

체크밸브의 원격 상태감시 시스템 구현

Realization of Remote Condition Monitoring System for Check Valve

이 승 언, 전 정 섭, 유 준*

(Seung-Youn Lee, Jeong-Seob Jeon, and Joon Lyou)

Abstract : This paper presents a realization of check valve condition monitoring system based on fault diagnosis algorithm and Fieldbus communication. We first acquired AE(acoustic emission) sensor data at the check valve test loop, extract fault features through the learned neural network, and send the processed data to a remote site. The overall system has been implemented and experimented results are given to show its effectiveness.

Keywords : check valve, AE sensor, neural network, device net.

I. 서론

원자력 발전소의 안정적 운전은 발전소 내의 많은 부분들의 정확한 동작에 의존한다. 이 중 체크밸브는 원자력 발전소당 약 450개 이상 설치되어 있으며 유체를 한 방향으로만 흐르게 하고 반대 방향으로는 흐르지 못하게 하는 역할을 수행한다. 체크 밸브는 고온, 고압의 가혹한 환경에서 사용되기 때문에 고장이 발생할 경우 발전소에 수격현상과 저압력 시스템에서 과압 현상 및 압력이 있는 시스템에 손상을 입히므로 이 밸브의 적절하고 신뢰할 수 있는 동작은 매우 중요하다[1,2].

1986년 미국에서 발생한 다수의 체크밸브 고장은 몇몇의 원자력발전소 시스템에 중대한 손상을 유발함으로 초미의 관심 대상이 되었다. 체크밸브는 그 내부의 위치나 움직임을 가리키는 외부 지시자 없이 자급식으로 스스로 동작한다. 따라서 체크밸브의 정상동작 여부를 확인하기 위한 일반적인 관행은 원자력 발전소의 운전 정지시마다 10~30개의 밸브를 분해하고 관찰하는 것이었다. 이러한 예방 유지 방법은 많은 시간이 소모되며, 인력 및 비용이 많이 들 뿐만 아니라 유지 유발 고장, 운전 정지 시간의 지연으로 인한 경제적 손실 등 매우 많은 심각한 문제점을 야기하였다. 이에 따라 이런 문제점들을 혁신적으로 개선할 수 있는 비파괴 검사기법이 도입이 절실하게 되었다[3-5].

이에 따라 Agostinelli는 음향방출 센서와 자속 센서를 사용하여 체크밸브를 진단하는 기법을 제안하였고[6], Yang은 초음파 센서와 음향 방출 센서를 이용한 체크밸브 진단 기법을 제안하였다[7]. Uhring과 Tsoukalas는 체크밸브의 힌지 핀과 백스탑에서 얻어진 신호를 FFT기법을 이용하여 주파수 영역으로 변환 후 각각을 신경망의 입출력으로 사용하므로 시스템 가동 중 고장 여부를 진단하는 기법을 연구하였다[8]. 이처럼 내부의 디스크의 위치, 움직임, 누수 등의 상

태 감시를 위해 음향방출, 초음파 관찰, 자속 신호 분석 등의 세 가지 방법이 사용되어 왔다. 하지만 대부분의 연구가 고장 여부를 검출하는데 초점이 모아져 있으며 고장발생시 구체적으로 어떤 고장이 발생했는지에 대한 연구는 미흡하다. 또한 체크밸브의 고장 상태를 확인하기 위해서는 개개의 체크밸브에 측정 장비를 가져가야 하므로 원격에서 감시할 수 있는 기법이 필요하다.

음향 방출기법은 다른 비파괴 검사방법들이 결합의 위치와 크기, 정적인 상태의 결합만을 검출하는데 반해 균열진전과 같은 동적인 거동을 감지하여 가동 상태인 기계나 구조물을 실시간으로 모니터링 할 수 있는 장점이 있다. 특히 원자력 발전소에서의 배관의 균열이나 밸브손상유무, 누설 검사 등을 위한 위험부분의 감시기구로서 널리 이용되고 있다[9]. 이에 따라 본 논문에서는 음향방출기법에 기반을 둔 원격 상태 감시 시스템의 개발을 통해 체크밸브의 성능감소나 노화 발생시 시기적절하게 검출하여 안전기능을 상실하기 전에 교체 또는 유지보수를 가능하도록 하였다. 뿐만 아니라 대표적인 고장 요소 분석을 통해 체크밸브의 고장 감지시 원인을 진단하는 알고리즘과 원격 모니터링을 통하여 운전원이 원격리에서도 체크밸브의 상태를 감시 할 수 있도록 하였다.

II. 체크밸브의 상태감시 기법

1. 체크밸브 손상 메커니즘




그림 1. 스윙형 체크밸브 구조.

Fig. 1. Structure of swing type check valve.

* 책임저자(Corresponding Author)

논문접수 : 2005. 1. 15., 채택확정 : 2005. 4. 25.

이승언 : 국방과학연구소(Isyacts@hanmail.net)

전정섭, 유준 : 충남대학교 전자공학과

(mukkeby@cnu.ac.kr/jlyou@cnu.ac.kr)

※ 본 연구를 수행하는데 있어 자료 및 실험환경 제공 등 많은 도움을 주신 원자력 연구소 관계자 여러분께 감사드립니다.




그림 2. 체크밸브의 인공결함.
Fig. 2. The artificial defects of check valve.




그림 3. 센서 위치.
Fig. 3. Sensor location.

일반적으로 널리 쓰이는 체크밸브는 스윙형이며 그림 1에서 보는 바와 같이 몸체(body)를 중심으로 디스크(disc), 디스크 너트(disc nut), 디스크 너트 핀(disc nut pin), 힌지 아암(hinge arm), 힌지 핀(hinge pin), 씰링(seat ring), 캡 스테드(cap studs) 등으로 구성되어 있다.

국내외에서 10년 이상 운전 중인 원전에 대해 고장 유형을 조사한 결과 “disc/seat 마모”, “hinge pin 마모”, “이물질 끼임 현상” 및 “잘못된 조립에 의한 누수” 등이 80% 이상을 차지하는 것으로 분석되었다[10-12]. 이 네 가지 원인이 발생할 경우에 대한 신호 특성에 대해 알아보기 위해 체크밸브의 고장유형 시험을 위한 DVI(Direct Vessel Injection) test loop의 제작 및 시험을 수행하였다.

연구에 사용한 체크밸브는 4인치로서 모두 4개의 밸브에 대해서 각각의 인위적인 고장을 만들어 시험을 수행하였다. 시험 결과 hinge pin wear와 improper assembly의 경우 고장을 일으킨 부위와 정도에 따라 어느 정도 그 기능을 수행하다가 디스크가 떨어져 나가거나 hinge arm의 이탈 등 예측하기 부적합한 파국고장으로 이어졌다. 이에 따라 예측이 가능한 disc/seat 마모와 foreign object 간섭에 대해서만 시험을 수행하였다. 그림 2는 본 연구에 사용된 체크밸브의 인공결함을 나타낸 사진이다.

2. AE센서를 이용한 데이터 취득

음향방출은 재료의 외력 또는 내부의 국부적인 변형이나 파괴가 일어날 때, 재료 내부에 축적되어 있던 변형 에너지(strain energy - 파면형성에너지, 열에너지, 격자변형에너지)의 급격한 방출에 의한 탄성파(elastic wave)로서 정의하며, 이러한 탄성파를 전기적으로 변환해 주는 계측장치를 AE 센서라고 한다.

AE신호는 신호의 강도 및 특정 주파수의 범위가 매우 광범위하며 검출할 수 있는 주파수 대역에 따라 공진형(resonant type)센서와 광대역(wide-band type)센서로 구분된다. 공진형 센서는 특정 주파수 성분에서 높은 수신감도를 나타내며 잡음 레벨이 낮은 것이 특징이며, 광대역 센서는 넓은 주파수 범위에서 균일한 감도를 나타내며 감도가 낮으므로 방출되는 신호의 강도가 낮을 경우에는 사용의 제약이 따르게 된다.

AE센서를 부착할 위치와 종류를 선택한 후 AE계측은 기능별로 세 가지로 나눌 수 있다. AE센서를 중심으로 하는 입력부와 AE센서에 의해 검출된 미약한 신호를 증폭시키기 위한 증폭부, 그리고 검출된 신호로부터 각종 신호처리를 수행하는 신호처리부이다.

2.1 센서 종류 및 위치 선택

본 실험에서 사용한 AE센서는 Physical Acoustic社에서 제작한 공진형 센서 R6, R15와 광대역 센서인 WB이다. R6의 경우 중심 주파수 60KHz를 기준으로 30~100KHz까지의 주파수를 검출하고, R15의 경우 중심 주파수 150KHz를 기준으로 50~200KHz이며, WB센서의 경우 650KHz를 중심으로 100~1200KHz까지의 주파수를 검출한다. 여러 번에 걸친 실험 결과 체크밸브의 누설에 가장 민감한 센서로 R15센서를 선정하였다. 밸브의 개폐시 밸브 입구와 출구에 작용하는 압력이 다르며 이때 밸브 내벽 및 디스크, 핀에 작용하는 하중이 달라지기 때문에 보다 국부적으로 압력이 가해지는 곳에 센서를 부착하는 것이 타당하다. 이에 따라 유한요소해석을 이용하여 압력을 분석하였다.

그 결과 밸브에 작용하는 압력은 밸브 상부보다 하부에서 더 큰 압력이 작용함을 알 수 있었고, 누설량은 압력과 상관관계가 있으므로 누설 신호를 측정하기 위해 밸브의 하부에 디스크와 가장 가까운 부위에 부착하는 것이 타당하다[13]. 이에 따라 AE센서를 그림 3과 같이 체크밸브의 출구측 하부 배관에 부착하였으며 센서의 수신감도를 높이기 위해 시험편에 coupling agent(Krautkramer社)를 부착하였다.

체크밸브 테스트는 물을 유체로 이용하여 수행되었고 실온(25°C)에서 모터를 이용하여 DVI test loop 내의 압력을 3bar, 6bar, 9bar로 올려가며 다음과 같은 경우에 대해서 각각 실험을 수행하였다.

- Normal Condition
- Disc Wear Failure : 1mm, 2mm, 3mm.
- Foreign Object : 0.5mm, 1.0mm, 1.2mm, 1.5mm, 2.0mm, 2.4mm.

Disc wear 고장의 경우 크기별로 디스크를 갈아내었으며 Foreign object의 경우 용접봉을 체크밸브 내에 설치하여 고장을 발생시켰다.

2.2 AE 신호의 배경잡음 제거 및 증폭

AE센서에 의해 검출된 신호는 대부분 μV ~mV로 매우 미약한 신호이기 때문에 신호처리를 위해서 수천 혹은 수만배의 증폭이 필요하다. AE 신호의 증폭은 통상 데시벨(dB)로 표시되며 다음과 같이 정의 된다.

$$dB = 20 \log(V_o / V_i) \tag{1}$$

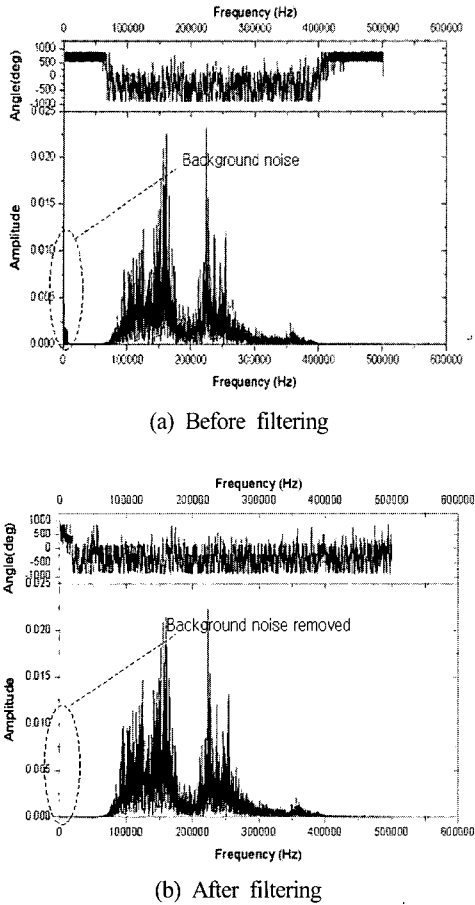


그림 4. Disc wear신호의 필터링.
Fig. 4. Filtering of the disc wear signal.




그림 5. MUSIC알고리즘을 이용한 특징 주파수 계산.
Fig. 5. Calculation of characteristic frequencies by MUSIC algorithm.

여기서, V_0 는 증폭전의 신호크기이며, V_N 는 증폭후의 AE 신호크기를 나타낸다. 이러한 신호의 증폭은 프리앰프와 메인 앰프에 의해서 이루어진다. 여기서 프리앰프는 센서와 메인 앰프간의 케이블 길이에 따른 감쇠현상을 막기 위한 것이다.

앰프에의 과도한 신호의 증폭은 주변의 불필요한 배경잡음이나 계측장비 자체의 잡음성분까지 증폭되는 경우도 발생할 수 있으므로 적절한 신호의 증폭이 요구되며 이러한 잡음을 제거하고 특정 주파수 범위내의 신호만을 검출하기 위해 필터링을 필요로 한다. 본 실험에서는 센서로부터 얻

어진 AE 신호들은 프리앰프(1220A)에서 40dB를 증폭하였으며 대역통과필터를 통과한 후 메인앰프에서 다시 40dB를 증폭시켰다. 대역통과필터는 잡음을 제거하는 역할을 수행하며 데이터 취득 결과 정상상태의 신호와 고장상태의 신호의 비교를 통하여 25KHz 이하의 저주파 영역에서 공통적인 배경 잡음이 존재함을 알 수 있었다. 따라서 버터워스필터를 15차수로 설계하였으며 통과 대역은 25KHz~460KHz로 설계하여 그림 4와 같이 배경잡음을 제거하였다.

2.3 특징점 추출

일반적인 재료에서 발생하는 음향방출 신호는 대개 수만에서 수십만개에 달한다. 이렇게 많은 파형을 하나하나 분석하여 처리한다는 것은 많은 시간이 소요되는 일이므로 파형의 특징을 나타내는 변수만을 추출하여 시험 분석 데이터로 이용하는 것이 일반적이며 대개 상용화된 장비는 이러한 변수를 사용하여 처리한다. 하지만 상용화된 장비는 값이 매우 비싸며 단일체크밸브에 사용되기 때문에 450여개의 체크밸브를 모두 감시하기에는 많은 문제가 있다. 본 연구에서는 스마트 센서 내부에서 음향 방출 신호의 특징점을 직접 추출하도록 하였다. 일반적이며 각 경우별로 특징을 잘 구분하는 실효전압치(RMS) 값과 전압 최대값, AE 에너지, 그리고 특징 주파수, 압력값을 이용하였고 각 파라미터별 설명은 다음과 같다.

2.3.1 RMS값

마모나 누설에 의해서 발생하는 음향 방출 신호는 연속형 신호이며 이 경우 적용할 수 있는 파라미터로서 실효전압치를 사용할 수 있다.

$$RMS = \sqrt{\left(\frac{1}{N} \sum_{i=0}^N V_i^2\right)} = \sqrt{\frac{V_1^2 + V_2^2 + \dots + V_N^2}{N}} \quad (2)$$

여기서 V_i 는 센서 출력이며 N 은 총 데이터 수이며, 본 실험에서는 최대 버퍼 크기인 216을 사용하였다.

2.3.2 전압 최대값

전압 최대값의 경우 돌발형 신호를 고려하여 일정한 값을 얻기 위해 구간 전압 최대값들의 평균을 이용하여 구하였다. 여기서 구간 m 은 8을 사용하였다.

$$V_p = \frac{\{Max(V_1 \sim V_m) + Max(V_{m+1} \sim V_{2m}) + \dots + Max(V_{N-m} \sim V_N)\}}{N/m} \quad (3)$$

2.3.3 AE 에너지

AE 에너지(EAE)는 재료의 파괴 인성치와 균열 진전량 및 신호발생원등을 규명하는데 이용하며 AE 진폭과 상관관계가 있다.

$$E_{AE} = \frac{1}{R} \sum_{i=0}^N V_i^2 \quad (4)$$

여기서 R 은 측정회로의 전기저항이다.

2.3.4 특징 주파수

Freq1과 Freq2는 얻어진 신호의 특징 주파수를 의미한다. FFT알고리즘을 이용한 주파수 영역으로 변환 후 MUSIC(Multiple Signal Classification) 알고리즘을 사용하여 계산하였다. 그림 5에서 보듯이 첫 번째 최고점을 첫 번째 특징

주파수 Freq1으로 사용하였고, 두 번째 최고점을 두 번째 특징 주파수 Freq2로 사용하였다.

2.3.5 압력

압력은 단위 면적당 미치는 힘의 크기이다. 국제적인 압력 단위는 파스칼(pa)이며 1bar는 10⁵pa이다. 본 논문에서는 압력을 사전에 알고 있다고 가정하였고 이를 특징점으로 사용하였다.

$$p = \frac{F}{A} \tag{5}$$

여기서 p는 압력이고 F는 힘, 그리고 A는 면적이다.

3. 신경망을 이용한 고장 진단 알고리즘

일정 데이터에 의하여 학습된 신경회로망은 학습데이터에 포함되지 않은 입력에 대해서도 일반적으로 추정할 수 있는 학습력과 적응력이 있다. 신경회로망에는 많은 종류가 있지만 본 논문에서는 일반적이며 널리 쓰이는 역전파 알고리즘을 적용하였다. 역전파 알고리즘은 오차함수의 기울기가 감소하는 기울기 감소법(gradient descent method)을 이용한다. 신경회로망 시스템은 초기에 중간 가중치를 임의로 설정하여 시스템을 구축한다. 구축된 시스템에 AE신호의 특징점을 입력하여 출력값을 계산하고, 원하는 출력값과의 오차를 계산하여 이 오차가 작아지는 방향으로 초기 가중치가 조절되어 간다. 이와 같이 출력오차가 최소화되도록 중간 가중치를 반복학습에 의해 조절하여 최적화시킨다.

역전파 알고리즘을 도입한 신경망의 학습과정은 다음을 반복하는 과정에 가중치를 변경시켜 최적화 시킨다.




그림 6. 신경망 모델.
Fig. 6. The neural network model.

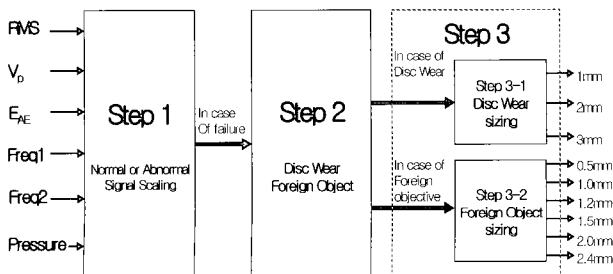


그림 7. 고장진단 알고리즘.
Fig. 7. Fault diagnosis algorithm.

$$\begin{aligned} w_{jk}(t+1) &= w_{jk}(t) + \Delta w_{jk} + \alpha(w_{jk}(t) - w_{jk}(t-1)) \\ b_j(t+1) &= b_j(t) + \Delta b_j + \alpha(b_j(t) - b_j(t-1)) \\ w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij} + \alpha(w_{ij}(t) - w_{ij}(t-1)) \\ b_k(t+1) &= b_k(t) + \Delta b_k + \alpha(b_k(t) - b_k(t-1)) \end{aligned} \tag{6}$$

여기서, \$W_{jk}, W_{ij}\$ 는 각 레이어 사이의 가중치 값이며 \$b_j, b_k\$는 바이어스의 가중치이다. \$\Delta w_{ij}, \Delta w_{jk}\$는 가중치의 변화율이며 \$\alpha\$는 모멘텀 계수이다. 은닉층의 노드 수를 오차를 최소화하기 위하여 몇 가지의 수를 변경하여 시험하였고 그 결과 은닉층의 개수를 12개로 정하였고, 학습률을 0.5로 설정하였으며 모멘텀 계수를 0.7로 잡았고, 결합강도의 초기값은 랜덤함수를 이용하여 -0.5-0.5의 범위에서 발생하도록 하였다.

신경망 입력 데이터는 다음 두 가지 측면에서 정규화될 필요가 있다. 첫 번째로 각 데이터의 신경망 학습에 미치는 중요도는 동일한 것이 되어야 하며 시그모이드형 전달함수가 조속히 포화상태에 빠지는 것을 방지하기 위함이다. 두 번째로 출력 또는 목표데이터는 출력 전달함수가 가질 수 있는 범위 내에 놓여야 하기 때문이다. 변환되지 않은 데이터는 해당 범위에서 대응될 수 없는 것이 된다. 입력데이터의 변환에 관해 선형변환 및 z-점수 변환방법 등이 있다. 본 논문에서는 선형변환 수식 (7)을 사용하여 각 입력 변수의 값을 0.1-0.9사이로 분포시켰다.

$$V_i = \frac{0.8}{v_{\max} - v_{\min}} v_i + \left(1 - \frac{0.8v_{\min}}{v_{\max} - v_{\min}}\right) \tag{7}$$

학습 데이터는 각 특징점들의 평균값을 이용하였으며 학습시킨 결과 오차가 모든 단계에 대해 0.1%이하로 수렴하는 것을 확인하였다.

그림 7은 본 실험에서 사용한 고장진단 알고리즘을 나타낸다. 총 3단계로 구성되었으며 각 단계별 내용은 아래와 같다.

- 단계 1 : 추출된 특징점을 기반으로 고장여부 판별.
- 단계 2 : 고장상태일 경우 DW인지 FO인지 구분.
- 단계 3 : 각 고장 유형별 고장 크기 구분.
 - 단계 3-1 : DW 고장 크기 구분.
 - 단계 3-2 : FO 고장 크기 구분.

각 단계별로 신경망을 학습시켰다. 즉 1단계에서는 정상인 상태의 데이터 특성과 DW와 FO를 고장인 경우로 학습시켰으며, 2단계에서는 정상시를 제외한 DW와 FO를 가지고 학습을 시켰다. 3단계에서는 DW 또는 FO의 크기별로 학습시켰다. 이렇게 데이터 특성별로 나누어 학습을 시킴으로 더욱 명확하게 신경망을 학습시키고, 주어진 입력에 대하여 적절하게 분류할 수 있다.

그림 8, 9, 10, 11은 학습된 신경망에 학습되지 않은 모든 데이터를 입력한 결과이다. 파란색선으로 표시된 것이 기준 출력이고 빨간 점으로 표시된 것이 신경망의 출력이다. 세로 점선에는 각 고장 모드별, 압력별 구분선을 나타내었으며 이를 상하 수평축에 표기하였다. 수평 점선에는 기준 출력 및 문턱값을 구분하며 이를 좌측 수직축에 표기하였다. 또한 오판영역을 그림에서 빗금으로 표기하였다.




그림 8. 1단계 학습 결과.
Fig. 8. Learning result of step 1.




그림 10. 3-1단계 학습결과.
Fig. 10. Learning result of step 3-1.




그림 9. 2단계 학습 결과.
Fig. 9. Learning result of step 2.




그림 11. 3-2단계 학습결과.
Fig. 11. Learning result of step 3-2.

1단계에서는 정상과 고장상태를 구분하며 정상상태일 경우 0.9를 출력하도록 하였고, 고장시 0.1을 출력하도록 학습 시켰다. 2단계에서는 DW인지 FO인지를 구분하며 DW일 경우 0.9, FO인 경우 0.1을 출력하도록 학습 시켰다. 문턱값은 0.5로 설정하였으며 실험 결과 1단계에서는 모든 경우에 대하여 정상과 고장을 완벽하게 분류하였으며 2단계에서는 0.37%의 매우 적은 오판율을 보였다. 가장 많은 오판율을 보인 곳은 foreign object 0.5mm 1bar의 경우로 disc wear로 구분하였다.

3-1 단계는 DW 크기를 구분하는 단계이며 1mm일 경우 0.1, 2mm일 경우 0.5, 3mm일 경우 0.9로 출력되도록 신경망 출력을 학습시켰다. 실험결과 5.33%정도의 적은 오판율을 보였다. 가장 많은 오판율을 보인 곳은 disc wear 1mm 9bar 인 경우로서 1mm를 2mm로 판정하였다.

3-2 단계는 FO 크기를 구분하는 단계이며 0.5mm일 경우 0.1, 1.0mm일 경우 0.3, 1.2mm일 경우 0.4, 1.5mm일 경우 0.5, 2.0mm일 경우 0.7, 2.4mm일 경우 0.9로 출력되도록 신경망 출력을 설정하였다. 실험결과 12.68%정도의 오판율을 보였다. 가장 많은 오판율을 보인 곳은 FO 2mm인 경우로 2mm를 2.4mm로 판정하였다. 따라서 신경망 학습결과 고장을 효과적으로 검출 및 분류하는 것을 확인 할 수 있었다.

III. 원격 상태 감시 기법

종래의 제어시스템에서 계측 기기들은 4~20mA의 아날로그 신호들을 그대로 전송하거나 RS-232등과 같은 병렬통신 장비들에 의하여 point-to-point 방식으로 연결되었다. 이러한 방식에서는 배선 및 통신관련 H/W와S/W 접속 및 설치에 많은 비용과 노력이 소모되며, 시스템의 설계와 유지 보수도 매우 어렵게 된다. 이러한 단점들을 해결하기 위하여 시리얼 통신을 통하여 제어관련 디지털 데이터를 실시간으로 지원하는 필드버스라는 개념의 프로토콜이 출현하게 되었다. 필드버스는 병렬로 연결되는 아날로그 시스템에 비해서 양방향 데이터 교환, 향상된 정확성, 데이터 크기, 케이블 절감의 장점을 가지고 있으며 필드버스의 종류에는 LON, PROFIBUS, CAN, AS-I, INTERBUS등이 있다[14].

본 논문에서는 CAN 프로토콜에 기반한 DeviceNet을 이용하여 통신을 수행하였다. DeviceNet은 센서, 액추에이터, 모터스타터와 같은 간단한 공장용 설비를 위한 산업용 네트워크이며 호환성이 뛰어나고 CAN에 준거한 통신프로토콜로써 저가격의 특징을 가진다. 또한 다습환경이나 오염된 곳, 부식성이 높은 환경 등 산업 용도를 위한 설계에 적합하므로 원자력 발전소 내에 원격 모니터링으로 활용하기 적합하다[15].

1. 시스템 구성

그림 12에서 보듯이 시스템은 크게 두 부분으로 구성되어 있다. 우선 DeviceNet interface Card를 장착한 PC를 마스터(원격 모니터링 시스템)로 사용하였고, 슬레이브(스마트 센서)는 PXI모듈로 구성하였다. 세시는 PXI 1002를 사용하였으며 데이터를 받기 위한 DAQ(NI PXI-6070E)와 데이터 전송을 위한 DeviceNet interface card(PXI-8461), 신호처리를 위한 임베디드 프로세서(PXI 8174)로 구성하였다. 커넥터는 BNC-2110을 이용하였다.

2. 프로그램 구현 및 실험결과

소프트웨어는 Labview를 이용하였으며 이는 프론트 패널과 블록 다이어그램으로 구성되어 있다. 프론트패널에는 각종 입력 값 및 출력 값의 형태를 디자인해주고, 블록 다이어그램에서는 입력된 데이터를 처리할 알고리즘을 코딩해 준다.

2.1 슬레이브 프로그램

Signal conditioning(pre-amp, band pass filter, main amp)과정을 거친 신호는 슬레이브의 DAQ에서 A/D 변환과정을 거치고, 임베디드 프로세서에서 앞서 언급한 AE센서 특징점을 추출한 후 특징점들을 DeviceNet을 통해 Master로 전송한다.

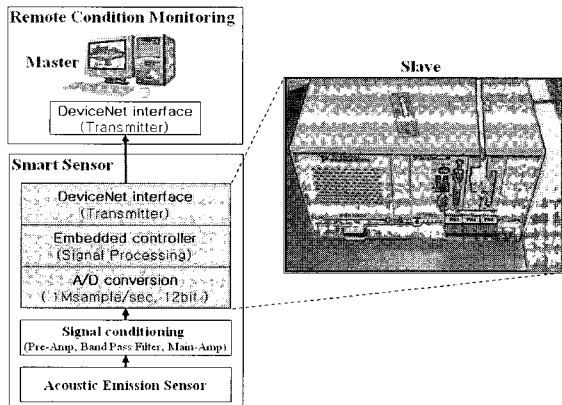


그림 12. 하드웨어 구성도.
Fig. 12. Hardware structure.




그림 13. 슬레이브 프로그램의 전면 패널.
Fig. 13. Front panel of slave program.

그림 13은 Disc wear 의 3bar, 2mm 고장일 경우에 대한 신호 파형 및 FFT 및 얻어진 신호로부터 추출된 특징점을 보여준다. 그림 14에 내부 프로그램 구성을 나타내었다.

2.2 마스터 프로그램

마스터에서는 슬레이브에서 송신된 특징점을 수신하며, 학습된 신경망의 입력에 넣어 제한한 고장 진단 알고리즘을 수행하도록 구성하였다. 그림 15에서 보듯이 수신된 신호는 step1에서 0.09의 출력으로 비정상이며, step2에서는 0.9의 출력으로 disc wear 고장이고, step 3에서는 0.51의 출력으로 고장 크기가 약 2mm 인 것으로 판별하였다. 이를 통해 시스템이 효과적으로 구현/동작함을 알 수 있었다.

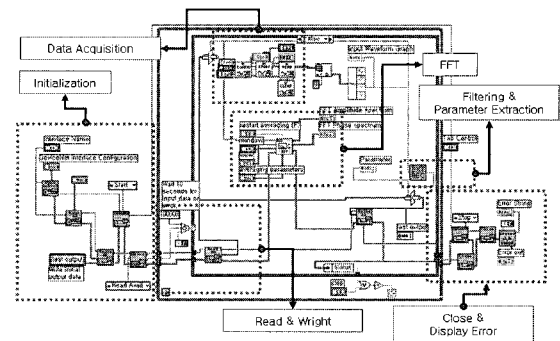


그림 14. 슬레이브 프로그램의 블록선도.
Fig. 14. Block diagram of slave program.




그림 15. 마스터 프로그램의 전면 패널.
Fig. 15. Front panel of master program.

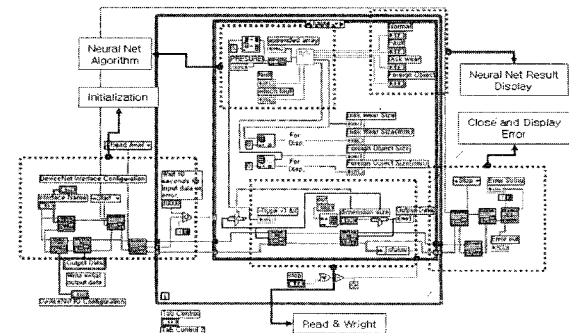


그림 16. 마스터 프로그램의 블록선도.
Fig. 16. Block diagram of master program.

IV. 결론

체크밸브는 원자력 발전소에서 시스템 보호와 적절한 동작에 있어 매우 중요한 역할을 담당한다.

본 논문에서는 음향방출기법에 기반을 둔 스마트 센서의 개발을 통해 체크밸브의 성능감소나 노화발생시 시기적절하게 검출하여 안전기능을 상실하기 전에 교체 또는 유지보수를 기능하도록 하였다. 뿐만 아니라 대표적인 고장 요소 분석을 통해 체크밸브의 고장 감지시 원인을 진단하는 알고리즘과 원격 모니터링을 통하여 운전원이 원격리에서도 체크밸브의 상태를 감시 할 수 있도록 하였다. 이는 차세대 원자력 발전소의 체크밸브 상태 감시에 있어 중요한 기여를 할 것으로 기대된다.

참고문헌


[1] S. H. Esteeck and Rosser, "Check valve water hammer characteristics," American Nuclear Society Meeting, 1959.
 [2] A. J. Pool, A. J. Porwit, "Prediction of surge pressure from check valves for nuclear," American Society of Mechanical Engineers, 1982.
 [3] D. S. Kupperman, D. Prine, "Application of acoustic leak detection technology for the detection and location of leaks in light water reactors," U. S. Nuclear Regulatory Commission, 1988.
 [4] H. D. Hayes, "Evaluation of check valve monitoring methods," *Proceedings of the 17th Water Reactor Safety Meeting*, October 23-25, Rockville, MD, 1989.
 [5] H. D. Haynes, et. al., "Aging and service wear of check valves used in engineered safety-feature system of nuclear power plants," *NUREG/CR-4302*, vol. 2, 1991.
 [6] A. Agostinelli, "Check valve diagnostics utilizing acoustic and magnetic technologies," *Nuclear Plant Journal*, pp.

80-90, November, 1990.
 [7] M. K. Yang, "Acoustic and ultrasonic signals as diagnostic tools for check valves," *Journal of Reactor Vessel Technology*, vol. 115, pp. 135-141, May, 1993.
 [8] R. E. Uhring et. al., "Using neural networks to monitor the operability of check valves," *Proc. of the Conf. on Expert System Application for the Electric Power Industry*, Phoenix, AZ, December 8-10, 1993.
 [9] R. E. Uhring and L. H. Tsoukalas, "Application of neural networks," *EPRI/TR-103443-PI-2*, Knoxville, TN, January, 1994.
 [10] U. S. Nuclear Regulatory Commission, "Nuclear plant aging research (NPAR) program plan," *NUREG-1144-Rev. 2*, NRC, June, 1991602-612, 1998.
 [11] K. L. McElhaney, "An analysis of check valve performance characteristics based on valve design," *Nuclear Engineering and Design*, vol. 197, pp. 169-182, 2000.
 [12] J. T. Kim et al, "Analysis of failure type of acitve component in nuclear power plant," *KAERI/TR-2334/2002*, 2002.
 [13] J. H. Lee et al, "Development of evaluation technique of characteristic of ultrasonic and acoustic emission sensor for development of fusion sensor," *KAERI/TR-2335/2002*, 2002.
 [14] J. H. Park, *An introduction to fieldbus*, Dong-Seo Press, Seoul, Korea, 2000.
 [15] H. S. Chang, H. S. Kim, "Control system design by CAN-based deviceNet" *Industrial technology of Korea*, vol. 8, pp. 731-746. 1998.




이 승 연

1980년 12월 27일생. 2003년 충남대학교 학사 및 2005년 동 대학원 석사 졸업. 현재 국방과학연구소 연구원. 제어 전공. 관심분야는 시스템 모델링, 신호처리, 이동로봇.



전 정 섭

1976년 7월 10일생. 2002년 충남대학교 학사 및 2004년 동 대학원 석사 졸업. 현재 동 대학원 박사과정. 제어 전공. 관심분야는 센서 신호처리, 필드버스.



유 준

1956년 3월 22일생. 1978년 서울대 전자공학과 졸업. 한국과학기술원 전기 및 전자공학박사(1984년). 1984~현재 충남대학교 정보통신공학부 교수. 관심분야는 고장진단, 산업공정, 센서 신호처리 등.