2000 추계학술발표회 논문집
한국원자력학회

디지털 제한계통의 계측기기 보정횟수 감소에 관한 연구

A study on Calibration Reduction of Instrument Channels for Digital Limitation System

김정기, 최중인

경원대학교
경기도 성남시 수정구 복정동 산65번지

요 약

본 연구의 목적은 계측기기채널의 온라인 신호를 통해서 계측기기의 성능을 분석하고 이를 기반으로 교정 시기를 정함으로써 불필요한 보정 횟수를 감소시키고 계측기기의 손상을 줄이며 유지 보수면에서 보다 경제적인 방안을 연구하고자 하는 것이다. 채널에 대한 성능 분석의 중요한 항목인 센서 신호검증기법으로는 신경회로망을 고려하였고, 통계적 성능평가방법으로는 SPRT를 이용 온라인으로 계측기기의 편향, 혹은 고장을 검출하므로써 모든 계측기기에 대해 일정 주기마다 의무적으로 해주었던 계측기기의 보정횟수를 감소시키며, 따라서 유지 보수비용을 줄일수 있는 경제적인 방안이 될 수 있을 것이다.

Abstract

A major objective of the study is prescribing instrument performance through analyzing on-line signals on instrument channels, deciding calibration period, reducing unnecessary maintenance, decreasing equipment damage. Through using neural networks for sensor signal validation method and SPRT for statistical performance evaluation method which is one of the most important issues in system performance analysis on instrument channels, detect drift and fault of instrument, deciding calibration period, a better system maintenance for instrument calibrations will be discussed.

1. 서 론

원자력 발전소의 운전 및 보수유지에서 계측제어(I&C)계통이 차지하는 비중은 매우 크다. 따라서 이 계측제어계통의 효율적 성능 관리는 원전의 안전성 및 신뢰도를 향상시킬 수 있을 뿐 아니라 발전 비용 절감에도 크게 기여할 수 있다.

계측제어 계통의 성능 관리는 설비의 점검, 교정 및 기능 시험을 통하여 수행되는데 이는 지정된 주기마다 실시함으로써 운전 가능성을 입증하도록 되어 있다. 그러나 최근에는 이와 같은 시간에 따른 정비(Time-Directed Maintenance) 방법보다는 상태에 따른 정비(Condition Directed Maintenance) 혹은 예방정비(Predictive Maintenance)의 형태로 나아가는 경향이 있다. 이에는 온라인 신호를 이용하여 기기의 성능을 분석 예측하고 이상 상태를 감지하는 기술이 필요하며 국내외적으로 이에 대한 많은 연구가 수행되고 있다[1]-[3]. 특히 계측제어 계통은 성능과 관련된 온라인 신호가 매우 가용적인 형태로 있기 때문에 보다 기술의 개발 및 적용이 용이한 분야이다.

일반적으로 계측제어 계통의 성능 관리에 있어서 중요한 분야는 계측설비의 점검으로서 이는 안전 관련 계통인 경우에는 기술지침서(Tech. Spec)상 요구되어 있다. 그러나 이는 주기적 점검 기반으로 이루어져 있으며 주로 오프라인으로 시행되고 있다. 이러한 보정방식으로 인하여 계측기기의 노화. 손상이 촉진되고 비 작동(non-service)상태에서 보정이 이루어지기 때문에 잘못된 보정을 얻을 수 있다. 또한 이 보정은 주어진 시간 간격으로 모든 계측기기에 대하여 수행되어야 하는데 보수적으로 사실상 불필요한 많은 횟수의 보정이 경험되고 있고 이 때문에 계측채널의 가용성 및 신뢰성이 줄어들어 보수유지비용의 증대를 가져온다. 따라서 이 계측기기 보정횟수를 안전성에 영향을 주지 않는 방법으로 감소시키는 것은 운영면 에서 매우 필요한 일이다.

본 연구에서는 대상 계통으로 원자로보호계통(RPS: Reactor Protection System)[4]을 선정하고 이 계통의 계측 채널에 대한 성능 분석의 중요한 항목인 센서 신호검증 기법으로 신경회로망을 이용한 온라인 감시계통을 소개한다. 이를 위하여 가동 원전의 온라인 신호를 취득, 데이터베이스를 구축하고 원자로 보호계통에서의 채널의 온라인 신호를 분석함으로써 계측기기의 성능을 분석하고 이를 기반으로 교정 시기를 정함으로써 불필요한 보정 횟수를 감소시키고 계측기기의 손상을 줄이며 유지 보수면에서 보다 경제적인 방안을 연구하고자 한다.

2. 신경회로망 온라인 감시모델

계측기기의 오작동으로 인한 인간의 실수를 피하기 위하여 널리 이용되는 방법중의 하나는 하드웨의 다중성을 이용한 방법이다. 주요한 공정변수를 위한 4개의 독립적인 채널이 원자력 발전소에서는 보통인데, 안전계통의 작동을 가져올수 있는 신호에 대하여 다중의 계측은 항상 필요하다. 하지만 CEAC(Control Element Assembly Calculator)신호와 같이 2개의 채널을 통해 1-out-of-2 로직을 갖는 경우에는 고장의 검출은 가능하지만 분리가 불가능하다. 이와 같은 경우 새로운 물리적 센서의 추가는 매우 어려운 문제이기 때문에 밀접한 상관관계에 있는 다른 센서 신호자료를 통하여 해석적 센서 신호를 만들어야 한다. 하지만 신호간의 동적 상관관계는 매우 비선형적이므로 모델링이 어려워 이를 위해서는 Model-Free 한 방법이 적합한데, 본 논문에서는 이러한 비선형 상관관계의 모델링을 위하여 신경회로망을 도입하였다. 또한 고장 및 편향에 대한 판별에 있어서는 실측치와 신경회로망의 출력인 예측치와의 차이인 residual이 계산되는데, 이것이 통계적 성능평가모델의 입력이 되고, 신호잡음등을 고려한 통계적 성능평가모델을 통하여고장 및 평향에 대한 판별을 하였다. 통계적 성능평가모델은 Wald[1945]에 의해 개발된 SPRT (Sequential Probability Ratio Test)로직을 적용하였다.

그림 1에 이와 같은 기법을 원전 계측 채널에 적용하는 간략한 체제를 보여주고 있는데, 이를 신경회로망 온라인 감시모델[5]-[7]이라 부르기로 한다. 여기서 예측모델은 신경회로망으로 구성

되는데, 출력이 적당한 동적한계내에서 입력을 추적하도록 훈련되어지며 예측모델에 입력되는 신호의 수와 각각의 입력신호의 예측치인 출력신호의 수는 같다. 예측모델에서의 입력은 어느정도 연관성이 있는 변수들이 입력을 구성하는데, 정상적으로 예측모델이 작동하기 위해서는 고장이 없는 정상작동 데이타로 학습되어야 하고, 이때 다양한 변수들 사이의 관계는 신경망 학습과정을 통하여 가중치로서 나타내어진다.

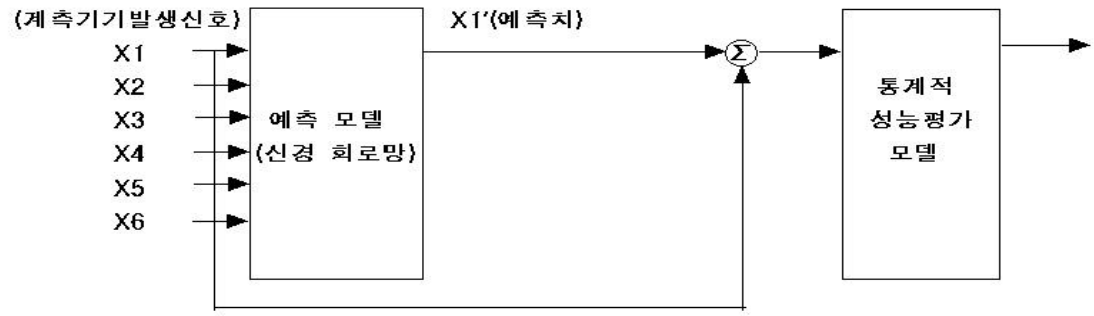

그림 1 신경회로망 온라인 감시모델

일단 신경회로망이 정상작동데이타로 학습되면, 예측모델의 입력이 잡음, 자료손실, 비선형성 등에 의해 왜곡되더라도 출력은 항상 정상센서일때의 값을 출력하게된다. 이러한 특성으로 인하여 예측모델의 입력과 출력의 차이를 감시함으로써 센서의 고장을 검출할수 있다. 즉, 실제 센서의 출력과 예측모델을 통하여 계산된 센서 출력이 비교되고 residual이라 불리는 오차가 계산되는데, 이것이 성능평가 모델의 입력이 된다. 성능평가 모델은 SPRT로직을 적용하였다.

SPRT는 specified missed and false alarm probability[Upadhyaya, 1987]에 근거한 최소의 셈플만을 가지고 고장을 검출할 수 있다.

3. 데이터의 선택과 처리

3.1 데이터의 선택

신경회로망 온라인 감시 시스템이 정상적으로 작동하기 위해서는 고장이 없는 정상작동데이타로 학습되어야 하는데, 본 연구를 위하여 한국전력공사등의 도움을 얻어 발전소의 연료공급주기동안의 관련변수들에 관한 데이터를 취득하였다.

3.2 데이터의 처리

사실상 모든 신경회로망은 그 입력과 출력이 적당한 범위로 제한되면 휠씬 효과적으로 학습한다. 데이터 처리는 입력 데이타가 신경회로망에 입력되기전에 데이터의 사전처리를 수행하고, 요구된 출력치를 주도록 하기 위하여 신경회로망출력의 사후처리를 수행한다.

본 연구에서는 신경회로망 학습을 돕기 위하여 각각의 신경회로망 입력 파라미터에 대하여 0.1- 0.9 범위에서 미리 선형 스케일링을 해 두었다.

4. 신경회로망의 구조와 노드수의 선택

4.1 신경회로망의 구조

본 연구를 위해 사용될 신경회로망의 구조는 5중계층구조이다. 그림 2와 같이 이것은 입력층과 3단계의 은닉층 그리고 선형 출력층의 5개의 계층으로 구성되어 있다. 은닉층은 3개의 비선형층으로 구성되어 있는데, 그 중 첫 번째 것은 사상층으로서 입출력의 노드보다 더 큰 차원의 노드를 갖는다. 두 번째 은닉층은 병목층으로 이 층의 노드의 수는 신경회로망에서 가장 작아야 한다. 세 번째층은 역사상층이라고 불리는데, 사상층과 같은 크기의 노드를 갖는다.

3개의 은닉층은 전체 네트워크의 구조 형성하는데, 여기서 병목층이 가장 중요한 역할을 한다. 사상층과 병목층, 역사상층, 이 3개의 층의 조합으로 인하여 입력데이타의 촘촘한 표현은 얻을수 있고, 이로써 네트워크는 보다 나은 시스템 파라미터를 구성할수 있게 된다.

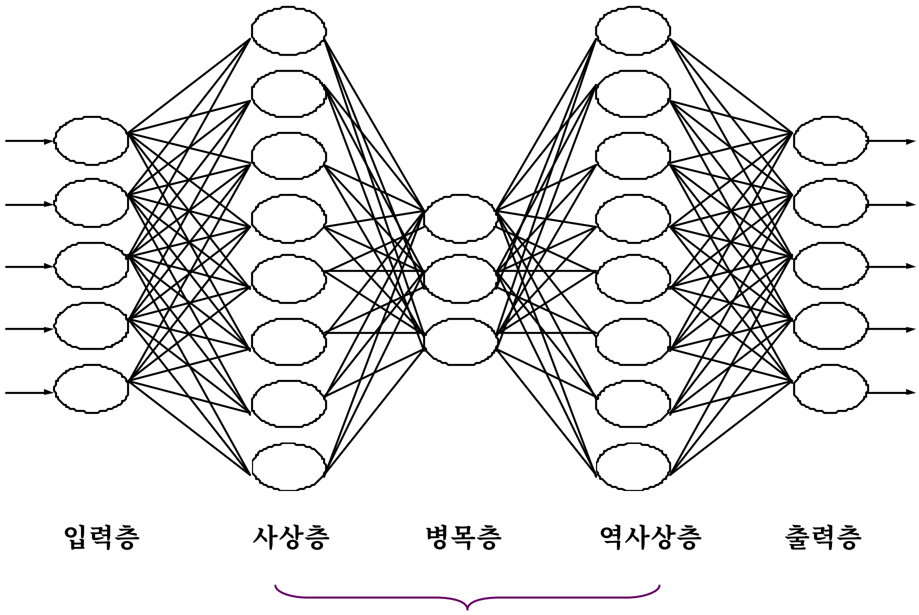

그림 2 5중계층 신경회로망의 구조

3개의 은닉층의 비선형 전달함수는 sigmoidal 논리함수이고 이것은 다음과 같이 주어진다.

$$s\,(x) = \frac{1}{1-e^{-x}}$$

그림3 에 논리함수를 나타내었다.

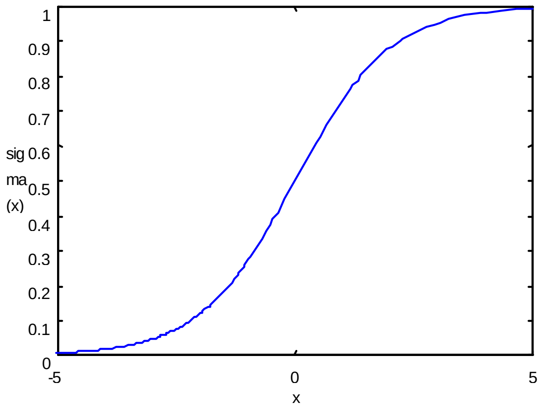

그림 3 Sigmoidal 논리함수

4.2 노드수의 선택

신경회로망에서 입·출력층의 노드의 수를 m이라 하고, 은닉층의 노드의 수를 f, 사상, 역사상층의 노드의 수를 M이라 하자. 입·출력층의 수(m)는 네트워크의 입·출력 파라미터의 수에 따라 정해지지만 사상, 역사상층의 노드의 수를 결정하는데에는 확실한 방법이 아직 없다.

일반적으로 사상층 노드의 수가 적으면 제한된 표현능력으로 인하여 정확성이 떨어지고 노드의 수가 많으면 네트워크가 over-fitting하거나, 본래의 기능보다는 오히려 데이터의 통계적 변형을 학습하는 경향이 있다. Kramer는 최적의 사상층의 수를 결정하기 위하여 사용될 수 있는 두가지 방법을 제공하였는데, Final Prediction Error(FPE)와 Akaike's Information theoretic Criterion(AIC)[8]가 그것이다.

반복되는 시행착오로 인하여 은닉층 각각에서 노드의 최적 수를 결정하기 위한 경험적인 공식이 발견되어 왔다. 이것은 하나의 층과 다른층의 개수의 비로 주어지는데, 보통 아래와 같다.

$$M/m \cong 1.25 \quad , \quad M/f \cong 1.6 \quad , \quad m/f \cong 1.3$$

아래표는 본 연구를 위하여 사용된 신경회로망에 대한 입. 출력 파라미터, 사상층, 역사상층의 노드수, 은닉층의 노드수를 나타낸다.

표 1. 신경회로망의 노드수

신경회로망	입력층	사상층	병목층	역사상층	출력층
신경망 1	5	6	4	6	5
신경망 2	4	5	3	5	4

5. 신경회로망 학습과 검증

일단 입출력이 선택되어 효과적인 학습을 위해 사전 스케일링 처리되고, 신경회로망 구조가 선택되고, 훈련 파라다임이 설정되면 신경회로망은 학습되고 검증된다. 검증을 위하여 입력공간을 학습시키고 신경회로망 성능을 평가하기 위한 몇 개의 데이터 집합이 선택되고 만들어진다. 만

일 검증집합에서의 나쁜 성능을 보이게 되면 그 검증집합을 학습집합과 병합하여 신경회로망을 재훈련시키도록 하므로 신경망 모델을 학습시키고 시험하는 것은 반복적인 일이다.

신경회로망의 학습을 위한 데이터는 정상운전작동시의 데이터를 사용해야 하므로 연료공급주기 동안의 데이터를 선택한다. 이 학습집합은 신경회로망 온라인 감시계통이 작동하는 프랜트에 대한 모든 동작상태를 포함한다. 다음에 신경회로망을 학습시키는데, 이때 신경회로망이 데이터의 잡음까지 학습을 하게 되면 poor generalization의 원인이 되므로 이를 막기 위하여 미리 잡음을 계산하고 적정선에서 학습을 멈춘다.

본 연구에서는 다중층 신경회로망이 사용되었으므로 이의 학습을 위하여 MATLAB의 feed-forward backpropagation Neural Network 학습 알고리즘을 이용하였다.

일단 학습이 끝나면, 신경회로망의 성능을 검증하기 위하여 학습에 사용되지 않은 다른 데이터가 사용된다. 동일변수 다른 데이터 주기의 계측기기 발생신호의 예측값인 신경회로망 출력과 계측기기 발생신호를 비교함으로써 신경회로망 성능의 결과가 검토되고 학습집합은 그 검토결과에 따라 변하게 된다. 여러번의 시험후에 신경회로망이 적당한 데이터로 적당히 학습되면, 인공적 고장을 갖는 데이터가 신경회로망의 입력으로 사용된다.

인공적인 고장을 갖는 데이터가 신경회로망의 입력으로 들어갔을 때 그 채널의 신경회로망의 출력, 즉, 예측치가 일정한 오차 허용범위 내에서 고장이 없는 원래의 계측기기 출력치와 일치하는지를 입증하기 위해 신경회로망 출력이 검토된다. 이 허용범위는 데이터의 잡음의 양과 그 크기로부터 결정된다.

6. 통계적 성능평가 방법

본 연구에서 예측모델로 사용되는 신경회로망의 출력은 감시된 파라미터의 추정치이다. 이 추정치는 측정치와 비교되고 residual이라 불리는 오차범위가 계산된다. 이 residual은 매 쌤플마다 실제값에서의 변화에 독립하며, 단지 센서의 기능저하상태 및 신호에 존재하는 실제 잡음에 의존하기 때문에 순차적인 계측들이 서로 독립이어야하는 통계적 성능평가 계통의 입력이 된다. Wald[1945]에 의해 개발된 SPRT(Sequential Probability Ratio Test)는 specified missed and false alarm probability[Upadhyaya, 1987]에 근거한 최소의 셈플만을 가지고 고장을 검출할 수 있다.

통계적 성능평가모델에서는 센서의 각 채널별 기능저하 또는 고장을 검출하게 되는데, 정규분포를 이루는 센서 출력을 모델하기 위하여 가우시안 확률밀도 함수가 되며, 신호 파동(Fluctuation)이 정규분포이기 때문에 이런 가정은 사실이다. 프로세스 신호인 x에 대하여 평가오차를 다음과 같이 정의하자.

$$e_m = x(t_m) - \hat{x}(t_m) \qquad \text{식 (1)}$$

$x(t_m)$: 프로세스 변수이며, 시간 t_m에서의 측정치

$\hat{x}(t_m)$: 시간 t_m에서의 $x(t_m)$의 계산된 평가치

또한 매 샘플마다 다음과 같은 데이터 집합 $E=\{e_1,e_2,e_3,\Lambda\ ,e_n\}$을 정의 하자. SPRT는 이런 에러에 적용되며 test의 지표가 어떤 크기에 도달하였을 때, 이 센서는 퇴화된 것으로 여겨진다.

이 오차가 정상 센서동작 동안 매 셈플마다 계산되어, 평균 m_0 및 분산 s_0^2가 이 오차신호에 대하여 계산된다.

정상모드의 신호오차를 모델하는 가우시안 밀도함수를 다음과 같이 정의한다.

$$P_0(e,m_0,s_0^2)=\frac{1}{\sqrt{2p\,s_0^2}}\exp[-\frac{(e-m_0)^2}{2s_0^2}] \qquad \text{식 (2)}$$

센서고장은 평균 m 및 분산 s^2의 변화에 의하여 설명될 수 있다.

평균값이 퇴화된 값 m_1에 도달했을 때, 센서가 퇴화되었다는 가설 H_1이 받아들여진다. 분산값이 퇴화된 값 s_1^2에 도달하였을 때, 센서가 퇴화되었다는 가설 H_1이 받아들여진다. 만일 평균과 분산이 정상상태로 남아있다면, 센서가 정상이라는 가설 H_0가 받아들여진다. 또한 가우시안 밀도함수 $P_1(e,m_1,s_1^2)$에 의한 고장문턱값(Threshold)이 정의된다.
통계적 성능평가방법인 SPRT를 위한 기초는 Likelihood Ratio(LR)에 있다.

다음식에 의해 LR은 계산된다.

$$g_1=\frac{P_1(e,m_1,s_1^2)}{P_1(e,m_0,s_0^2)} \qquad \text{식 (3)}$$

이 값이 매 샘플링 순간마다 업데이트 된다. 서로 독립적인 샘플을 가정하면, 결합밀도함수는 개개의 밀도함수를 서로 곱하므로써 얻어질 수 있다. 따라서 매 샘플링마다 업데이트 되는 전체의 LR은 다음식에 의하여 주어진다.

$$g_n=\frac{P_1(e_1/H_1)P_1(e_2/H_1)\Lambda\ P_1(e_n/H_1)}{P_0(e_1/H_0)P_0(e_2/H_0)\Lambda\ P_0(e_n/H_0)}=\frac{P_1(E/H_1)}{P_0(E/H_0)} \qquad \text{식 (4)}$$

H_0 : 정상의 평균 및 분산
H_1 : 퇴화된 평균 및 분산

계산의 단순화를 위해 이 LR값에 자연로그를 취한 Log Likelihood Ratio(LLR) l_n을 표현하면

$$l_n = \sum_{i=1}^{n} \ln[\frac{P_1(e_i / H_1)}{P_0(e_i / H_0)}]$$

식 (5)

$$l_n = l_{n-1} + \ln[\frac{P_1(e_i / H_1)}{P_0(e_i / H_0)}]$$

이 식은 센서 오차가 매 셈플마다 서로 독립이고 가우시안 밀도함수로 모델된다는 가정으로부터 밀도함수 $P_1(e, m_1, s_1^2)$과 $P_0(e, m_0, s_0^2)$에 가우시안 밀도함수를 대입하므로써 다음 식이 얻어진다.

$$l_n = l_{n-1} + \frac{e_n^2}{2}[\frac{1}{s_0^2} - \frac{1}{s_1^2}] + e_n[\frac{m_1}{s_1^2} - \frac{m_0}{s_0^2}] + \frac{1}{2}[\frac{m_0^2}{s_1^2} - \frac{m_1^2}{s_0^2}] + \ln[\frac{s_0}{s_1}]$$ 식 (6)

단지 바이어스 혹은 평균값 기능저하만을 체크하기 위해서는 s_1^2 이 s_0^2과 같다고 놓는다. 정상적인 센서를 위해 센서 오차의 평균값은 이론적으로 영이 되어야한다.

$$m_0 = 0$$ 식 (7)

이런 단순화를 이용하여 바이어스 퇴화 감지를 위하여 다음 식이 유도된다.

$$l_n = l_{n-1} + \frac{m_1}{s_0^2}[e_n - \frac{m_1}{2}]$$ 식 (8)

신호에서 과도한 noise준위를 감지하기 위하여 $m_1 = m_0 = 0$으로 놓으면 식 (6)은 다음식이 된다.

$$l_n = l_{n-1} + \frac{e_n}{2}[\frac{1}{s_0^2} - \frac{1}{s_1^2}] + \ln[\frac{s_0}{s_1}]$$ 식 (9)

식 (8)과 식 (9)는 각각 바이어스 및 과도한 노이즈 준위를 감지하는데 이용될수 있다. 즉, 식 (8)과 식 (9)에 의하여 정의된 LLR이 매 샘플순간마다 업데이트된다. 정상적인 센서에 대하여 영으로 초기화된 LLR은 감소하여 궁극적으로 영보다 작은 특정 한계치 A에 도달할 것이다. LLR값이 한계치 A에 도달하였을 때 , 센서는 정상으로 진단되며, 다시 영으로 초기화된다. 기능저하된 센서에 대하여는 이 값은 증가하게되고, 궁극적으로 특정 한계치 B에 도달하였을 때 센서는 기능저하되었다고 진단하며, 이 값은 다시 영으로 초기화된다. 바이어스 오차의 경우에 측정오차 e은 정상적인 평균치 m_0보다는 퇴화된 평균치 m_1에 더 가깝다. 그러므로 측정오차 e에서 밀도함수값 P_1이 P_0보다 더 크게 되므로, LLR이 증가하게 된다.

센서가 정상인지 퇴화되었는지를 결정하는데 이용되는 한계치 A 및 B는 다음과 같이 선정된다.

$$A = \ln[\frac{b}{1-a}], \quad B = \ln[\frac{1-b}{a}]$$ 식 (10)

a : 특정 거짓 경보확률(FAP, False Alarm Probability)
b : 에러확률 (MAP, Missed Alarm Probability)

이와 같은 방법으로 통계적 성능평가계통은 계측기기의 퇴화 또는 고장을 결정하게 된다.

7. 모의실험 및 결과

독립변수 다중채널입력에 대한 신경회로망 기법의 적용을 위하여, 국내표준원전의 원자로 보호계통의 중요 입력인 가압기 압력(B채널), 증기발생기의 압력(B채널), 증기발생기 수위(A채널), 원자로 중성자 출력신호, 냉각수 유량(RC LOOP 1A DIFF PRESSURE)등 5개의 파라미터를 적용 대상 공정 변수로 선정하였다.

5중계층 신경회로망의 학습을 위하여 각각 적용공정변수에 대한 정상작동온라인 신호의 데이터베이스를 구축, 본 연구의 해석 및 modeling 도구로 사용할 Matlab과의 연계를 구축하였다. 신경회로망의 학습을 위하여 다중층 신경회로망의 학습에 적합한 MATLAB의 feed-forward backpropagation Neural Network 학습 알고리즘을 이용하였다.

먼저 가압기 압력(B채널), 증기발생기의 압력(B채널), 증기발생기 수위(A채널), 원자로 중성자 출력신호, 냉각수 유량(RC LOOP 1A DIFF PRESSURE), 5개의 독립변수를 대상으로 신경회로망을 적용하였다. 신경회로망의 학습을 돕기 위하여 각각의 독립변수들에 대한 정상작동데이타에 0.1 - 0.9까지의 범위로 선형스케일링 하였으며, 사용된 스케일링 함수는 다음과 같다.

$$y = 0.00018254x + 0.09240000$$

신경망의 구성은 입·출력층 5개일 경우, 사상·역사상층 6개, 은닉층 4개의 노드로 구성하였고, 입·출력층 4개일 경우, 사상·역사상층 5개, 은닉층 3개의 노드로 구성하였다. 사상, 역사상, 은닉층에는 Log-sigmoid 함수를, 출력층에는 Purelinear함수를 각각 활성함수(activation function)로써 사용하였고 신경회로망은 178 Epoch에서 학습을 완료하였다.

학습이 끝난후, 가압기 압력(B채널)과 증기발생기의 압력(B채널)에 각각 고장 데이터를 모의하였으며, 모의를 위하여 사용된 SIMULINK블럭선도는 그림[4]에, 각각의 고장 모의 실험에 대한 결과는 그림 [5] - 그림[6]에 나타내었다. 가압기 압력의 경우, 3시간후부터 인위적인 고장데이타를 모의 하였으며, 증기발생기 압력의 경우 4시간 50분부터 고장 데이타를 모의하였다.

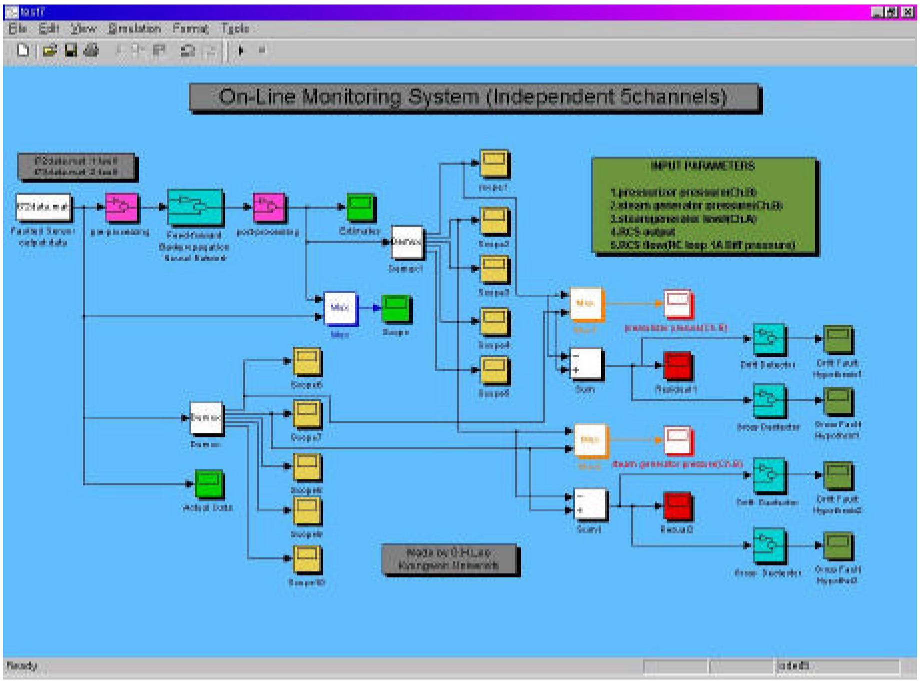

그림 4 신경회로망 온라인 감시모델 SIMULINK블록선도

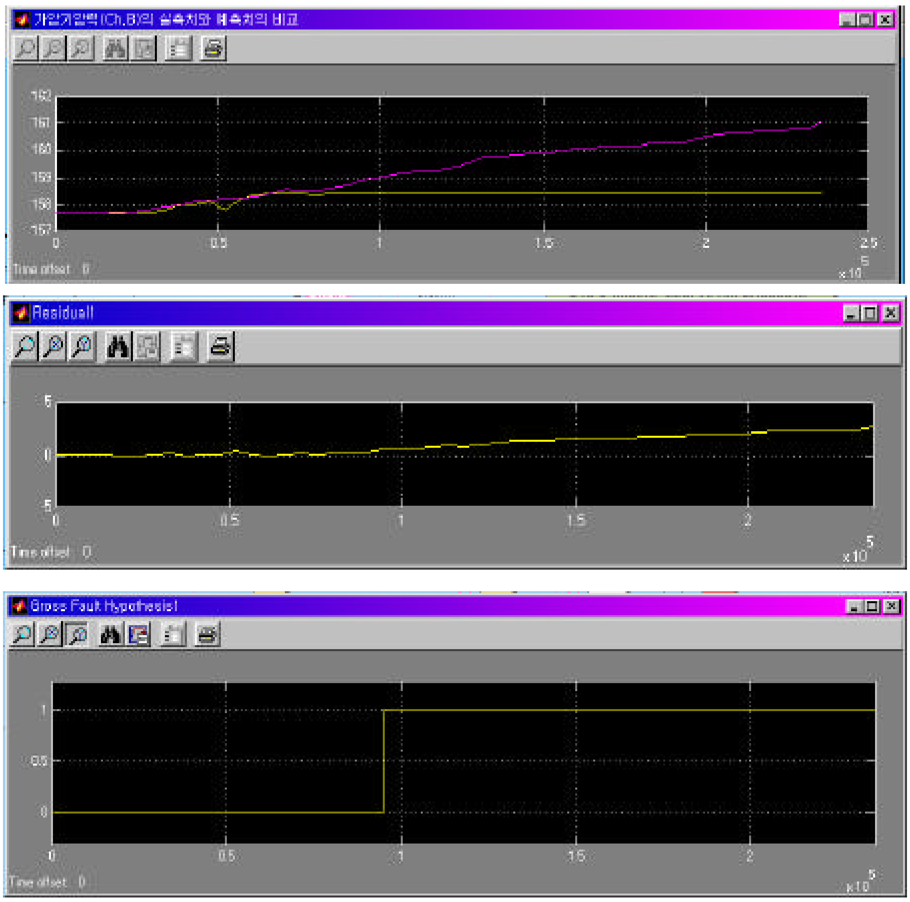

그림 5 가압기 압력 고장시 고장채널(가압기 압력)

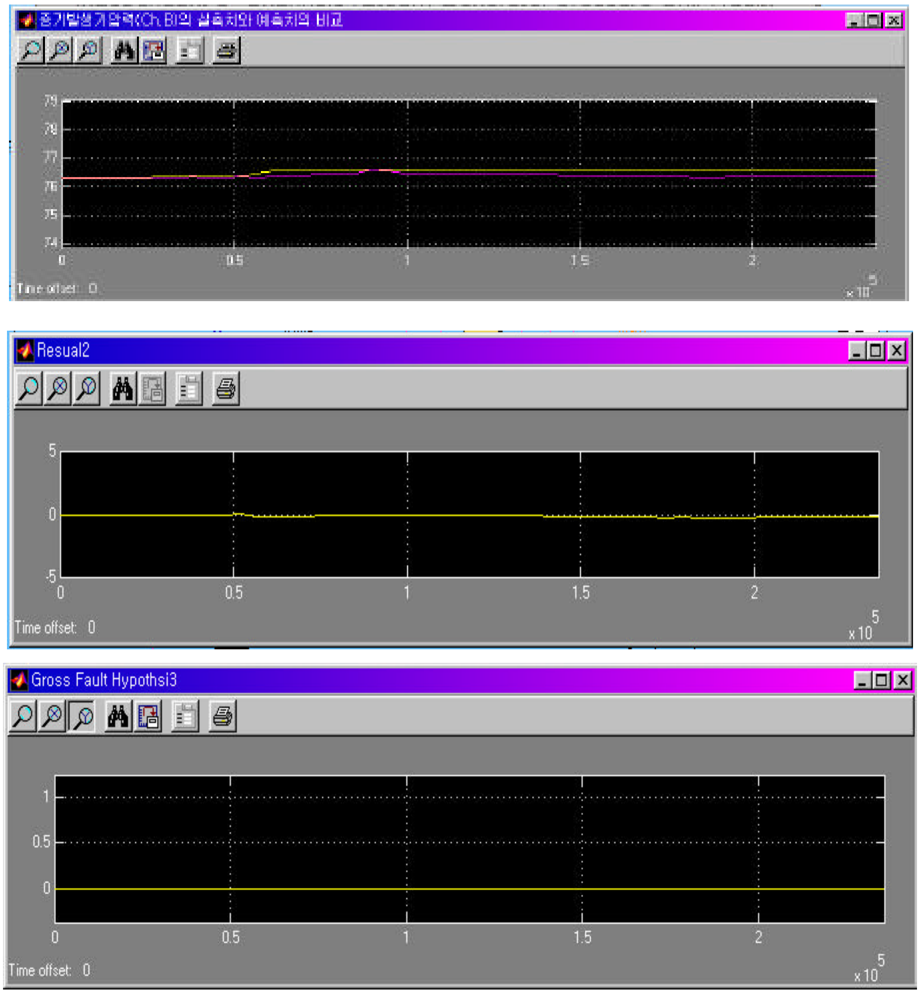

그림 6 가압기 압력 고장시 정상채널(증기발생기 압력)

그림[5]-그림[6]은 가압기 압력(B채널)의 고장모의결과이며, 여기에서 신경회로망 온라인 감시모델의 예측모델은 고장난 채널의 예측치를 예측하여, residual을 계산하고, 성능평가 모델에서는 센서의 상태가 정상일때는 0의 출력을 고장일때는 1의 출력을 하였다. 그러나 그림1의 경우, 5시간부근에서, residual이 약간 증가하는 것 을 볼 수 있다. 그 이유로는 냉각수 유량의 데이터는 다른 4개의 파라미타값과 상관관계가 매우 적었으며, 이로 인해 신경회로망 예측모델이 예측치를 바르게 예측하지 못했다는 점에 있다.

다음으로 냉각수 유량의 데이터를 제외한 나머지 4개의 파라미터들의 데이터들로 신경회로망 예측모델을 구현하여, 위와 마찬가지로 가압기 압력(B채널)에 각각 고장 데이터를 모의 하였고,

그림[7] - 그림[8]에 그 결과를 나타냈다. 각각의 그림으로부터 고장난 채널의 경우에는 고장의 크기에 비례하게 residual이 증가하고, 정상채널의 경우에는 거의 "0"에 가까운 residual을 나타내었다. 이로써 신경회로망 온라인 감시모델은 상관관계가 밀접한 변수가 파라미터로 사용될 경우 비교적 정확한 예측치를 구할수 있고, 이로부터 동일변수 다중채널뿐만 아니라, 독립채널 다중변수에 대하여도 센서채널의 편향이나 고장등의 센서의 상태를 파악할수 있음을 알수 있다.

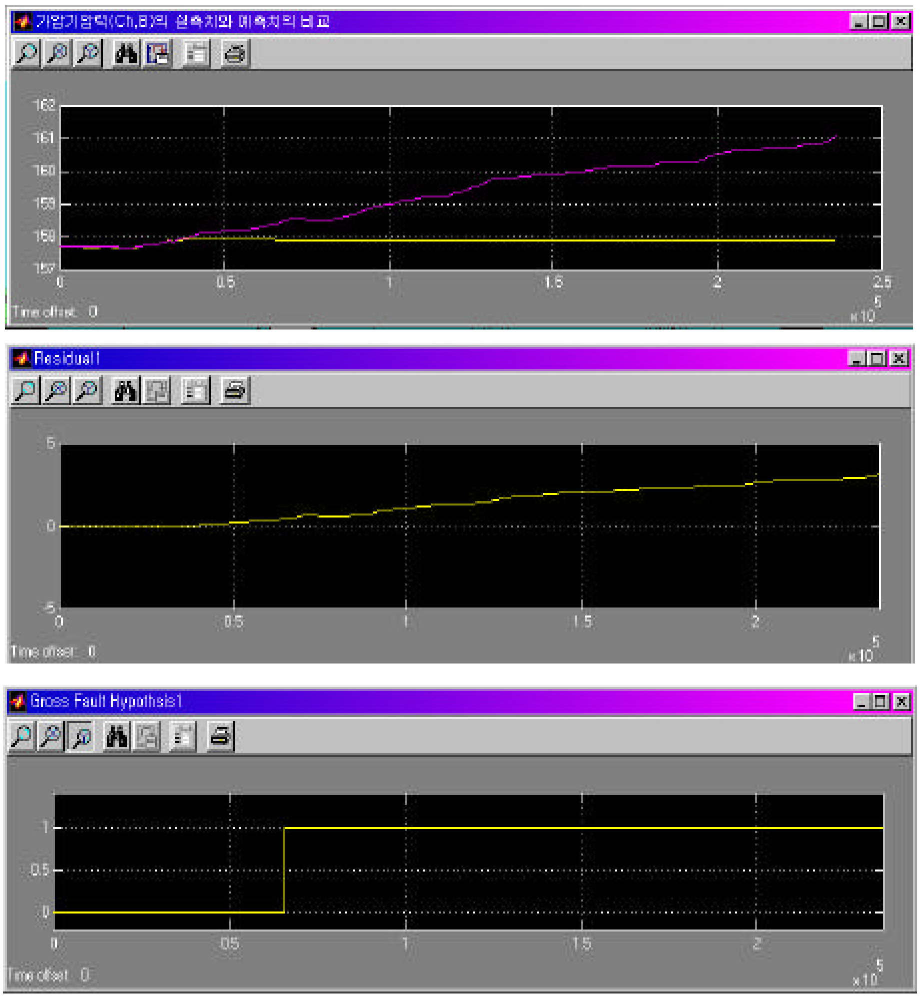

그림 7 가압기 압력 고장시 고장채널(가압기 압력)

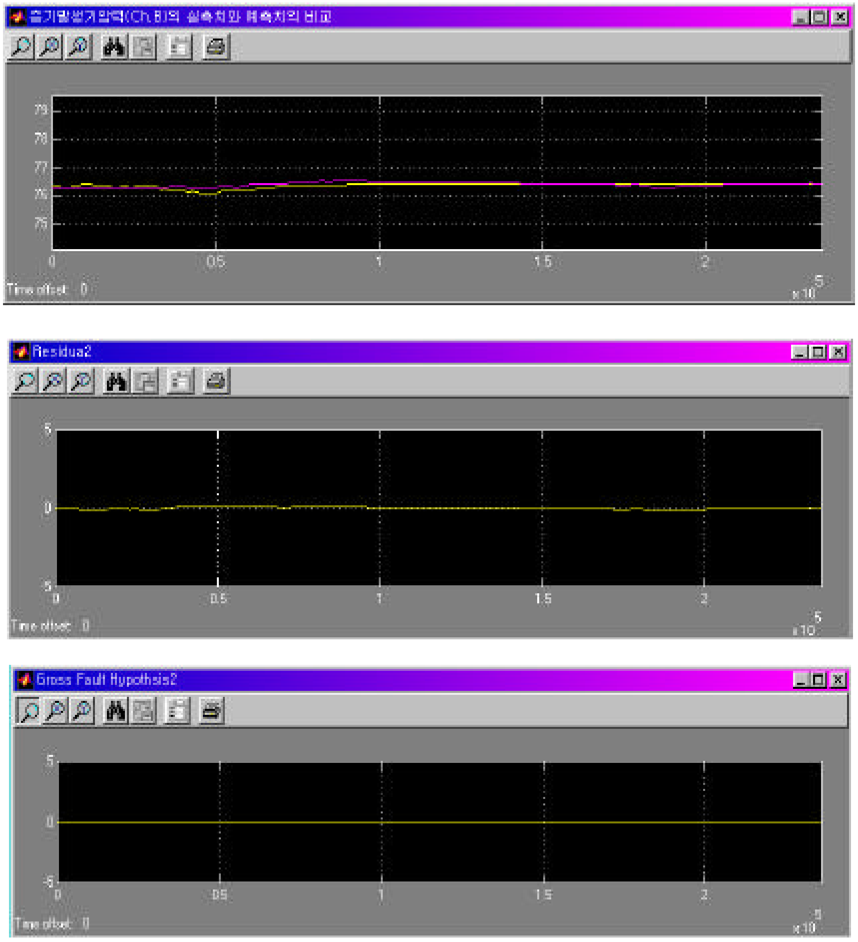

그림 8 가압기 압력 고장시 정상채널(증기발생기 압력)

8. 결론

본 연구에서는 적용대상으로 원자로보호계통(RPS: Reactor Protection System)을 설정하고, 계측 채널에 대한 성능 분석의 중요한 항목인 센서 신호검증 기법으로서 동일변수에 대한 다중입력과 독립변수에 대한 관련 변수 다중 입력에 대하여는 신경회로망을 이용한 온라인 감시모델을 구성, 적용하였다.

먼저, 국내표준원전의 현장운전자료의 취득을 통하여 구축된 온라인신호의 데이터베이스를 이용한 고장 모의를 통하여 가압기 압력 및 증기발생기 압력 등 주요 공정 변수에 대한 온라인 감시모델 적용 및 검증을 수행하였다.

각각의 고장 모의에 대하여 신경회로망 예측모델은 제한된 오차범위내에서 각 고장난 채널의 예측치를 추정하였고, 실측치와 예측치와의 차이로부터 통계적 성능평가모델인 SPRT(Sequential Probability Ratio Test)[9][10]를 통하여 센서의 상태를 파악할수 있었다.

본 논문에서는 고장난 센서 신호의 오류적 신호를 임의로 주어 모사를 수행하였는데, 계측기기의 불확실성들을 고려한 현실적인 고장 신호 모델링이 요구 된다.

신경회로망 온라인 감시모델이 2개의 채널을 통해 1-out-of-2로직을 갖는 계측기기에 적용될

경우 상관관계가 있는 다른 계측기기의 신호를 통한 예측을 통하여, 고장의 검출은 가능하지만 분리가 불가능했던 문제를 해결할수 있고, 온라인으로 계측기기의 편향, 혹은 고장을 검출하므로써 모든 계측기기에 대해 일정 주기마다 의무적으로 해주었던 계측기기의 보정횟수를 감소시키며, 따라서 유지보수비용을 줄일수 있는 경제적인 방안이 될 수 있다.

8. 참 고 문 헌

[1] "On-line Monitoring of Instrument Channel Performance", EPRI(TR-104965), Nov. 1998

[2] "Guidelines for Instrument Calibration Extension/Reduction", EPRI(TR-103335-RI), Oct. 1998

[3] "Surveillance of Instrumentation Channels at Nuclear Power Plants", EPRI(NP-6067-V1, V2), Oct. 1998

[4] "System Description for Plant Protection System for YGN3&4", 10487-SD-100

[5] "Validation of Critical Signals for the Safety Parameter Display System",EPRI(NP-5066-M), Apr. 1987

[6] D.Dong, T.J.McAvoy, "Sensor Data Analysis Using Autoassociative Neural Nets", Proceedings of World Congress On Neural Network, Vol 1, pp.161-166, San Diego June 5-9, 1994

[7] 최중인, 디지털 자동 감시 제한 계통의 개발 및 검증, KAERI/CM-030/95, 한국원자력연구소, 1995.

[8] M.A Kramer, "Autoassociative Neural Network", Tennessee, Knoxville, TN, May 24-26, 1995

[9] K.Humenik, K.C.Gross, "Sequential Probability Ratio Tests for Reactor Signal Validation and Sensor Surveillance Application", Nucl. Sci. Eng., Vol. 105, pp.383-390, 1990

[10] Katalin Kulacsy, "Futher Comments on the Sequential Probability Ratio Testing Methods" Ann. Nucl. Energy, Vol. 24, No.13, pp. 1005-1012, 1997