

인공신경망을 이용하여 하드웨어 다중 센서 신호 검증을 위한 패리티 공간 및 패턴인식 방법

Parity Space and Pattern Recognition Approach for Hardware Redundant System Signal Validation using Artificial Neural Networks

윤태섭
(Tae Seob Yoon)

Abstract : An artificial neural network(NN) technique is developed for hardware redundant sensor validation. Since the measurement space is a continuous space with many operating regions, it is difficult to train a NN to correctly detect failure in an accurate measurement system. A conventional backpropagation NN is modified to include an additional preprocessing layer that extracts classification features from scalar measurements. This feature extraction means transform the measurement space to parity space. The NN is independant of the state variable being measured, the instrument range, and the signal tolerance. This NN resembles the parity space approach to signal validation, except that analytical parity equations are unneeded and the NN pattern recognition capability is utilized for decision making.

Keywords : hardware redundancy, parity space, neural network, feature extraction, pattern recognition, fault detection and isolation

I. 서론

항공기, 화학플랜트, 원자력발전소 등과 같이 복잡한 대단위 시스템은 체르노빌 핵발전소 사고와 같은 중대한 재앙이나 경제적 피해로부터 보호하기 위해 적절한 온라인 고장진단 방법을 적용한다. 이러한 시스템의 안전성, 가용성, 신뢰성을 높이기 위해 지난 수십 년 동안 수많은 방법이 개발되었다. 이와같은 방법중의 하나가 하드웨어 다중 (hardware redundancy) 시스템이다. 하드웨어 다중 시스템에서는 여러 개의 센서가 온도, 압력, 속도와 같은 한가지 물리적 현상을 측정한다. 여러개 센서의 측정값이 일치하면 모든 센서 신호가 유효한 것이고, 한 개의 센서가 다른센서 값으로부터 정해진 범위(tolerance)를 벗어나면 그 센서 값은 유효하지 않다. 하드웨어 다중 시스템을 이용한 고장 탐지 및 분리 (fault detection and isolation: FDI) 방법은 중간 값 신호 선택, 투표(voting)와 같은 단순한 기술[1]에서부터 패리티 공간 방법[2]과 같은 시스템적 접근 방법도 있다.

패리티 공간 방법은 항공기 시스템의 관성항법장치 및 원자력발전소의 비정상적 측정값에 성공적으로 적용되었다. 그러나 패리티 방정식을 이용하는 분석적 패리티 방법은 시스템의 정확도에 근본적인 문제가 있다. 센서값의 tolerance가 큰 경우에는 별문제가 없지만 정밀도가 높은 측정값에는 심각한 문제를 발생시킬 수 있다. 즉 패리티 공간 방법에서 고장이 없는 영역은 정육각형이므로 패리티 벡터의 방향에 따라 tolerance 가 일정하지 않다. tolerance의 최대값은 정육각형의 외접원이고 최소값은 내접원이다. 고장탐지가 중대한 시스템은 최소값을 사용하고, 효율성이 중시되는 시스템은 최대값을

사용하지만 일반적으로는 최대값과 최소값의 평균값을 사용한다. 그러나 하드웨어 다중 센서 시스템을 적용하는 시스템은 안전성과 효율성이 동시에 요구되므로 정확한 값을 사용해야 한다.

최근에는 인공신경망이 패턴인식에 성공적으로 사용되며 고장진단에도 적용 가능한 기술로 등장하였다. 인공신경망을 지난 수년동안 시스템 고장 진단에 적용하는 연구가 활발하게 진행되었다[3]. 인공신경망은 프로세스모델이 필요없이 학습 데이터에 포함된 정보를 이용하므로 비선형 및 프로세스 모델이 알려지지 않은 프로세스도 처리할 수 있다. Kramer와 Leonard는 고장진단에서 백 프로파게이션 (back-propagation) 의 문제점을 바판하고 거리기반(distance-based) 인식기가 현실적 환경에서 적합하다고 제시하였다[4]. 그들의 바판은 학습 데이터의 양이 부족하고 불완전한 점에 중점을 두었다.

측정 공간에서는 측정값이 연속적인 값을 가지므로 무한정한 수의 측정값이 존재한다. 본 연구에서는 패리티 공간에서의 부정확한 tolerance 문제와 인공 신경망에서의 학습 데이터 문제를 해결하기 위해 측정 데이터를 인공신경망에 적용하기 전에 패리티 공간으로 변환하는 패리티 공간 변환 함수를 개발하였다. 이 변환 과정은 패턴인식을 하기 위한 일종의 특징 추출 과정이다. 이 변환과정은 센서 값의 거리에 기준을 두고 패리티 방정식을 이용하지 않고 측정 데이터에서 직접 패리티 공간으로 변환한다. 패리티 공간에서는 센서의 수에 따라 일정한 수의 공간으로 분할되므로 필요한 학습 데이터의 수가 적고, 또한 시스템의 실제 측정값에 상관없이 인위적으로 쉽게 만들 수 있다. 또한 신경망의 학습이 매우 쉽고 학습 후에는 결과도 매우 정확하다. 예를들면 3중 센서의 패리티 공간은 19개 영역으로 분할되고 19개의

학습 데이터를 인위적으로 준비하므로 구현하기가 매우 쉽고 정확하다. 이 방법의 다른 장점은 물리적인 측정 값의 종류나 크기에 양관없이 센서의 수에만 관련되므로 한번 구현한 신경망은 모든 시스템에 그대로 적용할 수 있다.

II. 패리티 공간 방법

패리티라는 용어는 디지털 통신 시스템에서 데이터의 여분의 정보를 나타내는 비트를 패리티 비트라 하며 예러를 탐지하고 정정하는데 처음으로 사용되었다.

센서 신호 점검 분야에서는 여분은 한가지 물량을 측정하기 위해 여러센서를 사용하는 시스템을 하드웨어 다중 시스템 (hardware redundancy) 이라 하고, 시스템 분석을 통하여 추가 정보를 구하는 방법을 분석적 여분 (analytical redundancy)이라 한다. 다중센서 패리티 공간 방법은 패리티 방정식을 사용하여 패리티 벡터를 구하고, 벡터 성분들을 분석하여 고장 유무를 판단하고 고장요소를 찾아내어 분리시킨다. 패리티 방정식을 이용하여 패리티 벡터를 구하는 방법을 소개하고 이 방법의 문제점을 분석한다.

패리티 공간 방법은 Patton 과 Chen[2]에 의하여 상세히 고찰되었고 다중 하드웨어 패리티 공간 방법은 Ray와 Luck[5]에 의하여 자세히 논의되었다. 1개의 다중 센서가 n -차원 상태 벡터에 적용되는 경우를 고려하면

$$y = Cx + e \quad (1)$$

여기서 y 는 $l \times 1$ 측정 벡터이고, C 는 $l \times n$ 측정 행렬, x 는 $n \times 1$ 상태벡터이고 e 는 $l \times 1$ 측정에러 벡터이다. 스칼라 변수에서는 n 은 1이다. 여기서 패리티 방정식은 스칼라 함수 $f(\cdot)$ 이고 선형함수라고 가정하고 (1)에 적용하면 다음 식을 얻는다.

$$f(y) = f(Cx + e) = f(Cx) + f(e) \quad (2)$$

패리티 방정식의 다음조건을 만족시켜야 한다.

$$f(Cx) = 0 \quad (3)$$

에러 e 의 영향이 시스템 상태 벡터 x 와 독립적이면 (2)는 다음과 같이 된다.

$$f(y) = f(Cx + e) = f(Cx) + f(e) = f(e) \quad (4)$$

이러한 요구조건은 $f(\cdot)$ 를 선형이고 행렬 형태로 다음과 같이 표현할 수 있다.

$$f(y) = Vy = V(Cx + e) = VCx + Ve. \quad (5)$$

행렬 V 는 행렬 C 에 직교이며 다음과 같이 정의된다.

$$VC = 0 \quad (6)$$

V 는 $(l-n) \times l$ 행렬이며 프로젝션 행렬이라 한다. 행렬 V 는 다음조건을 만족시키는 직교 단위행렬이라 하면 다음 조건을 만족시킨다.

$$VV^T = I_{l-n} \quad (7)$$

행렬 V 를 얻기 위해서는 (7)에 $(l-n)l$ 개의 미정요소가 있고 $(l-n)l$ 개의 방정식이 필요하다. (7)에서 $(l-n)(l-n+1)/2$ 개의 방정식을 얻을 수 있으므로 알려지지 않은 요소는 다음과 같다.

$$(l-n)l - (l-n)n - (l-n)(l-n+1)/2 \\ = (l-n)(l-n-1)/2 \quad (8)$$

행렬 V 의 $(l-n)(l-n-1)/2$ 요소를 임의로 정할 수 있으므로 대각요소의 아래부분은 0으로 하면 다음식을 얻는다.

$$V = \begin{bmatrix} v_{11} & \cdot & \cdot & v_{1l} \\ 0 & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot \\ 0 & 0 & 0 & v_{(l-n)l} \end{bmatrix}, \quad (9)$$

패리티 벡터 P 는 다음과 같이 정의한다

$$P = Vy = VCx + Ve = Ve \quad (10)$$

패리티 벡터가 구해지면 고장 판단 방법이 적용된다. 패리티벡터의 단일 표본 또는 이동평균에 대한 단순한 tolerance 시험, GLR(Generalized Likelihood) 및 SPRT(Sequential Probability Ratio Test) 방법등이 적용된다. 스칼라 양을 측정하는 3중 센서를 고려하면 $l=3$, $n=1$ 이다. 측정행렬 $C = [1 \ 1 \ 1]^T$ 이고 프로젝션 행렬 V 는 다음과 같다.

$$V = \begin{bmatrix} v_{11} & v_{12} & v_{13} \\ 0 & v_{22} & v_{23} \end{bmatrix} \quad (11)$$

직교특성에 의하여 2개의식이 얻어진다.

$$v_1 C = v_{11} + v_{12} + v_{13} = 0 \quad (12)$$

$$v_2 C = v_{21} + v_{22} + v_{23} = 0 \quad (13)$$

V 는 직교단위 행렬이므로 3개의 식이 얻어진다.

$$v_1^T v_1 = v_{11}^2 + v_{12}^2 + v_{13}^2 = 1 \quad (14)$$

$$v_2^T v_2 = v_{21}^2 + v_{22}^2 + v_{23}^2 = 1 \quad (15)$$

$$v_1^T v_2 = v_{11} v_{21} + v_{12} v_{22} + v_{13} v_{23} = 0 \quad (16)$$

5개의 식과 $v_{21}=0$ 이므로 프로젝션 행렬은 다음과 같아 된다.

$$V = \begin{bmatrix} \frac{2}{\sqrt{6}} & -\frac{1}{\sqrt{6}} & -\frac{1}{\sqrt{6}} \\ 0 & \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix} \quad (17)$$

패리티 벡터는 다음과 같이 얻어진다.

$$P = Vy = v_1^T y_1 = v_2^T y_2 = v_3^T y_3 \quad (18)$$

패리티 벡터는 특정 고장 센서와 관련된 고정된 방향을 가지므로 고장 센서는 쉽게 구별된다. 즉 패리티 벡터와 각 에러벡터와의 내적을 구하여 가장 큰값을 가지는 센서가 고장난 것이다. 그림 1에 패리티 벡터와 고장방향을 나타내었다. 센서 1에 고장이 발생하면 패리티 벡터는 e_1 방향으로 증가한다. 그림 2는 측정공간에서의 에러 허용 영역을 나타낸다.

그림 1의 분할된 패리티 공간은 그림 2의 에러 영역과 일치한다. 그림 1의 에러가 없는 영역은 정육각형 내부이고 그림 2에서는 점선으로 표시된 정육면체 내부이다. 그림 1의 각 공간은 그림 2의 각부분과 대응된다. 다만 그림 1에서는 3개의 센서가 모두 장애가 발생했을 때가 나타나지 않는다. 그림 2의 각 공간은 센서값의 상태

적인 배치를 나타낸다. 즉 정상적인 센서, 아래로 벗어난 센서, 위로 벗어난 센서 등 비교적 자세한 정보를 보여준다. 그렇지만 우리가 이용하는 정보는 벡터의 크기가 tolerance를 초과하는지 비교하고, 벡터와 에러축과의 내적에 의한 고장난 센서를 찾는 것 뿐이다. 이와같은 단점을 해결하기 위해 그림 1의 각 영역은 삼각형이므로 각각 3개의 직선의 식으로 나타내고 패리티 벡터의 방향과 크기를 계산하여 패리티 벡터가 위치하는 공간을 찾아내면 더욱 자세한 정보를 얻을 수 있으나 매우 복잡하고 정확도도 떨어지므로 실용성이 없다. 여기서 에러가 없는 영역은 정육각형이므로 각 방향에 따라 에러발생

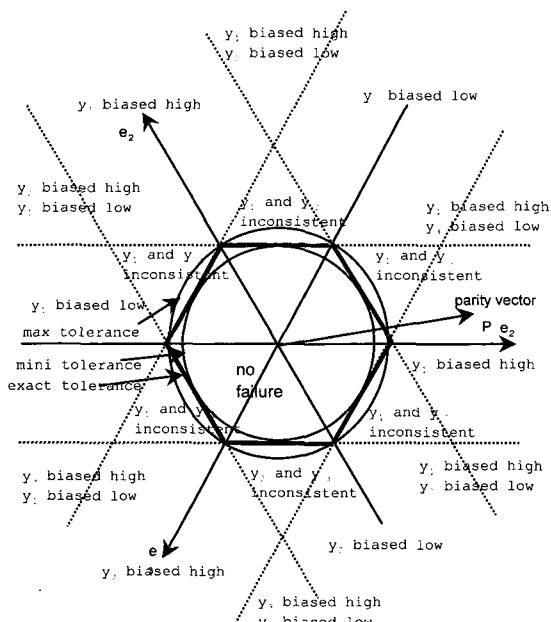


그림 1. 스칼라 양을 측정하는 3중센서의 고장방향과 패리티 공간의 분할영역들.

Fig. 1. Fault signature directions and division regions in the parity space for 3 redundant measurements of a scalar variable[6].

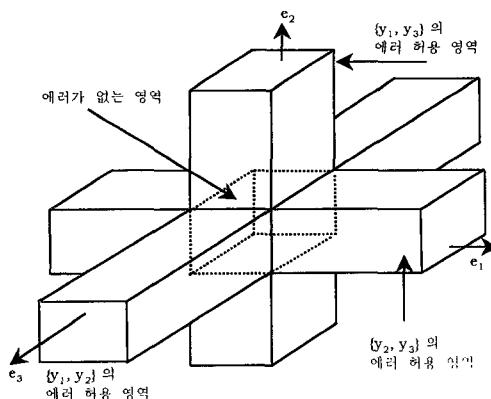


그림 2. 스칼라 양을 측정하는 3중센서의 에러 허용 영역.

Fig. 2. Allowable error regions in the measurement space for 3 redundant measurements of a scalar variable[6].

tolerance가 일정하지 않다. 따라서 패리티 벡터의 방향을 계산하고 그방향에 따른 에러발생 tolerance를 계산하여야 한다.

그러나 이 방법도 복잡하고 어려우므로 현실적으로는 정육각형의 내접원 또는 외접원을 사용한다. 내접원은 최소 값으로 미탐지 경보(missed alarm)가 중요한 시스템에서 사용하고, 외접원은 최대값으로 허위경보(false alarm)가 중요한 시스템에서 사용한다. 그러나 두 가지 경우를 타협하여 평균값을 사용하는 수도 많지만 정확한 정육각형을 사용할 수 있다면 시스템의 안전성과 효율성을 높일 수 있을 것이다. 여기서 최대, 최소 및 평균 tolerance는 다음과 같이 구할 수 있다.

$$T_{APS}^{\max} = \frac{2}{\sqrt{6}} \times T_{mes} = 0.8165 \times T_{mes} \quad (19)$$

$$T_{APS}^{\min} = \frac{\sqrt{3}}{2} \times T_{APS}^{\max} = \frac{\sqrt{3}}{2} \times \frac{2}{\sqrt{6}} \times T_{mes} = 0.7071 \times T_{mes} \quad (20)$$

$$T_{APS}^{\text{avg}} = \frac{(T_{APS}^{\max} + T_{APS}^{\min})}{2} \times T_{mes} = 0.7618 \times T_{mes} \quad (21)$$

여기서 T_{mes} 은 측정공간의 tolerance

T_{APS}^{\max} 은 패리티 공간의 최대 tolerance

T_{APS}^{\min} 은 패리티 공간의 최소 tolerance

T_{APS}^{avg} 은 패리티 공간의 평균 tolerance

III. 패턴인식 방법

그림 1의 패리티 공간은 19개의 영역을 가지고 있고 각 영역은 센서의 상태를 나타내므로 각 센서의 상태를 패턴으로 나타내어 인공신경망을 이용한 패턴인식 방법을 적용할 수 있다. 먼저 그림 1의 센서 상태를 다른 방법으로 표현하면 표 1과 같이 된다. 먼저 센서의 상태에 패턴을 다음과 같은 방법으로 할당한다.

센서 i 가 정상보다 높은 값일 때 $\rightarrow O_i = +1$

센서 i 가 정상일 때 $\rightarrow O_i = 0$

센서 i 가 정상보다 낮은 값일 때 $\rightarrow O_i = -1$

각 센서는 $-1, 0, +1, 3$ 가지 상태를 가지고 3개의 숫자로 나타내므로 $3^3 = 27$ 개의 패턴을 표현할 수 있으나 테이블 1에서 7번에서 12번까지의 패턴은 14번에서 19번까지의 패턴과 동일하므로 테이블2와 같이 4번째 숫자를 추가하여 패턴을 나타낸다. 표 1은 측정공간의 패턴이므로 패리티 공간으로 변환해야 한다. 패리티 공간은 센서간의 거리에 따라 그림 1의 패리티 공간 영역이 결정되므로 센서간의 거리에 따라 측정공간에서 패리티 공간으로 변환하는 함수를 개발하여야 한다. 조합 가능한 센서간의 거리 d_k 는 다음과 같이 계산된다.

$$d_k = |y_i - y_j| \quad \text{여기서 } i=1,2,3\dots N, i \neq j \quad (22)$$

3중 센서간의 거리를 다음과 같이 나타낼 수 있다.

$$d_1 = |y_1 - y_2| \quad (23)$$

$$d_2 = |y_1 - y_3| \quad (24)$$

$$d_3 = |y_2 - y_3| \quad (25)$$

페리티 공간의 벡터를 v_k 라 하면 센서간의 거리 절대값이 $|d_k|$ 가 tolerance 보다 작으면 0이 되고, d_k 가 tolerance 보다 작으면 -1, tolerance 보다 크면 1이 된다. 측정 공간에서 페리티 공간으로 변환하는 수식은 다음과 같고 그림 3과 같이 나타낼 수 있다[7].

$$|d_k| < tol \rightarrow v_k = 0 \quad (26)$$

$$d_k \leq -tol \rightarrow v_k = -1 \quad (27)$$

$$d_k \geq tol \rightarrow v_k = 1 \quad (28)$$

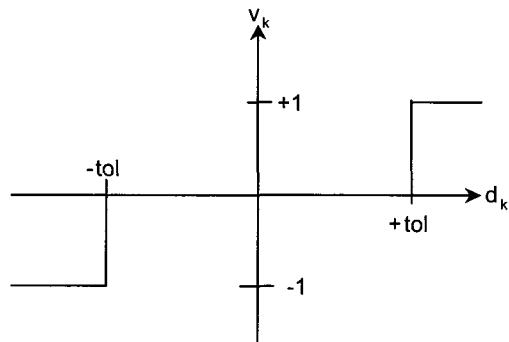


그림 3. 측정공간을 페리티 공간으로 변환하는 함수.

Fig. 3. A transformation function from measurement space to parity space.

v_k 의 개별값은 물리적 의미가 없지만 각각의 조합은 패턴(또는 벡터)을 구성하고 페리티 공간의 한 영역을 나타낸다. 그림 3에 페리티 공간의 패턴과 센서의 상태를 각 영역에 할당하였다. 이 패턴을 인공신경망에 적용하면 페리티 패턴은 입력이 되고 센서의 상태는 원하는 출력이 된다. 따라서 그림 3을 이용하여 표 2와 같은 인공신경망의 학습 데이터를 만들 수 있다. 이와같이 측정값을 인공신경망에 적용하기 전에 페리티 공간으로 변환하여야 한다. 여기서 측정값을 인공신경망에 적용하기 전에 정규화 시킬 필요가 있다. 센서 신호는 다음과 같이 [0,1] 범위사이로 정규화된다.

$$y_k^n = \frac{y_k - y_{\min}}{y_{\max} - y_{\min}} \quad (29)$$

여기서 y_{\max} 와 y_{\min} 은 각각 센서신호의 최대 및 최소값이다. tolerance도 역시 정규화되어야 한다. 정규화는 두가지 목적이 있다. 첫째로 입력값이 일정한 범위에 있으므로 인공신경망의 안정성을 높이고, 두 번째는 측정값이나 측정값의 범위에 무관한 인공신경망을 생성하여 센서의 수가 같으면 한번의 학습데이터로 모든 측정 용 사용할 수 있도록 한다.

표 2는 측정공간에서 페리티 공간으로 변환된 패턴을 나타낸다. 표 2의 각 패턴은 그림 1의 페리티 공간 각영역을 나타내므로 표 2의 패턴을 그림 1에 할당하면 그림 4와 같이 된다. 여기서 우리는 페리티 방정식을 사용하지 않고 (26), (27), (28)을 사용하여 측정공간에서 페리티 공간으로 변환되었음을 알 수 있다. 측정공간은 연속적인 공간으로 무한개의 측정값이 존재한다. 컴퓨터를

표 1. 스칼라 양을 측정하는 3중센서의 에러 종류.
Table 1. errors in the measurement space for 3 redundant measurements of a scalar variable.

패턴	상태	고장종류	센서의 조합
1	한개의 센서는 높은값		y_1, y_2, y_3
2			y_1, y_3, y_2
3			y_2, y_3, y_1
4	한개의 센서는 낮은값		y_3, y_1, y_2
5			y_2, y_1, y_3
6			y_1, y_2, y_3
7	한개의 센서는 높은값 한개의 센서는 낮은값		y_1, y_2, y_3
8			y_1, y_3, y_2
9			y_2, y_1, y_3
10	모두 정상		y_2, y_1, y_3
11			y_3, y_1, y_2
12			y_3, y_2, y_1
13	모두 정상		y_1, y_2, y_3
14			y_1, y_2, y_3
15			y_1, y_3, y_2
16	두 개의 센서가 불일치		y_2, y_1, y_3
17			y_2, y_3, y_1
18			y_3, y_2, y_1
19			y_3, y_1, y_2

이용한 시스템 고장진단에서는 연속적인 측정값은 아니고 A/D 변환기의 해상도에 따라 다르다. 12비트 A/D변환기는 2¹²개의 측정값이 가능하다.

그림 4는 오직 19개의 패턴만 존재하므로 정확한 결정을 하기가 매우 쉽다. 이 변환 과정은 패턴인식에서 일반적으로 사용하는 특징추출 과정이다. 패턴인식에서 특징추출방법은 패턴의 특징에 맞는 함수를 사용하여야 한다. 여기서는 측정공간에서는 연속적인 값을 가지며 무한대의 판단 영역이 존재하지만 페리티 공간으로 변환하면 이산적인 공간으로 변환되어 소수의 판단영역을 가지므로 정확한 패턴인식이 매우 간단해 진다. 여기서 정확한 판단은 장애 발생을 탐지하고 장애가 발생한 센서를 분리하여 측정값에서 제외하는 것을 의미한다.

그림 4의 페리티 공간에서 각 영역에 할당된 패턴을 식별하기 위해 인공신경망을 사용한다. 3중센서의 경우 인공신경망은 19개의 학습데이터가 있으므로 8개의 숨겨진 노드면 충분하므로[8] 3개의 입력노드 3개의 변환노드, 8개의 숨겨진 노드, 4개의 출력노드로 이루어 진다. 그림 5는 변환 계층을 포함한 3계층 인공신경망을 보여준다.

표 2. 스칼라 양을 측정하는 3중센서의 학습패턴.

Table 2. training patterns in the measurement space for 3 redundant measurement of a scalar variable.

패턴	학습 입력 패턴			원하는 출력 패턴			
	v_1	v_2	v_3	t_1	t_2	t_3	t_4
1	0	-1	-1	0	0	1	0
2	-1	0	1	0	1	0	0
3	1	1	0	1	0	0	0
4	0	1	1	0	0	-1	0
5	1	0	-1	0	-1	0	0
6	-1	-1	0	-1	0	0	0
7	-1	-1	-1	-1	0	1	1
8	-1	-1	1	-1	1	0	1
9	1	-1	-1	0	-1	1	1
10	1	1	-1	1	-1	0	1
11	-1	1	1	0	1	-1	1
12	1	1	1	1	0	-1	1
13	0	0	0	0	0	0	0
14	-1	0	0	-1	1	0	0
15	0	-1	0	-1	0	1	0
16	0	0	-1	0	-1	1	0
17	1	0	0	1	-1	0	0
18	0	1	0	1	0	-1	0
19	0	0	1	0	1	-1	0

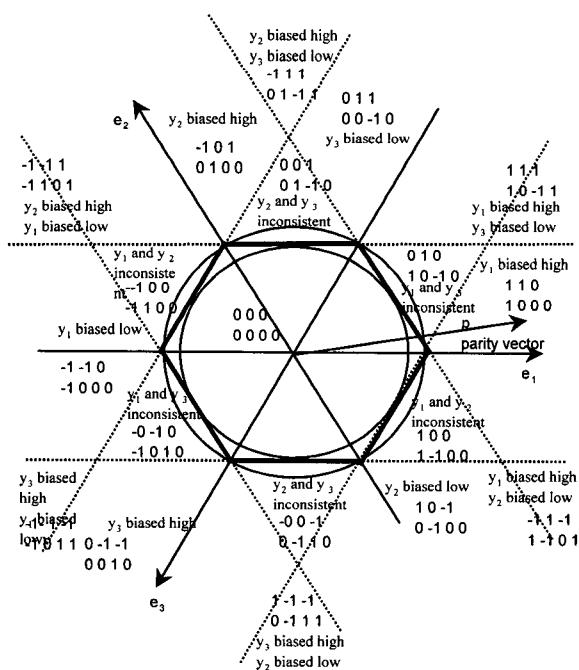


그림 4. 패리티 공간에 입력 패턴과 출력 패턴의 할당.

Fig. 4. Parity space decision regions assigned parity pattern and output node of PSNN.

여기서 측정공간에서 패리티 공간으로 변환하는 과정을 신경망에 통합할 수 있다. 이 기능을 입력층과 숨겨진층 사이에 삽입하고 그림 5와 같은 변경된 신경망을 개발하

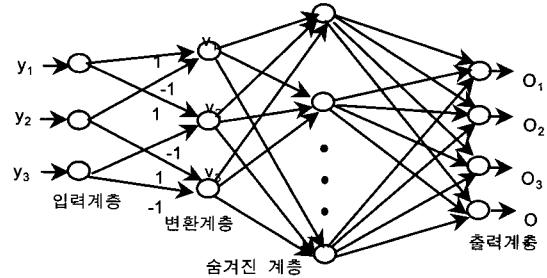


그림 5. 변환계층을 포함하는 신경망 구조.

Fig. 5. Modified neural network that includes feature extraction layer.

였다. 여기서 변환계층은 보통의 신경망 계층과 다르다. 입력계층과의 연결은 (5) (6) (7)에 나타난 대로이며 가중치는 미리 고정되어 있고 학습이 필요 없다. 활성 함수는 (8)과 같으며 그림 3에 보여진다. 여기서 변환계층은 패턴인식을 위한 특징추출 과정이다. 일반적으로 패턴인식에서 특징추출은 패턴인식을 위한 선행과정이며 인공신경망에서 특징추출은 일반적으로 계층간에 완전연결이 필요치 않다[9]. 특징 추출은 패턴의 특징에 따라 각각 적절한 방법을 적용해야 한다. 숨겨진 계층과 출력계층은 \tanh 함수[10]를 사용하였다. \tanh 함수는 -1, 0, +1 3가지 상태를 나타내기가 좋고 신경망의 특성도 좋다. 표 3은 표 2의 학습패턴을 그림 5의 신경망에 적용하여 학습한 결과이다. 학습결과가 매우 양호하고 측정데이터는 변환 계층을 거쳐 학습패턴과 똑같은 패턴이 신경망에 적용되므로 출력은 항상 표 3과 같은 값을 얻게 된다. 여기서 표의 원하는 출력 t 는 정수이고 그림 5의 신경망 실제출력값 O 는 표 3과 같이 정수가 아니다. 이 방법은 보통의 신경망 패턴인식 방법과 다르다. 일반적

표 3. 3중 센서에 대한 신경망의 학습결과.

Table 3. Training results of neural network for 3 redundant sensors.

패턴	원하는 출력노드 값				실제 출력노드 값			
	노드1	노드2	노드3	노드4	노드1	노드2	노드3	노드4
1	0	0	1	0	0.0007	0.0027	0.9999	0.0002
2	0	1	0	0	-0.000	0.9999	0.0008	0.0018
3	1	0	0	0	0.9999	-0.002	-0.001	-0.000
4	0	0	-1	0	-0.000	-0.002	-0.999	0.0003
5	0	-1	0	0	0.0019	-0.999	-0.000	0.0009
6	-1	0	0	-1	0.0035	0.0010	0.0008	
7	-1	0	1	1	-0.975	-0.004	0.9990	0.9719
8	-1	1	0	1	-0.996	0.9864	-0.001	0.9806
9	0	-1	1	1	-0.001	-0.991	0.9996	0.9755
10	1	-1	0	1	0.9904	-0.999	0.0006	0.9841
11	0	1	-1	1	0.0008	0.9910	-0.996	0.9741
12	1	0	-1	1	0.9976	0.0025	-0.993	0.9872
13	0	0	0	0	-0.000	0.0010	0.0009	-0.000
14	-1	1	0	0	-0.999	0.9806	-0.001	-0.000
15	-1	0	1	0	-0.997	-0.002	0.9945	0.0005
16	0	-1	1	0	-0.001	-0.980	0.9796	0.0002
17	1	-1	0	0	0.9949	0.996	0.0007	0.0003
18	1	0	-1	0	0.9986	0.0018	-0.993	0.0007
19	0	1	-1	0	0.0011	0.9959	-0.990	-0.000

으로 인공신경망은 불확실한 많은 학습 패턴을 사용하여 학습시킨다. 학습이 끝난 후에는 학습 데이터와 다른 실제 데이터를 적용하여 신경망의 학습능력에 따른 결과를 얻는다. 학습 데이터 및 신경망 구조에 따라 결과가 다르고 신경망의 학습능력에 한계가 있으므로 항상 정확한 결과를 기대할 수는 없다.

페리티공간 신경망은 다중 하드웨어 센서신호 검증을 위해 측정공간 값을 페리티공간 값으로 변환하는 기능을 추가한 특별한 용도의 신경망으로 PSNN(Parity Space Neural Network)이라 명명하였다.

인위적으로 정확한 학습 데이터를 만들고 학습 데이터와 실제 데이터가 같으므로 항상 정확한 결과를 기대할 수 있다. 별도의 실험을 하지 않아도 페리티 신경망의 성능은 입증된 것이다. 그림 6의 합성 데이터를 그림 5의 페리티 공간 신경망과 페리티 방정식을 이용하는 방법으로 분석하여 결과를 표 5에 요약하였다. 표 4와 그림 6은 신호의 특성을 보여준다.

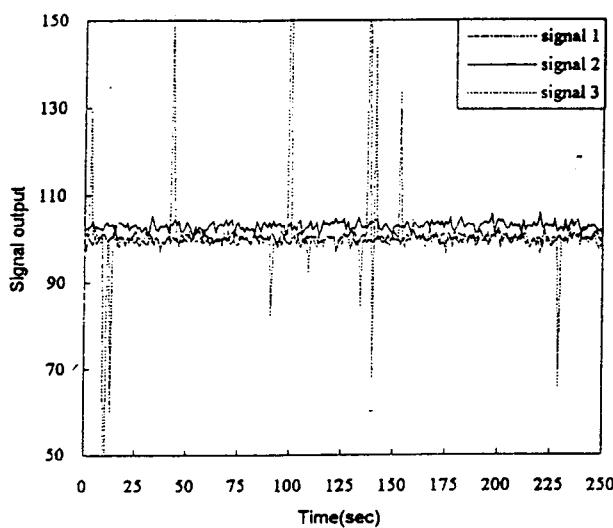


그림 6. 3종 센서의 테스트 데이터.

Fig. 6. Three redundant signals of test data set.

표 4. 테스트 데이터의 특성.

Table 4. Characteristics of test data set.

신호번호	형태	평균값	비고
1	에러없음	100	잡음추가됨, $\sigma = 1$
2	위로 벗어남	105	잡음추가됨, $\sigma = 1$
3	에러존재	100	스파이크 13개, $\sigma = 13.85$

사용된 데이터는 평균이 100이고 표준편차는 $\sigma=1$ 이다. 신호의 에러 형태는 큰값의 스파이크가 존재하므로 tolerance를 변화에, 즉 시스템 정밀도의 따라 페리티공간 신경망 방법과 분석적 페리티 방법의 탐지된 에러를 비교하였다. 여기서 tolerance가 작은 경우, 즉 정밀도가 높은 시스템에서는 두 방법의 차이가 커지고 정밀도가 낮은 시스템, 즉 tolerance가 큰 경우는 두가지 방법의

차이가 적다.

표 5. 합성 데이터에 대한 페리티 공간 신경망 및 분석적 페리티 공간 방법의 결과.

Table 5. Detected faults by the parity space neural network and analytical parity space method.

tolerance	페리터 공간 신경망이 탐지한 에러수	분석적 페리터 방법이 탐지한 에러수		
		최소 tolerance	평균 tolerance	최대 tolerance
1	246	247	245	245
1.5	239	242	239	232
2	219	222	217	211
3	167	180	163	145
4	93	107	92	75
5	47	61	45	29
6	23	28	22	17
7	17	17	17	16
8	15	16	15	15
9	15	15	13	13
10	13	13	13	12

IV. 결론

페리티 방정식을 이용하여 측정공간에서 페리티 공간으로 변환하는 방법의 문제점을 분석하고, 페리티 방정식을 이용하지 않고 측정공간에서 페리티 공간으로 변환하는 방법을 개발하였다. 센서 신호의 패턴을 페리티 공간으로 변환시키는 함수를 개발하고 신경망을 이용하는 패턴인식 방법을 적용하였다. 변환함수와 신경망을 결합하여 페리티 공간 신경망을 개발하였다. 새로운 신경망은 학습 데이터 준비와 학습과정이 매우 쉽다. 이 방법은 같은 수의 센서를 사용하는 경우 측정값의 종류와 범위에 상관없이 사용할 수 있다. 신경망과 패턴인식 기법을 시스템 고장진단에 사용하는 경우 학습자료 준비와 학습이 매우 어렵고 정확도가 떨어진다. 또 측정 대상과 범위가 바뀌면 모든 과정을 다시 반복해야 한다. 그러나 여기서 개발된 방법은 측정공간에서의 연속적인 판단영역이 페리티 공간으로 변환하여 이산적 판단영역이 존재한다. 따라서 학습 데이터 양을 정확하게 알 수 있고 인위적으로 정확하게 만들 수 있다. 학습 후에 실제 데이터도 페리티 공간 데이터로 변환되어 신경망에 적용되므로 학습 데이터와 실제 측정 데이터가 항상 같은 결과를 제공하므로, 정확도가 획기적으로 개선되며 다양한 분야에서 쉽게 적용할 수 있다.

이 방법의 단점은 다중센서의 수가 증가하면 표1의 센서조합 수가 급격하게 증가하여 학습 패턴의 수가 따라서 증가한다. 4중센서는 183개 5중센서는 1071개이고 6중센서 이상은 구현이 어렵게된다. 일반적으로 5중센서 이상은 거의 사용되지 않는 4중 및 5중센서까지는 구현되어 원자력발전소 센서신호 분석에 적용되었다[7]. 5중센서의 경우는 학습패턴이 1071개 이므로 일반적인 신경망의 용량을 초과하므로 증가시키는 방법이 적용되었

다[7]. 앞으로 벡터량을 측정하는 분야도 더욱 연구해야 한다.

참고문헌

- [1] R. B. Broen, "A nonlinear voter-estimator for redundant systems," *Proc. IEEE Conf. on Decision and Control*, Phoenix, Arizona, pp. 743-748, 1974.
- [2] R. J. Patton and J. Chen, "A review of parity space approach to fault diagnosis," *IFAC Fault Detection, Supervision and Safety for Technical Processes*, Barden-Barden, Germany, pp. 65-81, 1991.
- [3] Timo Sorsa and Heikki N. Koivo, "Application of artificial neural networks in process fault diagnosis," *Automatica*, vol. 29, no. 4, pp. 843-849, 1993.
- [4] M. A. Kramer and J. A. Leonard, "Diagnosis using backpropagation neural networks - analysis and criticism," *Computers Chem. Eng.*, vol. 14, no. 12, pp. 1323-1338, 1990.
- [5] A. Ray and R. Luck, "An introduction to sensor signal validation in redundant management systems," *IEEE Control Magazine*, vol. 11, no. 2, pp. 44-48, 1991.
- [6] A. Ray and M. Desai, "A redundant management procedure for fault detection and isolation," *Journal of Dynamic Systems, Measurement, and Control*, vol. 108, pp. 248-254, Sep. 1986.
- [7] T. S. Yoon, *Hardware Redundant System Signal Validation using Artificial Neural Network*, Ph. D. Dissertation, Arizona State University, May, 1995.
- [8] G. Mirchandani and Wei Cao, "On hidden nodes for neural nets," *IEEE Trans. Circuits and Systems*, vol. 36, no. 5, pp. 661-664, May, 1989.
- [9] J. Ghosh, L. Deuser and S. D. Beck, "A neural network based hybrid system for detection, characterization and classification of short duration oceanic signals," *IEEE Journal of Oceanic Eng.*, vol. 17, no. 4, pp. 351-363, Oct., 1992.
- [10] B. L. Kalman and S. C. Kwasny, "Why tanh: choosing a sigmoidal function," *IEEE/INNS International Joint Conference on Neural Networks*, vol. 4, pp. IV-578-581, Baltimore, 1992.

윤태섭



1959년 5월 10일생. 1982년 한국항공대학 항공전자공학과 졸업. 1982-1987 국방과학연구소 근무. 1987-1988 한국원자력연구소 근무. 1991년 및 1995년 미국 아리조나 주립대학교에서 석사 및 박사학위 취득. 1995년-1998. 9. 삼성 SDS 근무, 현재 삼지전자 근무. 주요관심 분야는 시스템 고장진단, 센서신호 검증, 패턴인식, 음성인식.