

## 차분 진화알고리즘 기반 다중 출력 방사형 기저 함수 다항식 신경 회로망 구조 설계

김죽동\*, 마창민\*\*, 오성권\*\*\*  
수원대학교\*

### Structural Design of Differential Evolution-based Multi Output Radial Basis Function Polynomial Neural Networks

Wook-Dong Kim\*, Chang-Min Ma\*\*, and Sung-Kwon Oh  
The University of Suwon\*

**Abstract** - 본 연구에서는 패턴분류를 위해 기존의 방사형 기저 함수 신경회로망(Radial Basis Function Neural Network)과 다항식 신경회로망(Polynomial Neural Network)을 결합한 다중 출력 방사형 기저 함수 다항식 신경회로망(Multi Output Radial Basis Function Polynomial Neural Network)의 분류기를 제안한다. 제안된 모델은 PNN을 기본 구조로 하여 1층에 기존의 다항식 노드 대신 다중 출력 형태의 RBFNN을 적용한다. RBFNN의 은닉층에는 기존의 활성함수가 아닌 fuzzy 클러스터링을 사용하여 입력 데이터의 특성을 고려한 적합도를 사용하였다. PNN은 입력변수의 수와 다항식 차수가 모델의 성능을 결정함으로 최적화가 필요하며 본 논문에서는 Differential Evolution(DE)을 사용하여 모델의 구조 및 파라미터를 최적화시켜 모델의 성능을 향상시켰다. 패턴분류기로써의 제안된 모델을 평가하기 위해 pima 데이터를 이용하였다.

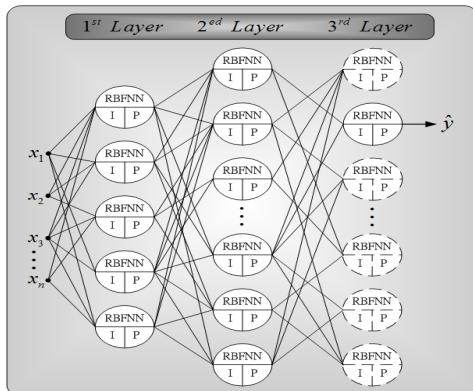
#### 1. 서 론

다항식 신경 회로망 (Polynomial Neural Network; PNN)은 다수 층의 다항식 중첩을 통하여 추정모델의 정확성을 잘 나타낸다. 특히 각 입력 변수의 수 및 노드의 다항식 차수가 서로 다른 구조를 가지고 있어서 데이터의 특성에 맞는 구조로 적용 능력을 향상시킬 수 있다. 패턴분류 분야에서 많이 사용되는 모델중 하나로 방사형 기저 함수 신경회로망(Radial Basis Function Neural Network; RBFNN)이 대표적이다. PNN을 이용한 패턴분류기를 설계하기 위해 본 논문에서는 RBF 신경회로망과 PNN을 결합한 다중 출력 방사형 기저 함수 다항식 신경회로망(Multi Output Radial Basis Function Polynomial Neural Network) 모델을 제안한다. 또한 데이터의 특성을 효율적으로 반영하기 위해 fuzzy clustering을 사용하며, PNN의 파라미터 및 구조 동정을 위해 차분 진화(Differential Evolution; DE) 최적화 알고리즘을 사용하였다.

#### 2. 본 론

##### 2.1 다중 출력 방사형 기저 함수 다항식 신경회로망

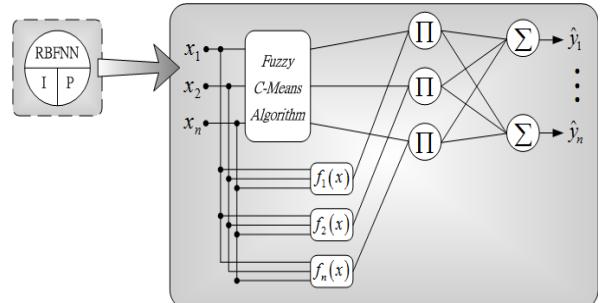
제안된 다중 출력 방사형 기저 함수 다항식 신경회로망(Multi Output Radial Basis Function Polynomial Neural Network; MORBFNN)은 그림 1과 같은 구조로 구성되어 있다. 모델은 총 3층으로 구성되어 있고 3층에서 가장 성능이 우수한 노드를 모델의 최종출력으로 하며, 최종 출력식은 3층의 선택된 노드와 연결되어 있는 1층과 2층의 노드들을 포함하여 나타낸다.



〈그림 1〉 다중 출력 방사형 기저 함수 다항식 신경 회로망의 구조

그림에서 I는 입력변수의 수를 나타내며, P는 다항식 차수를 나타낸

다. 제안된 모델에서는 각 노드에 들어가는 입력변수의 수와 다항식의 차수가 다르다. 또한 각 노드에 있는 RBFNN은 Fuzzy C-Means Algorithm (FCM)을 이용하여 은닉층을 구성한다. FCM의 목적함수는 방사형 기저 함수 형태를 갖고 있기 때문에 은닉층을 하나의 FCM 알고리즘으로 해석할 수 있다. 그리고 FCM의 클러스터 수가 은닉층의 노드 수가 되며, 페지화 계수를 변화시켜 방사형 기저 함수의 형태를 조절할 수 있다. 또한 제안된 모델의 RBFNN의 출력층은 단일 출력이 아닌 다중출력의 형태로 구성되어 있다.



〈그림 2〉 각 노드의 다중 출력 RBFNN 구조

PNN의 입력변수의 수 및 다항식 차수, RBFNN의 클러스터 수 및 페지화 계수를 Differential Evolution(DE)을 이용하여 최적화 시킨다. 표 1은 4종류의 다항식 차수를 나타낸다.

〈표 1〉 다항식 차수 (입력이 2개일 경우)

Type	Polynomial Type
Constant	$\hat{y} = a_0$
Linear	$\hat{y} = a_0 + a_1 x_1 + a_2 x_2$
Quadratic	$\hat{y} = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1^2 + a_4 x_2^2 + a_5 x_1 x_2$
Modified Quadratic	$\hat{y} = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1 x_2$

##### 2.2 차분 진화(DE) 알고리즘을 이용한 최적화 방법

차분 진화(Differential Evolution; DE) 알고리즘은 Price와 Storn에 의해 벡터 차분을 사용하여 Chebychev 다항곡선의 내삽문제를 해결하는 과정에서 개발되었다. DE는 간단한 구조를 갖으면서도 전역 최적해에 대한 수렴성이 뛰어나고 다른 진화 알고리즘들에 비해서 컴퓨팅 시간이 짧은 장점을 지닌다. DE는 해집단 기반의 병렬탐색을 수행하며 다른 진화 알고리즘과는 달리 차분 진화는 확률분포에 기반한 변이이산자(mutation operator)에 의존하지 않는다. 차분진화에서 사용되는 연산자는 주로 임의로 선택된 개체들 사이의 차이를 사용한다.

DE를 이용하여 제안된 모델의 입력변수의 수와 다항식의 차수, 클러스터의 수 및 페지화 계수를 최적화 시킨다. 최적화를 위해 필요한 개체의 구조는 그림 3과 같이 나타낼 수 있다.

Particle :	입력변수 수	다항식 차수	클러스터 수	페지화 계수
Range :	[2~Total Input]	[1~4]	[2~5]	[1.1~3]

〈그림 3〉 차분 진화 알고리즘의 개체 구조

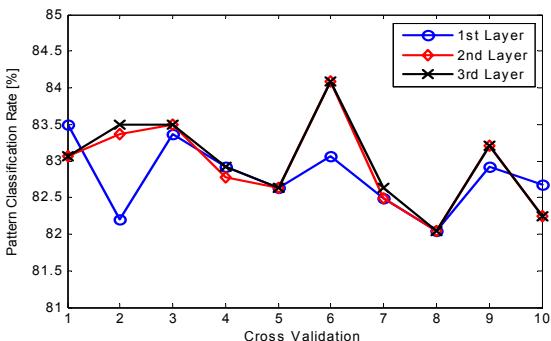
총 4개의 파라미터를 최적화 시키며 입력변수의 경우 2개부터 주어진 데이터의 최대 입력개수 안에서 선택된다. 다항식 타입은 표 1과 같이 4개의 타입 중에서 선택되고 클러스터의 수는 2개에서 5개 사이로 설정하였다.

### 3. 결 론

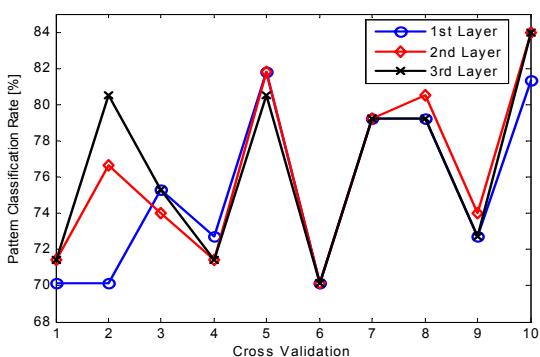
제안된 모델의 성능을 평가하기 위해 패턴분류에서 많이 사용되는 Pima Data Set을 사용하였다. Pima Data Set는 당뇨병이 많이 발생하는 Pima족 인디언인의 당뇨병 여부를 조사한 데이터로 총 8입력 2클래스로 구성되어 있다. 실험결과는 10 fold cross-validation을 사용하여 평균 패턴분류율로 나타내었다. 최적화를 위한 DE의 파라미터 및 탐색범위는 표 2와 같다.

<표 2> DE 파라미터 및 탐색범위

Parameters		Value
Number of generations	60	
Number of population	30	
Crossover rate	1	
F	0.5	
The range of search space	Number of input variable	[2~Total Input]
	Polynomial Type	[1~4]
	Number of clusters	[2~5]
	Fuzzification coefficient	[1.1~3]



<그림 4> 학습 데이터의 패턴분류

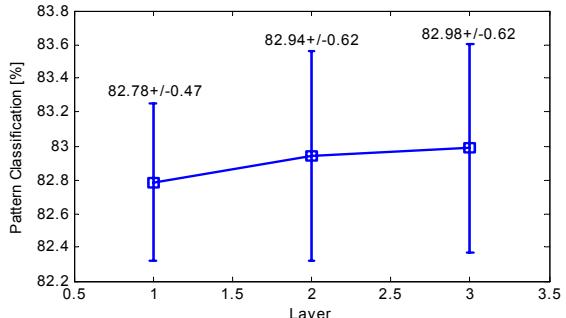


<그림 5> 테스트 데이터의 패턴분류

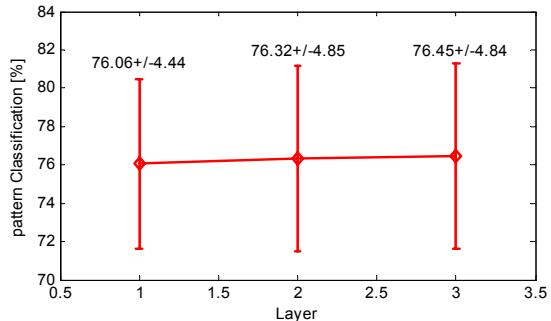
그림 4와 그림 5는 pima dataset의 10fcv의 각각의 성능을 나타낸 그림이다. 학습 데이터와 테스트 데이터 모두 2층과 3층의 분류률이 비교적 차이가 많이 나진 않지만 평균적으로 보면 3층의 분류률이 2층보다 높게 나타나는 것을 볼 수 있다.

그림 6과 그림 7은 그림 4와 그림 5에 나타나는 결과를 각 충별 10fcv의 평균과 표준편차를 나타낸 그림이다. 그림에서 볼 수 있듯이 학

습 데이터와 테스트 데이터 모두 3층에서 가장 높은 분류률을 갖는 것을 알 수 있다.



<그림 6> 학습 데이터의 평균과 표준편차



<그림 7> 테스트 데이터의 평균과 표준편차

<표 3> 기존 분류기의 평균 성능 비교

Classifier model	Classification Rate [%]
SVM	74.72
RVM	74.83
MLP	73.10
Proposed model	76.45

표 3은 본 논문에서 제안한 분류기의 테스트 데이터의 패턴 분류률을 기존의 패턴 분류기들과 비교하여 나타내었다. 제안된 분류기의 성능은 76.45%로 성능이 뛰어나진 않지만 기존의 패턴 분류기를 보다 성능이 우수함을 알 수 있다.

### 감사의 글

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2009-0074928) 그리고 본 연구는 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 Optimizaiton and Information Granulation," Applied Soft Computing, Vol. 9, pp. 1068-1089, 2009.
- [3] S. K. Oh, W. Pedrycz, B. J. Park, "Polynomial-based Radial Basis Function Neural Networks realized with the Aid of Particle Swarm Optimization," Fuzzy Sets and Systems, Vol. 163, pp. 54-77, 2011.
- [4] R. Storn, K. V. Price, "Differential Evolution-a fast and efficient heuristic for global optimization over continuous spaces", Journal of Global Optimization, vol. 11, pp. 341-359, 1997.