

## 퍼지추론 기반 Polynomial RBF Neural Network 설계와 얼굴 인식으로의 적용

김길성\*, 이경희\*, 오성권\*  
수원대학교 전기공학과\*

### The Design of Polynomial RBF Neural Network based on Fuzzy Inference and Its application to Face Recognition

Gil-Sung Kim\*, Kyung-Hee Lee\*, Sung-Kwun Oh\*  
Dept. of Electrical Engineering, The University of Suwon\*

**Abstract** – 본 연구에서는 퍼지 추론 메커니즘에 기반 한 Polynomial RBF Neural Network(p-RBFNN)를 설계하고 얼굴인식 문제로 적용하여 분류기로서의 성능을 분석한다. 제안된 p-RBFNN 구조는 FCM 클러스터링에 기반 한 분할 함수를 활성 함수로 사용하며, 다항식 함수로 구성된 연결가중치를 사용함으로서 기존 신경회로망 분류기의 선형적인 특성을 개선한다. p-RBFNN 구조는 언어적 해석 관점에서 "If-then"의 퍼지 규칙으로 표현되며 퍼지 추론 메커니즘에 의해 구동된다. 즉 조건부, 결론부, 추론부 세 가지의 기능적 모듈로 나뉘어 네트워크 구조가 형성된다. 조건부는 FCM 클러스터링을 사용하여 입력 공간을 분할하고, 결론부는 분할된 로컬 영역을 다항식 함수로 표현한다. 마지막으로, 네트워크의 최종 출력은 추론부의 퍼지추론에 의한다. 또한 제안된 p-RBFNN을 얼굴인식 문제로 적용하여 성능을 분석한다.

### 1. 서 론

신경회로망을 기반으로 설계된 분류기는 학습능력과 일반화(generalization) 능력의 우수성으로 인해 다양한 분야의 패턴인식 시스템에서 가장 많이 사용되는 분류기 중 하나이다. 기존에 신경회로망을 기반으로 한 많은 분류기는 연결가중치가 상수항으로 구성되어 있다. 상수항으로 구성된 연결가중치는 은닉층 뉴런의 활성 함수와의 선형 결합을 통해 출력 공간 내에 선형 판별 함수(linear discernment function)로 표현된다. 이는 네트워크가 출력 공간 내에 선형 판정 경계(조평면)를 생성하도록 만들며, 선형적인 특성을 가지게 한다. 본 연구에서는 이와 같은 문제의 해결책을 위해 출력공간상에 비선형 특성을 갖는 판별함수를 생성하기 위해 연결가중치를 기존의 상수항에서 1차식, 2차식으로 확장한 퍼지 추론 메커니즘에 기반 한 Polynomial RBF Neural Network(p-RBFNN)를 설계한다. 또한 제안된 p-RBFNN 구조는 FCM 클러스터링에 기반 한 분할 함수를 활성 함수로 사용한다. 이는 시그모이드 함수, 방사형 기저 함수를 사용한 활성 함수보다 입력 공간의 데이터 분포 특성을 잘 반영함으로써 빠른 학습 수렴과 성능 개선의 특징을 가진다. 제안된 p-RBFNN의 분류기로서의 성능을 분석하기 위해 얼굴인식 시스템에 적용한다.

### 2. Polynomial RBF Neural Network

#### 2.1 p-RBF Neural Network 구조

본 논문에서 제안한 퍼지 추론 메커니즘에 기반 한 Polynomial RBF Neural Network(p-RBFNN)는 활성 함수로 FCM 클러스터링에 의한 분할 함수를 사용하며, 비선형 특성의 판정 경계를 위해, 상수항 연결가중치가 아닌 다항식 연결가중치를 이용한다. 뿐만 아니라 제안된 p-RBFNN 구조는 기능적 모듈로 동작되며, 이는 퍼지 추론 메커니즘의 특징을 나타낸다. 본 논문에서 제안한 p-RBFNN 구조는 FCM 클러스터링 분할 함수와 다항식의 적용으로부터 식 (1)의 퍼지 규칙 표현과 같이 언어적 관점에서 해석될 수 있다.

$$\text{If } \mathbf{x} \text{ is } A_i \text{ then } f_{ji}(\mathbf{x}) \quad (1)$$

여기서,  $\mathbf{x}$ 는 입력 벡터,  $A_i$ 는 FCM 클러스터링에 의한  $i(=1, \dots, c)$  번째 그룹의 소속 함수(membership function or partition matrix),  $f_{ji}(\mathbf{x})$ 는  $j(=1, \dots, s)$  번째 출력에 대한  $i$  번째 퍼지 규칙의 다항식이다. 제안된 p-RBFNN 구조는 퍼지 규칙에 기반 한 네트워크 구조를 가지며, 조건부, 결론부, 추론부의 세 가지 기능적 모듈로 분리되어 동작한다. 그림 1은 기능적 모듈로서의 p-RBFNN 구조를 보여준다. p-RBFNN 구조의 결론부는 조건부에서 분리한 각 로컬 영역을 다항식 함수의 로컬 회기모델로서 표현하여 식 (1)의 "then" 이후의 규칙을 형성한다. 식 (1)의  $f_{ji}(\mathbf{x})$ 에서 출력 뉴런에 대한 첨자  $j(=1, \dots, s)$ 를 생략한  $f_i(\mathbf{x})$ 는 식 (2)-(4)의 형태를 갖는 세 가지 타입의 함수 중 하나의 형태를

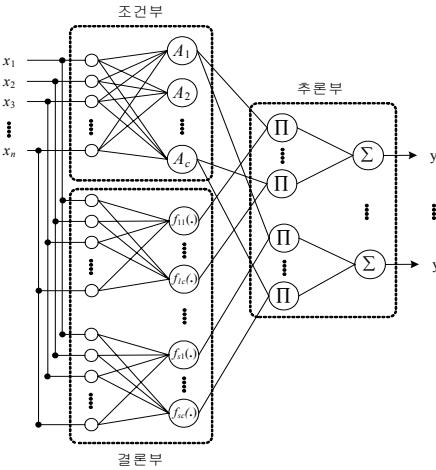
갖는다. 즉, 로컬 회기 모델은 상수항, 일차식 또는 이차식으로 표현되어 진다.  $f_i(\mathbf{x})$ 가 식 (2)의 상수항인 경우 FCM 클러스터링을 통한 소속 함수를 활성 함수로 사용한 RBFNNs[1]와 동일한 구조를 갖는다.

$$\text{Constant: } f_i(\mathbf{x}) = a_{i0} \quad (2)$$

$$\text{Linear: } f_i(\mathbf{x}) = a_{i0} + \sum_{j=1}^n a_{ij} x_j \quad (3)$$

$$\text{Quadratic: } f_i(\mathbf{x}) = a_{i0} + \sum_{j=1}^n a_{ij} x_j + \sum_{j=1}^n \sum_{k=j}^n a_{ijk} x_j x_k \quad (4)$$

식 (2)-(4)의 다항식 함수들은 조건부의 소속 함수(활성 함수)에 의해 활성화 되며 각 퍼지 규칙의 로컬 회기 모델로 동작한다. 본 논문에서 제안한 p-RBFNN는 기존의 식 (2)의 형태를 갖는 상수항의 연결가중치를 식 (3)-(4) 형태의 1차식과 2차식으로 확장함으로서 은닉층 뉴런의 출력간의 비선형 결합으로 인해 분류기로서의 성능을 향상시킨다.



〈그림 1〉 조건부, 결론부, 추론부의 세 가지 모듈로서 표현된 p-RBFNN의 구조

#### 2.2 후반부 다항식 계수 학습

본 연구에서는 p-RBFNN의 가중치인 다항식 함수의 계수를 학습하기 위하여 경사 하강법(Gradient Descent Method)을 이용한다. 학습은 오차식인 식(5)을 최소화하도록 진행된다.

$$E = \frac{1}{2} \sum_{k=1}^N (t_k - y_k)^2 \quad (5)$$

$N$ 은 입력 데이터 패턴수이며, 학습은 다항식 함수의 구조에 따라 세 가지로 구분된다. 가중치 갱신을 위한 최종 식은 식(6)-(8)로 표현되고  $\eta$ 는 학습률,  $\alpha$ 는 모멘텀 계수이다.

$$\text{Constant: } a_{i0}(n+1) = a_{i0}(n) + \eta(t-y)A_i + \alpha\Delta a_{i0}(n) \quad (6)$$

$$\text{Linear: } a_{ij}(n+1) = a_{ij}(n) + \eta(t-y)A_i x_j + \alpha\Delta a_{ij}(n) \quad (7)$$

$$\text{Quadratic: } a_{ijk}(n+1) = a_{ijk}(n) + \eta(t-y)A_i x_j x_k + \alpha\Delta a_{ijk}(n) \quad (8)$$

### 3. Principal Component Analysis

Principal Component Analysis(PCA) 기법은 벡터표현의 통계학적 특성을 바탕으로 고차원의 데이터를 저차원의 데이터로 줄여 다루기 쉽게 하기 위한 알고리즘으로서 Karhunen-Love 근사 방법[2]이라고도 한다. PCA는 데이터의 공분산 행렬의 고유벡터(eigenvector)를 계산하고, 상위 고유벡터의 선형조합으로 원래의 데이터에 근접해가는 것이다.  $N \times N$ 크기의  $M$ 개의 얼굴 영상들의 학습 데이터 집합을  $\Gamma_1, \Gamma_2, \dots, \Gamma_M$ 으로 나타낼 때, 이 데이터 집합의 평균 얼굴은 아래의 식 (9)와 같이 나타낼 수 있다.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (9)$$

각각의 얼굴과 평균얼굴과의 차영상은 벡터  $\Phi_i = \Gamma_i - \Psi$ 로 나타낸다. 벡터  $\mathbf{u}_k$  와  $\lambda_k$ 는 각각 다음의 식 (10)의 공분산 행렬의 고유벡터(eigenvectors)와 고유값(eigenvalues)이다.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (10)$$

여기서 행렬  $A = [\Phi_1 \Phi_2 \dots \Phi_M]$ 이다. 이러한 고유벡터들은 원영상과 같은 차원이고 얼굴과 비슷한 모양을 나타내기 때문에 고유얼굴(eigenface)이라고 불린다. 고유얼굴이 주어지면 각각의 가중치들은 얼굴영상( $\Gamma$ )을 고유얼굴( $\mathbf{u}_k$ ) 성분에 대하여 투영하여 다음 식 (11)에 의하여 얻어진다.

$$\omega_k = \mathbf{u}_k(\Gamma - \Psi) \quad \text{for } k=1, \dots, M' \quad (11)$$

여기서 상위  $M'$ 개의 고유치에 해당하는  $M'$ 개의 중요 고유얼굴들 ( $\mathbf{u}_1, \dots, \mathbf{u}_{M'}$ )이 선택된다. 가중치들은 하나의 입력 얼굴 영상을 표현하는데, 고유얼굴 각각의 기여도를 나타내는 하나의 벡터  $\Omega^T = [\omega_1, \dots, \omega_{M'}]$ 를 생성한다.

### 4. 실험

본 논문에서 제안된 퍼지 추론기반 Polynomial RBF Neural Network(p-RBFNN)를 얼굴인식으로 적용하여 분류기로서의 성능을 분석한다. 실험은 ORL Database[3]를 사용하였다. ORL Database의 40명 중 5명을 택하여 50개의 이미지에 대하여 각 사람별 학습영상 5장, 테스트 영상 5장을 N번을 랜덤하게 선택하여 인식률에 대한 N번의 평균과 표준편차를 구하는 N-Fold Cross-Validation 방법을 사용하였다. N-Fold Cross-Validation 방법은 얼굴인식의 성능 평가에 많이 사용된다[4]. p-RBFNN의 학습률, 모멘텀계수, 퍼지화 상수의 결정을 위해서 Kennedy and Eberhart에 의해 처음 소개된 새 폐와 물고기 폐와 같은 생체구조의 사회적 행동양식을 바탕으로 한 최적화 알고리즘인 Particle Swarm Optimization(PSO)[5]을 이용하였다. 아래의 <그림 2>는 실험에 사용된 5명의 얼굴 이미지이며 <표 1>은 실험에 사용된 파라미터들이다.

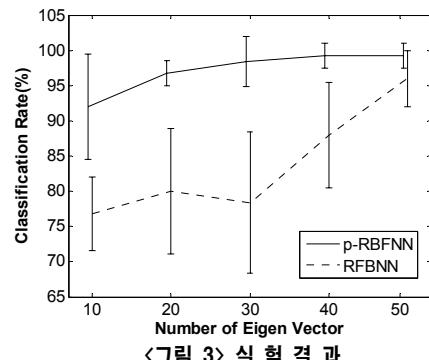


<그림 2> 실험에 사용된 ORL Database

<표 1> 실험 파라미터

	파라미터	값
p-RBFNN	학습 횟수	300
	퍼지 규칙 수 (FCM Cluster 수)	5
	N-Fold	5
	세대수	5
	particle 수	30
PSO	학습률	[1e-5, 0.5]
	모멘텀 계수	[1e-5, 0.5]
	퍼지화 상수	[1.1, 3.0]

실험은 PCA의 중요 고유얼굴 수인  $M'$ 에 대하여 10, 20, 30, 40, 50에 대하여 실험 하였으며 기존의 RBFNN[1]과 제안된 p-RBFNN의 성능은 아래의 <그림 3>과 같다.



<그림 3> 실험 결과

<그림 3>의 결과로 알 수 있듯이 거의 모든 경우에 p-RBFNN이 후반부가 상수인 기존의 RBFNN보다 우수한 성능을 보임을 알 수 있다. 이러한 결과는 연결가중치의 다양성의 확장으로 인하여 출력 공간상에 비선형의 특징을 갖는 판별함수가 생성되기 때문이다. 아래의 표 2는 기존의 연구들과의 성능을 비교한 표이다. 기존의 연구결과들과 비교해 볼 때 우수한 인식률을 보이는 것을 알 수 있다. 비교된 CNN, NFL, M-PCA, RBFNN에 대한 설명은 참고문헌 [4]에 언급되어 있다.

<표 2> 다른 연구들과의 비교

Classifier Model	No. of Simulation	No. of Eigen Vectors	Ave. of Classification Rate(%)
CNN	3	25, 30	96.17
NFL	4	40	96.875
M-PCA	10	Unknown	97.6
RBFNN	6	25, 30	98.18
<b>Our proposed p-RBFNN</b>	<b>5</b>	<b>30</b>	<b>98.40</b>

### 5. 결 론

본 논문에서 제안된 퍼지 추론기반 Polynomial RBF Neural Network(p-RBFNN)를 설계하고 얼굴인식으로 적용하여 그 성능을 분석하였다. 출력공간의 비선형 특징을 갖는 판별함수를 가능하게 함으로서 p-RBFNN은 기존의 연구들과 비교해 볼 때 우수한 성능을 보였다. 하지만 p-RBFNN은 학습 되어야 할 파라미터가 많아 ORL Database의 40명 중 5명만의 영상을 인식 할 수밖에 없었다. 이에 대한 해결책으로서 p-RBFNN을 위한 Hybrid Learning Algorithm등의 차후 연구가 필요하다.

#### 감사의 글

감사의 글: 이 논문은 2008년도 한국전자통신연구원의 재원으로 지원을 받아 수행된 연구임 (과제번호:2008-35MIC)

#### 참 고 문 헌

- W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks," IEEE Trans. Neural Networks, vol. 9, pp. 601 - 612, July 1998.
- Kirby M. and Sirovich, "Application of the Karhunen-Loeve Procedure for the Characterization of Human Faces", IEEE Trans. PAMI, 12(1):103-108, 1990.
- <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>
- M.J. Er, S.Q. Wu, J.W. Lu, H.L. Toh, "Face recognition with radial basis function (RBF) neural networks," IEEE Trans. Neural Networks, vol. 13, No. 3, pp. 697-710, 2002.
- J. Kennedy and R. Eberhart, "Particle swarm optimization," Proc. IEEE Int. Conf. Neural Networks, vol. 4, pp. 1942-1948, 1995.