

논문 2006-43CI-2-4

패턴 분류 성능을 개선하기 위한 수정된 LVQ 방식

(The Modified LVQ method for Performance Improvement of Pattern Classification)

엄기환*, 정경권**, 정성부***

(Ki Hwan Eom, Kyung Kwon Jung, Sung Boo Chung)

요약

본 논문에서는 수정된 LVQ를 이용한 패턴 분류 방식을 제안한다. 제안한 방식은 입력 패턴의 분류 성능을 개선하기 위하여 입력 벡터와 기준 벡터 사이의 확률을 분포의 비대칭도를 계산하여 학습에 이용한다. 학습을 하는 동안 기준 벡터는 입력 벡터의 확률 분포에 근접하게 되고, 기준 벡터는 Bayes 분류기의 결정 경계에 근접하게 위치한다. 가우시안 분포의 데이터와 Fisher의 IRIS 데이터 분류를 실험하여 LVQ1, LVQ2, GLVQ와 비교하여 제안한 방식이 우수한 분류 성능을 나타낸을 확인하였다.

Abstract

This paper presents the modified LVQ method for performance improvement of pattern classification. The proposed method uses the skewness of probability distribution between the input vectors and the reference vectors. During training, the reference vectors are closest to the input vectors using the probabilistic distribution of the input vectors, and they are positioned to approximate the decision surfaces of the theoretical Bayes classifier. In order to verify the effectiveness of the proposed method, we performed experiments on the Gaussian distribution data set, and the Fisher's IRIS data set. The experimental results show that the proposed method considerably improves on the performance of the LVQ1, LVQ2, and GLVQ.

Keywords : LVQ; learning vector quantization; pattern classification; skewness

I. 서 론

신경회로망은 구조가 단순한 뉴런(neuron)이란 노드(node)들로 연결된 망(network)형태를 이루면서 학습이라는 방법으로 조직화된다. 이러한 단순한 메커니즘을 사용하는 신경회로망은 패턴 인식 분야에서 다른 접근 방법들보다 더 가능성 있는 방법으로 인정받아서 많은 연구가 이루어져 왔다.

SOFM (Self Organizing Feature Map) 및 LVQ

(Learning Vector Quantization)를 중심으로 하는 경쟁 학습 알고리즘은 화상 처리, 음성 인식과 같은 방대한 데이터를 다루는 분야를 중심으로 최근에 많이 연구되고 있다^[1-4].

LVQ의 학습은 입력과 출력 사이의 연결 벡터인 기준 벡터(reference vector)와 입력 벡터의 거리를 비교하여, 기준 벡터와의 거리가 가장 가까운 입력 벡터가 승리 벡터가 되고, 기준 벡터와 승리 벡터가 같은 클래스(class)로 분류되면 연결 벡터를 증가시키고, 다른 클래스로 분류되면 연결 벡터를 감소시키는 과정을 통해 입력 패턴은 분류가 되고 연결 벡터는 학습하게 된다.

LVQ는 중복(overlapping) 되거나 복잡하고 다차원인 입력 패턴의 경우 그 데이터를 정확하게 분류하지 못하는 문제가 있으며, 네트워크의 크기와 학습율 등을 선정할 때 최적의 방법을 찾는데 많은 어려움이 있다. 이

* 정회원, ** 학생회원, 동국대학교 전자공학과
(Department of Electronic Engineering, Dongguk University)

** 정회원, 서일대학 컴퓨터응용전자
(Department of Applied Computer Added System,
Seoil College)

접수일자: 2005년11월10일, 수정완료일: 2006년3월3일

러한 문제를 해결하기 위해서 GLVQ(Generalized LVQ), FLVQ(Fuzzy LVQ) 등의 다양한 알고리즘이 제안되었고, 많은 연구가 진행되고 있다^[5-7].

본 논문에서는 LVQ의 문제점들 중에서 복잡하고 다차원인 입력 패턴의 분류 성능을 개선하기 위한 수정된 LVQ 학습 알고리즘을 제안한다. 제안한 학습 알고리즘은 입력 패턴의 확률과 LVQ의 기준 벡터와의 확률 분포 관계를 이용하는 학습 방식으로, 입력 패턴의 분포가 가지는 특성을 분류에 이용할 수 있다는 이점이 있어서 좀 더 효율적인 패턴 분류를 할 수 있다. 제안한 방식은 입력 패턴의 확률적인 해석을 하고, 그 해석에서부터 LVQ의 기준 벡터의 확률 분포와의 관계를 유도하여 LVQ 학습 알고리즘으로 전개한다. 제안한 LVQ 학습 알고리즘의 유용성을 확인하기 위해서 가우시안(Gaussian) 확률 분포를 따르는 패턴의 분류와 Fisher의 IRIS 데이터 분류를 대상으로 LVQ1, LVQ2, GLVQ 방식과 시뮬레이션을 통해서 성능을 비교 검토한다.

II. LVQ의 입력벡터와 기준벡터의 확률적인 관계

LVQ 네트워크의 기준 벡터는 각 서브 클래스의 벡터를 나타내고, 그들의 초기 위치는 학습에 의한 네트워크 출력의 수렴에 영향을 주기 때문에 기준 벡터의 초기값 설정은 LVQ 네트워크의 분류 성능에 영향을 미친다. 임의의 입력 벡터와 기준 벡터에 대하여 입력 벡터의 확률 분포 $p(x)$ 와 기준 벡터 x 의 확률 분포는 서로 연관성을 가지고 있다^[8-12].

기준 벡터 m_j 의 확률 분포를 $q(x)$ 라 하면, 이 $q(x)$ 는 기준 벡터 m_j 의 점밀도(point density)라고 정하고, n 차원 공간의 초구면(hypersphere)을 식(1)과 같이 정의할 수 있다.

$$x_1^2 + x_2^2 + \cdots + x_n^2 = R^2 \quad (1)$$

여기서 R 은 초구면의 반지름이다. 초구면의 중심(center)을 m_j 라 하면 식(1)은 식(2)가 된다.

$$\|x - m_j\|^2 = R^2 \quad (2)$$

n 차원의 초부피(hypervolume) V_n 은 식(3)이 되는데,

$$V_n = \int_0^R S_n r^{n-1} dr = \frac{S_n}{n} R^n \quad (3)$$

여기서 S_n 은 단위 반지름(unit radius)에 대한 초구면의 n 차원 초곡면(hyper surface)을 나타낸다. 단위 초구면(unit hypersphere)은 식(4)를 만족한다^[13].

$$\begin{aligned} S_n \int_0^\infty e^{-r^2} r^{n-1} dr &= \\ \int_{-\infty}^\infty \cdots \int_{-\infty}^\infty e^{-(x_1^2 + x_2^2 + \cdots + x_n^2)} dx_1 dx_2 \cdots dx_n \\ &= \left(\int_{-\infty}^\infty e^{-x^2} dx \right)^n \end{aligned} \quad (4)$$

초곡면 S_n 을 상수로 가정해서 초부피 V_n 을 식(5)로 나타낼 수 있다.

$$V_n = \frac{S_n}{n} R^n = k R^n \quad (5)$$

여기서 k 는 상수이다. 초곡면에서 $p(x)$ 를 근사적으로 상수라 가정하여, $\|x - m_i\|^2 = \rho^2$ 로 놓고 왜곡(distortion) D 를 계산하면 식(6)과 같다.

$$D = nk \int_0^R p(x) \rho^2 \rho^{n-1} d\rho = \frac{nk}{n+2} p(x) R^{n+2} \quad (6)$$

$q(x)$ 를 기준 벡터 m_j 의 점밀도라고 했으므로 식(7)과 같이 나타낼 수 있다.

$$q(x) = \frac{1}{k R^n} \quad (7)$$

왜곡 밀도(distortion density) $I[x, q(x)]$ 를 식(8)과 같이 정의한다.

$$\begin{aligned} I[x, q(x)] &= \frac{D}{k R^n} = \frac{n}{n+2} p(x) R^2 \\ &= \frac{n}{n+2} p(x) [k q(x)]^{-\frac{2}{n}} \end{aligned} \quad (8)$$

이 왜곡 밀도를 이용하여 전체 왜곡 척도(distortion measure)를 근사화하게 된다.

$$\int I[x, q(x)] dx = \int \frac{n}{n+2} p(x) [k q(x)]^{-\frac{2}{n}} dx \quad (9)$$

독립변수 x 와 종속변수 $y = y(x)$ 를 이용하여 적분형태로 나타내면 식(10)과 같이 된다^[14].

$$\int_a^b I(x, y, y_x) dx \quad (10)$$

여기서 $y_x = \frac{dy}{dx}$ 이고, a 와 b 는 적분구간이다. 제약 조건을 포함한 함수를 식(11)과 같이 구성한다.

$$\int_a^b I(x, y, y_x) dx = constant \quad (11)$$

라그랑주 승수(Lagrange multiplier) λ 를 이용하여 라그랑주 함수 K 를 만들면 식(12)가 된다.

$$K = I - \lambda I_1 \quad (12)$$

식(12)의 함수가 정상값을 가진다면 식(13)의 오일러 라그랑주 미분방정식(Euler Lagrange differential equation)을 만족한다.

$$\frac{\partial K}{\partial y} - \frac{d}{dx} \frac{\partial K}{\partial y_x} = 0 \quad (13)$$

여기에서 $y = q(x)$ 라고 하면, 다음과 같이 나타낼 수 있다.

$$I = \frac{nk^{-\frac{2}{n}}}{n+2} p(x) [q(x)]^{-\frac{2}{n}} \quad (14)$$

$$I_1 = q(x) \quad (15)$$

$$K = I - \lambda I_1 \quad (16)$$

식(13)에 식(16)을 대입하면, I 와 I_1 은 $\frac{\partial q}{\partial x}$ 에 의존하지 않기 때문에 식(17)이 된다.

$$\frac{\partial K}{\partial q(x)} = -\frac{2k^{-\frac{2}{n}}}{n+1} p(x) [q(x)]^{-\frac{n+2}{n}} - \lambda = 0 \quad (17)$$

이 식을 전개하면 식(18)과 같이 입력 벡터의 확률 밀도 $p(x)$ 와 기준 벡터 m_j 의 확률 밀도 $q(x)$ 의 관계를 구할 수 있다.

$$p(x) = C [q(x)]^{\frac{n+2}{n}} \quad (18)$$

여기서 C 는 상수이다.

III. 제안한 수정된 LVQ

제안한 방식은 그림 1의 구성을 갖는 LVQ 네트워크에 대하여 유clidean 거리를 이용한 오차 함수를 구성하고, 그 오차 함수를 최소화하는 방향으로 특정 벡터 혹은 기준 벡터를 조정한다. 그리고 입력 패턴의 확률 분포 정보를 이용하여 학습 알고리즘을 전개한다.

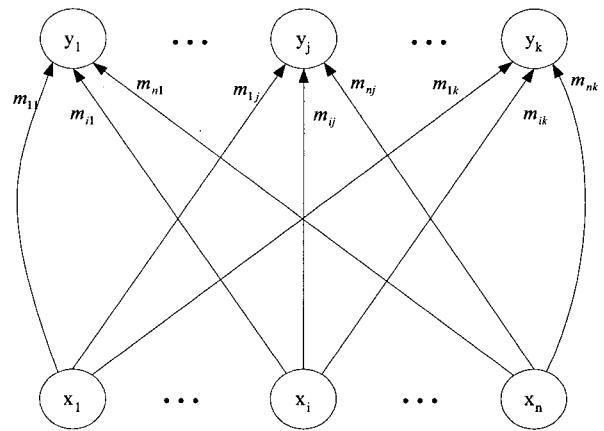


그림 1. LVQ 네트워크
Fig. 1. LVQ network.

입력 벡터를 $x \in R^n$ 이라 하고, LVQ 네트워크의 기준 벡터를 $m_i \in R^n$ 이라 하면 LVQ 네트워크는 입력 x 에 가장 근접한 m_c 를 찾는 것이다^[12].

$$\|x - m_c\| = \min_i \|x - m_i\| \quad (19)$$

왜곡 척도(distortion measure)를 식(20)과 같이 정의하고, E 가 최소가 되도록 gradient를 계산하면 최적의 m_c 를 구할 수 있다.

$$E = \int \|x - m_c\|^2 p(x) dx \quad (20)$$

여기서 $p(x)$ 는 식(21)의 입력 패턴의 확률 밀도 함수로 식(20)에 대입하면, $q(x)$ 가 m_j 와 관련된 함수이기 때문에 왜곡 척도 E 에 대한 gradient를 계산할 때에 고려하면 식(21)과 같다

$$\nabla_{m_j} \int \|x - m_c\|^2 p(x) dx$$

$$\begin{aligned}
 &= \int [\nabla_{m_c} \|x - m_c\|^2 C q(x)^{\frac{n+2}{n}} \\
 &\quad + \|x - m_c\|^2 \nabla_{m_j} C q(x)^{\frac{n+2}{n}}] dx \tag{21}
 \end{aligned}$$

식(21)의 첫 번째 항은 식(22)와 같이 나타낼 수 있다.

$$\begin{aligned}
 &\int \nabla_{m_j} \|x - m_c\|^2 C q(x)^{\frac{n+2}{n}} dx \\
 &= \int \nabla_{m_j} \|x - m_c\|^2 p(x) dx \\
 &= -2\delta_{cj}(x - m_j) \tag{22}
 \end{aligned}$$

두 번째 항은 식(23)과 같이 되며

$$\int \|x - m_c\|^2 \nabla_{m_j} C q(x)^{\frac{n+2}{n}} dx \tag{23}$$

식(23)에서 확률 밀도 $q(x)$ 의 gradient는 식(24)와 같다.

$$\nabla_{m_j} q(x)^{\frac{n+2}{n}} = \frac{n+2}{n} [q(x)]^{\frac{n+2}{n}-1} \frac{\partial q(x)}{\partial m_j} \tag{24}$$

여기서 $q(x)$ 를 가우시안 분포라 가정하면 식(25)이 되고,

$$q(x) = \frac{1}{\sqrt{2\pi}\sigma_j} \exp\left(-\frac{(x - m_j)^2}{2\sigma_j^2}\right) \tag{25}$$

기준 벡터 m_j 는 평균이라고 생각할 수 있으며, 식(24)에서 $\frac{\partial q(x)}{\partial m_j}$ 를 계산하면 식(26)과 같다.

$$\frac{\partial q(x)}{\partial m_j} = \frac{1}{\sigma_j^2} (x - m_j) q(x) \tag{26}$$

식(26)을 식(24)에 대입하면 식(27)이 된다.

$$\nabla_{m_j} q(x)^{\frac{n+2}{n}} = \frac{n+2}{n} \frac{1}{\sigma_j^2} (x - m_j) p(x) \tag{27}$$

식(23)은 식(28)이 된다.

$$\begin{aligned}
 &\int \|x - m_c\|^2 \nabla_{m_j} C q(x)^{\frac{n+2}{n}} dx \\
 &= C \frac{n+2}{n} \frac{1}{\sigma_j^2} .
 \end{aligned}$$

$$\int \|x - m_c\|^2 (x - m_j) p(x) dx \tag{28}$$

여기에서 $\|x - m_c\|^2$ 는 $i = j$ 인 경우에 최소값을 가지므로 식(29)와 같이 나타낼 수 있다.

$$\|x - m_c\|^2 = \delta_{ij}(x - m_j)^2 \tag{29}$$

첫 번째 항의 전개와 같이, 같은 입력과 기준 벡터를 클래스에 속하느냐 속하지 않느냐를 고려하여 δ 함수를 도입하면 식(30)이 된다.

$$\begin{aligned}
 &\int \|x - m_c\|^2 (x - m_j) p(x) dx \\
 &= \delta_{ij} \int (x - m_j)^3 p(x) dx \tag{30}
 \end{aligned}$$

그러므로 식(21)의 두 번째 항은 식(31)이 된다.

$$\begin{aligned}
 &\int \|x - m_c\|^2 \nabla_{m_j} C q(x)^{\frac{n+2}{n}} dx \\
 &= C \frac{n+2}{n} \frac{1}{\sigma_j^2} \delta_{ij} \int (x - m_j)^3 p(x) dx \tag{31}
 \end{aligned}$$

중심 모멘트(central moments) 개념을 적용하여 x 의 평균에 관한 3차 모멘트 μ_3 는 식(32)와 같으며 $p(x)$ 의 비대칭성을 측정하는 것이다. 이것은 확률 밀도 함수의 비틀림(skewness)이라 부른다.

$$\begin{aligned}
 \mu_3 &= E[(x - \bar{x})^3] \\
 &= \int (x - \bar{x})^3 p(x) dx \tag{32}
 \end{aligned}$$

정규화된 3차 중심 모멘트를 밀도 함수의 비대칭도(skewness) 혹은 비틀림 정도로 S 라 하며, 확률 분포가 평균값에 대한 비대칭의 방향과 그 정도를 나타내는 특성값으로 식(33)과 같다.

$$S = \frac{\mu_3}{\sigma^3} = \frac{\int (x - \bar{x})^3 p(x) dx}{\sigma^3} \tag{33}$$

식(31)은

$$\frac{1}{\sigma_j^2} \int (x - m_j)^3 p(x) dx = \sigma_j \frac{\mu_3}{\sigma_j^3} = \sigma_j S \tag{34}$$

으로 나타낼 수 있다.

따라서 식(21)은 식(35)과 같다.

$$\begin{aligned} & \int [\nabla_m \|x - m_c\|^2 C q(x)^{\frac{n+2}{n}} \\ & + \|x - m_c\|^2 \nabla_{m_j} C q(x)^{\frac{n+2}{n}}] dx \\ & = -2\delta_{ij}(x - m_j) + C \frac{n+2}{n} \delta_{ij}\sigma_j S \end{aligned} \quad (35)$$

식(35)에서 목표값과 동일한 클래스에 속하는 것을 고려하여 i 를 c 로 바꾸어주면 식(36)가 된다.

$$\begin{aligned} \nabla_{m_j} E &= -2\delta_{cj}(x - m_j) \\ & + C \frac{n+2}{n} \delta_{cj}\sigma_j S \end{aligned} \quad (36)$$

제안한 학습 알고리즘의 기준 벡터 조정은 입력 벡터와 기준 벡터의 확률 분포를 이용하여 다음과 같은 결과를 얻을 수 있다.

$$\begin{aligned} m_j(t+1) &= m_j(t) + 2\eta\delta_{cj}(x - m_j) + \eta\delta_{cj}C \frac{n+2}{n} \sigma_j S \\ &= m_j(t) + \alpha(t)(x - m_j) + \beta(t)\sigma_j S, T = C_j \end{aligned} \quad (37)$$

$$\begin{aligned} m_j(t+1) &= m_j(t) - \alpha(t)(x - m_j), T \neq C_j \end{aligned} \quad (38)$$

여기서 $\alpha(t)$, $\beta(t)$ 는 학습율을 포함하고 학습에 따라 감소하는 함수로 정의한다.

제안한 방식은 LVQ가 학습을 하는 동안에는 m_j 의 조정량을 크게 하여 학습 속도를 빠르게 하고, m_j 가 입력 벡터의 확률 분포를 나타내는 값으로 조정이 된다면 비대칭도는 0에 가깝게 되어 수렴하게 되도록 학습하는 방식이다.

제안한 방식의 학습 프로그램 루틴은 다음과 같다.

```
i = find(a ~= 0);
len = length(i);
[S,R] = size(w);
% 출력 뉴런과 목표값과 같으면
if len == 1
    x = t(i).*2 - 1;
```

```
dw = sparse(i,1:R,lr1*(p'-w1(i,:))*x,S,R,R);
% 기준 벡터를 평균으로 하여 입력 벡터에 대한 분산
% 과 3차 모멘트와 비대칭도 계산(s = m3./std.^3)
[s,m3,std]=MySkewness(P,w1);
% 기준 벡터 생성
w1 = w1 + dw + lr2*s.*std;
% 출력 뉴런과 목표값이 다르면
else
    dw = zeros(size(w1));
    x = t(i).*2 - 1;
    dw(i,:) = lr*(ones(len,1)*p'-w1(i,:)).*(x
    ones(1,R));
    w1 = w1 + dw;
end
```

IV. 시뮬레이션

제안한 학습 알고리즘의 유용성을 확인하기 위하여 가우시안 분포의 데이터와 Fisher의 IRIS 데이터를 대상으로 제안한 학습 알고리즘과 LVQ1, LVQ2, GLVQ 알고리즘과 분류 성능을 비교 검토하였다.

시뮬레이션은 P4 2.0GHz의 PC에서 MATLAB 6.5를 이용하였으며, 분류 성능의 비교를 위해 LVQ는 추가의 서브클래스(subclass)가 없이 클래스당 하나의 출력 뉴런을 할당하였다.

1. 가우시안 분포의 데이터

제안된 학습 알고리즘의 성능 평가를 위해 가우시안 분포(Gaussian distribution) 혹은 정규 분포(normal distribution)라고 불리는 데이터를 사용하여 실험을 수행하였다. 그림 2와 같이 평균을 (0.25, 0.25), (0.25, 0.75), (0.75, 0.25), (0.75, 0.75)로 하고, 분산을 0.2로 하여 4개의 클래스로 클래스 당 200개의 데이터를 생성하였다.

LVQ1, LVQ2, GLVQ는 입력 뉴런 2개, 출력총 뉴런 4개로 구성하였고, 초기 기준 벡터는 0으로 설정하였다. 학습율은 0.9에서 시간에 따라 감소하도록 하였다. 제안한 방식의 구성은 입력 뉴런 2개, 출력총 뉴런 4개로 하였고, 초기 기준 벡터는 0으로 설정하였다. 학습율 $\alpha(t)$ 와 $\beta(t)$ 는 0.9에서 시간에 따라 감소하도록 하였다.

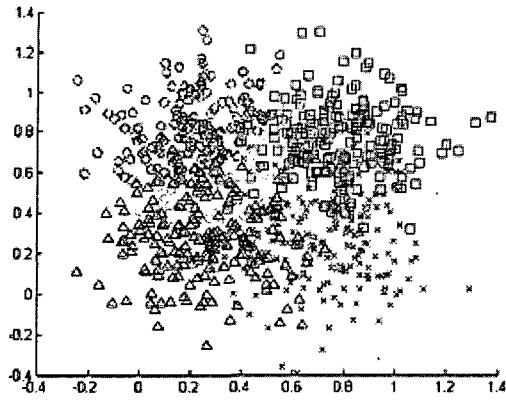
class 1: \triangle class 2: \circ class 3: \times class 4: \square

그림 2. 실험 데이터

Fig. 2. Experimental data.

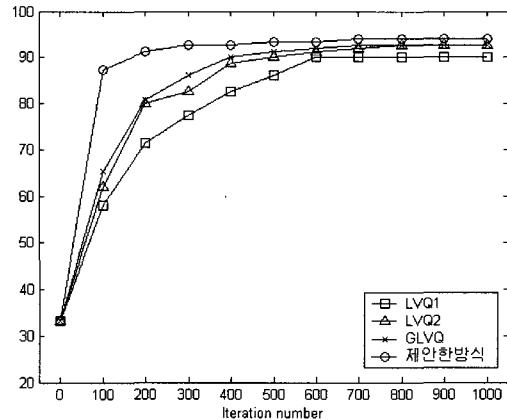


그림 4. IRIS 데이터의 패턴 분류율

Fig. 4. Pattern classification rate of IRIS data.

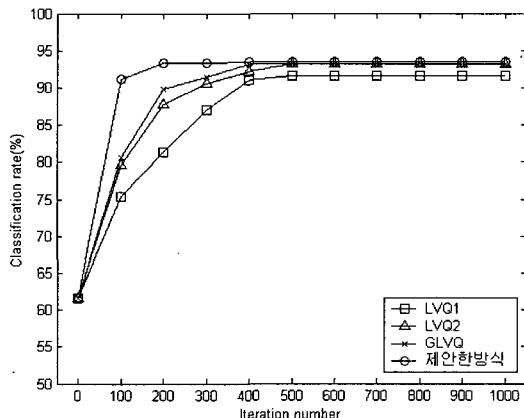


그림 3. 가우시안 데이터의 패턴 분류율

Fig. 3. Pattern classification rate of Gaussian data.

그림 3은 가우시안 데이터의 분류 결과에서 전체 800개의 데이터에 대한 분류율을 나타낸다.

그림 3에서 800개의 데이터 대하여 1000회의 학습이 종료된 후에 LVQ1은 91.63%, LVQ2와 GLVQ는 93.25%의 분류률을 얻을 수 있었으며, 제안한 방식은 93.50%의 분류율을 얻었다. LVQ1과 LVQ2는 500회 이후에 수렴을 하며, GLVQ는 400회에서 수렴을 한다. 제안한 방식은 200회 이후에 수렴을 하였다.

2. IRIS 데이터

Fisher의 IRIS 데이터는 붓꽃의 3 종류인 Setosa, Versicolor, Virginica에 대해서 꽃받침과 꽂잎의 크기 및 길이에 대해 각 종류마다 50개씩의 데이터로 구성되어 있는데, 패턴 분류나 클러스터링 해석을 위한 데이터로 널리 사용되고 있다.

LVQ1, LVQ2, GLVQ는 입력 뉴런 4개, 출력층 뉴런

3개로 구성하였고, 초기 기준 벡터는 0으로 설정하였다.

학습률 $\alpha(t)$ 와 $\beta(t)$ 는 0.9에서 시간에 따라 감소하도록 하였다. 제안한 방식의 구성은 입력 뉴런 4개, 출력층 뉴런 3개로 하였고, 초기 기준 벡터는 0으로 설정하였다. 학습률은 0.9에서 시간에 따라 감소하도록 하였다.

그림 4는 IRIS 데이터의 패턴 분류율의 결과이다. 그림 4에서 150개의 데이터 대하여 1000회의 학습이 종료된 후에 LVQ1은 90.00%, LVQ2와 GLVQ는 92.67%의 분류률을 얻었다. 제안한 방식은 94.00%의 분류율을 얻었고, 학습 횟수가 300회 이후에 수렴을 하였다. LVQ1은 600회, LVQ2는 800회, GLVQ는 700회 이후에 각각 수렴을 하였다.

IV. 결 론

본 논문에서는 LVQ를 이용한 복잡하고 다차원인 입력패턴의 분류에서 분류 성능을 개선하기 위하여 수정된 학습 알고리즘을 제안하였다. 제안한 방식은 입력 패턴의 거리 정보만을 이용하여 클러스터를 나누는 LVQ에 대하여 입력 패턴의 확률 분포를 해석하여 학습에 이용하는 방식이다. 입력 패턴과 기준 벡터에 대해서 유clidean 거리를 이용한 오차 함수를 구성하고, 이 오차 함수를 최소화하는 방향으로 기준 벡터를 조정하는 방식이다. 오차 함수의 구성에 패턴의 확률적인 분포를 이용한다. 입력 패턴의 확률 분포와 기준 벡터의 확률 분포의 관계는 초곡면 해석을 통해서 기준 벡터의 점밀도를 정의하고, 변분법을 통해서 증명을 하였다. 이렇게 구한 기준 벡터의 확률 분포로 오차 함수를

재구성하여 기준 벡터를 조정하는 학습 알고리즘을 수행하였다.

제안한 학습 알고리즘의 유용성을 확인하기 위해서 가우시안 확률 분포의 데이터, IRIS 데이터를 분류하는 실험을 통해서 입력 패턴의 거리 정보와 확률적인 분포 정보를 함께 사용하는 제안한 학습 알고리즘이 신경회로망 방식의 패턴 분류에서 기존의 LVQ1, LVQ2, GLVQ 방식들보다 우수한 분류 성능과 빠른 수렴 속도를 가짐을 확인하였다.

참 고 문 헌

- [1] Carl G. Looney, Pattern Recognition Using Neural Network, Oxford Univ. Press, 1997.
- [2] Martin T. Hagan, and Howard B. Demuth, Mark H. Beale, Neural Network Design, Thomson Learning, 1995.
- [3] T. Kohonen, "The self organizing map," Proceedings of the IEEE, vol. 78, no. 9, pp. 1464~1480, 1990.
- [4] T. Kohonen, "The self organizing map," Neurocomputing, vol. 21, no. 1~3, pp. 1~6, 1998.
- [5] Simon Haykin, Neural Networks, 2/E: A Comprehensive Foundation, Prentice Hall, 1998.
- [6] A. I. Gonzalez, M. Grana, and A. D'Anjou, "An

analysis of the GLVQ algorithm," IEEE Transactions on Neural Networks, vol. 6, no. 4, pp. 1012~1016, 1995.

- [7] S. C. Ahalt, A. K. Krishnamurthy, P. Chen, and D. E. Melton, "Competitive Learning Algorithm for Vector Quantization," Neural Networks, vol. 3, pp. 277~290, 1990.
- [8] Allen Gersho, and Robert M. Gray, Vector Quantization and Signal Compression, Kluwer Academic Pub., 1992.
- [9] S. P. Luttrell, "Code vector density in topographic mappings: Scalar case," IEEE Transactions on Neural Networks, vol. 2, no. 4, pp. 427~436, 1991.
- [10] H. Ritter, "Asymptotic level density for a class of vector quantization processes," IEEE Transactions on Neural Networks, vol. 2, no. 1, pp. 173~175, 1991.
- [11] N. Kitajima, "A new method for initializing reference vectors in LVQ," IEEE Int. Conf. on Neural Networks, vol. 5, pp. 2775~2779, Nov/Dec. 1995.
- [12] 정경권, 이용구, 엄기환, "SOM을 이용한 LVQ 네트워크 설계", 전자공학회논문지 제40권 CI편, 제5호, 280~288쪽, 2003년 9월
- [13] Michio Kaku, Hyperspace, Random House, 1995.
- [14] D. R. Smith, Variational Methods in Optimization, Dover, 1998.

저 자 소 개



엄 기 환(정기환)
1972년 동국대학교
전자공학과 학사 졸업
1986년 동국대학교
전자공학과 박사 졸업
1989년 ~ 1990년 Toho Univ. Post Doc.
2000년 ~ 2001년 Univ. of Canterbury Visiting Professor.
1994년 ~ 현재 동국대학교 전자공학과 교수
<주관심 분야 : 시스템 응용, 홈 네트워크>



정 성 부(정회원)
1979년 2월 동국대학교
전자공학과 공학사
1981년 2월 동국대학교
전자공학과 공학석사
2002년 2월 동국대학교
전자공학과 공학박사
현재 서일대학 컴퓨터응용전자 전공 교수
<주관심분야 : 제어계측, 컴퓨터, 회로해석>



정 경 권(학생회원)
1998년 2월 동국대학교
전자공학과 공학사
2000년 2월 동국대학교
전자공학과 공학석사
2003년 8월 동국대학교
전자공학과 공학박사
<주관심분야 : 디지털 신호처리, 인공지능, 시스템 응용>