

CNN과 다양한 분류 방법의 결합에 의한 성능 비교

한정수¹, 광근창^{2*}
^{1,2}조선대학교 제어계측공학과
 *e-mail : kwak@chosun.ac.kr

Performance Comparison by Combining CNN with Various Classification Methods

Jung-Soo Han*, Keun-Chang Kwak*

*Dept of Control and Instrumentation Engineering, Chosun University

요 약

본 논문에서는 컨볼루션 신경회로망(CNN: Convolutional Neural Network)과 다양한 분류기들의 결합을 통해 분류성능을 비교하고자 한다. 현재 일반적인 분류기로 알려진 것은 나이브 베이즈(Naive bayes), 트리(Tree), 판별 분석(Discriminant Analysis), 서포트 벡터 머신(SVM: Support Vector Machine) 등이 존재한다. 분류기들은 각각 다른 원리로 분류하기 때문에, 각각 성능을 비교해볼 필요가 있다. 분류기들의 성능을 비교하기 위한 사용한 데이터는 CNN에서 자주 사용되고 있는 MNIST 데이터를 사용하였다. 실험 결과로는 CNN에 선형 SVM을 결합하여 사용한 것이 분류율과 분류속도 측면에서 다른 분류기들의 성능보다 좋은 성능을 보이는 것을 확인할 수 있었다.


1. 서론

최근에 관심이 증가하고 있는 딥러닝 기술은 컴퓨팅 파워의 발전과 대량의 데이터를 확보할 수 있게 되면서 가능하게 되었다. 딥러닝 기술은 인간의 뇌와 유사한 사고방식을 통하여 인공지능을 마련하는 것으로 사람의 뇌에서 정보를 처리하는 뉴런(Neuron)과 비교되기도 한다. 신경망(Neural Network)은 오래 전부터 연구되어왔는데, 1950년대에 인간의 뇌에서 영감을 얻어 뉴런과 비슷하게 네트워크를 구현하였다[1]. 그러나 기계적인 문제 등 여러 가지 부분에서 성능이 좋지 않게 나와 한 동안 연구가 활발히 진행되지 않았었다. 그러다가 컴퓨터 성능의 발전과 빅데이터 확보가 가능하게 되면서 딥러닝이라는 이름으로 부활하게 되었다. 딥러닝의 주요 알고리즘에는 심층신경망(DNN), 순환 신경망(RNN), 컨볼루션 신경망(CNN), 제한 볼츠만 머신(RBM)등이 있다. 이 중 영상분야에서 효율적으로 사용할 수 있도록 만들어 진 것이 CNN이다. CNN은 1998년 Yann Lecun [2]이 처음 제안하였으나 성능면에서 다른 알고리즘에 비해 성능이 좋지 않아 주목받지 못하였다. 그러나 2012년 ImageNet Challenge라는 영상을 분류하는 대회에서 큰 차이로 우승하며 큰 주목을 받게 되었다. 2013년을 기점으로 대부분의 참가자들이 CNN을 사용하고 있고, 2014년부터는 10위권 참가자들은 모두 딥러닝 알고리즘을 사용하고 있다. 본 논문에서는 컨볼루션 신경망을 통해 추출된 특징들을 이용하여 다양한 분류기의 성능을 비교하는 실험을 진행하였다. 본 논문의 구성은 다음과 같

다. 2장에서는 컨볼루션 신경망에 대하여 간략하게 설명하고, 3장에서는 각 분류 방법에 따른 실험을 통해 성능을 비교 및 평가에 관해서 서술한다. 그리고 4장에서는 본 논문연구에 대한 결론을 내리고 마무리하도록 하겠다.

2. 컨볼루션 신경망(CNN)

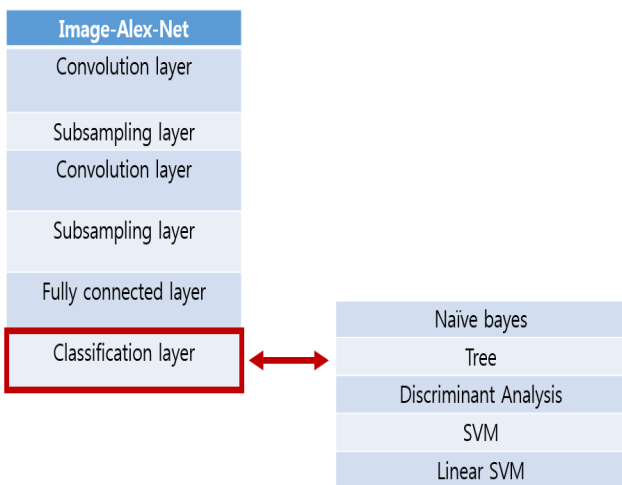
컨볼루션 신경망(CNN)은 그림1과 같이 컨볼루션 층(Colvolution layer)와 샘플링 부분(Subsampling part)을 반복하는 구조로 구성되어 있다. 여기서 샘플링 부분은 풀링 층(Pooling layer)에 해당한다. 컨볼루션 층은 영상의 각 영역에 대하여 복수의 필터를 적용시켜 특징지도(Feature map)를 만들어 내는 층이고 풀링 층은 특징 지도를 공간적으로 통합해 크기를 줄여 회전이나 위치의 변화에 변하지 않는 특징을 추출가능해지도록 하는 것이 풀링 층이다. 그리고 마지막 층에는 완전 연결 층(Fully connected layer)이 쌓여 요약된 정보로부터 분류 및 인식 기능을 가능하게 한다.



(그림 1) CNN의 구조

3. 실험

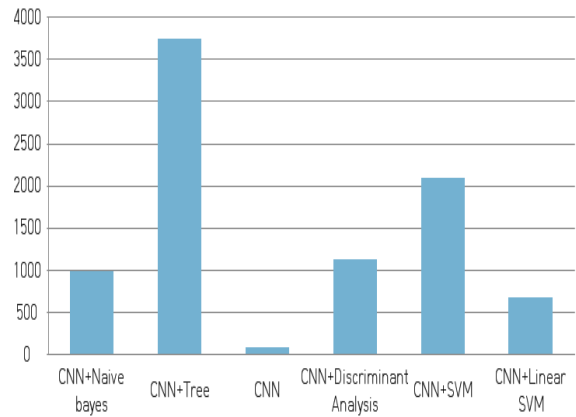
실험은 총 6가지의 방법으로 진행하였다. 기본 컨볼루션 신경망의 결과와 컨볼루션 신경망에 분류기를 합쳐 나온 결과를 비교하기 위하여 진행하였다. 실험에서 사용한 데이터는 컨볼루션 신경망에서 영상 이미지 인식 및 분류에 사용되고 있는 MNIST 데이터를 사용하였다. MNIST 데이터는 총 60000개의 학습 이미지와 10000개의 테스트 이미지로 구성되어있고 0부터 9까지의 숫자로 되어있다. 실험에 사용한 분류기는 나이브 베이즈(Naive bayes), 트리(Tree), 판별 분석(Discriminant Analysis), 서포트 벡터 머신(SVM), 선형 서포트 벡터 머신(Linear SVM)[3]을 사용하였다. 컨볼루션 신경망으로 사용한 모델은 아키텍처 모델 중 ImageNet-Alex-Net[4]을 사용하였다. 실험과정은 첫 번째로 분류율은 컨볼루션 신경망을 이용하여 학습 데이터의 특징과 테스트 데이터의 특징을 추출한다. 이 후 분류기를 생성한 뒤 추출된 테스트 데이터의 특징을 이용하여 예상 라벨들을 찾는다. 이 후 예상 라벨과 테스트 라벨을 비교하여 혼동 행렬(Confusion matrix)을 만든 후 혼동 행렬을 확률 유형 값을 가지게 변환한 뒤 분류율을 찾는다. 속도 실험은 데이터를 불러들이는 것부터 시작하여 결과를 보여주는 데까지 측정하였다. 표1과 그림 3은 각각 실험 결과를 보여준다.



(그림 2) 각 분류기 별 실험 과정

<표 1>. M-NIST 데이터 분류율 결과

종류	결과
CNN+Naive bayes	63.97%
CNN+Tree	85.08%
CNN	91.09%
CNN+Discriminant Analysis	98.87%
CNN+SVM	99.03%
CNN+Linear SVM	98.98%



(그림 3) M-NIST 데이터 분류 속도 결과

4. 결론

컨볼루션 신경망과 컨볼루션의 다양한 분류기를 붙여 성능을 비교하였다. 실험 결과 중 분류 결과를 보면 판별 분석, 서포트 벡터 머신, 선형 서포트 벡터 머신이 다른 분류기보다 성능이 높은 것을 확인 할 수 있었다. 성능이 떨어진 분류기가 다른 분류기에 비해 좋지 않다고 할 수 없지만, 이미지 분류를 목적으로 할 때에는 판별 분석, 서포트 벡터 머신, 선형 서포트 벡터 머신이 다른 분류기보다 높은 성능을 보이는 것을 확인하였다. 그러나 속도를 비교해보면 판별 분석과 서포트 벡터 머신이 선형 서포트 벡터 머신에 비해 많은 시간을 소요하는 것을 확인 할 수 있었다. 실험한 결과 전체를 보면 컨볼루션 신경망만을 사용하는 것보다는 분류기를 붙여주는 것이 실험 결과를 토대로 더 좋은 성능을 보인다는 것을 확인할 수 있었다. 그 중에서도 서포트 벡터 머신이 다른 분류기에 비해 고성능을 보여준다는 것을 확인할 수 있었다.

감사의 글

○ (국문) 이 논문은 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임(NRF-2015R1D1A1A01060701)"

참고문헌

[1] F. Rosenblatt, "The Perceptron : A Probabilistic Model for Information Storage and Organization in the Brain", Vol 65, No. 6, pp 386-408, 1957

[2] Yann LeCun, Leon Bottou, Yoshua Bengio, and Patrick Haffner, "Gradient-Based Learning Applied to Document Recognition", Vol 86, No. 11, pp 2278-2324, November 1998

[3] Yichuan Tang, "Deep Learning using Linear Support Vector Machines", Workshop on Challenges in Representation Learning, ICML, 2013

[4] Alex Krizhevsky, Ilya Sutskever and Geoffrey E. Hinton, "ImageNet classification with deep convolutional neural networks.", NIPS, 2012