

論文2002-39CI-3-2

## 고급 뉴로퍼지 다항식 네트워크의 해석과 설계

### (The Analysis and Design of Advanced Neurofuzzy Polynomial Networks)

朴炳俊\*, 吳聖權\*

(Byoung Jun Park and Sung Kwun Oh)

#### 요약

본 연구는 뉴로퍼지 네트워크와 다항식 뉴럴네트워크를 합성한 하이브리드 모델링 구조인 고급 뉴로퍼지 다항식 네트워크(Advanced neurofuzzy polynomial networks; ANFPN)를 제안한다. 제안된 네트워크 구조는 높은 비선형 규칙 기반 모델로, CI(Computational Intelligence)의 기술, 즉 퍼지 집합, 뉴럴네트워크, 유전자 알고리즘에 의해 설계되어진다. 뉴로퍼지 네트워크는 ANFPN 구조의 전반부를, 다항식 뉴럴네트워크는 후반부를 구성한다. ANFPN의 전반부에서, 뉴로퍼지 네트워크는 간략추론, 오류역전파 학습 규칙을 이용한다. 멤버쉽함수의 파라미터, 학습율, 모멘텀 계수는 유전자 최적화를 이용하여 조절된다. ANFPN의 후반부 구조로서 다항식 뉴럴네트워크는 학습을 통해 생성되는(전개되는) 유연한 네트워크 구조이다. 특히 다항식 뉴럴네트워크의 층과 노드 수는 고정되어 있지 않고 동적으로 생성된다. 본 연구에서는, 2가지 형태의 ANFPN 구조를 제안한다. 즉 기본 구조와 변형된 구조이다. 여기서 기본 구조와 변형된 구조는 다항식 뉴럴네트워크 구조의 각 층에서 입력변수의 수와 회귀다항식의 차수에 의존한다. 두 결합 구조의 특징 때문에 공정 시스템의 비선형적인 특성을 고려할 수 있고 보다 우수한 예측능력을 가진 좋은 출력성능을 얻을 수 있게 한다. ANFPN의 유용성과 실용성은 2개의 수치 예제를 통해 논의된다. 제안된 ANFPN은 기존의 모델보다 높은 정밀도와 예측능력을 가진 모델을 생성함을 보인다.

#### Abstract

In this study, we introduce a concept of advanced neurofuzzy polynomial networks(ANFPN), a hybrid modeling architecture combining neurofuzzy networks(NFN) and polynomial neural networks(PNN). These networks are highly nonlinear rule-based models. The development of the ANFPN dwells on the technologies of Computational Intelligence(CI), namely fuzzy sets, neural networks, and genetic algorithms. NFN contributes to the formation of the premise part of the rule-based structure of the ANFPN. The consequence part of the ANFPN is designed using PNN. At the premise part of the ANFPN, NFN uses both the simplified fuzzy inference and error back-propagation learning rule. The parameters of the membership functions, learning rates and momentum coefficients are adjusted with the use of genetic optimization. As the consequence structure of ANFPN, PNN is a flexible network architecture whose structure(topology) is developed through learning. In particular, the number of layers and nodes of the PNN are not fixed in advance but is generated in a dynamic way. In this study, we introduce two kinds of ANFPN architectures, namely the basic and the modified one. Here the basic and the modified architecture depend on the number of input variables and the order of polynomial in each layer of PNN 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 ANFPN are discussed and illustrated with the aid of two representative numerical examples. The results show that the proposed ANFPN can produce the model with higher accuracy and predictive ability than any other method presented previously.

**Key Words :** Neurofuzzy networks(NFN), Polynomial neural networks(PNN), Advanced neurofuzzy polynomial networks(ANFPN), Computational Intelligence(CI), Group method of data handling(GMDH), Genetic algorithms(GAs)

\* 正會員, 圓光大學校 電氣電子·情報工學部

(School of Electrical Electronic and Information Engineering, Wonkwang University)

※ 본 연구는 한국과학재단 목적기초연구(과제번호: R02-

2000-00284) 지원으로 수행되었음.

接受日字: 2001年6月18日, 수정완료일: 2002年4月15日

## I. 서 론

비선형성, 고계 동적시스템, 시변 특성 등과 관련된 복잡한 시스템에 대한 모델링 연구는 지속적으로 연구되어져 왔으며 최근에는 지능화, 최적화 등의 기술과 함께 다양한 영역에서 연구되고 있다. 시스템 모델링의 목적은 적절한 변수들을 선택하고, 주어진 데이터 집합으로부터 물리적 현상의 특징을 적절하게 반영할 수 있는 모델을 개발하는데 있다. 개발된 모델은 전문가의 경험과 같은 정보와 이용 가능한 수치데이터로부터 시스템 동작과 변수 사이의 종속관계에 대한 원하는 정보를 제공한다. 이러한 모델링 기술의 최근 경향은 퍼지 모델링, 뉴로컴퓨팅, 유전자 알고리즘을 적용하는 CI(Computational Intelligence) 기술의 이용에 있다.

Takagi, Hayashi<sup>[2]</sup>는 신경회로망으로 구동되는 퍼지 추론을 제안하였으나 입력력 수가 적은 경우는 그 효과가 미미하고, 전반부가 신경회로망이라는 특성화된 함수로 구성되어 기존의 퍼지추론보다 시스템 표현에 있어서 정성적으로 이해하기가 힘들다는 단점을 가지고 있다. Horikawa<sup>[3]</sup>는 퍼지-뉴럴네트워크에 의한 합성방법과 동정(identification)에 관한 연구를 하였다. 그러나 퍼지규칙의 전반부인 시그모이드 형태의 멤버쉽함수 초기화 설정이 어렵고, 최적 성능으로의 수렴특성이 나쁘다. Imaasaki<sup>[4]</sup>는 퍼지규칙이 전반부 네트워크, 추론 네트워크, 후반부 네트워크로 구조화된 신경회로망을 제안하였으며, 이는 추론 네트워크의 추가로 인한 오랜 학습 시간과 동조의 난점을 가지고 있다. 또한 입력력 증가에 따른 네트워크 구성시 경험적인 방법을 많이 요구한다. Nomura<sup>[5]</sup>는 엘타규칙에 의한 퍼지 추론의 자동 동조 방법을 제안하였다. 그러나 이것은 학습에 의한 동조로 각 규칙마다 멤버쉽함수가 변형됨에 따라 퍼지규칙 수가 증가하며, 입력력의 증가는 더 많은 퍼지규칙 수를 요구한다. Oh<sup>[18]</sup>는 다항식 뉴럴네트워크로 써 고차 다변수 입력에 의한 다양한 구조의 자기 구성 네트워크를 설계하였으나 입력력 변수에 의한 공간분할의 효과적 이용과 제한된 입력변수의 선택에 따른 많은 어려움이 따른다.

CI 기술의 한 영역으로써 본 논문에서는 하이브리드 구조 형태인 고급 뉴로퍼지 다항식 네트워크(Advanced neurofuzzy polynomial networks:ANFPN) 구조를 제안한다. 또한 제안된 구조의 개발을 위해 광범위한 설계방법을 토의한다. ANFPN 구조는 두 구조, 즉 뉴로퍼

지 네트워크(Neurofuzzy networks:NFN)와 다항식 뉴럴네트워크(Polynomial neural networks:PNN)를 기반으로 구성되며 전반부 구조로 NFN을, 후반부 구조로 PNN을 이용한다. ANFPN의 전반부 구조인 NFN은 Yamakawa가 제안한 구조<sup>[6]</sup>로 다른 비선형 모델에 비해서 학습속도가 빠르고 수렴특성이 우수하다는 장점을 가졌으며 간략추론, 오류역전과 학습 규칙을 이용한다. 멤버쉽함수의 파라미터, 학습률, 모멘텀 계수 등과 같은 NFN의 파라미터는 유전자 알고리즘에 의해 최적화된다. ANFPN의 후반부 구조로 이용된 PNN은 GMDH(Group method of data handling)<sup>[1]</sup>에 기반하여 학습(성장)을 통해 생성되는 유연한 구조로 PNN의 층과 노드 수는 고정되어 있지 않고 동적으로 생성 및 소멸한다. PNN<sup>[18]</sup>의 각 노드는 높은 유연성을 보여주며, 입력과 출력 변수 사이의 회귀다항식 함수에 의해 구현된다. 본 논문에서는 PNN 구조의 특성상 4입력 이상의 시스템 입력변수를 요구하는 단점을 보완하기 위해 PNN 구조를 개선한다. 이는 적은 입력변수 수를 가진 시스템에 대해서도 PNN의 다양한 구조 적용이 용이하도록 한다.

제안된 ANFPN은 NFN과 PNN의 상호 보완적 특성을 가진다. 즉 NFN은 PNN 구조의 적용이 용이하도록 입력에 대한 출력 특성 및 성능을 향상시키며, 최적의 네트워크를 생성하도록 한다. 또한 후반부에 이용된 PNN은 NFN의 학습방법인 오류역전과 학습방법을 도와 좀더 우수한 성능을 나타내도록 한다. 두 구조의 결합 형태인 ANFPN 구조로 공정의 비선형적 특성을 고려할 수 있을 뿐만 아니라 우수한 예측능력을 가진 좋은 출력성능을 얻을 수 있다. ANFPN은 기본 구조와 변형된 구조로 나누어 설계되며, 특히 후반부 구조인 PNN은 일반 구조로부터 고급 구조로 개선함으로 네트워크의 적용 능력과 성능을 향상시킨다. 기존의 지능 모델의 성능평가를 위해 널리 사용된 비선형 함수<sup>[7~10]</sup>와 가스로 공정<sup>[11~13,16,17]</sup>을 이용하여 제안된 모델의 유용성과 실용성을 논의하며 기존의 모델보다 높은 정밀도와 예측능력을 가진 모델을 생성함을 보인다.

## II. 고급 뉴로퍼지 다항식 네트워크(ANFPN) 구조와 알고리즘

이 장에서는 ANFPN의 구조와 설계과정에 대해 논한다. ANFPN은 서로 다른 구조, 즉 NFN<sup>[6]</sup>과 PNN<sup>[18]</sup>

의 합성에 의해 형성되며, 이들 두 구조의 결합에 따른 상승효과를 얻을 수 있다.

### 1. ANFPN의 구조

제안된 ANFPN은 전반부로 NFN과 후반부로 PNN의 합성 구조로, 크게 기본 구조와 변형된 구조로 설계 할 수 있다. 이 두 구조는 ANFPN의 후반부인 PNN 각 층의 노드 입력변수 수와 회귀다항식 차수에 의해 결정된다.

#### (1) ANFPN의 전반부 구조; 뉴로퍼지 네트워크 (NFN)

제안된 ANFPN의 전반부 구조를 형성하는 NFN<sup>[6]</sup>은 퍼지추론과 신경망의 융합에 의한 구조로 다른 모델에 비해 학습속도가 빠르고 수렴특성이 매우 우수하다는 장점을 가지며 그림 1과 같은 구조를 가진다.

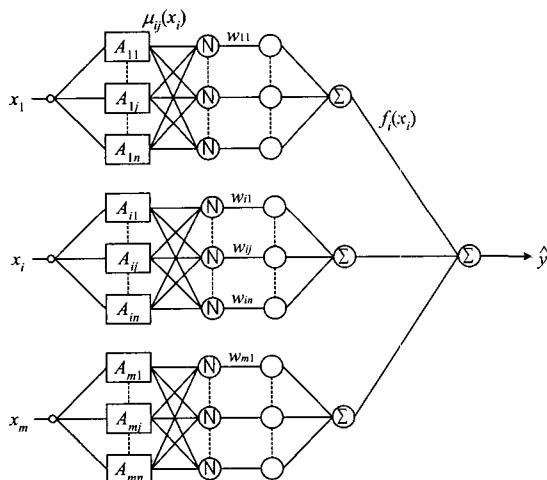


그림 1. NFN 구조

Fig. 1. NFN structure.

그림 1에서 '사각형'과 '원'은 NFN의 뉴론 유니트를 나타내고, 'N'은 정규화를 의미한다. 입력  $x_i$ 는 사각형으로 표시된 각 멤버쉽함수 뉴론을 거쳐 적합도가 구해지고 그 적합도는 정규화된 후, 연결 가중치  $w_{ij}$ 와 곱해지며 이들이 ' $\Sigma$ ' 뉴론에 의해 대수적으로 합해져  $i$  번째 출력  $f_i(x_i)$ 를 생성한다. 생성된 각 입력변수에 대한 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 다음과 같은 퍼지규칙을 이룬다.

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

(2)에서  $R^j$ 는  $j$ 번째 퍼지규칙을 나타내며,  $A_{ij}$ 는 전반부 멤버쉽함수로 본 논문에서는 보수적(complementary) 관계를 가진 삼각형 형태이다. 후반부의  $w_{ij}$ 는 상수이며, 그림 1의 연결 가중치를 나타낸다. (2)의 최종 추론결과는 (3)과 같이 무게 중심법(center of gravity)에 의해 표현된다.

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

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

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

입력변수에 대한 2개의 이웃하는 멤버쉽함수 적합도의 합은  $\mu_{ij}(x_i) + \mu_{ij+1}(x_i) = 1$ . 따라서 (4)는 아래와 같다. 이와 같은 특징 때문에 추론속도가 증가하는 효과를 얻을 수 있다.

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

NFN의 학습은 연결 가중치  $w_{ij}$ 를 모델에 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 오류역전파 알고리즘을 사용하며, 이는 최종출력과 원 출력 데이터간의 차, 즉 오차를 바탕으로 이루어진다.<sup>[6]</sup> 본 논문에서는 (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 출력 데이터,  $\hat{y}_p$ 는 모델의 출력을 나타낸다. N개의 입력 데이터 쌍이 주어진 경우, NFN의 최종 출력 오차

는 (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.

$$w(t+1) = w(t) + \Delta w \quad (8)$$

오차  $E_p$ 를 최소화하기 위한 연결 가중치의 변화량  $\Delta w$ 는 (9)와 같다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) \quad (9)$$

여기서 모멘텀을 더해 학습시간을 좀 더 단축시키고, 학습성능 역시 향상시킨다. 모멘텀은 관성이란 뜻으로, 연결 하중계수의 변화량이 클 경우에는 좀 더 변화량을 키워주고, 변화량이 작아지면 또 여기에 맞춰서 변화량을 줄여주는 역할을 한다. 모멘텀을 포함하는 연결 가중치 변화량은 (10)과 같다.  $\eta$ 는 학습율을,  $\alpha$ 는 모멘텀계수를 나타낸다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (10)$$

본 논문에서는 NFN의 최적화를 위해 유전자 알고리즘을 이용하여 학습율 및 모멘텀계수 그리고 멤버쉽함수의 파라미터를 조정한다. 유전자 알고리즘<sup>[14,15]</sup>은 생물학적 진화, 자연선택, 유전자 재조합의 생물학 원리에 바탕을 둔 확률적 탐색 방법으로, 임재적으로 좋은 결과를 가져다주는 과정을 추적하고, 반면에 지역 극소에 빠질 가능성을 제거하기 위해 임의의 지점을 검사함으로써, 해 공간 전체를 탐색할 수 있는 능력을 가진다.<sup>[14]</sup> 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 위해 2진(binary)형의 직렬방식을 사용하며, 선택(selection)연산으로는 roulette-wheel방식, 교배(crossover)연산은 one-point crossover 연산을 사용한다. 그리고 돌연변이 연산은 선택된 비트를 반전시키는 inversion 방식을 사용한다.<sup>[14,15]</sup>

## (2) ANFPN의 후반부 구조: 다항식 뉴럴네트워크 (PNN)

PNN<sup>[18]</sup>은 본 논문에서 제안한 ANFPN의 후반부를 구성한다. GMDH 알고리즘에 기초한 PNN은 차수 및 입력변수의 선택과 알고리즘의 최종 종료판정 기준에 의하여, 각 층에서 파라미터 동정에 의한 모델을 선정하게 되고, 계층적 모델 추정에 의해 최종 모델을 얻는다. PNN은 추정 모델을 얻기 위해 먼저 부분표현식 (Partial Description; PD)을 구성하며 이 부분 표현식은 표 1과 같은 회귀다항식을 사용한다. 다음에, 입출력 데이터를 이용하여 선형회귀분석으로 부분표현식의 계수를 구하고 중간변수를 구한다. 중간변수에 의한 새로운 입출력 데이터를 구성하여 부분표현식의 계수와 중간 변수를 구한다. 다음 계층에서도 이와 같은 형태의 연산을 되풀이하며, 알고리즘의 종료 판정을 만족할 때까지 반복한다. 알고리즘 종료한 후 얻어진 부분표현식은 계층적으로 조합하여 최종 추정 모델을 얻는다. 표 1은 PNN에 사용된 노드의 입력변수 수와 차수를 나타낸다. 여기서 Type 1과 Type 2는 1차, 2차 다항식, Type 3은 변형된 2차 다항식이다.

표 1. 회귀다항식 형태  
Table 1. Types of regression polynomial.

No. of inputs Order of the polynomial	1	2	3	4
1 (Type 1)	Linear	Bilinear	Trilinear	Tetralinear
2 (Type 2)	Quadratic	Biquadratic-1	Triquadratic-1	Tetraquadratic-1
2 (Type 3)		Biquadratic-2	Triquadratic-2	Tetraquadratic-2

- Bilinear =  $c_0 + c_1x_1 + c_2x_2$
- Biquadratic-1 = Bilinear +  $c_3x_1^2 + c_4x_2^2 + c_5x_1x_2$
- Biquadratic-2 = Bilinear +  $c_3x_1x_2$

PNN 구조는 1 층과 그 이후 층의 부분표현식을 구성하는 방법에 따라 모델의 구조가 정해지는데, 1 층과 그 이후 층이 각각 서로 동일 입력변수 수를 가지는 경우와 서로 다른 입력변수 수를 가지는 경우의 두 구조로 분류되며 이를 기본(Basic) PNN 구조, 변형된(Modified) PNN 구조라 한다. 또한 이를 각 구조는 동일 차수를 가지는 구조(Case 1)와 서로 다른 차수를 가지는 구조(Case 2)로 구분 할 수 있다. 그럼 2는 ANFPN의 후반부 구조인 일반(Generic) PNN 구조를 보여준다.

그러나 그림 2의 구조를 가진 일반 PNN은 적은 입력 시스템을 가진 공정에 대한 적용이 어렵다. 그럼에

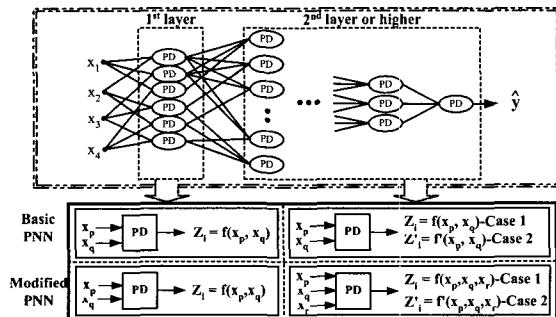


그림 2. 일반 PNN 구조

Fig. 2. Generic PNN structure.

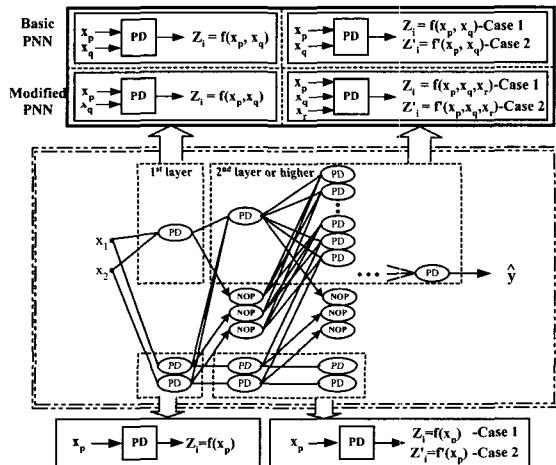


그림 3. 개선된 PNN 구조

Fig. 3. Advanced PNN structure.

서 보여지는 것처럼 PNN의 다양한 구조를 이용하기 위해선 4입력 이상의 시스템 입력을 요구한다. 따라서 본 논문에서는 이러한 PNN의 단점을 보완하고 제안된 모델의 성능 향상을 위해 PNN 구조를 개선한다. 개선된 PNN 구조는 그림 3과 같으며 이는 2 또는 3의 시스템 입력을 가진 공정에 대해서도 PNN의 높은 유연성과 다양한 구조의 효과를 얻을 수 있다. 그림 3에서 화살표는 전 층의 대응하는 동일한 노드가 현재 층으로 이동함을 나타내며, NOP는 연산이 수행되지 않는 노드를 표시한다.

### (3) 기본 ANFPN 구조

기본 ANFPN 구조는 NFN과 개선된 기본(Advanced and basic) PNN의 결합 구조이다. 개선된 기본 PNN 구조는 그림 3과 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. 기본 ANFPN은 그림 4에 나타난 전반부 NFN의 연결점과 그림 3에서의 개선된 기본 PNN의 결합으로부터 그림 5의 구조를 가진다. PNN 1층의 각 노드는 NFN의  $f_i$  출력에 연결된다. 즉, 각 입력신호는 멤버쉽함수를 거쳐 적합도가 구해지고 적합도는 각 입력변수에 대해 정규화된 후 연결 가중치와 곱해지며 이들이 대수적으로 합해져 후반부 PNN의 입력신호가 된다. ANFPN 구조는 전반부 구조인 NFN과 후반부 구조인 PNN의 결합에 의해 입력변수들의 상호관계를 둡고 다중 입력변수 및 고계다항식 구조를 효과적으로 이용할 수 있도록 하며, 모델 출력력을 개선시킨다. 뿐만 아니라 적절한 NFN 출력노드를 PNN에 의해 최적 선택할 수 있어 보다 출력 성능을 향상시킬 수 있다. 기본 ANFPN 구조는 그림 5에서 보여지는 것처럼 후반부 PNN의 구조에 따라 다음의 두 Case로 설계할 수 있다.

Case 1. 동일 입력변수 수와 동일 다항식 차수를 가지는 구조 : 그림 5에서 ANFPN 후반부 2층 이상의 부분표현식이 1층과 동일한  $z_i = f(x_p, x_q)$ 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 2입력 Type 2의 경우  $z = c_0 + c_1x_1 + c_2x_2 + c_3x_1^2 + c_4x_2^2 + c_5x_1x_2$ 가 되며, 2

총 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 5에서 후반부 2층 이상의 부분표현식이  $z_i' = f'(x_p, x_q)$ 의 경우로, 1층에서 2입력 Type 1로 ANFPN 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 5에서 ANFPN 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 되며, 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.

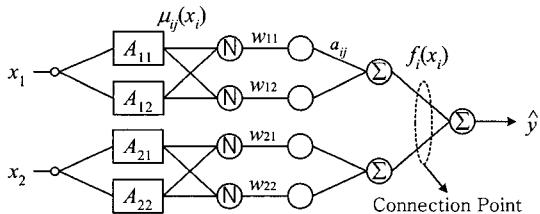


그림 4. PNN과의 결합을 위해 연결점을 가진 NFN 구조

Fig. 4. NFN structure with a connection point for combination with PNN.

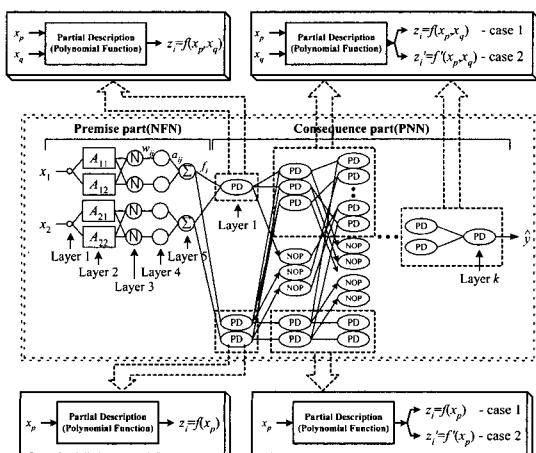


그림 5. 기본 ANFPN 구조

Fig. 5. Basic ANFPN architecture.

#### (4) 변형된 ANFPN 구조

변형된 ANFPN 구조는 NFN과 개선된 변형(Advanced and modified) PNN의 결합이다. NFN은 기본 ANFPN 구조와 마찬가지로 그림 4와 같은 연결점을 가진다. 개선된 변형 PNN 구조는 그림 3과 같이 네트워크를 형성하는 각 층의 노드에 다른 입력변수 수를 적용한 구조이다. 이는 1 층과 2 층 이후의 다항식 입력변수 수가 서로 다른 구조를 가짐으로써 계층구조의 간략성과 상호연계성이 고려된 구조이다. 따라서 복잡한 고차 회귀다항식 사용이 용이하며, 간편한 구조의 구성이라고 할 수 있다. 변형된 ANFPN은 그림 4에 나타난 전반부 NFN의 연결점과 개선된 변형 PNN과의 결합 구조로 그림 6과 같다. 이 구조는 기존의 PNN 구조의 특징을 모두 가지며 또한 전반부 NFN 구조로부터 주어진 시스템 입력에 대해 좋은 특성을 나타낸다. 변형된 ANFPN 구조는 기본 ANFPN 구조와는 달리 후반부 PNN 구조에서 다음의 두 Case로 고려할 수 있다.

Case 1. 서로 다른 입력변수 수와 동일 다항식 차수를 가지는 구조 : 그림 6에서 ANFPN 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. 한 예로 1층을 2입력 Type 1로 설정을 했다면, 2층 이상에서는 3입력 Type 1 구조를 사용할 수 있다. 즉, 1층에서 2입력 Type 1인  $z = c_0 + c_1x_1 + c_2x_2$ 의 형태가 사용되었다면, 2층 이상에서는 1층과 같은 Type 1이고 서로 다른 입력변수 수인 3입력 다항식  $z = c_0 + c_1x_1 + c_2x_2 + c_3x_3$ 가 된다.

Case 2. 서로 다른 입력변수 수와 서로 다른 다항식 차수를 가지는 구조 : ANFPN 구조인 그림 6에서 후반부 1층에서의 부분표현식은  $z_i = f(x_p, x_q)$ 이고, 2층 이상에서의 부분표현식은  $z_i' = f(x_p, x_q, x_r)$ 인 경우로서 1층에서의 부분표현식과 2층 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 6에서 각 층의 부분 표현식인 다항식함수의 출력  $z_i, z_i'$  표시는 서로 다른 Type을 의미한다. 한 예로 1층에 2입력

Type 1의 다항식 구조가 설정되면, 2층 이상에서는 3 입력 Type 3의 다항식구조가 선택될 수 있다.

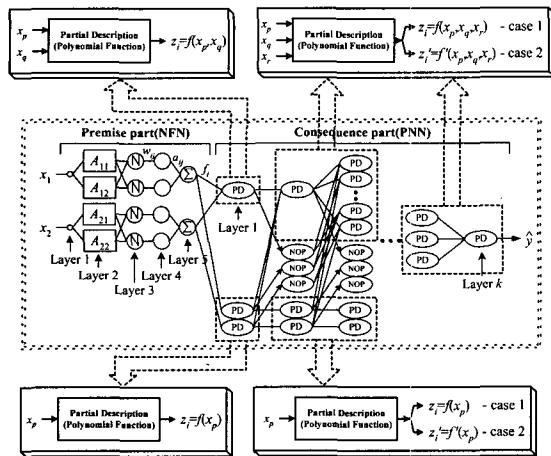


그림 6. 변형된 ANFPN 구조

Fig. 6. Modified ANFPN architecture.

## 2. ANFPN의 알고리즘

ANFPN 구조는 전반부 NFN과 후반부 PNN의 상호 결합으로 구성되어, 후반부 구조인 PNN 형태에 따라 두 가지 구조, 즉 기본 구조와 변형된 구조로 설계할 수 있다. ANFPN 구조의 전반부와 후반부 각 층에 대한 상세 설계과정은 다음과 같다.

### ANFPN의 전반부

**[Layer 1] Input layer :** 입력 신호를 다음 층의 노드에 전달한다. 이 층의 각 노드는 입력변수와 대응하여, 분할된 퍼지공간으로 입력신호를 보낸다.

**[Layer 2] Computing activation degrees of linguistic labels :** 멤버쉽함수는 그림 7과 같은 삼각형 형태이다. 1 층에서 보내진 입력신호  $x_i$ 는  $\mu_{ij}(x_i)$ 로부터 각 규칙의 적합도(활성값)를 구한다.

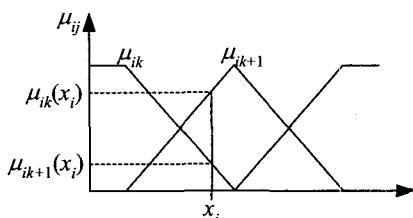


그림 7. 보수적 관계를 갖는 멤버쉽함수

Fig. 7. Complementary membership function.

**[Layer 3] Normalization of a degree of activation(firing) of the rule :** 각 규칙의 적합도(활성값)가 구해지면 정규화된 활성값  $\bar{\mu}_{ij}(x_i)$ 를 계산한다.

$$\bar{\mu}_{ij}(x_i) = \frac{\mu_{ij}(x_i)}{\sum_{j=1}^n \mu_{ij}(x_i)} \quad (11)$$

여기서  $n$ 은 각 입력에 대한 멤버쉽함수의 수이다. 입력변수  $x_i$ 는 그림 7과 같이 동시에 두개의 멤버쉽함수  $k, k+1$ 에만 영향을 받기 때문에 (11)은 다음과 같이 다시 쓸 수 있다.

$$\bar{\mu}_{ik}(x_i) = \frac{\mu_{ik}(x_i)}{\mu_{ik}(x_i) + \mu_{ik+1}(x_i)} = \mu_{ik}(x_i) \quad (12)$$

**[Layer 4] Multiplying a normalized activation degree of the rule by connection weight :** 구해진 정규화된 활성값은 연결 가중치와 곱하여진 후 다음 층의 계산을 위해 보내진다.

$$a_{ij} = \mu_{ij}(x_i) \times w_{ij} \quad (13)$$

**[Layer 5] Fuzzy inference for output of the rules :** 각 입력에 대한 5층 출력은 무게 중심법에 의한 폐지 추론에 의해 구해지며 (14)와 같다.

$$f_i(x_i) = \frac{\sum_{j=1}^n a_{ij}}{\sum_{j=1}^n \mu_{ij}(x_i)} = \frac{\sum_{j=1}^n \mu_{ij}(x_i) \cdot w_{ij}}{\sum_{j=1}^n \mu_{ij}(x_i)} \quad (14)$$

(11), (12), (13)에 의해 (14)를 정리하면,

$$f_i(x_i) = \mu_{ik}(x_i) \cdot w_{ik} + \mu_{ik+1}(x_i) \cdot w_{ik+1} \quad (15)$$

출력  $f_i$ 는 ANFPN의 후반부 구조인 PNN의 입력이 된다.

**[Output layer of NFN] Computing the output of NFN :** 5층에서 출력된 값들은 (1)과 같아 대수적으로 합해져 NFN의 출력  $\hat{y}$ 를 최종적으로 계산하게 된다.

### ANFPN의 후반부

**[Step 1] Configuration of input variables :** 그림 5 와 6에서 보여지는 것처럼 전반부 5층 출력인  $f_i$ 를 후반부의 입력변수로 설정한다. 즉,  $x_1 = f_1, x_2 = f_2, \dots, x_n = f_m$  ( $n = m$ :전반부 입력변수의 수)

[Step 2] **Forming a PNN structure** :  $n$ 개의 입력변수  $x_1, x_2, \dots, x_n$  중 노드의 입력변수 수를 선택하고 입력에 대한 노드의 다항식 차수를 선택한다. 노드의 입력변수 수를  $r$ 개 선택할 경우 발생하는 노드의 수  $k$ 는  $\frac{n!}{(n-r)!r!}$  가 된다. 여기서  $n$ 은 전체 입력변수의 수이고,  $r$ 은 선택된 입력변수의 수 즉, 노드의 입력변수 수이다. 예를 들어 PNN 각 노드의 부분 표현식을 2입력 1차식이라 하자.  $n$ 개의 입력변수 중에서 두 개의 입력변수  $x_p, x_q$ 를 선택하면, 다음과 같은 부분표현식  $k$ 개를 얻을 수 있다.

$$z_k = c_0 + c_1 x_p + c_2 x_q \quad k = 1, 2, \dots, \frac{n!}{(n-2)!2!} \quad (16)$$

여기서,  $c_0, c_1, c_2$ 는 계수이며,  $z_k$ 는 중간변수이다.

[Step 3] **Estimate the coefficients of a PD** : 선형 회귀분석에 의해 학습용 데이터를 사용하여, (17)을 최소화하는 계수  $c_0, c_1, c_2$ 를 구한다.

$$E = \frac{1}{2} \sum_{p=1}^N (y_p - \hat{z}_p)^2 \quad (17)$$

[Step 4] **Choosing PDs with the highest predictive capability** : 계수를 추정한 (16)의 부분표현식(PD)에 테스트 데이터를 대입하고, (7)에 의한 출력 오차  $E$ 를 계산한다. 얻어진  $E_1, E_2, \dots, E_{\frac{n!}{(n-r)!r!}}$ 에 대해서 값이 작은 노드의 출력을 다음 층의 입력으로 선택한다. 이때 노드의 선택은 값이 작은 순으로  $W$ 개를 선택하고,  $W$ 개를 제외한 노드는 버린다. 즉 일정한 노드의 수를 유지해 나간다.

(a)  $\frac{n!}{(n-r)!r!} < W$  인 경우 다음 층 입력변수의 수는  $\frac{n!}{(n-r)!r!}$  이다.

(b)  $\frac{n!}{(n-r)!r!} \geq W$  인 경우 다음 층 입력변수의 수는  $W$ 이다.

[Step 5] **Termination condition** : 알고리즘을 종료하는 방법으로는 2가지 방법이 사용된다. 첫 번째로 [Step 4]에서 얻어진 현재 층의 최소 오차  $E_{min}$ 이 다음의 부등식을 만족할 경우에 알고리즘을 종료한다.

$$E_{min} \geq E_{min*} \quad (E_{min*} \text{는 전 층의 최소 오차}) \quad (18)$$

두 번째 방법으로는 정해진 층수에 의해 알고리즘을

종료한다. 본 논문에서는 두 방법을 사용하여 구조의 복잡성과 모델의 정확성 사이의 상호균형을 고려한다.

[Step 6] **Determining new input variables for the next layer** : 종료 판정을 만족하지 않을 경우,  $x_1 = z_1, x_2 = z_2, \dots, x_W = z_W$ 가 되어 새로운 출력 데이터를 구성하고, [Step 3]부터 [Step 6]까지를 반복한다. 알고리즘이 종료할 경우,  $E_{min}$ 를 얻은 부분표현식에 전 층에서의 중간변수를 대입하고, 동일한 조작을 되풀이하여 최종 추정 모델  $\hat{y}$ 를 얻는다.

그림 8은 ANFPN의 설계과정을 전체 흐름도를 통해 보여주고 있다.

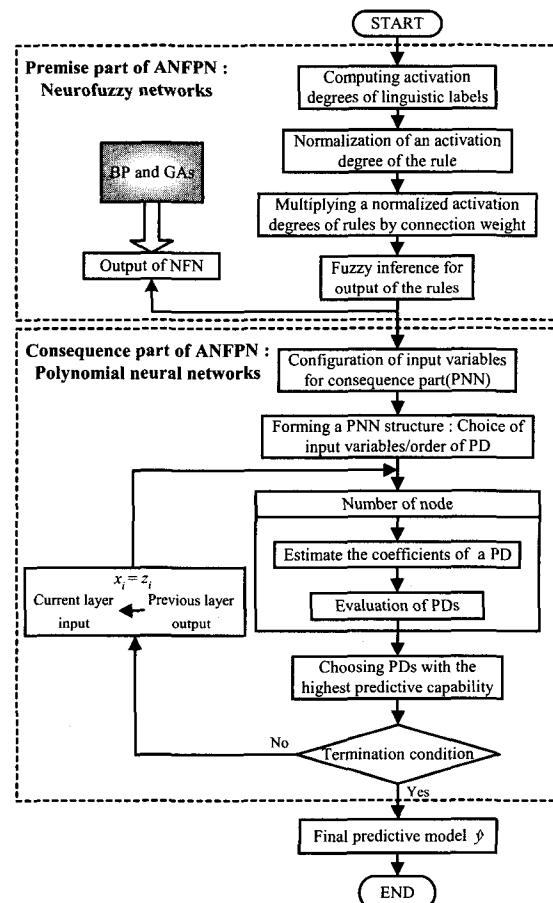


그림 8. ANFPN 설계를 위한 전체 흐름도

Fig. 8. An overall flowchart for the design of the ANFPN.

### III. 시뮬레이션 및 결과 고찰

제안된 ANFPN 구조의 시뮬레이션 및 평가를 위해 두 종류의 수치 데이터를 이용한다. 첫 번째는 간단한

수치 예제인 비선형 함수<sup>[7~10]</sup>를, 두 번째는 비선형 공정에 대한 성능 평가의 척도로 사용되고 있는 가스로 공정<sup>[11~13,16,17]</sup>을 사용한다. 이들은 입력과 출력의 관계를 나타내는 다수 데이터의 집합으로 나타내어진다. 모델의 평가 기준인 성능지수(Performance Index:PI)는 비선형 함수와 가스로 공정에 대해서 MSE(Mean Squared Error), 즉 (7)을 이용한다.

앞서 언급한 ANFPN의 전반부 구조인 NFN의 최적화를 위하여 사용된 유전자 알고리즘<sup>[14,15]</sup>의 해당 연산 값들로 세대는 100세대, 군집은 60개체까지 진행시켰으며, 각 문자열의 길이는 10 bit를, 교배율은 0.6, 돌연변이 발생율은 0.35를 사용한다.

### 1. 비선형 함수

모델링 성능 평가를 위해 광범위하게 이용되는 2입력 비선형 함수<sup>[7~10]</sup>는 (19)와 같이 표현되며 그림 9와 같은 비선형 특징을 나타낸다. 제안된 ANFPN 모델은 그림 9와 같은 입출력 관계를 가진 시스템 방정식으로부터 얻어진 50개의 입출력 데이터 쌍을 적용함으로써 제안된 모델의 타당성 및 정확도를 기존 모델과 비교 검토한다.

$$y = (1 + x_1^{-2} + x_2^{-1.5})^2, \quad 1 \leq x_1, x_2 \leq 5 \quad (19)$$

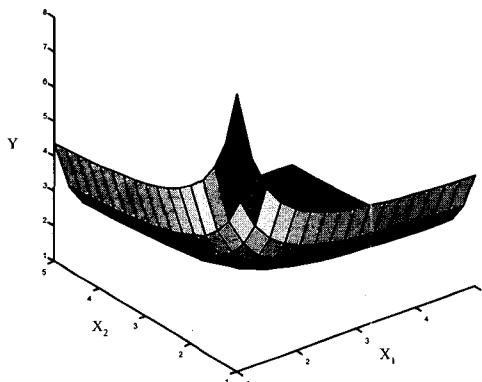


그림 9. 비선형 함수의 입출력 관계

Fig. 9. Input-output relation of nonlinear function.

ANFPN의 전반부 구조에 이용된 NFN은 각 입력에 대해 2개인 멤버쉽함수 혹은 3개인 멤버쉽함수를 고려한다. 전반부 NFN 구조는 유전자 알고리즘에 의해 학습율 및 모멘텀계수 그리고 멤버쉽함수의 파라미터를 동조한 것으로, 멤버쉽함수 개수가 각 입력에 대해 2개 즉 4개의 규칙을 가질 때 PI=0.099이며, 각 입력에 대

해 3개 즉 6개의 규칙을 가질 때 PI=0.036의 성능지수 값을 가진다. ANFPN의 후반부 구조인 PNN은 적은 수의 시스템 입력을 가진 공정에 대해 고차 회귀다항식의 구조와 변형된 구조를 적용할 수 있도록 그림 3과 같은 개선된 구조를 적용한다. 표 2는 4개의 규칙을 가진 ANFPN의 성능지수를 전반부와 후반부의 결합 구조와 후반부 각 층에서의 최적 성능지수를 보여주고 있으며, 표 3은 6개의 규칙을 가진 ANFPN의 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 ANFPN 구조의 '2입력'은 모든 층의 노드 입력 수가 '2'이고 변형된 구조의 '2→3입력'은 1층 노드는 2입력을 2층 이상의 노드는 3 입력을 가진 구조를 의미한다. 'Type c'는 모든 층 노드의 다항식 차수를 의미하고, 'Type c→d'는 다항식 차수가 1층 노드는 Type c, 2층 이상 노드는 Type d로 변하는 구조를 나타낸다. 즉, 'Type 2'는 모든 층의 노드가 2차 회귀다항식 구조이고, 'Type 3→2'는 1층 노드는 변형된 2차(Type 3), 2층 이상 노드는 2차 회귀

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

Case 1	2+2	2 입력 Type 2	1	0.0553
			2	0.0499
			3	0.0345
			4	0.0291
			5	0.0247
Case 2	2+2	2 입력 Type 3→2	1	0.0973
			2	0.0550
			3	0.0438
			4	0.0318
			5	0.0259
Case 1	2+2	2→3 입력 Type 2	1	0.0553
			2	0.0297
			3	0.0259
			4	0.0213
			5	0.0148
Case 2	2+2	2→3 입력 Type 1→2	1	0.0976
			2	0.0553
			3	0.0297
			4	0.0234
			5	0.0150

Table 3. Performance index of ANFPN with 6 rules.

Case 1	3+3	2 입력 Type 2	1	0.0290	
			2	0.0288	
			3	0.0250	
			4	0.0204	
			5	0.0105	
Case 2	3+3	2 입력 Type 3→2	1	0.0307	
			2	0.0290	
			3	0.0251	
			4	0.0229	
			5	0.0153	
Case 1	3+3	2→3 입력 Type 2	1	0.0290	
			2	0.0236	
			3	0.0207	
			4	0.0153	
			5	0.0081	
Case 2	3+3	2→3 입력 Type 3→2	1	0.0307	
			2	0.0280	
			3	0.0238	
			4	0.0157	
			5	0.0082	

다항식(Type 2)인 구조이다. 각 입력에 대한 회귀다항식 형태는 표 1과 같다.

표 2와 3에서 알 수 있듯이 제안된 ANFPN모델 구조는 NFN 자체 모델보다 우수한 구조를 가지고 있을 뿐만 아니라 개선된 형태의 PNN 구조를 이용함으로써 PNN의 다양한 회귀다항식 구조를 적용할 수 있고, 설계자가 원하는 모델을 설계할 수 있다. 또한 기본 구조보다는 변형된 구조에서 좋은 결과를 얻을 수 있는데 이것은 변형된 구조가 각 층에서 서로 다른 입력변수 구조를 가짐으로써 일반형 구조보다 좀더 상호연계성이 고려된 구조이기 때문이다. 따라서 다변수 고차 회귀다항식을 효과적으로 이용할 수 있다.

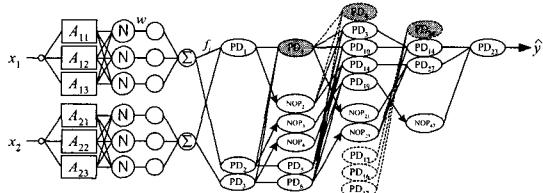


그림 10. 변형된 ANFPN의 최적 구조(Case 1)  
 Fig. 10. Optimal architecture of the modified  
 ANFPN in Case 1.

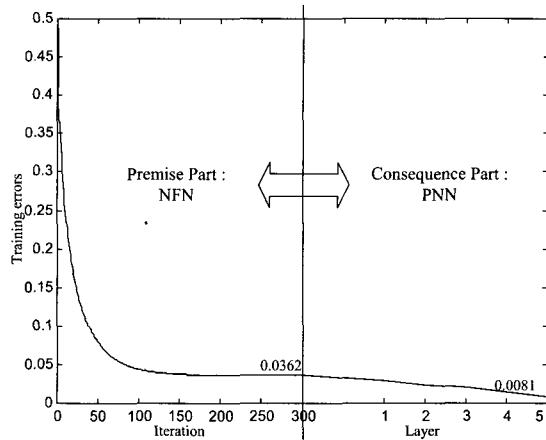


그림 11. 변형된 ANFPN의 학습 과정(Case 1)  
 Fig. 11. Learning procedure of the modified ANFPN  
 in Case 1.

비선형 함수에 대한 ANFPN 최적 구조로 6개의 규칙을 가진 NFN과 2~3입력 Type 2의 PNN이 결합한 구조를 선택하였을 때 변형된 ANFPN 최적 네트워크는 그림 10과 같다. 이때 PI는 0.0081이다. 여기서 PD는 부분표현식(Partial Description) 즉 회귀다항식을 말하며 번호는 선택된 노드의 번호이다. 실선 노드는 출력  $\hat{y}$ 를 생성하기 위해 사용된 노드로 진하게 표시된 노드는 현재 층에서 최적인 노드 즉 예리가 최소가 되는 노드이다. 일반 점선으로 표시된 노드는 출력  $\hat{y}$  생성에 사용되지 않는 노드이고, 점선으로 표시된 노드 중 진하게 표시된 노드는 최적의 ANFPN 네트워크를 생성하는 과정에서 제외되지만 현재 층에서 최소값의

표 4. 기존 모델과의 동정오차 비교  
 Table 4. Comparison of identification errors  
 with previous models.

Model	PI		
Sugeno and Yasukawa[7]	0.079		
Gomez-Skarmeta et al.[8]	0.070		
Kim et al.[9]	0.019		
Kim et al.[10]	0.0089		
제안된 모델 (ANFPN)	기본 구조	Case 1	0.0105
		Case 2	0.0153
	변형된 구조	Case 1	0.0081
		Case 2	0.0082

성능지수를 가진 노드를 나타낸다. 그림 11은 기본 ANFPN 구조의 학습과정을 보여주고 있다. 표 4는 기존의 모델링과 본 논문에서 제안한 ANFPN과의 동정 오차를 비교하여 제안된 방법이 우수한 특성을 나타냄을 보였다.

## 2. 가스로 시계열 공정

Box와 Jenkin<sup>[1]</sup> 사용한 가스로 시계열 데이터<sup>[11]</sup>를 이용하여 입출력 데이터인 가스 흐름율과 연소된 이산화탄소 농도를 모델 동정에 이용한다. 이 공정 데이터는 기존의 모델 성능평가를 위해 많이 적용된 표준 데이터로써, 본 논문에서 제안한 ANFPN 구조의 타당성과 유용성 평가를 위해 이용된다. 가스로 공정 모델링을 위해 입출력 데이터 쌍으로 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. 입력( $u(t)$ )은 가스 흐름율이고 출력( $y(t)$ )은 이산화탄소 농도이다.

표 5와 6은 각각 2입력과 3입력 ANFPN의 성능지수를 보여주고 있다. 전반부에 이용된 NFN은 각 입력에 대해 2개의 멤버쉽함수를 가지며, 유전자 알고리즘 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. 2입력 1출력 ANFPN 모델은 후반부 구조인 PNN의 다양한 변화를 위해 개선된 모델을 사용하여 최적의 네트워크를 생성한다. 성능지수 표에 보여지는 것처럼 제안된 구조는 변형된 구조에서 좋은 출력 특성을 가진다. 즉 NFN과 PNN의 결합 형태인 ANFPN은 구조를 다양하게 변화시킴으로써 설계자가 원하는 모델을 얻을 수 있으며, 적은 시스-

템 입력을 가진 모델에 대해서도 다중 입력과 고차 회귀다항식의 다층 구조를 효과적으로 이용할 수 있다.

표 5. 2입력 ANFPN 성능지수

Table 5. Performance index of ANFPN with 2 inputs.

Case	2+2	2 입력 Type 2	1	0.0247	0.339
			2	0.0247	0.338
Case 1			3	0.0242	0.330
			4	0.0226	0.274
			5	0.0231	0.270
Case 2	2+2	2 입력 Type 1→2	1	0.0251	0.329
			2	0.0247	0.339
			3	0.0236	0.334
			4	0.0243	0.320
			5	0.0237	0.277
Case 1	2+2	2→3 입력 Type 2	1	0.0247	0.339
			2	0.0241	0.346
			3	0.0237	0.341
			4	0.0216	0.282
			5	0.0194	0.267
Case 2	2+2	2→3 입력 Type 3→2	1	0.0248	0.328
			2	0.0237	0.344
			3	0.0209	0.304
			4	0.0222	0.277
			5	0.0199	0.264

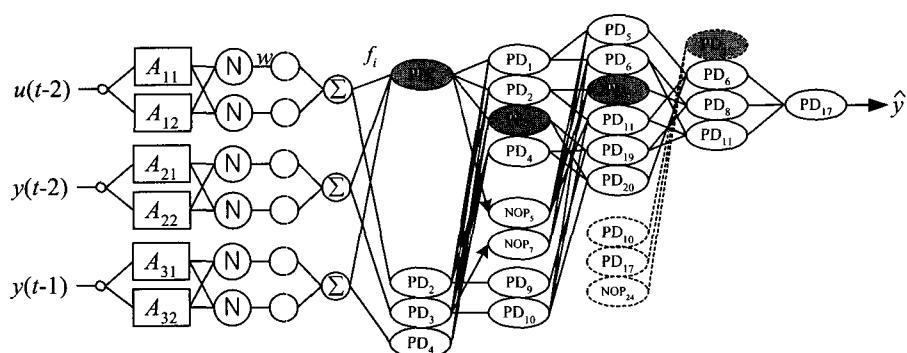


그림 12. 기본 ANFPN의 최적 구조(Case 2)

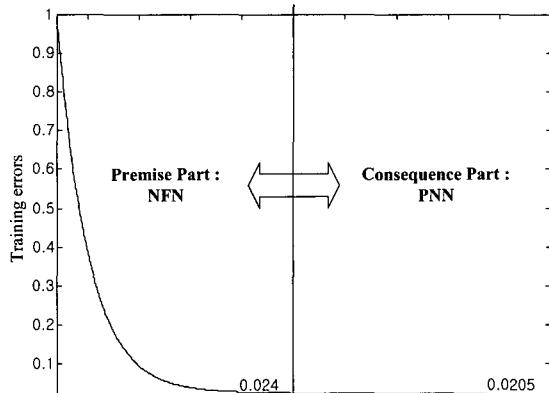
Fig. 12. Optimal architecture of the basic ANFPN architecture in Case 2.

표 6. 3입력 ANFPN 성능지수

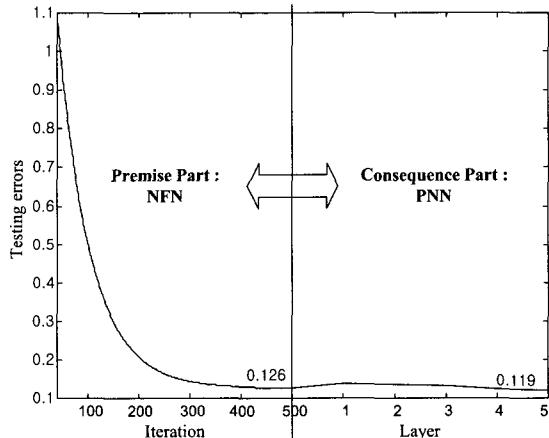
Table 6. Performance index of ANFPN with 3 inputs.

			P	E.PI
Case 1	2+2+2	3 입력 Type 2	1	0.0217 0.143
			2	0.0217 0.143
			3	0.0216 0.133
			4	0.0204 0.126
			5	0.0198 0.121
Case 2	2+2+2	3 입력 Type 1→3	1	0.0224 0.137
			2	0.0220 0.134
			3	0.0221 0.131
			4	0.0203 0.123
			5	0.0205 0.119
Case 1	2+2+2	2→4 입력 Type 2	1	0.1046 0.198
			2	0.0194 0.132
			3	0.0184 0.122
			4	0.0181 0.119
			5	0.0178 0.115
Case 2	2+2+2	3→4 입력 Type 3→2	1	0.0221 0.135
			2	0.0204 0.147
			3	0.0191 0.127
			4	0.0198 0.120
			5	0.0177 0.113

그림 12는 3입력 기본 ANFPN의 Case 2 구조를 보여 주고 있다. 전반부 구조인 NFN은 각 입력에 대해 2개의 멤버쉽함수를 적용하였고 후반부 구조인 PNN은 3입력 Type 1→3 구조를 가진다. 이 구조의 학습과정을 그림 13에 보였으며, 그림 13(a)는 학습 데이터에 대해, 그림 13(b)는 테스트 데이터에 대한 학습 과정을 보여주고 있다. 그림 14은 NFN과 3→4입력 Type 3→2 구조를 가진 PNN의 결합인 변형된 ANFPN의 최적 구



(a) Performance index for Training(PI)



(b) Performance index for evaluation(E\_PI)

그림 13. 기본 ANFPN의 학습 과정(Case 2)  
Fig. 13. Learning procedure of the basic ANFPN in Case 2.

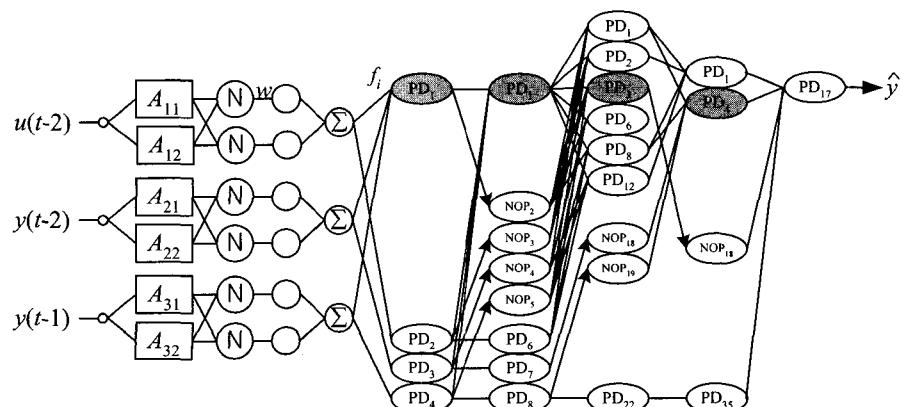
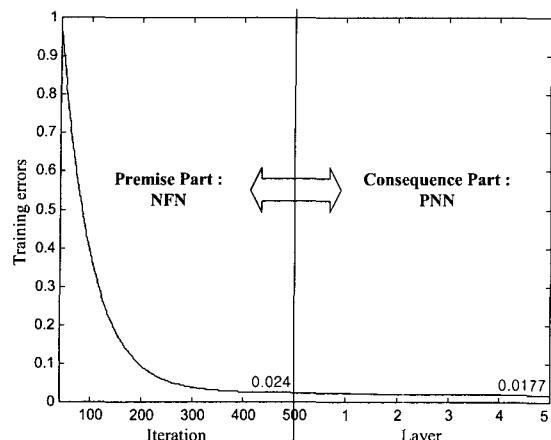
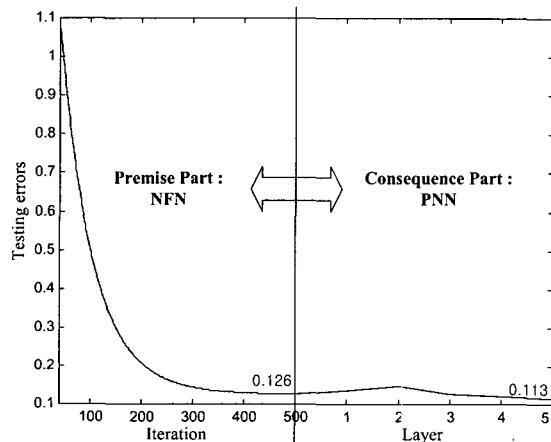


그림 14. 변형된 ANFPN의 최적 구조(Case 2)

Fig. 14. Optimal architecture of the modified ANFPN architecture in Case 2.



(a) Performance index for Training(PI)



(b) Performance index for evaluation(E\_PI)

그림 15. 변형된 ANFPN의 학습 과정(Case 2)  
Fig. 15. Learning procedure of the modified ANFPN  
in Case 2.

표 7. 기존 모델과의 동정오차 비교  
Table 7. Comparison of identification errors  
with previous models.

		Lin and Cunningham's model[12]		0.071	0.261	
		Kim's model[10]		0.034	0.244	
		Oh's fuzzy model[16]		0.020	0.264	
		Oh's FNN model[17]		0.021	0.332	
제안된 모델 (ANFPN)		Oh and Pedrycz's fuzzy model[13]		0.020	0.271	
		2입 력	기본 구조	Case 1	0.0231	0.270
			변형된 구조	Case 2	0.0237	0.277
		3입 력	기본 구조	Case 1	0.0194	0.267
			변형된 구조	Case 2	0.0199	0.264
			기본 구조	Case 1	0.0198	0.121
			변형된 구조	Case 2	0.0205	0.119

조를 보이며, 그림 15는 이 구조에 대한 학습과정을 보여준다. 그림 12와 14에서 보여지는 것처럼 최적 네트워크는 각 특징에 따라 서로 다른 네트워크를 형성함을 알 수 있다. 지금까지 제안된 ANFPN 구조를 가스로 공정에 적용하여 모델 설계 및 각 구조에 대한 평가를 하였다. 표 7은 기존의 모델링 방법과 제안된 모델링 방법의 동정오차를 비교하여 보여주며, 제안된 모델은 기존 모델들의 학습 성능지수보다 우수할 뿐만 아니라, 테스트 데이터를 고려한 테스트 성능 즉 예측 성능면에서도 우수한 특성을 보인다.

#### IV. 결 론

복잡한 비선형 시스템의 최적 모델 동정을 위하여 뉴로퍼지 컴퓨팅의 새로운 구조 형태인 하이브리드형 구조, 즉 ANFPN 구조를 제안하였으며 구조 설계를 위한 상세 과정을 논의하였다. 제안된 ANFPN은 NFN과 PNN을 기반으로 한 합성구조로 NFN은 ANFPN 구조의 전반부를, PNN은 후반부를 구성한다. 적은 입력을 가진 시스템에 대한 적응성을 높이기 위해 후반부 구조인 PNN을 개선함으로 전체 ANFPN 구조의 유연성(적응성), 확장성 및 출력성능을 향상시켰다. 이를 바탕으로 기본 구조와 변형된 구조를 가진 ANFPN 구조를 설계하였다. 제안된 ANFPN 구조는 NFN의 연결점과 보다 다양하고 유연한 구조를 가진 PNN 구조와의 결합을 통해 비선형 공정 특성에 따른 유연성을 가진, 즉 노드의 생성 및 소멸과정을 거쳐 최적의 네트워크 구조를 얻을 수 있었고 이러한 특징을 가진 ANFPN은 구조 설계에 의한 모델의 표현과 적응 능력으로부터 복잡한 다변수 비선형계의 시스템에 대해 우수한 근사 및 예측성능을 가진 모델 동정이 가능하였다.

#### 참 고 문 헌

- [ 1 ] 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.
- [ 2 ] H. Takagi and I. Hayashi, "NN-driven Fuzzy Reasoning," Int. J. of Approximate Reasoning, Vol. 5, No. 3, pp. 191~212, 1991.
- [ 3 ] Shin-ichi Horikawa, Takeshi Furuhashi and

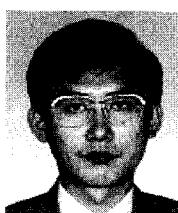
- Yoshiaki Uchigawa, "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back Propagation Algorithm," IEEE Trans. Neural Networks, Vol. 3, No. 5, pp. 801~806, 1992.
- [4] N. Imaasaki, J. Kiji and T. Endo, "A Fuzzy Rule Structured Neural Networks," Journal of Japan Society for Fuzzy Theory and Systems, Vol. 4, No. 5, pp. 985~995, 1992(in Japanese).
- [5] H. Nomura and Wakami, "A Self-Tuning Method of Fuzzy Control by Descent Methods," 4th IFSA World Conference, pp. 155~159, 1991.
- [6] Takeshi Yamakawa, "A New Effectie Learning Algorithm for a Neo Fuzzy Neuron Model," 5th IFSA World Conference, pp. 1017~1020, 1993.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] G. E. Box and G. M. Jenkins, Time Series Analysis : Forecasting and Control, Holden-day, 1970.
- [12] Y. Lin and G. A. Cunningham III, "A new approach to fuzzy-neural modeling," IEEE Trans. on Fuzzy Systems, Vol. 3, No. 2, pp. 190~197, 1995.
- [13] S. K. Oh and W. Pedrycz, "Fuzzy Identification by Means of Auto-Tuning Algorithm and Its Application to Nonlinear Systems," Fuzzy Sets and Syst., Vol. 115, No. 2, pp. 205~230, 2000.
- [14] David E. Goldberg, Genetic Algorithms in search, Optimization & Machine Learning, Addison-wesley, 1989.
- [15] Zbigniew Michalewicz, Genetic Algorithms+Data Structure=Evolution Programs, Springer-Verlag, 1992.
- [16] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하증값을 이용한 퍼지 시스템의 최적화," 대한전기학회논문지, 제48A권, 제6호, pp. 789~799, 1999
- [17] 오성권, 박병준, 박춘성, "적응 퍼지-뉴럴네트워크를 이용한 비선형 공정의 온-라인 모델링," 대한전기학회논문지, 제48A권, 제10호, pp. 1293~1302, 1999
- [18] 오성권, 김동원, 박병준, "다항식 뉴럴네트워크 구조의 최적 설계에 관한 연구," 대한전기학회논문지, 제49D권 3호, pp. 145~156, 2000

## 저자소개



朴炳俊(正會員)

1972년 12월 1일생. 1998년 원광대 제어계측공학과 졸업. 동대학원 석사(2000). 2000년~현재 동대학 박사과정. <주관심분야 : 시스템자동화, 퍼지이론 및 뉴로퍼지네트워크 응용, 지능형 모델링 및 계산지능 등>



吳聖權(正會員)

1957년 2월 13일생. 1981년 연세대학교 전기공학과 졸업. 1983~89년 금성산전연구소(선임연구원). 1993년 연세대 대학원 전기공학과 졸업(공부). 1996~1997년 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1993년~현재 원광대 전기전자 및 정보공학부 부교수. 현재 대한전기학회, 제어자동화시스템 공학회 편집위원. <주관심분야 : 시스템자동화, 퍼지이론 및 뉴로퍼지네트워크 응용, 계산지능 및 소프트 컴퓨팅 등>