

퍼지 엔트로피를 이용한 퍼지 뉴럴 시스템 모델링

박 인 규[†]

요 약

이 논문에서는 시계열 예측을 위하여 퍼지 엔트로피에 의한 입력공간의 분할과 퍼지 제어규칙을 자동으로 생성하는 방법을 제안하고, Mackey-Glass 데이터 Set을 이용한 시계열 예측 문제에 적용하여 그 성능을 검증한다. 이 방법은 샤논 함수와 퍼지 엔트로피 함수를 이용하여 입력공간을 분할하고, 분할된 부 공간에 대해 입력 데이터와 부합할 수 있는 각각의 규칙에 등급을 정하여 불필요한 제어규칙을 제거하여 최적의 규칙베이스를 구성하도록 한다. 적용되는 퍼지 신경망의 기본적인 구조는 퍼지 제어기의 규칙베이스와 추론의 과정을 신경회로망을 이용하여 구현하며 퍼지 제어규칙의 매개변수들은 최대 급경사 강하법에 의해 적용되어진다. 제안되는 알고리즘은 매개변수의 수를 줄이기 위하여 제어규칙의 결론부의 출력값은 신경망의 가중치로 구성하여 퍼지 신경망의 복잡도를 줄임으로써 추론형과 기술형 접근법을 혼합한 형태의 학습 알고리즘이다.

Fuzzy Neural System Modeling using Fuzzy Entropy

In Kue Park[†]

ABSTRACT

In this paper We describe an algorithm which is devised for the partition of the input space and the generation of fuzzy rules by the fuzzy entropy and tested with the time series prediction problem using Mackey-Glass chaotic time series. This method divides the input space into several fuzzy regions and assigns a degree of each of the generated rules for the partitioned subspaces from the given data using the Shannon function and fuzzy entropy function generating the optimal knowledge base without the irrelevant rules. In this scheme the basic idea of the fuzzy neural network is to realize the fuzzy rule base and the process of reasoning by neural network and to make the corresponding parameters of the fuzzy control rules be adapted by the steepest descent algorithm. The proposed algorithm has been naturally derived by means of the synergistic combination of the approximative approach and the descriptive approach. Each output of the rule's consequences has expressed with its connection weights in order to minimize the system parameters and reduce its complexities.

1. 서 론

퍼지집합과 퍼지논리는 부정확한 정보에 대한 인간 두뇌의 사고 방식의 원리를 모방하고 있고 신경회로망은 인간 두뇌의 물리적인 구조를 모방하고 있다. 퍼지집합과 퍼지논리는 불확실한 정보의 표현, 처리 및 응용을 함으로써 실세계에서 흔히 접할 수 있는

불확실하거나 부정확한 정보를 처리할 수 있는 토대를 제공해주는 방법인 반면에, 신경회로망은 대규모의 병렬분산처리 능력 및 학습능력을 제공해 주고 있다. 시스템의 상태와 제어사이의 비 선형 관계를 가지는 공정에 대해서는 기존의 제어이론보다는 학습기능을 가지는 퍼지추론이 보다 우수한 결과를 낳고 있다[1,2].

퍼지추론의 결과는 사용되는 퍼지 제어규칙에 좌우되기 때문에 신경회로망이 가지는 학습능력을 바탕으로, 퍼지 제어규칙, 멤버십 함수와 퍼지논리 제

이 논문은 1998년도 중부대학교 학술연구조성비에 의하여 연구되었음.

[†] 정희원, 중부대학교 정보공학부 전자계산과 조교수

어나 결정시스템의 여러 파라미터를 적응시키는 방향으로의 연구가 한층 더 활기를 띠고 있다[3-5]. 첫째는 퍼지 제어규칙의 조건부와 결론부에 포함되어 있는 멤버쉽 함수의 매개변수를 역전파 알고리즘을 이용하여 동정하는 파라미터 동정기법이 있다. 이에 대한 연구로는 학습기능을 이용하는 Wang과 Mendal의 방법[6], Ichitashi에 의한 방법[7], Araki에 의한 방법[8]등이 있다. 또한 제어규칙의 결론부가 입출력의 선형조합으로 나타나는 Sugeno에 의한 방법[9]과 기울기 하강법의 학습에 의한 Nomura에 의한 방법[10], 퍼지 클러스터링을 이용한 여러 방법[11]등이 있다. 결국 입력 데이터로부터 퍼지 제어규칙을 구성하는 퍼지집합을 구하는 이와 같은 추론형 접근법은 절차가 복잡하고 계산상의 복잡도가 가중되는 단점이 있다. 둘째는 입출력 공간의 분할을 통하여 제어규칙을 발생하고 발생된 제어규칙에 대한 가중치를 신경망이나 유전자 알고리즘과 같은 방법을 통하여 최적의 규칙을 획득하는 방법이다. 이와 같이 분할된 입출력 공간에 대해 최적의 부 공간을 선택하여 제어규칙으로 발생시키는 기술형 접근법 또한 조건부가 많을 경우에는 시스템의 복잡도가 기하급수적으로 늘어나는 단점이 있다.

이 논문에서는 학습 과정에 소요되는 계산량의 큰 증가 없이 보다 우수한 일반화 성능을 가지는 알고리즘을 개발하고 예측모델의 비교로 많이 쓰이는 Mackey-Glass Chaotic 시계열 Data Set을 통해 알고리즘의 우수성을 보인다. 입력공간에 대한 효과적 분할을 통하여 최적의 제어규칙을 얻기 위하여 퍼지 엔트로피 함수와 샤논함수를 이용하여 퍼지 제어규칙을 자동으로 생성할 수 있는 알고리즘이 2절에서 제안된다. 또한 퍼지 신경망의 기본적인 구성은 퍼지 제어기의 규칙베이스와 추론의 과정을 신경망을 이용하여 구현하였다. 제어규칙의 결론부의 제어량은 시스템의 복잡도를 낮추기 위하여 신경회로망의 가중치로 표현되어 조건부의 멤버쉽 함수의 파라미터와 함께 3절에서 오차 역전파(error back propagation)학습 알고리즘에 의해 적용되어진다. 제안된 알고리즘의 일반화 성능을 검증하기 위한 Bench Mark 자료로 많이 이용되는 Mackey-Glass 시계열 데이터를 이용하여 시계열 예측 문제에 적용하고 기존의 연구결과들과 비교한다.

2. 입력공간의 분할

2.1 퍼지 엔트로피와 제어규칙

샤논(Shannon)에 의해 소개된 정보의 엔트로피는 정보의 값을 수치적으로 표현하는 척도이다. 앞으로 발생할 어떤 결과($\mu_{\tilde{A}}(x)$)가 분명하다면 즉, 그림 1의 좌측에 있는 함수에서 $\mu_{\tilde{A}}(x)$ 가 0이나 1에 가깝다면 그 정보의 엔트로피는 작고 또한 분명하지 않다면 즉, 0.5라면 크다. 이러한 정보 엔트로피를 확장하여 어떤 결과의 애매한 발생여부를 퍼지집합의 애매성(fuzziness)으로 취급할 수 있다. 따라서 N개의 원소를 갖는 퍼지집합 \tilde{A} 에 대해 De Luca와 Termini가 제안한 퍼지 엔트로피(fuzzy entropy)는 식(1)과 같다[12].

$$H(\tilde{A}) = \frac{1}{N \ln 2} \sum_{x \in \tilde{A}} \{ -\mu_{\tilde{A}}(x) \ln \mu_{\tilde{A}}(x) - (1 - \mu_{\tilde{A}}(x)) \ln(1 - \mu_{\tilde{A}}(x)) \} \quad (1)$$

이는 $\mu_{\tilde{A}}(x)$ 로 정의되는 퍼지집합 \tilde{A} 와 $1 - \mu_{\tilde{A}}(x)$ 로 정의되는 퍼지집합의 여집합 \tilde{A}^c 의 불확실성을 합한 것으로 결국 퍼지 엔트로피는 하나의 퍼지집합에 대한 애매함의 정도를 나타내는 퍼지척도(measure of fuzziness)이다. 퍼지 엔트로피 함수는 퍼지집합에 대한 퍼지정도를 나타내며 [0, 0.5]에서는 단조적으로 증가하고 [0.5, 1]에서는 단조적으로 감소하며 0.5에서는 가장 큰 값 즉, 0.0과 1.0의 어느 쪽에도 속할 가능성이 가장 불확실한 상태를 가진다. 이러한 속성을 이용하여 입력 패턴들의 클러스터링을 수행한다. 먼저 그림 1의 샤논 함수의 중심점인 b가 클러스터간의 경계라고 가정한다. 여기서 경계는 인접클러스터에 속할 가능성이 가장 애매한 상태 즉, 임의의 클러스터에 속할 가능성이 가장 불확실한 상태이다. 따라서 임의의 b점에서의 식(2)의 샤논함수는 하나의 퍼지집합으로 이 집합에 대한 모든 패턴들의 퍼지 엔트로피를 구하여 패턴들의 인접 클러스터간의 속하는 정도를 측정한다. 같은 방법으로 b점을 계속 이동하면서 모든 x축에 대해 경계에 해당할 가능성에 해당하는 퍼지 엔트로피를 구한다. 결국 패턴들의 클러스터간의 경계는 인접한 값 보다 큰 엔트로피 값을 가지는 x가 클러스터간의 경계에 해당한다 [14,15].

$$\begin{aligned} \mu_x(x) &= S(x; a, b, c) \\ &= \begin{cases} 0 & x \leq a \\ 2 * [(x-a)/(c-a)]^2 & a \leq x \leq b \\ 1 - 2 * [(x-c)/(c-a)]^2 & b \leq x \leq c \\ 1 & x \geq c \end{cases} \end{aligned} \quad (2)$$




그림 1. 퍼지 엔트로피 함수와 사논함수

이러한 퍼지 엔트로피를 이용하여 각 변수에 할당되는 입력변수의 입력데이터의 공간을 분할하는 알고리즘은 다음과 같다.

단계 1. 사논함수에 의해 입력 데이터의 애매함을 측정하는 멤버십 함수를 정의한다.

$$\begin{aligned} &\text{for}(x=0; x < \text{max}; x++) \\ &\text{for}(y=0+(c-a)/2; y < \text{max}-(c-a)/2; y++) \\ &\mu(x; a, y, c) = S(x; a, y, c) \end{aligned}$$

단계 2. 입력 데이터의 빈도수(h(x))를 계산한다.

단계 3. 각각의 입력 변수에 대한 위의 식에 의해 퍼지 엔트로피(H)를 계산한다.

$$\begin{aligned} &\text{for}(y=0+(c-a)/2; y < \text{max}-(c-a)/2; y++) \\ &H(y) = \frac{1}{n \log 2} \sum_{x=0}^{\text{max}} S_n(\mu(x; a, y, c)) h(x) \end{aligned}$$

단계 4. $[0+(c-a)/2, \text{max}-(c-a)/2]$ 의 구간에서 다음을 만족하는 x를 검출한다.

$$\begin{aligned} &\text{for}(y=0+(c-a)/2; y < \text{max}-(c-a)/2; y++) \\ &H(y_{n-1}) > H(y_n) < H(y_{n+1}) : \text{center of clusters} \\ &H(y_{n-1}) < H(y_n) > H(y_{n+1}) : \text{boundary of clusters} \end{aligned}$$

결과적으로 단계 4에서 구해진 엔트로피 값 즉, 임의의 클러스터에 속할 가능성이 크다는 것은 입력력 데이터들을 클러스터링 할 경우에 클러스터간의 경계에 해당하고 엔트로피 값이 작다는 것은 클러스터의 중심에 해당한다. 따라서 구해진 클러스터들의 중심 값은 가우시안 멤버십 함수의 중심(c)에 해당한

다. 각 클러스터간의 경계 값을 이용하여 각 클러스터에 대한 멤버십 함수를 구성한다. 멤버십 함수는 초기에 적절한 폭을 갖도록 하기 위하여 함수의 폭이 각 경계값에서 0.5의 값을 갖도록 즉, $y(x)=1/2$ 를 만족하는 w를 각각 식(3)과 같이 구성한다.

$$y(x) = \exp\left(-\frac{(x-c)^2}{w^2}\right), \quad w = \sqrt{\frac{(x-c)^2}{\ln 2}} \quad (3)$$




그림 2. 입력공간의 분할과 멤버십 함수의 구성

퍼지 엔트로피에 의한 특징공간의 분할을 두 개의 특징공간에 대하여 고려해보면 각 부 공간에 할당되어 있는 멤버십 함수를 그림 2와 같이 사논함수로 구성한다. 이 경우에 사논함수의 중심인 b는 멤버십 함수의 중심으로 입력패턴이 함수의 속성을 만족하는 정도를 나타낸다. 그림 2에서 보면 임의의 멤버십 함수 A를 사논함수로 구성하여 학습패턴이 각각의 부 공간의 언어적 속성을 만족하는 정도를 식(2)의 퍼지 엔트로피에 의하여 평가하고 정규화과정을 통하여 해당공간에 대한 밀집도의 척도로서 이용한다. 이와 같은 방법으로 모든 부 공간에 대하여 정규화된 퍼지 엔트로피를 계산한다. 따라서 시스템의 제어 동작을 가장 잘 기술 할 수 있는 부 공간을 선정하기 위하여 각각의 부 공간에 대하여 구해진 정규화된 퍼지 엔트로피에 대하여 임의의 임계값을 적용하여

임계값 이상의 값을 가지는 부 공간을 가장 시스템을 잘 기술하는 부 공간으로 간주하여 퍼지 제어규칙을 구성하게 된다.

3. 퍼지 신경망(Fuzzy Neural Network)

3.1 퍼지 신경망의 구조

퍼지논리 제어기의 설계는 인간의 경험과 지식에 기초한 추론과정을 모델링하는 것으로 간주할 수 있다. 일반적으로 퍼지규칙의 결론부는 하나의 퍼지집합이다. 여기서 k번째 규칙은 식(4)와 같이 표현된다.

$$\text{IF } x_1 \text{ is } A_1^k \text{ and } x_2 \text{ is } A_2^k \text{ and } \dots \text{ and } x_n \text{ is } A_n^k \text{ THEN } y \text{ is } \beta^k \quad (4)$$

여기서 A_i^k 와 β^k 는 각각 R 에 속하는 U_i 와 V 의 퍼지 집합이다. $x=(x_1, \dots, x_n)^T \in U_1 \times \dots \times U_n$ 와 $y \in V$ 는 퍼지추론 시스템의 각각 입력과 출력이다. 위의 식과 같은 퍼지 규칙에 대해 다음에 설명될 추론과정을 신경망으로 구현한 것이 그림 3에 나타나 있다.

퍼지 신경망의 입력은 (a)층과 같이 네 개의 입력 X_1, X_2 와 X_3, X_4 로 이루어져 있다. 그리고 (b)층은 규칙의 조건부에 해당하는 언어변수로서 각 변수에 따른 소속 함수는 퍼지 엔트로피에 의해 분할된 각각의 퍼지집합(소속함수)들로 이루어져 있다. 그리고 소속함수의 전체집합은 정규화되어 있다. $G_1(x_1)$ 은 입력 x_1 이 퍼지변수 G_1 의 언어적 속성에 일치하는 소속정도를 의미한다. 이 소속 함수는 사각형의 적용

노드로서 신경회로망에 의해 적용될 중심과 폭의 파라미터를 가진다. (c)층은 규칙층으로 조건부의 해당 퍼지 부공간의 중요도를 출력한다. 결국 퍼지규칙의 진리값이 결정된다. 제어규칙의 결론부는 (c)층과 (d)층을 연결하는 β 로서 결론부의 퍼지집합을 퍼지 단일 값으로 나타낸다. 결국 각 퍼지규칙의 단일 값에 대해 (c)층의 출력과의 무게 중심법에 의한 비 퍼지화의 과정을 통하여 식(5)와 같이 최종 추론 값을 구할 수 있다.

$$y_{out} = \frac{\sum_{k=1}^m \beta^k \left[\prod_{i=1}^n \mu_{A_i^k}(x_i) \right]}{\sum_{k=1}^m \prod_{i=1}^n \mu_{A_i^k}(x_i)} \quad (5)$$

전방향의 신호의 전파와 각 계층의 각 노드들의 기능은 다음과 같다. 여기서 net_j^i 와 f_j^i 는 각각 j 번째 노드의 입력 가중합과 활성화수를 나타낸다. 또한 x_j^i 와 y_j^i 는 i 번째 계층의 j 번째 노드의 입력과 출력벡터를 나타낸다. 각 층에 관한 전방향의 전파는 다음과 같다.

$$a \text{ 층 : } net_j^1 = x_j^1 = x_j, \quad y_j^1 = f_j^1(net_j^1) = net_j^1 \quad (6)$$

$$b \text{ 층 : } (net_{ij}^2) = -\frac{(x_j^1 - c_{ij})^2}{(w_{ij})^2}, \quad y_{ij}^2 = f_{ij}^2(net_{ij}^2) = \exp(net_{ij}^2) \quad (7)$$

$$c \text{ 층 : } net_j^3 = \prod_{i=0}^n x_i^3, \quad y_j^3 = f_j^3(net_j^3) = net_j^3 \quad (8)$$

$$d \text{ 층 : } net^4 = \sum_{i=1}^m \beta_i^4 x_i^4, \quad y^4 = \frac{f^4 net^4}{\sum_{i=1}^m x_i^4} = \frac{net^4}{\sum_{i=1}^m x_i^4} \quad (9)$$

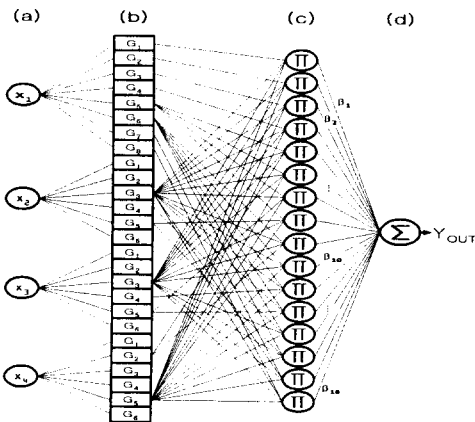


그림 3. 퍼지 신경망의 구조

3.2 퍼지 신경망의 학습

제안된 시스템의 적용 파라미터는 퍼지 제어규칙의 조건부의 멤버쉽 함수를 결정하는 파라미터 즉, 가우시안 멤버쉽 함수의 평균에 해당하는 중심과 분산에 해당하는 폭이다. 또 하나는 결론부의 퍼지집합의 단일 값을 나타내는 연결강도이다. 시스템이 초기화 된 후 역전파 알고리즘을 이용하여 일단의 학습 패턴에 대해 시스템의 각 파라미터를 적용시킨다. 일반적으로 역전파 신경망의 목적함수는 식(10)과 같이 정의된다.

$$E = \frac{1}{2} \sum_{j=1}^n (T_j - O_j)^2 \quad (10)$$

여기서 출력값 O_j 는 j 번째 출력 노드 y_j 의 출력이고 T_j 는 목표값이다. 이것을 감안하여 식E를 y_j 에 대해 편미분하면 식(11)와 같이 출력노드의 활성화 값에 대한 오차의 편미분 값을 얻게 된다.

$$\frac{\partial E}{\partial y_j} = d_j - y_j \quad (11)$$

이 값이 역전파 학습알고리즘의 역전파 출발점이 된다. 그리고 j 번째 출력노드에 의해서 전달되어지는 오차항은 식E를 net_j 에 대해 편미분하면 식(12)의 오차항을 얻을 수 있다.

$$\delta_j = \frac{-\partial E}{\partial net_j} = \frac{-\partial E}{\partial y_j} \frac{\partial y_j}{\partial net_j} = \frac{t_j - y_j}{\sum_i x_i} \quad (12)$$

또한 하위 계층에 대한 역전파 과정은 기존의 알고리즘과 동일하다. 따라서 최종적으로 b 층의 중심과 폭에 해당하는 적응 파라미터에 대한 c_{ij} 와 w_{ij} 에 대한 적응 규칙은 식(13),(14)와 같다. 학습중에 에러를 줄이고 진동을 줄이기 위하여 모멘텀 항을 사용하였다.

$$c_{ij}(t+1) = c_{ij}(t) + \eta \delta_{ij} \left[\frac{2(x_i - c_{ij})}{w_{ij}^2} \right] + \alpha \Delta c_{ij}(t) \quad (13)$$

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta_{ij} \left[\frac{2(x_i - c_{ij})^2}{w_{ij}^3} \right] + \alpha \Delta w_{ij}(t) \quad (14)$$

이상에서 언급한 전체적인 동정 개념도가 그림 4에 보여진다. 결과적으로 입력 데이터로 부터 퍼지 엔트로피에 의한 입출력 공간의 분할을 통하여 얻어진 여러 부 공간에 대한 평가를 통하여 시스템의 동정에 가장 부합하는 퍼지 제어규칙의 구성을 통하여 구조적인 동정이 이루어진다. 그 다음에 오차 역전파 알고리즘을 이용하여 퍼지 제어규칙의 조건부를 구성하는 가우시안 함수의 중심과 폭과 결론부를 구성하는 퍼지 단일값의 파라미터에 대한 파라미터의 동정이 이루어진다.

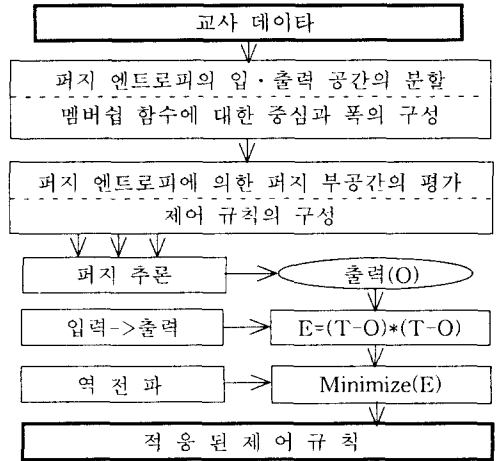


그림 4. 전체 시스템의 순차

4. 실험 및 결과

그림 5는 시계열의 예측 문제에서 많이 쓰이는 Mackey-Glass Chaotic 시계열 Data Set를 식 (15)에 의해 4차 Runge-Kuta법을 이용하여 1200개의 발생된 데이터를 나타낸 것이다. $t < 0$ 인 구간에서는 $x(t) = 0$ 이며 초기값은 1.2로 하였다[13]. 그림 5에서 발생된 1200개의 데이터에서 500개는 학습에 사용하였고, 나머지 600개는 예측에 사용하였다.

$$x(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (15)$$

입출력은 그림 6과 같이 시계열에서 $t=0$ 에서 입력 $x(t-18)$, $x(t-12)$, $x(t-6)$, $x(t)$ 을 구성하고 출력은 6단계의 앞선 값인 $x(t+6)$ 으로 구성하였다.

표 1에서는 사론함수와 퍼지 엔트로피함수를 이용하여 입력공간을 분할한 결과를 나타내었다. 분할된 부공간들의 중심값들이 입력변수별로 나타나 있다. $x(t-18)$ 입력변수는 7개의 영역으로 분할이 되고,




그림 5. Mackey-Glass 시계열 데이터




그림 6. 입출력 패턴의 구성

표 1. 입력공간의 분할 결과

| x(t-18) | x(t-12) | x(t-6) | x(t) |
|----------|----------|----------|----------|
| 0.135773 | 0.143828 | 0.143828 | 0.175664 |
| 0.181558 | 0.178045 | 0.187822 | 0.280528 |
| 0.230613 | 0.275810 | 0.275810 | 0.418759 |
| 0.279668 | 0.422458 | 0.422458 | 0.433059 |
| 0.312371 | 0.432234 | 0.432234 | 0.533157 |
| 0.384319 | 0.529999 | 0.529999 | 0.609422 |
| 0.417022 | | | |

$x(t-12)$, $x(t-6)$ 와 $x(t)$ 는 각각 6개로 분할이 되었다. 그림 7은 표 1에 의해서 입력과 가장 잘 부합하는 16개의 제어규칙을 추출하여 변수별로 구성한 것이다. 그림 8은 그림 7의 초기의 멤버십 함수를 가지고 학습을 완료한 후에 적용된 멤버십 함수를 나타내고 있다. 표 2에는 표 1의 퍼지 규칙을 이용하여 동정된 파라미터를 나타내었다. 기존의 방법과 달리 결론부의 파라미터가 신경망의 가중치로 구현이 되었어 파라미터의 수가 적고 신경망의 복잡도를 줄일 수 있었다. 퍼지 규칙에서 사용된 조건부의 적용 파라미터는 30개이고, 결론부는 16개로 총 46개의 파라미터이다.




그림 7. 학습이전의 멤버십 함수




그림 8. 학습이후의 멤버십 함수

그림 9와 그림 10에는 시계열의 예측결과와 예측오차를 각각 나타내었다. 실선이 원래의 값이고 점선이 예측된 값이다. 그림 11에는 동정용 데이터를 사용하여 식(16)에 의해 계산된 학습 오차곡선이 보여진다. 이 그림에서 학습 초기에 상당히 오차가 적은 상태에서 시작하는 것을 알 수 있는데 이는 퍼지 엔트로피 클러스터링을 통하여 시스템을 기술하는 제어규칙을 구조적으로 비교적 잘 동정한 것임을 보여주고 있다.




그림 9. Mackey-Glass 시계열의 예측결과




그림 10. 예측 오차

표 2. 동정된 파라미터 값

| 규칙 | 조건부 파라미터 | | | | | | | | 결론부 파라미터 |
|----|----------|----------|----------|----------|----------|----------|----------|----------|-------------|
| | x(t-18) | | x(t-12) | | x(t-6) | | x(t) | | |
| | 중심 | 폭 | 중심 | 폭 | 중심 | 폭 | 중심 | 폭 | |
| 1 | 0.072987 | 0.002286 | 0.363259 | 0.304038 | 0.351981 | 0.313454 | 0.678250 | 0.449963 | 0.045108 |
| 2 | 0.106177 | 0.094258 | 0.272715 | 0.299086 | 0.434381 | 0.414285 | 0.737270 | 0.273922 | 0.161183 |
| 3 | 0.258890 | 0.129701 | 0.282315 | 0.372529 | 0.277193 | 0.223490 | 0.753373 | 0.412554 | 0.302269 |
| 4 | 0.273713 | 0.139507 | 0.283627 | 0.139755 | 0.604549 | 0.075190 | 0.637723 | 0.458530 | 0.438214 |
| 5 | 0.304981 | 0.252166 | 0.226010 | 0.172029 | 0.272358 | 0.298551 | 0.688653 | 0.156438 | 1.029603 |
| 6 | 0.429550 | 0.245082 | 0.347689 | 0.137953 | 0.379749 | 0.254588 | 0.499710 | 0.311143 | 0.657667 |
| 7 | 0.554555 | 0.060284 | 0.395628 | 0.284924 | 0.399503 | 0.169112 | 0.742891 | 0.442143 | 0.416679 |
| 8 | 0.548216 | 0.287282 | 0.698091 | 0.173270 | 0.427995 | 0.071081 | 0.686548 | 0.183999 | 0.113902 |
| 9 | 0.344549 | 0.290343 | 0.420625 | 0.081862 | 0.337738 | 0.299410 | 0.794824 | 0.247488 | 0.941037 |
| 10 | 0.415060 | 0.213651 | 0.193177 | 0.113183 | 0.593454 | 0.316004 | 0.661599 | 0.547599 | 0.301278 |
| 11 | 0.681567 | 0.012961 | 0.405136 | 0.349593 | 0.605066 | 0.234772 | 0.683749 | 0.454658 | 0.063295 |
| 12 | 0.665838 | 0.029441 | 0.356919 | 0.317315 | 0.600721 | 0.358383 | 0.718895 | 0.427942 | 0.138985 |
| 13 | 0.591069 | 0.056092 | 0.592231 | 0.128592 | 0.223584 | 0.247717 | 0.642699 | 0.491873 | 0.143846 |
| 14 | 0.498996 | 0.146681 | 0.647732 | 0.339463 | 0.074330 | 0.248767 | 0.687370 | 0.553779 | 0.095584 |
| 15 | 0.547156 | 0.266098 | 0.289300 | 0.221502 | 0.442739 | 0.374028 | 0.683324 | 0.356445 | 0.507961 |
| 16 | 0.690367 | 0.141849 | 0.338934 | 0.341514 | 0.268715 | 0.314453 | 0.739779 | 0.417413 | 0.214142 |




그림 11. 학습시의 RMSE

$$R.M.S.E = \sqrt{\frac{1}{N} \sum_{k=1}^N (T(k) - O(k))^2} \quad (16)$$

여기서 N은 사용된 데이터 수, T(k)는 실제 데이터의 출력 값이고 O(k)는 동정된 모델로부터 추론된 값이다. 표 3에 보여진 nondimensional error index(NDEI)는 기존의 모델링 기법과의 비교를 위하여 예측한 결과의 root mean square error를 원

표 3. 시계열의 입출력 데이터를 사용한 퍼지 모델링 기법의 비교

| 방 법 | 학습패턴 수 | 파라미터 수 | NDEI |
|-------------------------|--------|--------|-------|
| 제안된 방법 | 500 | 46 | 0.038 |
| AR model | 500 | 104 | 0.39 |
| Cascaded-Correlation NN | 500 | 693 | 0.32 |
| Back-Prop NN | 500 | 540 | 0.05 |

시계열의 표준편차로 나는 것이다. 여기에 제시된 모든 방법들은 공히 500개의 동일한 데이터를 사용하였다. 또한 파라미터의 수가 기존의 방법에 비해 상당히 적기 때문에 계산상의 복잡도(complexity)를 줄일 수 있었다. 결국 이 표에 의하면 본 논문에서 제시된 기법에 의해 동정된 퍼지 모델이 다른 모델링 기법에 비해 비교적 정확하게 동정되었음을 알 수 있다.

5. 결 론

본 논문에서는 퍼지 제어를 신경망을 이용하여 구현하는데 있어서 보다 간단하고 계산상의 복잡도를 줄일 수 있는 퍼지 신경망을 제안하였다. 이를 위해 퍼지 엔트로피에 의한 클러스터링을 이용하여 입력 데이터의 구조를 동정하여 시스템을 기술하는 퍼지 규칙을 자동으로 생성하는 방법이 제시되었다. 또한 기존의 방법들의 단점으로 지적되어온 시스템의 적용 파라미터의 수를 줄임으로써 효율성을 기하였다. 시계열 데이터를 사용하여 제안된 방법의 타당성 및 정확성이 기존의 다른 방법들과 비교 검토되었고, 그 결과 제안된 기법이 간단하면서도 정확성이 입증되었다.

제안된 알고리즘의 장점은 학습 알고리즘이 기존의 역전파 알고리즘으로 간단하고 설계하기가 쉽고

과라미터의 감소로 인한 계산량이 적다는 데에 있다. 퍼지 엔트로피에 의한 입력 데이터의 구조를 동정할 경우에 입력 분할 공간에 대한 퍼지 엔트로피의 적합도에 대한 임계값을 결정하는 데에 따른 시행착오적인 방법이 아닌 일반적인 방법에 대한 연구가 이루어져야 할 것으로 사료된다.

참 고 문 헌

[1] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control", IEEE Trans. Syst. Man, Cybern., vol. 15, pp. 116-132, 1985.

[2] W. Pedrycz, "Fuzzy Control and Fuzzy Systems", New York: Wiley, 1989.

[3] Chin-Teng Lin and C. S. George Lee, "Neural Fuzzy Systems", Prentice-Hall, 1996.

[4] M. Mizumoto and M. Iwakiri, "Self-generation of fuzzy rules by fuzzy singleton-type reasoning method", Proc. of the 9th Fuzzy System symposium, Sapporo, 585-588, 1993.

[5] Y. Shi, M. Mizumoto, N. Yubazaki and M. Otani, "An improvement of fuzzy rules generation based on fuzzy clustering method", Proc. of the 6th Intelligent Systems symposium, Osaka, 215-218, 1996.

[6] Li-Xin Wang and Jerry M. Mendal, "Generating fuzzy rules by learning from examples", IEEE Trans. SMC, vol. 22, no. 6, pp. 1414-1427, 1992.

[7] H. Ichihashi, "Iterative fuzzy modeling and a hierarchical network", Proc. of the 4th IFSA Congress, vol. Eng., Brussels, 49-52, 1991.

[8] D. Araki, H. Nomura, I. Hayashi and N. Wakami, "A self generating method of fuzzy inference rules", Fuzzy engineering toward human friendly systems, pp. 1047-1058, eds.

T. Terano et al., 1991.

[9] M. Sugeno and G. T. Kng, "Structure identification of fuzzy model", Fuzzy sets and systems, vol. 28, pp. 15-23, 1988.

[10] H. Nomura, I. Hayashi and N. Wakami, "A learning method of fuzzy inference rules by descent method", IEEE Int. Conf. on Fuzzy Systems(San Diego, 1992) 203, 210.

[11] Yan Shi, M. Mizumoto and Peng Shi, "Tuning fuzzy rules based on fuzzy clustering and neuro-fuzzy Methods", Proc. of the 1991 IEEE Int. Symposium on Intelligent Control, arlington on, Virginia, U.S.A.

[12] S. K. Pal, "A measure of edge ambiguity using fuzzy sets", Pattern Recognition Letters 4, pp. 51-65, North-Holland, 1986.

[13] Jyh-Shing Roger Jang, "ANFIS: Adaptive-Network-based Fuzzy Inference System", IEEE Trans. on SMC vol. 23, no. 3, May/June, pp. 665-684, 1993.

[14] 박인규, 황상문, 진달복, "영상복원을 위한 유전자 기반 시스템 모델링: 러프-퍼지 엔트로피", 한국감성과학회, 제1권 제2호, pp. 93-103, 1998.

[15] 박인규, 진달복, "확장된 퍼지 엔트로피를 이용한 영상 분할 알고리즘", 한국통신학회, 제21권, 제6호, 1995.



박 인 규

1985년 2월 원광대학교 공과대학 공학사
 1987년 8월 연세대학교 대학원 전산기용용 공학석사
 1997년 2월 원광대학교 대학원 마이크로프로세서 응용 공학박사
 1997년 3월~현재 중부대학교 정보공학부 전자계산과 조교수
 관심분야 : 퍼지논리 및 소프트웨어컴퓨팅, 영상처리