
패턴인식의 정확성을 향상하기 위한 지능시스템 연구

정성부*, 김주웅**

A study of intelligent system to improve the accuracy of pattern recognition

Sung-boo Chung*, Joo-woong Kim**

이 논문은 2007년도 서일대학 학술연구비에 의해 연구되었음

요 약

본 논문에서는 패턴인식의 정확성을 향상시키기 위한 지능시스템을 제안한다. 제안한 지능시스템은 신경회로망의 무감독학습 방법인 SOFM(Self Organizing Feature Map), LVQ(Learning Vector Quantization), 그리고 퍼지이론의 FCM(Fuzzy C-means)을 이용하여 구성한다.

제안한 지능시스템의 유용성은 실험을 통해 확인한다. 실험은 Fisher의 Iris 데이터 분류, Cambridge 대학의 Olivetti 연구실(ORL; Olivetti Research Laboratory)에서 제공하는 얼굴 데이터베이스를 이용한 얼굴 영상 데이터 분류, 그리고 근전도(EMG, Electromyogram) 데이터를 분류하는 것이다. 제안한 지능시스템은 일반적인 LVQ와 비교한다.

실험을 통해 제안한 지능시스템이 일반적인 LVQ보다 패턴인식의 정확성이 더 우수함을 알 수가 있었다.

ABSTRACT

In this paper, we propose a intelligent system to improve the accuracy of pattern recognition. The proposed intelligent system consist in SOFM, LVQ and FCM algorithm.

We are confirmed the effectiveness of the proposed intelligent system through the several experiments that classify Fisher's Iris data and face image data that offered by ORL of Cambridge Univ. and EMG data.

As the results of experiments, the proposed intelligent system has better accuracy of pattern recognition than general LVQ.

키워드

패턴인식, 지능시스템, LVQ, SOFM, C-means 알고리즘

I. 서론

인류는 문명사회를 이루게 되면서 다양하고 많은 정보를 축적해왔다. 초기에 정보는 필기구, 종이, 물감, 악기 등과 같은 도구를 이용하여 저장하거나 표현했다. 그

후 전자산업의 발전으로 컴퓨터가 발명되고 컴퓨터 산업의 발전으로 이전에는 상상도 못했던 정보들도 표현이 가능해지면서 더 다양하고 더 많은 정보들이 축적되게 되었다. 이렇게 많은 양의 정보를 각 개인이 인지하고 습득한다는 것은 불가능하며, 학습한 정보라도 시간이

* 서일대학
** 뉴파워전자(주)

지나면서 잊어버리게 된다. 따라서 핵심 정보만을 기억하였다가 필요에 따라 목적과 용도에 맞는 정보를 찾는 방법을 모색하지 않을 수 없다. 그러기 위해서는 이들 자료들을 분류 및 정리, 그리고 처리할 필요가 있다.

다양하고 방대한 자료를 분류하고 처리하기 위한 기술이 다양하게 발전되어 왔다. 그중에서도 인식기술은 정보를 검색하고 분류, 처리하는데 가장 뛰어난 기술이다. 인식기술의 대표적인 것이 패턴인식이다. 패턴인식은 인지과학(Cognitive Science)과 인공지능(Artificial Intelligence) 분야에 속하는 문제 중 하나이다. 인지과학은 심리학, 컴퓨터 과학, 인공지능, 신경생물학과 언어학, 철학을 이용하여 지능과 인식의 문제를 다루는 포괄적인 학제적 과학 분야를 말하며, 인공지능은 인간의 학습능력과 추론능력을 인공적으로 모델링하여 외부 대상을 지각하는 능력, 나아가 자연언어와 같은 구문적 패턴까지 이해하는 능력 등을 컴퓨터 프로그램으로 구현하는 기술을 말한다.

패턴인식은 주로 문자인식, 음성인식, 영상인식 등에 이용되고 있으며, 구체적으로 문자인식분야에서 자동우편물 분류시스템, 음성인식분야에서 자동문개폐장치, 영상인식분야에서 자동어류분류시스템을 들 수가 있다.

패턴인식의 대표적인 접근 방법으로는 크게 통계적 방식, 구문론적 방식, 신경회로망과 같은 인공지능의 이론을 이용하는 방식 등이 있으며, 최근에는 병렬처리, 강인성, 일반화 등에서 우수한 성능을 가진 신경회로망을 많이 이용하고 있다. 대표적으로 사용되고 있는 신경회로망 이론은 BP(Backpropagation), SOFM, LVQ 등이 있다.

많은 분야에서 적용되는 인식기술의 관건은 인식의 정확성에 있다. 인식의 정확성을 향상시키기 위해서는 대상의 인지기술과 인지된 내용을 처리하는 처리기술이 향상되어야 한다. 두 가지 기술 중에서 특히 중요시되는 부분은 인식 처리기술인데, 이는 인식된 데이터의 특징을 정확히 분류해야하고, 분류된 내용과 DB와의 mapping이 정확해야하기 때문이다.

본 논문에서는 패턴인식의 정확성을 향상시키기 위한 지능시스템을 제안한다. 제안한 지능시스템은 신경회로망의 SOFM과 LVQ, 그리고 퍼지이론의 FCM으로 구성한다. 제안한 지능시스템은 SOFM과 FCM을 이용하여 데이터의 feature map을 구성하고, 구성된 feature map을 토대로 하여 LVQ 학습을 통해 데이터를 분류하게 된다.

제안한 지능시스템의 유용성을 알아보기 위해 실험

을 한다. 실험은 Fisher의 Iris 데이터, Cambridge 대학의 Olivetti 연구실에서 제공하는 얼굴 데이터베이스를 이용한 얼굴 영상 데이터, 그리고 근전도 데이터를 분류한다. 제안한 지능시스템은 일반적인 LVQ와 비교하여 각각에 대한 데이터 분류의 정확성이 향상되는지를 알아본다.[1-2]

II. SOFM, FCM, LVQ

대표적인 클러스터링 알고리즘인 SOFM, FCM, 그리고 LVQ는 각각의 특징을 가지고 있다. SOFM은 이웃하는 뉴런과의 거리를 계산하여 가장 가까운 뉴런이 승리 뉴런이 되어 학습하고, FCM은 목적함수를 최소로 하는 방향으로 학습한다. 그리고 LVQ는 SOFM과 유사하게 이웃하는 뉴런과의 경쟁에서 승리한 뉴런을 결정하고, 승리뉴런과 목표 출력을 비교하여 기준벡터를 학습한다. SOFM과 FCM은 비지도학습 방식이므로 목표 출력을 갖지 않는다. 따라서 SOFM과 FCM은 단지 분류만 하게 되며, 분류한 것이 원하는 결과를 초래하는 것인지는 알 수가 없는 단점이 있다. 그러나 LVQ는 비지도학습과 지도학습이 동시에 존재하는 하이브리드 형태이므로, 승리뉴런과 목표 출력간의 비교를 통해 학습하고, 이를 통해 LVQ의 출력 결과가 원하는 결과인지 아닌지를 확인할 수 있다. 이러한 특징은 패턴인식과 같은 분류의 문제뿐만 아니라 제어와 같은 분야에서도 LVQ가 널리 활용되게 하는 이유이다.

1. SOFM

SOFM은 Kohonen에 의해 제안된 경쟁네트워크를 근간으로 하는 비지도학습 알고리즘이며 단일 뉴런층으로 구성된 신경회로망이다.

일반적으로 경쟁네트워크는 승자전취(winner takes all) 방식으로, 뉴런들 중에서 승리뉴런을 결정하고, 승리뉴런만이 출력을 내고 연결강도를 강화한다. 따라서 승리뉴런에 대해서는 연결강도를 갱신하고, 경쟁에서 탈락한 뉴런들의 연결강도는 갱신하지 않는다.[3-4]

일반적인 경쟁네트워크의 구조와는 달리 SOFM의 경우, 승리뉴런이 결정되고 그 승리뉴런에 대해 출력을 내는 것은 일반적인 경쟁네트워크 구조와 같지만, 연결강도의 갱신이 승리한 뉴런뿐만 아니라 이웃한경 내에 존

제하는 모든 뉴런의 연결강도까지 갱신한다는 점에서 일반적인 경쟁네트워크와 다르다. 결과적으로 학습이 진행되는 동안에는 승리뉴런과 이웃하는 뉴런들이 비슷한 연결강도를 가지게 되고 승리뉴런과 이웃 뉴런들은 유사한 입력벡터에 반응하게 된다. 일반적으로 SOFM은 Kohonen 모델이 많이 사용하고 있다.

2. FCM

1981년 Bezdek에 의해 제안된 FCM은 HCM(Hard C-means) 클러스터링 알고리즘의 퍼지형 모델로, 가장 널리 사용되는 퍼지 클러스터링 알고리즘이다. FCM은 흔히 퍼지 ISODATA로 알려져 있으며, 자기 조직화 형태의 비지도학습 알고리즘이다. FCM은 소속함수의 정도에 따라 각각의 입력 데이터가 특정 클러스터에 속하게 되고, 이를 통해 클러스터의 중심값과 퍼지 C-분할(partition) 행렬(혹은 소속함수)을 동시에 구할 수 있다. 이러한 FCM은 클러스터링 알고리즘에 기초하여 목적함수를 최소화하는 방향으로 학습하는 알고리즘이며, 목적함수를 최소화하기 위해 데이터 열을 분리한다. 이렇게 분리된 데이터 열은 몇 개의 그룹 혹은 클러스터가 된다.

FCM의 성능은 클러스터의 초기 중심값과 소속함수에 좌우된다. 만약 클러스터의 초기 중심값이 최종 중심값과 유사할 경우 FCM은 빨리 수렴하게 되고 학습 시간이 크게 줄어든다. 또한 소속함수가 잘 분포되어 있을 경우에도 빠르게 수렴하는 특징이 있다. FCM의 각 패턴에 대한 소속함수는 패턴과 클러스터의 중심값과의 거리를 측정함으로써 구할 수 있으며, 각 패턴에 대한 소속함수는 각 입력패턴이 클러스터에 속한 정도를 나타낸다. 그러나 FCM은 일괄처리 학습 방식의 형태이므로 온라인 방식으로는 학습할 수 없는 단점이 있다. 이러한 단점에도 불구하고 FCM은 패턴인식, 데이터 분류, 영상 분할, 데이터 해석, 모델링 등의 분야에 적용되고 있다.[5-9]

3. LVQ

LVQ는 경쟁네트워크에 기초를 두고 만들어 졌으며, 비지도학습의 경쟁층과 지도학습의 선형층을 조합한 하이브리드 네트워크이다. LVQ의 구조는 다층 신경회로망의 구조로서, 입력층, 경쟁층 및 출력층의 3개층으로 구성된다. 입력층은 입력벡터로 구성되며, 경쟁층은 경쟁네트워크를 사용하며, 경쟁층의 활성화함수(activation function)는 경쟁함수(competitive function)를 사용한다.

출력층은 선형층으로서 전방향 신경회로망으로 구성된다. 출력층에서 사용되는 활성화함수는 선형함수(linear function)이다.

LVQ에서 경쟁층의 입력벡터는 경쟁네트워크의 입력벡터와는 다르다. 경쟁네트워크의 입력벡터는 입력 패턴과 원형패턴의 내적(inner product)을 계산한 결과를 입력벡터로 사용하지만, LVQ에서의 경쟁층은 입력패턴과 원형패턴 사이의 거리를 직접 계산하여 그 결과를 입력벡터로 사용한다. 따라서 경쟁네트워크만을 구성하여 사용하면 내적 계산을 위하여 벡터의 일반화 과정이 필요하지만, LVQ에서는 이러한 과정이 필요 없이 직접 계산할 수 있는 장점이 있다.

이러한 장점을 통해 LVQ는 클러스터링을 할 수 있으며 클러스터링과 함께 패턴인식이 가능하게 된다. 기존의 클러스터링 및 패턴인식기의 구조보다 비교적 간단하고 부분 클래스와 클래스의 표현이 용이하여 많은 부분에서 사용되고 있다.[10-12]

III. 제안한 지능시스템

본 논문에서는 패턴인식의 정확성을 향상시키기 위해 하이브리드 형태의 지능시스템을 제안한다. 제안한 지능시스템은 패턴인식에 우수한 성능을 가진 LVQ와 SOFM, FCM으로 구성되어 있으며, 전체 시스템은 훈련과정과 시험과정으로 나누어져 있다. 훈련과정은 훈련용 데이터를 이용해 네트워크를 훈련하는 과정으로, 그림 1은 훈련과정에 대한 블록선도이다.




그림 1. 제안한 지능시스템의 훈련과정에 대한 블록선도
Fig. 1 A block diagram of training process of the proposed intelligent system

제안한 지능시스템의 훈련과정은 **SOFM**과 **FCM**으로 구성된 하이브리드 네트워크 부분과 하이브리드 네트워크에서 얻은 결과를 이용해 입력 데이터를 분류하는 **LVQ** 부분으로 나눈다. 하이브리드 네트워크에 대한 블록선도가 그림 2에서 보여지고 있다.

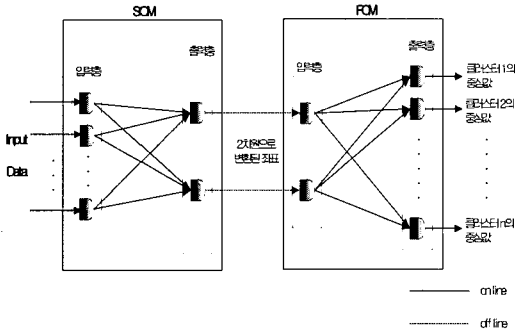


그림 2. 하이브리드 네트워크에 대한 블록선도
Fig. 2 A block diagram of the hybrid network

그림 2에서 보듯이, 하이브리드 네트워크는 **SOFM**와 **FCM**으로 구성되어 있다. **SOFM**는 Iris 데이터나 혹은 근전도 데이터와 같이 복잡하고 다차원인 데이터를 입력 패턴으로 하여 훈련을 하고, 훈련을 통해 입력패턴에 대한 승리뉴런을 결정한다. 결정된 승리뉴런은 저차원인 1차원 혹은 2차원의 배열 형태로 나오질될 수 있으며, 본문에서는 2차원 배열의 형태로 표현한다. 이러한 **SOFM**의 훈련에 의해 다차원의 입력패턴은 2차원의 배열 형태로 표현되고, 이 값은 오프라인 방식으로 **FCM**과 **LVQ**의 입력으로 제공된다.

다차원의 입력 데이터는 **SOFM**에 의해 저차원으로 변환되는데, 변환 과정은 훈련 데이터의 확률분포에 따라 군집화하는 **SOFM**의 특성에 따른다. 훈련 데이터의 확률분포가 서로 다른 경우 변환된 데이터는 크게 문제가 되지 않는다. 그러나, 확률분포가 서로 인접하거나 겹치는 부분이 있는 경우에는 같은 부류의 경계면을 확실하게 구성하는데 어려움이 있다. 그림 3은 2개의 부류가 인접하고 일부분이 겹친 경우에 대한 입력 데이터의 확률분포를 나타내고 있다.

그림 3에서 2개의 부류가 겹쳐진 부분에서 훈련 데이터의 확률밀도가 가장 높음을 볼 수가 있다. 이렇게 겹쳐진 부분에 대해 경계면을 확실하게 하고 **LVQ**의 분류 성

능을 개선하기 위해서는 겹쳐진 부분에 많은 기준벡터를 두어야 하며, 이를 토대로 서브클래스를 형성하여 부류의 경계면을 확실하게 구성하여야 한다. 따라서 **SOFM**의 결과를 토대로 해서 입력 데이터의 확률분포를 확인하고, 기준벡터를 초기화해야 한다.




그림 3. 입력데이터의 확률분포
Fig. 3 A probability distribution of input data

LVQ의 초기 기준벡터와 서브클래스의 개수는 **SOFM**에 의해 확률분포에 따라 군집화된 입력 데이터를 이용하여 **FCM**의 최적 클러스터의 수와 중심값을 구하게 되고, 여기서 구한 클러스터의 수와 중심값을 이용하여 **LVQ**의 서브클래스와 초기 기준벡터로 사용한다. 이를 통해 **LVQ**는 초기 기준벡터를 최적화 할 수 있고, 또한 서브클래스의 수도 적절하게 하여 네트워크의 크기 뿐만 아니라 데드 뉴런의 문제까지 개선하게 된다.

하이브리드 네트워크에서 얻은 값들을 이용하여 **LVQ**를 훈련하며, 이에 대한 블록선도는 그림 4와 같다.

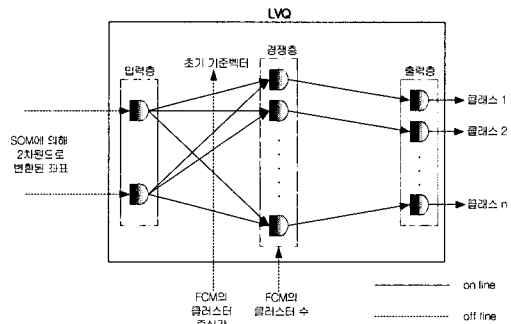


그림 4. LVQ의 훈련에 대한 블록선도
Fig. 4 A block diagram of LVQ network training

그림 4에서 LVQ의 입력은 SOFM의 훈련에 의해 결정된 승리뉴런의 좌표로서 2차원 배열의 형태를 하고 있다. 이것은 SOFM에 의해 전처리 되기 전에 다차원이었던 입력패턴이 전처리 과정을 통해 2차원으로 변환되고, 이로 인해 LVQ의 입력 데이터를 간소화하여 LVQ의 분류 성능을 향상시키고, 분류 속도 또한 빠르게 한다. 이와 같은 방식은 입력패턴의 데이터가 매우 많을지라도 SOFM를 통해 전처리 하여 2차원의 데이터로 변환할 수 있기 때문에 입력패턴이 매우 많은 차원으로 구성되어 있더라도 좋은 분류를 할 수 있게 한다.

그리고 FCM에 의해 구한 클러스터의 개수와 중심값은 LVQ의 경쟁층의 서브클래스 개수와 초기 기준벡터로 사용된다. 이로 인해 LVQ는 학습 기간이 짧아지고 분류 성능도 향상된다. 또한 FCM에 의해 결정된 서브클래스의 개수는 LVQ의 크기를 적절히 하여 데드(dead) 뉴런의 문제도 극복하게 한다.




그림 5. 제안한 지능시스템의 시험과정에 대한 블록선도

Fig. 5 A block diagram of classifying process of the proposed intelligent system

훈련과정이 끝난 후 제안한 하이브리드 지능 시스템의 시험과정에 대한 블록선도는 그림 5와 같다. 그림 5에서 보는 바와 같이 시험과정은 SOFM과 LVQ로만 구성된다. SOFM 및 LVQ는 훈련과정을 통해 연결강도가 최적화 된다. 시험용인 다차원의 입력 데이터는 SOFM에 의해 2차원 형태의 데이터로 변환되고, 변환된 데이터는 온라인으로 LVQ의 입력으로 제공된다. LVQ는 최적화된 기준벡터를 이용하여 변환된 2차원 배열 데이터를 간단하고 정확하게 분류하게 된다.

이상에서 살펴본 바와 같이 제안한 하이브리드 지능 시스템은 입력 데이터의 확률분포에 따라 군집화하는 특성을 가진 SOFM를 통해 다차원이고 데이터의 양이

많은 입력패턴을 저차원이며 데이터 양이 적은 입력패턴으로 변환한다. 이로 인해 제안한 하이브리드 지능 시스템은 입력패턴의 형태가 복잡하고 데이터의 양이 많을지라도 빠르고 정확하게 입력패턴을 분류할 수 있게 된다.

또한 SOFM에 의해 분포된 입력패턴에 대해 FCM을 이용하여 클러스터의 개수와 각 클러스터의 중심값을 구한다. FCM에서 구한 클러스터의 개수와 중심값은 LVQ의 서브클래스의 수와 초기 기준벡터로 각각 주어진다. FCM을 통해서 LVQ는 단점으로 지적되는 초기 기준벡터의 선정 문제를 해결하고, 또한 네트워크의 크기를 최적화하여 데드 뉴런의 문제도 해결하게 된다.

SOFM에 의해 변환된 데이터와 FCM에서 구한 파라미터를 이용하여 LVQ는 많은 양의 데이터를 처리할 수가 있게 되고, 또한 최적화된 초기 기준벡터와 서브클래스를 통해 빠르고 정확하게 분류할 뿐만 아니라 네트워크의 크기를 최적화하여 데드 뉴런의 문제까지 해결한다. 따라서 제안한 하이브리드 지능 시스템을 통해 LVQ는 빠르고 정확하게 데이터를 분류하게 된다.

IV. 실험

본 논문에서 제안한 지능시스템의 유용성을 알아보기 위해 Fisher의 Iris 데이터, Cambridge 대학의 Olivetti 연구실에서 제공하는 얼굴 데이터베이스를 이용한 얼굴 영상 데이터, 그리고 근전도 데이터를 분류하는 실험을 한다. 실험 결과를 토대로 제안한 방식과 일반적인 LVQ와 비교 검토한다.

1. Fisher의 Iris 데이터 분류

1936년 Fisher는 Iris의 3종류인 Setosa, Versicolor, Virginica의 꽃받침과 꽃잎의 크기와 길이를 조사하여 이를 데이터로 만들었는데, 이것이 Fisher의 Iris 데이터이다. Fisher의 Iris 데이터는 4개의 측정 요소(꽃받침, 꽃잎, 크기, 길이), 3개의 클래스, 그리고 각 클래스마다 50개씩의 데이터, 즉 $4 \times 3 \times 50$ 의 형태로 구성되어 있다.[13-14]

실험에 사용된 Iris 데이터는 각 클래스마다 25개씩의 데이터를 하나의 그룹으로 하여 2개의 그룹으로 나눈다. 첫 번째 그룹은 제안한 지능시스템의 훈련과정에 사용

하고 두 번째 그룹은 시험과정에 사용한다.

훈련용 Iris 데이터를 이용해 제안한 지능시스템과 일반적인 LVQ를 이용하여 패턴을 분류하는 실험을 한 결과는 표 1과 같다. 표 1에서 보는 바와 같이 4×3×25의 Iris 데이터를 분류한 결과 제안한 지능시스템의 경우 잘못 분류된 데이터는 단지 2개인 반면, 일반적인 LVQ의 경우는 23개의 데이터를 분류하지 못했다.

다음과정으로 시험용 Iris 데이터를 이용해 제안한 지능시스템과 일반적인 LVQ의 패턴인식에 대한 실험을 하였다. 표 2는 시험용 Iris 데이터에 대한 실험결과이다. 표 2에서 시험용 Iris 데이터를 분류한 결과 제안한 지능시스템은 1개의 데이터를, 일반적인 LVQ는 26개의 데이터를 분류하지 못했다. 이상의 결과를 토대로 Iris 데이터의 분류는 제안한 지능시스템이 일반적인 LVQ보다 분류의 정확성에서 우수함을 알 수가 있다.

표 1. 훈련용 Iris 데이터에 대한 분류 결과
Table. 1 A classifying result for training Iris data

C(클래스)	P(제안한방식)	L(일반적인LVQ)
△ (Setosa)	□ (Versicolor)	× (Virginica)

C	P	L	C	P	L	C	P	L	C	P	L	C	P	L
△	△	△	△	△	△	△	△	△	×	×	×	×	×	×
□	□	□	×	×	×	△	△	△	×	×	×	△	△	△
×	×	×	□	□	×	×	×	×	△	△	△	□	□	×
×	×	×	□	□	×	△	△	△	□	□	×	□	□	×
×	×	×	□	□	×	△	△	△	×	×	×	×	×	×
△	△	△	△	△	△	△	△	△	×	×	×	□	□	×
×	×	×	×	×	×	×	×	×	□	□	×	□	□	×
□	□	×	□	□	×	□	□	×	×	×	×	△	△	△
□	□	×	×	×	×	△	△	△	×	×	×	△	△	△
△	△	△	×	×	×	△	△	△	×	□	×	□	□	×
□	□	×	△	△	△	△	△	△	×	×	×	□	□	×
□	×	×	△	△	△	□	□	×	△	△	△	△	△	△
×	×	×	□	□	×	×	×	×	□	□	×	□	□	×
□	□	×	×	×	×	△	△	△	△	△	△	×	×	×
×	×	×	△	△	△	△	△	△	×	×	×	□	□	×

표 2. 시험용 Iris 데이터에 대한 분류 결과
Table. 2 A classifying result for testing Iris data

C	P	L	C	P	L	C	P	L	C	P	L	C	P	L
×	×	×	△	△	△	△	△	△	△	△	△	□	□	×
□	□	×	△	△	△	×	×	×	×	×	×	□	□	×
□	□	×	×	×	×	×	×	×	×	×	×	×	×	×
×	×	×	□	□	×	□	□	×	△	△	△	×	×	×
△	△	△	×	×	×	□	□	×	□	□	×	△	△	△
×	×	×	□	□	×	□	□	×	□	□	×	□	□	×
×	×	×	△	△	△	×	×	×	△	△	△	□	□	×
△	△	△	△	△	△	×	×	×	△	△	△	□	□	×
△	△	△	×	×	×	□	□	×	□	□	×	△	△	△
×	×	×	□	□	×	△	△	△	□	□	×	△	△	△
×	×	×	×	×	×	△	△	△	△	△	△	△	△	△
×	×	×	×	×	×	△	△	△	□	□	×	×	×	×
×	×	×	△	△	△	×	×	×	□	×	×	□	□	×
□	□	×	□	□	×	△	△	△	□	□	×	×	×	×
△	△	△	□	□	×	△	△	△	□	□	×	△	△	△

2. 얼굴 영상 데이터 분류

인간의 얼굴은 표정, 포즈, 조명 등의 변화로 인해 많은 다양성을 가지고 있기 때문에 정확히 분류한다는 것은 매우 어렵다. 얼굴 영상에 대한 분류에 있어 주안점이 이러한 무수히 많은 변화를 모두 수용하면서 어떠한 배경 영상에서도 적절한 시간 내에 얼굴을 검출해 낼 수 있어야 하는 것이다.

본 논문에서는 얼굴 영상 분류를 위해 Cambridge 대학의 Olivetti 연구실에서 제공하는 40명의 얼굴 데이터 베이스 중에서 20명의 데이터를 이용한다. 20명의 얼굴 데이터베이스는 20명 각각에 대해 10개의 얼굴 영상을 제공하며, 다양한 표정과 각도, 안경, 머리 모양 등의 변화가 있는 영상으로 구성되어 있으며, 46×56 픽셀의 크기로 구성되어 있다. 실험을 위해 20명의 얼굴 영상에 대해 처음 5개의 얼굴 영상은 훈련용 데이터로, 나머지 5개는 시험용 데이터로 구분한다.

표 3. 훈련용 얼굴 영상 데이터에 대한 분류 결과
Table. 3 A classifying result for training face image data

C	P	L	C	P	L	C	P	L	C	P	L
1	1	5	6	6	8	11	11	8	16	16	6
1	1	5	6	6	8	11	11	8	16	16	5
1	1	5	6	6	8	11	11	8	16	16	5
1	1	5	6	6	8	11	11	8	16	16	5
1	1	5	6	6	8	11	11	8	16	16	8
2	2	8	7	7	8	12	12	5	17	10	8
2	2	8	7	7	8	12	12	5	17	6	8
2	2	8	7	7	8	12	12	8	17	10	8
2	2	8	7	7	8	12	12	5	17	10	9
2	2	8	7	7	8	12	12	5	17	6	8
3	4	8	8	8	8	13	13	8	18	18	8
3	12	8	8	8	8	13	13	5	18	18	5
3	12	8	8	8	8	13	13	5	18	18	5
3	20	8	8	8	8	13	13	8	18	18	5
3	20	8	8	8	8	13	13	8	18	18	5
4	8	8	9	9	9	14	14	15	19	19	18
4	4	8	9	9	9	14	14	5	19	19	5
4	8	8	9	9	9	14	14	5	19	19	18
4	4	8	9	9	9	14	14	6	19	19	8
4	4	8	9	9	9	14	14	15	19	19	5
5	5	5	10	10	8	15	2	8	20	20	8
5	5	5	10	10	8	15	11	8	20	20	9
5	12	5	10	10	8	15	11	8	20	20	9
5	12	5	10	10	8	15	11	8	20	20	9
5	18	5	10	10	8	15	11	8	20	20	8

표 3은 훈련용 얼굴 영상 데이터에 대한 실험 결과이다. 제안한 지능시스템과 일반적인 LVQ를 비교했을 때, 제안한 지능시스템은 20개, 일반적인 LVQ는 85개가 잘못 분류되었다.

시험용 얼굴 영상 데이터에 대해서도 패턴 분류 실험을 하였다. 실험 결과는 표 4와 같다. 표 4에서 제안한 지능시스템은 28개, 일반적인 LVQ는 93개가 잘못 분류되었다. 이상의 결과에서 알 수 있듯이 얼굴 영상 데이터에 대한 패턴 분류에서도 제안한 지능시스템이 일반적인 LVQ보다 정확성에서 더 우수함을 알 수 있다.

표 4. 시험용 얼굴 영상 데이터에 대한 분류 결과
Table. 4 A classifying result for testing face image data

C	P	L	C	P	L	C	P	L	C	P	L	
1	1	5	6	6	8	11	11	8	16	15	6	
1	1	5	6	6	8	11	11	8	16	1	5	
1	1	5	6	6	8	11	2	8	16	16	5	
1	1	5	6	6	8	11	11	8	16	16	5	
1	1	5	6	6	8	11	11	8	16	16	8	
2	2	8	7	7	8	12	12	5	17	10	8	
2	2	8	7	7	8	12	12	5	17	6	8	
2	2	8	7	7	8	12	12	8	17	10	8	
2	2	8	7	7	8	12	12	5	17	10	9	
2	2	8	7	7	8	12	12	5	17	6	8	
3	4	8	8	8	8	10	13	13	8	18	18	8
3	12	8	8	8	8	10	13	13	5	18	18	5
3	12	8	8	8	8	10	13	13	5	18	18	5
3	20	8	8	8	8	10	13	13	8	18	18	5
3	20	8	8	8	8	10	13	13	8	18	13	5
4	8	8	9	9	9	14	14	15	19	19	18	
4	4	8	9	9	9	14	14	5	19	19	5	
4	8	8	9	9	9	14	14	5	19	19	18	
4	4	8	9	9	9	14	2	6	19	16	8	
4	4	8	9	9	9	14	14	15	19	19	5	
5	18	8	10	10	8	15	2	8	20	20	8	
5	18	8	10	10	8	15	11	8	20	20	9	
5	12	8	10	10	8	15	15	8	20	20	9	
5	12	5	10	10	8	15	11	8	20	20	9	
5	18	5	10	8	8	15	11	8	20	20	8	

3. 근전도 데이터 분류

근전도 신호는 근육의 수축·이완 시에 일어나는 근 신경섬유의 활동을 전기적인 신호로 표현한 것이다. 근전도 신호는 전기적으로 10[μ V] ~ 15[mV]의 전압과, 10 ~ 2000[Hz]의 주파수 특성을 가지는데, 이를 처리 가능한 데이터로 만들고 분석하기 위해서는 300 ~ 500,000 배 증폭을 해야 하고, 외부 노이즈를 제거하기 위해 필터를 사용해야만 한다. 그림 6은 근전도 신호를 측정하기 위한 시스템이다.[2]

근전도 신호를 측정하기 위해서는 전극을 사용하는데, 사용되는 전극의 종류에는 침 전극과 표면 전극이 있다. 일반적으로 피검자에게 고통도 없고 성능도 뒤지지

않는 표면 전극을 많이 사용한다. 표면 전극은 피부 표면에 부착하여 근전도 신호를 측정하는 전극으로 주로 1회용이며 Ag/AgCl 전극이다.

본 논문에서는 한글 자음을 수화로 표현할 때 발생하는 근전도 신호를 이용하여 근전도 데이터와 한글 자음을 mapping 한다. 근전도 신호의 측정을 위해 1회용의 Ag/AgCl 표면 전극을 사용하며, 측정은 2초간 시행한다. 한글 자음 수화를 측정하기 위해 4개의 채널을 사용한다. 전극의 위치는 그림 7과 같다.[15]




그림 6. 근전도 신호 측정 시스템
Fig. 6 EMG signal measuring system




그림 7. 전극의 위치
Fig. 7 Electrode placement

측정할 근전도 신호는 14개의 한글 자음 중 ‘ㄱ’, ‘ㄴ’, ‘ㅇ’, ‘ㅇ’, ‘ㅇ’의 5개의 자음을 이용하여 측정한다. 실험을 위한 근전도 신호의 측정은 각 자음에 대해 25번 실행하였다. 근전도 데이터는 각 채널당 200개의 데이터로 구성되어 있으므로 총 4×200의 데이터가 된다. 각 자음에 대한 25개씩의 데이터 중에서 훈련용으로 20개의 데이터를 사용하고, 시험용으로 5개의 데이터를 사용한다. 5개의 자음 글자에 대한 근전도 신호의 예는 그림 8과 같다.

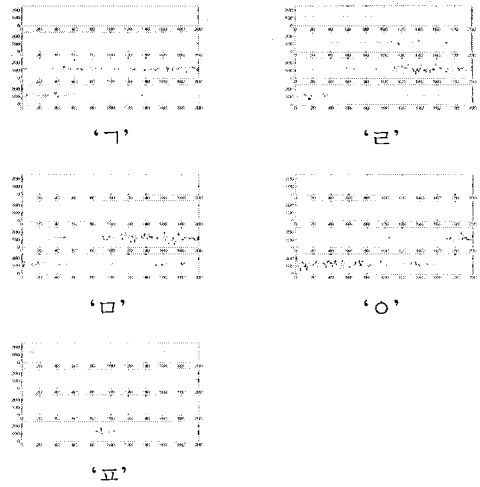


그림 8. 측정된 근전도 신호의 파형
Fig. 8 Waveform of EMG signals

근전도 데이터에 대해서도 제안한 지능시스템과 일반적인 LVQ에 대해 패턴 분류 실험을 했다. 훈련용 근전도 데이터에 대한 실험 결과가 표 5에 나타나 있다. 훈련용 근전도 데이터의 분류 결과 제안한 지능시스템이 15개, 일반적인 LVQ는 90개가 잘못 분류되었음을 알 수가 있다.

표 5. 훈련용 근전도 데이터에 대한 분류 결과
Table 5 The classifying result for training EMG data

		○ (ㄱ)	□ (ㄴ)	△ (ㅇ)	+ (ㅇ)	× (ㅇ)								
C	P	L	C	P	L	C	P	L	C	P	L			
○	○	△	□	△	△	△	△	+	+	+	+	×	×	○
○	○	△	□	□	△	△	△	+	+	+	+	×	×	○
○	○	△	□	□	□	△	△	+	+	+	+	×	×	○
○	○	△	□	□	□	△	△	+	+	+	+	×	×	○
○	○	△	□	×	△	△	△	+	+	+	+	×	×	○
○	○	△	□	×	△	△	△	+	+	+	○	×	×	○
○	○	△	□	□	+	△	△	+	+	+	○	×	△	○
○	○	△	□	□	△	△	△	+	+	+	+	×	×	○
○	○	△	□	□	+	△	△	+	+	+	○	×	×	○
○	○	△	□	□	△	△	△	+	+	+	○	×	×	○
○	○	△	□	□	△	△	△	+	+	+	○	×	×	○
○	○	△	□	□	△	△	△	+	+	+	○	×	×	○
○	○	△	□	□	+	△	△	+	+	+	○	×	×	○
○	○	△	□	□	+	△	△	+	+	+	○	×	×	○
○	○	△	□	□	△	△	△	+	+	+	○	×	×	○
○	○	△	□	□	×	△	△	+	+	+	○	×	×	○
○	○	△	□	□	+	△	△	+	+	+	○	×	×	○
○	○	△	□	□	△	△	△	+	+	+	○	×	×	○
○	○	△	□	□	×	△	△	+	+	+	○	×	×	○

표 6. 시험용 근전도 데이터에 대한 분류 결과
Table. 6 The classifying result for testing EMG data

C	P	L	C	P	L	C	P	L	C	P	L	C	P	L
○	○	△	□	□	+	△	△	+	+	+	□	x	x	○
○	○	○	□	□	+	△	○	+	+	□	□	x	x	○
○	○	△	□	□	+	△	△	+	+	□	+	x	△	○
○	○	△	□	□	+	△	△	+	+	□	□	x	△	○
○	○	△	□	□	+	△	△	+	+	□	□	x	x	○

시험용 근전도 데이터에 대해 제안한 지능시스템과 일반적인 LVQ의 패턴 분류 능력에 대한 실험을 하였다. 실험 결과는 표 6과 같으며, 시험용 근전도 데이터에 대한 분류 결과 제안한 지능시스템은 6개, 일반적인 LVQ는 23개가 잘못 분류되었음을 알 수가 있다.

이상의 결과에서 제안한 지능시스템은 일반적인 LVQ 보다 패턴의 분류와 인식의 정확성에서 매우 우수함을 알 수 있다.

V. 결 론

본 논문에서는 패턴인식의 정확성을 높이기 위한 지능시스템을 제안하였다. 제안한 지능시스템은 SOFM, LVQ, FCM으로 구성하였으며, 크게 훈련과정과 시험과정으로 나누어져 있다. 훈련과정은 SOFM과 FCM의 하이브리드 네트워크와 LVQ로 구성되었고, 제안한 지능시스템이 데이터를 정확하게 분류하게 위해 훈련하는 과정이다. 시험과정은 훈련과정에서 분류된 데이터를 이용하여 입력 데이터를 분류하는 과정으로 SOFM과 LVQ로 구성하였다.

제안한 지능시스템의 유용성을 확인하기 위해서 Fisher의 Iris 데이터, Cambridge 대학의 Olivetti 연구실(ORL; Olivetti Research Laboratory)에서 제공하는 얼굴 영상 데이터, 그리고 근전도 데이터를 분류하는 simulation 및 실험을 하였다. Iris 데이터의 경우 제안한 지능시스템이 98%의 분류 성공률을 보였고, 일반적인 LVQ가 67.3%의 성공률을 보였다. 얼굴 영상물 분류하기 위해 사용된 데이터는 Cambridge 대학의 Olivetti 연구실에서 제공하는 얼굴 데이터베이스를 이용하였다. 얼굴 영상 데이터의 분류에서 제안한 지능시스템은 76%의 성공률을 보였고, 일반적인 LVQ는 11%의 성공률을 보여주었다. 그리고 마지막으로 근전도 데이터의 분류

에서 사용된 근전도 데이터는 14개의 한글 자음중 ‘ㄱ’, ‘ㄴ’, ‘ㅇ’, ‘ㅇ’, ‘ㅇ’ 5개르 수화로 표현할 때 발생하는 근전도 신호를 데이터화 한 것을 사용하였다. 근전도 데이터의 분류에서 제안한 지능시스템은 83.2%의 성공률을 보였고, 일반적인 LVQ는 9.6%의 성공률을 보였다. 이상의 결과를 토대로 제안한 지능시스템이 패턴인식의 정확성 면에서 일반적인 LVQ보다 우수한 성능을 보여주는 것을 알 수 있었다.

감사의 글

본 연구는 2007년도 서일대학 학술연구비 지원에 의하여 이루어진 연구로서, 관계기관에 감사드립니다.

참고문헌

- [1] S. Abe, R. Thawonmas, M. Kayama, "A fuzzy classifier with ellipsoidal regions for diagnosis problems", *IEEE Trans. on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, Vol. 29, pp. 140-148, 1999.
- [2] Sukhan Lee, and George N. Saridis, "The control of a prosthetic arm by EMG pattern recognition", *IEEE Trans. on Automatic Control*, Vol. 29, pp. 290-302, 1984.
- [3] T. Kohonen, "The self organizing map", *Proc. of the IEEE*, Vol.78, pp. 1464-1480, 1990.
- [4] N. K. Bose, P. Liang, *Neural Network Fundamentals with Graphs, Algorithms, and Applications*, McGraw-hill, 1996.
- [5] M. Gil, E. G. Sarabia, J. R. Lata, J. P. Oria, "Fuzzy c-means clustering for noise reduction, enhancement and reconstruction of 3D ultrasonic images", *7th IEEE International Conference on Emerging Technologies and Factory Automation*, Vol. 1, pp. 465-472, 1999.
- [6] A. E. Gavoyiannis, D. G. Vogiatzis, D. R. Georgiadis, N. D. Hatzigiorgiou, "Combined support vector classifiers using fuzzy clustering for dynamic security assessment", *Power Engineering Society Summer Meeting*, Vol. 2, pp. 1281-1286, 2001.

- [7] K. H .Chung, M. J. Chiu, C. C. Lin, J. H. Chen, "Model-free functional MRI analysis using Kohonen clustering neural network and fuzzy C-means", IEEE Trans. on Medical Imaging, Vol. 18, pp. 1117-1128, 1999.
- [8] P. Teppola, S. P. Mujunen, P. Minkkinen, "Adaptive fuzzy c-means clustering in process monitoring", Chemometrics and Intelligent Laboratory System, Vol. 45, pp. 22-38, 1999.
- [9] Hyun-Sook Rhee, Kyung-Whan Oh, "Unsupervised learning network based on gradient descent procedure of fuzzy objective function", IEEE International Conference on Neural Networks, Vol. 3, pp. 1427-1432, 1996.
- [10] B. D. Ripley, Pattern Recognition and Neural Networks, Cambridge University Press, 1996.
- [11] A. Sato, K. Yamada, "A formulation of learning vector quantization using a new misclassification measure", Fourteenth International Conference on Pattern Recognition , Vol. 1, pp. 322-325, 1998.
- [12] Xu Yong, Yan Guangqun, Chen Hexin, Dai Yisong, "A new competitive learning algorithm for vector quantization based on the neuron winning probability", IEEE International Conference on Intelligent Processing Systems, Vol. 1, pp. 485-488, 1997.
- [13] J. C. Bezdek, J. M. Keller, R. Krishnapuram ,L. I Kuncheva, "Will the real iris data please stand up?", IEEE Transactions on Fuzzy Systems, Vol. 7, pp. 368-369, 1999.
- [14] R. Kozma, M. Kitamura, A. Malinowski, J. M. Zurada, "On performance measures of artificial neural networks trained by structural learning algorithms", Second New Zealand International Two-Stream Conference on Artificial Neural Networks and Expert Systems, pp. 22-25, 1995.
- [15] Carlo J. De Luca, "Surface EMG Detection and Recording", Neuro Muscular Research Center, 1997.

저자소개



정성부(Sung-boo Chung)

1979년 동국대학교 전자공학과 학사 졸업

1981년 동국대학교 전자공학과 석사 졸업

2002년 동국대학교 전자공학과 박사 졸업

1987년 ~ 현재 : 서일대학 컴퓨터전자과 교수

※ 관심 분야 : 지능시스템, 통신전자제어



김주웅(Joo-woong Kim)

1996년 동국대학교 전자공학과 학사 졸업

1998년 동국대학교 전자공학과 석사 졸업

2003년 동국대학교 전자공학과 박사 졸업

1994년 ~ 현재 : 뉴파워전자(주) 연구개발실장

1998년~현재 유한대학 전자정보과 겸임교수

※ 관심 분야 : 지능시스템, USN, SMPS