

얼굴인식을 위한 ELM 기반 퍼지 패턴분류기

오성권*, 노석범**
 수원대학교*, 원광대학교**

Extreme Learning Machine based Fuzzy Pattern Classifier for Face Recognition

Sung-Kwun Oh*, Seok-Beom Roh**
 The University of Suwon*, Wonkwang University**

Abstract - 본 논문에서는 얼굴 인식을 위하여 인공 신경망의 일종인 Extreme Learning Machine의 학습 알고리즘을 기반으로 하여 지능형 알고리즘인 퍼지 집합 이론을 이용하여 주변 노이즈에 매우 강한 특성을 보이며 학습 속도가 매우 빠른 새로운 패턴 분류기를 제안한다. 제안된 퍼지 패턴 분류기는 기존 신경회로망의 학습 속도에 비해 매우 빠른 학습 속도를 보이며, 패턴 분류기의 일반화 성능이 우수하다고 알려진 Extreme Learning Machine의 특성을 퍼지 집합 이론과 결합하여 퍼지 패턴 분류기의 일반화 성능을 개선하였다. 제안된 퍼지 패턴 분류기는 얼굴 인식 데이터를 이용하여 성능을 평가 하였다.

1. 서 론

현재는 사회가 매우 복잡해지고 스마트 폰, 태블릿 컴퓨터와 같은 모바일 기기들의 폭발적인 보급 증가로 있으며, 이로 인하여 보안 문제가 심각하게 대두되고 있는 상황이다.

이와 같은 보안 문제를 해결하기 위한 방안으로 생체 인식과 같은 보안 기술이 발달하게 되었으며, 특히 지문인식과 홍채 인식과 같은 생체 인식 기술은 매우 발달되었다. 그러나 이와 같은 지문인식과 홍채 인식과 같은 기술은 사용자의 적극적인 참여가 요구되는 기술이다. 보안기기 사용자의 적극적인 참여 없이 사용자의 권한여부를 판단하기 위하여 얼굴인식이 이용되어 지고 있다.

그러나 이와 같은 2차원 얼굴인식은 인식 대상자의 명암도와 포즈 그리고 조명변화에 따라 얼굴 인식 성공률이 매우 크게 영향을 받는다. 일반적으로 인식대상자의 포즈, 인식 과정에서 명암도의 변화에 강한 패턴 분류기를 설계하고자 여러 가지 지능형 알고리즘의 장점을 결합한 패턴 분류기 들이 제안되어져 왔다.

이들 중에서 신경회로망과 퍼지 집합 이론에 기반을 둔 퍼지 추론 시스템은 서로의 장단점을 보완하며 패턴 분류 분야에서 우수한 성과를 나타내 왔다.

신경회로망의 경우 우수한 학습 능력을 보유하고 있는 반면, 최종적으로 얻게 되는 네트워크의 구조가 블랙박스(black box) 형태를 취하게 되어 설계자가 네트워크의 구조들의 의미를 파악할 수 없다는 단점을 가지고 있다.

이와 달리, 퍼지 집합에 기반을 둔 퍼지 추론 시스템은 전문가의 전문 지식을 기반으로 퍼지 규칙을 설정하고 그 규칙에 따라 나타내고자 하는 시스템을 규정 할 수 있는 장점이 있으나 학습 방법에는 제약이 있다.

이와 같은 두 알고리즘의 장점을 결합하여 신경 회로망의 학습 이론과 퍼지 추론 시스템의 의미 있는 규칙을 접목한 뉴로 퍼지 뉴럴 네트워크가 연구되어져 왔다.

일반적으로 신경회로망에서 사용되는 학습 규칙인 오류 역전파 알고리즘 (Back Propagation Learning Algorithm)은 학습 시간이 오래 걸린다는 단점을 가지고 있으며, 신경회로망의 학습 알고리즘을 계층한 뉴로 퍼지 네트워크의 학습도 비록 신경회로망의 학습속도에 비해 빠른 편이지만, 여전히 학습 속도가 느리다는 단점을 가지고 있다.

이와 같은 신경망의 느린 학습 속도 문제를 해결하기 위하여 신경회로망의 입력층의 노드와 은닉층의 은닉 노드를 연결하는 연결 하중의 학습을 생략한 Extreme Learning Machine(ELM)이 제안되었다 [1].

Guang-Bin Hwang에 의해 제안된 FLM은 신경회로망의 입력 층과 은닉 층 사이의 연결 하중 값을 랜덤하게 설정하고, 은닉 층과 출력 층의 연결 하중은 Moore - Penrose generalized inverse matrix를 이용하여 학습을 하게 된다.

이와 같은 학습 기법으로 인하여 일반적인 신경회로망이 가지고 있는 반복 학습 (iterative learning)과정을 생략함으로써 학습속도를 대폭 향상 시킬 수 있다.

본 논문에서 ELM의 학습 구조를 뉴로 퍼지 회로망에 적용함으로써, 학습 속도를 높이며, 뉴로 퍼지 회로망의 일반화 성능을 개선 하고자 한

다. 제안된 Extreme Learning Machine 기반 퍼지 패턴 분류기를 이용하여 얼굴인식의 일반화 성능을 향상 시키고자 한다.

2. 본 론

2.1 PCA를 이용한 특징 추출

일반적으로 얼굴인식에 사용되는 이미지의 해상도가 좋을수록 인식률은 높아지게 되지만, 이미지의 해상도가 좋을수록 영상획득 장비를 통해서 얻게되는 이미지 데이터의 차원은 급격하게 증가된다. 증가된 이미지 데이터의 차원을 감소시키고 패턴 분류에 적합한 특징을 추출하기 위하여 본 논문에서는 PCA(Principal Component Analysis; 주 성분 분석)를 이용하였다.


주성분 분석을 통해 고차원의 입력 데이터를 저차원 입력 공간으로 매핑 시킴으로써 차원 감소를 이룰 수 있으며, 차원감소를 통하여 Computational load를 획기적으로 줄일 수 있다.

2.2 Extreme Learning Machine

본 논문에서는 신경 회로망의 학습 속도를 대폭 높이고 신경 회로망의 일반화 성능을 개선한 Extreme Learning Machine을 기반으로 한 퍼지 패턴 분류기를 제안한다.

일반적으로 한 층의 은닉층을 가진 신경회로망을 Single Hidden Layer Feed-foward Networks(SLFNs)라고 부른다.

그림 1은 SLFNs의 기본 구조를 나타낸다.



<그림 1> SLFNs의 기본 구조

데이터 쌍 $(\mathbf{x}_i, \mathbf{t}_i)$ 가 주어졌을 경우, 일반적인 SLFNs의 출력 식은 (1)과 같다. 여기서 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 이며 $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ 이다.

$$\mathbf{o}_j = \sum_{i=1}^C \beta_i \cdot g_i(\mathbf{x}_j) = \sum_{i=1}^C \beta_i \cdot g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) \quad (1)$$

여기서, \mathbf{o}_j 는 j번째 출력 노드의 출력 값을 의미하며, C는 은닉층의 노드 수를 나타낸다.

그리고 $g_i(\mathbf{x}_j)$ 는 은닉층의 i번째 은닉 노드의 출력을 나타내며, $\mathbf{w}_i = [w_{i1} w_{i2} \dots w_{im}]$ 는 입력층의 노드와 은닉층의 i번째 노드 사이의 연결 하중을 의미한다. b_i 는 은닉층의 i번째 노드의 스레스홀드 값이다.

일반적으로 활성화 함수 $g(x)$ 를 가진 C개의 은닉 노드로 이루어진 SLFNs N개의 샘플데이터를 근사화 할 수 있다고 알려져 있다[1].

$$\sum_{i=1}^C \beta_i \cdot (\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = t_j, j = 1, \dots, N \quad (2)$$

여기서, N은 데이터 샘플의 수를 의미한다. 식(2)를 행렬로 표현하면 (3)과 같다.

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (3)$$

여기서, $\mathbf{H} = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \dots & g(\mathbf{w}_C \cdot \mathbf{x}_1 + b_C) \\ \vdots & \dots & \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \dots & g(\mathbf{w}_C \cdot \mathbf{x}_N + b_C) \end{bmatrix}$,
 $\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_C^T \end{bmatrix}$, 그리고 $\mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}$ 이다.

위와 같은 SLFNs의 학습 위하여, ELM은 $\mathbf{w}_1, \dots, \mathbf{w}_C$ 과 b_1, \dots, b_C 를 임의의 확률 분포 함수를 통해 추출하여 사용한다. 일반적인 SLFNs는 \mathbf{w}_k 와 b_k 를 학습을 통해 결정하게 된다.

ELM에서는 $\boldsymbol{\beta}$ 를 결정하기 위하여 least square 방법을 이용하여 아래와 같은 목적함수를 최소화 하는 $\boldsymbol{\beta}$ 를 결정하게 된다.

$$J = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (4)$$

(4)를 최소화 시키는 smallest norm least squares의 해는 (5)와 같다.

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (5)$$

여기서, \mathbf{H}^+ 는 Moore-Penrose generalized inverse of Matrix \mathbf{H} [2]이다.

2.2 ELM 기반 퍼지 패턴 분류기

위에 설명한 ELM 알고리즘에 기반한 퍼지 패턴 분류기는 일반적인 TSK 퍼지 추론 시스템이다.

일반적인 TSK퍼지 모델의 퍼지 규칙 전부분은 일반적으로 전문가들의 전문적인 지식에 의해 기술 되거나 퍼지 클러스터링 알고리즘을 이용하여 데이터를 분석하여 퍼지 규칙의 전부분 구조를 결정한다.

그러나 ELM기반 퍼지 패턴 분류기에서는 전부분 퍼지 규칙을 랜덤하게 설정할 것이며, 후반부 구조의 coefficient 들은 (5)와 같이 결정 된다.

본 논문에서는 퍼지 클러스터의 정의를 위해서 반복 최적화 과정을 거치지 않고 랜덤하게 ν 값을 결정하여 사용하여 은닉 노드의 활성화 함수는 Fuzzy C-Means Clustering [3] 의 출력식과 같은 (6)을 통해 얻게 된다.

$$g(\mathbf{w}_1, \dots, \mathbf{w}_C) = \frac{1}{\sum_{j=1}^c \left(\frac{\|\mathbf{x}_k - \mathbf{w}_i\|}{\|\mathbf{x}_k - \mathbf{w}_j\|} \right)^{2/p-1}} \quad (6)$$

ELM 기반 퍼지 패턴 분류기를 구성하는 퍼지 규칙은 (7)과 같다.

$$\text{If } \mathbf{x} \text{ is } g_k \text{ then } o_1 \text{ is } \beta_{1j}, \dots, o_m \text{ is } \beta_{mj} \quad (7)$$

(7)과 같은 퍼지 규칙을 가진 퍼지 패턴 분류기의 파라미터를 학습하기 위하여 목적함수는 (8)과 같고, 목적함수를 최소화하는 파라미터 $\boldsymbol{\beta}$ 는 (9)과 같다.

$$\min_{\boldsymbol{\beta}} \|\mathbf{W}\mathbf{H}\boldsymbol{\beta} - \mathbf{W}\mathbf{T}\| \quad (8)$$

$$\boldsymbol{\beta} = ((\mathbf{W}\mathbf{H})^T \mathbf{W}\mathbf{H})^{-1} (\mathbf{W}\mathbf{H})^T \mathbf{W}\mathbf{T} \quad (9)$$

3. 실험 및 결과 고찰

본 논문에서는 노이즈에 강한 퍼지 집합 이론을 ELM에 적용한 퍼지 패턴 분류기를 제안한다. ELM은 신경 회로망에 비해 매우 빠른 학습속도와 패턴 분류기의 일반화 성능을 개선시키는 장점을 가지고 있다. 이와 같은 두 가지 종류의 알고리즘의 장점들을 결합하여, 주변 노이즈에 강하며, 패턴 분류기의 일반화 예측성능도 우수한 패턴 분류기를 제안한다.

제안된 ELM기반 퍼지 패턴 분류기를 얼굴 인식에 적용하기 위하여, 획득된 이미지의 특징을 추출하는 방법으로 주성분 분석을 이용한다.

얼굴 인식의 경우 일반적으로 인식 대상 주변의 조명 변화 와 인식 대상의 포즈 변화에 따라 얼굴 인식의 성공률이 좌우 된다.

이와 같이 주변 노이즈에 의해 패턴 분류기의 성능의 좌우 되는 문제의 경우 노이즈에 강한 패턴 분류기를 적용하는 것은 당연하다 할 수 있다.

본 논문에서는 제안된 퍼지 패턴 분류기의 성능을 평가하기 위하여 ORL 얼굴인식 데이터 집합을 사용하였다.



〈그림 2〉 ORL 이미지

표1은 제안된 퍼지 패턴 분류기를 이용한 ORL 얼굴 데이터에 대한 실험결과를 커널 파라미터 (D) 에 따라 열거 한 것이다.

〈표 1〉 제안된 분류기와 성능

D	0.1	1	5	10	20	30	50
인식률	93.75 (1.25)	95.25 (1.85)	91.5 (3.79)	86.25 (4.05)	81.75 (1.89)	78.75 (2.65)	75.75 (2.27)

ELM 기반 퍼지 패턴 분류기의 성능을 평가하기 위하여 5fold cross validation을 이용하여 얻은 결과는 95.25 (1.85)% 이다.

4. 결 론

본 논문에서는 입력 층과 은닉 층 사이의 연결 하중을 랜덤하게 결정하고 은닉층과 출력층 사이의 연결 하중은 Moore-Penrose generalized inverse를 이용하여 결정하는 ELM의 학습 알고리즘을 기반으로 하는 퍼지 패턴 분류기를 제안한다. 제안된 ELM 퍼지 패턴 분류기를 ORL 얼굴데이터에 적용하여 우수한 결과를 얻었다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음(GRRC 수원2015-B2, U-city 보안감시 기술협력센터) 그리고 한국산업단지공단의 10차년도 산업집적지경쟁력강화산업계획의 생산기술사업화 지원사업으로 연구를 수행하였음(NTIS-1415136442)

[참 고 문 헌]

- [1] G. B. Hwang, Q. U. Zhu, C. K. Siew, "Extreme learning machine: Theory and applications," Neurocomputing, Vol. 70, pp. 489-501, 2006
- [2] D. Serre, Matrices: Theory and Applications, Springer, New York, 2002
- [3] J. C. Bezdek, R. Ehrlich and W. Full, "FCM: The fuzzy c-means clustering algorithm," Computers & Geoscience, Vol. 10, pp. 191 - 203, 1984