

퍼지 뉴럴 네트워크 구조로의 새로운 모델링 연구

A New Modeling Approach to Fuzzy-Neural Networks Architecture

박 호 성, 오 성 권, 윤 양 응
(Ho-Sung Park, Sung-Kwun Oh, and Yang-Woung Yoon)

Abstract : In this paper, as a new category of fuzzy-neural networks architecture, we propose Fuzzy Polynomial Neural Networks (FPNN) and discuss a comprehensive design methodology related to its architecture. FPNN dwells on the ideas of fuzzy rule-based computing and neural networks. The FPNN architecture consists of layers with activation nodes based on fuzzy inference rules. Here each activation node is presented as Fuzzy Polynomial Neuron(FPN). The conclusion part of the rules, especially the regression polynomial, uses several types of high-order polynomials such as linear, quadratic and modified quadratic. As the premise part of the rules, both triangular and Gaussian-like membership functions are studied. It is worth stressing that the number of the layers and the nodes in each layer of the FPNN are not predetermined, unlike in the case of the popular multilayer perceptron structure, but these are generated in a dynamic manner. With the aid of two representative time series process data, a detailed design procedure is discussed, and the stability index is introduced as a measure of stability of the model for the comparative analysis of various architectures.

Keywords : FPNN(Fuzzy Polynomial Neural Networks), FPN(Fuzzy Polynomial Neuron), GMDH(Group Method of Data Handling), Polynomial fuzzy inference, Time series

I. 서론

최근에, 많은 연구자들은 다양한 방법으로 시스템 모델링에 많은 관심을 가지고 있다. 기존엔 여러 가지 형태의 시스템을 모델링하는데 있어서 그 시스템의 변수들을 경험적으로 추측할 수 있는 모델 설계자, 즉 전문가를 필요로 하였으나 이와 같은 경우엔 전문가의 선입관이 첨가되기 때문에 객관적인 모델을 구축할 수가 없었다. 따라서 객관적인 모델을 구축하기 위한 방법 중의 하나로 입-출력 데이터를 기본으로 선형 시스템을 동정하고 예측하는데 광범위하게 이용되는 회귀 분석과 같은 수학적 모델링 방법들이 사용되었다. 그러나 모델링을 하고자 하는 시스템이 복잡하고 대규모의 구조인 경우에는 함수식으로 모델의 표현이 한정되지 않기 때문에 회귀 분석을 적용할 수 없는 경우가 있다.

특히, 모델의 고계 비선형과 다변수 문제를 다룰 때에는 모델의 평가를 위해서 많은 양의 데이터들이 필요하다. 이러한 문제를 풀기 위한 하나의 방법으로 A. G. Ivakhnenko [1]는 GMDH(Group Method of Data Handling) 알고리즘을 소개하였다. GMDH는 시스템의 입력과 출력사이의 비선형 관계를 동정하기 위한 분석적인 기술이다. GMDH을 기반으로 구축된 다항식 네트워크는 표준 인공 신경망보다 더 적은 수의 노드를 가지지만 적응성면에서는 더 우수한 특성을 가진다.

이러한 구조는 과학과 공학[2][3] 등 다양한 분야에서 사

용되어 왔으며 우수한 예측 능력을 가진 모델을 구축한다.

GMDH 알고리즘은 데이터의 부분 표현식의 사용에 의해서 각 층에서의 노드들과 층들이 자기 스스로 연속적인 생성을 통해 최적의 구조를 구축하는 알고리즘이다. 이는 2입력, 2차 회귀다항식의 형태로 복잡한 비선형 시스템을 표현하는데는 어느 정도 한계가 있다.

그리고 퍼지 추론 방법, 특히 규칙 베이스 퍼지모델에 의한 모델링과 예측은 동정 방법에 따라 많은 연구가 수행되어 왔다. 언어적 접근방식에서 Tong은 논리적 조사 방법에 의해 가스로 공정을 동정하였고[4], B. Li 등은 이 방법의 수정으로 더 좋은 결과를 얻는 방법[5]과 결정 테이블에 기초한 자기 학습 알고리즘을 제안하였다. 이 알고리즘은 필요한 컴퓨터 용량 및 계산시간 때문에 고계 다변수 시스템의 적용에 문제점을 발생시켰다[6]. Pedrycz는 언어적 모델링 방법을 기준 퍼지 집합 개념을 이용하여 해석하였다[7]. 퍼지 관계 방정식에 기초한 접근 방식에서, Pedrycz는 퍼지 관계 방정식에 의해 새로운 합성규칙인 기준 퍼지 집합과 Zadeh의 제한적 가능성 분포의 개념에 기초해서 동정하였고[8], Xu는 이 두 가지 방법에 기초한 기준 퍼지 집합 이론과 자기 학습 알고리즘에 의해 퍼지 관계 모델을 구성하여 동정하였으나[5][6], 직접 추론 방식을 사용했기 때문에 혼합(선형)추론 방식 보다 그 성능이 떨어지는 단점이 있다. Sugeno는 자신이 제안한 선형 퍼지추론식에 경험적 방법을 통한 구조동정으로 콤플렉스법과 최소자승법에 의해 시스템을 동정하였으나[9], 전반부 구조동정에서 반복적인 퍼지분할에 의한 경험에 의존하는 문제점이 있다. 또한 퍼지 클러스터링 방법에 의해 가스로 공정을 동정하였으나[10], 직접 추론법에 의한 것으로 동정성능이 떨어졌다. GMDH 방법을 이용한 Hideo Tanaka 등[11][12]은

접수일자 : 2000. 12. 11., 수정완료 : 2001. 5. 29.

박호성 : 원광대학교 제어계측공학과(sung@gaehyok.wonkwang.ac.kr)
오성권, 윤양응 : 원광대학교 전기전자 및 정보공학부(ywyoong@wonkwang.ac.kr/ohsk@wonkwang.ac.kr)

※ 이 논문은 2000년도 원광대학교의 교비지원에 의해서 연구됨.

확신도 인자를 가진 퍼지 후반부 추론 규칙을 구성하기 때문에 좋은 특성을 얻지 못한다. 이들 모든 퍼지 동정 알고리즘은 주어진 공정 데이터에 기초함으로써 보다 좋은 성능, 즉 근사화 능력에 초점이 맞추어져 있고, 많은 최적화 기법과 함께 모듈화된 특별하고 상세한 규칙들의 제한적 표현능력으로 말미암아, 일반적인 퍼지 근사 이론의 실용성으로의 적용은 얼마간 제한되고 있다.

본 논문에서는 새로운 뉴로퍼지 구조로서 퍼지 다항식 뉴럴 네트워크(Fuzzy Polynomial Neural Networks : FPNN)를 제안한다. 제안된 FPNN은 확장된 GMDH 알고리즘과 퍼지 추론시스템의 융합으로부터 얻어지는 네트워크로 완전한 학습구조를 통한 네트워크 생성과정과 설계 방법을 토의한다. FPNN의 각 노드, 즉 퍼지 다항식 뉴런(Fuzzy Polynomial Neuron : FPN)은 퍼지 추론 시스템으로써 동작한다. 규칙 후반부에서 회귀 다항식의 몇 가지 형태를 이용한 FPNN의 구조로부터 시스템 환경에 보다 유연하게 적용할 수 있다.

각 입력 변수의 전반부 퍼지 규칙은 삼각형 또는 가우시안형으로 멤버쉽 함수를 정의하였고, 규칙 후반부의 회귀다항식으로는 간략 및 1차, 2차, 변형된 2차 방정식과 같은 고계 다항식이 사용된다. 이와 같은 FPNN 구조의 다양성으로부터 시스템 환경에 유연한 적용력을 가진 최적설계를 도모한다. 성능 평가를 위해서 Box와 Jenkins가 사용한 가스로 입출력 데이터[13]와 Mackey-Glass 시계열 데이터[14]를 이용하여 제안된 모델 구조의 타당성과 정확성을 시뮬레이션을 통해 확인하고, 근사화와 일반화 능력사이의 균형을 고려한 구조선택을 위해 본 연구에서 제안된 안정도 측도에 대해 토의한다.

II. FPNN 알고리즘과 모델 구조

이 절에서는 FPNN의 기본 처리 유니트으로써 퍼지 추론 시스템 구조인 퍼지 다항식 뉴런(FPN)을 소개한다. 즉, 이 FPN은 'If-then' 규칙들로 구성되고, 이 FPN들이 FPNN을 구축한다. 그리고 이 네트워크의 학습구조에 의한 단계별 알고리즘이 상세히 소개되고, 그 네트워크 내에서 생성되는 다양한 구조에 대해 조사한다.

1. 퍼지 다항식 뉴런(Fuzzy Polynomial Neuron : FPN)

이 절에서 소개된 FPN은 제안한 FPNN의 가장 기본이 되는 처리 단위의 일반적인 형태으로써, 퍼지 집합과 뉴럴 네트워크의 개념에 기초해서 자세히 설명된다. 그림 1에서 보여진 것처럼 FPN은 2개의 기본적인 기능 모듈로 구성되어 있다(여기서, 그림 1은 예를 들어 2입력이고 멤버쉽 함수의 수는 2×2인 경우이다). 처음 하나는 "F"로 표기되어진 것으로, 이는 퍼지 집합의 집합체로써 입력 수의 변수들과 뉴런에 의해 실현된 처리 부분 사이를 상호 연결해준다. 그림에서 x_p 와 x_q 를 입력변수들로 표시한다. "P"로 표기된 두 번째 모듈은 함수 기반 비선형(다항식) 처리에 관한 것이다. 이 비선형 처리는 어떤 입력 변수들(x_i 와 x_j)을 포함한다. 특별히, 비선형성의 다항식 형태인 퍼지 다항식 처리 유니트를 사용한다. 특히, 사용되는 다항식에는 상수 그리고 다항식의 특별한 경우로써의 선형 변환(linear mappings)(규칙 기반 시스템에서 종종 사용되는)을 포함한다.




그림 1. FPN 모듈의 일반적인 구조(F : 퍼지 집합 기반 처리 부분, P : 선형변환의 다항식 형태).

Fig. 1. A general topology of the generic FPN module(F : fuzzy set-based processing part, P : the polynomial form of mapping).

입력 변수들의 수는 데이터의 특성에 따라 변할 수 있다. 앞서 언급하였듯이, 퍼지 집합(여기서는 $\{A_i\}$, $\{B_k\}$)에 의해서 변환되어진 입력 변수들의 집합은 뉴런의 두 번째 다항식 모듈에 의해서 처리되는 변수들과 다르거나, 같거나 그렇지 않으면 부분적으로 중복될 수 있다. 이러한 입력처리 방법은 전체 처리 유니트에 특별한 유연성을 더해준다. 입력변수들을 변환시키기 위해 사용된 퍼지 집합들을 이용하여, FPN은 다중입력 단일출력(MISO) 규칙들을 실현시킨다. 그림 1에서 각 규칙의 형태는 다음과 같다.

$$\text{If } x_p \text{ is } A_i \text{ and } x_q \text{ is } B_k \text{ then } y \text{ is } P_{ik}(x_i, x_j, \mathbf{a}_{ik}) \quad (1)$$

여기서, \mathbf{a}_{ik} 는 규칙 후반부의 파라미터 벡터이다. 단일 FPN 구조에서 수용할 수 있는 규칙의 최대 수는, 각 변수에 대해 정의된 퍼지 집합 수와 변수 자신들의 수에 의해 결정된다. FPN의 입력변수들이 두 기능 모듈과 상호 작용하는 방법을 나타내기 위해 $FPN(x_p, x_q; x_i, x_j)$ 으로 표기하여 사용한다.

FPN의 처리는 참고문헌 [7][15]에 나타난 규칙 베이스 컴퓨팅 중에 있는 다음 표현식에 의해 연산처리 된다.

a) 규칙 "K"의 활성화는 규칙 안에 있는 퍼지 집합의 활성화인 'AND-합성'으로써 계산된다. 각 규칙 조건부의 이 합성은 일반적으로 사용되는 최소 및 곱의 어떤 t-norm을 통해 실현된다. μ_K 는 각 규칙의 활성화 레벨을 표시한다.

b) 규칙들의 활성화 레벨은 각 다항식의 조건부(함수변환) P_K 의 하중평균으로써 계산된 FPN의 출력에 기여한다(규칙의 index, K는 규칙 (1)에서 사용된 퍼지집합 두 개의 index에 대한 간결 표기이다. 즉 $K=(i, k)$).

$$z = \frac{\sum_{K=1}^{\text{all rules}} \mu_K P_K(x_i, x_j, \mathbf{a}_K)}{\sum_{K=1}^{\text{all rules}} \mu_K} = \sum_{K=1}^{\text{all rules}} \hat{\mu}_K P_K(x_i, x_j, \mathbf{a}_K) \quad (2)$$

여기서, $\hat{\mu}_K$ 는 규준화된 μ_K 를 나타낸다.

2. FPNN 알고리즘

제안된 FPNN은 기본 GMDH 알고리즘의 확장된 형태와 퍼지추론, 특히 회귀다항식 퍼지 추론 알고리즘의 상호결합에 의한 학습을 통하여 네트워크 생성을 실현한다. GMDH 알고리즘은 모델링하고자 하는 대상 시스템의 입력변수 x_i 와 x_j , 출력 y 의 쌍에 대해서 2차 회귀방정식을 계산함으로써 이 알고리즘을 시작한다.

$$y = A + Bx_i + Cx_j + Dx_i^2 + Ex_j^2 + Fx_ix_j \quad (3)$$

(3)을 사용하여 기존의 m 개의 입력 x_1, x_2, \dots, x_m 에서 출력 y 를 예측하는 2개의 입력을 선택해 $m(m-1)/2$ 개의 변수 수, 즉 노드의 수를 얻는다. 이 새로운 입-출력 관계로부터 2차 회귀다항식을 찾은 후 이 가운데에서 y 를 가장 잘 예측하는 2차 회귀 다항식 구조만이 판단기준을 통하여 선택한 다음 선택된 2차 회귀 다항식 구조의 결과값들을 다음 층의 입력으로 대치한다. 이 각각의 2차 회귀다항식을 통한 결과값들을 이용하여 새로운 입력변수를 구성한다. 이 새로운 입력변수를 가지고 앞에 했던 것처럼 노드의 수 결정과 2차 회귀다항식을 구성한다. 이 2차 회귀다항식들이 이전의 것보다 예측 능력이 떨어지기 시작하면 이 반복 과정을 중지한다. 이런 일련의 과정이 끝난 후, 가장 마지막 단계에서 얻어진 다항식들 중에서 가장 좋은 이차 다항식을 선택한다. 이 선택된 다항식 변수에 전 층에서의 2차 회귀다항식을 대입하고, 동일한 조작을 첫 번째 층까지 반복한다. 그런 다음 최종적으로 추정 모델을 얻는다. 다시 말해서, 대수적 대입 법칙을 사용해서 아래의 식과 같은 매우 복잡한 형태의 다항식을 얻을 수 있다.

$$y = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m d_{ijk} x_i x_j x_k + \dots \quad (4)$$

이 식을 Ivakhnenko 다항식이라 한다.

위에서 살펴본 기본 GMDH 알고리즘을 기반으로 한 단계별 상세한 FPNN 설계 알고리즘을 설명한다.

[단계 1] 시스템 입력변수의 결정 : 출력변수 y 에 관계하는 n 개의 시스템 입력변수를 결정한다. 필요하다면 데이터를 정규화 한다. 이 시스템 입력변수를 x_1, x_2, \dots, x_n 이라 한다.

[단계 2] 데이터 분할 : N 개의 입출력 데이터 $(x_i, y_i) = (x_{1i}, x_{2i}, \dots, x_{ni}, y_i), i=1, 2, \dots, N$ 을 학습용 데이터와 평가용 데이터로 분할한다. 학습용 데이터는 모델을 동정하기 위해 사용하는 데이터이고, 평가용 데이터는 모델을 평가하기 위해 사용하는 데이터이다. 학습용 데이터와 평가용 데이터의 개수를 각각 N_L 개와 N_C 개로 한다. 여기서, $N=N_L+N_C$ 이다.

[단계 3] FPNN 구조 결정 : 제안된 FPNN 알고리즘 구조는 그림 2에서 보여진 것과 같이 크게 FPNN 구조와 퍼지 추론 구조로 나눌 수 있다. FPNN 구조는 각 층 노드의 규칙 후반부를 표 1에 표시한 다항식 구조로부터 동일 차




그림 2. FPNN 모델 선택.
Fig. 2. The selection of FPNN model.

표 1. FPNN 구조.
Table 1. FPNN architecture.

FPN 층	규칙 전반부 입력 변수 수	규칙 후반부 다항식 구조		FPNN 구조
		Type P	Type Q	
1층	p	i) 선택된 입력 ii) 전체시스템 입력	i) 선택된 입력	i) P=Q:CASE I ii) P≠Q:CASE II
2~5층	p		i) 선택된 입력	

(p=2, 3, 4 ; P, Q=1, 2, 3, 4)

수를 사용할 경우와 서로 다른 차수 혹은 변형된 차수를 사용할 경우로 나눌 수 있다.

이와 같이, 회귀다항식 모델구조와 퍼지 추론 구조의 다양한 구조 선택을 통하여 시스템 환경과 변화에 적용할 수 있는 FPNN 모델 선택에 유연성을 줄 수 있다.

[단계 4] 입력변수 수 및 퍼지규칙 후반부 다항식 차수 선택 : 입력변수 x_1, x_2, \dots, x_n 을 가지고 선택한 모델에 따라 1층과 2층 이상부터 최종 출력층까지 각 노드의 입력변수 수와 퍼지 추론의 후반부 다항식을 결정한다. 각 층에 사용될 퍼지규칙 후반부 다항식은 다음 표 2와 같다.

[단계 5] 매개변수 추정을 위한 퍼지동정 : 입력변수 x_1, x_2, \dots, x_n 중 각 노드의 선택된 입력에 대해 퍼지 추론을 적용한다.

선택된 입력의 개수에 따라 층 노드의 개수는 $n!/((n-r)!r!)$ 과 같이 정의된다(n :전체 입력의 수, r :선택한 입력의 수). 퍼지 모델의 전반부 멤버십 함수는 삼각형과 가우시안형으로 나누어서 정의하고, 퍼지 추론 방법인 간략 추론과 회귀다항식 추론의 후반부 구조는 표 2에서 표현한 것과 같

표 2. 퍼지규칙 후반부 다항식 구조.
Table 2. The consequent polynomial structure of fuzzy rules.

다항식 차수 \ 입력수	1	2	3
0(Type 1)	Constant		
1(Type 2)	Linear	Bilinear	Trilinear
2(Type 3)	Quadratic	Biquadratic	Triquadratic
2(Type 4)		Modified Biquadratic	Modified Triquadratic

이 상수항 그리고 1차, 2차, 변형된 2차 다항식인 Type 1~4를 사용한다. 퍼지 추론 규칙과 파라미터 동정을 위한 회귀다항식 추론의 매개변수 추정은 다음과 같다.

회귀다항식 추론 경우의 퍼지 모델은 다음과 같은 형태를 가지는 구현 규칙들로 구성된다.

$$\begin{aligned}
 R^1: & \text{If } x_1 \text{ is } A_{11} \text{ and } \dots \text{ and } x_n \text{ is } A_{1n} \text{ then } y_1 = f_1(x_1, \dots, x_n) \\
 R^j: & \text{If } x_1 \text{ is } A_{j1} \text{ and } \dots \text{ and } x_n \text{ is } A_{jn} \text{ then } y_j = f_j(x_1, \dots, x_n) \quad (5) \\
 R^z: & \text{If } x_1 \text{ is } A_{z1} \text{ and } \dots \text{ and } x_n \text{ is } A_{zn} \text{ then } y_z = f_z(x_1, \dots, x_n)
 \end{aligned}$$

여기서, n, R^j, x_i, j, A_{ji} 그리고 z 는 간략추론과 같고, $f_z(x_1, \dots, x_n)$ 은 표 2에서 나타난 다항식이다.

예로 후반부 다항식이 1차식인 경우의 i 번째 데이터의 추론된 값 \hat{y}_i 는 다음과 같다.

$$\begin{aligned}
 \hat{y}_i &= \frac{\sum_{j=1}^z w_{ji} y_j}{\sum_{j=1}^z w_{ji}} = \frac{\sum_{j=1}^z w_{ji} (a_{j0} + a_{j1} x_{i1} + \dots + a_{jn} x_{in})}{\sum_{j=1}^z w_{ji}} \quad (6) \\
 &= \sum_{j=1}^z \hat{w}_{ji} (a_{j0} + a_{j1} x_{i1} + \dots + a_{jn} x_{in})
 \end{aligned}$$

$$w_{ji} = A_{j1}(x_{i1}) \wedge \dots \wedge A_{jn}(x_{in}) \quad (7)$$

여기서 i 는 $(1, \dots, m)$ 번째 데이터, $a_j (j=1, \dots, z; l=0, \dots, n)$ 는 후반부 파라미터이다.

후반부 파라미터는 최소자승법에 의한 최소값으로 간략추론과 같이 다음 식으로 구해진다.

$$\begin{aligned}
 \mathbf{a} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (8) \\
 \mathbf{X} &= [x_{11}, x_{12}, \dots, x_{1n}]^T, \quad \mathbf{Y} = [y_1 \dots y_m]^T \\
 \mathbf{x}_i^T &= [\hat{w}_{1i}, \dots, \hat{w}_{zi}, x_{i1}, \hat{w}_{1i}, \dots, x_{i1}, \hat{w}_{zi}, \dots, x_{in}, \hat{w}_{1i}, \dots, x_{in}, \hat{w}_{zi}] \\
 \mathbf{a} &= [a_{10} \ a_{20} \ \dots \ a_{z0} \ a_{11} \ \dots \ a_{z1} \ \dots \ a_{1n} \ \dots \ a_{zn}]^T
 \end{aligned}$$

[단계 6] 모델 평가 및 노드의 선택 : 선형 회귀분석에는 학습 데이터를 사용하고, 기존의 연구결과와 비교하기 위하여 성능지수, 즉 동정오차는, 가스로 공정한 경우엔 MSE (Mean Squared Error)을 사용해서 (9)와 같이 구해지고,

$$E = \frac{1}{N} \sum_{i=1}^N (y_i - y_i^*)^2 \quad (9)$$

Mackey-Glass 시계열 공정한 경우엔 RMSE(Root Mean Squared Error)을 사용해서 (10)과 같이 구해진다.

$$E = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i^*)^2} \quad (10)$$

위 식을 최소화하는 계수들을 구한다(N 은 데이터 수). 추정된 후반부 다항식에 테스트 데이터를 사용하여 (9) 또는 (10)의 동정오차 E 를 계산한다.

얻어진 $n!/\{(n-r)!r!\}$ 개의 $E_1, E_2, \dots, E_{n!/\{(n-r)!r!\}}$ 에 대해 서 값이 작은순으로 배열한다.

1층에서 얻어진 노드 수는 $n!/\{(n-r)!r!\}$ 개의 모두를 사용하며, 2층 이상부터는 선택한 임의의 노드 수 W 로부터,

- i) 노드 수가 $n!/\{(n-r)!r!\} > W$ 일 경우, 다음층의 노드 수를 W 개로 설정하여, E_1, E_2, \dots, E_W 와 같이 재배열하고 나머지 $n!/\{(n-r)!r!\} - W$ 개의 모델은 버린다.
- ii) 노드 수가 $n!/\{(n-r)!r!\} \leq W$ 일 경우, 다음층의 노드 수를 $n!/\{(n-r)!r!\}$ 개로 설정하여 $E_1, E_2, \dots, E_{n!/\{(n-r)!r!\}}$ 과 같이 재배열한다.

위와 같은 알고리즘을 바탕으로 2층 이상부터의 노드 수를 결정하는 이유는 노드 수가 많을 경우 프로그램 실행 시간 지연 및 실 공정에서의 적용에 문제점이 될 수 있기 때문이다. W 값을 너무 작게 설정하면 충분한 연산을 하지 못하기 때문에 좋은 결과값을 얻지 못한다. 따라서 노드 수인 W 의 선택에 있어서 상호균형을 고려하여 적당한 값을 설정한다.

[단계 7] 종료판정 : [단계 6]의 현재 층에서 얻어진 최소 동정오차 E_1 이 다음의 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$E_1 \geq E_* \quad (11)$$

단, E_* 는 이전 층의 최소 동정오차이다.

그러나 위와 같은 종료판정은 네트워크 생성 중에 최대 층수가 과대하게 발생할 우려가 있으며 그럴 경우 프로그램 실행 시 많은 시간과 계산량을 요구하게 된다. 또한 현재 층의 동정오차가 이전 층의 동정오차보다 크더라도 그 다음 연속 층에서의 동정오차가 이전 층들의 동정오차보다 더 적은 값이 나올 수 있는데도 프로그램을 종료시키는 단점이 있다. 이와 같은 단점을 보완하기 위해 본 논문에서는 알고리즘의 판정을 위의 경우와 병행하여 전체의 층 수를 최대 5개로 제한하여 알고리즘을 종료한다.

[단계 8] 다음 층의 새로운 입력변수 설정 : 현재 층에서 보존된 퍼지 다항식 뉴런(FPN)의 출력들(z_{1i}, \dots, z_{mi})에서 다음 층의 새로운 입력들(x_{1i}, \dots, x_{mi})로, $x_{1i} = z_{1i}, \dots, x_{mi} = z_{mi}$ 으로 구성되고, [단계 5]로 간다. 이후, [단계 5]부터 [단계 8]까지를 반복한다. 알고리즘이 종료할 경우, 최소 동정오차 E_* 을 얻은 퍼지 다항식 뉴런의 퍼지규칙에 전 층의 출력(중간변수 값)을 대입하고 동일한 조작을 제 1층까지 반복하여 최종 추정 모델 \hat{f} 를 얻는다.

그림 3은 FPNN 알고리즘의 전체 흐름도이다.

3. FPNN 모델 구조

본 논문에서 제안한 FPNN 모델 구조는 기본 GMDH 알고리즘과 회귀다항식 형태의 모델 구조에 기반을 둔 퍼지 추론 시스템을 결합함으로써 생성되는 구조로서, FPNN 모델의 전체 구조는 그림 4와 같다.

그림 4의 각 층의 노드, 즉 퍼지 다항식 뉴런은 퍼지 추론 시스템으로 앞서 설명한 것 같이 두 모듈로 구성되어 있다.

전반부는 그림 5와 같이 최소-최대값을 이용한 삼각형




그림 3. FPNN 알고리즘의 전체 흐름도.
Fig. 3. An overall flowchart of FPNN algorithm.




그림 4. FPNN 모델의 구조.
Fig. 4. The structure of FPNN model.

또는 가우시안형의 멤버십 함수로써 정의된다.
FPNN 구조는 앞 절 FPNN 알고리즘의 [단계 3]에서 설명한 것같이 체계적이고 효율적인 구조로 설계함으로써 시스템 환경에 유연히 적용할 수 있다.




그림 5. 멤버십 함수 정의.
Fig. 5. The definition of membership functions.




그림 6. FPNN 구조의 구성.
Fig. 6. Configuration of the FPNN architecture.

앞에서 설명된 그림 2의 FPNN 모델 선택을 통해 다양하고 체계적인 구조 설계가 가능하다. 즉, 차수의 선택에 있어서 'CASE I-각 층 노드의 규칙 후반부에서 동일 차수를 가지는 경우'와 'CASE II-2층 이상의 노드 규칙 후반부에서 1층과 비교시 서로 다른 차수 및 변형된 차수를 가지는 경우'에 대한 설계를 그림 6과 같이 나타낼 수 있다.

또한 각 노드, 즉 FPN의 규칙 후반부를 이루는 구조에 따라 (A) 모든 층에서 각 노드의 규칙 후반부는 선택된 입력을 사용한 경우와 (B) 각 노드의 규칙 후반부는 1층에서 전체 입력을 사용하고 2층 이상부터 선택된 입력을 사용한 경우로 나누어 모델을 구축하였다.

FPNN 구조의 구성은 그림 6과 같다. 그림 6에서 FPN (·)의 변수들은 세미콜론에 의해서 두 부분으로 나뉘어진다. 전자는 전반부 입력변수 (x_p, x_q)를, 후자는 퍼지 규칙의 후반부 회귀다항식에서의 입력변수 (x_1, x_2, x_3, x_4)를 각각 나타낸다.

III. 시뮬레이션 및 결과 고찰

본 논문에서 제안한 FPNN 알고리즘을 다음과 같이 단계별로 설계하여 2개의 실험적 예제인 가스로 공정의 시계열 데이터[13]와 Mackey-Glass 시계열 공정 데이터[14]를 적용하여 모델의 타당성 및 유용성을 평가하였다. 또한 주어진 각 공정마다 각각 다른 delay time에 따른 모델의 근사화와 일반화(예측) 능력을 상호 평가하기 위한 모델링과 이들 상호 능력에 의한 다양한 모델 구조의 유용성 평가를 위해 안정도 측도를 토의한다.

1. 가스로 공정

FPNN 알고리즘을 이용하여 각 단계별 상세 설계 절차를 Box와 Jenkins의 가스로 시계열 일출력 데이터[13]에 적용한다.

[단계 1] 시스템 입력변수의 결정 : 시스템 입력변수가 4 입력인 경우(Type I)엔 $u(t-2), u(t-1), y(t-2), y(t-1)$ 을, 6입력인 경우(Type II)엔 $u(t-3), u(t-2), u(t-1), y(t-3), y(t-2), y(t-1)$ 로 입력 변수를 설정한다. 출력 변수로는 $y(t)$ 로 설정한다.

여기서, $u(t)$ 는 가스 흐름율이고 $y(t)$ 는 연소된 이산화탄소의 농도이다.

[단계 2] 데이터 분할 : 총 296개의 데이터 중 처음 148개의 데이터는 학습에 이용하고 나머지 148개의 데이터는

테스트에 이용한다.

[단계 3] FPNN 구조 결정 : FPNN 구조에서 설명했듯이 여러 가지 형태의 구조로 나누어 선택할 수 있다. 즉, 'CASE I-각 층의 노드 규칙 후반부에서 동일 차수를 가지는 경우'와 'CASE II-2층 이상의 노드 규칙 후반부에서 1층과 비교시 서로 다른 차수 및 변형된 차수를 가지는 경우'로 세분화되며, 더 나아가 각 CASE별로 '(A)-모든 층에서 각 노드의 규칙 후반부는 선택된 입력을 사용'할 때와 '(B)-각 노드의 규칙 후반부는 1층에서 전체 입력을 사용하고 2층 이상부터 선택된 입력을 사용'할 때로 나누어 선택한다.

[단계 4] 입력변수 수 및 퍼지규칙 후반부 다항식 차수

표 3. FPNN 구조.
Table 3. FPNN architecture.

(a) CASE I

규칙 전반부 입력변수 수		규칙 후반부 다항식 구조(차수) 및 입력선택 방식			
1층	2~5층	1층			2~5층
		입력수 차수	4 시스템 입력	6 시스템 입력	
2	2	Type 1	(A) i = 2	(A) i = 2	Type 1
		Type 2			Type 2
		Type 3	(B) ii = 4	(B) ii = 6	Type 3
		Type 4			Type 4
3	3	Type 1	(A) i = 3	(A) i = 3	Type 1
		Type 2			Type 2
		Type 3	(B) ii = 4	(B) ii = 6	Type 3
		Type 4			Type 4

i)선택된 입력 수, ii)전체 시스템 입력 수

(b) CASE II

규칙 전반부 입력변수 수		규칙 후반부 다항식 구조(차수) 및 입력선택 방식			
1층	2~5층	1층			2~5층
		입력수 차수	4 시스템 입력	6 시스템 입력	
2	2	Type 1	(A) i = 2	(A) i = 2	Type 3
		Type 2			Type 1
		Type 3			Type 4
		Type 4			Type 1
3	3	Type 2	(A) i = 3	(A) i = 3	Type 1
		Type 3			Type 4
		Type 4			Type 1
		Type 4			Type 2

i)선택된 입력 수

표 4. 규칙 후반부 다항식 형태.

Table 4. Polynomial type of the consequence of rules.

입력 수	차수	회귀 다항식
2 입력	Type 1	a_0
	Type 2	$a_0 + a_1x_1 + a_2x_2$
	Type 3	$a_0 + a_1x_1 + a_2x_2 + a_3x_1^2 + a_4x_2^2 + a_5x_1x_2$
	Type 4	$a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2$
3 입력	Type 1	a_0
	Type 2	$a_0 + a_1x_1 + a_2x_2 + a_3x_3$
	Type 3	$a_0 + a_1x_1 + a_2x_2 + a_3x_3 + a_4x_1^2 + a_5x_2^2 + a_6x_3^2 + a_7x_1x_2 + a_8x_1x_3 + a_9x_2x_3$
	Type 4	$a_0 + a_1x_1 + a_2x_2 + a_3x_3 + a_4x_1x_2 + a_5x_1x_3 + a_6x_2x_3$

선택 : [단계 1]에서 설정한 전체 입력변수와 [단계 3]에서 선택한 모델에 따라 1층과 2층 이상부터 최종 출력층까지 각 노드의 입력변수 수와 퍼지 추론의 후반부 다항식을 결정한다. 각 층에 사용될 후반부 다항식은 표 4와 같다.

2입력과 3입력 모두에서 Type 1은 상수항, Type 2는 선형 다항식, Type 3는 2차 다항식, Type 4는 변형된 2차 다항식을 나타낸다.

[단계 5] 매개변수 추정을 위한 퍼지 동정 : [단계 4]에서 선택된 입력변수 수와 후반부 다항식에 의한 퍼지 추론으로부터 학습용 데이터를 사용하여 최소사승법에 의한 규칙 후반부 파라미터를 구한다.

[단계 6] 모델 평가 및 노드의 선택 : 학습 데이터를 사용하여 표 4에서 선택한 규칙 후반부 다항식에 대입해서 학습 데이터에 대한 모델의 동정오차, 즉 성능지수(Performance Index)를 식(9)의 MSE (Mean Squared Error)를 사용하여 구한다. 또한 얻어진 모델로부터 테스트 데이터를 사용하여 동정오차E를 계산하여 모델을 평가한다. 얻어진 $n!/((n-r)!r!)$ 개의 $E_1, E_2, \dots, E_{n!/((n-r)!r!)}$ 에 대해서 값이 작은 순으로 배열한다. 1층 노드의 수는 $n!/((n-r)!r!)$ 이며, 2층부터 최종 출력층까지 각 층 노드의 수, 즉 W는 30개로 제한하였으며, 만약 노드의 수가 30개보다 적을 경우엔 $n!/((n-r)!r!)$ 개를 그대로 적용한다.

[단계 7] 종료판정 : 제한한 FPNN 알고리즘은 식(11)의 종료판정 기준과 병행하여 전체 층 수를 5층으로 제한하여 알고리즘을 수행한다. 따라서, 프로그램 실행시 소요되는 시간과 계산량을 단축할 수 있고, 제한된 전체 층 수로부터 복잡한 구조 생성을 방지할 수 있다.

[단계 8] 다음 층의 새로운 입력변수 설정 : 현재 층에서 보존된 FPN의 출력값을 다음 층의 입력값으로 하는 새로운 입출력관계를 구성하고, 2층부터 최종 출력층까지는 [단계 5]부터 [단계 8]까지를 반복한다. 알고리즘이 종료할 경우, 동정오차 E를 얻은 퍼지 다항식 뉴런의 퍼지 규칙에 전 층의 출력(중간변수값)을 대입하고 동일한 조작을 제 1층까지 반복하여 최종 추정 모델 \hat{f} 를 얻는다.

퍼지규칙 전반부 각 입력변수에 대한 멤버십 함수의 수는 2입력인 경우엔 (2×2)와 (3×2)를 사용하였다. 아래 보여진 그림들은 표 3에서 시스템 입력이 6 입력일 경우이다. 여기서 멤버십 함수의 수는 2입력의 (2×2)를 사용한 경우로써 각각의 모델 구조에 대한 시뮬레이션 결과를 그림으로 나타낸 것이다. 그림들의 각 층에서 각 Type별 가장 우수한 평가 성능지수를 가진 최적 생성 노드로 앞 층의 노드 번호가 표기되어 있고, 또한 그 최적 생성 노드의 PI, E_PI값이 그림에 도시되어 있다. 여기서, 각 Type별 최적 생성노드의 첫 번째 괄호안의 노드 번호는 삼각형 멤버십함수, 두 번째 괄호안의 노드 번호는 가우시안형 멤버십함수를 각각 사용한 경우를 나타낸다. 그리고 PI는 학습 데이터에 대한 성능지수를 의미하며, E_PI는 테스트 데이터에 대한 성능지수를 의미한다.

CASE I - 각 층의 노드 규칙 후반부에서 동일 차수를 가지는 경우

(A) 모든 층에서 각 노드의 규칙 후반부는 선택된 입력을 사용

그림 7은 FPNN 구조가 CASE I-(A)의 경우일 때의 각각의 성능지수를 나타낸 것이다. 그림에서 알 수 있듯이 멤버십 함수는 가우시안형을 사용했을 때 성능이 우수하였고 최적의 모델은 후반부 다항식으로는 Type 2를 사용한 모델로써 이때의 PI=0.0168, E_PI=0.1168이다.

(B) 각 노드의 규칙 후반부는 1층에서 전체 입력을 사용하고 2층 이상부터 선택된 입력을 사용

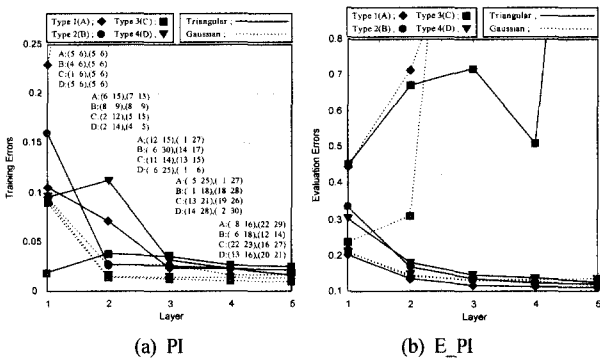


그림 7. CASE I-(A)의 경우.
Fig. 7. In case of CASE I-(A).




그림 8. CASE I-(B)의 경우.
Fig. 8. In case of CASE I-(B).




그림 9. FPNN 구조(2 입력(3×2), Type 2, 가우시안형).
Fig. 9. FPNN structure(2 inputs(3×2), Type 2, Gaussian-like Type).

그림 8은 FPNN 구조가 CASE I-(B)의 경우이다. 학습과 테스트 데이터에 대한 동정오차(성능지수)를 고려해볼 때 삼각형을 사용할 때 대체적으로 성능이 우수함을 알 수 있다. 가장 우수한 모델은 삼각형을 이용하며 후반부 다항식으로는 Type 1을 사용한 모델로써 이때 PI=0.0210, E_PI=0.1108이다.

그림 9는 시스템 입력을 6입력으로 사용할 때, CASE I의 모든 경우에서 가장 우수한 모델을 구축한 것이다. 아래 그림의 모델은 CASE I-(A)경우로, 선택된 입력이 2입력(3×2)을 사용하고 후반부 다항식으로는 Type 2를 선택한 경우이며 멤버십 함수로는 가우시안형을 사용하였다. 이때 PI=0.0151이고 E_PI=0.1184이다. 또한 점선으로 표시된 각 층의 노드는 각 층에서 가장 우수한 평가 성능 지수를 가진 노드들이지만, 그림 9의 4층에서처럼 최종적의 최적의 FPNN 구조를 생성하는 과정에서는 제외될 수도 있다.

CASE II - 2층 이상의 노드 규칙 후반부에서 1층과 비교시 서로 다른 차수 및 변형된 차수를 가지는 경우

그림 10에서 나타낸 각 노드의 동정오차는 CASE II-(A)의 경우이다.

CASE II-(A)인 경우 2층 이상의 후반부 다항식이 간단한 구조인 경우엔 삼각형을, 복잡한 구조일수록 가우시안형을 사용할 때 모델 성능이 향상됨을 알 수 있다.

그림 11은 CASE II-(A)의 모든 경우에서 가장 우수한 모델을 구축한 것이다. 이는 그림 10에서 (a)와 (b)에서 나타낸 결과값 중에서 가우시안형을 사용하고 1층에서는 Type 2, 2층 이상부터는 Type 4를 선택한 경우이며 이때 PI=0.0127, E_PI=0.1255이다.




그림 10. CASE II-(A)의 경우.
Fig. 10. In case of CASE II-(A).




그림 11. FPNN 구조(2입력(2×2), 1층 ; Type 2, 2층 이상 ; Type 4, 가우시안형).

Fig. 11. FPNN structure(2 inputs(2×2), 1st layer ; Type 2, 2nd layer or higher ; Type 4, Gaussian-like Type).

표 5. 기존의 퍼지모델과 동정오차비교.

Table 5. Comparison of identification errors with conventional fuzzy models.

모 델			Performance Index			
			PI	PI _s	E_PI _s	
Tong's model[4]			0.469			
Xu's model[6]			0.328			
Pedrycz's model[7]			0.320			
Sugeno's model[9]			0.068			
Oh's model[15]			0.123	0.020	0.271	
Sugeno's model[16]			0.355			
Park's model[17]			0.055			
Kim's model[18]				0.034	0.244	
Lin and Cunningham's model[19]				0.071	0.261	
Our model	Type I	CASE I	G(2×2)	0.0490	0.0166	0.1161
			G(3×2)	0.0460	0.0176	0.1228
		CASE II	G(2×2)	0.0476	0.0164	0.1283
			T(3×2)	0.0527	0.0174	0.1524
	Type II	CASE I	G(2×2)	0.0452	0.0168	0.1168
			G(3×2)	0.0392	0.0151	0.1184
		CASE II	G(2×2)	0.0379	0.0127	0.1255
			G(3×2)	0.0318	0.0101	0.1365

(Type I : 4 system inputs, Type II : 6 system inputs)

기존의 모델과 제시한 FPNN 모델과의 성능비교를 표 5에 보였다. 표 5로부터 제안된 모델은 기존의 모델들에 비해 우수한 성능을 가짐을 알 수 있다.

표 5에서 표기된 (G)와 (T)의 표시는 각 경우에서 최적의 모델을 구축하였을 때의 사용된 멤버십 함수를 나타낸 것이다. 여기서 (G)는 가우시안형, (T)는 삼각형을 의미한다. 표에서 볼 수 있듯이 각 경우에서 대부분의 최적 모델은 멤버십 함수를 삼각형을 사용하는 것보다 가우시안형을 사용했을 때 성능이 우수한 모델을 생성할 수 있음을 알 수 있다.

1.1. 안정도 측도

다양한 FPNN 모델 중에서 적합한 구조를 선택하는 것에 대한 의문이 증가할 것이다. 분명히, 학습 데이터와 테스트 데이터에 대한 모델의 성능들(PI, E_PI)은 우리가 고

려해야 할 두 가지의 중요한 관점들이다. PI와 E_PI 값들은 FPNN 모델의 근사화와 일반화 능력을 나타내는 좋은 척도가 된다. 이러한 PI와 E_PI를 이용해서 안정도 측도를 위한 다음 식을 도입한다.

$$k = \frac{E_PI_s}{PI_s} \tag{12}$$

이 지수는 테스트 데이터에 의해서 모델의 성능이 얼마만큼 저하되는지를 나타낸 모델의 안정도 측도를 나타낸다. 따라서 이 지수가 최소값을 가질 때 그 최소값을 가진 구조를 선택한다. 부가적으로, 만일 FPNN 구조의 각 집단에서 k의 값이 그렇게 큰 변화가 없다면, 구조 선택은 그다지 중요하지 않을 수 있다. 한가지 강조하고자 하는 것은, 만일 PI의 값들이 변화가 심하면 위에서 제시한 안정도 측도의 유용함이 제한을 받을 것이다. 표 6에서는 표 5에 나타난 PI와 E_PI에 의해 계산되어진 안정도 측도, k를 나타낸 것이다.

표 6에서 나타난 안정도 측도k값에 의해 CASE I에서 보다 더 안정된 모델 구조를 구축할 수 있음을 알 수 있다. 그림 12는 6 시스템 입력의 CASE I인 경우, 즉 그림 7에서 (a)와 (b)에서 나타낸 결과값 중에서 멤버십 함수는 가우시안형을 사용하고 후반부 다항식으로는 Type 2를 사용할 때의 모델구조를 보인다.

2. Mackey-Glass 시계열 공정

Mackey-Glass 시계열은 예측 알고리즘의 성능 평가를 위한 대표적인 예로서 사용되는 시계열이다[14]. 특히 Mackey-Glass 시계열은 비선형 시스템으로부터 발생하는 카오스

표 6. FPNN의 다양한 구조에 대한 안정도 지수.

Table 6. Stability index for various architectures of the FPNN.

FPNN Architectures			k
4 시스템 입력	CASE I	G(2×2)	6.993
		G(3×2)	6.977
	CASE II	G(2×2)	7.823
		T(3×2)	8.758
6 시스템 입력	CASE I	G(2×2)	6.952
		G(3×2)	7.841
	CASE II	G(2×2)	9.881
		G(3×2)	13.514




그림 12. FPNN 구조(2입력(2×2), Type 2, 가우시안형).

Fig. 12. FPNN structure(2 inputs(2×2), Type 2, Gaussian-like Type).

표 7. 시스템 입력 변수.

Table 7. System's input variables.

시스템 입력 형태	입·출력 관계
Type I	$[x(t-18), x(t-12), x(t-6), x(t), x(t+6)]$
Type II	$[x(t-24), x(t-18), x(t-12), x(t-6), x(t), x(t+6)]$

신호의 일종으로 신호의 복잡성으로 인해 랜덤 시계열(Random Time Series)처럼 보일 수 있으나 다음 식과 같은 비선형 동력학 방정식에 의해 생성된다.

$$\dot{x}(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (13)$$

이 시계열의 미래값 예측은 많은 연구자들에 의해서 연구되어진 결과에 대한 성능 평가의 척도가 되고 있다. 본 연구에서는 기존의 방법들과 비교를 위해 미래값 $x(t+6)$ 의 예측 성능을 조사한다. 식(13)의 수치적 해를 찾기 위한 방법으로 4차 Runge-Kutta 방법을 적용한다. time step은 0.1, 초기조건 $x(0)$ 는 1.2로, 시간지연상수(Time Delay Constant) τ 는 17로 놓고 $x(t)$ 를 발생시킨다. Mackey-Glass 시계열 $x(t)$ 로부터 아래와 같은 4입력, 5입력 형태의 입력력 데이터 쌍을 구하였다. 여기서 데이터 발생 초기에는 과도영역(Transient Region)이 존재하므로 $t=118$ 에서 $t=1117$ 까지 1000개의 데이터를 추출하였다.

제안된 모델의 학습을 위해 $x(118)$ 부터 $x(617)$ 까지 500개의 시계열 데이터를 사용하였고, 예측 성능의 평가를 위해 $x(618)$ 부터 $x(1117)$ 까지 500개의 시계열 데이터를 예측치와 비교하였다. 시물레이션의 예측 성능을 위해, 식(10)과 같이 잘 알려진 성능지수인 RMSE(Root Mean Squared Error)를 이용한다.

Mackey-Glass 시계열 데이터를 이용한 FPNN 알고리즘에 의한 모델 구조 선택에 따른 결과값들에 대해 고찰한다.

이 공정에서는 2입력인 경우엔 (2×2)을, 3입력인 경우엔 (2×2×2)의 멤버쉽 함수 수를 사용하여 Mackey-Glass 시계열 데이터의 미래값 예측 성능을 평가하였다. 그림 13과 15에 나타난 각 성능지수에 대한 그래프는 4입력의 시스템 입력 수를 사용할 때를 표시한다.

CASE I - 각 층의 노드 규칙 후반부에서 동일 차수를 가지는 경우

이 구조 역시 가스로 공정에서와 마찬가지로 (A)모든 층에서 각 노드의 규칙 후반부는 선택된 입력을 사용한 경우와 (B)각 노드의 규칙 후반부는 1층에서 전체 입력을 사용하고 2층 이상부터 선택된 입력을 사용한 경우로 나누어진다. 여기에서는 두 가지 경우에 대해서 모두 시물레이션한 결과 경우(A) 보다는 경우(B)에서의 성능이 우수함을 보였다. 또한 멤버쉽 함수로 삼각형보다는 가우시안형을 사용하는 것이 본 구조에서 성능이 우수함을 알 수 있었으며, 후반부 다항식 선택에 있어서는 Type 3을 사용할 경우가 보다 성능지수가 우수함을 알 수 있었다. 또한 선택된 입력에 대해서도 2입력보다는 3입력인 경우에 더 우수한




그림 13. CASE I-(B)의 경우.
Fig. 13. In case of CASE I-(B).




그림 14. FPNN 구조(3입력, Type 3, 가우시안형).
Fig. 14. FPNN structure(3 inputs, Type 3, Gaussian-like Type).

성능지수를 얻을 수 있었다.

그림 13은 경우(B)로써 선택된 입력은 3입력이다.

그림 14는 가우시안형을 사용하고, 후반부 다항식은 Type 3을 사용했을 때의 최적 네트워크 구조를 나타낸 것이다. 이때 $PI=0.0011$, $E_PI=0.0011$ 이다.

CASE II - 2층 이상의 노드 규칙 후반부에서 1층과 비교 시 서로 다른 차수 및 변형된 차수를 가지는 경우

그림 15에서 나타난 각 노드의 동정오차는 모든 층에서 각 노드의 규칙 후반부는 선택된 입력을 사용한 경우로써 1층에서의 후반부 다항식과 2층 이상의 후반부 다항식이 서로 다른 구조(차수)를 가지는 모델의 특성에 대해서 나타난 결과값들이다.

그 특성을 살펴보면 역시 2입력을 선택했을 때보다는 3입력을 선택했을 때 더 우수한 성능지수를 가지며, 1층에




그림 15. CASE II-(A)의 경우.
Fig. 15. In case of CASE II-(A).




그림 16. FPNN 구조(3입력, 1층 ; Type 3, 2층 이상 ; Type 2, 가우시안형).

Fig. 16. FPNN structure(3 inputs, 1st layer ; Type 3, 2nd layer or higher ; Type 2, Gaussian-like Type).

표 8. 기존의 퍼지모델과 동정오차비교.

Table 8. Comparison of identification errors with conventional fuzzy models.

모 델		Performance Index			NDEI	
		PI	PI _s	E_PI _s		
Wang[20]		0.044				
Wang[20]		0.013				
Wang[20]		0.010				
Cascaded-correlation NN[21]					0.06	
Backpropagation MLP[21]					0.02	
6th-order polynomial[21]					0.04	
Jang[22]			0.0016	0.0015	0.007	
Our model	Type I	CASE I(G)	0.0011	0.0011	0.0011	0.0049
		CASE II(G)	0.0026	0.0027	0.0028	0.0114
	Type II	CASE I(G)	0.0004	0.0004	0.0004	0.0018
		CASE II(G)	0.0004	0.0004	0.0004	0.0018

(Type I : 4 system inputs, Type III : 5system inputs)

서 후반부 다항식으로는 Type 3, 2층 이상부터 Type 2를 사용할 때 성능지수가 가장 우수하였다. 또한 멤버쉽 함수의 형태에도 삼각형보다는 가우시안형에서 성능이 우수함을 알 수 있다.

그림 16은 멤버쉽 함수가 가우시안형이고, 1층에서 Type 3을 사용하고 2층 이상에서 Type 2를 사용할 때의 최적 네트워크 구조이며, 이때의 성능지수는 PI=0.0027, E_PI=0.0028이다.

기존의 모델과 본 논문에서 제시한 FPNN 모델과의 성능비교는 표 8과 같고 기존의 모델들에 비해 우수한 성능을 가짐을 알 수 있다. 표 8에서 (G) 표기는 멤버쉽 함수를 가우시안형으로 사용했다는 의미이며, 따라서 Mackey-Glass 시계열 공정에서도 멤버쉽 함수를 삼각형을 사용하는 것보다 가우시안형을 사용했을 때 성능이 더 우수함을 알 수 있다.

여기서, NDEI(Non-Dimensional Error Index)[21][23]는 시스템 출력 데이터의 표준편차에 의해 RMSE에 의해 구해진 모델의 출력 데이터를 나눈 것으로 정의된다. 또한 식 (12)에 나타낸 안정도 척도(지수) k값을 적용했을 시, 모든 모델의 성능이 거의 k≈1.0인 유형임을 알 수 있다[24].

IV. 결론

본 논문에서는 데이터 수가 적고 비선형 요소가 많은 시스템의 체계적이고 효율적인 최적 모델을 얻기 위하여 퍼지 다항식 뉴럴 네트워크(FPNN)를 제안하였다. FPNN의 구조는 퍼지 추론 규칙을 기반으로 한 활성화노드, 즉 퍼지 다항식 뉴런(FPN)들로 구성되어 있다. 규칙의 전반부는 삼각형 및 가우시안형의 멤버쉽 함수를 사용하였고, 규칙의 후반부는 간략 추론과 더불어 1차, 2차 그리고 변형된 2차 방정식과 같은 고계 다항식에 의한 회귀다항식 추론을 이용하였다.


제안된 FPNN 구조에서 복잡한 비선형 공정 시스템에 대해 시스템 환경에 적응할 수 있는 체계적이고 객관적인 모델을 구축하기 위한 다양한 형태의 구조를 제안하였다. 제안된 FPNN 구조의 모델 성능은 기존의 다른 지능형 모델보다 학습과 테스트 성능면에서 아주 우수함은 물론 다음과 같은 특징들로 요약될 수 있다.

- ▶ FPNN은 제한된 데이터 집합으로도 정교하고 더 정확한 예측 능력을 가진 모델을 구축할 수 있다.
- ▶ 멤버쉽 함수의 수와 형태의 적절한 선택과 층들간의 유기적인 조직으로부터 FPNN은 기존의 다른 퍼지 모델보다 성능이 우수하다.
- ▶ FPNN의 구조는 일반적인 다층 퍼셉트론 구조의 경우와 달리 미리 정해져 있지 않고 학습하는 동안 모델 스스로 노드의 선택과 제거를 통해 네트워크 구조를 생성한다.
- ▶ FPNN 모델은 근사화를 위한 overfitting과 일반화 사이의 충돌을 감소시킬 수 있다.

참고문헌


- [1] A. G. Ivakhnenko, "The group method of data handling; a rival of method of stochastic approximation," *Soviet Automatic Control*, 1-3, pp. 43-55, 1968.
- [2] V. Sommer, P. Tobias, D. Kohl, H. Sundgren, and L. Lundstrom, "Neural networks and abductive networks for chemical sensor signals: A case comparison," *Sensors and Actuators*, B, 28, pp. 217-222, 1995.
- [3] S. Kleinstueber and N. Sepeshri, "A polynomial network modeling approach to a class of large-scale hydraulic systems," *Computers Elect. Eng.* 22, pp. 151-168, 1996.
- [4] R. M. Tong, "The evaluation of fuzzy models derived from experimental data," *Fuzzy Sets and Systems.*, vol. 13, pp. 1-12, 1980.
- [5] C. W. Xu, "Fuzzy system identification," *IEE Proceeding* vol. 126, no. 4, pp. 146-150, 1989.
- [6] C. W. Xu, and Y. Zailu, "Fuzzy model identification self-learning for dynamic system," *IEEE Trans. on Syst. Man, Cybern.*, vol. SMC-17, no. 4, pp. 683-689, 1987.
- [7] W. Pedrycz, "An identification algorithm in fuzzy relational system," *Fuzzy Sets Syst.*, vol. 13, pp. 153-167, 1984.
- [8] W. Pedrycz, "Numerical and application aspects of fuzzy relational equations," *Fuzzy Sets Syst.*, vol. 1, pp. 1-18, 1983.

- [9] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control," *IEEE Trans Syst. Cybern.*, vol. SMC-15, no. 1, pp. 116-132, 1985.
- [10] M. A. Ismail, "Soft clustering algorithm and validity of solutions," *Fuzzy Computing Theory, Hardware and Applications*, edited by M.M. Gupta, North Holland, pp. 445-471, 1988.
- [11] I. Hayashi and H. Tanaka, "The fuzzy GMDH algorithm by possibility models and its application," *Fuzzy Sets and Systems*, 36, pp. 245-258, 1990.
- [12] Hideo Tanaka, Katsunori, and Hisao Ishibuchi, "GMDH by If-Then rules with certainty factors," *Fuzzy Sets and Systems*, 36, pp. 245-258, 1990.
- [13] Box and Jenkins, "Time series analysis, forecasting and control," 2nd ed. Holden Day, San Francisco, CA, 1976.
- [14] M. C. Mackey and L. Glass, "Oscillation and chaos in physiological control systems," *Science*, 197:287-289, July, 1977.
- [15] S. K. Oh and W. Pedrycz, "Identification of Fuzzy systems by means of an Auto-Tuning algorithm and its application to nonlinear systems," *Fuzzy Sets and Systems*, vol. 115, no. 2, pp. 205-230, 2000.
- [16] M. Sugeno and T. Yasukawa, "Linguistic modeling based on numerical data," *IFSA'91 Brussels, Computer, Management & Systems Science*, pp. 264-267, 1991.
- [17] Mignon Park, Euntai Kim, Minkee Park, and Seunghwan Ji, "A New Approach to Fuzzy Modeling," *IEEE Transaction on Fuzzy Systems*, vol. 5, no. 3, Aug. 1997.
- [18] E. T. Kim et al, "A simple identified Sugeno-type fuzzy model via double clustering," *Information Science* 110, pp. 25-39, 1998.
- [19] Y. Lin and G. A. Cunningham III, "A new approach to fuzzy-neural modeling," *IEEE Trans. Fuzzy Systems* 3, (2), pp. 190-197, 1995.
- [20] L. X. Wang and J. M. Mendel, "Generating fuzzy rules from numerical data, with application," *IEEE Trans. on Systems, Man, and Cybern.*, 22 no. 6, pp. 1414-1427, 1992.
- [21] R. S. Crowder III. Predicting the Mackey-Glass time series with cascade-correlation learning. In D. Touretzky, G. Hinton, and T. Sejnowski, editors, *Proceedings of the 1990 Connectionist Models Summers School*, pp/ 117-123, Carnegie Mellon University, 1990.
- [22] J. R. Jang and C. Sun, "Predicting chaotic time series with fuzzy if-then rules," *2nd IEEE Inter. Conf. Fuzzy Systems*, San Francisco, pp. 1079-1084, 1993.
- [23] A. S. Lapedes and R. Farber. "Nonlinear signal processing using neural networks: prediction and systems modeling". *Technical Report LA-UR-87-2662*, Los Alamos National Laboratory, Los Alamos, New Mexico 87545, 1987.
- [24] 오성권, "퍼지모델 및 제어이론과 프로그램," 기다리 출판사, 1999.



박 호 성

1974년 1월 20일생. 1999년 원광대 제어계측공학과 졸업. 동대학원 석사(2001), 2001~현재 동대학 박사과정. 관심분야는 퍼지, 뉴럴네트워크 및 뉴로-퍼지 등의 지능형 모델링과 제어. 시스템 자동화 등.



오 성 권

1957년 2월 13일생. 1981년 연세대 전기공학과 졸업. 1983-89년 금성산진연구소(선임연구원). 1993년 연세대 대학원 전기공학과 졸업(공학). 1996-97 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993-현재 원광대 전기전자 및 정보공학부 부교수. 관심분야는 시스템자동화, 퍼지이론 및 신경회로망 응용, 지능형 모델링 및 제어 등.



윤 양 응

1941년 9월 25일생. 1985년 전북대 대학원(공학박사). 2001년 현재 원광대 전기전자 및 정보공학부 교수. 관심분야는 전기 기기 제어, 지능 시스템 및 제어 등.