

HOG와 인공신경망을 이용한 자동차 모델 인식 시스템 성능 분석

(Performance Evaluation of Car Model Recognition System Using
HOG and Artificial Neural Network)

박기완¹⁾, 방지성²⁾, 김병만^{3)*}

(Ki-Wan Park, Ji-Sung Bang, and Byeong-Man Kim)

요약 본 논문에서는 영상처리와 기계학습을 이용하여 자동차를 판별하는 시스템을 제안하고 그 성능을 확인한다. 차량의 앞면을 인식 하도록 하였으며 앞면을 선택한 이유는 제조사, 모델별로 앞면이 다르고 개조가 힘들기 때문이다. 제안하는 방법은 먼저 학습 데이터로부터 HOG특징을 추출하고, 이 특징 데이터에 대해 인공신경망 학습기법을 적용하여 판별 모델을 구축한다. 그리고 사용자가 자동차의 앞면을 찍으면 그 사진에서 특징점을 추출하고 특징점을 학습된 판별 모델을 거쳐 차량의 정보를 표시한다. 실험 결과, 98%의 높은 평균 인식률을 보였다.

핵심주제어 : 자동차 모델 인식, MLP, HOG, k-NN

Abstract In this paper, a car model recognition system using image processing and machine learning is proposed and its performance is also evaluated. The system recognizes the front of car because the front of car is different for every car model and manufacturer, and difficult to remodel. The proposed method extracts HOG features from training data set, then builds classification model by the HOG features. If user takes photo of the front of car, then HOG features are extracted from the photo image and are used to determine the model of car based on the trained classification model. Experimental results show a high average recognition rate of 98%.

Key Words : Car Model Classification, MLP, HOG, k-NN

1. 서론

자동차 산업의 발전과 사용자의 요구로 현재

수많은 디자인의 자동차가 존재하며, 매년 각기 다른 디자인의 자동차가 출시되고 있다. 또한 특정 차량의 경우 같은 자동차 명이라도 연식에 따라서 디자인이 크게 달라진다. 이렇게 수많은 차량들 속에서 자동차를 구매하려고 하는 사람이 길거리에서 마음에 드는 차량을 발견 했을 경우 또는 교통사고 목격자가 뺑소니 차량의 번호판을 보지 못했을 경우 등의 상황에서는 그 자동차가 어떤 자동차인지 알기가 쉽지 않다. 이와 같은

* Corresponding Author : bmkim@kumoh.ac.kr

† 이 논문은 2016년 금오공과대학교 연구비 지원에 의해 연구되었음.

Manuscript received Sep. 9, 2016 / revised Sep. 26, 2016 / accepted Oct. 27, 2016

1) 금오공과대학교 컴퓨터소프트웨어공학과 제1저자

2) 금오공과대학교 컴퓨터소프트웨어공학과 제2저자

3) 금오공과대학교 컴퓨터소프트웨어공학과 교신저자

필요성에 의하여 차종은 물론 구체적인 모델의 인식에 대한 필요성이 사회 여러 분야에서 꾸준히 제기되어 왔다. 그러나 현재까지 자동차 인식에 대한 연구는 크게 자동차 번호판 인식과 차종(소형, 중형, 대형) 인식 두 가지가 주를 이루었다[1-4].

이에 본 논문에서는 차량 정면에 대한 특징값과 신경망을 이용하여 특정 모델 정보를 인식하는 시스템을 제안하였다. 본 논문에서와 같이 차량 모델을 판별하는 연구들 [5-8]이 있지만, 이 연구들은 CCTV로 차량을 인식하거나 고정된 카메라로 도로 위에서 운행 중인 차량들을 대상으로 했고, 디지털 카메라로 촬영 했더라도 모델 인식을 위해 비지도 학습을 했다는 점에서 본 연구와 다르다.

현재 국내에서 운행되는 대표적인 차량 8대를 선정하여 테스트를 진행 하였으며 차량의 정면을 선택한 이유는 제조사와 차량의 종류, 이름 별로 디자인이 다르다는 것과 개조가 힘들다는 것에 착안하여 차량의 정면을 대상으로 특징점을 추출하기로 결정 하였다. 특징 추출은 조명의 영향을 적게 받으며 국소 영역의 기하학적인 변화에 강한 특징을 가진 것으로 알려진 HOG[9]를 사용하였으며, 추출된 특징은 인공신경망중 하나인 MLP(MultiLayer Perceptron)를 이용하며 미리 특징점을 학습 시켰다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 자동차 판별과 그에 관련된 영상처리, 인공신경망에 대한 기존 연구를 살펴보고, 3장에서는 차량 종류 학습 및 판별이 어떻게 이루어지는지 과정을 나타내며 과정별 상세 설명을 하였다. 4장에서는 3장에 기술한 내용을 기반으로 실험한 결과를 기술하였고, MLP가 아닌 k-NN과의 성능 비교도 기술하였다. 마지막으로 5장에서 결론 및 향후과제에 대하여 기술한다.

2. 관련 연구

차량 정보 추출의 가장 대표적인 연구는 차량 번호판 인식에 관한 연구이다. 김우태와 임길택 [1]은 예지 영상의 방향성분 히스토그램 특징을

이용하여 자동차 번호판 영역을 추출하였고, 박창석 등[2]은 이동 차량에서의 실시간 자동차 번호판 인식을 위해 번호판 영역에서 나타나는 강한 수직 엣지 성분을 이용하여 번호판 후보 영역들을 찾고, 이진화 된 영상에서의 배경과 문자의 구성비를 따져 번호판 영역을 추출하는 방법을 사용하였다. 서병훈 등[3]은 태양의 고도와 차량 구조의 영향으로 그림자가 진 번호판의 이미지를 이진화 했을 경우 생기는 문제점에 대하여, 그림자의 경계선을 파악 한 뒤 그림자가 드리워진 영역과 드리워지지 않은 영역을 구분하여, 각각의 영역을 이진화 하는 방법을 제안 하였다.

또한, 차종(소형, 중형, 대형)과 차량 모델 정보 인식에 대한 연구도 진행되었는데, 이평원[4]은 차량이 없는 배경화면과 차량이 있는 입력화면을 비교하여 차량의 위치를 알아낸 후 모양을 결정하고, 그 모양을 기초로 소형차, 대형차, 오토바이 이 세 종류를 판단했던 기존의 연구들을 개선하여 관측점을 이용해 보다 빠르게 차량의 종류를 알아내는 방법을 제안하였다.

차량 모델 인식에 관한 연구로서 이전에 몇 가지 연구가 진행 되었는데, 하태준[5]은 신피질의 동작원리를 흉내낸 Hierarchical Temporal Memory(HTM) 이론을 기반으로 자동차 인식 시스템을 구현 하고 정확도를 측정 하였다. 이 논문은 비지도학습 방법인 HTM을 사용했다는 점에서 지도학습 방법인 MLP를 사용한 본 논문과 차이가 있다.

이효종[6]은 차량의 정면부 상에서 얻어진 GLCM(Gray Level Co-occurrence Matrix)을 사용하여 질감 특성을 추출 하고, 그 특징 값들을 입력 값으로 받아들이는 신경 회로망을 구성하여 모델 정보에 한 학습을 시킨 후 요청된 차량의 정보를 추출하는 방법을 제안하였다. 학습을 위해 인공신경망을 사용한 것이 본 논문과 같지만, 사용자가 사용할 경우를 가정하여 휴대폰 카메라로 데이터를 수집한 본 논문과 달리 도로상에 설치된 카메라로 차량의 이미지를 획득하였으며, 획득한 이미지에서 질감을 이용하여 특징점을 추출한 것이 본 논문의 데이터 수집 및 특징점 추출 방법과 다르다.

김민호와 최두현[7]은 영상에서 차량의 헤드라

이트만 분리 한 뒤 SURF(Speeded Up Robust Features) 알고리즘을 적용하여 헤드라이트의 특징을 추출 한 뒤 사전에 준비된 여러 차량의 특징 벡터 데이터베이스와 비교하여 차종을 분류했다. 이 연구 또한 이효종의 연구와 같이 고정된 카메라로 주행중인 차량의 이미지를 획득하였다. 특징점 추출에 차량의 앞면을 사용한 본 논문과 달리 차량의 헤드라이트만을 사용하였으며, 다른 기계학습 방법을 사용하지 않고 추출된 특징점을 데이터베이스에 저장된 특징값과 비교한 점에서 본 논문과 차이가 있다.

강우영 등[8]은 입력 영상에서 차량영역을 추출한 후 PCA(Principal Component Analysis)기법을 적용하여 특징벡터를 생성하고, 미리 PCA를 이용하여 분석된 학습 차량들의 3차원 벡터공간 좌표와 유클리디안 거리를 구하여 차량 모델을 인식하도록 하였다. 이 연구는 PCA기법을 이용하여 차원을 축소하고 학습 차량의 좌표상의 점들과의 유클리디안 거리를 계산하여 차량 모델 인식을 시도하였다. 본 논문에서는 특징점 추출에 HOG를 이용하여 이미지의 기울기를 사용하였으나 이 연구는 차량 사진을 이진화 하여 사용하였고, 차량 모델 인식을 위해 인공신경망을 사용한 본 논문과 달리 이 연구는 유클리디안 거리를 계산하여 모델을 인식하였으며, 특징에 대한 차원을 줄여 실시간 인식 시도에 적합함을 연구한 점이 본 논문의 연구와 다르다.

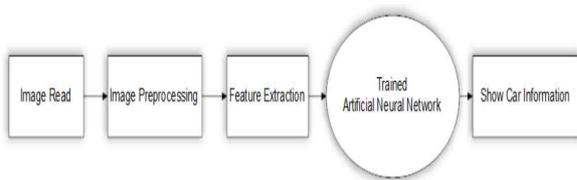


Fig. 1 Process of testing phase

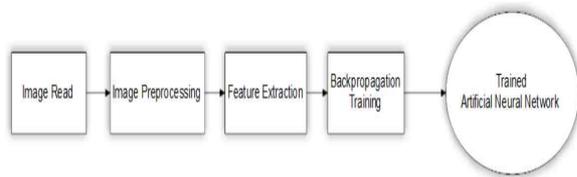


Fig. 2 Process of training phase

3. 차량 종류 학습 및 판별

제안 시스템은 크게 학습 단계, 판별 단계로 나누어지며 학습 단계는 <Fig. 1>, 판별 단계는 <Fig. 2>과 같다. 학습 단계에서는 학습을 위해 준비된 이미지를 읽어 들인 후 전처리를 한다. 전처리 후 특징을 추출하여 그 특징을 인공신경망 역전파 알고리즘으로 학습시키며, 학습된 판별 모델은 판별 단계에서 사용되어 진다. 판별 단계에서는 사용자가 촬영한 사진을 읽어 들인 후 전처리를 한다. 특징 추출 후 그 특징을 기반으로 학습된 인공신경망에서 차량을 판별 한 뒤 차량 정보를 표시 한다.

3.1 전처리

본 논문에서는 학습과 판별 전 특징점을 추출하기 위해 이미지에 대하여 전처리 작업을 실행한다. 전처리 작업은 두 가지를 실행 하는데 첫 번째는 Gray변환 이고, 두 번째는 사이즈 조절이다. 본 논문에서는 사이즈를 256*128px로 설정하였다. 사용자의 휴대폰에 따라서 사진의 해상도가 달라 사용자가 촬영한 사진 그대로 특징점을 추출 할 경우, 특징점의 개수가 달라지기 때문이다. 실험시에는 Gray처리 후에 256*128px로 resize하였다.

3.2 이미지에서의 특징추출

영상에서 차량 모델을 인식하기 위하여 HOG(Histogram of Oriented Gradient)를 사용하기로 하였다. HOG는 Dalal et.al.에 의해 제안된 특징 기술자로, 슬라이딩 윈도우를 기반으로 기울기의 분포를 계산하여 특징을 추출한다. 영상에서의 기울기란 영상 내에서 밝기가 변화하는 방향을 의미한다.

HOG는 영상 내의 지역별 영역의 그라디언트 방향 성분의 발생 빈도를 누적시켜 히스토그램을 생성하며, 배경과 객체간의 대비(Contrast)와 잡음(Noise)에 강인함이 검증되어 있으므로 정확한 객체의 특징 추출을 필요로 하는 분야에 주로 이용된다. 특징 추출 한 것을 이미지화 한 것과 한

부분을 확대 한 것의 예는 <Fig. 3>과 같다.

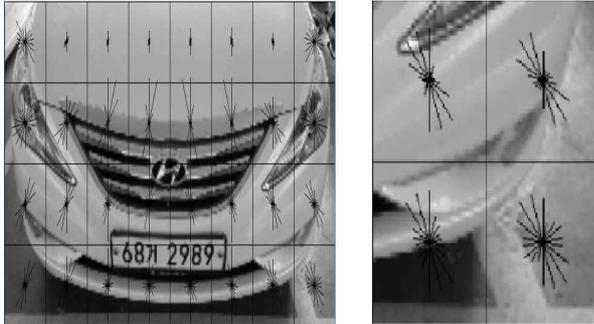


Fig. 3 An example of HOG feature extraction (1 cell=32*32px)

3.3 차량 종류 학습 및 판단

본 논문에서는 특징점에 대한 학습 및 판단을 위해 MLP를 이용한다. MLP는 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 인공신경망으로 단층 퍼셉트론 (Perceptron) 의 여러 가지 단점들을 극복했으며, 대부분 오류 역전파 (Backpropagation) 학습 알고리즘을 사용하여 학습 시킨다[10]. MLP의 예는 <Fig. 4>과 같다. 본 실험에서도 오류 역전파 학습 알고리즘을 사용하여 학습시키며 은닉층 노드의 개수는 100, 200, 300, 400, 500개로 설정하여 실험하였다.

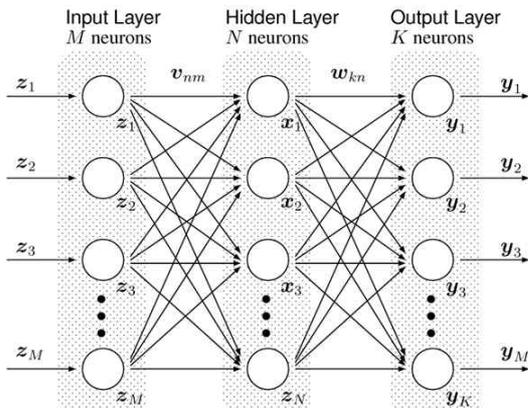


Fig. 4 An example of MLP

4. 성능실험

테스트를 진행 했던 컴퓨터의 사양은 <Table 1>과 같고 테스트를 위한 차량은 총 8종류로 선정했으며 선정된 차종은 <Table 2> 와 같다. 차량에 대한 사진은 차량의 앞면을 각 자동차 종류별로 200장 씩 사용 하였고 이중 100장은 학습 데이터로, 나머지 100장은 테스트 데이터로 사용 하였다. 사용자가 직접 사진을 촬영 했을 경우를 가정하여 모든 사진은 직접 휴대폰으로 촬영 하였으며 두 개의 헤드라이트와 라디에이터가 모두 나오는 범위 안에서 다수의 차량을 여러 각도에서 촬영 하였다. 사진의 제약조건으로는 차량의 앞면에서 두 개의 헤드라이트와 라디에이터가 포함 되어야 하며 헤드라이트와 라디에이터가 포함 된다면 각도는 크게 상관없다. 특징점 추출 전 전처리로 사이즈를 256*128로 축소하기 때문에 해상도는 상관없다. 잡음이나 흔들림 등 인식에 방해가 될 만한 요소들은 최대한 없는 것이 좋다. 수집의 예시는 <Fig. 5>와 같다.



Fig. 5 Examples of collecting data

Table 1 Specification of system for experiments

Type	Specification
Processor	Intel(R) Core(TM) i5-6200U CPU @ 2.30GHz 2.40GHz
Memory	8.00GB
HDD	500GB
OS	Windows 10 Pro

4.1 특징점 추출 셀 사이즈별 비교

인식률 비교를 위해 다양한 방식으로 실험을

Table 2 List of Cars

Car name	Manufacturer
SM5	Renault Samsung Motors
Morning	Kia Motors
Grandeur	Hyundai Motors
K5	Kia Motors
Chevrolet Spark	GM Korea
YF Sonata	Hyundai Motors
NF Sonata	Hyundai Motors
Porter	Hyundai Motors

진행 하였다. 먼저 수집된 영상에 대한 특징점 추출의 경우 HOG의 셀(Cell) 사이즈는 8*8, 16*16, 32*32, 64*64(px) 총 4가지로 실험을 하였고, 블록(Block) 사이즈는 셀 사이즈에 상관없이 64*64px로 고정하여 사용하였으며 블록 이동 간에 겹침은 하지 않았다. 차 종류당 200장을 찍었으므로 총 1600장의 사진에서 셀 사이즈 별로 특징점을 추출하는데 걸렸던 시간과 셀 사이즈 별 특징점의 개수는 <Table 3>과 같다.

Table 3 Computed time of cell size

Cell size (unit:px)	Number of features (256/cell width * 128/cell height * bin)	Computed time
8*8	4608	241s
16*16	1152	25s
32*32	288	11s
64*64	72	10s

또한 설정한 셀 사이즈 별로 인식률의 변화를

확인하기 위하여 MLP에 학습을 시켜 실행하였다. 이때 입력층은 각 특징점의 개수별로 설정 하였으며 은닉층은 모두 100개로 설정 하였고 출력층은 차량 종류 수인 8개로 설정 한 후 MLP를 1000번 반복 학습 시켜 실험 하였다. 각 셀 사이즈별 1000번 학습 시키는데 걸린 시간은 <Table 4>와 같고 인식률 실험 결과는 <Table 5>와 같다.

Table 4 Training time by cell size

Cell size(unit:px)	Trained time of 1000 times
8*8	2773s
16*16	701s
32*32	202s
64*64	54s

4.2 셀 사이즈 별 성능 분석

실험 결과 셀 사이즈 16*16이 평균 인식률 91.5%로 가장 높았다. 정확한 비교를 위해 셀 사이즈 8*8과 16*16을 각각 5번씩 반복 실행 해 본 결과 셀 사이즈 8*8은 인식률이 최소 89.875%에서 최대 91%, 셀 사이즈 16*16의 인식률은 최소 91.375%에서 최대 92.75% 까지 나타났다. 이는 처음 MLP의 가중치 값들이 무작위로 설정 되어 생기는 오차와 상관없이 셀 사이즈 8*8과 16*16의 인식률 차이가 1~2% 난다고 볼 수 있다. 그 이유로 생각 되는 것은 이 실험에서 차량 앞면 데이터를 수집할 때 사용자가 사용 할 때를 가정하여 여러 각도에서 사진을 찍었는데 <Fig.

Table 5 Recognition rate

(unit : %)

	8*8	16*16	32*32	64*64
SM5	100	100	98	92
Morning	91	89	85	5
Grandeur	73	78	76	19
K5	82	89	86	9
Chevrolet Spark	93	94	95	6
YF Sonata	97	95	93	76
NF Sonata	86	93	69	35
Porter	97	94	91	83
Averaged rate	89.875	91.5	86.625	40.625

Table 6 Recognition table of cell size 16*16

(unit : %)

	SM5	Morning	Grandeur	K5	Chevrolet Spark	YF Sonata	NF Sonata	Porter
SM5	100	0	0	0	0	0	0	0
Morning	0	89	0	0	8	0	0	3
Grandeur	0	0	78	1	1	20	0	0
K5	1	0	0	89	5	3	2	0
Chevrolet Spark	0	2	2	0	94	2	0	0
YF Sonata	0	0	0	1	4	95	0	0
NF Sonata	0	1	1	5	0	0	93	0
Porter	2	0	2	1	1	0	0	94

6>와 같이 그때 생기는 여백의 배경과 주차라인 같은 불필요한 정보 까지 셀 사이즈 8*8이 16*16에 비하여 민감하게 인식하여 생기는 오차라고 추정된다. <Table 5>에서 셀 사이즈 16*16에서 그랜저(Grandeur)의 경우 78%로 다른 차량 인식률에 비해 낮다. 셀 사이즈 16*16의 인식표 <Table 6>을 보면 78%는 그랜저로 맞게 인식했지만 20%는 YF 소나타로 인식을 하였다. 조



Fig. 7 2014 Grandeur(Left), 2011 Grandeur (Mid), YF Sonata(Right)



Fig. 6 An Example of worthless space on pictures

사 해본 결과 본 논문의 실험을 위해 수집된 그랜저 사진의 경우 연식에 따라 크게 두 가지 디자인으로 나뉘는데, 그 예는 <Fig. 7>와 같으며 예시에서 왼쪽과 가운데이다. 보는바와 같이 연식에 따라 앞면 라디에이터 디자인이 바뀌는데, 2011그랜저의 경우 같은 제조회사의 차량 중 하나인 YF Sonata와 앞면 모양이 비슷하여 20%의 오인식을 보인 것으로 추정된다. 그러나 학습 데이터 100장 중 12장만이 2011 그랜저였으며 테스트 데이터 100장중 61장이 2011 그랜저 였다. 2011 그랜저의 학습 데이터가 더 많았다면 인식률은 더 높아졌을 것이다.

4.3 은닉층 노드 개수 별 실험 및 성능 비교

4.2절에서 셀 사이즈별 성능을 비교해 보았고, 이번 실험에서는 4.2절에서 인식률이 가장 높았던 셀 사이즈 16*16의 데이터를 가지고 은닉층의 노드 개수에 따라서 인식률의 차이가 있는지 확인하기 위해 노드 개수별로 실험을 진행 하였다.

이 실험에서 입력층은 각 셀 사이즈별 특징점 개수로 설정하였고, 은닉층은 100개, 출력층은 8개 실험하였다. 이 실험에서 입력층은 은닉층과 관계 없이 셀 사이즈 16*16의 특징점 개수인 1152개로 설정하였으며, 출력층은 8개 그대로 두고 은닉층을 100개씩 늘려 500개 까지 실험 하였다. 각 은닉층 노드 개수별 인식률은 <Table 7>과 같고, 각 은닉층 노드 개수별 걸린 학습 시간은 <Table 8>과 같다.

4.4 은닉층 노드 개수별 성능 분석

은닉층의 노드 개수 별로 실험을 진행 하였다.

Table 7 Recognition table of each hidden layer
(unit : %)

	100	200	300	400	500
SM5	100	100	99	100	100
Morning	89	92	90	93	90
Grandeur	78	79	79	78	78
K5	89	83	80	84	85
Chevrolet Spark	94	96	94	98	96
YF Sonata	95	95	95	94	96
NF Sonata	93	91	95	92	93
Porter	94	92	92	95	93
Averaged rate	91.5	91	90.5	91.75	91.37

Table 8 Training time by each hidden layer

Hidden layer size	Trained time of 1000 times
100	750s
200	983s
300	1336s
400	1734s
500	2016s

은닉층의 노드를 400개로 하였을 때 인식률이 91.75%로 가장 높게 나왔으나, 같은 학습 데이터와 테스트 데이터로 은닉층 노드 개수별로 5번 반복 실행 해 본 결과 평균 인식률이 최대 92% 최소 90%로 나와 처음 학습을 시작하기 전 레이아웃 사이에 가중치 값이 어떻게 설정되느냐에 따라 최종 인식률이 1~2% 사이에서 차이가 있다고

Table 9 Recognition rate of k-NN

(unit : %)

	1-NN	3-NN	5-NN	7-NN	9-NN
SM5	97	98	97	96	94
Morning	98	100	98	98	98
Grandeur	60	52	50	50	50
K5	98	97	93	91	91
Chevrolet Spark	99	97	97	97	98
YF Sonata	99	99	98	98	98
NF Sonata	92	90	92	92	90
Porter	97	95	99	99	98
Averaged rate	92.5	91	90.5	90.12	89.62

볼 수 있으므로 은닉층 노드 개수별 학습에 따른 인식률 변화는 큰 의미가 없다고 할 수 있다.

4.5 학습 방법에 따른 인식률 비교

학습 방법에 따른 인식률 비교를 위해 k-NN (k-Nearest Neighbour) 알고리즘[11]을 사용하여 MLP와 인식률을 비교하였다. 패턴 인식에서 k-NN은 분류나 회귀에 사용되는 비모수 방식이며, 이번 실험에서 분류는 과반수 의결로 분류하였다. k-NN에서 테스트한 데이터는 4.1절에서 가장 성능이 좋았던 셀 사이즈 16*16의 특징점 데이터를 사용하였고, k-NN에서 k를 1, 3, 5, 7, 9으로 나눠서 실험을 하였다. 인식률은 <Table 9>과 같고, 학습과 판별에 걸린 시간은 <Table 10>과 같다.

Table 10 Computed time of k-NN

k	Computed time(unit : s)
1	1.872
3	1.732
5	1.750
7	1.766
9	1.773

4.6 결과 분석

k-NN을 이용하여 실험한 결과 그랜저를 제외

Table 11 Recognition rate of k-NN after changing training data ordering

(unit : %)

	1-NN	3-NN	5-NN	7-NN	9-NN
SM5	100	99	99	99	99
Morning	100	100	99	99	99
Grandeur	96	92	95	86	84
K5	100	98	99	98	97
Chevrolet Spark	100	100	99	99	98
YF Sonata	98	99	97	98	98
NF Sonata	100	100	100	100	100
Porter	100	99	99	98	98
Averaged rate	99.25	98.37	98.37	97.12	96.62

한 나머지는 인식률이 상승하였다. 그랜저의 인식률이 비정상적으로 낮아 그 이유를 생각해 봤을 때 앞서 설명한 바와 같이 학습 데이터 100장에서 12장만이 2011 그랜저이었고, 테스트 데이터에서 61장이 2011 그랜저이기 때문에 2011 그랜저에 대한 학습 데이터가 모자라 생긴 오인식이라 생각 되었다. 그래서 처음 100장을 학습 데이터로, 나머지 100장을 테스트 데이터로 사용하던 방법을 바꿔 200장에서 랜덤으로 100장을 학습 데이터로, 랜덤으로 선택된 100장을 제외한 나머지를 테스트 데이터로 하여 k-NN에 대한 실험을 다시 진행하였다.

4.7 학습 데이터 순서 변경 후 인식률 비교

실험 결과 <Table 11>과 같이 전체적으로 성능이 크게 향상 되었으며 1-NN의 경우 99.25%라는 높은 인식률을 보였으며 전체적으로 인식률이 향상되었다. 따라서 데이터 순서 변경이 인식률에 영향을 미친다는 사실을 확인 한 후 인공신경망을 이용했을 때도 인식률에 영향을 미치는지 확인하기 위해 순서가 변경된 데이터를 가지고 이전에 했던 실험을 반복하였다.

먼저 4.1절과 동일하게 셀 사이즈 별로, 은닉층 노드 개수를 100개로 설정한 뒤 1000번 반복 학습시켜 실험을 하였고 그 결과는 <Table 12>과 같다.

Table 12 Recognition rate after changing training data ordering

(unit : %)

	8*8	16*16	32*32	64*64
SM5	98	99	100	94
Morning	100	100	100	57
Grandeur	96	94	89	60
K5	97	98	95	65
Chevrolet Spark	96	99	98	34
YF Sonata	98	99	97	79
NF Sonata	98	97	94	71
Porter	96	98	98	99
Averaged rate	97.37	98	96.37	69.87

실험 결과 셀 사이즈 16*16의 인식률이 가장 높았으며 4.2절에서와 같이 셀 사이즈 8*8과 16*16을 5번 반복 실험 했을 때에도 평균 인식률의 차이가 1% 정도 났다. 따라서 셀 사이즈 16*16의 학습 데이터와 테스트 데이터를 기준으로 4.3절과 같이 은닉층 노드 개수별 실험을 진행하였으며 MLP 은닉층 노드 개수별 인식률은 <Table 13>와 같다.

실험 결과 은닉층 노드의 개수를 400개로 했을 때 인식률이 가장 높았으나, 4.4절의 결과와 같이 초기 가중치 값이 어떻게 설정 되느냐에 따라 생기는 오차로 볼 수 있어 노드 개수 별 인식률은 차이가 없다고 볼 수 있다.

학습 데이터와 테스트 데이터의 순서에 따라서

Table 13 Recognition rate of each hidden layer after changing training data ordering

(unit : %)

	100	200	300	400	500
SM5	99	100	100	100	100
Morning	100	100	99	100	100
Grandeur	94	95	94	95	93
K5	98	98	99	99	99
Chevrolet Spark	99	98	98	98	98
YF Sonata	99	99	99	99	98
NF Sonata	97	98	99	99	98
Porter	98	100	98	99	99
Averaged rate	98	98.5	98.25	98.625	98.125



Fig. 8 An example of data order

도 결과가 바뀔을 확인 하였으며, 원인은 <Fig. 8>과 같이 처음 학습 데이터와 테스트 데이터는 사진을 찍은 순서대로 정렬되어 있었는데 순서대로 학습하던 것을 랜덤으로 학습 하게 되면서 다양한 차량의 앞면이 학습되어 인식률이 높아진 것으로 추정 된다. 데이터를 랜덤으로 사용 하여도 인식률은 1-NN을 사용 했을 때의 인식률이 MLP를 사용한 인식률 보다 높았으나 모든 학습 데이터와 비교해야 하는 k-NN의 특성상 실행 속도 때문에 실제 상황에서는 한계가 있을 것이다.

5. 결론 및 향후 과제

본 논문에서는 지금까지 차량인식에서 가정했던 상황인 CCTV나 차량에 달린 카메라로 차량을 인식하는 방법이 아닌 사용자가 직접 차량의 앞면을 촬영 했을 때, 차량을 판별하는 시스템을 제안 하였고 실험을 통해 성능을 확인 하였다. 사진은 차량 모델 당 200장씩 총 1600장을 직접 촬영 하였으며, 모델 당 학습 데이터 100장, 테스트 데이터 100장으로 사용 하였다. 차종별 모델

식별을 위한 특징점은 HOG를 사용 하였으며 4가지의 셀 사이즈를 선정하여 인식률을 비교 하였을 때, 셀 사이즈 16*16의 인식률이 가장 높았다. 인식률이 가장 높았던 셀 사이즈 16*16의 특징점 값들을 인공신경망중 하나인 MLP에 오류 역전파 학습 방법으로 학습 시켰으며 데이터를 순서대로 사용 했을 경우 은닉층 노드 개수별 실험에서 평균 인식률은 약 91% 정도로 확인 되었다. 그러나 데이터를 랜덤으로 사용 했을 경우 평균 인식률이 약 98%로 높게 나와 데이터 순서에 따라 인식률이 바뀔을 확인 하였다.

향후 인식률을 더 높이기 위해서는 풍부한 자료를 사용하거나 특징점을 추출하는 방법, 학습 방법 등에 대한 추가 연구가 필요하다.

References

[1] Woo-Tae Kim, Kil-Taek Lim, "Extraction of Car License Plate Region Using Histogram Features of Edge Direction",

- Journal of the Korea Industrial Information Systems Research, Vol. 14, No. 3, pp. 1-14, 2009.
- [2] Chang-Seok Park, Byeong Man Kim, Byung-Hoon Seo, Jun-Woo Kim, Kwang-Ho Lee, "Real-time Recognition of Car Licence Plate on a Moving Car", Journal of the Korea Industrial Information Systems Research, Vol. 9, No. 2, pp. 32-43, 2004.
- [3] Byung-Hoon Seo, Byeong Man Kim, Chang-Bae Moon, Yoon-Sik Shin, "Binarization of Number Plate Image with a Shadow", Journal of the Korea Industrial Information Systems Research, Vol. 13, No. 4, pp. 1-13, 2008.
- [4] Pyeng-Won Lee, "Development of an Image Processing Algorithm for the Recognition of Car Types and Number Plate", Department of Control and Measurement Engineering, The University of Seoul Graduate School, 2000.
- [5] Tae-Joon Ha, "A Recognition System for Car Images Based on the HTM Network", Department of Computer and Information Science, Graduate School of Industry Gyeongsang National University, 2010.
- [6] Hyo-Jong Lee, "A Study on the Model Recognition of Moving Vehicles Using a Neural Network", Journal of the Institute of Electronics Engineers of Korea SP, Vol. 42, No. 4, pp. 69-78, 2005.
- [7] Min-Ho Kim and Doo-Hyun Choi, "Model Recognition of Moving Vehicles Based on Features of Car Head Lights", Proceedings of Information and Control Symposium, pp. 211-212, 2011.
- [8] Woo-Young Kang, Tae-Gyun Lee, Min-Ho Kwak, Hyo-Jong Lee, "Development of Model Recognition Algorithm for Moving Vehicles", Proceedings of Korean Institute of Information Scientists and Engineers, Vol. 39, No. 2, pp. 214-216, 2012.
- [9] Yeunghak Lee, Jooyoung Ko, Jung-Hee Suk, Tae Moon Roh, Jaechang Shim, "Pedestrian Recognition using Adaboost Algorithm Based on Cascade Method by Curvature and HOG", Journal of KIISE : Computing Practices and Letters Vol. 16, No. 6, pp. 654-662, 2010.
- [10] Won Taek Woo, "A Design And Implementation Of Simple Neural Networks System In Turbo Pascal", The Journal of Information Systems, Vol. 2000, No. 6, pp. 33-88, 2000.
- [11] Altman, N. S., "An introduction to Kernel and Nearest-Neighbor Nonparametric Regression", The American Statistician, Vol. 46, No. 3, pp. 175-185, 1992.

박 기 완 (Ki-Wan Park)



- 학생회원
- 금오공과대학교 컴퓨터소프트웨어공학과 학사과정
- 관심분야 : 알고리즘, 인공지능

방 지 성 (Ji-Sung Bang)



- 금오공과대학교 컴퓨터소프트웨어공학과 학사과정
- 관심분야 : 소프트웨어공학, 모바일 프로그래밍

김 병 만 (Byeong-Man Kim)



- 정회원
- 서울대학교 컴퓨터공학과 공학사
- 한국과학기술원 전산학과 공학석사
- 한국과학기술원 전산학과 공학박사
- 국립금오공과대학교 교수
- 미국 UC, Irvine 대학 방문교수
- 미국 콜로라도 주립대학 대학 방문교수
- 관심분야 : 인공지능, 정보검색, 정보보안