

객체의 분류를 위한 효율적인 다층퍼셉트론의 설계 및 구조에 관한 연구

이용규*, 고형일**, 이일병*
 *연세대학교 컴퓨터과학과, **기산전자 기술연구소
 e-mail: uto4247@yonsei.ac.kr*, silent@yonsei.ac.kr** ,
yillbyunglee@yonsei.ac.kr*†

A Study on the design and Structure of Multi-Layer Perceptron for Effective Classifying Objects

Yong-Kyu Lee*, Hyeong-il Ko**, Yillbyung Lee*†
 *Dept of Computer Science, Yonsei University
 **R&D Laboratory, Kisan Electronics Co., Ltd.

요 약

다층 퍼셉트론 분류기는 그 패턴 분류 성능이 훌륭하여 오랜 기간 동안 여러 응용분야에서 사용되어 왔다. 그러나 다른 분류기보다 학습시간이 오래 소요된다는 점이 문제로 지적받아 왔다. 따라서 본 논문은 회전하는 객체의 분류를 위하여 다층 퍼셉트론의 학습시간을 줄이는 효율적인 신경망 시스템을 제안한다. 주성분 분석법을 이용하여 원 데이터의 정보를 가장 잘 잘 나타내도록 변환한 뒤, 그 결과를 다층 퍼셉트론 분류기의 입력으로 사용하였다. 제안하는 시스템은 기존 다층 퍼셉트론 분류기와 비교하였을 때 학습시간을 줄이면서 좀 더 높은 인식률을 보였다.

1. 서론

다층퍼셉트론은 패턴분류의 문제에 있어서 분명 훌륭한 알고리즘임에는 틀림없다. 그러나 긴 학습시간의 문제가 있다.[1] 이는 곧 입력레이어의 뉴런의 개수와도 연결이 된다. 본 논문에서는 회전하는 객체의 분류를 위해 주성분 분석법을 이용하여 입력뉴런의 수를 현저하게 줄이면서 좀 더 높은 성능의 효율을 낼 수 있는 방법을 기술한다.

2. 관련연구

2.1 주성분 분석법

주성분 분석법은 데이터에 있어서 불필요한 차원을 제거 할 수 있는 방법이다. 다시 말해 데이터의 차원을 줄이면서 분류에 도움이 되는 특징이나 속성은 최대한 유지시키려는 것이다. 이는 데이터의 분산이 큰 방향으로 데이터를 사영시켜 정보손실을 최소화한다. 데이터의 평균과 공분산은 <식2.1>으로 나타낼 수 있다.[2]

$$\sum = \frac{1}{N} \sum_{i=1}^N (x_i - m_x)(x_i - m_x)^T$$

$m_x = \text{평균}, N = \text{데이터수}, x_i = \text{데이터}, \sum = \text{공분산}$
 <식2.1> 데이터의 평균과 공분산


이렇게 구한 데이터의 공분산은 고유분석을 통하여 고유값 행렬과 고유벡터 행렬을 구하게 된다<식2.2>. 고유값은 해당 고유벡터에 내적을 통하여 얻는 값들의 분산을 나타내게 된다. 그러므로 고유값이 클 때에 해당하는 고유벡터에 사영시켜서 얻는 특징값은 데이터의 손실을 적게 할 수 있다. [2][3]

$$\sum = UAU^T,$$

$\sum = \text{공분산 행렬}, U = \text{고유벡터 행렬}, A = \text{고유값 행렬}$
 <식2.2> 고유분석

2.2 다층 퍼셉트론

다층퍼셉트론은 (그림 2.1)과 같은 구조를 가진다. 입력층과 한 개 이상의 은닉층, 출력층으로 이루어지며 각 층 간에는 연결강도가 존재한다.[4]



(그림 2.1) 다층퍼셉트론의 구조

† 교신저자

다층퍼셉트론에서의 학습은 바로 이 연결강도의 변화를 통하여 오류에너지를 줄이는 방법이다<식.2.3>.

u : 입력층과 은닉층의 연결강도

v : 은닉층과 출력층의 연결강도

E : Error energy , p : learning rate

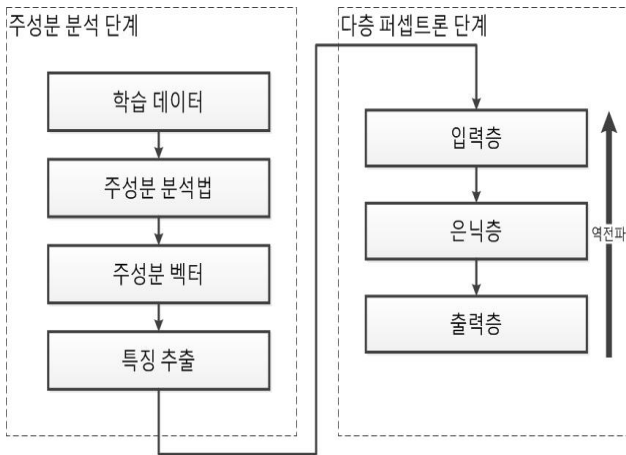
$$u(t+1) = u(t) - p \frac{\partial}{\partial u} E, \quad v(t+1) = v(t) - p \frac{\partial E}{\partial v}$$

<식 2.3> 연결강도 변화율

오류에너지를 출력층에서 입력층쪽으로 역전파하여 연결강도를 수정하게 된다. 이를 위하여 오류역전파 알고리즘을 이용하여 학습 시키게 된다. [2][7]

3. 시스템의 설계

제안하는 시스템의 구조는 (그림3.1)과 같다.



(그림 3.1) 시스템의 구조

학습시킬 데이터에 대해서 주성분 분석법을 통하여 데이터를 사영시킬 주성분벡터를 구하고 구해진 주성분 벡터의 개수를 정하여 내적을 이용하여 특징을 추출하게 된다. 특징 추출된 데이터를 다층퍼셉트론의 입력층에서 받아 전방향 단계 과정을 통하여 출력층까지 나아가게 되고 목표 값과 실제 출력 값의 차이를 줄이기 위하여 오류역전파 알고리즘을 이용하여 연결강도를 수정하게 된다. 이렇게 학습된 분류기는 테스트데이터도 동일한 주성분 벡터에 사영시켜 입력층에 넣어주게 되고 출력층에서 가장 높은 값을 출력하는 클래스로 할당하게 된다.

4. 실험

본 실험은 Matlab(R2011b)를 이용하여 구현하였으며 실험환경은 CPU는 Intel(R) Core i5 3210M 2.50GHz, RAM DDR3 8GB, OS는 MS Windows 7 64bit 이다. 데이터는 COIL-20 database를 사용하였다(그림4.1). 총 1440장으로 구성되어 있으며 객체 당 5°씩 회전하여 72장씩 20개의


클래스가 존재한다[12].



(그림4.1) COIL-20 데이터 샘플


객체의 0°-235°에 해당하는 960개는 학습데이터로 240°-355°에 해당하는 480개는 테스트데이터로 사용하였으며 데이터의 크기는 32 * 32 pixel의 값으로 축소하여 사용하였다.

(그림4.2)는 학습데이터에서 주성분벡터의 개수를 정하기 위하여 고유치 합 비율의 변화를 나타낸 것이다.[3]



(그림4.2) 고유치 합 비율

주성분 벡터의 수를 61개 사용할 때 역치값이 0.9800으로 정보의 손실양이 전체의 2%이하임을 알 수 있다. 본 실험을 위하여 주성분벡터의 수는 61개를 사용하였으며 선택한 주성분벡터에 데이터를 내적으로 사영시켜 본래의 데이터의 1024차원을 61차원으로 줄일 수 있다. 그림(4.3)은 데이터를 사영시킬 고유벡터를 고유치가 큰 순으로 나열한 30개를 보여준다.



(그림 4.3) 30개의 고유벡터

비교실험을 위하여 오류역전파를 위한 학습계수는 0.05, 학습 횟수는 500으로 고정하고 실험하였다.

<표4.1>은 기존의 다층퍼셉트론의 은닉뉴런의 개수별 오류율을 나타내고 <표 4.2>는 제안하는 구조의 은닉뉴런의 개수별 오류율을 나타낸다.


<표 4.1> 기존의 다층퍼셉트론 오류율

Hidden Neuron	Training Data	Test Data	Error Rate	학습 시간 (seconds)
	MSE	MSE		
64	0.0151451	0.105156	15.83%	53.36
128	0.0188361	0.100966	13.96%	90.10
256	0.0183183	0.100985	14.58%	182.18
512	0.0177071	0.103716	15.21%	338.25
768	0.0181538	0.10273	12.92%	535.58
1024	0.0170347	0.103381	13.75%	662.94

<표 4.2> 제안하는 구조의 오류율

Hidden Neuron	Training Data	Test Data	Error Rate	학습 시간 (seconds)
	MSE	MSE		
20	0.0333553	0.113426	16.25%	11.74
30	0.0287461	0.107334	14.58%	12.39
40	0.0287539	0.0983795	11.88%	13.49
80	0.0214852	0.100741	14.58%	16.94
90	0.0208648	0.100917	13.96%	18.66
100	0.02182	0.098083	12.5%	19.58

실험을 통해 알 수 있듯이 가장 낮은 오류율을 보인 구조는 기존의 다층퍼셉트론은 1024-768-20(입력-은닉-출력)으로 12.92%의 오류율을 보였다. 제안하는 구조 61-40-20(입력-은닉-출력)는 가장 낮은 오류율은 11.88%였다. 이 두 구조를 비교해 보면 제안하는 구조가 오류율 뿐만 아니라 학습시간에서도 더 효율적인 것을 알 수 있다. (그림4.4)는 두 구조의 학습 횟수에 따른 테스트 데이터의 오류율을 나타낸다.



(그림 4.4) 학습 횟수에 따른 오류율

(그림4.4)에서 알 수 있듯이 기존의 MLP분류기에 비하여 제안하는 구조의 분류기가 좀 더 낮은 오류값에서 수렴하는 것을 확인할 수 있다.

5. 결론 및 향후 연구과제

실험을 통하여 회전하는 객체에 대하여 기존의 다층퍼셉트론보다 좀 더 효율적인 시스템을 기술하였다. 주성분 분석법을 통하여 분류에 필요 없는 특징들을 제거 할 수 있고 실제로 학습해야할 연결강도의 수를 대폭 줄일 수 있다. 입력 뉴런의 개수가 한 개가 늘어날 때마다 실제로 학습해야할 연결강도의 수는 은닉뉴런의 개수만큼 늘어나게 된다. 그러므로 상당히 학습시간을 줄일 수 있다. 그러나 다층퍼셉트론의 설계에 있어서 가변적인 요소가 너무 많이 존재한다. 은닉층의 개수, 은닉뉴런의 수, 학습계수 등 모두 실험을 통하여 정해줘야 하는 값들이다. 데이터에 따른 가변적인 요소를 최적화 해줄 수 있는 방안을 찾아야 할 것이다.

참고문헌

- [1] 김대수 “신경망 이론과 응용(1)” 17판. 진한엠엔비
- [2] 오일석 “패턴인식”. 교보문고
- [3] 박혜영, 이관영 “패턴인식과 기계학습”. 이한출판사
- [4] Simon Haykin “Neural Networks a comprehensive foundation” 2nd Ed. Pearson
- [5] 한학용 “패턴인식 개론” 개정판. 한빛미디어
- [6] Lindsay I Smith “A tutorial on Principal Components Analysis”. 2002
- [7] David E.Rumelhart, Geoffrey E.Hilton, Ronal J.Williams “ Learning representations by back-propagating errors”. 1986
- [8] 오창식 “뉴로컴퓨터 개론”. 내하출판사
- [9] Widrow, B., Lehr, M.A., “30 years of Adaptive Neural Networks: Peceptron, Madaline, and Backpropagation,” Proc. IEEE, vol 78, no 9, pp. 1415-1442, 1990
- [10] Richard P.Lippmann “Pattern Classification Using Neural Networks” 1989
- [11] Ian Jolliffe “Principal Component Analysis” 2nd Ed. Springer
- [12] Sameer A.Nene, Shree K.Nayar, Hiroshi Murase, “Columbia Object Image Library (COIL-20)” No. CUCS-005-96. 1996