

# 가스모니터링 시스템에서의 신경회로망 기반 센서고장진단

## Neural Network-Based Sensor Fault Diagnosis in the Gas Monitoring System

이인수<sup>\*</sup> · 조정환<sup>\*\*</sup> · 심창현<sup>\*\*\*</sup> · 이덕동<sup>\*\*\*\*</sup> · 전기준<sup>\*\*\*\*</sup>

In Soo Lee, Jung Hwan Cho, Chang Hyun Shim, Duk Dong Lee, and Gi Joon Jeon

\* 상주대학교 전자전기공학부 교수

\*\* 경북대학교 전자·전기·컴퓨터공학부 박사과정

\*\*\* (주)센스엔센서 CEO

\*\*\*\* 경북대학교 전자·전기·컴퓨터공학부 교수

### 요약

본 논문에서는 실내대기 가스모니터링 시스템에서의 센서 고장 진단을 위한 신경회로망 기반 고장진단방법을 제안한다. 제안한 고장진단방법에서는 신호패턴추출을 위해 센서히터 온도조절방법을 이용하였으며, 분류를 위해서는 ART2 신경회로망을 이용하였다. 그리고 가스모니터링 시스템의 실제 데이터를 이용한 시뮬레이션을 통해 제안한 ART2 신경회로망 기반 센서고장진단방법의 성능과 유용성을 확인하였다.

### Abstract

In this paper, we propose neural network-based fault diagnosis method to diagnose of sensor in the gas monitoring system. In the proposed method, using thermal modulation of operating temperature of sensor, the signal patterns are extracted from the voltage of load resistance. Also, ART2 neural network is used for fault isolation. The performance and effectiveness of the proposed ART2 neural network-based fault diagnosis method are shown by simulation results using real data obtained from the gas monitoring system.

**Key Words :** Gas monitoring system, sensor fault diagnosis, thermal modulation, ART2 neural network

### 1. 서 론

최근에 전자코(electronic nose)의 응용에 대한 연구가 활발하게 이루어지고 있으며, 특히 가정 및 산업시스템에서의 가스누출에 의한 사고를 방지하기 위해서 유해 가스를 분류해내고 이를 경보하기 위한 가스 모니터링에 대한 중요성이 크게 증가하고 있다[1, 2]. 가스 모니터링 시스템은 전자코라 불리는 센서의 성능에 의존하므로 센서에서의 고장은 시스템의 모니터링 성능을 저하시키므로써 잘못된 경보의 원인이 될 수 있으며 이로 인해 큰 인명피해가 발생할 수 있다. 그러므로 가스 모니터링의 안정성 확보를 위해서는 센서에서의 고장을 알아내기 위한 고장진단 방법에 대한 연구가 필요하다.

고장진단은 시스템에서의 오동작 여부를 판단하고 고장을 분류하는 것을 말한다. 기존의 고장진단 방법은 크게 모델에 근거한 방법과 모델에 근거하지 않는 방법으로 분류할 수 있다. 모델에 근거한 방법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 상태추정 접근법과 파라미터추정 접근법으로 나눌 수 있다. 먼저 추정된 상태와 공칭모델의 상태와의 오차로부터 고장의 발생여부

를 판단하는 상태추정 접근법으로는 패리티(parity) 검사, 칼만필터나 관측기(observer)를 이용한 이노베이션 검증법, 오류감지필터 접근법 등이 있다[3-5].

파라미터추정에 의한 고장진단 방법으로는 먼저, 파라미터 추정에 의한 고장진단 방법 중에서 추정된 파라미터를 이용하여 모델 파라미터와 물리적 파라미터와의 관계로부터 물리적 파라미터의 변화를 계산하여 고장의 종류를 알아내는 간접적인 방법[4]을 들 수 있다. 그러나, 모델 파라미터와 물리적 파라미터 사이의 비선형성으로 인해 두 파라미터 사이의 명확한 관계정립이 어렵다. 다음으로 추정된 파라미터를 직접 고장분류에 이용하는 방법[6]은 추정된 모델과 정상적인 공칭모델과의 오차로부터 고장의 발생 유무를 결정하며, 미리 구축한 고장모델과 추정된 모델을 비교하여 고장상태를 분류한다. 그러나 사전에 발생 가능한 모든 고장을 예측하여 고장모델로 구축한다는 것은 매우 어렵기 때문에 예기치 않은 고장상태도 자동 분류할 수 있는 수단이 필요하다.

모델에 근거하지 않는 방법은 대상 시스템의 측정치, 경험 또는 물리적 검토를 기초로 하며, 시스템의 출력 값이 제한된 범위를 벗어나는지의 유무로써 고장을 감지해내는 한계치 검사(limit checking), 전문가 시스템 기법 및 신경회로망을 이용한 방법 등이 있는데, 전문가 시스템을 이용하는 방법은 명확한 규칙선정이 어렵다는 문제점이 있다. 반면, 신경회로망은 복잡처리가 가능하므로 처리속도면에서 이점이 있으며

입력이 다소 불완전하고 잡음을 포함한 경우라도 큰 효과를 발휘할 뿐만 아니라 학습의 기능도 있다[7]. 이러한 장점으로 인해 신경회로망은 패턴인식, 신호처리 및 영상처리, 패턴분류 문제 등에 성공적으로 적용되고 있으며, 이를 토대로 신경회로망을 고장진단 문제에 이용하려는 많은 연구가 있었다 [8-11]. 대부분의 연구에서는 고장을 일종의 패턴으로 간주하여 신경회로망을 미리 획득한 고장패턴으로 학습을 시킨 뒤 고장을 분류하고 있으나, 사전에 모든 고장에 대한 학습 데이터를 얻기가 힘들다는 단점이 있다[12].

이러한 단점을 해결하기 위해 자율학습 신경회로망인 ART(adaptive resonance theory) 신경회로망을 이용하는 방법이 연구되었다[13, 14]. 이 방법들은 고장분류를 위해서 자율학습 신경회로망을 이용하므로 발생 가능한 모든 고장의 종류를 알아야 하는 기존의 연구들과는 달리 예기치 않은 새로운 고장상태도 자동 분류할 수 있다는 장점이 있다. 특히, 이 등[14]은 패턴을 분류할 때 하나의 경계인수(vigilance parameter)를 사용하는 기존의 ART2 신경회로망[15]의 단점을 보완한 여러 경계인수를 갖는 ART2 신경회로망을 제안하였으며, 이를 고장분류에 이용하므로써 보다 정확한 고장분류가 이루어지도록 한 바 있다.

본 논문에서는 실내대기에 존재하는 가스의 종류를 알아내기 위한 가스모니터링 시스템에서의 센서 고장진단을 위해 신경회로망 기반 고장진단방법을 제안한다. 제안한 방법에서는 실제 실험에서 센서의 고장분류 신호패턴추출을 위한 센서히터 온도조절방법과 예기치 않은 새로운 고장의 분류도 가능한 여러 경계인수를 갖는 ART2 신경회로망을 함께 적용하여 센서의 고장진단을 수행하였다. 그리고 가스모니터링 시스템에서의 센서고장실험을 통해 획득한 실제 데이터를 이용하여 시뮬레이션을 수행하였으며 결과들로부터 제안한 신경회로망 기반 센서고장진단방법의 성능과 유용성을 확인하였다.

## 2. 가스모니터링 시스템과 실험환경

실내대기 가스모니터링 및 센서의 고장진단 실험을 위해 제작한 시스템의 실험환경은 그림 1과 같이 가스 라인(gas bottles), 습도 발생기(saturator) 및 테스트 용기(chamber)로 구성되어 있다. 가스 라인은 혼합 공기와 MFC's(mass flow controllers)를 포함한 여러 가지 가스통으로 구성되며, 테스트 용기는 가스측정을 위한 TGS2611센서와 마이크로컨트롤러(MCU, MSP430 ultra-low power)로 이루어져 있다. 가스의 측정절차는 먼저, 건조한 혼합공기가 습도 발생기에 보내져 MFC's에 의해 조절된 원하는 목표 가스와 혼합되며, 이 혼합가스는 테스트 용기에 보내지게 되고, 마이크로컨트롤러가 주기적으로 TGS2611센서의 출력값을 읽어 RS232 통신을 통해 컴퓨터로 전송한다.

가스측정을 위한 TGS2611센서의 고장 원인으로는 크게 세 가지 유형을 들 수 있다. 첫 번째는 센서에 기름때가 흡착되는 경우로서 이는 센서의 감도를 떨어뜨려 오동작을 일으키는 원인이 된다. 두 번째는 센서 히터에 고전압이 인가되는 경우로서 히터 전극 부분의 손상으로 센서 노화 현상이 빨리 진행되는 원인이 된다. 세 번째는 센서가 습기에 노출된 경우로서 이는 오동작의 원인이 된다. 본 논문에서는 이 세 가지 유형의 고장을 인위적으로 발생시켜 TGS2611센서의 고장진단 실험을 행하여 실제 실험데이터를 획득하였다.

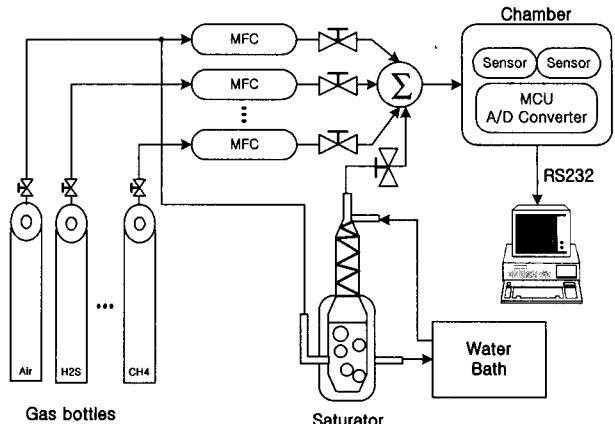


그림 1. 가스모니터링 실험장치

Fig. 1. Experimental set-up.

## 3. 신경회로망을 이용한 센서의 고장진단

신경회로망을 이용한 센서의 고장진단시스템의 구조는 그림 2와 같이 센서신호패턴을 입력으로 하여 센서에 발생된 고장의 종류를 분류하기 위한 여러 경계인수를 갖는 ART2 신경회로망 고장분류기와 센서신호패턴 추출을 위한 센서히터 온도조절방법에 의한 신호패턴 획득부로 구성이 된다.

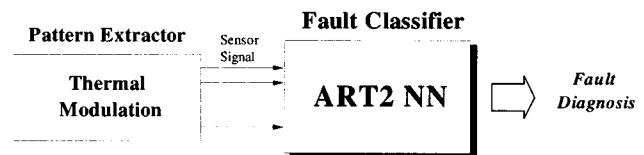


그림 2. ART2 신경회로망 기반 센서 고장진단시스템

Fig. 2. ART2 neural network-based sensor fault diagnosis system.

### 3.1 센서 고장진단 실험 환경 구축 및 센서패턴추출

가스센서는 동작온도에 크게 의존하므로 온도에 따른 센서의 감도의 차이를 이용하여 서로 다른 온도 대역에서 데이터를 획득한다면 대상 가스를 구분 및 진단을 위해서는 장점이 있다. 그러므로 본 논문에서는 데이터 획득을 위해 센서히터 온도 조절방법[16]을 사용하며, 이 방법의 장점으로는 하나의 센서를 사용하기 때문에 다양한 감지 물질을 사용하는 센서 어레이 방법에 비해 간단하고 안정적인 점을 들 수 있다. 이에 반해서 이 방법은 반응하는데 시간이 걸린다는 단점이 있다. 최근에는 이러한 단점을 보완하기 위해 마이크로센서가 연구중이며 마이크로센서는 열 전도도 막이 작고, 두께 또한 좁아서 열에 대한 반응이 매우 빠르다.

센서로부터 전기신호를 얻기 위해서 그림 3과 같은 회로를 사용하며 로드저항  $R_L$ 이 센서와 직렬로 연결되어 있다. 센서저항  $R_s$ 와 모니터 전압과의 관계는 아래와 같다.

$$R_s = R_L \left( \frac{V_c}{V_{RL}} - 1 \right) \quad (1)$$

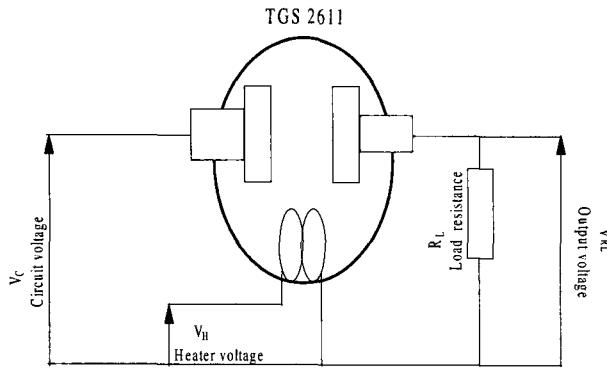


그림 3. 센서로부터 신호를 얻기 위한 아날로그 회로  
Fig. 3. Analog circuit for extracting sensor signals.

센서히터의 온도 조절 방식에 따른 데이터 획득을 위해 마이크로 컨트롤러가 보내는 일련의 측정 신호들은 그림 4와 같다. 즉, 센서히터의 온도는 마이크로 컨트롤러가 조절하며, 10초 동안 센서 히터를 가열한 후 히터 신호를 끄고, 100ms마다 센서에 부착된 로드 저항의 전압값을 읽어서 10개의 신호를 추출하고, 10초 동안 가열하면서 100ms마다 같은 방식으로 10개의 신호를 추출하므로써 총 20개의 데이터를 획득한다. 센서로부터 획득된 20개의 데이터를 ART2 신경회로망 고장분류기의 입력으로 사용하여 센서에서 발생한 고장을 분류한다.

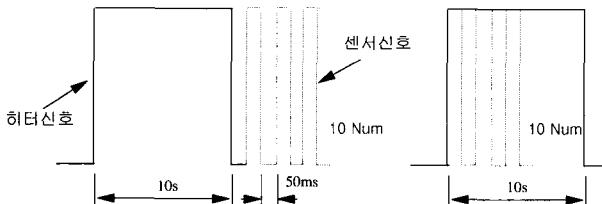


그림 4. 센서신호패턴 추출을 위한 마이크로 컨트롤러의 출력신호  
Fig. 4. MCU output signal for extracting sensor signal patterns.

TGS2611센서에 대해 다음과 같이 세 가지 고장 유형을 인위적으로 발생시켜 센서의 고장진단 실험을 실행하였다.

첫 번째 기름때 노출에 의한 센서의 고장실험으로서 가정 주방에서의 기름때로 인해 기름때가 이 센서에 흡착되면, 센서의 감도가 떨어져 오작동을 일으키는 원인이 된다. 실험은 먼저 TGS2611센서를 유리 시험관에 끼워놓고 알코올 램프로 시험관을 가열하여 증발하는 기름때에 20분간 노출시킨 후 공기상태에서 데이터를 받는다.

두 번째는 센서 히터에 고전압이 인가되는 고장으로서 주로 센서 히터 전원은 5V이나 갑자기 고전압이 인가되면 히터 전극 부분이 손상되어 센서의 노화 현상이 빨리 진행되는 원인이 된다. 실험은 센서 히터에 고전압 7V를 10분간 인가한 후 그에 따른 데이터를 측정한다.

세 번째는 센서가 습기에 노출된 고장으로서 반도체식 가스 센서는 습도에 의존하므로 많은 습기에 노출되면 또 다른 오작동의 원인이 된다. 실험은 센서를 뜨거운 증기애 20분간 노출시켜 데이터를 측정한다.

이와 같은 일련의 과정을 고장이 발생할 때까지 여러 번

반복하여 고장진단 실험을 위한 실제 데이터를 획득하였으며, 한 시점에 하나의 센서고장이 발생하는 단일고장을 가정하였다.

### 3.2 여러 경계인수를 갖는 ART2 신경회로망 고장분류기

ART2 신경회로망은 이미 학습된 패턴과 입력패턴간의 일치정도를 검사하기 위한 경계인수 검사를 통해 유사하면 같은 클래스로 학습하고, 그렇지 않으면 새로운 클래스를 생성시키는 증가 분류 알고리듬에 의해 패턴을 분류함으로써 추가 학습이 가능하다는 장점이 있다. 그러므로 ART2 신경회로망을 고장분류기로 사용한다면 예상하지 않은 새로운 고장이 발생했을 때 이를 효과적으로 분류할 수 있다. 본 절에서는 하나의 경계인수를 사용하는 기존의 ART2 신경회로망의 단점을 보완한 여러 경계인수를 갖는 ART2 신경회로망 [14]을 센서의 고장분류를 위한 고장분류기로 사용한다. 여러 경계인수를 갖는 ART2 신경회로망의 구조는 기존의 ART2 신경회로망과 같으나, 기존의 ART2 신경회로망에서 패턴을 분류할 때 하나의 경계인수를 사용함으로써 고장에 대한 각 시스템 파라미터의 민감도 차이를 고려하기 어려운 문제점을 보완하기 위해 새로운 거리측정 및 경계인수 조건을 사용한다.

여러 경계인수를 갖는 ART2 신경회로망은 그림 5와 같이 저장된 패턴과 유사한 입력에 대하여 반응을 하고 안정된 내부표현을 유지하기 위한 계층 1과 저장된 패턴과 유사성이 없는 패턴이 입력될 경우 새로운 클래스를 생성시키게 하는 계층 2로 구성된다. 최초의 입력 패턴이 ART2 신경회로망에 전달되면 첫 번째 클래스로 분류하여 입력패턴을 첫 번째 출력노드와 입력노드들간의 가중치로 저장한다.

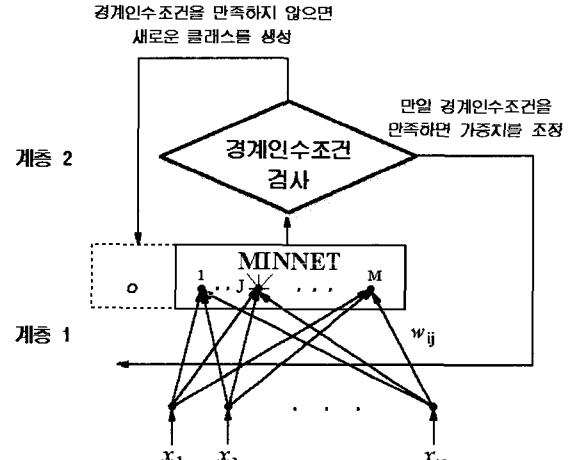


그림 5. ART2 신경회로망의 구조도  
Fig. 5. Architecture of the ART2 neural network.

새로운 입력패턴이 신경회로망에 전달되면 입력패턴과 각 출력노드와의 거리를 아래와 같이 계산한다.

$$d_i = \| W_i - X \|^E_{\infty} \quad i=1, 2, \dots, N, \\ \leq \max_i | \frac{1}{\varepsilon_i} (w_{ij} - x_i) |, \quad j=1, 2, \dots, M \quad (2)$$

여기서  $W_i$ 와  $w_{ij}$ 는 각각  $j$  번째 출력노드에 대한  $N$ 차원의

표 1. 센서신호패턴 및 고장진단결과  
Table 1. Sensor signal patterns and fault diagnosis results

고장종류	패턴번호	센서신호	ART2 신경회로망 진단결과
정상상태	P01	2099 2333 2309 2239 2163 2088 2016 1946 1877 1812 0520 0877 1126 1300 1428 1525 1602 1666 1721 1771	클래스 #1
고장 #1	P11	1904 2251 2294 2263 2211 2157 2102 2049 1998 1948 0422 0764 1039 1259 1432 1569 1676 1761 1832 1888	새로운 클래스 #2 생성
고장 #2	P21	2260 2482 2460 2404 2340 2277 2218 2160 2106 2054 0773 1224 1495 1658 1764 1836 1891 1937 1980 2017	새로운 클래스 #3 생성
고장 #3	P31	1739 2073 2117 2084 2032 1970 1910 1852 1796 1740 0403 0702 0926 1095 1224 1326 1409 1478 1537 1588	새로운 클래스 #4 생성

가중치벡터 및  $i$  번째 입력노드와  $j$  번째 출력노드 사이의 가중치이며,  $X$  와  $x_i$  는 각각  $N$  차원의 입력벡터 및  $i$  번째 입력이고  $N$  과  $M$  은 각각 입력노드 및 출력노드 수이다.

$\|\cdot\|_E^E$  는 가중치가 부여된 무한대 노음이며

$E = diag(\frac{1}{\varepsilon_1}, \frac{1}{\varepsilon_2}, \dots, \frac{1}{\varepsilon_N})$

로서  $N \times N$  차원의 대각 가

중치행렬이고,  $\varepsilon_i$  는  $i$  번째 입력노드의 입력패턴에 대한 경계인수로서 입력패턴 중에서 고장으로 인해 많이 변하는 파라미터에 대해서는  $\varepsilon_i$  를 크게 설정하고, 적게 변하는 경우에는 작게 설정하므로써 고장유형에 따른 각 파라미터의 민감도 차이를 충분히 고려한 분류가 가능하다.

출력노드중에서 (2)에 의해 계산된 거리가 최소인 노드만이 활성화되며, 입력패턴과 활성화된 출력노드에 대한 템플리트패턴과의 유사성은 계층 2에서의 경계인수조건 검사를 통해서 판별되는데 여러 경계인수를 갖는 ART2 신경회로망에서는 아래와 같은 경계인수 조건을 사용한다.

$$\text{경계인수조건} : \|W_j - X\|_{\infty}^E < 1 \quad (3)$$

여기서  $W_j$  는 활성화된  $J$  번째 출력노드에 관한  $N$  차원의 템플리트패턴벡터이며  $J$  는 활성화된 출력노드이다.

만일 입력패턴이 경계인수 검사를 통과하면 아래와 같은 가중치 조정식을 이용하여 같은 클래스로 학습한다.

$$W_j^{\text{new}} = \frac{X + W_j^{\text{old}} [class_j^{\text{old}}]}{[class_j^{\text{old}}] + 1} \quad (4)$$

여기서  $W_j^{\text{old}}$  와  $W_j^{\text{new}}$  는 각각  $J$  번째 출력 노드에서의 조정 전후의 가중치이며,  $[class_j]$  는  $class_j$  에 속한 패턴들의 개수이다. 그러나 경계인수 검사를 통과하지 못하면 입력패턴을 새로운 클래스로 저장한다.

#### 4. 시뮬레이션결과 및 고찰

가스모니터링 시스템에서 가스신호 획득을 위한 센서에 인위적으로 고장을 발생시켜 획득한 실제 데이터를 이용하여 본 논문에서 제시한 ART2 신경회로망 기반 고장진단방법의 성능을 평가하였다. 제안한 ART2 신경회로망 기반 센서고

장진단 알고리듬의 고장분류성능을 알아보기 위한 실험을 위한 ART2 신경회로망 고장분류기의 입력은 3.1절에서 설명한 바와 같이 TGS2611센서로부터 획득하여 12비트 A/D 변환한 신호 20개를 사용하였으며 고장분류를 위한 신경회로망 고장분류기의 경계인수 파라미터벡터

$$\varepsilon = 10 * [10, 7, 7, 7, 5, 5, 5, 5, 5, 4, 4, 5, 6, 6, 6, 6, 6, 5, 6, 5]$$

로 설정하였다.

TGS2611센서에 인위적으로 아래와 같이 고장을 발생시켜 센서의 고장진단 실험을 수행하였으며 고장진단 실험 및 데이터 측정을 위해 제작한 보드는 그림 6과 같다.

고장 #1 : 기름때 노출로 인해 센서에 기름때 흡착

고장 #2 : 센서 히터에 고전압 인가

고장 #3 : 습기에 노출

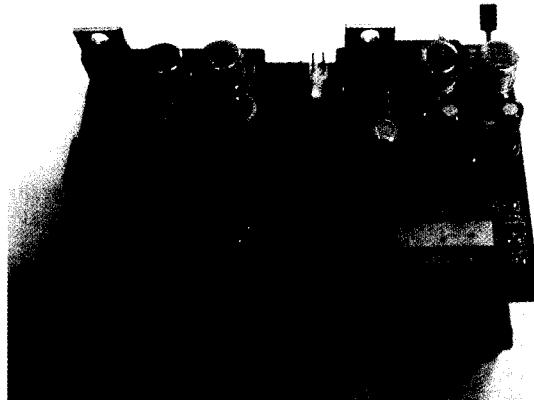


그림 6. 센서고장진단 테이타 측정보드  
Fig. 6. Measurement board for sensor fault diagnosis.

표 1과 같은 정상상태, 고장 #1, 고장 #2 및 고장 #3의 센서고장패턴에 대한 결과가 그림 7, 8 및 9에 각각 도시되어 있다. 그림 7은 센서가 정상상태(P01)이다가 150번째 순간에 센서에 고장 #1(P11)이 발생한 경우의 고장진단결과를 도시한 것으로서 고장 #1 패턴 P11이 ART2 신경회로망에 입력되면 클래스 #1(정상상태)과의 경계인수검사를 통과하지 못하여 자동으로 새로운 고장클래스 #2를 생성시키고 새로운 고장으로 선언함을 알 수 있다. 다음으로 150번째 순간에 센서에

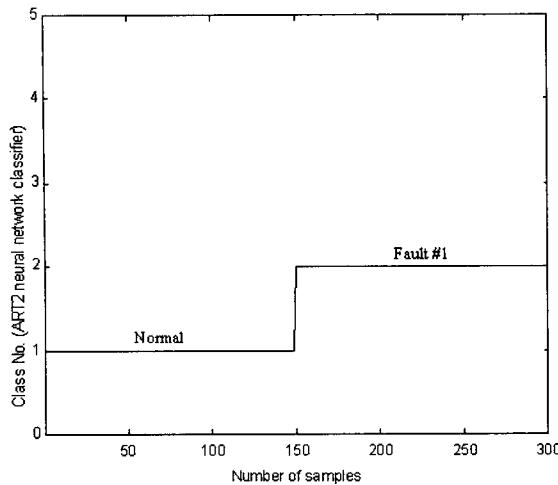


그림 7. 고장 #1에 대한 고장진단결과  
Fig. 7. Result of fault diagnosis for fault #1.

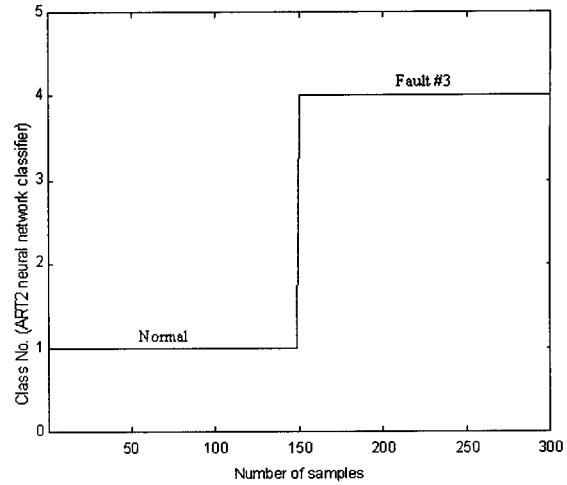


그림 9. 고장 #3에 대한 고장진단결과  
Fig. 9. Result of fault diagnosis for fault #3.

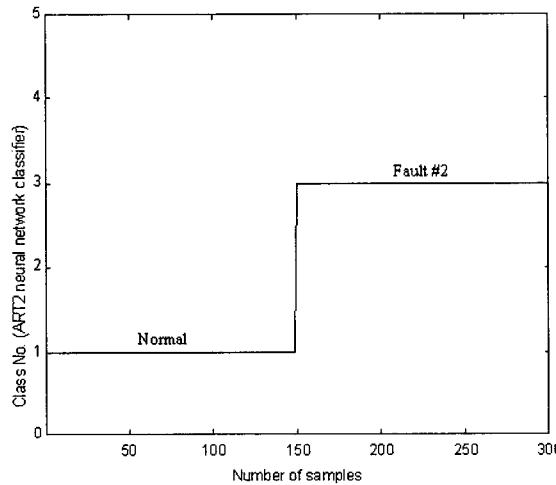


그림 8. 고장 #2에 대한 고장진단결과  
Fig. 8. Result of fault diagnosis for fault #2.

새로운 고장 #2가 발생한 경우의 고장진단 결과가 그림 8에도 시도되어 있으며 새로운 고장클래스 #3을 생성시킴을 알 수 있다. 마지막으로 150번째 순간에 센서에 새로운 고장 #3이 발생한 경우의 고장진단 결과는 그림 9와 같으며, 현재 발생한 센서의 고장을 새로운 고장으로 인식하여 고장클래스 #4를 자동 생성시킴을 알 수 있다.

표 1의 실제 실험 데이터를 이용하여 고장진단을 수행한 결과 ART2 신경회로망에 네 개의 고장클래스(고장클래스 #1은 시스템이 정상상태인 경우, 고장클래스 #2는 고장 #1에 대한 클래스, 고장클래스 #3은 고장 #2에 대한 클래스, 고장클래스 #4는 고장 #3에 대한 클래스)가 생성된 뒤 다시 150 번째 순간에 표 2와 같은 각 고장에 대한 실제 데이터를 이용하여 센서의 고장진단을 수행하였으며, 고장진단 결과는 표 2와 같다. 즉, 정상상태 패턴 (P02~P10)이 입력되면 이 패턴들은 경계인수검사를 통하여 고장클래스 #1로 분류됨을 알 수 있다. 다음으로 고장 #1 패턴 (P12~P20)이 입력되면 이 패턴들은 클래스 #2와의 경계인수검사를 통하여 고장클래스 #2로 분류되어 현재의 센서의 상태를 고장 #1로 진단함을 알 수 있다. 마찬가지로 고장 #2 패턴 (P22~P30)과 고장 #3 패턴 (P32~P40)이 입력되면 각각 고장클래스 #3과 #4로 분류됨을 알 수 있다.

표 2. 센서신호패턴 및 고장진단결과  
Table 2. Sensor signal patterns and fault diagnosis results

고장종류	패턴번호	센서신호	ART2 신경회로망 진단결과
정상상태	P02	2108 2339 2315 2244 2168 2093 2020 1950 1882 1816 0526 0884 1134 1308 1436 1532 1609 1673 1728 1778	클래스 #1
	P03	2111 2342 2318 2247 2170 2095 2022 1951 1882 1818 0526 0886 1135 1311 1439 1535 1613 1676 1729 1780	클래스 #1
	P04	2121 2348 2323 2252 2176 2099 2027 1955 1888 1822 0529 0891 1141 1316 1444 1539 1616 1679 1734 1784	클래스 #1
	P05	2123 2349 2325 2253 2177 2100 2027 1957 1890 1822 0532 0895 1145 1321 1448 1544 1620 1683 1739 1787	클래스 #1
	P06	2158 2377 2345 2273 2195 2119 2043 1974 1904 1838 0546 0915 1167 1343 1469 1564 1639 1702 1756 1806	클래스 #1
	P07	2164 2382 2349 2276 2197 2121 2048 1976 1907 1840 0549 0918 1171 1347 1473 1567 1642 1704 1760 1808	클래스 #1
	P08	2168 2384 2352 2277 2199 2123 2048 1978 1908 1842 0549 0920 1173 1349 1474 1570 1644 1707 1761 1811	클래스 #1

표 2. 계 속  
Table 2. continued

고장종류	패턴번호	센서신호	ART2 신경회로망 진단결과
정상상태	P09	2176 2388 2355 2280 2202 2125 2051 1981 1911 1844 0552 0923 1178 1354 1479 1574 1649 1710 1765 1814	클래스 #1
	P10	2181 2393 2360 2285 2206 2128 2056 1983 1915 1848 0556 0929 1184 1359 1484 1579 1654 1715 1770 1818	클래스 #1
고장 #1	P12	1912 2258 2300 2267 2216 2160 2106 2053 2001 1951 0426 0770 1047 1267 1440 1577 1684 1770 1838 1895	클래스 #2
	P13	1920 2263 2303 2270 2218 2163 2107 2054 2003 1953 0428 0774 1051 1272 1445 1582 1689 1774 1842 1898	클래스 #2
	P14	1926 2270 2308 2274 2222 2166 2111 2057 2006 1957 0432 0780 1058 1279 1452 1588 1695 1780 1848 1904	클래스 #2
	P15	1934 2274 2312 2278 2225 2169 2114 2061 2008 1958 0433 0783 1062 1283 1457 1592 1698 1783 1851 1907	클래스 #2
	P16	1968 2299 2333 2295 2241 2183 2127 2074 2020 1970 0445 0802 1084 1306 1480 1613 1718 1800 1867 1922	클래스 #2
	P17	1976 2305 2335 2297 2243 2185 2128 2074 2022 1971 0449 0808 1091 1314 1487 1621 1726 1807 1873 1928	클래스 #2
	P18	1979 2307 2338 2300 2243 2186 2130 2075 2024 1972 0450 0809 1093 1316 1489 1623 1727 1809 1875 1929	클래스 #2
	P19	1983 2311 2341 2301 2247 2189 2133 2077 2025 1975 0453 0813 1098 1321 1494 1627 1731 1812 1878 1932	클래스 #2
	P20	1990 2315 2345 2304 2249 2191 2134 2079 2027 1977 0455 0817 1103 1326 1499 1633 1736 1817 1882 1935	클래스 #2
	P22	2266 2490 2468 2407 2343 2279 2220 2164 2110 2057 0774 1227 1495 1658 1763 1836 1893 1939 1980 2017	클래스 #3
고장 #2	P23	2272 2493 2471 2411 2348 2286 2226 2166 2111 2060 0776 1230 1496 1660 1764 1840 1895 1940 1981 2016	클래스 #3
	P24	2276 2495 2471 2410 2348 2284 2226 2170 2113 2060 0774 1227 1495 1660 1766 1840 1894 1938 1980 2018	클래스 #3
	P25	2280 2500 2475 2413 2349 2288 2228 2172 2116 2064 0776 1229 1499 1662 1767 1840 1895 1941 1980 2018	클래스 #3
	P26	2300 2518 2489 2430 2364 2299 2239 2181 2130 2074 0794 1254 1522 1683 1787 1860 1913 1959 2000 2036	클래스 #3
	P27	2302 2515 2490 2426 2366 2302 2243 2183 2128 2074 0797 1258 1526 1690 1791 1863 1918 1961 2002 2038	클래스 #3
	P28	2310 2521 2493 2434 2365 2303 2242 2187 2132 2080 0801 1262 1530 1690 1794 1866 1918 1966 2005 2041	클래스 #3
	P29	2312 2522 2495 2434 2369 2310 2247 2190 2134 2080 0804 1266 1534 1695 1796 1867 1922 1970 2010 2046	클래스 #3
	P30	2315 2527 2498 2438 2374 2310 2247 2190 2133 2080 0803 1266 1532 1693 1795 1867 1922 1968 2006 2044	클래스 #3
	P32	1744 2076 2118 2084 2032 1972 1912 1854 1796 1738 0404 0703 0927 1096 1224 1328 1409 1478 1537 1588	클래스 #4
	P33	1749 2082 2123 2087 2034 1975 1916 1858 1798 1742 0404 0703 0927 1094 1224 1328 1410 1477 1536 1587	클래스 #4
고장 #3	P34	1749 2084 2128 2091 2036 1975 1916 1858 1801 1744 0404 0705 0928 1096 1228 1330 1412 1480 1538 1590	클래스 #4
	P35	1759 2089 2130 2096 2039 1980 1920 1862 1806 1748 0407 0708 0931 1100 1230 1332 1415 1483 1542 1592	클래스 #4
	P36	1788 2114 2149 2114 2058 1998 1936 1875 1818 1759 0420 0728 0955 1125 1255 1358 1437 1507 1566 1616	클래스 #4
	P37	1792 2118 2151 2113 2058 1996 1936 1876 1818 1761 0422 0732 0960 1131 1261 1362 1442 1510 1570 1620	클래스 #4
	P38	1795 2122 2158 2117 2061 2002 1940 1879 1822 1763 0424 0735 0964 1136 1266 1367 1447 1515 1572 1623	클래스 #4
	P39	1802 2126 2158 2121 2065 2006 1943 1884 1826 1767 0426 0739 0966 1137 1268 1369 1451 1520 1578 1626	클래스 #4
	P40	1803 2126 2158 2122 2066 2004 1942 1883 1824 1766 0424 0736 0966 1136 1265 1366 1447 1514 1572 1623	클래스 #4

## 5. 결 론

본 논문에서는 실내대기에서의 가스누출 여부 및 종류를 알아내기 위한 가스모니터링 시스템에서의 센서 고장진단을 위해 신경회로망 기반 고장진단방법을 제안하였다. 제안한

고장진단방법에서는 예기치 않은 새로운 고장상태도 분류하기 위해서 여러 경계인수를 갖는 ART2 신경회로망을 이용하였으며, 고장진단분류를 위한 신호패턴추출을 위해 센서히터 온도조절방법을 이용하였다. 가스모니터링 시스템에서의 실험 데이터를 이용한 시뮬레이션을 통해 제안한 신경회로망 기반 센서고장진단방법이 가스모니터링 시스템에서의 센서고장진단에 잘 적용됨을 알 수 있었다.

그러므로 제안한 센서의 고장진단방법을 실제 가스모니터링 시스템에 적용하여 운용한다면 시스템의 신뢰성 향상에 크게 기여할 것으로 기대한다. 앞으로 남은 과제는 다중고장 상황에서의 고장진단방법에 대한 연구와 실제 대기 상태모니터링 시스템에 적용하여 운용하는 것이다.

### 참고문헌

- [1] W. Gopel, "Chemical imaging: Concepts and visions for electronic and bio-electronic noses," *Sens. Actuators B*, vol. 52, pp. 125-142, 1998.
- [2] C. Delpha, M. Siadat, and M. Lumbreiras, "Identification of Forane R134a in an air conditioned atmosphere with a TGS sensor array," *IEEE Trans. on Instrumentation and Measurement*, vol. 50, pp. 1370-1374, 2001.
- [3] E. Y. Chow and A. S. Willsky, "Analytical redundancy and the design of robust failure detection systems," *IEEE Trans. Automat. Contr.*, vol. AC-29, no. 7, pp. 603-614, 1984.
- [4] R. Patton, P. Frank and R. Clark, *Fault Diagnosis in Dynamic Systems: Theory and Application*, Prentice Hall, 1989.
- [5] M. A. Massoumnia, "A geometric approach to the synthesis of failure detection filters," *IEEE Trans. Automat. Contr.*, vol. AC 31, no. 9, pp. 839-846, 1986.
- [6] M. M. Polycarpou and A. T. Vemuri, "Learning methodology for failure detection and accommodation," *IEEE Contr. Syst. Mag.*, pp. 16-24, 1995.
- [7] C. H. Dagli, *Artificial Neural Networks for Intelligent Manufacturing*, Chapman and Hall, 1994.
- [8] E. Eryurek and B. R. Upadhyaya, "Sensor validation for power plants using adaptive back propagation neural network," *IEEE Trans. Nuclear Science*, vol. 37, no. 2, pp. 1040-1047, 1990.
- [9] L. I. Burke, "Competitive learning based approaches to tool-wear identification," *IEEE Trans. Syst., Man and Cybern.*, vol. 22, no. 3, pp. 559-563, 1991.
- [10] T. Sorsa and H. N. Koivo, "Application of artificial neural networks in process fault diagnosis," *Automatica*, vol. 29, no. 4, pp. 843-849, 1993.
- [11] M. Pardo, G. Faglia, G. Sberveglieri, M. Corte, F. Masulli and M. Riani, "Monitoring reliability of sensors in an array by neural networks", *Sens. Actuators B*, vol. 67, pp. 128-133, 2000.
- [12] M. A. Kramer and J. A. Leonard, "Diagnosis using backpropagation neural networks analysis and criticism," *Computers Chem. Engng.*, vol. 14, no. 12, pp. 1323-1338, 1990.
- [13] A. Srinivasan and C. Batur, "Hopfield/ART-1 neural network-based fault detection and isolation," *IEEE Trans. Neural Networks*, vol. 5, no. 6, pp. 890-899, 1994.
- [14] 이인수, 신필재, 전기준, "ART2 신경회로망을 이용한 선형 시스템의 다중고장진단", *제어·자동화·시스템공학회 논문지*, 제 3권, 제 3호, pp. 244-251, 1997.
- [15] S. Y. Kung, *Digital Neural Networks*, Prentice Hall, 1993.
- [16] A. P. Lee and B. J. Reedy, "Temperature modulation in semiconductor gas sensing," *Sens. and Actuators B*, vol. 60, pp. 35-42, 1999.

### 저자소개



이인수

1963년 4월 16일 생  
1986년 경북대학교 전자공학(공학사).  
1989년 동대학원 졸업(공학석사).  
1997년 동대학원 졸업(공학박사).  
1997년~현재 상주대학교 전자전기공학부  
부교수.

관심분야 : 시스템의 고장진단 및 고장허용제어, 지능제어 및 응용, 지능형센서시스템 등



조정환

2001년 경상대학교 제어계측공학과  
(공학사).  
2003년 경북대학교 대학원 전자공학과  
(공학석사).  
2003년~현재 동대학원 박사과정.

관심분야 : 지능형센서시스템, 패턴인식, 신경망, 퍼지, 임베디드 시스템



심창현

1967년 1월 6일 생  
1989년 경북대학교 전자공학과 졸업  
(공학사)  
1993년 동대학원 졸업(공학석사)  
2003년 동대학원 졸업(공학박사)  
1994~1996 (주)유진LED 생산책임자  
1998~1999 KAIST 미세정보시스템 연구  
센터 위촉연구원  
2002~현재 (주)센스엔센서 대표이사



**이덕동**

1942년 12월 21일 생  
1966년 경북대학교 물리학과 졸업(이학사)  
1974년 경북대학교 대학원 전자공학과 졸업  
(공학석사)  
1984년 연세대학교 대학원 전자공학과 졸업  
(공학박사)  
1974~현재 경북대학교 전자전기컴퓨터학부  
교수

1979~1980 Stanford University 교환교수

1981~1982 Cornell University 교환교수

1995~1997 경북대학교 전자기술연구소 소장

2000~2002 경북대학교 공대 학장

2002~현재 한국센서학회 회장



**전기준**

1969년 서울대학교 공과대학 공학사  
1978년 University of Houston 전기공학과  
공학석사  
1983년 University of Houston 전기공학과  
공학박사  
1996~1997년 Purdue University 방문교수  
2002~2004년 한국과학재단 전문위원  
1983~현재 경북대학교 전자전기컴퓨터학부 교수

관심분야 : 지능시스템제어, 고장진단시스템, 최적 및 적응제어