논문 2013-50-8-23

SIFT와 신경망을 이용한 학습 기반 차량 번호판 검출

(Learning-based Detection of License Plate using SIFT and Neural Network)

홍 원 주*, 김 민 우*, 오 일 석**

(Won Ju Hong, Min Woo Kim, and Il-Seok Oh[©])

요 약

차량 번호판 검출의 기존 연구들은 대부분 높은 성능을 얻기 위해 영상 획득 환경을 제한한다. 본 논문은 제약사항이 적은 환경에서 다양한 종류의 차량 번호판을 검출하기 위해 SIFT와 신경망을 이용한 새로운 방법을 제안한다. SIFT는 영상의 크기, 회전 변화에 불변하는 지역특징으로서 처리해야 할 환경이 고정되지 않은 경우에도 분별력이 뛰어나다. 영상에서 추출한 SIFT를 번호판 내부의 것(내부 부류)과 외부의 것(외부 부류)으로 나누어 2부류 분류기를 학습한다. 분류기는 신경망을 사용하며, 찾고자 하는 번호판의 종류를 학습 집합에 포함하는 것으로 다양한 종류의 번호판을 동일한 알고리즘으로 검출할 수 있다. 제안하는 방법은 입력 영상에서 지역특징을 추출하고 미리 학습한 분류기로 번호판 내부 부류를 가려낸다. 분류기의 성능이 높지 않더라도 분류 결과 내부 부류는 번호판 내부에 밀집하여 나타나고 번호판 외부에서는 흩어져 나타난다. 이러한 특성을 이용해 지역특징 맵을 만들고, 이 맵에서 임계값 이상인 전역 최댓값을 번호판 영역으로 검출한다. 다양한 환경에서 데이터 베이스를 수집하고 지역특징 분류와 번호판 검출 알고리즘을 실험한다. 지역특징을 분류기로 분류한 결과 정인식률은 97.1%, 정확률은 62.0%, 재현율은 50.2%를 보였다. 정인식률에 비해 정확률과 재현율은 낮았지만, 번호판 검출 결과 98.6%의 높은 검출 성능을 보였다.

Abstract

Most of former studies for car license plate detection restrict the image acquisition environment. The aim of this research is to diminish the restrictions by proposing a new method of using SIFT and neural network. SIFT can be used in diverse situations with less restriction because it provides size- and rotation-invariance and large discriminating power. SIFT extracted from the license plate image is divided into the internal(inside class) and the external(outside class) ones and the classifier is trained using them. In the proposed method, by just putting the various types of license plates, the trained neural network classifier can process all of the types. Although the classification performance is not high, the inside class appears densely over the plate region and sparsely over the non-plate regions. These characteristics create a local feature map, from which we can identify the location with the global maximum value as a candidate of license plate region. We collected image database with much less restriction than the conventional researches. The experiment and evaluation were done using this database. In terms of classification accuracy of SIFT keypoints, the correct recognition rate was 97.1%. The precision rate was 62.0% and recall rate was 50.2%. In terms of license plate detection rate, the correct recognition rate was 98.6%.

Keywords : License Plate, Learning, Local Descriptor, SIFT(Scale Invariant Feature Transform), Neural Network

* 학생회원, 전북대학교 전자정보공학부(컴퓨터공학)

(Division of Electronic & Information Engineering, Chonbuk National University)

** 정회원, 전북대학교 컴퓨터공학부/영상정보신기술연구소

(Division of Computer Science & Engineering, Chonbuk National University)

© Corresponding Author(E-mail: isoh@jbnu.ac.kr)

※ 이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임 (2010-0010737)

접수일자: 2013년1월24일, 수정완료일: 2013년7월24일

I. 서 론

차량 번호판 인식은 번호판의 영역 검출, 개별 문자 분할, 문자 인식의 세 단계로 나눌 수 있다. 이중 첫 번째 단계인 번호판 영역 검출의 성능은 전체 번호판 인식 성능에 큰 영향을 미친다. 이 단계의 난이도를 좌우하는 중요한 요인으로서는 차와 카메라 간의 거리, 각도, 명암, 배경의 복잡도 등이 있다. 이러한 요인을 고정하면 문제가 단순해지는 반면 응용할 수 있는 환경은 크게 제한된다.

기존 연구 동향은 이러한 요인을 고정하고 문제를 폰 사례와 요인을 완화하려고 노력한 사례로 구분할 수 있다. 먼저 고정하여 문제를 단순화한 사례에 대해 설명한다. 이러한 방법으로는 번호판 내부의 수직 에지 비율이 외부보다 높다는 특성을 이용한 방법^[1], 수직과 수평 투영 에지 정보를 이용한 방법, 번호판의 색상 정보를 이용한 방법^[2], 색상 정보를 이용한 방법의 단점을 극복하기 위해 컬러 영상을 명암 영상으로 변환한 방법^[3], 번호판 내부의 큰 숫자 4개의 위치 정보를 이용한 방법^[4] 등이 있다. 또한, 에지와 색상 정보를 이용한 방법^[5], 에지와 형태학적 정보를 이용한 방법, 색상과 명암 정보를 이용한 방법^[6] 등 하나의 정보만을 이용하는 연구에서 하나 이상의 정보를 이용해 고정된 요인을 줄이면서 검출 성능을 높이는 연구로 확장되고 있다. 이러한 연구는 문제에 제약을 가하여 높은 성능을 얻을 수 있지만, 적용 가능한 상황이 제한된다는 단점이 있다. 요즈음은 주행 중인 차량에서 수집한 영상을 대상으로 번호판 인식을 수행하는 응용이 늘고 있어 새로운 접근 방법을 시도하고 있다.

주행 차량에서 수집한 영상은 조명, 크기, 회전, 어파인(affine), 가림(occlusion) 등 다양한 변화를 포함한다. 이 논문이 제안하는 방법은 이러한 영상을 대상으로 한다. 그림 1은 제안하는 방법에 적용이 가능한 영상의 예이다.

다양한 변화를 포함하는 영상에서 번호판을 추출하는 방법들은 SIFT(Scale Invariant Feature Transform)^[7~8]나 MSER(Maximally Stable Extremal Regions)와 같은 지역 특징(local feature)을 주로 사용한다. 지역 특징은 어떤 화소를 중심으로 지역적인 영상 구조에 따라 추출되기 때문에 다양한 변화에 둔감하다. 또한, 실증적인 실험 연구 결과 SIFT와 MSER는

(a) 정면 영상

(b) 회전 변환

(c) 크기 변환

(d) 회전과 크기 변환

그림 1. 제안하는 방법에서 적용 가능한 예

Fig. 1. Images the proposed method can process.

매우 높은 반복성(repeatability)을 제공해준다^[9]. 지역 특징을 활용하여 번호판 인식을 시도한 기존 방법을 매칭 방법과 학습 방법으로 나누어 기술한다.

매칭을 이용한 방법으로는 Iqbal^[10], Kim^[11] 등이 있다. Iqbal은 차량 모델을 식별하기 위해 전역특징과 SIFT를 제약사항이 많은 상황과 적은 상황에 대해 비교 실험을 했다. 입력 영상에서 SIFT를 추출한 후 템플릿 영상에서 추출된 SIFT와의 매칭을 통해 차량 모델을 식별한다. Kim은 교통표지판 인식을 위해 SIFT를 이용했다. 인식 속도와 정확도의 개선을 위해 전처리과정에서 모양과 색상으로 후보 영역을 제한한다. 그 후 입력 영상에서 SIFT를 추출하고 템플릿 집합의 영상들과 매칭을 통해 교통표지판을 인식한다. 이러한 매칭 기반 방법은 인식해야 할 대상 템플릿을 수집해야 하는 부담이 있고, 번호판 추출 문제의 경우 모든 숫자 조합을 템플릿으로 수집하는 것은 불가능하다. 또한 하나의 입력 영상에 대해서 모든 템플릿 영상과 매칭하기 때문에 템플릿 집합이 많아지거나 영상이 복잡해질수록 매칭 시 많은 시간을 소요하는 단점이 있다.

학습을 이용한 방법으로는 Ho^[12], Lim^[13], Yang^[14] 등이 있다. Ho는 번호판 검출을 위해 Adaboost와 SIFT-SVM을 이용했다. 입력 영상에서 후보 윈도우(sub-window)와 Adaboost를 이용해 문자 후보 영역을 찾고 SIFT-SVM을 이용해 문자 영역을 결정한다. 이 문자 영역들을 이용해 번호판을 검출한다. 이 방법은

다양한 윈도우 크기로 입력 영상을 탐색하기 때문에 계산량이 많다. Lim은 번호판 문자 검출을 위해 MSER와 SIFT를 이용했다. 입력 영상에서 MSER를 이용해 문자 후보 영역을 구하고 휴리스틱 필터를 이용해 문자가 아닌 영역을 제거한다. 남은 후보 영역에서 SIFT와 SVM을 이용해 최종 문자 영역을 결정한다. Yang은 번호판 영역을 찾기 위해 SIFT와 SVM을 이용했다. 입력 영상에 에지 연산과 모폴로지 연산을 이용해 후보 영역을 찾고 같은 크기로 정규화한다. 이 영역에서 SIFT를 추출하고 이를 수직과 수평으로 투영한 히스토그램, 정규화 영역을 수직으로 투영한 히스토그램을 SVM의 특징으로 이용해 번호판 영역을 찾는다. 이러한 학습 기반 방법에서는 먼저 후보 영역을 찾고 이 영역에서 SIFT를 추출하고 분류기를 이용해 번호판을 찾는다. 따라서 후보 영역을 찾는 알고리즘을 별도로 개발해야 하는 부담뿐 아니라, 이 과정의 성능이 전체 시스템의 성능에 영향을 미치는 문제점을 안고 있다.

본 논문은 후보 영역을 찾을 필요 없는 학습 기반 번호판 검출 방법을 제안한다. 제안하는 방법은 학습 집합에서 SIFT를 수집한 후 번호판 내부의 것(내부 부류)과 외부의 것(외부 부류)으로 구분한다. 두 부류로 구분된 SIFT가 2부류 분류기의 학습을 위한 학습 집합이 된다. 이들을 이용하여 다층 퍼셉트론^[15]을 학습한다. 번호판 검출 과정은 그림 2를 통해 설명한다. 새로운 영

그림 2. 번호판 검출 과정
Fig. 2. License plate detection process.

상이 들어오면, 그림 2(a)와 같이 SIFT를 추출하고, 그것들을 그림 2(b)와 같이 신경망으로 내부 부류와 외부 부류를 분류한다. 분류 결과를 이용해 그림 2(c)와 같이 지역특징 맵을 만든 후, 내부 부류로 판정된 SIFT가 밀집한 곳을 그림 2(d)와 같이 번호판 영역으로 최종적으로 결정한다. 이처럼 제안한 방법은 특징으로 SIFT를 사용하고 분류를 위해 신경망을 사용하였다. 전처리 및 후보 영역 추출 단계를 배제하였으므로, 번호판 추출 문제를 순수한 학습 문제로 다룰 수 있게 되었다.

II장에서는 제안하는 방법인 SIFT와 신경망을 사용한 번호판 검출 알고리즘을 설명한다. III장에서는 실험에 사용된 데이터베이스와 분류기, 그리고 지역특징 분류 결과와 번호판 검출 결과를 살펴본다. IV장에서 결론과 향후 연구를 제시한다.

II. 번호판 검출 알고리즘

제안하는 방법은 그림 3과 같이 학습 집합을 이용한 신경망 학습과정과 입력 영상에서 추출된 지역특징의 분류 결과를 이용한 번호판 검출과정으로 나눠 설명한다.

그림 3. 제안하는 방법의 순서도
Fig. 3. The flowchart of our proposed approach.

1. 지역특징 분류

영상에서 지역특징을 추출하면, 그 특징이 번호판 내부 부류인지를 신경망이 결정한다. 신경망은 다층퍼셉트론을, 학습은 오류 역전파 알고리즘을 사용한다.

먼저 신경망 학습을 위해 학습 집합을 수집한다. 그림 4(a)와 같이 번호판 영역을 결정하기 위해 사각형의 네 꼭짓점 좌표를 지정한다. 이때 번호판 테두리 부근의 변화를 배제하고 문자 근처에서 추출된 지역특징만을 내부 부류로 사용하기 위해 번호판의 테두리 영역은

(a) 번호판 영역의 정보 (빨간색 사각형)
(b) 번호판 내/외부 지역특징
(노란색 O : 번호판 내부, 빨간색 X : 번호판 외부)

그림 4. 번호판 영역과 내/외부 지역특징

Fig. 4. The license plate area and inside/outside local features.

표 1. 학습 영상에서 추출된 특징 수

Table 1. Features extracted from training images.

부류 \ 집합	내부 부류	외부 부류
학습 집합	24,701	1,301,953
검증 집합	2,744	144,661

제외한다. 영상에서 SIFT를 추출하고 번호판 영역에 속하는 것은 내부 부류로, 번호판 영역에 속하지 않는 것은 외부 부류로 구분한다. 그림 4(b)는 추출된 SIFT를 번호판 내/외부 부류로 구분한 결과이다.

학습을 위해 총 250장의 영상에서 SIFT 특징을 수집했다. 표 1은 학습 영상에서 추출된 특징 수를 표시한 것이다. 일반적으로 자동차가 포함된 영상에서 번호판이 차지하는 영역은 매우 작다. 따라서 표 1에서 볼 수 있듯 추출된 SIFT 대다수는 외부 부류에 속한다. 표 1에서 수집한 특징을 그대로 분류기 훈련에 사용하면 분류기가 외부 부류에 유리한 방향으로 학습되어 거짓 부정(false positive)이 많아지는 학습 집합의 불균형 문제가 발생한다.

이 문제를 해결하기 외부 부류를 부분 추출(sub-sampling)하여 학습 집합 내 외부 부류의 비율을 조절한다. 그림 5의 1배(원본) 그래프는 표 1의 학습 집합만으로 신경망을 학습하고, 검증 집합으로 신경망의 성능을 측정한 결과이다. 0.5배와 0.1배의 그래프는 외

그림 5. 외부 지역특징의 비율에 따른 성능 실험

Fig. 5. Performance evaluation according to the ratios of outside local features.

그림 6. 다층 퍼셉트론의 구조

Fig. 6. Structure of the multi-layer perceptron.

부 부류를 각각 0.5배와 0.1배로 부분 추출하여 학습한 신경망의 성능을 검증 집합으로 측정한 결과이다. 0.5배 일 때 1배와의 성능 차이도 크게 나지 않으며 학습도 안정적으로 이루어지는 것을 확인했으며, 이후 외부 부류를 0.5배로 부분 추출하여 신경망의 학습에 사용한다.

그림 6은 논문에서 사용한 다층 퍼셉트론의 구조이다. 분류기 입력으로 SIFT의 지역 기술자 정보 중 그라디언트 히스토그램만을 사용한다. 그라디언트 히스토그램은 주위 영역을 얼마나 보느냐에 따라 특징의 수가 달라진다. 본 논문에서는 특징벡터의 크기가 128인 것을 사용한다. 은닉 층(hidden layer)은 실험을 통해 50개의 노드로 구성했으며 활성화 함수는 양극 시그모이드를 사용했다. 학습 집합에서 외부 부류를 0.5배로 줄여 새로운 학습 집합을 만들고, 이 집합에서 90%는 분류기를 학습하는 데 사용하고 10%는 분류기의 성능을 평가하는 검증 집합으로 사용한다.

입력 영상이 들어오면 지역특징을 추출하고 그것을 미리 학습시킨 분류기로 내부와 외부 두 부류로 분류

한다. 그림 2(b)는 그림 2(a)의 SIFT를 분류한 결과로 내부 부류로 판정된 SIFT가 번호판 내부에서는 밀집되고, 번호판 외부에서는 흩어져 나타나는 것을 확인할 수 있다.

2. 번호판 검출

이 절에서는 내/외부 부류로 분류된 지역특징을 이용해 지역특징 맵을 생성하고, 이를 통해 번호판을 검출하는 과정에 대해 설명한다.

그림 2(b)는 번호판 외부 영역에 내부 부류로 오분류된 거짓 긍정(false positive)이 존재하지만 밀집도가 낮고, 번호판 내부 영역에 내부 부류로 분류된 참 긍정(true positive)은 밀집도가 높은 것을 확인할 수 있다. 이 특성을 이용해 번호판 영역에서 큰 값을 갖는 지역특징 맵을 생성하고 전역 최댓값을 갖는 영역을 번호판으로 출력한다.

먼저 지역특징 맵을 생성하는 방법을 설명한다. 입력 영상과 같은 크기의 맵을 생성하고 0으로 초기화한다. 내/외부 부류로 분류된 각 지역특징의 위치에 그림 7과 같은 41×41 크기의 내/외부 가우시언 마스크를 누적하여 지역특징 맵을 만든다. 내/외부 가우시언 마스크는 같은 크기와 모양을 가지지만 서로 다른 부호를 가진다. 같은 부류로만 분류된 지역특징이 밀집된 영역은 해당 부류의 특성이 뚜렷하게 나타나고, 일부 오분류된 지역특징이 포함된 경우는 같은 부류로만 밀집된 영역보다 특성이 덜 뚜렷하게 나타난다.

그림 2(c)는 이렇게 생성한 지역특징 맵이다. 그림 2(b)에 거짓 긍정이 존재하지만, 번호판 외부 영역에 외부 부류로 분류된 참 부정(true negative)이 상대적으로 많아 그림 2(c)에서 거짓 긍정의 특성이 도드라지지 않는 것을 확인할 수 있다. 이처럼 지역특징 맵에서는 같은 부류로 분류된 지역특징의 밀집도가 높을수록 해당 부류의 특성이 뚜렷하게 나타나는 점을 이용해 번호판을 검출할 수 있다.

(a) 내부 가우시언 마스크 (b) 외부 가우시언 마스크

그림 7. 내/외부의 가우시언 마스크

Fig. 7. Gaussian mask of inside and outside.

지역특징 맵에서 전역 최댓값을 찾고, 이 값이 임계값 이상일 경우 해당 위치를 번호판으로 검출한다. 그림 2(d)는 검출된 번호판 위치를 빨간색 점으로 나타낸 결과이다. 제안하는 방법은 정확한 번호판의 경계가 아닌, 실제 번호판 내부의 일부 영역을 번호판으로 검출한다. 현재는 한 영상에서 하나의 번호판만을 검출하지만, 추후 연구를 통해 번호판 다수를 동시에 검출하도록 확장할 계획이다.

III. 실험 및 결과

1. 번호판 영상 데이터베이스 수집

실험에 사용한 데이터베이스는 모바일 카메라를 이용해 수집했다. 구형, 신형, 영업용 번호판을 대상으로 한 차량에 대해 정면, 좌측, 우측 영상을 차와 카메라 간의 거리나 각도, 카메라의 높이를 변화시키며 수집했다. 또한, 한 영상에서 번호판 다수를 찾는 향후 연구를 위해 하나 이상의 번호판이 포함되도록 촬영했다. 모바일 카메라의 해상도는 2592×1936 이지만, 실험에서는 1370×1024 로 줄여 사용했다. 그림 8은 데이터베이스의 예이다. 그림 8(a)는 한 차량의 정면, 좌측, 우측을 그림 8(b)는 한 영상에 번호판이 둘 이상 포함된 경우이다.

표 2는 수집한 데이터베이스의 규모와 번호판 수에 따른 영상의 분포를 표시한다. 번호판 수가 학습 집합은 2개, 테스트 집합은 1개일 때 가장 많은 영상이 존재했다. 표 3은 학습 집합에서 번호판의 종류에 따라 번호판 수와 각 번호판에서 추출된 내부 부류 지역특징 수를 표시한 것이다.

(a) 한 차량의 정면, 좌측, 우측 영상

(b) 둘 이상의 번호판을 포함한 영상

그림 8. 수집한 데이터베이스의 예

Fig. 8. Example images in database.

표 2. 데이터베이스 영상에서 차량 번호판 수

Table 2. License plate number of images from the database.

집합	총 영상 수	차량 번호판 수				
		1개	2개	3개	4개	5개
학습	250	82	153	14	1	0
테스트	219	109	88	20	1	1

표 3. 학습 집합의 번호판 수와 지역특징 수

Table 3. License plate number of the training set and the number of local features.

번호판 종류 \ 수	번호판 수	지역특징 수
구형 번호판	218	13,527
신형 번호판	207	13,497
영업용 번호판	9	421

2. 지역특징 분류 결과

표 4는 표 2의 테스트 집합에 대한 지역특징 분류 결과의 혼동 행렬이다. 정인식률(correct recognition)은 97.1%, 정확률(precision)은 62.0%, 재현율(recall)은 50.2%의 결과를 보였다. 이는 외부 부류를 0.5배로 부분 추출한 학습 집합을 사용했지만, 아직도 학습 집합의 부류간 불균형이 심하기 때문이다. 하지만 높은 정인식률과 매우 낮은 거짓 긍정률을 가지는 분류기를 사용하고, 같은 부류의 밀집도가 높을수록 해당 부류의 특성이 뚜렷하게 나타나는 지역특징 맵을 이용해 번호판을 검출하기 때문에 높은 번호판 검출 성능을 기대할 수 있다.

표 4. 지역특징 분류 결과의 혼동 행렬

Table 4. Confusion matrix of local feature classification results.

분류 결과 \ 참 부류	내부 부류	외부 부류	참 부류의 총 지역특징
내부 부류	5,545 (50.2%)	5,505 (49.8%)	11,050 (100%)
외부 부류	3,398 (1.1%)	293,734 (98.9%)	297,132 (100%)

(a) 분류가 잘 된 영상 (번호판이 하나 있는 경우)

(b) 분류가 잘 된 영상 (번호판이 두 개 이상인 경우)

(c) 분류가 잘 되지 않은 영상

그림 9. 테스트 집합의 지역특징 분류 결과

Fig. 9. Local feature classification results of the test image.

그림 9는 번호판 내부 영역의 내부 부류 밀집도를 기준으로 테스트 집합의 지역특징 분류 결과를 구분한 것이다. 그림 9(a)-(b)는 분류가 잘 된 결과로 거짓 긍정과 거짓 부정이 적어 번호판 내부 영역에서 내부 부류의 밀집도가 높게 나타난 경우이다. 대부분의 테스트 영상에서 이와 같은 특성을 보였다. 그림 9(c)는 그림 9(a)-(b)와 반대의 경우로 거짓 긍정과 거짓 부정이 많아 번호판 내부 영역에서의 내부 부류 특성이 뚜렷하게 나타나지 않은 결과를 보인다. 이와 같은 경우는 번호판 검출에 실패할 수 있다.

3. 번호판 검출 결과

3.2절의 지역특징 분류 결과를 이용해 지역특징 맵에서 번호판을 검출한다. 이 영역이 그림 3(a)에서 정의한 번호판 영역에 속하는지를 기준으로 성능을 평가했다. 표 5는 테스트 집합의 번호판 검출 결과이다. 높은 정인식률과 매우 낮은 거짓 긍정률을 가지는 분류기가 번호판 내부 영역에서 내부 부류를 밀집시켜준다. 이 결

표 5. 번호판 검출 결과

Table 5. License plate detection results.

테스트 영상	성공 영상	성공률(%)
219	216	98.6%

(a) 번호판이 한 개인 경우

(b) 번호판이 두 개인 경우

(c) 번호판이 세 개 이상인 경우

그림 10. 번호판 검출 성공 영상

Fig. 10. Successes by the proposed algorithm.

(a) 지역특징 분류 결과

(b) 번호판 검출 결과

그림 11. 번호판 검출 실패 영상

Fig. 11. Failures by the proposed algorithm.

과로 지역특징 맵을 만들어 번호판을 검출하기 때문에 98.6%의 높은 검출 성능을 보였다.

본 논문에서는 한 영상에 존재하는 번호판 수와 관계 없이 하나의 번호판을 검출하는데, 검출 성공 결과는 그림 10을 통해 확인할 수 있다.

그림 11은 번호판 검출에 실패한 경우이다. 지역특징 분류 결과 번호판 내부 영역에 내부 부류가 적고 밀집도가 낮다. 번호판 내부 영역보다 우측의 표지판 영역에서 내부 부류 밀집도가 높아 번호판 검출에 실패했다.

IV. 결 론

본 논문은 지역특징과 신경망을 이용해 영상 획득 환경의 제약사항이 적고, 유형이 다른 번호판에서도 쉽게 적용이 가능한 학습 기반의 번호판 검출 방법을 제안했다. 학습 집합에서 SIFT를 수집하고 번호판 내부 부류와 외부 부류로 나누어 신경망을 학습시켰다. 이후 새로운 영상이 들어오면 SIFT를 추출하여 미리 학습한

신경망으로 내부 부류와 외부 부류를 분류한다. 이때 내부 부류로 판정된 SIFT는 번호판의 내부에 밀집하고 외부에 산재하는 특성을 이용하여 지역특징 맵을 만들고 번호판을 찾는다.

신경망의 지역특징 분류 성능은 정인식률이 97.1%로 높았지만, 부류 간 훈련 집합의 불균형으로 인해 정확률은 62.0%, 재현율은 50.2%를 보였다. 재현율이 낮아 거짓 긍정이 존재하지만, 번호판 외부 영역에는 참부정이 상대적으로 많다. 이 점과 특정 부류의 밀집도가 높을수록 해당 부류의 특성이 뚜렷이 나타나는 지역특징 맵을 통해 최종적으로 번호판 검출 성능은 98.6%로 높았다. 실험을 통해 제안하는 방법이 제약사항이 적은 환경에서 높은 번호판 검출 성능이 보이는 것을 확인했다.

제안하는 방법은 한 영상에서 하나의 번호판만을 검출했지만, 추후 연구를 통해 번호판 다수를 동시에 검출하도록 확장할 계획이다. 또한, 현재는 실제 번호판 내부의 일부 영역을 번호판으로 검출했지만, 이 또한 향후 연구를 통해 정확한 번호판의 경계를 검출할 계획이다.

REFERENCES

- [1] D. Zheng, Y. Zhao, and J. Wang, "An efficient method of license plate location," *Pattern Recognition Letters*, vol. 26, pp. 2431-2438, 2005.
- [2] 전영민, 차정희, "차량번호판 색상모델에 의한 번호판 영역분할 알고리즘," *전자공학회논문지*, 제43권 CI편, 제2호, 21-32쪽, 2006년 3월.
- [3] S. L. Chang, L. S. Chen, Y. C. Chung, and S. W. Chen, "Automatic license plate recognition," *IEEE Transactions on Intelligent Transportation System*, vol. 5, no. 1, pp. 42-53, March 2004.
- [4] 이득용, 오일석, "숫자 인식에 기반한 자동차 번호판 추출," *한국컴퓨터종합학술대회 논문집*, 제34권, 제1호, 407-411쪽, 2007년.
- [5] 김재도, 한영준, 한현수, "에지 기반 영역확장 기법을 이용한 다양한 크기의 번호판 검출," *정보과학회 논문지*, 제36권, 제2호, 122-130쪽, 2009년 2월.
- [6] C. Wu, L. C. On, C. H. Weng, T. S. Kuan and K. Ng, "A macoa license plate recognition system," *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics*, pp. 4506-4510, Guangzhou, China, August 2005.
- [7] D. G. Lowe, "Object recognition from local scale-invariant features," *Proceedings of the Seventh IEEE International Conference on Computer Vision*, pp. 1150-1157, Kerkyra, Greece, September 1999.
- [8] D. G. Lowe, "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91-110, 2004.
- [9] K. Mikolajczyk and C. Schmid, "Scale & affine invariant interest point detectors," *International Journal of Computer Vision*, vol. 60, no. 1, pp. 63-86, 2004.
- [10] U. Iqbal, S. W. Zamir, M. H. Shahid, K. Parwaiz, M. Yasin and M. S. Sarfraz, "Image based vehicle type identification," *International Conference on Information and Emerging Technologies*, pp. 1-5, Karachi, Pakistan, June 2010.
- [11] 김상철, 이제민, 김대운, 낭종호, "검침과 훼손, 회전에 강건한 교통표지판 인식을 위한 SIFT 적용 방법," *한국컴퓨터종합학술대회 논문집*, 제39권, 제1호, 351-353쪽, 2012년.
- [12] W. T. Ho, H. W. Lim and Y. H. Tay, "Two-stage license plate detection using gentle Adaboost and SIFT-SVM," *First Asian Conference on Intelligent Information and Database Systems*, pp. 109-114, Dong Hoi, Vietnam, April 2009.
- [13] H. W. Lim and Y. H. Tay, "Detection of license plate characters in natural scene with MSER and SIFT unigram classifier," *IEEE Conference on Sustainable Utilization and Development in Engineering and Technology*, pp. 95-98, Petaling Jaya, Malaysia, November 2010.
- [14] D. Yang, J. Kong, N. Du, X. Li and X. Che, "A novel approach for license plate localization based on SVM classifier," *2nd IEEE International Conference on Information Management and Engineering*, pp. 655-660, Chengdu, China, April 2010.
- [15] 오일석, *패턴인식*, 교보문고, 110-132쪽, 2008년.

— 저 자 소 개 —

홍 원 주(학생회원)
2010년 전북대학교 전자정보공학
부(컴퓨터공학) 학사 졸업.
2012년 전북대학교 전자정보공학
부(컴퓨터공학) 석사 졸업.
2013년~현재 전북대학교 전자정
보공학부(컴퓨터공학)
박사 과정.

<주관심분야 : 컴퓨터비전, 패턴인식>

김 민 우(학생회원)
2007년 전북대학교 전자정보공학
부(컴퓨터공학) 학사 졸업.
2009년 전북대학교 전자정보공학
부(컴퓨터공학) 석사 졸업.
2009년~현재 전북대학교 전자정
보공학부(컴퓨터공학)
박사 과정.

<주관심분야 : 컴퓨터비전, 패턴인식>

오 일 석(정회원) - 교신저자
1984년 서울대학교 컴퓨터공학과
학사 졸업.
1992년 KAIST 전산학과 박사 졸
업.
1992년~현재 전북대학교 컴퓨터
공학부 교수.

<주관심분야 : 컴퓨터비전, 패턴인식>