Adam을 사용한다. Adam의 경우에는  $L_2$  norm 기반의 Unbiased 된 Expectation의 형태로 학습률(Learning rate)을 조절한다. 여기서 학습률은 하이퍼파라미터(Hyperparameter)로 설정하는 값에 따라 지도학습의 속도와 신경망 성능에 영향을 미친다. 값이 너무 크면 최적의 손실값을 못 찾고 반대로 값이 너무 작으면 학습 속도가 매우 느려진다. 시행 착오법(Try and error method)으로 학습률 값을 동조(Tuning)한다. 신경망을 학습시킬 때에는 과소적합(Underfitting)과 과대적합(Overfitting)을 조심해야한다. 과소적합은 모델의 특징에 대해 학습을 최적화하지 못했을 때 발생된다. 이는 하이퍼파라미터의 값을 줄이고 조기종료 시점까지 충분히 학습시키면 해결할 수 있다. 또한 파라미터가

많고 복잡한 모델을 선택하면 된다. 반대로 과대적합의 경우에는 학습 데이터에 대해서만 특화된 특징을 가져서 일반화 성능이 떨어지는 것을 의미한다. 이를 해결하기 위해서는 더 많은 학습 데이터를 모으는 방법과 학습 데이터의 잡음을 줄이는 방법 그리고 정규화 방법이 있다. 정규화 방법에는 드롭아웃(Dropout)과  $L_2$  일반화 등 다양한 알고리즘이 있다[8].




Fig. 12. Neural network using dropout method.  
그림 12. 드롭아웃 방법을 이용한 신경망

본 논문에서는 과대적합을 해결하기 위해서 정규화 방법으로 드롭아웃(Dropout)을 사용한다. 드롭아웃은 그림 12와 같이 일정한 확률로 노드들을 사용하지 않는 방법으로 과대적합을 해결해준다. 학습 과정에서만 노드들을 일정한 확률로 사용하지

않으며, 학습이 완료된 후에는 끊어진 망들을 모두 연결해서 사용한다.

Table 1. ehicle traffic control system specification.

표 1. 차량 통행 관제 시스템 사양

Device	Component	Specification	
Camera	Resolution	1980 × 1080 (30FPS)	
	lens & iris	26mm f/1.7	
	Angle of view	80°	
Vehicle traffic control system	CPU	Intel i7-8700K	
	GPU	GTX 1080 TI	
	RAM	DDR4 32GB	
	Development Tool		OpenCV 3.4.2
			Python 3.4.2
		Tensorflow 2.0	

V. 실험 결과

제안한 알고리즘을 구현한 차량 통행 관제 시스템의 사양은 표 1과 같다. 43,221장의 차량 번호판 이미지를 이용해서 설계한 CNN 알고리즘을 지도 학습하고 테스트한다. 차량 번호판 이미지는 날씨와 상관없이 오전 10시부터 오후 5시까지의 시간대에 수집했다. 그림 13은 차량 통행 인식과 번호판

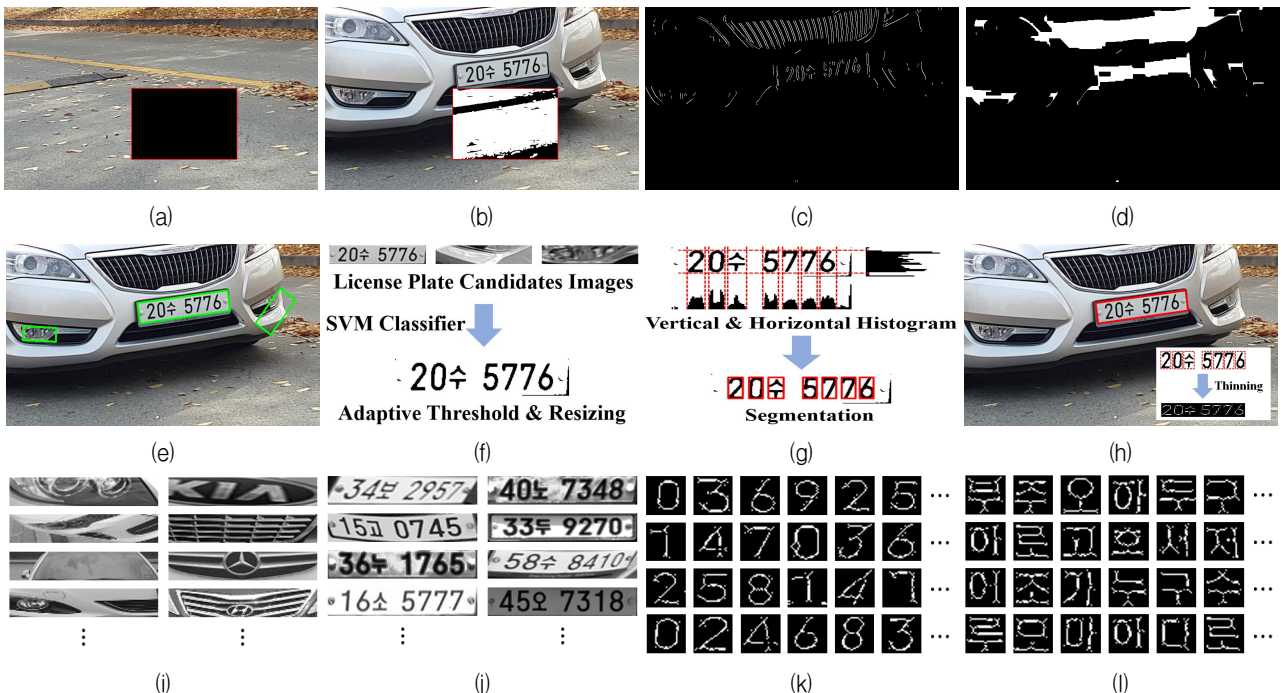


Fig. 13. Experimental results of vehicle recognition and license plate detection and recognition.  
그림 13. 차량 인식과 번호판 검출 및 인식 실험 결과

검출 및 인식의 실험 결과를 나타낸다. (a)와 같이 우측하단에 ROI를 지정했다. 지정한 ROI에서 이동 평균 차분 영상을 구한다. 95%이상의 변화율이 감지되면 차량이 통행하는 것으로 간주했다. 여기서 이동평균의 가중치  $\alpha$  값은 0.001이다. (b)는 차량의 통행을 인식한 결과 이미지이다. 입출입이 인식되면 카메라 영상을 이미지로 저장한다. 이후 5×5 가우시안 블러를 적용해서 노이즈를 제거하고 왜곡을 보정한다. (c)는 번호판 특성에 맞게 수정한 Canny 알고리즘을 수행한 결과로 세로 에지만을 검출한다. 이후 가로 방향의 모폴로지를 수행해서 (d)처럼 번호판을 하나의 영역으로 묶었다. 모폴로지 연산 후에는 OpenCV의 findContours 함수를 사용하여 객체들의 외곽선을 (e)와 같이 찾았다. 후보 이미지의 왜곡을 보정하기 위해서 Affine 변환을 사용하고 중회비와 SVM을 적용해서 최종적으로 (f)처럼 번호판을 검출한다. 그리고 적응형 이진화 기법으로 번호판에 있는 노이즈를 제거했다. (g)는 번호판 이미지의 수평과 수직 방향의 히스토그램을 구한 결과이다. 영역분할을 이용해서 번호판의 개별 객체를 검출한다. (h)는 개별 객체에 골격화를 수행하고 설계한 CNN을 통해서 번호판을 최종적으로 인식한 결과를 나타낸다. CNN을 학습시킬 때에 정답 레이블의 데이터는 One-hot Encoding 형태로 구성했다. 학습 데이터는 미니 배치(Mini batch) 방식으로 100개씩 적용하였으며 에포크(epoch)는 1000으로 설정했다. 30% 확률의 드롭아웃을 이용해서 학습을 진행한다. 그림 13의 (i)와 (j)는 SVM을 지도 학습하기 위해서 사용한 데이터 집합의 일부이다. (i)는 True 데이터로 차량 번호판 집합이고 (j)는 False 데이터로 비번호판 집합이다. (k)와 (l)은 설계한 CNN을 지도 학습하기 위한 데이터 집합의 일부로서, 세션화된 번호판의 숫자와 문자를 나타낸다. 실험에 사용된 번호판 종류는 비상업용 자가용이다.

본 논문에서는 총 5가지의 알고리즘을 이용해서 성능을 비교한다. 여기서 정확도는 100회를 수행한 평균값이다. 첫번째로 비교한 알고리즘은 K-NN (K-Nearest Neighbor)이다. K-NN은 입력 데이터 주변에 있는 k개수만큼의 다른 데이터와 비교해서 출력값을 결정한다. k값에 따라서 과대적합 또는 과소적합의 문제가 발생한다. 여기서는 k값을 15로 설정했다[2]. 두번째 기법인 테서렉트OCR(Tesseract

Optical Character Recognition)은 구글에서 오픈소스로 제공하는 엔진으로 라이브러리를 통해서 쉽게 구현할 수 있다[9].




Fig. 14. Haar-like feature patterns.  
그림 14. Haar-like feature 무늬

세번째 Haar-like feature는 픽셀을 사용하는 기존 방법들과는 다르게 영역 간의 밝기 차이를 특징으로 분류한다. 그러므로 픽셀을 이용하는 알고리즘들보다도 쉽게 복잡한 형태의 물체를 학습할 수 있고 연산량이 작아서 빠른 검출이 가능하다. 또한 이미지에서 지역적이고 반복적으로 특징을 검출함으로써 검출하려는 객체의 일부분이 가려져도 다른 영역의 특징으로 인해 검출될 수 있다[10]. 그림 14는 실험에 사용한 마스크 무늬이다.




Fig. 15. Recurrent Neural Networks for License Plate.  
그림 15. 번호판 인식을 위한 순환 신경망

네번째로 비교한 방법은 RNN(Recurrent Neural Networks)으로 그림 15와 같은 순환 신경망이다[11]. RNN은 여러개의 셀을 중첩해서 심층 신경망을 만든다. 이에 이미지를 단계별로 구분해서 입력해야 한다. 본 논문에서 사용하는 숫자와 문자 객체의 이미지 크기는 28×28이므로 가로 한 줄의 28픽셀을 한 단계의 입력으로 구분해서 넣는다. 세로도 28줄이므로 총 28단계를 거쳐서 데이터를 입력하게 된다. RNN에서 사용한 학습률은 0.001이며 에포크는 100, 그리고 배치 사이즈는 128이다. 표 2는 성능을 비교한 결과이다.



Table 2. License plate recognition algorithms comparison.  
표 2. 번호판 인식 알고리즘들 비교

Algorithm	Accuracy (%)
K-NN(K-Nearest Neighbor)	89.82
Tesseract OCR	92.58
Haar-like feature	94.92
RNN(Recurrent Neural Networks)	96.87
Proposed CNN	97.57

## VI. 결론

차량 번호판은 고유 식별값을 가지므로 지능형 교통관제 시스템에서 번호판 인식은 가장 중요한 알고리즘 중에 하나이다. 본 논문은 고전적인 영상 처리 기법과 CNN을 융합하여 기존 알고리즘보다 번호판의 인식률을 높였다. 제안한 알고리즘은 기존과 달리 차량 인식에 루프 방식을 사용하지 않기 때문에 유지보수에 용이하다. 번호판 인식의 경우에는 히스토그램을 이용해서 객체의 영역을 분할하고 검출하기 때문에 번호판 규격이 신형으로 변경되어도 인식할 수가 있다. 제안한 알고리즘의 정확도가 97.57%인 이유는 날씨와 시간대 그리고 오염된 번호판으로 인한 것이다. 주변 환경의 광량이 인식률에 영향을 미치며 오염으로 인한 번호판 훼손은 인식의 오류를 불러일으킨다. 향후 연구에서는 오류를 발생시키는 이러한 문제점들을 해결하기 위해서 적외선 카메라를 사용할 것이다. 적외선 LED를 사용하면 야간에도 번호판을 인식할 수 있기 때문이다. 그리고 번호판의 오염으로 인해서 온전한 정보를 가지지 못한 객체를 추정하는 알고리즘 또한 추가하여 인식률을 향상시킬 예정이다.

## References

- [1] S. Sheik Mohammed Ali, Bobby George, Lelitha Vanajakshi, "An Efficient Multiple-Loop Sensor Configuration Applicable for Undisciplined Traffic," *IEEE Transactions on Intelligent Transportation Systems*, vol.14, no.3, pp.1151-1161, 2013. DOI: 10.1109/TITS.2013.2255038
- [2] Jung-Hwan Kim, Sun-Kyu Kim, Sanghyuk Lee, Tae-Min Lee, Joonhong Lim, "License plate detection and recognition algorithm for vehicle black box," *2017 International Automatic Control Conference*, 2017. DOI: 10.1109/CACS.2017.8284273
- [3] Zied Selmi, Mohamed Ben Halima, Adel M. Alimi, "Deep Learning System for Automatic License Plate Detection and Recognition," *14th IAPR International Conference on Document Analysis and Recognition*, pp.2379-2140, 2017. DOI: 10.1109/ICDAR.2017.187
- [4] SeungHyun Park, Seongwon Cho, "A Car Plate Area Detection System Using Deep Convolution Neural Network," *Smart Media Journal*, vol.5, no.1, pp.15-23, 2016. DOI: 10.9717/kmms.2017.20.8.1166
- [5] Byeong-jun Kim, Dong-hoon Kim, Joonwhoan Lee, "An Improved License Plate Recognition Technique in Outdoor Image," *Journal of Korea Multimedia Society*, vol.26, no.5, pp.423-431, 2016. DOI: 10.5391/JKIIS.2016.26.5.423
- [6] Yun Yang, Donghai Li, Zongtao Duan, "Chinese vehicle license plate recognition using kernel-based extreme learning machine with deep convolutional features," *IET Intelligent Transport Systems*, vol.12, no.3, pp.213-219, 2018. DOI: 10.1049/iet-its.2017.0136
- [7] Yunju Jeong, Israfil Ansari, Jaechang Shim, Jeonghwan Lee, "A Car Plate Area Detection System Using Deep Convolution Neural Network," *Journal of Korea Multimedia Society*, vol.20, no.8, pp.1166-1174, 2017.
- [8] Ian Goodfellow, Yoshua Bengio, Aaron Courville, *Deep Learning-Adaptive Computation and Machine Learning*, MIT Press, 2016.
- [9] Rahul R. Palekar, Sushant U. Parab, Dhruvil P. Parikh, Vijaya N. Kamble, "Real time license plate detection using openCV and tesseract," *2017 International Conference on Communication and Signal Processing*, pp.2111-2115, 2017. DOI: 10.1109/ICCSP.2017.8286778
- [10] Kuan Zheng, Yuanxing Zhao, Jing Gu, Qingmao Hu, "License plate detection using Haar-like features and histogram of oriented gradients," *2012 IEEE International Symposium on Industrial*

*Electronics*, pp.1502-1505, 2012.

DOI: 10.1109/ISIE.2012.6237313

[11] Jingjing Zhang, Yuanyuan Li, Teng Li, Lina Xun, Caifeng Shan, "License Plate Localization in Unconstrained Scenes Using a Two-Stage CNN-RNN," *IEEE Sensors Journal*, vol.19, no.13, pp.5256-5265, 2019.

DOI: 10.1109/JSEN.2019.2900257

## BIOGRAPHY

### Jung-Hwan Kim (Member)



2013 : BS degree in System Control Engineering, Hoseo University.

2015 : MS degree in Electronic Systems Engineering, Hanyang University.

2016~current : PhD degree course in Electronic Engineering, Hanyang University.

### Joonhong Lim (Member)



1979 : BS degree in Electronic Engineering, Seoul National University.

1981 : MS degree in Electrical Engineering, KAIST.

1986 : PhD degree in Electrical and Computer Engineering, University of Iowa.

1986~1989 : Assistant Professor, Dept. of Electronic Engineering, Korea Aerospace Univ.

1989~current : Professor, Dept. of Electronic Engineering, Hanyang Univ.