

LVQ(Learning Vector Quantization)을 퍼지화한 학습 법칙을 사용한 퍼지 신경회로망 모델

김용수

대전대학교 컴퓨터 공학부

대전시 동구 용운동 96-3, 300-716

Tel: +82-42-280-2547, Fax: +82-42-284-0109, E-mail: kkystj@dju.ac.kr

Abstract

본 논문에서는 LVQ를 퍼지화한 새로운 퍼지 학습 법칙들을 제안하였다. 퍼지 LVQ 학습법칙 1은 기존의 학습률 대신에 퍼지 학습률을 사용하였는데 이는 조건 확률의 퍼지화에 기반을 두고 있다. 퍼지 LVQ 학습법칙 2는 클래스들 사이에 존재하는 입력 벡터가 결정 경계선에 대한 정보를 더 가지고 있는 것을 반영한 것이다. 이 새로운 퍼지 학습 법칙들을 improved IAFIC(Integrated Adaptive Fuzzy Clustering) 신경회로망에 적용하였다. Improved IAFIC 신경회로망은 ART-1 (Adaptive Resonance Theory) 신경회로망과 Kohonen의 Self-Organizing Feature Map의 장점을 취합한 퍼지 신경회로망이다. 제안한 supervised IAFIC 신경회로망 1 과 supervised IAFIC neural 신경회로망 2의 성능을 오류 역전파 신경회로망의 성능과 비교하기 위하여 iris 데이터를 사용하였는데 Supervised IAFIC neural network 2 가 오류 역전파 신경회로망보다 성능이 우수함을 보여주었다.

Keywords:

LVQ; 퍼지 LVQ 학습 법칙; Improved IAFIC 신경회로망; Supervised IAFIC 신경회로망

서론

신경회로망은 뉴런들이 상호 연결된 네트워크이고, 이 뉴런들은 연결강도에 의해 상호 연결되어 있다. 이 연결강도들은 신경회로망의 성능을 개선하기 위해서 조정이 된다. 따라서 연결강도를 조정하는 학습법칙은 신경회로망의 성능을 좌우하는 중요한 요소들 중의 하나이다. 학습법칙에는 무감독 학습 법칙과 감독 학습 법칙과 강화 학습 법칙이 있다. LVQ는 감독 학습 법칙중 많이 쓰이는 학습 법칙의 하나이다. LVQ는 분류가 맞으면 승자의 연결강도를 입력 벡터쪽으로 조정하고, 분류가 틀리면 연결강도를 입력 벡터쪽으로부터 멀리 보낸다[1, 2]. 이러한 LVQ를 퍼지화하는 연구가 이루어져 왔는데,

Chung과 Lee는 퍼지 소속도를 학습률과 같이 사용하여 LVQ를 퍼지화 하였다[3]. 그들은 목표 소속도와 실제의 퍼지 소속도의 차이에 학습률을 곱한 것을 사용하였으나 현실적으로 목표 소속도를 얻는 것이 어려운 문제점을 안고 있다. Kusumoputro et al. 또한 LVQ를 퍼지화 하였다[4]. 그들은 퍼지 소속도를 학습률과 같이 사용하여 LVQ를 퍼지화 하였다.

본 논문에서는 LVQ를 퍼지화한 2개의 새로운 퍼지 학습 규칙을 제안한다. 이 새로운 퍼지 학습 법칙들은 LVQ의 학습률 대신에 반복횟수의 함수 및 Π 소속 함수와 퍼지 소속도를 사용하였다., Π 소속함수는 outlier들이 클래스들의 대표값들에 미치는 악영향의 정도를 줄여준다. 퍼지 LVQ학습 법칙 1에서 Π 소속함수와 퍼지 소속도를 사용한 것은 조건 확률의 퍼지화에 근거를 두고 있다. 조건 확률은 존재하는 클래스들 중에서 하나의 클래스를 선정할 확률에 입력 벡터의 선정된 클래스에 존재하는 확률을 곱한 것이다. 퍼지 소속도는 존재하는 클래스 중에서 하나의 클래스를 선정할 확률을 퍼지화 한 것이고, Π 함수는 입력 벡터가 선정된 클래스에 존재할 확률을 퍼지화 한 것이다. 퍼지 LVQ학습 법칙 2는 퍼지 LVQ학습 법칙 1에서 사용한 퍼지 소속도 대신에 1과 퍼지 소속도의 차이를 사용하였다. 이는 퍼지 소속도가 입력 벡터가 특정의 클래스에 소속되어 있는 정도를 나타내는 것외에 입력 벡터가 클래스들의 대표값들과 비교하여 상대적으로 위치해 있는 정보를 가지고 있는 것을 활용한 것이다. 입력 벡터가 클래스들의 대표값들 사이에 위치해 있으면 결정 경계선에 대한 정보를 더 가지고 있기 때문에 클래스의 대표값을 조정할 때 더 큰 양을 조정할 수 있도록 한 것이다.

제안한 퍼지 학습 법칙들을 improved IAFIC 신경회로망에 적용하였다[5, 6]. Improved IAFIC 신경회로망은 ART-1 신경회로망[7] 과 Kohonen의 Self-Organizing Feature Map[8]의 장점을 취합한 것이다. Improved IAFIC 신경회로망은 ART-1

신경회로망과 유사한 제어 구조를 가지고 있기 때문에 ART-1 신경회로망과 같이 안정성과 유연성을 가지고 있다. 이 신경회로망은 과거에 배운 내용을 보존하는 안정성이 있으면서도 새로운 입력 벡터를 반영하는 유연성이 있다. ART-1 신경회로망은 잡음에 민감한데 비하여 improved IAFC 신경회로망은 ART-1 신경회로망에 비하여 덜 민감하다. 이는 학습 법칙이 다른 데에서 기인한다. 한편 Kohonen의 Self-Organizing Feature Map은 임의의 작은 수로 연결강도를 초기화 해야 하기 때문에 Underutilization 문제가 있다. Improved IAFC 신경회로망은 ART-1 신경회로망과 유사한 제어 구조를 사용하기 때문에 연결강도를 임의의 작은 수로 초기화 할 필요가 없어서 Underutilization 문제가 없다. Improved IAFC 신경회로망은 vigilance parameter를 사용하여 클래스의 크기와 개수를 조절한다. 그러나 improved IAFC 신경회로망의 vigilance parameter의 의미는 ART-1 신경회로망의 vigilance parameter와는 다르다. 이는 vigilance parameter의 유클리디안 영역에서의 재해석에 기인한다. Improved IAFC 신경회로망에서 vigilance parameter는 거리 임계값 또는 클러스터 반지름과 관계가 있다[9].

제안한 퍼지 신경회로망들의 성능과 오류 역전과 신경회로망의 성능을 비교하기 위하여 iris 데이터를 사용하였다. 이 iris 데이터는 클러스터링 알고리즘의 성능을 비교하는데 많이 사용되어 왔다.

1. Supervised IAFC 신경회로망

Supervised IAFC 신경회로망들은 ART-1 과 유사한 제어구조를 가지고 있다. 따라서, 이들은 안정하면서도 유연하다. 또한 임의의 작은 수로 연결강도를 초기화할 필요가 없기 때문에 underutilization 문제를 해결한다. 이 퍼지 신경회로망 들은 클래스들의 크기와 개수를 조절하기 위하여 vigilance parameter 를 사용하는데, 이 vigilance parameter 의 의미는 ART-1 신경회로망 의 vigilance parameter 와는 다르다. Supervised IAFC 신경회로망 들은 유클리디안 거리를 비유사 척도 (dissimilarity measure)로 사용한다. 따라서, vigilance 테스트에서 이 퍼지 신경회로망 들은 비유사도가 vigilance parameter 보다 작으냐를 테스트한다.

입력 벡터가 supervised IAFC 신경회로망들에 가해진 후, 출력 뉴런들간의 경쟁은 winner-take-all 식으로 일어난다. 입력 벡터와의 유클리디안 거리가 제일 작은 연결강도를 가진 출력 뉴런이 경쟁에서 승리한다. 즉 I 번째 출력 뉴런,

$$I = \min_j \| \mathbf{x} - \mathbf{v}_j(t) \|,$$

이 경쟁에서 승리한다. \mathbf{x} 는 입력 벡터이고, $\mathbf{v}_j(t)$ 는 I 번째 출력 뉴런의 연결강도이다.

출력 뉴런들 중에 승자를 결정한 후에, supervised IAFC 신경회로망 들은 다음의 vigilance 기준에 의해 vigilance test 를 한다:

$$e^{-u_j} \| \mathbf{x} - \mathbf{v}_j(t) \| \leq T,$$

여기서 T는 vigilance parameter 이다.

퍼지 소속도 u_j 는 다음과 같이 정의 된다:

$$u_j = \frac{\left[\frac{1}{\| \mathbf{x} - \mathbf{v}_j(t) \|} \right]^{\frac{1}{m-1}}}{\sum_{j=1}^n \left[\frac{1}{\| \mathbf{x} - \mathbf{v}_j(t) \|^2} \right]^{\frac{1}{m-1}}},$$

여기서 n 은 committed 출력 뉴런의 수이고, $m \in [1, \infty)$ 은 weight exponent 이며 실험적으로 2 로 놓는다. 위의 새로운 vigilance 기준은 퍼지 소속도를 이용하여 입력 벡터의 존재하는 클래스의 연결강도들과의 상대적 거리를 고려한 것이다. 결정 경계선에 가까운 곳에 입력 벡터가 위치할 때 클래스들간의 경쟁이 치열하기 때문에 입력 벡터의 위치가 조금만 변해도 승자를 결정하는 것에 영향을 미칠 수 있다. 반면에 입력 벡터가 경쟁이 약한 곳에 위치할 때는 입력 벡터의 위치가 변하여도 승자를 결정하는 것에 영향을 미치지 않는다. 따라서, 입력 벡터가 경쟁이 치열한 곳에 위치할 때는 입력 벡터와 승자의 연결강도 간의 유클리디안 거리에 큰 가중치를 주고, 경쟁이 약한 곳에 위치할 때는 작은 가중치를 준다. 이는 Mahalanobis 거리가 유클리디안 거리에 통계적 성질을 고려하여 가중치를 다르게 주는 것과 비교할 수 있다. Mahalanobis 거리는 공분산(covariance)을 이용하여 공분산이 크면 공분산 행렬의 역을 곱하므로 가중치가 작고, 공분산이 작으면 가중치가 크다[10]. 그러나, 존재하는 클래스의 개수가 1 이면 $\| \mathbf{x} - \mathbf{v}_j(t) \| \leq T$ 를 vigilance 기준으로 사용한다.

만약 승자가 vigilance 테스트를 만족하면은 supervised IAFC neural network 1 은 승자의 연결강도를 다음의 식에 의하여 조정 한다:

$$\begin{aligned} \mathbf{v}_j(t+1) &= \mathbf{v}_j(t) + f(t) \cdot \prod(\mathbf{x}, \mathbf{v}_j(t), T) \cdot u_j \cdot (\mathbf{x} - \mathbf{v}_j(t)) \\ &\quad \text{if } \mathbf{x} \text{ is classified correctly,} \\ \mathbf{v}_j(t+1) &= \mathbf{v}_j(t) - f(t) \cdot \prod(\mathbf{x}, \mathbf{v}_j(t), T) \cdot u_j \cdot (\mathbf{x} - \mathbf{v}_j(t)) \\ &\quad \text{if } \mathbf{x} \text{ is classified incorrectly,} \\ \mathbf{v}_j(t+1) &= \mathbf{v}_j(t) \\ &\quad \text{for } i \neq 1, \end{aligned}$$

위의 식에서 $f(t)$ 는 $1/1+k(t-1)$ 이다.

$\Pi(\mathbf{x}, \mathbf{v}_i(t), T)$ 는 아래의 식으로 정의 된다:

$$\Pi(\mathbf{x}, \mathbf{v}_i(t), T) = 1 - 2 \left(\frac{\|\mathbf{x} - \mathbf{v}_i(t)\|}{T} \right)^2 \quad \text{when } 0 \leq \|\mathbf{x} - \mathbf{v}_i(t)\| \leq \frac{T}{2},$$

$$2 \left(\frac{\|\mathbf{x} - \mathbf{v}_i(t)\|}{T} \right)^2 \quad \text{when } \frac{T}{2} \leq \|\mathbf{x} - \mathbf{v}_i(t)\| \leq T,$$

$$0 \quad \text{when } \|\mathbf{x} - \mathbf{v}_i(t)\| \geq T.$$

위의 식에서 사용된 퍼지 학습률은 조건 확률의 퍼지화에 근거를 두고 있다. 조건 확률은 존재하는 클래스들 중에서 하나의 클래스를 선정할 확률에 입력 벡터의 선정된 클래스에 존재하는 확률을 곱한 것이다. 퍼지 소속도는 존재하는 클래스들 중에서 하나의 클래스를 선정할 확률을 퍼지화한 것이고, Π 함수는 입력 벡터가 선정된 클래스에 존재할 확률을 퍼지화한 것이다.

다른 한편으로 supervised IAFC 신경회로망 2 는 승자의 연결강도를 아래의 식에 의해서 조정 한다:

$$\mathbf{v}_i(t+1) = \mathbf{v}_i(t) + f(t) \cdot \Pi(\mathbf{x}, \mathbf{v}_i(t), T) \cdot (1 - \mu_i) \cdot (\mathbf{x} - \mathbf{v}_i(t))$$

if \mathbf{x} is classified correctly,

$$\mathbf{v}_i(t+1) = \mathbf{v}_i(t) - f(t) \cdot \Pi(\mathbf{x}, \mathbf{v}_i(t), T) \cdot (1 - \mu_i) \cdot (\mathbf{x} - \mathbf{v}_i(t))$$

if \mathbf{x} is classified incorrectly,

$$\mathbf{v}_i(t+1) = \mathbf{v}_i(t)$$

for $i \neq 1$,

위의 퍼지 학습 법칙에서 $1 - \mu_i$ 를 사용하는 이유는 클래스들 사이에 존재하는 입력 벡터가 결정 경계선에 대한 정보를 더 가지고 있기 때문이다. 한 쪽에 치우쳐있는 입력 벡터는 퍼지 소속도가 크고 연결강도를 조정할 때 결정 경계선을 약화시키는 경향이 있다. 이를 방지시키기 위해서 μ_i 대신에 $1 - \mu_i$ 를 사용하였다.

알고리즘을 요약하면 아래와 같다.

- (1) 파라미터들(t, k)과 입력 뉴런들과 출력 뉴런들을 초기화 한다.
- (2) 입력 벡터 \mathbf{x} 를 가한다.
- (3) 입력 벡터가 첫 번째 입력 벡터이면
- (4)로 가고; 그렇지 않으면 (5)로 간다.
- (4) 입력 벡터를 첫 번째 출력 뉴런의 연결 강도로 하고 (2)로 간다.
- (5) 승자인 출력 뉴런을 찾는다.
- (6) 승자인 출력 뉴런이 vigilance 테스트를 만족하면 (7)로 가고; 그렇지 않으면 (8)로 간다.
- (7) 승자인 출력 뉴런의 연결강도를 조정하고 (2)로 간다.

- (8) 첫 번째 uncommitted 출력 뉴런을 활성화하고 입력벡터를 첫 번째 uncommitted 출력 뉴런의 연결강도로 한다. (2)로 간다.

2. 실험 및 결과

제안한 퍼지 신경회로망들의 성능과 오류 역전과 신경회로망의 성능을 비교하기 위하여 클러스터링 알고리즘의 성능을 비교하는데 많이 쓰이는 iris 데이터를 사용하였다. 오류 역전과 신경회로망은 감독 학습 법칙을 사용한 신경회로망 중에서 잘 알려진 신경회로망 모델이다. iris 데이터는 150 개의 4 차원 데이터로 구성되어 있다. 이 데이터는 3 개의 subspecies 로부터 추출한 데이터이고, 각 subspecies 는 50 개의 데이터를 가지고 있다. 150 개의 데이터 중 임의로 75 개의 데이터를 선정해 훈련 데이터로 사용했는데, 각 subspecies 로부터 25 개의 데이터를 사용하였다. 나머지 75 개의 데이터는 테스트 데이터로 사용하였다.

반복 학습을 하는 중에 현재의 연결강도와 이전의 연결강도의 차이인 $\sqrt{|V(t+1) - V(t)|^2}$ 이 0.01 보다 작으면 연결강도 들이 실험적으로 수렴한 것으로 보고 supervised IAFC 신경회로망들의 훈련을 중단시키도록 하였다. 훈련이 중단된 이후에 supervised IAFC 신경회로망 들을 테스트 하였다. 그림 1 은 supervised IAFC 신경회로망들의 성능과 오류 역전과 신경회로망의 성능을 비교하였다.

		Desired		
		1	2	3
Actual	1	19		
	2	6	25	
	3			25

(1) Supervised IAFC 신경회로망 1

		Desired		
		1	2	3
Actual	1	20		
	2	5	25	
	3			25

(2) 오류 역전과 신경회로망

		Desired		
		1	2	3
Actual	1	23		
	2	2	25	
	3			25

(3) Supervised IAFC 신경회로망 2

그림 1 - iris 데이터를 사용한 3개의 신경회로망들의 성능비교

Supervised IAFC 신경회로망 1 은 훈련시키기 위해 11 번 반복 학습을 하였으며, T 가 1.55 이고 k 가 0.5 일 때 6 개의 오류를 발생시켰다. 그림 2 는 Supervised IAFC 신경회로망 1 을 훈련시킬 때 반복 횟수에 따른 오류의 개수를 보여준다. 오류 역전파 신경회로망은 5 개의 오류를 발생시켰다. Supervised IAFC 신경회로망 2 는 학습시키기 위해 9 번의 반복 학습을 하였으며, 테스트할 때 2 개의 오류를 발생시켰다. 그림 3 은 Supervised IAFC 신경회로망 2 를 훈련시킬 때 반복 학습에 따른 오류의 개수를 보여준다.

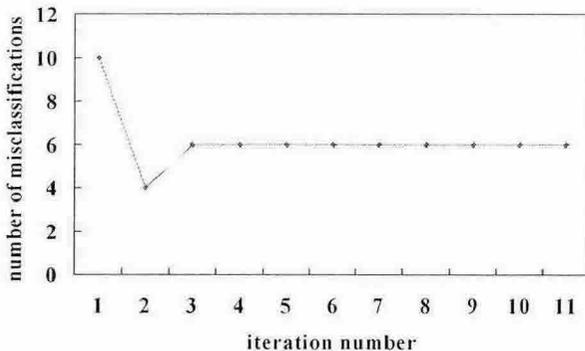


그림 2 - Supervised IAFC 신경회로망 1 을 훈련시킬 때 반복횟수에 따른 오류의 개수

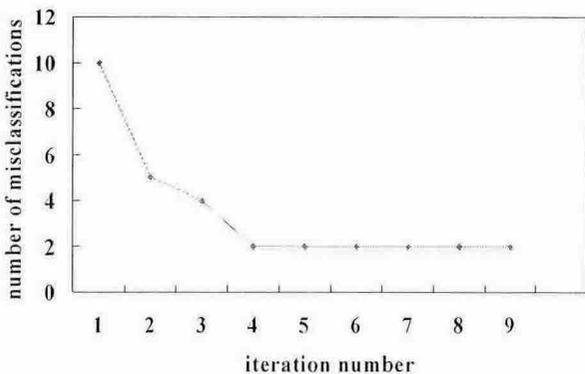


그림 3 - Supervised IAFC 신경회로망 2 를 훈련시킬 때 반복횟수에 따른 오류의 개수

3. 결론

본 논문에서 LVQ 를 퍼지화한 새로운 퍼지 학습 법칙들을 제안하였고, 이 새로운 퍼지 학습 법칙들을 사용하는 supervised IAFC 신경회로망 1 과 supervised IAFC 신경회로망 2 를 제안하였다. Supervised IAFC 신경회로망 1 과 오류 역전파 신경회로망과 supervised IAFC 신경회로망 2 의 성능을 비교하기 위하여 iris 데이터를 사용하였다. Supervised IAFC 신경회로망들은 훈련을 위한 반복 횟수가 다른 신경회로망 모델들에 비해 아주 작고, supervised IAFC 신경회로망 2 는 오류 역전파 신경회로망보다 성능이 우수함을 보여주었다.

4. 참고문헌

- [1] Kohonen, T. (1990). "Self-Organizing Map," *Proceeding of the IEEE*, Vol. 78, No.9, pp.1464-1480.
- [2] Lin, C-T, and Lee, C. S. G. (1996). *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*. Upper Saddle River, NJ : Perntice-Hall.
- [3] Chung, F.-L. , and Lee, T. (1994). "A Fuzzy Learning Model for Membership Function Estimation and Pattern Classification," *Proceeding of the third IEEE Conference on Fuzzy Systems*, Vol. 1, pp. 426-431.
- [4] Kusumoputro, B., Widyanto, M. R., Fanany, M. I., and Budiarto, H. (1999). "Improvement of Artificial Odor Discrimination System Using Fuzzy-LVQ Neural Network," *Proceedings of the third International Conference on Computational Intelligence and Multimedia Applications*, pp. 474-478.
- [5] Kim, Y. S., and Mitra, S. (1994). "An adaptive integrated fuzzy clustering model for pattern recognition," *Fuzzy Sets and Systems*, Vol. 65, pp. 297 - 310.
- [6] Kim, Y. S. (1999). "An Unsupervised neural network Using a Fuzzy Learning Rule," *Proceedings of 1999 IEEE International Fuzzy Systems Conference*, Vol. 1, pp. 349-353.
- [7] Carpenter, G. A., and Grossberg, S. (1987). "A Massively Parallel Architecture for A Self-Organizing Neural Pattern Recognition Machine," *Computer Vision, Graphics, and Image Processing*, Vol. 37, pp. 54-115.
- [8] Kohonen, T. (1989). *Self-Organization and Associative Memory*, 3rd ed., NewYork : Spring-Verlag.
- [9] Moore, B. (1989). "Art-1 and Pattern Clustering," *Proceedings of the 1988 Connectionist Models Summer School*, pp. 174-185.
- [10] Tou, J. T., and Gonzalez, R. C. (1974). *Pattern Recognition Principles*, MA : Addison Wesley.