

인공 신경망을 이용한 공정고장 진단방법

이상규 박선원
한국과학기술원 화학공학과

A Fault Diagnosis Method Using an Artificial Neural Network

Sang-Gyu Lee Sun-Won Park
Dept. of Chemical Engineering
K A I S T

ABSTRACT

This paper describes a neural-network-based methodology for providing a potential solution in the area of process fault diagnosis. The existing neural networks for fault diagnosis learn fault mode by using pairs of single-symptom-single-cause only. But in real plants, the effect of a fault propagates continuously from its origin; different sensor values reflect this. In this paper, we suggest a new method which can handle the effect of symptom propagation. The proposed method can find the exact origin of the fault of which the symptom is propagated continuously with time.

1. 서론

최근 화학공정의 고장진단에 있어서 인공 신경망의 사용이 활발하게 진행되고 있다. 현재까지의 주요 연구로는 Himmelblau 등[1,5]의 오류역전파 학습 및 2단 신경망의 제안과 Venkatasubramanian 등[4]의 다중고장 분석과 그리고 Ungar 등[3]의 입력 센서값에 관한 연구 등이 있다.

인공 신경망을 이용한 공정 고장진단에 있어서의 기존 학습방법에서는 증상과 원인의 한 쌍으로 학습하였으나 실제의 화학공정은 고장발생 시점으로부터 센서값들이 시간에 따라 연속적으로 변화한다. 본 연구에서는 이러한 고장 증상의 시간에 따른 전파효과를 고려한 새로운 학습 방법을 제안하고자 하며 이러한 방법을 사용함으로써 공정에 이상이 발생되었을 때 연속적으로 전파되는 증상을 인식 하여 정확한 원인을 찾아줄 수 있음을 보여주는데 있다.

인공 신경망을 이용한 고장진단 방법은 기존의 규칙 기반 방법에 비하여 여러 장점이 있다.

- 1) 센서값을 사용할때 전처리가 복잡하지 않다.
 - 2) 공정 분석의 실수에 대하여 강건성이 높다.
 - 3) 센서값의 Noise에 대하여 강건성이 높다.
- 이와 같은 장점을 이용하여 신경망 안에 연속적인 증상을 저장하여 On-Line 으로 공정 고장진단을 한다.

2. 오류역전파 학습

지금까지의 고장진단에 관한 대부분의 연구는 심층지식(deep knowledge)을 이용하여 표충지식(shallow knowledge)을 얻는 방법이다. 그러나 심층지식의 경우 Model에 대한 불확실성, 그리고 표충지식의 경우에는 표현에 있어서의 한계점이 문제되어 왔다. 이에 페턴처리나 경험에 입각하는 침감적 판단에 잘 어울리는 인공신경망을 고장진단에 사용하여 한다.

이러한 인공신경망으로 구성된 페턴인식 시스템은 기존의 페턴매치에 의한 방법에 비하여 기존의 훈련되지 않은 새로운 형태의 입력페턴에 대해서도 가장 유사한 형태의 페턴을 찾을 수 있으며 병렬성을 이용한다면 신속한 처리가 가능하며 입력 페턴이 미리 훈련된 페턴에 비해 약간 손상된 형태라도 잘 인식해 낼 수 있으며, 또한 간단한 구조로 인하여 특별한 소프트웨어가 필요치 않다는 장점이 있다.

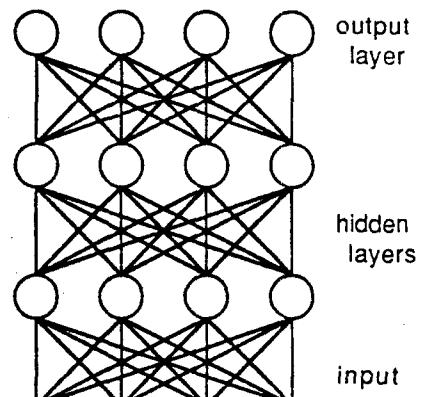


그림 1. 다층 인식자 모델

신경망의 구조는 그림 1과 같은 다층인식자로 학습방법은 현재 많이 사용되는 최대 경사법 (Steepest Descent Method)의 한 종류인 오류역전파 학습 (Error Backpropagation)을 사용하였다.

신경망의 연산방법은 입력된 정보가 네트워크의 결합 가중치에 따라서 각노드로 전파되어 변환 함수를 계산한 후에 다음 혹은 외부로 출력하게 된다. 각노드의 변환 함수는 일반적으로 사용하는 식(2)인 Sigmoid Transfer Function을 이용하였다.

$$Sum_j = \sum_i W_{ji} x_i \quad (1)$$

$$S(Sum_j) = \frac{1}{1 + \exp(-b * Sum_j)} \quad (2)$$

학습은 출력된 패턴과 목적으로 하는 패턴형태의 오차를 연결 가중치의 수정에 이용하게 된다. 즉 새로운 연결 가중치 $W(t+1)$ 은

$$W_{ji}(t+1) = W_{ji}(t) + \Delta W_{ji}(t) - \alpha \Delta W_{ji}(t-1) \quad (3)$$

$$\Delta W_{ji}(t) = \eta \delta_j x_i \quad (4)$$

여기서 η 는 학습속도상수이며 x_i 는 가중치 함수에 할당된 입력값이다. α 는 전가중치의 변화값에 0에서 1 사이의 값으로 더욱빠르게 목표값에 도달하게 한다. 출력값과 입력의 오차보정은 δ_j 에 의하여 계산된다.

$$\text{출력층: } \delta_j = x_j (1 - x_j) (t_{pj} - x_j) \quad (5)$$

$$\text{중간층: } \delta_j = x_j (1 - x_j) \sum_k \delta_k w_{kj} \quad (6)$$

x_j 는 출력값이며 t_{pj} 는 원하는 출력값이다. 계산은 출력층에서부터 초기 입력층까지 오차가 역전파되는 형태이므로 오류역전파 학습이라 한다.

3. 본 론

화학 공정의 고장진단에 있어서 기존의 인공신경망을 이용한 고장진단은 고장이 발생된 후에 전파되는 증상의 중간단계는 생략하고 단지 한 특정 시점에서의 공정상태만으로 분석하였으나, 본 논문에서는 증상이 전파되는 중간 과정 역시 분석 하려 하는데 있다. 즉 그림 2의 중류탑의 FEED 조성이 갑자기 변하는 경우에 있어서 단지 ⑤만을 학습하는 것이 아니라 FEED의 이상이 시간에 따라 전파될 때 나타나는 특정한 센서값들인 ①부터 ⑤까지의 증상을 모두 학습시키는 것이다.

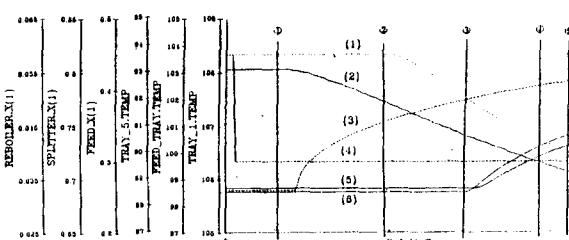


그림 2. 중류탑의 Feed 조성 변화에 따른 영향

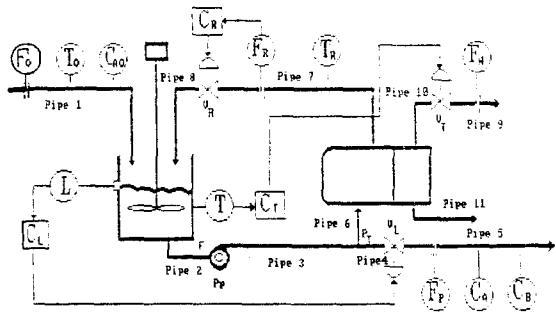


그림 3. Recycle이 있는 반응기

본 연구에 사용된 자료는 그림 3과 같이 Recycle이 있는 반응기를 대상으로 Kramer의 ESDG (Extended Sigend Digraph)를 응용하여 특징적인 증상전파를 5단계로 하여 얻었으며 학습은 2000번을 하였다. 학습에 사용된 자료는 28개의 센서값을 이용하여 26개의 고장원인을 찾아내는 것이다. 한개의 고장원인에 대하여 5개의 증상을 저장하므로 몇개의 중복된 증상을 포함하여 $26 * 5 = 130$ 개의 패턴을 저장하게 된다.

결과그림에서 "— Upper bound —"과 "— Lower bound —"는 그아래의 "Ls C1 ..."의 센서로부터 입력되는 값을 의미하며 "1"이면 해당 센서값의 bound가 현 상태의 증상을 나타낸다. 또한 "1st / 2nd / 3rd"는 신경망의 결과로서 구해진 고장 원인의 확신도의 순서이다. 이를 향의 값은 고장원인의 상대적 확신도의 크기를 나타낸다. 이로부터 잘 학습된 신경회로망은 가능한 이상 원인들의 상대적 확신도를 정량적으로 보여줄 수 있다. 사용자가 각 규칙에 Certainty Factor를 구체적으로 지정해 주어야 하는 규칙기반 방법에서의 한계성을 극복할 수 있다. 또한 이러한 상대적 확신도를 이용하여 그 수치에 따라 다중고장과 Noise여부 등을 쉽게 판단할 수 있다.

1) 그림 5와 그림 6는 시간에 따른 고장전파의 분석으로 열교환기의 외부로부터 오는 냉각수의 온도가 올라가는 경우와 Tank Leaking의 예를 보았다. Tank Leaking 경우에 있어서 초기 고장 분석 결과의 Resolution이 낮은 원인은 이와 비슷한 증상의 고장원인이 매우 많이 존재함을 의미하며 시간이 지날수록 고장원인의 Identity가 높아져 Resolution이 증가함을 볼 수 있다.

2) 그림 7은 다중고장의 한 예로 고장원인의 3 후보가 모두 높은 수치를 가지고 있다.

3) 그림 8은 제어기의 고장에 온도에서 Ts에서의 Noise를 가상하여 시험한 결과이다. 결과로부터 Noise에 대한 Resolution이 우수함을 알 수 있다.

4) 그림 9은 입력값이 0과 1이 아닌 그사이의 값이 입력되는 경우의 모사 결과로서 신경망에의한 고장진단에서는 입력센서값에 대한 복잡한 전처리가 필요 없음을 알 수 있다.

위에서 보여준 신경망 방법은 규칙 기반 방법이 갖는 단점을 보완해 준다. 따라서 보다 완벽한 고장진단 시스템은 두가

지 방법을 복합적으로 사용한 Hybride 형태의 시스템이 요구된다.

4. 결 론

화학공정의 인공신경망을 이용한 고장분석은 앞의 결과에서와 같이 시간에 따라 증상이 전파하는 경우에도 적용이 가능함을 알아 냈다.

본 논문에서는 Recycleo에 있는 반응기 모델을 이용하여 26개의 고장원인을 28개의 센서값을 이용하여 분석하도록 하였으며 고장원인으로부터 시간에 따라 전파되는 증상을 5단계로 구별하여 학습시켜서 고장이 전파되어 증상이 시간에 따라 변하여도 고장분석이 가능함을 보았으며 그밖에 센서값의 처리방법과 다중고장과 Noise에 대하여 강건성이 뛰어남을 알 수 있었다.

이러한 인공신경망의 특성을 잘 이용하기 위하여 주어진 신경망내에 시간 전파에 따른 많은 패턴을 저장할 수 있는 학습방법의 연구가 필요하며 공정 특성에 따라 규칙 기반 방법과의 병합으로 더 좋은 성능을 얻을 수 있을 것으로 기대된다.

참 고 문 헌

- [1] Hoskins, J., C. and D. M. Himmelblau, "Artificial Neural Network Model of Knowledge Representation in Chemical Engineering," *Comput. Chem. Engng.*, 12, 9/10, 881 (1988).
- [2] Kramer, M., A. and B. L. Palowitch, "A Rule-Based Approach to Fault Diagnosis Using the Signed Directed Graph," *AIChE J.*, 33, 1, 130 (1987).
- [3] Ungar, L., H. and B. A. Powell and S. N. Kamens, "Adaptive Networks for Fault Diagnosis and Process Control," *Comput. Chem. Engng.*, 14, 4/5, 561 (1990).
- [4] Venkatasubramanian, V. and King Chan, "A Neural Network Methodology for Process Fault Diagnosis," *AIChE J.*, 35, 12, 1993 (1989).
- [5] Watanabe, K., I. Matsuura, M. Abe, M. Kubota and D. M. Himmelblau, "Incipient Fault Diagnosis of Chemical Process via Artificial Neural Network," *AIChE J.*, 35, 11, 1803 (1989).

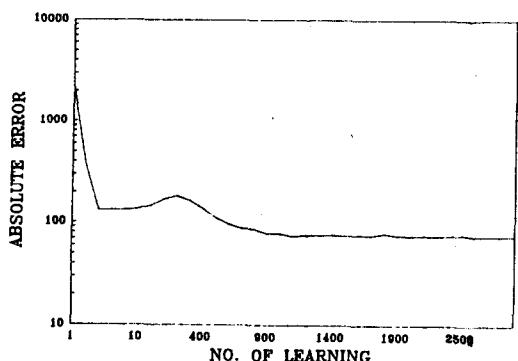


그림 4. 3 Layer Perceptron의 학습에 따른 오차 감소특성

Fault : 23 Twt: Inlet Temp, HE High

卷之三

Failure : 18 L = : Tank leakage

ט' ט' ט' ט'

- 1 -

Case 1

	upper bound (+)		lower bound (-)	
1st	C1	F1	F1	Cr
2nd	F1	Cr	Tr	To
3rd	Tr	To	Ct	Fm
4th	Ct	Fm	Co	Fo
5th	Co	Fo	Ob	Le
6th	Ob	Le	Fp	Fp
7th	Fp	Fp	Fr	Fr
8th	Fr	Fr	Cr	Tr
9th	Cr	Tr	To	Ct
10th	To	Ct	Fm	Co
11th	Ct	Fm	Co	Fo
12th	Fm	Co	Fo	Ob
13th	Co	Fo	Ob	Le
14th	Ob	Le	Fp	Fp
15th	Fp	Fp	Fr	Fr
16th	Fr	Fr	Cr	Tr
17th	Cr	Tr	To	Ct
18th	To	Ct	Fm	Co
19th	Ct	Fm	Co	Fo
20th	Fm	Co	Fo	Ob
21st	Co	Fo	Ob	Le
22nd	Ob	Le	Fp	Fp
23rd	Fp	Fp	Fr	Fr
24th	Fr	Fr	Cr	Tr
25th	Cr	Tr	To	Ct
26th	To	Ct	Fm	Co
27th	Ct	Fm	Co	Fo
28th	Fm	Co	Fo	Ob
29th	Co	Fo	Ob	Le
30th	Ob	Le	Fp	Fp
31st	Fp	Fp	Fr	Fr
32nd	Fr	Fr	Cr	Tr
33rd	Cr	Tr	To	Ct
34th	To	Ct	Fm	Co
35th	Ct	Fm	Co	Fo
36th	Fm	Co	Fo	Ob
37th	Co	Fo	Ob	Le
38th	Ob	Le	Fp	Fp
39th	Fp	Fp	Fr	Fr
40th	Fr	Fr	Cr	Tr
41st	Cr	Tr	To	Ct
42nd	To	Ct	Fm	Co
43rd	Ct	Fm	Co	Fo
44th	Fm	Co	Fo	Ob
45th	Co	Fo	Ob	Le
46th	Ob	Le	Fp	Fp
47th	Fp	Fp	Fr	Fr
48th	Fr	Fr	Cr	Tr
49th	Cr	Tr	To	Ct
50th	To	Ct	Fm	Co
51st	Ct	Fm	Co	Fo
52nd	Fm	Co	Fo	Ob
53rd	Co	Fo	Ob	Le
54th	Ob	Le	Fp	Fp
55th	Fp	Fp	Fr	Fr
56th	Fr	Fr	Cr	Tr
57th	Cr	Tr	To	Ct
58th	To	Ct	Fm	Co
59th	Ct	Fm	Co	Fo
60th	Fm	Co	Fo	Ob
61st	Co	Fo	Ob	Le
62nd	Ob	Le	Fp	Fp
63rd	Fp	Fp	Fr	Fr
64th	Fr	Fr	Cr	Tr
65th	Cr	Tr	To	Ct
66th	To	Ct	Fm	Co
67th	Ct	Fm	Co	Fo
68th	Fm	Co	Fo	Ob
69th	Co	Fo	Ob	Le
70th	Ob	Le	Fp	Fp
71st	Fp	Fp	Fr	Fr
72nd	Fr	Fr	Cr	Tr
73rd	Cr	Tr	To	Ct
74th	To	Ct	Fm	Co
75th	Ct	Fm	Co	Fo
76th	Fm	Co	Fo	Ob
77th	Co	Fo	Ob	Le
78th	Ob	Le	Fp	Fp
79th	Fp	Fp	Fr	Fr
80th	Fr	Fr	Cr	Tr
81st	Cr	Tr	To	Ct
82nd	To	Ct	Fm	Co
83rd	Ct	Fm	Co	Fo
84th	Fm	Co	Fo	Ob
85th	Co	Fo	Ob	Le
86th	Ob	Le	Fp	Fp
87th	Fp	Fp	Fr	Fr
88th	Fr	Fr	Cr	Tr
89th	Cr	Tr	To	Ct
90th	To	Ct	Fm	Co
91st	Ct	Fm	Co	Fo
92nd	Fm	Co	Fo	Ob
93rd	Co	Fo	Ob	Le
94th	Ob	Le	Fp	Fp
95th	Fp	Fp	Fr	Fr
96th	Fr	Fr	Cr	Tr
97th	Cr	Tr	To	Ct
98th	To	Ct	Fm	Co
99th	Ct	Fm	Co	Fo
100th	Fm	Co	Fo	Ob

תְּבִ�ָה וְתַּבְּרֵנָה בְּעֵבֶד נָשָׁא בְּעֵבֶד נָשָׁא

Fault 18 b - Truck Leaking

卷之三

Case 1

```

possible fault origin : 1st      9  Pp+ : Ppb0 fail + : 0.04
                           2nd      1  L- : Level Sena. fail1 - : 0.01
                           3rd     17  Vr- : Valve R fail1 - : 0.01
upper bound (s) : Le C1 Fp Fr Cr Tr s1 Fw Co Ca Fo CsLe C1 Fp Fr Cr Tr s1 Fw Co Ca Fo Cs
lower bound (-) : Le C1 Fp Fr Cr Tr s1 Fw Co Ca Fo CsLe C1 Fp Fr Cr Tr s1 Fw Co Ca Fo Cs

```

Case	5	upper bound (+)	lower bound (-)
Ls	C1 F1 Fr Cr Tr To Ts Ct Fw Co Cb1 ls C1 F1 Fr Cr Tr To Ts Ct Fw Co Cb		
possible fault origin :	1st 18 L- : Tank leaking		: 0.91
	2nd 17 Vr- : Valve R fail -		: 0.11

area = πr^2 = $\pi (0.05)^2$ = 0.00785 m^2

그림 7. 대중고장에 대한 신경망 봉투법의 적용 결과

Fault	3 C1+	Lever Cont.	fault	
Time Delayed Fault Patterns (Scenario)				
	upper bound (+)		upper bound (-)	
	La Cl Fp Fr Cr Tr To Ts Ct Fw		La Cl Fp Fr Cr Tr To Ts Ct Fw	
	0 1 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 0 0 0 0	
possible fault origin : 1st 3 C1+ :				
	2nd 19 Ts* :		2nd 19 Ts* :	
	3rd 1 Le* :		3rd 19 Ts* :	
	upper bound (+)		upper bound (+)	
	La Cl Fp Fr Cr Tr To Ts Ct Fw		La Cl Fp Fr Cr Tr To Ts Ct Fw	
	0 1 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 0 0 0 0	
possible fault origin : 1st 3 C1+ :				
	2nd 14 Cr* :		2nd 14 Cr* :	
	3rd 19 Ts* :		3rd 19 Ts* :	

No. 87222222 고장이 다른 시장단위인 경계를 넘어서

7부 9. 정 속적 이 뿐만 아니라 정체적인 정체성을 갖자