

진화론적 최적 규칙베이스 퍼지다항식 뉴럴네트워크

Genetically Optimized Rule-based Fuzzy Polynomial Neural Networks

박 병 준, 오 성 권*, 김 현 기
(Byoung-Jun Park, Sung-Kwan Oh, and Hyun-Ki Kim)

Abstract : In this paper, a new architecture and comprehensive design methodology of genetically optimized Rule-based Fuzzy Polynomial Neural Networks(gRFPNN) are introduced and a series of numeric experiments are carried out. The architecture of the resulting gRFPNN results from asynergistic usage of the hybrid system generated by combining rule-based Fuzzy Neural Networks(FNN) with polynomial neural networks (PNN). FNN contributes to the formation of the premise part of the overall rule-based structure of the gRFPNN. The consequence part of the gRFPNN is designed using PNNs. At the premise part of the gRFPNN, FNN exploits fuzzy set based approach designed by using space partitioning in terms of individual variables and comes in two fuzzy inference forms: simplified and linear. As the consequence part of the gRFPNN, the development of the genetically optimized PNN dwells on two general optimization mechanism: the structural optimization is realized via GAs whereas in case of the parametric optimization we proceed with a standard least square method-based learning. To evaluate the performance of the gRFPNN, the models are experimented with the use of several representative numerical examples. A comparative analysis shows that the proposed gRFPNN are models with higher accuracy as well as more superb predictive capability than other intelligent models presented previously.

Keywords : genetically optimized rule-based fuzzy polynomial neural networks(gRFPNN), computational intelligence(CI), fuzzy set-based FNN(FS_FNN), genetically optimized PNN(gPNN), GMDH

I. 서론

현대사회는 정보화 사회로, 컴퓨터 산업을 기반으로 하고 있다. 컴퓨터는 많은 분야에 다양한 변화를 가져왔으며, 산업화 및 과학 기술의 급속한 발달과 함께 CI (Computational Intelligence) 기술 발전의 계기를 마련하였다.

최근에는 CI 기술이 산업전반에 다양하게 활용되면서 이의 능력에 대해 많은 관심이 모아지고 있으며, 정보기술 (Information Technology; IT) 시장의 핫이슈(Hot issue)로 부각되면서 미국, 일본 등과 같은 선진국에서 활발한 연구를 바탕으로 여러 분야에 응용되고 있다[1,18]. CI 기술은 인간의 신경구조를 모방한 신경망[2]과 인간의 언어적 지식과 전문가적 경험을 사용하는 퍼지이론[3-6] 그리고 유전자 알고리즘[7]과 같은 지능시스템들이 보다 활발하게 연구되면서 합성, 융합, 결합을 통한 고급 CI 기술에 관한 연구가 다양한 형태로 추진되고 있다[8-11]. 본 연구에서는 고급 CI 기술의 한 영역으로써 효과적인 비선형 문제의 분석과 해결을 위한 진화론적 최적 규칙베이스 퍼지다항식 뉴럴네트워크(gRFPNN) 개발을 목표로 하며, 구조 개발을 위한 광범위한 설계방법론을 토의한다.

제안된 gRFPNN은 기존에 제시된 모델 구조인 자기구성 퍼지다항식 뉴럴네트워크(SOFPNN[9,10,19,20])와 유전자 알

고리즘(Genetic Algorithms; GAs[7])의 융합에 의해 생성되는 최적화 구조이다. gRFPNN은 기존 SOFPNN 모델과 같이 전반부와 후반부 구조로 구성된다. gRFPNN의 전반부 구조는 간략 및 선형 퍼지추론과 신경망의 융합에 의해 설계된 퍼지집합 기반 퍼지뉴럴네트워크(Fuzzy Set based Fuzzy Neural Networks; FS_FNN[9,10])에 의해 설계되며, 하이브리드 방법 즉, GAs와 오류역전파(Back-propagation; BP) 학습 알고리즘을 이용하여 파라미터를 최적화한다. gRFPNN의 후반부 구조는 SOFPNN의 후반부 구조와는 달리 GAs와 다항식 뉴럴네트워크(Polynomial Neural Networks; PNN[11])의 융합에 의한 구조적 최적화로부터 구현된다. 기존에 제안된 SOFPNN의 후반부 구조는 고정된 입력 수와 다항식 차수를 이용하여 네트워크의 성장과정을 통해 다양한 구조로 설계되지만, 최적 네트워크 구조임을 보증하지 못하다. 그러나 제안된 gRFPNN은 GAs에 의해 구조적으로 최적화된 네트워크가 되도록 하며, 기존의 모델링 방법들 보다 훨씬 유연성과 정확성을 가진 구조를 생성한다.

제안된 gRFPNN 구조의 평가를 위해 본 논문에서는 몇 개의 비선형 공정을 이용한다. 주어진 공정에 제안된 구조를 적용하고 이에 대한 결과 분석 및 평가를 통해 구조의 정확성, 타당성 등을 검증한다.

II. 기존의 자기구성 퍼지다항식 뉴럴네트워크의 구조

하이브리드 구조 형태인 자기구성 퍼지다항식 뉴럴네트워크(SOFPNN[9,10,19,20])은 FS_FNN과 PNN의 상호 결합된 구조로 FS_FNN은 SOFPNN 구조의 전반부를, PNN은 후반부를 구성한다. SOFPNN의 전반부 구조인 FS_FNN은 각 입

* 책임저자(Corresponding Author)

논문접수 : 2003. 10. 20., 채택확정 : 2004. 9. 1.

박병준, 오성권 : 원광대 전기전자및정보공학부

(lcap@wonkwang.ac.kr/ohsk@wonkwang.ac.kr)

김현기 : 수원대 전기공학과(hkkim@suwon.ac.kr)

※ 본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2003

-B-274) 주관으로 수행된 과제입니다.

력에 대해 개별적으로 정의된 퍼지집합을 기반으로 설계되며, 간략 퍼지추론, 선형 퍼지추론, 오류역전파(BP) 학습 규칙을 이용한다. 후반부 구조로 이용된 PNN은 수학적인 다항식 형태로 표현되며 GMDH [12]에 기반을 둔다. PNN은 학습을 통해 발전하는 유연한 구조로 층(layer)과 다항식 뉴런(Polynomial Neuron; PN)의 생성 및 소멸을 통해 구축된 네트워크이다. PNN의 각 PN은 높은 유연성을 보여주며, 입력과 출력 변수 사이의 회귀다항식(1차식, 2차식, 변형된 2차식) 함수에 의해 구현된다. 이는 공정 모델 특성과 계층구조의 간략성 및 상호 연계성 고려로부터 고차 회귀다항식 사용이 용이하고 간단한 구조로 설계된다[11].

SOPFNN은 FS_FNN과 PNN의 장점을 가지며 상호 보완의 특성을 가진다. 즉 FS_FNN과 PNN의 특성을 모두 나타낸다. 전반부 FS_FNN 사용은 구조의 특성상 4입력 이상의 시스템 입력변수를 요구하는 PNN의 단점을 보완함으로써 적은 입력변수를 가진 시스템에 대해서도 PNN의 다양한 구조 적용을 용이하게하며, 후반부에 PNN을 사용함으로써 FS_FNN의 학습방법인 오류역전파 학습방법을 도와 좀더 향상된 성능을 나타낸다. SOPFNN의 구조는 전반부와 후반부의 구조에 따라 다양하게 설계된다. 특히 후반부 구조인 PNN의 설계에 따라 SOPFNN의 구조는 결정된다[9,10,19,20].

III. gRFPNN의 구조와 알고리즘

본 연구에서 제안된 진화론적 최적 규칙베이스 퍼지다항식 뉴럴네트워크(gRFPNN) 구조는 진화에 의해 그림 1과 같이 생성된다. 전반부 구조는 간략 및 선형 퍼지추론 형태의 FS_FNN을 이용하며 후반부는 GAs와 PNN의 융합에 의한 구조적 최적화(Genetically optimized PNN gPNN)로부터 구현된다.

1. 전반부 구조; FS_FNN

퍼지집합 기반 퍼지뉴럴네트워크(FS_FNN)은 각각의 입력변수들에 대해 정의된 퍼지집합을 기반으로 개개의 변수만을 고려한 공간분할에 의해 설계되어진다. 이것은 각 입력변수들에 대해 독립적으로 이루어지며, 분할된 공간을 통해 형성된 퍼지언어 정보로 퍼지규칙을 형성함으로써 구성된다. 다른 모델에 비해 학습속도가 빠르고 수렴특성이 우수하다는 장점을 가진다[9,10].

간략 퍼지추론에 의해 구현되는 FS_FNN의 구조는 그림 2(a)와 같으며, ‘원’은 FS_FNN의 뉴런 유니트를 나타내고, ‘N’은 정규화를, ‘Σ’은 대수적 합을 의미한다.

xk의 각 입력신호는 퍼지집합에 의해 정의된 각 멤버쉽 함수를 거쳐 적합도가 구해지고, 정규화된 적합도는 연결가중치 wki와 곱해지며 이들이 Σ 뉴런에 의해 대수적으로 합해져 k번째 출력 fk(xk)를 생성한다. 생성된 출력 값은 (1)과 이 모두 합해져 ŷ를 출력한다.

$$\hat{y} = f_1(x_1) + f_2(x_2) + \dots + f_k(x_k) = \sum_k f_k(x_k) \quad (1)$$

여기서, k은 입력변수 수이다. 입력 xk에 대한 fk(xk)는 퍼지규칙을 이루고 있으며 그 규칙은 (2)와 같다.

$$R^i : \text{If } x_k \text{ is } A_{ki} \text{ then } Cy_{ki} = w_{ki} \quad (2)$$

간략 퍼지추론 FS_FNN의 학습은 그림 2에서 멤버쉽함수 뒷부분에 위치한 연결가중치 wki를 모델에 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 신경회로망의 학습에 가장 일반적으로 사용되는 BP 알고리즘이 사용되며, 이는 최종출력과 원 데이터간의 차, 즉 오차를 바탕으로 이루어진다[9,10].

그림 2(b)는 후반부 구조가 입력과 출력사이의 선형관계로 표현되는 FS_FNN 구조를 보여준다. 여기서 ‘Π’의 뉴런은 입력신호들의 곱으로 뉴런의 출력을 생성한다. 선형 퍼지추론 구조를 가진 FS_FNN의 모델 출력은 간략 퍼지추론 구조와 같이 (1)에 의해 구해지며, 입력 xk에 대한 fk(xk)의 퍼지규칙은 (3)과 같다.

$$R^i : \text{If } x_k \text{ is } A_{ki} \text{ then } Cy_{ki} = ws_{ki} + w_{ki} \cdot x_k \quad (3)$$

FS_FNN 선형 퍼지추론 구조의 학습은 간략 퍼지추론과 마찬가지로 그림 2(b)의 연결가중치 wski와 wki를 조정해 나가면서 이루어진다.

2. 후반부 구조; gPNN

본 연구에서 제안한 gRFPNN의 최적 구조를 위해 진화론적 최적 다항식 뉴럴네트워크(gPNN)을 설계한다. gPNN은 최적화 탐색 방법인 GAs를 이용하여 PNN의 입력변수 수와 이에 해당되는 입력변수 그리고 다항식의 차수를 동조함으로써 생성된다. 즉, 최적의 PNN 구조이다.





그림 1. gRFPNN 구조를 위한 전체 구성도. Fig. 1. Overall diagram for gRFPNN architecture.



(a) Simplified (b) Linear

그림 2. FS_FNN 구조. Fig. 2. Architecture of FS_FNN.

기존의 PNN은 네트워크의 성장과정을 통하여 각층의 다항식 뉴런(Polynomial neuron; PN)에서 고정된(설계자에 의해 미리 선택된) 노드 입력의 수뿐만 아니라 다항식 차수(1차, 2차, 변형된 2차)를 이용하였다. 이러한 PNN은 학습을 통해 발전하는 구조로 층과 PN 수가 고정되어 있지 않고 생성 및 소멸하면서 네트워크를 구성한다. PNN 구조는 주어진 비선형 문제에 높은 유연성을 보여주며, 공정 모델 특성과 계층구조의 간략성 및 상호 연계성 고려로부터 고차 회귀다항식 사용이 용이하고 간단한 구조로 설계된다[11]. 그러나 기존의 PNN 구조는 한 층에서의 PN 모두가 똑같은 입력변수의 수와 다항식 차수를 가지기 때문에 모델 구축에 있어서 다양성과 데이터 특성에 맞는 모델을 구축하지 못하는 단점이 있었다.

따라서 PNN은 PN의 입력 수와 변수의 선택 및 다항식의 차수 결정 등을 해결해야하는 문제를 가지고 있다. 이들 문제들은 주어지는 공정에 대해 다르게 나타나고 모델 성능에 영향을 미치기 때문에 전문가의 지식을 요구하게 된다. 본 연구에서는 PNN 구조가 가지고 있던 단점을 해결하고, 전문가의 경험에 의존한 구조의 최적화를 객관적이고 효율적으로 구축하기 위해 GAs를 적용한다. GAs의 염색체 정보를 통한 PNN과의 융합은 다양한 구조와 방법론적 설계를 요구하지 않으며, 기존의 일률적인 입력변수의 수와 다항식 차수에서 벗어난 단일화된 최적 네트워크 구조인 gPNN을 생성한다.

3. 진화론적 최적 규칙베이스 퍼지다항식 뉴럴네트워크

gRFPNN은 GAs를 이용하여 SOFPNN을 최적화한 구조로, 진화를 통해 네트워크를 생성해 간다. gRFPNN 구조는 전반부(FS_FNN)와 후반부(PNN)로 구성된다. 전반부와 후반부 구조는 각각 GAs에 의해 최적화된다. GAs에 의한 FS_FNN의 최적화는 모델의 출력에 적용하도록 파라미터를 동조함으로써 이루어지며, 후반부 구조인 PNN은 GAs에 의해 진화하여 최적 구조로 설계된다.

그림 3은 gRFPNN 구조를 위한 전체 설계 흐름도이다. 제안된 gRFPNN의 전후반부 상세 설계과정은 다음과 같다.

gRFPNN의 전반부 FS_FNN

- [Layer 1] : 입력층.
- [Layer 2] : 멤버쉽함수에 대한 적합도(활성값) 계산.
- [Layer 3] : 정규화된 적합도 계산.

$$\bar{\mu}_{ki} = \frac{\mu_{ki}}{\sum_{i=1}^n \mu_{ki}} = \mu_{ki} \quad (4)$$

여기서 n은 각 입력에 대한 멤버쉽함수의 수, 즉 퍼지규칙 수이다. 입력변수 x_k 는 두개의 멤버쉽함수에만 영향을 받기 때문에 $\bar{\mu}_{ki} = \mu_{ki}$ 이다. 이와 같은 특징 때문에 빠른 추론속도의 효과를 얻을 수 있다[9].

[Layer 4] 연결 가중치와의 곱.

$$a_{ki} = \bar{\mu}_{ki} \times Cy_{ki} = \mu_{ki} \times Cy_{ki} \quad (5)$$

$$\begin{cases} \text{Simplified} : Cy_{ki} = w_{ki} \\ \text{Linear} : Cy_{ki} = ws_{ki} + w_{ki} \cdot x_k \end{cases} \quad (6)$$

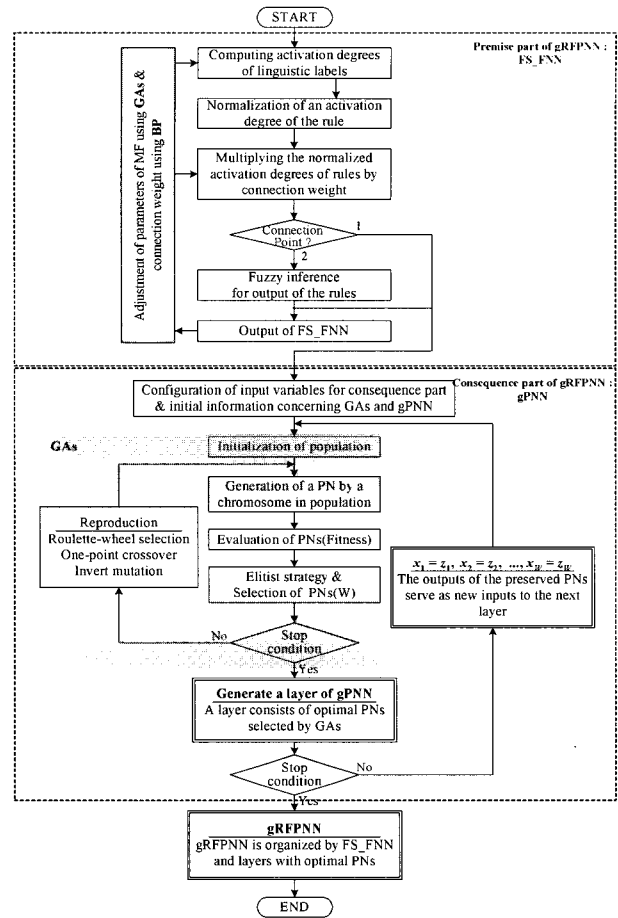


그림 3. gRFPNN 구조를 위한 전체 설계 흐름도.
Fig. 3. Overall design flowchart for gRFPNN architecture.




그림 4. FS_FNN과 gPNN과의 결합을 위한 연결점.
Fig. 4. Connection points for combining FS_FNN with gPNN.

FS_FNN은 후반부 구조인 gPNN과 2개의 연결지점(Connection point; CP)을 가진다. 첫 번째는 각 입력에 대한 퍼지규칙의 후반부 출력(CP01)이고 두 번째는 각 입력에 대한 퍼지추론 결과(CP02)이다. gRFPNN의 전반부 구조로 연결점 CP01을 선택한 경우, 입력에 대한 적합도와 연결가중치의 곱인 a_{ki} 는 gPNN의 입력이 된다.

[Layer 5] : 각 입력의 퍼지규칙에 대한 퍼지추론.

$$f_k(x_k) = \sum_{i=1}^n a_{ki} = \sum_{i=1}^n \mu_{ki} \cdot Cy_{ki} = \mu_{ki} \cdot Cy_{ki} + \mu_{ki+1} \cdot Cy_{ki+1} = a_{ki} + a_{ki+1} \quad (7)$$

[Layer 6] : FS_FNN의 출력.

FS_FNN의 6층에서 (1)과 같이 계산된 최종출력은 원 출

력과의 오차를 구하고, 구하여진 오차를 역방향으로 전달시켜 학습을 통해 연결가중치를 조절한다.

gRFPNN의 후반부 gPNN

[단계 1] 입력변수의 설정. 전반부 구조에서 CP01을 선택한 경우 aki를 gPNN의 입력변수로 설정한다. 즉, $x_1=a_{11}, x_2=a_{12}, \dots, x_n=a_{ki}$ ($n=k \times i$)가 된다. FS_FNN과 gPNN의 연결점 CP02를 선택하면 $f_k(x_k)$ 가 후반부 구조의 입력으로 설정한다. 즉, $x_1=f_1(x_1), x_2=f_2(x_2), \dots, x_n=f_m(x_m)$ ($n=m$)가 된다.

[단계 2] gRFPNN 구조 생성을 위한 기본 정보 결정

[단계 3] 초기 세대 생성. 여기서 염색체 하나의 개체는 gPNN을 구성하는 하나의 PN 정보를 가지고 있으며, 각각의 개체는 하나의 PN과 같은 역할을 한다.

[단계 4] GAs의 염색체 정보에 의한 PN 결정.

[단계 4-1] 입력변수의 수 선택.

Step 1 : 주어진 전체 염색체 정보 중 처음 3비트는 입력변수의 수를 결정하기 위해 이용된다. 설계자에 의해 이 비트 수는 달라질 수 있다.

Step 2 : 선택된 3비트를 10진수로 복호화 한다.

Step 3 : 복호화된 10진수를 설계자가 정한 최대 입력변수의 수로 정규화한다.

Step 4 : Step 3에서 정의된 정수는 하나의 PN를 구축하는 입력변수의 수로 선택되어진다.

[단계 4-2] 다항식 차수 선택

Step 1 : 입력변수 수의 선택 비트 이후의 3비트를 다항식 차수 선택을 위한 비트로 설정한다. 이 비트 수 역시 설계자에 의해 달라질 수 있다.

Step 2 : 선택되어진 3비트를 10진수로 복호화 한다.

Step 3 : 복호화된 10진수를 1~3 사이의 정수로 정규화한다.

Step 4 : 결정된 값은 PN의 다항식 차수로 설정된다.

- 1 → Type 1 : 선형식 ($z = c_0 + c_1x_1 + c_2x_2$)
- 2 → Type 2 : 2차 다항식
($z = c_0 + c_1x_1 + c_2x_2 + c_3x_1^2 + c_4x_2^2 + c_5x_1x_2$)
- 3 → Type 3 : 변형된 2차 다항식
($z = c_0 + c_1x_1 + c_2x_2 + c_3x_1^2 + c_4x_2^2$)

[단계 4-3] 입력변수 선택

Step 1 : 염색체 정보의 나머지 비트는 입력변수 선택을 위해 사용된다.

Step 2 : 입력변수 선택 비트를 [단계 4-1]에서 구한 입력변수의 수로 균등 분할한다.

Step 3 : 분할된 각 비트들을 10진수로 복호화 한다.

Step 4 : 복호화된 값은 1에서 전체 입력변수의 수 사이의 정수로 정규화 한다.

Step 5 : 정규화된 값들은 입력변수의 번호가 된다. 즉 PN의 입력변수가 된다. 만약 선택된 입력변수가 중복되면, 하나의 변수로 처리한다.

[단계 5] PN의 매개변수 추정 및 평가[11]

[단계 6] PN 선택과 엘리트 전략

[단계 7] 재생산(선택, 교배, 돌연변이)

단계 4부터 단계 7까지 반복한다.

[단계 8] gRFPNN의 후반부 층 결정.

[단계 9] 종료판정. 네트워크의 복잡성과 우수성 등의 상호 균형을 고려하여 알고리즘을 종료한다.

[단계 10] 새로운 입력변수 설정. GAs에 의해 생성된 현재 층의 PN 출력들(z_1, z_2, \dots, z_W)로부터 다음 층의 새로운 입력들(x_1, x_2, \dots, x_W)을 $x_1=z_1, x_2=z_2, \dots, x_W=z_W$ 으로 구성하고, [단계 3]로 간다. 이후 [단계 3]부터 [단계 10]까지를 반복 수행한다.

[단계 11] 종료. 마지막 층의 최적 PN의 다항식에 입력이 되는 전 층의 PN을 대입하고 동일한 조작을 1층까지 반복하여 최종 추정 모델 \hat{y} 를 얻는다.

FS_FNN과 gPNN의 합성 구조인 gRFPNN 구조는 주어진 비선형 문제를 해결하기 위해 구조 설계와 구조의 결정, 방법론적 설계 등의 과정이 생략된다. 단지 GAs의 염색체 정보를 가지고 문제해결의 최적 해를 찾아 진화하며, 최적의 구조를 구축하게 된다. 따라서, 전문가의 지식을 필요로 하는 많은 부분을 배제함으로써 객관적이고, 유연성, 정확성, 예측능력을 가진 모델을 설계할 수 있다.

IV. 실험연구 및 결과고찰

본 연구에서는 제안된 gRFPNN 구조의 평가와 분석을 위해 세 종류의 데이터를 이용한다. 첫 번째는 비선형 함수 [3,8,21]로 3입력 1출력의 구조를 가지는 수치 예제이다. 두 번째는 비선형 공정에 대한 성능 평가의 척도로 사용되는 가스로 공정[13]에 대해, 마지막으로 NOx 배출공정[22]에 모델을 적용한다. 각 공정에 적용된 gRFPNN의 구조 생성을 위해 공통적으로 적용되는 GAs의 교배율과 돌연변이율은 각각 0.75와 0.065를 적용하였다.

1. 비선형 함수

제안된 모델의 적용 및 유용성을 비교 평가하기 위하여 3입력 1출력으로 표현되는 비선형 함수를 이용한다[3,8,21]. 모델의 성능지수(Performance index; PI)는 (8)을 이용하며, 40개의 데이터 중 20개는 학습 데이터로, 나머지 20개는 테스트 데이터로 사용한다. 여기서 N은 데이터의 수를 나타낸다.

$$PI = \frac{1}{N} \sum_{p=1}^N \frac{|y_p - \hat{y}_p|}{y_p} \times 100(\%) \quad (8)$$

gRFPNN의 비선형 함수 적용을 위한 설계정보와 GAs의 염색체 정보는 표 1과 같다. 최적 구조의 생성을 위한 GAs는 gRFPNN 후반부 각 층에 대해 100세대, 60개체 그리고 30개의 엘리트 개체 선택으로 제안된 구조를 생성한다. 표 1의 유전자 정보 중 엘리트 군집 크기(Elite population size)는 선택되어질 최적 PN의 최대수(W)로, 선택된 PN은 gRFPNN의 후반부 한 층을 구성하며, 이들의 출력은 다음 층의 입력변수들이 된다. 따라서 1층에서의 입력 수는 3 또는 6이지만 2층 이상에서는 선택된 PN 수만큼의 입력변수를 가지게 된다. 여기서 W는 최대수로 이보다 적게 선택될 수 있다. 문자열 길이(String length)는 (3+3+24)로, (입력변수의 수 선택비트+다항식 차수 선택 비트+입력변수 선택비트)를 의미한다. 즉, PN의 입력변수 수를 결정하는데 3비트,

PN의 다항식 차수를 결정하는데 3비트, PN의 입력변수를 선택하는데 24비트를 사용한다. 입력변수 선택비트를 '24'로 설정한 이유는, 하나의 PN에 선택될 입력변수의 수는 최대 4입력($1 \leq N \leq 4$)으로 4입력 모두가 선택될 경우, 하나의 입력변수 선택에 6비트(24/4)가 할당되어 선택될 입력변수를 표현할 수 있기 때문이다. 선택될 입력변수는 앞에서 언급한 것과 같이, 1층에서는 주어진 시스템 입력변수(1~3 또는 1~6), 2층 이상은 선택되어질 PN의 수(1~W)가 된다. 문자열의 길이는 주어지는 gRFPNN의 정보에 맞게 적절히 선택하여야 한다. 적은 수의 문자열은 원하는 정보를 주지 못하며, 많은 수의 문자열은 느린 탐색과 많은 시간을 요구하고, 최적의 모델을 구축하지 못하는 경우가 발생할 수 있다. gRFPNN의 설계정보는 전반부와 후반부로 나뉘어 각각 설정된다. 전반부의 입력 수는 주어진 시스템 입력변수의 수이며, gRFPNN의 입력이 된다. 전반부 구조의 학습을 및 모멘텀계수는 GAs에 의해 동정된 값이다. 전반부 구조인 FS_FNN은 각 입력변수에 대해 2개의 멤버쉽함수를 적용함으로써 6개의 퍼지규칙으로 구성된다. 이들 퍼지규칙의 출력은 후반부 구조와 연결이 되며, gPNN의 입력이 된다. 여기서 전반부 구조인 FS_FNN은 그림 4에서 보여주는 것과 같이 2개의 연결지점(CP)을 가진다. 이 연결점의 선택에 따라 후반부 구조는 6 또는 3개의 입력변수를 가진다. 후반부 gPNN은 각 전반부 구조에 대해 주어진 입력변수 중 4개보다 적은 입력을 선택($1 \leq N \leq 4$)하여 GAs에 의해 PN을 구성하고, 엘리트 집단(W)을 선택하여 gRFPNN 후반부의 한 층을 이룬다. 후반부 층을 형성하는 선택된 PN들로부터 입력변수를 다시 형성하고, 새로이 다음 층을 생성함으로써 네트워크 구조를 구축해 나간다.

표 1에 의한 gRFPNN 구조의 결과는 표 2와 같다. 여기서 'FI'는 퍼지추론, 'NR'은 퍼지규칙 수, 'MF'는 멤버쉽함수, 'CP'는 전반부와 후반부의 연결지점, 'Ly'는 후반부 층, 'NI'는 PN의 입력변수 수, 'Input No.'는 PN의 입력변수 번호(혹은 입력노드 번호), 'Ty'는 후반부 구조를 구성하고 있는 PN의 다항식 차수(Type), PI는 학습데이터에 대한 성능지수, E_PI는 테스트 데이터에 대한 성능지수를 나타낸다. 표 2는 gRFPNN 후반부의 각 층에 대한 최적 PN 노드의 입력노드 번호 및 성능지수 값을 나타낸다. 예를 들어 선형 퍼지추론구조의 FS_FNN과 gPNN의 CP02 연결구조를 보면, gRFPNN의 후반부 1층에서 최적 PN은 x1, x2, x3(전반부 구조의 측면에서 보면 f1(x1), f2(x2), f3(x3)가 된다.)의 입력변수들이 선택되었고, 다항식은 2차식으로 구성된다. 이때 성능지수는 $PI=0.908$, $E_PI=1.423$ 이다. 입력변수의 경우, 후반부 구조의 1층은 전반부와 연결에 의한 입력이 되지만, 2층 이상은 전 층의 PN 출력이 된다. 따라서 2층 이상의 입력변수 번호는 전 층을 구성하고 있는 PN의 번호가 된다. 즉, 2층의 최적 PN은 1층을 구성하는 PN들 중 1, 2, 7, 그리고 16번째 PN의 출력으로부터 4입력을 구성하고, 2차식의 다항식으로 표현된다. 이때 $PI=0.113$, $E_PI=0.299$ 의 출력특성을 가진다. 3층, 4층, 5층도 마찬가지로 구성된다.

제안된 gRFPNN의 전반부 구조는 FS_FNN의 간략 및 선형 퍼지추론 구조를 이용하였으며, 이때 간략 퍼지추론 구

표 1. GAs와 gRFPNN의 관련 정보.

Table 1. Information related to GAs and gRFPNN.

GAs	Generation		100	
	Population size		60	
	Elite population size(W)		30	
	String length		3+3+24	
gRFPNN	Premise (FS_FNN)	No. of entire inputs		3
		Iteration		1000
		Learning rate	Simplified	0.039
			Linear	0.335
		Momentum coefficient	Simplified	0.004
	Linear		0.058	
	No. of rules		6	
	Consequence (gPNN)	No. of entire inputs	CP01	6
			CP02	3
		Layer		5
No. of inputs to be selected(N)		$1 \leq N \leq 4$		
Type(T)		$1 \leq T \leq 3$		

N, T : integer

표 2. 비선형 함수에 대한 gRFPNN의 성능지수.

Table 2. Performance index of gRFPNN for the nonlinear function.

Premise part	CP	Consequence part						PI	E_PI	
		Ly	NI	Input No.			Ty			
Simplified (2+2+2)	01	1	4	6	2	5	3	2	2.070	2.536
		2	4	4	9	7	15	3	0.390	0.896
		3	3	28	7	18	.	3	0.363	0.642
		4	4	5	1	7	19	1	0.350	0.539
		5	2	5	3	.	.	2	0.337	0.452
	02	1	3	3	1	2	.	2	2.706	3.946
		2	4	8	7	4	11	2	0.299	0.517
		3	3	15	5	14	.	3	0.299	0.467
		4	3	5	3	24	.	3	0.299	0.412
		5	3	14	25	1	.	2	0.299	0.398
Linear (2+2+2)	01	1	4	3	2	6	5	2	0.667	0.947
		2	4	1	7	28	15	2	0.087	0.315
		3	4	28	9	1	14	2	0.0029	0.258
		4	4	16	23	3	22	2	0.0014	0.136
		5	4	11	12	20	7	1	0.0014	0.112
	02	1	3	2	1	3	.	2	0.908	1.423
		2	4	16	1	2	7	2	0.113	0.299
		3	4	15	2	28	24	3	0.029	0.151
		4	4	5	15	20	24	3	0.010	0.068
		5	3	12	3	7	.	3	0.0092	0.056

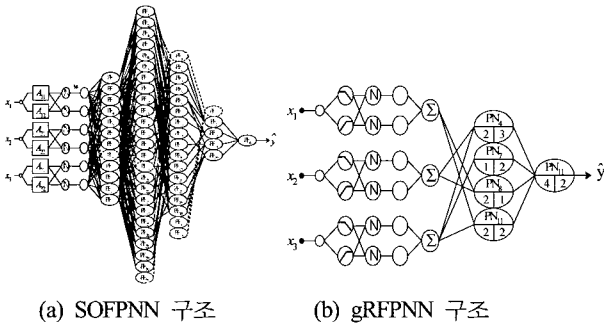


그림 5. 기존 SOFPNN[9]과 gRFPNN의 비교.
Fig. 5. Comparison of the gRFPNN and the previous SOFPNN[9].




그림 6. PN 노드의 구성.
Fig. 6. Formation of a PN node.




그림 7. 비선형 함수에 대한 gRFPNN의 최적 구조.
Fig. 7. Optimal topology of gRFPNN for the nonlinear function.

조의 성능지수는 PI=5.217, E_PI=5.142, 선형 퍼지추론 구조는 PI=2.929, E_PI=3.45이다. 결과에서 보여지는 것처럼 제안된 gRFPNN 구조는 전반부 FS_FNN의 성능을 개선하였고, 선형 퍼지추론 및 CP02의 연결점에서 보다 나은 출력특성을 얻을 수 있었다. 또한 후반부 층이 증가할수록 모델의 근사화와 일반화 능력이 향상되고 있음을 알 수 있다.

표 3. 기존 모델방법과의 동정오차 비교.

Table3. Comparison of performance with other modeling methods.

Model	PI	E PI	No. of rules	
Linear model[21]	12.7	11.1		
GMDH[21]	4.7	5.7		
Sugeno's [3,21]	Fuzzy I	1.5	2.1	3
	Fuzzy II	1.1	3.6	4
Shin-ichi's FNN[8]	Type 1	0.84	1.22	8(23)
	Type 2	0.73	1.28	4(22)
	Type 3	0.63	1.25	8(23)
FNN[14]	Simplified	2.865	3.206	9(3+3+3)
	Linear	2.670	3.063	9(3+3+3)
Multi-FNN [14]	Simplified	0.865	0.956	9(3+3+3)
	Linear	0.174	0.689	9(3+3+3)
SOFPNN[9]	BFPNN	0.299	0.555	6 rules/5 th layer
	MFPNN	0.116	0.360	8 rules/5 th layer
The proposed gRFPNN	Simplified	0.299	0.517	6 rules/2 th layer
		0.299	0.398	6 rules/5 th layer
	Linear	0.113	0.299	6 rules/2 th layer
		0.0092	0.056	6 rules/5 th layer

표 4. GAs와 gRFPNN의 관련 정보.

Table4. Information related to GAs and gRFPNN.

GAs	Generation		150	
	Population size		60	
	Elite population size(W)		30	
	String length		3+3+24	
gRFPNN	Premise (FS_FNN)	No. of entire inputs		2
		Iteration		300
		Learning rate	Simplified	0.0014
			Linear	0.0052
		Momentum coefficient	Simplified	0.0002
			Linear	0.0004
	No. of rules		4	
	Consequence (gPNN)	No. of entire inputs	CP01	4
			CP02	2
		Layer		5
No. of inputs to be selected(N)		1 ≤ N ≤ 4		
Type(T)		1 ≤ T ≤ 3		

N, T : integer

따라서 구조의 복잡성과 모델의 성능 등을 고려하여 적절한 층을 선택하도록 한다. 그림 5는 비슷한 성능지수 값에 대해 기존에 제시된 SOFPNN 구조와 본 연구에서 제안된 방법론에 의해 설계되어진 gRFPNN 구조를 비교하여 보여주고 있다. 여기서 두 방법론에 의한 구조는 전반부에 같은 구조인 FS_FNN을 이용하였다. SOFPNN의 후반부 구조는 하나의 PN이 4 입력 Type 2로 고정된 구조로 PNN의 설계 방법에 따라 구축되었으며, 이때 PI=0.299, E_PI=0.555 이다[9]. 제안된 gRFPNN은 gPNN의 방법론에 의해 설계되진다. 이때 PI=0.299, E_PI=0.517 이다. 두 구조의 비교로부터 알 수 있듯이 성능 면에서는 비슷한 결과를 가지고 있

나, 구조적인 측면에서는 제안된 gRFPNN이 훨씬 간결한 구조를 보여준다. 그림 5 (b)에서 각 층을 이루는 PN은 그림 6과 같이 표현된다. 여기서 PNn은 각 층을 구성하고 있는 n 번째 PN 노드, N은 PNn으로 들어오는 입력 수, T는 PNn의 다항식 차수를 나타낸다. 그림 7은 선형 퍼지추론구조의 FS_FNN과 gPNN이 CP02에서 결합된 최적의 gRFPNN 구조를 보여준다. 그림 7(a)는 후반부 2층에서 최적 PN을 선택하였을 때, (b)는 5층에서 최적 모델을 선택하였을 때의 구조이다. 이처럼 구조의 복잡성과 모델의 성능 등을 고려하여 적절한 층을 선택할 수 있다. 표 3은 3입력 1출력의 비선형함수에 적용한 기존의 모델과 본 연구에서 제시한 모델과의 성능을 비교하여 보여준다. 여기서 Sugeno의 퍼지모델 I, II는 다차원 추론방식에 기초한 퍼지모델이고 Shin-ichi의 모델은 신경회로망의 학습기능을 이용하여 퍼지규칙을 동정한 방법이다. Multi-FNN은 클러스터를 이용한 구조로 3개의 FNN으로 구성된다. SOFPNN의 BFPNN의 모델은 그림 5(a)와 같이 전반부는 6개의 퍼지규칙으로 구성되며, 후반부를 구성하는 다항식이 4 입력 Type 2로 고정되어있다. MFNN은 전반부가 퍼지관계에 의해 구현되며, 후반부는 4입력 Type 3로 구성된다. 결과에서 보여지는 것처럼 제안된 구조들에서 좋은 출력특성을 얻을 수 있으며, 근사화 및 일반화 능력이 우수함을 알 수 있다.

2. 가스로 공정

Box와 Jenkin[13]이 사용한 가스로 시계열 데이터를 이용하여 입출력 데이터인 가스 흐름율(u(t))과 연소된 이산화탄소 농도(y(t))를 모델 동정에 이용한다.




그림 8. gRFPNN의 최적 구조.
Fig. 8. Optimal topology of gRFPNN.

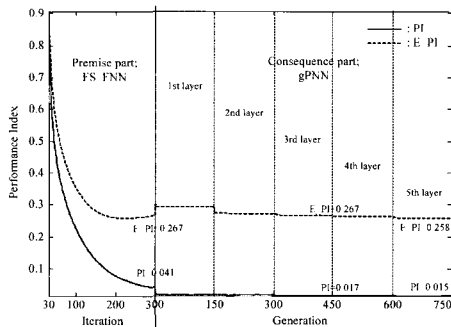


그림 9. gRFPNN의 최적화 과정.
Fig. 9. Optimization procedure of gRFPNN.

표 5. 가스로 공정에 대한 gRFPNN의 성능지수.

Table5. Performance index of gRFPNN for the gas furnace.

Premise part	CP	Consequence part						PI	E_P I	
		Ly	NI	Input No.		Ty				
4 (2+2)	01	1	2	3	1	·	·	3	0.025	0.328
		2	4	24	11	30	18	2	0.024	0.269
		3	3	9	10	23	·	2	0.020	0.265
		4	4	7	13	27	20	2	0.019	0.262
		5	3	1	10	7	·	2	0.018	0.254
	02	1	2	1	2	·	·	3	0.024	0.328
		2	4	1	4	5	7	3	0.021	0.282
		3	3	29	27	26	·	2	0.020	0.270
		4	3	15	13	21	·	3	0.019	0.268
		5	4	8	4	20	13	2	0.018	0.265
4 (2+2)	01	1	4	4	2	1	3	3	0.019	0.292
		2	4	7	12	2	10	2	0.018	0.271
		3	4	20	21	5	3	2	0.017	0.267
		4	3	22	13	29	·	2	0.016	0.263
		5	4	25	18	27	9	3	0.015	0.258
	02	1	2	1	2	·	·	3	0.027	0.310
		2	3	4	6	5	·	2	0.021	0.279
		3	4	6	14	7	1	2	0.018	0.270
		4	3	15	3	2	·	2	0.018	0.263
		5	3	16	6	14	·	2	0.016	0.259

표 6. 기존 모델방법과의 동정오차 비교.

Table6. Comparison of performance with other modeling methods.

Model		PI	E-PI	No. of rules	
Kim, et al.[15]		0.034	0.244	2	
Lin and Cunningham[16]		0.071	0.261	4	
Fuzzy	GAs[23]	Simplified	0.023	0.344	4(2×2)
		Linear	0.018	0.264	4(2×2)
	Complex [4]	Simplified	0.024	0.328	4(2×2)
		Linear	0.023	0.306	4(2×2)
	Hybrid[6]	Simplified	0.024	0.329	4(2×2)
		Linear	0.017	0.289	4(2×2)
	HCM+GAs [5]	Simplified	0.035	0.289	4(2×2)
			0.022	0.333	6(3×2)
0.026			0.272	4(2×2)	
Linear	0.020	0.264	6(3×2)		
	Neural Networks[5]		0.034	4.997	
FNN[17]	Simplified	0.043	0.264	6(3+3)	
	Linear	0.037	0.273	6(3+3)	
Multi-FNN[24]	Simplified	0.025	0.274	6(3+3)	
	Linear	0.024	0.283	6(3+3)	
SOFPNN	Generic[19]	0.017	0.250	4 rules/5 th layer	
	Advanced[20]	0.019	0.264	6 rules/5 th layer	
The proposed gRFPNN	Simplified	0.018	0.254	4 rules/5 th layer	
		0.018	0.112	6 rules/5 th layer	
	Linear	0.015	0.258	4 rules/5 th layer	
		0.018	0.110	6 rules/5 th layer	

$$PI = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (9)$$

2입력 1출력 $(u(t-3), y(t-1); y(t))$ 의 구조를 가진 가스로 시계열 데이터를 이용하여, 최적의 gRFPNN을 구축한다. 이를 위한 GAs 정보 및 설계정보는 표 4와 같다. gRFPNN 구조의 전반부에 적용된 간략 및 선형 퍼지추론 구조는 각각 $PI=0.035$, $E_PI=0.281$ 및 $PI=0.041$, $E_PI=0.267$ 의 근사화 및 일반화 성능을 가진다. 표 5는 표 4의 설계정보에 의한 gRFPNN 구조의 성능지수를 나타낸다. 앞의 실험예제들과 마찬가지로 전반부에 선형 퍼지추론의 FS_FNN을 이용한 구조에서 좀더 나은 출력결과를 얻을 수 있다. 또한 후반부 층의 적절한 선택에 따라 성능과 복잡성을 고려한 최적의 네트워크 구조를 구축할 수 있다. 표 5로부터 선택된 구조의 gRFPNN은 그림 8의 네트워크 구조로 형성되며, 이때 모델의 최적화 과정(학습과정)은 그림 9에 보였다.

표 6에서 기존의 모델과 제안된 모델의 성능지수를 비교하였다. 퍼지모델은 GAs를 이용한 동정, 기하학적 방법인 Complex를 이용한 동정, 하이브리드 동정(GAs+ Complex), HCM과 GAs를 이용한 동정 등 멤버쉽함수의 파라미터 동정과 관계된다. FNN은 하이브리드 알고리즘을 이용하여, 멤버쉽함수의 파라미터를 동조한 구조이며, Multi-FNN은 클러스터를 이용한 구조로 4개의 FNN으로 구성된다.

SOFNN 구조는 Generic과 Advanced의 구조로 설계되며, 각각 2입력($u(t-3), y(t-1)$)과 3입력($u(t-2), y(t-2), y(t-1)$)의 시스템 입력을 다루고 있다. 2입력은 4개의 퍼지규칙으로, 3입력은 6개의 퍼지규칙으로 구성된다. Generic type은 후반부 구조인 PNN의 특성상 전반부 구조와 CP01의 연결만이 고려되며, 이의 개선을 위해 Advanced type을 제시하였고 CP02와의 연결구조를 다루었다. 그러나 제안된 방법은 앞의 결과에서 보여지듯이 시스템 입력구조의 제약을 받지 않으며, 적은 입력변수에서 좋은 출력특성을 보여준다. 표 6의 결과로부터 제안된 모델은 2입력 및 3입력의 시스템 입력을 가지는 다른 모델보다 향상된 학습 및 테스트 성능을 가진다.

3. 가스 터빈 발전소의 NOx 배출공정

대기상 질소산화물(NOx)은 주로 연소공정을 통해 배출되며 산업공정, 발전소, 자동차 배기가스, 난방 등에 의해서 발생된다. 그 중 대기에서 문제가 될 만큼 존재하는 것들은 N_2O , NO 및 NO_2 이고 이들 물질을 대기오염 측면에서 NOx(질소 산화물)로 일컫는다.

NOx의 저감방법으로는 발생원으로부터 NOx의 배출을 억제하는 방법과 배출가스중의 NOx를 제거하는 방법을 들 수 있는데, 최근에는 Gas Turbine에 사용하는 주변 환경변수를 입력변수, 출력변수는 NOx양으로 배출 메커니즘을 모델링하고, 최적 모델을 구축하여 시뮬레이터를 구성함으로써 NOx를 효과적으로 관리하는 방법이 연구되고 있다.

본 연구에서는 이러한 입출력 변수들을 이용하여 제안된 모델의 성능을 평가한다. 평가를 위해 전체 260개의 데이터를 랜덤하게 130개씩 선택하여 학습데이터와 테스트 데이터로 사용하며, 모델의 근사화와 일반화 성능을 얻는다. 근사화와 일반화 능력을 측정하는 성능지수는 (9)와 같다.

표 7. GAs와 gRFPNN의 관련 정보.

Table 7. Information related to GAs and gRFPNN.

GAs	Generation		150	
	Population size		100	
	Elite population size		50	
	String length		CP01 3+3+70 CP02 3+3+35	
gRFPNN	Premise (FS_FNN)	No. of entire inputs		5
		Iteration		1000
		Learning rate	Simplified	0.052
			Linear	0.034
		Momentum coefficient	Simplified	0.010
	Linear		0.001	
	No. of rules		10	
	Consequence (gPNN)	No. of entire inputs		CP01 10 CP02 5
		Layer		5
		No. of inputs to be selected(N)	CP01	$1 \leq N \leq 10$
CP02			$1 \leq N \leq 5$	
Type(T)		$1 \leq T \leq 3$		

N, T : integer

표 8. NOx 공정에 대한 gRFPNN의 성능지수.

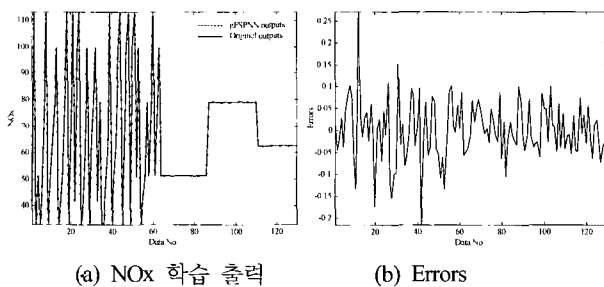
Table 8. Performance index of gRFPNN for the NOx emission process.

Premise part		CP	Consequence part			PI	E_PI
FI	NR(MFs)		Ly	Nl	Ty		
10	(2+2+2+2+2)	01	1	7	2	0.916	2.014
			2	6	2	0.623	1.430
			3	9	1	0.477	1.212
			4	10	1	0.386	1.077
			5	4	2	0.337	1.016
		02	1	5	2	1.072	2.220
			2	5	2	0.176	0.291
			3	5	3	0.105	0.168
			4	3	2	0.060	0.113
			5	4	2	0.049	0.081
10	(2+2+2+2+2)	01	1	9	2	0.023	0.137
			2	5	2	0.0095	0.044
			3	9	1	0.0057	0.029
			4	2	2	0.0057	0.027
			5	9	1	0.0045	0.026
		02	1	5	2	2.117	4.426
			2	5	2	0.875	1.647
			3	5	2	0.550	1.144
			4	5	3	0.390	0.793
			5	3	2	0.340	0.680

표 7의 설계정보와 GAs의 염색체 정보로부터 가스터빈 발전소의 NOx 배출공정에 적합한 gRFPNN 구조를 구축한다. gRFPNN의 후반부 구조는 전반부와 연결점에 따라 PN의 입력 수를 달리하였다. 즉 후반부 입력변수의 수에 대해 CP01과의 연결에 의한 PN은 $1 \leq N \leq 10$, CP02는 $1 \leq N \leq 5$ 의 입력을 선택하도록 하였다. 표 8은 표 7을 바탕으로 생성된 gRFPNN의 성능지수를 나타낸다. 전반부 구조로 적용된 간략 퍼지추론의 경우 $PI=22.331$, $E_PI=19.783$, 선형추론은 $PI=8.054$, $E_PI=12.147$ 의 성능지수를 가진다. 결과에서 보여지는 것과 같이 전반부 FS_FNN의 성능을 개선할 뿐만

아니라 PNN 구조를 최적화시킨다. 제안된 구조는 전반부에 선형 퍼지추론을 적용한 구조에서 월등한 성능향상을 보이며, 간략 퍼지추론은 02, 선형 퍼지추론은 01의 연결점에서 좋은 출력특성을 가진다. 그림 10(a)는 학습 데이터에 대한 gRFPNN의 출력과 원 출력을 비교하여 보여주며 그때 모델 오차는 그림 10(b)와 같다. 그림 11은 테스트 데이터에 대한 모델출력과 오차이다. 모델 출력은 전체(학습 및 테스트) 데이터에 대해 ± 0.5 의 오차를 가진다.

표 9는 가스터빈 발전소의 NOx 배출공정에 적용된 기존의 모델들과 성능지수를 비교하여 보여준다. Ahn의 모델은 전체 데이터를 이용하여 PI만을 고려한 값이다.

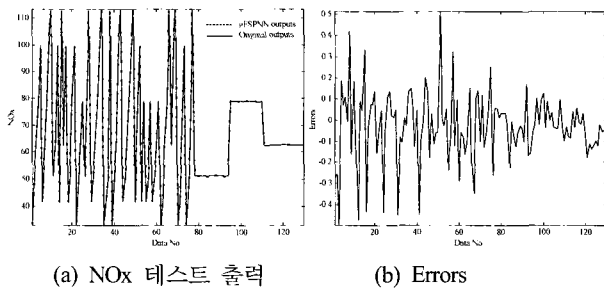


(a) NOx 학습 출력

(b) Errors

그림 10. 학습 데이터에 대한 gRFPNN의 출력과 오차.

Fig. 10. Output and errors of gRFPNN for learning dataset.



(a) NOx 테스트 출력

(b) Errors

그림 11. 테스트 데이터에 대한 gRFPNN의 출력과 오차.

Fig. 11. Output and errors of gRFPNN for testing dataset.

표 9. 기존 모델방법과의 동정오차 비교.

Table 9. Comparison of performance with other modeling methods.

Model	PI	E.PI	No. of rules	
Regression model[17]	17.68	19.23		
Ahn's[22]	FNN	5.835		
	AIM	8.420		
FNN[17]	Simplified	6.269	8.778	
	Linear	3.725	5.291	
Multi FNN[14]	Simplified	2.806	5.164	
	Linear	0.720	2.025	
The proposed gRFPNN	Simplified	0.176	0.291	10 rules/2th layer
		0.049	0.081	10 rules/5th layer
	Linear	0.0095	0.044	10 rules/2th layer
		0.0045	0.026	10 rules/5th layer

FNN은 GAs와 개선된 complex 알고리즘의 결합에 의한 하이브리드 알고리즘을 이용하여, 멤버쉽함수의 파라미터를 동조한 구조이며, Multi-FNN은 클러스터를 이용한 구조로 4개의 FNN으로 구성된다. 제안된 gRFPNN 구조는 전반부와 후반부와의 상호결합을 통해 각 구조의 단점을 보완하고 성능을 개선함으로써 다른 모델보다 좋은 출력특성을 가지게 된다. 또한 GAs에 의한 구조 최적화는 좀 더 효율적이고, 객관적인 그리고 대상 공정에 대해 적용할 수 있는 유연한 구조를 설계할 수 있도록 해주며, 우수한 근사화 및 예측성능을 가지는 모델을 제공한다.

V. 결론

본 연구는 CI 기술의 한 영역으로써 효과적인 비선형 문제의 해석 및 해결을 위한 고급 CI 기술인 진화론적 최적 규칙베이스 퍼지다항식 뉴럴네트워크(Genetically optimized Rule-based Fuzzy Polynomial Neural Networks; gRFPNN)의 구조 개발과 광범위한 설계방법론을 토의하였다. 제안된 gRFPNN은 유전자 알고리즘(GAs)을 기반으로, 퍼지집합 기반 퍼지뉴럴네트워크(FS_FNN), 자기구성 다항식뉴럴네트워크(PNN)와의 결합(Combination)에 의해 설계되는 합성 구조이다. gRFPNN은 GAs를 이용하여 후반부 구조인 PNN의 구조를 최적화하고 뉴런을 생성함으로써 유연성과 정확성을 가지도록 설계된 구조이다. 기존의 SOFNN은 설계자가 네트워크를 구성하는 PN의 입력변수 수, 다항식 차수 등을 경험에 의해 결정해야만 하였다. 따라서, 객관적이고 주어진 문제의 특성에 맞는 모델을 설계하지 못하였고, 최적의 모델 구축을 위해 많은 시행착오를 필요로 하였다. 그러나 제안된 gRFPNN은 GAs의 탐색체 정보를 이용하여 PN의 입력 변수 수, 입력변수, 다항식 차수를 결정함으로써 유연성과 정확성을 가진 적용 모델을 설계할 수 있었다. 따라서 제안된 gRFPNN의 구조는 시스템 환경의 변화에 적응하고 진화하며, 근사화와 예측(일반화) 능력이 우수한 특징을 가진다.

참고문헌

- [1] W. Pedrycz and J. F. Peters, *Computational Intelligence and Software Engineering*, World Scientific, Singapore, 1998.
- [2] K. S. Narendra and K. Parthasarathy, "Gradient methods for the optimization of dynamical systems containing neural networks," *IEEE Transactions on Neural Networks*, vol. 2, pp. 252-262, 1991.
- [3] G. Kang and M. Sugeno, "Fuzzy modeling," *Transactions of the Society of Instrument and Control Engineers*, vol. 23, no. 6, pp. 106-108, 1987.
- [4] S. K. Oh and W. Pedrycz, "Fuzzy identification by means of auto-tuning algorithm and its application to nonlinear systems," *Fuzzy Sets and Systems*, vol. 115, no. 2, pp. 205-230, 2000.
- [5] B. J. Park, W. Pedrycz and S. K. Oh, "Identification of fuzzy models with the Aid of evolutionary data granulation," *IEE Proc. -Control theory and application*,

- vol. 148, Issue 5, pp. 406-418, 2001.
- [6] S. K. Oh, W. Pedrycz and B. J. Park, "Hybrid identification of fuzzy rule-based models," *International Journal of Intelligent Systems*, vol. 17, Issue 1, pp. 77-103, 2002.
- [7] Z. Michalewicz, *Genetic Algorithms + Data Structure = Evolution Programs*, Springer-Verlag, 1992.
- [8] S. I. Horikawa, T. Furuhashi and Y. Uchigawa, "On fuzzy modeling using fuzzy neural networks with the back propagation algorithm," *IEEE Transactions on Neural Networks*, vol. 3, no. 5, pp. 801-806, 1992.
- [9] B. J. Park, W. Pedrycz and S. K. Oh, "Fuzzy polynomial neural networks: hybrid architectures of fuzzy modeling," *IEEE Trans. on Fuzzy Systems*, vol. 10, Issue 5, pp. 607-621, 2002.
- [10] S. K. Oh, W. Pedrycz and B. J. Park, "Self-organizing neurofuzzy networks based on evolutionary fuzzy granulation," *IEEE Trans. on Systems, Man and Cybernetics-part A*, vol. 33, no. 2, pp. 271-277, 2003.
- [11] S. K. Oh, W. Pedrycz and B. J. Park, "Polynomial neural networks architecture: analysis and design," *Computers and Electrical Engineering*, vol. 29, Issue 6, pp. 653-725, 2003.
- [12] A. G. Ivakhnenko, "The group method of data handling: a rival of method of stochastic approximation," *Soviet Automatic Control*, vol. 1, no. 3, pp. 43-55, 1968.
- [13] D. E. Box and G. M. Jenkins, *Time Series Analysis, Forecasting and Control*, California: Holden Day, 1976.
- [14] H. S. Park and S. K. Oh, "Multi-FNN identification based on HCM clustering and evolutionary fuzzy granulation," *International Journal of Control, Automation and Systems*, vol. 1, no. 2, pp. 194-202, 2003.
- [15] E. Kim, H. Lee, M. Park and M. Park, "A simply identified sugeno-type fuzzy model via double clustering," *Information Sciences*, vol. 110, pp. 25-39, 1998.
- [16] Y. Lin, G. A. Cunningham III, "A new approach to fuzzy-neural modeling," *IEEE Transaction on Fuzzy Systems*, vol. 3, no. 2, pp. 190-197, 1997.
- [17] S. K. Oh, W. Pedrycz and H. S. Park, "Hybrid identification in fuzzy-neural networks," *Fuzzy Sets and Systems*, vol. 138, pp. 399-426, 2003.
- [18] 오성권, 프로그래밍에 의한 컴퓨터지능(퍼지, 신경회로망 및 진화알고리즘을 중심으로), 내하출판사, 2002.
- [19] 박병준, 오성권, 장성환, "퍼지뉴럴 네트워크와 자기구성 네트워크에 기초한 적응 퍼지 다항식 뉴럴네트워크 구조의 설계", 제어자동화시스템공학 논문지, 8권, 2호, pp. 126-135, 2002.
- [20] 박병준, 오성권, "고급 뉴로퍼지 다항식 네트워크의 해석과 설계", 대한전자공학회 논문지, 39권, CI편, 3호, pp. 18-31, 2002.
- [21] 菅野道夫(譯:박민용,최항식), 퍼지제어 시스템, pp. 143-158, 대영사, 1990.
- [22] 안태천, 오성권, "발전소의 대기오염물질 배출패턴 모델정립", 기초전력공학 공동연구소, 1997.
- [23] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하중값을 이용한 퍼지시스템의 최적화", 대한전기학회 논문지, 48A권, 6호, pp. 789-799, 1999.
- [24] 박호성, 오성권, "HCM 클러스터링에 의한 다중 퍼지 뉴럴 네트워크 동정과 유전자 알고리즘을 이용한 이의 최적화", 한국 퍼지 및 지능 시스템 학회 논문지, 10권, 5호, pp. 487-496, 2000.




박 병 준

1998년 원광대 제어계측공학과 졸업. 동대학원 석사(2000). 동대학원 전기공학과 박사(2003). 관심분야는 CI, 뉴로 퍼지컴퓨팅, 퍼지이론, 하이브리드 시스템, 유전알고리즘, 지능형 모델링 및 제어 등.



김 현 기

1977년 연세대 전기공학과 졸업. 동대학원 석사(1985). 동대학원 박사(1991). 1989년~현재 수원대 전기공학과 교수. 2001년~현재 한국산학연 논문집 편집위원장. 2004년~현재 한국산학연 기술학회 부회장. 관심분야는 뉴로퍼지컴퓨팅, 퍼지이론, 유전알고리즘, 지능형 모델링 및 제어, 자동화시스템 등.



오 성 권

1981년 연세대 전기공학과 졸업. 동대학원 석사(1983). 동대학원 박사(1993). 1993년~현재 원광대 전기전자및정보공학부 교수. 2002년~현재 대한전기학회 및 제어자동화시스템공학회 편집위원. 관심분야는 CI, 뉴로퍼지컴퓨팅, 퍼지이론, 하이브리드 시스템, 유전알고리즘, 지능형 모델링 및 제어 등.