

확장된 퍼지엔트로피 클러스터링을 이용한 카오스 시계열 데이터 예측

박 인 규(朴 仁 圭)

중부대학교 정보공학부

전화 : (0412) 750-6755 / 팩스 : (0412) 750-6755

Chaotic Time Series Prediction using Extended Fuzzy Entropy Clustering

In Kue Park

School of Information Engineering Joongbu University

E-mail : ikpak@joongbu.ac.kr

Abstract

In this paper, we propose new algorithms for the partition of input space and the generation of fuzzy control rules. The one consists of Shannon and extended fuzzy entropy function, the other consists of adaptive fuzzy neural system with back propagation learning rule. The focus of this scheme is to realize the optimal fuzzy rule base with the minimal number of the parameters of the rules, reducing the complexity of the system. The proposed algorithm is tested with the time series prediction problem using Mackey-Glass chaotic time series.

I 서론

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 제공

해주는 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 내고 있다. 퍼지추론의 결과는 사용되는 퍼지 제어규칙에 좌우되기 때문에 신경회로망이 가지는 학습능력을 바탕으로, 퍼지 제어규칙, 멤버십 함수와 퍼지논리 제어나 결정시스템의 여러 파라미터를 적용시키는 방향으로의 연구가 한층 더 활기를 띠고 있다. 첫째는 퍼지 제어규칙의 조건부와 결론부에 포함되어 있는 멤버십 함수의 매개변수를 역전파 알고리즘을 이용하여 동정하는 파라미터 동정 기법이고, 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 공간(subspace)을 선택하여 제어규칙으로 발생시키는 기술형 접근법(descriptive approach) 또한 조건부가 많을 경우에는 시스템의 복잡도가 기하급수적으로 늘어나는 단점이 있다.

이 논문에서는 확장된 퍼지엔트로피 함수를 이용하여 입력공간의 효율적인 분할을 통하여 퍼지제어 규칙을 구성하였다. 이를 바탕으로 구성된 적용퍼지추론 시스템에 의해 퍼지 제어규칙의 조건부와 결론부의 파라미터를 적용적으로 동정하고, 제어규칙의 결론부의 제어량은 시스템의 복잡도를 낮추기 위하여 신경회로

망의 가중치로 표현되어 조건부의 멤버쉽 함수의 파라미터와 역전파 학습 알고리즘에 의해 적용되어진다.

II. 확장된 퍼지엔트로피에 의한 클러스터링

샤논(shannon)의 정보 엔트로피는 정보의 값을 수치적으로 표현하는 척도이다. 앞으로 발생할 어떤 결과가 분명하다면 그 정보의 엔트로피는 작고 또한 분명하지 않다면 크다. 이러한 샤논의 정보 엔트로피를 확장하여 어떤 결과의 애매한 발생여부를 퍼지집합의 애매성으로 고려한 것이 De Luca 와 Termini가 제안한 퍼지 엔트로피이고, 여기에 확률정보를 고려한 것이 확장된 퍼지 엔트로피이다. 결국 하나의 퍼지집합에 대한 애매함의 정도를 나타내는 퍼지척도이다. 입력 데이터를 퍼지집합으로 고려한 샤논함수를 이용한 클러스터링 과정은 다음과 같다.

1. 샤논함수에 의해 입력 데이터의 애매함을 측정하는 멤버쉽 함수를 정의한다. 단, 샤논함수의 중심점(b)의 좌우로 일정한 폭(a와 c)을 유지하면서 b점을 x축에 따라 이동하며, max는 x축의 최대 값이다.

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

2. 입력 데이터의 빈도수(h(x))를 계산한다.
3. 각각의 입력 변수에 대한 위의 식에 의해 확장된 퍼지 엔트로피를 계산한다.

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

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

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

결과적으로 4에서 구해진 엔트로피 값 즉, 임의의 클러스터에 속할 가능성이 크다는 것은 입출력 데이터들을 클러스터링 할 경우에 클러스터간의 경계에 해당하고 엔트로피 값이 작다는 것은 클러스터의 중심에 해당한다. 이와 같이 검출된 엔트로피 값에 대해 임의의 임계값 이상의 엔트로피에 대해서만 중심 값을 구함으로써 효율적인 퍼지 규칙베이스를 구성할 경우에 불필요한 제어규칙을 줄일 수 있다.

III. 퍼지 신경회로망

그림 1은 확장된 퍼지 클러스터링 알고리즘에 의해 동정된 제어규칙에 의한 추론의 과정을 신경회로망으로 나타낸 것이다.

로 나타낸 것이다.




그림 1 퍼지신경회로망
Fig. 1 Fuzzy neural networks

퍼지 신경망의 입력인 a층이고 b층은 규칙의 조건부의 각 변수에 따른 소속 함수는 퍼지 엔트로피에 의해 분할된 각각의 퍼지집합으로 학습에 의해 적용될 중심과 폭의 파라미터를 가진다. c층은 각 규칙의 제어량을 출력한다. 제어규칙의 결론부는 c층과 d층을 연결하는 β 로서 결론부의 퍼지집합을 퍼지 단일 값으로 나타낸다. 결국 각 퍼지규칙의 단일 값에 대해 c층의 출력과의 비퍼지화의 과정을 통하여 최종 추론 값을 구할 수 있다. 또한 제안된 시스템의 학습을 위하여 역전파 알고리즘을 이용하였다. 시스템의 적용 파라미터는 조건부의 퍼지집합의 중심과 폭, 결론부의 제어량을 나타내는 β 값이다. 이상에서 언급한 전체적인 동정 개념도는 그림2와 같다.




그림 2 전체적인 시스템 동정절차
Fig 2 Identification procedures of entire system

입력 데이터로부터 확장된 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 파라미

터에 대한 파라미터의 동정이 이루어진다.

IV. 실험 및 결과

시계열의 예측 문제에서 많이 쓰이는 Mackey-Glass Chaotic 시계열 Data Set를 식 (1)에 의해 4차 Runge-Kuta법을 이용하여 1200개의 발생된 데이터를 이용하였다. $t < 0$ 인 구간에서는 $x(t)=0$ 이며 초기값은 1.2로 하였다^[13]. 그림 5에서 발생된 1200개의 데이터에서 500개는 학습에 사용하였고, 나머지 600개는 예측에 사용하였다.

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

입출력의 패턴은 그림 3과 같이 연속된 시계열에서 $t=0$ 을 기준으로 과거의 값에서 6단계마다 입력 $x(t-18)$, $x(t-12)$, $x(t-6)$, $x(t)$ 을 구성하고 출력은 $t=0$ 에서 6단계의 앞선 값인 $x(t+6)$ 으로 구성하였다.




그림 3 입력력 패턴의 구성
Fig 3 The structure of input/output pattern

표 1 입력공간의 분할 결과
Table 1 Partition results of the input space

$x(t-18)$	0.11573	0.16158	0.28053	0.23888	0.34237	0.35419	0.41522
$x(t-12)$	0.15382	0.17306	0.24680	0.42428	0.49423	0.42949	
$x(t-6)$	0.13388	0.18722	0.27810	0.42588	0.49427	0.62979	
$x(t)$	0.16564	0.28038	0.41889	0.43809	0.53467	0.50972	

표 1에서는 사분함수와 퍼지 엔트로피함수를 이용하여 입력공간을 분할한 결과를 나타내었다. $x(t-18)$ 입력 변수는 7개의 영역으로 분할이 되고, $x(t-12)$, $x(t-6)$ 와 $x(t)$ 는 각각 6개로 분할이 되었다. 그림 4는 표 1에 의해서 입력 데이터와 가장 잘 부합하는 16개의 제어 규칙을 추출하여 변수별로 구성한 것이다. 또한 그림 5는 그림 4의 초기의 멤버쉽 함수를 가지고 학습을 완료한 후에 적용된 멤버쉽 함수를 나타내고 있다.





그림 4 학습이전의 멤버쉽 함수
Fig. 4 Membership function before learning




그림 5 학습이후의 멤버쉽 함수
Fig. 5 Membership function after learning

표 2에는 표 1의 퍼지 규칙을 이용하여 동정된 파라미터를 나타내었다. 기존의 방법과 달리 결론부의 파라미터가 신경망의 가중치로 구현으로 파라미터의 수가 적고 신경망의 복잡도를 줄일 수 있었다.

표 2 동정된 파라미터 값
Table. 2 Values of identified parameters

R	조건부 파라미터								결론부 파라미터
	$x(t-18)$		$x(t-12)$		$x(t-6)$		$x(t)$		
	중심	폭	중심	폭	중심	폭	중심	폭	
1	0.03987	0.00286	0.36224	0.30408	0.35093	0.31345	0.67820	0.44893	0.06108
2	0.106177	0.094258	0.27274	0.29308	0.49468	0.41428	0.73720	0.27322	0.16183
3	0.23880	0.129701	0.28294	0.37232	0.27759	0.22349	0.53373	0.41254	0.30223
4	0.223713	0.138107	0.28382	0.13943	0.60454	0.07519	0.63722	0.48531	0.48214
5	0.30481	0.25206	0.22800	0.17202	0.27228	0.28850	0.68865	0.15848	1.02808
6	0.43850	0.24082	0.34786	0.13945	0.37944	0.25456	0.48970	0.31144	0.65667
7	0.55465	0.031284	0.38838	0.28482	0.48803	0.16912	0.74290	0.42143	0.41853
8	0.548216	0.28722	0.68091	0.17327	0.42735	0.07108	0.68548	0.18388	0.11302
9	0.34549	0.231843	0.42082	0.09182	0.33728	0.23910	0.79482	0.24748	0.94107
10	0.41303	0.21351	0.15917	0.11318	0.58854	0.31604	0.61338	0.54738	0.30128
11	0.681357	0.02351	0.40513	0.34888	0.61081	0.23472	0.68374	0.45468	0.03233
12	0.68388	0.02341	0.38919	0.31731	0.61072	0.38838	0.71888	0.42742	0.13888
13	0.39109	0.03392	0.52223	0.12882	0.22384	0.24771	0.64238	0.48872	0.14884
14	0.48888	0.14888	0.64773	0.38943	0.07433	0.24875	0.68370	0.55372	0.03884
15	0.54715	0.28808	0.28800	0.22100	0.44234	0.37402	0.68324	0.35444	0.50791
16	0.68087	0.14189	0.38884	0.34154	0.28875	0.31463	0.73975	0.41743	0.21442

퍼지 규칙에서 사용된 조건부의 적용 파라미터는 30개이고, 결론부는 16개로 총 46개의 파라미터이다. 그림 6과 그림 7은 시계열의 예측결과와 예측오차를 각

각 나타내었다. 실선이 원래의 값이고 점선이 예측된 값이다.




그림 6 Mackey-Glass 시계열의 예측결과
Fig. 6 Prediction results of Mackey-Glass time series




그림 7 예측 오차
Fig. 7 Prediction errors

오차곡선의 변화는 학습 초기에 상당히 오차가 적은 상태에서 시작하는 것을 알 수 있었는데, 이는 확장된 퍼지엔트로피 클러스터링을 통하여 시스템을 기술하는 제어규칙을 구조적으로 비교적 잘 동정한 것임을 보여 주고 있다. 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 동정한 퍼지 모델이 다른 모델링 기법에 비해 비교적 정확하게 동정되었음을 알 수 있다.

5. 결론

퍼지 제어를 신경망을 이용하여 구현하는데 있어서 보다 간단하고 계산상의 복잡도를 줄일 수 있는 퍼지 신경망을 보였다. 이를 위해 확장된 퍼지엔트로피에 의한 클러스터링을 이용하여 입력 데이터의 구조를 동정하여 시스템을 기술하는 퍼지 규칙을 자동으로 생성하는 방법이 제시되었다. 또한 기존의 방법들의 단점으로 지적되어온 시스템의 적응 파라미터의 수를 줄이므로써 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 파라미터의 감소로 인한 계산량이 적다는 데에 있다. 퍼지 엔트로피에 의한 입력 데이터의 구조를 동정한 경우에 입력 분할 공간에 대한 퍼지 엔트로피의 적합도에 대한 임계값을 결정하는 데에 따른 시행착오적인

방법이 아닌 일반적인 방법에 대한 연구가 이루어져야 할 것으로 사료된다.

참고 문헌

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