

# 퍼지 이론을 利用한 電力負荷豫測시스템의 설계

(Design of Electric Power Load Forecasting System Using Fuzzy Logic)

金伊坤\*  
(Yi-Gon Kim)

## 要　　約

전력 부하의 예측은 산업 활동에 있어 전력의 안정적인 공급과 생산비의 절감을 위해 대단히 중요하다. 전력 부하의 예측 방법들이 많이 연구되고 있으나 기존의 방법들은 수학적으로 복잡하고 계산 시간이 많이 소요되는 단점을 갖고 있다. 본 연구에서는 최적 규칙수를 구하는 클러스터링 알고리즘과 데이터를 2분하여 설계한 변수선택 방법을 이용하여 모델을 간략화하는 알고리즘을 제안하였으며, CMAC을 이용한 데이터의 양·부 판별 알고리즘을 이용함으로써 노이즈의 영향을 최소화하였다. 제안된 알고리즘을 이용하여 전력부하예측 시스템을 설계하고 분석한 결과 그 타당성을 입증하였다.

## Abstract

An electric power load forecasting is very important for the stable supply of electric power and the reduction of production cost in industrial activities. Many studies are reported in this field. Most of them are mathematically complicated and have a long computing time.

Accordingly, we propose a new algorithm that can simplify model and economize computing time by using FCM clustering algorithm and variable selection method in modeling. Proposed method adopts CMAC to minimize the influence of inaccurate data. In this paper, we designed a forecasting system using real data and proved the validity of proposed method by means of the result.

## 1. 서　　론

산업 사회의 발달과 더불어 전력의 수요가 급격하게 증가함에 따라 전력의 안정적인 공급과 효율적인 이용이 보다 절실하게 요구되고 있다.

\* 正會員：麗水水產大學校 講師·工博  
接受日字：1994年 2月 18日

전력부하 예측은 일반적으로 예측하는 기간에 따라서 年이나 月 단위로 행하는 장기 예측과 日이나 時間단위로 하는 단기 예측으로 분류할 수 있으며 전력 부하의 예측을 이론적 방법에 의해 분류한다면 요인분석과 시간배열방법<sup>1)</sup>으로 분류할 수 있다. 요인분석 방법은 전력부하의 변화에 영향을 주는 요인들을 추출하여 이들과 부하의 상관 관계를 계산함으로 환경의 변화가 심할 때 적

합한 방법이다. 그러나 이 방법은 예측에 관계하는 모든 요인들을 다 끄집어 내기가 불가능하고 심지어 그 요인 자체를 정확하게 평가하기 어렵다. 시간배열 방법은 시간상으로 가까운 날들의 부하 패턴을 고려해 보는 방법<sup>2)</sup>인데, 이 방법은 환경의 변화가 심하지 않는 날에 적당하지만 상대적으로 큰 변화가 있을 때는 적당하지 않다.

본 연구에서는 요인 분석에 의한 단기 예측을 연구범위로 삼는다. 단기 예측에서 요인 분석을 이용한 예측 방법으로는 선형 회귀모델과 칼만 필터를 이용한 방법과 신경 회로망, 퍼지 전문가 시스템을 이용한 방법등이 있다.<sup>3)-7)</sup> 그러나 이 방법은 신경 회로망과 퍼지 이론을 이용함으로써 시스템의 구조가 복잡해지고 계산 시간이 많이 걸리는 단점을 갖고 있다.

따라서 본 연구에서는 유클리드 노름에 의한 FCM<sup>8)-9)</sup>(Fuzzy C-Means Method)을 이용하여 최적 규칙수를 결정하는 알고리즘과 입력 변수의 후보중에서 가장 인과 관계가 많은 변수를 선택하는 알고리즘을 이용하여 모델을 간략화하는 알고리즘을 제안하였으며, 간략화된 퍼지모델을 이용하여 비선형 특성을 갖는 전력부하예측시스템을 설계하였다. 그리고 CMAC이론<sup>10)</sup>을 이용하여 모델링에 이용되는 데이터중에서 부정확한 데이터를 제거하는 방법을 제안하였다.

## 2. 규칙수 선정과 데이터의 양·부 판별

### 2.1 퍼지 클러스터링과 규칙수 선정 알고리즘

#### 1. 퍼지 클러스터링

클러스터링(hard clustering)은 어느 데이터가 어떤 클러스터에 속하는 정도를 0 또는 1로 분류하는 것을 말한다. 그러나 퍼지 클러스터링은 소속도가 [0, 1]의 멤버쉽 값으로 주어지기 때문에, 특성이 같은 데이터집합의 분할이 보다 유연하게 이루어진다.

FCM은 C-Means법을 퍼지에 확장한 것이다. 지금 데이터의 수를  $n$ , 클러스터의 수를  $c$ 라고 할 때,  $i$ 번째 클러스터에  $k$ 번째의 데이터가 속하는 소속도를  $\mu_{ik}$ 라 한다면, 클러스터링의 결과는

식(2.1)의 분할 행렬로 표시될 수 있다.

$$U = \begin{bmatrix} \mu_{11} & \cdots & \mu_{1n} \\ \vdots & \ddots & \vdots \\ \mu_{c1} & \cdots & \mu_{cn} \end{bmatrix} \quad (2.1)$$

$U$ 행렬이 다음 3개의 조건을 만족할 때, 이를 퍼지 C분할행렬이라고 부른다.

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

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

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

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

$$J_m(U, V) = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m \|x_k - v_i\|^p \quad (2.2)$$

여기서,  $m$  : weight  $1 < m < \infty$

$x_k$  :  $k$ 번째의 특징벡터

$v_i$  :  $i$ 번째의 클러스터의 중심 벡터

$$v_i = \frac{1}{\sum_{k=1}^n \mu_{ik}^m} \sum_{k=1}^n \mu_{ik}^m x_k$$

$$\| . \| ^p : p노름$$

일반화된 FCM 알고리즘

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

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

Step 3 :  $X_k \subset v_i^{(t)}$  또는  $X_k > v_i^{(t)}$  경우

$$\mu_{ik} = \left\{ \sum_{j=1}^c \frac{\|x_k - v_j\|^p}{\|x_k - v_i\|^p} \right\}^{-1} \quad (2.3)$$

$x_k = v_i^{(t)}$ 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 수렴 판정치  $\epsilon$ 에 대해서

$\|J_m(U^{(t+1)}, V) - J_m(U^t, V)\| < \epsilon$ 이면 종료하고, 그렇지 않으면 Step 2로 돌아간다.

통상적으로 가중치 파라미터  $m$ 은 2.0이고  $t$ 는 알고리즘내의 독립된 시간을 말한다.

### 2. 규칙수의 선정

평가함수는 일반적으로 클러스터 수가 증가함에 따라서 단조적으로 감소한다. 그러나 클러스터링에 있어서 클러스터의 수를 늘린다고 해서 좋은 것은 아니기 때문에 적절한 분할 수를 결정하기 위한 평가지표가 필요하다. 최적의 클러스

터 수를 결정하기 위해서 평가지표를 이용한다. 본 논문에서는 최적 분할수를 구하는 방법으로 유클리드 노름을 이용한 식(2.4)의 평가함수 S를 국소 최소치로 하는 방법을 이용한다. 식(2.4)에서 S는 클러스터링 내의 변동)-(클러스터간의 변동)을 평가하는 것으로 분할수 c를 2로부터 1씩 증가시켜가면서, 각 단계마다 평가함수 S를 계산하고 S가 앞단계에 비해 증가하면 탐색을 종료하여 후단계의 분할 수 c를 최적 규칙수로 정한다.

$$S(U, V, c) = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m \{ \|x_k - v_i\|^2 - \|v_i - x_a\|^2 \} \quad (2.4)$$

여기서  $X_a$ 는  $x$ 의 평균값이다.

지표  $S(U, V, c)$ 를 전체 데이터의 분산으로 나눈다.

$$s(U, V, c) = S(U, V, c) / V_{av}(X) \quad (2.5)$$

단, 여기서  $V_{av}(X)$ 는 전 데이터의 분산이다. 이것은 데이터의 좌표 값에 따라  $s(U, V, c)$ 의 절대 값이 변하는 것을 막고 데이터의 구조에 따라서 값이 변하게 함으로써 분할하는데 평가함수로서 의미를 갖도록 하는 것이다.  $s(U, V, c)$ 가 적합한 분할수의 절대적 지표라고 하기에는 곤란하고, 어느 정도 주관적인 면도 있다고 생각되지만 앞에 정의한 지표  $s(U, V, c)$ 는 실험결과 다른 지표에 비해서 보다 좋은 결과가 얻어졌다.  $s(U, V, c)$ 를 이용해서 최적 규칙수를 찾는 클러스터링 알고리즘을 정리하면 다음과 같다.

Step 1~Step 3과정은 FCM알고리즘과 동일함

Step 4 : 주어진 수렴판정치  $\epsilon$ 에 대해서

$\|J_m(U^{t+1}, V^t) - J_m(U^t, V^{t-1})\| < \epsilon$ 이면 Step 5로 가고, 그렇지 않으면 Step 2로 돌아간다.

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

## 2.2 변수선택 알고리즘

입력변수의 선택에는 변수 증가법을 이용하여 모델의 평가가 가장 좋은 입력변수를 1개씩 최종 선택한다.

변수 증가법은 다음의 수행순서로 한다.

Step 1) 입력변수의 수를 1개로 가정하고 모델

의 평가 가장 좋은 변수를 입력 변수에 확정한다.

Step 2) 변수 수를 1씩 증가시켜 모델의 평가가 전단계보다 양호한 것을 입력 변수로 확정한다.

Step 3) 전단계보다 나쁘면 입력변수의 후보에서 제거한다.

Step 4) 후보가 존재하면 2)로 가고, 않으면 종료함

본 논문에서는 변수선택을 위한 모델 평가 E는 A군의 데이터에 기초해서 구성된 A모델을 B군의 데이터에 의해 평가한 평균자승 예측오차 ( $E_{AB}$ )와, B군의 데이터에 기초한 B모델을 A군의 데이터에 의해 평가한 평균자승 예측오차( $E_{BA}$ )의 평균치로 다음식과 같이 구한다.

$$E = \frac{(E_{AB} + E_{BA})}{2} = \frac{\sum_{i=1}^{NB} (Y_{Bi} - Y_{AB})^2 / NB + \sum_{i=1}^{NA} (Y_{Ai} - Y_{BA})^2 / NA}{2} \quad (2-6)$$

여기서  $Y_{Ai}$ ,  $Y_{Bi}$  : A군, B군의 출력 데이터

$Y_{AB}$  : A모델을 이용한 B군 데이터의 출력 추정치

$Y_{BA}$  : B모델을 이용한 A군 데이터의 출력 추정치

NA, NB : A군 데이터의 수, B군 데이터의 수

Step 4)에서 입력변수가 결정되지 않았다면, A군 데이터와 B군 데이터를 섞어서 다시 멤버쉽 함수를 구하고 선택을 계속한다.

## 2.3 데이터 판별 알고리즘

입·출력 데이터에 불필요한 데이터가 포함되어 있다면 이러한 데이터의 영향으로 규칙구성에 나쁜 영향을 미친다. 이와 같은 문제를 해결하기 위해서, 인간 소뇌의 정보처리 기능을 모방한 신경회로망 모델 CMAC(Cerebellum Model Arithmetic Computer)을 이용하였다.<sup>10)</sup> 이것은 J.S. Albus에 의해 제안되었으며 생체의 정보처리기능을 모방한 여러개의 세포 모델로 구성되고, 이들 모델이 병렬적으로 값을 출력할 때, 이들 출력치 합을 구함으로써 추론치를 구하는 방법이다. CMAC는 입·출력 데이터에 대한 추론 오차의 크기에 따라서 각 과립세포모델의 출력치를

학습변화시켜서 데이터의 검출을 행한다.

CMAC의 데이터 양·부판별 알고리즘

Step 1 : 시스템으로부터 얻어진 n개의 입·출력 데이터( $x_i, y_i$ , ( $i=1, 2, \dots, n$ ))를 관측한다.

Step 2 : n개의 입·출력 데이터에 대해서,  $t=1$ 로부터 순서대로  $y_{at}$ 를 구한다.<sup>11)</sup>

Step 3 : 추론오차  $\text{error}_c^2$ 가 알고리즘 종료치  $Q_0$ 보다 적게 되는 경우에 알고리즘을 종료한다.

$$\text{Error}^2 = \sum_{i=1}^n (y_{at} - y_i)^2 \leq Q_0 \quad (2.7)$$

단,  $y_{at}$ , last는  $t=n$ 에서의 입력  $X_i$ 에 대한 개선된 CMAC의 추론치이다. 식(2.7)을 만족하지 않는 경우는 Step 2.에 다시 돌아가고 같은 조작을 반복한다. 개선된 CMAC의 알고리즘이 종료된 시점에서 n개의 입·출력 데이터에 대해서

$$E_i = |y_{at} - y_i| \geq Q_{ac} \quad (2.8)$$

식(2.7)을 계산하고 식(2.8)을 만족하는 부적합한 입·출력 데이터를 입·출력 데이터들로부터 제거한다.

식(2.10)에서  $Q_{ac}$ 은  $Q_0$ 를 n로 나눈 각 데이터에 레이블의 스레스홀드 값이다.

### 3. 퍼지 모델링

#### 3.1 퍼지 모델링 알고리즘

본 절에서는 제안된 퍼지 클러스터링에 의한 퍼지모델링에 대해서 설명한다. 본 논문에서 이용되는 FCM은 기존 C-Means에 퍼지 이론을 적용한 것이다. 퍼지이론을 응용한 FCM은 처음에 각 데이터가 각 클러스터에 속하는 소속도로서 멤버쉽 함수의 초기치를 정하고, 그 멤버쉽 함수를 사용한 평가함수가 최소가 되도록 클러스터의 중심 모델의 퍼지변수를 결정한다. 입력 변수가  $x_1, x_2$ 로 출력변수가  $y$ 인 입·출력 시스템의 퍼지모델은 다음과 같이 표현된다.

$$R^j : \text{if } x_1 \text{ is } A_1^j \text{ and } x_2 \text{ is } A_2^j, \text{ then } y \text{ is } B^j \quad (3.1)$$

$$(j=1, 2, 3, \dots, l)$$

여기서,  $R^j$ 는 j번째의 규칙, l은 규칙 수,  $A_1^j, A_2^j, B^j$ 는 퍼지 집합이다. 본 논문에서  $B^j$ 는 싱글톤 (singleton)이라고 불려지는 실수치를 이용한다. 본 논문에서는 퍼지모델의 추론법으로서 맥스-프로덕트(max-product)합성법을 이용한다. 즉, 규

칙의 후반부를 싱글톤으로 표현하고 중심법을 이용해서非퍼지화한 값을 모델의 출력으로 한다. 추론법을 식(3.1)의 모델의 입력이  $(x_1^0, x_2^0)$ 인 경우에 식(3.2)과 식(3.3)으로 표현된다.

$$W^j = \mu_{A_1^j}(x_1^0) \times \mu_{A_2^j}(x_2^0) \quad (3.2)$$

$$y = \frac{\sum_{j=1}^l (W^j \times b^j)}{\sum_{j=1}^l W^j} \quad (3.3)$$

식(3.2)의  $\mu_{A_1^j}(x_1^0)$ 은 퍼지 집합  $A_1^j$ 에 대한 멤버쉽 함수,  $\mu_{A_2^j}(x_2^0)$ 은 퍼지집합  $A_2^j$ 에 대한 멤버쉽 함수 또는 싱글톤실수치,  $W^j$ 를 입력  $(x_1^0, x_2^0)$ 의 규칙  $R^j$ 에 대한 적합도라 부른다.

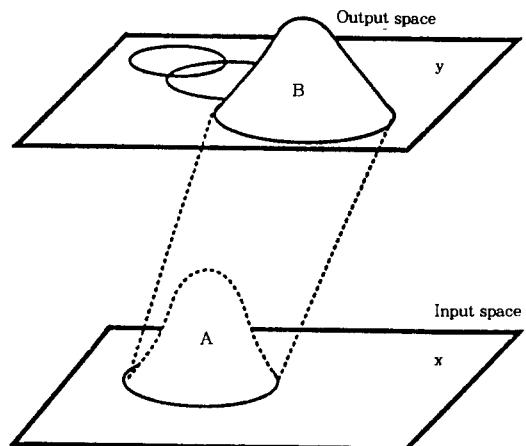


그림 3.1. 입력공간상의 퍼지클러스터  
Fig. 3.1. Fuzzy cluster in the input space

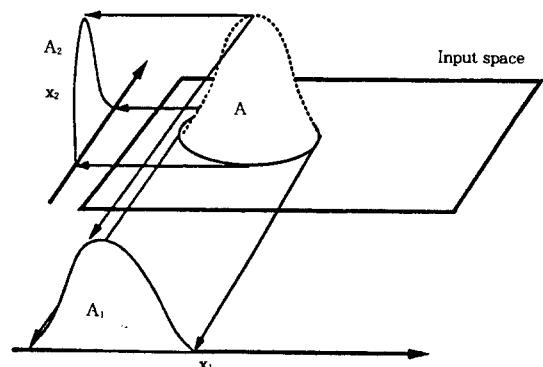


그림 3.2. 퍼지클러스터의 사영  
Fig. 3.2. Projection of a fuzzy cluster

은 양호한 모델이라고 하지는 않는다. 그러나, 일반적인 규범이 퍼지모델링에는 없고 구조동정에 관한 연구도 그 수가 적다. 본 연구의 구조동정에서 규칙 수는 클러스터의 변동을 이용한 평가지표가 국소 최소가 되는 후건부의 최적 분할수에서 두개의 입력 퍼지집합을 사영시키는 클러스터 집합이 어떤 것인지를 구하면 된다. 출력의 클러스터 집합과 그들에 대응하는 입력의 집합인 퍼지집합의 멤버쉽 함수는 그림 3.1과 같이 출력의 클러스터링에 의해 입력 공간상에 나타난다. 따라서 입력 퍼지집합의 멤버쉽 함수는 입력공간상에서 클러스터링 결과를 각 변수의 축 위에 사영하면 그림 3.2와 같이 입력변수의 축 위에 나타난다. 이와같이 1개의 클러스터에 대해서 각 입·출력변수의 1개 멤버쉽 함수가 사영결과로서 얻어지고, 각 변수의 멤버쉽 함수를 변수의 값으로 하는 1개의 규칙이 구성된다.

모델링 알고리즘의 개요는 다음과 같다.

1. 입·출력 조합의 데이터를 CMAC알고리즘을 이용하여 양·부를 결정한다.
2. 출력 데이터를 최적 분할수로 퍼지 클러스터링 한다.
3. 각 클러스터마다 클러스터링 결과를 각 입·출력변수 축 위에 사용하고 멤버쉽 함수를 구한다.
4. 모델을 평가하고, 입력 변수를 선택한다.

### 3.2 퍼지모델의 구조와 파라미터 동정

퍼지모델링은 일반 모델링과 달라서 전건부와 후건부로 된 규칙기준모델(rule based model)의 동정문제이다. 규칙의 구조동정은 전건부와 후건부의 동정으로 나눌 수 있으며, 전건부와 후건부동정은 구조동정과 파라미터 동정으로 구분한다.

본 논문에서 퍼지모델의 구조동정이라는 것은 변수의 선택과 그 변수가 걸쳐 있는 공간의 퍼지 분할을 말하는 것이고, 파라미터 동정은 퍼지 수의 파라미터를 결정하는 것이다. 단 2절에서 언급한 것과 같이 모델링의 전제 조건으로서 후건부의 변수선택은 사전에 되어 있다. 퍼지 모델에서도 규칙의 수를 증가시키면 모델의 예측오차는 일반적으로 적게되지만 규칙 수가 많은 모델

식(3.1)에서 표시한 퍼지 모델의 규칙은 다음과 같이 해석될 수 있다. 「출력  $y$ 가  $B$ 로 되는 것은 입력  $x_1$ 은  $A_{1j}$ 이고 입력  $x_2$ 가  $A_{2k}$ 인 경우이다」와 같은 규칙을 만들기 위해서는 출력치가 거의 같은 데이터들을 한 개의 클러스터로 만들어로 결정하고, 전건부의 변수는 모델의 예측오차의 평균치를 평가기준으로 한 변수선택 동정법을 이용하여 선택하였다. 본 연구에서는 파라미터동정을 간략화하기 위해서 멤버쉽함수를 사각형 퍼지변수로 근사화시켜서 응용하였다.

## 4. 전력부하 예측시스템설계

### 4.1 실측 데이터의 분석

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 외부온도, 일기예보에 의한 당일의 일기, 당일의 불쾌지수, 외부온도의 변화, 부하의 변화들이며 입력변수의 후

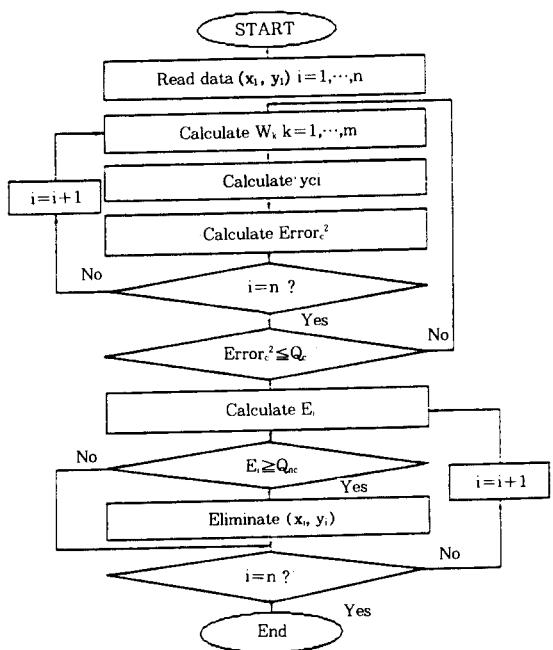


그림 4.1. 데이터 선택 알고리즘  
Fig. 4.1. Data selection algorithm

보선택을 위한 데이터분석을 한다. 데이터내용은 다음과 같다.

### 1) 데이터내용

- ①  $x_1$  : 계측할 때의 외부온도
- ②  $x_2$  : 일기예보에 의한 당일의(9, 12, 15시) 일기 쾌청=9에서부터 비=1까지
- ③  $x_3$  : 일기예보에 의한 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)(측정시간의 전력부하)
- ⑦  $y (=x_b(t+4))$  : 출력(측정시각으로부터 4시간 이후의 전력부하)

본 논문에서는 8월 한달동안의 월요일, 일요일, 토요일을 제외한 평일의 데이터를 이용하여 8월 중 평일의 전력부하를 예측하는 모델을 설계하고자 한다. 예측하고자 하는 출력은 측정시각

으로부터 4시간이후의 전력부하이다. 전력부하의 변동에 영향을 미치는 요인들에 대한 인간의 느낌이 시간의 자연을 갖고 나타나기 때문에 4시간 후의 부하를 측정하기 위해 측정시간으로부터 자연시간  $t \leq 4$ 까지의 변수가 부하의 변동과 상관이 있을 것으로 판단하여 입력변수의 후보배열에 포함시킨다.

### 4.2 입력변수의 선택

FCM을 이용한 퍼지모델링 방법에서는 출력변수는 선택되어 있는 것으로 하므로, 출력변수는 예측시각으로부터 4시간후의 전력부하  $x_6(t+4)$ 이다. 출력은 매일 비슷한 형태의 곡선을 그리고 있고 요일에 따라서 그 곡선의 기울기와 변화의 폭은 다르게 나타나고 있다. 그리고 시간변화에 따른 요인들의 분포곡선은 비선형적으로 나타나고 있다.

필요한 입력변수를 선택하기 위해서는 실측된

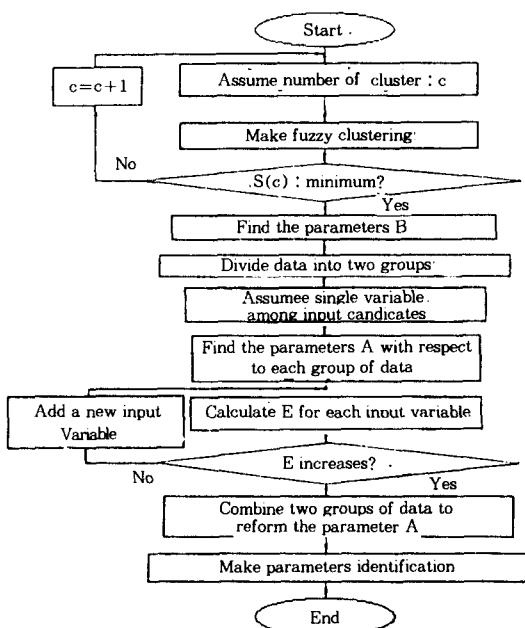


그림 4.2. 모델링 수순  
Fig. 4.2. Modeling Procedure

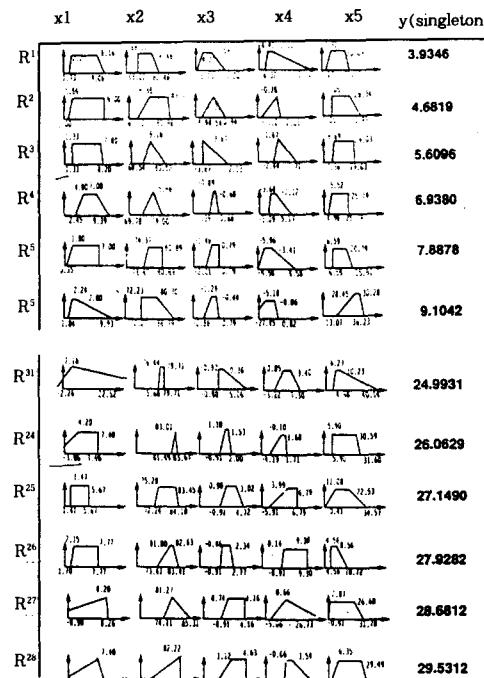


그림 4.3. 제안된 퍼지모델  
Fig. 4.3. Proposed fuzzy model

데이터로부터 전력부하에 인과관계를 갖는 가능한 모든 요인들을 후보변수로 선택한다. 부하의 변화에 대한 요인들의 영향은 시간적으로 지연을 갖고 나타나기 때문에 예측에 필요한 실제 데이터를 시간배열을 이용하여 입력변수의 후보로 선택했다. 시계열 상에서 입력변수는 각각  $x_N(t)$ ,  $x_N(t-1), \dots, x_N(t-4)$ ,  $N=1, 2, \dots, 6$ 이다(여기서  $N$ 은 변수의 갯수). 따라서 시계열 상태의 입력변수는  $6 \times 5 = 30$ 개가 된다. 그리고 데이터측정이 이산적이기 때문에 연속적이지 못함으로써 생기는 영향을 최소화하기 위하여 이동평균(Moving Average)를 취하여 입력변수로 선택하였다.

식(4.1)로 이동평균을 취한 입력변수의 수를  $N$ 이라고 하고 이동평균의 구간을 4시간으로 하였다.

$$MX_N(t) = \sum_{m=1}^N X_N(t-m)/4 \quad (4.1)$$

식(4-1)에 의해서 이동평균을 취한 입력변수는 5개로 시계열에 의한 변수를 합하면 전체입력변수의 후보수는 35개로 선택된다.

#### 4.3 전력부하예측 시스템의 모델링

다음은 전력부하예측시스템을 모델링하기 위한 페지모델링 알고리즘을 정리한다. 입·출력 공간은 입력변수를 35(시계열 데이터 30, 이동평균(Moving Average)데이터 5), 출력변수를  $x_6(t+4)$ 로 하여 페지모델링을 다음의 알고리즘에 의해 실시한다. CMAC에 의한 데이터의 양·부판별 알고리즘의 과정은 그림 4.1과 같고, 모델링 수행순서는 그림 4.2와 같다.

출력변수가  $x_6(t+4)$ 이고 후보입력변수가 시계열데이터 30개, 이동평균을 취한 5개의 변수를 합한 전체 35개를 입력변수로 하여 출력변수  $x_6$

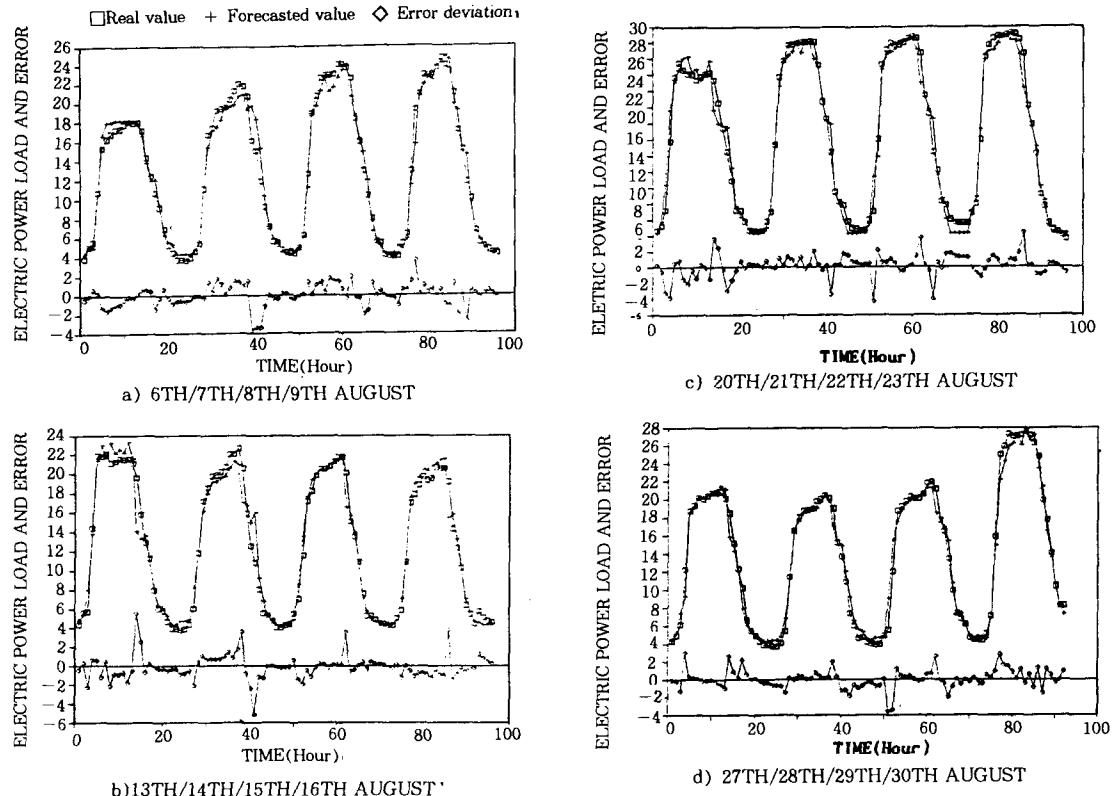


그림 4.4. 예측 결과와 오차 분포

Fig. 4.4. Forcasted Result and error distribution

(t+4)를 클러스터링하여 모델링하였다. 이때 제안된 알고리즘에 의해 모델링한 결과 선택된 입력변수는  $x_1=MX_2$ ,  $X_2=MX_3$ ,  $X_3=MX_5$ ,  $X_4=X_5$ ,  $X_5=X_6(t-4)$ 이다.

#### 4.4 전력부하의 예측

제안된 알고리즘의 타당성을 입증하기 위하여 최적지표를 이용하여 결정된 규칙수와 변수선택법에 의하여 선택된 입력변수를 갖는 모델에 대해서 실측데이터를 이용 예측하였다. 제안된 알고리즘에 의해 모델링된 예측모델은 그림 4.3과 같고 5개 변수와 28개의 규칙을 갖는다. 그 모델에 의한 예측값과 실제값을 주단위로 그리면 그림 4.4의 a), b), c), d)와 같다. 그리고 기존의 입력변수 선택방법과 비교하기 위해 이동평균을 취한 변수를 입력변수로 하고 규칙의 수는 제안된 방법과 같은 수를 가지고 퍼지모델링을 하여 같은 데이터로 예측하였다. 또한 참고로 최적의 규칙수가 아닌 몇가지 경우에도 적용하였다. 퍼지

표 4.1. 룰의 수에 대한 제안된 퍼지모델의 에러율  
Table 4.1. Error Rate of Proposed Fuzzy Model to rule Number

Number of input variable	Number of rule	Error rate
5	4	12.935
5	12	7.927%
5	20	6.718%
5	28	5.30 %
forecasting resule of linear method		11.0 %

표 4.2. 룰의 수에 대한 기존 퍼지모델의 에러율  
Table 4.2. Error Rate of Existing Fuzzy Model to Rule Number

Number of input variable	Number of rule	Error rate
5	4	13.146
5	12	8.606%
5	20	7.380%
5	28	5.929%
forecasting resule of linear method		11.0 %

모델의 규칙수가 4, 12, 20, 28인 경우 각각 예측값을 구하여 상대평가를 실시한 결과 상대오차가 표 4.1과 표 4.2와 같았다.

#### 5. 예측결과의 검토 및 고찰

전력부하의 예측결과에 의하면 오차율은 표 4.1과 표 4.2와 같다. 표 4.1, 표 4.2와 같이 제안된 알고리즘에 의해 설계된 모델의 예측결과는 기존의 입력변수의 선택방법에 의해 구성된 모델보다 정확도에서 변수의 선택방법과 클러스터링에 의한 모델링 방법이 개선된 사실을 확인할 수 있다.

35개의 입력변수 중에서 제안된 알고리즘에 의해 선택한 5개의 입력변수를 갖는 퍼지모델의 경우 임의로 선택한 모델의 경우보다 우수한 결과를 얻었다.

결과적으로 출력에 미치는 영향이 비교적 큰 변수를 선택하는 것이 보다 더 효과적임을 보여주고 그 결과가 타당함을 입증하고 있다.

규칙수에 따른 오차율은 그림 5.1과 같다. 규칙의 수를 증가시킴에 따른 오차율의 개선효과를

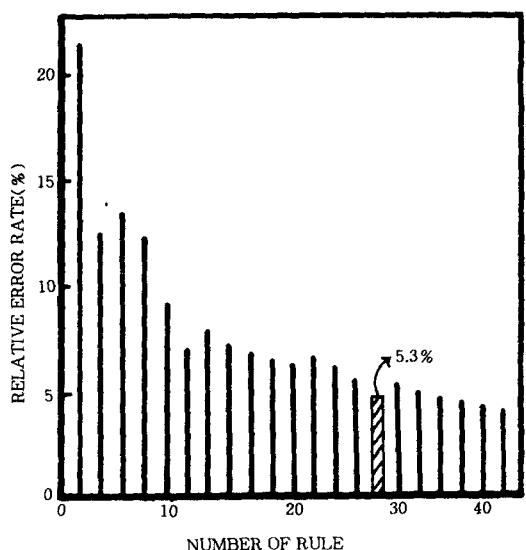


그림 5.1. 규칙 수에 따른 오차율  
Fig. 5.1. Error Distribution with respect to rule number

보면, 초기 12개의 규칙수까지는 현저하게 좋아지고 있지만 점차 수를 더 증가시키면 개선율은 점점 완만하게 되다가 28개 이후는 모델의 복잡도에 비해서 효과적이지 못함을 보여주고 있다. 따라서 본 논문에서 제안된 최적 규칙수 선택 알고리즘에 의해 선택된 28개의 규칙수가 효과적임을 보여준다.

그림 4.4는 제안된 모델의 예측결과에서 오차의 분포를 보면 최저치와 최고치부분에 고르게 분포되어 있고 상승부와 하강부의 곡선상에서 약간의 오차를 갖고 있지만 거의 매끄럽게 추적하고 있음을 볼 수 있다. 이것은 비선형적인 특성에 대한 퍼지모델링 방법의 적합성을 보여준다. 최고치 부분과 최저치 부근에서 오차율이 적게 나타나는 것은 데이터가 이부분에 상대적으로 많이 분포함으로서 규칙의 분포가 상대적으로 많기 때문이다. 따라서 규칙의 증가에 의해 상승부와 하강부에도 보상을 부분적으로 할 수 있다.

## 6. 결 론

본 연구에서 퍼지모델을 이용하여 전력부하를 예측하는 방법에 대해 연구한 결과는 다음과 같다.

1. 클러스터의 변동을 평가함수에 이용하여 최적 클러스터 수를 결정할 수 있는 지표를 제안함으로서 모델을 간략화하였다.

2. 데이터를 특성이 같은 두개의 그룹으로 나누어 각 그룹의 데이터로 설계된 모델에 대해 교차평가한 후에 두 모델의 평균자승 예측오차의 평균치를 평가기준으로 한 변수 증가법을 이용하여 입력변수를 선택할 수 있는 방법을 제안함으로서 모델구조를 간략화 하였다.

3. CMAC을 이용하여 데이터에 포함된 부정확한 데이터를 제거할 수 있는 알고리즘을 제안하여 모델링의 정확도를 개선하였다.

4. 제시된 방법을 평일의 전력부하 예측에 실제 적용하여 기존의 선형예측방법에 의한 상대오차 11.0%에 비해 5.3%로 개선된 결과를 얻어 본 연구의 타당성을 입증하였다.

5. 전력부하의 예측오차는 重부하시나 經부하

시 모두 고르게 분포되어 있어서 부하의 크기에 영향을 받지 않음을 알 수 있었고 중부하시에서 경부하시로 급격히 변하는 경우에 오차가 약간 큰 것을 알 수 있었다.

6. FCM을 이용하여 퍼지모델링을 한 결과 알고리즘이 간단해져 계산시간을 절약할 수 있었다.

따라서, 본 논문에서 제안된 방법을 적용하면 보다 쉽고, 간단하게 정확도가 높은 예측이 가능하므로, On-Line Modeling이 가능하며, 전력의 안정적인 공급과 경제적인 이용 그리고 시설 안정성을 유지하는데 유용하게 사용되리라 사료된다.

## 참 고 문 헌

- 1) M. T. Hagan, S.M. Behr, "The Time Series Approach to Short Term Load Forcasting," IEEE Trans. on PWRS, vol PWRS-2, no. 3, Aug. 1987, pp. 785~791.
- 2) R. Campo, P. Ruiz, "Adaptive Weather-Sensitive Short Term Load forecast", IEEE Trans. on Power Systems, Vol PWRS-2, No. 3, Aug 1987, pp. 175~185.
- 3) G.D. Irissari, S.E.Widergren P.D.Yehsakul, "On-Line Load Forecasting for Energy Control Center App.", IEEE Trans. on PAS, vol. PAS-1010, no.1, Jan. 1982.
- 4) 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, '90.
- 5) S.Rahman, R. Bhatnagar, "An Expert System Based Algorithm for Short Term Load Forcast", IEEE Trans. On PWRS vol. 3, no. 2, May 1988, pp. 392~399.
- 6) Y.I.Park, J.K.Park, "An Expert System for Short Term Load Forecasting by Fuzzy Decision", Korea-U.S.A. Joing Seminar on Expert Systems for Electric Power Systems, 1989, pp. 59~75.
- 7) 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-PWRS, IEEE -PES Summer Meeting, Minneapolis, MN, Jul. 1990.
- 8) 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.
- 9) R.Gunderson, "Application of Fuzzy ISODATA Algo-

- rithms to Star Tracker Pointing Systems", Proc. 7th Triennial World IFAC Congress, 1978, pp. 1319~1323.
- 10) 前田, 山中, "CAMA學習に 基づくオペレータの制御戰略を とする 障礙物回避制御, 第6會 システムシンポ

ジウム講演論文集", 1990, pp. 531~534.  
11) 김 이곤, 퍼지모델을 利用한 電力負荷豫測에 關한 研究, 全南大學校 博士學位論文, 1992.

◇ 著者紹介 ◇



김 이 곤 (金伊坤)

1955年 11月 11日生. 1985년 東亞大學  
校 電子工學科 卒. 1988年 韓國航空大  
學 大學院 航空電子工學科 卒(碩士).  
1993年 全南大學校 大學院 電氣工學  
科 卒(博士). 1992年 日本東京工大 客員研究員. 現在  
麗水水產大學校 講師.