

퍼지뉴럴 네트워크와 자기구성 네트워크에 기초한 적응 퍼지 다항식 뉴럴네트워크 구조의 설계

The Design of Adaptive Fuzzy Polynomial Neural Networks Architectures Based on Fuzzy Neural Networks and Self-Organizing Networks

박 병 준, 오 성 권, 장 성 환

(Byoung-Jun Park, Sung-Kwun Oh, and Sung-Whan Jang)

Abstract : The study is concerned with an approach to the design of new architectures of fuzzy neural networks and the discussion of comprehensive design methodology supporting their development. We propose an Adaptive Fuzzy Polynomial Neural Networks(APFNN) based on Fuzzy Neural Networks(FNN) and Self-organizing Networks(SON) for model identification of complex and nonlinear systems. The proposed AFPNN is generated from the mutually combined structure of both FNN and SON. The one and the other are considered as the premise and the consequence part of AFPNN, respectively. As the premise structure of AFPNN, FNN uses both the simplified fuzzy inference and error back-propagation learning rule. The parameters of FNN are refined(optimized) using genetic algorithms(GAs). As the consequence structure of AFPNN, SON is realized by a polynomial type of mapping(linear, quadratic and modified quadratic) between input and output variables. In this study, we introduce two kinds of AFPNN architectures, namely the basic and the modified one. The basic and the modified architectures depend on the number of input variables and the order of polynomial in each layer of consequence structure. Owing to the specific features of two combined architectures, it is possible to consider the nonlinear characteristics of process system and to obtain the better output performance with superb predictive ability. The availability and feasibility of the AFPNN are discussed and illustrated with the aid of two representative numerical examples. The results show that the proposed AFPNN can produce the model with higher accuracy and predictive ability than any other method presented previously.

Keywords : adaptive fuzzy polynomial neural networks(APFNN), fuzzy neural networks(FNN), self-organizing networks(SON), group method of data handling(GMDH), genetic algorithms(GAs), design methodology

I. 서론

최근 시스템 모델링의 문제는 최적화 기술과 함께 다양한 영역에서 연구되고 있다. 이들 중 선형 또는 비선형 미분 방정식에 기반을 둔 정량적인 수학적 모델과 인공지능의 영역에서 나타나는 정성적 특징을 가진 지능형 모델은 시스템 모델링을 위한 대표적인 기술이다. 시스템 모델링과 동정의 근본적인 목적은 물리적 현상의 특징을 적절하게 반영할 수 있는 모델을 개발하는 것이다. 이를 위해 실험 데이터를 바탕으로 모델링 기술은 적용된다. 기존 모델링의 대부분은 미분 또는 차분 방정식의 언어에서 표현되어진 선형 또는 비선형 함수의 형태로 수학적 모델을 이끌어 냈다. 그러나 정교한 수학적 모델이 거의 완벽하게 시스템을 표현할 수 있다하더라도 그것은 시스템 동작과 변수 사이의 종속관계에 대한 원하는 정보를 제공하지 못한다. 또한 모델링을 하고자 하는 시스템이 복잡하고, 대규모 구조인 경우는 함수식으로 모델의 표현이 한정되지 않기 때문에 적용하기가 어렵다. 이러한 문제와 어려움을 해결하기 위해 퍼지 모델, 신경회로망과 같은 지능형 모델에 관한 연구가 진행되었으며

최근에는 퍼지 모델과 신경회로망이 가지고 있는 독특한 특성을 살리면서 지능 모델의 효율과 성능향상을 위한 두 모델의 융합에 관한 연구가 여러 가지 각도에서 다양하게 제시되고 있다[1]-[9]. Takagi, Hayashi[1]는 신경회로망으로 구동되는 퍼지추론을 제안하였으나 입출력 수가 적은 경우는 그 효과가 미미하고, 전반부가 신경회로망이라는 특성화된 함수로 구성되어 기존의 퍼지추론보다 시스템 표현에 있어서 정성적으로 이해하기가 힘들다는 단점을 가지고 있다. Horikawa[2]는 퍼지-뉴럴네트워크에 의한 합성방법과 동정에 관한 연구를 하였다. 그러나 퍼지규칙의 전반부인 시그모이드 형태의 멤버쉽함수 초기치 설정이 어렵고, 최적 성능으로의 수렴특성이 나쁘다. Imasaki[3]는 퍼지규칙이 전반부 네트워크, 추론 네트워크, 후반부 네트워크로 구조화된 신경회로망을 제안하였으며, 이는 추론 네트워크의 추가로 인한 오랜 학습 시간과 동조의 난점을 가지고 있다. 또한 입출력 증가에 따른 네트워크 구성시 경험적인 방법을 많이 요구한다. Nomura[4]는 멜타규칙에 의한 퍼지 추론의 자동 동조 방법을 제안하였다. 그러나 이것은 학습에 의한 동조로 각 규칙마다 멤버쉽함수가 변형됨에 따라 퍼지규칙 수가 증가하며, 입출력의 증가는 더 많은 퍼지규칙 수를 요구한다. Oh[5][6]는 다항식 뉴럴네트워크로써 고차 다변수 입력에 의한 다양한 구조의 자기 구성 네트워크를 설계하였으나

입출력 변수에 의한 공간분할의 효과적 이용과 제한된 입력 변수의 선택에 따른 많은 어려움이 따른다.

본 논문은 복잡한 비선형 시스템의 모델동정을 위하여 퍼지 뉴럴네트워크(Fuzzy Neural Networks:FNN)와 자기구성 네트워크(Self-Organizing Networks:SON)를 기반으로 한 적응 퍼지 다항식 뉴럴네트워크(Adaptive Fuzzy Polynomial Neural Networks:AFPNN)를 제안한다. 제안된 AFPNN은 FNN과 SON의 상호 결합된 구조로 지능형 모델과 수학적 모델의 합성 구조라 할 수 있다. FNN은 AFPNN 구조의 전반부를, SON은 후반부를 구성한다. AFPNN의 전반부 구조인 FNN은 Yamakawa가 제안한 구조[7][8]로, 다른 비선형 모델에 비해서 학습속도가 빠르고 수렴특성이 우수하다는 장점을 가졌으며 간략추론, 오류역전파 학습 규칙을 이용한다. 멤버쉽함수의 파라미터, 학습률, 모멘텀 계수 등과 같은 FNN의 파라미터는 유전자 알고리즘에 의해 최적화된다. AFPNN의 후반부 구조로 이용된 SON은 수학적인 형태로 표현되며 GMDH(Group Method of Data Handling)에 기반한다. A. G. Ivakhnenko가 제안한 GMDH[10]는 입력변수의 선택과 입출력 데이터의 분할, 2변수 2차식의 부분표현식에 의해 시스템 방정식을 예측하였다. 그러나 2변수의 입력변수는 입력변수들 사이의 상호의존적인 면을 약하게 하였으며, 2차식으로 모든 경우를 표현함으로써 해당 공정모델의 적응력을 감소시켰다. SON은 이러한 문제를 해결하였고, 뿐만 아니라 학습을 통해 발전하는 유연한 구조로 SON의 층과 노드 수는 고정되어 있지 않고 생성 및 소멸한다. SON의 각 노드는 높은 유연성을 보여주며, 입력과 출력 변수 사이의 회귀다항식(1차식, 2차식, 변형된 2차식) 함수에 의해 구현된다. 이것은 공정 모델 특성과 계층구조의 간략성 및 상호 연계성 고려로부터 고차 회귀다항식 사용이 용이하고 간단한 구조로 설계됨을 알 수 있다. 제안된 AFPNN은 FNN과 SON의 장점을 가지며 상호 보완의 특성을 가진다. 즉 위에서 언급한 FNN과 SON의 특성을 모두 나타내며, 전반부 FNN 사용은 구조의 특성상 4입력 이상의 시스템 입력변수를 요구하는 SON의 단점을 보완함으로써 적은 입력변수를 가진 시스템에 대해서도 SON의 다양한 구조 적용이 용이하다. 또한 후반부에 SON을 사용함으로써 FNN의 학습방법인 오류역전파 학습방법을 도와 좀 더 좋은 성능을 나타낸다. 두 종류의 AFPNN 구조는 후반부 SON 구조의 기본 구조와 변형된 구조로부터 결정된다. 이 구조는 후반부 SON 구조의 각 층에서 입력변수의 수와 회귀다항식의 차수에 의존한다. 두 결합 구조의 특징은 공정의 비선형적인 특성을 고려할 수 있도록 하고 보다 우수한 예측능력을 가진 좋은 출력성능을 얻을 수 있게 한다. 모델의 성능평가를 위해 비선형 함수[11]-[14]와 가스로 공정[15]-[19]를 이용하여 제안된 모델의 유용성과 실용성을 논의하며 기존의 모델보다 높은 정밀도와 예측능력을 가진 모델을 생성함을 보인다. 또한 기존의 학습용 데이터뿐만 아니라 평가용 데이터를 이용한 모델의 성능, 즉 예측능력과 일반화 능력 모두를 고려하여 실 공정 적용의 유용성을 검토한다.

II. 적응 퍼지 다항식 뉴럴네트워크(AFPNN) 구조

제안된 AFPNN 구조는 크게 기본 구조와 변형된 구조로

설계할 수 있다. 이 두 구조는 AFPNN의 후반부인 SON 구조의 해당 노드의 입력변수 수와 회귀다항식 차수에 의해 결정된다.

1. FNN : AFPNN의 전반부 구조

본 논문에서는 제안된 AFPNN의 전반부 구조로 FNN을 이용한다. FNN은 퍼지추론과 신경회로망의 유사성과 상호보완관계를 이용한 구조로 본 논문에서 이용된 FNN[7][8]은 다른 모델에 비해 학습속도가 빠르고 수렴특성이 매우 우수하다는 장점을 가지며 그림 1과 같은 구조를 가진다.

그림 1에서 x_i 의 각 입력신호는 각 멤버쉽함수를 거쳐 적합도가 구해지고 적합도는 연결 가중치와 곱해지며 이들이 대수적으로 합해져 i 번째 출력 $f_i(x_i)$ 를 생성한다. 생성된 출력 값은 (1)과 같이 모두 대수적으로 합해져 \hat{y} 를 최종적으로 출력하게 된다.

$$\hat{y} = f_1(x_1) + f_2(x_2) + \dots + f_m(x_m) = \sum_{i=1}^m f_i(x_i) \quad (1)$$

여기서, m 은 입력변수 수이다. 입력 x_i 에 대한 f_i 는 퍼지규칙을 이루고 있으며 그 규칙은 (2)와 같다.

$$\begin{aligned} R^1 : & \text{If } x_i \text{ is } A_{i1} \text{ Then } y_{i1} = w_{i1} \\ & \vdots \\ R^j : & \text{If } x_i \text{ is } A_{ij} \text{ Then } y_{ij} = w_{ij} \\ & \vdots \\ R^n : & \text{If } x_i \text{ is } A_{in} \text{ Then } y_{in} = w_{in} \end{aligned} \quad (2)$$

(2)에서 R_j 는 j 번째 퍼지규칙을 나타내며, A_{ij} 는 전반부의 퍼지변수이다. 후반부의 w_{ij} 는 상수이며, 그림 1의 연결 가중치를 나타낸다. 퍼지추론의 전반부 멤버쉽함수는 보수적(complementary)인 관계를 가진 삼각형 형태이다. (2)의 최종 추론 결과는 (3)의 무게 중심법(center of gravity)에 의해 표현된다.

$$f_i(x_i) = \frac{\sum_{j=1}^n \mu_{ij}(x_i) \cdot w_{ij}}{\sum_{j=1}^n \mu_{ij}(x_i)} \quad (3)$$

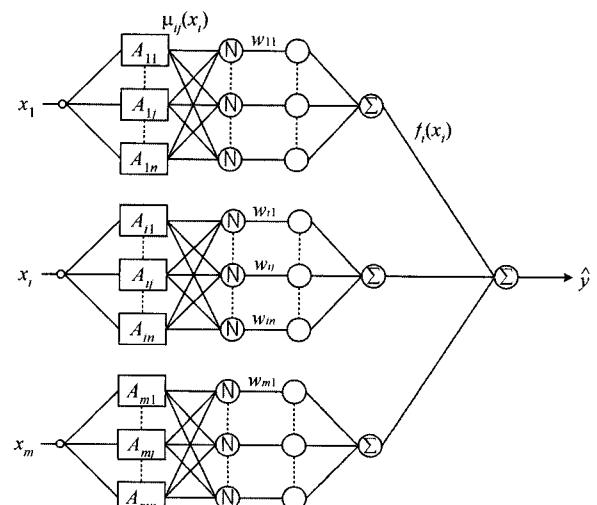


그림 1. AFPNN 구조의 전반부로서의 FNN.

Fig. 1. FNN used for the premise part of AFPNN architecture.

여기서, $\mu_{ij}(x_i)$ 는 입력 x_i 에 대한 전반부 적합도이다. 입력 변수 x_i 는 보수적인 특성에 의해 동시에 두 개의 멤버쉽함수 $j, j+1$ 에만 영향을 받기 때문에 (3)은 다음과 같이 다시 쓸 수 있다.

$$f_i(x_i) = \frac{\mu_{ij}(x_i) \cdot w_{ij} + \mu_{j+1}(x_i) \cdot w_{j+1}}{\mu_{ij}(x_i) + \mu_{j+1}(x_i)} \quad (4)$$

보수적 관계를 가지는 2개의 이웃하는 멤버쉽함수의 입력변수에 대한 적합도 합은 언제나 1이다. 즉 $\mu_{ij}(x_i) + \mu_{j+1}(x_i) = 1$. 따라서 (4)는 (5)와 같다.

$$f_i(x_i) = \mu_{ij}(x_i) \cdot w_{ij} + \mu_{j+1}(x_i) \cdot w_{j+1} \quad (5)$$

학습 알고리즘 : FNN의 학습은 그림 1의 멤버쉽함수 뒷부분에 위치한 연결 가중치를 모델에 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 신경회로망의 학습에 가장 일반적으로 사용되는 오류역전파 알고리즘이 사용되는데, 이는 실 출력과 모델 출력간의 차, 즉 오차를 이용한다. 즉, (6)과 같은 형태의 출력오차를 사용한다.

$$E_p = (y_p - \hat{y}_p)^2 \quad (6)$$

여기서, E_p 는 각 데이터에 대한 오차이고, y_p 는 주어진 출력데이터(목표값; target value or desired response), \hat{y}_p 는 모델의 출력(FNN의 실제 출력)을 나타낸다. N 개의 입력 출력 데이터 쌍이 주어진 경우, FNN의 최종 출력 오차는 (7)과 같다.

$$E = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (7)$$

연결 가중치의 조절은 (8)과 같이 기존의 값에 오차로부터 구해진 조절량 만큼의 변화를 더해주면 된다.

$$w_{ij}(new) = w_{ij}(old) + \Delta w_{ij} \quad (8)$$

오차 E_p 를 최소화하기 위한 연결 가중치의 변화량 Δw 는 (9)와 같이 경사하강법(Gradient Descent Method)을 이용하여 구할 수 있다.

$$\Delta w_{ij} = \eta \left(-\frac{\partial E_p}{\partial w_{ij}} \right) \quad (9)$$

여기서, η 는 학습률이다. (9)에서 우변의 편미분은 사슬법칙(chain rule)에 의해 (10)과 같이 세 부분으로 전개될 수 있다.

$$-\frac{\partial E_p}{\partial w_{ij}} = -\frac{\partial E_p}{\partial \hat{y}_p} \cdot \frac{\partial \hat{y}_p}{\partial f_i(x_i)} \cdot \frac{\partial f_i(x_i)}{\partial w_{ij}} \quad (10)$$

(10)에서 우측 식의 각 항은 다음 (11)-(13)과 같이 유도된다.

$$-\frac{\partial E_p}{\partial \hat{y}_p} = 2(y_p - \hat{y}_p) \quad (11)$$

$$\frac{\partial \hat{y}_p}{\partial f_i(x_i)} = 1 \quad (12)$$

$$\frac{\partial f_i(x_i)}{\partial w_{ij}} = \mu_{ij}(x_i) \quad (13)$$

그러므로 변화량 Δw_{ij} 는 (11)-(13)으로부터 (14)와 같다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) \quad (14)$$

여기에 모멘텀을 더해 학습시간을 좀더 단축시키고, 학습성능 역시 향상시킨다. 모멘텀은 관성이란 뜻으로, 연결 하중 계수의 변화량이 클 경우에는 좀더 변화량을 키워주고, 변화량이 작아지면 또 여기에 맞춰서 변화량을 줄여주는 역할을 한다. 모멘텀은 (15)와 같이 현재의 연결 가중치와 그 이전 연결하중의 차이에 의해 계산된다.

$$m(t) = w(t) - w(t-1) \quad (15)$$

이렇게 계산된 모멘텀은 모멘텀계수라 불리우는 α 와 곱해져 연결 가중치 조절식에 추가된다. 모멘텀까지 포함하는 연결 가중치 변화량은 (16)과 같다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (16)$$

본 논문에서는 FNN의 최적화를 위해 유전자 알고리즘을 이용하여 학습률 및 모멘텀 계수 그리고 멤버쉽함수의 파라미터를 동정한다[8][18][19]. 유전자 알고리즘[20][21]은 생물학적 진화, 자연선택, 유전자 재조합의 생물학 원리에 바탕을 둔 확률적 탐색 방법으로, 임자적으로 좋은 결과를 가져다주는 과정을 추적하고, 반면에 지역 극소에 빠질 가능성을 제거하기 위해 임의의 지점을 검사함으로써, 해 공간 전체를 탐색할 수 있는 능력을 가진다[20]. 유전자 알고리즘의 특징은 주어진 값을 2진 코딩하여 코딩된 문자열을 하나의 개체로 그리고 개개의 비트를 유전자처럼 취급하며, 하나의 지점부터 최적지점으로가 아닌 동시에 여러 지점에서 최적지점을 찾아 나간다. 그리고 미분과 같은 수학적 연산이 아닌 결과의 적합도를 기준(목적함수)으로 수행되며, 결정적인 방법이 아닌 확률적인 방법이다. 모델의 최적화를 위하여 사용된 유전자 알고리즘은 2진(binary)형의 직렬방식을 사용하며, 선택(selection)연산으로는 roulette-wheel방식, 교배(crossover)연산은 one-point crossover 연산을 사용한다. 그리고 돌연변이 연산은 선택된 비트를 반전시키는 invert 방식을 사용한다.

2. SON : AFPNN의 후반부 구조

SON[5]은 본 논문에서 제안한 AFPNN의 후반부를 구성한다. GMDH 알고리즘에 기초한 SON은 차수 및 입력변수의 선택과 알고리즘의 최종 종료판정 기준에 의하여, 각 층에서 파라미터 동정에 의한 모델을 선정하게 되고, 계층적 모델 추정에 의해 최종 모델을 얻는다. SON은 추정 모델을 얻기 위해 먼저 부분표현식(Partial Description; PD)을 구성하

표 1. 회귀다항식 형태.

Table 1. Types of regression polynomial.

| | | |
|---------|--------|--|
| | Type 1 | $c_0 + c_1x_1 + c_2x_2$ |
| 2 입력 | Type 2 | $c_0 + c_1x_1 + c_2x_2 + c_3x_{12} + c_4x_{22} + c_5x_1x_2$ |
| | Type 3 | $c_0 + c_1x_1 + c_2x_2 + c_3x_1x_2$ |
| | Type 1 | $c_0 + c_1x_1 + c_2x_2 + c_3x_3$ |
| 3 입력 | Type 2 | $c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_1^2 + c_5x_2^2 + c_6x_3^2 + c_7x_1x_2 + c_8x_1x_3 + c_9x_2x_3$ |
| | Type 3 | $c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_1x_2 + c_5x_1x_3 + c_6x_2x_3$ |
| 4 입력 | Type 1 | $c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_4$ |
| | Type 2 | $c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_4 + c_5x_1^2 + c_6x_2^2 + c_7x_3^2 + c_8x_4^2 + c_9x_1x_2 + c_{10}x_1x_3 + c_{11}x_1x_4 + c_{12}x_2x_3 + c_{13}x_2x_4 + c_{14}x_3x_4$ |
| | Type 3 | $c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_4 + c_5x_1x_2 + c_6x_1x_3 + c_7x_1x_4 + c_8x_2x_3 + c_9x_2x_4 + c_{10}x_3x_4$ |

며 이 부분 표현식은 표 1과 같은 회귀다항식을 사용한다. 다음에, 입출력 데이터를 이용하여 선형회귀분석으로 부분 표현식의 계수를 구하고 중간변수를 구한다. 중간변수에 의한 새로운 입출력 데이터를 구성하여 부분표현식의 계수와 중간변수를 구한다. 다음 계층에서도 이와 같은 형태의 연산을 되풀이하며, 알고리즘의 종료 판정식을 만족할 때까지 계속 반복된다. 알고리즘을 종료한 후 얻어지는 부분표현식은 계층적으로 조합하고, 최종 추정 모델을 얻는다. 본 논문에서는 구조의 복잡성과 모델의 정확성 사이의 상호균형을 고려하여 정해진 층 수(5층)에 의해 알고리즘을 종료한다. 표 1은 SON에 사용된 노드의 입력변수 수와 차수를 나타낸다. 여기서 Type 1과 Type 2는 1차, 2차 다항식, Type 3는 변형된 2차 다항식이다.

SON 구조는 1층과 그 이후 층의 부분표현식을 구성하는 방법에 따라 모델의 구조가 정해지는데, 1층과 그 이후 층이 각각 서로 동일 입력변수 수를 가지는 경우와 서로 다른 입력변수 수를 가지는 경우의 두 구조로 분류되며 이를 기본 SON 구조, 변형된 SON 구조라 한다. 또한 이들 각 구조는 동일차수를 가지는 구조(Case 1)와 서로 다른 차수 혹은 변형된 형태의 차수를 가지는 구조(Case 2)로 구분할 수 있다. 그림 2는 AFPNN의 후반부 구조인 SON 구조를 보여준다. SON의 구조 선택에 따라 제안된 AFPNN의 구조가 결정된다.

3. 기본 AFPNN 구조

AFPNN의 기본 구조는 FNN과 기본 SON의 결합 구조이다. 기본 SON 구조는 그림 2와 같이 네트워크를 형성하는 각 층의 노드에 1) 동일 입력변수 수 및 동일 다항식 차수(Case 1) 또는 2) 동일 입력변수 수 및 1층과 2층 이상에 다른 다항식 차수(Case 2)를 적용한 구조이다. AFPNN는 그림 3에 나타난 전반부 FNN의 연결점과 SON의 결합으로부터 그림 4의 구조를 가진다. SON 1층의 각 노드는 FNN의 f_i 출력이 전 층에 연결된다. 즉, 각 입력신호는 멤버쉽함수를 거쳐 적합도가 구해지고 적합도는 각 입력변수에 대해 규준화된 후 연결 가중치와 곱해져 후반부 SON의 입력신호가 된다. AFPNN 구조는 전반부 구조인 FNN의 멤버쉽함수의 수를 조절함에 의해 후반부 입력변수의 수를 조절할 수 있다. 이

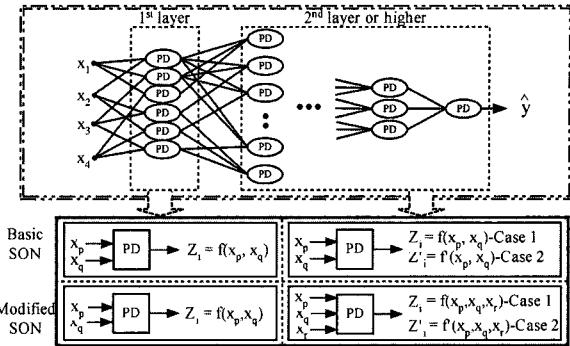
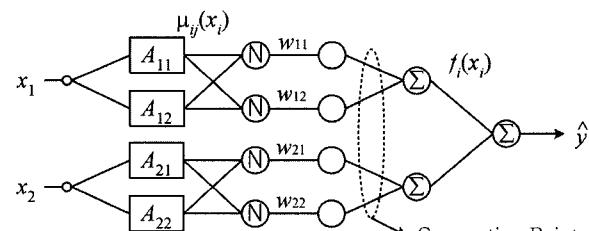


그림 2. AFPNN의 후반부 구조로 이용된 SON.

Fig. 2. SON used to the consequence part of AFPNN.

그림 3. SON과의 결합을 위해 연결점을 가진 FNN 구조.
Fig. 3. FNN architecture with a connection point for combination with SON.

는 SON 1 층의 입력변수들을 확장시키는 역할을 함으로써 SON 입력변수들의 상호관계를 둘고 다중 입력변수 및 고계 다항식을 가진 SON 구조를 효과적으로 이용할 수 있도록 하며, 모델 출력력을 개선시킨다. 뿐만 아니라 적절한 FNN 출력노드를 SON 알고리즘에 의해 최적 선택할 수 있어 보다 출력 성능을 향상시킬 수 있다. 기본 AFPNN 구조는 그림 4에서 보여지는 것처럼 SON의 구조에 따라 다음의 두 Case로 설계할 수 있다.

Case 1. 동일 입력변수 수와 동일 다항식 차수를 가지는 구조 : 그림 4에서 AFPNN 후반부 2층 이상의 부분표현식이 1층과 동일한 $z = f(x_p, x_q)$ 의 경우로써 1층에서 2입력 Type 2로 입력변수 수와 다항식 차수가 정해진다면, 다음 층에서도 전 층과 같은 다항식 차수로 부분표현식이 구성되어 최적의 추정모델을 얻는 구조이다. 즉, 1층 노드의 부분표현식이 2 입력 Type 2의 경우 $z_i = c_0 + c_1x_1 + c_2x_2 + c_3x_{12} + c_4x_{22} + c_5x_1x_2$ 가 되며, 2층 이상에서도 이와 같은 형태의 다항식이 부분표현식으로 사용된다. 각 입력 수에 대한 다항식 차수(Type)는 표 1과 같다.

Case 2. 동일 입력변수 수와 서로 다른 다항식 차수를 가지는 구조 : 그림 4에서 후반부 2층 이상의 부분표현식이 $z'_i = f'(x_p, x_q)$ 의 경우로, 1층에서 2입력 Type 1로 AFPNN 후반부 노드의 입력변수 수와 다항식 차수를 정한다면, 다음 층에서는 입력변수의 수를 동일하게 설정하고, Type을 변화시킴으로써 계층끼리의 상호 연계성을 고려한 구조 생성으로부터 최적 모델을 얻는다. 그림 4에서 AFPNN 후반부 부분표현식의 출력 z_i, z'_i 표시는 상호간 서로 다른 Type이 이용되었음을 의미한다. 즉 1층에서 2입력 Type 1의 다항식을 부분표현식으로 사용하였다면 그 구조는 $z = c_0 + c_1x_1 + c_2x_2$ 가 되

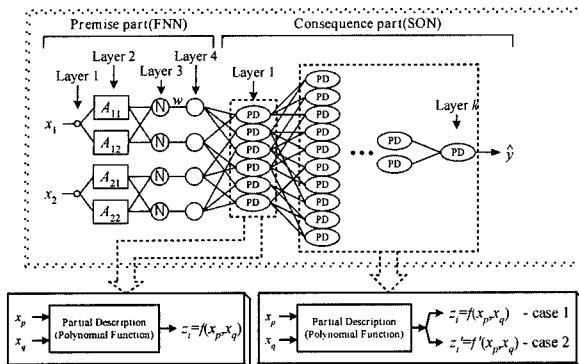


그림 4. 기본 AFPNN 구조.

Fig. 4. Basic AFPNN architecture.

며, 2층 이후에서는 동일한 수의 입력변수지만 차수를 달리하는 다항식을 사용하는 것으로 Type 3, 즉 변형된 2차식을 사용한다면 형태는 $z' = c_0 + c_1x_1 + c_2x_2 + c_3x_1x_2$ 가 된다.

4. 변형된 AFPNN 구조

변형된 AFPNN 구조는 FNN과 변형된 SON의 결합이다. FNN은 기본 AFPNN 구조와 마찬가지로 그림 3과 같은 연결점을 가진다. 변형된 SON 구조는 그림 2와 같이 네트워크를 형성하는 각 층의 노드에 다른 입력변수 수를 적용한 구조이다. 이는 1층과 그 이후 층의 다항식이 서로 다른 구조를 가짐으로써 계층구조의 간략성과 상호연계성이 고려된 구조이다. 따라서 복잡한 고차 회귀다항식 사용이 용이하며, 간편한 구조의 구성이라고 할 수 있다. 변형된 AFPNN은 그림 3에 나타난 전반부 FNN의 연결점과 변형된 SON의 결합구조로 그림 5와 같다. 이 구조는 변형된 SON 구조의 특징을 모두 가지며 또한 전반부 FNN 구조로부터 주어진 시스템 입력에 대해 규준화된 멤버쉽 값의 출력 개수로 확장함으로써 적은 시스템 입력변수 수를 가진 모델에 대해서도 좋은 특성을 나타낸다. 변형된 AFPNN 구조는 기본 AFPNN 구조와는 달리 1층과 2층 이상에 다른 입력변수 수 및 동일 차수를 가진 구조(Case 1)와 다른 입력변수 수 및 다른 차수를 가진 구조(Case 2)로 고려할 수 있다.

Case 1. 서로 다른 입력변수 수와 동일 다항식 차수를 가지는 구조 : 그림 5에서 AFPNN 후반부 1층에서의 부분표현식이 $z_i = f(x_p, x_q)$ 이고, 2층 이상에서의 부분표현식이 $z_i = f(x_p, x_q, x_r)$ 인 경우로 1층에서의 부분표현식과 2층 이상에서의 부분표현식이 서로 다른 입력 구조를 가진다. 1층을 2입력 Type 2로 설정을 했다면, 2층 이상에서는 3입력 Type 2 구조를 형성하며 복잡한 고차 회귀다항식까지 사용할 수 있다. 최종 추론된 모델은 여러 층을 거쳐 생성된 최적화된 모델이다. 1층에서 2입력 Type 2인 $z_i = c_0 + c_1x_1 + c_2x_2 + c_3x_1^2 + c_4x_2^2 + c_5x_1x_2$ 의 형태가 사용되었다면, 2층 이상에서는 1층과 같은 Type 2를 사용하여 입력변수 수를 달리하여 다항식을 구성하는 것이다. 즉 3입력 Type 2로 다항식을 나타내면 $z_i = c_0 + c_1x_1 + c_2x_2 + c_3x_3 + c_4x_1^2 + c_5x_2^2 + c_6x_3^2 + c_7x_1x_2 + c_8x_1x_3 + c_9x_2x_3$ 가 된다.

Case 2. 서로 다른 입력변수 수와 서로 다른 다항식 차수를 가지는 구조 : AFPNN 구조인 그림 5에서 후반부 1층에서의 부분표현식은 $z_i = f(x_p, x_q)$ 이고, 2층 이상에서의 부분표현식은 $z_i' = f'(x_p, x_q, x_r)$ 인 경우로 1층에서의 부분표현식과 2층

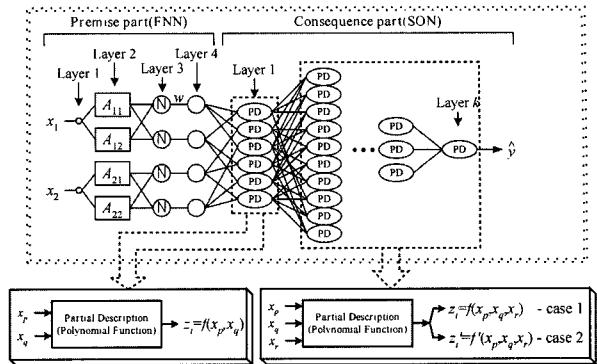


그림 5. 변형된 AFPNN 구조.

Fig. 5. Modified AFPNN architecture.

이상에서의 부분표현식의 입력 구조가 서로 다른 형태를 띠고 있을 뿐만 아니라, 부분표현식의 Type을 서로 다르게 설정할 수 있는 구조이다. 다항식 차수 또는 입력변수 수 증가에 따른 구조의 상호연계성을 보다 고려한 구조로 구성할 수 있고, 차수 또는 입력변수 수 감소에 따른 계층구조를 간략화하여 설계할 수 있는 장점을 가진다. 그림 5에서 각 층의 부분표현식인 다항식함수의 출력 z_i, z_i' 표시는 서로 다른 Type을 의미한다. 1층에 2입력 Type 1의 다항식 구조가 설정되면, 2층 이상에서는 3입력 Type 3의 다항식구조가 선택될 수 있다.

III. 수치 예제

제안된 AFPNN의 평가를 위해 다른 지능모델에 널리 사용된 두 종류의 수치 데이터를 이용한다. 첫 번째는 간단한 수치 예제인 비선형 함수[11]-[14]를, 두 번째는 비선형 공정에 대한 성능 평가의 척도로 사용되고 있는 가스로 공정[15]-[19]을 사용한다. 이들은 입력과 출력의 관계를 나타내는 다수 데이터의 집합으로 나타내어진다. 모델의 평가 기준인 성능지수(Performance Index:PI)는 수치 데이터인 비선형 함수와 가스로 공정에 대해서 MSE(Mean Squared Error), 즉 (7)을 이용한다. 전반부 구조인 FNN 모델의 최적화를 위해 각 파라미터들은 앞서 언급한 것과 같이 유전자 알고리즘을 이용하고 해당 연산값들로 세대는 100세대, 군집은 60개체까지 진행시켰으며, 각 문자열의 길이는 10bit를, 교배율은 0.6, 돌연변이 발생률은 0.35를 사용한다.

1. 비선형 함수

본 논문에는 제안된 모델의 적용 및 타당성을 평가하기 위해 (17)로 표현되는 2입력 1출력 비선형 함수[11]-[14]를 이용한다.

$$y = (1 + \sqrt{x_1^2 + x_2^2})^2, \quad 1 \leq x_1, x_2 \leq 5 \quad (17)$$

그림 6과 같은 비선형 특징을 가진 시스템 방정식으로부터 얻어진 50개의 입출력 데이터 쌍을 제안된 모델에 적용함으로써 모델의 타당성 및 정확도를 기준 모델과 비교 검토한다.

AFPNN 구조는 전반부 구조인 FNN의 멤버쉽 함수 수를 조절함에 의해 적은 시스템 입력 수를 가진 모델에 대해서

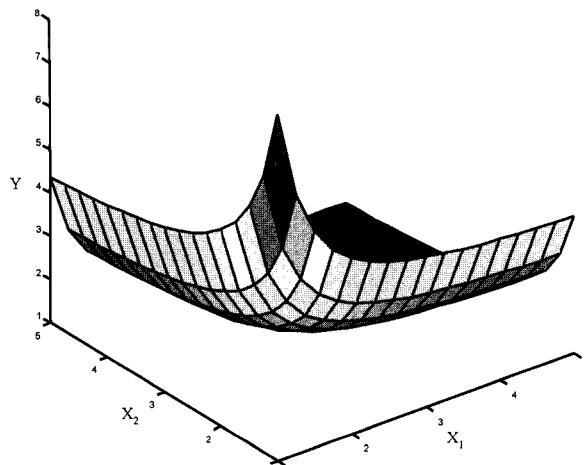


그림 6. 비선형 함수의 입출력 관계.

Fig. 6. Input-output relation of nonlinear function.

도 후반부 구조인 SON의 다양한 구조를 적용할 수 있으며 설계자가 원하는 모델을 설계할 수 있다. 따라서 본 논문에서는 각 입력에 대해 2개인 멤버쉽함수와 각 입력에 대해 3개인 멤버쉽함수를 고려한다. AFPNN의 전반부에 이용된 FNN은 유전자 알고리즘에 의해 학습을 및 모멘텀계수 그리고 멤버쉽함수의 파라미터를 동조한 것으로, 멤버쉽함수 개수가 각 입력에 대해 2개인, 즉 4개의 규칙일 때 PI=0.099이며, 각 입력에 대해 3개인, 즉 6개의 규칙일 때 PI=0.036의 성능지수 값을 가진다. 표 2는 4개의 규칙을 가진 AFPNN의 성능지수를 전반부와 후반부의 결합 구조와 후반부 각 층에서의 최적 성능지수를 보여주고 있으며, 표 3은 6개의 규칙을 가진 AFPNN의 성능지수를 보여준다. 표에서 후반부 구조 'a 입력'은 모든 층의 노드가 a 입력을 가진 구조이고 'a→b 입력'은 1층 노드는 a 입력을 2층 이상의 노드는 b 입력을 가진 구조를 의미한다. 다시 말하면, 기본 AFPNN 구조의 '3 입력'은 모든 층의 노드 입력 수가 '3'이고 변형된 구조의 '2→4 입력'은 1층 노드는 2 입력을 2층 이상의 노드는 4 입력을 가진 구조를 의미한다. 'Type c'는 모든 층의 노드의 다항식 차수를, 'Type c→d'는 다항식 차수가 1층 노드는 Type c, 2층 이상 노드는 Type d로 변하는 구조이다. 즉, AFPNN 구조에서 'Type 2'는 모든 층의 노드가 Type 2의 2차 회귀다항식으로 표현되며, 'Type 3→2'는 1층 노드는 변형된 2차(Type 3), 2층 이상 노드는 2차(Type 2) 회귀다항식인 구조이다. 각 입력에 대한 회귀다항식 형태는 표 1과 같다.

표 2와 3에서 알 수 있듯이 제안된 AFPNN모델 구조는 FNN 자체 모델보다 우수한 구조를 가지고 있음을 알 수 있다. 또한 기본 구조보다는 변형된 구조에서 좋은 결과를 얻을 수 있는데 이것은 변형된 구조가 각 층에 서로 다른 구조를 가짐으로써 일반형 구조보다 좀 더 상호연계성이 고려된 구조이기 때문이다. 따라서 고차 회귀다항식을 효과적으로 이용할 수 있다.

비선형 함수에 대한 최적의 구조로 6개의 규칙을 가진 FNN과 4입력 Type 1→2의 SON이 결합한 구조를 선택하였을 때 기본 AFPNN 최적 구조는 그림 7과 같다. 이때 PI는 0.0027이다. 여기서 PD는 부분표현식(Partial Description), 즉

표 2. 4개의 규칙을 가진 AFPNN 성능지수.
Table 2. Performance index of AFPNN with 4 rules.

| AFPNN | | 전반부(FNN) | 후반부(SON) | | PI | | |
|-----------|--------|----------|------------------|----|--------|--|--|
| | | | 멤버쉽함수 | 구조 | | | |
| 기본 구조 | Case 1 | 2+2 | 3 입력 Type 2 | 1 | 0.0544 | | |
| | | | | 2 | 0.0383 | | |
| | | | | 3 | 0.0322 | | |
| | | | | 4 | 0.0270 | | |
| | | | | 5 | 0.0229 | | |
| | Case 2 | | | 1 | 0.0663 | | |
| | | | | 2 | 0.0427 | | |
| | | | | 3 | 0.0272 | | |
| | | | | 4 | 0.0226 | | |
| | | | | 5 | 0.0199 | | |
| 변형된 구조 | Case 1 | 2+2 | 2→4 입력 Type 2 | 1 | 0.0553 | | |
| | | | | 2 | 0.0350 | | |
| | | | | 3 | 0.0183 | | |
| | | | | 4 | 0.0088 | | |
| | | | | 5 | 0.0044 | | |
| | Case 2 | | | 1 | 0.0973 | | |
| | | | | 2 | 0.0356 | | |
| | | | | 3 | 0.0205 | | |
| | | | | 4 | 0.0082 | | |
| | | | | 5 | 0.0049 | | |

표 3. 6개의 규칙을 가진 AFPNN 성능지수.
Table 3. Performance index of AFPNN with 6 rules.

| AFPNN | | 전반부(FNN) | 후반부(SON) | | PI | | |
|-----------|--------|----------|------------------|----|--------|--|--|
| | | | 멤버쉽함수 | 구조 | | | |
| 기본 구조 | Case 1 | 3+3 | 3 입력 Type 2 | 1 | 0.0806 | | |
| | | | | 2 | 0.0228 | | |
| | | | | 3 | 0.0070 | | |
| | | | | 4 | 0.0049 | | |
| | | | | 5 | 0.0033 | | |
| | Case 2 | | 4 입력 Type 1→2 | 1 | 0.0353 | | |
| | | | | 2 | 0.0118 | | |
| | | | | 3 | 0.0065 | | |
| | | | | 4 | 0.0054 | | |
| | | | | 5 | 0.0027 | | |
| 변형된 구조 | Case 1 | 3+3 | 3→4 입력 Type 2 | 1 | 0.0806 | | |
| | | | | 2 | 0.0088 | | |
| | | | | 3 | 0.0029 | | |
| | | | | 4 | 0.0020 | | |
| | | | | 5 | 0.0017 | | |
| | Case 2 | | | 1 | 0.0806 | | |
| | | | | 2 | 0.0130 | | |
| | | | | 3 | 0.0039 | | |
| | | | | 4 | 0.0026 | | |
| | | | | 5 | 0.0022 | | |

회귀다항식을 말하며 번호는 선택된 노드의 번호이다. 점선으로 표시된 노드 중 진하게 표시된 노드는 최적의 기본 AFPNN의 네트워크를 생성하는 과정에서 제외될 수 있지만 각 층에서 최소값의 성능지수를 가진 노드이며 일반 점선 노드는 전체 네트워크 형성에서 사용되지 않은 노드를 나타낸다. 그림 8은 최적 구조인 기본 AFPNN 구조의 학습과정을 보여주고 있다. 표 4는 기존의 모델링과 본 논문에서 제안한 AFPNN과의 동정오차를 비교하여 제안된 방법이 우수한 특성을 나타냄을 보인다.

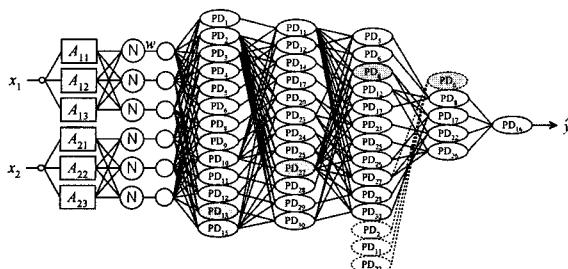


그림 7. 기본 AFPNN의 최적 구조 : Case 2.

Fig. 7. Optimal architecture of the basic AFPNN : Case 2.

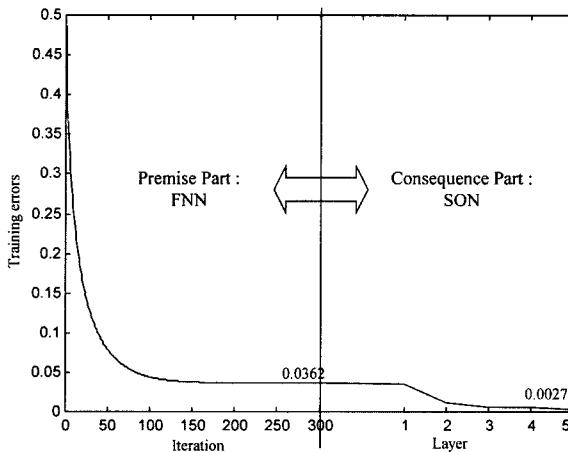


그림 8. 기본 AFPNN의 학습 과정 : Case 2.

Fig. 8. Learning procedure of the basic AFPNN : Case 2.

표 4. 기존 모델과의 동정오차 비교.

Table 4. Comparison of identification errors with previous models.

| Model | | PI |
|---------------------------|--------|--------|
| Sugeno and Yasukawa[11] | | 0.079 |
| Gomez-Skarmeta et al.[12] | | 0.070 |
| Kim et al.[13] | | 0.019 |
| Kim et al.[14] | | 0.0089 |
| 제안된 모델 (AFPNN) | 기본 구조 | Case 1 |
| | Case 2 | 0.0027 |
| | 변형된 구조 | Case 1 |
| | Case 2 | 0.0022 |

2. 가스로 공정

Box와 Jenkins가 사용한 가스로 시계열 데이터[15]를 이용하여 입출력 데이터인 가스 흐름을과 연소된 이산화탄소 농도를 모델 동정에 이용한다. 이 공정 데이터는 기존의 모델 성능평가를 위해 많이 적용된 표준 데이터로써, 본 논문에서 제안한 AFPNN 구조의 타당성과 유용성 평가를 위해 이용된다. 가스로 공정 모델링을 위해 입출력 데이터쌍으로 2입력 1출력 $[(u(t-3), y(t-1)); y(t)]$ 과 3입력 1출력 $[u(t-2), y(t-2), y(t-1); y(t)]$ 을 고려한다. 여기서 입력($u(t)$)은 가스 흐름을이고 출력($y(t)$)은 이산화탄소 농도이다.

표 5와 6은 각각 2입력과 3입력 AFPNN의 성능지수를 보

표 5. 2입력 AFPNN 성능지수.

Table 5. Performance index of AFPNN with 2 inputs.

| 구조 | Case 1 | 전반부(FNN) 멤버쉽함수 | 후반부(SON) | | PI | E_PI | |
|--------|--------|-------------------|-----------------|---|--------|-------|--|
| | | | 구조 | 총 | | | |
| 기본 구조 | Case 1 | 2+2 | 2 입력 Type 2 | 1 | 0.0247 | 0.339 | |
| | | | | 2 | 0.0247 | 0.337 | |
| | | | | 3 | 0.0242 | 0.310 | |
| | | | | 4 | 0.0238 | 0.295 | |
| | | | | 5 | 0.0216 | 0.270 | |
| | Case 2 | | 2 입력 Type 1→2 | 1 | 0.0251 | 0.329 | |
| | | | | 2 | 0.0248 | 0.331 | |
| | | | | 3 | 0.0250 | 0.283 | |
| | | | | 4 | 0.0239 | 0.276 | |
| | | | | 5 | 0.0235 | 0.268 | |
| 변형된 구조 | Case 1 | 2+2 | 2→4 입력 Type 2 | 1 | 0.0247 | 0.339 | |
| | | | | 2 | 0.0243 | 0.336 | |
| | | | | 3 | 0.0333 | 0.271 | |
| | | | | 4 | 0.0210 | 0.253 | |
| | | | | 5 | 0.0181 | 0.246 | |
| | Case 2 | | 2→4 입력 Type 3→2 | 1 | 0.0248 | 0.328 | |
| | | | | 2 | 0.0248 | 0.329 | |
| | | | | 3 | 0.0285 | 0.280 | |
| | | | | 4 | 0.0189 | 0.260 | |
| | | | | 5 | 0.0176 | 0.250 | |

표 6. 3입력 AFPNN 성능지수.

Table 6. Performance index of AFPNN with 3 inputs.

| 구조 | Case 1 | 전반부(FNN) 멤버쉽함수 | 후반부(SON) | | PI | E_PI |
|--------|--------|-------------------|-----------------|---|--------|-------|
| | | | 구조 | 총 | | |
| 기본 구조 | Case 1 | 2+2+2 | 4 입력 Type 2 | 1 | 0.0218 | 0.141 |
| | | | | 2 | 0.0205 | 0.121 |
| | | | | 3 | 0.0187 | 0.112 |
| | | | | 4 | 0.0176 | 0.107 |
| | | | | 5 | 0.0164 | 0.104 |
| 변형된 구조 | Case 2 | 2+2+2 | 4 입력 Type 1→2 | 1 | 0.0224 | 0.137 |
| | | | | 2 | 0.0233 | 0.129 |
| | | | | 3 | 0.0197 | 0.117 |
| | | | | 4 | 0.0182 | 0.107 |
| | | | | 5 | 0.0172 | 0.103 |
| 변형된 구조 | Case 1 | 2+2+2 | 3→4 입력 Type 2 | 1 | 0.0217 | 0.143 |
| | | | | 2 | 0.0259 | 0.132 |
| | | | | 3 | 0.0206 | 0.122 |
| | | | | 4 | 0.0182 | 0.107 |
| | | | | 5 | 0.0172 | 0.106 |
| 변형된 구조 | Case 2 | 2+2+2 | 3→4 입력 Type 3→2 | 1 | 0.0221 | 0.135 |
| | | | | 2 | 0.0255 | 0.128 |
| | | | | 3 | 0.0197 | 0.115 |
| | | | | 4 | 0.0163 | 0.105 |
| | | | | 5 | 0.0161 | 0.096 |

여주고 있다. 전반부에 이용된 FNN은 각 입력에 대해 2개의 멤버쉽함수를 가지며, 유전자 알고리즘에 의해 최적화된 구조로 2입력의 경우 PI=0.035, E_PI=0.28이고 3입력의 경우는 PI=0.024, E_PI=0.126의 성능지수 값을 가진다. 여기서 PI는 학습 성능지수를 E_PI는 테스트 성능지수를 의미한다. 후반부에 이용된 SON은 전반부 구조인 FNN의 성능을 개선하고 보다 좋은 구조를 얻기 위해 다양한 구조를 적용하였다. 표 5와 6에 나타난 AFPNN의 성능지수를 살펴보면, 2입력 모델보다는 3입력의 모델에서 좋은 결과를 보이며 또한 기본 구조보다는 변형된 구조에서 향상된 출력 및 예측 결과를 얻을 수 있었다.

제안된 AFPNN은 전반부에 이용된 FNN과 후반부 구조인 SON의 구조를 다양하게 변화시킴으로써 설계자가 원하는 모델을 얻을 수 있도록 도와 주며 적은 시스템 입력을 가진 모델에 대해서도 다중 입력과 고차 회귀다항식의 다중 구조를 가진 SON을 효과적으로 이용할 수 있도록 함으로써 높은 정밀도와 예측 능력을 가진 모델을 생성한다.

그림 9는 3입력 기본 AFPNN의 Case 2 구조를 보여 주고 있다. 전반부 구조인 FNN은 각 입력에 대해 2개의 멤버쉽 함수를 적용하였고 후반부 구조인 SON은 4입력 Type 1→2 구조를 가진다. 이 구조의 학습과정을 그림 10에 보였으며, 그림 10(a)는 학습 데이터에 대해, 그림 10(b)는 테스트 데이터에 대한 학습 과정을 보여주고 있다. 그림 11은 FNN과 3→4 입력 Type 3→2 구조를 가진 SON의 결합인 변형된 AFPNN의 최적 구조를 보이며, 그림 12는 이 구조에 대한 학습과정을 보여주고 있다. 그림 9와 11에서 보여지듯이 변형된 구조

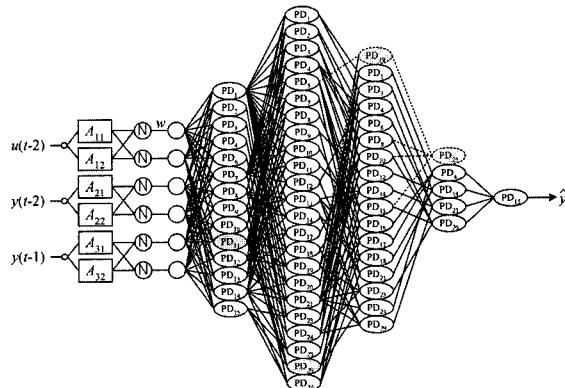
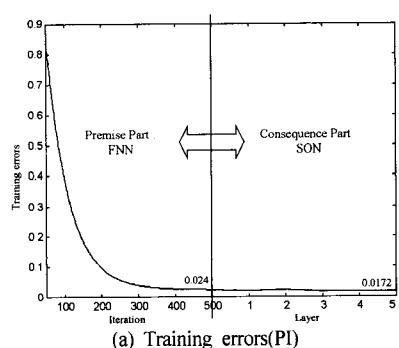
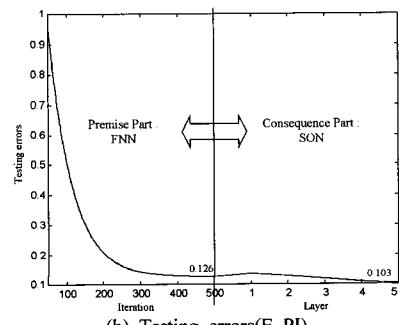


그림 9. 기본 AFPNN의 최적 구조 : Case 2.

Fig. 9. Optimal architecture of the basic AFPNN : Case 2.



(a) Training errors(PI)



(b) Testing errors(E_PI)

그림 10. 기본 AFPNN의 학습 과정 : Case 2.

Fig. 10. Learning procedure of the basic AFPNN : Case 2.

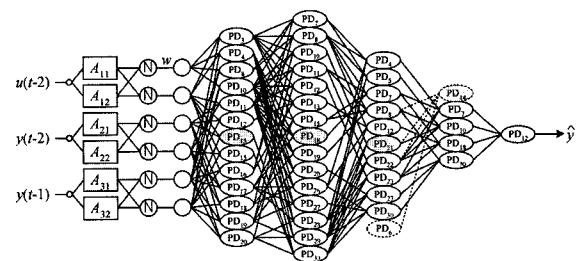
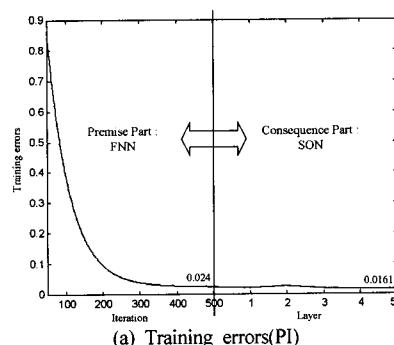
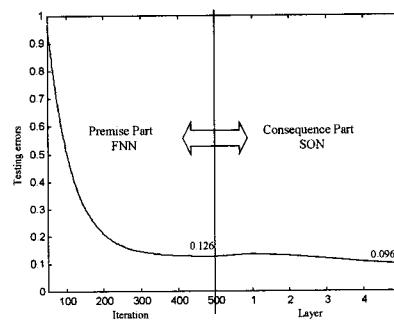


그림 11. 변형된 AFPNN의 최적 구조 : Case 2.

Fig. 11. Optimal architecture of the modified AFPNN : Case 2.



(a) Training errors(PI)



(b) Testing errors(E_PI)

그림 12. 변형된 AFPNN의 학습 과정 : Case 2.

Fig. 12. Learning procedure of the modified AFPNN : Case 2.

표 7. 기존 모델과의 동정오차 비교.

Table 7. Comparison of identification errors with previous models.

| Model | PI | E PI |
|----------------------------------|--------|---------------------|
| Kim, et al.'s model[14] | 0.034 | 0.244 |
| Lin and Cunningham's model[16] | 0.071 | 0.261 |
| Oh and Pedrycz's Fuzzy model[17] | 0.020 | 0.271 |
| Oh's Fuzzy model[18][22] | 0.020 | 0.264 |
| Oh's Adaptive FNN[19] | 0.021 | 0.332 |
| 제안된 모델 (AFPNN) | 기본 구조 | Case 1 0.0216 0.270 |
| | | Case 2 0.0235 0.268 |
| | 변형된 구조 | Case 1 0.0181 0.246 |
| | | Case 2 0.0176 0.250 |
| 제안된 모델 (AFPNN) | 3입력 | Case 1 0.0164 0.104 |
| | | Case 2 0.0172 0.103 |
| | 기본 구조 | Case 1 0.0172 0.106 |
| | | Case 2 0.0161 0.096 |

는 기본 AFPNN 구조보다 좀 더 단순화되고 성능 또한 개선되어짐을 알 수 있다.

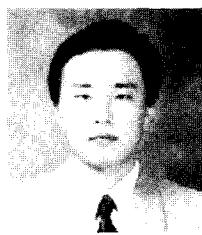
지금까지 본 논문에서 제안된 AFPNN을 가스로 공정에 적용하여 모델 설계 및 각 구조에 대한 평가를 하였다. 표 7은 기존의 모델링 방법과 제안된 모델링 방법의 동정오차를 비교하여 보여준다. 표 7에서 알 수 있듯이 제안된 모델은 기존 모델들의 학습 성능보다 우수할 뿐만 아니라, 테스트 데이터를 고려한 테스트 성능, 즉 예측 성능면에서도 우수한 특성을 보인다.

IV. 결론

본 논문은 복잡한 비선형 시스템의 최적 모델동정을 위하여 퍼지뉴럴네트워크의 새로운 구조를 제안하였으며 광범위한 설계방법을 논의하였다. 제안된 AFPNN은 FNN과 SON을 기반으로 한 합성구조로 FNN은 AFPNN 구조의 전반부를, SON은 후반부를 구성한다. 전반부 구조인 FNN은 유전자 알고리즘에 의해 최적화되었으며 SON과의 결합을 위해, 각 시스템 입력에 대한 출력 f_i 의 이전 층인 규준화된 멤버쉽 값의 출력신호를 가진 연결점을 고려하여 후반부 입력 수 증가에 따라 보다 구조의 유연성, 확장성을 증가시켰다. 후반부 구조인 SON은 학습을 통해 전개되는 유연한 구조로 SON의 각 노드는 높은 유연성을 보여주며, 입력과 출력 변수 사이의 회귀다항식(1차식, 2차식, 변형된 2차식) 함수에 의해 구현된다. AFPNN은 FNN의 연결점과 보다 다양하고 유연한 구조를 가진 SON 구조와의 결합을 통해 비선형 공정 시스템 특성에 따른 보다 적응력을 가진 구조를 설계할 수 있었다. 이러한 특징을 바탕으로 본 논문에서는 기본 구조와 변형된 구조를 가진 AFPNN을 설계하였다. 또한 기존의 뉴럴네트워크 구조와는 달리 네트워크 각 층의 노드가 고정되어 있지 않고 모델 특성에 따라 노드의 생성 및 소멸과정을 거쳐 최적의 네트워크를 형성하는 특성을 가지고 있다. 이러한 특징을 가진 AFPNN은 구조 설계에 의한 모델의 표현과 적응능력으로부터 복잡한 다변수 비선형계의 시스템에 대해 우수한 동정 및 예측성능이 가능하였다.

참고문헌

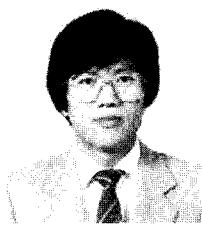
- [1] H. Takagi and I. Hayashi, "NN-driven fuzzy reasoning," *Int. J. of Approximate Reasoning*, vol. 5, no. 3, pp. 191-212, 1991.
- [2] S. Horikawa, T. Furuhashi, and Y. Uchigawa, "On fuzzy modeling using fuzzy neural networks with the back propagation algorithm," *IEEE trans. Neural Networks*, vol. 3, no. 5, pp. 801-806, 1992.
- [3] N. Imasaki, J. Kiji, and T. Endo, "A fuzzy rule structured neural networks," *Journal of Japan Society for Fuzzy Theory and Systems*, vol. 4, no. 5, pp. 985-995, 1992(in Japanese).
- [4] H. Nomura and Wakami, "A self-tuning method of fuzzy control by descent methods," *4th IFSA World Conference*, pp. 155-159, 1991.
- [5] 오성권, 김동원, 박병준, "다항식 뉴럴네트워크 구조의 최적 설계에 관한 연구," *대한전기학회논문지*, 제49D권, 제3호, pp. 145-156, 2000.
- [6] S. K. Oh and W. Pedrycz, "The design of self-organizing polynomial neural networks," *Information Sciences*, 2002(to appear).
- [7] T. Yamakawa, "A new effective learning algorithm for a neo fuzzy neuron model," *5th IFSA World Conference*, pp. 1017-1020, 1993.
- [8] 오성권, 윤기찬, 김현기, "유전자 알고리즘과 합성 성능 지수에 의한 최적 퍼지-뉴럴 네트워크 구조의 설계," *제어·자동화·시스템공학논문지*, 제6권, 제3호, pp. 273-283, 2000.
- [9] B. J. Park, W. Pedrycz, and S. K. Oh, "Fuzzy polynomial neural networks: hybrid architectures of fuzzy modeling," *IEEE Trans. on Fuzzy Systems*, 2002(to appear).
- [10] A. G. Ivahnenko, "The group method of data handling : a rival of method of stochastic approximation," *Soviet Automatic Control*, vol. 13, no. 3, pp. 43-55, 1968.
- [11] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling," *IEEE Trans. on Fuzzy Systems*, vol. 1, no. 1, pp. 7-31, 1993.
- [12] A. F. Gomez-Skarmeta, M. Delgado, and M. A. Vila, "About the use of fuzzy clustering techniques for fuzzy model identification," *Fuzzy Sets and Systems*, vol. 106, pp. 179-188, 1999.
- [13] E. T. Kim, M. K. Park, S. H. Ji, and M. Park, "A new approach to fuzzy modeling," *IEEE Trans. on Fuzzy Systems*, vol. 5, no. 3, pp. 328-337, 1997.
- [14] 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.
- [15] G. E. Box and G. M. Jenkins, *Time Series Analysis : Forecasting and Control*, Holden-day, 1970.
- [16] Y. Lin, G. A. Cunningham III, "A new approach to fuzzy-neural modeling," *IEEE Trans. Fuzzy Systems*, vol. 3, no. 2, pp. 190-197, 1995.
- [17] S. K. Oh and W. Pedrycz, "Fuzzy identification by means of auto-tuning algorithm and its application to nonlinear system," *Fuzzy Sets and Syst.*, vol. 115, no. 2, pp. 205-230, 2000.
- [18] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하중값을 이용한 퍼지 시스템의 최적화," *대한전기학회논문지*, 제48A권, 제6호, pp. 789-799, 1999.
- [19] 오성권, 박병준, 박춘성, "적용 퍼지-뉴럴네트워크를 이용한 비선형 공정의 온-라인 모델링," *대한전기학회논문지*, 제48A권, 제10호, pp. 1293-1302, 1999.
- [20] David E. Goldberg, *Genetic Algorithms in search, Optimization & Machine Learning*, Addison-wesley, 1989.
- [21] Zbigniew Michalewicz, *Genetic Algorithms+Data Structure =Evolution Programs*, Springer-Verlag, 1992.
- [22] B. J. Park, W. Pedrycz, and S. K. Oh, "Identification of fuzzy models with the aid of evolutionary data granulation," *IEE Proc.-CTA*, vol. 148, Issue 05, pp. 406-418, 2001.

**박 병 준**

1972년 12월 1일 생. 1998년 원광대 제어계측공학과 졸업. 동대학원 석사(2000). 2000년~현재 동대학원 박사과정. 관심분야는 시스템자동화, 퍼지이론 및 뉴로퍼지네트워크 응용, 지능형 모델링 및 계산지능 등.

**오 성 권**

1957년 2월 13일 생. 1981년 연세대학교 전기공학과 졸업. 1983~89년 금성산전연구소(선임연구원). 1993년 연세대 대학원 전기공학과 졸업(공박). 1996~1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993년~현재 원광대 전기전자 및 정보공학부 부교수. 관심분야는 시스템자동화, 퍼지이론 및 뉴로퍼지네트워크 응용, 계산지능 및 소프트 컴퓨팅 등.

**장 성 환**

1950년 6월 25일 생. 1974년 홍익대 전기공학과 졸업. 1982년 연세대 대학원 전기공학과 졸업(공학 석사, 박사). 1985~1986년 Northwestern 대학 전기 및 컴퓨터공학과 방문교수. 1980~현재 원광대 전기전자 및 정보공학부 교수. 관심분야는 자동제어, 지능제어 및 응용 등.