

다항식기반 RBF 신경회로망을 이용한 2-클래스 문제에 대한 패턴분류

김길성¹, 박병준², 오성권¹
¹수원대학교 전기공학과
²지엠텍(주) 기술연구소

Pattern Classification of Two Classes' Problem
 Using Polynomial based Radial Basis Function Neural Networks.

Gil-Sung Kim¹, Byoung-Jun Park², Sung-Kwon Oh¹
¹Dept. of Electrical Engineering, University of Suwon.
²The Technology Research Institute GM TECH CO.,LTD.

Abstract - 본 논문에서는 다항식 기반 Radial Basis Function(RBF)신경회로망(Polynomial based Radial Basis Function Neural Networks)을 설계하고 이를 2-클래스 패턴 분류 문제에 응용하여 그 성능을 분석한다. 제안된 다항식기반 RBF 신경회로망은 입력층, 은닉층, 출력층으로 이루어진다. 입력층은 입력 벡터의 값들을 은닉층으로 전달하는 기능을 수행하고 은닉층은 Fuzzy c-means 클러스터링을 통하여 뉴런의 출력 값을 내보낸다. 은닉층과 출력층사이의 연결가중치는 상수, 선형식 또는 이차식으로 이루어지며 경사 하강법에 의해 학습된다. Networks의 최종 출력은 연결가중치와 은닉층 출력의 곱에 의해 퍼지추론의 결과로서 얻어진다. 제안된 다항식기반 RBF 신경회로망은 각기 다른 4종류의 2-클래스 분류 문제에 적용 및 평가되어 분류기로서의 성능을 분석한다.

언어적 해석의 관점에서, 다항식기반 RBF 신경회로망은 FCM 클러스터링을 통한 전반부규칙과 다항식 함수로 구성된 후반부 규칙으로 이루어진, 식(1)의 룰(rule)로서 표현된다. 그러므로 룰의 개수는 FCM의 클러스터 개수와 은닉층 노드수와 같고 다항식기반 RBF 신경회로망의 최종 출력은 퍼지추론으로서 얻어진다.

$$\text{If } X \text{ is } A_i \text{ then } f_i(x) \tag{1}$$

X는 입력벡터 $[x_1, \dots, x_n]$, A_i 는 i 번째 클러스터의 멤버십함수, f_i 는 다항식 함수, n 은 입력변수 수, c 는 클러스터 개수이다. f_i 는 은닉층과 출력층 사이의 가중치를 표현하는 다항식 함수로서 상수, 선형, 2차식의 세 가지 타입 중 한 가지로서 구성되며 식(2)-(4)로 표현된다.

$$\text{Type 1 : Constant; } f_i(x) = a_0 \tag{2}$$

$$\text{Type 2 : Linear; } f_i(x) = a_0 + \sum_{j=1}^n a_j x_j \tag{3}$$

$$\text{Type 3 : Quadratic; } f_i(x) = a_0 + \sum_{j=1}^n a_j x_j + \sum_{j=1}^n \sum_{k=j}^n a_{ijk} x_j x_k \tag{4}$$

1. 서 론

지난 수십 년간 패턴인식을 위한 다양한 방법들이 연구되었다. 그 중 신경회로망을 기반으로 한 Multi-Layer Perceptron(MLP), Polynomial Neural Networks(PNN), Radial Basis Function Neural Networks(RBFNN) 등은 좋은 패턴인식 성능을 보이는 방법이다[1-3]. 본 연구에서는 기존의 RBF 신경회로망의 성능 개선을 위하여, 다항식기반 RBF 신경회로망을 설계한다. 구현한 다항식 기반 RBF 신경회로망은 입력층, 은닉층, 출력층으로 구성된 3층 네트워크이다. 성능 개선의 방법으로 Fuzzy c-means 클러스터링을 이용하여 Radial Basis Function에 퍼지추론 개념을 접목시켰으며, 기존 RBFNN의 은닉층과 출력층사이의 가중치를 상수항으로만 구성한 것보다 달리 선형 다항식과 2차 다항식을 사용하여 다항식 기반 RBF 신경회로망을 설계하였다. 구현한 다항식 기반 RBF 신경회로망의 패턴분류 성능을 검증 위해 각기 다른 특성을 가진 4가지 종류의 2클래스 문제에 적용하여 기존의 상수항으로만 구성된 RBFNN과 다항식 기반 RBF 신경회로망의 성능을 비교 평가한다.

2.2 Fuzzy c-means 클러스터링

본 연구에서 구현한 다항식기반 RBF 신경회로망은 FCM 클러스터링을 이용하여 은닉층 노드들의 활성값을 계산한다. FCM에서의 클러스터 수에 따라 은닉층 뉴런의 개수가 정해지며 이는 식(1)의 IF-then 룰의 개수와 같다. FCM은 식(5)로 표현되는 목적함수 값을 최소화 하는 클러스터링 방법이며 n 차원 입력 벡터들의 c 개의 클러스터에 대한 소속값을 구한다[5].

$$Q = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \|x_k - v_i\|^2 \tag{5}$$

식(5)의 m 은 FCM의 퍼지화 계수(상수)이며, c 는 클러스터 수, N 은 데이터 패턴 개수를 나타낸다. k 번째 입력 벡터 x_k 와 i 번째 클러스터의 중심 v_i 간의 거리를 표준편차로 나눈 weighted Euclid distance는 식 (6)으로서 얻는다.

$$\|x_k - v_i\|^2 = \sum_{j=1}^n \frac{(x_{kj} - v_{ij})^2}{\sigma_j^2} \tag{6}$$

식(6)의 σ_j 는 j 번째 차원의 입력변수들의 표준편차이다. 식 (5),(6)의 결과로서 소속 행렬 $U=[u_{ik}(i=1, \dots, c; k=1, \dots, N)]$ 로 표현되고 은닉층 뉴런의 출력값으로 사용된다.

2.3 Fuzzy Inference

2.1절에서 언급한 바와 같이, 구현한 다항식 기반 RBF 신경회로망의 구조는 식(1)의 If-then 룰로 표현될 수 있으며 이를 통해 언어적 해석이 가능해진다. 본 신경회로망은 FCM의 각 클러스터를 룰로서 사용하여 퍼지공간분할 개념을 구현한다. 그러므로 네트워크의 최종출력은 전반부규칙에 해당하는 은닉층의 출력과 후반부 규칙에 해당하는 다항식 함수를 곱하여 얻어지는 퍼지추론 결과를 가진다. 최종 출력 y 는 모든 룰의 합으로서 계산되며, 이는 다음의 식(7)과 같이 표현된다.


$$y = g(x) = \sum_{i=1}^c u_i f_i(x) \tag{7}$$

$g(x)$ 는 다항식 기반 RBF 신경회로망의 출력 함수, u_i 는 FCM으로 구한 클러스터 A_i 에 대한 소속값, $f_i(x)$ 는 후반부 규칙으로 표현되는 식(2)-(4)의 다항식 함수이다. 각 룰에 해당하는 c 개의 다항식 함수를 사용하여 네트워크를 구성한다. If-then절로 표현되는 다항식 기반 RBF 신경회로망의 구조는 퍼지 뉴런 네트워크와 구조의 유사성을 갖는다[6].

2. 다항식기반 RBF 신경회로망

2.1 다항식기반 RBF 신경회로망의 구조

기본 RBFNN은 입력층, 한 개의 은닉층, 출력층을 가진 3층 네트워크구조이다. 네트워크 내의 가중치는 은닉층과 출력층 사이에서만 존재하며 학습된다. 은닉층의 노드들은 Radial Basis Function을 활성화함수로 사용하여 활성값을 계산한다. 활성화함수로 사용되는 RBF로서는 가우시안함수가 가장 많이 사용된다[4]. 본 연구에서 구현한 다항식기반 RBF 신경회로망은 기본 RBFNN과 같이 네트워크가 3층으로 구성되고 가중치가 은닉층과 출력층 사이에서만 존재한다. 그러나 기존의 RBFNN이 상수항으로만 가중치를 구성한 것과는 달리 다항식기반 RBF 신경회로망은 입력변수들을 사용한 다항식으로 구성하여 어려운 패턴분류 문제를 위한 알맞은 공간 분할곡선을 만들 수 있다. 또한 은닉층의 노드들이 Fuzzy c-means(FCM) 클러스터링 방법으로 활성화된다. 즉, FCM의 클러스터들이 각 은닉층의 노드에 한 개씩 할당되며, 각 클러스터에 대한 소속값이 노드의 활성값으로 사용된다. 그림 1은 다항식기반 RBF 신경회로망의 구조를 보여준다.



〈그림 1〉 다항식기반 RBF 신경회로망의 구조

3. 다항식기반 RBF 신경회로망의 학습

본 연구에서는 다항식 기반 RBF 신경회로망의 가중치인 다항식 함수의 계수를 동정하기 위하여 경사 하강법을 이용하여 학습시킨다. 학습은 오차 식인 식(8)을 최소화하도록 진행된다.

$$E = \frac{1}{2} \sum_{k=1}^N (t_k - y_k)^2 \quad (8)$$

N 은 입력 데이터 패턴수이며, 학습은 다항식 함수의 구조에 따라 세 가지로 구분된다. 가중치 갱신을 위한 최종 식은 식(9)-(11)로 표현되고 n 는 학습률, α 는 모멘텀 계수이다. 본 연구에서는 학습률 0.01, 모멘텀 계수 0.001을 사용하였다.

Constant: $a_{i0}(n+1) = a_{i0}(n) + \eta(y - \hat{y})A_i + \alpha \Delta a_{i0}(n) \quad (9)$

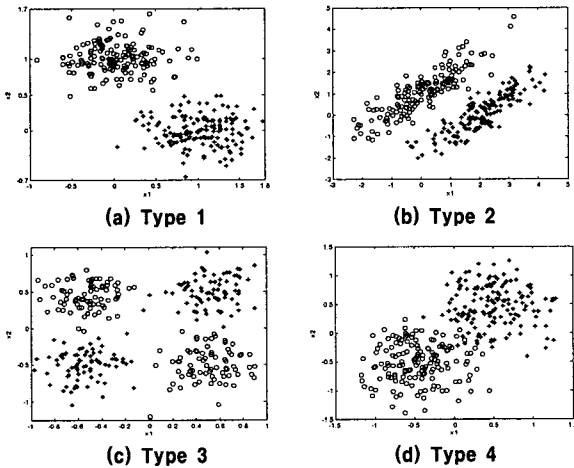
Linear: $a_{ij}(n+1) = a_{ij}(n) + \eta(y - \hat{y})A_i x_j + \alpha \Delta a_{ij}(n) \quad (10)$

Quadratic: $a_{ijk}(n+1) = a_{ijk}(n) + \eta(y - \hat{y})A_i x_j x_k + \alpha \Delta a_{ijk}(n) \quad (11)$

4. 시뮬레이션

4.1 Synthetic Data Set

본 연구에서 구현한 다항식 기반 RBF 신경회로망의 패턴분류성능을 분하기 위해 2-클래스를 가진 4개의 모의 데이터 집합을 구성하여 실험하였다. 서로 다른 분포의 각 데이터 집합은 각 클래스별로 150개의 패턴을 가진, 300개의 패턴으로 구성된다. 그림 2는 구성된 데이터 집합의 분포를 보여준다. 본 연구에서는 각 4개의 타입의 데이터 집합에 대하여 FCM의 물수(클러스터 수)를 2-5개까지 증가시키며 패턴분류 성공률을 분석하였다.



〈그림 2〉 4가지 타입의 모의 데이터 집합


4.2 실험 결과

표 1은 RBFNN과 다항식 기반 RBF 신경회로망의 각 데이터 집합에 대한 패턴분류 성공률과 수렴 시 학습 횟수를 비교한 표이다. 다항식 기반 RBF 신경회로망이 적은수의 룰을 가지고 RBFNN보다 더 좋은 인식률을 보였다.


〈표 1〉 Classification Rate(Learning Iteration)

Data Set	Number of rules	Constant (RBFNN)	Linear	Quadratic
Type 1	2	100% (1)	100% (1)	100% (1)
	3	100% (1)	100% (1)	100% (1)
	4	100% (1)	100% (1)	100% (1)
	5	100% (1)	100% (1)	100% (1)
Type 2	2	78.3% (1)	99.3% (1)	99.3% (3)
	3	98.3% (1)	100% (3)	100% (7)
	4	98.3% (1)	99.6% (2)	99.6% (2)
Type 3	2	50.0% (1)	99.0% (7)	99.3% (90)
	3	74.3% (1)	99.3% (3)	99.3% (2)
	4	99.3% (4)	99.3% (1)	99.3% (1)
	5	98.6% (1)	99.0% (345)	99.6% (123)
Type 4	2	97.6% (1)	97.6% (1)	98.0% (20)
	3	95.6% (3)	98.0% (29)	97.6% (2)
	4	98.6% (2)	98.3% (1)	98.6% (2)
	5	96.6% (1)	98.0% (40)	98.0% (29)

그림 3은 각각의 4가지 데이터 집합 중 RBFNN과 본 연구에서 제안한 다항식 기반 RBF 신경회로망의 패턴 인식률의 가장 큰 차이를 보이는 2개 룰일 경우의 Type2와 3개 룰일 경우의 Type3의 데이터 집합의 패턴분류 결과를 보여준다. 룰이 3개인 그림 2-(b)의 경우 데이터의 분포가 그림과 같을 때, 가중치가 상수항만으로 구성된 기존의 RBFNN은 분할곡선 1개로 서 분할되어져 74.3%의 인식률을 보이는 반면, 제안된 다항식 기반 RBF 신경회로망은 같은 수의 룰이지만 분할곡선이 2개가 형성되어 99.3%의 높은 인식률을 보인다.



(a) Type 2



(b) Type 3

〈그림 2〉 RBFNN(Constant)와 다항식 기반 RBF 신경회로망(Quadratic)의 패턴 분류 결과

3. 결 론

본 논문에서는 Fuzzy c-means 클러스터링과 다항식기반의 RBF 신경회로망을 구현하였다. 제안된 다항식기반 RBF 신경회로망의 패턴분류 성능 분석을 위해 4가지 타입의 모의 데이터 집합을 구성하여 실험하였고, 그 결과로서 기존의 RBFNN보다 우수한 성능을 보임을 알 수 있었다. 이와 같은 우수한 패턴 인식률로 미루어 보아, 2-클래스 패턴분류의 문제에 있어 신뢰할만한 분류기로서의 성능을 가짐을 증명하였다. 또한 제안된 다항식기반 RBF 신경회로망은 2-클래스 패턴분류 문제 외에 여러 패턴 인식 분야에서 우수한 성능을 보일 것으로 사료되며 다양한 응용이 기대된다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원의 전력 산업 연구 개발 사업(R-2007-2-044)으로 수행된 과제임.

참고 문헌

- [1] J. Shurmann, Pattern Classification: A Unified View of Statistical and Neural Approaches, Wiley Interscience, New York, 1996.
- [2] U. Kreßel and J. Schurmann, "Pattern classification techniques based on function approximation", in Handbook of Character Recognition and Document Image Analysis, H. Bunke and P.S.P. Wang, Eds. World Scientific, Singapore, pp. 49 - 78, 1997.
- [3] H. Sarimveis, P. Dognanis and A. Alexandridis, "A classification technique based on radial basis function neural networks", Advances in Engineering Software, vol. 37, pp. 218-221, 2006.
- [4] C. Zhang, J. Jiang and M. Kamel, "Intrusion detection using hierarchical neural networks", Pattern Recognition Letters, vol. 26, pp. 779-791, 2005.
- [5] J.C. Bezdek, Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, N. York, 1981
- [6] S.-K. Oh, W. Pderycz and B.-J. Park, "Self-organizing neurofuzzy networks in modeling software data", Fuzzy Sets and Systems, vol. 145, pp. 165-181, 2004.