

퍼지 시스템을 이용한 코호넨 클러스터링 네트워크

강성호*, 손동설**, 임종규*, 박진성*, 엄기환*

*동국대학교, **유한대학

Kohonen Clustering Network Using The Fuzzy System

Kang Seong Ho*, Son Dong Seol**, Lim Joong Gyu*, Park Jin Sung*, Eom Ki Hwan*

*Dongguk University, **Yuhan college

Email : ksh7209@dgu.edu

요약

본 논문에서는 클러스터 해석으로 알려진 고전적인 패턴인식 알고리즘인 KCN(Kohonen Clustering Network)의 문제점을 개선하기 위한 방식을 제안하였다. 제안한 방식은 퍼지시스템을 이용하여 학습하는 동안 자동적으로 이웃 반경의 크기와 학습률을 조절한다. 퍼지 시스템의 입력은 입력 데이터와 연결강도와의 거리와 거리의 변화율을 사용하였으며, 출력은 이웃 반경의 크기와 학습률을 사용하였다. 퍼지 시스템의 제어 규칙은 기존의 코호넨 클러스터링 네트워크를 이용한 시뮬레이션에 의하여 정하였다. 제안한 방식의 유용성을 입증하기 위해 Anderson의 IRIS 데이터를 이용하여, 기존의 코호넨 클러스터링 네트워크를 시뮬레이션한 결과 제안한 방식의 성능의 우수함을 확인하였다.

ABSTRACT

We proposed a method to improve KCN's problems. Proposed method adjusts neighborhood and learning rate by fuzzy logic system. The input of fuzzy logic system used a distance and a change rate of distance. The output was used by size of neighborhood and learning rate. The rule base of fuzzy logic system was taken by using KCN simulation results. We used Anderson's Iris data to illustrate this method; and simulation results showed effect of performance.

키워드

Clustering Analysis, Kohonen Clustering Network, Fuzzy Logic System, Self-Organization, Unsupervised Learning.

I. 서 론

클러스터 해석으로 알려진 고전적인 패턴 인식은 코호넨 자기 구성(Kohonen self-organizing) 알고리즘과 유사하다.

1982년에 Kohonen은 이전의 von der Malsburg, willshaw와는 다른 일차원 또는 이차원 격자 구조를 이용한 자기 구성 맵에 관한 논문을 발표했다. 당시 Kohonen의 모델은 혁신적인 모델로 받아들여졌다[1].

그러나, KCN은 몇 가지 중요한 문제점이 있다. 첫째, KCN은 발견적(heuristic) 과정이므로 결과는 프로세스의 어느 모델 최적화를 기본으로 한 것은 아니다. 둘째, 출력인 최종 연결 강도는 입력 데이터 열에 종속적이다. 셋째, 연결강도 초기값에 크게 의존한다. 넷째, KCN 알고리즘의 파라미터인 학습률, 이웃 반경의 크기 등에 크게 영향을 받는 것 등

이다[2].

퍼지 이론은 1965년 미국 버클리 대학의 L.A. Zadeh 교수에 의해 '퍼지 집합 이론(Fuzzy Set Theory)'이 처음으로 소개되어진 뒤 많은 분야에서 다용도로 그리고 빠르게 응용되어져 오고 있다. 기존의 부울 논리 체계는 0과 1의 개념이 확실한 반면 퍼지 논리는 임의의 값이 어떤 집합에 속하는 정도에 따라 0과 1사이의 값을 가지게 되며, 정확한 수치를 가지고 나타낼 수 없는 애매한 상황을 다루는데 적합하다[4].

본 논문에서는 클러스터 해석으로 알려진 고전적인 패턴인식 알고리즘인 KCN(Kohonen Clustering Network)의 문제점을 개선하기 위한 방식을 제안한다. 제안한 방식은 퍼지시스템을 이용하여 학습하는 동안 자동적으로 이웃 반경의 크기와 학습률을 조절

한다. 퍼지 시스템의 입력은 입력 데이터와 연결강도와의 거리와 거리의 변화율을 사용하였으며, 출력은 이웃 반경의 크기와 학습율을 사용하였다. 퍼지 시스템의 제어 규칙은 기존의 코호넨 클러스터링 네트워크를 이용한 시뮬레이션에 의하여 정하였다. 제안한 방식의 유용성을 입증하기 위해 Anderson의 IRIS 데이터를 이용하여, 기존의 코호넨 클러스터링 네트워크와 제안한 방식을 시뮬레이션하여 성능을 비교 검토한다.

II. 코호넨 자기 구성 알고리즘

KCN의 구조는 입력층과 출력층 두 층으로 구성되며, 그림1은 코호넨 클러스터링 네트워크의 구조이다[3].

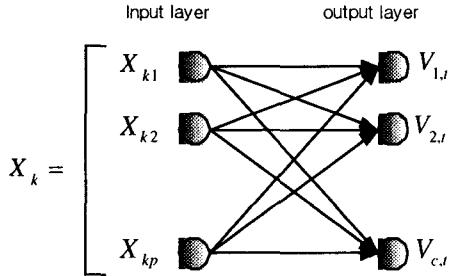


그림 1. 코호넨 클러스터링 네트워크의 구조

KCN 알고리즘은 다음과 같다[2][3].

1. $c, | \cdot |, \epsilon > 0$ 는 고정된다.
여기서, ϵ 는 양의 작은 상수이다.
 - 2.. $v_o = (v_{1,o}, v_{2,o}, \dots, v_{c,o}) \in R^c$,
 $a_{ik,o} \in (1, 0)$ 는 초기화되고, 이웃 뉴런 N_0 는
생신된다.
여기서, v_o 는 가중치 벡터이고, $a_{ik,o}$ 는 학습
률이다.
 3. $t = 1, 2, \dots, t_{\max}; k = 1, 2, \dots, n$ 에 대하여,
 - a. $d_{ik}^2 = |x_k - v_{i,t}|^2$ 는 $i=1$ 에서 c 까지 계산
된다.
 - b. $|d_{ik}^2$ 는 오름차순으로 정렬된다.
 - $d_{ik}^2 \leq d_{2k}^2 \leq \dots \leq d_{ck}^2$
 - c. 승리뉴런의 가중치 벡터는 생신된다.
 $v_{i,t} = v_{i,t-1} + a_{ik,o}(x_k - v_{i,t-1}) \quad (1)$
 - d. $|N_t|$ 인 경우, b. 과정에서 x_k 에
가장 가까운 $(n_t - 1)$ 뉴런은 생신된다.
- $$v_{i,t} = v_{i,t-1} + a_{ik,o}(x_k - v_{i,t-1}), \quad (2)$$

- e. 다음 k 에 대하여 반복한다.
4. $E_t = |v_t - v_{t-1}|^2$
 $= \sum_i |v_{i,t} - v_{i,t-1}|^2$
를 계산한다.
5. $E_t \leq \epsilon$ 인 경우, 학습 과정을 종료한다.
 $E_t > \epsilon$ 인 경우, 학습률 $a_{ik,o}$ 이웃뉴런 N_t 는
생신되고, 다음 t 에 대하여 반복한다.

KCN 알고리즘상의 주의 점은 다음과 같다[2][3].

1. 하나의 x_k 가 네트워크에 연속적으로 인가 되고, 단
지 일부 뉴런의 가중치만 직접적으로 생신된다.
이러한 특징은 종속적인 라벨(label-dependent)
 $v_{i,t}$ 배열을 만들고, 다른 반복 알고리즘에는 원
하지 않는 속성일 수 있다.
2. 학습률 a 는 i, k, t 로 인덱싱 한다. 이것은 승리 뉴
런의 가중치 벡터 $v_{1,t}$ 를 중심으로 분포되어 있
는 이웃뉴런 N_t 가중치 벡터를 생신하기 위해
 a 가 사용되고, v_1 의 인덱스는 x_k 의 함수이다.
또한, a 는 $E_t \leq \epsilon$ 의 조건을 만족하기 위해 일
반적으로 시간에 따라 감소한다.(“solution”벡터가
아니라도, 충분한 시간이 흐른 후에 학습규칙은
인위적으로 종료된다.)
3. 학습률과 이웃뉴런의 반경을 설정하는 것은 KCN
의 학습을 종료하는데 중요하다. 이러한 파라미터
에 따라 다른 결과가 발생한다. Kohonen은
 $a \rightarrow 0$ 으로 $v_t \rightarrow v^*$ 된다는 의미에서 수렴을 증
명하였다. 그러나, v^* 는 단지 반복학습과정상의
제한된 값이다. v^* 는 모델의 최적 값은 아니다.

III. 퍼지논리 시스템

퍼지 논리 시스템(Fuzzy Logic System)은 입력
신호의 퍼지화, 전문가의 지식에 기반을 둔 퍼지
규칙에 의한 퍼지 추론, 비퍼지화로 구성되며, 그
럼2는 FLS의 블록선도이다[4][8].

퍼지추론기(Fuzzy Inference Engine)는 퍼지 규칙
베이스(Fuzzy Rule Base)에서 사용된 퍼지 제어
규칙을 이용하여 추론을 하며 결론을 내리는 논
리연산 부분으로, 최소-최대 연산, 적-대수합 연산
을 많이 사용된다. 비퍼지화기(Defuzzifier)는 퍼
지추론의 결과인 퍼지값을 단일 실수값으로 변환
시키는 부분으로 본 논문에서는 무게중심법을 이
용한다. 식(3)은 무게중심법을 나타내는 식이다.

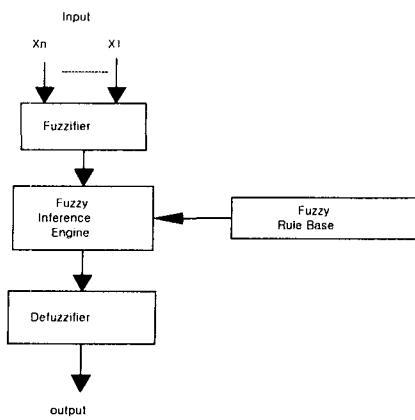


그림 2. FLS의 블록선도

$$g_{Fuzz} = \frac{\sum_{i=1}^n R_i \cdot Z_i}{\sum_{i=1}^n R_i} \cdot S \quad (3)$$

여기서 n 은 제어규칙의 수이고, R_i 는 퍼지추론후의 적합도, Z_i 는 i 번째 제어규칙에서 추론된 후의 퍼지집합의 지지값, S 는 스케일링 벡터이다.

IV. 퍼지 시스템을 이용한 코호넨 클러스터링 네트워크

KCN의 문제점을 개선하기 위한 방식을 제안한다. 제안한 방식은 퍼지시스템을 이용하여 학습하는 동안 자동적으로 이웃 반경의 크기와 학습율을 조절한다. 퍼지 시스템의 입력은 입력 데이터와 연결강도와의 거리와 거리의 변화율을 사용하였으며, 출력은 이웃 반경의 크기와 학습율을 사용하였다. 퍼지 시스템의 제어 규칙은 기존의 코호넨 클러스터링 네트워크를 이용한 시뮬레이션에 의하여 정하였다.

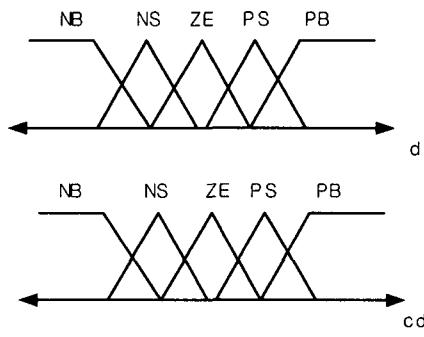


그림3. 학습율에 관한 입력 멤버쉽 함수

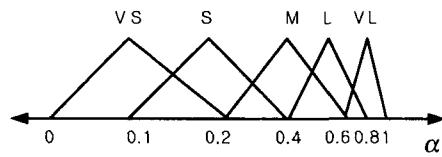


그림 4. 학습율에 관한 출력 멤버쉽 함수

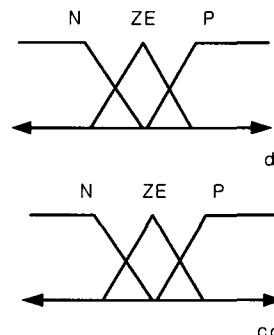


그림 5. 이웃반경에 관한 입력 멤버쉽 함수

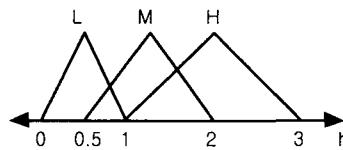


그림 6. 이웃반경에 관한 출력 멤버쉽 함수

표 1. 학습율의 제어 규칙

cd/d	NB	NS	ZE	PS	PB
NB	VL	VL	VL	L	M
NS	VL	VL	L	M	S
ZE	VL	L	M	S	VS
PS	L	M	S	VS	VS
PB	M	S	VS	VS	VS

표 2. 이웃반경의 제어 규칙

cd/d	N	Z	P
N	H	H	M
Z	H	M	L
P	M	L	L

V. 시뮬레이션

Anderson의 IRIS 데이터 150개를 대상으로 시뮬레이션 하였다. IRIS데이터는 4차원 벡터로 3개

의 클래스로 구성되어 있다. IRIS데이터는 로그 변환을 이용하여 정규화 시켰다.

$$x' = \ln(x - \min(x) + 1) \quad (4)$$

여기서, \ln 은 자연로그이다.

KCN의 학습율은 지수 감쇠함수를 이용하였다 [1].

$$\alpha(t) = \alpha_0 \exp\left(-\frac{t}{\tau_1}\right) \quad t=0,1,2,\dots \quad (5)$$

여기서, τ_1 은 시상수이다. 이웃반경 함수는 다음과 같다.

$$h_{i,i(x)}(t) = \exp\left(-\frac{d_{j,i}^2}{2\alpha^2(t)}\right) \quad t=0,1,2,\dots \quad (6)$$

여기서, d 는 Euclidean distance이다. 종료 조건인 오차율 $\epsilon = 0.0001$, 최대 반복시간 $t_{\max} = 5,000$ 으로 고정하였다.

뉴런의 초기연결강도는 0.0006에서 1.7236까지 범위 내에 랜덤한 값을 이용하였다. 입력층의 뉴런은 4개, 출력층 뉴런은 100개로 10×10 격자 형태로 구성하였다. FKCN의 경우 같은 초기조건하에서 시뮬레이션을 실행하였다.

아래 그림은 IRIS 데이터 분포와 KCN, FKCN의 시뮬레이션 결과를 나타내며, 오차율 변화가 심한 200번째 반복 구간까지를 나타낸다.

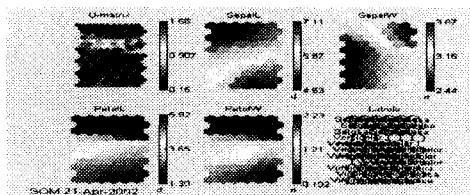


그림 4 IRIS데이터 분포

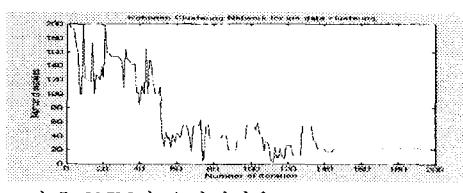


그림 5. KCN의 오차변화율

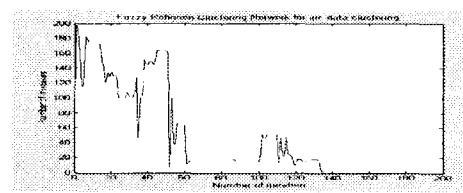


그림 6. FKCN의 오차변화율

시뮬레이션 결과 제안한 방식의 인식율은 96.5%로 일반적인 KCN 방식의 인식율보다 약 10% 향상되었고, 평균 반복 학습은 약 30% 감소하였다. 오차율의 변화도 KCN에 비해 완만히 변화하였다.

VI. 결론

본 논문에서는 KCN의 문제점을 개선하기 위한 방식을 제안하였다. 제안한 방식은 퍼지시스템을 이용하여 학습하는 동안 자동적으로 이웃 반경의 크기와 학습율을 조절한다. 제안한 방식의 유용성을 입증하기 위하여 IRIS데이터를 대상으로 시뮬레이션 하였다. 제안한 방식의 인식율은 96.5%로 일반적인 KCN 방식의 인식율보다 약 10% 향상되었고, 평균 반복 학습은 약 30% 감소하는 등 제안한 방식의 우수성을 확인하였다.

참고문헌

- [1] Simon Haykin "Neural Networks" Second Edition, Prentice Hall International, Inc, 1999
- [2] Bezdek J.C, Tsao E.C.-K, Pal N.R " Fuzzy Kohonen Clustering Networks" Fuzzy system, 1992, IEEE International Conference on, 1992
- [3] El Majek J., Tourki R., "Kohonen clustering networks for use in Arabic word recognition system" Microelectronics, 1998. ICM '98. Proceedings of the Tenth International Conference on, 1998
- [4] Li-Xin Wang "A Course in Fuzzy Systems and Control" Prentice-Hall International, Inc, 1997
- [5] Abhijit S. Pandya, Robert B. Macy "Pattern Recognition with Neural Networks in C++" CRC Press, 1995
- [6] Richard O. Duda, Peter E. Hart, David G. Stork "Pattern Classification" Second Edition, John Wiley & Sons, Inc, 2000
- [7] Singh Kh.M, Bora P.K., Mahanta A. "Features preserving filters using fuzzy Kohonen clustering network in detection of impulse noise" Electrical and Electronic Technology, 2001
- [8] Kevin M. Passino, Stephen Yurkovich "Fuzzy Control" Addison-Wesley, 1997