

Feature Extraction of Letter Using Pattern Classifier Neural Network

柳 泳 材*

(Young-Jae Ryoo)

Abstract - This paper describes a new pattern classifier neural network to extract the feature from a letter. The proposed pattern classifier is based on relative distance, which is measure between an input datum and the center of cluster group. So, the proposed classifier neural network is called relative neural network(RNN). According to definitions of the distance and the learning rule, the structure of RNN is designed and the pseudo code of the algorithm is described. In feature extraction of letter, RNN, in spite of deletion of learning rate, resulted in the identical performance with those of winner-take-all(WTA), and self-organizing-map(SOM) neural network. Thus, it is shown that RNN is suitable to extract the feature of a letter.

Key Words : pattern classifier, relative neural network, feature extraction.

1. 서 론

최근 신경회로망은 스스로 학습하는 능력 때문에 문자인식을 비롯한 시각제어, 패턴분류 등 다양한 분야에서 널리 적용되고 있다[1, 2]. 특히 신경회로망은 문자나 형상인식에 활발히 응용되고 있다. 일반적인 화상 데이터에서 문자나 형상은 다량의 패턴 데이터로 구성되어 있다. 문자인식을 위해서는 다량의 데이터로부터 문자를 대표하는 특징(feature)을 추출하는 과정이 선행되어야 한다. 이와 같은 문자 화상 데이터에서 특징을 추출하는 과정은 다량의 데이터를 패턴별로 분류하는 방법을 통하여 처리된다.

다양한 신경회로망의 종류 중 패턴분류에 사용되는 신경회로망은 무감독학습 신경회로망이다. 일반적으로 무감독학습 신경회로망의 학습규칙은 전방향에 대해서는 Hebb 규칙이, 역방향에 대해서는 경쟁학습이 사용된다. 따라서 자율학습 신경회로망이라고 하며, 경쟁학습 알고리즘을 이용하므로 경쟁학습 신경회로망이라고도 한다. 최근 다양한 무감독 신경회로망 또는 경쟁학습 알고리즘이 제안되어 데이터의 패턴분류에 사용되고 있다[3, 4].

그중 가장 대표적인 경쟁학습 신경회로망의 하나는 승자전취(Winner-Take-All; WTA)[5] 알고리즘이다. WTA는 경쟁학습 하는 동안 주어진 입력벡터와 가장 유사한 가중벡터를 가진 승자세포만 학습에 참여시킨다. 따라서 승자세포로 선택되지 못한 세포는 학습에 참여할 수 없게 되어 필요 없는 세포가 된다. 이러한 세포는 실제 시스템을 구현할 때 불필

요한 메모리로 남게 되어 그 효율성이 떨어지며, 시스템의 분류성능을 저하시킨다.

이와 같은 문제점을 보완하기 위해서 몇 가지 학습규칙이 개발되었다. Malsburg 학습규칙은 흥분성 소자와 억제성 소자를 접촉하는 방법이며, Leaky 학습모델은 승자세포와 패자세포에서 서로 다른 학습율을 갖게 하는 방법이 제안되었다[6]. Kohonen은 SOM(Self-Organizing Map) [7, 8]을 제안하여 승자세포 뿐만 아니라 주위의 이웃하는 세포도 학습에 참여시킴으로써 WTA의 단점을 극복하고자 노력하였다. SOM은 주어진 입력 데이터에 대해 가장 가까운 승자세포를 찾고 이웃(neighbor)세포를 결정하여 학습에 참여시킨다. 이때 승자세포와 이웃세포는 이웃함수(neighbor function)와 학습 횟수에 따른 학습율의 조절을 통해 결정한다. 따라서 SOM의 성능은 이웃함수의 결정과 초기 학습율의 선택에 따라 많은 영향을 받게 된다. 그런데 이러한 이웃함수와 초기 학습율은 분류하고자 하는 패턴의 복잡성과 개수에 따라 그 선택이 일정하지 않다는 단점을 가지고 있다.

따라서, 이 논문에서는 기존의 경쟁학습 알고리즘에서 요구되는 초기 학습율의 설정에 따른 문제점을 극복하기 위한 학습 알고리즘을 모색하고자 한다. 또한 화상의 문자 데이터와 같이 경계가 불분명한 패턴, 서로 크기가 다른 데이터가 혼합된 패턴에서 문자패턴의 특징을 추출하기 적합한 신경회로망을 제안하고자 한다. 2장에서는 제안하는 신경회로망에서 입력 데이터를 군집으로 분류하기 위한 거리측도인 군집들 상호간의 상대적인 거리(relative distance)를 정의하고 이를 이용한 상대 신경회로망(Relative Neural Network; RNN)을 구성한다. RNN의 기본적인 구조는 일반화된 거리측도인 Euclidean 거리를 얻어내는 부분과 상대거리를 출력하는 부분으로 이루어져 있다. 이 신경회로망과 그 근간을 이루는 학습 알고리즘을 3장에서 다룬다. 4장에서는 A 문자패턴과 Y

* 正 會 員 : 木浦大 制御시스템工學科 助教授 · 工博
 接受日字 : 2002年 10月 9日
 最終完了 : 2002年 11月 18日

문자패턴에서 특징점을 추출하는 실험을 행한다. 실험결과를 통해 WTA, SOM, 그리고 RNN의 성능을 비교 평가해본다.

2. 상대거리를 이용한 신경회로망

2.1 상대거리의 정의

본 논문에서는 다음과 같은 N 차원의 벡터 x 로 구성된 P 개의 입력패턴 X 를 M 개의 군집 Y 로 분류하고자 하는 문제를 다루어 본다.

$$\begin{aligned} x &= [x_1, x_2, \dots, x_i, \dots, x_N]^T, \\ & x_i \in R, \\ X &= [x^1, x^2, \dots, x^h, \dots, x^P], \\ & x^h \in x. \end{aligned} \quad (1)$$

M 개의 출력 $Y = [y_1, y_2, \dots, y_j, \dots, y_M]^T$ 에 연결되는 가중 벡터가 다음과 같이 존재한다.

$$\begin{aligned} W &= [w_1, \dots, w_j, \dots, w_M]^T, \\ w_j &= [w_{j1}, \dots, w_{jn}, \dots, w_{jN}]. \end{aligned} \quad (2)$$

M 개의 군집 중에 j 번째 군집에 해당하는 상대거리는 상대적 거리에 의해 정의된다. 상대적 거리는 식(3)와 같이, 소속한 j 번째 군집의 가중벡터 w_j 에 의한 Euclidean 거리 d_j 와 소속하지 않은 타 군집 k 번째 군집 w_k 와의 Euclidean 거리 d_k 의 상대적인 비를 나타낸다.

$$\begin{aligned} R_j &= \left[\frac{\sum_{k=1}^M \|x - w_j\|^q}{\sum_{k=1}^M \|x - w_k\|^q} \right]^{1/q} \\ &= \left[\frac{\sum_{k=1}^M \left(\frac{d_j}{d_k} \right)^q}{\sum_{k=1}^M 1} \right]^{1/q} \\ &= \left[\sum_{k=1}^M (r_j)^q \right]^{1/q}, \end{aligned} \quad (3)$$

단, $r_j = \frac{d_j}{d_k}, a = 2, 3, \dots$

상대거리 R_j 는 입력된 벡터 x 와 선택된 j 번째 군집의 가중 벡터의 거리가 입력벡터와 다른 모든 가중벡터의 거리에 비해 가까운 정도를 상대적으로 나타낸다.

2.2 상대 신경회로망의 구성

일반화된 신경회로망의 구조는 입력층, 은닉층, 그리고 출력층을 포함하고 있어야 한다. 따라서 상대 신경회로망도 이와 같은 요소로 구성하였다. 입력층에서 은닉층으로 전달과정을 살펴보면, 이는 입력데이터를 이용하여 Euclidean 거리 값을 산출하는 과정이다. 입력층에서 은닉층으로 결선과정에

서는 식(4)와 같이 입력데이터와 가중벡터와의 차를 전달한다. 이를 전달받은 은닉층 신경소자는 식(5)와 같은 활성화함수를 이용하여 Euclidean 거리를 구한다. 은닉층에서 출력층으로 전달과정을 보면, 은닉층 출력의 Euclidean 거리를 이용하여 결선과정에서는 식(6)과 같이 타 Euclidean거리와 비를 구하고, 출력층 신경소자의 활성화함수에 의해서는 식(7)과 같이 모든 출력소자의 가중벡터와 비교하면 상대거리를 유도할 수 있다.

$$\lambda_j = (x_i - w_{ij})^a \quad (4)$$

$$d_j = F(\lambda) = \left\{ \sum_{i=1}^N \lambda_i \right\}^{1/a} \quad (5)$$

$$r_j = \frac{d_j}{d_k} \quad (6)$$

$$y_j = G(r) = \left\{ \sum_{k=1}^M r_j \right\}^{-1} \quad (7)$$

3. 상대거리를 이용한 경쟁학습 알고리즘

3.1 가중벡터의 학습규칙

군집을 분류하는 기본적인 방법은 군집에 소속한 입력 데이터들의 중심으로 군집을 형성하는 가중벡터들을 선택하는 것이다. 모든 입력 데이터를 가중벡터의 학습에 참여시켜야 하며, 학습에 참여하는 정도는 입력된 패턴이 선택된 군집에 얼마나 유사한지에 따라 결정되어야 한다. 식 (8)은 이와 같은 사실을 기반으로 가중벡터를 결정하는 방법을 나타내었다. 입력 데이터 x^h 는 가중벡터 w_j 에 유사한 정도를 나타내는 신경회로망의 출력 y_j 에 의존하여 가중벡터 w_j 에 미치는 영향이 달라진다.

$$w_j = \frac{\sum_{h=1}^P y_j^h x^h}{\sum_{h=1}^P y_j^h} \quad (8)$$

식(8)을 k 번째 시점의 가중벡터를 결정하기 위한 식으로 변형하면 다음과 같다.

$$\begin{aligned} w_j(k) &= w_j(k-1) \\ &+ \frac{\sum_{h=1}^P y_j^h \{x^h - w_j(k-1)\}}{\sum_{h=1}^P y_j^h} \end{aligned} \quad (9)$$

가중치 변화량을 나타내면 다음과 같다.

$$\begin{aligned} \Delta w_j &= \frac{\sum_{h=1}^P y_j^h (x^h - w_j)}{\sum_{h=1}^P y_j^h} \\ &= \frac{w_{uj}}{w_{lj}} \end{aligned} \quad (10)$$

식(9)에 의하여 학습을 진행시키면 군집을 형성하는 가중 벡터들은 입력패턴으로 구성된 군집들의 중심으로 이동하게 된다. 이때 가중벡터의 변경은 기본적으로 입력벡터와 가중 벡터의 차에 의하여 이루어진다. 입력된 벡터에 의해 선택된 군집은 상대거리를 신경회로망의 출력으로 나타내고, 이 출력의 거리에 따라 가중벡터의 학습에 영향을 주게 된다. SOM은 이웃하는 소자를 학습에 참여시키기 위한 이웃함수를 결정해야 하며, 초기 학습율을 결정하여야 한다. 반면 이 논문에서 제안하는 방식은 입력패턴의 거리를 나타내는 출력 값이 학습에 참여하는 정도를 결정하게 된다. 따라서, 학습율과 같은 특별한 파라미터의 선정이 필요 없는 장점이 있다.

3.2 알고리즘 의사코드(Pseudocode)

```

Wij : Weights ← -1.0 과 1.0 사이 임의의 실수
           { 가중벡터 초기화 }

DO UNTIL 종료검사 만족할 때까지
  WijWij ← 0
  { 부분 가중벡터의 초기화 }

DO FOR 입력패턴개수 만큼 반복
  x ← Input
  { 입력벡터 설정 }

  { 전향 전파 }
  DO FOR 출력소자개수 만큼 반복
    { 은닉층 전파 }
    dj ← dj + (xj - wij)2
    { 제곱Euclidean 거리 산출 }

  DO FOR 출력소자개수 만큼 반복
    { 출력층 전파 }
    ri ← ri + dj / dk
    { 상대적거리 산출 }
    yi ← 1 / ri
    { 상대속도 산출 }

  DO FOR 출력소자개수 만큼 반복
    { 부분 가중벡터 변경 }
    Wij ← Wij + y*(x-wij)
    Wij ← Wij + y

DO FOR 출력소자개수 만큼 반복
  { 전체 가중벡터 변경 }
  Wij ← Wij + Wij / Wij
    
```

그림 1 상대 신경회로망 알고리즘의 의사코드.
Fig. 1 Pseudo code of algorithm for relative neural network.

상대 신경회로망과 알고리즘을 구현하기 위한 구체적인 의사코드는 그림 1과 같다. 초기에 가중벡터의 값은 -1과 1사이에 존재하는 임의의 실수값으로 입력한다. 학습은 각 가중치의 변화가 일정값 이하로 나타나 더 이상 학습이 필요 없는 종료조건이 나타날 때까지 반복한다. 모든 입력패턴에 대하여 학습을 수행하는 iteration과정에서는 먼저 부분 가중벡터 (W_{ij}, W_{ij})의 값을 초기화시킨다. 전방향 전파과정으로 입력세포에 패턴이 전달되면, 입력층에서 은닉층 전파와 은닉층에서 출력층 전파가 이루어진다. 은닉층에서는 입력벡터와 가중벡터에 의하여 출력소자 개수만큼의 Euclidean 거리의 제곱을 계산한다. 출력층에 전달된 Euclidean 거리의 제곱을 이용하여 출력소자 개수만큼의 상대거리속도를 출력한다.

3.3 상대 신경회로망의 구조

상대 신경회로망의 구조는 그림 2와 같다. 입력세포에 학습패턴이 전달되면, 입력층에서 은닉층으로 전파가 이루어진다. 은닉층 소자는 입력벡터와 가중벡터에 의하여 출력소자 개수만큼의 Euclidean 거리의 제곱 d_j를 출력한다. 출력층 소자는 전달된 d_j를 이용하여 출력소자 개수만큼의 상대거리 속도 y_j를 출력한다. 은닉층 소자의 활성화함수 F는 절대거리를, 출력층 소자의 활성화함수 G는 상대거리를 산출하는 함수이다.




그림 2 상대 신경회로망의 구조.
Fig. 2 Structure of relative neural network.

4. 성능비교 실험

4.1 문자 데이터 획득




그림 3 문자 데이터 획득을 위한 영상처리과정.
Fig. 3 Image processing procedure for an acquisition of letter data.

문자영상으로부터 문자를 인식하는 과정을 간략히 살펴보면 그림 3과 같다. 흑백영상의 경우 그레이 값으로 구성된 각 화소의 문자 영상데이터를 처리하게 된다. 영상에서 문자의 윤곽선을 검출하기 위해 미분연산이 사용된다. 문자가 포함된 영상은 문자와 바탕 간에 상당한 밝기 차이가 있다. 이

차이는 대개 문자의 윤곽선에 해당하며 픽셀의 그레이 값이 불연속이거나 미분이 불연속인 점이 존재하게 된다. 소벨 미분연산자와 같은 처리를 통하여 불연속적인 문자의 윤곽선을 검출할 수 있다. 문자 윤곽선 영상이 수평과 수직으로 화소 투영(pixel projection) 처리되면 문자만 존재하는 영역을 분할할 수 있게 된다. 분할된 문자영역 내에는 다량의 화소 정보로 문자를 구성하고 있다. 이와 같이 지나치게 많은 화소 정보는 문자인식을 처리하는데 효율성을 저하시킨다. 따라서 문자인식을 위해서는 문자를 대표하는 최소한의 데이터가 필요하다. 이를 문자의 특징점(feature)라고 말하며, 패턴 분류기를 이용하여 추출이 가능하다. 최근 무감독 신경회로망의 패턴분류기능은 이와 같은 문자나 형상 인식에 다양하게 활용되고 있다. 신경회로망은 문자나 형상을 이루는 다량의 데이터로부터 그 형태를 인식할 수 있는 특징점을 추출할 수 있기 때문이다. 이렇게 추출된 특징점을 이용하여 문자는 쉽게 인식될 수 있다. 따라서 문자인식을 위해서는 특징점의 추출이 매우 중요한 처리과정 중의 하나이다. 이 논문에서는 특징점을 추출하기 위해 기존의 신경회로망과 제안하는 신경회로망을 이용하여 실험해본다.

4.2 Λ 문자패턴의 특징지도


무감독 신경회로망의 패턴분류기능은 문자나 형상 인식에 다양하게 활용되고 있다. 신경회로망은 문자나 형상을 이루는 다량의 데이터로부터 그 형태를 인식할 수 있는 특징점을 추출할 수 있기 때문이다. 그림 4는 600개의 데이터로 이루어진 문자 Λ 로부터 10개의 출력으로 이루어진 특징점을 추출한 결과를 보여준다.

그림 4의 (a)를 보면, 문자 Λ 는 600개의 데이터로 구성되어 있음을 알 수 있다. 문자의 좌측부분(/)은 좌표 (-1, 0)과 (0, 1)을 직선으로 잇는 300개의 데이터로, 우측부분(\)은 좌표 (1, 0)과 (0, 1)을 직선으로 잇는 300개의 데이터로 구성되어 있다. 신경회로망은 문자의 특징을 추출하기 위해 10개의 출력을 발생한다. 이때 출력에 연결된 가중벡터는 특징점의 데이터 위치를 생성한다. 이로써 문자의 특징점 좌표 10개를 추출할 수가 있다. 그림 4의 (b)에 의하면, SOM은 좌측부분과 우측부분에 각각 5개의 출력이 추출되었음을 볼 수 있다. 그러나 특징점의 분포는 좌우 대칭이 되지 않음을 알 수 있다. 이는 문자인식에 있어서 부정확한 판단을 발생시키는 단점을 내포하고 있다. 반면, 그림 4의 (c)에서 RNN은 좌측과 우측부분에 각각 5개씩의 출력이 추출되었다. 또한 특징점의 분포가 좌우대칭을 이루고 있어 정확한 특징지도를 생성하였음을 알 수 있다.


4.3 Υ 문자패턴의 특징지도

그림 5는 600개의 데이터로 이루어진 Υ 문자로부터 10개의 출력으로 이루어진 특징점을 추출한 결과를 보여준다. 문자 패턴 Υ 은 600개의 데이터로 구성되었으며, 문자의 좌측부분(/)은 좌표 (-0.5, 1)과 (0, 0)을 직선으로 잇는 300개의 데이터로, 우측부분(\)은 중심 (1, 1), 반경 1인 원호를 잇는 300개의 데이터로 구성되어 있다. 신경회로망은 문자의 특징점을 추출하기 위해 10개의 출력을 발생하고, 출력에 연결된 가중


벡터는 특징점의 데이터를 생성한다. 그림 5의 (a)에서, WTA은 6개의 출력은 문자패턴을 추출하는데 사용이 되었으나, 4개의 출력은 사용되지 않고 있다. 이는 WTA의 단점인 학습에 참여하지 못한 출력소자의 발생이 원인이다. 따라서 패턴추출에 관여하지 못한 출력은 필요 없는 소자로 남게 되었다. 그림 5의 (b)를 보면, SOM은 9개의 출력이 정확하게 추출되었다. 그러나 1개의 출력은 문자형태와 관계없는 특징점을 추출하는 오류를 나타내었다. 반면, 그림 5의 (c)를 보면 RNN은 10개의 출력 모두 문자패턴을 대표하는 특징점을 생성하였다. 이와 같이 RNN은 문자의 특징점 추출에 우수한 성능을 보여준다.



(a) Λ 문자 데이터.
(a) Data of letter Λ .




(b) SOM에 의한 특징점 추출.
(b) Feature extraction by SOM.




(c) RNN에 의한 특징점 추출.
(c) Feature extraction by RNN.


그림 4 Λ 문자의 특징점 추출.
Fig. 4 Feature extraction of letter Λ .



(a) WTA에 의한 특징점 추출.
(a) Feature extraction by WTA.



(b) SOM에 의한 특징점 추출.
(b) Feature extraction by SOM.



(c) RNN에 의한 특징점 추출.
(c) Feature extraction by RNN.

그림 5 Y 문자의 특징점 추출.
Fig. 5 Feature extraction of letter Y.

5. 결 론

기존의 경쟁 학습망은 이웃함수의 결정과 초기 학습율의 선택에 따라 그 성능이 달라지는 문제점이 있다. 또한 학습 데이터의 복잡성과 개수에 따라 초기 학습율의 선택이 일정하지 않다는 난점을 가지고 있다. 본 논문에서는 이와 같은 문제점을 극복하기 위해 학습율의 영향을 받지 않는 경쟁 학습 알고리즘과 신경회로망을 제안하였다. 입력벡터에 대해 모든 군집의 중심벡터를 고려할 수 있는 상대거리를 정의하였다. 상대거리측도인 신경회로망의 출력값은 가중벡터를 변경하는 학습에 참여하는 정도이며, 이를 사용함으로써 기존 신경회로망의 학습율을 대체하였다.

상대거리측도와 가중벡터를 변경하는 학습규칙을 바탕으로 상대 신경회로망(RNN)의 구조를 설계하고, 알고리즘을 구현하기 위한 구체적인 의사코드를 기술하였다. 제안한 RNN의 분류성능을 실험하기 위하여 문자의 특징점 추출에 적용하였다. A문자의 특징점 추출의 경우, RNN은 SOM과 동등한 성능을 나타내었다. 반면 Y문자의 특징점 추출의 경우, RNN이 다른 경쟁학습 신경회로망보다 효과적인 분류결과를 나타내었다. 향후 제안된 RNN이 영상분류 및 형상인식과 같은 분야에 적용하여도 효과적인 결과를 얻어낼 것으로 예상된다.

참 고 문 헌

- [1] R. Desimone, "Neural Networks for Vision and Image Processing", G. A. Carpenter and S. Grossber, Eds, Cambridge, MA: MIT Press, 1992.
- [2] Young-Jae Ryoo, Young-Cheol Lim, Kwang-Heon Kim, "Classification of Materials Using Temperature Response Curve Fitting and Fuzzy Neural Network", Sensors and Actuators-A, Vol.94, Issues No.1-2, pp. 11-18, 2001.
- [3] Laurene Fausett, "Fundamentals of Neural Networks Architectures, Algorithms, and Applications", Prentice Hall, 1994.
- [4] James A. Freeman and David M. Skapura, "Neural Networks Algorithms, Applications, and Programming Techniques", Addison Wesley, 1992.
- [5] J. P. F. Sum, C. -S. Leung, K. S. Tam, G. H. Young, W. K. Kan, and L. Chan, "Analysis for a Class of Winner-Take-All Model," IEEE Trans. on Neural Networks, Vol.10, No.1, pp.64-71, 1999.
- [6] S. Y. Kung, "Digital neural networks", Prentice Hall, 1993.
- [7] T. Kohonen, "Self-Organizing Maps", Springer-Verlag, 1995.
- [8] Helge Ritter, Thomas Martinetz, and Klaus Schulten, "Neural Computation and Self-Organizing Maps", Addison Wesley, 1992.

저 자 소 개



유 영 재 (柳泳材)

1968년 1월 9일생. 1991년 전남대 전기공학과 졸업(학사). 1993년 동 대학원 전기공학과(석사). 1998년 동 대학원 전기공학과(박사). 2000~현재 목포대학교 제어시스템공학과 교수

Tel : +82-61-450-2754

Fax : +82-61-453-4843

email : yjryoo@mokpo.ac.kr