

퍼지-뉴럴네트워크 구조에 의한 비선형 공정시스템의 지능형 모델링*

Intelligence Modeling of Nonlinear Process System Using Fuzzy Neural Networks-based Structure

오 성 권*, 노 석 범*, 남 궁 문**

Sung-Kwun Oh*, Suck-Bum Rho*, Gung-Moon Nam**

*이 논문은 1994년도 한국학술진흥재단의 공모과제 연구비에 의하여 연구되었음

요 약

본 논문에서는 복잡한 비선형 시스템의 모델링을 위해 퍼지-뉴럴 네트워크(FNNs)를 사용한 최적 동정 방법이 제안 된다. 제안된 퍼지-뉴럴 모델링은 공정시스템의 입출력 데이터를 이용하여 기존의 최적이론, 언어적 퍼지구현규칙, 뉴럴네트워크 등의 지능형 이론을 도입하여 시스템의 구조와 파라미터 동정을 구현한다. 이 모델링의 추론형태는 간략추론이 사용된다. 최적 모델을 얻기위해, 퍼지-뉴럴 네트워크의 학습률과 모멘텀 계수가 본논문에서 제안한 개선된 컴플렉스 법과 수정된 학습알고리즘을 이용하여 자동동조 된다. 이 알고리즘의 비선형 공정으로의 응용을 위하여, 교통 경로 선택 데이터 및 하수처리시스템의 활성오니 공정 데이터가 제안한 모델링의 성능을 평가하기 위해 사용된다. 제안된 방법이 기존의 다른 논문과 비교하여 더 높은 정확도를 가진 지능형 모델을 생성함을 보인다.

ABSTRACT

In this paper, an optimal idenification method using fuzzy-neural networks is proposed for modeling of nonlinear complex systems. The proposed fuzzy-neural modeling implements system structure and parameter identification using the intelligent schemes together with optimization theory, linguistic fuzzy implication rules, and neural networks(NNs) from input and output data of processes. Inference type for this fuzzy-neural modeling is presented as simplified inference. To obtain optimal model, the learning rates and momentum coefficients of fuzzy-neural networks(FNNs) are tuned automatically using improved modified complex method and modified learning algorithm. For the purpose of its application to nonlinear processes, data for route choice of traffic problems and those for activated sludge process of sewage treatment system are used for the purpose of evaluating the performance of the proposed fuzzy-neural network modeling. The results show that the proposed method can produce the intelligence model with higher accuracy than other works achieved previously.

*원광대학교 공과대학 제어계측공학과 조교수

*원광대학교 공과대학 제어계측공학과 석사과정

**원광대학교 공과대학 토목환경공학과 조교수

I. 서 론

비선형적이고 다변수인 시스템을 대상으로 한 퍼지 제어기와 퍼지 모델링 기법의 유용성은 이미 알려진 사실이며 이들은 퍼지 추론 시스템에 기초하고 있다. 퍼지 추론 시스템은 크게 퍼지 규칙과 추론 엔진으로 구성되어 있다. 퍼지 제어기나 퍼지 모델의 성능은 퍼지 규칙의 구성 방법에 의존하며 보다 좋은 성능을 위해서는 퍼지 규칙의 동정(identification)이 필연적이다. Sugeno[1]는 다차원 추론 방식에 기초한 동정 기법을 제안했다. 이 방법은 퍼지 규칙의 수를 최소로 하면서도 상당히 정확성을 보임이 입증되었으나 입·출력 변수의 증가에 따른 계산량의 급증이라는 어려움을 야기한다. 이를 해결하기 위해 최근에는 신경 회로망의 학습 기능을 이용하여 퍼지 규칙을 얻고자 하는 방향으로 연구가 진행되고 있다. 이는 퍼지 추론에 의한 시스템과 신경회로망 시스템이 가지는 장점을 결합함으로써 보다 나은 시스템 성능 특성을 얻는 퍼지-뉴럴 융합화 연구로서 양 이론의 유사성과 상호 보완 관계를 이용한다. 이를 양 이론의 유사성은 퍼지추론의 최소-최대 연산(Min-Max operation)이 신경회로망의 곱셈-덧셈 연산(Product-Sum operation)에 해당되며, 또한 부분적인 특성 함수인 멤버쉽 함수, 시그모이드 함수에 의해 시스템 전체의 복잡한 비선형성을 표현한다는 점이며, 상호 보완 관계란 퍼지 추론이 논리구조를 취급하는 반면에, 신경회로망은 학습기능을 가지는 점이다[2]. 이들 융합화에 관한 연구가 여러가지 각도에서 다양하게 제시되고 있는데 Takagi, Hayashi 등[3]은 신경회로망으로 구동되는 퍼지 추론을 제안하였으나 입·출력 수가 적은 경우는 그 효과가 미미하고, 전반부가 신경회로망으로 특성화된 함수로 구성되어 기존의 퍼지 추론보다 시스템표현에 있어서 정성적으로 이해하기가 힘들다. Horikawa[4]는 퍼지-뉴렐 네트워크에 의한 합성방법과 동정에 관한 연구를 하였는데, 이 경우에는 전반부 멤버쉽 함수인 시그모이드 형태의 멤버쉽 함수의 초기치 설정이 어렵고, 최적 성능으로의 수렴특성이 나쁘다. 그리고 한정된 비선형 데이터[5]가 아닌 입·출력 데이터가 많은 경우에는 학습에 의한 성능 개선시 시그모이드 함수는 좋은 특성을 나타내지 못한다. Imasaki[6]는 퍼지 규칙이 전반부 네트워크, 추론 네트워크, 후반부 네트워크로 구성된 구조화된 신경회로망을 제안하였으나, 추론 네트워크의 추가, 추가 학습에 의해 오랜 학습시간과 튜닝의 난점이 있다. 또한 입·출력수 증가에 따른 네트워크 구성시 경험적인 방법이 많이 요구되며, 시스템 표현에 있어서도 정성적으로 이해하기가 힘들다. Nomura[7]는 엘타규칙에 의한 퍼지 추론의 자동동조 방법을 제안하였는데 학습에 의한 튜닝으로 각 규칙마다 멤버쉽 함수가 변형되므로 퍼지규칙 수가 증가하며, 입·출력수가 증가함에 따라 더 많은 퍼지규칙 수가 요구된다. Yamakawa[8]등은 보수적(complementary) 소속함수를 가지는 퍼지 규칙에 의해 비선형 특성을 나타내는 퍼지-뉴런 모델에 의한 학습방법을 제안하였으나 멤버쉽함수의 퍼지입력공간 선택 및 멤버쉽 함수치 선택의 어려움이 있다.

본 논문에서는 간략추론의 퍼지 추론방식과 뉴럴 네트워크의 융합에 의한 퍼지-뉴렐 네트워크 구조에 의해 퍼지규칙을 자동 추출한다. 최적 시스템모델을 얻기위해, 퍼지-뉴렐 네트워크의 학습률과 모멘텀 계수가 본 논문에서 제안한 개선된 캠플렉스법과 수정된 학습알고리즘을 이용하여 자동동조되며, 또한 개선된 캠플렉스법에 의해 퍼지 멤버쉽 함수치가 자동동조된다. 교통 경로 선택 데이터[6, 7] 및 하수처리시스템의 활성오니 공정 데이터[8]가 제안한 모델링의 성능을 평가하기 위해 사용된다. 제안된 방법이 기존의 다른 논문과 비교하여 더 높은 정확도를 가진 지능형 모델을 생성함을 동정오차면에서 비교하였다.

II. 퍼지-뉴렐네트워크의 구조와 학습 알고리즘

1) 퍼지-뉴렐네트워크의 구조

퍼지-뉴렐네트워크의 구조는 퍼지 추론과 뉴렐 네트워크의 오차 역전달(Error back-propagation) 알고리즘을 합성한 것으로 보수적(Complementary) 멤버쉽함수(Membership function)를 가지는 퍼지규칙에 의해 비선형 특성을 나타낸다. 이 퍼지-뉴렐 네트워크의 구조는 그림 1과 같다. 각 퍼지-뉴런의 특성은 비선형 함수인 f_i 에 의해 나타내어지고 함수 f_i 내에 시그모이드 함수는 포함되지 않는다. 최종 출력은 각 퍼지-뉴런 출력의 대수적 합에 의해 얻어진다. 그러므로 퍼지-뉴런의 출력은 다음 식 (1)에 의해 나타내어질 수 있다.

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

여기서, m =퍼지-뉴런의 수

입력공간 x_i 는 몇개의 멤버쉽함수에 의해 나뉘어지는데 이것은 그림 2와 같이 변수 x_i 의 최대값, x_{\max} 와 최소값, x_{\min} 사이의 범위 내에서 멤버쉽함수 $\mu_{i1}, \mu_{i2}, \dots, \mu_{ij}, \dots, \mu_{in}$ 에 의해 특정지워진다. 여기서 $1, 2, \dots, j, \dots, n$ 은 멤버쉽함수의 갯수를 나타낸다. 멤버쉽함수 뒤에는 하중계수 $w_{i1}, w_{i2}, \dots, w_{ij}, \dots, w_{in}$ 이 있고, 멤버쉽함수에 대한 입력변수의 적합도와 하중계수가 곱해져서 i 번째 퍼지-뉴런의 출력이 된다. 즉, f_i 로 표시된 i 번째 퍼지-뉴런은 일단의 퍼지규칙을 이루고 있으며 그 규칙은 식 (2)와 같다.

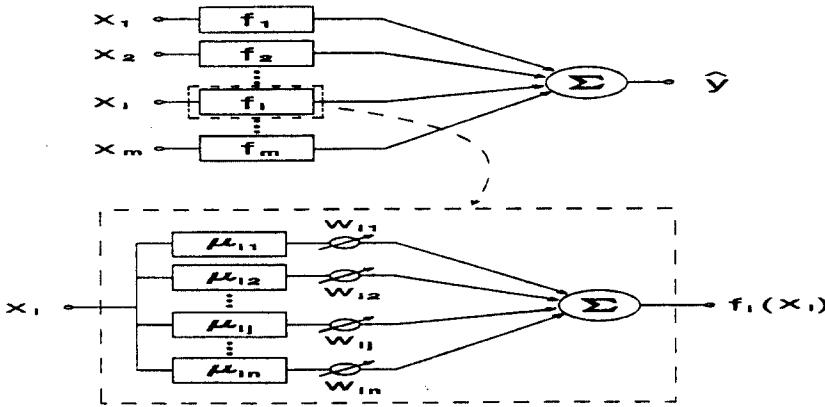


그림 1. 퍼지-뉴럴네트워크의 구조
Fig. 1 Construction of fuzzy-neural network

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

식 (2)에서 R^j 는 j 번째 퍼지규칙을 나타내며, 전반부의 A_{ij} 는 퍼지변수이고 멤버쉽함수 μ_{ij} 로 표현된다. 후반부의 w_{ij} 는 상수이며 하중계수가 이에 해당된다. x_i 에서 $f_i(x_i)$ 로의 사상(mapping)은 퍼지 추론과 비퍼지화에 의해 이루어진다. 여기서 사용되는 퍼지추론은 식 (2)의 후반부가 상수인 경우이다. 전반부의 멤버쉽함수는 삼각형이고 이웃하는 멤버쉽함수와는 보수적(complementary)인 관계를 가진다. 입력변수 x_i 는 동시에 두개의 멤버쉽함수에만 관계되고 $k, k+1$ 로 나타내어지는 두개의 이웃하는 멤버쉽함수에 대한 입력변수의 적합도의 합은 언제나 1이 된다. 즉, $\mu_{ik}(x_i) + \mu_{ik+1}(x_i) = 1$. 그러므로 무게중심법(Center of Gravity method)에 의한 비퍼지화에서 나누는 부분이 필요없게 되고 퍼지-뉴런의 출력은 다음의 식(3)에 의해 간략하게 나타낼 수 있다.

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

하중계수 w_{ij} 는 뉴럴 네트워크에서 흔히 쓰이는 오차 역전달(Back Propagation) 알고리즘에 의한 학습과정을 통하여 수정된다. m개의 입력 데이터 쌍이 주어진 경우, 출력오차 평가지수를 다음 식 (4)와 같이 정의한다.

$$E_p = \frac{1}{2} * (y_p - \hat{y}_p)^2$$

$$E = \sum_{p=1}^m E_p \quad (4)$$

식 (4)에서 y_p 는 p번째 출력 데이터(교사신호)이고, \hat{y}_p 는 폐지-뉴런 네트워크의 출력 값이다. 이때 오차 E_p 를 최소화하기 위한 연결하중계수 w_{ij} 는 최급강하법(Gradient Descent Rule)에 의해 식 (5)와 같이 구해질 수 있다.

$$\Delta w_{ij} = -\eta \cdot \left(\frac{-\partial E_p}{\partial w_{ij}} \right) \quad (5)$$

여기서, η 는 학습률이다.

식 (5)에서 (·)는 사슬법칙(chain rule)에 의해 다음 식 (6)과 같이 변형될수 있다.

$$-\frac{\partial E_p}{\partial w_{ij}} = -\frac{\partial E_p}{\partial \hat{y}_p} \cdot \frac{\partial \hat{y}_p}{\partial f_i(x_i)} \cdot \frac{\partial f_i(x_i)}{\partial w_{ij}} \quad (6)$$

식 (6)에서 우측 식의 각항은 다음 식 (7)~(9)과 같이 유도된다.

$$\frac{\partial E_p}{\partial \hat{y}_p} = y_p - \hat{y}_p \quad (7)$$

$$\frac{\partial \hat{y}_p}{\partial f_i(x_i)} = 1 \quad (8)$$

$$\frac{\partial f_i(x_i)}{\partial w_{ij}} = \mu_{ij}(x_i) \quad (9)$$

그러므로 변화량, Δw_{ij} 는 식 (6)~(9)로부터 식 (10)과 같이 된다.

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

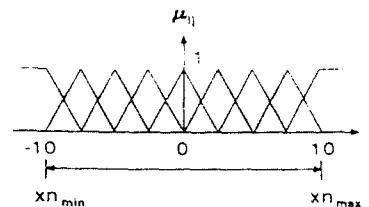
이러한 폐지-뉴럴 모델은 비선형 시스템을 모델링 하는데 있어서 성능(Performance)과 학습시간 측면에 있어서 기존의 뉴럴 네트워크보다 훨씬 우수하다.

그리고 그림 2의 멤버쉽함수에서 입력 변수의 분포영역을 최소, -10과 최대, 10정도의 적당한 값으로 사상시킨다. 먼저 식 (11)과 같이 입력변수 x_i 는 [-10, 10] 사이의 범위로 사상시킬 수 있다. 사상과정에서 변수 x_i 의 최대값, x_{\max} 와 최소값, x_{\min} 에 각각 사상계수 mshmax와 mshmin을 곱하면 식 (11)은 식 (12)와 같이 변형된다.

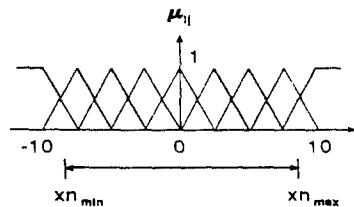
$$xn_i = \frac{x_i - (x_{\min} + x_{\max})/2}{(x_{\max} - x_{\min})/2} * 10 \quad (11)$$

$$xn_i = \frac{x_i - (x_{\max} \cdot mshmax + x_{\min} \cdot mshmin)/2}{(x_{\max} \cdot mshmax - x_{\min} \cdot mshmin)/2} * 10 \quad (12)$$

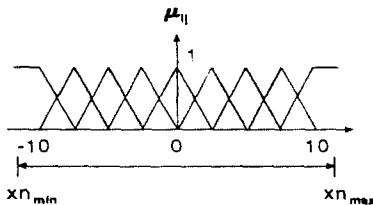
이와 같은 과정을 통하여 적절한 xn_{\max} 와 xn_{\min} 값을 설정함으로써 입력변수의 분포영역을 임의로 조절함으로서 식 (11)~(14)의 입력변수의 사상을 통해 모델성능을 개선시킬 수 있다.



(a) mshmax = 1, mshmin = 1인 경우



(b) mshmax < 1, mshmin < 1인 경우



(c) mshmax > 1, mshmin > 1인 경우

그림 2. 퍼지-뉴럴네트워크의 멤버십 함수와 입력 변수의 사상

Fig. 2 Membership function of fuzzy-neural network and mapping input variables

$$\begin{cases} xn_{\max} > 10 & (\text{if } mshmax > 1) \\ xn_{\max} = 10 & (\text{if } mshmax = 1) \\ xn_{\max} < 10 & (\text{if } mshmax < 1) \end{cases} \quad (13)$$

$$\begin{cases} xn_{\min} < -10 & (\text{if } mshmin > 1) \\ xn_{\min} = -10 & (\text{if } mshmin = 1) \\ xn_{\min} > -10 & (\text{if } mshmin < 1) \end{cases} \quad (14)$$

2) 수정된 학습 알고리즘

학습이 진행되는 동안, 큰 학습률은 무게 하중 벡터를 global minimum 영역에 빠르게 도달하도록 만들지만 그 영역에서 진동하게 된다. 작은 학습률은 진동을 일으키지는 않지만 수렴 속도가 느린 단점을 가지고 있다. 이런 단점을 보완하기 위해 학습이 진행되는 중간에 식(15)와 같은 오차의 변화율이 주어진 값보다 작으면 일정한 비율로 학습률을 감소시킨다.

$$\frac{|E(w_{ij}(t+1)) - E(w_{ij}(t))|}{E(w_{ij}(t))} \quad (15)$$

III. 동조 알고리즘

퍼지-뉴럴 네트워크의 학습률 η 과 모멘텀계수 α 는 개선된 컴플렉스법을 이용하여 자동동조함으로써 최적의 학습성능을 얻어 모델의 성능을 개선한다. 모델링 방법의 파라미터 동정에서 학습률과 모멘텀 계수의 최적 값을 구하기 위해 컴플렉스 개념에 기존의 최적화 이론인 심플렉스 개념을 확장, 융합함으로써 다음과 같은 수정된 컴플렉스법을 제안한다. 이 수정된 컴플렉스법은 목적함수를 최소화시키는 방법인 심플렉스법에 제약조건이 주어지는 경우로 식 (16)의 형태의 수식을 풀기위한 방법이다.

$$\begin{aligned} & \text{Minimize } f(x) \\ & \text{Subject to } g_j(x) \leq 0, \quad j = 1, 2, \dots, m \\ & \quad x_i^l \leq x_i \leq x_i^u \quad i = 1, 2, \dots, n \end{aligned} \tag{16}$$

여기서, 학습률 η 과 모멘텀계수 α 는 수정된 컴플렉스법을 이용하여 자동동조함으로써 퍼지-뉴렐 네트워크는 최적의 학습을 수행한다.

여기서, l은 하한(lower bound), u는 상한(upper bound)을 나타낸다.

단계 1: 모든 제약조건을 만족시키는 K개의 해집합($X_1, X_2, \dots, X_k, k \geq n$)을 대략 $K = 2n$ 개를 선정한다. (n은 초기 정점의 수)

단계 2: 심플렉스의 개념에서 투영(Reflection), 확장(Expansion), 축소(Contraction)의 기본 개념을 이용하여 α, β, γ 의 초기값을 설정 한다. 즉,

- i) 투영(Reflection) : $x_r = x_o + \alpha(x_o - x_h)$
- ii) 확장(Expansion) : $x_e = x_o + \gamma(x_r - x_o)$
- iii) 축소(Contraction) : $x_c = x_o + \beta(x_h - x_o)$

단계 3: 초기 평가치로써 목적함수 최대, 최소값($f(X_h), f(X_l)$)을 구하고, 주어진 모든 조합(X_k)의 중심값을 구한다. 투영방법을 이용하여 X_r 을 구한다.

$$x_r = x_o + \alpha(x_o - x_h) \tag{17}$$

여기서 $x_h = \max (x_i), i = 1, \dots, k$

$$x_o = \frac{1}{n-1} \sum_{\substack{i=1 \\ i \neq h}}^n f(x_i)$$

$$\alpha = \frac{x_r \text{과 } x_o \text{ 사이의 거리}}{x_h \text{과 } x_o \text{ 사이의 거리}}$$

여기서 X_r 의 제약조건 및 문제에서 주어진 그외의 조건을 만족치 않는 경우는 $X_e = (X_o + X_r)/2$ 를 구하여 대체하고 반복하여 X_e 의 주어진 제약조건을 조사한다. 확장방법에 의해 구한 X_e 의 평가치 $f(X_e)$ 를 구한 다음, $f(X_r)$ 및 $f(X_e)$ 를 초기 최소평가치와 비교하여 초기 최대 평가치를 가지는 X_h 에 치환한다.

단계 4: 투영 방법(reflection)에 의해 구한 X_r 의 평가치 $f(x_r)$ 를 초기 최소 평가치와 비교하여 최소값보다 적을 경우 확장방법(expansion)을 이용하여 X_e 를 구한다.

$$x_e = \gamma x_r + (1-\gamma) x_o \tag{18}$$

$$\gamma = \frac{x_e \text{과 } x_o \text{ 사이의 거리}}{x_r \text{과 } x_o \text{ 사이의 거리}}$$

여기서 X_e 의 제약조건 및 문제에서 주어진 그외의 조건을 만족치 않는 경우는 $X_e = (X_o + X_e)/2$ 를 구하여 대체하고 반복하여 X_e 의 주어진 제약조건을 조사한다. 확장방법에 의해 구한 X_e 의 평가치 $f(X_e)$ 를 구한다음, $f(X_r)$ 및 $f(X_c)$ 를 초기 최소 평가치와 비교하여 초기 최대 평가치를 가지는 X_h 에 치환한다.

단계 5: 투영방법에 의해 구한 평가치 $f(X_r)$ 이 평가치 최대값을 제외한 모든 값과 비교하여 큰 경우에 축소방법을 이용하여 X_c 를 구한다.

$$x_c = \beta x_h + (1 - \beta) x_o \quad (19)$$

$$\beta = \frac{x_c \text{과 } x_o \text{ 사이의 거리}}{x_h \text{과 } x_o \text{ 사이의 거리}}$$

여기서 X_c 의 제약조건 및 문제에서 주어진 그 외의 조건을 만족치 않는 경우는 $X_c = (X_o + X_c)/2$ 를 구하여 대체하고, 반복하여 X_c 의 주어진 제약조건을 조사한다. 축소방법에 의해 구한 X_c 의 평가치 $f(X_c)$ 를 구한다음, $f(X_c)$ 가 $f(X_h)$ 보다 적으면 X_h 는 X_c 로 대체되나 그렇지 않으면 $X_i = (X_k + X_l)/2$ 로 대체된다.

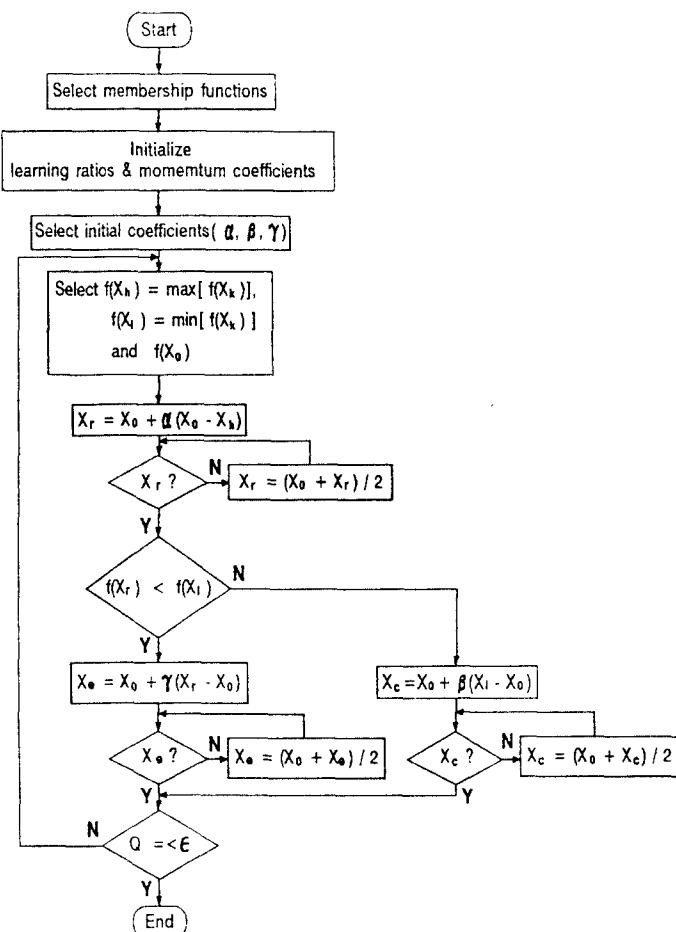


그림 3. 제안된 자동적 조율 알고리즘의 흐름도

Fig. 3 The flowchart of proposed auto-tuning algorithm

단계 6: 수정된 컴플렉스의 수렴조건은

- 1) X_1, \dots, X_k 사이의 임의의 두 정점사이의 거리가 지정된 미소값 이하로 된 경우와
- 2) 목적함수(평가치)의 표준편차가 지정된 미소값보다 적은 경우이다. 이 경우의 표준편차는 식 (20)과 같다.

$$Q = \left\{ \sum_{i=1}^{n+1} \frac{[f(x_i) - f(x_o)]^2}{n+1} \right\}^{1/2} \leq \epsilon \quad (20)$$

이들 수렴조건을 검정한 후 만족치 않는 경우는 단계 3으로 복귀된다.
이들 각 단계에 의한 자동동조알고리즘의 흐름도는 그림 3과 같다.

IV. 시뮬레이션 및 결과고찰

1) 교통 경로 선택

도로망에 대한 교통량배분은 종래부터 교통계획 및 공학에 있어서 실무자 및 연구자의 관심을 불러 일으키고 있는 분야중의 하나이다. 이에 대한 연구는 1950년대부터 산업경제의 발전에 따라 미국, 유럽, 일본 등 선진국을 중심으로 사람 및 물동량 수송을 위해 수많은 고속도로가 계획 설계 건설되게 되어, 경쟁관계에 있는 도로간 즉 2개 경로 또는 다수 경로간에 어떻게 적절하게 교통량배분하여 원활한 수송시스템을 구축할 것인가가 교통계획에 있어 큰 문제로 대두 되어 일반도로에서 고속도로로, 또는 고속도로에서 일반도로로의 교통량전환 모델에 대한 연구가 진행되게 되었다. 이것이 대한 기본개념은 all or nothing법이 이용되고 있는데 이것은 임의의 기종점(OD) 교통량은 가장 짧은 경로로 흐른다는 것을 배경으로하고 있다.

또 하나의 다른 방법으로서 전환률곡선에 의한 방법이 제안되었다. 일반적으로 도로교통이용자의 경로선택에 관해서는 경로선택에 영향을 주는 요인을 검토할 필요가 있다. 그 요인으로서 소요시간, 통행요금, 편이성, 연도경관, 쾌적성, 안전성, 로면형상 등을 생각할 수 있다. 이 전환률에 의한 방법은 고속도로의 전환률을 이러한 요인 함수로서 경험적인 데이터의 해석에 의해 구한다. 그 대표적인 것에는 시간비를 이용한 미국연방도로국의 전환률곡선, 소요시간차를 이용한 캘리포니아 전환률곡선 등이 있다.

교통량배분 이론으로서 최초에 제안한 것은 J. G. Wardrop[9]의 교통균형원칙이다. 이 교통균형원칙이 오늘날의 교통배분이론의 기초가 되었다. 그후, 교통배분에 관한 연구는 佐佐木[10]의 수송계획법에 의한 접근을 시작으로 星野[11]의 연립방정식에 의한 추계법이 제안되었고, 등시간 원칙[11]을 도입한 정식화 방법도 제안되었다. 1960년대에 이르러서는 전자계산기의 발달에 따라 실제의 도로망을 대상으로한 simulation 방법에 의해 도로망의 교통류를 재현하는 수법이 제안되기도 하였다. 그후 분할배분법[12]에 의해 최단경로만이 아닌 다경로 교통배분법이 개발되었다. 이러한 여러 방법은 Wardrop의 등시간 원칙에 바탕한 Network의 균형 흐름을 나타내는 것이다.

1970년부터는 simulation이나 분할배분법 등과 같은 근사적인 해법에 의해 수리계획 최적화 문제로의 접근이 여러 각도로 이루어졌다.

최근에는 교통균형원칙의 발전이 거듭되어 동적인 교통량배분이 제안되게 되었고, 교통량배분이론은 변분부등식 문제 또는 상보성문제로서 정식화되게 되었다.

Wardrop의 등시간원칙에서는 교통이용자의 선택행동에 대해서 다음과 같은 전제조건을 설정하고 있다. 1) 모든 이용자는 동일의 기준을 가지고 독립적으로 행동한다. 2) 교통이용자는 완전한 정보를 파악하고 있다. 3) 모든 이용자는 항상 소요시간을 최소로하는 경로를 선택한다.

그러나 기존의 교통시스템에 있어서는 교통이용자가 완전한 교통정보를 입수하는 경우나 항상 기종점(OD) 간의 확정적인 최단경로를 선택하는 경우가 현실의 현상에 따르는 지에 대한 의문이 많이 제기되고 있다.

이점에 대해서는 그후 Wardrop의 교통균형원칙의 확장으로서 특히 1980년대에 수많은 연구자들이 이 문제에 대해서 연구를 하여 교통정보의 불완전성과 경로의 평가함수값의 불확정성을 고려해서 경로의 선택을 확률적으

로 사용하는 이른바 확률적인 교통균형배분법이 개발되었다. 이 수법은 경로의 평가함수를 random원리에 바탕하여 각 OD쌍 간의 교통수요량을 각 경로의 경로선택 확률을 이용해서 배분하는 것이다.

그러나 종래의 확정적인 교통균형배분법이나 확률교통배분법 모두는 도로이용자의 교통경로선택의 현실적인 의사결정에 바탕한 행동을 기술해야 한다는 점에서 검토해야 할 점이 남아있다.

이러한 배경으로부터 본 연구에서는 현실의 교통시스템에 있어서의 교통이용자의 경로선택 행동시 존재하는 선택행동 지식과 그것에 존재하는 퍼지성에 근거하여 교통흐름 상에서의 경로선택 행동모델화를 시도하였다.

본 연구의 중요한 관점은 불완전정보화에서의 도로이용자의 경로선택 행동을 도로이용자의 경로선택 의사결정 규칙과 의사결정 요인속에 포함된 퍼지성을 고려하여 모델화를 시도하는 것이다. 즉, 도로이용자는 경로의 실제의 소요시간 및 도로에 대한 각종 정보 등을 정확히 알지못하고 과거의 주행경험 또는 습관 등을 바탕으로 경로선택행동을 한다는 것을 가정으로 한다.

이러한 접근은 기존의 통계적인 데이터처리를 기본으로 하는 함수 모델화과는 구조적 또는 기능적으로 다른 관점으로의 시도이다. 이를 위해 본 연구에서는 뉴럴네트워크의 결합형 모델화를 시도하여 구축된 모델에 대한 평가를 시도하였다. 그림 4는 본 연구에서 실행 대상으로 한 경쟁관계에 있는 2개의 경로를 나타낸 것이다. 경로선택의 모델화는 교통수단 및 교통로의 상이, 그리고 경쟁 경로수 등에 의해 다양하게 전개되어진다. 본 연구의 예제에서는 위에서 언급한 경로선택에 대한 여러가지 요인 중에서 우선 [교통비용]의 효용효과를 고려하는 것으로 하였다. 그리하여 경로선택의 전형적인 모델인 Logit Model[13]과 동정된 퍼지뉴럴 모델에 의한 선택률을 비교하여 동정된 모델의 정도를 평가하였다.

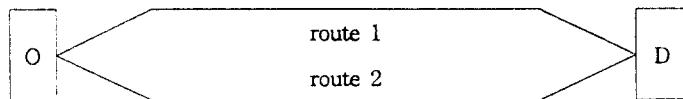


그림 4. 경로선택의 간단한 예

Fig. 4 Simple Example of Route Choice

이러한 전체를 바탕으로 가장 간단한 교통경로/기관선택문제를 생각하는 것으로 한다. 교통경로선택모델의 전형적인 예로는 2항형 logit model을 생각할 수가 있다. 따라서, 여기서는 대상을 경로운전자(이용자)로 생각했고 개인수준의 교통행동 표현이 어떻게 모델화 되는가가 주목대상이다[7]. 평가지수는 $PI = \sum_{i=1}^n |y - \hat{y}_p|$ 를 사용한다. 여기서 입력 T1과 T2는 각각 route1과 route2에 대한 교통통행 비용이다. 출력 P_{1n} 은 route 1에 대한 선택률

표 1. BL모델에 대한 샘플 데이터
Table 1. Example Data For Logit Model

No	route	T1	T2	No	route	T1	T2
1	2	52.9	4.4	12	1	18.5	84.0
2	2	4.1	28.5	13	1	82.0	38.0
3	1	4.1	86.9	14	2	8.6	1.6
4	2	56.2	31.6	15	1	22.5	74.1
5	2	51.8	20.2	16	1	51.4	83.8
6	1	0.2	91.2	17	2	81.0	19.2
7	1	27.6	79.7	18	1	51.0	85.0
8	2	89.9	2.2	19	1	62.2	90.1
9	2	41.5	24.5	20	2	95.1	22.2
10	2	95.0	43.5	21	1	41.6	91.5
11	2	99.1	8.4				

이다. 표 1은 BL모델을 추계용 Sample의 예를 표시하는 것이다[14]. 기관선택을 추계의 예제로서 표시되었지만 다수의 요인을 가진 경로간의 선택을 판정해도 일반성은 잃지 않는다. 퍼지-뉴럴네트워크내의 간략추론의 전반부 멤버쉽함수 13개를 사용하여 동정하였으며, 학습율, 모멘텀계수 파라미터를 동정하기 위한 개선된 캠플렉스법의 투영, 확장, 축소방법의 파라미터 초기값은 $\alpha = 1.0$, $\beta = 0.5$, $\gamma = 2.0$ 을 사용한다. 표 2는 기존의 모델링과 본 논문의 퍼지-뉴럴네트워크 모델링과의 동정오차 및 적중률면에서 그 성능을 비교하여 제안된 방법이 우수한 특성을 나타냄을 보였다. 실데이터와 모델 5의 출력데이타의 비교는 그림 5와 같다.

표 2. 기존의 모델링 방법과 동정오차 비교

Table 2. Comparison of identification error with conventional fuzzy modeling methods

Type	동정오차	적중률
1) BL(Binary Logit)모델[14]	5.452	90.47
2) PS(Production System)모델[6]	2.0	85.7
3) 뉴렐네트워크 모델링[6]	0.497	95.2
4) 퍼지-뉴렐네트워크 모델링[6]	1.178	90.47
5) 퍼지-뉴렐네트워크 모델링(our model)	0.000493	100.

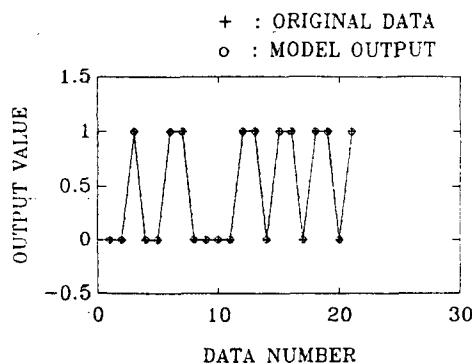


그림 5. 실데이터와 모델 5의 출력데이타의 비교

Fig. 5 Comparison of original data and output data for model 5

2) 하수처리 시스템의 활성오니공정

하수처리에는 활성오니공정이 일반적으로 사용되고 있다. 활성오니공정은 침사지, 최초침전지, 폭기조 및 최종침전지를 포함한다. 침사지와 최초침전지에서는 하수중에 포함된 혼탁물질의 입자가 중력에 의해 침강된다. 폭기조에서는 수시간 연속적으로 하수중에 공기가 흡입된다. 유기물 재거의 중심을 이루는 미생물은 폭기조의 과정에서 자연발생하는 다종류의 미생물 군이고 이를 활성오니라 한다. 웅집한 미생물의 덩어리를 플록(floc)이라 한다. 활성오니는 폭기조내 공기로부터 용해한 산소에 의해 유기물을 생물화학적으로 산화해서 증식하고 대사과정에서 유기물을 물과 탄산가스로 분해한다. 최종침전지에서 플록(floc)은 침강 재거되고 맑은 물이 3차처리 공정으로 유입된다. 한편 최종 침전지에서 침강한 미생물은 폭기조 입구에서 재순환 되어 다시 유기물 재거에 사용된다.

활성오니공정은 폭기조 및 최종침전지를 하나의 단일 모델로 선정하였다. 실제 최초침전지로 유입되는 생물학적 산소요구량(Biological Oxygen Demand : BOD) 및 유입수의 부유물(Suspended Solid : SS) 농도를 측정하고, 최종침전지에서 유출되는 생물학적 산소요구량(Effluent Biological Oxygen Demand : EBOD) 및 부유물 농

도(Effluent Suspended Solid : ESS)가 주요 측정 대상이 된다. 활성오니공정의 용존산소 설정치(Dissolved Oxygen Set-Point : DOSP) 및 반송율 설정치(Recycle Sludge Ratio Set-Point : RRSP)는 유입수의 생물학적 산소요구량 및 부유물 농도에 따라 유출수의 생물학적 산소요구량(EBOD), 부유물(ESS) 농도가 영향을 받으므로 조작자가 이 유출수의 농도를 소정치 이하로 낮추기 위해 사용되는 데이터이다. 유출수의 생물학적 산소요구량(EBOD) 및 부유물(ESS) 농도는 측정된 데이터의 혼합액 부유물(Mixed Liquid Suspended Solid : MLSS) 농도, 잉여오니흐름율(Waste Sludge Ratio : WSR), 반송율 설정치(RRSP), 용존산소 설정치(DOSP)에 의존하며 BOD, SS 농도는 서로 일정한 상관관계를 가지고 있다. 하수처리 시스템의 개요도는 그림 6과 같다.

본 논문에서는 수도권 하수처리장 중의 하나를 모델로 선정하여 이 처리장의 1년치 수질 데이터를 추출하여 활성오니공정을 제안된 퍼지-뉴럴네트워크로 모델링하였다. 활성오니공정 모델을 퍼지-뉴런을 통해 모델링하기 위해 각 입력변수의 비선형 퍼지-뉴런에 포함된 멤버쉽함수의 갯수를 3, 5, 7, 13, 21로 설정하고 학습률과 모멘텀 계수를 동일하게 정하고 시뮬레이션을 행하였다. 각각에 의한 결과가 표 3에 보여지며, 오차의 수렴과정을 그림 7에 보였다. 이 결과를 통하여 멤버쉽함수를 많게 할수록 모델링 성능이 좋아지는 것을 볼 수 있다. 또한 이 활성오니공정의 동일한 입출력 데이터를 이용하여 기존의 방법에 의한 퍼지모델링[15]과 성능을 비교한다.

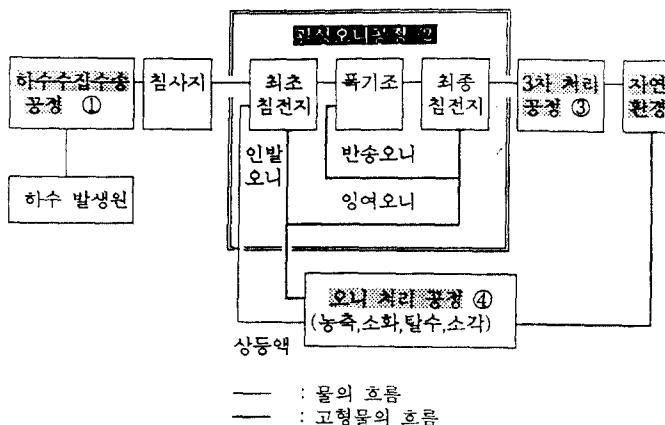


그림 6. 하수처리시스템의 개요도
Fig. 6 Configuration of sewage treatment system

입력으로 1) 혼합액 부유물(Mixed Liquid Suspended Solid : MLSS), 2) 잉여오니흐름율(Waste Sludge Ratio : WSR), 3) 반송율 설정치(Recycled Return sludge : RRSP), 4) 용존산소 설정치(Dissolved Oxygen Set Point : DOSP)을 사용하고, 출력으로 1) 부유물의 농도(Effluent Suspended Solids : ESS)를 사용한다.

성능지수로는 $PI = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2$ 를 사용한다. 표 3은 퍼지-뉴럴네트워크내의 간략 퍼지추론의 전반부 멤버쉽함수 갯수의 증가에 따른 각 모델 성능지수가 우수함을 알 수 있고, 이 모델의 오차수렴 과정은 그림 7과 같다.

표 5에서 보는 바와 같이 수정된 학습 알고리즘을 사용한 경우의 모델링 오차가 기존의 학습 알고리즘을 사용한 경우보다 적음으로 성능이 우수함을 알 수 있다.

표 3. 멤버쉽 갯수에 따른 활성오니 공정 모델의 성능 지수

Table 3. Performance index of model for A.S.P. in the number of membership function

멤버쉽 함수의 갯수	3	5	7	13	15
성능 지수	12.858117	10.760273	8.910335	2.503827	0.816277

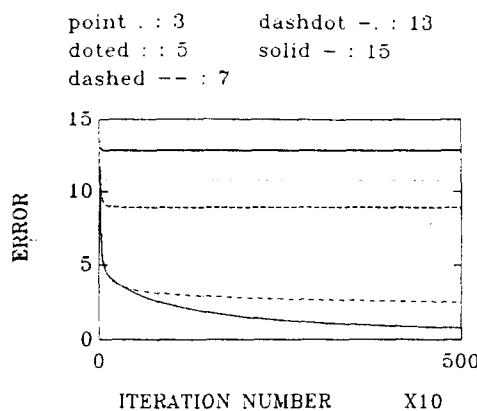


그림 7. 멤버쉽 함수의 갯수에 따른 각 모델의 오차 수렴과정 비교

Fig. 7 The comparison of error convergence procedure of each model according to the number of membership function

또한 사상 계수 mshmax와 mshmin 값은 초기치를 각각 1로 설정하였는데 각 멤버쉽 함수에 속하는 데이터의 갯수가 0이 되지 않도록 즉, 모든 멤버쉽 함수의 연결하중이 학습되도록 사상 계수의 값을 조정하여 모델의 성능을 높일 수 있다. 또한 멤버쉽 함수의 갯수에 따른 각 최적모델의 최종 사상계수의 값은 다르다는 것을 알 수 있다. 멤버쉽함수 3, 5, 7, 13개의 경우 표 4와 같은 최적 사상계수를 나타내고 15개인 경우 mshmax와 mshmin 값은 각각 1.0, 1.05의 최적 사상계수를 나타냈다. 표 5에서 보는 바와 같이 멤버쉽함수 13, 15개의 경우에 의한 성능지수 PI값은 1.104, 0.293으로서 초기치로 선정한 경우의 성능지수 2.166, 0.457보다 결과가 매우 향상된 것을 알 수 있다. 이와같이 개선된 컴플렉스법, 수정된 학습알고리즘 및 최적사상계수를 사용함으로써 기존의 퍼지-뉴럴모델보다 동정모델의 정확도를 개선할 수 있다. 그림 8은 기존 학습알고리즘 및 최적의 사상계수에 의한 수정된 학습알고리즘에 따른 오차의 수렴과정을 보인다. 그림 9는 멤버쉽함수 갯수 즉 3, 5, 7, 13, 15인 각 경우의 최적사상계수를 가지는 수정된 학습알고리즘에 의한 퍼지-뉴럴 모델출력과 실 데이터의 출력과의 비교를 나타낸 것으로 동정모델의 정확도를 알 수 있다.

표 4. 최적의 사상 계수

Table 4. Optimal mapping coefficients

입력 변수	mshmax	mshmin
MLSS	0.85	1.05
WSR	0.85	1.05
RRSP	0.85	1.05
DOSP	0.85	1.05

표 5. 수정된 학습 알고리즘과 기존 학습 알고리즘과의 성능 비교

Table 5. Comparison of identification error between conventional learning algorithm and modified one

멤버쉽 함수의 갯수	3	5	7	13	15
1) 기존의 학습알고리즘 사용시 성능지수	12.858117	10.760273	8.910334	2.503827	0.816277
2) 수정된 학습알고리즘 사용시 성능지수(초기사상계수이용시)	12.266345	10.259945	8.481753	2.1660427	0.457974
3) 수정된 학습알고리즘 사용시 성능지수(최적사상계수이용시)	12.113760	8.486619	7.064596	1.104633	0.293213

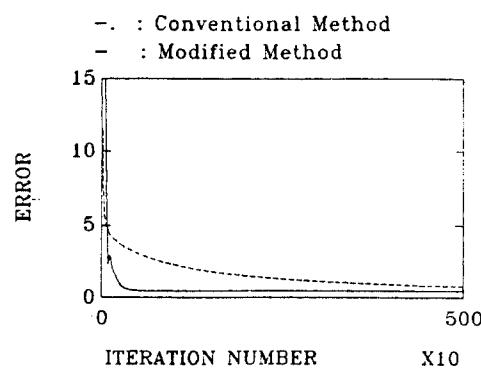


그림 8. 기존 및 수정된 학습 알고리즘에 따른 오차의 수렴과정 비교

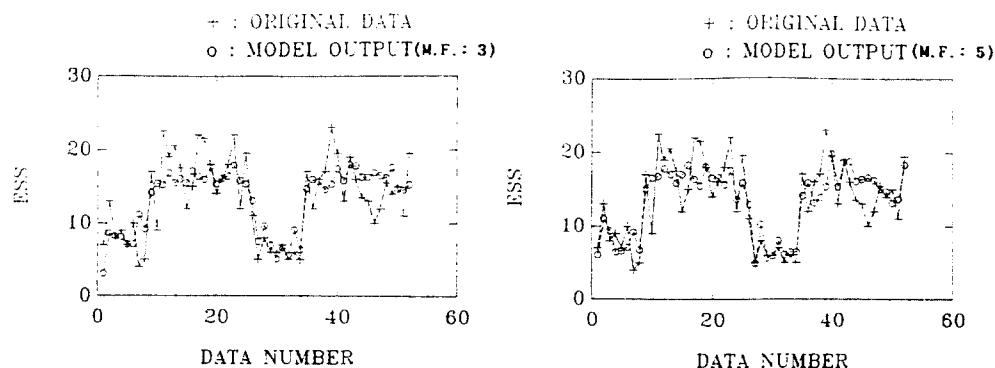
Fig. 8 Comparison of error convergence procedure between
conventional learning algorithm and modified one

표 6은 본 논문에서 얻은 하수처리 활성오니공정의 최적 모델과 기존 모델링 방법과의 동정오차 관점에서 비교하여 우수한 특성을 나타냄을 보였다.

표 6. 기존의 모델링 방법과 동정오차 비교

Table 6. Comparison of identification error with
conventional fuzzy modeling methods

모델	동정 오차
Conventional model[15]	1.34
Fuzzy-Neural model[Our model]	0.29



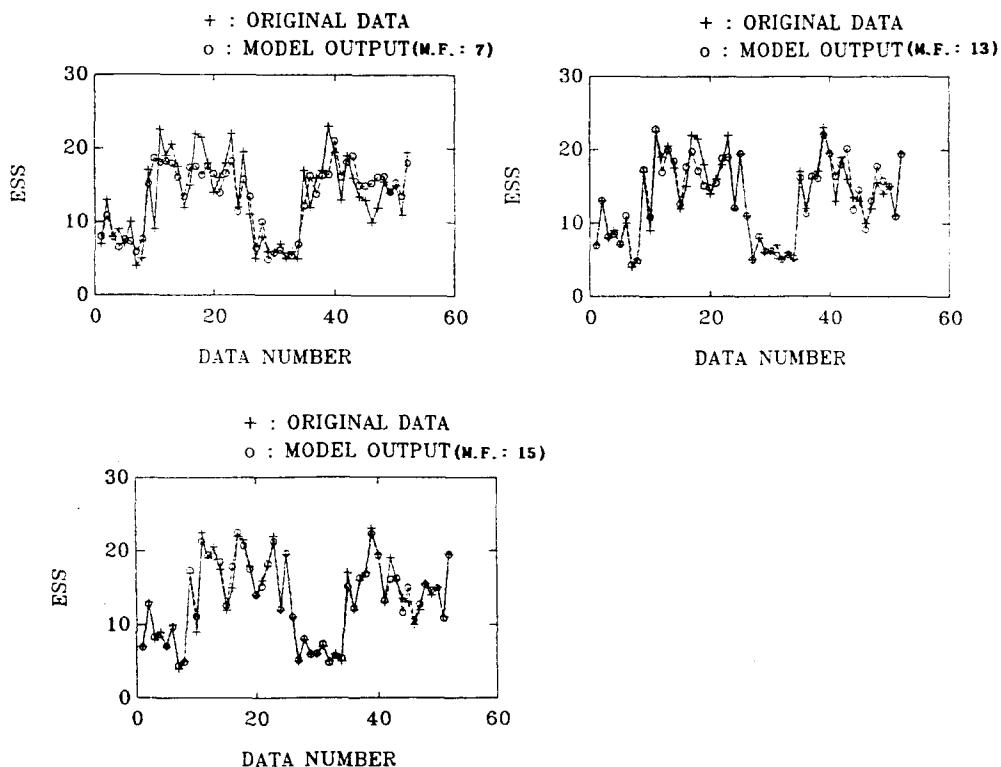


그림 9. 실 데이터와 멤버쉽 갯수에 따른 출력과의 비교
 Fig. 9 Comparison of original data and each output according to
 number of membership function

V. 결 론

본 논문에서는 비선형적인 요소가 많고 언어적 규칙을 찾기 어려운 시스템을 모델링 하기 위해서 최적화이론, 퍼지 추론규칙과 뉴럴네트워크 결합에 의한 퍼지-뉴럴네트워크 모델링 방법을 제안하였다. 제안된 퍼지-뉴럴네트워크의 성능을 시험하기 위해 교통 경로선택공정과 활성온니 공정을 모델링 하였다. 교통경로선택공정에서 기존의 지능형 모델보다 동정오차 및 적중률에서 우수한 성능을 나타냈고, 하수처리 활성온니공정에서 제안된 모델링 방법은 입력 변수의 비선형 퍼지-뉴런에 포함된 멤버쉽함수의 갯수 증가에 따라 모델링 성능을 한층 개선할 수 있었으며, BP알고리즘의 학습률을 변화 시키는 수정된 학습 알고리즘을 사용함으로써 빠른 수렴속도와 정확성을 얻을 수 있었다. 또한 파라미터의 동정에는 개선된 컴플렉스 알고리즘을 사용함으로써 학습시 오차의 수렴성을 향상시켜 공정시스템 모델의 성능지수를 향상시킬 수 있었다. 이 동정보모델 수법을 이용하여 정보의 종류, 교통목적, 운전자의 하루 운전시간, 예상 여행시간의 지각폭 및 예상 여행시간차 등에 따라 교통경로 선택모델을 구축하여 보다 효과적인 교통정보를 제공하는데 도움이 되고, 고부가 가치의 시뮬레이터 구성에 의한 예측 및 효율적인 제어정보를 얻을 수 있으리라 기대되며, 또한 비선형 모델링을 위한 다변수 입출력 지능형 모델구조를 설계하는데도 활용될 수 있을 것이다.

참 고 문 헌

1. 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.
2. 高木英行, "ニューラルネット PartⅢ: ファジイ 技術との融合化", 日本ファジイ學會誌 Vol.4, No.6, pp. 1086-1097, 1992.
3. H. Takagi and I. Hayashi, "NN-driven Fuzzy Reasoning", Int. J. of Approximate Reasoning, Vol.5, No. 3, pp.191-212, 1991.
4. Shin-ichi Horikawa, Takeshi Furuhashi, and Yoshiki 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.
5. 普野道夫, "ファジイ 制御", 日刊工業新聞社, 1988.
6. 今崎直樹, 木治潤一, "ファジイル-ル構造化ニューラネットワーカ", 日本ファジイ學會誌 Vol.4, No.5, pp.985-995, 1992.
7. H. Nomura and Wakami, "A Self-Tuning Method of Fuzzy Control by Descent Methods", 4th IFSA'91, pp.155-159, 1991.
8. Takeshi Yamakawa, "A New Effective Learning Algorithm for a Neo Fuzzy Neuron Model", Fifth IFSA World Conference, pp.1017-1020, 1993.
9. Wardrop, J. G. : Some Theoretical Aspect of Road Traffic Research, Proc. of the Institution of Civil Engineers, Part I, Vol.1, pp.325~378, 1952.
10. 佐左木 綱:道路網における輸送計画について, 第4回日本道路會議論文集, pp.43~46, 1957.
11. 星野 哲三:道路網における交通量配分の理論, 第5回日本道路會議論文集 pp.68 sim 70, 1959.
12. Martin, B. V. and Manheim, M. L. : A Research Program for Comparison of Traffic Assignment Techniques, Highway Research Record 88, pp.69~84, 1965.
13. Ben-Akiva, M., Bergman, M. J., Daly, A. J. and Ramaswamy R. : Modeling Inter Urban Route Choice Behaviour, Proc. of Ninth International Symposium on Transportation and Traffic Theory, VNU Science Press, pp.299~330, 1984.
14. 森彬壽旁, "非集計モデルの 推定と 檢定", 日本土木計劃學講習會テキスト15, pp.JSCE, 1984.
15. 오 성권, 우 광방, "퍼지추론 방법에 의한 퍼지동정과 하수처리공정시스템 응용", 대한전자공학회 논문집 제 31권 B편 제 6호, pp.43-52, 1994년 6월.
16. R. M. Tong, "Synthesis of fuzzy models for industrial processes", Int. J. Gen. Syst., Vol.4, pp.143-162, 1978.
17. 秋山孝正, "知識利用型の 経路選擇 モデル化手法", 日本土木計劃學研究論文集, JSCE, No.11, pp.65-72, 1993.
18. 秋山孝正, "阪神高速道路の交通制御エキスパートシステム", 人工知能學會研究會資料集18, pp.115-124, 1991.