

역전파학을 이용한 퍼지모델의 파라미터 동정: 전력부하 예측

Identification of Fuzzy Model using Back-propagation: Electric Power Load Forecasting

김이곤*, 류영재**, 김홍렬***, 박창석***, 곽호철****
I. G. KIM*, Y. J. LYU**, H. Y. KIM***, C. S. PARK***, H. C. GWAK****

<抄 録>

본 연구에서는 퍼지 클러스터링 알고리즘과 변수선택 방법을 이용하여 모델의 구조동정을 행하고, 신경회로망의 Back-Propagation 학습방법을 이용하여 파라미터동정을 행하는 새로운 퍼지모델링 알고리즘을 제안하였다. 실제 데이터를 이용하여 전력부하예측시스템을 설계하였으며 그결과 타당성을 입증하였다.

<Abstract>

We propose new fuzzy modeling algorithm that uses FCM clustering algorithm and variable selection method in structure identification of model and uses back-propagation in parameter identification of model. In this paper, we design a electric power load forecasting system using real data and prove the validity of proposed method by means of the result.

1. 서 론

비선형 시스템의 모델링은 대단히 복잡하고 어려운 분야이다. 퍼지 규칙을 이용한 모델링 기법들^[1-5]이 제안됨에 따라 비선형 시스템의 모델링 방법으로 그 유용성이 대단히 높게 평가되고 있다. 일반 퍼지 언어 규칙을 이용한 퍼지모델은 시스템의 정성적 동작특성을 인간이 쉽게 이해할 수 있을 뿐 만 아니라, 시스템의 동작특성을 선형화 모델링 방법에 비해 간단하게 언어적 규칙에 의해 표현할 수 있다는 장점을 갖고 있다. Sugeno-Tagaki에 의해 제안된 선형방정식에 근거한 퍼지모델은 시스템의 묘사력이 뛰어나 제어에 적당하여 널리 이용되고 있다. 기존의 퍼지 모델링 기법들은 분할이 일률적이어서 룰의 수가 많아져 최적 시스템 설계에는 부적합하였으나, 근자 새롭게 제안된 퍼지모델링 방법^[2,3]은 퍼지클러스터링에 의한 퍼지공간분할로 퍼지규칙의 자동생성이 가능하여 더욱 편리

하게 최적 모델링이 가능해 졌다. 이들 방법들은 크러스터를 임의의 퍼지변수로 근사화함으로써 파라미터 동조를 실시하고 있으며 퍼지변수의 선정에는 단지 모델의 정밀도에 국한하고 있다. 그러므로 근사화에 의한 오차를 보상할 수 없을뿐아니라, On-Line Modeling에 적합치 않다.

따라서, 이러한 문제를 해결하기 위해, 본 연구에서는 수치 입, 출력데이터로부터 퍼지클러스터링과 변수선택방법을 이용하여 퍼지모델의 구조동정을 행하여 동정된 파라미터를 초기치로하여 역전파학을 이용한 파라미터동조 방법을 추가한 퍼지모델링 알고리즘을 제안하였다. 알고리즘의 타당성을 검증하기 위하여 전력부하예측시스템의 설계에 적용하였다. 기존에 단기 전력부하예측에 대한 많은 논문^[9-12]들이 보고되고 있으나 이들 방법들은 복잡하고 시스템의 모델링 방법이 복잡한 단점을 갖고 있다. 새로운 퍼지 모델링 알고리즘을 이용하여 비선형 특성을 갖는 전력부하예측시스템을 설계하였으며 실측된 데이터를 이용하여 그타당성을 입증하였다.

* : 麗水水産大學校 電氣工學科 專任講師

** : (株)世宇産業電子시스템연구소 선임연구원

*** : 전남대학교 대학원

**** : 광양제철소 설비기술부제어시스템팀

2. 퍼지모델의 규칙수와 변수선택

2.1 최적 규칙수 선정

FCM^[6,7,8]은 C-Means법을 퍼지에 확장한 것이다. 데이터의 수를 n , 클러스터의 수를 c 라고 할 때, i 번째 클러스터에 k 번째의 데이터가 속하는 소속도를 μ_{ik} 라 한다면, 클러스터링의 결과는 식(2-1)의 분할 행렬로 표시될 수 있다. 즉 퍼지클러스터링은 어느 데이터가 어떤 클러스터에 속하는 정도를 멤버십함수 나타내는 것을 말하며 이때 소속도가 [0, 멤버십 값으로 주어지기 때문에, 특성이 같은 데이터집합의 분할이 보다 유연하게 이루어진다.

$$U = \begin{bmatrix} \mu_{11} & \dots & \mu_{1n} \\ \vdots & \dots & \vdots \\ \mu_{c1} & \dots & \mu_{cn} \end{bmatrix} \quad (2-1)$$

U행렬은 퍼지멤버십함수이며, 다음 3개의 조건을 만족할 때, 이를 퍼지 C분할행렬이라고 부른다.

$$(1) \mu_{ik} \in [0, 1] \quad 1 \leq i \leq c, \quad 1 \leq k \leq n$$

$$(2) \sum_{i=1}^c \mu_{ik} = 1 \quad 1 \leq i \leq c$$

$$(3) 0 < \sum_{k=1}^n \mu_{ik} < n \quad 1 \leq k \leq n$$

FCM은 필요 조건에 의한 반복법을 이용하여 평가 함수를 국소 최소로 하는 최적의 C분할 행렬을 구하는 방법이다. 일반화된 평가 함수는 다음 식과 같다.

$$J_m(U, V) = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m \|x_k - v_i\|^p \quad (2-2)$$

$$\mu_{ik} = \left\{ \frac{\|x_k - v_i\|^p}{\sum_{j=1}^c (\|x_k - v_j\|^p)^{1/(m-1)}} \right\}^{-1} \quad (2-3)$$

$$v_i = \frac{\sum_{k=1}^n \mu_{ik}^m x_k}{\sum_{k=1}^n \mu_{ik}^m} \quad (2-4)$$

여기서, m : weight $1 < m < \infty$

x_k : k 번째의 특징벡터

v_i : i 번째의 클러스터의 중심 벡터

$\|\cdot\|^p$: p 노름

평가 함수는 일반적으로 클러스터 수가 증가함에 따라 단조적으로 감소한다. 그러나 클러스터링에 있어서 클러스터의 수를 늘린다고 해서 좋은 것은 아니기 때문에 적절한 분할 수를 결정하기 위한 평가 지표가 필요하다. 최적의 클러스터 수를 결정하기 위해서 평가 지표를 이용한다. 본 논문에서는 최적 분할수를

구하는 방법으로 식(2-5)의 평가 함수 S 를 국소 최소로 하는 방법을 이용한다. S 는 클러스터링 내의 변동과 클러스터 간의 변동을 평가하는 것으로 분할수 c 를 2로부터 1씩 증가시켜 가면서, 각 단계마다 계산하고 앞단계에 비해 증가하면 탐색을 종료하여 전단계의 분할 수 c 를 최적 규칙수로 정한다.

$$S(U, V, c) = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m \{ \|x_k - v_i\|^2 - \|v_i - X_{0i}\|^2 \} \quad (2-5)$$

X_{0i} : x 의 평균값이다.

식(2-5)를 이용해서 최적 규칙수를 찾는 알고리즘을 정리하면 다음과 같다.

Step 1: c , m 과 U 의 초기 값 $U^{(0)}$ 를 설정하고 $t=0$ 로 한다.

Step 2: 클러스터의 중심 벡터 $v_i^{(t)}$ 를 구한다.

Step 3: $x_k < v_i^{(t)}$ 또는 $x_k > v_i^{(t)}$ 경우

$x_k = v_i^{(t)}$ 로 계산
식(2-3)의 경우

$$\mu_{ik} = \begin{cases} 1 & j = i \\ 0 & j \neq i \end{cases}$$

로서 $U^{(t)}$ 를 $U^{(t+1)}$ 로 갱신한다.

Step 4: 주어진 수렴판정치 ϵ 에 대해서

$$\|J_m(U^{t+1}, V^t) - J_m(U^t, V^{t-1})\| < \epsilon \text{ 이면}$$

Step 5로 가고, 아니면 **Step 2**로 간다.

Step 5: s^t 값을 계산한 다음 s^t 와 s^{t-1} 를 비교하여 s^t 가 적으면 $c=c+1$ 하여 **Step 2**로 가고 크면 중지한다. 이때 c 는 최적 규칙수이다.

파라미터 m 은 퍼지 변수의 겹침 수이고 통상 2.0이다. t 는 알고리즘내의 독립된 시간을 말한다.

2.2 입력변수선택

입력 변수의 선택에는 변수 증가법^[2,31]을 이용하여 모델의 평가가 가장 좋은 입력 변수를 1개씩 최종 선택한다. 변수증가법은 변수 선택을 위한 모델 평가 E 는 A 군의 데이터에 기초해서 구성된 A 모델을 B 군에 데이터에 의해 평가한 평균자승 예측오차(E_{AB})와, B 군의 데이터에 기초한 B 모델을 A 군의 데이터에 의해 평가한 평균자승 예측오차(E_{BA})의 평균치로 다음식과 같이 구한다.

$$E = (E_{AB} + E_{BA}) / 2$$

$$= \sum_{i=1}^{NB} (Y_{Bi} - Y_{ABi})^2 / NB + \sum_{i=1}^{NA} (Y_{Ai} - Y_{BAi})^2 / NA / 2 \quad (2-6)$$

Y_{A1}, Y_{B1} : A군, B군의 출력 데이터
 Y_{AB} : A모델을 이용한 B군 데이터의 출력 추론값
 Y_{BA} : B모델을 이용한 A군 데이터의 출력 추론값
 NA, NB : A군 데이터의 수, B군 데이터의 수
 입력변수를 선택한다. 입력 변수가 결정되지 않았다면, A군 데이터와 B군 데이터를 섞어서 다시 멤버십 함수를 구하고 선택을 계속한다.

3. Probagation

임. 출력데이터로부터 FOM과 변수선택방법을 이용하여 얻어진 초기 퍼지모델의 파라미터를 신경회로망의 역전파 학습방법을 이용하여 학습하는 방법을 제시한다. 하나의 규칙에 대한 수정된 퍼지신경회로망 모델^[5]은 Fig. 3-1과 같이 전건부와 후건부, 추론부로 구성된다.

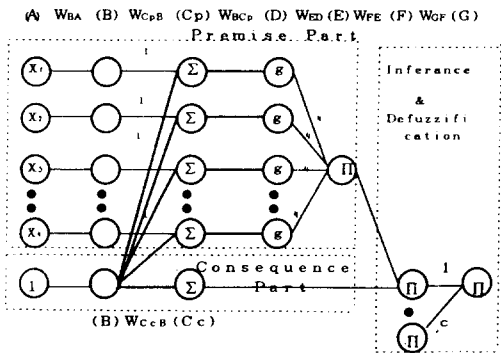


Fig. 3-1 Structure of Neural Network for C rules

이렇게 구성된 퍼지신경회로망 모델을 c개의 규칙을 갖는 모델로 표현할 수 있다. Fig. 3-1.에서 (A)층은 입력층(input layer), (E)층은 출력층(output layer)이고 나머지 층들은 중간층(hidden layer)이며, 각 층들을 서로 연결하고 있는 연결가중치는 퍼지 규칙의 파라미터를 나타내는 값을 갖는다. 중간층들 중 (B), (C), (D), (E)층은 전건부를 나타내고 있어 이들 층과 연결되는 가중치 $W_{BA}, W_{CB}, W_{CP}, W_{DB}, W_{EP}$ 는 전건부의 멤버십함수를 구성하는 파라미터들이고 Base층과 연결된 W_{CB} 는 후건부 싱글톤 b를 나타낸다. 여기에서 뉴런의 Σ 기호는 입력치들의 합을 나타내고 Π 기호는 입력들의 곱을 나타낸다. 식(3-2)의 $g(x)$ 는 시그모이

드함수인 식(3-1)의 $f(x)$ 를 미분한 식으로서 중형 멤버십함수를 만들고 이 식으로부터 입력변수의 소속정도를 나타내는 멤버십함수 값을 생성한다.

$$f(x) = \left[\frac{1}{1 + e^{-ax}} \right] \quad (3-1)$$

$$g(x) = f'(x) = a \left[\frac{e^{-ax}}{1 + e^{-ax}} \right] \left[1 - \frac{1}{1 + e^{-ax}} \right] \quad (3-2)$$

단, x : 뉴런의 입력
 a : sigmoid 함수의 기울기

(B)층과 (A)층을 연결하는 w_{BA} 는 (B)층의 값이 -1에서 1사이의 값이 되도록 하는 정규화를 위한 값이고 D층의 입력은 식(3-3)에서 $w_{CB}(x + w_{CP})$ 이다. 여기서 w_{CB} 와 w_{CP} 값은 시그모이드 함수의 기울기와 위치를 나타내며 중형멤버십함수를 결정하는 요인이 된다. 뒷식에서 살펴본 바와 같이 퍼지신경회로망에서 w_{CB} 값은 멤버십함수의 기울기를 결정하고, w_{CP} 값은 함수모양의 중심을 결정한다.

$$f(x) = \left[\frac{1}{1 + e^{-w_{CB}(x + w_{CP})}} \right] \quad (3-3)$$

(D)층에서 출력되는 $g(x)$ 값은 멤버십 함수로서 0에서 0.25까지 출력됨에 따라 연결 가중치 w_{EP} 를 4로 정하여 멤버십 함수의 최대치가 1이 되도록한다. 이렇게 각 입력층에 입력된 변수들은 중간층을 거치는 과정에서 ($A_{ji}(x_{j0})$)의 의미를 반영하고 (E)층에서 출력되는 값들을 각각 곱하여 i번째 룰의 적합도 w^i 를 계산한다. 후건부 선형방정식을 구성하는 회로는 Fig. 3-1.에서 1로된 입력층(input layer) (B)와 (C)층과 연결되도록 하면 연결가중치 w_{CB} 값이 후건부의 b를 나타낸다. 따라서 (C)층의 출력은 다음 식과 같이 i번째 룰의 후건부는 $y^i = b^i$ 와 같다. (F)층은 지금까지 퍼지화된 전건부의 적합도 w^i 과 후건부의 출력 y^i 로부터 추론을 행하는 층으로서 적합도 w^i 와 출력 y^i 를 곱한 값을 출력한다. (F)층에서 추론된 값은 연결치 w_{GF} 를 통하여 (G)층에 입력되는데 이때 w_{GF} 는 모든 룰의 (E)층 뉴런에서 계산된 w^i 을 합한 값의 역수로서 (G)층에 입력되는 추론값은 식(3-4)과 같다.

$$w_{GF} = \frac{1}{\sum_{k=1}^n w^k} \quad (3-4)$$

$$y^i = \frac{w^i * y^l}{\sum_{k=1}^p w^k} \quad (3-5)$$

i번째 룰에서 계산된 식(3-5) 출력 y^i 로 부터 식 (3-6)과 같이 합하면 비퍼지화 과정을 행한것과 같다.

$$y^* = \sum_{i=1}^n y^i \quad (3-6)$$

FCM으로 결정된 파라미터들을 전건부 멤버십함수와 후건부의 싱글톤으로 설정한다. 그러나 이들의 값은 근사화된 값이므로 최적으로 조정되어야만 더 정확한 출력을 얻을 수 있다. 만일 연결 가중치가 부적합한 값으로 설정되어 있다면 그 에러의 변화분에 대한 값을 각 층에 역전파시켜 조정시킴으로써 정확한 연결 가중치값을 동정하도록 한다. 전건부 파라미터 동정의 경우 각 규칙에 따른 멤버십 함수의 모양과 관련된 가중치 w_{cp} 와 w_{cp} 들을 변화시켜 적절한 모양이 되도록 동정하고, 후건부동정으로는 싱글톤에 해당되는 w_{cb} 값을 역전파(back propagation) 학습을 이용하여 동정한다. 다층신경회로망의 역전파 학습알고리즘은 일반화된 델타룰(generalized delta rule)을 적용함으로써 이루어 지는데 임의의 (n)번째층을 표현한 모델에 따르면 Fig.3-2와 같다.




Fig.3-2 neuron model (n)layer

(n-1)층에 존재하는 L개의 뉴런에서 출력되는 $O_i^{(n-1)}$ 는 각각의 연결 가중치와 곱해지고 합산되어 $I_j^{(n)}$ 라는 값으로 (n)층에 입력된 다음 (n)층의 $f(I_j^{(n)})$ 의 함수를 통하여 출력 $O_j^{(n)}$ 이 얻어진다.

$$I_j^{(n)} = \sum_{i=1}^L w^i * O_i^{(n-1)} \quad (3-7)$$

$$O_j^{(n)} = f(I_j^{(n)}) \quad (3-8)$$

이때 (n-1)층에 입력된 P번째 학습데이터로부터 (n)층에서 원하는 출력이 $D_j^{(n)}$ 이고 실제로 추론된 출

력이 $O_j^{(n)}$ 이라면 그 에러값은 $\epsilon^{(n)} = D_j^{(n)} - O_j^{(n)}$ 이고 이때 에너지 평가 함수는 식(3-9)과 같이 정의 된다.

$$E_{pj} = \frac{1}{2} (D_j^{(n)} - O_j^{(n)})^2 \quad (3-9)$$

에너지 평가함수 E_{pj} 를 최소로 하기 위해 P번째 데이터의 오차에 대한 i번째의 결합가중치 $w_{ji}^{(n)}$ 의 변화량 $\Delta w_{ji}^{(n)}$ 는 다음과 같이 유도된다.

$$\frac{\partial E_{pj}}{\partial w_{ji}} = - (D_j^{(n)} - O_j^{(n)}) \frac{\partial f(I_j^{(n)})}{\partial I_j^{(n)}} \frac{\partial I_j^{(n)}}{\partial w_{ji}} \quad (3-10)$$

(n)층 입력의 i번째 입력 가중치에 대한 미분을 구하면 식(3-11)과 같고 이를 식(3-10)에 대입하면 식 (3-12)와 같다.

$$\begin{aligned} \frac{\partial I_j^{(n)}}{\partial w_{ji}} &= \frac{\partial}{\partial w_{ji}} \left\{ \sum_{k=1}^L w_{kj} * O_k^{(n-1)} \right\} \\ &= O_i^{(n-1)} \end{aligned} \quad (3-11)$$

$$\frac{\partial E_{pj}}{\partial w_{ji}} = - (D_j^{(n)} - O_j^{(n)}) f'(I_j^{(n)}) O_i^{(n-1)} \quad (3-12)$$

다음 학습되기 전의상태를 (t)라면 (t+1)상태의 가중치를 갱신하는 변화량은 에러의 변화분에 역으로 작용한다.

$$w_{ji}^{(n)}(t+1) = w_{ji}^{(n)}(t) + \Delta w_{ji}^{(n)}(t) \quad (3-16)$$

$$\Delta w_{ji}^{(n)} = \eta (D_j^{(n)} - O_j^{(n)}) f'(I_j^{(n)}) O_i^{(n-1)} \quad (3-17)$$

여기서 η 는 학습율(learning-rate)이다.

식을 간략화 시키기위해 식(3-18)라 놓으면 식 (3-19)과 같이 된다.

$$\delta^{(n)} = (D_j^{(n)} - O_j^{(n)}) f'(I_j^{(n)}) \quad (3-18)$$

$$w_i^{(n)}(t+1) = w_i^{(n)}(t) + \eta \delta^{(n)} O_i^{(n-1)} \quad (3-19)$$

위 역전파 학습알고리즘에 따라 퍼지신경회로망의 전건부 중형멤버십 함수와 후건부 싱글톤 값이 다음의 학습과정을 통해 동정된다. 단 첨자 k는 k번째 퍼지 규칙을 나타내며 첨자 p는 p번째 데이터를 표시한다.

$$E_p = (D_p - O^{(G)}) \quad (3-20)$$

$$\delta_p^{(G)} = E_p \quad (3-21)$$

$$\delta_p^{(F)k} = w_{cp}^k \delta_p^{(G)} \quad (3-22)$$

$$\delta_p^{(D)k} = \frac{4}{\alpha} \delta_j^{(E)k} \quad (3-23)$$

$$\delta_p^{(Cp)k} = g'(I^{(D)k}) \delta_p^{(D)k} w_{Dcp}^k \quad (3-24)$$

$$= \frac{\partial(O^{(D)k})}{\partial(I^{(D)k})} \delta_p^{(D)k} w_{Dcp}^k \quad (3-25)$$

$$= \frac{\partial}{\partial(I^{(D)k})} \left[\frac{\alpha e^{-I^{(D)k}}}{(1 + \sum_{j=1}^c I^{(D)kj})} \right] \delta_p^{(D)k} w_{Dcp}^k \quad (3-26)$$

$$= \alpha O_j^{(D)} \left[1 - \frac{e^{-I^{(D)k}}}{(1 + e^{-I^{(D)k}})} \right] \delta_p^{(D)k} w_{Dcp}^k \quad (3-27)$$

(F)층의 곱셈계산에 따라 (E)층과 (C)층 뉴런에 대한 델타식은 다음과 같다.

$$\delta_p^{(E)k} = \delta_p^{(F)} \left[\frac{\partial O^{(F)}}{\partial O^{(E)k}} \right] \quad (3-28)$$

$$\delta_j^{(C)k} = \delta_j^{(F)} \left[\frac{\partial O^{(F)}}{\partial O^{(C)k}} \right] \quad (3-29)$$

윗식으로부터 (t+1)상태의 연결 가중치는 식(3-30)과 같이 수정된다.

$$w_i^k(t+1) = w_i^k(t) + \eta \delta_i^k O_i \quad (3-30)$$

위 역전파 학습알고리즘에 따라 전건부 멤버십 함수와 후건부 계수가 학습데이터에 맞도록 동정되며 다음과 같다. 역전파 학습 알고리즘에 따른 파라미터 동정은 후건부 파라미터 동정과 전건부 파라미터 동정으로 나누어 실행되는 데, 후건부 동정에서는 후건부 싱글톤을 동정하고 전건부 동정에서는 멤버십함수의 기울기와 중심을 결정하는 w_{Cp} 와 w_{Dcp} 를 동정한다.

4. 퍼지 모델링

4.1. 퍼지모델링 알고리즘

퍼지 이론을 응용한 FCM은 처음에 각 데이터가 각 클러스터에 속하는 소속도로서 멤버십 함수의 초기치를 정하고, 그 멤버십 함수를 사용한 평가 함수가 최소가 되도록 클러스터의 중심 모델의 퍼지변수를 결정한다. 입력 변수가 x_1, x_2 로 출력 변수가 y 인 입력-출력 시스템의 퍼지 모델은 다음과 같이 표현된다.

$$R^i: \text{if } x_1 \text{ is } A_1^i \text{ and } x_2 \text{ is } A_2^i, \text{ then } y^i = b^i \quad (4-1)$$

$$(i = 1, 2, 3, \dots, c)$$

여기서, R^i 는 i 번째의 규칙, c 는 규칙 수, A_1, A_2 는 종

형의 퍼지집합이고, b^i 는 i 번째룰의 후건부 싱글톤이다. 퍼지 모델의 추론법으로서 맥스-프로덕트(max-product) 합성법을 이용한다. 중심법을 이용해 비퍼지화한 값을 모델의 출력으로 한다. 추론법을 식(4-1)의 모델의 입력이 (x_{10}, x_{20}) 인 경우에 식(4-2)과 식(4-3)으로 표현된다.

$$w^i = \mu_{A_1}^i(x_{10}) \times \mu_{A_2}^i(x_{20}) \quad (4-2)$$

$$y = \frac{\sum_{i=1}^c (w^i \times y^i)}{\sum_{i=1}^c w^i} \quad (4-3)$$

식(4-2)의 $\mu_{A_1}^i(x_{10})$ 는 퍼지 집합 A_1 에 대한 멤버십 함수.

$\mu_{A_2}^i(x_{20})$ 는 퍼지 집합 A_2 에 대한 멤버십함수, y^i 는 i 번째룰의 출력, w^i 를 입력 (x_{10}, x_{20}) 의 규칙 R^i 에 대한 적합도라 부른다.

이와 같은 규칙을 만들기 위해서는 출력치가 거의 같은 데이터들의 클러스터 집합들을 구하면 된다. 입력 퍼지집합의 멤버십 함수는 입력 공간상에서 클러스터링 결과를 각 변수의 축 위에 사영하면 입력 변수의 축 위에 나타난다. 이와같이 1개의 클러스터에 대해서 각 입-출력 변수의 1개 멤버십 함수가 사영 결과를 중형멤버십함수로 근사화함으로써 얻어지고, 각 변수의 멤버십 함수를 변수의 값으로 하는 1개의 규칙이 구성된다. 모델링 수행 순서는 Fig. 4-1와 같이 수행한다.

4.2 퍼지 모델의 구조와

파라미터 동정

퍼지 모델링은 일반 모델링과 달라서 전건부와 후건부로 된 규칙기준 모델(rule based model)의 동정 문제이다. 규칙의 구조동정은 전건부와 후건부의 동정으로 나눌 수 있으며, 전건과 후건부동정은 구조동정과 파라미터 동정으로 구분한다.




Fig. 4-1 Diagram of New Fuzzy Modeling Process.

본 논문에서 퍼지 모델의 구조동정이라는 것은 변수의 선택과 그 변수가 걸쳐 있는 공간의 퍼지 분할을 말하는 것이고, 파라미터 동정은 퍼지 멤버십함수의 파라미터를 결정하는 것이다. 단 모델링의 전체 조건으로서 후건부의 변수 선택은 시스템의 출력으로 사전에 선택되어 있다. 퍼지 모델에서도 규칙의 수를 증가시키면 모델의 예측 오차는 일반적으로 적게 되지만 규칙 수가 많은 모델은 양호한 모델이라고 하지는 않는다. 그러나, 일반적인 규범이 퍼지 모델링에는 없고 구조 동정에 관한 연구도 그 수가 적다. 본 연구의 구조 동정에서 규칙 수는 클러스터의 변동을 이용한 평가지표가 국소 최소가 되는 후건부의 최적 분할 수로 결정하고, 전건부의 변수는 모델의 예측 오차의 평균치를 평가 기준으로 한 변수선택 동정법을 이용하여 선택하였다. 본 연구에서는 파라미터동정을 간략화하기 위해서 멤버십함수를 종형퍼지변수로 근사화시켜서 신경회로망의 Back-Propagation 학습방법을 이용하였다.

5. 전력부하예측시스템

설계 및 고찰

데이터는 8월 한달 중에서 8월 1, 2, 6, 7, 8, 9, 13, 14, 15, 16, 20, 21, 22, 23, 27, 28, 29, 30의 전력부하와 전력부하에 관계하는 외부 온도, 일기 예보에 의한 당일의 일기, 일기 예보에 의한 당일의 불쾌지수, 외부 온도의 변화, 부하의 변화들이며 입력 변수의 후보 선택을 위한 데이터 분석을 한다. 데이터 내용은 다음과 같다.

1) 데이터 내용

- ① x_1 : 외부 온도
- ② x_2 : 당일의(9, 12, 15시)일기: 쾌청-비 = 9-1
- ③ x_3 : 당일(9, 12, 15시)불쾌지수
- ④ x_4 : 외부 온도의 변화: $x_4(t) = x_1(t) - x_1(t-1)$
- ⑤ x_5 : 부하의 변화: $x_5(t) = x_6(t) - x_6(t-1)$
- ⑥ x_6 : 부하(전력부하)(측정 시각의 전력부하)
- ⑦ $y (=x_6(t+4))$: 출력(4시간 이후의 전력부하)

본 논문에서는 8월 한달 동안의 월요일, 일요일, 토요일을 제외한 평일의 데이터를 이용하여 8월 중 평일의 전력부하를 예측하는 모델을 설계하고자 한다. 예측하고자 하는 출력은 측정 시각으로부터 4시간 이후

의 전력부하이다. 전력부하의 변동에 영향을 미치는 요인들에 대한 인간의 느낌이 시간의 지연을 갖고 나타나기 때문에 4시간 후의 부하를 측정하기 위해 측정 시각으로부터 지연시간 $t \leq 4$ 까지의 변수가 부하의 변동과 상관이 있을 것으로 판단하여 입력 변수의 후보 배열에 포함 시킨다.

FCM을 이용한 퍼지모델링 방법에서는 출력 변수는 선택되어 있는 것으로 하므로, 출력 변수는 예측 시각으로부터 4시간 후의 전력부하 $x_6(t+4)$ 이다. 출력은 매일 비슷한 형태의 곡선을 그리고 있고 요일에 따라서 그 곡선의 기울기와 변화의 폭은 다르게 나타나고 있다. 그리고 시간 변화에 따른 요인들의 분포 곡선은 비선형적으로 나타나고 있다.

필요한 입력 변수를 선택하기 위해서는 실측된 데이터로부터 전력부하에 인과 관계를 갖는 가능한 모든 요인들을 후보 변수로 선택한다. 부하의 변화에 대한 요인들의 영향은 시간적으로 지연을 갖고 나타나기 때문에 예측에 필요한 실제 데이터를 시간 배열을 이용하여 입력 변수의 후보로 선택했다. 시계열 상에서 입력 변수는 각각 $x_N(t), x_N(t-1), \dots, x_N(t-4), N=1, 2, \dots$ 이다 (여기서 N 은 변수의 개수). 따라서 시계열 상태의 입력 변수는 $6 \times 5 = 30$ 개가 된다. 그리고 데이터 측정이 이산적이기 때문에 연속적이지 못함으로써 생기는 영향을 최소화하기 위하여 이동 평균(Moving Average)를 취하여 입력 변수로 선택하였다. 식(5-1)로 이동 평균을 취할 입력 변수의 수를 N 이라고 하고 이동 평균의 구간을 4시간으로 하였다.

$$Mx_N(t) = \sum_{m=0}^4 x_N(t-m) / 4 \quad (5-1)$$

식(5-1)에 의해서 이동 평균을 취한 입력 변수는 5개로 시계열에 의한 변수를 합하면 전체 입력 변수의 후보 수는 35개로 선택된다.

다음은 새로운 퍼지모델링 알고리즘을 이용하여 전력부하 예측시스템을 모델링한다. 입, 출력 공간은 입력 변수를 35(시계열 데이터 30, 이동 평균(Moving Average)데이터 5), 출력 변수를 $x_6(t+4)$ 로 하여 퍼지 모델링을 실시한다.

제안된 알고리즘에 의해 모델링한 결과 선택된 입력 변수는 $X_1=MX_2$, $X_2=MX_3$, $X_3=MX_4$, $X_4=X_5$, $X_5=X_6(t-4)$ 이다. 제안된 알고리즘의 타당성을 입증하기 위하여 제안된 알고리즘에 의해 설계된 모델의 학습의 효과를 학습 회수에 대한 오차율과 설계된 모델에 의한 추론결과를 Fig. 5-1, Fig. 5-2에서 각각 보였다.




Fig. 5-1 Trend of Error Rate in Learning.




Fig. 5-2 Forecasted Result of New Fuzzy Model.

Fig. 5-1에서 보였듯이 학습회수를 증가함에 따라 오차율의 개선을 볼 수 있으며, 제안된 알고리즘에 의해 설계된 모델의 예측 결과는 기존의 방법에 의해 구성된 모델보다 정확도에서 개선된 사실을 확인할 수 있었다.

6. 결 론

본 연구에서 퍼지 모델의 파라메터인 퍼지변수의

최적화를 위하여 퍼지클러스터링에 의해 분할된 클러스터군을 중형 퍼지멤버십함수로 근사화하여 수정된 신경회로망 모델을 이용하여 학습시킴으로써 퍼지 모델의 정밀도를 향상시킬 수 있음을 보였으며, 이와 같은 제어 루프를 구성함으로써 On-line 모델링이 가능함을 보였다. 실제 수치데이터를 이용하여 전력부하 예측시스템을 설계하여 정밀도가 높은 예측 결과를 보여줌으로써 비선형시스템의 모델링에 적합함을 입증할 수 있었다.

7.참 고 문 헌

- [1] M. Sugeno, Industrial Applications of Fuzzy Control, New York: Elsevier Science Publish, (1985)
- [2] 김 이 곤, 퍼지 모델을 이용한 電力負荷豫測에 관한 研究, 全南大學校 博士學位論文, 1992.
- [3] 이계호, 임영철, 김이곤, 조경영, "신경회로망을 이용한 퍼지론의 추론과 학습에 관한 연구", 한국통신학회 논문지, Vol. 18, No. 2, pp. 231-238, 1993.
- [4] M. Sugeno and T. Ysugawa, "A Fuzzy-Logic-Based Approach to Qualitative Modeling," IEEE Trans. on Fuzzy Systems, Vol. 1, pp. 7-31, Feb. 1993.
- [5] 임영철, 장영학, 조경영, 김이곤, 박봉기, "퍼지신경회로망을 이용한 자율주행차량의 조향제어에 관한 연구", Proceedings of JCEANF 93' 1993.
- [6] Y. Fukuyama, M. Sugeno, "A New Method of Choosing The Number of Clusters for Fuzzy C-Means Method", 5th Fuzzy System Symposium, Jun. 2-3, 1989, pp. 247-252.
- [7] R. Gunderson, "Application of Fuzzy ISODATA Algorithms to Star Tracker Pointing Systems", Proc. 7th Triennial World IFAC Congress, 1978, pp. 1319-1323.
- [8] R. Campo, P. Ruiz, "Adaptive Weather-Sensitive Short Term Load Forecast", IEEE Trans. on Power Systems, Vol. PWRS-2, No. 3, August 1987, pp. 175-185.
- [9] G. D. Irissari, S. E. Widergren, P. D. Yehsakul, "On-Line Load Forecasting for Energy Control Center App.", IEEE Trans. on PAS, vol. PAS-101, no. 1, Jan. 1982
- [10] J. H. Park, Y. M. Park, K. Y. Lee, "Composite Modeling for Adaptive Short-Term Load Forecasting", paper 90SM378-0-PWRS, IEEE-PES Summer, Minneapolis, 1990.
- [11] S. Rahman, R. Bhatnagar, "An Expert System Based Algorithm for Short Term Load Forecast", IEEE Trans. on PWRS, vol. 3, no. 2, May 1988, pp. 392-399.
- [12] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, M. J. Damborg, "Electric Load Forecasting Using an Artificial Neural Network", paper no. 90SM377-2-PWR S, IEEE-PES Summer Meeting, Minneapolis, MN, Jul. 1990.