

다중목적 입자군집 최적화 알고리즘을 이용한 방사형 기저 함수 기반 다항식 신경회로망 구조 설계

김육동*, 오성권**
수원대학교

Structural Design of Radial Basis Function-based Polynomial Neural Networks by Using Multiobjective Particle Swarm Optimization

Wook-Dong Kim*, Sung-Kwun Oh**
The University of Suwon

Abstract - 본 연구에서는 방사형 기저 함수를 이용한 다항식 신경회로망(Polynomial Neural Network) 분류기를 제안한다. 제안된 모델은 PNN을 기본 구조로 하여 1층의 다항식 노드 대신에 다중 출력 형태의 방사형 기저 함수를 사용하여 각 노드가 방사형 기저 함수 신경회로망(RBFNN)을 형성한다. RBFNN의 은닉층에는 fuzzy 클러스터링을 사용하여 입력 데이터의 특성을 고려한 적합도를 사용하였다. 제안된 분류기는 입력변수의 수와 다항식 차수가 모델의 성능을 결정하므로 최적화가 필요하며 본 논문에서는 Multiobjective Particle Swarm Optimization (MoPSO)을 사용하여 모델의 성능뿐만 아니라 모델의 복잡성 및 해석력을 고려하였다. 패턴 분류기로써의 제안된 모델을 평가하기 위해 Iris 데이터를 이용하였다.

그림에서 I는 입력변수의 수를 나타내며, C는 클러스터의 수, P는 다항식 차수를 나타낸다. 제안된 모델에서는 각 노드에 들어가는 입력변수의 수와 클러스터의 수, 그리고 다항식 차수가 각각 다르게 적용된다. 또한 각 노드에 있는 RBFNN은 Fuzzy C-Means (FCM)를 이용하여 은닉층을 구성한다. FCM의 0과1사이로 표현되는 소속행렬은 기존의 퍼지 멤버십 함수나 활성화함수의 적합도로 사용되며 본 논문에서는 은닉층을 FCM을 사용하여 소속행렬을 모델의 적합도로 사용하였다.

각 노드에 들어가는 다항식 형태는 총 4개로 나눌 수 있으며, 표1과 같다.

<표 1> 2입력 일 때의 다항식 형태

Type	Polynomial Type
Constant	$\hat{y} = a_0$
Linear	$\hat{y} = a_0 + a_1x_1 + a_2x_2$
Quadratic	$\hat{y} = a_0 + a_1x_1 + a_2x_2 + a_3x_1^2 + a_4x_2^2 + a_5x_1x_2$
Modified Quadratic	$\hat{y} = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2$

표1은 2입력 일 때의 다항식 형태를 나타낸다. 파라미터 계수(a)는 최소자승법(LSE)을 통해 구한다. 입력이 많아질수록 다항식의 형태는 복잡해지며, 그로인해 연산시간 및 모델의 구조가 복잡해진다. 따라서 성능과 구조를 고려한 적절한 다항식 형태의 선택이 필요하다.

식(1)은 FCM 소속행렬을 구하는 식으로 \mathbf{v} 는 클러스터의 중심점을 나타내며, m은 퍼지화 계수를 나타낸다.

$$u_{ji} = \frac{(1/\|\mathbf{x} - \mathbf{v}_j\|^2)^{1/(m-1)}}{\sum_{j=1}^c (1/\|\mathbf{x} - \mathbf{v}_j\|^2)^{1/(m-1)}} = \frac{1}{\sum_{j=1}^c (d_{ji}/d_{ji})^{2(m-1)}} \quad (1)$$

$$d_{ji} = d(\mathbf{x} - \mathbf{v}) = \|\mathbf{x} - \mathbf{v}\| = \sqrt{\sum_{k=1}^n (x_{ik} - v_{jk})^2} \quad (2)$$

일반적으로 퍼지화 계수는 m=2로 설정하여 소속행렬을 구하지만 제안된 모델에서는 최적화 알고리즘으로 최적의 퍼지화 계수를 찾는다. 퍼지화 계수의 변화는 곧 FCM 알고리즘의 목적함수의 형태를 변화시켜 데이터의 특성을 좀 더 고려한 적합도를 생성한다.

최적화 알고리즘을 이용하여 입력변수의 수 및 다항식 차수, RBFNN의 클러스터 수 및 퍼지화 계수를 동조한다. 최적화 알고리즘으로는 2개 이상의 목적함수를 이용할 수 있는 Multiobjective Particle Swarm Optimization (MoPSO)을 사용하여 모델의 분류율과 더불어 정확성(accuracy) 및 모델의 구조를 최적화 시킨다.

2.2 다중목적 입자군집 최적화 알고리즘

다중목적 입자군집 최적화(MoPSO) 알고리즘은 두 개 이상의 서로 다른 목적함수를 모두 만족하는 해를 찾는 최적화 알고리즘이다. 제안된 모델을 최적화 하는데 있어 사용된 목적함수(Objective Function; O.F)는 식(3)-(5)와 같다.

$$O.F1 = \frac{F}{N} \quad (F: \text{분류실패 횟수}, N: \text{전체 데이터의 수}) \quad (3)$$

$$O.F2 = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (y_i: \text{실제출력}, \hat{y}_i: \text{모델출력}) \quad (4)$$


1. 서 론

패턴인식분야에서 신경회로망을 이용한 연구가 활발히 진행되고 있으며 대표적으로 방사형 기저 함수 신경회로망이 있다. 신경회로망은 멀티출력을 갖기 때문에 클래스를 분류하는데 있어 용이하다. 다항식 신경회로망(Polynomial Neural Networks; PNN)은 여러 층의 다항식 중첩을 통해 추정모델의 정확성을 잘 나타낸다. 특히 각 층마다 입력변수의 수 및 노드의 다항식 차수가 서로 다른 구조를 가지고 있어 데이터의 특성에 맞는 구조로 적응 능력을 향상시킬 수 있다. PNN를 이용한 패턴분류기를 설계하기 위해 본 논문에서는 RBF 신경회로망과 PNN을 결합한 새로운 모델을 제안한다. 또한 데이터의 특성을 효율적으로 반영하기 위해 fuzzy clustering을 사용하며, 파라미터 및 구조 동정을 위해 최적화 알고리즘을 사용하였다.

2. 본 론

2.1 방사형 기저 함수 다항식 신경회로망 구조


제안된 방사형 기저 함수 다항식 신경회로망(Radial Basis Function Polynomial Neural Networks; RBF-PNN)은 그림 1과 같이 구성할 수 있다. 전체적인 모델의 구성은 PNN을 기본 구조로 사용한다. 그리고 각 노드에 RBF 신경회로망이 삽입되어 신경회로망의 출력이 노드의 출력이 되며 이는 다음층의 입력으로 사용된다. 일반적으로 제안된 모델은 2층 이상으로 구성되며 각 층의 모델 성능을 비교하여 최적의 성능을 나타내는 층을 모델의 출력층으로 결정한다. 따라서 데이터의 따라 모델의 층수가 변할 수 있다. 모델의 최종 출력은 출력층에서 가장 성능이 우수한 노드와 연결된 1층과 2층의 노드들을 포함하여 나타낸다.



<그림 1> 방사형 기저 함수 다항식 신경회로망의 구조

$$O.F3 = C + I + NP \quad (NP: \text{파라미터의 계수의 수}) \quad (5)$$

첫 번째 목적함수는 분류 실패율을 나타내며, 두 번째 목적함수는 실제 클래스와 모델의 클래스 사이의 오차를 나타낸다. 마지막으로 세 번째는 입력변수의 수와 클러스터의 수 그리고 다항식의 파라미터 계수를 합하여 모델의 복잡성을 나타낸다. 일반적으로 하나의 목적함수를 사용하게 되면 모델의 성능과 구조를 모두 만족하기 어렵다. 하지만 다중 목적함수를 사용함으로써 모델의 성능뿐만 아니라 구조도 고려한 최적의 모델을 구성할 수 있다.



〈그림 2〉 MoPSO 알고리즘 순서도

2.4 실험결과 및 고찰


제안된 모델의 성능을 평가하기 위해 패턴분류에서 많이 사용되는 Iris dataset을 사용하였다. Iris는 총 4입력 3클래스로 Iris라는 꽃을 3종류로 나눈 데이터이다. 실험결과는 5 fold cross-validation을 사용하여 평균 패턴 분류율로 나타내었다. 최적화를 위해 PSO의 세대 수(generation)는 60번으로 설정하였으며, 개체 수(population)은 30개로 정하였다.

〈표 2〉 Iris 데이터의 실험결과


Layer	TR	TE	TR_A	TE_A
1	98.00 ± 1.62	95.33 ± 1.83	0.0278 ± 0.013	0.0389 ± 0.00
2	100.00 ± 0.00	98.00 ± 1.83	0.0021 ± 0.001	0.0287 ± 0.015
3	100.00 ± 0.00	94.00 ± 4.35	0.0010 ± 0.001	0.0478 ± 0.017

표 2는 각 층에서의 패턴분류율 및 정확성을 나타낸다. TR은 학습데이터의 분류율이며, TE는 테스트 데이터의 분류율을 나타낸다. 또한 TR_A와 TE_A는 출력의 정확성(accuracy)를 보여준다. Iris data의 경우 학습 데이터는 2층 이후부터 100%의 인식률을 보인다. 하지만 테스트 데이터의 결과를 놓고 보면 2층에서 가장 좋은 성능을 나타낸다. 따라서 실제 모델을 구성할 때 2층으로 최종 모델을 설계한다.


그림 3에서 보면 각 층에서 보이는 solutions의 분포가 3개의 목적함수가 최소화 되는 위치로 이동함을 알 수 있다. 실험결과는 이런 solutions 중에서 3개의 목적함수의 합이 최소가 되는 solutions을 선택하여 평균으로 나타내었으며, 표 2와 같다.



(a) 1층에서의 solutions



(b) 2층에서의 solutions



(c) 3층에서의 solutions

〈그림 3〉 각 층에서의 solutions 분포

표3은 기존 분류기와 성능을 비교하였으며, 기존 분류기와 비교하여 성능이 HFNB를 제외하고는 우수함을 알 수 있다.

〈표 3〉 기존 분류기와 성능비교

Models	Classification Rate [%]	
C4.5	94.0	
FID 3.1	96.0	
NEFCLASS	96.0	
HFNB	98.7	
Proposed model	2nd Layer	98.0
	3rd Layer	94.0

3. 결 론

본 논문은 다항식 신경회로망에 방사형 기저 함수를 결합한 방사형 기저 함수 다항식 신경회로망 분류기를 제안하였으며, 모델의 성능 및 구조를 최적화시키기 위해 다중목적 입자 군집 최적화 알고리즘을 사용하였다. 세 개의 목적함수를 이용하여 모델의 구조를 최소화시키면서도 모델의 성능은 기존모델과 비슷하게 나타난다.

감사의 글

이 논문은 2010년도 정부(과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2010-D00065) 그리고 2009년도 지식경제부의 재원으로 한국에너지 기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(2009T100100563)

[참 고 문 헌]

- [1] S. K. oh, W. Pedrycz, B. J. Park "Polynomial Neural Networks Architecture: Analysis and Design," Computers&Electrical Eng., Vol. 29, pp. 703-725, 2003.
- [2] S. K. oh, W. Pedrycz, S. B. Roh, "Hybrid Fuzzy Set-based Polynomial Neural Networks and Their Development with the Aid of Genetic Optimizaion and Information Granulation," Applied Soft Computing, Vol. 9, pp. 1068-1089, 2009.
- [3] C.R. Raquel and P.C. Naval Jr, "An effective use of crowding distance in multiobjective particle swarm optimization," Proc. Genetic and Evol. Comput. (GECCO 2005), pp. 257-264, 2005.