

# 적응 퍼지-뉴럴네트워크를 이용한 비선형 공정의 온-라인 모델링

論 文

48A - 10 - 17

## On-line Modeling of Nonlinear Process Systems using the Adaptive Fuzzy-neural Networks

吳 聖 權\* · 朴 炳 俊\*\* · 朴 春 成\*\*\*

(Sung-Kwun Oh · Byoung-Jun Park · Chun-Seong Park)

**Abstract** - In this paper, an on-line process scheme is presented for the implementation of a intelligent on-line modeling of nonlinear complex system. The proposed on-line process scheme is composed of FNN-based model algorithm and PLC-based simulator. Here, an adaptive fuzzy-neural networks and HCM(Hard C-Means) clustering method are used as an intelligent identification algorithm for on-line modeling. The adaptive fuzzy-neural networks consists of two distinct modifiable structures such as the premise and the consequence part. The parameters of two structures are adapted by a combined hybrid learning algorithm of gradient decent method and least square method. Also we design an interface S/W between PLC(Programmable Logic Controller) and main PC computer, and construct a monitoring and control simulator for real process systems. Accordingly the on-line identification algorithm and interface S/W are used to obtain the on-line FNN model structure and to accomplish the on-line modeling. And using some I/O data gathered partly in the field(plant), computer simulation is carried out to evaluate the performance of FNN model structure generated by the on-line identification algorithm. This simulation results show that the proposed technique can produce the optimal fuzzy model with higher accuracy and feasibility than other works achieved previously.

**Key Words** : FNN(퍼지-뉴럴네트워크), On-line Identification(온라인 동정), Clustering Method (클러스터링 방법), Hybrid Learning Algorithm(하이브리드 학습 알고리즘), Programmable Logic controller(프로그램 논리 제어기)

### 1. 서 론

시스템이 복잡해지면서 모델링 오차, 파라미터 변화, 비선형성 등이 발생하게 되고 이 경우 시스템을 해석하기에 여간 어렵지 않다. 이를 해결하기 위한 방법으로 시스템의 환경변화에 적절히 대응할 수 있도록 적응형 지능 알고리즘에 대한 많은 연구가 최근에 이루어지고 있다. 적응형 지능 알고리즘은 새로운 모델링 방법 및 제어를 위한 최적화 기술이며 퍼지논리, 신경망, 퍼지-뉴럴네트워크 등과 같은 응용영역을 가지고 있다. 최근에는 퍼지와 신경망이 결합한 퍼지-뉴럴네트워크 모델의 연구가 활발히 진행되고 있다. 퍼지-뉴럴네트워크는 변화하는 환경에 대하여 자기자신을 적응시키고 패턴을 인식하는 장점을 가진 신경망과 퍼지 if-then 규칙에 의한 언어적 지식 표현이 가능한 퍼지 추론 시스템이 결합된 형태로 상당히 좋은 성능을 발휘한다. 이러한 지능형 알고리즘은 실 공정에의 적용을 위해 온라인 모델링에 관한 연구[8,12]가 진행되고 있지만 아직 미비한 상태이며, 또한 실 공정 적용은 많은 문제를 가지고 있다.

이들 연구 중 Jang과 Sun[8]이 제안한 모델로써 퍼지 추론 시스템에 신경망의 학습 개념을 구체화한 적응 퍼지-뉴럴네트워크 온라인 모델은 기존의 연구들 중 좋은 성능을 가지고 있지만 비선형 공정의 특징을 반영하지 못함으로써 임의의 공정 적용 시 많은 제한조건과 오차를 가지게 된다.

본 논문에서는 적응 퍼지-뉴럴네트워크 구조를 이용하여 온라인 모델링의 구현을 위한 온라인 공정구조를 연구한다. 즉, 연속시간 또는 실시간으로 FNN 구조를 이용한 퍼지규칙 모델을 얻는 문제를 다룬다. 제안된 온라인 공정구조는 FNN에 기초한 모델 알고리즘과 PLC에 기초한 시뮬레이터로 구성된다. 여기서 적응 퍼지-뉴럴네트워크와 HCM 클러스터링 방법이 온라인 모델링을 위한 지능형 동정 알고리즘으로써 사용된다. 적응 퍼지-뉴럴네트워크는 Jang과 Sun[8]이 제안한 모델로 HCM 클러스터링 알고리즘을 이용하여 주어진 공정의 특성을 파악하고 퍼지 공간 분할 시 이를 반영함으로써 적응 퍼지-뉴럴네트워크 모델의 성능과 공정에 대한 적용성을 향상시키며 프로그램 수행 시 발생하는 문제들을 해결한다. 적응 퍼지-뉴럴네트워크는 전반부와 후반부와 같은 구별되고 수정할 수 있는 두 구조들로 이루어지며 두 구조의 파라미터들은 경사하강법과 최소자승법으로 결합된 하이브리드 학습알고리즘에 의해 조절된다. 여기서, 적응 퍼지-뉴럴네트워크 전반부 멤버쉽함수의 초기 파라미터들은 HCM 클러스터링 방법을 사용하여 구해지고, 구해진 파라미터들은 오류역전과 알고리즘에 의해 학습된다. 그리고 후반부 파라미터들의 동정을 위해 순환 최소자승법(Recursive

\* 正 會 員 : 圓 光 大 電 氣 電 子 工 學 部 副 教 授 · 工 博

\*\* 準 會 員 : 圓 光 大 電 氣 電 子 工 學 部 碩 士 課 程

\*\*\* 正 會 員 : 圓 光 大 電 氣 電 子 工 學 部 碩 士

接 受 日 字 : 1999年 2月 3日

最 終 完 了 : 1999年 7月 27日

Least Squares Method)을 사용한다. 온라인 모델링을 수행하기 위해서 플랜트의 입력 및 출력 등을 제어 감시하는 PLC(Programmable Logic Controller)와 주 컴퓨터사이의 인터페이스 S/W를 설계하며, 실 공정시스템에 대한 감시 제어 시뮬레이터를 구축한다. 여기서 PLC는 비선형 공정 시스템과 온라인 모델링을 수행하는 컴퓨터와의 인터페이스를 담당하고 시스템의 동작상태를 감시 제어한다. 온라인 모델링을 위한 전체 시스템은 PLC와 컴퓨터의 인터페이스 부분, 모델링 수행의 감시 제어 시뮬레이터 화면 그리고 모델링을 수행하는 적응 퍼지-뉴럴네트워크 모델로 구성된다. 실험을 위해 가스로 공정과 하수처리 공정의 두 공정을 이용하여 실시간 퍼지 모델링을 수행 및 평가한다.

2. 적응 퍼지-뉴럴네트워크

전형적인 수학적 방법에 근거한 시스템 모델링은 불확실하고 복잡한 시스템에 대해서는 적합하지 않다. 이와 반면에 퍼지집합 이론, 퍼지규칙 그리고 퍼지추론을 도입한 퍼지추론 시스템은 인간의 지식을 정량적으로 표현할 수 있고 언어적인 제어 규칙으로 표현할 수 있다. 이러한 퍼지추론 시스템을 신경망의 네트워크 개념으로 확장하고 학습 알고리즘을 부가한 적응 퍼지-뉴럴네트워크 시스템은 퍼지 모델링 및 제어 시스템을 위한 뉴로-퍼지 시스템의 하나이다. 적응 퍼지-뉴럴네트워크 각 층의 노드는 퍼지추론 시스템의 독립적인 행동을 수행하며, 오류 역전파 알고리즘 및 최소자승법을 사용한 하이브리드 학습 알고리즘을 이용하여 퍼지-뉴럴네트워크의 전반부 및 후반부 파라미터를 동정한다.

2입력 1출력을 가지고 각 입력변수에 대하여 2개의 멤버쉽함수를 사용하는 적응 퍼지-뉴럴네트워크의 구조 예를 그림 1에 보였다.




그림 1 적응 퍼지-뉴럴네트워크의 구조 예  
Fig. 1 Structure of adaptive fuzzy-neural network

여기서, 입력은  $x, y$ 이고 출력은  $f$ 이다. 여기에 포함된 퍼지규칙은 다음과 같은 선형 추론형태의 규칙 두 개를 가진다.

$$R^1 : \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 = p_1 + q_1x + r_1y \quad (1)$$

$$R^2 : \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 = p_2 + q_2x + r_2y$$

각 층의 각 노드에서 수행되는 계산은 다음과 같다.

1 층 : 각 노드  $i$ 에 의한 출력은 식 2와 같다.

$$O_i^1 = \mu_{A_i}(x) \quad (2)$$

여기서,  $x$ 는 노드  $i$ 의 입력,  $A_i$ 는 퍼지 언어 변수이다.

$O_i^1$ 는  $A_i$ 의 멤버쉽함수 값으로 입력  $x$ 가  $A_i$ 를 만족하는 정도를 나타낸다.  $\mu_{A_i}(x)$ 은 식 3으로 표현되는 종 모양의 멤버쉽함수를 사용한다.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[ \left( \frac{x - c_i}{a_i} \right)^2 \right]^k} \quad (3)$$

여기서,  $(a_i, b_i, c_i)$ 는 파라미터 집합이다. 이러한 파라미터들을 조정함으로써 멤버쉽함수의 모양을 변경시킨다. 이것이 동정되어야 할 전반부 파라미터이다.

2 층 : 각 노드는 입력되는 신호들을 곱해서 식 4와 같이 출력된다. 이것은 각 퍼지 규칙의 전반부 적합도를 계산하는 것을 의미한다.

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i=1,2 \quad (4)$$

3 층 : 각 노드  $i$ 는  $i$ 번째 규칙의 적합도에 대한 모든 규칙의 적합도의 합의 비를 식 5와 같이 계산한다. 즉, 각 노드의 출력은 표준화된 적합도가 된다.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (5)$$

4 층 : 각 노드에 대하여 후반부 변수를 곱한다.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i + q_i x + r_i y) \quad (6)$$

$$= \frac{w_i (p_i + q_i x + r_i y)}{\sum_j w_j}$$

여기서,  $\bar{w}_i$ 는 3층의 출력이고  $\{p_i, q_i, r_i\}$ 는 동조되어야 할 후반부 파라미터들의 집합이다.

5 층 : 모든 입력 신호를 합하여 전체 퍼지모델의 출력을 식 7과 같이 계산한다.

$$O_i^5 = \sum_j \bar{w}_j f_j = \frac{\sum_j w_j f_j}{\sum_j w_j} \quad (7)$$

적응 퍼지-뉴럴네트워크의 각 파라미터들을 동정하기 위해 경사하강법에 기초한 오류역전파 알고리즘과 최소자승법을 합성하여 사용한다. 이러한 하이브리드 학습 알고리즘은 전방향 경로에서 각 노드의 출력 신호는 4층까지 계산되고, 전반부 변수가 고정된 상태에서 후반부 변수가 최소자승법에 의해 동정된다. 후방향 경로에서는 오차율이 출력노드에서 입력 노드까지 역으로 전달되고 전반부 변수가 경사 하강법에 의해 조정된다. 이러한 하이브리드 알고리즘에 의한 접근은 경사 하강법으로만 수행하는 것보다 학습 속도가 매우 빠르다. 또한, 전반부 및 후반부 파라미터의 동정에서 전반부 및 후반부 파라미터를 따로따로 동정하기 때문에 동정해야 할 파라미터의 수를 줄일 수 있다. 표 1은 각 전달 방향에 대하여 요약하였다.

표 1 적응 퍼지-뉴럴네트워크 모델의 하이브리드 학습  
Table 1 Hybrid Learning of adaptive fuzzy-neural network model

	전방향 경로	후방향 경로
전반부 파라미터	고정	경사 하강법
후반부 파라미터	최소자승법	고정
신호	노드의 출력	에러

전반부 변수의 동정을 위한 오류역전파 알고리즘은 다음과 같이 에러를 근거로 하여 퍼지규칙의 전반부 파라미터를 동정한다.

$$\Delta a = -\eta \frac{\partial E}{\partial a} \quad (8)$$

여기서,  $\eta$  는 학습율이고 식 9과 같이 계산된다.

$$\eta = \frac{k}{\sqrt{\sum_{\sigma} \left(\frac{\partial E}{\partial a}\right)^2}} \quad (9)$$

그러므로 새로운 파라미터  $a$  는 다음과 같이 주어진다.

$$a_{n+1} = a_n + \Delta a \quad (10)$$

### 2.1 입력공간의 퍼지분할

입력공간을 분할하는데 있어서 기존의 방법은 입력 변수의 최소값과 최대값 사이를 임의의 개수로 등분하여 일률적으로 정의하였다. 그러나 계통은 나름대로의 특성을 가지고 있기 때문에, 그 특성에 따라 멤버쉽함수를 정의하는 것이 보다 합리적일 수 있다.

본 논문에서는 입출력 관계의 특성을 이용하여 모델링을 수행한다. 따라서 데이터의 특성을 파악하는 것이 매우 중요하다. 입출력 데이터의 특성을 찾아내기 위해 HCM 클러스터링 알고리즘을 이용한다. 클러스터링 기법을 통해 데이터를 특성별로 분류하고, 분류된 클러스터들의 중심을 사용하여 멤버쉽함수를 정의한다.

클러스터링 알고리즘이란 데이터 내부의 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 것이다. 본 논문에서는 데이터들간의 거리를 기준으로 하여 근접한 정도를 측정하고, 이를 바탕으로 데이터를 분류하는 HCM 방법을 사용한다. HCM 방법은  $n$ 개의 데이터를  $c$ 개의 그룹으로 분류하고 데이터의 거리가 최소인 각 그룹의 중심을 찾는다. 또한 클러스터의 소속을 "0", "1"로 나타내는 이치논리를 사용한다. 클러스터링 기법에서 가장 먼저 결정해야 될 것이 클러스터의 개수이다. 일반적으로  $n$ 개의 데이터로 구성된 집합 안의 클러스터 개수는 클러스터가 2개 이상  $n$ 개 미만이어야 한다. 만약 클러스터가 1개라면 모든 데이터가 하나의 클러스터에 포함되기 때문에 결국 주어진 데이터 자체가 되고, 클러스터의 개수가  $n$ 개라면 주어진 데이터 개수만큼 클러스터 개수가 정의되는 것이기 때문에 데이터 하나 하나가 하나의 클러스터를 형성하는 것과 같게되므로 클러스터링을 하는 의미가 없다. 클러스터의 개수는 데이터에 따라 적절한 개수를 선택해 주어야한다. HCM 알고리즘의 수행과정은 다음과 같다.

step 1. 클러스터의 개수( $2 \leq c \leq n-1$ )를 결정하고 중심  $c_i (i=1, \dots, c)$  값을 랜덤하게 선택하여 초기화한다.

step 2. 소속행렬  $U$ 를 결정한다.

$$u_{jk} = \begin{cases} 1 & \text{if } \|x_k - c_i\|^2 \leq \|x_k - c_j\|^2, \text{ for } j \neq i \\ 0 & \text{otherwise} \end{cases}$$

step 3. 아래 식을 계산한다. 중심 근처에 충분히 다가갔는지 확인한다

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left( \sum_{k, x_k \in G_i} d(x_k - c_i) \right)$$

step 4. 새로운 클러스터 중심  $c_i$ 를 생성하고 step 2로 간다.

$$c_i = \frac{1}{|G_i|} \sum_{k, x_k \in G_i} x_k$$

이렇게 구해진 클러스터의 중심을 이용하여 적용 퍼지-뉴럴네트워크 모델의 전반부 초기 멤버쉽함수를 결정한다.

결정된 초기 멤버쉽함수의 파라미터들은 후반부 경로에서 경사하강법에 기초한 오류역전파 알고리즘에 의해 적용 퍼지-뉴럴네트워크 모델의 최적 파라미터로 학습되어진다.

### 2.2 적응 퍼지-뉴럴네트워크의 온라인 모델 동정

퍼지 추론 시스템(Fuzzy Inference System)은 지식과 경험을 바탕으로 인간 판단의 애매성을 포함하는 경험지식을 언어적 제어 규칙으로 표현하고 퍼지 추론을 이용해서 연산을 수행하도록 한 것으로 주어진 입출력 데이터간의 상관관계로부터 내부지식으로 정의하여 전문가의 경험지식에 의한 결과를 도출한다. 적응 퍼지-뉴럴네트워크 모델은 선형 퍼지 추론과 같은 형태이다. 이것은 선형 퍼지 추론 규칙을 동정하는 의미와 같다. 선형 퍼지 추론 모델은 주어진 입출력 데이터로부터 퍼지규칙을 생성하기 위한 체계적인 접근 방법이다. 이 방법은 입출력 데이터가 비선형적인 관계에 있을 경우에 매우 효율적으로 적용할 수 있다는 장점을 가지고 있다. 즉, 비선형적인 데이터의 관계를 선형적인 다항식의 합으로 조합하여, 데이터들간의 상호 연관성을 찾아 입력 공간에서 데이터 구성과 근사한 몇 개의 다항식으로 수식화하여 표현하는 방법이다.

선형 퍼지 추론 모델은 각 입력 변수의 전체 공간을 퍼지 부분 공간으로 분할하여 각 부분공간의 입·출력 관계를 1차 선형식으로 나타내고 가중치를 고려한 이들의 합에 의해 비선형 시스템의 입·출력 관계를 나타내며 이러한 형태의 퍼지모델의 도입으로 인해 퍼지 시스템의 구축이 좀 더 체계화되고 이것의 적용분야가 다양해졌다. 또한, Sugeno 퍼지모델의 퍼지 언어적 변수는 전반부에만 있기 때문에 퍼지 규칙과 비퍼지 규칙 사이의 구별이 쉽다. 선형 퍼지모델은 식 11의 형태를 가지는 구현 규칙들로 구성된다.

$$R^j: \text{IF } x_1 \text{ is } A_{j1} \dots x_k \text{ is } A_{jk} \text{ Then } y = a_0 + a_1x_1 + \dots + a_jx_k \quad (11)$$

여기서  $R^j$ 는  $j(j=1, \dots, n)$ 번째 규칙,  $x_l(l=1, \dots, k)$ 는 입력변수,  $A_{jl}$ 은 퍼지집합의 멤버쉽함수,  $a_{jl}$ 은 후반부의 파라미터이고  $n$ 은 규칙 수이다. 추론된 값  $y^*$ 는 다음과 같다.

$$y_i^* = \frac{\sum_{j=1}^n w_{ji} y_j}{\sum_{j=1}^n w_{ji}} = \frac{\sum_{j=1}^n w_{ji} (a_0 + a_1x_{1i} + \dots + a_jx_{ki})}{\sum_{j=1}^n w_{ji}} \quad (12)$$

여기서  $i$ 는  $i(i=1, \dots, m)$ 번째 데이터이다.

후반부 파라미터 동정은 전반부 입력변수 및 파라미터가 주어지면, 성능 평가지수 PI(Performance Index)를 최소화하는 후반부 파라미터  $a_{ji}$ 를 결정할 수 있다. PI는 원 시스템의 출력 데이터  $y_i$ 와 모델의 출력 데이터  $y_i^*$ 간의 차이를 의미하는 성능지수로 식 13으로 정의된다.

$$PI = \frac{1}{m} \sum_{i=1}^m (y_i - y_i^*)^2 \quad (13)$$

퍼지 if-then 규칙의 후반부 파라미터는 입·출력 데이터가 주어졌을 때 최소자승법에 의해 구해진다. 최소자승법에 의한 매개변수 추정은 식 14와 같다.

$$V(a, m) = \frac{1}{2} \sum_{i=1}^m \epsilon_i^2 = \frac{1}{2} \sum_{i=1}^m (y_i - y_i^*)^2 = \frac{1}{2} \sum_{i=1}^m \left[ y_i - \sum_{n=1}^N a_n w_{ni} \right]^2 \quad (14)$$

$$= \frac{1}{2} \sum_{i=1}^m [y_i - x_i^T a]^2 = \frac{1}{2} \cdot \|E\|^2$$

$$w_{ji} = \frac{(A_{ji}(x_{1i}) \wedge \dots \wedge A_{jk}(x_{ki}))}{\sum_{i=1}^n (A_{ji}(x_{1i}) \wedge \dots \wedge A_{jk}(x_{ki}))} \quad (15)$$

식 14에서  $E=Y-Xa$ 이므로 최소자승법에 의한 후반부 파라미터의 동정은 식 16에 의해 구해진다.

$$\hat{a} = (X^T X)^{-1} X^T Y \quad (16)$$

$$x_j^T = [w_{j1}, \dots, w_{jn}, x_{1j}w_{j1}, \dots, x_{1j}w_{jn}, \dots, x_{kj}w_{j1}, \dots, x_{kj}w_{jn}] \quad (17)$$

$$a^T = [a_{10}, \dots, a_{n0}, a_{11}, \dots, a_{n1}, \dots, a_{1k}, \dots, a_{nk}]$$

$$Y = [y_1, y_2, \dots, y_n]^T, \quad X = [x_1, x_2, \dots, x_n]^T$$

선형 퍼지 추론 모델링의 경우 N개의 샘플링 데이터를 가지고서 최소자승법에 의한 후반부 파라미터를 결정하였다. 하지만 새로운 입력 데이터가 순차적으로 들어오는 경우 즉, 온라인 모델링을 수행할 경우에는 새로운 데이터가 순차적으로 입력되기 때문에 사용할 수 없다. 이러한 경우에는 순환 최소자승법(Recursive Least Square Method)을 이용하여 모델링을 수행해야 한다. N개의 샘플링 데이터에 대해서는 최소자승법을 이용하여 식 18과 같이 후반부 파라미터를 결정한다.

$$a_N = (X_N^T X_N)^{-1} X_N^T Y_N \quad (18)$$

$$X_N = \begin{bmatrix} w_{11} & \dots & w_{1n} & x_{11}w_{11} & \dots & x_{11}w_{1n} & \dots & x_{k1}w_{11} & \dots & x_{k1}w_{1n} \\ w_{12} & \dots & w_{12} & x_{12}w_{12} & \dots & x_{12}w_{12} & \dots & x_{k2}w_{12} & \dots & x_{k2}w_{12} \\ \vdots & & \vdots & \vdots & & \vdots & & \vdots & & \vdots \\ w_{1N} & \dots & w_{1N} & x_{1N}w_{1N} & \dots & x_{1N}w_{1N} & \dots & x_{kN}w_{1N} & \dots & x_{kN}w_{1N} \end{bmatrix}$$

$$a_N = [a_{10} \dots a_{n0} \ a_{11} \dots a_{n1} \ \dots \ a_{1k} \dots a_{nk}], \quad Y_N^T = [y_1 \ y_2 \ \dots \ y_n]$$

새로운 입력 데이터가 들어오는 경우 순환 최소자승법(Recursive Least Square Method)을 적용하여 새로운 파라미터를 계산한다. N+1번째부터 입력 데이터에 대해서 파라미터 추정은 식 19와 같이 표현할 수 있다.

$$a_{N+1} = \left( \begin{bmatrix} X_N \\ x_{N+1} \end{bmatrix}^T \begin{bmatrix} X_N \\ x_{N+1} \end{bmatrix} \right)^{-1} \begin{bmatrix} X_N \\ x_{N+1} \end{bmatrix}^T \begin{bmatrix} Y_N \\ y_{N+1} \end{bmatrix} \quad (19)$$

여기서,  $x_{N+1} = [w_{1N+1} \ \dots \ w_{1N+1} \ \dots \ x_{kN+1}w_{1N+1} \ \dots \ x_{kN+1}w_{1N+1}]$  이것은 식 20으로부터 식 21과 같이 간략하게 표현하여 선형 퍼지 추론의 후반부 파라미터를 결정한다. 그러므로 다음과 같이 순차 최소자승법으로 후반부 파라미터를 새로운 입력 데이터에 대해서 조정할 수 있다.

$$P_N = [X_N^T X_N]^{-1} \quad (20)$$

$$K_{N+1} = \frac{P_N}{1 + x_{N+1}^T P_N x_{N+1}} \quad (21)$$

$$a = a_N + K_{N+1} x_{N+1}^T [y_{N+1} - x_{N+1} a_N] \quad (22)$$

$$P_{N+1} = P_N - \frac{P_N x_{N+1}^T x_{N+1} P_N}{1 + x_{N+1}^T P_N x_{N+1}} \quad (23)$$

### 3. 온라인 시스템 구성

온라인 모델링은 시스템이 동적으로 변하거나 주위 환경에 대해 민감한 시스템을 동정하는데 필요하다. 오프라인에 의한 모델링은 컴퓨터 시뮬레이션을 통해 모델을 획득하기 때문에 실제 플랜트에 적용하기에는 많은 문제점이 따른다. 주위 환경에 민감한 시스템이나 노이즈가 있는 시스템은 오프라인 보다는 온라인에 의한 모델링이 필요하며 온라인 모델링을 위한 전체 시스템 구축이 중요하다. 특히 실제 플랜

트에 모델을 적용하기 위해서는 온라인 모델링에 의한 모델 구축이 필수적이다. 그림 2는 기본적인 온라인 모델링에 의한 파라미터 동정의 구조이다. 대상 시스템의 출력과 모델 출력의 오차를 근거로 모델의 파라미터는 동정 알고리즘에 의해서 실시간으로 조정된다.




그림 2 온라인 모델링에 의한 파라미터 동정  
Fig. 2 Parameter identification by on-line modeling




그림 3 온라인 모델링을 위한 전체 시스템 구성  
Fig. 3 System configuration for online modeling

온라인 모델링을 위해서 본 연구에서는 산업 플랜트 공정의 자동화에 쓰이는 PLC를 이용하여 비선형 공정의 자동화 공정과 하수처리 공정의 온라인 모델링을 수행한다. 전체 시스템의 구성은 그림 3에서 보여주는 것과 같이 크게 두 부분으로 나뉘어진다. 하나는 비선형 공정의 자동화를 위해 구축된 PLC 시스템이고 다른 하나는 자동화된 공정의 감시 및 제어를 담당하는 메인 컴퓨터부분이다. 본 논문에서는 이러한 시스템을 결합하여 비선형 공정의 감시 및 제어를 담당하는 감시제어 시뮬레이터를 구축하고 제안된 적응 퍼지-뉴럴네트워크 모델을 이용하여 비선형 공정에 대한 실시간 모델링을 수행함으로써 최적의 퍼지모델을 획득한다.

플랜트의 실시간 감시 제어 및 온라인 모델링을 위하여 PLC와 컴퓨터의 인터페이스를 구축한다. 논문에서는 Master-K 500H PLC를 사용하여 컴퓨터와 인터페이스를 구축하였다. Master-K 500H PLC는 RS-232C 인터페이스 방식으로 컴퓨터와 통신을 수행한다. PLC의 컴퓨터 링크 기능을 이용하여 실시간으로 비선형 공정의 입출력 데이터를 취득하였고, 컴퓨터에서는 취득한 데이터를 이용하여 적응 퍼지-뉴럴네트워크 모델링을 수행한다. 또한 컴퓨터의 시뮬레이터 화면을 구축하여 실시간으로 비선형 공정의 감시 및 제어를 수행하며 모델링 수행에 따른 각 파라미터의 변화와 예측 능력을 실시간으로 확인한다. 그림 4에 비선형 공정의 온라인 모델링 수행 흐름도를 보였다.




그림 4 비선형 공정 시스템의 온라인 모델링 수행 흐름도  
Fig. 4 Online modeling flow chart of the nonlinear process system


### 4. 시뮬레이션

본 논문에서는 적응 퍼지-뉴럴네트워크 모델의 성능을 평가하기 위하여 두 종류의 데이터를 이용해 시뮬레이션을 수행한다. 첫 번째는, 비선형 공정에 대한 성능 평가의 척도로 사용되고 있는 가스로 공정 데이터이고, 두 번째로 하수처리 공정의 대부분을 차지하고 있는 활성오니 공정 데이터를 사용한다. 이들은 입력과 출력의 관계를 나타내는 다수 데이터의 집합으로 나타내어진다. 시뮬레이션에서 사용되는 데이터의 집합은 학습 및 테스트로 나누어진다. 전체 데이터의 절반은 근사화를 위한 학습 데이터로 사용되고 나머지 절반은 모델의 일반화를 위한 데이터로 사용된다. 성능평가 기준인 PI는 가스로 공정과 하수처리 공정에 대해서 MSE (Mean Squared Error), 즉 식 13을 사용한다.

#### 4.1 가스로 공정

Box와 Jenkin[6]이 이용한 가스로 공정 데이터를 이용한다. 이 데이터는 296개의 입출력 데이터쌍을 이루고 있다. 입력 변수  $u(t)$ 는 메탄가스의 흐름율이고 출력  $y(t)$ 는  $CO_2$ 의 농도이다. 메탄가스 흐름율은 실험에서 -2.5에서 2.5로 변하는 것을 사용하나 실제 공정에서 메탄가스 흐름율은 식 24에 의해 0.5에서 0.7로 변한다. 논문에서는 전체 데이터의 절반은 학습 데이터, 나머지 절반은 테스트 데이터로 사용하였다.

$$X_m(t) = 0.60 - 0.048 \times X(t) \quad (24)$$



(a) Training Data (b) Testing Data

그림 5 데이터 집합( $u(t-3), y(t-1), y(t)$ )에 의해 유겨된 데이터 점들

Fig. 5 Data points induced by I/O data set( $u(t-3), y(t-1), y(t)$ )

일정 데이터가 주어진 경우, 입출력 데이터에 의해 최적 구조를 가지는 입출력변수를 선정한다. 논문에서는 가스로 공정의 입출력 구조로  $u(t-3)$ 과  $y(t-1)$ 을 선정하였다. 그림 5는 입력과 출력에 대한 데이터의 분포를 보여준다. 데이터 집합 ( $u(t-3), y(t-1), y(t)$ ) 이외의 ( $u(t-1), y(t-1), y(t)$ ), ..., ( $u(t-5), y(t-1), y(t)$ ) 및 ( $u(t-3), y(t-2), y(t)$ ), ( $u(t-3), y(t-3), y(t)$ )등에 의한 데이터 분포는 덜 균일하고 흩어진 분포구조로 제안된 입출력 구조인 ( $u(t-3), y(t-1), y(t)$ )보다 성능이 현저히 떨어진다.

적응 퍼지-뉴럴네트워크 모델의 전체 구조는 각 입력 변수에 대하여 각각 2개, 3개 4개의 퍼지 언어 변수를 사용하여 퍼지규칙을 구성하였다. 각 입력 변수에 대한 퍼지 변수가 사용하는 퍼지 언어 변수는 식 3과 같은 종 모양의 멤버쉽함수이고, HCM 클러스터링 알고리즘에 의해 구해진 초기 파라미터  $\{a_i, b_i, c_i\}$ 는 오류역전과 알고리즘에 의해 동정된다. 또한 퍼지 추론의 후반부 파라미터는 최소자승법에 의

해 최적의 해를 찾는다. 각 입력에 대해 멤버쉽함수가 3개인 경우, 전반부 파라미터 18개, 후반부 파라미터 27개의 파라미터가 하이브리드 학습 알고리즘에 의해 자동 조정된다. 그림 6은 가스로 공정에 대한 적응 퍼지-뉴럴네트워크 모델의 구조이다.




그림 6 적응 퍼지-뉴럴네트워크 모델의 구조


Fig. 6 The structure of the adaptive fuzzy-neural network model

가스로 공정에 대한 시뮬레이션은 입력이  $u(t-3), y(t-1)$ 일 때와  $u(t-4), y(t-1)$ 일 때를 각각 수행하였다. 입력이  $u(t-3), y(t-1)$ 이고 각 입력에 대해 멤버쉽함수가 3개일 때 모델의 성능은 학습성능이 0.0215이고 테스트성능은 0.3327로써 좋은 결과를 보여주고 있다. 표 2는 각 입력 변수에 대한 학습 및 테스트성능 결과를 보여준다. 표에서 알 수 있듯이 입출력 구조가  $u(t-4), y(t-1)$ 보다는  $u(t-3), y(t-1)$ 일 때 좋은 성능결과를 얻을 수 있다. 그림 7과 8은 입력이  $u(t-3)$ 과  $y(t-1)$ 일 때 초기 멤버쉽함수와 오류역전과 알고리즘에 의해 동정된 멤버쉽함수를 보여 주고 있다. 그림 9는 학습 데이터에 대한 제안된 모델의 동정 결과 및 오차를 보여주고 있고, 그림 10은 테스트 데이터에 대한 모델의 동정 결과 및 동정 오차를 나타내고 있다. 또한 그림 11은 학습 횟수에 따른 학습 성능 및 테스트 성능의 수렴을 보여준다.

표 2 가스로 공정의 모델링 결과

Table 2 Modeling result of the gas furnace process


입력 변수	규칙수	학습	테스트
$u(t-3), y(t-1)$	4	0.022	0.353
	9	0.021	0.332
	16	0.022	0.352
$u(t-4), y(t-1)$	4	0.078	0.425
	9	0.072	0.380
	16	0.072	0.376



(a) 초기 멤버쉽함수 (b) 동정된 멤버쉽함수

그림 7 입력  $u(t-3)$ 에 대한 초기 및 동정된 멤버쉽함수


Fig. 7 Initial and final tuned membership function for the input  $u(t-3)$



(a) 초기 멤버십함수 (b) 동정된 멤버십함수

그림 8 입력  $y(t-1)$ 에 대한 초기 및 동정된 멤버십함수


Fig. 8 Initial and final tuned membership function for the input  $y(t-1)$



(a) 학습 데이터에 대한 출력 (b) 출력 오차

그림 9 모델의 학습 데이터에 대한 결과

Fig. 9 The result of model for training data



(a) 테스트 데이터에 대한 출력 (b) 출력 오차

그림 10 모델의 테스트 데이터에 대한 결과

Fig. 10 The result of model for testing data




그림 11 학습 횟수에 따른 모델의 성능 지수

Fig. 11 Performance index of model according to learning iteration

기존의 퍼지추론 방법들과 제안된 모델의 학습 및 테스트 성능을 표 3에 비교하였다. 온라인 퍼지모델[12]은 데이터 집합 전체를 이용한 결과이다. Min-Max[9, 10], Complex[9, 10] 방법들은 퍼지 멤버십함수로 삼각형 멤버십함수를 사용한 오프라인(off-line) 동정 모델이다. Min-Max법은 멤버십 함수를 일정하게 배열하고 퍼지 추론한 결과이며, Complex

는 삼각형 멤버십함수의 각 파라미터를 수정된 컴플렉스법을 사용하여 동정한 결과이다. 제안된 모델은 온라인 모델링이 가능하기 때문에 실제 플랜트에 적용할 때는 좋은 성능을 나타낼 수 있다.

표 3 가스로 공정의 모델 성능 비교

Table 3 Comparison of model performance to the gas furnace process

입력변수	Method	전체 규칙수	학습성능	테스트성능
$u(t-3)$ $y(t-1)$	On-line	4	0.145	
	Fuzzy model[12]	4	0.1443	
	Our model	9	0.1280	
	Min-Max[9,10]	4	0.024	0.358
	Complex[9,10]	4	0.022	0.326
	Our model	9	0.021	0.332
$u(t-4)$ $y(t-1)$	Min-Max[9,10]	4	0.078	0.343
	Complex[9,10]	4	0.105	0.220
	Our model	9	0.072	0.380

4.2 하수처리 공정

현재 대부분의 하수처리 플랜트는 제어 공정에서 조절 데이터를 얻기 위해 수학적 모델을 이용하고 있다. 그러나 이러한 수학적 모델이 하수처리공정 변수들 사이의 관계를 정확하고 효과적으로 설정하지 못하므로, 제안된 방법을 통해 수도권 하수처리장 중의 하나를 모델로 선정하여 1년간의 수질 데이터를 가지고 모델링한다.




그림 12 활성오니공정을 이용한 하수처리시스템의 개요도

Fig. 12 Configuration of the sewage treatment system

활성오니공정은 하수처리를 위한 다양한 방법 중 가장 많이 사용되는 방법으로, 침사지, 최초침전지, 폭기조 및 최종 침전지로 구성된다. 활성오니란 유기물 제거의 중심을 이루는 미생물로 폭기조에서 자연 발생되며, 응집한 미생물의 덩어리를 플록이라 한다. 활성오니는 폭기조내에서 공급되는 산소와 결합하여 유기물을 물과 탄산가스로 분해한다. 최종 침전지에서는 플록을 침강, 제거하고 맑은 물을 외부로 흘러 보낸다. 한편 최종침전지에서 침강한 미생물은 폭기조 입구에서 재순환되어 다시 유기물 제거에 사용된다. 본 논문에서는 활성오니공정의 폭기조 및 최종침전지를 하나의 단일 모델로 설정하여, 실제 최초침전지로 유입되는 생물학적 산소요구량 및 유입수의 부유물 농도를 측정하고, 최종침전지에서 유출되는 생물학적 산소요구량 및 부유물 농도를 통하여 하수처리 정도를 비교한다. 모델은 혼합액 부유물 (MLSS: Mixed Liquid Suspended), 잉여오니 흐름율 (WSR: Waste Sludge Ratio), 반송율 설정치 (RRSP: Recycled Return Sludge), 용존산소 설정치 (DOSP: Dissolved Oxygen


Set Point)를 입력으로하고, 부유물의 농도(ESS:Effluent Suspended Solids)를 출력으로하는 4입력 1출력 구조를 가진다. 본 연구에서는 2입력 1출력 형태의 공정과 4입력 1출력 형태의 공정을 제안된 모델에 대하여 시뮬레이션을 수행한다. 2입력인 경우 4개의 입력 변수를 각각 두 개씩 선택하여 모델의 입출력을 구성하였고, 각 입력 변수에 대하여 퍼지 언어변수를 2개, 3개, 4개를 사용하였다. 4입력 1출력인 경우 각 입력 변수에 대하여 퍼지 언어변수는 2개씩 사용하여 전체 퍼지규칙 수는 16개이다. 2입력 1출력인 경우 각 입력에 대하여 멤버십함수가 3개 일 때 동정해야할 전체 파라미터의 수는 전반부 파라미터 18개, 후반부 파라미터 45개이다. 4입력인 경우 전체 파라미터 수는 전반부 파라미터 24개, 후반부 파라미터 80개이다.

표 4는 각 입력변수의 선택에 대해서 모델링을 수행한 결과이며, PI는 학습 데이터에 대한 성능지수이고 E\_PI는 테스트 데이터에 대한 성능지수이다. 그리고  $\min((PI+E\_PI)/2)$ 는 PI와 E\_PI를 모두 고려한 것으로 학습과정 중 두 성능지수의 합을 2로 나눈 값이 가장 작은 것을 의미하며  $\min(PI)$ 는 PI만을 고려한 것으로 학습 데이터에 대한 성능지수가 학습과정 중 가장 작은 것을 의미한다. 또한  $\min(E\_PI)$ 는 학습 데이터에 의한 FNN구조에 의한 퍼지모델을 구축한 다음 생성된 퍼지모델에 테스트 데이터를 가하여 평가용 성능지수 E\_PI를 구하고, 오직 이 E\_PI를 최소화시키는 방향으로 학습하게 된다. 제안된 모델에 대해서는 입력 변수가 WSR, DOSP일 때 가장 우수한 동정 결과를 얻었다.

표 4 하수처리 공정의 모델링 결과

Table 4 Modeling result of the sewage treatment process


입력 변수	전체 규칙 수	min((PI+E_PI)/2)		min(PI)		min(E_PI)	
		PI	E_PI	PI	E_PI	PI	E_PI
MLSS, WSR	4	11.289	16.306	6.086	39.856	11.289	16.306
	9	5.345	26.175	2.339	258.163	5.345	26.175
	16	1.738	45.544	1.156	157.865	11.530	42.044
MLSS, RRSF	4	10.524	59.008	8.679	99.287	10.524	59.008
	9	3.779	6376.672	3.660	7426.563	3.779	6376.672
	16	2.886	130.680	0.251	317.865	2.886	130.680
MLSS, DOSP	4	9.176	24.061	9.043	25.915	9.176	24.061
	9	6.622	24.191	5.174	29.387	7.223	23.717
	16	5.192	28.244	2.218	205.891	5.192	28.244
WSR, RRSF	4	11.867	22.644	7.168	121.034	11.867	22.644
	9	9.515	29.362	5.890	101.184	9.515	29.362
	16	37.070	201.983	2.860	791.421	50.061	196.508
WSR, DOSP	4	9.352	17.447	9.023	28.879	9.629	17.347
	9	4.488	17.497	2.990	25.873	4.806	17.312
	16	5.351	90.527	0.029	564.835	5.351	90.527
RRSF, DOSP	4	11.657	18.286	6.765	42.633	11.657	18.286
	9	7.027	25.532	3.008	67.179	7.027	25.532
	16	24.200	722.918	0.081	5028.707	39.213	712.377
MLSS, WSR, RRSF, DOSP	16	7.469	22.176	0.961	72.361	7.469	22.176



(a) 입력변수 WSR (b) 입력변수 DOSP

그림 13 초기 및 최종적으로 동정된 멤버십함수

Fig 13 Initial and Final tuned membership function



(a) 학습 데이터에 대한 출력 (b) 테스트 데이터에 대한 출력  
그림 14 적응 FNN 모델의 출력과 실 데이터의 출력 비교 (입력변수 : WSR, DOSP)

Fig. 14 Comparison of original data and output data for adaptive FNN model

표 5 하수처리 공정의 모델링 결과 비교

Table 5 Comparison of the sewage treatment process

입력변수	Method	전체 규칙수	학습성능	테스트성능
WSR, DOSP	Min-Max[9,10]	4	8.622	57.188
	Complex[9,10]	4	7.878	46.393
	GA[11]	4	6.871	28.599
	Our model	4	9.352	17.447
		9	4.488	17.497

### 5. 온라인 공정 시뮬레이터

본 논문에서는 온라인 모델링을 수행하기 위해 가스로 공정과 하수처리 공정 시스템을 이용한다. 온라인 모델링을 위해 PLC와 컴퓨터 사이의 인터페이스 S/W를 설계하였고 공정 시스템에 대한 감시제어 시뮬레이터를 구축하였다. PLC는 Master-k 500H를 사용하며 RS-232C 인터페이스 방식으로 컴퓨터와 통신을 수행한다.

#### 5.1 가스로 공정 시스템

본 절에서는 비선형 공정인 가스로 공정 시스템에 대하여 온라인 모델링을 수행한다. 그림 15는 가스로 공정에 대한 온라인 모델링의 감시 및 제어 화면이다.




그림 15 가스로 공정의 온라인 모델링 감시 제어 화면

Fig. 15 Monitoring and control screen of the on-line modeling in the Gas furnace process

온라인 모델링을 위하여 PLC에 가스공정의 테스트 데이터를 저장해 놓고 9초의 지연시간을 주어 순차적으로 새로운 입출력 데이터가 발생하도록 대상 시스템을 구성하였다. 실시간 모델링을 수행하는 컴퓨터와 PLC의 인터페이스를 PLC의 전용 RS-232C 프로토콜을 이용하여 구축하고 온라인 모델링 시뮬레이터 화면을 통해 실시간으로 모델링 수행과정을 감시 제어 가능하도록 설계하였다. 퍼지 추론에서 각 입력 변수에 대하여 3개의 전반부 멤버쉽함수를 사용하고 가스공정의 학습 데이터를 사용하여 동정된 멤버쉽함수를 사용한다.




그림 16 가스공정의 온라인 모델링에서 각 입력 멤버쉽함수의 멤버쉽 값

Fig. 16 The membership value of each input membership function identified in the on-line modeling

그림 16은 새로운 각 입력변수에 대하여 멤버쉽함수의 멤버쉽 값을 얻는 화면을 구성하였다. 그림 17은 적용 퍼지-뉴럴네트워크 모델의 출력과 플랜트의 실제 출력을 보여주는 트렌드 화면이고 그림 18은 실제 출력과 모델 출력의 오차이다.




그림 17 온라인 동정을 위한 감시 화면  
Fig. 17 Monitoring screen for on-line identification




그림 18 온라인 모델링의 동정 오차를 위한 감시 화면  
Fig. 18 Monitoring screen for identification error of on-line modeling.

온라인 모델링에 의해 구축된 가스공정의 입력 변수  $[u(t-3), y(t-1)]$ 에 대하여 동정된 9개의 퍼지규칙은 다음과 같다.

- $R^1$ : If  $u(t-3)$  is Small<sub>1</sub> and  $y(t-1)$  is Small<sub>2</sub>, then  $y(t) = a_1 \cdot X$
- $R^2$ : If  $u(t-3)$  is Small<sub>1</sub> and  $y(t-1)$  is Middle<sub>2</sub>, then  $y(t) = a_2 \cdot X$
- $R^3$ : If  $u(t-3)$  is Small<sub>1</sub> and  $y(t-1)$  is Large<sub>2</sub>, then  $y(t) = a_3 \cdot X$
- $R^4$ : If  $u(t-3)$  is Middle<sub>1</sub> and  $y(t-1)$  is Small<sub>2</sub>, then  $y(t) = a_4 \cdot X$
- $R^5$ : If  $u(t-3)$  is Middle<sub>1</sub> and  $y(t-1)$  is Middle<sub>2</sub>, then  $y(t) = a_5 \cdot X$
- $R^6$ : If  $u(t-3)$  is Middle<sub>1</sub> and  $y(t-1)$  is Large<sub>2</sub>, then  $y(t) = a_6 \cdot X$
- $R^7$ : If  $u(t-3)$  is Large<sub>1</sub> and  $y(t-1)$  is Small<sub>2</sub>, then  $y(t) = a_7 \cdot X$
- $R^8$ : If  $u(t-3)$  is Large<sub>1</sub> and  $y(t-1)$  is Middle<sub>2</sub>, then  $y(t) = a_8 \cdot X$
- $R^9$ : If  $u(t-3)$  is Large<sub>1</sub> and  $y(t-1)$  is Large<sub>2</sub>, then  $y(t) = a_9 \cdot X$

여기서,  $X=[1, u(t-3), y(t-1)]$ 이고  $a_i$ 는 다음 행렬의  $i$ 번째 열벡터이다. 퍼지추론의 동정된 후반부 파라미터들을 아래 표에 나타냈다.

$$A = \begin{bmatrix} 0.008112 & 0.008994 & 0.388128 \\ -0.001440 & 0.002281 & -0.075314 \\ 0.003039 & -0.007175 & 0.294188 \\ 0.038191 & 0.024105 & 1.275048 \\ 0.025293 & 0.025127 & 1.346796 \\ 0.004628 & 0.028792 & 1.160725 \\ 0.000000 & 0.000000 & 0.000002 \\ 0.000000 & 0.000000 & 0.000003 \\ 0.000000 & 0.000000 & 0.000014 \end{bmatrix}$$

언어변수  $NA_i, ZE_i, PO_i(i=1,2)$ 는 파라미터  $a, b, c$ 를 가진 종 모양의 멤버쉽함수에 의해서 정의된다. 표 6은 가스공정에 대한 적용 퍼지-뉴럴네트워크 모델의 동정된 전반부 파라미터이다.

표 6 가스공정의 동정된 전반부 파라미터  
Table 6 final tuned premise parameter of the fuzzy rules

A	a	b	c
Small1	0.739066	1.978293	-0.295176
Middle1	1.479457	1.489489	0.646485
Large1	0.014627	1.575979	1.751710
Small2	1.357272	0.390248	45.691769
Middle2	0.083646	1.805045	53.069027
Large2	2.881152	0.609037	60.097565

### 5.2 하수처리 공정 시스템

본 절에서는 비선형 공정인 하수처리 공정 시스템에 대하여 온라인 모델링을 시뮬레이션 하였다. 가스공정과 마찬가지로 적용 퍼지-뉴럴네트워크를 이용하여 하수처리 공정에 대하여 온라인 모델링을 수행한다. 오프라인에서 다른 입력 변수보다 좋은 성능을 발휘한 입력변수로서 WSR과 DOSP를 온라인 모델링에 이용한다. 적용 퍼지-뉴럴네트워크 모델의 퍼지 추론의 멤버쉽함수는 종 모양의 멤버쉽함수를 사용하는데 멤버쉽함수의 파라미터 값은 학습 데이터에 의해 동정된 값을 사용한다. 각 입력 변수에 대하여 세 개의 멤버쉽함수를 사용하고 전체 규칙 수는 9개이다. 온라인 모델링을 위한 전체 시스템의 구조는 하수처리 공정의 가상 플랜트를 가지는 PLC를 사용하고, PLC는 가상 플랜트의 입출력 제어를 담당하고 컴퓨터와 인터페이스를 통하여 온라인 모델링에 필요한 입출력 데이터를 전송한다. 온라인 모델링을 감시 및 제어 시뮬레이터 화면은 Visual Basic 언어



를 이용하여 구축하였고 PLC의 전용 프로토콜에 의한 RS-232C 통신을 구축하여 실시간 모델링을 수행한다. 그림 29는 하수처리 비선형 공정의 온라인 모델링을 위한 감시 제어 화면이다. 온라인 모델링에서 퍼지 추론의 전반부 멤버쉽 값은 그림 20에 보였다. 또한, 그림 21은 실제 플랜트의 출력과 제안된 모델에 의한 온라인 동정의 출력을 나타냈다. 그림 22는 실제 출력과 적용 퍼지-뉴럴네트워크 모델의 동정 오차를 나타낸 것이다.




그림 19 하수처리 공정의 온라인 모델링을 위한 감시 제어 화면

Fig. 19 Monitoring and control screen of the online modeling in the sewage treatment process




그림 20 하수처리 공정의 온라인 모델링에서 각 입력 멤버쉽함수의 멤버쉽 값

Fig. 20 The membership value of each input membership function identified in the on-line modeling




그림 21 온라인 동정을 위한 감시 화면

Fig. 21 Monitoring screen for on-line identification




그림 22 온라인 모델링의 동정 오차를 위한 감시 화면

Fig. 22 Monitoring screen for identification error of on-line modeling.

온라인 모델링에 의해 구축된 하수처리 공정의 입력 변수가 [WSR, DOSP]에 대하여 동정된 9개의 퍼지규칙은 다음과 같다.

- $R^1$ : If WSR is Small<sub>1</sub> and DOSP is Small<sub>2</sub>, then ESS =  $c_1 \cdot X$
- $R^2$ : If WSR is Small<sub>1</sub> and DOSP is Middle<sub>2</sub>, then ESS =  $c_2 \cdot X$
- $R^3$ : If WSR is Small<sub>1</sub> and DOSP is Large<sub>2</sub>, then ESS =  $c_3 \cdot X$
- $R^4$ : If WSR is Middle<sub>1</sub> and DOSP is Small<sub>2</sub>, then ESS =  $c_4 \cdot X$
- $R^5$ : If WSR is Middle<sub>1</sub> and DOSP is Middle<sub>2</sub>, then ESS =  $c_5 \cdot X$
- $R^6$ : If WSR is Middle<sub>1</sub> and DOSP is Large<sub>2</sub>, then ESS =  $c_6 \cdot X$
- $R^7$ : If WSR is Large<sub>1</sub> and DOSP is Small<sub>2</sub>, then ESS =  $c_7 \cdot X$
- $R^8$ : If WSR is Large<sub>1</sub> and DOSP is Middle<sub>2</sub>, then ESS =  $c_8 \cdot X$
- $R^9$ : If WSR is Large<sub>1</sub> and DOSP is Large<sub>2</sub>, then ESS =  $c_9 \cdot X$

여기서,  $X=[1, WSR, DOSP]$ 이고  $c_i$ 는 다음 행렬의  $i$ 번째 열벡터이다.

$$C = \begin{bmatrix} 2.242264 & 0.432205 & -0.313583 \\ -0.944103 & -1.313570 & 4.611900 \\ -0.960711 & -0.125288 & -8.771051 \\ 3.289994 & 2.931742 & 2.336931 \\ -3.291064 & 4.251189 & 0.338557 \\ 0.983404 & -4.677991 & -4.677991 \\ 2.143134 & 1.955657 & 8.760627 \\ 0.908622 & 1.024604 & 2.280434 \\ -0.046584 & 0.215022 & 0.215022 \end{bmatrix}$$

언어적 변수  $NA_i, ZE_i, PO_i(i=1,2)$ 는 파라미터  $a, b, c$ 를 가진 종 모양 멤버쉽함수에 의해서 정의된다. 표 7은 하수처리 공정에 대한 적용 퍼지-뉴럴네트워크 모델의 동정된 전반부 파라미터이다.

표 7 하수처리 공정의 동정된 전반부 파라미터 (입력 : WSR, DOSP)

Table 7 Final tuned premise parameter of the fuzzy rules

A	a	b	c
Small1	0.479998	1.926196	-0.016131
Middle1	1.698117	1.801779	1.308934
Large1	0.283064	2.476682	1.224144
Small2	1.932732	1.567730	2.759437
Middle2	0.866818	1.620332	5.764657
Large2	0.601517	1.666163	8.596302

### 6. 결론

본 논문은 퍼지 추론 시스템에 신경망의 네트워크 개념을 적용한 적용 퍼지-뉴럴네트워크 구조를 이용하여, 비선형성이 강하고 복잡한 시스템에 대해서 퍼지 모델링을 수행하였

다. 특히, 비선형 공정에 대하여 온라인 모델링을 수행하여 실시간 모델 구축을 행하였다. 온라인 모델링을 위해서 PLC와 인터페이스 설계, PLC의 감시 및 제어 시뮬레이터 개발 그리고 온라인 모델링 수행 화면을 구축하였다. 적응 퍼지-뉴럴네트워크 모델에서 오류 역전파 알고리즘과 최소자승법을 결합한 하이브리드 학습 알고리즘과 HCM 클러스터링 알고리즘을 이용하여 보다 최적의 모델을 설계하였다. 온라인 모델링 수행에 앞서서 사용된 모델의 성능 평가를 위해서 비선형 공정인 가스로 공정과 하수처리 공정에 대하여 컴퓨터 시뮬레이션을 수행하였다. 각 공정 시스템에 대한 온라인 모델링에서 PLC를 사용하여 보다 안정된 인터페이스를 구축하였고 적응 FNN 구조에 의한 퍼지모델에 의한 감시 및 제어가 보다 정확하고 유용함을 보였다. 또한, 사용자 인터페이스 및 GUI 환경의 모델링 화면을 구축함으로써 실시간으로 보다 효율적인 모델링 수행을 할 수 있었다. 본 연구에서 사용한 방법을 이용하여 환경 시스템으로서 하수처리 공정, 폐수처리 공정 및 쓰레기 소각로 등에 응용할 수 있을 것으로 기대된다.

**감사의 글**

이 논문은 1998년 한국학술진흥재단의 학술연구비에 의하여 지원되었음.

**참 고 문 헌**

[1] T.Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control", *IEEE Trans. Syst. Man, Cybern.*, Vol. SMC-15, No.1, pp.116-132, 1985.

[2] M. Sugeno and G. T. Gang, "Structure Identification of Fuzzy Model", *Fuzzy Sets Syst.*, Vo 28, pp. 15-33, 1988.

[3] M. Sugeno and T. Takagi, "Successive Identification of a Fuzzy Model and Its Application to Predictionn of a Complex System", *Fuzzy Sets Syst.*, Vo42, pp.315-334, 1991.

[4] 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.

[5] J.-S. Roger Jang and C.T. Sun. "Functional equivalence between radial basis function networks and fuzzy inference systems". *IEEE Transactions on Neural Networks*, 4(1):156-159, January 1993.

[6] G.E.P. Box and F.M. Jenkins, *Time Series Analysis : Forecasting and Control*, 2nd ed. Holden-Day, 1976.

[7] L. Ljung, *System Identification: Theory for the User*. Englewood Cliffs, NJ: Prentice-Hall, 1987.

[8] J. R. Jang, C. T. Sun and E. Mizutani *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, Prentice-Hall,

1997.

[9] 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 Syst.*, 1999(To appear).

[10] Sung Kwun Oh, "Fuzzy Identification by Means of an Auto-tuning Algorithm and a Weighted Performance Index", *Journal of Fuzzy Logic and Intelligent Systems*, Vol. 8, No. 6, pp.106-118, 1998.

[11] 박병준, 오성권, 안태권, 김현기 "유전자 알고리즘과 하중값을 이용한 퍼지시스템의 최적화", *대한전기학회 논문지*, 제48권, 제6호, pp.789-799, 1999.

[12] 남의석, 박종진, 오성권, 김현기, 우광방 "온라인 퍼지 모델링에 관한 연구", '94한국자동제어학술회의 논문집, pp.1223-1228, 1994년 10월.

[13] 오성권, "퍼지모델 및 제어이론과 프로그램", 기다리출판사, 1999년 3월.


**저 자 소 개**

**오 성 권 (吳 聖 權)**

전기학회논문지 제48권 제6호 참조  
Tel : 0653-850-6342  
E-mail : ohsk@wonmms.wonkwang.ac.kr

**박 병 준 (朴 炳 俊)**

전기학회논문지 제48권 제6호 참조  
Tel : 0653-850-6342  
E-mail : lcap@autosys.wonkwang.ac.kr



**박 춘 성 (朴 春 成)**

1971년 9월 2일 생. 1998년 원광대 제어계측공학과 졸업. 1999년 동 대학교 대학원 제어계측공학과 졸업(석사). 1999년~현재 한국 원자력연구소 인턴연구원. 주관심분야는 공장자동화, 퍼지이론 및 신경회로망 응용, 패턴인식 등.