퍼지 및 지능시스템학회 논문지 2007, Vol. 17, No. 4, pp. 460-465

규칙의 커플링문제를 최소화하기 위한 퍼지-러프 분류방법

A Fuzzy-Rough Classification Method to Minimize the Coupling Problem of Rules

손창식* · 정환묵* · 서석태** · 권순학**
Chang S. Son, Hwan M. Chung, Suk T. Seo, Soon H. Kwon

* 대구가톨릭대학교 컴퓨터정보통신공학부
** 영남대학교 전기공학과

요 약

본 논문에서는 규칙의 커플링 문제를 최소화하기 위해 주어진 데이터의 통계적 특성과 퍼지-러프집합을 기반으로 한 새로운 패턴분류 방법을 제안한다. 제안한 방법 하에서 주어진 데이터의 통계적 특성은 입력부 퍼지집합의 파티션 개수를 결정하고, 생성된 규칙의 커플링문제를 최소화하기 위한 선택기준으로 사용하였다. 또한 러프집합은 수치적인 데이터로부터 생성된 규칙들 간의 불필요한 속성들을 제거하기 위한 도구로서 이용하였다. 제안된 방법의 타당성을 검증하기 위하여 Fisher의 IRIS 데이터를 사용하여 기존의 패턴분류 방법과 분류 정확도를 비교하였다. 실험결과, 제안한 방법이 기존의 학습에 의한 방법들보다 비교적 좋은 성능을 가진다는 것을 알 수 있었다.

키워드 : 규칙의 커플링, 패턴분류, 퍼지-파티션, 규칙생성, 규칙감축

Abstract

In this paper, we propose a novel pattern classification method based on statistical properties of the given data and fuzzy-rough set to minimize the coupling problem of the rules. In the proposed method, statistical properties is used by a selection criteria for deciding a partition number of antecedent fuzzy sets, and for minimizing an coupling problem of the generated rules. Moreover, rough set is used as a tool to remove unnecessary attributes between generated rules from the numerical data. In order to verify the validity of the proposed method, we compared the classification results (i.e, classification precision) of the proposed with the conventional pattern classification methods on the Fisher's IRIS data. From experiment results, we can conclude that the proposed method shows relatively better performance than those of the classification methods based on the conventional approaches.

Key Words : Coupling of Rules, Pattern Classification, Fuzzy-Partition, Rule Generation, Rule Reduction

1. 서 론

퍼지규칙 기반 분류시스템에서 분류의 성능은 규칙들 간에 커플링문제를 얼마나 최소화하느냐에 따라 결정된다. 다시 말해, 분류의 성능을 향상시키기 위해서 주어진 입력패턴으로부터 생성한 규칙이 얼마나 정확한가? 그리고 그 규칙에 대응하는 파티션 구간(분류경계)이 적절한가? 의 여부에 의해서 결정된다. 하지만 이 두 가지 측면은 서로 상호보완적인 관계에 있기 때문에 결정하기란 그리 쉽지가 않다. 그래서 이러한 점들을 보다 객관적으로 고려하기 위해 신경망이나 유전자알고리즘, 그리고 엔트로피 최적화 기법들을 결합한 다양한 접근방법들이 제안되었다.

제안된 기존의 대표적인 방법들로는 주어진 입력패턴으로부터 생성된 각 규칙의 확신도(certainty factor)를 가중치로 조절함으로써 분류 경계를 조절하는 방법[1]과 주어진 데이터로부터 최적의 규칙을 추출하기 위한 학습에 의한 방법[2-8], 그리고 엔트로피와 러프-퍼지집합을 이용한 분류규칙 추출 및 파티션 결정방법[9-11] 등이 있다.

접수일자 : 2007년 4월 3일
완료일자 : 2007년 7월 31일

규칙의 가중치를 고려한 확신도 조절방법[1]에서는 생성된 각 규칙의 확신도를 가중치로 조절함으로써 학습에 의한 방법을 사용하지 않더라도 분류 경계를 효과적으로 조절할 수 있음을 제시하였고, 신경망이나 유전자알고리즘을 결합한 방법[2-8]에서는 학습을 통해 최적의 분류경계면과 규칙을 자동 생성할 수 있는 방법을 제안하였다. 게다가 엔트로피를 기반으로 한 분류방법[9]에서는 Pawlak [12,13]에 의해서 제안된 러프집합 개념을 확장한 VP-Model (Variable Precision Rough Set Model)을 사용하여 수치적 데이터로부터 규칙을 추출하고, 엔트로피 최적화 개념을 이용하여 퍼지집합의 파티션 구간을 결정할 수 있는 방법을 제시하였다.

하지만 제안된 기존의 방법들의 공통적인 제약점으로는 규칙의 커플링문제를 최소화하는데 고려되어야 할 변수들이 너무 많고, 학습하는데 소요되는 시간이 오래 걸린다는 것이다.

따라서 본 논문에서는 규칙의 커플링문제를 보다 단순한 방법으로 최소화하기 위해 주어진 데이터의 통계적 특성과 러프집합을 이용한 새로운 방법을 제안한다. 제안된 방법에서 통계적 특성은 입력부 퍼지집합의 파티션을 결정하고, 커플링 되는 규칙을 최소화하기 위한 선택기준으로 사용하였다. 더욱이 러프집합은 수치적 데이터로부터 생성된 규칙들

간의 불필요한 속성을 제거하기 위해서 사용하였다. 그리고 실험에서는 제안된 방법의 타당성을 검증하기 위해 엔트로피, 신경망, 유전자알고리즘을 기반으로 한 방법과 분류 정확도를 비교하였다.

본 논문의 구성은 다음과 같다. 2장에서는 기존의 패턴분류 방법들 중에서 몇 가지 대표적인 방법들과 러프집합에 대해서 소개한다. 3장에서는 커플링문제를 해결하기 위해 주어진 데이터로부터 퍼지집합의 파티션을 결정하는 방법과 규칙 추출 및 선택방법에 대해서 설명한다. 4장에서는 여러 패턴분류 방법과의 비교를 통해 제안된 방법의 타당성을 보여준다. 5장에서는 결론을 맺는다.

2. 기존의 패턴분류 방법

2.1 규칙의 가중치에 의한 분류경계 조절

참고문헌[1]은 패턴분류 경계를 조절하기 위해 신경망이나 유전자알고리즘을 사용하지 않고도 규칙의 가중치만을 고려함으로써 분류경계를 효율적으로 조절할 수 있는 방법을 제안하였다.

만약 다음과 같은 퍼지 IF-THEN 규칙이 있다고 가정할 때 분류 경계는 다음과 같다.

$$\begin{aligned} &Rule\ R_j : If\ x_1\ is\ A_{j1}\ \text{and} \ldots x_n\ is\ A_{jn} \\ &\quad Then\ Class\ C_j,\ j=1,2,\ldots,N \end{aligned}$$

여기서 $CF_j\ (0 \le CF_j \le 1)$는 j번째 규칙의 확신도를 의미한다.

$$\mu_{j^*}(X_p) \cdot CF_{j^*} = \max\{\mu_j(X_p) \cdot CF_j : j=1,2,\ldots,N\} \quad (1)$$

여기서 $\mu_{j^*}(X_p)$는 새로운 패턴 $X_p=(x_{p1},\ldots,x_{pn})$에 대한 j번째의 승자규칙(winner rule)을 의미한다.

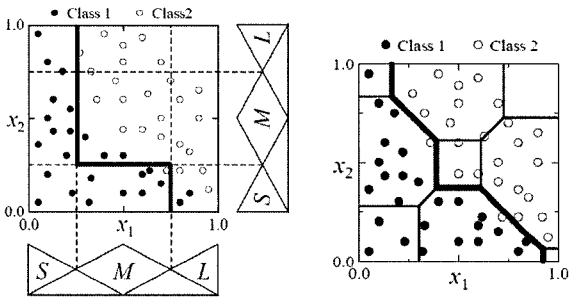

(a) (b)

그림 1. 퍼지 IF-THEN 규칙의 분류경계[1]
(a) 일반적인 분류경계 (b) 가중치에 의해서 조절된 분류경계

Figure 1. Classification boundary of fuzzy if-then rules[1]
(a) General classification boundary (b) Modified classification boundary by (rule) weights

2.2 퍼지 파티션과 규칙의 가중치 조절방법

참고문헌[6,7]에서는 각각 모든 가능한 파티션의 형태를 고려하여 규칙을 생성하고 최종 규칙을 유전자알고리즘으로부터 자동 생성할 수 있는 방법과 분류 성능을 향상시키기 위해 규칙의 확신도를 조절할 수 있는 학습방법을 제안하였다.

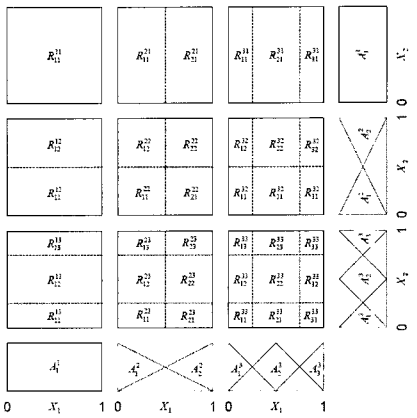

그림 2. $I_{\max}=3,\ J_{\max}=3$의 퍼지 파티션 공간[6]

Figure 2. Fuzzy partition space of $I_{\max}=3,\ J_{\max}=3$[6]

그림 2는 x, y축으로 각각 3개의 파티션 형태를 고려한 모든 가능한 파티션 공간을 나타낸다. 여기서 A_1^1은 *don't care* 파티션 공간을 나타낸다.

다음은 참고문헌[7]에서 제안한 규칙의 확신도를 조절하기 위한 학습방법이다.

$$CF_j^{new} = CF_j^{old} + \eta_1(1 - CF_j^{old}) \quad (2)$$

$$CF_j^{new} = CF_j^{old} - \eta_2 CF_j^{old} \quad (3)$$

여기서 η_1, η_2는 각각 양의 학습률과 음의 학습률을 나타내고, CF_j^{new}, CF_j^{old}는 각각 양과 음의 학습률로 갱신된 새로운 확신도와 이전의 확신도를 나타낸다.

2.3 러프집합

러프집합은 Pawlak[12,13]에 의해서 처음 제안되었고, 주로 분류문제를 처리하기 위한 하나의 수학적 도구로서 사용된다. 일반적으로 러프집합은 주어진 정보가 전체집합으로 정의되는 모든 오브젝트와 관련이 있다는 가설을 기초로 한다. 이러한 가설로부터 주어진 정보를 추출하기 위해서는 리덕트(reduct)와 코어(core)라는 지식감축의 개념을 사용한다.

Skowron[14]는 주어진 정보로부터 리덕트와 코어로 보다 단순한 방법으로 연산이 가능한 식별가능행렬(discernibility matrix)을 제안하였다. 다음은 Skowron에 의해서 제안된 식별가능행렬을 계산하기 위한 방법이다.

$$(c_{ij}) = \{a \in A : a(x_i) \ne a(x_j)\},\ \text{for}\ i,j=1,2,\ldots,n \quad (4)$$

여기서 c_{ij}는 x_i, x_j을 구별하게 하는 모든 속성들의 집합을 의미한다.

따라서 식별가능 행렬에서 코어는 주어진 정보의 핵심적인 부분(단일 원소로 이루어진 항목들의 집합)이므로 다음과 같이 정의될 수 있다.

$$core(A) = \{a \in A : c_{ij} = (a),\ \text{for}\ some\ i,j\} \quad (5)$$

식 (5)로부터 리덕트를 계산하기 위하여 다음과 같이 식별가능 함수 $f(A)$을 계산할 수 있다.

$$f(A)=\prod_{(x,y)\in U^2}\left\{\sum\delta(x,y):(x,y)\in U^2 \text{ and } \delta(x,y)\neq 0\right\} \quad (6)$$

식 (6)에 의해서 계산된 리덕트로부터 각 오브젝트 x에 대한 최종 식별가능 함수 $f^x(A)$을 다시 정의할 수 있다.

$$f^x(A)=\prod_{y\in U}\left\{\sum\delta(x,y):y\in U \text{ and } \delta(x,y)\neq 0\right\} \quad (7)$$

3. 퍼지-러프 분류방법

3.1 퍼지집합의 파티션 결정

본 절에서는 입력부 퍼지집합의 파티션 수와 구간을 객관적으로 결정하기 위해 주어진 입력데이터의 정보만을 고려하여 결정하였다.

식 (8)에서 식 (10)은 주어진 임의의 데이터(d)로부터 퍼지집합의 파티션 수와 파티션 구간을 결정하기 위한 방법이다.

$$P=\{p_1,p_2,...,p_i,...,p_n\} \quad (8)$$

$$p_i=\frac{\alpha_i^{\max}-\alpha_i^{\min}}{d_i^{sd}},\ d_i\in[\alpha_i^{\min},\ \alpha_i^{\max}] \quad (9)$$

$$(\alpha_i^{\min}=d_i^{\min}-d_i^{sd},\ \alpha_i^{\max}=d_i^{\max}+d_i^{sd})$$

여기서 P는 주어진 데이터의 전체 속성(변수)에 대한 파티션 정보를 나타내고, $p_i\ (i=1,2,...,n)$는 전체 n개의 속성 중에서 i번째 속성의 파티션 수를 나타낸다. 또한 $d_i^{\min}, d_i^{\max}, d_i^{sd}$는 각각 전체 데이터의 최소값, 최대값, 그리고 표준편차를 의미한다.

식 (9)에서 $\alpha_i^{\min}=d_i^{\min}-d_i^{sd}$와 $\alpha_i^{\max}=d_i^{\max}+d_i^{sd}$는 새로운 입력 데이터가 들어올 경우, 매핑을 위한 추가적인 공간을 확보하기 위해 표준편차만큼 공간을 확장한 것을 나타낸다.

다음은 식 (9)로부터 획득한 파티션 수 p_i을 근거로 k개의 파티션 구간을 나눈 것을 표현한 것이다.

$$p_i=\{q_i^1,q_i^2,...,q_i^k\} \quad (10)$$

제안한 방법에서는 k개의 파티션 구간, 즉 $q_i^1,q_i^2,...,q_i^k$는 서로 동일한 크기의 범위를 가진 구간으로 설정하였다.

3.2 규칙의 커플링문제를 최소화하기 위한 규칙 추출 및 선택방법

규칙의 커플링문제를 최소화하기 위해서 제안한 방법에서는 입력데이터에 대응하는 소속함수들을 추출하여 규칙을 구성하고, 추출된 규칙의 빈도와 적합도(compatibility)를 고려하여 각 클래스에 해당하는 규칙을 선택하였다.

만약 다음과 같은 퍼지 $IF \sim THEN$ 규칙이 있다고 가정하자.

$$Rule^i: IF\ x_{i1}\ is\ A_{i1} \text{ and } ... \text{ and } x_{in}\ is\ A_{in}$$
$$THEN\ C_j$$

여기서 $x_{i1},...,x_{in}$과 y_i는 각각 입력변수(antecedent variable)와 출력변수(consequent variable)를 의미하고, $A_{i1},...,A_{in}$과 $C_j(j=1,2,..,k)$는 각각 입력부 소속함수와 출력부 클래스를 나타낸다.

이때 m개의 수치적인 입력패턴이 주어졌을 때 규칙 추출은 다음과 같다.

$$NR_l=\max(\min(\mu_{A_{i1}}(\alpha),\mu_{A_{i2}}(\beta),...,\mu_{A_{in}}(\omega))) \quad (11)$$
$$(l=1,2,...,m)$$

여기서 $\mu_{A_{i1}}(\alpha),\mu_{A_{i2}}(\beta),...,\mu_{A_{in}}(\omega)$는 각 입력변수에 대응하는 소속함수의 적합도를 나타낸다. 즉 입력 패턴에 대해서 최대 적합도를 가지는 소속함수만을 추출하여 규칙을 구성한다는 것을 의미한다.

다음은 식 (11)로부터 얻은 규칙과 적합도를 이용하여 각 클래스에 해당하는 규칙을 선택하기 위한 판단기준이다.

(1) 커플링 규칙이 발생하지 않는 경우

추출된 규칙의 빈도와 적합도에 관계없이, 각 클래스에 대응하는 규칙은 해당 클래스의 규칙으로 선택한다.

(2) 커플링 규칙이 발생하는 경우

$$f_{C_s}=\sum_{i=1}^{n}NR_l \quad (12)$$

$$f_{C_t}=\sum_{i=1}^{n}NR_l \quad (13)$$

여기서 f_{C_s}, f_{C_t}는 각각 전체 n개의 규칙 중에서 s번째와 t번째 클래스에 대한 규칙의 빈도수를 나타낸다.

$$NR_l=\begin{cases}C_s, & f_{C_s}>f_{C_t}\\ C_t, & f_{C_s}<f_{C_t}\end{cases} \quad (14)$$

식 (14)에서 $f_{C_s}>f_{C_t}$, $f_{C_s}<f_{C_t}$는 각각 s번째 규칙의 빈도수가 t번째의 빈도수보다 큰 경우 s번째 클래스의 규칙으로 선택하고, 그렇지 않은 경우는 t번째 클래스의 규칙으로 선택함을 의미한다.

$$NR_l=\begin{cases}C_s, & \max_l(\mu_{C_s})>\max_l(\mu_{C_t}),\ \text{if } f_{C_s}=f_{C_t}\\ C_t, & \max_l(\mu_{C_s})<\max_l(\mu_{C_t}),\ \text{if } f_{C_s}=f_{C_t}\end{cases} \quad (15)$$

식 (15)에서는 만약 s번째 규칙의 빈도수와 t번째 규칙의 빈도수가 같다면, 규칙은 s번째 클래스의 최대-적합도와 t번째 클래스의 최대-적합도를 비교하여 더 큰 적합도를 가진 클래스로 분류하는 것을 나타낸다.

본 논문에서는 주어진 데이터만을 고려하여 규칙을 획득하기 위해 수치적인 입력패턴으로부터 규칙을 생성하고, 규칙의 빈도수와 적합도를 이용하여 각 클래스의 규칙을 선택하였다. 하지만 최종적으로 생성된 규칙은 각 입력변수들 간의 상관성만을 고려하여 추출된 규칙이므로 아직 불필요한 속성이 남아 있을 수 있다.

따라서 생성된 규칙을 보다 최적의 규칙으로 구성하기 위해 2장에서 소개한 러프집합을 이용하여 규칙들 간에 상관성을 고려하여 최종 규칙을 획득하였다.

3.3 패턴분류

본 절에서는 3.2절에서 획득한 규칙으로부터 주어진 입력패턴의 적합도를 계산하여 각 클래스에 대응하는 규칙의 이행정도(degree of fulfillment)가 최대인 규칙을 추출하여 출력을 결정하였다.

다음은 입력패턴에 대해서 최종 클래스를 결정하기 위한

수행단계를 나타낸다.

Step 1) 각 입력패턴의 입력부 적합도를 계산한다.

$$W_i = \min(\mu_{A_{i1}}(\alpha),...,\mu_{A_{in}}(\omega)) \quad (16)$$

여기서 W_i는 n개의 입력패턴에 대한 i번째 규칙의 적합도를 나타낸다.

Step 2) 입력부 적합도로부터 규칙의 이행정도를 계산한다.

$$\mu_{dof_i}(y) = \max(W_i) \quad (17)$$

여기서 $\mu_{dof_i}(y)$는 규칙의 이행정도가 최대인 규칙을 출력 클래스로 결정한다는 것을 의미한다.

4. 실험결과 및 검토

실험에서는 패턴분류 연구 분야에서 널리 사용되는 Fisher[15]의 IRIS 데이터를 바탕으로 제안한 방법의 효과성을 보이고자 한다.

Fisher의 IRIS 데이터의 각 클래스는 3가지 종류(Setosa, Versicolor, Virginica)로 나누어진다. 게다가 각 데이터는 4개의 속성을 갖는 4차원으로 이루어져 있으며, 각 속성은 Sepal Length(SL), Sepal Width(SW), Petal Length(PL), Petal Width(PW)으로 구성되어 있다.

4.1 파티션 결정

주어진 IRIS 데이터의 정보만을 이용하여 입력부 퍼지집합의 파티션을 결정하기 위해 다음과 같은 통계적 특성을 활용하였다.

표 1. IRIS 데이터의 통계적 특성
Table 1. Statistical properties of IRIS data

통계적 정보 / 속성	Min	Max	Sd
Sepal Length	4.3	7.9	0.828
Sepal Width	2.0	4.4	0.436
Petal Length	1.0	6.9	1.762
Petal Width	0.1	2.5	0.765

표 1에서 Min, Max, 그리고 Sd는 IRIS 데이터의 각 속성, 즉 Sepal Length, Sepal Width, Petal Length, Petal Width의 최소, 최대, 표준편차를 나타낸다.

식 (9)로 획득한 각 속성의 파티션 구간과 파티션 수는 다음과 같다.

표 2. 파티션 수와 구간
Table 2. Numbers of partitions and their intervals

파티션 / 속성	파티션 수	파티션 구간
Sepal Length	6	[3.472 8.728]
Sepal Width	8	[1.564 4.836]
Petal Length	5	[0 8.662]
Petal Width	4	[0 3.265]

예를 들어, 표 2에서 Sepal Length의 파티션 수는 $\frac{8.728-3.472}{0.828} = 6.3478 \fallingdotseq 6$을 의미한다.

식 (9)로부터 획득한 IRIS 데이터의 파티션 수와 파티션 구간으로부터 다음과 같은 입력부 퍼지집합을 생성하였다.

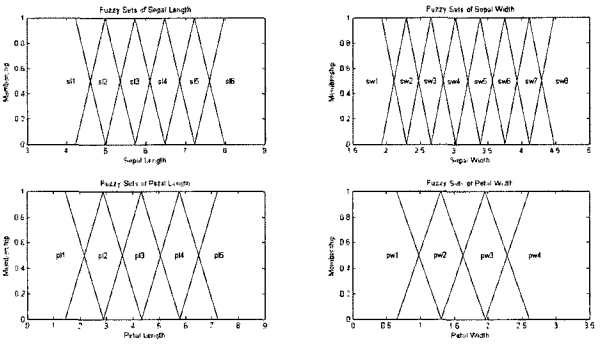

그림 3. 입력부 퍼지집합
Figure 3. Fuzzy sets for antecedent parts

4.2 규칙추출 및 선택

4.1절에서 생성한 입력부 퍼지집합으로부터 생성할 수 있는 모든 규칙의 수는 $6 \times 8 \times 5 \times 4 = 960$개이다. 이러한 많은 양의 규칙을 도메인 전문가나 시스템 설계자로부터 획득하기란 싶지 않다.

따라서 제안된 방법에서는 주어진 입력패턴에 대응하는 규칙, 즉 수치입력패턴에 대응하는 규칙 중에서 최대 적합도를 가지는 규칙만을 추출하여 규칙을 구성하였다.

식 (11)의 max-min 연산으로 51개의 규칙을 얻을 수 있었고, 획득한 규칙을 근거로 커플링이 발생하지 않는 규칙과 발생하는 규칙을 각 클래스 별로 분석한 결과, 다음과 같음을 알 수 있었다.

<커플링이 발생하지 않은 경우>
- Setosa로 분류되는 규칙 - 10개 규칙
- Versicolor로 분류되는 규칙 - 15개 규칙
- Virginica로 분류되는 규칙 - 23개 규칙

<커플링이 발생한 경우>
- Setosa로 분류되는 규칙 - 존재하지 않음
- Versicolor로 분류되는 규칙 - 3개 규칙
- Virginica로 분류되는 규칙 - 3개 규칙

다음은 Versicolor와 Virginica 클래스에서 커플링이 발생하는 3개의 규칙을 나타낸다.

규칙 1 : SL is sl3, SW is sw2, PL is pl3, PW is pw2.
규칙 2 : SL is sl3, SW is sw3, PL is pl4, PW is pw2.
규칙 3 : SL is sl3, SW is sw4, PL is pl3 PW is pw3.

식 (12)과 식 (13)을 계산한 결과, 규칙 1(0.7, 0.5367), 규칙 2(0.5325, 0.5), 규칙 3(0.5055, 0.6333)이 Versicolor 클래스에 대응된 빈도수는 각각 4번, 1번, 1번이었고, Virginica 클래스에 대응된 빈도수는 각각 1번, 1번, 2번이었다. 규칙

1,2,3의 괄호 안에 첫 번째 값은 Versicolor 클래스의 최대 적합도, 두 번째 값은 Virginica의 최대 적합도를 나타낸다.

식 (14)과 식 (15)에 의해서 규칙 1과 2는 Versicolor 클래스로, 규칙 3은 Virginica 클래스로 분류되는 규칙으로 결정하였다. 하지만, 식 (14)과 식 (15)로부터 최종 선택한 규칙은 주어진 입력패턴에 대해서 각 속성의 상관성만을 고려하여 결정한 규칙이므로, 불필요한 속성을 완전히 제거한 최적의 규칙이라 볼 수 없다.

따라서 제안한 방법에서는 이러한 불필요한 속성을 제거하기 위해 Skowron[14]에 의해서 제안된 식별가능행렬(식 (4)에서 식(7))을 이용하여 최종 규칙을 선택하였다. 다음은 러프집합으로 불필요한 속성을 제거한 후 최종 결정된 규칙들이다.

표 3. 속성감축 후 선택된 규칙
Table 3. Selected rules after reduction of attributes

Rule	SL	SW	PL	PW	Class
1	-	sw8	-	-	Setosa
2	-	sw7	-	-	
3	sl3	sw6	-	-	
4	sl2	sw6	-	-	
5	sl2	sw5	-	-	
· · · · ·					
10	-	sw5	pl3	-	Versicolor
11	sl4	sw4	pl3	-	
12	sl4	sw4	pw2	-	
13	-	sw2	pl3	-	
14	-	-	pl3	pw2	
· · · · ·					
37	sl5	sw3	-	-	Virginica
38	sl5	-	-	pw3	
39	sl3	-	-	pw3	
40	sl2	-	-	pw3	
41	sl5	sw6	-	-	

표 3은 러프집합으로 불필요한 속성을 제거한 후 선택된 최종 규칙이다. 표에서 '-'은 불필요한 속성이 제거된 것을 의미한다.

4.3 패턴분류 결과

표 3에서 획득한 최종 규칙과 식 (16), 식 (17)을 이용하여 150개의 입력패턴들의 정확도를 분석하였다. 다음은 각 입력패턴에 대한 출력패턴을 나타낸 그림이다.

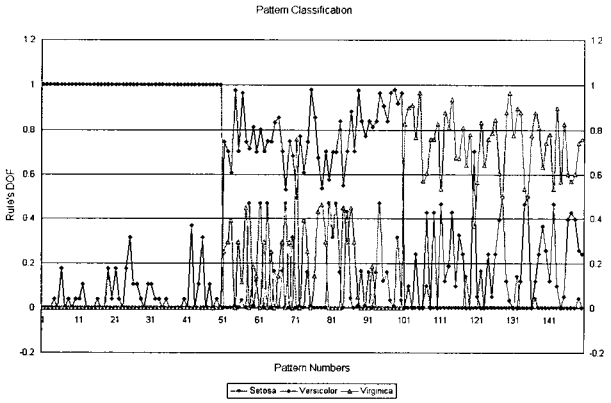

그림 4. 입력 패턴에 대한 출력
Figure 4. Output by the input patterns

그림 2에서 'Pattern Numbers'는 주어진 모든 입력 패턴 수, 'Rule's DOF'는 각 입력 패턴에 대한 규칙의 이행 정도를 나타낸다. 예를 들어, IRIS의 네 번째 입력패턴 (4.6, 3.1, 1.5, 0.2)에 대한 각 클래스의 규칙의 이행정도는 (1.0, 0.038808, 0)이므로 첫 번째 클래스인 Setosa로 분류된다. 이렇게 분류된 결과를 각 목표 패턴과 비교한 결과, Setosa 클래스에서는 50개(100%), Versicolor 클래스에서는 49개(98%), Virginica 클래스에서는 48개(96%)의 패턴들을 분류하였다. 따라서 제안한 방법에서 IRIS 데이터의 전체 분류 정확도는 98%였다.

4.4 기존의 패턴분류 방법과의 비교

제안한 방법의 타당성을 검증하기 위해 본 절에서는 기존의 몇 가지 패턴분류 방법들과 비교하였다. 다음은 IRIS 데이터를 사용한 기존의 패턴분류 방법과 비교한 결과를 나타낸 것이다.

표 4. 기존 방법들과의 비교
Table 4. Comparison the proposed with conventional methods

패턴분류 방법		규칙 수 및 분류 정확도	
Neuro - Fuzzy Approach	Nauck [2]	은닉층 뉴런 : 10 규칙 수 : 7	145개 (96.6%)
	Abe [3]	규칙 수 : 10	146개 (97.3%)
	Jang [4]	클러스터 반경 : 1.0	146개 (97.3%)
	Nozaki [5]	규칙 수 : 6 학습 사이클 : 100	142개 (94.8%)
Genetic - Fuzzy Approach	Ishibuchi [6]	규칙 수 : 6	149개 (99.3%)
	Ishibuchi [7]	규칙 수 : 5	147개 (98%)
Entropy based Fuzzy-Rough	Tsai [9]	규칙 수 : 16	(149개) 99.33%
Proposed Method		규칙 수 : 41	147개 (98%)
		규칙 수 : 41 (가중치 고려)	148개 (98.7%)

표 4에서 알 수 있듯이, 제안한 방법은 기존의 학습에 의한 패턴분류 방법들보다 비교적 좋은 분류 정확도를 가진다는 것을 볼 수 있다. 게다가 규칙의 커플링 문제를 해결하기 위해 신경망이나 유전자 알고리즘을 기반으로 학습을 하지 않더라도 통계적 정보만을 이용하여 분류 정확도를 향상시킬 수 있음을 볼 수 있다.

또한 Ishibuchi에 의해서 제안된 가중치에 의한 규칙의 확신도 조절방법과 유사한 방법으로 확신도를 조절한 결과, 148개(98.7%)로 분류 정확도가 향상되었다.

다음은 규칙의 확신도를 조절하기 위해 본 논문에서 사용된 조절방법이다.

$$new_CF_{i+1} = Old_CF_i \tag{11}$$

$$new_CF_{i+1} = Old_CF_i \times \alpha, \ \ \alpha \in [0,1] \tag{12}$$

여기서 식 (11)은 주어진 입력패턴에 대해서 정확하게 분류한 경우 이전의 규칙의 확신도를 그냥 갱신하는 것을 의미하고, 식 (12)은 정확하게 분류하지 못한 경우 가중치 α만큼 규칙의 가중치를 감소시킴을 의미한다. 규칙의 확신도를 조

절하기 위해서 본 논문에서 사용한 가중치는 $\alpha = 0.01$이다.

5. 결 론

기존의 퍼지규칙 기반 패턴분류 방법은 규칙의 커플링 문제를 해결하기 위해 엔트로피나 신경망 혹은 유전자알고리즘을 결합하여 규칙을 생성하거나 최적의 분류경계면을 찾는다. 그러나 이러한 방법들은 최적의 분류경계면과 규칙을 획득하는데 고려되어야 할 변수가 너무 많아서 학습하는데 많은 시간이 소요된다는 제약점을 가진다.

따라서 본 논문에서는 규칙의 커플링문제를 보다 단순한 방법으로 최소화하기 위해 주어진 데이터의 통계적 정보와 러프집합만을 이용한 새로운 방법을 제안한다. 제안된 방법에서 통계적 정보는 입력부 퍼지집합의 파티션을 결정하고 규칙 선택 시 발생될 수 있는 규칙의 커플링 문제를 최소화하기 위해서 사용되었다. 게다가 러프집합은 획득한 규칙들의 상관성을 고려하여 불필요한 속성들을 제거하기 위해서 사용되었다.

제안된 방법의 타당성을 검증하기 위해서 신경망, 유전자알고리즘, 그리고 엔트로피를 기반으로 한 패턴분류 방법과 비교하였다. 실험결과, 규칙의 커플링문제를 해결하기 위해 단순히 주어진 데이터의 통계적 정보만을 고려하더라도 분류의 정확도를 향상시킬 수 있다는 것을 볼 수 있었다.

참 고 문 헌

[1] H. Ishibuchi, and T. Nakashima, Effective of Rule Weights in Fuzzy Rule-Based Classification Systems, IEEE Transactions on Fuzzy Systems, Vol. 9, No. 4, pp. 506-516, 2001.

[2] D. Nauck, U. Nauck, and R. Kruse, Generating Classification Rules with the Neuro-Fuzzy System NEFCLASS, In Proceedings of the Biennial Conference of NAFIPS, Berkeley, pp. 19-22, 1996.

[3] S. Abe, M.S. Lan, and R. Thawonmas, Tuning of a Fuzzy Classifier Derived from Data, International Journals of Approximate Reasoning, Vol. 14, pp. 1-24, 1996.

[4] J-S.R. Jang, ANFIS : Adaptive Network Based Fuzzy Inference Systems, IEEE Transactions on System, Man and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.

[5] S.M. Nozaki, H. Ishibuchi, and H. Tanaka, Adaptive Fuzzy Rule Based Classification Systems, IEEE Transactions on Fuzzy Systems, Vol. 4, No. 3, pp. 238-250, 1996.

[6] H. Ishibuchi, K. Nozaki, N. Yamamoto, and H. Tanaka, Construction of Fuzzy Classification Systems with Rectangular Fuzzy Rules Using Genetic Algorithm, Fuzzy Sets and Systems, Vol. 65, No. 2-3, pp. 237-253, 1994.

[7] H. Ishibuchi, T. Murata, and I.B. Turksen, Single Objective and Two Objective Genetic Algorithms for Selecting Linguistic Rules for Pattern Classification Problems, Fuzzy Sets and Systems, Vol. 89, No. 2, pp. 135-150, 1997.

[8] J.S. Lim, Finding Fuzzy Rules for IRIS by Neural Network with Weighted Fuzzy Membership Function, International Journal of Fuzzy Logic and Intelligent Systems, Vol. 4, No. 2, pp. 211-216, 2004.

[9] Y.C. Tsai, C.H. Cheng, and J.R. Chang, Entropy-Based Fuzzy Rough Classification Approach for Extracting Classification Rules, Expert Systems with Applications, Vol. 31, pp. 436-443, 2006.

[10] C.H. Lee and S.H. Seo, Efficient Extraction of Hierarchical Structured Rules Using Rough Sets, International Journal of Fuzzy Logic and Intelligent Systems, Vol. 4, No. 2, pp. 205-210, 2004.

[11] 이철희, 서선학, 러프집합과 계층적 분류구조를 이용한 데이터마이닝에서 분류지식발견, 한국 퍼지 및 지능시스템학회, 12권, 3호, pp. 202-209, 2002.

[12] Z. Pawlak, Rough Sets, International Journal of Computer and Information Science, Vol. 11, No. 5, pp. 341-356, 1982.

[13] Z. Pawlak, Rough Sets : Theoretical Aspects of Reasoning about Data, Kluwer Academic Publishers, 1991.

[14] A. Skowron, and C.M. Rauszer, The Discernibility Matrices and Functions in Information Systems, Institute of Computer Sciences Report 1/91. Technical University of Warsaw, pp. 1-41, 1991.

[15] R.A. Fisher, The Use of Multiple Measurements in Taxonomic Problems, In Annual Eugenics, Vol. 7, No. 2, pp. 179-188, 1936.

저 자 소 개

손창식(Chang S. Son)
제16권 제6호 참조

정환묵(Hwan M. Chung)
제16권 제6호 참조

서석태(Suk T. Seo)
제17권 제3호 참조

권순학(Soon H. Kwon)
제17권 제3호 참조