

## 자동 구축 폐지 규칙기반 패턴 인식 시스템에 의한 고장진단 시스템의 구현

°홍윤광, 조성원  
홍익대학교 전기·제어공학과

### Automatically Constructed Fuzzy Rule-Based Pattern Classification Systems for Fault Diagnosis

°Yoonkwang Hong, Seongwon Cho  
Dept. of Electrical & Control Eng., Hong Ik Univ.

#### abstract

This paper presents the automatic construction of fuzzy rule-based systems for diagnosing the faults of complex systems. Generally, fuzzy systems work well when we can use expert's experience to articulate fuzzy IF-THEN rules and memberships for fuzzy sets. When we cannot do this, we should generate the fuzzy rules and membership functions for fuzzy sets directly from experimental data. In this paper, we propose a new method on how to extract fuzzy sets and fuzzy rules. We also introduce an efficient fine-tunning algorithm of the parameters of membership functions.

#### 1. 서론

폐지 규칙기반 고장진단 시스템은 IF-THEN 형식의 규칙들을 사용하여 구조적인 지식표현이 가능하고 인간의 언어 형태로 지식을 체계화 할 수 있다는 장점이 있다. 하지만 폐지 규칙기반 고장진단 시스템에서 진단 대상이 복잡해지면 폐지 집합과 규칙의 생성이 무척 어려워지고 탐색 경로가 길어져서 진단이 느려진다는 문제점이 있다. 특히 속도가 느려지는 단점은 고속의 온라인 고장진단을 어렵게 한다. 이러한 문제를 해결하기 위해서 규칙의 자동 생성과 병렬처리가 필요하다.

폐지 규칙기반 고장진단에 사용되는 규칙의 형태를 살펴보면 아래와 같다.  $n$ 개의 속성 값들에 근거해 대상을 분류하는 규칙을 가정해 보자. 이러한 규칙들은 속성 값들의 집합을 상용하는 지정된 클래스로 매핑(Mapping)한다. 분류 규칙들은 다음과 같이 표현될 수 있을 것이다.

if  $X_1$  is  $A_{11}$  and  $X_2$  is  $A_{12}$  and  $X_n$  is  $A_{1n}$  then Class is  $C_1$   
if  $X_1$  is  $A_{21}$  and  $X_2$  is  $A_{22}$  and  $X_n$  is  $A_{2n}$  then Class is  $C_2$

if  $X_1$  is  $A_{m1}$  and  $X_2$  is  $A_{m2}$  and  $X_n$  is  $A_{mn}$  then Class is  $C_m$   
 $X_1, X_2, \dots, X_n$ 은 분류할 대상에 대한 속성(Attribute)들이고,  $A_{11}, A_{12}, \dots, A_{mn}$ 은 속성에 대한 폐지집합들이다.  $C_1, C_2, \dots, C_m$ 는 클래스의 이름들이다.

본 논문에서는, 실험 데이터로부터 고장진단에 필요한 폐지 집합과 규칙들을 자동으로 생성하는 방법에 대해 설명한다. 또한 유도된 멤버십함수들의 파라미터들을 미세조정할 수 있는 효율적인 신경회로망의 구조와 학습 알고리즘을 제안하였다. 그리고 신경회로망 구조의 진단 시스템으로 고속의 진단을 요하는 전력전송 선로의 고장진단 문제에 적용하여 실험하였다.

#### 2. 폐지집합에 대한 멤버십함수의 유도

입·출력 데이터 집합내의 각 샘플은 어떤 대상들에 대한 정확한 속

"본 연구는 한국전력공사의 지원에 의하여 기초전력공학공동 연구소 주관으로 수행되었음."

성값과 그 대상의 클래스 값으로 이루어져 있다. 각 속성에 대하여 계산된 수의 폐지 집합과 그것에 대한 멤버십함수가 유도된다. 사용되는 모든 멤버십함수는 폐지 수(Fuzzy Number)라고 가정한다. 그러므로 멤버십함수는 다음과 같이 두개의 파라미터를 갖는 가우시안(Gaussian)함수로 표현할 수 있다.

$$\mu_{X_i}(x_j) = e^{-\frac{(x_j - a_i)^2}{b_i^2}}, \quad (i=1, 2, \dots, M, j=1, 2, \dots, L) \quad (1)$$

위 식에서  $\mu_{X_i}$ 는  $i$ 번째 클래스의  $j$ 번째 속성 데이터들에 대한 멤버십함수를 의미한다.  $L$ 은 속성의 수이고  $M$ 은 클래스의 개수이다.  $a_i$ 와  $b_i$ 는 폐지변수(Fuzzy Variable) 파라미터 추정법(Parameter Estimation)에 의하여 구할 수 있다 [2]. 두 파라미터가 모두 미지의 값일 때 파라미터 추정은 다음과 같은 방법에 의해 수행한다.

첨자의 사용을 간단히 하기 위하여 구해야 할 파라미터를 각각  $a$ 와  $b$ 라고 가정한다. 각 클래스의 각 속성의 데이터에 대하여 다음과 같은 정의를 한다.

정의: 멤버십함수가 아래의 식과 같은 형태를 가질 때, 폐지 변수  $X$ 는 정규(Normal)라 부른다.

$$\mu_X(x) = e^{-\frac{(x-a)^2}{b^2}} \quad (2)$$

윗 식에서  $a \in R$ 이고  $b > 0$ 이다.  $X$ 는 파라미터  $(a, b)$ 를 갖는 정규 폐지 변수이고,  $N(a, b)$ 로 표현한다.

$a$ 와  $b$ 를 추정하는 방법은 다음과 같다. 각 클래스의 각 속성의 데이터에 대하여 다음과 같은 가정을 한다.  $X_1, \dots, X_n$ 은 서로 상관 관계를 갖지 않는 정규분포,  $N(a, b)$ ,이고  $x_1, \dots, x_n$ 은 실제 값들이다. 가능성  $a$ 가 주어졌을 때, 다음과 같은 식을 만족하는  $\epsilon_a$ 를 찾아 낼 수 있다.

$$a | \frac{X_i - a}{b} | > \epsilon_a, \quad i=1, \dots, n \\ = \min_{1 \leq i \leq n} a | \frac{X_i - a}{b} | > \epsilon_a = a | \frac{X_i - a}{b} | > \epsilon_a = a \quad (3)$$

(3)식에서  $a$ 는 스케일 측도(Scale Measure)이다. 위험도(Risk)  $a$ 를 가지고,  $| (x_i - a)/b | \leq \epsilon_a$ , 즉  $a - b\epsilon_a \leq x_i \leq a + b\epsilon_a$ 라는 주장을 할 수 있다. 다시 말해 파라미터  $b$ 의 추정값  $b$ 는 다음과 같은 조건식을 만족한다.

$$b \geq \frac{\max_{1 \leq i \leq n} x_i - \min_{1 \leq i \leq n} x_i}{2\epsilon_a} \quad (4)$$

$b$ 의 추정 값은 확신도 간격(Confidence Interval),  $[a - b\epsilon_a, a + b\epsilon_a]$ ,의 길이를 최소로 하는 값이어야 한다. 그 리므로  $b$ 의 추정값,  $b$ ,은 다음과 같이 주어지게 된다.

$$\delta = \frac{\max_{1 \leq i \leq n} x_i - \min_{1 \leq i \leq n} x_i}{2\epsilon_a} \quad (5)$$

$x_1, x_2, \dots, x_n$  이 정규화된 분포의 샘플들이라고 가정하면  $\hat{b}$ 는 다음과 같이 근사화될 수 있다. 근사화된 식은 노이즈의 영향에 강인한 성질을 갖는다.

$$\hat{b} \approx \frac{|x_1 - \hat{a}| + |x_2 - \hat{a}| + \dots + |x_n - \hat{a}|}{n\epsilon_a} \quad (6)$$

(5)식에서  $a - b\epsilon_a \leq \min_{1 \leq i \leq n} x_i$  와  $\max_{1 \leq i \leq n} x_i \leq a + b\epsilon_a$  의 두 관계식에 의해 a의 추정값,  $\hat{a}$ , 을 끝 바로 구해 낼 수 있다.

$$\hat{a} = \frac{\max_{1 \leq i \leq n} x_i + \min_{1 \leq i \leq n} x_i}{2} \quad (7)$$

$\hat{b}$ 와 마찬가지로  $\hat{a}$ 도 노이즈의 영향에 강인한 성질을 갖는 식으로 근사화 될 수 있다.

$$\hat{a} \approx \frac{x_1 + x_2 + \dots + x_n}{n} \quad (8)$$

각 클래스의 모든 속성에 대하여 위와 같은 파라미터 추정법에 의하여 폐지집합의 멤버쉽함수들을 유도해낸다. 유도된 멤버쉽함수의 개수는  $M \times L$ 이 된다. 각 속성에 대하여 유도된 폐지집합들 사이의 유사정도가 임계값보다 크면, 유사한 폐지집합들을 합쳐 하나의 새로운 폐지집합을 만든다. 두 폐지집합 사이의 유사정도는 Lin과 Lee에 의해 제안된 방법을 사용한다 [3].

유사정도가 임계값보다 클 경우에는 파라미터 추정을 통하여 두개의 멤버쉽함수를 하나의 멤버쉽함수로 합친다.

### 3. 폐지 규칙의 추출

유도된 폐지집합에 근거하여 샘플 데이터로부터 폐지규칙을 이끌어낸다. 가능한 폐지 규칙의 최대갯수는 아래의 식과 같다.

$$(\prod_{i=1}^L F_i) \times M \quad (9)$$

이 식에서  $F_i$ 는 i번쨰 속성에 대하여 정의된 폐지집합의 개수이고, L은 속성의 수이고, 그리고 M은 클래스 수이다. Kosko는 신경회로망의 일종인 경쟁학습 알고리즘을 사용하였고, Lin과 Lee는 Hebbian 학습 알고리즘을 사용하여 폐지 규칙을 추출하였다 [1][3]. 이러한 방법은 많은 반복학습을 수행하여야 한다. 본 논문에서는 비반복(Non-Iterative) 방법을 사용하여 폐지규칙을 추출한다. 폐지규칙은 다음과 같은 과정을 거쳐 추출한다 [4].

단계 1: CMD(Cumulative Degree of Match)를 초기화 한다.

$$CMD^N(j_1, j_2, \dots, j_L, p) = 0$$

$$\text{for } j_1 = 1, 2, \dots, F_1 \\ j_2 = 1, 2, \dots, F_2$$

$$j_i = 1, 2, \dots, F_i$$

$$j_L = 1, 2, \dots, F_L \\ p = 1, 2, \dots, M$$

단계 2: k번째 샘플에 대하여, 샘플의 속성값  $V_k$ 와 폐지집합

$$A_i(j_i) \text{ 사이의 유사정도}, DM_i(V_k, A_i(j_i))$$

다.  $V_k$ 는 k번째 샘플의 i번째 속성값이다. 유사정도,

$$DM_i(V_k, A_i(j_i))$$
는  $V_k$ 가 폐지집합  $A_i(j_i)$ 에서 갖는 멤버쉽값과 같다.

$$i = 1, 2, \dots, L \text{ 과 } j_i = 1, 2, \dots, F_i \text{에 대하여}$$

여 반복한다. L은 속성의 갯수이고  $F_i$ 는 i번째 속성에 대하여 정의된 폐지집합의 갯수이다.

단계 3: k번째 샘플에 결합 유사정도(Combined Degree of Match)를 계산한다.

$$DM^k(j_1, j_2, \dots, j_L, \dots, j_L) = \\ f(DM_1(V_k, A_1(j_1)), DM_2(V_k, A_2(j_2)), \dots, \\ DM_L(V_k, A_L(j_L)), \dots, DM_L(V_k, A_L(j_L)))$$

(10)

k번째 샘플에 대하여  $\prod_{i=1}^L F_i$ 개의 서로 다른 CDM이 존재한다. 함수  $f$ 는 T-norm연산자이다.

단계 4:  $p = 1, 2, \dots, M$ 에 대하여, CDM을 업데이트시킨다.

k번째 샘플의 클래스가 p이면,

$$\begin{aligned} CDM^k(j_1, j_2, \dots, j_L, \dots, j_L, p) \\ = CDM^{k-1}(j_1, j_2, \dots, j_L, \dots, j_L, p) \\ + DM^k(j_1, j_2, \dots, j_L, \dots, j_L, p) \end{aligned} \quad (11)$$

k번째 샘플의 클래스가 p가 아니면,

$$\begin{aligned} CDM^k(j_1, j_2, \dots, j_L, \dots, j_L, p) \\ = CDM^{k-1}(j_1, j_2, \dots, j_L, \dots, j_L, p) \end{aligned} \quad (12)$$

$(\prod_{i=1}^L F_i) \times M$  개의 서로 다른 CDM이 존재한다.

단계 5: 만약  $k = N$  ( $N$ 은 샘플의 갯수)이면, 단계 6으로 간다.

그렇지 않으면,  $k = k+1$  하고 단계 2로 간다.

단계 6: 모든 CDM의 최종값,  $CDM^N(j_1, j_2, \dots, j_L, \dots, j_L, p)$ ,에 대하여 임계값( $\tau$ )보다 큰가를 체크한다.

$CDM^N(j_1, j_2, \dots, j_L, \dots, j_L, p) > \tau$  이면, 다음과 같은 폐지 규칙을 생성한다.

If  $X_1$  is  $A_1(j_1)$  and  $X_2$  is  $A_2(j_2), \dots, X_L$  is  $A_L(j_L)$   
THEN Class is p.

### 4. 신경회로망의 구성

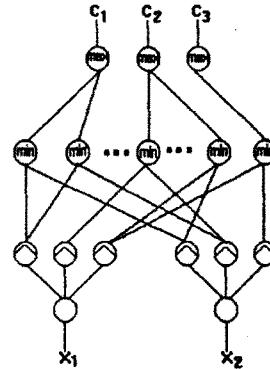


그림 1. 유도된 폐지집합과 규칙에  
기반해 구성된 네트워크

앞에서 유도된 폐지 폐편 분류 시스템을 표현하기 위하여 그림 1과 같은 신경회로망을 구성할 수가 있다. 구성된 신경회로망은 네개의 층으로 이루어져 있다. 각 층의 노드들이 하는 기능은 다음과 같다.

- 첫번째 층의 노드들은 입력을 전달하는 기능을 한다.
- 두번째 층의 노드들은 멤버쉽함수를 나타낸다. 각 속성에 대하여 2장에서 유도된 멤버쉽함수의 갯수 만큼의 노드들을 갖는다.
- 세번째 층은 규칙층으로서 각 노드는 하나의 규칙을 표현한다. 규칙층의 노드수는 앞에서 유도된 규칙의 수와 동일하다. Min연산자로서 기능한다.
- 네번째 층의 노드들은 각 규칙들이 할당되는 클래스를 표현한다. 각 노드는 그 노드로 지정된 클래스에 할당된 규칙층의 노드들과 연결된다. Max연산자로서 기능한다.

### 5. 미세 조정(Fine Tuning) 알고리즘

파라미터 추정에 의해 멤버쉽함수들의 중심값과 분산값들을 결정하고 폐지 폐편분류에 필요한 규칙들을 유도한 후, 분류 정확도를 높이기 위하여 미세조정 알고리즘을 수행한다. 미세조정을 수행하기 위하여 다

음과 같은 두개의 목적함수를 정의한다.

$$Q = \sum_{i=1}^M \sum_{j=1}^{N_i} o_{ij} \quad (13)$$

$$\bar{Q} = \sum_{i=1}^M \sum_{j=1}^{N_i} \sum_{k=1, k \neq j}^{N_i} o_{ik} \quad (14)$$

$M$ 은 클래스의 수,  $N_i$ 는  $i$ 번째 클래스에 속하는 데이터들의 개수,  $o_{ij}$ 는  $j$ 번째 데이터에 대한  $i$ 번째 출력 노드의 출력값을 표현한다.

$i$ 번째 클래스에 속하는 데이터가 입력으로 주어질 경우,  $i$ 번째 출력 노드와 연관된 미세조정(Fine-Tunning)하고자 하는 파라미터가  $w$ 라면, 학습 규칙은 다음과 같다.

$$w(t+1) = w(t) + \eta \left( \frac{\partial Q}{\partial w} \right) \quad (15)$$

$i$ 번째 클래스에 속하는 데이터가 입력으로 주어질 경우,  $i$ 번째가 아닌 출력노드와 연관된 미세조정(Fine-Tunning)하고자 하는 파라미터가  $w$ 라면, 학습 규칙은 다음과 같다.

$$w(t+1) = w(t) - \eta \left( \frac{\partial \bar{Q}}{\partial w} \right) \quad (16)$$

위 식에서  $\eta$ 는 학습율이다.

제안된 미세 조정 과정은 수십 번의 반복 학습만으로 충분하다는 것을 실험을 통해 알 수 있었다.

## 6. 실험

제안된 전단 시스템을 실제 문제인 전력전송선로에 적용하였다. 전송 선로의 고장전단은 고속도로하고 여러 가지 요인에 의한 짐음에 의해서 명확한 진단이 힘든 시스템이다.

전력전송 선로의 파도 상태를 해석하기 위해서는 EMTP를 사용하였다. 전처리 과정에서는 획득한 데이터로부터 실효치전류와 0상 전류를 얻어내고 이 값을 정규화하였다. 따라서 실험에 사용된 입력정보는 정규화된 A상, B상, C상, 0상 전류의 실효치를 사용하였다. 분류 패턴은 1선지락, 2선지락, 2선단락의 3가지 고장상태와 정상상태의 총 4가지를 이용하였고, 학습에는 각 종류별로 200개씩, 테스트에는 각 종류별로 400개씩 데이터를 사용하였다. 실험에서 CDM의 임계값  $\epsilon$ 는 0.8을 사용하였다. 그럼 2는 EMTP로부터 얻은 1선지락 데이터의 순시치와 전처리된 결과이다.

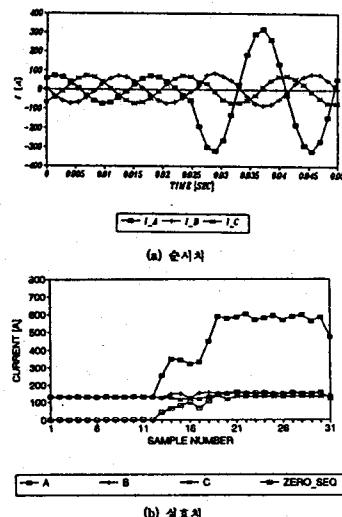


그림 2 . 1선지라고장의 순시치와 실효치

실험에 의한 고장전단결과는 학습에 사용한 데이터에서는 100%, 테스트용 데이터로는 98%의 정확도를 나타내었다.

## 7. 결론

본 논문에서는 고장에 관한 데이터가 주어졌을 때, 퍼지 고장전단 시스템을 구축하기 위하여 전단 규칙들을 자동으로 생성하는 알고리즘을 제안하였다. 멤버쉽함수들을 파라미터 추정법을 사용하여 결정하고, 비반복적 방법을 통하여 규칙들을 생성하는 알고리즘을 제안하였다. 유도된 멤버쉽함수와 퍼지규칙들에 기반해 신경회로망을 구성하고, 미세 조정을 효율적으로 할 수 있는 신경회로망의 구조와 학습 알고리즘을 제안하였다. 제안된 전단 시스템을 전력 전송 선로의 고장전단에 적용하여 성능을 테스트하였다.

### 참고 문헌

- [1] B. Kosko, Neural Networks and Fuzzy Systems: A Dynamical Approach to Machine Intelligence, Eglewood Cliffs, NJ:Prentice Hall, 1992.
- [2] Cai Kai-Yuan, "Parameter Estimations of Normal Fuzzy Variables", Fuzzy Sets and Systems, Vol. 55, No. 2, April 26, 1993.
- [3] C.T. Lin and C.S.G. Lee, "Reinforcement Structure/Parameter Learning for Neural-Network-Based Fuzzy Logic Control Systems", IEEE Transaction on Fuzzy Systems, Vol. 2, No. 1, pp. 46-63, February, 1994.
- [4] S. Cho and M.R. Lehto, "An Algorithm to compute the Degree of Match in Fuzzy Systems", Fuzzy Sets and Systems, Vol. 49, No. 3, August 1991.
- [5] 황인호, "신경회로망을 이용한 퍼지 시스템의 자동 구축", 흥의대학교 석사 학위 논문, 1994
- [6] 신명철, 김철환, 권기백, 이복구, "신경회로망을 이용한 송전선로의 고장판별에 관한 연구", 전기학회 논문지, 42권, 11호, pp 67-76, 1993.