

# 데이터 전처리를 이용한 다중 모델 퍼지 예측기의 설계 및 응용

論 文

58-1-27

## Design of Multiple Model Fuzzy Predictors using Data Preprocessing and its Application

方 寧 根\* · 李 哲 熙†  
(Young-Keun Bang · Chul-Heui Lee)

**Abstract** - It is difficult to predict non-stationary or chaotic time series which includes the drift and/or the non-linearity as well as uncertainty. To solve it, we propose an effective prediction method which adopts data preprocessing and multiple model TS fuzzy predictors combined with model selection mechanism. In data preprocessing procedure, the candidates of the optimal difference interval are determined based on the correlation analysis, and corresponding difference data sets are generated in order to use them as predictor input instead of the original ones because the difference data can stabilize the statistical characteristics of those time series and better reveals their implicit properties. Then, TS fuzzy predictors are constructed for multiple model bank, where k-means clustering algorithm is used for fuzzy partition of input space, and the least squares method is applied to parameter identification of fuzzy rules. Among the predictors in the model bank, the one which best minimizes the performance index is selected, and it is used for prediction thereafter. Finally, the error compensation procedure based on correlation analysis is added to improve the prediction accuracy. Some computer simulations are performed to verify the effectiveness of the proposed method.

**Key Words** : Non-stationary Time Series, Multiple Fuzzy Model, Data Preprocessing, Model Selection, Error Compensation

### 1. 서 론

시계열 데이터는 시간의 흐름에 따라 일정한 간격으로 관측하여 기록한 자료로 전력의 생산량이나 전력 수요(부하), 태양 흑점 변동, 지구의 기온 변화, 주가 지수, 환율 변화 등 다양한 분야에서 나타난다. 시계열 데이터의 특징은 자료가 관측된 순서에 따라 배열되며, 일반적으로 인접된 값들이 독립이 아니고 서로 종속적이라는 점이다. 시계열 데이터를 분석하는 주된 목적은 관측된 과거의 데이터로부터 특징적인 패턴을 규명하거나 일련의 규칙성을 발견하여 이를 모델링하고 모델링하여 미래에 대한 예측을 하고자 하는 것이다. 이러한 시계열의 분석은 데이터의 이면에 내재해 있는 여러 가지 확률적, 통계적 특성들을 파악하거나, 추세 성분, 순환 성분, 계절 변동 성분, 확률 변동 성분 등이 일부 또는 모두 포함되어 시계열 데이터가 생성되었다고 보고 이에 대한 모델을 개발함으로써 수행할 수 있다.

일반적으로 시계열 해석에는 AR(Auto-Regressive), MR(Moving Average), ARMA(Auto-Regressive Moving Average)와 같은 선형 회귀모델이나 Box-Jenkins 방법(Auto-Regressive Integrated Moving Average : ARIMA)

등이 널리 사용되고 있다[1-2]. 근래에는 이와 같은 선형적 접근 방법들로서 해결하지 못하는 문제점들을 극복하고자 퍼지이론, 신경망, 유전 알고리즘 등과 같은 soft computing 기법을 이용하여 시계열 데이터의 불확실성과 비선형 특성을 적절하게 취급할 수 있는 방법들에 대한 연구가 많이 이루어지고 있다[3-5].

그런데, 시계열 해석에 퍼지이론을 적용하는 기존 연구들의 대부분은 원 시계열을 그대로 사용하여 예측을 수행함으로써 정상(stationary) 시계열의 예측 문제에서는 좋은 결과를 보이지만 비정상(non-stationary) 시계열 예측의 경우 우수한 성능을 나타내지 못한다. 이는 비정상 시계열에서는 평균이나 분산 등과 같은 통계량이 시간의 흐름에 따라 지속적으로 변화되는 특성을 제대로 반영하지 못하고 있기 때문이다. 따라서 최근에는 적합한 모델을 구현하는 방법과 더불어 비정상 시계열 데이터를 좀 더 정상화시킴으로써 예측의 성능을 높이는 연구가 진행되고 있다. 비정상 시계열의 안정화 방법으로는 로그변환법이나 연속적인 차분을 이용할 수 있지만 로그 변환을 이용한 연구[6]에서는 분산의 안정성을 판별하기 위한 복잡한 연산 과정이 필요하다. 이에 반해 원 시계열 데이터의 1차 차분 데이터를 사용함으로써 평균을 안정화시키고 이를 통해 예측 성능을 높이는 방법이 제안되었으나[7], 1차 차분이 모든 비정상 시계열 데이터의 유동적 특성을 잘 표현해주는 것은 아니며, 또한 연속적인 차분은 분산과 상관성을 복잡하게 만드는 결과를 초래하게 되므로 이러한 문제에 대한 접근이 쉽지 않았다. 이에 대한 대안으로 우리는 데이터의 전처리와 모델 선택을 이용

† 교신저자, 正會員 : 江原大 電氣電子工學部 教授 · 工博  
E-mail : chlee@kangwon.ac.kr

\* 正 會 員 : 江原大 大學院 電氣電子工學科 博士課程  
接受日字 : 2008年 7月 31日  
最終完了 : 2008年 11月 17日

하여 과 차분으로 초래되는 분산의 증가나 상관성의 복잡성을 피하면서도 비정상 시계열 데이터의 특성 표현에 가장 적합한 최적의 차분 간격 값을 찾아서 시계열의 예측 모델에 입력으로 사용하는 방법을 제안한 바 있다[8].

본 논문에서는 [8]의 구조와 성능이 더욱 개선된 퍼지 시계열 예측 기법을 제안한다. 제안된 방법에서는 상관 해석에 기반하여 차분 간격 후보군이 적절히 선택될 수 있도록 하고, 시계열 발생 시스템의 모델링에 사용된 TS 퍼지 규칙 기반 생성에 k-means 알고리즘[9-10]을 적용하여 조건부 입력 공간의 퍼지 분할이 데이터에 최적화될 수 있도록 하였다. 또한 TS 퍼지 규칙 결론부에서 결정되는 예측 출력에 예측기 입력과 규칙 생성에 기여한 훈련 데이터들과의 상관 해석에 기반한 오차 보정 메커니즘을 추가함으로써 예측 성능을 더욱 향상시킬 수 있도록 하였다. 호주의 전력량 생산 데이터와 Mackey-Glass 시계열에 대해 시뮬레이션을 수행하여 제안된 방법의 효용성을 검증하였다. 제안된 방법은 시뮬레이션 결과에서 볼 수 있듯이 비정상 또는 혼돈(chaotic) 시계열과 같이 유동적 비선형성을 나타내는 시계열 데이터에 대해 양호한 예측 성능을 보인다.

## 2. 다중 모델 퍼지 예측기의 개요

일반적으로 퍼지 예측 시스템은 퍼지화기, 규칙기반, 추론 엔진, 비퍼지화기로 구성되며, 관측된 시계열 데이터 입력을 퍼지화한 뒤 사전 정보와 데이터로부터 도출된 언어적 퍼지 규칙 기반에 의거해 퍼지 추론을 수행하여 얻어진 결과를 비퍼지화함으로써 원하는 미래의 값을 예측하게 된다. 기존의 연구에서는 Mamdani 퍼지 모델을 많이 사용하였으나, Mamdani 모델의 경우 일반적으로 원하는 예측 정확도를 달성하기 위해서는 입출력 변수에 대한 퍼지 분할 영역(퍼지 집합)과 입력의 수가 많아야 하며, 데이터에 기반한 퍼지 규칙 도출이 까다롭고 복잡하다. 이에 반해 아래와 같은 형태의 규칙기반을 갖는 TS 퍼지 모델은 규칙의 조건부에는 퍼지 집합을 이용함으로써 데이터가 지니고 있는 불확실성이나 비선형성을 능동적으로 수용하면서도 결론부의 선형 수식을 통해 고전적인 선형 회귀 모델의 이점도 동시에 취할 수 있으며, 데이터 표현에 대한 적합성과 예측기 구현의 용이성도 피할 수 있다. 그러므로 본 논문에서는 TS 퍼지 모델을 채택하여 퍼지 시계열 예측 시스템을 구성하였다.

$$R: \text{If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } A_2 \text{ and } \dots \text{ and } x_n \text{ is } A_n \quad (1)$$

$$\text{Then } y = a_1 x_1 + a_2 x_2 + \dots + a_n x_n$$

TS 퍼지 모델은 주어진 사전 정보와 데이터로부터 규칙의 조건부에 사용되는 입력 공간의 퍼지 분할과 결론부 선형 수식의 파라미터를 식별하는 과정을 필요로 하게 된다. 입력 공간의 퍼지 분할에는 경험적 방법, 템플릿 기반 방법, clustering, 신경망 학습이나 유전 알고리즘을 이용한 최적화 등 여러 가지 방법을 적용할 수 있으나 본 논문에서는 k-means 알고리즘을 이용한 clustering 기법을 적용하여 데이터 표현에 대한 적합성을 향상시켰으며, 결론부 파라미터의 식별에는 가장 대표적인 최소 자승법(Least Squares Method)을 이용하여 파라미터 식별의 부정확성을 최소화하

도록 하였다. 자세한 설명은 4절에서 다루기로 한다.

한편, 서론에서 언급한 바와 같이, 유동적 비선형성을 갖는 시계열의 경우 원 시계열 데이터를 그대로 예측기 입력으로 사용할 경우 정확한 예측이 어려우므로, 평균이나 분산을 안정화시켜 데이터에 내재된 패턴이나 규칙성이 드러날 수 있도록 하는 것이 필요하다. 따라서 원 시계열 데이터의 차분을 사용하면 효과적이나, 이때 문제가 되는 것은 시계열의 패턴이나 규칙성을 가장 잘 뽑아낼 수 차분 간격이 얼마인지를 알 수 없다는 점이다. 이를 해결하기 위하여, 우리의 선행 연구[8]에서는 그림 1과 같이 훈련 데이터를 이용하여 고정된 하나의 차분 간격이 아니라 여러 개의 차분 간격에 대해 각각 퍼지 예측 모델을 수립하여 다중 모델을 구성하고 예측을 수행한 후, 그 중에서 예측 오차의 자승 평균(Mean Square Error : MSE)를 최소로 하는 모델을 최종적인 퍼지 시계열 예측 시스템으로 선택하도록 하였다. 실제 예측 동작 모드에서는 이렇게 선택된 하나의 퍼지 모델만이 예측을 수행한다.

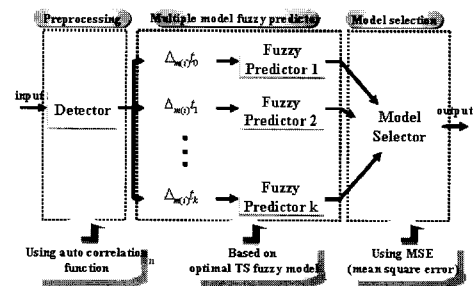


그림 1 다중모델 퍼지 예측기의 구조

Fig. 1 Structure of the proposed prediction system

그림 1에서 detector는 다중 모델 구성을 위한 차분 간격 후보군을 선택하는 기능을 담당하는데, 본 논문에서는 상관 해석[10]을 이용하여 이의 성능을 개선하였다. 이에 대한 자세한 설명은 3.1절에서 하기로 한다. 또한 그림 1의 각 퍼지 예측기에서 예측 수행시 발생하는 예측 오차를 적절하게 보상할 수만 있다면 예측 정확도가 향상될 것이나, 일반적으로 그 보상이 쉽지 않다. 제안된 방법에서는 예측기에 인가되는 차분 입력 쌍과 각 퍼지 규칙  $R_i$ 의 생성에 기여한 훈련 데이터들과의 교차 상관 계수를 이용하여 유사성을 판별하여 유사성이 가장 큰 훈련 데이터가 발생시키는 예측 오차를 이용하여 입력의 특성을 반영한 오차 보정이 이루어지도록 함으로써 상당한 정도로 예측 성능을 향상시켰다.

본 논문에서 제안하는 방법은 최적의 퍼지 시계열 예측기를 설계하기 위한 훈련 모드와 설계된 예측기를 이용하여 시계열 예측을 수행하는 동작 모드로 나누어지며, 따라서 주어진 시계열 데이터를 훈련 데이터와 검증 데이터의 두 그룹으로 나누어 사용하게 된다. 훈련 데이터는 초기 시계열 데이터 중에서 모든 TS 퍼지 모델의 퍼지 규칙 결론부의 파라미터 식별이 제대로 이루어질 수 있을 정도의 양을 선택한다. 제안된 방법의 전체적인 구성은 다음과 같으며, 그림 2는 제안된 알고리즘의 흐름도이다.

**훈련 모드**

- 1단계 : 데이터의 전처리에 의한 차분 간격 후보군 선정
- 2단계 : 각 차분 간격에 대해 TS 퍼지 규칙의 조건부 생성
- 3단계 : 최소자승법을 이용한 TS 퍼지 규칙의 결론부 파라미터 식별
- 4단계 : 구성된 퍼지 모델에 훈련 데이터를 예측 입력으로 사용하여 시계열 예측 수행
- 5단계 : 교차 상관 계수를 이용한 오차 보정값 결정
- 6단계 : 오차 보정에 의한 TS 퍼지 규칙의 결론부 변형
- 7단계 : 차분 간격 후보군에 대응하여 구성한 퍼지 예측 모델들 중 MSE가 최소인 모델 선택 → 설계 종료

**동작 모드**

- 8단계 : 선택된 예측 모델을 이용하여 시계열 예측 수행

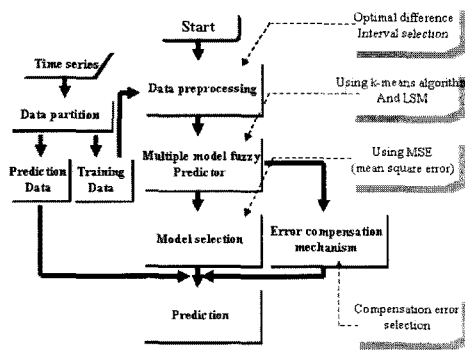


그림 2 제인된 다중모델 퍼지 예측기의 흐름도  
Fig. 2 Total flow chart of the proposed prediction system

**3. 데이터의 전처리 과정**

비정상 또는 숨어 있는 주기성이나 증가 추세와 같은 일련의 경향을 보이는 시계열의 경우 원 데이터를 그대로 퍼지 예측기의 입력으로 사용하기보다는 데이터의 차분 값을 사용하면 데이터의 유동적 비선형성 뒤에 내재된 패턴이나 규칙성이 예측 시스템에 잘 표착될 수 있으므로 예측 성능이 더 양호하다. 또한 평균이 안정된 차분 시계열은 TS 퍼지 모델의 결론부 선형 수식에 좀 더 적합하게 반영될 수 있다. 그런데, 데이터에 따라 특성을 잘 드러내어 줄 최적의 차분 간격이 달라지므로 그 후보군을 선별하는 것이 데이터의 전처리 과정이다. 훈련 모드에서는 상관 해석에 의거하여 높은 가능성을 지니는 다수의 차분 간격 후보군을 선정하고(데이터의 전처리), 각각에 대해 독립된 퍼지 예측 모델을 수립함으로써 다중 모델을 구성하여 일차적으로 예측을 수행한 뒤, 규정된 평가 지수를 최소화하는 모델을 실제 동작 모드에서 사용할 퍼지 시계열 예측 시스템으로 선정하게 된다(모델 선택). 동작 모드에서는 원 시계열 데이터로부터 선정된 차분 간격을 갖는 차분 데이터를 입력으로 사용하여 훈련 모드에서 선정된 최적 예측 모델에 의해 시계열 예측을 수행하게 된다. 먼저, 주어진 시계열 데이터 중 예측 모델을 구성하는데 어려움이 없을 정도의 적정 길이의 데이터를 훈련 데이터로 선정하여 다음과 같이 정의되는 자기 상관 계수를 구한다.

$$r_j = \frac{\sum_{i=1}^{N-j} (y(i) - \bar{y})(y(i+j) - \bar{y})}{\sum_{i=1}^N (y(i) - \bar{y})^2} \quad (2)$$

여기서,  $N$ 은 훈련 데이터의 길이이고,  $j$ 는 차분 간격 값이다. 또한,  $y(i)$ 는  $i$ 번째 훈련 데이터이며,  $\bar{y}$ 는 훈련 데이터의 평균이다. 구하여진 자기 상관 계수 값이 큰 것부터 작은 순서대로 나열한 뒤 인접한 두 상관 계수의 값의 차이가 가장 크게 나는 것에서 잘라 최적 차분 간격 값의 후보군으로 선정한다. 예를 들어, 다음과 같이 자기 상관 계수가 크기로 나열된다면

$$r_{m(1)} = 0.98, r_{m(2)} = 0.95, r_{m(3)} = 0.90, r_{m(4)} = 0.82, \\ r_{m(5)} = 0.61, r_{m(6)} = 0.54, r_{m(7)} = 0.43, r_{m(8)} = 0.36$$

여기서,  $r_{m(1)} - r_{m(5)} = 0.21$ 로 가장 큰 차이를 나타내므로 이를 기준으로  $r_{m(1)}, r_{m(2)}, r_{m(3)}, r_{m(4)}$ 의 4개의 상관 계수가 선택되고 이에 대응되는 차분 간격  $m(1), m(2), m(3), m(4)$ 가 최적 차분 간격의 후보군으로 선정된다. 차분 간격의 후보군이 선정되면, 퍼지 예측 모델에 입력으로 사용하기 위하여 이들 차분 간격들  $\{m(i)\}$ 에 대한 차분 값들을 훈련 데이터로부터 생성한다. 차분 간격  $m(i)$ 에 대해 시간  $t$  순간에 생성되는 차분 데이터는 다음과 같다.

$$\begin{aligned} \Delta_{m(i)}t_0 &= y(t) - y(t - m(i)) \\ \Delta_{m(i)}t_1 &= y(t-1) - y(t-1 - m(i)) \\ &\vdots \\ \Delta_{m(i)}t_n &= y(t-n) - y(t-n - m(i)) \\ &\vdots \\ \Delta_{m(i)}t_{m(i)-1} &= y(m(i)+1) - y(1) \end{aligned} \quad (3)$$

(3)에서 보면, 차분 간격 값  $m(i)$ 에 따라  $N$ 개의 훈련 데이터로부터 생성되는 차분 데이터의 수가 달라짐을 알 수 있다. 이는 유효한 데이터 값만을 이용하여 차분 데이터를 생성하기 위한 것으로  $y(n) = 0, n \leq 0$ 라는 가정을 배제하여 예측 과정에 그로 인한 편향(bias)이 생기는 것을 방지하는 효과를 가져다준다. 이렇게 생성된 각 차분 간격 값에 대한 차분 데이터들은 퍼지 예측기의 입력으로 사용되며, 또한 TS 퍼지 규칙 기반의 결론부 선형 수식 파라미터의 식별에 이용된다.

**4. 다중모델 퍼지 예측기 설계**

데이터의 전처리 과정에서 생성된 차분 데이터들을 입력으로 사용하여 예측을 수행하는 퍼지 예측기 모델로는 TS 퍼지 모델을 사용하였다. 왜냐하면, TS 퍼지 모델은 비교적 적은 수의 입력 변수와 입력 공간 퍼지 분할(퍼지 집합)을 가지고서도 시계열 발생 시스템을 적절히 기술할 수 있으며, 결론부의 선형 수식을 통해 선형 회귀 모델의 원리를 수용할 수 있으며, 또한 평균이 안정화된 차분 시계열을 사용함으로써 TS 퍼지 모델의 결론부 선형수식의 특성에 좀 더 잘 반영될 수 있기 때문이다. 본 논문에서는 예측기 구현의 용이성을 고려하여, 선정된  $k$ 개의 차분 간격  $m(i)$ 에 대해 예측이 수행되는 시간  $t$ 에서 가장 최근의 차분 데이터  $\Delta_{m(i)}t_0, \Delta_{m(i)}t_1, \Delta_{m(i)}t_2$ 의 3개를 입력 변수로 하고 이들에 대

해 각각 NB, NS, ZE, PS, PB의 5개 퍼지 집합으로 입력 공간을 퍼지 분할하였다. 따라서 차분 간격  $m(i)$ 에 해당하는  $i$  번째 TS 퍼지 예측 모델의 언어적 규칙은 다음과 같은 형태가 된다.


$$R_j: \text{if } \Delta_{m(i)}t_0 \text{ is } A_j \text{ and } \Delta_{m(i)}t_1 \text{ is } B_j \text{ and } \Delta_{m(i)}t_2 \text{ is } C_j \quad (4)$$

$$\text{then } \hat{\nabla}_t^j = \alpha_0^j \Delta_{m(i)}t_0 + \alpha_1^j \Delta_{m(i)}t_1 + \alpha_2^j \Delta_{m(i)}t_2$$


여기서 결론부의 출력은  $\hat{\nabla}_t^j = \hat{y}^j(t+p) - y(t)$ 로서 현재 순간의 데이터  $y(t)$ 와  $j$ 번째 규칙에 의해 결정되는 예측하고자 하는  $p$ 스텝 앞의 예측 값  $\hat{y}^j(t+p)$ 와의 차분 값이다. 다시 말해 과거와 현재의 데이터로부터 예측되는 미래 값의 증가분의 예측 값이다. (4)의 퍼지 규칙을 생성하려면, 규칙의 조건부에 사용되는 입력 공간의 퍼지 분할과 소속 함수 결정 및 결론부 선형 수식의 파라미터를 식별하는 것이 필요하다. 만약 퍼지 예측 시스템을 적용한 시계열 예측이 만족스럽지 못하거나 예측 정확도를 더 높이고자 한다면, 퍼지 규칙 (4)의 입력 변수와 이에 대한 퍼지 집합 수를 더 늘리면 된다. 그러나 그렇게 되면 조건부의 입력 공간 퍼지 분할과 소속 함수 결정이 복잡해지고 결론부의 식별해야 할 파라미터의 수도 늘어나서 예측기 구현이 훨씬 까다로울 뿐만 아니라, 더 많은 양의 훈련 데이터가 요구되므로 시계열 데이터의 수가 입력 변수와 퍼지 집합의 개수 선정에 제한 요소로 작용하게 된다. 따라서 본 논문에서는 시계열 예측 기법의 검증에 널리 활용되는 데이터들에 대해 입력 변수와 퍼지 집합의 개수를 바꾸어가며 시뮬레이션해서 이의 분석 결과를 토대로 요구되는 예측 성능을 충족시키면서 예측기 구현이 용이한 최저 수준으로 선정하였다.

4.1 입력 공간 퍼지 분할

퍼지 예측기의 입력 변수  $\Delta_{m(i)}t_0, \Delta_{m(i)}t_1, \Delta_{m(i)}t_2$ 에 대해 다음과 같이 퍼지 영역으로 분할한다. 먼저  $N$ 개의 훈련 데이터로부터 차분 간격  $m(i)$ 에 대해 생성된 차분 값  $\Delta_{m(i)}N_0, \dots, \Delta_{m(i)}N_{N-m(i)-1}$ 의 최소값과 최대값 사이를 퍼지 분할의 전체 영역(universe of discourse)으로 하고, 입력 변수 데이터에 대해 k-means 클러스터링 알고리즘을 이용하여 구한 클러스터 중심값을 삼각형 소속 함수의 중심값으로



(a) 퍼지 분할 예 (an example of fuzzy partitioning)



(b) 중심 값의 변화 (changes of center values for fuzzy sets)

그림 3 k-means 클러스터링을 이용한 퍼지 분할

Fig. 3 Fuzzy partitioning via the k-means clustering

채택하여 그림 3과 같이 NB, NS, ZE, PS, PB의 5개 퍼지 집합으로 분할하였다.

그림 3(b)는 k-means 알고리즘을 이용해 차분 데이터에 적합화시킨 소속 함수의 한 예로서, 클러스터링이 진행됨에 따라 소속 함수가 계속 바뀌는 것을 볼 수 있다. 이러한 입력 공간의 퍼지 분할은 다중 모델을 구성하는  $k$ 개의 퍼지 예측기 각각에 대해 독립적으로 수행된다. 각각의 퍼지 예측기마다 사용되는 차분 데이터가 다르므로 k-means 알고리즘에 의해 구해지는 퍼지 집합의 소속 함수도 당연히 달라진다. 그림 3과 같은 소속 함수에 대해서 퍼지 예측기의 입력 값이 A, F 구간에 위치할 경우에는 하나, B, C, D, E 구간에 위치할 경우에는 두 개의 퍼지 집합에 속하게 된다. 따라서 입력 값  $x$ 에 대한 소속 함수 값은 다음과 같이 구할 수 있다.

$$\begin{aligned} \text{A, F 구간} &: \mu_{NB}(x) \text{ or } \mu_{PB}(x) = 1 \\ \text{B, C, D, E 구간} &: \mu_L(x) = \frac{C_R - x}{C_R - C_L} \\ &: \mu_R(x) = \frac{x - C_L}{C_R - C_L} \end{aligned} \quad (5)$$

여기서  $\mu_L(x)$ 는 입력 값  $x$ 가 속한 구간의 왼쪽에 위치한 클러스터 중심값  $C_L$ 을 중심값으로 하는 퍼지 집합에 대한 소속 함수 값을 나타내며,  $\mu_R(x)$ 는 오른쪽에 위치한 클러스터 중심값  $C_R$ 을 중심값으로 하는 퍼지 집합에 대한 소속 함수 값을 나타낸다. 예를 들어, 그림 3(a)에서 입력 값이  $x = \Delta_{m(i)}t_1$ 인 경우  $C_L = \text{cluster3}$ ,  $C_R = \text{cluster4}$ 가 되고  $\mu_L(x) = \mu_{ZE}(x)$ ,  $\mu_R(x) = \mu_{PS}(x)$ 가 된다.

4.2 퍼지 규칙 생성

TS 퍼지 규칙의 조건부에 사용되는 입력 변수가 3개, 각 입력 변수에 대한 퍼지 집합이 각 5개씩이므로 이론적으로는  $5 \times 5 \times 5 = 125$ 개의 규칙이 생성 가능하지만, 입력으로 이용되는 차분 값들이 만족시키지 못하는 조건부를 갖는 퍼지 규칙의 결론부 파라미터를 식별하는 데에는 사용할 데이터가 없기 때문에 규칙의 생성이 불가능하다. 그러므로 본 논문에서는 훈련 데이터로부터 생성된 차분 값  $\Delta_{m(i)}N_0, \dots, \Delta_{m(i)}N_{N-m(i)-1}$ 가 만족시키는 조건부에 해당되는 규칙들만을 생성한다. 이것은 또한 입력 공간의 퍼지 분할 자체가 이들 차분 값에 의거해 이루어졌으며, 훈련 데이터를 제외한 나머지 시계열 데이터도 훈련 데이터와 동일한 특성을 갖는다는 전제하에 시계열 예측을 수행하는 것이므로, 이들 규칙만으로 시계열 예측이 가능하다고 간주할 수 있기 때문에 충분히 타당하다.

규칙의 생성에는 인접한 차분 값 3개가 한 쌍을 이루어 사용되며, 이 입력 쌍은 시간적으로 한 스텝씩 미끄러지며 계속 생성된다. 이는  $t$ 에서  $t+1$ 으로 시간 값이 1 증가함에 따라  $t+1$ 에서 새로 들어오는 차분 값  $\Delta_{m(i)}(t+1)_0$ 를 제외하면  $\Delta_{m(i)}(t+1)_1 = \Delta_{m(i)}t_0$ ,  $\Delta_{m(i)}(t+1)_2 = \Delta_{m(i)}t_1$ 이 된다는 사실을 이용한 것이다. 그러므로 전체 입력 쌍은

$$\{\Delta_{m(i)}N_{N-m(i)+1}, \Delta_{m(i)}N_{N-m(i)}, \Delta_{m(i)}N_{N-m(i)-1}\},$$

$$\{\Delta_{m(i)}N_{N-m(i)+2}, \Delta_{m(i)}N_{N-m(i)+1}, \Delta_{m(i)}N_{N-m(i)}\} \dots, \dots,$$

$$\{\Delta_{m(i)}N_1, \Delta_{m(i)}N_2, \Delta_{m(i)}N_3\}, \{\Delta_{m(i)}N_0, \Delta_{m(i)}N_1, \Delta_{m(i)}N_2\}$$

이 된다. 이 입력 쌍 하나하나에 대해 대응되는 규칙의 조건부를 생성하여 중복되는 규칙들은 제거하고 서로 다른 규칙들로 규칙 기반을 구성하면 된다. 그림 3에서 입력 쌍  $\{\Delta_{m(i)}t_0, \Delta_{m(i)}t_1, \Delta_{m(i)}t_2\}$ 의 경우를 살펴보자.  $\Delta_{m(i)}t_0$ 는 퍼지 집합 NS 또는 ZE에 속하고,  $\Delta_{m(i)}t_1$ 는 ZE 또는 PS에, 그리고  $\Delta_{m(i)}t_2$ 는 PS 또는 PB에 속하므로 이 입력 쌍에 대해서는 다음과 같이 8개의 규칙이 생성된다.

- $R_1$ : if  $\Delta_{m(i)}t_0$  is NS and  $\Delta_{m(i)}t_1$  is ZE and  $\Delta_{m(i)}t_2$  is PS then ~
- $R_2$ : if  $\Delta_{m(i)}t_0$  is NS and  $\Delta_{m(i)}t_1$  is ZE and  $\Delta_{m(i)}t_2$  is PB then ~
- $R_3$ : if  $\Delta_{m(i)}t_0$  is NS and  $\Delta_{m(i)}t_1$  is PS and  $\Delta_{m(i)}t_2$  is PS then ~
- $R_4$ : if  $\Delta_{m(i)}t_0$  is NS and  $\Delta_{m(i)}t_1$  is PS and  $\Delta_{m(i)}t_2$  is PB then ~
- $R_5$ : if  $\Delta_{m(i)}t_0$  is ZE and  $\Delta_{m(i)}t_1$  is ZE and  $\Delta_{m(i)}t_2$  is PS then ~
- $R_6$ : if  $\Delta_{m(i)}t_0$  is ZE and  $\Delta_{m(i)}t_1$  is ZE and  $\Delta_{m(i)}t_2$  is PB then ~
- $R_7$ : if  $\Delta_{m(i)}t_0$  is ZE and  $\Delta_{m(i)}t_1$  is PS and  $\Delta_{m(i)}t_2$  is PS then ~
- $R_8$ : if  $\Delta_{m(i)}t_0$  is ZE and  $\Delta_{m(i)}t_1$  is PS and  $\Delta_{m(i)}t_2$  is PB then ~

훈련 데이터로부터 만들어진 차분 값에서 취해진 모든 입력 쌍에 대해 이러한 방법으로 조건부를 생성하여 중복되는 규칙들은 제거하면 퍼지 예측 모델의 규칙 기반을 구성할 모든 퍼지 규칙들이 생성된다. 이러한 규칙 생성 작업은 입력 공간 퍼지 분할과 마찬가지로 다중 모델을 구성하는  $k$ 개의 퍼지 예측 모델 각각에 대해 독립적으로 수행된다.

### 4.3 퍼지 규칙 파라미터 식별

퍼지 규칙의 결론부의 선형 수식의 파라미터 식별에는 그 규칙의 조건부를 생성하는 모든 입력 쌍들을 데이터로 사용하게 되며, 본 논문에서는 파라미터 식별 기법으로 최적해를 제공하는 최소 자승법을 적용한다. 차분 간격  $m(i)$ 에 대한  $i$  번째 TS 퍼지 예측기의  $j$  번째 퍼지 규칙  $R_j$ 의 생성에 기여한 입력 쌍 데이터들이  $n$ 쌍이라면, 이들에 의한 결론부 선형 식은 다음과 같이  $n$ 개의 연립 방정식이 된다.

$$\begin{aligned} \widehat{\nabla}_{t_1}^j &= \alpha_0^j \Delta_{m(i)}t_1^j + \alpha_1^j \Delta_{m(i)}t_1^j + \alpha_2^j \Delta_{m(i)}t_1^j \\ \widehat{\nabla}_{t_2}^j &= \alpha_0^j \Delta_{m(i)}t_2^j + \alpha_1^j \Delta_{m(i)}t_2^j + \alpha_2^j \Delta_{m(i)}t_2^j \\ &\vdots \\ \widehat{\nabla}_{t_n}^j &= \alpha_0^j \Delta_{m(i)}t_n^j + \alpha_1^j \Delta_{m(i)}t_n^j + \alpha_2^j \Delta_{m(i)}t_n^j \end{aligned} \quad (7)$$

이를 벡터-행렬식으로 표현하면

$$\begin{bmatrix} \widehat{\nabla}_p^j(1) \\ \widehat{\nabla}_p^j(2) \\ \vdots \\ \widehat{\nabla}_p^j(n) \end{bmatrix} = \begin{bmatrix} \Delta_{m(i)}t_0^j(1) & \Delta_{m(i)}t_1^j(1) & \Delta_{m(i)}t_2^j(1) \\ \Delta_{m(i)}t_0^j(2) & \Delta_{m(i)}t_1^j(2) & \Delta_{m(i)}t_2^j(2) \\ \vdots & \vdots & \vdots \\ \Delta_{m(i)}t_0^j(n) & \Delta_{m(i)}t_1^j(n) & \Delta_{m(i)}t_2^j(n) \end{bmatrix} \begin{bmatrix} \alpha_0^j \\ \alpha_1^j \\ \alpha_2^j \end{bmatrix} \quad (8.a)$$

$$Y_j = X_j \Theta_j \quad (8.b)$$

여기서  $Y_j$ 는 출력 벡터,  $X_j$ 는 입력 데이터 행렬,  $\Theta_j$ 는 계수 벡터이다. 식(8.b)의 계수 벡터  $\Theta_j$ 는 최소 자승법을 이용하여 다음과 같이 구할 수 있다.

$$\widehat{\Theta}_j = (X_j^T X_j)^{-1} X_j^T Y_j \quad (9)$$

식(9)과 같이 데이터로부터 구한 추정 계수는 다음과 같이 정의되는 오차 파워의 합을 최소화하는 최적해이다.

$$E_j = (Y_j - X_j \widehat{\Theta}_j)^T (Y_j - X_j \widehat{\Theta}_j) \quad (10)$$

## 5. 오차 보정

파라미터 식별 과정에 의해 추정된 계수  $\widehat{\Theta}^j = [\widehat{\alpha}_0^j, \widehat{\alpha}_1^j, \widehat{\alpha}_2^j]$ 를 사용하여 입력 데이터로부터 예측을 수행할 때 발생하는 예측 오차를 적절하게 보상할 수 있다면 예측 정확도가 향상될 것이다. 그러나 예측 오차는 일반적으로 정규 분포 백색 잡음의 특성을 갖는 확률 프로세스가 되므로 그 보상이 쉽지 않다. 본 논문에서는 예측기 입력으로 원 시계열이 아니라 차분 값을 사용하고 예측 값의 결정에 TS 퍼지 규칙을 사용하기 때문에, 유사한 예측 패턴을 보이는 데이터들을 동질 집단으로 구분(즉 같은 규칙  $R_j$ 을 만족시키는 데이터 그룹으로 분류)할 수 있으며, 같은 예측 규칙( $R_j$ ) 하에서 각 데이터의 개별적인 예측 정확도를 살펴볼 수 있다. 이러한 점을 이용하여 다음과 같은 원리로 입력 데이터에 적합한 오차 보정을 수행한다. 예측을 위해 인가되는 입력 쌍이 만족시키는 퍼지 규칙  $R_j$ 의 생성에 기여한 훈련 데이터들 중에서 입력 쌍과 가장 유사한 특성의 훈련 데이터를 찾아서 그 훈련 데이터의 경우에 발생된 예측 오차만큼을 보정한다면 완벽하지는 않을지라도 아주 상당한 정도로 예측 오차를 줄일 수 있을 것이다. 입력 쌍과 규칙  $R_j$ 의 생성에 기여한 훈련 데이터들의 유사성을 판별하는 방법으로는 교차 상관 계수를 이용한 상관성 분석을 사용한다.

예측을 위한 입력 쌍  $X_i = [\Delta_{m(i)}t_0, \Delta_{m(i)}t_1, \Delta_{m(i)}t_2]$ 와 훈련 데이터  $T_n = [\Delta_{m(i)}n_0, \Delta_{m(i)}n_1, \Delta_{m(i)}n_2]$ 의 교차 상관 계수  $\rho_{XT}$ 는 다음과 같이 정의된다.

$$\rho_{XT} = \frac{C_{XT}}{\sqrt{C_{XX}} \sqrt{C_{TT}}} \quad (11)$$

여기서  $C_{XX}$ 는  $X_i$ 의 공분산,  $C_{TT}$ 는  $T_n$ 의 공분산, 그리고  $C_{XT}$ 는  $X_i$ 와  $T_n$ 의 교차 공분산으로서,  $X_i$ 의 평균을  $\bar{X}_i$ ,  $T_n$ 의 평균을  $\bar{T}_n$ 이라고 하면 다음과 같이 계산된다.

$$C_{XX} = \sum_{i=0}^2 (\Delta_{m(i)}t_i - \bar{X}_i)^2 \quad (12)$$

$$C_{TT} = \sum_{i=0}^2 (\Delta_{m(i)}n_i - \bar{T}_n)^2 \quad (13)$$

$$C_{XT} = \sum_{i=0}^2 (\Delta_{m(i)}t_i - \bar{X}_i)(\Delta_{m(i)}n_i - \bar{T}_n) \quad (14)$$

식(12)의 교차 상관 계수는  $-1 \leq \rho_{XT} \leq 1$ 이고,  $|\rho_{XT}|=0$ 이면 무상관을 의미하며,  $|\rho_{XT}|=1$ 이면 완전한 선형 관계를 의미하게 된다. 그러므로 교차 상관 계수의 크기가 클수록 입력 쌍과 훈련 데이터 간의 유사성이 크다고 볼 수 있으므로

퍼지 규칙  $R_j$ 의 생성에 기여한 훈련 데이터들 중 입력 쌍과의 교차 상관 계수가 가장 큰 훈련 데이터에 의해 발생하는 예측 오차를 선택하여 오차 보정 값  $e_i^j$ 로 사용한다. 그러면, 입력 쌍  $X_i$ 에 대해 퍼지 규칙  $R_j$ 의 결론부에 의한 출력은 다음과 같이 계산된다.

$$\widehat{\nabla}_i^j = \widehat{a}_0^j A_{m(i)}t_0 + \widehat{a}_1^j A_{m(i)}t_1 + \widehat{a}_2^j A_{m(i)}t_2 + \widehat{e}_i^j \quad (15)$$

이때 최대 교차 상관 계수가 미리 설정한 임계치 이하일 경우에는 두 데이터 간의 유사성이 존재하지 않는 것으로 간주하여 오차 보정을 하지 않는다.

총  $q$ 개의 퍼지 규칙을 갖는 퍼지 예측기의 입력 쌍  $X_i$ 에 대한 출력  $\widehat{\nabla}_i$ 은 각각의 규칙  $R_j$ 의 조건부에서 결정되는 적합도  $\mu_j$ 와 결론부에서 (15)을 이용하여 결정된  $\widehat{\nabla}_i^j$ 로부터 다음과 같이 가중 합으로 구해진다.

$$\widehat{\nabla}(t) = \frac{\sum_{i=1}^q \mu_i \widehat{\nabla}_i^j}{\sum_{i=1}^q \mu_i} \quad (16)$$

퍼지 예측기의 출력  $\widehat{\nabla}_i$ 은 시간  $t$ 에서 예측된 미래 값의 증가분이므로 원하는 시계열의 예측 값  $\widehat{y}(t+p)$ 는 다음과 같이 구할 수 있다.

$$\widehat{y}(t+p) = y(t) + \widehat{\nabla}(t) \quad (17)$$

### 6. 예측 모델 선택

데이터의 전처리 과정에서 선정된 차분 간격의 수가  $k$ 개 라면, 각각에 상응하는 퍼지 예측기를  $k$ 개 병렬로 구성하여 생성된 차분 데이터를 입력으로 인가하여 예측을 수행한다. 그런 뒤에 각각의 퍼지 예측기에 대해 다음과 같이 정의되는 자승 오차 평균(Mean Squared Error : MSE)를 구하게 된다.

$$MSE = \frac{1}{N-m(i)} \sum_{n=m(i)+1}^N (y(n) - \widehat{y}(n))^2 \quad (18)$$

여기서,  $\widehat{y}(n)$ 은 퍼지 예측기에서 출력한  $y(n)$ 의 예측 값이며, 차분 간격  $m(i)$ 인 퍼지 예측기 모델에서는 예측에 사용되는 차분 데이터가  $N-m(i)$ 개이므로 위와 같이 평균이 구해진다. 이렇게 구해진  $k$ 개의 MSE 중에서 가장 작은 값을 갖는 예측기를 최종적으로 예측 동작 모드에서 사용할 퍼지 예측기 모델로 결정한다.


### 7. 컴퓨터 시뮬레이션 및 검토

제안된 기법의 유효성을 검증하기 위하여 컴퓨터 시뮬레이션을 수행하였다. 시뮬레이션 예로는 비정상 및 혼돈 비선형 특성을 갖는 대표적인 시계열 데이터를 선택하여 예측 결과를 분석, 검토해보고 기존의 연구 결과들과 성능을 비교하였다.

첫 번째 사례는 분기별 호주의 전력생산량[11]을 예측한 것으로 전체 155개의 데이터 중 70개는 훈련 데이터, 그 나머지는 검증 데이터로 활용하였으며, 성능을 비교 분석하기 위한 지표로는 다음과 같이 정의되는 상대 오차 평균(Mean Relative Error : MRE)을 사용하였다.

$$MRE = \frac{1}{N} \sum_{i=1}^N \left( \frac{|y(i) - \widehat{y}(i)|}{|y(i)|} \times 100 \right) \% \quad (19)$$


시뮬레이션은 본 논문에서 제안한 방법과 원 시계열 데이터를 직접 사용하여 동일한 구조와 방식으로 구성된 TS 퍼지 예측기를 이용한 경우에 대해 각각 오차 보정이 있는 경우와 오차 보정이 없는 경우의 두 가지로 수행하였다. 그림 4는 원 시계열 데이터에 대한 오차 보정이 없는 TS 퍼지 예측 모델의 시뮬레이션 결과로서, (a)에서 검은색은 원 시계열 데이터, 파란색은 예측 값인데, 검증 데이터 구간에서 정확한 예측이 이루어지지 않고 있음을 볼 수 있으며, 따라서 예측 오차도 비교적 큰 값을 가짐을 (b)에서 확인할 수 있다. 그림 5는 제안된 방법(오차 보정 포함)에 의한 시뮬레이션 결과로서, 양호한 예측이 이루어져서 예측 오차도 상당히 감소하였음을 볼 수 있다.



(a) using original time series (b) prediction error

그림 4 호주의 전력생산량 예측 결과(오차보정 ×)

Fig. 4 Results of simulation 1 (error compensation ×)



(a) using difference data (b) prediction error

그림 5 호주의 전력 생산량 예측결과(오차 보정 ○)

Fig. 5 Results of simulation 1 (error compensation ○)

아래의 표 1은 MRE를 이용하여 각각의 시뮬레이션 결과의 성능을 비교한 것으로 제안된 방법이 MRE=1.6992로 가장 좋은 성능을 나타냄을 볼 수 있다. 표에서 보면, 원 시계열을 이용하는 것보다 제안된 방법과 같이 데이터의 전처리 과정을 통해 최적 간격의 차분 데이터를 선정하여 예측을 수행 하는 것이 성능이 더 좋으며, 같은 예측기에 대해서는 오차 보정이 있는 경우가 없는 경우보다 양호한 예측 성능을 보임을 알 수 있다.

표 1 호주 데이터 예측 성능 비교

Table 1 comparison of two prediction performance

	원 시계열 사용 TS 퍼지 예측기		전처리 및 모델 선택 TS 퍼지 예측기	
	오차 보정 ×	오차 보정 ○	오차 보정 ×	오차 보정 ○
MRE	4.2899	4.1324	2.1720	1.6992
최적 차분간격	-	-	8	8

표 2는 동일한 사례에 대해 soft computing을 이용한 기존의 연구 결과들[4-5][7][12]과 본 논문에서 제안된 방법의 예측 성능을 비교한 것으로 진하게 표시된 부분이 제안된 방법의 성능이며, 이들 중 가장 최근에 제안된 GA-RS 방식보다도 예측 성능이 우수함을 볼 수 있다.

표 2 기존기법들과의 성능 비교

Table 2 comparison of our method with other methods

	Mamdani 퍼지 모델	다중 퍼지 모델	Fuzzy AR	GA-RS 방식	제안된 방법
MRE	7.8123	2.7125	3.1254	1.81	1.6992

두 번째 시뮬레이션 예는 혼돈 비선형 시계열 예측에 자주 이용되는 Mackey-Glass 시계열 데이터로서 다음과 같이 정의되는 수식으로부터 발생된다.

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t) \quad (20)$$

위 식의 파라미터 값으로  $a=0.2$ ,  $b=0.1$ ,  $\tau=17$ 을 사용하였다. 데이터는  $x(124)$ 부터  $x(1123)$ 까지 1000개의 데이터를 추출하여 500개의 데이터를 훈련 데이터로, 나머지를 검증 데이터로 하고, 제안된 방법에 대해 오차 보정이 있고 없는 두 가지 경우에 대해 시뮬레이션을 수행하였다. 두 경우 모두 최적 차분 간격은 1로 선정되었다. 그림 6은 오차 보정이 없는 경우의 시뮬레이션 결과로서, (a)에서 검은색이 원 시계열 데이터, 파란색이 예측 값이며, (b)는 예측 오차를 나타낸다. 그림에서 보듯이, 데이터의 전처리를 통해 최적 차분 간격 데이터를 이용하여 예측을 수행하게 되면 오차 보정이 없더라도 비교적 양호한 예측이 이루어짐을 알 수 있다.





그림 6 Mackey-Glass 시계열 예측 결과(오차보정 ×)  
Fig. 6 Results of simulation 2 (error compensation ×)

그림 7은 오차 보정이 있는 경우의 시뮬레이션 결과로서, 그림 6과 비교할 때 예측 오차가 더욱 감소하였음을 알 수 있다.



(a) using difference data (b)prediction error  
그림 7 Mackey-Glass 시계열 예측 결과(오차보정 ○)  
Fig. 7 Results of simulation 2 (error compensation ○)

이 시계열 예측에 대해 성능 평가 지표로는 다음과 같이 정의되는 RMSE(Root Mean Squared Error)를 사용한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y(i) - \hat{y}(i))^2} \quad (21)$$

오차 보정이 없는 경우에는  $RMSE=0.0112$ , 오차 보정이 있는 경우에는  $RMSE=0.0085$ 로서 오차 보정이 있는 경우가 더 좋은 예측 성능을 보임을 확인하였다. 표 3은 이 시계열 예측에 대해 Wang과 Mendel의 방법[13], MCM-1과 MCM-2[14]와 제안된 방법의 성능을 비교한 것으로서 제안된 방법이 훨씬 적은 수의 입력 공간 퍼지 분할 영역(퍼지 집합)으로도 더 나은 예측 성능을 보임을 알 수 있다.

표 3 기존 기법들과의 성능 비교

Table 3 Comparison of our method with other methods

퍼지 집합 수	RMSE			
	WANG	MCM-1	MCM-2	제안된 방법
5	-	-	-	0.0085
7	0.0372	0.0374	0.0340	-
11	0.0253	0.0265	0.0235	-
15	0.0191	0.0197	0.0187	-
19	0.0161	0.0162	0.0159	-
23	0.0135	0.0142	0.0131	-
27	0.0115	0.0115	0.0113	-
31	0.0108	0.0108	0.0105	-

이상의 시뮬레이션 결과에서 보듯이, 제안된 방법은 데이터 전처리와 모델 선택을 이용해 시계열의 내재된 특성을 가장 잘 표출할 수 있는 차분 간격 데이터를 예측 입력으로 사용하여 예측을 수행함으로써 비정상 또는 혼돈 비선형성을 갖는 시계열 데이터에 대한 예측 성능이 대폭 향상되었으며, 오차 보정 메커니즘에 의해 예측 정확도를 더욱 증가시킬 수 있음을 알 수 있다.

## 8. 결 론

유동적 비선형 특성을 보이는 비정상 또는 혼돈 시계열에 대한 정확한 예측은 쉽지 않으며, 원 시계열 데이터를 그대로 입력으로 사용할 경우 대부분 동작 조건이나 시간에 따라 변화하는 시계열의 특성을 제대로 반영하지 못하여 우수한 성능을 나타내지 못한다. 이를 해결하기 위하여, 본 논문에서는 상관 해석에 기반한 데이터의 전처리를 통해 적절한

최적 차분 간격 후보군을 선정하고 이들 각각에 대한 TS 퍼지 예측기로 다중 모델을 구성하여 성능 지수 평가에 의해 최적의 차분 간격과 퍼지 예측기를 최종적으로 시계열 예측 모델로 선택하는 방법을 제안하였다. TS 퍼지 예측기의 규칙 생성에는 k-means 클러스터링을 이용한 조건부 입력 공간 퍼지 분할과 최소 자승법에 의한 결론부 파라미터 식별을 통해 데이터 기술 적합도가 뛰어난 규칙이 생성될 수 있도록 하였다. 또한 TS 퍼지 규칙 결론부에서 결정되는 예측 출력에 예측기 입력과 규칙 생성에 기여한 훈련 데이터들과의 상관 해석에 기반한 오차 보정 매커니즘을 추가함으로써 예측 성능을 더욱 향상시킬 수 있도록 하였다. 제안된 방법의 유효성을 검증하기 위하여 수행한 호주의 전력량 생산 데이터와 Mackey-Glass 시계열에 대한 시뮬레이션 결과는 예상대로 까다로운 시계열 예측 문제에 대해서도 좋은 예측 성능을 보이며 기존의 연구 결과들에 비해 개선된 예측 성능을 가짐을 나타내고 있다. 그러므로 제안된 방법은 비정상 또는 혼돈 시계열과 같이 유동적 비선형성을 나타내는 시계열 데이터 예측에 매우 유용하게 사용될 수 있을 것으로 기대된다. 향후 연구 과제로는 설계를 위한 훈련 모드에서만 아니라 예측 동작 모드에서도 다중 모델에 의해 시간에 따라 데이터의 주요 특성이 변화하는 감지하고 이에 맞추어 최적의 예측기를 선정하여 예측을 수행하는 적응 기법과 오차 보정 매커니즘의 복잡성을 줄이면서도 효율적인 오차 보정이 이루어질 수 있는 방법에 대한 연구가 필요할 것으로 사료된다.

**감사의 글**

본 과제(결과물)는 지식경제부의 지원으로 수행한 에너지 자원 인력 양성사업의 연구결과입니다.

**참 고 문 헌**

[1] George E. P. Box and Gwilym M. Jenkins, Time series analysis: Forecasting and Control, Holden-Day, 1970.  
 [2] George J. Klir and Bo Yuan, Fuzzy Sets and Fuzzy Logic Theory and Applications, Prentice-Hall, 1995  
 [3] Juhong Nie, "Nonlinear Time-Series Forecasting: A Fuzzy Neural Approach", Neuro computing, vol.16, pp.66-76, MacMaster University, 1997  
 [4] K.Ozawa, T.Niimura, "Fuzzy Time-Series Model of Electric Power Consumption", IEEE Canadian conference on Electrical and Computer Engineering, pp.1195-1198, 1999  
 [5] Daijin Kim, Chulhyun Kim, "Forecasting Time Series with Genetic Fuzzy Predictor Ensemble". IEEE Trans. on Fuzzy Systems, vol. 5, pp.523-535, 1997  
 [6] O.Valenzuela, I.Rojas, F.Rojas, H.Pomares, L.J.Herrera, A.Guillen, L.Marquez. M.Pasadas, "Hybridization of Intelligent techniques and ARIMA models for time series prediction", vol. 159, pp. 821-845, April 2008  
 [7] Inteak Kim, Song-Rock Lee, "A Fuzzy Time Series

Prediction Method based on Consecutive Values", IEEE International Fuzzy Systems, vol.2, pp.703-707, 1999

[8] Chul-Heui Lee, Sang-Hun Yoon, "Fuzzy Nonlinear Time Series Forecasting with Data Preprocessing and Model Selection", Journal of Telecommunications and Information, vol.5, pp.232-238, 2001  
 [9] Carl G. Looney, "Pattern Recognition using Neural Networks", Oxford University Press, 1997  
 [10] Stephen J. Redmond, Conor Heneghan, " A method for initialising the K-means clustering algorithm using kd-trees", pattern recognition letters, vol. 28, pp. 965-973, 2007  
 [11] 김해경, 김태수, 시계열 분석과 예측 이론, 문운당, 2003  
 [12] <http://www-personal.buseco.monash.edu.au/>  
 [13] 주용석, 유전알고리즘과 러프집합을 이용한 퍼지 시스템 모델링, 강원대학교 석사학위논문, 2003  
 [14] L. X. Wang, J. M. Mendel, "Generating fuzzy rules from numerical data, with applications", IEEE Trans. on Systems, Man, and Cybern, 22 No.6, pp1414-1427, 1992  
 [15] 김인택, 공창욱, "시계열 예측을 위한 퍼지 학습 알고리즘", 한국 퍼지 지능시스템 학회, vol.7, No.3, pp. 34-42, 1997

**저 자 소 개**



**방 영 근 (方 寧 根)**

1974년 7월 4일생. 2000년 삼척대학교 졸업(학사). 2001~2003년 동대학교 전기공학과 졸업(석사). 2004년~현재 강원대학교(춘천) 전기전자공학과 박사과정  
 E-mail : b2y2c1@hanmail.net



**이 철 희 (李 哲 熙)**

1959년 7월 4일생. 1983년 서울대학교 전기공학과 졸업(학사). 1989년 동 대학원 전기공학과 졸업(공학박사). 1990년~현재 강원대학교 전기전자공학부 교수  
 관심분야: Intelligent System & Soft computing 제어 및 신호처리  
 E-mail : chlee@kangwon.ac.kr