

시계열 예측을 위한 퍼지 학습 알고리즘

Fuzzy Learning Algorithms for Time Series Prediction

김 인 택*, 공 창 욱*
Intaek Kim*, Changwook Kong*

요 약

본 논문은 새로운 퍼지 규칙의 생성을 위한 학습 알고리즘과 시계열 예측에의 응용을 다루고 있다. 데이터에서 IF-THEN문 형태의 퍼지 규칙을 생성시키는 과정에서 동일한 전건부(IF문)에 대해 상이한 후건부(THEN문)가 생겨 모순된 규칙을 형성시키는 경향이 있다. 수정된 중심값 방법(Modified Center Method)으로 명명된 새로운 알고리즘은 이와 같은 모순된 규칙의 형성을 효과적으로 해결하여, 시계열 예측을 수행하는데 그 오차를 줄일 수 있다. 알고리즘의 효과를 살펴보기 위해 Mackey-Glass time series와 Gas Furnace data 분석에 적용하였다.

ABSTRACT

This paper presents new fuzzy learning algorithms and their applications to time series prediction. During generating fuzzy rules from numerical data, there is a tendency to produce conflicting rules which have same premise but different consequence. To resolve the problem, we propose MCM(Modified Center Method) which is proven to reduce the error in the prediction. We have applied MCM to the analysis of Mackey-Glass time series and Gas Furnace data to verify its efficiency.

I. 서 론

시계열(Time Series)은 주기적으로 측정된 값들의 나열을 의미한다. 이러한 시계열의 예로 매일 평균 기온, 매 10분마다 측정된 신호 대기 차량의 수, 3월 정오의 서울시 전력 소모량, 일일 주가 지수, 특정 시스템의 이산 출력값, 야구장 입장객 수 등등 이루 헤아릴 수 없이 많이 있다. 여기서 값들의 순서(Order)가 매우 중요한 의미를 가지는데 이는 시계열의 발생 원에 대한 정보를 포함하기 때문이다. 특히 시계열 중

연속된 또는 특정 주기를 가지는 값 사이에는 얼마간의 종속성이 발견되는데, 이런 성격에 근거하여 시계열의 발생원을 몇 가지 측면에서 분석할 수 있다. Weigend와 Gershenfeld[1]에 의하면 시계열의 분석을 예측(Prediction), 모델링(Modeling), 그리고 특성화(Characterization) 등으로 분류하였다. 예측은 과거의 데이터를 토대로 짧은 시간 동안 시스템의 변천을 알아내는 것인데 비해, 모델링은 주어진 시스템의 장기적인 경향을 알아내는 것이라고 설명하고 있다. 그러므로 예측을 위한 모델이 장기적인 경향을 반영하지 않을 수 있으며, 마찬가지로 모델링도 단기간 예측에 적절하지 않을 수도 있다고 볼 수 있다. 한편 시계열

*명지대학교 제어계측공학과

의 특성화는 시계열이 가진 신호의 특징을 파악하는 작업으로, 예를 들어 일반화된 차원(Generalized Dimension)[2]의 값 등을 토대로 수행될 수 있다. 시계열의 분석은 앞에서 언급한 바와 같이 경제와 사업 기획, 주가예측, 기후예측, 생산계획 및 재고정리, 물리학, 공학 등 매우 많은 분야에서 이용되고 있는데 이는 우리가 얻는 시계열을 위에서 언급한 예측이나 모델링 등을 통해 분석이 가능하기 때문이다. 즉, 시계열의 발생원은 어느 정도의 결정론적인 동력학 시스템(Deterministic Dynamic System)에 의해 지배를 받는다고 볼 수 있기 때문이다.

과거의 시계열 분석방법은 주로 선형 모델, 즉 ARMA(Autoregressive-Moving Average) Process, Power Spectrum 등에 의존한 경우가 대부분이었다[3][4]. 그런데 이러한 선형 모델로는 비선형성이 포함된 대부분의 시계열을 분석하는데 있어 많은 문제점을 가지고 있다. 1980년대 말부터 학계의 관심을 끌었던 신경회로망 또는 퍼지논리와 같은 연산지능(Computational Intelligence) 알고리즘의 등장으로 비선형적인 데이터의 해석에 어느 정도 그 실마리가 풀어지기 시작했다고 볼 수 있다[1]. 시계열 분석을 위한 신경회로망[5][6]과 퍼지논리[7][8]의 적용은 신경회로망 구조가 지닌 비선형성의 포용과 퍼지규칙에 내재하는 비선형성으로 인하여 가능하게 되었다. 이와 같이 신경회로망과 퍼지 논리로 대표되는 지능 연산 알고리즘은 범용 근사기(Universal Approximator)[9][10]의 역할을 수행한다는 것은 널리 알려졌다.

퍼지논리는 과거 수년간 연산 지능 또는 지능 제어의 패라다임으로 많은 관심과 성공을 거두어 왔다. 일반적으로 퍼지 개념은 불명확(Ambiguous)하고 모호한(Vague) 환경에서 지식의 표현을 쉽게 할 수 있기 때문에 수학적 모델이 불가능하거나 수학적으로, 표현되기 힘든 시스템, 또는 비선형적인 시스템에 적용이 용이하다.

퍼지논리를 적용한 모델링과 예측은 과거부터 많은 연구가 수행되었던 문제이다. 1980년에 Tong[11]은 실험 데이터로부터 퍼지 모델을 얻고, 이를 위한 평가방법을 제안하였다. 이들은 모델을 복잡성, 정확성, 그리고 불확실성의 측면에서 모델들의 성능을 평가하였다. Pedrycz[12]는 퍼지이론을 사용하여 비결정론적인 시스템의 인식(Identification)에 적용하였다. 좀

더 근래에 Wang[7]은 새로운 학습 알고리즘을 제안했는데, 본 논문에서 다루려는 문제와 유사하다. 데이터를 학습할 경우, 전건부의 개수가 적으면, 모순된 학습이 발생할 수 있다. 즉, 동일한 전건부에 대해 다른 후건부의 규칙이 생기는 경우가 발생하여 이에 대한 해결이 요구된다. Jang과 Sun[13]은 그들이 제안했던 ANFIS(Adaptive Network-based Fuzzy Inference System)을 이용하여 시계열 예측에 적용하였다. 예로 Mackey-Glass time series를 16개의 퍼지 규칙으로 구현하였으나 실제의 구현은 일반적인 퍼지 추론의 그것보다 훨씬 더 복잡한 문제점을 가지고 있다.

본 논문에서는 퍼지 논리에 의한 시계열의 분석을 위한 새로운 학습 알고리즘; Max_Min 방법과 수정된 중심값 방법(Modified Center Method)를 제안하여 그 성능을 살펴본다. 성능의 척도로 RMSE(Root Mean Square Error)를 사용하였으며, 사용된 표준데이터는 Mackey-Glass time series와 Box, Jenkins의 Gas Furnace data[4]를 사용하였다.

본 논문의 구성은 다음과 같다. 제 II장에서는 새로운 추론 방법을 제안하여 예제를 통해 설명하였다. 제 III장에서는 몇 가지의 예측을 설정하여 Mackey-Glass time series에 적용하여 예측을 수행하였으며, Gas Furnace data를 통해 학습후 퍼지 추론에 의한 재현을 살펴보았다. 마지막 장에서는 본 논문의 결론을 요약하고 향후 과제를 간단하게 요약하였다.

II. 퍼지 추론 방법의 제안

퍼지 추론 시스템은 추론 엔진(Inference Engine)으로 아래와 같은 형태의 퍼지 규칙을 가진다.

R: if x_1 is A and x_2 is B, ... x_n is C, then x_{n+1} is D.

여기서 if 이하의 전건부(premise)는 규칙의 조건부에 해당하며, then 이하는 후건부(consequence)로 규칙의 작용부를 의미한다. 본 논문에서 다루고자 하는 시계열 $x_1, x_2, \dots, x_n, x_{n+1}$ 은 퍼지 언어 변수(Fuzzy Linguistic Variables)이며 A, B, C, ... D 등은 퍼지 언어값(Fuzzy Linguistic Values)으로 표현한다. 따라서 시계열의 예측은 아래의 식 (1)을 만족하는 퍼지 규칙 R을 찾아내는 작업이다.

$$\hat{x}_{n+k} = R(x_1, x_2, \dots, x_n) \quad (1)$$

위의 식에서 우리가 가지고 있는 데이터는 x_1, x_2, \dots, x_n 이며 k 시간만큼 후의 값인 x_{n+k} 를 예측하고자 한다. 따라서 이는 open loop 예측으로 예측된 결과가 다시 추론 시스템의 입력으로 들어가는 close loop 예측과는 달리 에러가 적지만 매우 단시간의 예측만 가능하다.

퍼지 규칙을 만드는 작업은 아래와 같이 매우 간단하다:

(1) 시계열 값 x 가 가질 수 있는 범위를 퍼지 언어값에 의해 p 개로 구분한다.

(2) 각 시계열 값에 해당하는 퍼지 언어값을 부여하여 식(1)의 퍼지 규칙 R 을 생성시킨다.

여기서 문제가 되는 것은 식(1)에서 n 이 적은 값을 가질 때, 동일한 전건부에 대해 상이한 후건부를 가진 모순된 규칙(Conflicting Rules)이 발생한다. 예를 들어 $n=2$ 일 때, 서로 다른 시계열 구간에서 아래와 같은 규칙들을 얻었다고 가정하자.

$$R_i: \text{if } x_1 \text{ is } A \text{ and } x_2 \text{ is } B, \text{ then } x_3 \text{ is } C. \quad (2-1)$$

$$R_k: \text{if } x_1 \text{ is } A \text{ and } x_2 \text{ is } B, \text{ then } x_3 \text{ is } D. \quad (2-2)$$

이와 같이 모순된 규칙들이 한 개의 퍼지 규칙 집합에 속해 추론 시스템으로서의 역할을 할 수 없으므로 두 규칙 사이의 적절한 타협이 요구된다. 이를 해결하기 위한 방법으로 Wang[7]은 각각의 언어 변수가 가지는 소속함수값(Degree of Membership Function)의 곱을 이용하여 유효한 규칙을 선택하였다. 본 논문에서는 새로운 3 가지 방법을 제안하여 Wang의 결과와 비교하고자 한다.

2.1 Max_Min 방법

Wang의 방법[7]은 앞의 예의 식 (2)에서 $(\mu_A(x_1) \times \mu_B(x_2) \times \mu_C(x_3))$ 와 $(\mu_A(x'_1) \times \mu_B(x'_2) \times \mu_C(x'_3))$ 의 값을 비교 선택하여 큰 값을 가진 쪽을 추론 시스템의 퍼지 규칙으로 사용하였다. 이는 어떤 특정 시계열 값이 특정 퍼지 언어값에 속하는 정도가 큰 쪽을 선택한다는 의도를 가지고 있다. 즉 곱이 큰 쪽의 규칙이 더 전건부의 조건과 후건부의 출력에 충실하다고 보기 때문이다. 이와 유사한 방법으로 이 절에서 제안하고자

하는 Max_Min 방법은 모순된 규칙의 소속함수값(위 식(2)에서는 세 개의 값이 존재) 중 최소값을 선택하여(Max_Min) 비교한 후 그 최소값이 큰 쪽(Max_Min)을 규칙으로 선택하는 방법이다. 이 방법에 대한 명확한 이해는 아래의 예에서 쉽게 알 수 있다.

<예제 1> 시계열의 어떤 구간에서 얻은 3 개의 데이터의 소속함수값이 각각 0.6, 0.8, 0.9로 각각 퍼지 언어값 A, B, C 영역에 속함을 알았다(2-1). 그러나 다른 구간의 3 개 데이터를 살펴본 결과 소속함수값이 각각 0.7, 0.7, 0.7로 각각 퍼지 언어값 A, B, D영역에 있을 경우(2-2)를 가정하자. Wang의 방법에 의하면 각각의 곱이 $0.432(=0.6 \times 0.8 \times 0.9)$ 와 $0.343(=0.7 \times 0.7 \times 0.7)$ 이므로 두 개의 모순된 규칙 중에서 (2-1)을 유효한 퍼지 규칙으로 사용한다. 그러나 본 절에서 제안한 Max_Min 방법에서는 첫 번째 데이터에서 얻은 최소값이 0.6, 다른 데이터에서 얻은 최소값은 0.7이므로 두 번째의 규칙에 해당되는 (2-2)를 퍼지 규칙으로 정한다.

2.2 수정된 중심값 방법 1 (Modified Center Method 1)

앞의 Max_Min 방법은 모두 미리 정해진 수의 소속함수를 이용하여 전건부와 후건부에 사용하였다. 시계열 데이터가 가지는 값들이 균등하지 않게 분포한 경우, 고정된 소속함수의 사용은 추론과정에서 실제값과 예측값의 차이를 발생하는 요인이 될 수 있다. 이는 퍼지 언어값이 동일한 입력에 대한 상이한 몇 개의 출력중 하나만을 선택함으로써 선택되지 않은 퍼지 규칙은 무의미해지기 때문이다. 따라서 이와 같은 문제점을 줄이기 위한 노력으로, 이 절에서는 수정된 중심값 방법이라 명명된 방법으로 새로운 퍼지 언어값을 부여한다. 학습도중에 앞의 예제 1에서와 같이 두 개의 모순된 규칙이 생기면, 상이한 출력 소속함수의 중심값을 아래와 같은 방법으로 구할 수 있다.

$$y(E) = \frac{M \times y(C) + N \times y(D)}{M + N} \quad (3)$$

여기서 $y()$ 는 해당 퍼지 언어값의 중심값을 의미하고, M 은 앞의 규칙(2-1)에서의 각 시계열이 A, B, C라는 퍼지 소속함수에 속하는 정도의 값인 (μ_A, μ_B, μ_C) 중

최소값을 의미한다. N도 마찬가지로 다른 시계열의 구간에서 얻은 규칙(2-2)에서 얻은 소속함수값의 최소값을 표시한다.

〈예제 2〉 앞의 예제 1의 경우를 가정하자. 퍼지 언어값 C를 가진 소속함수의 중심값이 y(C)라면 퍼지 언어값 D에 해당하는 중심값은 y(D)이다. 그러므로 수정된 중심값 방법 1에 의한 새로운 출력 소속함수의 중심값 y(E)는 $(0.6 \times y(C) + 0.7 \times y(D)) / (0.6 + 0.7)$ 임을 알 수 있다.

위의 식(3)은 모순된 규칙의 수가 다수일 때 아래와 같이 일반적인 표현이 가능하다.

$$y(E) = \frac{\sum w_i y(L_i)}{\sum w_i} \quad (4)$$

여기서 w_i 는 퍼지소속 값의 최소값을 의미하고 L_i 는 해당 출력 퍼지 언어값이다. 이 방법으로 시계열을 학습하다보면 학습초기에는 입력과 동일했던 출력 소속함수가 모순된 규칙들의 발생으로 인해, 새로운 출력 소속함수의 형성을 살펴볼 수 있다. 결론적으로 출력 소속함수의 개수는 추론을 위한 퍼지 규칙의 수와 동일해짐을 알 수 있다.

2.3 수정된 중심값 방법 2 (Modified Center Method 2)

출력 소속함수의 중심값을 변화시킬 수 있는 또 다른 방법(수정된 중심값 방법 2)으로 앞의 식(3)에서 설명한 M과 N값을 Wang이 사용한 곱을 이용하여 얻는다. 이와 같은 경우도 퍼지 규칙에 사용되는 출력 소속함수의 개수는 앞의 절에서 설명했던 방법과 동일하다.

〈예제 3〉 다시 예제 1의 경우를 가정하자. 수정된 중심값 방법 2에 의한 새로운 퍼지 언어값 E의 중심값은 $(0.432 \times y(C) + 0.343 \times y(D)) / (0.432 + 0.343)$ 임을 알 수 있다.

따라서 이 방법에 의한 일반적인 표현은 식 (4)과 동일하다. 단 여기서 계수가 Max_Min이 아닌 곱의 값을 가진다.

III. 시계열 예측에의 응용

본 장에서는 앞에서 제안된 방법들을 Mackey-Glass time series와 Gas-Furnace data에 적용하여 그 타당성을 살펴본다. 시뮬레이션을 위해 아래의 알고리즘들을 사용한다.

- (a) Wang과 Mendel이 제안한 알고리즘[7] (WANG)
- (b) MAX_MIN방법을 적용한 알고리즘 (MAX_MIN)
- (c) 수정된 중심값 방법 1 (MCM-1)
- (d) 수정된 중심값 방법 2 (MCM-2)

3.1 Mackey-Glass Time Series

Mackey-Glass(MG) time series는 예측 알고리즘의 성능 평가를 위한 대표적인 예제로 사용되는 시계열이다[7, 8]. 특히 MG time series는 예정된(Deterministic) 비선형 시스템으로부터 발생하는 카오스 신호의 일종으로 신호의 복잡성으로 인해 마치 랜덤 시계열(Random Time Series)처럼 보일 수 있으나 다음의 식과 같은 비선형 동력학 방정식에 의해 생성된다.

$$\frac{dx(t)}{dt} = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (5)$$

위의 식 (5)에서 초기치 $x(0)$ 는 1.2로, 시간지연 상수(Time Delay Constant) τ 는 17로 놓고 $x(t)$ 를 발생시킨다. 데이터 발생초기에는 과도 영역(Transient Region)이 존재하므로, $x(124)$ 부터 $x(1123)$ 까지 1000개의 데이터를 시뮬레이션을 위해 데이터로 추출하였다. 그림 1은 본 시뮬레이션에 사용된 1000개의 데이터를 보여준다.

퍼지 규칙의 학습을 위해 $x(124)$ 부터 $x(623)$ 까지 500개의 시계열 데이터를 사용하였고, 예측 성능의 평가를 위해 $x(624)$ 부터 $x(1123)$ 까지 500개의 시계열 데이터를 예측치와 비교하였다. 예측 알고리즘의 성능에 중요한 영향을 미치는 입력 퍼지영역 소속함수의 개수를 7, 11, 15, 19, 23, 27, 31과 같이 7가지 경우에 대하여 실험하였다.

본 논문에서는 아래와 같은 세 가지의 시뮬레이션에서 제안한 방법을 사용하여 각각의 퍼지 규칙들을 얻었다.

(시뮬레이션 1) 과거 두 개의 데이터로 한 스텝 앞의 데이터 예측

$$\hat{x}(t+1) = F(x(t), x(t-1))$$

(시뮬레이션 2) 과거 아홉 개의 데이터로 한 스텝 앞의 데이터 예측[7]

$$\hat{x}(t+1) = F(x(t), x(t-1), \dots, x(t-8))$$

(시뮬레이션 3) 과거 네 개의 데이터로 여섯 스텝 앞의 데이터 예측[8]

$$\hat{x}(t+6) = F(x(t), x(t-6), x(t-12), x(t-18))$$

시뮬레이션 1과 시뮬레이션 2는 한 스텝 앞의 데이터를 예측하기 위해 두 개와 아홉 개의 과거 데이터를 이용하는데 반해, 시뮬레이션 3은 여섯 스텝 앞의 데이터를 예측하기 위해 여섯 스텝 간격으로 네 개의 과거 데이터를 사용하였다. 직관적으로 시뮬레이션 2가 시뮬레이션 1보다 더 나은 결과(적은 에러)를 가져 오리라 예상할 수 있다.

시뮬레이션의 예측 성능을 평가하기 위해, 아래의 식 (2)의 RMSE(Root Mean Squared Error)를 구하였다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x(i) - \hat{x}(i))^2} \quad (6)$$

시뮬레이션 1에서 MCM-1을 적용한 결과(입력 퍼지영역은 19개)를 그림 2에서 살펴볼 수 있으며, 학습 과정에서 발생된 출력 퍼지 소속함수가 수정된 중심 값 방법에 따라 이동된 후의 모습은 그림 3, 그리고 실제치와 예측치의 오차를 그림 4에 나타냈다. 다른 방법들에 대한 시뮬레이션의 결과가 표 1과 그림 5에 있다. 그림 5의 가로축의 값 i 는 입력 퍼지 소속함수의 수($4i + 3$)를 의미한다. 그림 6과 7의 가로축의 값도 동일한 의미를 가진다. 시뮬레이션 2의 결과는 표 2와 그림 6, 그리고 시뮬레이션 3의 결과는 표 3과 그림 7에서 알 수 있다.

시뮬레이션 1과 2의 에러를 분석하면 WANG, MCM-2의 방법이 MAX_MIN, MCM-1의 방법보다 매우 적은 차이로 나은 결과를 보여준다(그림 5과 6 참조). 시뮬레이션 3에서는 입력 퍼지 소속함수의 개수가 증가할수록 앞의 두 가지 방법(WANG, MAX_MIN)보다 MCM-1, MCM-2 등의 방법이 나은 결과를 가져 온다.




그림 1. Mackey-Glass 시계열
Fig. 1 Mackey-Glass time series




그림 2. 예측 결과(실선-실제치, 점선-예측치)
Fig. 2 Prediction result(solid-real value, dashed-predicted value)




그림 3. 수정된 입출력 퍼지영역 소속함수
Fig. 3 Modified IN/OUT fuzzy region membership function




그림 4. 실제치와 예측치의 오차
Fig. 4 Error between real value and predicted value

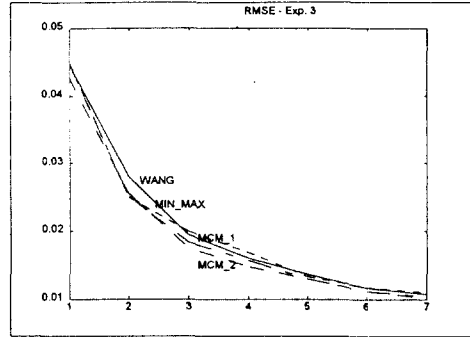


그림 7. 시뮬레이션 3에서의 오차(RMSE) 비교
Fig. 7 Comparison of error(RMSE) for simulation 3




그림 5. 시뮬레이션 1에서의 오차(RMSE) 비교
Fig. 5 Comparison of error(RMSE) for simulation 1

표 1. 예측 오차(시뮬레이션 1)
Table 1. Prediction error(simulation 1)

입력 소속함수 개수	RMSE			
	WANG	MAX_ MIN	MCM-1	MCM-2
7	0.0351	0.0389	0.0389	0.0350
11	0.0332	0.0368	0.0367	0.0327
15	0.0271	0.0315	0.0297	0.0258
19	0.0215	0.0267	0.0231	0.0202
23	0.0184	0.0178	0.0174	0.0168
27	0.0129	0.0137	0.0139	0.0129
31	0.0129	0.0137	0.0123	0.0114




그림 6. 시뮬레이션 2에서의 오차(RMSE) 비교
Fig. 6 Comparison of error(RMSE) for simulation 2

표 2. 예측 오차(시뮬레이션 2)
Table 2. Prediction Error(simulation 2)

입력 소속함수 개수	RMSE			
	WANG	MAX_ MIN	MCM-1	MCM-2
7	0.0372	0.0401	0.0374	0.0340
11	0.0253	0.0273	0.0265	0.0235
15	0.0191	0.0198	0.0197	0.0187
19	0.0161	0.0163	0.0162	0.0159
23	0.0135	0.0146	0.0142	0.0131
27	0.0115	0.0118	0.0115	0.0113
31	0.0108	0.0108	0.0108	0.0105

표 3. 예측 오차(시뮬레이션 3)

Table 3. Prediction error(simulation 3)

입력 소속함수 개수	RMSE			
	WANG	MAX_ MIN	MCM-1	MCM-2
7	0.0447	0.0451	0.0448	0.0427
11	0.0280	0.0250	0.0251	0.0255
15	0.0194	0.0199	0.0183	0.0175
19	0.0160	0.0168	0.0156	0.0147
23	0.0137	0.0133	0.0130	0.0130
27	0.0117	0.0118	0.0112	0.0112
31	0.0107	0.0109	0.0104	0.0101

3.2 Gas Furnace Data

앞 절에서 수행했던 4 가지의 방법을 잘 알려진 Box 와 Jenkins의 Gas Furnace data의 재현에 적용하였다. 본 데이터는 296쌍의 입출력으로 이루어졌으며 입력 (x)는 Gas의 흐름을 나타내고 출력(y)은 연소 기체에 포함되어 있는 이산화탄소의 농도를 나타낸다. 모델링을 위해 많은 연구에서 주로 사용되는 아래의 식 (7)을 사용한다.

$$\hat{y}(t) = F(y(t-1), x(t-4)) \tag{7}$$

즉 현재의 이산화탄소의 농도는 한 샘플시간 전의 그것과 네 샘플시간 전의 Gas의 흐름에 의해 지배받는다. 모델링의 오차를 측정하기 위해 RMSE로 각 알고리즘의 성능을 비교하였다.

1부터 296까지 296개의 데이터로 학습하여 퍼지규칙을 생성하고, 다시 학습구간에 대하여 재현을 시켰다. 그림 8와 9을 실제치와 예측치의 비교 및 오차를 보여준다. 앞 장에서 제안한 수정된 중간값 방법을 적용한 MCM-1과 MCM-2가 WANG이나 MAX_MIN 알고리즘보다 그림 11에서 비교했듯이 적은 에러를 보여 주었다.

그림 10에서는 출력 퍼지 소속함수의 중심값 이동 결과가 히스토그램이 밀집된 부분에 유사하게 분포되고 있어 재현이 좀 더 정확히 이루어질 수 있음을 확인할 수 있다.




그림 8. Gas Furnace data 예측결과 (실선-실제치, 점선-예측치)

Fig. 8 Prediction result for Gas Furnace data




그림 9. 실제치 예측치의 오차

Fig. 9 Error between real value and predicted value

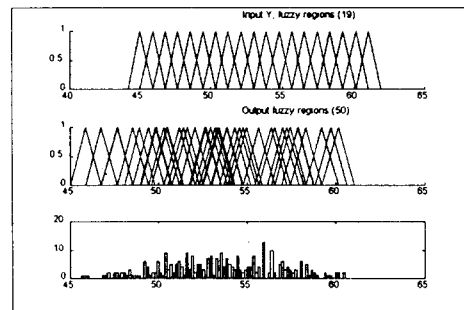


그림 10. 입출력 퍼지영역 함수와 히스토그램

Fig. 10 IN/OUT fuzzy region membership function and histogram




그림 11. 오차 비교(RMSE)
Fig. 11 Comparison of error(RMSE)

IV. 결론 및 향후 과제

본 논문에서는 예측을 위한 퍼지 추론 시스템의 학습방법에 대한 몇 가지의 알고리즘들, MAX_MIN, MCM-1, MCM-2 등을 제안하여 기존의 방법과 비교해 보았다.

시뮬레이션 결과는 출력 퍼지 소속함수를 개선시킨 MCM-1, MCM-2의 경우가 더 나은 결과를 가져왔다. 이는 다른 두 가지 방법들(WANG, MAX_MIN)이 학습과정에서 발생되는 모순된 규칙을 처리할 때, 그들 중 취사선택하므로 정보의 일부를 잃어버리는 경향이 있다. 이에 비해 수정된 중심값을 적용한 방법들(MCM-1, MCM-2)은 취사선택이라기 보다는 모순된 규칙들간의 적절한 조화를 추구하므로 정보의 유실이 비교적 적은 학습방법이라 할 수 있다. 이와 같은 방법은 궁극적으로 출력 소속함수의 중심값이 이동하여 그 소속함수의 개수가 증가하기 마련이다. 그러나 이러한 소속함수 증가는 추론 시스템을 구성하는데 있어 크게 부담을 주는 것이 아니므로 예측 및 재현의 오차가 적어지는 경향은 매우 큰 장점이라 할 수 있다.

향후 과제로서 수정된 중심값을 통해 출력 소속함수 뿐만 아니라 입력 소속함수도 개선할 수 있는 여지가 남아 있는데, 이와 같은 방법을 도입하면 더 나은 예측 및 재현이 이루어질 것으로 예상된다. 이러한 학습 방법은 시계열 분석에 국한된 것이 아니라, 퍼


지 논리가 적용가능한 일반적인 응용문제에서, 퍼지 규칙을 형성하는 효과적인 방법이 되리라 판단된다.

참고 문헌

1. Andreas S. Weigend and Neil A. Gershenfeld, ed., *Time Series Prediction*, Addison Wesley, 1994.
2. H.G.E. Hentschel and I. Procaccia, "The Infinite Number of Generalized Dimensions of Fractals and Strange Attractors.", *Physica D* 8: pp. 435-444, 1983.
3. G. Janacek and L. Swift, *TIME SERIES Forecasting, Simulation, Applications*, Ellis Horwood, 1993.
4. G.E.P. Box and F.M. Jenkins, *Time Series Analysis : Forecasting and Control*, 2nd ed. Holden-Day, 1976.
5. E.R. Wan, "Time Series Prediction by Using a Connectionist Network with Internal Delay Lines," in Andreas S. Weigend and Neil A. Gershenfeld, ed., *Time Series Prediction*, Addison Wesley, 1994.
6. O. Mohammed, D. Park, R. Merchant, T. Dinh, C. Tong, A. Azeem, J. Farah, C. Drake, "Practical Experiences with An Adaptive Neural Network Short-Term Load Forecasting System", *IEEE Trans. on Power Systems*, 10, no. 1, pp. 254-262, 1995.
7. L.X. Wang and J.M. Mendel, "Generating fuzzy rules from numerical data, with applications," *IEEE Trans. on Systems, Man, and Cybern.*, 22 no. 6, pp. 1414-1427, 1992.
8. I. Kim and S. Lee, "Chaotic Time Series Prediction," *3rd International Conf. on Fuzzy Logic, Neural Nets and Soft Computing*, pp. 525-526, 1994.
9. L.X. Wang, "Fuzzy systems are universal approximators," *Proc. IEEE International Conf. on Fuzzy Systems*, pp. 1163-1170, 1992.
10. K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators," *Neural Network*, vol. 2, pp. 359-366, 1989.
11. R.M. Tong, "The Evaluation of Fuzzy Models

derived from Experimental Data," *Fuzzy Sets and Systems*, vol. 4, pp. 1-12, 1980.

12. W. Pedrycz, *Fuzzy Control and Fuzzy Systems*, John Wiley & Sons Inc., 1989.
13. 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.



김 인 택(Intaek Kim) 정회원
1984년: 서울대학교 전자공학과
(학사)
1986년: 서울대학교 전자공학과
(석사)
1992년: Georgia Institute of
Technology, 전기공학과
(박사)

1993년~1995년: 금성중앙연구소 선임연구원
1995년~현재: 명지대학교 제어계측공학과 조교수
※주관심분야: 센서융합, 퍼지논리, 진화연산



공 창 옥(Changwook Kong) 정회원
1995년: 명지대학교 제어계측공
학과(학사)
1995년~현재: 명지대학교 대학
원 제어계측공학
과 석사과정
※주관심분야: 퍼지 및 신경망