

정보 입사화를 통한 방사형 기저 함수 기반 다항식 신경 회로망의 진화론적 설계

논 문
60-4-29

Evolutionary Design of Radial Basis Function-based Polynomial Neural Network with the aid of Information Granulation

박 호 성* · 진 용 하** · 오 성 권†
(Ho-Sung Park · Yong-Ha Jin · Sung-Kwun Oh)

Abstract - In this paper, we introduce a new topology of Radial Basis Function-based Polynomial Neural Networks (RPNN) that is based on a genetically optimized multi-layer perceptron with Radial Polynomial Neurons (RPNs). This study offers a comprehensive design methodology involving mechanisms of optimization algorithms, especially Fuzzy C-Means (FCM) clustering method and Particle Swarm Optimization (PSO) algorithms. In contrast to the typical architectures encountered in Polynomial Neural Networks (PNNs), our main objective is to develop a design strategy of RPNNs as follows : (a) The architecture of the proposed network consists of Radial Polynomial Neurons (RPNs). In here, the RPN is fully reflective of the structure encountered in numeric data which are granulated with the aid of Fuzzy C-Means (FCM) clustering method. The RPN dwells on the concepts of a collection of radial basis function and the function-based nonlinear (polynomial) processing. (b) The PSO-based design procedure being applied at each layer of RPNN leads to the selection of preferred nodes of the network (RPNs) whose local characteristics (such as the number of input variables, a collection of the specific subset of input variables, the order of the polynomial, and the number of clusters as well as a fuzzification coefficient in the FCM clustering) can be easily adjusted. The performance of the RPNN is quantified through the experimentation where we use a number of modeling benchmarks - NOx emission process data of gas turbine power plant and learning machine data(Automobile Miles Per Gallon Data) already experimented with in fuzzy or neurofuzzy modeling. A comparative analysis reveals that the proposed RPNN exhibits higher accuracy and superb predictive capability in comparison to some previous models available in the literature.

Key Words : Radial basis function neural network, Polynomial neural network, Fuzzy C-means clustering method, Radial polynomial neuron, Particle swarm optimization, Information granulation

1. 서 론

최근 들어, 계산적 지능(Computational Intelligence: CI)의 합성을 통한 지능형 시스템의 점진적인 성장은 다양한 과학 및 공학 분야에 매우 흥미 있는 관심을 가지고 있다. 이와 같은 연구들은 CI 기술의 합성을 통한 진보된 시스템의 성능이 시스템의 복잡성이 큰 문제를 분석하는데 있어서 독립적인 지능형 시스템보다 우수한 성능을 가짐으로써 더 활발히 진행되어져 오고 있는 실정이다. CI 기술 중에서 중요한 연구 분야중의 하나로 자리매김하고 있는 RBFNN은 뉴로 컴퓨팅분야에서 많은 관심과 더불어 이에 대한 다수의 비교적인 연구와 다양한 적용이 이루어지고 있다. 방사형 기저 함수들로 이루어져 있는 RBFNN의 일반적인 구조는 다음과 같이 몇 개의 주요한 개발 방향과 설계 전략을 가지고 있다. (i) FCM 클러스터링 방법과 같이 표현되어지는 다양한

클러스터링 기법을 사용을 통해 전형적인 형태의 기저 함수로써 가우시안 함수를 이용하는 대신 대안적인 방법으로 처리하는 방법도 널리 사용되어지고 있으며[7-8], (ii) 은닉층에서의 파라미터뿐만 아니라 네트워크의 출력층에서 위치한 선형 뉴런들의 파라미터들의 추정하기 위하여 경사 하강법뿐만 아니라 진화론적 최적화를 포함한 전역 극소 기법들이 시도되었다[9-10].

이에 본 논문에서는 CI 기술들의 합성 즉, 방사형 기저 함수 신경 회로망(Radial Basis Function Neural Network: RBFNN)[5,6,9], 다항식 신경 회로망(Polynomial Neural Network: PNN)[12-13], Fuzzy C-Means (FCM) 클러스터링[11], 그리고 입자 군집 최적화(Particle Swarm Optimization: PSO) 알고리즘[14-15]을 이용하여 시스템이 복잡하고 대규모의 구조를 가지는 비선형 실 시스템의 동적 분석을 표현하고자 한다. 기존의 다항식 신경 회로망을 구축하는데 주요한 역할을 하는 다항식 노드(Polynomial Neuron: PN)를 간단한 형태의 구조와 일반적인 근사화 능력의 장점을 가진 RBFNN 형태의 방사형 다항식 노드(Radial Polynomial Neuron: RPN)으로 대체함으로써 효율적으로 모델의 근사화 및 일반화 능력을 개선하고, 방사형 다항식 노드(RPN)을 구성하고 있는 RBFNN에서의 노드를 일반적인 가우시안 함수를 사용하는 대신 FCM 클러스터링

* 정 회 원 : 수원대 산업기술연구소 연구교수 · 공박

** 준 회 원 : 수원대 전기공학과 석사과정

† 교신저자, 시니어회원 : 수원대 공대 전기공학과 교수 · 공박

E-mail : ohsk@suwon.ac.kr

접수일자 : 2010년 4월 16일

최종완료 : 2011년 1월 12일

방법을 이용함으로써 실험적 예제에서 사용된 데이터들의 정보 입자화를 효율적으로 처리하고자 한다.

제안된 RPNN의 최적화를 위하여 간결하고 수렴이 빠른 장점을 가진 입자 군집 최적화(Particle Swarm Optimization: PSO) 알고리즘[14]을 이용하여 제안된 RPNN을 구축하는 RPN의 성능을 향상시키는데 크게 영향을 미치는 파라미터들(-입력 변수의 수, 선택된 입력 변수, 후반부 다항식 차수, RPN를 구성하고 있는 RBFNN의 노드의 수(FCM 클러스터의 수와 동일), 그리고 FCM 클러스터링의 퍼지화 계수)을 탐색하여 모델 구축에 있어서 유연성과 정확성을 가지며 객관적이고 좀 더 정확한 예측 능력을 가진 RPNN 모델을 구축하고자 한다.

2. 방사형 기저 함수 기반 다항식 신경 회로망의 구조 및 형태

RPN은 RPNN의 가장 기본이 되는 처리 단위의 일반적인 형태로써, 방사형 기저 함수 (RBF)과 함수 기반 다항식 처리의 개념에 기초해서 자세히 설명된다. 그림 1에서 보인 것처럼 RPN은 다음과 같이 2개의 기본적인 기능 모듈로 구성되어 있다.

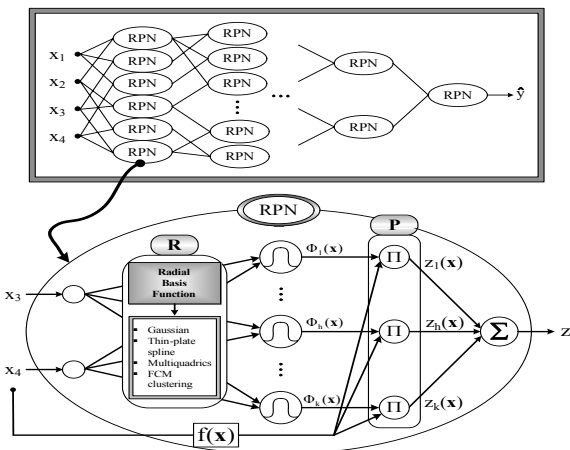


그림 1 RPN 모듈의 일반적인 구조 (R : 방사형 기저 함수 처리 부분, P : 선형 변환의 다항식 형태)

Fig. 1 A general topology of the generic RPN module (R : Radial Basis Function-based processing part, P : the polynomial form of mapping)

그림 1에서 보이듯이, RPN은 방사형 기저 함수 신경 회로망(Radial Basis Function Neural Network: RBFNN)의 형태로 이루고 있는 다중입력 단일출력(Multi-Input Single-Output: MISO)의 모델 구조를 가지고 있으며, 다음과 같은 형태를 가지고 있다.

만일 방사형 기저 함수로써 가우시안 함수 (Gaussian Function)가 사용되었다면, 가우시안 함수를 통해서 생성된 $\Phi_1(\mathbf{x})$ 는 다음과 같은 형태를 이룬다.

$$\Phi_1(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{v}_1\|^2}{2r_1^2}\right) \quad (1)$$

(여기서, \mathbf{v}_i 와 r_i 는 i 번째 노드의 가우시안 함수의 중심값과 폭을 의미한다.)

그림 1에서 보여준 후반부 다항식 $f(\mathbf{x})$ 는 다음 표 1에서 보여준 것과 같이 4가지 형태의 다항식 구조를 가진다.

표 1 RPN에서 회귀다항식의 서로 다른 형태.
Table 1 Different forms of the regression polynomials building a RPN.

Order	Type	Polynomial equation
0	Type 1	Constant
1	Type 2	Linear
2	Type 3	Quadratic
	Type 4	Modified quadratic

그림 1에서 보여준, 두 번째 모듈 “P”에 의해서 처리된 각각의 코결 모델들의 출력은 식 (1)과 표 1에서 나타낸 후반부 회귀 다항식의 형태에 따라서 다음과 같이 나타낸다.

$$z_k(\mathbf{x}) = \Phi_k(\mathbf{x})f_k(\mathbf{x}) \quad (2)$$

RPN 노드의 최종 네트워크의 출력 $z(\mathbf{x})$ 는 각각의 활성화 레벨의 선형 조합으로써 다음과 같이 계산된다.

$$z(\mathbf{x}) = \sum_{i=1}^K z_i(\mathbf{x}) = \sum_{i=1}^K \Phi_i(\mathbf{x})f_i(\mathbf{x}) \quad (3)$$

(여기서, $z(\mathbf{x})$ 는 현재 층에서의 RPN 노드의 출력인과 동시에 다음 층에서 RPN의 입력과 같은 역할을 한다).

3. 방사형 기저 함수 기반 다항식 신경 회로망의 최적화

RPN 노드의 성능 향상에 주요한 역할을 하는 파라미터들(-RPN 노드로 들어가는 입력 변수의 수, 전체 입력 변수 중에서 RPN 노드를 구성하는 입력 변수, RPN 노드에서의 후반부 다항식 차수, RPN을 구성하고 있는 RBFNN의 노드의 수(즉, FCM 클러스터링에서 클러스터의 수) 그리고 FCM 클러스터링 방법의 퍼지화 계수)의 최적화를 위하여 입자 군집 최적화 (Particle Swarm Optimization: PSO) 알고리즘을 적용한 방사형 기저 함수 기반 다항식 신경 회로망의 최적화에 대해서 알아본다.

그림 2는 제안한 RPNN 모델을 최적화하기 위하여 RPN에 적용한 FCM 클러스터링 방법과 입자 군집 최적화 알고리즘을 통한 최적화 과정을 간단하게 나타낸 것이다.

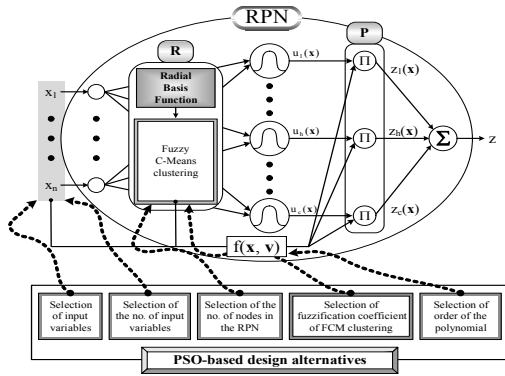


그림 2 FCM과 PSO에 의한 RPN의 최적화 설계
 Fig. 2 Optimized design of RPN by means of FCM and PSO

Fuzzy C-Means clustering (FCM) 방법에 대해서 초점을 맞춘다. FCM 클러스터링 방법은 일반적으로 클러스터링 방법 중의 하나로서 데이터 전처리에 넓게 사용되어지고 있으며, 주어진 데이터의 특징을 해석하여 파악된 데이터의 정보를 기반으로 입력 데이터를 분할함으로써 기존의 데이터 전처리 방법들보다 더 효율적이고 유기적으로 주어진 데이터의 특징을 파악하는 장점을 가지고 있다.

U라 표시되는 partition matrix를 구하기 위한 FCM 클러스터링 방법의 알고리즘은 다음과 같다.

[단계 1] 클러스터의 개수를 결정하고, 소속행렬 $U^{(r)}$ 를 다음과 같이 초기화한다.

$$U^{(r)} = \left\{ u_{ik} \in [0,1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^N u_{ik} < N \forall i \right\} \quad (4)$$

[단계 2] [단계 1]로부터 얻어진 u_{ik} 값을 기반으로 각각의 클러스터에 대한 중심값과 소속 함수의 값을 구한다.

$$v_i^{(r)} = \{v_{i1}^{(r)}, \dots, v_{ic}^{(r)}\}, v_{ij}^{(r)} = \left(\frac{\sum_{k=1}^N (u_{ik})^m \cdot x}{\sum_{k=1}^N (u_{ik})^m} \right) \quad (5)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_i^{(r)}\|}{\|x_k - v_j^{(r)}\|} \right)^{2/(m-1)}} \quad (6)$$

(여기서, $m > 1$ 은 퍼지화 계수를 나타내고, $v_i^{(r)}$ 는 입력 변수들의 중심값을 의미한다. 본 논문에서는 퍼지화 계수(m)를 PSO 알고리즘을 이용하여 1.8~3.1 범위에서 최적으로 선택하여 모델에 적용하였다.)

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬을 생성한다.

$$d_{ik} = d(x_k - v_i^{(r)}) = \left[\sum_{l=1}^n (x_{kl} - v_{il}^{(r)})^2 \right]^{1/2} \quad (7)$$

[단계 4] 만일 식 (8)을 만족한다면 종료하고, 그렇지 않으면 $r=r+1$ 로 놓고 [단계 2]로 간다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon (\text{tolerance level}) \quad (8)$$

식 (6)에서 생성된 partition matrix가 그림 1과 그림 2에서 보인 RPN 노드 내부의 방사형 기저 함수의 출력값을 나타낸다.

다음 식 (9)는 2입력(x_1, x_2), 1차 선형식이 선택되어졌을 때의 방사형 기저 함수에서 i 번째 노드에서 정보 입자화를 통한 후반부 다항식의 일반적인 형태를 나타낸 것이다.

$$z_i(x) = u_i(x) f_i(x, v) = u_i(x) \{a_{i0}x_0 + a_{i1}(x_1 - v_{i1}) + a_{i2}(x_2 - v_{i2})\} \quad (9)$$

(여기서, x_0 는 1의 값을 가진다)

4. 진화론적 최적 방사형 기저 함수 기반 다항식 신경 회로망 알고리즘과 설계

본 논문에서 제안한 정보 입자화와 PSO [14]에 기반한 진화론적 최적 방사형 기저 함수 기반 다항식 신경 회로망 알고리즘과 설계 방법은 다음과 같다.

[단계 1] 시스템 입력변수의 결정

출력변수 y 에 관계하는 n 개의 시스템 입력변수를 결정한다. 필요하면 데이터를 정규화한다. 이 시스템 입력변수를 x_1, x_2, \dots, x_n 이라 한다.

[단계 2] 데이터 분할

N 개의 입출력 데이터 $(x_i, y_i) = (x_{1i}, x_{2i}, \dots, x_{ni}, y_i), i=1, 2, \dots, N$ 을 효율적인 모델링을 위해서 다음과 같이 2가지 형태로 데이터를 분할한다.

- Case 1 : 전체 데이터를 학습용 데이터(N_{PI})와 테스트용 데이터(N_{EPI})로 분할한다. 학습용 데이터는 모델을 동정하기 위해 사용하는 데이터이고, 테스트용 데이터는 모델을 테스트하기 위해 사용하는 데이터이다. 여기서, $N = N_{PI} + N_{EPI}$ 이다.
- Case 2 : 비선형성이 강한 데이터들은 모델에 대한 구체적인 성능을 평가하기 위해서 전체 데이터를 학습용 데이터(N_{PI}), 평가용 데이터(N_{VPI}), 그리고 테스트용 데이터(N_{EPI})로 분할한다. 학습용 데이터는 모델을 동정하기 위해 사용하는 데이터이고, 평가용 데이터와 테스트용 데이터는 모델을 테스트하기 위해 사용하는 데이터이다. 여기서, $N = N_{PI} + N_{VPI} + N_{EPI}$ 이다.

[단계 3] RPNN 구조 정보 결정

RPNN 구조를 구축하는 있어서 기본적인 정보를 결정한다. 즉, RPNN의 a)종료조건 선택-최적 노드의 적합도 값 비교 또는 최대 층 수 결정, b)노드에 입력될 최대 입력변수의 수 결정, c)하나의 층에서 생성될 노드의 수 결정 그리고 d)목적함수의 하중계수 값을 결정한다.

[단계 4] PSO 알고리즘을 이용한 RPNN 구조 결정

PSO 알고리즘을 이용하여 RPNN을 구성하고 있는 RPNN의 구조 결정에 주요한 역할을 하는 파라미터들(-입력변수, 입력변수의 수, 후반부 다항식 차수, RPNN을 구성하는 노드

들의 수, 그리고 방사형 기저 함수로써 사용된 FCM 클러스터링의 퍼지화 계수)을 결정한다. 그림 3은 PSO 알고리즘에서 각각의 particle에 의해서 최적의 RPN 구축을 나타낸다. 이와 같이 생성된 RPN들의 구성을 통해서 RPNN은 주어진 시스템 환경의 변화에 적용할 수 있는 유연성을 가진 모델을 구축할 수가 있다. 그림 3에서 최종적인 결정된 RPN은 RPNN 모델의 각 층에서 각 노드에 해당되는 것이다.

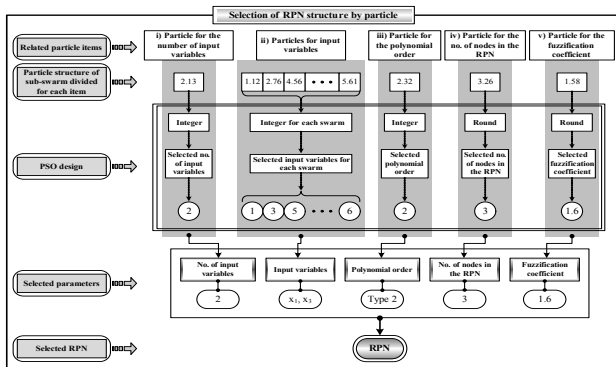


그림 3 PSO의 particle를 이용한 RPNN 구조에서 이용할 수 있는 RPN 설계

Fig. 3 The RPN design available in RPNN architecture by using a particle of PSO

기존의 PNN 구조는 하나의 층에서 모든 노드가 정해진 입력변수 수, 다항식 차수를 가지고 있고 입력변수는 입력변수 수의 조합으로 이루어졌지만, 본 논문에서 제안한 알고리즘은 PSO 알고리즘을 통해 최적화된 각각의 노드들의 조합을 통해서 모델의 최적화를 이룰 수 있는 장점을 가지고 있다.

그림 3에서는 PSO를 이용하여 노드의 구조를 설계하는 과정을 보여주며 세부적인 알고리즘은 다음과 같다.

[단계 4-1] 입력변수의 수 선택

주어진 전체 swarm 중 첫 번째 swarm을 입력변수의 수를 선택하는 swarm으로 설정한다. 여기서 첫 번째 swarm의 범위는 2와 n 사이의 실수로 설정된다. 정수화된 값이 하나의 노드를 구축하는 입력변수의 수로 선택되어진다. 그림 3에서는 2개의 입력변수의 수가 선택되어짐을 알 수 있다. 선택된 입력변수의 수는 $2 \leq l \leq n$ 사이의 정수화된 수로 설정된다. 여기서, l은 선택되어진 입력 변수의 수이다.

[단계 4-2] 입력변수 선택

전체 swarm 중 두 번째 swarm부터 (n+1)번째 swarm까지를 입력변수 선택을 위한 swarm으로 사용한다. 여기서 각각의 swarm 범위는 1과 n 사이로 설정된다. 첫 번째 swarm에서 선택되어진 값부터 [단계 4-1]에서 선택되어진 입력변수의 수만큼의 swarm값들을 RPN 노드를 구성할 때 노드의 입력변수로 선택된다. 그림 3에서는 첫 번째 입력변수(x1)와 세 번째 입력변수(x3)가 선택되어짐을 알 수 있다. 만약 선택된 입력변수가 중복된다면 중복된 입력변수가 서로 다른 입력변수가 나올 때까지 랜덤하게 다시 설정한다.

[단계 4-3] 후반부 다항식 차수 선택

전체 swarm중에서 (n+2)번째 swarm을 후반부 다항식 차수 선택을 위한 swarm으로 설정한다. 여기서 후반부 다항식 차수를 위한 swarm의 범위는 1과 4 사이로 설정한다. 정수화된 값이 하나의 노드를 구축하는 후반부 다항식을 위한 Type으로 선택되어진다.

[단계 4-4] RPN안에서의 노드의 수 선택

전체 swarm중에서 (n+3)번째 swarm을 RPN 안에서 생성된 노드의 수 선택을 위한 swarm으로 설정한다. 여기서 노드의 수를 위한 swarm의 범위는 2와 10 사이로 설정한다. 정수화된 값이 하나의 RPN을 구축하는 노드의 수로 선택되어진다. 그림 3에서는 3개의 노드의 수가 선택되어짐을 알 수 있다. 즉, FCM 클러스터링에 의해서 선택되어진 입력들(x1, x3)을 3개의 클러스터로 분할되어져 하나의 RPN을 구성하게 된다.

[단계 4-5] 퍼지화 계수 선택

전체 swarm중에서 마지막 swarm을 FCM 클러스터링에서의 퍼지화 계수 선택을 위한 swarm으로 설정한다. 여기서 퍼지화 계수를 위한 swarm의 범위는 1.8과 3.1 사이로 설정한다.




그림 4 제안된 모델에서 각 RPN의 형태

Fig. 4 Formation of each RPN in the proposed model architecture

제안된 모델의 각 층을 구성하고 있는 RPN은 그림 4와 같이 나타낼 수 있다. 'RPNn'은 각각의 층에서 대응하는 n 번째 노드를 나타내고, 'N'은 각 RPN 노드에 들어오는 입력의 수를, 'T'는 대응되는 RPN 노드 후반부에 사용되는 다항식 차수를, 'c'는 RPN 노드를 구성하는 클러스터의 수를, 그리고 'm'은 RPN 노드에서 사용되는 FCM 클러스터링의 퍼지화 계수를 나타낸다.

[단계 5] 모델의 구축과 테스트 그리고 노드의 선택

기존의 PNN에서는 모델의 구축은 앞에서 설명하였듯이 일반적인 설계방법이었으나 본 논문에서는 그림 3과 4에 보인 것과 같이 FCM 클러스터링 방법과 PSO 알고리즘을 이용하여 모델의 최적화에 맞게 각 노드들을 유연하게 구축할 수 있다.

[단계 5-1] PSO기반 RPNN 모델의 최적화 모델 구축을 위한 세대 수, Swarm 수, 가속상수(acceleration constant), 관성하중(inertia weight) 등의 초기 정보를 설정한다.

[단계 5-2] 최적화하고자하는 값들을 위해 velocity의 최대 값을 구하고 임의의 숫자로 swarm을 생성하고 velocity 최

대값을 이용하여 임의의 숫자로 velocity를 구하여 초기값을 설정한다.

[단계 5-3] Swarm에 의해서 생성된 노드의 성능 테스트를 위해서 본 논문에서는 모델의 근사화와 일반화 능력 사이의 합리적 균형을 얻기 위해 [단계 2]에서 분할된 데이터 형식에 따라 식 (10)과 식 (11)와 같은 하중값을 가진 목적함수를 이용하여 생성된 노드를 평가한다.

• Case 1인 경우

$$F(\text{Fitness Function}) = \theta \times \text{PI} + (1 - \theta) \text{EPI} \quad (10)$$

• Case 2인 경우

$$F(\text{Fitness Function}) = \theta \times \text{PI} + (1 - \theta) \text{VPI} \quad (11)$$

여기서, 식 (10)에서 PI는 학습 데이터에 대한 성능지수, EPI는 테스트 데이터에 대한 성능지수를 의미하고 식 (11)에서 VPI는 평가용 데이터에 대한 성능지수를 의미한다.

[단계 5-4] 다음 세대의 생성을 위해서 구해진 성능지수가 가장 뛰어난 swarm을 'pbest'으로 설정하고 성능지수가 가장 뛰어난 particle을 'gbest' 설정한다. 그리고 이들 값을 사용하여 particle velocity를 구한다.

[단계 5-5] 이전 세대에서 사용했던 swarm에 particle velocity값을 더하여 새로운 swarm을 생성한다.

[단계 5-6] 각 swarm의 particle을 생성할 때 입력변수와 같은 중복을 피해야하는 particle은 중복된 값만 따로 중복을 피하기 위해 중복되지 않는 값을 넣어준다.

[단계 5-7] 중복된 적합도 값들을 하나로 처리한 후 설계자가 PNN 구조를 설계하기 전 결정한 노드의 제한된 개수 W개만큼 선호되는 적합도 값들을 선택한다.

[단계 5-8] 다음세대에서의 particle velocity를 생성하기 위해서 선택된 노드들 중에서 최적의 적합도 값을 가지는 노드를 선택한다.

[단계 5-9] [단계 5-5]에서 얻어진 정보를 가지고 다음 세대의 Swarm을 생성한 후 [단계 5-3]에서 [단계 5-8]까지 반복한다. 정해진 세대까지 이를 반복 실행한다.

[단계 5-10] 위의 단계들을 거쳐서 마지막 세대까지 PSO 알고리즘이 실행되면 최적의 노드들이 생성되며 생성된 노드들은 PNN 모델을 구축하는 하나의 층을 이루게 된다.

[단계 6] 종료판정

[단계 5]의 현재 층에서 얻어진 최적 노드의 최대 적합도 값 F_1 이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F_1 \leq F^* \quad (12)$$

단, F^* 는 이전 층의 최적 노드인 최대 적합도 값이다.

전체 층의 수를 최대 3층으로 제한하여 네트워크의 복잡성과 우수성의 상호 균형을 고려하여 알고리즘을 종료한다. 모델 후반부 다항식의 계수 추정은 최소자승법(Least square method)을 이용하였으며, 모델의 성능지수 식은 다음 식들을 이용하였다. 가스 터빈 발전소의 NOx 배출 메카니즘 데이터를 사용한 경우엔 식 (13)과같이 MSE (Mean Squared Error)를 사용하여 구하고,

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (13)$$

Machine learning data 집합(-Automobile Miles Per Gallon(MPG) data)을 사용한 경우엔 식 (14)와 같이 RMSE (Root Mean Squared Error)를 사용하여 모델의 성능을 평가하였다.

$$E = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

여기서, n은 전체 데이터 개수, y_i 는 원 데이터 출력 그리고 \hat{y}_i 는 모델의 출력을 의미한다.

[단계 7] 다음 층의 새로운 입력변수 설정

현재 층에서 보존된 노드의 출력들($z_{1i}, z_{2i}, \dots, z_{wi}$)에서 다음 층의 새로운 입력들($x_{1j}, x_{2j}, \dots, x_{wj}$)로, $x_{1j}=z_{1i}, x_{2j}=z_{2i}, \dots, x_{wj}=z_{wi}$ 으로 구성하고, [단계 4]로 간다(여기서, $j=i+1$). 이 후, [단계 4]부터 [단계 7]까지를 반복한다. 알고리즘이 종료할 경우, 마지막 층의 최적 적합도 값 F^* 을 얻은 노드의 다항식에 입력이 되는 전 층의 출력을 대입하고 동일한 작업을 제 1층까지 반복하여 최종 추정 모델 \hat{y} 을 얻는다.

5. 시뮬레이션 및 결과 고찰

본 논문에서 제안된 네트워크 구조는 몇 개의 수치적 실험을 통해서 모델의 특징과 성능에 대해서 알아본다. 첫 번째 데이터 집합은 가스 터빈 발전소의 NOx 배출 메카니즘 데이터[17]이고 두 번째 데이터 집합은 Machine Learning data (-MPG data) 집합이다. 모든 실험들은 발생된 결과들의 타당성으로써 좀 더 높은 객관성을 제공하기 위해 10-fold cross validation 모드를 실행하였다.

표 2 PSO 알고리즘 및 모델 구축을 위한 정보
Table 2 Values of the parameters of the PSO algorithm and the proposed model

Parameters	Data				
	NOx	MPG			
PSO	Generation size	100 for each layer			
	Swarm size	100 for each layer			
	Selected swarm size	30 for each layer			
	v_{max}	20% of search space			
	$[w_{min} \ w_{max}]$	[0.4 0.9]			
	c_1, c_2	2.0			
FCM	No. of clusters per RPN	2 ~ 10			
	Fuzzification coefficient	1.8 ~ 3.1			
RPNN	No. of input variables to be selected	2 ~ 4	2 ~ 6		
	Polynomial type	1 ≤ T ≤ 4			
	Weighting factor(θ)	0.5			
	Division of data	Case 1	50:50	60:40	60:40
		Case 2	50:30:20		
Maximum layer	3	3			

여기서, T는 표 1에 나타낸 다항식 구조

5.1. 가스 터빈 발전소의 NOx 배출 메카니즘 데이터

최근 환경보전의 필요성을 크게 인식하며 CO, CO₂, SO, SO₂, NO, N₂O, NO₂ 및 프레온 가스 등과 같은 공해물질을 줄이고, 이들을 관리하기 위한 연구가 선진국을 중심으로 이루어지고 있다. 본 논문 역시 환경보전의 필요성을 인식하며, 이에 따른 화력발전소 대기오염물질의 배출패턴에 관한 모델을 정립하고 공기 오염물질인 NOx의 배출량을 예측하고자 한다[17]. 특히, 화력발전소의 가스 터빈에서 발생하는 독성이 강한 NOx의 배출 메카니즘에 제안된 알고리즘을 도입하여 배출 패턴 모델을 구축하고 평가한다. 가스 터빈 발전소의 NOx 배출 메카니즘 데이터는 총 5입력(Tamb, COM, LPT, Pcd, Texh) 1출력(NOx)의 260개의 데이터로 구성되어 있으며, 모델의 성능지수 평가방법은 식 (14)에서와 같이 MSE를 이용하였다.

표 3 제안된 모델의 성능지수

Table 3 Performance index of the proposed network

Layer	Case 1		Case 2		
	PI	EPI	PI	VPI	EPI
1	0.0088 ±0.0084	0.1856 ±0.1432	0.0049 ±0.0033	0.1454 ±0.1097	0.1572 ±0.1170
2	0.0059 ±0.0030	0.0286 ±0.0192	0.0043 ±0.0012	0.0151 ±0.0127	0.0227 ±0.0160
3	0.0062 ±0.0021	0.0092 ±0.0025	0.0049 ±0.0014	0.0075 ±0.0029	0.0105 ±0.0023

그림 5는 표 3에서 보여준 네트워크 출력중에서 3층에서 가장 우수한 성능을 가진 모델의 각 층에서 generation 수행 과정에 따른 성능지수의 최적화 과정을 나타낸 것이다.

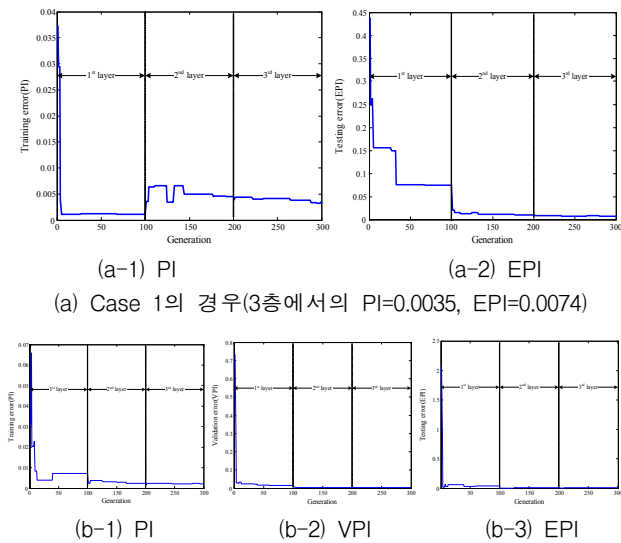


그림 5 PSO 알고리즘에 의한 각 성능지수들의 최적화 과정
Fig. 5 The optimization process of each performance index by the PSO algorithms

그림 6는 그림 5에서 보여준 가장 우수한 모델들의 원 출력과 모델 출력과의 차이를 나타낸다.

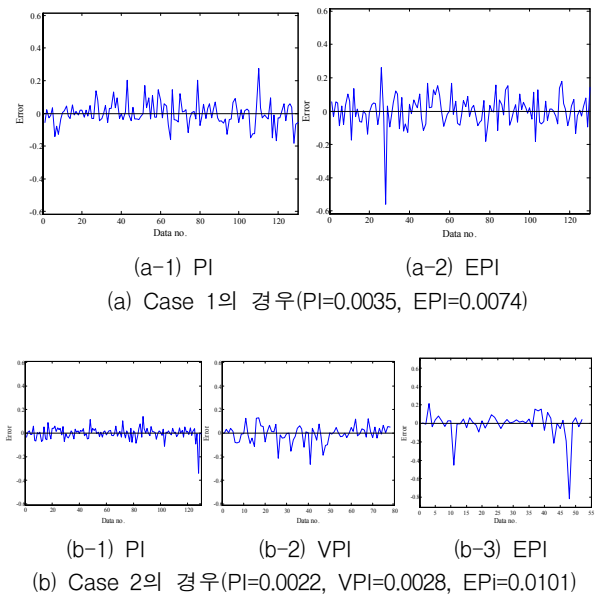


그림 6 RPNN의 오차곡선
Fig. 6 Errors curves of RPNN

그림 7은 표 3에서 보여준 성능지수중에서 Case 1인 경우 3층에서의 모델 성능이 PI=0.0035, EPI=0.0074 인 경우의 모델의 전체 네트워크 구조를 나타낸 것이다.

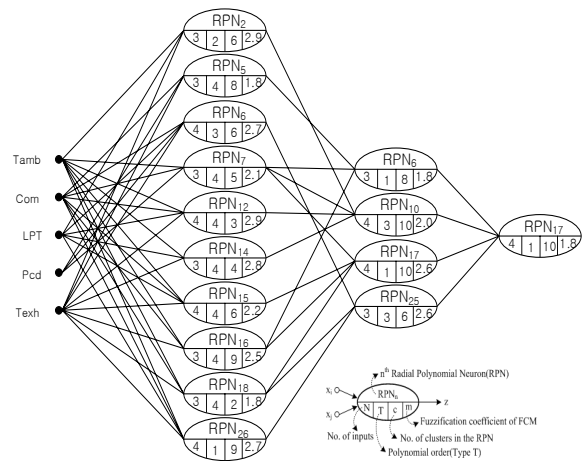


그림 7 진화론적으로 최적화된 RPNN의 네트워크
(Case 1, PI=0.0035, EPI=0.0074)
Fig. 7 Genetically optimized RPNN network
(Case 1, PI=0.0035, EPI=0.0074)

표 4는 가스 터빈 발전소의 NOx 배출 메카니즘 데이터를 사용하여 식 (13)에 의해 계산된 성능지수으로써 기존의 모델과 본 논문의 모델을 비교한 것이다.

표 4 기존의 모델들과의 성능 비교

Table 4 Comparative analysis of the performance of various models

Model		PI	VPI	EPI
Regression model		17.68		19.23
FNN(GAs+complex) [26]	Simplified	6.269		8.778
	Linear	3.725		5.291
Multi-FNN[27]	Linear	0.720		2.025
Hybrid Fuzzy Set-Based FNNs[28]	Simplified	2.7806		5.164
	Linear	3.725		5.291
Hybrid Fuzzy Relation-Based FNNs[29]	Simplified	0.070		1.649
	Linear	0.080		0.190
gHFSPNN[18] (3 rd layer)	Triangular MF	0.0100±		0.0598±
	Gaussian MF	0.0005		0.0042
	Gaussian MF	0.0065±		0.0585±
Proposed Model (3 rd layer)	Case 1	0.0062±		0.0092±
	Case 2	0.0021	0.0075±	0.0025
		0.0049±	0.0075±	0.0105±
		0.0014	0.0029	0.0023

5.2 Automobile Miles Per Gallon(MPG) 데이터


본 논문의 성능을 평가하기 위한 두 번째 데이터는 Machine Learning data로써 일반적으로 지능형 모델링에 있어서 벤치마킹되고 있는 MPG 데이터를 이용하여 제안된 모델의 성능을 평가하였다. 입력은 출력과 관련된 7가지 요소(Cylinders, Displacement, Horsepower, Weight, Acceleration, Model year, Origin)들로 구성되어 있다. 모델의 성능지수는 식 (14)와 같이 RMSE를 사용하여 모델을 평가하였다.

표 5 MPG 데이터에 대한 RPNN 모델의 성능지수


Table 5 Performance index of RPNN for the MPG data

Layer	Case 1		Case 2		
	PI	EPI	PI	VPI	EPI
1	1.810±0.218	2.822±0.222	1.758±0.291	2.827±0.298	3.371±0.471
2	1.486±0.250	2.688±0.226	1.312±0.300	2.693±0.241	3.769±1.215
3	1.210±0.222	2.746±0.247	1.076±0.189	2.678±0.148	3.619±0.468

그림 8은 표 5에서 나타낸 모델의 성능 중에서 가장 우수한 성능을 가진 모델의 층의 증가에 따른 최적화 과정을 나타낸 것이다.



(a-1) PI (a-2) EPI
(a) Case 1의 경우(PI=1.033, EPI=2.552)




(b-1) PI (b-2) VPI (b-3) EPI
(b) Case 2의 경우(PI=0.743, VPI=2.807, EPI=3.476)


그림 8 제안된 RPNN 최적화를 위한 각 층 성능지수의 수렴 과정

Fig. 8 Convergence process for the optimization of the proposed RPNN

그림 9는 그림 8에서 보여준 가장 우수한 성능을 가진 모델들의 출력과 원 데이터 출력과의 선형성을 보여준 것이다. 그림에서도 알 수 있듯이 학습 데이터에 대한 성능 즉, 모델의 근사화 능력이 일반화 능력(테스트 데이터에 대한 성능) 보다 선형성이 뚜렷함을 알 수 있다.



(a-1) PI (a-2) EPI
(a) Case 1의 경우(PI=1.033, EPI=2.552)



(b-1) PI (b-2) VPI (b-3) EPI
(b) Case 2의 경우(PI=0.743, VPI=2.807, EPI=3.476)

그림 9 원 출력과 모델 출력의 비교

Fig. 9 Scatter plots showing model output versus original output

표 6은 MPG 데이터를 사용하여 성능 지수를 식 (14)에 의해 계산된 값으로 동일한 실험적 예제를 사용한 기존의 모델과 본 논문에서 제시한 방사형 기저 함수 기반 다항식 신경 회로망 모델과의 성능비교를 한 것이다. 기존의 지능형 모델들에 비해서 제안한 모델의 근사화 및 일반화 능력이 우수함을 알 수 있다.

표 6 기존의 모델들과의 성능 비교

Table 6 Comparative analysis of the performance of various models

Model		PI	VPI	EPI
RBFNN[30]		3.24±0.24		3.62±0.31
RBFNN with context-free clustering[30]		3.21±0.21		3.51±0.27
Linguistic Modeling[30]	Without optimization	3.78±1.52		4.22±1.22
	One-loop optimization	2.90±0.32		3.17±1.01
	Multi-step optimization	2.86±0.83		3.14±0.98
Development of incremental models[31]	Linear regression	3.383±0.194		3.472±0.295
	Polynomial (2 nd order)	2.807±0.122		2.972±0.196
	Incremental model	2.390±0.142		3.060±0.285
HFSPNN[18] (3 rd layer)	Triangular MF	1.962±0.214		2.396±0.180
	Gaussian MF	1.886±0.133		2.479±0.192
Proposed Model (3 rd layer)	Case 1	1.210±0.222		2.746±0.247
	Case 2	1.076±0.189	2.678±0.148	3.619±0.468

6. 결 론

본 논문에서는 주어진 정보 입자화의 효율적인 처리와 시스템이 복잡하고 대규모의 구조를 가지는 비선형 실 시스템의 동적 분석을 표현하고자 방사형 기저 함수 기반 다항식 신경 회로망에 대한 새로운 구조와 설계 방법론에 대해서 제안하고 폭넓은 성능평가를 하였다.

제안된 모델의 설계 관점에서 가장 큰 특징은 다음과 같이 나타낼 수 있다.

- 기존의 다항식 신경 회로망 구조에 간단한 형태의 구조와 일반적인 근사화 능력을 가지는 방사형 기저 함수 신경 회로망을 접목함으로써 새로운 형태의 진보된 지능 모델을 구축할 수 있었다.
- 제안한 RPNN 모델을 구성하고 있는 방사형 다항식 노드(RPN)에 사용되어지는 RBFNN에 FCM 클러스터링 방법을 이용함으로써 주어진 실험 데이터에 대한 효과적이고 분별 있는 입자들에 대한 정보를 구축하여 효율적인 네트워크를 설계할 수 있었다는 것이다.
- RPN의 성능을 향상시키는데 크게 영향을 미치는 파라미터들(-입력 변수의 수, 선택된 입력 변수, 후반부 다항식 차수, RPN를 구성하고 있는 RBFNN의 노드의 수, 그리고 FCM 클러스터링의 퍼지화 계수)을 진화론적으로 탐색하여 모델 구축에 있어서 유연성과 정확성을 가지며 객관적이고 좀 더 정확한 예측 능력을 가진 RPNN 모델을 구축할 수가 있었다.

감사의 글

본 연구는 2009년도 지식경제부의 재원으로 한국에너지 기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다 (2009T100100563) 그리고 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2009-0074928).

참 고 문 헌

- [1] W. Pedrycz and J. F. Peters, Computational Intelligence and Software Engineering, World Scientific, Singapore, 1998.
- [2] W. Pedrycz, G. Vukovich, "Granular neural networks," Neurocomputing, Vol. 36, pp. 205-224, 2001.
- [3] T. Takagi and M. Sugeno, "Fuzzy Identification of Systems and its Application to Modeling and Control," IEEE Trans. on Systems Man and Cybernetics, Vol. 15, pp. 116-132, 1985.
- [4] Y. Tan, J. Wang, and J. M. Zurada, "Nonlinear blind source separation using a radial basis function network," IEEE Trans. Neural Networks, Vol. 12, No. 1, pp. 124-134, 2001.
- [5] M. Han and J. Xi, "Efficient clustering of radial basis perceptron neural network for pattern recognition," Pattern Recognition, Vol. 37, pp. 2059-2067, 2004.
- [6] J. M. Vilaplana, J. L. P. Molina, and J. L. Coronada, "Hyper RBF model for accurate reaching in redundant robotic systems," Neurocomputing, Vol. 61, pp. 495-501, 2004.
- [7] M. L. Kothari, S. Madnani, and R. Segal, "Orthogonal Least Square Learning Algorithm Based Radial Basis Function Network Adaptive Power System Stabilizer," Proceeding of IEEE SMC, Vol. 1, pp. 542-547, 1997.
- [8] A. Staiano, J. Tagliaferri, W. Pedrycz, "Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering Automatic structure and parameter," Neurocomputing, Vol. 69, pp. 1570-1581, 2006.
- [9] N. B. Karayiannis, "Reformulated radial basis neural networks trained by gradient descent," IEEE Trans. Neural Networks, Vol. 10, No. 3, pp. 657-671, 1999.
- [10] S. M. Loone and G. Irwin, "improving neural network training solutions using regularisation," Neurocomputing, Vol. 37, pp. 71-90, 2001.
- [11] W. Pedrycz, H. S. Park, S. K. Oh, "A granular-oriented development of functional radial basis function neural networks," Neurocomputing, Vol. 72, No. 1-3, pp. 420-435, 2008.
- [12] S. K. Oh, W. Pedrycz, S. B. Roh, "Hybrid fuzzy set-based polynomial neural networks and their development with the aid of genetic optimization and information granulation," Applied Soft Computing, Vol. 9, No. 3, pp. 1068-1089, 2009.
- [13] S. K. Oh, W. Pedrycz, H. S. Park, "Genetically Optimized Fuzzy Polynomial Neural Networks," IEEE Trans. on Fuzzy Systems, Vol. 14, No. 1, pp. 125-144, 2006.
- [14] J. Kennedy and R. Eberhart, "Particle Swarm

Optimization," Proc. of IEEE International Conference on Neural Networks, Vol. 4, pp. 1942-1948, 1995.

- [15] B. J. Park, S. K. Oh, Y. S. Kim, T. C. Ahn, "Comparative Study on Dimensionality and Characteristic of PSO," Journal of Control, Automation and Systems Engineering, Vol. 12, No. 4, pp. 328-338, 2006.
- [16] S. K. Oh, "A study on the development of intelligent models and simulator concerning the pattern of an air pollutant emission in a thermal power plant," Technical Report, Korea Energy Management Corporation, 2004.
- [17] S. K. Oh, W. Pedrycz, H. S. Park, "Hybrid Identification in fuzzy-neural networks," Fuzzy Set Syst. Vol. 138, No. 3, pp. 399-426, 2003.
- [18] S. K. Oh, W. Pedrycz, H. S. Park, "Rule-based multi-FNN Identification with the aid of evolutionary fuzzy granulation," J. Knowledge-Based Syst, Vol. 17, No. 1, pp. 1-13, 2004.
- [19] S. K. Oh, W. Pedrycz and H. S. Park, "Hybrid Identification in Fuzzy-Neural Networks," Fuzzy Sets and Systems, Vol. 138, No. 2, pp. 399-426, 2003.
- [20] W. Pedrycz, K. C. Kwak, "Linguistic models as a framework of user-centric system modeling," IEEE Trans. SMC-A, Vol. 36, No. 4, pp. 727-745, 2006.
- [21] W. Pedrycz, K. C. Kwak, "The Development of Incremental Models," IEEE Trans. Fuzzy Systems, Vol. 15, No. 3, pp. 507-518, 2007.



진 용 하 (陳 庸 夏)

2009년 수원대학교 전기공학과 졸업. 동 대학원 석사(2011.2.). 관심분야는 퍼지추론 시스템, 뉴럴 네트워크, Granular Computing, 진화론적 최적화 알고리즘.
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : yhj@suwon.ac.kr



오 성 권 (吳 聖 權)

1981년 연세대학교 전기공학과 졸업, 동 대학원 석사(1983), 박사(1993). 1983-1989년 금성산전연구소(선임연구원). 1996-1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993-2004년 원광대학교 전기전자 및 정보공학부 교수. 2005~현재 수원대학교 전기공학과 교수, 2002~현재 대한전기학회, 제어로봇시스템학회, 퍼지및지능시스템학회 편집위원. 관심분야는 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 컴퓨터 지능, 지능제어.
Tel : 031-229-8162
Fax : 031-220-2667
E-mail : ohsk@suwon.ac.kr

저 자 소 개



박 호 성 (朴 浩 成)

1999년 원광대학교 제어계측공학과 졸업. 동 대학원 석사(2001), 박사(2005). 2005-2006년 원광대학교 전기전자 및 정보공학부 전임강사, 2006-2007년 캐나다 Alberta 대학 전기 및 컴퓨터공학과 Post-Doc. 2008~현재 수원대학교 산업기술연구소 학술연구교수. 관심분야는 퍼지추론시스템, 신경 회로망, 퍼지-신경 회로망, 진화론적 최적화 알고리즘, 입자컴퓨팅, 뉴로퍼지컴퓨팅, 진화컴퓨팅등의 컴퓨터지능.
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : parkhs@suwon.ac.kr