

인공 신경망을 이용한 증류탑의 고장진단

이상규 · 박선원

한국과학기술원 화학공학과
(1991년 2월 22일 접수, 1991년 6월 25일 채택)

Fault Diagnosis of a Distillation Column Using an Artificial Neural Network

Sang Gyu Lee and Sun Won Park

Dept. of Chem. Eng., KAIST, P.O. Box 150, Cheongryang, Seoul 130-650
(Received 22 February 1991; accepted 25 June 1991)

요 약

기존의 인공 신경망을 이용한 고장 진단 방법들은 시간에 따라 변하는 고장의 증상들을 다루지 못하고 있으나, 실제의 공정에 있어서 고장의 영향은 시간에 따라 전파되기 때문에, 시간에 따라 변하는 센서값들은 on-line 고장 진단을 위한 중요한 정보를 제공한다. 본 연구에서는 시간에 따라 변하는 변수들의 측정값들을 고장의 증상으로써 인공 신경망에 학습시키는 방법을 사용한 증류탑의 고장 진단 시스템을 개발하였다. 개발된 고장 진단 시스템은 단일 고장뿐만 아니라 다중 고장의 경우에도 정확한 고장 진단 능력을 보인다.

Abstract—The existing fault diagnosis methods using artificial neural networks do not deal with time varying symptoms of faults. But in real plants, because the effect of the fault propagates continuously with time, the changing values of various sensors provide valuable information for on-line fault diagnosis. This paper describes a new method in which time varying values of the measurements are used as the symptoms of the faults to train the artificial neural network. A fault diagnosis system for a distillation column based on the proposed method can accurately diagnose both single and multiple faults.

1. 서 론

화학 공정의 대형화에 따른 복잡성과 자동화로 공정 조업자의 역할은 더욱 중요해지고 복잡해 졌다. 이에 따라 공정 조업자의 판단에 도움을 줄 수 있는 전문가 시스템(expert system)이 최근에 많이 연구되고 있다.

전문가 시스템에서는 가동중인 화학 공정에서 이상이 발생되었을 경우에 on-line으로 받아들이는 제반의 정보를 이용하여 그 원인을 찾아내는 고장 진단(fault diagnosis) 분야가 가장 활발히 연구되고 있다. 공정 전문가의 경험적 지식이나 공정 model을 컴퓨터에 저장함으로써

고장 진단 전문가 시스템은 고장이 발생하였을 경우 공정 조업자에게 빠른 조언을 할 수 있다. 즉 이러한 고장 진단 시스템은 공정 조업자에게 조언을 함으로써 대형사고를 미연에 방지하고 공정의 안전성을 높이며 미리 계획하지 않은 조업중단을 최소화함으로써 조업의 안전과 이윤을 증대시킬 수 있다.

기존에 있는 대부분의 고장 진단 시스템이 사용하는 지식 기반 방법에는 수학적 model을 수식으로 표현한 정량적 접근법과 model을 표상적(symbolic)으로 표현한 정성적인 방법이 있다. 정량적 접근법은 각 공정의 parameter 상태 변수들(state variables)을 Luenberger

Observer 등의 기법을 사용하여 계산했으나 화학 공정의 정확한 수학적 model을 얻기가 어렵다는 점이 커다란 단점으로 되어 왔다[6]. 표상적 표현에 의한 접근법은 경험적 지식을 사용함으로써 인하여 구축이 용이하나 계산시간이 길어서 빠른 분석을 할 수가 없으며, 더욱 문제가 되는 것은 정량적 센서자료를 정성적으로 표현할 때 많은 양의 정보를 유실하게 된다는 것이다 [1].

지식 기반 시스템의 위와 같은 단점을 보완하기 위하여 복잡한 공정에 대한 빠른 추론과 센서 정보를 유실없이 사용할 수 있고 공정 분석에 대하여 강건성(robustness)이 높은 인공 신경망(artificial neural network)에 대한 연구가 활발히 진행되고 있다. 이 분야의 연구로는 인공 신경망의 적용성과 2단계 인공 신경망을 제시한 Himmelblau팀[3, 10]과 다중 고장과 학습 parameter 비교를 한 Venkatasubramanian팀[7, 8] 등의 활발한 연구가 있다.

본 연구에서는 고장 진단에 사용될 인공 신경망을 학습시킬 때 한 가지 출력 패턴에 대하여 여러 형태의 입력 패턴을 사용하는 방법을 사용했다. 이 방법은 화학 공정에서 어떤 고장이 발생하였을 때 시간에 따라 변화하는 여러 변수의 측정값들을 그 고장의 증상으로 학습시키는 것을 뜻한다. 이런 방법에 의한 학습은 한 고장에 대하여 고장 초기상태, 혹은 증상의 대표적인 상태만으로 학습시킨 기존의 방법에 비하여 높은 강건성을 보이게 된다. 고장 발생후에 변화하는 증상을 학습시키기 위하여 학습용 입력자료는 dynamic simulator를 이용하였으며 학습된 인공 신경망의 성능 비교 역시 dynamic simulator로부터 얻은 결과를 바탕으로 분석하였다.

2. 인공 신경망

2-1. 다층 인식자(Perceptron)

최근에 들어 전자와 전산 분야의 발달로 인하여 인공 신경망이 다시 새롭게 관심의 대상이 되고 있다. 현재 인공 신경망의 형태로는 Perceptron model, Hopfield model, Hamming model, Neocognitron 등의 분류가 가능하며 학습 방법에 따라서 지도 학습과 자율 학습으로 분류가 가능하다. 인공 신경망의 응용 분야로는 패턴인식, 음성인식, 표적인식 및 추적, 로봇 제어와 인공지능각치 등이 다양하다[2]. 그 중 본 연구와 직접 관련이 있는 것은 패턴인식으로 각 센서에서 얻어진 공정 상태의 패턴으로부터 고장 형태를 분류하는 것을 뜻한다.

인공 신경망으로 구성된 패턴인식 시스템은 기존의




Fig. 1. Perceptron model.




Fig. 2. Activation functions in artificial neural network.

패턴매치에 의한 방법에 비하여 여러 가지 장점이 있다 [2].

- (1) 기존의 훈련되지 않은 새로운 형태의 입력 패턴에 대해서도 가장 비슷한 형태의 패턴을 찾을 수 있다.
- (2) 병렬성을 이용하면 신속한 처리가 가능하다.
- (3) 입력 패턴이 미리 훈련된 패턴에 비해 약간 손상된 형태라도 잘 인식해 낼 수 있다.
- (4) 간단한 구조로 인하여 특별한 소프트웨어가 필요치 않다.

본 연구에서는 다층 인식자(Perceptron)인 Fig. 1과 같은 형태의 인공 신경망을 이용했다. 그림에서 각각의 node들은 전 node들로부터 출력된 값과 연결된 가중치의 곱을 합한 다음 Fig. 2와 같은 활성화 함수를 통과한 후의 값을 갖는다. 그리고 그 값이 출력층인 경우에는 패턴인식의 결과로 나타나게 된다.

본 연구에 사용된 인공 신경망은 node층이 3 layer인 다층 인식자로 중간층이 한 개이고, 비선형 경계치 함수는 sigmoid 함수를 사용했다. 각 node들의 계산을 수학적으로 표현하면 계산 대상층의 j번째 node의 출력값인 x_j 는 그전 층의 i번째 출력값인 x_i 들과 그 사이의 가중치인 W_{ji} 들로써 결정된다.

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

이러한 합의 결과를 비선형 경계치 함수에 넣어서 x_j 를 계산한다.

$$x_j = S(\text{net}_j) = \frac{1}{[1 + \exp(-b \text{net}_j)]} \quad (2)$$

여기서 b 는 sigmoid 함수의 기울기로써 함수의 sensitivity를 결정하며 보통 1의 값을 사용한다. 이와 같은 연산으로 중간층과 출력층을 통과한 후에 출력 신호로 나온 결과를 이용하여 패턴을 인식하게 된다.

각 node들의 연결 가중치는 입력 패턴에 따른 출력 패턴과 원하는 패턴과의 오차로 계산된다. 이러한 계산을 학습이라 하며, 본 연구에서는 지도 학습중에 오류 역전파와 학습인 Generalized Delta Rule(GDR)을 사용하였다.

2-2. 오류 역전파 학습

인공 신경망의 학습은 주어진 입력에 대해 원하는 출력을 주입시키는 지도 학습(supervised learning)과 지도 출력이 없는 자율 학습(unsupervised learning)으로 분류될 수 있다. 본 연구에서의 학습은 고장 증상을 입력 패턴으로 하고 그 고장위치를 원하는 출력 패턴으로 하는 지도 학습, 즉 다층 인식자의 구조에 오류 역전파와 학습(error back propagation learning)을 이용하였다. 오류 역전파와 학습의 초기에는 가중치를 임의로 주었으나 임의로 갖고 있는 다층 인식자에서 출력된 값과 출력으로 원하는 값의 오차로써 가중치를 변화시키고 계속해서 오차가 주어진 값보다 작을 때까지 반복하여 가중치를 변화시키는 것이다[5, 9].

학습시키려는 입력 패턴과 출력 패턴의 한 쌍을 p 라 하고 입력 패턴이 다층 인식자를 통과한 후의 각 j 번째 출력 node의 값을 x_{pj} 라 하고 그 node에서 출력되기를 원하는 값을 t_{pj} 라 하면 출력된 값의 오차는 아래와 같다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - x_{pj})^2 \quad (3)$$

$$x_{pj} = S(\text{net}_{pj}) \quad (4)$$

$$\text{net}_{pj} = \sum_i W_{ji} x_{pi} \quad (5)$$

여기서 함수 $S(\)$ 는 sigmoid 함수이고, W_{ji} 는 다층 인식자의 i 에서 j 로의 가중치이고, x_{pi} 는 출력층의 전층에서 i 번째 node의 출력값이다. 반복 학습 횟수를 t 라 하면 $W_{ji}(t)$ 에서 한 단계 학습시킨 $W_{ji}(t+1)$ 는 아래와 같다.

$$W_{ji}(t+1) = W_{ji}(t) + \Delta W_{ji}(t) \quad (6)$$

식 (3)에서 나온 오차인 E_p 가 줄어드는 방향으로 Gradient Descent 법칙을 적용하여 가중치 W_{ji} 를 변화시킨다.

$$\Delta_p W_{ji} \propto - \frac{\partial E_p}{\partial W_{ji}} \quad (7)$$

여기서 $\Delta_p W_{ji}$ 는 ΔW_{ji} 중 패턴 p 에 대한 가중치의 변화이다. 식 (7)의 오른쪽 항을 정리하면 아래와 같다.

$$- \frac{\partial E_p}{\partial W_{ji}} = - \frac{\partial E_p}{\partial \text{net}_{pj}} \frac{\partial \text{net}_{pj}}{\partial W_{ji}} = \delta_{pj} x_{pi} \quad (8)$$

여기에 사용된 δ_{pj} 의 정의는 다음과 같다.

$$\delta_{pj} = - \frac{\partial E_p}{\partial \text{net}_{pj}} \quad (9)$$

식 (8)을 이용하여 식 (7)을 정리한다.

$$\Delta_p W_{ji} = \eta \delta_{pj} x_{pi} \quad (10)$$

여기서 η 는 학습속도상수(learning rate)로써 0에서 1사이의 값이 사용되며 학습속도를 결정한다. 식 (9)를 출력층과 중간층에 적용하기 위하여 chain rule을 적용한다.

$$\delta_{pj} = - \frac{\partial E_p}{\partial \text{net}_{pj}} = - \frac{\partial E_p}{\partial x_{pj}} \frac{\partial x_{pj}}{\partial \text{net}_{pj}} \quad (11)$$

이 식을 출력단의 학습에 적용할 때에는 원하는 출력인 t_{pj} 를 알고 있으므로 식 (2)와 (3)을 이용하여 아래와 같이 표현한다.

$$\delta_{pj} = (t_{pj} - x_{pj}) S' \quad (12)$$

여기서 S' 는 sigmoid 함수의 net_{pj} 에 의한 미분이다.

$$S' = \frac{\partial x_{pj}}{\partial \text{net}_{pj}} \quad (13)$$

또한 중간단을 학습할 때는 원하는 출력값을 모르므로 출력단으로부터의 오차합을 이용한다. 식 (11)의 오른쪽 항중 한 부분에 chain rule을 적용하고 식 (5)와 (9)를 이용하여 정리하면 아래와 같다.

$$\sum_k \frac{\partial E_p}{\partial \text{net}_{pk}} \frac{\partial \text{net}_{pk}}{\partial x_{pj}} = - \sum_k \delta_{pk} W_{kj} \quad (14)$$

$$\delta_{pj} = S' \sum_k \delta_{pk} W_{kj} \quad (15)$$

실제 출력값을 원하는 목적값으로 하기 위한 오차 보정은 δ_{pj} 에 의하여 계산된다. 위의 오차 보정식을 미분이 풀어진 형태로 표현하면 아래와 같다.

$$\begin{aligned} \delta_{pj} &= x_{pj}(1-x_{pj})(t_{pj}-x_{pj}) : \text{출력층} \\ \delta_{pj} &= x_{pj}(1-x_{pj}) \sum_k \delta_{pk} W_{kj} : \text{중간층} \end{aligned} \quad (16)$$

학습은 출력층에서부터 초기 입력층까지 오차가 역전파되면서 이루어지므로 오류 역전파라 한다. 가중치 함수의 변환식인 식 (10)에서 학습속도상수가 커지면




Fig. 3. Information flow in the fault diagnosis system.

학습법칙의 적용은 빨라지나 진동하는 경향이 있으므로 이전 패턴에 대한 학습을 위하여 momentum 계수를 사용한다. Momentum 계수가 사용된 패턴 p에 관계없이 전체 패턴에 대하여 적용되는 학습식을 아래에 나타내었다.

$$\Sigma W_{ji}(t) = \eta \delta_j x_i + \alpha \Delta W_{ji}(t-1) \quad (17)$$

Momentum 계수인 α 는 진동이 일어나는 것을 방지하고 학습속도를 증가시키기 위한 것으로 0에서 1 사이의 값을 가진다. 학습속도상수와 momentum 계수의 값은 수학적으로 얻어지는 것이 아니다. 본 연구에서는 인공 신경망의 학습속도상수를 0.9로, momentum 계수를 0.6으로 학습시켰다. 이 값들은 다른 연구에서도 많이 사용되고 있으며[7, 8] 본 연구에서도 몇 번의 수행결과를 통해 그 값을 선택하였다.

3. 인공 신경망을 이용한 고장 진단 장치

3-1. 고장 진단 장치의 구성




Fig. 4. Role of data preprocessor.

화학 공정의 고장 진단 시스템은 공정 상태의 센서 값을 on-line으로 읽어서 그 현상을 분석하는 것이다. 현재 많이 사용되는 지식 기반 고장 진단의 경우 그 센서값들을 표상적(symbolic)으로 바꾸기 위하여 각각의 센서 자료 preprocessor를 통과한 후에 전문가 시스템에 보내게 되는데 이 때 많은 양의 정보가 유실될 수 있다. 본 연구에 사용되는 인공 신경망은 센서들로부터 얻어진 정량적 상태의 정보를 그대로 사용하기 위하여 센서값들을 인공 신경망에서 사용되는 sigmoid 형태의 preprocessor를 통과한 후에 그 값을 그대로 인공 신경망에 넣는 방법을 사용했다.

본 연구에서는 Fig. 3과 같은 형태의 고장 진단 시스템 구조를 제안한다. Fig. 4는 센서 자료의 preprocessor를 설명하기 위한 그림으로 feed의 온도가 갑자기 올라가는 경우에 탑상 제품의 유량과 그 양에 따라 인공 신경망에 들어가는 양의 입력 node에서의 값, 그리고 음의 입력 node에서의 값을 나타내었다. 이와 같이 한 개의 센서 값에 대하여 인공 신경망에 두 개의 입력 node를 만든 이유는 인공 신경망의 특성상 음의 값이 입력되는 것보다는 양의 값과 음의 값으로 분리된 두 개의 값이 입력되는 것이 분석의 성능을 높일 수 있기 때문이다. 탑상 제품 유량 센서로부터 얻은 공정 상태의 값은 센서

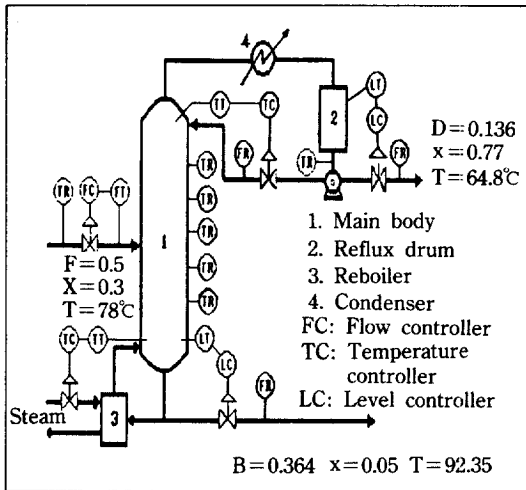


Fig. 5. Distillation column used for simulation study.

Table 1. Information available for on-line diagnosis for a simulated distillation column

No	Sensor name	Steady state
1	Feed temperature	78°C
2	Condenser temperature	64.8°C
3-9	Tray 1-7 temperature	92.4-65.4°C
10	Feed flow	0.5 mole/sec
11	Reflux flow	0.3177 mole/sec
12	Top product	0.1359 mole/sec
13	Bottom product	0.3641 mole/sec
14	Reflux drum level	50%
15	Bottom level	50%
16	Condenser Q_{Cond}	2677.3 cal/sec
17	Reboiler Q_{Rebo}	2641 cal/sec
18	Reboiler heat input controller output	2641 cal/sec
19	Reflux flow controller output	0.3177 mole/sec
20	Top product flow controller output	0.1359 mole/sec
21	Bottom product flow controller output	0.3641 mole/sec

자료 preprocessor인 sigmoid 함수를 통과한 후에, Fig. 4의 아래쪽 두 그림에 나타나 있듯이, 0에서 1사이의 값으로 바뀌게 된다. 이 때 센서값과 정상 상태값과의 차가 음이나 양이냐에 따라서 센서값이 인공 신경망의 입력층에서 다른 node에 입력되며 정상 상태와의 차가 양일 경우에는 음의 입력 node가, 음일 경우에는 양의 입력 node가 0의 값으로 입력되는 형태를 사용했다. 이러한 구조로 인하여 인공 신경망의 입력 node의 개

Table 2. Simulated faults used to train the neural network for a distillation column diagnosis

No	Fault name	Trained deviation
1	Bottom level sensor fails low	-20%
2	Bottom level sensor fails high	+20%
3	Reboiler steam pressure low	-20%
4	Reboiler steam pressure high	+25%
5	Reboiler steam valve fails closed	-90%
6	Reboiler steam valve fails open	+60%
7	Bottom temperature sensor fails low	-6%
8	Bottom temperature sensor fails high	+6%
9	Bottom product valve fails closed	-99%
10	Bottom product valve fails open	+30%
11	Drum level sensor fails low	-20%
12	Drum level sensor fails high	+20%
13	Feed composition low	-67%
14	Feed composition high	+67%
15	Feed temperature low	-10%
16	Feed temperature high	+10%
17	Feed flow valve fails closed	-99%
18	Feed flow valve fails open	+100%
19	Reflux flow valve fails closed	-99%
20	Reflux flow valve fails open	+100%
21	Top flow pump fails stop	-100%
22	Top product valve fails closed	-99%
23	Top product valve fails open	+100%
24	Top temperature sensor fails high	-10%
25	Top temperature sensor fails high	+10%

수는 고장 진단에 사용되는 화학 공정 센서 갯수의 2배로 되는 형태로 된다.

3-2. 공정 모델 설명 및 고장 사례 학습

화학 공정에 있어서 증류탑은 매우 중요하며 또한 그 거동에 대한 분석이 매우 어렵다. 본 연구의 대상 공정 모델은 Fig. 5에 나타나듯이 물과 methanol을 분리하는 증류탑으로서 총 5개의 제어루프를 갖고 있으며 PI 제어기가 사용된다. 이러한 대상 공정 모델로부터 받은 21개의 정보를 Table 1에 나타내었으며 on-line 고장 분석에 이용된다.

Feed 라인과 탑저와 탑상 제품의 특성을 Fig. 5에 표시했다. 본 연구에서 선택한 고장 형태는 증류탑에서 고장이 발생되었을 때 전파 속도가 빠르고 그 증상이 전체적으로 전파되는 25개의 대표적인 것으로서 Table 2에 나타나 있다. 센서값의 벗어나는 정도를 수치적으로 바꾸는 센서 데이터 preprocessor에는 sigmoid 함수를 사용했다. Sigmoid 함수의 기준값은 온도센서의 경우에는 센서 noise의 범위를 3°C 이내로 가정하여 4°C로

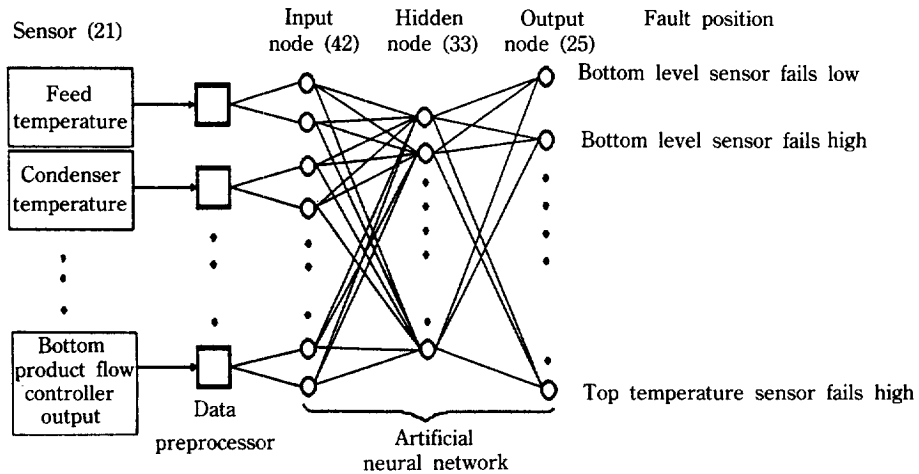


Fig. 6. Artificial neural network and data preprocessors for fault diagnosis of the example process.

하고 flow 센서의 경우에는 정상 상태의 10%로 하고 함수의 폭을 넓혔다. 또한 heat flow의 경우에는 함수의 기준값을 5%로 하였다.

본 연구에서 사용된 인공 신경망 학습용 자료는 증류탑 simulator를 이용하여 고장이 발생된 다음부터 1000 sec까지를 50 time step(20 sec 간격)으로 나뉘어 만들어졌다. 즉 25개의 고장 원인에 대하여 50개의 유사한 값들로 이루어진 증상군을 이용하여 학습시켰다.

학습에 적용된 인공 신경망인 다층 인식자는 node 층이 3 layer로 입력층의 node 개수는 센서 개수에 2를 곱한 42개이며, 출력층의 node 개수는 학습시킨 고장 개수인 25개이고 중간층은 33개로 하였다. 즉 센서 정보에서부터 인공 신경망의 출력층까지의 구조를 보면 Fig. 6과 같다.

본 연구에서는 dynamic simulator에서 25개의 가상적 고장을 일으키도록 프로그래밍을 한 후에 각각의 fault simulation 결과인 시간에 따른 50 time step에 대한 21개의 센서값들을 인공 신경망에 학습시킨다. 학습의 반복 횟수 1번의 범위는 25개의 고장에 대하여 각 고장이 발생한 후 시간에 따른 50개의 패턴 전체를 학습하는 것을 의미한다. 인공 신경망을 학습시킬 때는 이러한 1번의 반복 횟수를 시간에 따라 50 time step으로 나눈다. 한 time step의 학습범위는 그 time step에 해당되는 25개 고장 증상들의 패턴들로 이루어진다. 그러므로 한 time step에서 입력단에는 25개의 고장 패턴이 차례로 입력되고 출력단에는 각각의 고장위치가 출력되도록 학습시킨다. 이러한 방법에 따라 25개의 고장 패턴으로 이루어진 한 time step이 끝나면, 그 다음 time step으로 학습을 시킨다. 계속해서 50개의 time step이 모두 수행되면 학습의 한 반복 횟수가 끝나는




Fig. 7. Convergences of the training.

것이 된다. 본 인공 신경망에서는 고장위치를 나타내기 위해서 인공 신경망의 출력이 그 고장 위치에서는 1의 값을, 그리고 나머지 고장 위치에는 0의 값을 갖도록 하였다.

4. 인공 신경망의 학습 특성과 결과 분석

4-1. 학습속도상수와 momentum 상수

인공 신경망의 학습은 주어진 패턴과 원하는 패턴의 반복 학습에 의하여 이루어진다. 학습자료의 반복에 의한 학습정도를 Fig. 7에 나타내었으며 그림에서 보여준 것은 식 (17)의 momentum 상수를 0.6으로 고정하고 학습속도상수인 η 값을 0.3에서 0.9까지로 변화하였을 때의 학습정도를 나타낸 것으로, 본 연구의 자료는 학습속도상수의 영향이 별로 없음을 나타낸다. 그림에서 y축의




Fig. 8. Fault certainty when reboiler steam pressure increases.

단위인 E는 인공 신경망의 성능 비교에 많이 사용되는 r.m.s.(root mean square) 오차로 대수 단위이다.

$$E = \sum_p E_{rms,p} \quad ; p=1, 2, \dots, P \quad (18)$$

여기서 P는 전체 학습 패턴 갯수이며, $E_{rms,p}$ 는 패턴 p에 대한 r.m.s.오차를 나타낸다.

$$E_{rms,p} = \left[\sum_i \frac{(t_{pi} - x_{pi})^2}{N} \right]^{1/2} \quad ; i=1, 2, \dots, N \quad (19)$$

t_{pi} 와 x_{pi} 는 각각 목적으로 하는 출력값과 실제 출력값이며, N은 출력층의 node갯수이다. 그림에서 x축의 값인 반복횟수는 25개의 고장에 대한 50개의 시간에 따른 측정값들을 학습한 것을 한 단위로 하여 나타내었다. 본 연구에 사용된 가중치군은 학습속도상수를 0.9로 하고 momentum 상수를 0.6으로 하여 50번 학습된 것이다.

4-2. 학습된 증상에 대한 인공 신경망의 결과 분석

학습된 인공 신경망은 입력 센서 자료 21개를 받아서 preprocessor를 거친 후에 각 자료를 분류하여 그 결과로 각 고장 위치의 확신도(certainty)를 출력한다. 학습된 증상에 대한 고장 분석은 대부분이 초기에서부터 거의 1에 가까운 확신도를 출력하였다. 그 한 예로 reboiler의 스팀량이 정상 흐름의 1.25배로 갑자기 높아지는 경우를 Fig. 8에 나타내었다. 그림에 나타나듯이 고장 발생인 0 sec 이후에서부터 확신도 값은 1에 가깝게 그 고장위치를 가리켰다. 나머지 24개의 고장 분석




Fig. 9. Temperature changes when feed temperature increases.




Fig. 10. Flow changes when feed temperature increases.

역시 이와 유사한 결과가 나왔다.

4-3. 학습되지 않은 증상에 대한 고장 분석

4-3-1. 고장 원인이 천천히 나타나는 경우

대상 증류탑의 정상 feed 온도는 78°C이다. 학습된 'Feed Temperature Increase' 이상 상태의 증상 패턴은 이 feed의 온도가 78°C에서 갑자기 85°C로 올라가는 현상이다. 이러한 증상을 학습시킨 인공 신경망으로 feed의 온도가 정상 상태에서 500 sec까지는 78°C에서부터 천천히 증가하여 85°C로 되고 그 상태로 1000




Fig. 11. Heat flow changes when feed temperature increases.




Fig. 12. Fault certainty when feed temperature increases.

sec까지 유지되는 simulation 결과를 분석하였다. 그 결과로 인한 증류탑의 온도변화를 Fig. 9에 나타내었는데 각 단의 온도변화가 feed 온도변화에 비하여 작은 이유는 탑상과 탑저에서 온도 제어를 하기 때문이다. 이렇듯이 feed 온도변화를 각 단의 온도 센서로는 알 수 없기 때문에 Fig. 10에서 보여준 탑상 제품의 양과 탑저 제품의 양, 그리고 reflux 유량의 변화와, Fig. 11에서 보여준 reboiler와 condenser의 열량 변화로 고장 진단을 해야만 하는 어려움이 있다. 이와 같은 simulation 결과를 인공 신경망으로 진단한 결과는 Fig. 12이다.




Fig. 13. Flow changes when feed composition decreases.

그림에 나타나듯이 온도의 변화가 점차 확대되고 전파 되는데 걸리는 시간때문에 증상을 인식하는데는 약간의 시간이 걸린다.

4-3-2. Noise에 대한 분석

실제 공정에서 공정 변수들의 오차는 보통 3%이내를 noise로 볼 수 있다고 한다. 따라서 본 연구의 대상 모델에 들어가는 feed의 온도와 유량과 스팀의 양, 그리고 측정값에 3%의 변화를 주어서 고장 분석을 하였다. 그 결과로 변화에 대한 고장 확신도의 값들이 정상 상태에서 거의 변하지 않는 것을 알았다. 이것으로 인공 신경망에 의한 고장 진단은 noise에 대하여 강건성이 뛰어남을 알 수 있다(결과 생략).

4-3-3. 학습된 고장의 1/2값으로 simulation한 증상

본 사례 연구는 증류탑의 feed조성이 떨어지는 경우를 진단하는 것이다. 증류탑의 정상 feed 조성은 0.3이다. Feed의 조성이 떨어지는 고장의 학습 패턴은 0.3에서 갑자기 0.1로 떨어지는 형태이다. Simulator를 이용하여 feed의 조성이 갑자기 0.2로 떨어졌을 때의 증상을 만들었다. Fig. 13은 이러한 simulation의 결과로 나타난 증상과 학습된 증상을 비교한 것이며 Fig. 14는 학습된 고장의 1/2값인, feed 조성이 갑자기 0.2로 떨어지는 증상에 대한 고장 분석이다.

4-3-4. 학습된 고장의 2배 이상의 값으로 simulation한 증상

앞의 사례 연구와 반대의 원인 분류에 들어가는 형태인 feed의 조성이 증가되는 경우로 이상 원인의 강도를 학습된 값의 2배 이상으로 주어 보았다. 증류탑의 정상 feed 조성은 0.3이다. 학습된 고장 패턴은 이 feed의 조성이 0.5로 갑자기 증가되는 형태의 학습이었다. 이




Fig. 14. Fault certainty when feed composition decreases.




Fig. 16. Fault certainty when a double fault occurs in feed and drum.




Fig. 15. Fault certainty when feed composition increases.

러한 인공 신경망에 feed의 조성이 정상 상태에서 500 sec 사이에는 0.3에서 0.8로 변화하고 그 이후에는 0.8로 들어가는 형태를 simulation한 결과를 분석하였다. 결과인 Fig. 15는 학습된 고장 원인의 값이 2배 이상이 되어도 분석이 가능함을 말해준다.

4-3-5. 다중 고장에 대한 분석 결과

인공 신경망에 의한 고장 진단이 다중 고장 분석에 있어서 기존의 지식 기반 고장 진단에 비하여 수월하다는 것은 Venkatasubramanian[7, 8] 등의 연구에 잘 나와 있다. Fig. 16은 'Drum Level Sensor Fails High'




Fig. 17. Fault certainty when a double fault occurs in top and bottom.

와 'Feed Composition High'의 증상이 동시에 일어나는 경우에 대한 결과이다. 이 경우에 있어서 'Feed Composition High'의 증상은 feed에서부터 전파되는 조성에 의한 온도변화이므로 고장 초기에는 'Drum Level Sensor Fails High'에 의하여 진단의 결과가 흐려지다가 고장의 영향이 증류탑을 거쳐 탑상과 탑저로 전파된 다음에야 분석이 가능해진다. 이 때 'Drum Level Sensor Fails High'에 대한 증상은 'Feed Composition High'의 증상에 의하여 상쇄됨을 알 수 있다.




Fig. 18. Fault certainty when a reboiler steam valve fails closed after plant steady state changes.

앞의 예와 같이 증상이 전파되면서 그 증상들이 서로 상쇄되는 경우와는 달리, Fig. 17은 탑상과 탑저의 다중 고장으로 서로의 영향력이 작을 때는 다중 고장 분석의 선명도가 높다는 것을 보여준다.

4-3-6. 공정의 정상 상태가 변한 경우의 분석

화학 공정은 운전자의 요구에 따라 공정의 정상 운전 상태가 변할 수 있다. 본 사례 연구는 feed의 유량이 0.5인 정상 상태에서의 고장에 대하여 학습된 인공 신경망을 이용하여 feed의 유량이 0.8로 변한 정상 상태에서 고장이 일어나는 경우에 대하여 고장 진단을 하였다.

Feed의 정상 상태가 변하면 나머지 센서들의 정상 상태값도 변하게 된다. 즉 feed 유량이 0.8로 변한 정상 상태에서 reflux 유량은 0.5084로 탑상과 탑저 제품의 유량은 각각 0.2174와 0.5826으로 변하며 그밖에 스팀과 냉각수 등의 양이 변하게 된다.

인공 신경망으로 정상 상태가 변한 경우에 대한 고장 진단을 할 때는 단지 preprocessor에서 센서 자료를 처리할 때 기준이 되는 정상 상태값만 바꾸면 분석이 가능해진다. Fig. 18은 feed의 유량이 0.8로 변한 후의 'Reboiler Steam Valve Fails Closed' 고장에 대한 분석 결과이다.

4-4. 한 시점에서의 증상만으로 학습된 인공 신경망의 문제점

앞의 사례 연구들은 한 고장 원인에 대하여 시간에 따른 50개 시점에서의 센서값을 학습시킨 것이지만 기




Fig. 19. Fault certainty when feed composition decreases (learning based on sensor data at one representative time point).

존의 인공 신경망을 이용한 대부분 방법[4, 7, 8]은 한 고장에 대하여 대표적인 한 시점에서의 센서값들을 학습시킨 것이다. 본 연구에 사용된 한 시점에서의 센서값들에 의한 학습은 simulation으로부터 얻은 고장 증상중에서 대표적 초기 증상을 선택하여 2500번 반복 학습된 것이다. 이 반복 학습 횟수는 앞의 결과 분석에 사용했던 50개 시점에서의 증상을 50번 학습한 것과 같은 학습 횟수로서 학습 정도를 나타내는 식 (1)에서 E값은 $E_{2500} = 6.24 \times 10^{-6}$ 으로 나타났다.

Fig. 19는 Fig. 14에서 사용된 증상인 feed 조성이 0.3에서 갑자기 0.2로 떨어지는 형태의 simulation 결과를 한 시점에서의 증상만으로 학습된 인공 신경망에 그대로 넣은 결과이다. 진단의 결과가 300 sec에서 900 sec까지만 정확한 분석이 가능한 이유는 학습된 대표적 초기 증상이 그 안에서만 유효하기 때문이다.

Fig. 20은 Fig. 16에서 사용된 증상인 'Feed Composition High'와 'Drum Level Sensor Fails Closed'가 동시에 발생하는 다중 고장 형태의 simulation 결과를 한 시점에서의 증상만으로 학습된 인공 신경망에 넣은 결과이다. 진단의 결과에서 보이듯이 'Feed Composition High'의 경우 거의 분석이 안되는데 그 이유는 조성의 영향은 매우 느리며 또한 공정에서는 온도변화로 조성의 변화를 알 수 있으므로 더욱 거동이 느려지기 때문이다. 그러나 액위 센서에 의한 고장은 그 전파가 빠르므로 분석 역시 빠르게 된다. 그리고 feed 조성변화의 증상이 전체적으로 나타나는 영역은 이미 초기




Fig. 20. Fault certainty when a double fault occurs in feed and drum (learning based on sensor data at one representative time point).

증상이 아니다. 즉 학습되지 않은 영역이므로 다른 분석의 결과로 나타나게 된다.

5. 결론 및 제언사항

대상 공정을 증류탑으로 하는 고장 진단 전문가 시스템을 인공 신경망을 이용하여 구축하였다. 또한 인공 신경망의 학습과 분석을 위하여 물과 methanol을 분리하는 증류탑의 dynamic simulator를 이용하였다.

본 연구에 사용된 인공 신경망은 node층이 3 layer인 다층 인식자이며 오류 역전파 학습을 이용하였다. 학습에 사용된 자료는 25가지의 고장들에 대하여 시간 변화에 따른 50개의 측정값들이다. 이에 다음의 결과를 얻었다.

(1) 고장 진단을 위하여 구축된 인공 신경망은 빠른 진단과 강건성이 높은 진단을 할 수 있었다.

(2) 각 센서 및 제반 정보를 가공하는 방법으로 sigmoid 형태의 함수를 이용함으로써 정량적 정보의 유실을 막을 수 있었다.

(3) 학습된 고장 원인의 1/2값으로 simulation한 증상과 2배 이상으로 한 증상의 분석, 그리고 noise에 대한 강건성 등을 대상으로 인공 신경망에 적용하여 좋은 결과를 얻었다. 또한 다중 고장의 경우에도 각각의 증상이 상대의 고장 원인으로 인하여 많은 부분이 상쇄되지 않는다면 선명도가 높은 다중 고장 분석이 가능함을 알아냈다.

(4) 증류탑의 정상 운전에 의하여 공정 정상 상태가 다른 정상 상태로 변하여도 이전의 공정 상태에서 학습된 인공 신경망을 이용하여 고장 진단을 할 수 있음을 알아냈다.

(5) 한 고장 원인에 대한 대표적인 한 시점에서의 센서값들을 학습시킨 인공 신경망과 본 연구에서 제시한 시간에 따라 변하는 여러 변수의 측정값들을 증상으로 학습시킨 인공 신경망을 비교하여 시간에 따른 증상 (time dependent symptom)을 학습시킨 것이 진단의 선명성과 다중 고장의 분석 등에서 뛰어난 결과를 얻었다.

규칙 기반 시스템은 경험적으로 얻은 단순 증상에 대한 고장 진단과 진단 결과에 대한 설명 기능이 우수하다는 장점을 가지고 있다. 따라서 보다 우수한 성능을 위하여 규칙 기반 방법과 인공 신경망 방법의 병합이 요구된다.

NOMENCLATURE

- b : slope of the sigmoid function
- $E, E_{rms,p}$: root mean square error
- E_p : square error of p^{th} pattern
- N : number of output nodes
- net_j : summation of outputs of nodes in the previous layer multiplied by weights going into the j^{th} node in the artificial neural network
- P : number of patterns
- S' : differentiation of sigmoid function
- $S(\)$: sigmoid function
- t : learning iteration number
- t_{pj} : target value of the p^{th} pattern in the j^{th} output node in the artificial neural network
- x_{pj} : output value of j^{th} node of p^{th} pattern in the artificial neural network
- W_{ji} : connection weights between j^{th} node in the current layer and i^{th} node in the previous layer in the artificial neural network

Greek Letters

- α : momentum constant in the error back propagation learning
- δ_{pj} : effect of input value on the error of j^{th} node of p^{th} pattern in the artificial neural network
- η : learning rate in the error back propagation learning

REFERENCES

1. 오전근 : Ph. D. Dissertation, Seoul National Univ., Seoul Korea(1990).
2. 이수영 : “신경 회로망 컴퓨터”, 한국과학기술원 하계강좌, 2(1990).
3. Himmelbrau, D. M.: “Fault Detection and Diagnosis in Chemical and Petrochemical Processes”, Elsevier, (1978).
4. Hoskins, J. C. and Himmelblau, D. M.: *Comput. Chem. Engng.*, **12**(9/10), 881(1988).
5. McClelland, J. L., Rumelhart, D. E. and the PDP Research Group: “Parallel Distributed Processing”, MIT Press, (1986).
6. Moor, R. L. and Kramer, M. A.: “Chemical Process Control-CPC III”, Elsevier, 839(1986).
7. Venkatasubramanian, V. and Chan, K.: *AIChE J.*, **35**(12), 1993(1989).
8. Venkatasubramanian, V., Vaidyanathan, R. and Yamamoto, Y.: *Comput. Chem. Engng.*, **14**(7), 699 (1990).
9. Wasserman, P. D.: “Neural Computing Theory and Practice”, Van Nostrand Reinhold, (1989).
10. Watanabe, K., Matsuura, I., Abe, M., Kubota, M. and Himmelblau, D. M.: *AIChE J.*, **35**(11), 1803 (1989).