

모듈라 신경망에 기반한 번호판 인식시스템의 특징 벡터 클러스터링 방법에 따른 성능평가

*박창석⁰ *김병만 *서병훈 **이광호

*금오공과대학교 소프트웨어공학과

**국립목포대학교 컴퓨터공학과

*{icisl⁰, bmkim, seozang}@se.kumoh.ac.kr **klee@ai.mokpo.ac.kr

Performance Evaluation of Clustering Methods of Feature Vectors in Vehicle Plate Recognition Systems based on Modular Neural Network

*Chang Seok Park⁰ *Byeong Man Kim *Seo Byung Hoon **Kwang Ho Lee

*Dept. of Software Engineering, Kumoh National Institute of Technology

**Dept. of Computer Education, Mokpo National University

요 약

분할 및 합병 개념에 바탕을 둔 모듈라 신경망이 자동차 번호판 문자 인식에서 단일 신경망 사용 보다 학습 절 측면이나 학습 속도 면에서 좋은 결과를 보였다. 본 논문에서는 번호판 인식을 위한 모듈라 신경망 구성 시, 특징 벡터 클러스터링 방법에 따른 모듈라 신경망의 성능을 평가하였다. K-means Clustering 알고리즘을 이용하여 유사한 특징 벡터를 그룹핑하는 방법과 본 논문에서 제안한 알고리즘을 사용하여 유사하지 않는 특징 벡터들로 모듈라 신경망을 구성할 경우가 그렇지 않은 경우보다 좋은 인식 결과를 보였다.

1. 서 론

최근 분류기 쪽에서 모듈라 학습을 이용한 방법들에 대해서 상당한 관심이 모아지고 있다[1,2]. 분할 및 합병(divide and conquer) 개념에 바탕을 둔 모듈라 학습 방법이 복잡한 문제를 해결함에 있어서 학습 절 측면이나 학습 속도 면에서 단일 분류기에 비해 좋은 결과를 보여왔으며, 인공신경망을 이용한 분류 방법 쪽에서도 이러한 연구들[3,4,5,6]이 이루어지고 있다. 모듈라 신경망을 이용한 자동차 번호판 문자 인식에서도 단일 신경망을 사용하였을 때 보다 좋은 학습 및 인식률을 보였다[7].

번호판 인식을 위한 모듈라 신경망 구성 시 특징 벡터들을 어떻게 그룹핑 하느냐에 따라 학습의 성능과 인식률이 달라질 수 있다. 따라서 본 논문에서는 모듈라 신경망 구성 시, [7]에서 사용한 K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터들을 그룹핑 한 후 이를 바탕으로 구성한 모듈라 신경망과 제안한 클러스터링 방법에 따라 유사하지 않은 특징 벡터들을 그룹핑 한 후 구성한 모듈라 신경망을 비교 평가하였다. 또한, 전체 학습 패턴을 몇 개의 그룹으로 분할하는 가에 따라 성능이 좌우되기 때문에 그룹 수를 달리 하면서 실험을 하였다. 실험 결과, 유사하지 않은 특징 벡터들로 그룹핑된 모듈라 신경망이 좋은 학습 및 인식 결과를 보였다.

본 논문의 2장에서는 제안한 클러스터링 방법에 따른 모듈라 신경망 구성 방법에 대해 소개하고 3장에서는 실험을 통한 검증을 4장에서는 결론 및 향후 연구 과제에 대해서 다룬다.

2. 모듈라 신경망을 위한 서브네트워크 구성

모듈라 신경망의 구조는 여러 가지 형태가 있을 수 있지만 본 논문에서는 모듈라 신경망을 이용한 자동차 번호판 문자인

식[7]에서 연구된 방법과 동일하다. 신경망 구조는 전체 학습 패턴을 어떻게 분할하는 가에 따라 성능이 좌우된다. 본 논문에서는 특징 벡터들을 2.3절과 2.4절의 방법에 따라 그룹핑하고 이를 바탕으로 모듈라 신경망을 구성한 후 두 방법의 성능을 평가하였다.

2.1 모듈라 신경망의 전체 구조

모듈라 신경망의 구조는 [7]에서 소개한 것처럼 세 계층으로 입력층, 국부층(Local Layer), 결정층(Decision Layer)으로 구성된다.

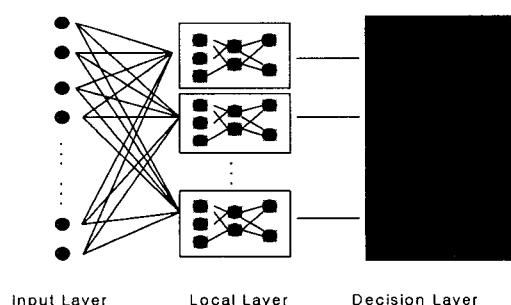


그림 1. 모듈라 다중퍼셉트론 신경망 구조

입력층은 획득 영상에서 전처리 과정을 통해 추출된 개별 문자의 특징 벡터가 입력되는 층이며, 국부층은 각 그룹의 패턴들을 학습 및 인식하는 층으로 패턴 그룹 수만큼의 다중퍼셉트론들로 구성되며, 각 다중퍼셉트론의 입력층 뉴런의 수는 특징 벡터의 차원과 같으며 출력층의 뉴런의 수는 각 서브네트워크

가 담당하는 학습패턴의 수와 같다. 즉, 각 서브네트워크의 입력층 뉴런의 수는 동일하지만 출력층 뉴런의 수는 다르다. 결정층은 국부층에서 인식된 결과를 종합하여 최종 결정을 내리는 층이다.

패턴의 인식은 먼저 모든 서브네트워크에 동일한 테스트 데이터가 입력된다. 추출된 개별 문자 영역의 이미지가 특징 벡터로 만들어지고 모든 서브네트워크를 통해 입력된다. 그런 후 각 서브네트워크는 학습된 결과를 이용하여 각자의 결과를 출력하게 된다. 최종적으로 결정층에서 이들 결과를 종합하여 최종 인식 패턴을 결정하게 된다.

최종 인식 패턴 결정은 먼저 각 서브네트워크의 출력 뉴런 중에서 가장 큰 값들을 선택하고 이에 해당하는 패턴들의 표준 벡터들과 입력 패턴을 비교하여 가장 가까운 것으로 판단한다. 이처럼 각 서브네트워크에서 인식한 패턴들에 대해서 별도로 표준패턴과 비교하는 이유는 주어진 입력 패턴이 해당 서브네트워크에서는 최고의 출력값을 가질 지라도 다른 서브네트워크에서 인식한 패턴의 출력값 보다 작을 수가 있기 때문이다. 이는 학습시 각 서브네트워크들이 독립적으로 학습하는 데서 기인한다. 한마디로, 모듈라 신경망을 통해 입력 패턴과 유사한 후보 인식패턴을 골라내고 이 후보패턴에 대해서만 표준 패턴과 비교하는 방법을 사용한다[7].

2.2 특징벡터 구성 방법

일반적으로 패턴을 가장 잘 표현할 수 있는 특징을 추출하여 특징벡터를 만들어야 번호판 인식에서 좋은 인식률을 볼 수 있다. 하지만, 본 연구의 주제가 특징벡터가 주어졌을 경우 어떻게 모듈라 신경망을 구성하는 것이 좋은 가이드 때문에 본 논문에서는 간단한 특징벡터 구성 방법을 사용하였다.

본 논문에서 사용한 특징 벡터는 문자 영상을 이진화 한 후 1의 개수가 같도록 가변 그물눈을 생성한 후 각 블록 내에서의 1의 비율을 계산한 값을 사용하였다. 그물눈은 수평 방향으로 8분할하고 수직 방향으로 8분할하였다. 즉, 특징 벡터는 64차원 (8×8)이며 각 차원은 0과 1 사이의 값을 갖는다[7].

2.3 유사한 특징 벡터간의 그룹핑

첫 번째 방법은 그림 2와 같이 K-means Clustering 알고리즘을 이용하여 유사한 패턴 사이들을 그룹화 하는 방법이다. 사전에 결정된 그룹의 수 k 에 기초하여 전체 데이터를 유사한 k 개의 그룹으로 구분하는 방법이다.

- ① 첫 번째 단계에서 k 개의 클러스터를 미리 정해놓고 각 패턴들을 랜덤하게 클러스터에 할당한다.
- ② 두 번째 단계에서 그룹의 중심을 선택한다.
- ③ 세 번째 단계에서 각 특징 벡터를 갖는 패턴(관찰치)을 그 중심과 가장 가까운 거리에 있는 그룹에 할당한다.
- ④ 네 번째 각 그룹별로 그에 속하는 패턴(관찰치)을 이용해 새로운 중심을 계산한다.

위의 과정을 기존의 중심과 새로운 중심의 차이가 없을 때 까지 반복한다.

그림 2. 유사한 특징 벡터간의 그룹핑

표 1은 그룹의 수를 8로 했을 경우의 패턴 분할의 형태를 보여주고 있다.

표 1. 유사한 특징 패턴 그룹핑의 한 형태

그룹 1	노 소 구 수 느 스 2 3 5 6 7 9
그룹 2	하 강 경 광 남 산 원 인 전 천 0
그룹 3	파 류 후 북 올 층 1 4 8
그룹 4	나 누 두 무 부 우 주 추 쿠 투 푸
그룹 5	다 라 마 바 아 타 너 더 커 니 디 리 이 지 치 키 티
그룹 6	고 도 로 모 보 오 조 초 코 토 포 호 그 드 르 민 브 으 즈 즈 크 트 흐
그룹 7	가 사 자 차 카 거 서 기 시
그룹 8	러 머 벼 어 저 쳐 터 페 허 미 비 피 히 대 제

2.4 제안한 유사하지 않은 특징 벡터간의 그룹핑

유사하지 않은 패턴들을 그룹화하기 위해 그림 3과 같은 변형된 K-means 클러스터링 알고리즘을 사용하였다.

- ① k 개의 클러스터를 미리 정해놓고 각 패턴들을 랜덤하게 클러스터에 할당한다.
- ② 임의의 패턴과 각 그룹과의 거리를 구한다. (단, 거리는 그룹에 속한 패턴 중 가장 가까운 패턴과의 거리)
- ③ 가장 먼 그룹에 임의의 패턴을 할당한다. 단, 임의의 패턴이 원래 속해 있던 그룹에 다른 패턴이 존재하지 않을 경우, 즉, 원소의 수가 1인 경우는 새로운 그룹에 할당하지 않는다.
- ④ ②~③과정을 패턴이 속한 그룹이 차이가 없을 때까지 반복한다.

그림 3. 유사하지 않은 특징 벡터간의 그룹핑

그림 4는 $K=2$ 일 때 유사하지 않은 패턴 사이에 클러스터링을 보여준다.

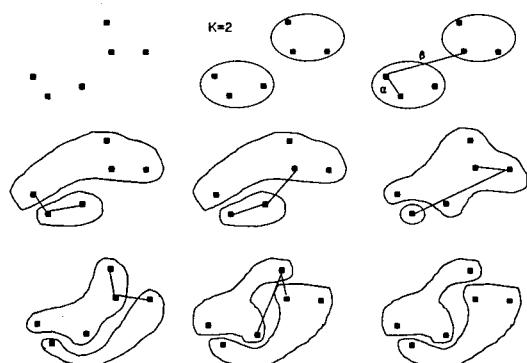


그림 4. $K=2$ 일 때 클러스터링의 예

표 2는 제안한 방법에 따른 특징 벡터간의 그룹핑에서 그룹의 수를 8로 했을 경우의 패턴 분할의 형태를 보여주고 있다.

표 2. 유사하지 않은 특징 패턴 그룹핑의 한 형태

그룹 1	무 바 부 북 비 산 수 자 천 터 호
그룹 2	강 도 디 루 벼 사 으 저 추 키 토 파 프
그룹 3	7 9 고 누 다 두 드 리 서 소 원 초 카 페
그룹 4	5 경 기 나 르 오 우 이 인 티 하 허 후 흐

그룹 5	6 거느러미 보시아 제조주 총츠
그룹 6	1 2 4 8 광 노더 르 차 커 크 타 포 푸 피
그룹 7	0 가 구 그 너 라 머 모 무 울 저 전 즈 치 투
그룹 8	3 남 니 대 마 스 어 지 코 쿠 트 히

3. 실험 및 결과

3.2 클러스터링 방법에 따른 성능 비교

특정 벡터 클러스터링 방법에 따라 모듈라 신경망의 성능을 평가하기 위해 차량번호와 가장 유사한 hydronic-extra 폰트를 조작해서 만든 크기 60×60 샘플 데이터 108개를 학습 데이터로 사용하였으며, 차량 번호판으로부터 얻은 별도의 데이터 423개를 실제 테스트 데이터로 사용하였다. 모듈라 신경망의 결정층에서 사용되는 표준 패턴은 학습 시에 사용한 데이터들의 중심벡터로 하였다. 즉, 한 패턴에 대해 여러 개의 학습 데이터가 존재하는데, 이때 이 패턴의 표준 패턴은 해당 학습 데이터의 중심으로 하였다.

실험에 사용한 모듈라 네트워크는 2개의 그룹부터 10개의 그룹으로 구성하면서 사용하였다. 각 다중퍼셉트론 학습 시 이득함은 0.9로, 모멘텀항은 0.2로 하였다.

표 3은 K-means Clustering 알고리즘을 이용하여 유사한 특정 벡터들을 그룹핑한 경우의 성능과 제안한 클러스터링 방법에 따라 유사하지 않은 특정 벡터들을 그룹핑한 경우의 모듈라 신경망의 성능을 보여주고 있다. 초기 학습 후 테스트 한 결과이며, 그룹의 수가 1부터 4인 경우 성능이 0% 인 것은 수렴에 실패하고 지역 최소값에 봉착한 것이다. 유사한 특정 벡터 그룹핑 시에는 그룹의 수가 8일 경우 성능이 좋았으며, 유사하지 않은 특정 벡터를 그룹핑 할 시는 그룹의 수가 5일 때가 가장 좋았다.

표 3. 클러스터링 방법에 따른 성능 비교

그룹수 방법	4	5	6	7	8	9	10
유사한 그룹핑	0%	52.2%	58.3%	49.1%	58.4%	51.5%	40.4%
유사하지 않은 그룹핑	41.1%	69.0%	64.3%	59.3%	63.5%	38.0%	49.6%

추가로, 재학습을 통한 각각의 모듈라 신경망의 성능을 비교하였다. 테스트 방법은 차량 번호판으로부터 얻은 전체 데이터 885개를 214개, 215개, 236개, 220개의 네 그룹으로 나누어 테스트하였으며, 각 다중퍼셉트론 학습 시 이득함은 0.9, 모멘텀항은 0.2로 하였다.

표 3을 보면 유사한 그룹핑 방법에서 그룹 수 8일 때의 인식률이 좋았으며, 유사하지 않은 그룹핑 방법에서는 그룹 수 5일 때 인식률이 좋았다. 따라서 [7]에서 사용한 방법과 제안한 방법으로 구성한 모듈라 신경망의 성능을 비교하기 위하여 각각 좋은 인식률을 보인 그룹 수 8과 5일 때를 동일한 조건으로 테스트를 하였다.

표 4는 유사한 특정 벡터들로 구성된 8개의 다중퍼셉트론으로 이루어진 모듈라 신경망의 성능을 나타내고, 표 5는 유사하지 않은 특정 벡터들로 구성된 5개의 다중퍼셉트론으로 이루어진 모듈라 신경망의 성능을 나타낸다.

표 4, 5에서 보는 바와 같이 제안한 방법으로 서브네트워크를 구성한 모듈라 신경망이 기존 방법에 비해 문자인식에서 좋은 결과를 보였으며 훈련 반복횟수가 증가할 수록 좋은 인식률

을 보였다.

표 4. [7]에서 사용한 방법으로 구성된 모듈라 신경망의 인식률

구분 훈련수	총 테스트 패턴 수	인식 패턴 수	인식 실패 패턴 수	재학습 패턴 수	인식률
1	214	163	51	9	76.1 %
2	215	177	38	11	82.3 %
3	236	220	16	7	93.2 %
최종테스트	220	212	8		96.3 %

표 5. 제안된 방법으로 구성된 모듈라 신경망의 인식률

구분 훈련수	총 테스트 패턴 수	인식 패턴 수	인식 실패 패턴 수	재학습 패턴 수	인식률
1	214	181	33	7	84.5 %
2	215	187	28	11	87.3 %
3	236	225	11	5	95.3 %
최종테스트	220	214	6		97.2 %

4. 결론 및 향후과제

본 논문에서 번호판 인식을 위한 모듈라 신경망을 구성 시, 특정 벡터 사이에 클러스터링 방법에 따라 모듈라 신경망의 성능을 평가하였다. K-means Clustering 알고리즘을 이용하여 유사한 특정 벡터를 그룹핑한 경우 보다 제안한 클러스터링 방법에 따라 유사하지 않은 특정 벡터를 그룹핑한 경우가 인식률 면에서 더 좋은 성능을 보였다. 또한, 인식률 측면뿐만 아니라 학습 속도 면에서도 상당한 이득이 있었다. 이러한 점은 실용적 측면에서 많은 도움이 되리라 생각된다.

차후, 모듈라 신경망의 구조에 대한 연구가 필요하며 현재 사용하는 결정층의 최종 판단 방법을 달리하여 실험해 볼 필요도 있다. 또한, 현재는 간단한 전처리 과정만을 거쳤는데 보다 실용적인 시스템을 구축하기 위해서는 질이 좋지 않는 영상에서 개별문자를 추출하는 연구나 특정 추출에 대한 연구가 필요하다.

[참고 문헌]

- [1] Shailesh Kumar, Joydeep Ghosh, Melba M. Crawford "Hierarchical Fusion of Multiple Classifiers for Hyperspectral Data Analysis", Pattern Analysis & Applications Volume 5 Issue 2, pp 210-220, 2002
- [2] Sushmita Mitra, Pabitra Mitra, Sankar K. Pal "Evolutionary Modular Design of Rough Knowledge-based Network using Fuzzy Attributes", Neurocomputing, Vol 36, pp45-66, 2001
- [3] Ballard D. "Modular learning in neural networks" Proc AAAI-87, 1987; 279-284
- [4] Happel BLM, Murre JMJ. "Design and evolution of modular neural network architectures." Neural Network 1994; 7: 6/7: 985-1004
- [5] Ramamurti V, Chosh J. "Structurally adaptive modular networks for nonstationary environments" IEEE Trans Neural Network 1999; 10(1): 152-160
- [6] Petridis V, Kehagias A. "Predictive Modular Neural Networks" Applications to Time Series. Kluwer Academic, Boston, 1998
- [7] 박창석, 김병만, 이광호, 최조천, 오득환, "모듈라 신경망을 이용한 자동차 번호판 문자인식," 한국정보과학회, 가을학술발표 논문집, Vol. 29, No. 2, pp.568~570, 2002, 10