

비반복적 훈련 신경망을 이용한 숫자인식

이재승*, 안도랑, 이동욱
동국대학교 전기공학과

Digits Recognition Using a Non-Iterative Neural Network

Jae-Seung Lee*, Do-Rang Ahn, Dong-Wook Lee
Dept. of Electrical Eng., Dongguk Univ.

Abstract - Most neural network learning schemes are derived from learning systems which are generally iterative in nature. But, when the given input-output training vector pairs satisfy a PLI condition, the training and the application of a hard-limited neural network can be achieved non-iteratively with very short training time and very robust recognition when it is applied to recognize any untrained patterns.

In this paper, a method of expanding the dimension of training pattern data is suggested. The proposed method demonstrates better performance and robustness.

1. 서 론

패턴 인식은 다양한 응용분야를 가지고 있고 그 중에서 숫자 인식은 다른 인식 대상에 비하여 비교적 오래 전부터 연구되어 왔다. 현재 우편번호인식, PDA 등의 일부 응용범위를 가지고 있지만, 특히 컴퓨터의 발전과 정보기술의 결합으로 응용범위가 더 넓어지고 있다.

대부분의 신경망은 학습과정 또는 훈련과정이 반복적인 과정으로 이루어진다. 즉, 어떤 훈련패턴과 그에 대응하는 목표값(Target vector)을 사상(Mapping)하게 되는데 어느 수령범위를 만족할 때까지 연결가중치 행렬(Connection Matrix)이 단계적으로 반복적인 과정을 거치면서 조정된다. 반면에 OHP(One-layered,

Hard-Limited, Perceptron)의 비반복적 훈련 신경망은 PLI (Positive-Linear-Independency) 조건을 만족하는 패턴에 대하여 한 번에 연결가중치 행렬을 구할 수 있다. 이와 더불어 자동특징벡터 추출 및 자동특징벡터 경쟁과정을 통하여 잡음과 변형에 대하여 좀 더 강인한 시스템을 구성할 수 있다[1].

본 논문에서는 위의 비반복적 훈련 신경망 특성을 이용하여 패턴에 대하여 좀 더 강인하고 인식률을 향상을 위한 알고리즘을 제안하였다. 제안한 알고리즘은 패턴데이터의 차원을 확장함으로써 특징벡터의 수가 늘어나고, 결과적으로 특징벡터들의 가중치강화를 할 수가 있다. 그리고, 모의실험결과 오프라인 인쇄체 숫자에 대하여 제안한 알고리즘이 기존의 방법보다 더 좋은 결과를 보여주었다. 특히, 작은 크기의 패턴데이터에 대하여 기존의 방법보다 상대적으로 좋은 인식률 향상의 가능성을 살펴보았다.

2. 본 론

2.1 신경망

1940년대에 시작된 신경망 관련 연구는 최초의 신경망 모델로 여겨지는 맥클러-피츠 모델에서의 단순한 논리 구현과 헵의 시냅스라고 알려진 연결강도 조정을 위한 생리학적 학습 규칙으로부터 시작되었다. 그 후로 신

경망 이론은 1957년 로젠블릿에 의해 발명된 퍼셉트론 모델이 제안되면서 활발한 연구가 진행되었다. 그러나, 선형 분리만 가능하다는 제한점이 알려지면서 20년간 침체기를 맞이하였다. 그러나, 1980년대 중반에 입력 층, 출력층, 은닉층을 쓰는 다층 퍼셉트론 모델과 오류 역전파학습 알고리즘의 제안으로 선형 분리문제뿐만 아니라 여러 가지 문제점을 해결할 수 있었으며 이로 인하여 신경망 연구가 새롭게 활기를 띠게 되었다. 또한, 다양한 패턴인식의 가능성을 보여주고 있다.

2.1.1 다층퍼셉트론

다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망으로 그림 1과 같이 계층구조를 가지고 있다. 그리고, 각 층내의 연결과 출력층에서의 입력층으로의 직접적인 연결은 존재하지 않는 전방향의 네트워크이다.

단층일 경우는 선형분리, 2층인 경우 오목한 개구역 또는 오목한 폐구역을 형성하며, 3층인 경우에는 이론상 어떠한 형태의 구역도 형성할 수 있다.

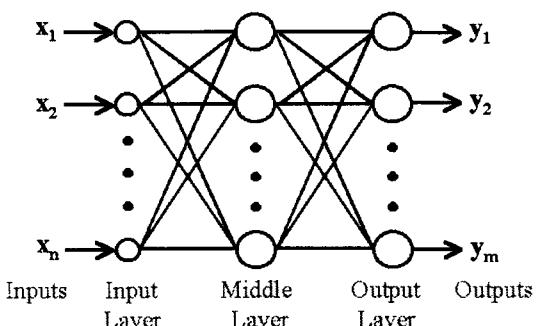


그림 1. Two-layered Perceptrons

2.1.2 오류역전파 알고리즘

반복적 구배(Iterative gradient) 알고리즘의 일종으로 입력층의 각 유니트에 입력값을 주면, 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해나간다. 특히, 지도학습에서는 입력 및 원하는 출력 패턴이 네트워크에 제시되는데, 네트워크는 입력층에 주어진 입력패턴이 출력층에 전파되면서 변한 출력패턴을 목표패턴과 비교한다. 네트워크에서 출력된 패턴이 일치하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우는 얻어진 출력패턴과 목표패턴의 차이를 감소시키는 방향으로 네트워크의 연결강도를 조절하여 학습을 한다. 네트워크에 은닉 유니트가 없

는 경우는 델타 규칙과 동일하다. 즉 p번째의 입력/목표 출력 패턴이 제시되는 경우에 노드 i에서 노드 j로의 연결강도 변화는 다음의 식(1)과 같이 표현된다.

$$\Delta_p w_{ji} = \eta(t_{pj} - o_{pj})i_{pj} = \eta\delta_{pj}i_{pj} \quad (1)$$

여기서, t_{pj} 는 p번째 목표 출력의 j성분, o_{pj} 는 p번째 입력 패턴으로부터 네트워크가 계산한 출력의 j성분, i_{pj} 는 p번째 입력 패턴의 i성분, $\delta_{pj} = t_{pj} - o_{pj}$ 는 목표 출력과 실제 출력의 차(오차), $\Delta_p w_j$ 는 입력 층 i 유니트로부터 출력 층 j 유니트에의 연결강도의 변화량이다.

2.2 비반복적 훈련 신경망

오류역전파 알고리즘을 이용한 신경망은 반복적인 과정으로 시스템이 훈련되어지므로 훈련시간이 길다. 반면에 전달함수가 계단함수(Hard-limited Function)를 가지는 비반복적 OHP(One-layered, Hard-Limited, Perceptron)신경망은 추가변수(Slack constant)를 이용하여 연결가중치 행렬을 비반복적으로 구하므로써 훈련 시간이 짧다. 이를 위하여 패턴 데이터는 다음의 PLI 조건을 만족하여야 한다. 그리고, 이에 따른 시스템의 특성인 자동특징벡터 추출 및 자동특징벡터 경쟁을 가지는 시스템을 구성할 수 있다.

2.2.1 PLI 조건

그림 2와 같은 OHP 신경망에 대하여 N개의 원소로 이루어진 M개의 아날로그 패턴데이터와 P차원 목표값을 가지는 V의 이진데이터가 있을 때 즉,

$$\{U_m \rightarrow V_m, m=1 \text{ to } M\} \quad (2)$$

단, $2^P \geq M$

에서 다음 부등식(3)을 만족하고

$$A_i \bullet Y_{mi} > 0, \quad m=1 \text{ to } M, i \text{ fixed.} \quad (3)$$

단, $Y_{mi} = v_{mi} U_m$, with $v_{mi} (= \pm 1)$ being the i-th bit of V_m .

위의 부등식(3)은 다음의 필요충분조건을 만족할 때, A_i 를 구할 수 있다.

All $\{Y_{mi}, i \text{ fixed}, m=1 \text{ to } M\}$ are positively, linearly independent(PLI). 즉,

$$\sum_{m=1}^M p_m Y_{mi} \neq 0, \quad (i \text{ fixed}, p_m \geq 0) \quad (4)$$

PLI는 선형독립보다 더 넓은 범위의 데이터이고, 대부분의 패턴데이터는 선형독립이므로 PLI 조건을 만족한다.

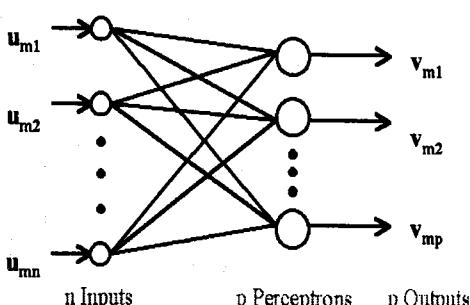


그림 2. OHP 신경망

따라서, 연결가중치 행렬 A_i 는 적절한 추가변수(Slack constant) q_{mi} 를 이용하여 다음 식(5)와 같이 구할 수 있다.

$$A_i \bullet Y_{mi} = q_{mi}, \quad m=1 \text{ to } M, i \text{ fixed.} \quad (5)$$

위의 식에서 q_{mi} 를 적절히 조절하면 매우 빠르게 훈련 시킬 뿐만 아니라 간단한 시스템을 구성할 수 있다.

2.2.2 자동특징벡터 추출 및 경쟁

추가변수의 값은 부분행렬의 개수 K로 둘 때 가장 간단하고 최적화된 시스템을 만들 수 있다. 그리고, 추가변수로 바꾼 부등식들은 다음 식(6)과 같은 행렬형태로 표현되어 질 수 있다.

$$AU = QV \quad (6)$$

단, $Y_{mi} = v_{mi} U_m = U_m / v_{mi}$

A: PxN 행렬, U: NxM 행렬,

Q: PxP 대각행렬, V: PxM 이진행렬

U행렬을 재배치하여 MxM부분행렬 U^k 로 나누고 각 U^k 의 행렬식이 큰 순서대로 내림차순하여 배열하고, 그에 따른 A행렬도 A^k 로 나누고 배치한다. 그러면 다음의 식(7)과 같이 표현되어 질 수 있다.

$$\sum_{k=1 \text{ to } K} A^k U^k = QV \quad (7)$$

위의 식(7)에서 각각 A^k 는 다음의 식(8)과 같이 구해진다.

$$A^k = V(U^k)^{-1} \quad (8)$$

여기서 각 U^k 는 패턴벡터 U의 k번째 특징벡터들이다. 자동적으로 특징벡터들을 만들어준다. 또한, 다음의 식(9)와 같이 인식과정 중에 가중치를 부여할 경우에

$$S = Sgn[\sum_k w_k A^k T^k] \quad (9)$$

단, w_k 는 부분행렬 U^k 의 행렬식의 절대값, T^k 는 테스트특징벡터

행렬식이 가장 큰 특징벡터에 가장 큰 가중치를 부여하여, 접음과 변형에 간단한 시스템을 만들 수 있다.

2.3 제안알고리즘

비반복적 신경망의 간이성과 특징벡터의 가중치를 강화하기 위하여 가장 큰 행렬식을 가지는 특징벡터에 대하여 특징벡터를 구한다. 즉, 다음과 식(10)과 같이 특징벡터의 확장이 발생한다.

$$n C_M \rightarrow \sum_{n=N}^M C_M \quad (10)$$

그에 따른 연결함수와 패턴벡터가 다음과 같은 등식(11)이 만족되는 행렬함수로 변환된다.

$$AU = QV \rightarrow A'U' = QV \quad (11)$$

단, A' : $P \times N'$ 행렬, U' : $N' \times M$ 행렬,

$$N' = \sum_{n=N \text{ to } M} n$$

위의 식(11)은 비반복적 신경망의 특징벡터 표현식

$$\begin{aligned} \sum_{k=1 \text{ to } K} \mathbf{A}^k \mathbf{U}^k &= \mathbf{QV} \\ \Rightarrow \sum_{k'=1 \text{ to } K'} \mathbf{A}^k \mathbf{U}^k &= \mathbf{QV} \end{aligned} \quad (12)$$

에서 $K' \gg k$ 를 만족하는 더 많은 특징벡터를 얻을 수 있다. 또한, 인식과정 중에서 가중치 값이 기존 방법의 주요특징벡터를 중심으로 작은 분포됨으로서 좀 더 잡음과 변형에 강인한 시스템을 구성할 수 있다.

2.4 전처리

전처리는 일반적으로 영상의 질을 개선하거나 특정한 응용목적에 알맞도록 변환시키는 영상처리를 의미한다.

여기에는 공간영역적 방법과 주파수영역적 방법이 있는데, 본 논문에서는 다양한 크기의 문자패턴을 공간적으로 일정한 크기를 만들기 위하여 크기정규화를 수행하였다. 크기정규화를 수행하고 세선화 과정을 수행하였다. 또한, 주파수 영역적 방법으로 다음의 식(13)과 같이 2차원 푸리에변환을 통하여 패턴데이터를 만들었다.

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \exp \left[-j2\pi \left(\frac{ux}{M} + \frac{vy}{N} \right) \right] \quad (13)$$

단, $x = 0, 1, 2, \dots, N-1$, $y = 0, 1, 2, \dots, M-1$
 $u = 0, 1, 2, \dots, M-1$, $v = 0, 1, 2, \dots, N-1$

위의 변환된 값의 크기값, 즉 $|F(u, v)|$ 값을 패턴데이터로 사용하였다.

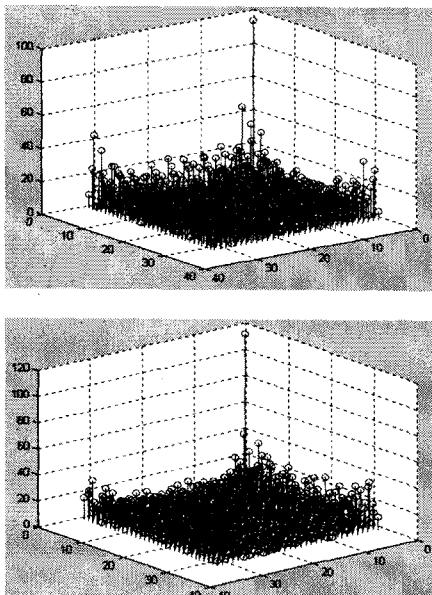


그림 3. 2D-FFT변환된 패턴데이터 표본

다음의 그림 4는 크기정규화된 2진 영상 및 세선화 과정을 거친 숫자 패턴에 대한 영상을 나타내었다.



그림 4. 크기정규화된 영상 및 세선화 영상

2.5 실험 및 결과

MATLAB에서 비반복적 신경망의 자동특징벡터 추출 및 자동특징벡터 경쟁의 특성을 이용하여 기존방법의 신경망과 제안된 방법의 신경망을 실험하였다. 패턴데이터는 오프라인 인쇄체 문자에 대하여 훈련을시키고, 스캐너로 입력받은 2진 영상을 테스트 데이터로 하였다. 5개의 훈련데이터 및 10개의 훈련데이터에 대하여 테스트하였다. 다양한 크기와 약간의 기울어진 문자의 영상에 대하여 정규화크기를 32x32 및 16x16 크기의 영상으로 테스트한 결과를 표 1에 정리하였다.

	기존의 방법		제안한 방법	
	32x32	16x16	32x32	16x16
5가지 숫자	87%	80%	91%	86%
10가지 숫자	82%	73%	84%	81%

표 1. 인식률

실험결과에서 볼 수 있듯이 제안한 특징벡터의 증가로 인식률이 향상이 있음을 보여주었다. 특히, 패턴데이터의 크기가 작아질 경우에 본 논문에서 제시한 방법이 좀 더 효율적으로 인식됨을 알 수 있다.

3. 결 론

본 논문에서는 일반적인 반복적인 훈련신경망과는 달리 비반복적 훈련신경망을 이용하여 숫자인식 시스템을 구성하여 보았다. 특히, 자동특징벡터 추출 및 자동특징벡터경쟁의 특성을 이용한 시스템은 여러 논문에서 제시한 다양한 특징벡터추출방법과는 달리 패턴데이터 자체에서 여러 패턴의 구별되는 특징벡터를 추출하고 주요특징벡터에 대하여 가중치를 강화하여 특징벡터의 경쟁을 유도하는 특성이 있다.

또한, 제안한 알고리즘은 좀더 강인한 시스템을 구성하기 위하여 특징벡터의 확대를 통하여 가중치를 강화함으로써 강인한 시스템을 구성하였다.

향후, 전처리에서 패턴을 좀더 범용적으로 처리한다면 다른 소규모 패턴에 대하여 다양한 응용분야를 가질 수 있다. 그리고, 중규모 이상의 패턴에 대하여 관련연구가 필요하리라 생각된다.

(참 고 문 헌)

- [1] Hu, C.J, "Feature Competition and Feature Extraction in a Noniterative Neural Network Pattern Recognition Scheme", SPIE, Proceedings of the Optical Pattern Recognition IX, 146-151, 1998
- [2] Carl G, "Pattern Recognition Using Neural Networks", Oxford, 1997
- [3] 김희승, "영상인식", 생능출판사, 1997
- [4] 김대수, "신경망 이론과 응용(I)", 하이테크정보, 1997
- [5] 김대수, "신경망 이론과 응용(II)", 하이테크정보, 1997