

퍼지신경망과 비중복면적 분산 측정법을 이용한 최소의 특징입력 및 퍼지규칙의 추출

Extracting Minimized Feature Input And Fuzzy Rules Using A Fuzzy Neural Network And Non-Overlap Area Distribution Measurement Method

임 준식[†]
Joon Shik Lim[†]

경원대학교 전자거래학부
Department of E-Commerce Software, Kyungwon University

요약

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)을 이용하여 위스콘신 유방암(Wisconsin breast cancer)의 진단을 수행하는 퍼지규칙을 추출하고, 비중복면적 분산 측정법을 사용하여 특징입력을 최소로하는 방안을 제안하고 있다. NEWFM 구조의 중간 부분인 하이퍼박스(hyperbox)들은 n 개의 대, 중, 소로 구성된 가중 퍼지소속함수 집합으로 구성되며, 학습 후 각 집합의 대, 중, 소로 구성된 가중 퍼지소속함수는 퍼지집합의 경계합(bounded sum)을 사용하여 다시 하나의 가중 퍼지소속함수로 합성(BSWFM) 된다. n 개의 특징입력(feature input)은 학습된 모든 하이퍼박스에 연결되어 예측 작업을 수행한다. 여기에 비중복면적 분산 측정법을 적용하여 중요도가 낮은 특징입력을 제거하면서 최소의 m 개 특징입력만을 사용한 하이퍼박스로 단순화 시킨다. 이러한 방법으로 위스콘신 유방암의 9개의 특징입력 중 4개를 사용하여 NEWFM으로 추출된 2개의 퍼지규칙은 99.71%의 예측 인식율을 가지며 이는 퍼지규칙의 수와 인식율에 있어 현재 발표된 논문의 결과보다 우수함을 보여준다.

Abstract

This paper presents fuzzy rules to predict diagnosis of Wisconsin breast cancer with minimized number of feature input using the neural network with weighted fuzzy membership functions (NEWFM) and the non-overlap area distribution measurement method. NEWFM is capable of self-adapting weighted membership functions from the given the Wisconsin breast cancer clinical training data. n set of small, medium, and large weighted triangular membership functions in a hyperbox are used for representing n set of featured input. The membership functions are randomly distributed and weighted initially, and then their positions and weights are adjusted during learning. After learning, prediction rules are extracted directly from n set of enhanced bounded sums of n set of small, medium, and large weighted fuzzy membership functions. Then, the non-overlap area distribution measurement method is applied to select important features by deleting less important features. Two sets of prediction rules extracted from NEWFM using the selected 4 input features outperform to the current published results in number of set of rules, number of input features, and accuracy with 99.71%.

Key Words : 퍼지 신경망, 규칙 추출, 가중 퍼지 소속함수, 비중복 분산 면적 측정법

1. 서 론

패턴 분류나 진단, 예측 등을 위해 신경망 및 퍼지집합 이론을 결합한 적용적 의사결정지원 툴(adaptive decision support tool)인 퍼지신경망(Fuzzy Neural Network, FNN)이 제안되어 왔다[1,4,7,8,9,11,14,16,17]. 여러 가지 구조의 FNN이 학습(learning), 적용(adaptation), 규칙추출(rule extraction)을 위한 알고리즘과 더불어 제시된 바 있다

[3,6,10,12,13].

if-then 형식의 퍼지규칙의 추출 기법은 의사결정을 위한 FNN의 장점 중 하나이다. 이는 분류나 예측에 있어서 보편적인 패턴을 if-then 퍼지규칙과 같은 단순한 형태의 지식 표현으로 나타내는 것이다. 주어진 일련의 학습 데이터로부터 지식 추출을 위하여 자기 조직화 시스템(self-organizing system) 기반 퍼지신경망이 개발되었다[5,15,17]. Setnes[11]는 유전자 알고리즘을 이용하여 간단하고 정확도가 높은 퍼지규칙 기반 모델을 얻는데 초점을 맞추었다.

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)[10]을 이용하여 위스콘신 유방암(Wisconsin breast

cancer)[18]의 진단 예측을 수행하는 퍼지규칙을 추출하고, 비중복면적 분산 측정법을 사용하여 특정입력수를 최소로 하는 방안을 제안하고 있다. 가중 퍼지소속함수는 퍼지소속함수의 중요도에 따라 그 정점의 소속함수값을 1 이하로 줄 수 있도록 하여 예측이나 분류 능력을 강화시킬 수 있다[10]. NEWFM은 3개 계층인 입력 계층(input layer), 하이퍼박스 계층(hyperbox layer), 클래스 계층(class layer)으로 구성된다. 각 하이퍼박스 계층에 있는 모든 하이퍼박스 노드는 n 개의 퍼지집합으로 구성되는데 이들은 분류를 위한 클래스 노드와 각각 연결된다. 하나의 퍼지집합은 3개의 대, 중, 소의 가중 퍼지소속함수로 구성된다. NEWFM은 각 하이퍼박스 노드안에 있는 n 개의 퍼지집합을 n 개의 특징입력에 따라서 학습시킨다. 학습이 끝나면 모든 퍼지집합의 3개 대, 중, 소 가중 퍼지소속함수는 경계합(bounded sum)에 의해 하나의 가중 퍼지소속함수로 합성된다. 따라서 각 하이퍼박스 노드는 n 개의 가중 퍼지소속함수로 단순화 된다.

또한 본 논문에서 제안하고 있는 비중복면적 분산 측정법은 중요도가 낮은 특징입력을 줄여가면서 최소의 m 개의 가중 퍼지소속함수로 재구성시킨다. 이와 같이 경계합에 의한 합성 및 비중복면적 분산 측정법에 의해 단순화 및 최소개의 가중 퍼지소속함수는 간단한 퍼지규칙을 만들 수 있도록 한다. 또한 예측이나 분류의 효율을 낮추는 특징입력을 제거함으로써 모든 특징입력을 사용하는 경우보다 더 효과적인 예측이나 분류 결과를 줄 수 있다.

2. 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Function, NEWFM)

2.1 NEWFM의 구조

NEWFM의 구조는 그림 1에 나타나 있다. NEWFM은 3개의 계층인 입력 계층, 하이퍼박스 계층, 클래스 계층으로 구성되어 있다. 입력 계층에는 n 개의 입력노드들로 구성되어 있으며 각 입력노드는 하나의 특징입력을 입력받게 된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드로 구성된다. i 번째 하이퍼박스 노드 B_i 은 단 하나의 클래스 노드에 연결




그림 1. 가중 퍼지 소속함수 신경망의 구조

Fig. 1 Structure of Neural Network Weighted with Weighted Fuzzy Membership Function

되며 n 개의 입력노드로부터 각각 연결된 n 개의 퍼지집합을 갖는다. B_i 의 i 번째 퍼지집합은 B_i^i 로 표시되는데 그림

2에서 보는 바와 같이 대, 중, 소로 구성된 3개의 가중 퍼지소속함수를 가진다. 출력 계층은 p 개의 클래스 노드들로 구성된다. 각 클래스 노드는 하나 혹은 하나 이상의 하이퍼박스 노드에 연결되어 있다. 입력노드로 입력되는 h 번째 입력패턴은 $I_h = \{A_h = (a_1, a_2, \dots, a_n), class\}$ 로 기록된다. 여기서 class는 분류 결과이고 A_h 는 n 개 입력특징으로 구성된다.

2.2 정의 및 오퍼레이션(Definitions and Operations)

- ① w_{hi} : 하이퍼박스노드 B_i 과 클래스노드 C_j 사이의 연결 가중치는 초기값으로 연결이 안 된 상태인 $w_{hi} = 0$ 이 주어진다. 만일 하이퍼박스노드 B_i 과 클래스 노드 C_j 가 연결되어 있다면 $w_{hi} = 1$ 로 설정된다. C_j 는 하이퍼박스노드로부터 하나 이상의 연결을 가질 수 있는 반면 B_i 은 클래스 노드에 하나만이 연결되도록 제한되어 있다.
- ② v_i : v_1, v_2, v_3 는 그림 2에서와 같이 대, 중, 소 퍼지소속함수의 중심위치를 각각 나타낸다. 중심위치들은 학습 수행 중에 좌우로 조정되나 v_0 와 v_4 는 일정한 값으로 고정되어 있다. 입력 a_i 는 그림 2의 $v_{min} \sim v_{max}$ 범위 안에 있다.
- ③ μ_j 및 W_j : μ_j 는 B_i^i 퍼지집합의 퍼지소속함수를 나타내며 $j = 1, 2, 3$ 은 대, 중, 소 퍼지소속함수의 인덱스를 각각 나타낸다. 각 퍼지소속함수 μ_j 의 모양은 3개의 위치 (v_{j-1}, v_j, v_{j+1}) 로 표현되는 삼각형으로 되어 있는데 소속함수의 강도(strength)를 나타내는 소속함수 가중치 W_j ($0 \leq W_j \leq 1$, 초기값 $0.45 \leq W_j \leq 0.55$)를 갖는다. 그림 2에서 가중 퍼지소속함수인 회색 삼각형은 v_{j-1}, W_j, v_{j+1} 로 나타낸다.
- ④ $Len(\mu_j)$: μ_j 의 너비를 측정하기 위한 길이는 $Len(\cdot)$ [9]으로 정의된다.

$$Len(\mu_j) = ((v_{j+1} - v_{j-1})/2) W_j \quad (1)$$




그림 2. B_i^i 의 i 번째 퍼지집합 (3개 가중 퍼지소속함수)

Fig. 2 i-th Fuzzy set of B_i (3 Weighted Fuzzy Membership Functions)

- ⑤ $Adjust(B_i)$: 이 오퍼레이션은 h 번째 입력패턴인 $A_h = (a_1, a_2, \dots, a_n)$ 에 의해, B_i 내의 n 개 퍼지집합이 가지고 있는 대, 중, 소 퍼지소속함수와 그 가중치를 조정한다. 입력 a_i 를 받는 B_i^i 의 v_j 와 W_j 는 a_i 에 의하여 조정된다($j = 1, 2, 3$). $Adjust(B_i)$ 오퍼레이션 결과 새로운 중심위치인 $new(v_j)$ 와 새로운 가중치인 $new(W_j)$ 가 다음과 같은 표현으로 설정된다. α 와 β 는 0~1사이의 학습률 범위이고 변수 E_j 는 v_j 와 입

력 a_i 간의 차이를 나타낸다. 만일 E_j 가 인접 E_{j+1} 보다 크면 적은 것이 선택된다.

$$new(v_j) = v_j \pm \alpha E_j \mu_j(a_i) W_j \quad (2)$$

$$new(W_j) = W_j + \beta (\mu_j(a_i) - W_j) \quad (3)$$

자세한 $Adjust(B_l)$ 의 오퍼레이션과정은 다음 장의 NEWFM 알고리즘에서 기술한다. 그림 3은 입력 a_i 와 B_l^i 의 가중 퍼지소속함수 조정을 위한 $Adjust(B_l)$ 오퍼레이션의 한 예를 보여주고 있다.




그림 3. B_l^i 의 $Adjust(B_l)$ 연산 전후의 예

(Fig. 3) An Example of Before and After $Adjust(B_l)$ of B_l^i

⑥ $Random(B_l)$: 이 오퍼레이션으로 하이퍼박스 B_l 이 만 들어 지는데 B_l 내의 n 개 퍼지집합이 가지고 있는 μ_j 및 W_j ($j = 1, 2, 3$)를 초기화 시킨다. W_j 는 0.45~0.55 범위의 임의의 초기 가중치를 가지며, 중심위치 v_j 는 아래에서와 같은 범위 내의 임의의 값이어야 한다.

$$r_{j-1} \leq v_j < r_j, \text{ 여기서 } j = 1, 2, 3$$

한편 그림 2의 v_0 와 v_4 는 일정한 값으로 고정되어 있으며 연결 가중치 w_k 는 0으로 초기화된다.

⑦ $Output(B_l)$: 하이퍼박스 B_l 의 출력은 h 번째 특징입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 의해 다음 식과 같이 계산된다.

$$Output(B_l) = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^3 B_l^i(\mu_j(a_i)) W_j. \quad (4)$$

2.3 NEWFM 학습을 위한 알고리즘

이 절에서는 학습을 위한 NEWFM 알고리즘을 기술한다. NEWFM 알고리즘은 초기화 단계로 $Learning(B_l, C_i)$ 프로시저를 이용하여 퍼지소속함수의 중심위치 및 가중치를 조정하고 최대값을 갖는 $Output(B_l)$ 과 그에 해당하는 클래스노드에 연결한다. 일단 연결이 되면 입력패턴 $I_h = \{A_h = (a_1, a_2, \dots, a_n), class\}$ 에 대해 최대값을 갖는 $Output(B_l)$ 이 그에 해당되는 클래스노드와 일치하는 경우에만 $Learning(B_l, C_i)$ 프로시저가 실행되어 가중 퍼지소속함수의 학습이 진행된다. 모든 입력패턴이 다 입력되어 학습이 끝나면 반복하여 모든 입력패턴으로 학습을 시키면서 목표하는 분류 결과가 나올 때까지 학습을 반복하게 된다.

Algorithm NEWFM ;

```

1 While (result is satisfied)
1.1 for l = 1 to m // m is number of hyperboxes, usually start
   from number input
1.1.1 Random( B_l );
1.1.2 for j = 1 to p // p is number of class nodes
1.1.2.1 w_j = 0; // initial connection weight between B_l and C_j
1.2 for k = 1 to h // h is number of input patterns
   find B_l that has the maximum value of EnhOutput
   (B_l) among m hyperbox nodes from the input A_k;
   // input vector : I_k = {A_k = (a_1, a_2, ..., a_n), diagnosis}
1.2.2 Learning( B_l, C_i ); // C_i is a diagnosis in I_k

```

Procedure Learning (B_l, C_i) ;

```

// m is number of hyperboxes
1 Case 1 : ∀ m, w_mi = 0, where m ≠ i;
1.1 w_k = 1;
1.2 Adjust( B_l );

```

2 Case 2 : ∃ m satisfying w_mi = 1, where m ≠ i

```

2.1 w_k = 1;
2.2 Adjust( B_l );

```

Procedure Adjust(B_l) ;

```

1 for i = 1 to n // for each i th set of membership function in B_l
1.1 for j = 1 to 3 // for each membership function
1.1.1 if v_{j-1} ≤ a_i < v_j // for left side of μ_j
      E_j = min(|v_j - a_i|, |v_{j-1} - a_i|);
      new(v_j) = v_j - α E_j μ_j(a_i) W_j;
1.1.2 else v_j ≤ a_i ≤ v_{j+1} // for right side of μ_j
      E_j = min(|v_j - a_i|, |v_{j+1} - a_i|);
      new(v_j) = v_j + α E_j μ_j(a_i) W_j;
1.1.3 new(W_j) = W_j + β (μ_j(a_i) - W_j);

```

2.4 퍼지규칙 추출(Fuzzy Rule Extraction)

학습을 거친 NEWFM은 입력패턴을 분류하기 위한 if-then 형식의 퍼지규칙 추출에 사용될 수 있다. 학습을 거친 후에는 하이퍼박스노드 B_l 의 각 퍼지집합에는 3개의 가중 퍼지소속함수(weighted fuzzy memberships, WFM, 그림 6의 회색 부분)가 포함된다. 규칙들은 WFM으로부터 직접 추출될 수 있다. 규칙 추출 전략(rule extraction strategy)을 아래와 같이 제안한다.

① $μ_b^i(x)$ (그림 4의 굵은 선)로 표시된 WFM의 bounded sum은 다음과 같이 정의된다. WFM의 bounded sum (BSWFM)은 그림 4에서와 같이 3개의 WFM의 퍼지 특성을 통합한다.

$$μ_b^i(x) = \sum_{j=1}^3 B_l^i(μ_j(x)) \quad (5)$$




그림 4. 3개 가중 퍼지소속함수의 Bounded Sum 예(굵은 선)

Fig. 4 An Example of Bounded Sum of 3 Weighted Fuzzy Membership Functions (Bold Line)




그림 5. 위스콘신 유방암의 양성(흑색선)과 악성(회색선) enhanced BSWFM
Fig. 5 Enahnced BSWFM for WBC of Benign(black lines) and Malignant(grey lines)

- ② $Output(B_i)$ 값을 얻기 위해 수행하는 추론은 식(4)를 통해 얻은 값이다. 이에 더하여 추론 성능을 강화하기 위하여 $Len(\mu_j)$ 휴리스틱을 사용한 $EnhOutput(B_i)$ 을 다음과 같이 제안한다. 이 방법은 때로 추론 성능을 떨어뜨리는 경우도 발생하기 때문에 실험적으로 선별 하여 사용해야 한다. 본 논문의 위스콘신 유방암 예에 서는 $EnhOutput(B_i)$ 를 사용하는 것이 더 좋은 분류 결과를 주고 있다.

$$EnhOutput(B_i) = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^3 B_i^j(\mu_j(a_i)) W_j / Len(\mu_j) \quad (6)$$

$Len(\mu_j)$ 휴리스틱은 $Len(\mu_j)$ 이 작을수록 보다 결집된 정보를 가진다는 개념에 기초를 둔 것이다.

- ③ 학습결과 얻어진 클래스 C_i 에 대한 규칙은 m 개의 하이퍼박스 중 C_i 와 연결된 B_i 들($w_h=1$, where $h=1, 2, \dots, m$)의 enhanced BSWFM들로 나타낼 수 있다.

3. 실험 결과 (Experimental Results)

이번 장에서는 NEWFM에 의해 추출된 Wisconsin breast cancer 진단 폐지규칙을 보여주고 이의 성능을 인식율을 통해 평가한다. NEWFM으로 추출된 2개의 폐지규칙은 99.56%의 인식율을 가지며 이는 폐지규칙의 수와 인식율에 있어 지금까지의 다른 논문의 결과보다 우수함을 보여주고 있다.

두 번째 폐지규칙의 단순화를 위하여 특징입력 수를 최소화하는 방안을 제시한다. 결과적으로 Wisconsin breast cancer 특징입력 수를 9 개에서 4개로 줄이면서 99.71%의 인식율로 향상 시키고 있다.

3.1 위스콘신 유방암의 분류

위스콘신 유방암 폐지규칙 인식율 실험에서는 위스콘신 대학병원에서 수집한 위스콘신 유방암(Wisconsin Breast Cancer, WBC)의 데이터베이스[18]를 사용하였다. 이 자료는 WBC 진단을 위한 9개의 특징입력값과 양성(benign) 혹은 악성(malignant)의 진단 클래스로 구성되어 있다. 이 데이터 베이스는 699개의 레코드를 갖고 있지만 16개 레코드는 특징값이 몇 개 빠져 있어 이를 제외한 683개 레코드를 사용하였다. 그림 5는 NEWFM에 의한 학습과정을 거친 강화된 가중 폐지소속함수(enhanced BSWFMs)이다.

<표 1>은 그림 5의 enhanced BSWFMs로부터 얻어낸 WBC 분류를 위한 폐지규칙을 보여준다. <표 2>는 WBC분류에 있어서 본 논문에서 제시한 폐지규칙과 그 밖의 분류기법[12,13]과의 비교 결과를 보여주고 있다.

<표 1> 위스콘신 유방암 폐지규칙

<Table 1> Fuzzy Rules of Wisconsin Breast Cancer

	CT	CSi	CSh	MA	SECS	BN	BG	NN	Mi	Class
rule 1	(b)	(b)	(b)	(b)	(b)	(b)	(b)	(b)	(b)	Benign
rule 2	(g)	(g)	(g)	(g)	(g)	(g)	(g)	(g)	(g)	Malignant

(b)s are the black lines and (g)s are the grey lines in (Fig. 5).

<표 2> 위스콘신 유방암 인식 결과 비교
 <Table 2> Comparisons of Recognition results for Wisconsin Breast Cancer

Algorithm	Recognition Rate	No. of Rules
Nauck [12]	96.5%	4
Gomez [2]	99.12%	11
NEWFM	99.56%	2
NEWFM*	99.71%	2

NEWFM*은 비중복면적 분산 측정법을 적용하여 추출한 4개의 특징입력(표 1의 회색열)을 사용한 결과임

3.2 비중복면적 분산 측정법

그림 5에서 나타난 위스콘신 유방암 데이터에 대한 진단 분류용 enhanced BSWFM은 가시적으로 양성과 악성에 대한 차이점을 보여줄 수 있을 뿐 아니라, 이러한 차이점을 이용하여 중요도가 낮은 특징입력을 제거함으로써 더욱 간단한 퍼지규칙을 만들 수 있게 한다. 특징입력이 제거되면 하이퍼박스노드의 enhanced BSWFM의 수도 같이 줄어든다.

다음 그림 6은 두 양성과 악성의 Clump Thickness(CT) 특징입력에 대한 enhanced BSWFM를 겹쳐 놓은 모습이다. 특징입력 Clump Thickness를 i 번째 특징입력이라 하면, 그림 6의 흰 부분인 Benign Superior Area (A_b^i)는 양성의 퍼지값이 큰 경우의 면적이고, 그림 6의 빛금 친 부분인 Malignant Superior Area (A_m^i)는 악성의 퍼지값이 큰 경우의 면적을 나타낸다. $A_b^i + A_m^i$ 면적이 넓으면서 A_b^i 와 A_m^i 의 넓이가 균등히 분산되어 있으면 두 클래스를 분류할 수 있는 특징을 더 많이 가지고 있다고 볼 수 있다. i 번째 특징입력에 대한 비중복면적 분산(Non-Overlap Area Distribution) 허리스틱 함수는 다음 식(7)과 같다.

$$f(i) = (A_b^i + A_m^i) / \text{Max}(A_b^i, A_m^i) \quad (7)$$




그림 6. 위스콘신 유방암의 양성과 악성 enhanced BSWFM의 비중복면적 분산의 예
 Fig. 6 An Example of Non-Overlap Area Distribution of Benign and Malignant Enhanced BSWFMs

이와 같은 비중복면적 분산 측정법에 의해 위스콘신 유방암의 9 개 특징입력 중 $f(i)$ 값이 가장 낮은 9 번째 ($i=9$) Bland Chromatin(BC) 특징입력을 제거하고 NEWFM을 다시 실행하여 학습시키게 된다. 이를 분류 결과가 사전 목표

값을 유지하는 동안 가장 낮은 특징입력의 $f(i)$ 값을 갖는 특징입력을 하나씩 반복하여 제거한다.

본 논문에서는 비중복면적 분산법을 적용하여 위스콘신 유방암의 9 개 특징입력 중 4 개(표 1의 회색열)만을 사용하여 99.71%의 분류 인식율(표 2)을 갖는 퍼지규칙을 추출하고 있다. 다음 그림 7은 최종적으로 추출한 특징입력 중 4 개의 양성과 악성의 enhanced BSWFM을 보여주고 있다.




그림 7. 추출된 4개 특징에 대한 위스콘신 유방암의 양성(흑색선)과 악성(회색선) enhanced BSWFMs
 Fig. 7 Benign(black lines) and Malignant(grey lines) Enhanced BSWFMs for Extracted 4 Input Features

4. 결 론

본 논문은 NEWFM과 비중복면적 분산 측정법을 이용하여 위스콘신 유방암 진단을 위한 최소 퍼지규칙을 제안하고 있다. 추출된 퍼지규칙은 그 인식율에 있어서 4개의 특징입력만 사용하면서 2개의 규칙으로 타 논문에서 보여준 인식율보다 높은 결과인 99.71%를 보여주고 있다. 이러한 결과는 학습방법에 있어 하이퍼박스노드 B_i 의 대, 중, 소 퍼지집합을 학습 후 BSWFM에 의해 통합된 하나의 가중 퍼지소속함수로 입력패턴의 특징을 표현하기 때문이다. BSWFM은 0~1의 퍼지 소속함수값 범위를 각 특징의 중요도에 따라 0~1 이하인 값을 가짐으로써 퍼지 소속함수에 가중치를 부여하였다는 점이 분류에 대한 분별력을 강화하였다. 또 다른 BSWFM의 특징 중의 하나는 그림 7의 Uniformity of Cell Shape와 Bare Nuclei의 malignant에서 나타난 것처럼 정점이 2 개까지 허용되기 때문에 하나의 BSWFM으로 두 가지 인접한 특징입력을 표현할 수 있다는 점이다. 또한 enhanced BSWFM는 입력패턴의 특징이 집중된 BSWFM을 증폭하고 특징이 분산된 BSWFM을 약화시킴으로써 인식율을 더욱 향상 시키는 결과를 주고 있다.

비중복면적 분산 측정법의 적용은 규칙의 최소화를 위해 사용된 허리스틱 함수로써 불필요하거나 분류 결과에 악영향을 주는 특징입력을 제거함으로써 규칙을 최소화 시켜준다. 이와 같은 규칙의 최소화는 향후 임베디드 시스템이나 모바일 장치 등 소형 장치를 통한 응용 서비스 활용에 필수적이며 가시화된 최소 규칙으로 특징입력의 특성을 분석하는데 유용하게 사용될 수 있다.

참 고 문 헌

- [1] G. A. Carpenter, S. Grossberg and J. Reynolds, "ARTMAP : Supervised real-time learning and classification of nonstationary data by a self-organizing neural network," *Neural Networks*, Vol.4, pp.565-588, 1991.
- [2] A. F. Gomez-Skarmeta, M. V. F. Jimenez, J. G. Marin-Blazques, "Approximative Fuzzy Rules Approaches for Classification with Hybrid-GA Techniques," *Information Sciences*, Vol.136, pp.193-214, 2001.
- [3] H. Ishibuchi and T. Nakashima, "Voting in Fuzzy Rule-Based Systems for Pattern Classification Problems," *Fuzzy Sets and Systems*, Vol.103, pp.223-238, 1999.
- [4] R. Jang, "ANFIS : Adaptive network-based fuzzy inference system," *IEEE Trans. Syst., Man, Cybern.*, Vol.23, pp.665- 685, May-June, 1993.
- [5] C. F. Juang and C. T. Lin, "An On-Line Self-Constructing Neural Fuzzy Inference Network and Its Applications," *IEEE Trans. Fuzzy Systems*, Vol.6, No.1, pp.12-32, 1998.
- [6] N. Kasabov, *Foundation of Neural Networks, Fuzzy Systems and Knowledge Engineering*, The MIT Press, Cambridge, MA, 1996.
- [7] T. Kasuba, "Simplified Fuzzy ARTMAP," *IEEE AI Expert*, pp.19-25, Nov., 1993.
- [8] Ho J. Kim, Tae W. Ryu, Thai T. Nguyen, Joon S. Lim, and Sudhir Gupta, "A Modified Fuzzy Min-Max Neural Network for Pattern Classification," *Computational Science and Its Applications ICCSA 2004 (LNCS 3046)*, pp.792-798, Springer-Verlag, 2004.
- [9] H.-M. Lee, K.-H. Chen and I-F. Jiang, "A Neural Networks with Disjunctive Fuzzy Information," *Neural Networks*, Vol.11, pp. 1113-1125, 1998.
- [10] Joon Shik Lim, "Finding Fuzzy Rules by Neural Network with Weighted Fuzzy Membership Function," *International Journal of Fuzzy Logic and Intelligent Systems*, Vol. 4, No.2, pp.211-216, September, 2004.
- [11] C. T. Lin and C. S. George Lee, "Neural-network-based fuzzy logic control and decision system," *IEEE Trans. Computers*, Vol.40, No.12, Dec., 1991.
- [12] D. Nauck and R. Kruse, "A Neuro-Fuzzy Method to Learn Fuzzy Classification Rules from Data," *Fuzzy Sets and Systems*, Vol.89, pp.277-288, 1997.
- [13] M. Setnes and H. Roubos, "GA-Fuzzy Modeling and Classification : Complexity and Performance," *IEEE Trans., Fuzzy Systems*, Vol.8, No.5, pp.509-522, 2000.
- [14] P. Simpson, "Fuzzy min-max neural networks-Part 1 : Classification," *IEEE Trans., Neural Networks*, Vol.3, pp. 776-786, 1992.
- [15] K. Tanaka, M. Sano and H. Watanabe, "Modeling and Control of Carbon Monoxide Concentration Using a Neuro-Fuzzy technique," *IEEE Trans., Fuzzy Systems*, Vol.3, pp.271-279, June, 1995.
- [16] C. Z. Ye, J. Yang, D. Y. Geng, Y. Zhou, N. Y. Chen, Fuzzy Rules to Predict Degree of Malignancy in Brain Glioma, *Medical and Biological Engineering and Computing*, Vol.40, 2002.
- [17] J. S. Wang and C. S. G. Lee, "Self-Adaptive Neuro-Fuzzy Inference System for Classification Applications," *IEEE Trans., Fuzzy Systems*, Vol.10, No.6, pp.790-802, 2002.
- [18] W. Wolberg, O. Mangasarian, "Multisurface Method of Pattern for Medical Diagnosis Applied to Breast Cytology," *Proc. National Academy of Sciences*, Vol.87, pp.9193-9166, 1990.

저 자 소 개



임준식(Joon Shik Lim)

1986년: 인하대학교 전자계산학과(학사)
1989년: University of Alabama at Birmingham, Dept. of Computer Science (M.S.)
1994년: Louisiana State University, Dept. of Computer Science (Ph.D.)

1995년~현재: 경원대학교 전자거래학부 부교수(현)

관심분야: neuro-fuzzy systems, biomedical systems

e-mail: jslim@kyungwon.ac.kr