

論文99-36S-9-6

Rough Set Theory와 Neuro-Fuzzy Network를 이용한 추론시스템

(Inference System Fusing Rough Set Theory and Neuro-Fuzzy Network)

鄭日熏*, 徐在龍*, 延貞欽*, 趙鉉讚**, 全洪兌*

(Il Hun Jung, Jae-Yong Seo, Jung-Heum Yon, Hyun-Chan Cho, and
Hong-Tae Jeon)

요 약

퍼지 집합 이론과 신경망 이론의 융합은 퍼지논리 시스템의 최적 규칙 베이스를 얻기 위해 신경망을 적용하는 방향으로 주된 연구가 진행되고 있다. 그러나 이러한 접근 방법은 신경망의 제한된 학습능력으로 인해 최적성의 한계는 여전히 극복되지 못하고 있는 실정이다. 따라서 본 논문에서는 이러한 어려움을 극복하기 위해 입출력 데이터로부터 최적의 규칙을 얻을 수 있는 Rough Set 이론과 뉴로-퍼지의 새로운 융합기법을 제안한다. 제안한 알고리즘은 생성된 규칙 베이스가 중복되지 않기 때문에 기존의 FNN과 비교하여 더욱더 우수함을 냉장고의 온도추론 시스템에 적용하여 검증하였다.

Abstract

The fusion of fuzzy set theory and neural networks technologies have concentrated on applying neural networks to obtain the optimal rule bases of fuzzy logic systems. Unfortunately, this is very hard to achieve due to limited learning capabilities of neural networks. To overcome this difficulty, we propose a new approach in which rough set theory and neuro-fuzzy fusion are combined to obtain the optimal rule base from input/output data.

Compared with conventional FNN, the proposed algorithm is considerably more realistic because it reduces overlapped data when construction a rule base. This results are applied to the construction of inference rules for controlling the temperature at specified points in a refrigerator.

I. 서 론

대표적인 지능 기법인 퍼지 집합 이론은 복잡한 시스템 분석이나 수학적으로 모델화가 어려운 분야에서 퍼지 규칙의 합성에 근거한 근사 추론 방법으로 많은

성공적인 실제 사례들을 보여 주고 있으며, 제어 시스템 설계나 정보 처리 등 그 활용 범위가 크게 확산되고 있다^[1,2]. 또한, 신경 회로망은 병렬 분산 처리를 간단으로 주어진 정보를 이용하여 학습을 가능하게 함으로써, 시스템의 특징을 추출하는데 매우 우수한 능력을 발휘하고 있다. 현재 탁월한 생물의 지능 시스템을 기계화하기 위해 좀더 실제적인 신경망 구조와 메커니즘 그리고 학습 기법 등에 관한 광범위한 연구가 진행되고 있다^[3].

또한 불확실하고 애매한 정보로부터 유익한 정보를 추출하는 데에 많은 관심을 모으고 있는 Rough Set 이론이 있다^[4]. 1982년에 Pawlak이 제안한 Rough Set이

* 正會員, 中央大學校 電子工學科
(Dept. of Electronic Eng. Chung-Ang Univ.)

** 正會員, 韓國技術教育大學校 電子工學科
(Dept. of Electronic Eng. Korea Univ. of Tech. and Edu.)
接受日字: 1999年3月22日, 수정완료일: 1999年7月24日

본은 소속 함수 혹은 가능성 함수로 대표되는 퍼지 집합이나 학습에 의한 신경 회로망 기법과는 달리 주어진 데이터에 관한 예비적인 지식이나 부가적인 정보를 필요로 하지 않는다는 훌륭한 이점을 가지고 있다. 그리고 퍼지 이론과 신경망 이론과 같이 하나의 독립적인 응용 영역을 가지고 있으면서도 다른 이론들과의 상호 보완적인 관계를 가지고 있다는 점에서 앞으로 생물체의 지능추론/제어 시스템을 구현하는데 큰 역할을 할 것으로 판단된다.^[5,6]

한편 신경망 이론과 퍼지 이론의 융합은 신경망의 학습 속도 개선 및 최적의 신경망 구조 결정에 퍼지 이론을 응용하거나 퍼지 규칙의 자동 생성을 위해 신경망 기법을 도입하는 접근 방법으로 진행되고 있다. 연구 결과들의 대부분은 후자의 경우에 집중되어 있으며, 기존의 퍼지 시스템이 가지고 있는 퍼지 규칙 생성에 있어서의 한계성을 어느 정도 해결할 수 있는 긍정적인 결과를 가져왔다.^[7,8] 그러나 신경망의 지역적 최소치로 수렴하는 제한된 학습 기능으로 인한 최적성의 한계는 여전히 극복되지 못하고 있다. 최근에는 유전자 알고리즘과의 결합을 통해 그 제한성을 극복하고자 하고 있으나 많은 계산량으로 인해 유전자 알고리즘의 최적성의 훌륭한 이점을 크게 살리지 못하는 실정이다. 따라서 본 논문에서는 Rough Set 이론과의 결합을 통해 뉴로-퍼지 네트워크 시스템의 한계성을 극복할 수 있는 새로운 지능기법을 제안한다. 제안한 시스템은 Rough Set 이론의 리덕트(Reduct) 개념으로 주어진 데이터로부터 중첩되지 않는 규칙을 생성하고, 뉴로-퍼지 추론 시스템의 규칙으로 사용한다. 이렇게 구성된 러프-뉴로-퍼지 추론 시스템을 실제 냉장고 온도 추론에 적용하여 제안한 시스템의 우수성을 검증하였다.

본 논문의 구성은 다음과 같다. 2장에서는 Rough Set 이론과 규칙생성에 대해서 설명하였고, 3장에서는 러프-뉴로-퍼지 시스템을 이용한 냉장고 온도 추론 시스템을 제안 하였으며, 4장에서는 컴퓨터 모의실험을 통해 제안한 알고리즘의 우수성을 검증하였다. 마지막으로 5장에서는 결론을 기술하였다.

II. Rough Set 이론과 규칙 생성

1. Rough Set 이론

Rough Set 이론은 1980년대 Z. Pawlak이 제안한 정보처리 기법으로 불확실한 정보로부터 명확한 지식을

얻는 데에 유용한 이론으로 인식되고 있다. 일반적으로 Rough Set 이론은 주어진 정보나 데이터들을 어떤 속성(attribute)들에 의해 분류할 때 경계가 모호한 집합을 말한다.

본 장에서는 Rough Set의 기본적인 개념에 대해서 살펴본다.

1) 불구분 관계(Indiscernibility Relation)

두 개의 공집합이 아닌 유한 집합인 데이터의 전체 집합(universe of discourse) U 와 속성(attribute)들을 모아놓은 집합인 A 가 있다고 가정하자. 이때 U 의 두 개의 원소 x, y 가 A 의 한 부분집합인 B 에 대해서 같은 속성값을 갖게되면 x, y 는 속성집합 B 에 대해 불구분관계 또는 동치관계(equivalence relation)를 갖는다고 말할 수 있으며 아래 식과 같이 수학적으로 표현할 수 있다.

$$x \text{ IND } (B) y \text{ IFF } a(x) = a(y) \quad (1)$$

여기에서, $x, y \in U, a \in B (\subseteq A)$ 는 속성 집합 A 의 하나의 속성이고, $a(x)$ 는 원소 x 에 대한 a 의 속성값이다.

2) 근사화(Approximation)

전체 데이터 집합의 부분집합 X 를 하나의 속성집합 B 로 표현하면, 아래 식 (2)와 같은 하한근사집합(Lower Approximation)과 식 (3)과 같은 상한근사집합(Upper Approximation)을 정의할 수 있다.

B-하한근사(Lower approximation) :

$$BX = \{x \in U \mid [x]_B \subseteq X\} \quad (2)$$

B-상한근사(Upper approximation) :

$$\overline{BX} = \{x \in U \mid [x]_B \cap X \neq \emptyset\} \quad (3)$$

여기서, $[x]_B$ 는 전체집합 U 를 불구분 관계 $IND(B)$ 에 의해 분류된 집합들에서 원소 x 가 포함되어 있는 집합을 나타낸다. 그리고 상기 하한근사집합과 상한근사집합의 차집합 $BN_B(X)$ 는 다음과 같다.

$$BN_B(X) = \overline{BX} - BX \quad (4)$$

상기 차집합 $BN_B(X)$ 는 집합 X 를 속성 집합 B 에 대해 분류하였을 때의 경계 영역을 나타낸다.

상기 하한근사집합과 상한근사집합의 개념을 이용하여 속성 B 에 의해 X 의 근사화 정도를 표현할 때 근

사화 정도(accuracy of approximation)를 다음과 같이 정의한다.

$$\alpha_B(X) = \frac{|B(X)|}{|B|}, \quad 0 \leq \alpha_B(X) \leq 1 \quad (5)$$

여기서 $|\cdot|$ 는 집합의 요소 개수를 나타낸다.

3) 구분 행렬(Discernibility Matrix)

n 개의 원소로 구성된 전체 집합 $U = \{x_1, x_2, \dots, x_n\}$

에 대하여 속성집합 A 의 부분집합 B 에 대하여 각 원소사이의 속성값이 다른 속성들을 행렬 요소로 하는 $n \times n$ 의 행렬을 구분 행렬인 $M(U, B)$ 로 정의하고 다음과 같이 수학적으로 정의할 수 있다.

$$(c_{ij}) = \{a \in B | a(x_i) \neq a(x_j)\} \text{ for } i, j = 1, 2, \dots, n \quad (6)$$

4) 구분 함수(Discernibility Function)

구분 함수 $f(B)$ 는 구분 행렬에 의해 정의되는 다음과 같은 속성들의 boolean 함수이다.

$$f(U, B) = \bigwedge_{c_{ij} \neq \emptyset} \{ \bigvee_{a \in c_{ij}} a \} \text{ for } i, j = 1, 2, \dots, n \quad (7)$$

5) 리덕트(Reduct)

만약 속성집합 B 의 하나의 원소 a 가 $IND(B) = IND(B - \{a\})$ 를 만족할 경우, 속성 a 를 속성집합 B 의 잉여속성(superfluous attribute)이라고 한다. 그렇지 않을 경우 속성 a 를 B 의 필수속성(indispensable attribute)이라고 한다. 또한 B 에 속한 모든 속성들이 필수 속성일 경우 B 가 직교(orthogonal)한다고 한다. 속성집합 $B' \subset B$ 가 직교하고, $IND(B) = IND(B')$ 일 경우, B' 를 B 의 리덕트라고 한다. 전체 집합 U 에서 속성집합 B 의 리덕트 B' 를 $RED(U, B)$ 라고 표현하거나, U 를 잘 알 수 있는 경우 $RED(B)$ 라고 표현한다. 또한 이런 $RED(B)$ 들의 집합을 $REDS(U, B)$ 라고 표현한다.

6) 변형된 리덕트

어떤 동치관계(equivalence relation)인 관계를 R 로 나타낼 때, $[x]R$ 은 R 에 의해 나누어진 U 의 집합중에 원소 $x \in U$ 가 포함된 집합을 의미한다. 만약 $a \in B$ 에 대해 $[x]_{IND(B)} = [x]_{IND(B - \{a\})}$ 를 만족할 경우, x 에 대한 속성 a 의 값, $a(x)$ 를 잉여속성값이라고 말하고, 그렇지 않을 경우 필수속성값이라고 한다. x 에 대하여 B 의 모든 속성값이 필수속성값이라면 B 에

대한 속성값들의 집합, $B(x)$ 가 x 에 대하여 직교(orthogonal)한다고 말한다. 또한 $B'(x) \subset B(x)$ 가 x 에 대하여 직교하고 $[x]_{IND(B)} = [x]_{IND(B')}$ 일 경우 이 속성집합을 x 에 대한 리덕트, $RED^x(U, B)$ 라고 한다. 이러한 리덕트의 집합을 $REDS^x(U, B)$ 라 표현한다.

전체집합 $U = \{x_1, x_2, \dots, x_n\}$ 라고 할 경우 다음의 변형된 구분 함수를 사용하여 구할 수 있다.

$$f^x(U, B) = \bigwedge_{c_{ij} \neq \emptyset} \{ \bigvee_{a \in c_{ij}} a(x_i) \} \text{ for } j = 1, 2, \dots, n \quad (8)$$

위의 리덕트 개념을 U 의 부분집합 X 에 대해 확장하여 다음과 같이 정의된 구분 함수를 사용한다.

$$f^X(U, B) = \bigvee_{x \in X} f^x(U - \{X - x\}, B) \quad (9)$$

이러한 부분집합의 리덕트 개념에서 우리가 얻고자 하는 규칙이라 불리는 리덕트중의 하나를 아래와 같은 구분 함수를 통해 얻을 수 있다.

$$f_m^X(U, B) = \bigvee_{x \in X} f_m^x(U - \{X - x\}, B) \quad (10)$$

단, 여기서 $f_m^x(U, B)$ 는 $RED^x(U, B)$ 중에 원소의 개수가 제일 적은 리덕트의 구분 함수를 의미한다.

III. 온도 추론 시스템

1. 온도추론 문제 정의

기존의 냉장고에서는 설치되어 있는 제한된 수의 온도 센서로 내부의 온도 분포를 균일하게 유지할 수 있는 집중 냉각하는 방식을 사용해야 한다. 그러나 이러한 방식은 내부의 냉기 전달특성 뿐만 아니라 내용물이 있는 경우의 냉기 대류에 영향을 미치는 여러 현상까지 연구해야 하는 어려운 점을 갖는다. 또한 온도 센서의 배열 문제, 제작공정의 증대 그리고 케환 신호의 증대로 인한 제어 시스템의 복잡성 등으로 인해 구현이 용이하지 않다.

이에 본 논문에서는 그림 1과 같이 냉각 시스템 내부에 설치된 제한된 숫자의 온도 센서에서 측정된 값을 이용하여 내부 12개 지점에서의 내부 온도 값을 추론하는 지능 추론 시스템(그림 2)을 제안한다.




그림 1. 냉장고 시스템
Fig. 1. Refrigeration System.



그림 2. 온도 추론 시스템
Fig. 2. Temperature inference system.

2. Rough Set에 의한 규칙 생성

앞에서 언급한 Rough Set 이론을 이용하여 아래의 예와 같은 방법으로 냉장고 내부의 규칙 베이스를 생성한다.

- [Step 1] 표 1과 같이 Rough Set 이론에 의한 온도 추론 규칙들을 유도하기 위해 다음과 같이 내부 센서 C1과 C2에서 측정한 온도값과 C1의 변화율(dC1)과 센서 C2의 변화율(dC2) 그리고 12지점 중 한 곳의 측정 온도값을 구한다.
- [Step 2] 표 2와 같이 표 4~6에 의해 정의된 속성 구간값을 이용하여 측정값을 속성 symbol 값으로 표현한다.
- [Step 3] 표 2와 같이 구성한 관측 테이블을 중첩된 데이터를 줄여 표 3과 같이 간략화 한다. 이 간략화된 테이블에서 C1, C2, dC1, dC2는 조건부 속성(condition attribute), d1은 결론부 속성(decision attribute)에 해당된다.

표 1. 냉장고 시스템에서의 측정값의 한 예
Table 1. An example of values of measurement in refrigeration system.

번호	센서1	센서2	센서1 변화율	센서2 변화율	중BL
p 1	2.459	2.553	-0.017	0.04	1.1
p 2	2.551	2.645	-0.009	0.05	2.5
p 3	2.449	2.789	-0.005	0.017	1.3
⋮	⋮	⋮	⋮	⋮	⋮
p 9	2.471	2.512	-0.029	0.09	0.2
p10	2.551	2.699	0.001	-0.039	5.7
p11	2.480	2.779	0.020	-0.044	0.5

표 2. Observation 테이블
Table 2. Observation table.

번호	C1	C2	dC1	dC2	d1
p 1	0	2	1	2	1
p 2	2	1	2	2	2
p 3	0	1	2	0	1
⋮	⋮	⋮	⋮	⋮	⋮
p 9	1	0	0	2	0
p10	2	1	2	0	4
p11	1	2	2	0	0

표 3. 간략화된 테이블
Table 3. Reduced table.

번호	C1	C2	dC1	dC2	d1
u1	0	2	1	2	1
u2	0	1	2	0	1
u3	1	0	0	0	0
u4	2	1	2	2	2
u5	1	0	1	1	3
u6	1	0	0	2	0
u7	2	1	2	0	4
u8	1	2	2	0	0

위의 테이블에서 다음과 같은 규칙 형태를 얻을 수 있다.

$$\begin{aligned} & \text{IF } C0 \text{ is } I \text{ and } C2 \text{ is } J \text{ and } dC1 \text{ is } K \\ & \text{and } dC2 \text{ is } L \text{ then } d1 \text{ is } M \end{aligned} \tag{11}$$

여기에서 I, J, K, L, M 값은 $C1, C2, dC1, dC2, d1$ 이산화된 값이다.

표 4. 속성 Symbol
Table 4. Attribute symbol.

속 성	symbol	속성	symbol
센서 1	C1	중FC	d5
센서1변화율	dC1	중FR	d6
센서 2	dC2	하BL	d7
센서2변화율	dC2	하BC	d8
중BL	d1	하BR	d9
중BC	d2	하FL	d10
중BR	d3	하FC	d11
중FL	d4	하FR	d12

표 5. 출력 구간값
Table 5. Output interval value.

구간값	d1 ~ d12의 속성값
0	$d(x) < 0.6$
1	$0.6 \leq d(x) < 2.2$
2	$2.2 \leq d(x) < 3.8$
3	$3.8 < d(x) < 5.4$
4	$5.4 \leq d(x)$

표 6. 센서 입력 구간값
Table 6. Sensor input interval value.

구간값	C1의 속성값	C2의 속성값
0	$C1(x) < 2.460$	$C2(x) < 2.547$
1	$2.460 \leq C1(x) < 2.540$	$2.547 \leq C2(x) < 2.634$
2	$2.540 \leq C1(x)$	$2.634 \leq C2(x)$
구간값	dC1의 속성값	dC2의 속성값
0	$dC1(x) < -0.017$	$dC2(x) < -0.033$
1	$-0.017 \leq dC1(x) < 0.017$	$-0.033 \leq dC2(x) < 0.033$
2	$0.017 \leq dC1(x)$	$0.033 \leq dC2(x)$

【Step 4】 표 3을 Rough Set을 이용하여 표 7과 같은 구분 행렬 $M(U, B)$ 를 구성한다.

$$B = \{C1, dC1, C2, dC2\}, \quad (12)$$

$$U = \{u1, u2, u3, u4, u5, u6, u7, u8\} \quad (13) \text{ 와 같다.}$$

【Step 5】 $X = \{x \in U \mid d1(x) = d1\} = \{u1, u2\}$ 를 정의하고, 원소 $u1$ 과 $u2$ 에 대한 리덕트를 식 (14)와 같은 방법으로 구한다.

$$\begin{aligned} f^{u1}(U - \{u2\}, B) &= (C1 \vee dC1 \vee C2 \vee dC2) \\ &\wedge (C1 \vee dC1 \vee C2) \wedge (C1 \vee C2 \vee dC2) \wedge \\ &(C1 \vee dC1 \vee C2) \wedge (C1 \vee dC1 \vee C2 \vee dC2) \\ &\wedge (C1 \vee dC1 \vee dC2) \\ &= C1 \vee (dC1 \wedge C2) \vee (dC1 \wedge dC2) \vee (C2 \wedge dC2) \end{aligned} \quad (14)$$

$$\begin{aligned} REDS^{u1}(U - \{u2\}, B) \\ = \{\{C1_0\}, \{dC1_1, C2_2\}, \{dC1_1, dC2_2\}, \{C2_2, dC2_2\}\} \end{aligned} \quad (15)$$

$$REDS^{u2}(U - \{u1\}, B) = \{\{C1_0\}\} \quad (16)$$

표 7. 구분 행렬 M(U, B)
Table 7. Discernibility matrix M(U, B)

	u1	u2	u3	u4	u5	u6	u7	u8
u1								
u2	dC1, C2, dC2							
u3	C1, dC1, C2, dC2	C1, dC1, C2						
u4	C1, dC1, C2	C1, dC1, dC2	C1, dC1, C2, dC2					
u5	C1, C2, dC2	C1, dC1, C2, dC2	dC1, dC2	C1, dC1, C2, dC2				
u6	C1, dC1, C2	C1, dC1, C2, dC2	dC2	C1, dC1, C2	dC1, dC2			
u7	C1, dC1, C2, dC2	C1	C1, dC1, C2	dC2	C1, dC1, C2, dC2	C1, dC1, C2, dC2		
u8	C1, dC1, dC2	C1, C2	dC1, C2	C1, C2, dC2	dC1, C2, dC2	dC1, C2, dC2	C1, C2	

【Step 6】 다음과 같이 X 에 대한 리덕트들을 식 (15), (16)로부터 구할 수 있다.

$$\begin{aligned} REDS^X(U, B) = \{ \{ \{C1_0\} \}, \{ \{C1_0\}, \{dC1_1, C2_2\} \}, \\ \{ \{C1_0\}, \{dC1_1, dC2_2\} \}, \\ \{ \{C1_0\}, \{C2_2, dC2_2\} \} \} \end{aligned} \quad (17)$$

규칙형태로 구하면

$$RULES^X(U, B) = \{\{C1_0\}\} \quad (18)$$

【Step 7】 Step 6으로부터 아래와 같은 규칙을 얻는다.

$$\text{IF } C1 = 0, \text{ then } d1 = 1 \quad (19)$$

3. 러프-뉴로-퍼지 네트워크에 의한 추론 시스템

1) 시스템의 구성

앞에서의 Rough Set으로 생성한 규칙은 결론부 속성이 구간값이므로 규칙을 사용할 때 구간값의 결론만을 얻게 된다. 따라서, 실수 출력값이 요구되는 시스템에서는 Rough Set 이론에 의한 규칙 생성 기법은 응용상의 한계점을 갖게 된다. 이에 본 논문에서는 Rough Set 이론을 통해 규칙의 최적성을 보장할 수 있으며 실수 값을 추론 할 수 있는 시스템을 그림 3과 같이 제안한다.




그림 3. 러프-뉴로-퍼지 시스템의 구성도
Fig. 3. The structure of the Rough-Neuro-Fuzzy system.

2) 러프-뉴로-퍼지 네트워크에 의한 온도 추론

Rough Set 이론에 의해 냉장실 한 지점에서의 온도를 결정하기 위한 규칙이 다음과 같이 생성되었다고 가정하자.

$$\text{IF } C1 \text{ is } N \text{ and } C2 \text{ is } Z \text{ and} \quad (20)$$

$$dC1 \text{ is } Z \text{ and } dC2 \text{ is } P, \text{ then } d1 = Y_2$$

여기에서 N, Z, P, Y_2 는 이산화된 구간값이며 소속 함수 형태로 표현하면 그림 4와 같은 형태로 표현될 수 있다.




그림 4. 구간 속성값의 소속함수
Fig. 4. Membership function of interval attribute value.

속성값의 소속함수를 그림 5와 같은 퍼지 소속 함수로 변형하고 후건부의 값을 구간 중심값인 가변 가능한 실수값으로 변형한다. 이렇게 만들어진 식 (21)과 같은 형태의 규칙을 퍼지 규칙이라고 부르고, 특히 Rough Set 이론을 사용하여 간소화된 규칙인 경우를 러프-퍼지 규칙이라고 부른다.

$$\text{IF } C1 \text{ is } N \text{ and } C2 \text{ is } Z \text{ and} \quad (21)$$

$$dC1 \text{ is } Z \text{ and } dC2 \text{ is } P, \text{ then } d1 = a_2$$

여기에서 N, Z, P 는 그림 5의 퍼지 소속함수이고 a_2 는 구간중심인 하나의 실수값이다.




그림 5. 퍼지 소속함수
Fig. 5. Fuzzy membership function.

이 규칙들을 그림 6과 같은 뉴로-퍼지 네트워크의 규칙으로 재구성한다.

그림 6에서 y 값은 센서 $C1, C2$ 변화율 $dC1, dC2$ 에 의해 추론되는 내부 12개 지점의 한 지점에서의 온도로 다음 과정에 의해 결정된다.

먼저 입력 ($C1, C2, dC1, dC2$)에 대한 전건부의 소속 정도는 아래 식들에 의해 결정한다.




그림 6. 뉴로-퍼지 네트워크
Fig. 6. The structure of the Neuro-Fuzzy network.

$$A(x) = \begin{cases} 1 - \frac{2|x - c_A|}{w_A}, & 2|x - c_A| < w_A, \\ 0, & \text{otherwise} \end{cases} \quad (22)$$

(i = 1, 2, 3, 4, j = 1, 2, 3)

$$\hat{\mu}_i = \frac{\prod_{j=1}^n A_{ij}(G_j(x_j))}{\sum_{j=1}^m \prod_{j=1}^n A_{ij}(G_j(x_j))} \quad (23)$$

식 (22)에서 x는 센서입력, k는 퍼지룰의 갯수, n은 소속함수의 갯수이다. 또한 G(·)는 입력공간을 퍼지공간으로 설정하기 위한 비례인자(scaling factor)이다.

최종적으로 다음 식 (24)에 의해 추론값을 구한다.

$$y = \frac{\sum_{j=0}^m \mu_j \cdot a_j}{\sum_{j=0}^m \mu_j} = \sum_{j=0}^m \hat{\mu}_j \cdot a_j \quad (24)$$

한편 그림 6의 뉴로-퍼지 시스템의 후건부 가중치인 a_i 값들을 조정하기 위해 다음과 같은 오차 함수를 정의한다.

$$E(t) = \frac{1}{2} (y_d(t) - y^*(t))^2 \quad (25)$$

식 (25)의 오차 함수를 최소화하는 a_i 값들을 발견하기 위해 최급하강 (steep decent)법이 이용되며, 그 결과 a_i 값은 식 (26),(27)에 의해 결정된다.

$$\begin{aligned} \Delta a_i &= -\eta \cdot \frac{\partial E}{\partial a_i} \\ &= \eta \cdot (y_d - y^*) \hat{\mu}_i \end{aligned} \quad (26)$$

$$a_i(t+1) = a_i(t) + \Delta a_i(t) \quad (27)$$

IV. 컴퓨터 시뮬레이션

1. 냉장고 시스템

그림 7은 12지점의 온도값 중의 한곳인 중BL 위치에




그림 7. 중BL(d1)에서 실제 온도값
Fig. 7. Real temperature values of the middle BL(d1).

서의 실제 온도값을 나타낸다.

여기에서 ①, ②는 그림 4의 각 위치에 상온의 물통을 넣어 두는 시점을 표시한 것이다.

2. 모의실험 I

표 8의 규칙 베이스를 가진 뉴로-퍼지 네트워크 구조에 의한 중BL(d1)부분의 추론 값과 실제 값을 그림 8에 나타냈다. 그림 8(a)의 경우 데이터에서 얻은 러프-퍼지 규칙을 가지고도 만족스러운 결과를 얻을 수 있었고, 그림 8(b)에서는 BP 학습에 의해 RMS 오차가 0.2211에서 0.1926으로 감소되어 매개변수 조절이 이루어진 것을 알 수 있다.




그림 8. 중 BL 지점의 온도 추론 결과 (a) 러프-퍼지 규칙을 사용한 추론값(RMS 오차 = 0.2211) (b) Back Propagation 학습후(RMS 오차 = 0.1926)

Fig. 8. Temperature inference result at the point middle BL (a) Inference values using Rough-Fuzzy rule(RMS error = 0.2211) (b) After back-propagation learning(RMS error= 0.1926).

표 9는 이러한 방법으로 실험한 냉장고 각 지점에서 추론 결과를 나타낸 것이다. 측정지점이 센서에서 거리가 멀거나, 이동하는 냉기의 속도가 빠른 지점의 결과는 상대적으로 낮은 정확성을 가지는 것을 알 수 있다.

표 8. 냉장실 중BL(d1)에서의 온도 추론 규칙
Table 8. Temperature inference rules at the point middle BL (d1) in storage refrigeration.

C1	C2	dC1	dC2		d1
0	0	-	-	⇒	4
-	1	0	-	⇒	4
0	1	1	-	⇒	4
1	0	0	-	⇒	4
1	0	1	1	⇒	4
1	1	1	1	⇒	4
0	-	1	1	⇒	3
⋮	⋮	⋮	⋮		⋮
	2	1	2	⇒	1
	2	2	1	⇒	1
2	1	-	1	⇒	1
2	-	-	2	⇒	1
2	2	-	1	⇒	1

표 9. 냉장고 각 지점에서의 규칙수와 추론 결과
Table 9. The numbers of rule and inference result at each points in refrigeration.

위치	퍼지 규칙	러프-퍼지 규칙	학습전	학습후
중BL	76	33	0.2211	0.1926
중BC	86	45	1.3152	0.6617
중BR	76	35	0.3313	0.2611
중FL	76	35	0.2865	0.2656
중FC	75	35	0.4878	0.3896
중FR	76	32	0.4264	0.3087
하BL	77	31	0.7069	0.5199
하BC	85	43	0.7830	0.7217
하BR	90	44	0.8522	0.5285
하FL	90	45	0.8895	0.5917
하FC	96	48	1.0994	0.6567
하FR	119	46	1.3622	0.69469

3. 모의 실험 II

본 모의실험에서는 중BC 부분의 데이터를 이용하여 입력 공간 분할 개수에 의한 성능 변화를 퍼지 규칙과 러프-퍼지 규칙을 비교하여 살펴보았다.

그림 9는 러프-퍼지 규칙과 퍼지 규칙을 사용하여 얻은 추론 오차값을 입력공간 분할에 따라 얻은 결과이다. 여기서 N은 입력공간의 개수이며, 입력공간을 3,

4등분할 경우에는 러프-퍼지 규칙의 성능이 좋았으나 그 이상의 공간 분할인 경우에 서로 비슷해짐을 알 수 있다.




그림 9. 러프-퍼지 규칙과 퍼지 규칙의 추론 오차값 비교

Fig. 9. Comparison of inference error values of Rough-Fuzzy rules and Fuzzy rules.

위의 실험 결과로부터 러프-퍼지 규칙이 완벽한 시스템 규칙을 생성하기보다는 일반적인 규칙을 생성함으로써 시스템 변화에 둔감하게 됨을 알 수 있었다.

V. 결론

본 논문에서는 언어적 규칙을 추론기에 적용할 수 있는 퍼지 추론기의 장점과 신경망의 적응적인 매개변수 변화 방식을 갖춘 뉴로-퍼지 네트워크에 Rough Set을 사용하여 데이터로부터 얻은 러프-퍼지 규칙을 적용하여 실제 시스템 구현을 위한 지능 추론 시스템을 제안하였다.

제안한 추론 시스템은 퍼지 규칙을 사용하여 추론한 경우와 거의 성능면에서의 차이가 없었으며, 규칙 개수와 계산량이 감소하였으며, 시스템 변화에 민감하지 않은 추론 성능을 얻을 수 있음을 보여주었다. 또한 임의의 범위까지 입력 공간을 분할함으로써 성능이 향상됨을 알 수 있었다.

그리고 실제로 입력 종류의 개수가 많은 시스템일 경우 전문가가 규칙을 얻기가 힘이 들에 불구하고, Rough Set 이론을 사용하면 규칙을 만들 때 오히려 관련 속성들이 많아짐으로 더욱 성능이 뛰어난 규칙을 얻을 수 있었다.

참 고 문 헌

- [1] Li-Xin Wang, A Course In Fuzzy Systems And Control, Prentice-Hall International, Inc., 1997, pp. 289-327.
- [2] D. Driankov, H. Hellendoorn, An Introduction to Fuzzy Control, Springer, 1995, pp. 197-292.
- [3] J.-S. R. Jang, C.-T. Sun, E. Mizutani, Neuro-Fuzzy and Sift Computing, Prentice-Hall International, Inc., 1997, pp. 451-496.
- [4] Fernandez-Baizan, "Rough Sets As A Tool In Data Engineering", IEEE International Conference on System, Volume 1 of 5, pp. 435-440, 1995.
- [5] R. Yasdi, "Combining Rough Sets Learning and Neural Learning-method to deal with uncertain and imprecise information", Neurocomputing 7, pp. 61-84, 1995.
- [6] A. Mrozek, "Use of rough sets and decision tables for implementing rule-based control of industrial processes," Bull. Polish Academy Sci. T. Sc. 34, pp. 357-371, 1986.
- [7] S. Horikawa, T. Furuhasi, S. Okuma, Y. Uchikawa, "On fuzzy modelling using fuzzy neural networks with the back-propagation algorithm," IEEE Trans. on neural network, vol. 3, no. 5, pp. 801-806, 1992.

저 자 소 개

鄭 日 薰(正會員)

1974年 6月 20日生 1997년 2월 중앙대학교 전자공학과 졸업(학사). 1999년 2월 중앙대학교 대학원 전자공학과 졸업(석사). 1999년 3월~현재 (주) 네오 웨이브 재직 중. 주관심분야는 퍼지, 유전알고리즘, 신경망, Adaptive, Optimal Control 등임

延 貞 欽(學生會員)

1970年 9月 23日生 1994년 2월 중앙대학교 전자공학과 졸업(학사). 1996년 8월 중앙대학교 대학원 전자공학과 졸업(석사). 1996년 9월~현재 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 퍼지, 유전알고리즘, 신경망 등임

全 洪 兌(正會員)

현재 중앙대학교 전자공학과 교수

徐 在 龍(正會員)

1969年 7月 21日生 1996년 2월 중앙대학교 전자공학과 졸업(학사). 1998년 2월 중앙대학교 대학원 전자공학과 졸업(석사). 1998년 8월~현재 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 퍼지, 유전알고리즘, 신경망, FNN 등임

趙 鉉 讚(正會員)

현재 한국기술교육대학교 전자공학과 교수