

# 질감특성을 이용한 차종 식별에 관한 연구

김경욱, 이효종  
전북대학교 전자정보공학부  
전북대학교 영상정보신기술 연구센터  
e-mail:{kwkim, hlee}@sel.chonbuk.ac.kr

## A Study on Classification of Types of Vehicles using Texture Features

Kyong-Wook Kim, Hyo-Jong Lee  
Dept of Electronics and Information Engineering,  
Chon-buk National University  
Center for Advanced Image Technology,  
Chon-buk National University

### 요 약

본 논문에서는 차종 식별을 위해 차량 영상의 질감 특징을 사용하였다. 차량의 질감 특징 정보를 얻기 위한 관심영역으로 라디에이터 그릴 부분을 선택하였다. 추출된 관심영역으로부터 GLCM(Gray Level Co-occurrence Matrix)을 사용하여 질감 특징 값을 추출하였고, 그 특징 값들을 입력으로 취하는 3층의 신경회로망을 구성한 후 역전파 학습 알고리즘을 사용하여 학습을 시켜서 차종 식별을 시도하였다.

### 1. 서론

영상처리를 이용한 차량의 인식에서 개별차량의 식별을 위해 관심의 대상이 되는 부분에는 차량의 번호판, 색깔, 차량 구성 요소들의 모양, 차량의 모델 정도 등이 있다. 번호판 인식에 관한 연구는 이미 많은 연구가 진행되어 왔다. 그러나 번호판만으로 차량의 검색은 어려운데, 그 이유는 번호판이 쉽게 교체될 수 있고, 카메라가 인식할 수 없도록 조작하기가 쉽기 때문이다. 범죄와 관련된 차량의 번호판은 일반 차량보다 번호판이 바뀌거나 조작될 가능성이 더 크기 때문에 번호판 외의 그 차량을 대표할 수 있는 차량정보가 필요하다.

본 논문에서는 차종 식별을 위한 차량의 특징으로 질감을 선택하였다. 질감 특징 값을 구하기 위한 관심영역으로는 라디에이터 그릴 부분을 선택하였다. 결정된 관심영역으로부터 GLCM (Gray Level Co-occurrence Matrix)을 사용하여 질감 특징 값들을 추출하였고, 그 특징 값들을 입력으로 취하는 3

층의 신경회로망을 구성한 후 역전파 알고리즘을 사용하여 학습을 시켰다. 그리고 학습에 사용되지 않은 데이터들을 가지고 차종 식별을 시도하였다.

2절에서는 질감 특징 값을 추출하기 위한 관심영역 설정의 과정을 설명하였다. 3절에서는 GLCM을 이용한 차량의 질감 특징 추출에 대해 기술하였고, 4절에서는 신경회로망, 그리고 실험 및 결과, 결론 순으로 기술하였다.

### 2. 질감 특징 값을 위한 관심영역 설정 과정

본 논문은 도로에서 주행하는 차량 영상으로부터의 차종 식별에 관한 연구이다. 차종 식별을 위한 질감 특징 값을 추출하기 위해서는 먼저 도로를 포함하고 있는 동영상으로부터 차량이 존재하는 부분을 분리해 내고 분리된 차량이미지로부터 질감 특징을 위한 관심영역을 설정하여 특징 값을 추출해 내야 한다.

질감 특징 값을 위한 관심영역의 설정 과정은 다음과 같다.

첫째, 도로에서 차량이 주행하는 동영상으로부터 연속하는 두 프레임 이미지를 선택한다. 이때 차량의 전면부가 처리하기에 적당한 위치에 있도록 두 프레임을 선택한다. 둘째, 차분, 이진화, 프로젝션을 통하여 도로를 포함한 프레임 이미지로부터 차량의 영역을 분리해낸다. 셋째, 차량의 영역이 결정되면 허프변환[2], 회전변환을 이용해 차량이 기울어진 만큼 역으로 회전시켜 차량 이미지를 반듯하게 조정한다. 넷째, 반듯한 이미지가 구해지면 인접하는 두 픽셀의 명암 차를 이용한 알고리즘을 사용하여 번호 판 영역을 결정한다. 그리고 마지막으로 라디에이터 그릴 영역은 일반적으로 번호 판의 바로 윗부분에 존재하므로 번호 판 영역이 결정되면 자동적으로 라디에이터 그릴 영역도 결정된다.[1]

### 3. GLCM

본 논문에서는 차량의 모델 정보를 위한 특징 값을 구하기 위해 질감을 사용하였다. 이미지에 주기적인 요소를 질감이라고 할 수 있는데, 예를 들면 벽돌로 지어진 건물의 이미지나, 물결치는 호수 이미지를 들 수 있다. 그런 이미지에서는 벽돌이 일정 간격으로 주기적으로 배치되어있거나, 물결이 어느 정도 주기를 갖고 반복될 것이다. 이런 질감의 의미를 자동차 검색을 위한 특징 값 추출에 사용하였다.

차종이 다른 모든 차량들은 당연히 외관 또한 다르다. 특히 차량 앞부분의 전조등, 라디에이터 그릴 부분은 각각각색이다. 즉, 각 차종마다 거의 고유한 외관을 가지고 있다. 또 전조등이나 라디에이터 그릴 부분은 대부분이 질감을 가지고 있다. 그렇기 때문에 질감을 이용해 차량 검색이 가능할 것이다.

각 차량의 질감 특징을 수치화하기 위해서 통계적 질감 분석 방법인 GLCM (Gray Level Co-occurrence Matrix)을 사용하였다. GLCM은 비슷한 그레이 레벨 값을 갖는 픽셀들의 위치에 관한 정보를 갖는다. 그레이 값에서 얼마간의 차이를 갖는  $d$  만큼 떨어진 두 픽셀이 이미지에서 얼마나 많이 존재하는지를 나타낸다. 어떤 영상에서 픽셀거리  $d$ 로 했을 때의 GLCM행렬을  $G$ 라고 했을 때,  $G[i,j]$ 는 그 영상 내에서 레벨이  $i$ 인 한 픽셀에서 거리  $d$ 만큼 떨어진 다른 한 픽셀의 레벨이  $j$ 인 모든 경우의 수를 총 픽셀 쌍의 수로 나눈 값을 나타낸다. 이때 두 픽셀의 방향이 중요하다. 즉 수평방향, 수직방향, 그리고 두 대각선 방향 각각에 GLCM 값이 존재하게 된다. 256 Level의 그레이 이미지의 GLCM

은 256 x 256 크기의 매트릭스로 나타나고 픽셀거리  $d$ 에 따라 각각의 GLCM이 존재하게 된다. 즉 모든 픽셀거리  $d$ 에 대해 네 방향에 따라 각각의 256 x 256의 행렬이 존재하게 된다. 이것은 정말로 많은 데이터이고 때로는 원래 영상의 데이터보다 많기도 하다. 그리하여 질감 특성으로써 이 매트릭스를 직접 사용하는 것은 바람직하지 못하기 때문에 이 매트릭스로부터 Contrast, Homogeneity, Entropy, Energy 등의 값을 산출해 질감 특징으로 사용한다.[3]

식(1)

$$Contrast = \sum_i \sum_j (i-j)^2 P[i,j]$$

식(2)

$$Energy = \sum_i \sum_j P^2[i,j]$$

식(3)

$$Entropy = - \sum_i \sum_j P[i,j] \log P[i,j]$$

식(4)

$$Homogeneity = \sum_i \sum_j \frac{P[i,j]}{1+|i-j|}$$

위의 식(1)-(4)는 실험에서 사용한 각각의 특징 값을 구하는 수식들이다. Contrast는 명암도 차이를 측정하고, Energy는 명암도의 균일성을 재는 척도이다. Entropy는 그레이 레벨 분포의 임의성을 나타내고, Homogeneity는 GLCM 각 원소들 간의 균일성을 측정한다.

### 4. 신경회로망

3절에서 질감 특징 값을 구하기 위해 사용한 네 개의 서술자는 각각 네 방향의 값을 갖게 된다. 즉 하나의 관심영역으로부터 구해진 질감 특징 값은 총 16개이고 16차원의 벡터로 나타낼 수 있다. 본 논문에서는 3절에서 구해진 16개의 질감 특징 값들을 입력으로 취하는 3층 신경 회로망을 구성하여 차종을 학습시키고 차종 식별을 시도하였다.

그림 (1)에서 IN은 입력층으로서 학습을 위한 데이터를 대입하는 부분으로, 3절에서 구해진 16개의 질감 특징 값들을 입력으로 이용하였다. 즉 입력층 노드의 수는 특징 값들의 수에 해당하는 16이 된다.

HN은 은닉층이다. 은닉층 노드의 수를 150으로 설정하여 학습을 수행시켰다.

OUT은 출력층을 나타내며, 초기 학습에서는 출력층의 결과를 미리 결정해 주고, 학습을 통해 각 층별로 가중치를 얻어 낼 수 있도록 학습을 수행하였다. 실험에서 사용한 차량의 종류의 수는 모두 24종이다. 따라서 출력층의 노드의 개수는 24로 설정하였다.

합산한 내용을 표 2에 나타내었다.




그림 (1) 3층 구조의 신경회로망

## 5. 실험 및 결과

실험에서 사용한 데이터는 시내 외곽의 육교 위에서 촬영한 세 시간 분량의 동영상이다. 먼저 이 동영상으로부터 연속하는 두 프레임을 추출하였다. 외제차량이나 대형 트럭, 버스 등은 제외하였고, 또 차량의 수가 5대 미만인 차종은 제외하였다. 최종적으로 890쌍의 프레임 이미지를 선택하였다.

구해진 890쌍의 프레임 이미지를 차분, 이진화, 프로젝트 과정을 통해 차량영역을 추출하였고, 기울기 조정을 거친 후 번호판 영역을 추출하고 질감 특징값을 얻기 위한 관심영역을 결정하였다. 번호판 영역 추출에 있어서 오류가 있는 경우에는 관심 영역 또한 바르게 결정되지 못하기 때문에, 번호판 영역에 오류가 있는 데이터는 다시 제외하였다. 그리하여 차종 결정을 위해 신경망을 이용해 학습을 시키는 과정에서는 총 24종 415대의 데이터를 사용하였다.

표 1에는 415개의 데이터 모두를 학습에 사용한 후 차종을 인식한 결과를 나타내었다. 24종 415대를 사용한 학습의 결과는 93.7%로 어느 정도 수렴함을 알 수 있었다.

학습에 사용되지 않은 데이터로 인식률을 조사하는데 있어서는 차량의 데이터가 적어서 80%-20% 잭 나이프 방법을 사용하였다. 각 차종별로 80%의 데이터로 학습을 시키고 나머지 20%의 데이터로 인식률을 검사하였다. 이런 방법으로 훈련을 위한 데이터와 인식률을 검사하기 위한 데이터를 바꿔가면서 총 5회의 실험을 하였다. 5회의 실험 결과를 모두

차종	데이터수	정인식	오인식	%(정인식/데이터수)
포터	50	50	0	100
봉고프런티어1	15	14	1	93.3
스타렉스	30	26	4	86.7
봉고프런티어2	27	27	0	100
EF소나타	21	21	0	100
소나타2	17	16	1	94.1
New EF 소나타	24	24	0	100
세피아1	14	12	2	85.7
카니발	23	21	2	91.3
크레도스1	17	16	1	94.1
그레이스	16	14	2	87.5
그랜저XG	18	17	1	94.4
무쏘2	18	16	2	88.9
이스타나	10	10	0	100
New 그랜저	14	14	0	100
갤로퍼1	15	15	0	100
프레지오	12	10	2	83.3
포텐샤	14	13	1	92.9
엑센트	13	10	3	76.9
SM5	17	16	1	94.1
에쿠스	7	7	0	100
렉스틴	6	5	1	83.3
라노스	9	8	1	88.9
다이너스티	8	7	1	87.5
합계	415	389	26	<b>93.7</b>

표 (1) 학습에 사용한 데이터의 인식 결과

차종	데이터수	정인식	오인식	%(정인식/데이터수)
포터	50	42	8	84
봉고프런티어1	15	10	5	66.7
스타렉스	30	22	8	73.3
봉고프런티어2	27	16	11	59.3
EF소나타	21	16	5	76.2
소나타2	17	2	15	11.8
New EF 소나타	24	16	8	66.7
세피아1	14	3	11	21.4
카니발	23	13	10	56.5
크레도스1	17	7	10	41.2
그레이스	16	4	12	25
그랜저XG	18	8	10	44.4
무쏘2	18	7	11	38.9
이스타나	10	7	3	70
New 그랜저	14	12	2	85.7
갤로퍼1	15	8	7	53.3
프레지오	12	8	4	66.7
포텐샤	14	6	8	42.9
엑센트	13	5	8	38.5
SM5	17	5	12	29.4
에쿠스	7	6	1	85.7
렉스틴	6	1	5	16.7
라노스	9	3	6	33.3
다이너스티	8	7	1	87.5
합계	415	234	181	<b>56.4</b>

표 (2) 신경망을 이용한 인식 결과

표 2에서 보이는 바와 같이 각 차종별로 인식률이 크게 차이가 나타났다. 인식률이 높은 것은 85% 이상인 것도 있는 반면, 인식률이 저조한 것은 10%를

겨우 넘기는 것도 있었다. 전체적인 인식률은 56.4%로 나타났다.

학습에 사용한 데이터의 인식 결과는 93.7%인 반면 학습에 사용하지 않은 데이터의 인식 결과는 56.4%로 저조하다. 그 이유는 크게 두 가지로 요약할 수 있다. 첫째는 차종별로 특징 값들의 분포가 어느 한 값에 집중되어 있지 않고 넓게 퍼져 있다는 것이다. 둘째는 차종별로 데이터의 수에 차이가 많고 대부분의 차종의 경우 데이터의 개수가 적다는 것이다.

포터의 인식률은 84%이다. 포터 역시 특징 값들의 분포가 넓게 퍼져 있지만 인식률이 양호한 이유는 데이터의 개수가 많아서 특징 값들이 하나씩 떨어져 있지 않고 여러 곳에 집중적으로 뭉쳐 있기 때문이다. 또 다이너스티와 렉스톤의 경우, 데이터의 수가 10개 미만으로 적지만 특징 값들이 한곳에 집중적으로 뭉쳐 있기 때문에 양호한 인식률을 나타내었다. 그러나 그레이스의 경우는 데이터 수가 다이너스티나 렉스톤 보다는 많지만, 다이너스티나 렉스톤처럼 특징 값들이 한곳에 집중적으로 뭉쳐 있지도 않았고, 또 포터처럼 데이터 수가 많지도 않아서 특징 값들이 여러 곳에 하나씩 떨어져서 존재하는 경우가 많았다. 그렇기 때문에 인식률이 저조하였다.

각 차종별로 학습에 사용하는 데이터의 수가 많으면 좀 더 나은 결과를 기대 할 수 있을 것이다.

## 6. 결론

본 논문의 최종 목적은 도로 영상에 존재하는 차량들의 종류를 식별하는 것이다. 그 준비 과정으로써 영상처리를 이용해 도로 영상에서 개별 차량의 인식을 실험하였다. 그리고 차종 식별을 위한 차량의 특징으로써 질감(Texture)을 도입하였고, 질감으로써 차량의 고유한 특징을 가장 잘 나타낼 수 있는 관심영역을 논의하였다. 그리고 관심 영역으로부터 GLCM을 이용하여 그 차량의 특징을 나타내는 질감 특징 값을 찾았고, 그 값을 신경 회로망의 입력으로 삼아 역전파 알고리즘을 이용한 학습을 통해 차종 식별을 시도하였다.

연속하는 두 프레임 영상의 차분을 이용하여 차량 영역을 검출하였는데 차량 전면부의 정보를 잃지 않는 범위 내에서는 100%에 가까운 결과를 나타내었다. 차량의 기울기 조정 과정에서는 변수들을 양자화 할 때 양자화 간격을 더 작게 하면 더 미세하

게 기울기를 조정할 수 있을 것이다. 번호판 영역은 문자와 배경에 의해 생성되는 명암도 변화의 특성을 이용한 방법을 이용하였는데, 차량의 라디에이터 그릴 영역에서도 번호판 내부에 존재하는 명암도 변화와 비슷한 특성이 있어서, 추출된 번호판 영역이 라디에이터 그릴영역의 일부를 포함하는 경우가 오류의 과반수를 차지하였다. 더 확실하게 번호판 영역만을 찾을 수 있는 알고리즘 연구가 필요하다. 번호판 영역의 중심으로부터 질감 특징을 위한 관심영역을 설정하기 때문에 번호판 영역의 올바른 추출이 중요하다.

신경회로망 실험에서는 적합한 망 구조를 찾는 데 많은 시간이 걸렸다. 본 논문에서는 입력층을 16으로 제한하였는데 더 나은 결과를 위해, 픽셀 거리를 두개를 사용하거나, 또 다른 서술자들을 포함시켜 입력층의 개수를 증가시켜 학습시키는 방법도 고려해 볼 사항이다.

차량 인식을 위해 색상, 번호판 문자인식 등 많은 연구가 진행되어 오고 있다. 그러나 질감 특징을 차량 인식에 적용한 연구는 흔하지 않다. 본 논문을 통해 차량 전면부의 질감 특징 값들이 차종 식별을 위해 사용 될 수 있음을 알았다. 좋은 결과를 위해서는 많은 연구가 필수적이다. 차량 인식에 있어 질감을 이용한 연구가 활발히 진행되었으면 하는 바람이다.

## 참고문헌

- [1] 김경욱 "도로 영상에서의 차량 인식 및 차종 식별에 관한 연구" 전북대학교 석사논문 2004. 02.
- [2] Refael C. Gonzales and Richard E. Woods "Digital image Processing", Addison-Wesley Publishing Company.
- [3] J. R. Parker "Algorithms for Image Processing and Computer Vision" Wiley Computer Publishing
- [4] 김희승, "영상인식-영상처리, 컴퓨터비전, 패턴인식, 신경망," 생능출판사, 1994.