

고장 패턴을 이용한 시스템의 고장진단

°이진하\*, 라경택\*, 이영석\*\*, 서보혁\*  
 \*경북대학교 대학원 전기공학과, \*\*영진전문대 전기계열

Fault Diagnosis of System Using Fault Pattern

°Jin-Ha Lee\*, Kyung-Taek La\*, Young-Seog Lee\*\*, Bo-Hyeok Seo\*  
 Dept. of Electrical Eng. Kyungpook Nat. Univ.\*, Dept. of Electrical Eng. Yeungjin Junior College\*\*

**Abstract** - Using neural network approach, the diagnosis of faults in industrial process that requires observing multiple data simultaneously are studied in this paper. Two-stage diagnosis is proposed as the basic structure. The first stage detects the dynamic trend of each measurements and the second stage diagnosis the faults. This paper makes up for the disadvantage of neural about unknown faults. The potential of this approach is demonstrated in simulation using a model of tank reactor.

2. 문제 설정

2.1 대상 시스템

본 논문에서 고장진단을 위하여 예로 든 시스템은 탱크 반응로이다. 이 모델은 시스템의 데이터를 출력하기 위한 모델이며, 식으로 나타낸 시스템의 동적특성은 실제 고장 진단에는 이용되지 않는다.




그림 1. 탱크 반응로

그림 1은 발열반응을 나타내는 탱크 반응로이며, 물질 A를 탱크로 주입하여 반응을 거친 다음, 출구로 내 보낸다. 발열반응에서 발생하는 열을 제거하기 위하여 냉각수를 흘린다. 탱크내부의 온도는 전체적으로 균일하다고 가정한다.

그림 1의 시스템을 나타내는 식은 다음과 같다.

$$\frac{dv}{dt} = F_o - F \tag{1}$$

$$\frac{d(VC_a)}{dt} = F_o C_{ao} - FC_a - VkC_a \tag{2}$$

$$\rho C_p \frac{d(VT)}{dt} = \rho C_p (F_o T_o - FT) - \lambda VkC_a - UA_h (T - T_j) \tag{3}$$

$$\rho_j V_j C_j \frac{dT_j}{dt} = F_j \rho_j C_j (T_{jo} - T_j) + UA_h (T - T_j) \tag{4}$$

식에 사용된 변수들은 다음과 같다.

- $F_o, F$  : 입구와 출구에서의 흐르는 속도
- $C_{ao}, C_a$  : 입구와 출구에서의 A의 농도
- $V, V_j$  : 탱크와 냉각수의 부피
- $\rho, \rho_j$  : 탱크 내부와 냉각수의 밀도
- $U$  : 열 전달 계수
- $A_h$  : 열 전달 면적
- $C_p, C_j$  : 탱크 내부와 냉각수의 열 용량
- $T, T_j$  : 탱크내부와 냉각수의 온도

1. 서 론

최근 산업의 발전과 더불어 시스템이 복잡해지고 빨라지게 되었으며, 이러한 시스템의 신뢰성을 유지하는 일이 무엇보다도 중요한 일로 대두되었다. 시스템의 신뢰성 유지를 위해서는 그 시스템에서 발생하는 고장에 대한 보다 빠르고 구체적인 정보를 제때에 얻어서 이용할 필요가 있다. 이러한 이유로 인해서 최근에는 고장진단 분야에서 많은 연구들이 이루어지고 있다.

고장진단 기법은 여러 가지가 있으나 가장 일반적인 방법은 수학적 모델을 기반으로 하는 방법이다. 이는 프로세스에 대한 모델링과 측정할 수 없는 상태변수에 대한 예측을 필요로 한다. 가장 기본적인 개념은 모델의 출력과 실제 프로세스에서의 출력을 비교하여 시스템의 상태를 알아낼 수 있는 잔차를 생성하여 그 시스템의 상태를 알아내는 것이다. 하지만 이런 방법은 시스템의 모델링이 정확하지 않을 경우 많은 문제를 일으킨다. 시스템 모델의 불확실성은 관찰할 수 있는 정보의 예측을 어렵게 만들고 잘못된 진단으로 인한 손실을 야기한다.

한편, 모델을 기반으로 하지 않는 고장진단 기법은 프로세스의 변수 또는 파라미터를 측정, 기록하고 이들의 통계적 특성에 대한 가설검사에 의해 고장을 검출하는 신호검증기법, 프로세스의 변수 또는 파라미터의 측정치를 도표를 이용하여 관찰함으로써 동적 시스템의 상태를 감시하는 관리도 기법, 진동 및 음향의 주파수 분석 결과에 의해 장치의 동작상태를 감시하는 기법 등 여러 가지 기법들이 있다.

본 논문에서는 모델에 기반을 두지 않고, 실제 프로세스에서 나오는 자료로부터 프로세스의 고장을 진단하는 방법을 이용한다. 주 진단부는 크게 두 부분으로 구성된다. 전반부는 뉴럴을 이용해 시스템에서 나오는 데이터의 패턴을 파악하는 부분이며, 후반부는 파악된 패턴을 바탕으로 고장을 검출하고 분류한다. 또 표준화된 데이터를 바탕으로 시스템이 정상상태에서 벗어나는 정도를 파악하여 알려지지 않은 고장에 대한 검출을 수행한다.

### 3. 본론

#### 3.1 고장 진단 알고리즘

고장 진단 알고리즘의 구조는 그림2와 같다.

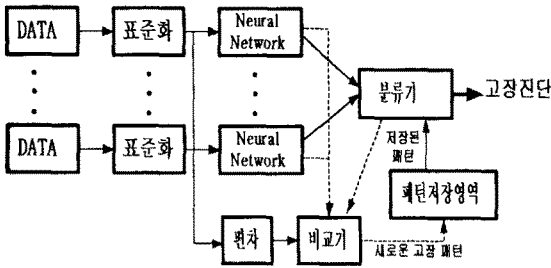


그림 2. 고장 진단 알고리즘

#### 3.2 데이터의 획득과 변환

데이터는 시스템의 반응속도나 정밀도에 따라서 적절한 시간 간격과 개수를 결정하게 된다. 데이터의 개수가 많을 경우 대체로 외란에 강하고 정확한 고장의 검출이 가능하지만, 신속한 검출이 어렵게 된다.

일단 검출된 데이터는 데이터의 변동범위와 진단에 도움이 되는지를 고려하여 수치를 -1에서 1사이로 표준화시킨다. 표준화는 측정치의 변동에 대해서 민감하게 하고, 고장시의 변화된 패턴을 수치로 일반화하기 위해 뉴럴의 입력을 일정한 범위내에 두기 위한 방법이다.

#### 3.3 뉴럴 네트워크

대부분의 데이터는 정상상태에서 증가나 감소하는 형태로 고장이 나타난다. 그래서 패턴을 학습시킬 때에도 정상상태에서 증가나 감소하는 형태를 기준으로 패턴을 학습시킨다.




그림 3. 학습시킨 패턴

가장 증가정도가 큰 것을 (0.9 0.1 0.1)로 학습시키고, 가장 감소정도가 큰 것을 (0.1 0.1 0.9)로 학습시킨다. 그리고 그 사이에는 증가, 감소의 정도를 적절히 고려하여 기준값을 정하였다.

그림 3의 패턴은 일반적인 뉴럴을 이용하여 이미 널리 알려진 역전파법을 이용하여 네트워크를 학습시켰다.

패턴을 학습시킨 후, 각 고장패턴을 뉴럴 네트워크를 통과하게 되면 패턴의 형태에 따라 적절한 출력값을 나타내게 된다. 그림 4는 첫 번째 고장 유형에 대한 패턴을 나타낸 것이다. 고장은 600에서부터 발생하고 있다. 고장의 패턴은 각 변수마다 다르게 나타나며, 서로 다른 고장에 대해서는 같은 변수에 대해서도 서로 다른 패턴이 나타나게 된다.

표1은 두 가지의 고장 패턴을 뉴럴 네트워크의 출력으로 나타내어 보았다.




그림 4. 고장 1의 실제 고장 패턴

표 1. 뉴럴에서 출력된 고장패턴

변 수	고장 1	고장 2
Fj	9.2689718e-001	9.7591638e-002
	7.0165227e-002	1.2818684e-001
	9.7836397e-002	8.7580847e-001
F	9.9299933e-002	9.9299933e-002
	8.9817073e-001	8.9817073e-001
	1.0695777e-001	1.0695777e-001
V	9.9299933e-002	9.9299933e-002
	8.9817073e-001	8.9817073e-001
	1.0695777e-001	1.0695777e-001
Tj	8.8532484e-001	9.1795379e-002
	1.1176664e-001	4.0463164e-001
	9.7697666e-002	6.2461764e-001
Ca	1.5920844e-001	6.4347980e-002
	6.8556863e-001	9.3800284e-001
	2.1853002e-001	1.0132180e-001
T	9.1032773e-001	9.4724283e-002
	8.6667203e-002	2.7070028e-001
	9.7775586e-002	7.4497270e-001

#### 3.4 분류기

기존의 경우에는 대부분 뉴럴 네트워크를 이용했으나, 여기서는 뉴럴 네트워크 대신에 각 고장 패턴의 값을 저장하고 입력이 들어올 때마다 그 저장된 패턴과 새 패턴과의 차를 구하여 유사한 패턴일 경우, 고장으로 인식하고 특정 노드에 고장의 발생을 알리게 된다. 하지만 이미 밝혀진 고장 패턴과 유사한 패턴이 아닌 경우, 고장이 아닌 것으로 진단하게 된다. 이러한 패턴의 비교는 뉴럴네트워크에서 나온 출력값으로 하게 된다.

$$D = \frac{1}{s} \sum_{i=1}^s |f_{si} - y_i| < \delta_s \quad (5)$$

$f_s$ 는 저장된 고장패턴,  $y$ 는 입력패턴,  $\delta_s$ 는 고장인지 여부를 판단하는 문턱값이다.

저장된 패턴  $f_s$ 에 대해서 유사한 패턴  $y$ 가 입력되었을 때에는  $f_s$ 와  $y$  사이에 차이가 작기 때문에  $D$ 의 값은 문턱값보다 작게되고, 이로 인해서 고장이 발생했음을 알게 된다.

문턱값은 상당히 중요한 역할을 하게 되는데, 문턱값이 너무 낮으면 노이즈의 영향을 많이 받을 경우, 고장진단

이 힘들게 되고, 문턱값이 높을 경우는 다른 패턴과의 혼동 우려가 있다.

### 3.5 알려지지 않은 고장에 대한 검출 기준

그림 4에서 알 수 있듯이 각 변수의 수치를 표준화 시킬 때, 0인 상태를 정상상태로 두었기 때문에, 각 수치의 편차는 그만큼의 정상상태에서 벗어난 정도를 나타낸다. 이는 알려지지 않은 고장을 검출해 내는데, 이용될 수 있다. 여기서 구한 편차는 각 변수를  $x$ , 변수의 개수를  $n$ 이라 하면 변수에 대한 평균적인 편차  $\sigma_{avg}$ 는

$$\sigma_{avg} = \frac{1}{n} \sum_{i=1}^n \sqrt{|x_i|^2} \quad (4)$$

이 된다.

실제로 편차가 어느 일정치를 넘을 때에는 그 패턴이 지금 현재 고장 패턴에 존재하는 패턴인지 확인하기 위하여 고장 분류기의 출력을 조사한다. 그 고장이 지금까지 알려진 고장이 아닐 경우, 이를 새로운 고장패턴으로 간주하여 새로운 고장 패턴으로 저장하게 된다. 단, 저장은 실제 데이터 전체를 저장하는 것이 아니라 뉴럴에 의해서 워치된 패턴으로 저장된다. 이렇게 함으로써 알려지지 않은 고장에 대한 검출이 가능하게 된다.

만약 그림 5에서 첫 번째 유형의 고장이 알려지지 않은 고장이라고 하고 알려지지 않은 고장의 문턱값  $\delta_{af} = 1.7$ 로 가정한다면, 시간이 696이후로 1.7 이상의 평균 편차 값이 지속되므로 이때 분류기의 저장공간에서는 어느 일정시간이 지난 후에도 계속 편차가 1.7을 넘어 감을 인지하고 그때 들어온 패턴  $y$ 를 새로운 고장패턴으로 저장하게 된다. 이로 인해서 알려지지 않은 고장 패턴은 저장된 고장패턴으로 바뀌게 된다.

### 3.6 고장 검출 시물레이션




그림 5. 고장 검출 예

그림 5는 저장된 고장 패턴을 4개라고 가정하고  $D$ 의 값을 각각의 저장된 패턴에 대해서 나타내었다. 여기에서 발생한 고장은 앞에서 언급한 적이 있는 첫 번째 유형의 고장(고장 1)이며, 고장이 처음 나타난 시간은 600에서이다. 위의 그래프에서 첫 번째 변수는 바로 위의 그래프에서 보았던  $F_j$ 이다. 다른 변수들도 위의 그림에서와 같은 형태로 나타날 것이다. 그 아래 4개의

그래프는 각각 저장된 고장에 대한  $D$ 를 나타낸다. 작은 값일수록 저장된 패턴에 가까워 고장이 발생했다는 뜻이므로 680 근처에서 첫 번째 유형의 고장이 발생했음을 첫 번째 고장에 대한  $D$ 의 그래프를 통해서 알 수 있다. 어느 정도의 허용되는 범위 내에서의 노이즈는 고장진단에 크게 영향을 미치지 않는다. 또 그림 5의 가장 아래에 있는 그래프는 편차를 나타낸다. 고장이 나타나면서 편차가 커짐을 눈으로 확인할 수 있다.

## 4. 결 론

수학적 모델을 사용하지 않는 고장진단 방법은 비교적 수학적 모델링이 어려운 곳에서 실제 그 곳에서 발생되는 데이터를 중심으로 고장 진단을 행한다.

기존의 뉴럴 네트워크로 패턴을 분류하는 방법은 새로운 패턴이 추가될 때마다 새로운 패턴을 다시 학습해야 하고, 이에 대한 수렴성도 보장되지 않을 뿐 아니라 실제로 알려지지 않은 고장이 밝혀졌다 하더라도 전체 네트워크를 새로 학습시켜야 하는 단점이 있다. 특히 복잡한 패턴에 대해서는 수렴성이 더욱 보장되지 않는다.

본 논문에서 제안된 고장 진단 방법은 현재 시점을 중심으로 일정 길이의 데이터를 일정한 규칙에 의하여 학습시킨 뉴럴 네트워크에 통과시킴으로써 패턴의 모양을 수치로 나타내었다. 그리고 그 수치 자체를 패턴으로 저장하고 입력 패턴도 같은 형식의 수치로 비교함으로써 저장된 고장패턴과 새로운 입력패턴과의 유사성을 찾게 된다.

여기에 각 데이터를 표준화시키고 평균적인 편차의 개념을 적용함으로써 알려지지 않은 고장에 대한 검출을 가능하게 하였다.

또 본 논문에서는 알려지지 않은 고장의 검출 뿐 아니라, 하나의 패턴을 추가하는데 있어서도 용이한 면이 있다. 또한 복잡한 패턴에 대해서도 단순히 각 성분들 간의 거리를 고려하여 유사성을 알아내기 때문에 유사한 패턴을 찾는데 있어서는 매우 유리하다.

### (참 고 문 헌)

- [1] Yunesuke Maki and Kenneth A Laparo, "A Neural-Network Approach to Fault Detection and Diagnosis in Industrial Process", IEEE Trans. on Control Systems, Vol. 5, No 6, 1997.
- [2] Jacek M. Jurada, "Introduction to Artificial Neural Systems", PWS, 1992
- [3] Luyben, "Process, Modeling, Simulation, and Control for Chemical Engineers" 2nd Edition, McGraw-Hill, 1989
- [4] 이기상 "고장검출진단 및 고장허용제어의 개념과 동향", 전기학회지, Vol. 48, No. 4, 1999.
- [5] Mohamed El Hachemi Benbouzid, "Induction Motors' Faults Detection and Localization Using Stator Current Advanced Signal Processing Technique" IEEE trans. on Power Electronics, Vol 14, No. 1, 1999
- [6] Kumpati S. Narendra, Kannan Parthasarathy "Identification and Control of Dynamical systems Using Neural Networks", IEEE Trans. on Neural networks, Vol. 1, No. 1, 1990.
- [7] Ray. "Advanced Process Control", Mc-Graw-Hill, 1981
- [8] Richard Dorr, Frederic Kratz, "Detection, Isolation, and Identification of Sensor Faults in Nuclear Power Plants", IEEE trans. on Control System Technology, Vol. 5, No. 1, 1997