

분류를 위한 퍼지 규칙의 소속함수 학습

장민경 곽동현⁰ 류정우 김영원
송실대학교 컴퓨터학과

lovekumdo@empal.com⁰, mkim@comp.ssu.ac.kr

Learning Membership Functions of Fuzzy Rules for Classification

Jang-Min Kyung Dong-Heon Kwak⁰ Joung-Woo Ryu Myung-Won Kim
Dept. of Computing, Soongsil University

요 약

패턴 분류 문제에서 수치적 속성일 경우 퍼지 적용은 효과적인 결과를 보인다는 것은 많은 연구를 통해 알려졌다. 하지만 퍼지를 적용한 패턴분류의 결과는 소속함수의 모양과 개수에 따라 크게 영향을 받는다. 이는 문제점을 가지고 있다. 따라서 이러한 문제점은 퍼지를 쉽게 응용분야에 적용시키지 못하는 원인이 된다. 따라서 본 논문에서는 자동으로 소속함수를 정의할 수 있는 소속함수 학습 방법을 제안한다. 제안한 방법은 Penalty연산과 Reward연산을 통해 소속함수가 학습되고 Coverage연산을 통해 소속함수 개수가 학습된다. 제안된 방법의 가능성을 확인하기 위해 벤치마크 데이터 중 Iris, Appendicitis, Breast Cancer를 사용하여 기존 방법과 비교한다.

1. 서 론

패턴 분류 문제에서 규칙 생성을 목적으로 하는 대표적인 분류 방법으로 무질서도 개념을 사용하는 의사결정트리[1]가 있다. 의사결정트리는 분류하고자 하는 속성이 수치적인 경우 수치적 속성을 구간으로 나누어 처리하도록 한다 [1][2]. 그러나, 이러한 방법은 구간을 어떻게 정의하는지에 따라 결과가 민감해지고, 불확실한 정보 표현과 처리에 한계가 있으므로 새로운 차원의 개념처리가 요구된다.

퍼지 이론은 언어적 불확실성을 퍼지 집합의 개념을 이용하여 정량적으로 표현하고 추론할 수 있는 수단을 제공한다. 따라서 분류하고자 하는 패턴이 수치적인 속성일 경우 퍼지 이론을 사용하여 언어적 불확실성을 표현하는 것에 대한 문제점을 해결할 수 있다. 하지만 소속함수의 모양과 개수에 따라 분류의 성능에 큰 영향을 미친다는 단점이 있다.

본 논문에서는 이를 해결하기 위해 소속함수의 모양과 개수를 자동적으로 조절하는 퍼지 규칙의 소속함수 학습 방법을 제안한다. 제안한 학습 방법은 Penalty 연산과 Reward 연산을 통해 속성에 대한 소속함수를 학습시키며, Coverage 연산을 통해 속성에 대한 소속함수의 개수를 자동적으로 조절한다. 또한 제안한 방법의 타당성을 보이기 위해 벤치마크 데이터 중 Iris, Appendicitis, Breast Cancer를 사용하며, 기존 방법과 비교한다.

2. 관련 연구

분류에 있어서 수치적인 속성일 경우 구간 값을 어떻게 정하는지에 따라 결과가 민감해진다. 이는 문제점이 있다. 이러한 문제점은 불확실하거나 애매한 개념을 처리할 때 사용되는 퍼지 이론으로 보완할 수 있다. 그러나 일반적으로 퍼지규칙을 유도할 때 직관적이고 경험적으로 생성하기 때문에 소속함수의 설정이 퍼지시스템에서 중요한 문제가 된다. 따라서 정확한 퍼지 규칙을 생성하기 위한 소속함수 학습 방법이 연구되어지고 있

다. 현존하는 패턴분류 문제에서 소속함수 학습방법은 유전자 알고리즘을 통해 최적의 소속함수 모양과 개수를 결정하는 방법[3]과 온라인 학습을 통한 오류를 보정하는 방법이 있다 [4].

히스토그램을 기반으로 초기 소속함수를 생성하고 유전자 알고리즘을 통해 생성된 초기 소속함수를 보정하여 최적의 소속함수 모양과 개수를 찾아 주지만 학습 시간이 오래 걸린다는 문제점과 학습 변수에 민감하다는 문제점을 가지고 있다. 또한 상각 소속함수만을 생성하기 때문에 일반성이 결여되어 있다. 반면 오류 보정 학습 방법은 퍼지 규칙의 분류 능력을 향상시키기 위해 잘 못 분류하는 퍼지 규칙의 소속함수에 대해서만 학습을 수행한다. 따라서 수행 속도가 빠르다는 장점을 가지고 있지만 소속함수 개수를 각 속성별로 사용자가 정의해 주어야 한다는 문제점을 가지고 있다.

따라서 본 논문에서는 잘 못 분류하는 소속함수에 대해서만 학습하는 것이 아니고 잘 분류하는 소속함수에 대해서도 학습할 뿐만 아니라 분류할 수 없는 것에 대해서도 학습할 수 있는 기능을 추가하고 학습변수를 상황에 따라 자동으로 설정할 수 있도록 확장된 오류 보정 학습 방법을 제안한다.

3. 확장된 오류 보정 학습 방법

제안하고 있는 확장된 오류 보정 학습방법 과정은 <그림.1>과 같다. 패턴 분류를 위한 초기 규칙은 각 속성의 퍼지집합에 의해 생성하고 각각의 규칙에 대한 대표 클래스와 신뢰도는 다음과 같이 계산한다[5].

(1) 주어진 규칙에 해당하는 퍼지 소속정도를 통해 β_{c1}, β_{c2} 를 다음과 같이 정의한다.

$$\beta_{c1} = \sum_{p \in c1} \mu_1^k(x_{1p}) \cdot \mu_1^k(x_{2p})$$

$$\beta_{c2} = \sum_{p \in c2} \mu_1^k(x_{1p}) \cdot \mu_1^k(x_{2p})$$


(2) 구해진 β_{c1}, β_{c2} 를 통해 다음과 같이 대표 클래스를 구한다.

If $\beta_{c1} > \beta_{c2}$, then $C_{ij}^* = C_1$, If $\beta_{c1} < \beta_{c2}$, then $C_{ij}^* = C_2$

1) 본 연구는 한국 과학기술부에서 지원하는 뇌신경정보학연구 사업으로 수행되었음.

(3) 만약 $\beta_{c1} \neq \beta_{c2}$ 경우 주어진 규칙에 대한 신뢰도는 다음과 같이 결정한다.

$$CF_r^* = \frac{|\beta_{c1} - \beta_{c2}|}{(\beta_{c1} + \beta_{c2})}$$



<그림1> 수행 과정

3.1 대표 규칙 (Single Winner Rule)

초기 규칙들이 생성되면, 입력 패턴에 대해서 활성화되는 규칙들 중 대표규칙(Single Winner Rule)을 정의한다. 만약 입력 패턴으로부터 k 개의 초기 규칙들이 활성화 되었을 때, 다음과 같이 max-product 연산에 의해 대표 규칙을 결정한다.

$$\mu_q(x) \cdot CF_q = \max\{\mu_q(x) \cdot CF_r \mid r = 1, 2, \dots, k\}$$

$$\mu_q(x) = \mu_{q1}(x_1) \cdot \mu_{q2}(x_2) \cdot \dots \cdot \mu_{qn}(x_n)$$

$\mu_q(x)$ 는 규칙의 조건부에 대한 입력 패턴의 소속정도를 의미한다.

3.2 오류 보정을 위한 연산들

제한하고 있는 방법은 기존방법과 다르게 Penalty연산 뿐 아니라 Reward 연산과 Coverage 연산을 통해 학습이 이루어진다.

3.2.1 Penalty 연산

Penalty 연산은 입력패턴에 대해 잘 못 분류하는 소속함수에 대해서 수행되는 연산이다.

<그림3>, <그림4>와 같이 left, center, right 세 개의 x좌표 값을 갖는 삼각형 소속함수가 주어졌을 때, 소속함수는 다음과 같은 과정에 의해 학습이 이루어진다.


(단계 1) 만약, 입력값 x 에 대해 $x \leq center$ 이면, center' = center + d, left' = left + d (d : 학습 매개변수)

(단계 2) 만약, 입력값 x 에 대해 $x > center$ 이면, center' = center - d, right' = right - d (d : 학습 매개변수)


<그림4> <그림5>와 같이 left, center, right 세 개의 x좌표 값을 갖는 좌측 사다리꼴 소속함수가 주어졌을 때, 퍼지 소속함수는 다음과 같은 과정에 의해 학습이 이루어진다.

(단계 1) 만약, 입력값 x 에 대해 $x \leq center$ 이면, center' = x - d, right' = right - d (d : 학습 매개변수)


(단계 2) 만약, 입력값 x 에 대해 $x > center$ 이면, center' = center - d, right' = right - d (d : 학습 매개변수)




<그림3> $x \leq center$ 일 경우 Penalty 연산 적용 예



<그림4> $x > center$ 일 경우 Penalty 연산 적용 예



<그림5> 좌측 사다리꼴 소속함수 Penalty 연산 적용 예




<그림6> 우측 사다리꼴 소속함수 Penalty 연산 적용 예

3.2.2 Reward 연산


Reward 연산은 입력패턴에 대해 잘 분류되는 규칙에 대해서는 소속함수의 소속정도를 높여주는 연산이다. 연산은 <그림6> <그림7>와 같이 수행된다.

(단계 1) 만약, 입력값 x 에 대해 $x \leq center$ 이면, center' = center - d, left' = left - d (d : 학습 매개변수)

(단계 2) 만약, 입력값 x 에 대해 $x > center$ 이면, center' = center + d, right' = right + d (d : 학습 매개변수)



<그림6> $x \leq center$ 일 경우 Reward 연산 적용 예



<그림7> $x > center$ 일 경우 Reward 연산 적용 예

이상 기술한 두 연산을 적용하기 위해서는 소속함수를 학습시키기 위한 학습 변수가 필요하다. 따라서 제한한 방법에서는 이러한 학습 변수를 규칙의 신뢰도 값에 비례하여 자동으로 조정되도록 하고 신뢰도와의 결합은 Product 연산을 사용한다.

3.2.3 Coverage 연산

소속함수에 대한 학습 수행 시, 활성화된 규칙들 중 주어진

입력 패턴을 맞추는 규칙이 없을 경우 Coverage 연산을 수행한다. 즉, 입력 패턴에 대해 새로운 소속함수를 생성하게 되는데, 입력 패턴을 소속함수의 중앙 좌표 값으로 하는 삼각 소속함수를 생성한다. 이러한 소속함수를 생성함으로써 그에 대한 새로운 규칙들이 생성되고 따라서 항상 활성화된 규칙들 중 입력패턴을 맞추는 수 있도록 하여 적용시 미분류 패턴이 발생하지 않도록 한다. 이와 같이 Coverage 연산을 수행함으로써 속성별 소속함수 개수를 사용자가 직접 정의해주어야 하는 문제점을 해결할 수 있다.

4. 실험

4.1 실험 방법 및 실험 데이터

본 논문에서 제안한 방법의 타당성을 확인하기 위하여 패턴 분류 문제에 표준적으로 사용되는 Iris data, Appendicitis data, Breast Cancer data를 사용하였다. 초기 규칙을 생성하기 위해 사용된 각 데이터들의 속성은 속성 선택 기법[4]에 의해 데이터 속성들 중에서 분류가 잘 이루어지는 두 개의 속성을 선택하였으며, 속성별 소속함수의 개수는 두 개와 세 개로 제한하여 생성하였다. 단, coverage 연산을 적용할 때에는 각 속성별 초기 소속함수 개수를 두개로 하였다. 입력 데이터는 [0,1]의 값으로 정규화하였다. Iris data, Appendicitis는 Leaving-one-out 방법으로 실험하였다. Leaving-one-out 방법은 n개의 데이터 중 n-1개의 데이터로 학습하고 나머지 한 개의 데이터로 테스트하는 과정을 n번 반복하여 수행하는 방법이다. Breast Cancer data의 경우는 10-fold cross validation을 사용하여 실험하였다.

4.2 실험 결과


<표 1>은 각 실험 데이터에 대해 오류 보정 학습 방법을 사용했을 때의 인식률과 본 논문에서 제안한 소속함수 학습 방법을 적용하였을 때의 인식률을 보여주고 있다.

표 1. 확장된 오류보정학습에 의한 인식률

		속성별 소속함수 개수	
		2개	3개
Iris data	Error Correction	66.7 %	95.3 %
	[penalty만 적용]	60.0 %	87.0 %
	[penalty+reward 적용]	82.7 %	96.0 %
	[penalty+reward+coverage 적용]	96.7 %	
Appendicitis data	Error Correction	80.2 %	78.3 %
	[penalty만 적용]	80.2 %	80.2 %
	[penalty+reward 적용]	82.1 %	82.1 %
	[penalty+reward+coverage 적용]	82.1 %	
Breast Cancer data	Error Correction	71.6 %	75.0 %
	[penalty만 적용]	32.8 %	70.0 %
	[penalty+reward 적용]	70.0 %	75.6 %
	[penalty+reward+coverage 적용]	75.6 %	

실험데이터에 대하여 소속함수를 학습시키기 위해 Penalty 연산만 적용하였을 경우 입력 데이터를 포함하지 않는 영역이 발생하여, 미분류 되는 데이터가 발생함으로써 낮은 인식률을 보이고 있다. 하지만, Penalty 연산과 Reward 연산을 수행했을 경우 Penalty 연산시 미분류 되었던 데이터에 대하여 소속함수가 학습이 수행되어 전체적으로 인식률이 향상된 것을 확인할 수 있다. 그러나 Appendicitis data의 경우 전체 데이터의 클래스수가 서로 교차하는 부분이 넓게 분포하는 데이터의 특성상 Penalty 연산만 적용할 경우 Iris data에서와 같이 미분류 되는 데이터가 발생할 경우 Reward 연산 적용 전후 각각 80.2%

와 82.1%의 인식율을 보이고 있다. <그림8>은 Iris data에 대하여 Penalty 연산 수행, Penalty 연산과 Reward 연산을 수행, Penalty 연산과 Reward 연산, Coverage 연산을 수행한 각각에 대하여 학습이 수행된 후의 소속함수를 보여준다.



<그림 8> Iris data 에 대한 각 연산 수행 후 소속함수

각 실험 데이터에 대하여 속성에 대한 소속함수를 학습시키기 위하여 Penalty 연산과 Reward 연산을 적용하고, 소속함수의 개수를 조정하기 위해 Coverage 연산을 적용한 결과 새로운 소속함수가 생성된 것을 확인할 수 있다. 새로운 소속함수는 입력 데이터가 포함되지 않는 경우 패턴을 분류하기 위해 생성되며, Penalty 연산과 Reward 연산을 통해 다시 학습된다.

5. 결론 및 향후 연구

기존의 퍼지 규칙 학습 알고리즘은 각 속성별 소속함수의 개수와 모양에 따라 시스템의 성능이 영향을 받는다는 단점과 학습에 사용되는 변수를 직접 정의해 주어야 하는 문제점이 있다. 본 논문에서는 퍼지 규칙에 기반한 기존 분류 방법의 단점을 보완하였으며, 효율적인 퍼지 규칙 생성을 위한 학습 방법을 제안하였다. 퍼지 추론에 의해 선택된 대표 규칙을 통해 입력 데이터가 올바르게 분류되지 않은 경우에는 Penalty 연산을 수행하며, 올바르게 분류된 규칙에 대해서는 Reward 연산을 수행하여 소속 함수를 학습시킨다. 활성화된 규칙 중 입력 패턴에 대해 맞추는 규칙이 존재하지 않을 경우, Coverage 연산을 통해 새로운 소속함수를 생성하게 된다. Coverage 연산을 통해 분류할 수 없는 데이터에 대한 문제를 해결하며, 속성별 소속함수의 개수를 사용자가 직접 정의해 주어야 하는 문제점을 해결할 수 있다. 또한 학습 과정시 자동으로 입력변수를 조정함으로써 학습 과정에 있어 학습 변수에 대한 민감한 문제를 해결할 수 있다.

향후연구로는 다차원에 대해서 실험한 결과를 분석할 것이고 제안한 방법의 효율성을 향상시킬 수 있는 속성 선택 기법을 개발 할 것이다.

6. 참고 문헌

[1] J. Ross Quinlan, C4.5 : programs for machine Learning, Morgan Kaufmann, 1993.
 [2] Ian H. Witten, Eibe Frank, Data Mining : Practical machine Learning Tools and Techniques with Java Implementations, Morgan Kaufmann, 1999.
 [3] M.W. Kim, J.G.Lee and C.W.Min, Efficient Fuzzy Rule Generation Based on Fuzzy Decision Tree for Data Mining, IEEE Int. Fuzzy Systems Conf. Proceeding, 1999,pp.1223-1228
 [4] Nakashima, T. Nakai, G. Ishibuchi, H. Improving the performance of fuzzy classification systems by membership function learning and feature selection. Fuzzy System, 2002. FUZZ-IEEE'02. Pro. of the 2002 IEEE Int.I Conf. on, Vol: 1, 2002. pp488-493
 [5] Ishibuchi, H. Nozaki, K. Tanaka, H. Pattern classification by distributed representation of fuzzy rules. Fuzzy Systems, 1992. IEEE Int. Conf. on, 1992. pp.143-650