

FCM과 TAM recall 과정을 이용한 고장진단

이기상*, 박대홍**, 정원석*, 최낙원*
*단국대학교 전기공학과, **고려대학교 전기공학과

Fault Diagnosis Using FCM and TAM recall Process

Kee-Sang Lee*, Tae-Hong Park**, Won-Seok Jeong*, Nak-Won Choi**
*Dept. of Electrical Eng., Dankook University
**Dept. of Electrical Eng., Korea University

Abstract - In this paper, two diagnosis algorithms using the simple fuzzy cognitive map (FCM) that is an useful qualitative model are proposed.

The first basic algorithm is considered as a simple transition of Shiozaki's signed directed graph approach to FCM framework. And the second one is an extended version of the basic algorithm. In the extension, three important concepts, modified temporal associative memory (TAM) recall, temporal pattern matching algorithm and hierarchical decomposition are adopted. As the resultant diagnosis scheme takes short computation time, it can be used for on-line fault diagnosis of large scale and complex processes that conventional diagnosis methods cannot be applied. The diagnosis system can be trained by the basic algorithm and generates FCM model for every experienced process fault.

In on-line application, the self-generated fault model FCM generates predicted pattern sequences, which are compared with observed pattern sequences to declare the origin of fault. In practical case, observed pattern sequences depend on transport time. So if predicted pattern sequences are different from observed ones, the time weighted FCM with transport delay can be used to generate predicted ones.

The fault diagnosis procedure can be completed during the actual propagation since pattern sequences of two different faults do not coincide in general.

이 많은 연구결과가 보고된 바 있으며, 저차선형계통의 고장검출 진단에 효과적으로 사용되고있다. 그러나 이 기법은 근본적으로 ON 모델을 요구하므로 불확실성을 포함한 계통, 대규모 계통과 비선형성이 강한 계통 등에서의 적용이 곤란하다.

정성적 모델 접근 방법의 대표적인 예로는 지식기반 진단시스템을 들 수 있다[1]. 이 지식기반 진단시스템은 크게 Shallow knowledge 모델에 근거한 방법과 Deep knowledge 모델에 근거한 방법으로 나눌 수 있다.

Shallow knowledge 모델에 근거한 방법은 고장원인과 증상간의 직접적 관계에 근거한 방법으로서 IF-THEN 구조의 규칙기반 형태를 갖으며 MYCIN과 같은 의용진단시스템에 적용되고있다. 그러나 이 방법은 지식습득이 곤란하고, 규칙수가 많은 것에 비해 원천성이 결여되는 문제점이 있다.

Deep knowledge 모델에 근거한 방법은 정상상태 및 고장발생시의 변수간 상호작용과 고장의 전파과정에 대한 구조적 지식에 근거한 방법으로서 Shallow knowledge 모델 접근방법의 단점을 해결해 준다. 대표적인 예로는 인과관계 탐색기법, 가설검증기법 등을 들 수 있다[2].

데이터 구조에 근거한 기법은 패턴인식 및 분류에 근거한 것으로서 Neural Net approach를 예로 들 수 있다.

이들 각각은 화공 프로세스, 비행시스템, 원전계통 등 대규모 계통의 전반적인 FDIU 설계에 도입된 바 있으며 이중 Deep knowledge 또는 Structured knowledge 를 이용한 진단기법은 계통특성의 모호성을 고려하는 동시에 계통요소간의 인과관계를 함께 고려할 수 있다.

본 연구에서는 모든 프로세스 변수간의 인과관계에 대한 지식 표현 및 추론수단으로서 Deep knowledge 모델인 FCM을 이용한 고장진단기법과 변형된 TAM recall 과정 및 패턴매칭을 이용한 실시간 고장진단기법을 제안하고 그 유용성을 입증함에 목적을 둔다.

제안된 FDIU는 기존 AI기법의 문제점인 계통 모델링 및 지식습득의 어려움을 해결할 수 있으며, 대규모계통의 실시간 고장진단에 적합하다. 그리고 고장모델 발생 및 프로세스 특성변화에 대한 적용이 가능하고 센서의 고장검출에 이용할 수 있다.

2. FCM(Fuzzy Cognitive Map)

FCM은 개환경로를 포함한 퍼지 유허부호 그래프(FSDG)로서 불확실한 인과관계에 대한 전문가의 지식을 습득, 표현 및 추론하기 위하여 제안되었다[3][4].

FCM은 계통의 상태(파라미터)를 나타내는 절점과 방향성 가지로 구성되며 가지의 비중 e_{ij} 는 상태 x_i 가 상태 x_j 에 미치는 영향의 척도로서 [-1,1] 사이의 값을 갖는다. $e_{ij} = 0$ 은 x_i 와 x_j 간에 인과관계가 없음을 나타내며, $e_{ij} > 0$ 은 x_i 가 증가(감소)할 때 x_j 가 증가(감소)함을 나타내며, $e_{ij} < 0$ 은 x_i 가 증가(감소)할 때 x_j 가 감소(증가)함을 나타낸다. 또한 e_{ij} 가 [-1,1] 사이의 연

1. 서론

최근 산업이 발달함에 따라 산업프로세스는 점차 대규모화 및 복잡해 지고 있다. 따라서 프로세스의 안정성 및 신뢰도 확보를 위해 고장진단기법의 중요성이 더욱 증가되고있으며, 특히 복잡하고 대규모인 계통에 대한 효과적인 고장진단기법의 개발이 요구된다.

고장진단은 프로세스내 상태변수의 측정치의 집합, 또는 이를 가공한 특징량의 집합이 주어진 경우 이들 데이터를 분석함으로써 프로세스의 고장여부를 검출하고, 고장인 경우 그 고장요인을 식별하는 것이다. 따라서 고장진단시스템 설계의 핵심은 시스템의 모델링, 측정치로부터 특징량 추출 및 고장요인의 식별알고리즘이라할 수 있다.

이러한 고장검출진단 유니트(FDIU)는 매우 다양하게 분류되며 그중 가장 일반적인 분류방법의 하나는 사용된 모델에 따른 분류이다.

- (i) 정량적모델(QN model)에 근거한 해석적 중첩기법(ARN)
- (ii) 정성적모델(QL model)에 근거한 기법
- (iii) 데이터 구조에 근거한 기법

이중 정량적 모델 기법은 상태 및 파라미터 추정에 근거한 것으로 A.S. Willsky, R. Isermann등에 의해 70년대 중반이후 대안

속치를 갖지 않고 $(-1, 0, 1)$ 인 값만을 가질 경우 이 FCM을 단순 FCM이라한다.

FCM은 고장진단시스템을 포함한 모든 전문가 시스템의 근간을 이루고있는 탐색트리표현에 비해 다음과 같은 장점을 갖는다[3].

- 1) 탐색트리는 전향구조이므로 많은 계통에 포함되어 있는 계통환경로를 표현할 수 없는 반면 FCM은 개념적 또는 실질적 개환이 가능하다.
- 2) 탐색트리 기법은 트리 크기에 따라 탐색시간이 지수적으로 증가하여 실시간 적용이 불가능 하므로 특히 대규모 계통에 의 적용이 곤란한 반면 FCM을 이용한 추론과정은 간단한 백터-행렬 연산에 의해 수행되므로 실시간 적용이 가능하다.
- 3) 트리구조에서는 각 전문가가 별도로 작성한 트리들의 결합 및 sub-Block 마다 작성된 블록의 결합에 의한 전 계통의 트리작성이 불가능한 반면 FCM의 경우에는 위의 두가지 결합이 모두 가능하다. 이런 특성은 탐색트리의 경우 많은 전문가에 의해 작성된 트리일수록 신뢰도가 뒤지는 반면 FCM은 많은 전문가가 개입될수록 그 신뢰도가 향상됨을 의미하며, 이는 AI의 문제점인 지식습득의 측면에서 FCM의 유용성을 입증해 주는 중요한 사항이다.

3. 단순 FCM을 이용한 기본 고장진단 알고리즘

본 절에서 제안하는 고장진단기법은 상태변수의 측정치 또는 이로부터 추출된 관측패턴과 FCM으로 표현된 계통모델을 이용하여 고장요소를 식별하는 것으로 Shiozaki[5] 등의 SDG 기법에 근거한 매우 단순한 진단기법을 FCM에 도입한 것이다.

이 고장진단기법은 관측패턴을 생성하기 위한 전처리 과정과 진단알고리즘으로 구성되며 각 과정은 다음과 같다.

3.1 고장패턴의 생성

진단의 첫단계는 관측패턴의 생성이다. 관측패턴집합(W) 내의 요소(w_i)는 $\{-1, 0, 1\}$ 중의 한 값을 갖는다고 가정한다. 이때 "1"은 정상치로 부터의 증가, "0"은 정상치, "-1"은 정상치로 부터의 감소를 의미한다.

w_i 의 결정을 위해 먼저 프로세스 상태가 정상동작대역(NOBS: Normal Operating Band)에서 벗어난 정도를 나타내는 편지지표(DI: Deviation Index)를 다음과 같이 정의한다.

$$DI_i = \frac{\text{Measured Value} - \text{NOB}}{0.5 \cdot \text{NOB}}$$

위에서 첨자 i 는 i 번째 상태에 대한 지표임을 나타내며 정상동작인 경우 DI_i 는 $[-1, 1]$ 인 값을 갖는다.

고장패턴요소 w_i 는 편지지표에 대한 다음의 임계치 검사로서 결정된다.

$$w_i = \begin{cases} 1, & DI_i \geq 1 \\ 0, & |DI_i| < 1 \\ -1, & DI_i \leq -1 \end{cases}$$

3.2 기본 고장진단 알고리즘

고장진단 알고리즘은 관측패턴과 FCM모델을 적절히 결합함으로써 관측패턴과 관련된 고장의 영향을 받는 상태간의 인과관계를 추출하는 과정 및 그 인과관계의 출발점, 즉 root를 찾는 과정으로 이루어지며 각 과정은 다음과 같다.

전개의 편의상 정상상태 및 고장발생에 대한 계통변수간의 인과관계를 나타내는 FCM 행렬 E는 주어졌다고 가정한다.

Step 1) 인과관계행렬(cause-effect relation matrix)의 추출

고장의 영향을 받는 상태간의 인과관계행렬은 다음의 두가지 연산에 의해 구해진다.

$$i) WE = \text{Diag}(W) \cdot E \cdot \text{Diag}(W)$$

$$ii) CR(i, j) = T(WE(i, j))$$

위에서 T()는 임계치함수이며 임계치(Th)는 $[0, 1]$ 구간내에 존재하도록 선정한다. 관계행렬 CR은 단지 고

장요소의 식별에만 관계하므로 $CR(i, j)$ 는 다음과 같이 정의될 수 있다.

$$CR(i, j) = \begin{cases} 1, & WE(i, j) \geq Th \\ 0, & WE(i, j) < Th \end{cases}$$

위 과정의 물리적의미는 다음과 같다. 즉 $w_i \neq 0$ 인 모든상태는 반드시 다음관계가 성립한다.

$$w_i \cdot E(i, j) \cdot w_j > 0, \text{ for all nonzero } w_i, w_j$$

Step 2) 고장원인의 식별

CR 행렬의 root를 구하는 과정은 다음과 같다.

CR(i, j) 행렬의 각 변수에 대해

- ① 영향을 받는 변수의 수(Indegree)를 계산
- ② 영향을 주는 변수의 수(Outdegree)를 계산
- ③ Indegree(j)=0 이고 Outdegree(i)≥1 인 i번째 node에 대응하는 변수가 고장요인

이 과정에 대한 알고리즘은 다음과 같다.

CR(i, j), $1 \leq (i, j) \leq m$ 인 모든 요소에 대해

```

initial. : no(i)=0, ni(j)=0;
loop     : for(i=1 to m){ for(j=1 to m){
              if(CR(i, j)=1) then no(i)=no(i)+1;
            }
            for(j=1 to m){ for(i=1 to m){
              if(CR(i, j)=1) then ni(j)=ni(j)+1;
            }
          }
diagnosis : for(k=1 to m){
              if(no(i)≥1 & ni(j)=0)
                then k'th node is fault source;
              if(# of failure source≥2)
                then basic FDI fails;
            }
  
```

3.3 부분 관측패턴에 대한 고장진단의 응용

3.2절의 FDS에서는 모든상태가 측정되고 $w_i = \{-1, 0, 1\}$ 로 환산된다고 가정하였다. 그러나 완전한 관측패턴의 발생이 항상 가능한 것은 아니며 측정경비의 문제, NOB의 부적절한 선정 또는 측정장치의 고장 등으로 인해 부분적인 관측패턴만이 얻어질 수 있다.

사실상 전술한 FDS의 Step 2) 에서 고장요소가 2개 이상으로 되는 경우는 실제 고장소스가 한개인 상황에서 관측패턴 W에 오류가 있음을 의미한다. 이런 센서고장의 검출은 다중센서방식이 나 간단한 FDI 알고리즘에 의해 수행될 수 있다.

그러나 본절의 논의에서는 단순히 고장센서의 출력을 버리는 고전적인 방식을 가정하였으며 관측패턴에서 이들은 미지값, 즉 비측정변수로 취급한다.

이러한 경우 FDS 적용과정은 다음과 같다.

Step 1) 비측정변수(M)에 대해 발생가능한 모든패턴(2^M)을 발생시키고 이를 부분적으로 관측된 패턴에 결합

Step 2) 발생된 모든패턴 $W^i (i=1, \dots, 2^M)$ 에 대해서 3.2절의 알고리즘을 적용

Step 3) consistent path에서 구한 root(w_i)에 대응하는 요소를 고장요인으로 식별

4. 순시 관측패턴을 이용한 고속 실시간 고장진단

전문가의 지식 또는 실질적 데이터에 근거하여 계통에 대한 단순 FCM이 얻어지면 3장에 기술한 기본적인 고장진단 알고리즘에 의한 고장진단이 가능하다. 그러나 이 기본적 고장진단 기법은 관련된 모든 변수에 대한 확정적인 정보, 즉 전체 관측패턴이 얻어져야만 진단이 가능하다.

이러한 사실은 이 진단기법이 시간지연 또는 비교적 큰 전파지연을 갖는 프로세스에 대한 고장요인의 조기검출에 적합치 않음을 의미한다. 사실상 고장진단 시스템의 중요한 목적중 하나가 고장을 조기진단하여 운전자의 후속조치를 취하게 함으로써 고장의 파급효과를 방지하기 위한 것임을 고려할때 이러한 단점은 반

드시 보완되어야 한다.

그러나 현재까지 개발된 전문가 진단시스템은 거의 모든 경우 Forward 또는 Backward chaining에 대한 탐색과정을 포함하므로 실질적 입장에서 실시간 기법으로 사용될 수 없다.


따라서 본장에서는 3절에서 제안된 기본적인 FCM에 근거한 고장진단 알고리즘과 FCM의 TAM(Temporal Associative Memory) recall 과정을 결합한 고속 실시간 고장진단기법을 제안한다. 이 진단기법은 크게 Training 과정, 변형된 TAM recall 과정 및 매우 간단한 패턴매칭 과정으로 이루어지며 각 과정은 다음과 같다.

4.1 Training 과정과 FCM base의 자동구축

제안된 실시간 고장진단 시스템의 핵심은 FCM으로 표현된 고장 모델이다. 이 고장진단 시스템의 학습은 FCM으로 표현된 고장 모델의 자동학습과정을 의미하며 단순 FCM을 이용하는 경우에 이 학습과정은 3절에서 제안된 기본적 FDS가 각 고장에 대해 "1"회 진단을 수행함으로써 완결된다. 만일 운전경험에서 얻어진 고장 데이터가 충분하다면 고장모델 FCM의 발생을 위한 학습과정은 별도로 수행할 수 있다.

고장모델 발생과정은 다음과 같다.

- Step 1) 발생된 관측패턴에 대해 3.2절의 진단 알고리즘을 수행한다.
 - Step 2) 진단과정에서 발생된 CR 행렬은 부호가 없는 고장모델이며 고장의 전파경로만을 나타낸다. 관측패턴과 같은 추정패턴을 recall하는 고장모델은 CR 행렬의 영이 아닌 요소에 대응되는 계통모델에 대한 FCM 행렬 E의 부호를 부여함으로써 얻어진다.
 - Step 3) 고장모델의 타당성 검증은 TAM recall 과정에 의해 수행된다.
- 다음과 같은 계통을 고려해보자.



<그림 1> 간단한 tank-pipeline 시스템

위의 계통에 대한 단순 FCM은 다음과 같다.

$$E = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix}$$

계통운전중 다음의 관측패턴이 얻어졌다고 가정하자.

$$W_0 = [0 \quad + \quad - \quad - \quad -]$$

3.2절의 Step 1) 적용결과는 다음과 같다

$$CR_0 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Step 2)를 적용하면 F1 감소(-)가 고장요소임을 알 수 있다.

이 CR₀ 행렬의 영이 아닌 요소에, 대응하는 계통모델의 FCM 행렬 E의 부호를 부여 함으로써 고장모델을 얻는다. F1 감소(-)에 대한 고장모델 FCM_{F1(-)}은 다음과 같이 얻어진다.

$$FCM_{F1(-)} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

위의 과정에 의해 학습된 고장모델 FCM들은 모두 FCM base에 저장된다.

4.2 변형된 TAM recall 및 순시 패턴매칭에 의한 고장진단

FCM의 TAM recall은 고장원인을 투입하여 고장패턴을 추론하는 과정이며, 이 과정의 반복수행은 고장원인의 순차적 전파과정과 패턴벡터내 각 요소의 부호 (-1, 0, 1)를 결정해 준다.

위 FCM_{F1(-)}은 고장원인이 F1 감소(-)인 경우에 대한 고장모델이므로 F1의 감소(-)가 최초로 검출되었을 때 recall 과정에 사용된다. recall 과정은 매우 단순한 벡터연산이다.

Step 1) 검출된 고장원인을 다음 벡터로 표현한다.

$$D_0 = \begin{bmatrix} f_0 & L_1 & f_1 & L_2 & f_2 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$$

Step 2) 고장모델 FCM_{F1(-)}을 사용해서 다음 연산을 수행한다.

$$D_0 \cdot FCM_1 = [0 \quad 1 \quad 0 \quad -1 \quad 0] = D_1$$

매 Step에서 D_i 벡터의 3번째 요소를 (-1)로 대체하면

$$D_1 = [0 \quad 1 \quad -1 \quad -1 \quad 0]$$

$$D_2 = [0 \quad 1 \quad -1 \quad -1 \quad -1]$$

$$D_3 = D_2$$

⋮

위의 결과는 고장원인이 F1 감소(-)인 경우 1단계 전파가 L₁ 증가와 L₂ 감소로 나타나고, 2단계 전파 결과가 L₁ 증가, L₂ 감소 및 F₂ 감소로 순차적으로 나타남을 의미한다. 또한 D₃=D₂는 고장의 전파과정이 끝났음을 의미한다. 일반적인 TAM recall 과정과 위 과정의 차이는 recall 과정에서 Thresholding이 생략되었다는 점이다. 위에서 D₂는 F1 감소(-)가 고장인 경우의 관측패턴과 일치한다.

패턴매칭에 의한 진단과정은 다음과 같다.

- Step 1) 최초로 편기값(|D_i| > 1) 발생된 변수를 고장요인으로 가정
- Step 2) 가정된 고장요인에 대해 recall 과정을 수행해서 고장 패턴 시퀀스를 예측
- Step 3) 예측패턴 시퀀스와 관측패턴 시퀀스를 비교해서 일치하면 가정된 고장요인을 고장요인으로 판정

이 과정은 추정된 패턴 시퀀스와 측정된 패턴 시퀀스를 비교하는 방식이므로 순시 관측패턴매칭에 대한 Hypothesis Test로 분류할 수 있다.

위의 예에서 최초의 관측패턴, W₀가

$$W_0 = [0 \quad 0 \quad -1 \quad 0 \quad 0]$$

라면 TAM recall 과정으로 즉시 D₁, D₂를 생성한다. 만일 다음 관측패턴, W₁이

$$W_1 = [0 \quad 1 \quad -1 \quad -1 \quad 0] = D_1$$

이면 고장요인은 F1 감소(-)로 판정된다.

4.3 전파지연시간이 개입된 FCM 및 고장진단

위 방법을 적용할 경우 고려해야할 중요한 제약은 각 인접변수 간의 전파지연시간에 대한 사전정보가 요구된다는 점이다. 위의 예에서 패턴 시퀀스는 고장영향의 전파과정이라는 측면에서 정확한 표현이지만 실제 관측패턴의 시퀀스는 고장의 전파시간에 의존한다.

순시 관측패턴을 이용한 실시간 고장진단은 기본적으로 전술한 바 같이 고장의 전파과정에 시간적인 차이가 있는 경우 전체관측패턴이 발생되기전에 조기진단을 가능케 하기 위한 것이다.

패턴벡터 요소 w_i가 발생후 w_j가 발생할때 까지의 시간을 t_{ij}라 하고 t₃₄ < t₃₂ < t₃₅(=t₃₄+t₄₅)라 하면 관측패턴의 시간

시퀀스는 다음과 같다.

$$\begin{aligned} W_0^t &= [0 \ 0 \ -1 \ 0 \ 0] \\ W_1^t &= [0 \ 0 \ -1 \ -1 \ 0] \\ W_2^t &= [0 \ 1 \ -1 \ -1 \ 0] \\ W_3^t &= [0 \ 1 \ -1 \ -1 \ -1] \end{aligned}$$

따라서 $W_2^t = W_1 = D_1$ 의 관계가 확인되기 위해서는 t_{32} 가 경과해야 한다. 더욱 곤란한 문제는 $t_{34} < t_{35} < t_{32}$ 와 같을때 발생하며 이 경우 관측패턴의 시퀀스는 다음과 같다.

$$\begin{aligned} W_0^t &= [0 \ 0 \ -1 \ 0 \ 0] \\ W_1^t &= [0 \ 0 \ -1 \ -1 \ 0] \\ W_2^t &= [0 \ 0 \ -1 \ -1 \ -1] \\ W_3^t &= [0 \ 1 \ -1 \ -1 \ -1] \end{aligned}$$

위의 경우에는 전체 관측패턴이 발생후 t_{32} 까지를 관찰해야만 고장진단이 가능하다. 위의 시간 시퀀스와 관련된 또하나의 문제는 중간과정에 D_1 과 같은 패턴이 발생되지 않는다는 사실이다.

이러한 FCM의 TAM recall과정과 관측패턴의 시간 시퀀스간의 불일치 문제는 3.2절의 FD 알고리즘에 의한 Training시에 각 (w_i, w_j)간의 전파지연시간을 개입시킴으로써 해결될 수 있다. 일반적으로 전파지연은 운전상황에 따라 변화할 수 있으나 대부분의 경우 시간 시퀀스의 변화를 초래하지는 않는다.

이렇게 전파지연시간이 개입된 FCM에 의한 recall에서는 FCM 행렬의 요소중 전파지연시간이 작은것부터 차례로 투입하면서 recall 과정을 진행하는 것이다.

위의 고장모델 FCM_{r1(-)}에 전파지연시간을 개입시켰을 경우의 FCM 행렬은 다음과 같다.

$$FCM_{r1(-)} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & (-1, t_{32}) & 0 & (1, t_{34}) & 0 \\ 0 & 0 & 0 & 0 & (1, t_{45}) \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

위의 FCM에 의한 recall에서 t_{ij} 는 w_i 가 w_j 를 firing하는데 걸리는 시간이므로 FCM 행렬의 (i, j)요소중 작은것부터 차례로 투입하면서 recall 과정을 진행한다.

예를 들어 $t_{34} < t_{35} (=t_{34}+t_{45}) < t_{32}$ 인 경우의 recall 과정은 다음과 같다.

$$D_0^t = [0 \ 0 \ -1 \ 0 \ 0]$$

Step 1> 전파지연시간 t_{34} 을 갖는 (3,4)요소를 투입

$$D_0^t \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = [0 \ 0 \ 0 \ -1 \ 0] \\ \Leftrightarrow [0 \ 0 \ -1 \ -1 \ 0] = D_1^t$$

Step 2> 전파지연시간 $t_{35} (=t_{34}+t_{45})$ 을 갖는 (4,5)요소를 투입

$$D_1^t \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = [0 \ 0 \ 0 \ -1 \ -1] \\ \Leftrightarrow [0 \ 0 \ -1 \ -1 \ -1] = D_2^t$$

Step 3> 전파지연시간 t_{32} 을 갖는 (3,2)요소를 투입

$$D_2^t \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = [0 \ 1 \ 0 \ -1 \ -1] \\ \Leftrightarrow [0 \ 1 \ -1 \ -1 \ -1] = D_3^t$$

관측패턴 시퀀스 W^t 와 예측패턴시퀀스 D^t 를 비교하면

$$\begin{aligned} D_0^t &= W_0^t \\ D_1^t &= W_1^t \\ D_2^t &= W_2^t \\ D_3^t &= W_3^t \end{aligned}$$

와 같이 일치하므로 예측되고장요인 F_1 감소(-)를 고장요인으로 판정한다.

이 절에서 논의한 실시간 고장진단 시스템은 3절에 기술한 간단한 FD알고리즘 또는 계층적진단 알고리즘을 이용한 학습과정에 의해 모든 고장에 대한 FCM 모델을 발생시키므로 FCM base의 구축은 자동적으로 이루어진다는 특징을 갖는다.

4.4 센서고장의 검출

센서고장의 경우에는 인접한 센서가 정상적이면 후속되는 고장 패턴이 발생되지 않으므로 FCM recall에 의해 예측된 고장패턴과 전혀 일치하지 않는다. 따라서 FCM recall에 의한 패턴 시퀀스와 관측패턴 시퀀스가 상이하고 관측패턴 시퀀스의 모든 요소가 영인 경우를 센서고장으로 진단한다.

만약 위의 예에서

$$\begin{aligned} W_0^t &= [0 \ 0 \ -1 \ 0 \ 0] \Leftrightarrow D_0^t = [0 \ 0 \ -1 \ 0 \ 0] \\ W_1^t &= [0 \ 0 \ 0 \ 0 \ 0] \Leftrightarrow D_1^t = [0 \ 0 \ -1 \ -1 \ 0] \end{aligned}$$

이면 $W_1^t \neq D_1^t$ 이므로 F_1 센서가 고장임을 판단할 수 있다.

5. 다중구조 FCM으로의 확장

많은 변수를 포함하는 대규모 계통의 정성적 모델링은 전문가라 할지라도 많은 시간과 인력을 요구한다. 그러나 FCM은 서로 다른 전문가에 의해 하위블럭별 FCM을 작성하여 합성함으로써 전 계통에 대한 FCM모델을 구할 수 있으므로 대규모 계통의 정성적 모델링에 효과적으로 사용될 수 있다.

5.1 중복분할방식에 근거한 계층적 진단

이러한 특성으로 인해서 FCM은 진단 알고리즘의 단순화를 위한 분할 및 계층적 진단을 가능케 한다. FCM으로 표현된 계통 모델을 분할하는 방법으로는 계통 모델을 매개변수를 공유하는 블럭들로 분할하는 중복분할방식이 바람직하다.

중복분할방식에 근거한 계층적 진단과정은 다음과 같다[6].

Step 1> 고장블럭의 식별

블럭간 매개변수간의 상호작용을 표현한 상위 FCM에 근거해서 3.2절의 알고리즘을 수행

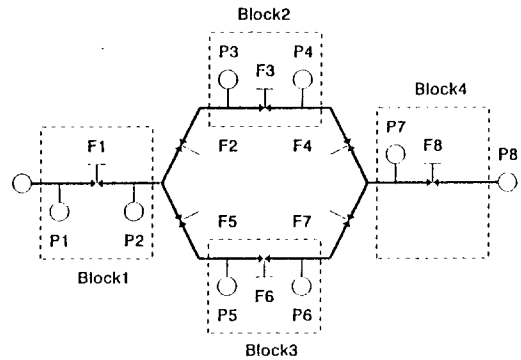
Step 2> 고장 하위블럭의 식별

하위블럭간 매개변수간의 상호작용을 표현한 중위 FCM에 근거해서 3.2절의 알고리즘을 수행

Step 3> 고장요소의 식별

하위블럭에 대한 FCM에 근거해서 고장요소를 식별

다음의 Bypass-pipeline system을 고려해 보자.



< 그림 2 > Bypass-pipeline system

위 계통은 4개의 블럭으로 분할될 수 있으며 각 블럭에 대한 하위 FCM은 다음과 같다.

$$FCM_1 = \begin{matrix} P_1 & F_1 & P_2 & F_2 & F_5 \\ F_1 & 0 & 1 & 0 & 0 \\ P_2 & -1 & 0 & 1 & 0 \\ F_2 & 0 & 0 & -1 & 0 \\ F_5 & 0 & 0 & -1 & 0 \end{matrix}$$

$$FCM_2 = \begin{matrix} F_2 & P_3 & F_3 & P_4 & F_4 \\ P_3 & 0 & 1 & 0 & 0 \\ F_3 & -1 & 0 & 1 & 0 \\ P_4 & 0 & -1 & 0 & 1 \\ F_4 & 0 & 0 & -1 & 0 \end{matrix}$$

$$FCM_3 = \begin{matrix} F_5 \\ P_5 \\ F_6 \\ P_6 \\ F_7 \end{matrix} \begin{bmatrix} F_5 & P_5 & F_6 & P_6 & F_7 \\ 0 & 1 & 0 & 0 & 0 \\ -1 & 0 & 1 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix}$$

$$FCM_4 = \begin{matrix} F_4 \\ F_7 \\ P_7 \\ F_8 \\ P_8 \end{matrix} \begin{bmatrix} F_4 & F_7 & P_7 & F_8 & P_8 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ -1 & -1 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

위 FCM들을 합성하면 전 계통에 대한 FCM을 얻을 수 있다.
블럭간 매개변수들로 구성된 1st Level FCM은 다음과 같이 얻어진다.

$$E_{1st} = \begin{matrix} P_2 \\ F_2 \\ F_4 \\ F_5 \\ F_7 \\ P_7 \end{matrix} \begin{bmatrix} P_2 & F_2 & F_4 & F_5 & F_7 & P_7 \\ 0 & 1 & 0 & 0 & 1 & 0 \\ -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & -1 & 0 & -1 & 0 \end{bmatrix}$$

계통운전중 다음과 같은 관측패턴이 얻어진 경우를 고려하자.

$$W = [0 \ - \ (+) \ (+) \ + \ + \ - \ (+) \ (-) \ + \ - \ + \ (-) \ (-) \ - \ 0]$$

위 계통은 Two-level FCM을 갖으므로 계층적진단 역시 2층 구조로 진행된다. 1st layer의 진단은 고장블럭을 찾아내는 과정이며, 2nd layer의 진단은 1st layer의 진단결과에서 반영된 고장블럭내에서 고장요소를 찾아내는 과정이다. 위의 관측패턴은 F7의 감소(-)로 인해 발생한 패턴이며 진단 알고리즘의 타당성 검증을 위해 정성적 시뮬레이션에 의해 구하였다. (+)로 표시한 변수는 1st Level FCM에 포함된 블럭간 매개변수를 의미한다.

< 1st layer 진단 >

W에서 1st Level FCM 변수만을 선택하고

$$W_1 = [+ \ + \ + \ - \ - \ -]$$

3.2절의 Step 1)을 수행한 결과는 다음과 같다

$$CR_3 = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 & 0 \end{bmatrix}$$

Step 2)를 수행한 결과는 고장블럭을 <BLOCK 3>으로 판정한다.

< 2nd layer 진단 >

2nd layer의 진단은 1st layer의 진단결과에 따라서 해당블럭의 FCM 및 포함된 변수에 의해 수행된다.
고장블럭내의 관측패턴은 다음과 같다.

$$W_{B3} = [- \ + \ - \ + \ -]$$

다시 3.2절의 Step 1)을 수행한 결과는 다음과 같다

$$CR_{B3} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

Step 2)를 수행하면 고장 요인이 F7의 감소(-)임을 알수있다.

위 CR 행렬의 영이 아닌 요소에 대응하는 1st Level FCM행렬의 부호를 부여함으로써 1st Level 고장모델을 얻는다.

$$CR_3^* = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & -1 & 0 & 0 & 0 \end{bmatrix}$$

같은 방법으로 CR_{B3} 행렬에 2nd Level FCM 행렬의 부호를 부여하여 2nd Level 고장모델을 얻을 수 있다.

$$CR_{B3}^* = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix}$$

5.2 다층구조 FCM에 대한 변형된 TAM recall 과정 및 패턴매칭에 의한 고장진단

다층구조 FCM 일 경우에 대한 recall 과정은 진단과 마찬가지로 계층적으로 수행된다.

다층구조 FCM에 대한 recall 과정은 다음과 같다.

Step 1) 검출된 고장원인을 벡터로 표현한다.

Step 2) 고장원인을 포함하는 하위 FCM 고장모델을 이용해서 고장블럭내 변수간 전파과정을 추정한다.

Step 3) 고장블럭에 대한 상위 FCM 고장모델을 이용해서 블럭간 전파과정을 추정한다.

Step 4) 전파된 각 블럭에 대한 FCM 모델을 이용해서 각 블럭내 변수간 전파과정을 추정한다.

Step 5) 각 블럭에서 생긴 고장패턴들을 결합하여 전체 고장패턴을 생성한다.

위의 예에서 고장원인을 벡터로 표현하면 다음과 같다.

$$W_r = \begin{matrix} F_5 & P_5 & F_6 & P_6 & F_7 \\ [0 & 0 & 0 & 0 & -1] \end{matrix}$$

고장원이 F7 감소(-) 이므로 <Block 3>의 고장모델을 이용하여 다음 연산을 수행한다.

$$W_r \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix} = [0 \ 0 \ 0 \ 1 \ 0] \\ \Leftrightarrow [0 \ 0 \ 0 \ 1 \ -1] = F_1$$

$$F_1 \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix} = [0 \ 0 \ -1 \ 1 \ 0] \\ \Leftrightarrow [0 \ 0 \ -1 \ 1 \ -1] = F_2$$

$$F_2 \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix} = [0 \ 1 \ -1 \ 1 \ 0] \\ \Leftrightarrow [0 \ 1 \ -1 \ 1 \ -1] = F_3$$

$$F_3 \cdot \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix} = [-1 \ 1 \ -1 \ 1 \ 0] \\ \Leftrightarrow [-1 \ 1 \ -1 \ 1 \ -1] = F_4$$

그러므로 <Block 3>내 고장패턴은 다음과 같다.

$$W_r = \begin{matrix} F_5 & P_5 & F_6 & P_6 & F_7 \\ [-1 & 1 & -1 & 1 & -1] \end{matrix}$$

다음으로 고장이 다른블럭으로 전파되가는 과정을 추정하기 위해 상위 FCM 고장모델을 이용하여 블럭간 고장전파관계를 구한다. 블럭간 매개변수만의 관측패턴은 다음과 같다.

$$W_B = \begin{matrix} P_2 & F_2 & F_4 & F_5 & F_7 & P_7 \\ [0 & 0 & 0 & -1 & -1 & 0] \end{matrix}$$

<Block 3>고장에 대한 상위 FCM 고장모델을 이용하여 다음 연산을 수행한다.

$$W_B \cdot \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & -1 & 0 & 0 & 0 \end{bmatrix} = [1 \ 0 \ 0 \ 0 \ 0 \ -2] \\ \Leftrightarrow [1 \ 0 \ 0 \ -1 \ -1 \ -1] = F_{B1}$$

$$F_{B1} \cdot \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & -1 & 0 & 0 & 0 \end{bmatrix} = [1 \ 2 \ 1 \ 0 \ 0 \ -2] \\ \Leftrightarrow [1 \ 1 \ 1 \ -1 \ -1 \ -1] = F_{B2}$$

따라서 매개변수의 고장패턴은 다음과 같다.

$$W_B = \begin{matrix} P_2 & F_2 & F_4 & F_5 & F_7 & P_7 \\ [1 & 1 & 1 & -1 & -1 & -1] \end{matrix}$$

<Block 1>에 대한 관측패턴은 다음과 같다

$$W_r = \begin{matrix} P_1 & F_1 & P_2 \\ [0 & 0 & 1] \end{matrix}$$

위의 관측패턴에 대해 다음 연산을 수행한다.

$$W_r \cdot \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 1 \\ 0 & -1 & 0 \end{bmatrix} = \begin{bmatrix} 0 & -1 & 0 \\ 0 & -1 & 1 \end{bmatrix}$$

그러므로 <Block 1>의 고장패턴은 다음과 같다.

$$W_r = \begin{bmatrix} P_1 & F_1 & P_2 \\ 0 & -1 & 1 \end{bmatrix}$$

다음으로 <Block 4>에 대한 recall 과정은 다음과 같다.

$$W_r = \begin{bmatrix} P_7 & F_8 & P_8 \\ -1 & 0 & 0 \end{bmatrix}$$

위의 관측패턴에 대해 다음 연산을 수행한다.

$$W_r \cdot \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix} = \begin{bmatrix} 0 & -1 & 0 \\ -1 & -1 & 0 \end{bmatrix}$$

따라서 <Block 4>의 고장패턴은 다음과 같다.

$$W_r = \begin{bmatrix} P_7 & F_8 & P_8 \\ -1 & -1 & 0 \end{bmatrix}$$

<Block 2>에 대한 관측패턴은 다음과 같고

$$W_r = \begin{bmatrix} F_2 & P_3 & F_3 & P_4 & F_4 \\ 1 & 0 & 0 & 0 & 1 \end{bmatrix}$$

recall 과정은 다음과 같다.

$$W_r \cdot \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ -1 & 0 & 1 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & -1 & 0 \\ 1 & 1 & 0 & -1 & 1 \end{bmatrix} = F_1$$

$$F_1 \cdot \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ -1 & 0 & 1 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & -1 & 0 \end{bmatrix} = \begin{bmatrix} -1 & 1 & 2 & -1 & -1 \\ 1 & 1 & 1 & -1 & 1 \end{bmatrix} = F_2$$

그러므로 다음과 같은 고장패턴을 얻을 수 있다.

$$W_r = \begin{bmatrix} F_2 & P_3 & F_3 & P_4 & F_4 \\ 1 & 1 & 1 & -1 & 1 \end{bmatrix}$$

결국 각 블록에서 구한 고장패턴들을 결합하면 전체 고장패턴을 얻을 수 있다.

$$W_r = \begin{bmatrix} P_1 & F_1 & P_2 & P_3 & F_3 & P_4 & F_4 & F_5 & P_5 & F_6 & P_6 & F_7 & P_7 & F_8 & P_8 \\ 0 & -1 & 1 & 1 & 1 & -1 & 1 & -1 & 1 & -1 & 1 & -1 & -1 & -1 & 0 \end{bmatrix}$$

따라서 처음 관측패턴이

$$W = \begin{bmatrix} F_5 & P_5 & F_6 & P_6 & F_7 \\ 0 & 0 & 0 & 0 & -1 \end{bmatrix}$$

이고 이후 발생하는 관측패턴 시퀀스가 위의 추정패턴 시퀀스와 일치하면 F7 감소(-)를 고장요인으로 판정한다.

▶ 전파지연시간이 개입된 경우

각 고장블록내 인과관계행렬의 영이 아닌 요소에 대응하는 하위 FCM행렬의 부호를 부여한 2nd Level 고장모델에 전파지연시간을 개입시키면 다음과 같다.

$$CR_{B3} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ (-1, t_{21}) & 0 & 0 & 0 & 0 \\ 0 & (-1, t_{32}) & 0 & 0 & 0 \\ 0 & 0 & (-1, t_{43}) & 0 & 0 \\ 0 & 0 & 0 & (-1, t_{54}) & 0 \end{bmatrix}$$

전파지연시간이 $t_{32} < t_{43} < t_{21} < t_{54}$ 와 같을 경우 전파지연시간이 작은것부터 차례로 투입하면서 recall과정을 진행한다.

고장 Block내의 관측패턴이 다음과 같을때

$$W_{B3} = [0 \ 0 \ 0 \ 0 \ -1]$$

전파지연시간이 작은것부터 차례로 투입하면 예측패턴 시퀀스는 다음과 같다.

$$\begin{aligned} T_1 &= [0 \ 0 \ 0 \ 1 \ -1] \\ T_2 &= [0 \ 0 \ -1 \ 1 \ -1] \\ T_3 &= [0 \ 1 \ -1 \ 1 \ -1] \\ T_4 &= [-1 \ 1 \ -1 \ 1 \ -1] \end{aligned}$$

다음으로 CR행렬의 영이 아닌 요소에 대응하는 1st Level FCM행렬의 부호를 부여받은 1st Level 고장모델에 전파지연시간을 개입시키면 다음과 같다.

$$CR^t = \begin{bmatrix} 0 & (1, t_{12}) & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ (-1, t_{41}) & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & (1, t_{56}) \\ 0 & 0 & (-1, t_{63}) & 0 & 0 & 0 \end{bmatrix}$$

만약 전파지연시간이 $t_{56} < t_{41} < t_{63} < t_{12}$ 라면 블럭간 관측패턴이 다음과 같으므로

$$W^t = [0 \ 0 \ 0 \ -1 \ -1 \ 0]$$

예측패턴 시퀀스는 다음과 같다.

$$\begin{aligned} T_1 &= [0 \ 0 \ 0 \ -1 \ -1 \ -1] \\ T_2 &= [1 \ 0 \ 0 \ -1 \ -1 \ -1] \\ T_3 &= [1 \ 0 \ 1 \ -1 \ -1 \ -1] \\ T_4 &= [1 \ 1 \ 1 \ -1 \ -1 \ -1] \end{aligned}$$

따라서 순시 관측패턴 시퀀스가 위 예측패턴 시퀀스와 일치하면 F7의 감소(-)를 고장요인으로 판정한다.

6. 결론

본 논문에서는 FCM을 이용한 고장진단기법과 변형된 TAM recall 과정 및 패턴매칭을 이용한 실시간 고장진단기법을 제안하였다.

변형된 FCM recall 및 패턴매칭에 의한 실시간 고장진단기법은 간단한 FD 알고리즘 또는 계층적진단 알고리즘을 이용한 학습과정에 의해 모든 고장에 대한 FCM 모델을 발생시키므로 FCM base의 구축이 자동적으로 이루어진다는 특징을 갖는다. 센서고장도 프로세스고장과 같이 고장모델 FCM에 의한 recall 과정을 유발시킨다는 사실에 근거해서 센서고장검출에 매우 효과적으로 사용될 수 있다.

또한 순시 관측패턴을 이용한 실시간 고장진단기법은 전파과정에 시간적인 차이가 있는 경우 Training시 전파지연시간을 개입시킴으로써 전체 관측패턴이 발생하기 전에 고장의 조기진단을 가능하게 한다.

기존 AI 기법의 가장 큰 문제점인 계층모델링 및 지식습득의 어려움을 해결할 수 있고 진단과정이 단순하여 기억용량과 계산 시간면에서 효과적이므로 대규모계통의 실시간 고장진단에 적합하다. 변형된 TAM recall 과정을 이용하여 고장모델 발생이 가능하며 미분형 Hebb's rule에 의해 프로세스 특성변화에 대해 적용할 수 있다.

참고문헌

- [1] R.Patton, P.Frank, R.Clark, " Fault Diagnosis in Dynamic Systems Theory and Application ", Prentice Hall, 1989
- [2] Mark A. Kramer, " A Rule-Based Approach to Fault Diagnosis Using The Signed Directed Graph ", AIChE Journal, vol.33, no7, Jul., 1987
- [3] Bart Kosco, " Neural Networks and Fuzzy Systems : A Dynamical Systems Approach to Machine Intelligence ", Prentice Hall, 1992
- [4] Y. Tsuge, H. Matsuyama, " Advanced Estimate of the Accuracy of The Diagnostic Result for The Fault Diagnosis by Use of The Signed Directed Graph ", Engineering, Kyushu Univ., vol.44, no.3, Sep., 1984
- [5] J. Shiozaki, H. Matsuyama, " Fault Diagnosis of Chemical Process by The Use of Signed Directed Graphs. Extention to Five-Range Patterns of Abnormality ", Int. Chemical Eng., vol.25, no.4, pp. 651-659, Oct., 1985
- [6] 이 기상, 박 태홍, 정 원석, 최 낙원, " FCM을 이용한 프로세스 고장진단 ", 대한 전기 학회 하계 학술대회 논문집(A), pp.430-432, 1993