

論文96-33B-2-21

초기 일반 지식을 갖고 있는 점증 적응 학습 알고리듬

(Incremental Adaptive Learning Algorithm with Initial Generic Knowledge)

吳 圭 桓 **, 蔡 淳 翱 *

(Kyuhwan Oh and Soo-Ik Chae)

要 約

본 논문에서는 고정 대표 벡터라는 새로운 개념을 도입하고 LVQ의 공간 분할 방법에 이 개념을 적용하여 분류를 위한 알고리듬을 제안한다. 제안한 알고리듬은 경쟁 학습을 기반으로 하되 일반성의 유지 및 신속한 적응을 위하여 고정 벡터를 사용하고, 대표 벡터의 생성을 위한 유효 반경과 빠른 계산을 위한 L1 거리를 이용한다. 이는 빠른 적응 학습이 주목적인 반면 일반성의 유지와 실시간 처리 및 적은 데이터의 충분한 학습 효과를 요구하는 여러 분야에 적용 가능하다. 본 논문에서 제안한 알고리듬을 온라인 필기체 인식에 적용하여 학습 집합에 대하여 98 %, 테스트 집합에 대해서는 94 % 이상의 인식률을 얻었다.

Abstract

This paper introduces the concept of fixed weights and proposes an algorithm for classification by adding this concept to vector space separation method in LVQ. The proposed algorithm is based on competitive learning. It uses fixed weights for generality and fast adaptation, efficient radius for new weight creation, and L1 distance for fast calculation. It can be applied to many fields requiring adaptive learning with the support of generality, real-time processing and sufficient training effect using smaller data set. Recognition rate of over 98 % for the train set and 94 % for the test set was obtained by applying the suggested algorithm to on-line handwritten recognition.

I. 서 론

벡터 공간을 필요에 따라 분할하는 방법은 여러 가지가 있지만 VQ의 LBG-알고리듬^[1]과 신경 회로망의 경쟁 학습 알고리듬^[2]이 대표적이다. 이 두 가지 방법은 입력 벡터와 대표 벡터 사이의 왜곡을 최소화 하려는 관점에서 고안되었으며, 등학율 원리인 양심 원

리에 기반을 둔 빈도 선택 경쟁 학습^[3]이나 동왜곡 원리의 경쟁 선택 학습^[4]도 같은 견지에서 개발되었다.

벡터 공간 분할의 적용 분야에 따라서 왜곡을 최소화시키는 알고리듬보다는 그 응용의 특성에 알맞은 공간 분할 방법이 필요하게 된다. 특히 벡터 분류기에 적용될 알고리듬에서는 왜곡을 최소화하는 것이 별 의미가 없다. 신속한 추가 대표 벡터 조정이 지속적으로 요구되는 경우에도 이에 적합한 방법이 요구된다. 예를 들면, 온라인 필기체 문자 인식이 이 경우에 해당한다. 온라인 필기체 문자 인식에서 사용자는 인식기가 자신에 대하여 신속히 적응하기를 원한다. 또한, 필체가 다양한 대다수 일반인에 대해서도 어느 정도의 인식율을 유지하는 상식이 필요하다. 한 특정인에 대하여 적응된 후 다시 다른 사람에 대한 추가 학습이 이루어 질 경

* 正會員, ** 準會員, 서울大學校 牛導體共同研究所 및
電子工學科

(Inter-University Semiconductor Research Center & Department of Electronic Engineering
Seoul National University)

接受日字: 1995年3月13日, 수정완료일: 1996年1月11日

우, 기존 학습 상태에 커다란 변화를 주지 않아야 한다. 그리고, 온라인이므로 학습 및 인식 시간이 실시간 이거나 이에 가까워야 한다. 마지막으로 적은 양의 필기체 데이터로서도 학습이 가능해야 한다.

온라인 필기체 인식과 같은 특성을 갖는 패턴 인식인 경우 가능한 분류 알고리듬으로는 기존의 벡터 양자화나, 경쟁 학습 알고리듬, 오차 역전파와 같은 방법이 있다. 이와는 달리 통계적인 접근법등의 전통적인 방법으로도 구현할 수 있다^[5]. 그러나, 온라인 필기체 문자 인식의 요구 조건을 모두 만족하기는 쉽지 않다.

본 논문에서는 이와 같은 요구 조건을 만족시키기 위하여 고정 대표 벡터라는 새로운 개념을 도입하고 이 개념을 적용한 학습 알고리듬을 제안한다. 제안한 알고리듬은 경쟁 학습을 기반으로 하되 일반성 유지 및 신속한 적응을 위하여 고정 벡터를 사용하고 대표 벡터의 생성을 위한 유효 반경과 빠른 계산을 위한 L1(1-norm) 거리를 이용한다. 이는 빠른 적응 학습이 주목적인 반면 일반성의 유지와 실시간 처리 및 적은 데이터의 충분한 학습 효과를 요구하는 여러 분야에 적용 가능하다.

본 논문의 알고리듬을 온라인 필기체 인식에 적용한다면 이상의 특징으로 인하여 필요 요건을 모두 만족 시킬 수 있다. 고정 벡터의 도입으로 일반성을 유지할 수 있을 뿐만 아니라 유효 반경에 의한 효율적인 대표 벡터의 생성과 더불어 신속한 적응 학습이 가능하며 적은 양의 학습 데이터로 충분한 학습 효과를 얻을 수 있다. 추가 적응 학습에 의해서 기존의 대표 벡터와 근접한 위치에 새로운 대표 벡터가 생성되더라도 기존 대표 벡터의 큰 위치 변경없이 유효 반경만 서로 겹치게 되므로 이전 학습 상태의 변화는 줄어든다. 또한, 거리 척도로서 L1을 이용하므로 인식 시간도 줄일 수 있다. 본 논문의 2 절에서는 고정 대표 벡터의 개념과 대표 벡터 생성의 기준이 되는 유효 반경 및 거리 척도로서의 L1을 설명한다. 본 논문의 학습 및 인식 알고리듬은 3 절에서 상술된다. 4 절에서는 제안한 알고리듬을 온라인 필기체 인식에 응용하여 LVQ와 성능을 비교한다. 5 절에서는 추가 적응 학습의 한계를 설명하고, 마지막으로 6 절에서 결론을 내린다.

II. 제안한 알고리듬의 특징

본 논문에서 도입한 고정 대표 벡터는 학습에 의하

여 변경되는 통상의 대표 벡터와는 달리 학습 이전에 결정되며 이후의 학습에 의해 변경되지 않는다. 이는 어느 정도 이상의 일반성을 유지할 수 있도록 고정 벡터를 결정하고 그 위치를 고정시킴으로써 항상 초기 상태를 유지하도록 하기 위한 것이다. 여기서 일반성이란 어떤 집합의 공통적이고 일반적인 특성, 즉 상식을 의미한다.

온라인 필기체 인식의 경우를 예로 들면, 가령 모든 사람이 같은 글자 'A'를 쓴다고 하더라도 필체, 필순 등의 필기자마다 독특한 차이점이 존재한다. 이러한 차이가 있음에도 불구하고 또한, 대부분의 글자가 'A'라는 것을 알 수 있는데 이는 이들의 공통점이 존재하기 때문이다. 각 글자의 차이점을 특수성이라고 한다면, 공통점을 일반성이라 할 수 있다. 고정 대표 벡터는 분류 알고리듬이 계속되는 추가 적응 학습에도 불구하고 초기의 일반성을 유지할 수 있도록 하기 위한 것이다. 이처럼 고정 대표 벡터가 일반성을 유지하고 있다면 추가 적응 학습을 할 때 각각의 특수성에 대해서만 학습을 하면 충분하므로 신속한 적응이 이루어질 수 있다. 또한, 고정 벡터가 존재함으로써 오입력 데이터를 어느 정도 막을 수 있다. 가령, 학습에 사용될 데이터 'A'가 'B'로 잘못 설정되어 있다면, 높은 확률로 'B'의 고정 대표 벡터에 가장 가까이 있게 된다. 이때 고정 벡터와의 거리가 한계치보다 작다면, 이 데이터를 기각함으로써 오입력을 막을 수 있다.

본 논문에서 제안한 분류 알고리듬은 필요에 따라 대표 벡터를 생성하는데 그 기준으로서 각 대표 벡터는 유효 반경을 갖는다. 유효 반경은 학습에 의해 팽창 및 수축을 하여 해당 대표 벡터의 직접적인 영향권을 나타낸다. 유효 반경은 문턱값^[6]과 비슷한 개념이지만 상당한 차이가 있다. 문턱값은 해당하는 대표 벡터의 활성화와 비활성화만을 결정한다. 이에 비해 유효 반경은 입력이 어떤 대표 벡터의 유효 반경 안에 위치하여 활성화되면 해당 출력은 입력과 대표 벡터 사이의 거리가 된다. 여러 대표 벡터가 동시에 활성화되더라도 입력과의 거리에 따라 가장 가까운 단 하나의 대표 벡터만이 선택되게 된다.

본 논문에서 제안한 알고리듬은 거리 척도로서 통상의 유클리드 거리인 L2 대신 L1을 이용하였다. L1은 L2를 이용할 경우보다 성능의 저하를 요구하지만, 콤팍셈과 제곱근이 필요하지 않고 덧셈만으로 계산이 가능하므로 빠른 속도를 얻을 수 있다. 만약 하드웨어의 구

현을 고려한다면 L1 거리가 더욱 유리하다.

III. 제안한 학습 및 인식 알고리듬

본 논문에서 제안하는 알고리듬은 그림 1과 같은 OCON(One-Class-in-One-Network) 구조^[7]를 갖고 있다.

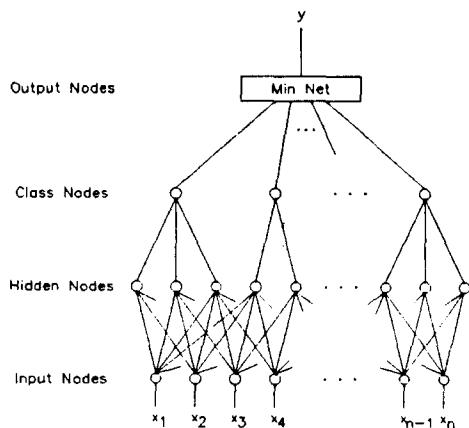


그림 1. 제안한 알고리듬에 사용된 회로망 구조
Fig. 1. Network architecture for the proposed algorithm.

회로망은 입력층과 은닉층, 부류층, 그리고 최소망으로 구성된다. 입력층에서는 학습 벡터를 받아들이고 은닉층에서는 각각의 대표 벡터와 입력 벡터와의 거리를 계산한다. 부류층에서는 자신의 부류에 속한 대표 벡터 중에서 입력 벡터와의 거리가 가장 가까운 것을 선택하여 출력하며 유효 반경 이내에 입력 벡터가 위치한 대표 벡터가 우선 선택된다. 최소망에서는 부류층의 출력 중 가장 거리가 작은 부류를 출력한다. 최소망의 결과에 따라 대표 벡터와 유효 반경의 조정이 이루어진다.

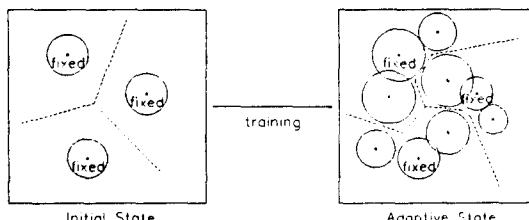


그림 2. 대표 벡터와 유효 반경의 학습

Fig. 2. Training of the representative vectors and the effective radii.

그림 2에 학습 전과 학습 후의 벡터 공간 상태가 나타나 있다. 학습이 이루어지지 않은 초기 상태에서는 고정 대표 벡터와 이들의 유효 반경만 존재하며 이에 따라 공간이 나누어진다. 학습 이후에는 고정 대표 벡터 외에 생성된 여러 대표 벡터가 존재한다. 고정 벡터인 경우 위치는 변경되지 않고 유효 반경만 변화가 있음을 알 수 있다.

고정 벡터는 여러 가지 방법으로 결정이 가능한데 다음의 알고리듬 설명에서는 고정 벡터가 미리 결정되어 있다고 가정한다. 제안한 알고리듬은 학습과 인식 알고리듬으로 나뉘며, 학습 알고리듬은 인식 확인 과정과 생성 과정으로 나뉜다. 인식 확인 과정은 학습 벡터의 입력에서 최소망의 출력까지를, 생성 과정은 인식 확인 과정의 결과를 이용하여 회로망의 대표 벡터와 해당 유효 반경을 수정한다.

1. 학습 알고리듬

전체 학습 알고리듬의 흐름도는 그림 3과 같다. 인식 확인 과정의 결과에 따라 생성 과정이 달라지게 된다.

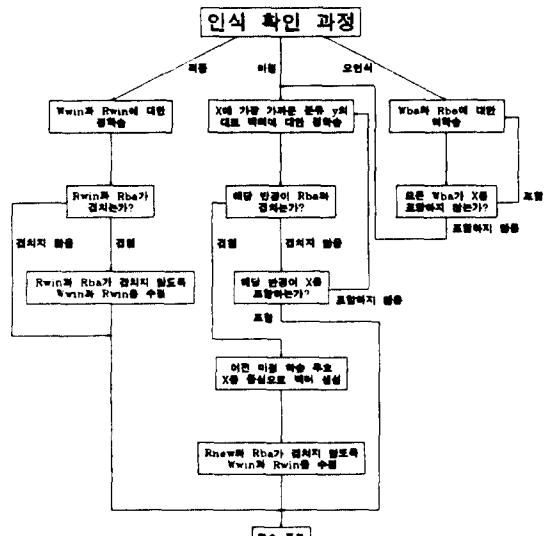


그림 3. 학습 알고리듬의 흐름도

Fig. 3. Flow chart of the proposed training algorithm.

회로망 입력층의 출력을 $A = [a_1, a_2, \dots, a_n]$, 은닉층의 출력을 $B = [b_1, b_2, \dots, b_p]$, 부류층의 출력을 $C = [c_1, c_2, \dots, c_q]$, 최소망의 출력을 $D = [d]$ 라 두며, 은닉층의 j 번째 대표 벡터를 W_j

$= [w_{j1}, w_{j2}, \dots, w_{jn}]$, 대표 벡터의 유효 반경을 $R = [r_1, r_2, \dots, r_p]$ 라 둔다. 은닉층의 갯수는 p 개이며, 부류층의 갯수는 q 개이고, 입력 벡터는 n 차원이다.

1) 인식 확인 과정

학습 입력 벡터 $X = [x_1, x_2, \dots, x_n]$ 와 이 벡터가 속한 부류 y 가 주어져 있다. 이때 각 단계의 출력은 다음과 같다.

입력층 $A : a_i = x_i, i = 1, \dots, n$.

은닉층 $B : b_j = |A - W_j|, j = 1, \dots, p$.

부류층 $C : c_k = \min b_j, \text{ the class of } j = k$.

최소망층 $D : d = \operatorname{argmin} c_k$.

부류층의 출력으로는 입력 벡터가 유효 반경 이내에 위치하는 대표 벡터가 우선 선택된다. 입력 벡터가 두 개 이상의 유효 반경 안에 위치할 경우 거리가 가까운 대표 벡터가 선택된다. 마찬가지로 최소망층의 출력도 입력이 유효 반경 이내에 위치하는 대표 벡터를 갖는 부류가 우선 선택된다.

최소망층의 출력 d 가 부류 y 이며 X 가 해당 대표 벡터의 유효 반경 안에 포함되면 인식 확인 과정의 결과는 '적중'이 된다. 반대로 출력 d 가 y 와 다른 부류가 되고 X 가 해당 벡터의 유효 반경 안에 포함되면 '오인식'에 해당된다. 이 두 가지를 제외한 나머지 경우 인식 확인 과정의 결과는 '미정'이 된다.

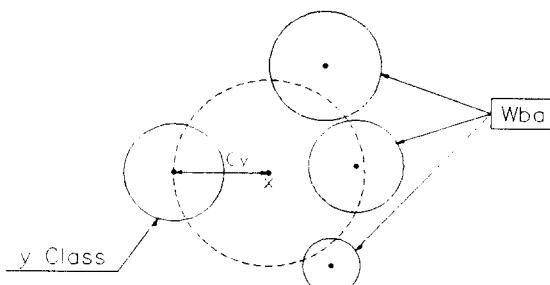


그림 4. 주위 대표 벡터 찾기

Fig. 4. Searching representative vectors near to the input.

생신 과정에서는 입력 벡터 주위의 y 와 다른 부류에 속한 대표 벡터(W_{ba})를 찾는 것이 요구된다. 인식 확인 과정에서 찾는 것이 연산상 유리하므로 다음의 식을 만족하는 대표 벡터를 찾는다.

주위 대표 벡터

$$W_{ba} = b_l : b_l < c_y + r_j, \text{ the class of } j \neq y, l = 1, \dots,$$

c_y 는 입력과 부류 y 에 속한 대표 벡터 중 입력에 가장 가까운 벡터와의 거리를 뜻한다. 그럼 4에서 X 를 중심으로 반경이 c_y 인 원과 유효 반경이 겹쳐지는 모든 부류의 대표 벡터가 주위 대표 벡터에 해당한다.

2) 생신 과정

인식 확인 과정의 결과에 따라 생신 과정은 세 가지로 나뉜다.

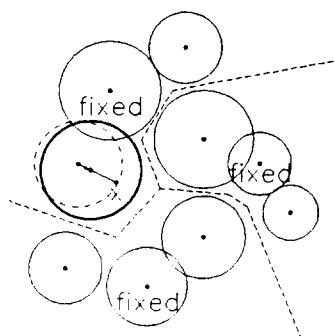


그림 5. 인식 확인 과정의 결과가 적중인 경우
Fig. 5. When Recall result is Hit.

입력 벡터 X 가 부류 y 에 속한 대표 벡터의 유효 반경에 위치할 경우가 적중이다. 이 때 그림 5과 같이 X 를 포함하는 벡터(W_{win})와 유효 반경(R_{win})은 다음과 같이 조정된다. η_m 과 η_r 은 각각 대표 벡터와 유효 반경에 대한 학습율이다.

$$W_{win} = W_{win} + \eta_m (X - W_{win}),$$

$$R_{win} = R_{win} + \eta_r |X - W_{win}|,$$

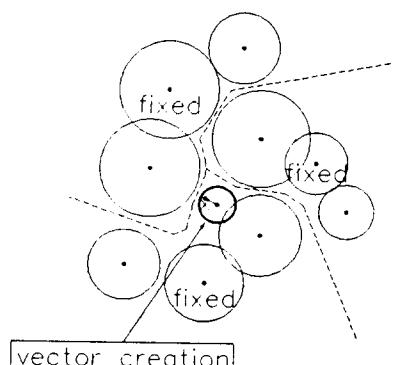


그림 6. 인식 확인 과정의 결과가 미정인 경우
Fig. 6. When Recall result is Void.

학습 결과, R_{win} 이 주위 타 부류에 속한 대표 벡터의 유효 반경을 침범할 수 있다. 이때는 타 부류의 유효 반경을 침범하지 않도록 W_{win} 의 위치와 R_{win} 가 수정된다.

그림 6과 같이 입력 벡터 X 가 어떠한 대표 벡터의 유효 반경에도 속하지 않을 때가 미정에 해당한다. 이 경우 우선, X 와 거리가 가장 가까운 부류 y 의 대표 벡터가 선택된다. 선택된 벡터의 해당 유효 반경이 X 를 포함할 때까지 이 대표 벡터와 유효 반경은 반복하여 적중인 경우와 동일한 학습을 받는다. 주위 타 부류의 유효 반경을 침범하지 않고 X 를 포함할 수 있으면, 이로서 학습이 끝난다. 만약, X 를 포함하기 전에 타 부류의 유효 반경을 침범하면 이제까지의 반복 학습을 무효로 한다. 동시에 X 의 위치에 새로운 대표 벡터를 생성하고 주위 타 부류의 유효 반경과 겹치지 않도록 생성된 벡터(W_{new})와 유효 반경(R_{new})을 다음처럼 역 학습시킨다.

$$W_{new} = X, R_{new} = R_{init}$$

```
while( Rnew > Rmin ) {
```

$$W_{new} = W_{new} - \eta_m (W_{new} - W_{ba})$$

$$R_{new} = R_{new} - \eta_r | X - W_{win} |$$

```
}
```

원칙적으로 부류가 다른 유효 반경 사이에는 겹침을 허용하지 않지만 대표 벡터의 생성시에는 겹침을 허용한다. 즉, 생성 후의 조정 단계에서 R_{new} 가 R_{min} 보다 작아질 경우 더 이상의 조정 대신 유효 반경이 겹쳐진다.

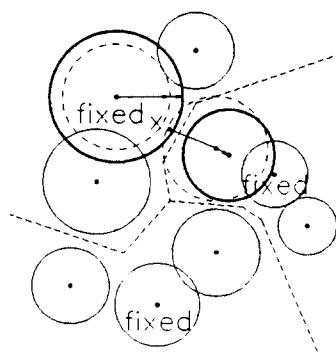


그림 7. 인식 확인 과정의 결과가 오인식인 경우
Fig. 7. When Recall result is Miss.

입력 벡터 X 가 자신이 속한 부류 y 가 아닌 다른 부

류의 유효 반경에 포함되는 경우가 오인식이다. 이때 그림 7처럼 X 를 포함하는 타 부류의 모든 대표 벡터(W_{ba})와 유효 반경(R_{ba})이 X 를 포함하지 않을 때까지 다음과 같은 역학습을 받는다.

```
while( X ∈ any Wba ) {
    Wba = Wba - ηm ( X - Wba )
    Rba = Rba - ηr | X - Wba |
}
```

이처럼 X 가 어떤 대표 벡터의 유효 반경에도 포함되지 않게 되면 미정 상태가 되고, 이후의 학습은 미정의 경우와 동일하다.

2. 인식 알고리듬

인식 알고리듬으로는 입력 벡터의 위치에 따라 두 가지 경우가 이용된다. 적어도 한 개의 유효 반경 이내에 입력 벡터가 존재할 경우 그러한 대표 벡터 중에서 입력 벡터와 더 가까운 벡터가 선택된다. 만약 어떠한 대표 벡터에도 속하지 않을 때에는 입력 벡터와 유효 반경 가장 자리까지의 거리가 가장 가까운 벡터가 선택된다.

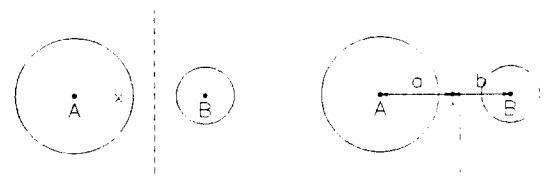


그림 8. 인식의 예 : X 가 A 에 속하는 경우

Fig. 8. Retrieval example : when X belongs to class A.

그림 8에서 입력 벡터 X 의 위치에 따라 두 가지 경우가 나타나 있다. 두 경우 모두 X 가 부류 A 에 속한다. 두 번째 경우에는 X 와 A 사이의 거리(a)가 X 와 B 사이(b)보다 더 크지만 유효 반경 가장 자리까지의 거리가 A 쪽이 더 가까우므로 X 는 A 에 속하게 된다. 그림 8의 점선은 두 부류를 가르는 경계선을 의미한다.

IV. 온라인 필기체 숫자 및 알파벳 인식의 실험

본 논문에서 제안한 알고리듬을 가장 잘 적용될 수 있는 온라인 필기체 문자 인식에 응용하였다. 본 논문

의 알고리듬은 일반성 유지와 신속한 적응을 요구하는 분야에 적합하도록 개발되었으므로 타 알고리듬과의 비교는 목적이 다른 바 쉽지가 않다. 다만 LVQ는 제안한 알고리듬의 기반이 되고 이와 같은 목적에 어느 정도 적합하다고 판단되기 때문에 본 논문에서는 LVQ(LVQ1)와 성능을 비교하였다. 본 논문에서 수행한 온라인 필기체 인식 실험의 대상은 숫자와 영문자로 한정하였다.

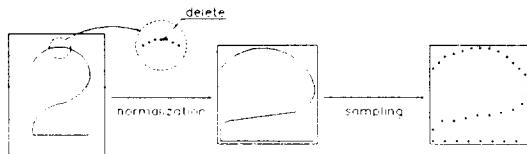


그림 9. 필기체 문자의 전처리와 특징 추출을 위한 표본화

Fig. 9. Preprocessing of handwritten characters and sampling for feature extraction.

1. 전처리와 특징 추출

필기체 문자를 2 차원 영상 그대로 인식에 이용하는 것은 글자의 크기, 위치, 회전과 기타 잡음에 너무 무력하므로 통상의 경우 전처리 과정과 특징 추출을 수행한다. 본 논문의 인식 실험에서는 전처리 과정으로 그림 9과 같이 글자를 구성하는 점 중 간격이 너무 가까운 것을 제거하여 연산 효율을 높였으며 글자의 크기와 위치에 무관하도록 크기 정규화를 하였다^[8].

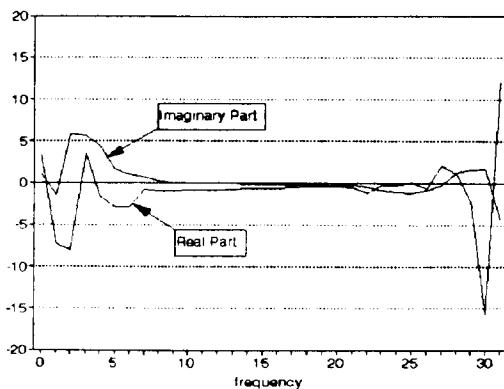


그림 10. 글자 A의 DFT

Fig. 10. DFT of character A.

본 실험에서 사용한 특징 추출 방법은 DFT(Discrete Fourier Transform)이다^[9]. 즉 X 좌표를 실

수, Y 좌표를 허수로 생각하고 FFT 알고리듬을 사용하여 변환을 하였다. 표본점의 개수는 32 개이므로 FFT를 수행하면 32 개의 복소수로 결과가 도출되며 이들 각각의 실수부와 허수부를 합하면 64 차원의 벡터가 된다.

숫자나 영문자를 푸리에 변환하면 고주파 부분은 거의 0에 가까운 값이 되며, 그림 10의 'A'의 DFT 결과에서 이를 보여 준다. 비록 고주파 부분에 차이가 존재해도 그 값을 저주파 부분에 비해서 상당히 작으므로 이를 무시할 수 있다^[8]. 본 실험에서는 고주파 부분(그림 10의 10-19)을 제외한 나머지 부분의 실수부와 허수부를 합한 44 차원 벡터를 특징 벡터로 사용하였다.

2. 고정 대표 벡터와 망 변수의 결정

일반성을 대표하는 고정 벡터는 여러 가지 방법으로 결정할 수 있다. 신경망을 이용하거나 벡터 양자화, 통계적 방법등에 의해서 정하는 것이 가능하다. 다만 어느 정도의 일반성을 지니고 있으면 아무 상관이 없다. 본 실험과 같은 필기체 인식에서는 일반인에 대해 80% 이상의 인식율을 갖는다면 고정 대표 벡터 집합으로 선택할 수 있다고 생각된다. 본 실험에서는 단순히 평균을 취하여 고정 대표 벡터를 정했다.

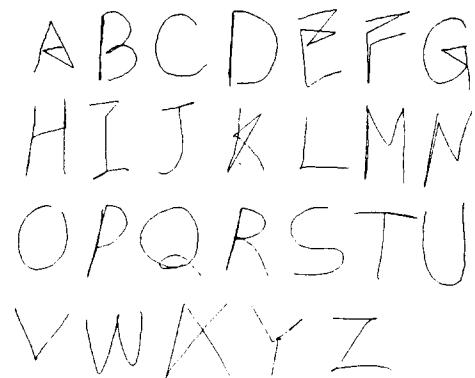


그림 11. 실험에 사용한 온라인 필기체 문자의 예

Fig. 11. Examples of on-line handwritten characters used in the experiments.

실험의 대상인 숫자와 영문자는 모두 62 가지의 종류가 있지만 모양이 비슷하거나 글자의 크기외에는 구별할 수 없는 글자가 존재한다. C/c, l/l, O/o/O, P/p, S/s, U/u, V/v, W/w, X/x, Z/z로서 모두 11 경우가 있다. 이러한 글자들은 모양이 너무 비슷하거나

혹은 전처리 과정에 의해 모두 크기가 같아지기 때문에 본 실험의 특징 추출 방법으로 서로 구별할 수가 없다. 따라서, 이상의 경우를 같은 부류로 생각하여 51 가지의 대상으로 한정하였다. 그럼 11에 실험에 사용한 필기체 문자 중 A~Z 까지의 알파벳 대문자가 예로서 제시되어 있다. 온라인 문자이므로 획과 획이 서로 연결되어 있다.

또한, 특징 추출 방법으로 DFT를 사용하기 때문에 글자의 필순과 특징 벡터와는 밀접한 관련이 있다. 같은 글자라도 필순이 다르면 전혀 다른 특징 벡터가 추출된다. 실험의 대상으로 한정한 51 개의 부류 중에는 필순이 2 개 이상인 경우가 존재하므로 이러한 부류는 각각의 필순마다 고정 대표 벡터가 적어도 한 개씩은 존재해야 한다. 최종적으로 51 개의 부류와 이에 속한 97 개의 고정 대표 벡터가 산술 평균에 의해 표 1과 같이 결정되었다.

표 1. 부류와 고정 대표 벡터의 개수

Table 1. Number of the classes and the fixed representative vectors.

부류	고정벡터갯수	부류	고정벡터갯수	부류	고정벡터갯수
A	2	R	2	j	3
B	1	S/s	1	k	3
C/c	1	T	1	l/l	1
D	2	U/u	3	m	1
E	3	V/v	3	n	1
F	4	W/w	2	q	2
G	2	X/x	3	r	1
H	1	Y	1	t	3
I	1	Z/z	2	y	2
J	1	a	1	2	2
K	3	b	1	3	1
L	1	d	2	4	3
M	2	e	1	5	3
N	3	f	1	6	2
O/o/O	1	g	2	7	2
P/p	1	h	2	8	3
Q	2	i	3	9	1

본 논문에서 제안한 알고리듬의 망 변수인 η_m , η_r , R_{init} , R_{min} 과 비교 대상인 LVQ의 학습율은 특징 벡터를 고려하여 실험적으로 결정하였다. 유효 반경의 초기 치인 R_{init} 은 대표 벡터간 최소 거리의 1/3 크기에서 결정 실험을 시작하였다.

3. 실험 과정과 결과

실험의 대상은 13 명분의 필기체 영어 대소문자 및 숫자이며 이중 8 명분의 데이터가 고정 대표 벡터의 결정에 사용되었으며 나머지 5 명분의 데이터가 실제 인식 실험에 사용되었다. 첫번째 실험은 본 논문의 알고리듬과 LVQ의 인식 비교 실험으로서 같은 초기 상태 즉, 고정 벡터만의 상태에서 적응 학습을 수행한 후 인식율을 비교하였다. 실험 방법은 각 개인마다 초기 상태에서 인식 실험을 수행하고, 두 알고리듬으로 동일한 학습 집합에 의해 1 회 학습한 후 다시 인식 실험을 수행하였다. 학습 및 테스트 집합은 각각 62 종류 $\times 5$ 즉, 310 개의 서로 다른 글자로 구성된다.

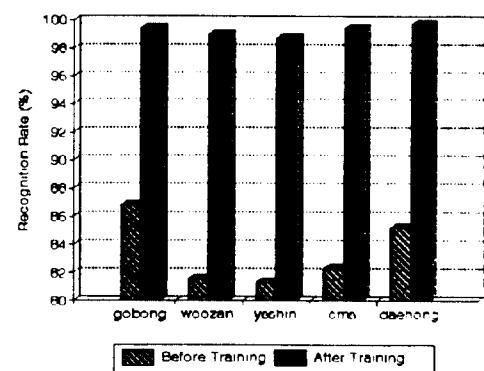


그림 12. 제안한 알고리듬의 학습 집합 인식율

Fig. 12. Recognition rate of the proposed algorithm for the train sets.

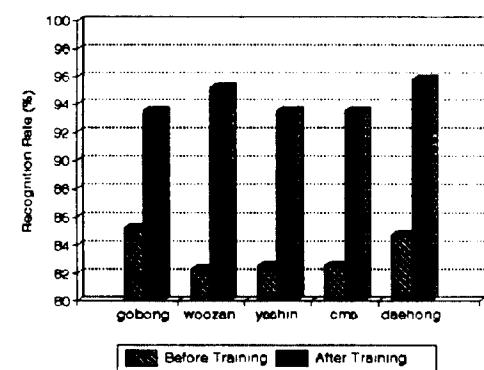


그림 13. 제안한 알고리듬의 테스트 집합 인식율

Fig. 13. Recognition rate of the proposed algorithm for the test sets.

그림 12, 13은 제안한 알고리듬의 학습 및 테스트 집합의 인식율이며, 그림 14, 15는 LVQ의 인식율이다.

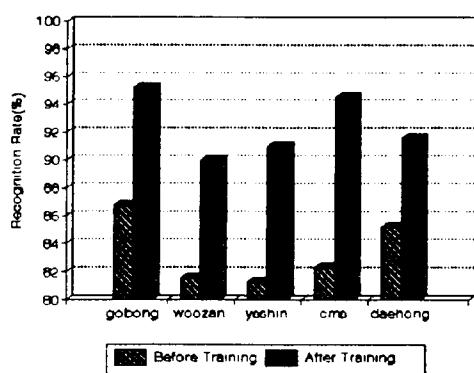


그림 14. LVQ의 학습 집합 인식율

Fig. 14. Recognition rate of LVQ for the train sets.

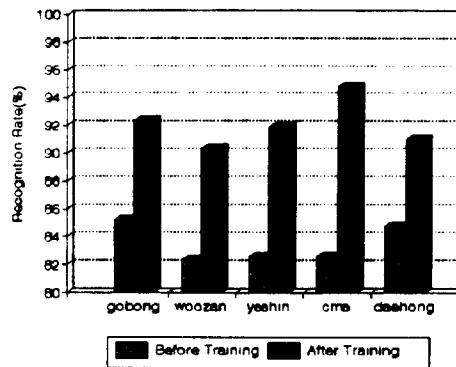


그림 15. LVQ의 테스트 집합 인식율

Fig. 15. Recognition rate of LVQ for the test sets.

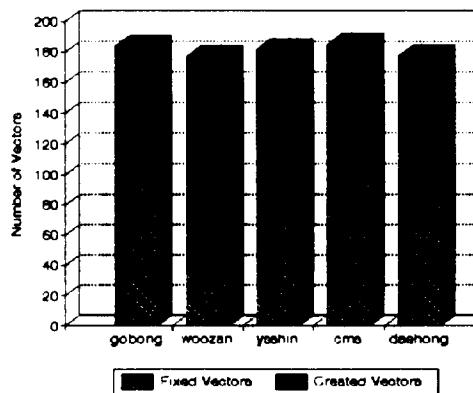


그림 16. 제안한 알고리듬의 학습 이후 대표 벡터 개수

Fig. 16. Number of representative vectors after the training of the proposed algorithm.

제안한 알고리듬의 경우 학습 집합에 대해서는 98% 이상의, 테스트 집합에 대해서도 대부분의 인식율이 94% 이상으로 증가하였다. LVQ에 비해서 절대적인 인식율 뿐만 아니라 인식율의 증가치도 제안한 알고리듬이 우수함을 알 수 있다. 또한, 한 글자당 5 개로 학습하여 테스트 집합의 인식율이 95% 이상이므로, 이는 적은 양의 데이터로 충분한 학습 효과를 얻을 수 있음을 의미한다. 그림 16은 제안한 알고리듬의 적응 학습 이후의 대표 벡터 개수를 보여준다.

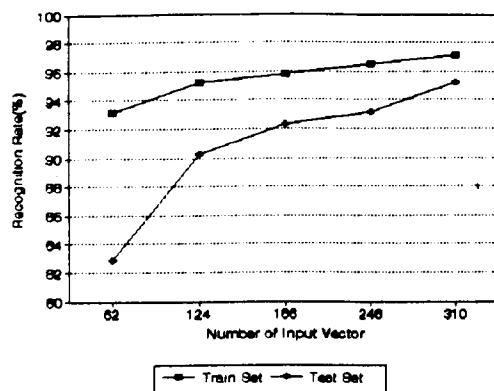


그림 17. 제안한 알고리듬의 학습 데이터 증가에 따른 인식율 변화

Fig. 17. Recognition rate variation of the proposed algorithm according to the increase of training data.

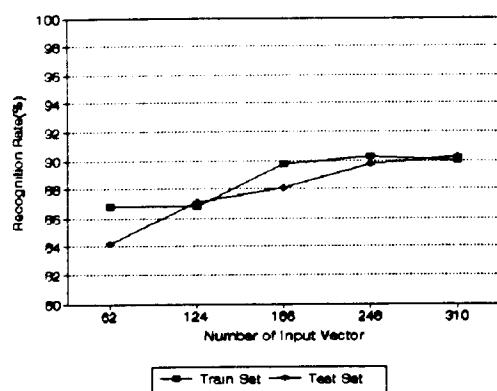


그림 18. LVQ의 학습 데이터 증가에 따른 인식율 변화

Fig. 18. Recognition rate variation of LVQ according to the increase of training data.

두번째 실험은 적응 속도의 실험으로서 두 알고리듬

의 학습 데이터를 늘려가며 동일한 학습 집합과 테스트 집합에 대하여 인식 실험을 하였다. 그럼 17의 제안한 알고리듬이 그림 18의 LVQ에 비해서 더 빠른 적용력을 보이고 있다.

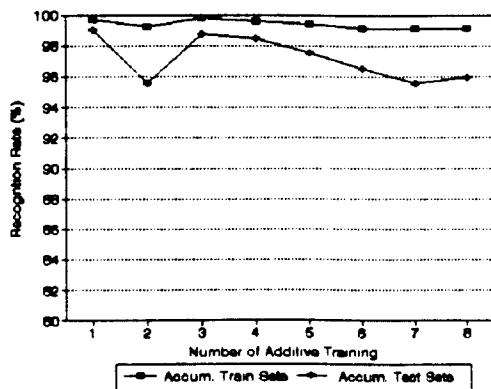


그림 19. 제안한 알고리듬의 추가 학습에 의한 이전 인식율 변화

Fig. 19. Previous recognition rate variation for the additive training of the proposed algorithm.

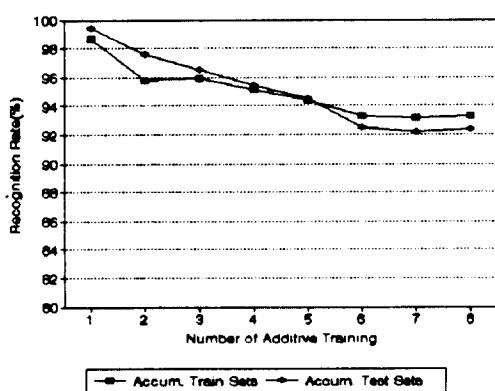


그림 20. LVQ의 추가 학습에 의한 이전 인식율 변화

Fig. 20. Previous recognition rate variation of the additive training for LVQ.

세번째 실험은 추가 적용 학습으로서 여러 사람에 대하여 연속적인 적용 학습을 수행한 후 인식 실험을 하였다. 즉, 고정 대표 벡터의 결정에 사용된 8 명분의 학습 집합을 초기 상태에서부터 차례대로 누적 학습을 수행하고, 매 회 학습에 대해서 이전 학습 상태의 유지도를 알 수 있도록 학습된 사람과 추가 학습한 사람의 학습 및 테스트 집합으로 인식 실험을 하였다. 그럼

20의 LVQ는 추가 학습에 의해 두 인식율이 모두 떨어지고 있지만, 그럼 19의 제안한 알고리듬은 일정 수준을 유지하고 있으므로 일반성을 유지하고 있다.

V. 제안한 학습 알고리듬의 적용 한계

본 논문에서 제안한 알고리듬은 일반성의 유지하에 특수성에 대한 적용이 목적으로 벡터 공간을 분할하여 이를 구현한다. 공간의 분할은 학습에 의해서 결정되고, 학습은 기존 대표 벡터와 유효 반경의 조정, 대표 벡터의 생성에 의해서 이루어진다. 고정 대표 벡터만의 초기 상태에서 학습이 시작되며 추가 학습에 의해 대표 벡터가 생성된다. 이러한 대표 벡터의 증가는 새로운 특수성에 추가 적용되면서 지속된다.

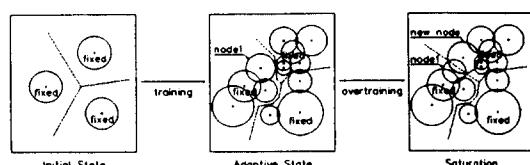


그림 21. 과잉 학습에 의한 포화

Fig. 21. Saturation due to overtraining.

적정 학습 상태는 그림 21의 두번째 그림과 같이 서로 다른 부류의 유효 반경 사이에 지나친 겹침이 없고 추가 학습에 의해서 이전의 학습 상태가 크게 변하지 않을 때이다. 이 상태에서 새로운 특수성에 대한 추가 학습을 계속 수행하면, 서로 다른 부류의 유효 반경 사이에 겹침이 점차로 늘어나게 된다. 그림 21의 세번째 그림(saturation)이 여기에 해당한다. 이러한 학습이 지속되면 같은 부류에 속한 유효 반경 사이의 거리도 가까워져서 결국은 대표 벡터의 갯수만 증가할 뿐, 더 이상의 의미있는 공간 분할이 되지 못한다. 이러한 상태에 이르면, 공간 분할이 한계에 이르렀다고 말할 수 있다.

어떠한 학습 알고리듬도 기존 학습 상태를 유지하면서 모든 특수성에 대한 적용 학습을 가능하게 할 수는 없다. 따라서, 본 논문에서 제안한 학습 알고리듬의 적용 한계도 당연하다고 볼 수 있다. 실제 응용에서는 이러한 경우 거리가 가까운 대표 벡터를 서로 병합하거나 겹쳐지는 기존 가변 벡터를 제거함으로써 해결 할 수 있다. 예를 들어, 필기체 인식의 경우 사용자의 수에 제한을 두어 한계에 이르는 것을 막을 수 있다.

VI. 결 론

본 논문에서는 LVQ의 공간 분할 방법에 새로운 개념을 추가하여 분류를 위한 알고리듬을 제안하였다. 제안한 알고리듬은 경쟁 학습을 기반으로 하되 고정 대표 벡터를 도입하여 적응 학습을 수행해도 일반성을 유지하게 하였고, 유효 반경에 의한 대표 벡터의 생성과 더불어 신속한 적응력과 적은 데이터로서도 충분한 학습 효과를 얻을 수 있게 하였다. 또한 L2 거리 대신에 L1을 사용하여 학습 및 인식의 소요 시간을 줄일 수 있었다.

제안한 알고리듬을 온라인 필기체 문자 인식에 적용하여 그 타당성을 실험하였으며 학습 집합에 대해서는 98 % 이상의 테스트 집합에 대해서는 94 % 이상의 인식률을 얻었다. 본 논문의 학습 알고리듬은 적응의 한계 즉, 과도한 누적 적응에 의한 벡터 공간의 포화에 이를 수 있다. 이점에 대해서 알고리듬 자체의 해결책은 갖고 있지 못하므로, 실제 응용시에는 이에 대한 대비가 있어야 한다.

참 고 문 헌

- [1] Y. Linde, A. Buzo, and R. M. Gray, "An algorithm of vector quantizer design," *IEEE Trans. Communications*, vol. 28, no. 1, pp. 84~95, Jan. 1980.
- [2] B. Kosko, "Stochastic competitive learning," *IEEE Trans. Neural Networks*, vol. 2, no. 5, pp. 522~529, Sep. 1991.
- [3] S. C. Ahalt, A. K. Krishnamurthy, P.

Chen, and D. E. Melton, "Competitive learning algorithms for vector quantization," *Neural Networks*, vol. 3, pp. 277~290, 1990.

- [4] N. Ueda, and R. Nakano, "A new competitive learning approach based on an equidistortion principle for designing optimal vector quantizers," *Neural Networks*, vol. 7, no. 8, pp. 1211~1227, 1994.
- [5] C. C. Tappert, C. Y. Suen, and T. Wakahara, "The state of the art in on-line handwriting recognition," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 12, no. 8, pp. 787~808, Aug. 1990.
- [6] L. N. Cooper et al., United States Patent, no. 4, 760, 604, Jul. 26, 1988.
- [7] S. Y. Kung, *Digital Neural Networks*, chap. 1, Prentice Hall, New Jersey, 1993.
- [8] M. J. Joe, M. S. Kang, G. S. Yoon, H. J. Lee, and S. K. Ahn, "On-line handwriting character recognition using neural network," *1st JCEANF*, pp. 283~292, 1991.
- [9] H. Arakawa, K. Odaka, and I. Masuda, "On-line recognition of handwritten characters-alphanumerics, hiragana, katakana, kanji," *Proceedings 4th International Conference on Pattern Recognition*, pp. 810~812, Nov. 1978.

저 자 소 개

吳圭桓(準會員)

1971年 10月 2日生. 1994年 2月 서울대 전자공학과 졸업(학사). 현재 서울대 전자공학과 석사과정. 관심 분야는 신경망을 이용한 문자 인식, 저전력 VLSI 설계, 데이터 통신을 위한 디지털



PLL.

蔡洙翊(正會員) 第31卷 B編 第5號 參照

현재 서울대학교 전자공학과 및 반도체공동연구소 교수