

Time-Delay Neural Network를 이용한 증류탑의 on-line 고장 진단

◦이 상규, 박 선원
한국과학기술원 화학공학과

On-line Fault Diagnosis of a Distillation Column Using Time-Delay Neural Network

◦Sanggyu Lee and Sunwon Park
Department of Chemical Engineering, KAIST

ABSTRACT Modern chemical processes are becoming more complicated. The sophisticated chemical processes have needed the fault diagnosis expert systems that can detect and diagnose the faults of some processes and give an advice to the operator in the event of process faults. We present the Time-Delay Neural Network (TDNN) approach for on-line fault diagnosis. The on-line fault diagnosis system finds the exact origin of the fault of which the symptom is propagated continuously with time. The proposed method has been applied to a pilot distillation column to show the merits and applicability of the TDNN.

1. 서론

고장 진단이란 공정의 운전 상태를 감시하고 공정 운전자의 판단을 도와주는 장치이다. 이러한 고장 진단 장치는 가동중인 화학 공정의 정보를 on-line으로 받아들여 분석하고 그 원인을 찾아내는 것으로 최근 급속도로 발달하는 컴퓨터 기술과 전문가 시스템 기술을 이용함으로써 대형 사고를 미연에 방지하고 미리 계획하지 않은 조업 중단을 최소화하여 조업의 안정성과 이윤을 높일 수 있다.

화학 공정에 이상이 발생되면 그 현상은 공정 센서값이나 공정 변수들의 값이 정상 상태에서 벗어나거나 비정상적인 경향으로 보이게 된다. 이러한 이상을 감지하고 진단하기 위해서는 공정 상태의 정보를 실시간으로 분석해야 한다. 이제까지 이러한 공정의 고장 인식 및 진단의 방법으로 여러가지 방법이 제시되어 왔고 실시되어 왔다. 이러한 고장 진단 방법들의 분류는 knowledge based methods, qualitative reasoning, signed directed graphs, process modeling: parameter estimation, cluster analysis: statical analysis, artificial neural networks로 크게 6 가지로 나누어질 수 있다[2].

그러나 실제적인 적용에 있어서는 공정의 특성 및 적용 크기에 따라서 방법들의 일부분만을 이용하거나 병합, 또는 병행으로 사용하기 때문에 방법들을 명확히 구분하는 데는 많은 어려움이 따른다.

고장 진단 방법의 대부분이던 지식 기반 방법(knowledge based methods)은 전문가 시스템의 일반적인 형태로 표상적 내용을 규칙(rule)의 형태로 표현한 것이다. 이 방법은 규칙의 첨가 및 삭제가 쉬우며, 또한 결과에 대한 설명 기능이 자동적으로 해결된다. 그러나 진단 시스템의 개발 및 보수가 어렵고 예상하지 못한 고장 진단에 대한 진단 결과는 보장할 수 없으며 정량적 센서 자료를 정성적으로 표현할 때 많은 양의 정보를 유실하게 된다는 단점을 갖고 있다. 또한 정량 모델 방법(process modeling: parameter estimation)은 수학적 모델을 기반으로 현 공정 상태를 인식하는 방법으로 정확한 공정 모델이 표현되어 있다면 대상 공정의 상태를 정확히 파악할 수 있으나, 공정의 수학적 모델을 만들기가 어렵고 계산 시간이 많이 요구된다는 것이 문제로 되어왔다.

기존의 방법에 따른 이러한 단점을 보완하기 위하여 복잡한 공정에 대한 빠른 추론과 센서 정보를 유실없이 사용할 수 있는 인공 신경망(artificial neural network)에 대한 연구가 활발히 진행되고 있다. 이 분야의 연구로는 인공 신경망의 적용성을 제시한 Himmelblau 팀[3]과 다중 고장각 학습 parameter 비교를 한 Venkatasubramanian 팀[5,6]등의 연구가 있다.

화학 공정의 고장 진단에 많이 사용되어진 기본적인 인공 신경망(multi-layer perceptron)의 형태로는 시간에 따른 공정의 변화를 인식하고 분석하는 능력이 없다는 것이 커다란 단점으로 제시되어 왔었다. 본 연구에서는 Waibel 등[7]이 음성인식에 사용한 TDNN(Time-Delay Neural Network)를 고장 진단에 적용하여 고장발생 후 시간에 따른 공정의 증상을 학습 및 진단할 수 있도록 하였

다. 고장 발생후에 변화하는 증상을 학습시키기 위한 학습용 입력 자료는 pilot scale 중류탑을 이용하였으며 학습된 인공 신경망의 성능 비교 역시 중류탑으로 부터 얻은 결과를 바탕으로 분석하였다.

2. Time-Delay Neural Network

기본적인 인공 신경망의 형태로는 시간에 따른 공정의 변화를 인식하고 분석하는 능력이 없다는 것이 커다란 단점으로 제시되어 왔었다. 본 연구에서는 TDNN를 고장 진단에 적용하여 고장발생 후 시간에 따른 공정의 증상을 학습 및 진단할 수 있도록 하였다.




Fig.1 다중 인식자 노드

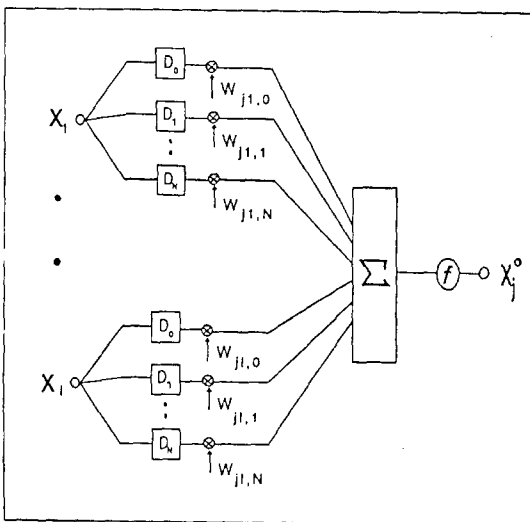


Fig.2 TDNN 노드

일반적인 인공 신경망의 노드 형태는 Fig.1 과 같다. 그림에서 보듯이 일반적인 인공 신경망의 노드 기능이란 입력값들을 각각의 가중치와 곱해지고 합한 다음 이 값이 다시 비선형 함수를 통과한 후에 출력하는 것이다. 그러나, TDNN의 노드는 Fig.2 [7]에서 처럼 각각의 입력값을 입력된 그때의 값 뿐만 아니라 현 시점에서 부터 지나간 몇개의 입력값 역시 사용하게 된다. 이들 입력값들은 시간 지연 함수인 D_n 으로 표현되는데, 현재의 입력인 D_0 와 지나간 입력인 $D_1 \sim D_N$ 으로 이루어진다. 그림에서 1 개의 입력값들은 각각의 지연 함수와 연결된 가중치에 곱해진 후에 합하여지는 것이다. 즉, TDNN의 노드 출력값 x_j 는 아래와 같다.

$$x_j^o = f\left(\sum_{i=1}^I \sum_{n=0}^N W_{ji,n} D_n(x_i)\right) \quad (1)$$

$$f(z) = (1 + \exp(-z))^{-1} \quad (2)$$

여기서 $D_n(x_i)$ 는 i 번째 입력값의 n 번째 시간 지연 값을 나타내며 $W_{ji,n}$ 은 j 번째 출력 노드에 대한 $D_n(x_i)$ 의 연결 가중치이다. 이러한 형태로 인하여 각각의 TDNN 노드는 입력값의 N 개 시간 지연 영역 만큼에 대한 비교 및 관련성을 유추해낼 수 있다. 본 연구에서는 고장 진단을 위한 인공 신경망의 형태를 노드층들이 3 층인 형태이다. 이러한 TDNN의 입력층에는 화학 공정의 측정된 각각의 정보가 시간의 흐름에 따라 한 칸씩 이동되어 입력된다. 이 입력층은 시간에 따라 이동하는 프레임 (frame) 들로 이루어진 중간층으로 연결되고 계속해서 출력층까지 각각의 TDNN 노드로 인공 신경망을 구성한다.

TDNN의 기본적 형태는 다중 인식자 인공 신경망과 유사하므로 다중 인식자의 학습 방법인 오류 역전파 학습을 약간 변형시키면 적용할 수 있다.

3. 고장 진단을 위한 센서 정보 처리 구조

본 연구에서는 Fig.3 과 같은 형태의 고장 진단 시스템 구조를 제안한다. 그림에서 화학 공정으로 부터 얻어진 정보들은 인공 신경망에 전달되기 전에 공정 자료 preprocessor를 통과하게 된다. 공정 자료 preprocessor의 기능은 화학 공정으로부터 얻어진 정보를 그 정보에 해당되는 정상 상태와의 차를 구하고 그차를 Sigmoid 함수에 적용하여 출력한다. 이러한 preprocessor를 사용함으로써 공정의 정상 상태가 변화했을 때에도 인공 신경망의 분석이 가능하며 또한 Sigmoid 함수의 사용으로 인공 신경망의 분석 성능을 높일 수 있다.

총 6 개이며 on-line으로 얻을 수 있는 증류탑의 정보는 센서와 제어 신호로 합이 총 19 개이고 증류탑의 제어용 software는 THE FIX™ (Intellution, Inc. Ver.2.3)로 현재 IBM PC/AT 386™에서 동작되고 있다.

인공 신경망에 저장하려는 대상 증류탑의 자료는 실험을 통하여 얻었다. 진단하려는 고장의 종류는 Table 1 에 나타낸 총 22 개로 실험한 후에 각각의 고장에 대하여 매 30 초 간격의 10 분 데이터를 이용하였다. 즉 각 고장에 대한 각 센서의 시간에 따른 20 개의 데이터를 사용하여 인공 신경망을 학습하는 것이다.

본 연구에 사용된 TDNN의 구조는 Fig.7 의 형태로 입력층의 입력 센서 자료 (N_S) 가 19 개이고 시간 지연 갯수 (N) 은 3 개이다. 그리고 중간층에서는 중간 프레임 (N_{HF}) 이 3 개이고 각 중간 프레임에 있는 중간 노드 갯수 (N_{HN}) 는 15 개이며, 출력층의 노드 갯수는 고장 진단 갯수인 22 개이다. 인공 신경망은 학습 속도 상수를 0.9 으로, 그리고 momentum 상수를 0.6 으로 하여 학습시켰다. 그 결과로 10번의 학습에 5% 이내의 r.m.s. 오차를 얻었다.

Number	Fault Name
1	Feed Flow Sensor Fails Low
2	Feed Flow Sensor Fails High
3	Feed Heating Power Low
4	Feed Heating Power High
5	Feed Temperature Sensor Fails Low
6	Feed Temperature Sensor Fails High
7	Feed Flow Valve Fails Closed
8	Feed Flow Valve Fails Open
9	Reboiler Heating Power Low
10	Reboiler Heating Power High
11	Bottom Temperature Sensor Fails Low
12	Bottom Temperature Sensor Fails High
13	Reflux Flow Sensor Fails Low
14	Reflux Flow Sensor Fails High
15	Reflux Flow Valve Fails Closed
16	Reflux Flow Valve Fails Open
17	Drum Level Sensor Fails Low
18	Drum Level Sensor Fails High
19	Top Temperature Sensor Fails Low
20	Top Temperature Sensor Fails High
21	Top Pump Fails Stop
22	Air Supplier Fails Low

Table 1 실험에 사용된 증류탑의 고장 진단 대상

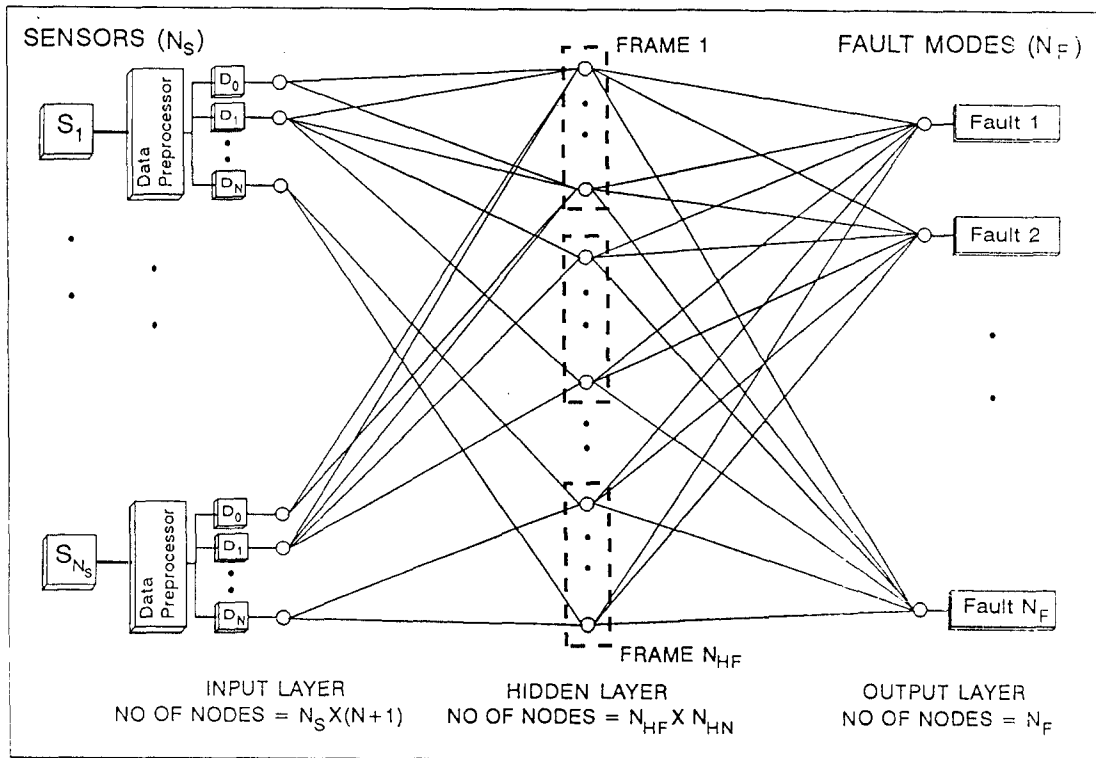


Fig.7 증류탑의 고장 진단을 위한 TDNN의 구조




Fig. 3 제안된 고장 진단 장치의 정보 흐름도

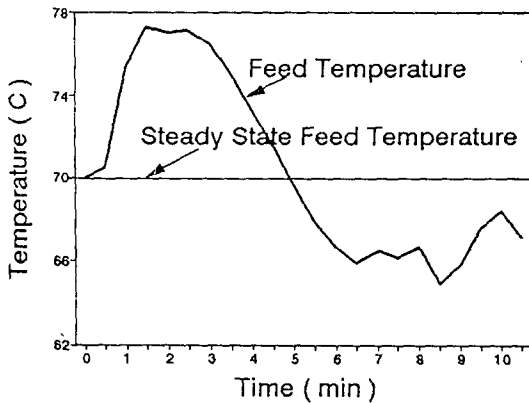


Fig. 4 Feed의 유량이 떨어질 경우의 feed 온도의 변화




Fig. 5 Feed 온도 변화에 따른 data preprocessor의 출력

Fig. 4는 feed의 유량 흐름이 갑자기 떨어졌을 때 있어서 feed 온도 센서로부터 얻은 공정 상태 값이다. 이런 값이 공정 자료 preprocessor를 통과한 후의 값을 Fig. 5에 나타내었다. 공정 자료 preprocessor의 전달 함수를 표현하며 아래와 같다.

$$f_s(U) = (1 + \exp(-bU))^{-1} \quad (3)$$

$$U = |U_M - U_{SS}| - U_T \quad (4)$$

여기서 b 는 정상 상태인 $U = 0$ 에서의 전달 함수 기울기이고, U_M 은 측정된 공정 정보 값이며, U_{SS} 는 공정 정보의 정상 상태 값을 나타내고, U_T 는 사용된 Sigmoid 함수의 threshold 값이다. 인공 신경망 노드의 입력값인 X 는 최종적으로 아래의 함수를 통과한 후에 적용된다.

$$\begin{cases} X = f_s(U) & \text{for } U_M > U_{SS} \\ X = -f_s(U) & \text{for } U_M < U_{SS} \end{cases} \quad (5)$$

4. 증류탑에의 TDNN 적용

제어 및 고장 진단에 사용될 pilot scale 증류탑은 충전 증류탑으로, 탑은 4 inch pipe로 되어 있다. 증류탑의 충전 물질은 raschig ring이며 탑의 높이는 285 cm이다. Reboiler와 feed 부분의 heating은 전기를 이용하였고 condenser는 total condensing으로 운전하고 있다. Fig. 6은 설치된 증류탑의 흐름 및 장치도로 이 증류탑 장치를 이용하여 물과 methanol의 이성분계의 증류 실험을 수행하여 증류탑의 제어 자료 및 고장 진단 자료를 얻었다.

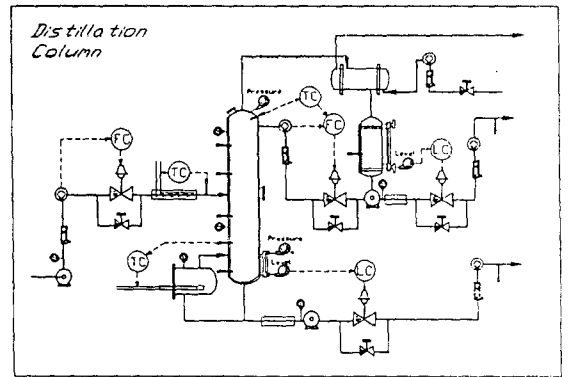


Fig. 6 실험에 사용된 pilot scale 증류탑

증류탑의 각 측정 장치를 알아보면, 온도 센서로 10개의 RTD(resistance thermo-dectector)를 이용하여 탑의 각 부분 온도와 feed의 온도 등을 측정하였고, DP(differential pressure)를 이용하여 액위의 높이와 압력을 측정하였다. 그리고 turbine meter로 각 유량을 측정하였다. Feed의 유량은 520 cc/min이며 성분은 물과 methanol로 조성이 부피비로 methanol 0.3이며 제어계는

단일 고장 진단 결과

중류탑의 정상 상태 탑저 온도 센서는 90°C 를 가리키고 있으며 탑저 reboiler에 의하여 90°C 의 설정치를 유지하게 되어있다. 이러한 탑저 온도 센서가 갑자기 고장이 나서 90°C 아래로 떨어지는 것이 인공 신경망 (TDNN)으로 분석하려는 고장의 형태로 학습용 데이터는 탑저 온도를 80°C 로 떨어뜨린 후에 그 증상들을 학습시켰다. 이러한 인공 신경망의 진단 성능 test는 탑저 온도 센서가 85°C 로 떨어지는 형태로 그 결과를 Fig.8 에 나타내었듯이 좋은 진단 결과가 나타났다.

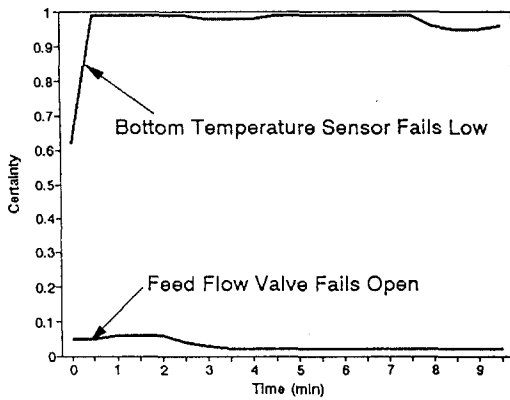


Fig.8 TDNN의 단일 고장 진단

다중 고장 진단 결과

중류탑의 고장 진단 학습의 자료는 22개 각각의 단일 고장들로서 한 개의 인공 신경망을 학습하였다. 중류탑에서 다중 고장을 발생시킨 후 단일 고장들로서 학습된 인공 신경망으로 고장 분석을 하였다. Fig.9 는 'Drum Level Sensor Fails Low' 와 'Feed Heating Power High'의 다중 고장에 대한 결과이다.




Fig.9 TDNN의 다중 고장 진단

5. 결론

화학 공정의 고장 진단 방법으로 고장 발생후 시간에 따른 공정의 변화를 인식하고 분석하기 위하여 TDNN (Time-Delay Neural Network)를 적용하였다. 대상 공정은 pilot scale 중류탑이며 총 22개의 고장에 대하여 진단이 가능하도록 하였다. 실험을 통한 결과로 제안된 방법은 단일 고장 진단과 다중 고장 진단에서 좋은 진단 성능을 보였다.

참고문헌

1. 이 상규 그리고 박 선원, "인공 신경망을 이용한 중류탑의 고장 진단," Vol.29, No.5, October, pp545-556, 1991.
2. Himmelblau, D. M., "USE OF ARTIFICIAL NEURAL NETWORKS TO MONITOR FAULTS AND FOR TROUBLESHOOTING IN THE PROCESS INDUSTRIES," IFAC Symposium, Newark, Delaware, April, pp144-149, 1992.
3. Hoskins, J. C. and D. M. Himmelblau, "Artificial Neural Network Models of Knowledge Representation in Chemical Engineering," Comp. Chem. Engng., Vol.12, No.9/10, pp881-890, 1988.

4. Lee, Sang Gyu and Sun Won Park, "ON-LINE FAULT DIAGNOSIS OF A DISTILLATION COLUMN USING AN ARTIFICIAL NEURAL NETWORK," IFAC Symposium, Newark, Delaware, April, pp305-310, 1992.
5. Venkatasubramanian, V., R. Vaidyanathan, Y. Yamamoto, "Process Fault Detection and Diagnosis Using Neural Networks - I. Steady-state Processes," Comput. Chem. Engng., Vol.14, No.7, pp699-712, 1990.
6. Venkatasubramanian, V., Recall and Generalization Performances of Neural Networks for Process Fault Diagnosis," Chemical Process Control - CPCV, CACHE, pp647-664, 1991.
7. Waibel, A., T. Hanazawa, G. Hinton, K. Shikano and K. J. Lang, "Phoneme Recognition Using Time-Delay Neural Networks," IEEE TRANSACTIONS ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING, Vol.37, No.3, 1989.