

LCD 라인의 음향 특성신호에 웨이블릿 변환과 인공신경망회로를 적용한 공정로봇의 건정성 감시 연구

김의열* · 이상권*† · 장지욱*

* 인하대학교 기계공학과

Condition Monitoring of an LCD Glass Transfer Robot Based on Wavelet Packet Transform and Artificial Neural Network for Abnormal Sound

Eui-Youl Kim*, Sang-kwon Lee*† and Ji-Uk Jang*

* Dept. of Mechanical Engineering, Inha Univ.

(Received March 26, 2012 ; Revised May 12, 2012 ; Accepted May 12, 2012)

Key Words: Abnormal Operating Sound(비정상 작동 소음), Wavelet Packet Transform(웨이블릿 변환), Artificial Neural Network(인공 신경망회로), Shannon Entropy(샤넌 엔트로피)

초록: LCD 생산라인의 공정 로봇에서 방사되는 비정상 작동 소음은 로봇의 결함 탐지에 사용된다. 이 신호의 장점은 상대적으로 낮은 민감도에 비해 단지 마이크로폰을 이용하여 다수의 결함을 확인할 수 있는 것이다. 결함요소 추출을 위한 웨이블릿 변환(WPT)과 불량률의 분류를 위한 인공신경망 회로(ANN)이 본 논문에서 사용되었다. 결과적으로, 비정상 작동 소음이 기계요소의 결함 진단에 효율적으로 사용될 수 있다.

Abstract: Abnormal operating sounds radiated from a moving transfer robot in LCD (liquid crystal display) product lines have been used for the fault detection line of a robot instead of other source signals such as vibrations, acoustic emissions, and electrical signals. Its advantage as a source signal makes it possible to monitor the status of multiple faults by using only a microphone, despite a relatively low sensitivity. The wavelet packet transform for feature extraction and the artificial neural network for fault classification are employed. It can be observed that the abnormal operating sound is sufficiently useful as a source signal for the fault diagnosis of mechanical components as well as other source signals.

1. 서 론

LCD 제조 업체의 대량 생산 시설이 가전 제품과 모바일 통신 기기 같은 시장에서 기하 급수적으로 증가하는 LCD 패널에 대한 수요에 대응하기 위해 효율적으로 운영되어야 하고, 합리적인 결함관리 시스템의 활용은 생산성과 수익성 측면에서 중요하다. 각종 생산 설비는 유기적 통일체로 연속해서 연결된다. 그 중 하나가 심각한 오류가 있다면, 전체 생산라인은 예상 보수와 조사가 기계 구성 요소 간의 연쇄 반응에 의한 치명적인 손상을 방지하기 위해 끝날 때까지 천천히 작동되어야

한다. 한편, 고급 신호 처리 기술을 기반으로 한 다양한 방법론이 개발되고 있고 생산 시설에서 기계 구성 요소의 결함 검출에 사용되는데, 일반적으로 진동, 음향 방출 그리고 주요 신호로써의 전기적 신호를 바탕으로 한다. 위에 있는 방법론과는 달리, Fig. 1 에서 보여진 것처럼, 이 연구는 이동하는 로봇으로부터 비정상적인 작동 음이 작동할 때 인간 청각 인지와 같은 결함 진단 시스템을 사용 함으로써 엔지니어의 불확실한 결정을 최소화하는데 있다. 비록 이것의 민감도는 다른 인접해 있는 설비가 작동하는 소리와 주위의 소음으로 인해 약간 낮지만, 이것의 장점은 움직이는 공정 로봇(transfer robot)의 작업 공간 내부에 마이크로폰만 사용 함으로서 동시에 여러 오류의 감시가 가능하다는 점이다. 이 연구의 초기 과정으로, 주위의 소음과 다른 인접해 있는 설비가 작동하는

† Corresponding Author, sangkwon@inha.ac.kr

© 2102 The Korean Society of Mechanical Engineers

소리의 부정적인 영향은 마이크론의 최적의 위치를 찾기 위해 조사되었다. WPT(Wavelet Packet Transform)⁽¹⁻³⁾는 비정상적인 작동 소음에서 기계적인 구성 요소의 결함으로 인한 사소한 특징들을 추출하는 데 사용되었고, ANN(artificial neural network)는 추출된 특징과 결함의 진행 상태 사이의 비선형 관계를 만드는데 사용되었다. 특히, 인공 신경 네트워크의 적용에서, 개선 방법의 두 가지 유형은 학습된 ANN의 오류를 최소화하기 위해 고려되었고, 이것은 이 논문에서 개발된 오류 분류 알고리즘의 불확실성과 밀접한 관련이 있다. 첫째로, 원본 데이터 샘플들의 크기와 다양성은

통계적 특성에 따른 재생 과정을 통해 증가되었다. 둘째로, 입력 벡터에서 상관성이 없는 부분공간(직교화에 관하여 엔트로피 기반의 기능 선택 방법에 의해 선택된)은 입력 벡터의 차원을 최소화하기 위해 제거되었고 최저 한도는 숨겨진 층의 복잡성을 요구한다.

2. 작동음의 녹음

대상 결함에 관한 세부 정보 없이, 움직이는 공정로봇에서 방사되는 비정상 작동 소음을 녹음하기 위한 실험은 특징 추출과 목표 결함의 분류를 위한 시작 과정으로 몇 달 동안 불규칙하게 실시되었다. 관련 연구들의 실험실 실험 조건과 달리, 실험이 한국의 LCD 회사의 대량 생산 시설에서 실시되었기 때문에 녹음 과정에서 다소 어려움과 한계가 있었다. 결함 진단을 위한 본 연구의 실험보다 생산성이 우선 되는 유지 보수 일정이 더 중요하기 때문에, 작동 소음의 녹음은 유지 보수 전후 시점으로, 구체화 되지 않은 공정로봇에서 짧은 기간 동안 제한적으로 실시되었다. 목표 결함에 가까운 작동 소음의 민감도는 진동, 음향 방출, 그리고 전기적 신호의 결함 진단을 위한 주요 신호로서 더 낮다. 그러므로 첫 번째 실험에서 주위의 소음과 마이크론의 위치의 영향은 대상 결함에 높은 감도 수준을 가지고 있는 마이크론의 최적 위치를 찾기 위하여 상세히 실험적으로 조사되었다. Fig. 2는 특정 결함을 가지고 있는 움직이는 공정로봇으로부터 방사되는 비정상적인 작동 소음 녹음을 위한 실험적인 조건을 보여준다. B&K 1/2" 4189의 두 개의 마이크론은 공정로봇을 관찰하기 위해 작업 공간의 내부와 외부에 각각 설치되었다. Head Acoustics사의 artificial biannual head인 HMS III 역시 심리 음향 측면에서 마이크론을 통한 작동 소음과 비교하기 위해서, 엔지니어가 일반적으로 일하는 작업 공간 외부에 설치하였다. 움직이는 공정로봇으로부터 방사되는 작동 소음은 NI 9233 module과 LabVIEW를 사용하여 50kHz의 샘플링으로 녹음되고, MATLAB을 사용하여 녹음된 소리의 신호를 후 처리 과정으로 실시했다.

Fig. 3과 4는 결함 있는 베어링으로 교체 전후로 발생하는 녹음된 작동 소음에 대해서 일반적으로 보여준다. 공정로봇으로부터의 작동 소음은 내부 사이에 투명한 플라스틱 파티션을 통해 전송되는 과정에서 감소되었기 때문에, Fig. 2에서 보여

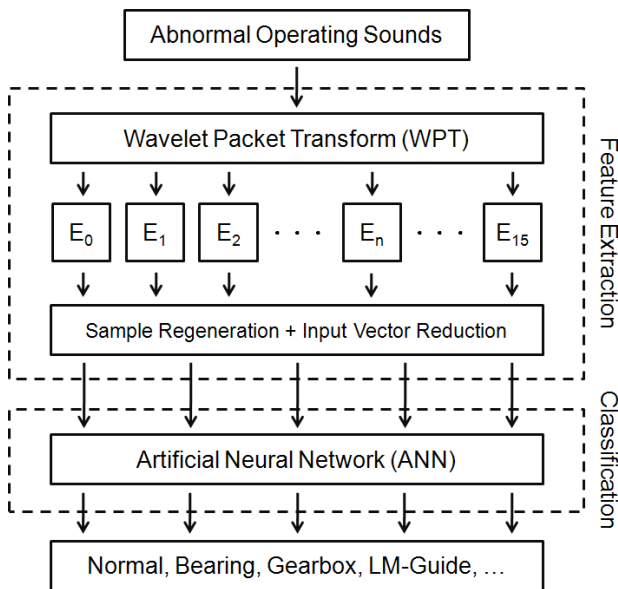


Fig. 1 Structure of fault diagnosis algorithm for a moving transfer robot using the wavelet packet transform and the artificial neural network




Fig. 2 Experimental environment condition for the recording of operating sound radiated from a moving transfer robot in the actual mass production facility

진 것 같이, Fig. 3 의 작업 공간의 내부에서 기록된 민감도는 Fig. 4 의 민감도 보다 높다. 게다가, 투명한 플라스틱 파티션이 안쪽으로 주위 소음의 전파를 방지하기 때문에 주위 소음의 부정적인 영




Fig. 3 Comparison of the operating sounds before and after the replacement of a bearing inside of the workspace for a moving transfer robot; (a) Before, (b) After




Fig. 4 Comparison of the operating sounds before and after the replacement of a bearing outside of the workspace for a moving transfer robot; (a) Before, (b) After

향은 외부 보다 낮다. 이것은 음향적인 측면에서 공기와 투명한 플라스틱 파티션 사이의 임피던스 미스매치에 의해서 발생하는 원리이다. 인접한 생산 설비와 특별히 지정되지 않는 공정로봇에서 주로 발생된다. Artificial biannual head 의 결과 역시 Fig. 4 에 나와 있는 것처럼 마이크로폰의 결과와 같다. 이 결과들을 바탕으로, Fig. 3 에서의 유지 보수 전후의 차이는 결함 진단을 위한 결함신호로 충분한 민감도의 Fig. 4 의 차이보다 더 확실하다. 그러므로, 작업공간 외부에서 녹음된 작동 소음은 더 이상 특징 추출 및 분류 과정에서 고려되지 않았고, 최적의 마이크로폰 위치는 목표 결함으로서의 높은 민감도와 주위 소음의 낮은 영향 때문에 공정로봇의 작업 공간 내부로 설정 하였다. 공정로봇이 가지고 있는 결함이 발견될 때마다, 실험은 몇 달 동안 현지 기술자의 도움으로 불규칙하게 진행되었다. 결과적으로, Fig. 2 에서 보여진 것 같이 베어링, 기어박스, 그리고 선형운동가이드 (linear motion guide)의 비정상 작동 소음은 다른 조건에서 여러 번 기록되었고, 이것은 결함을 가지고 있는 상세한 정보가 없는 불특정 공정로봇에 대해서 신호 처리 기법을 사용하여 결함과 관련된 특징 추출을 하기 위해 조사하였다.

3. 결함요소 추출

3.1 웨이블릿 변환 이론(WPT)

결함을 가지고 있는 움직이는 공정로봇으로부터 나오는 비정상 작동 소음 $x(t)$ 는 아래와 같이 원하는 신호 부분 $s(t)$, 소음 부분 $\varepsilon(t)$,로 나타낼 수 있다.

$$x(t) = s(t) + \varepsilon(t) \quad (1)$$

SNR(signal to noise ratio) 을 향상시키기 위해 잡음부분인 $\varepsilon(t)$ 를 제외하고, 원하는 신호 부분인 $s(t)$ 만 웨이블릿 변환 이론을 적용하여 재현될 수 있다. 반면에, CWT(continuous wavelet transform)는 결함 진단 과정에서 정지된 신호와 정지되지 않은 신호 모두에 대해 효과적인 방법으로 사용되고 있지만 매우 느리다. DWT(discrete wavelet transform) 역시 CQF(conjugate quadratic filters)를 기반으로 빠른 알고리즘으로 사용된다. 그러나 DWT 는 낮은 주파수 범위의 고해상도에 비해, 높은 주파수 범위에서 상대적으로 낮은 해상도를 가진다. 한편, WPT 는 로그 주파수 해상도 DWT 와는 달리, MRA(multi-resolution analysis)의 원칙을 기반으로 웨이블릿 변환의 일반화된 형태로 낮은 주파수 대

역과 높은 주파수 대역에서 부분 공간에서 동일한 대역폭을 가지고 있다. 이러한 이유로, WPT 가 기계적인 구성 요소의 결함 진단에서 특징 추출 과정에 널리 사용되고 있다. 이 연구 또한 공정로봇으로부터 나오는 비정상적인 작동 소음의 사소한 특징들을 추출하는데 WPT 를 사용한다. WPT 의 원리는 다음과 같이 설명 될 수 있다.

첫째, WPT 의 이론적인 개념은 아래와 같이 시간-주파수의 형태로 수학적으로 표현될 수 있다.^(2,3)

$$w^n_{j,k}(t) = 2^{j/2} w^n(2^j t - k) \quad (2)$$

정수 j 와 k 는 각각 scale 과 translation 매개 변수이며, 정수 n 은 주파수 성분을 나타내는 node 매개 변수이다. 처음 두 WPT 는 아래와 같이 scaling 함수와 기본 웨이블릿 기저 함수(mother wavelet) 이다.

$$w^0_{0,0}(t) = \phi(t) \quad (3)$$

$$w^1_{0,0}(t) = \Psi(t) \quad (4)$$

N=2, 3 에 대한 나머지 WPT 는 다음과 같은 반복적인 관계로 정의할 수 있다.

$$w^{2n}_{0,0}(t) = \sqrt{2} \sum_k h(k) w^n_{1,k}(2t - k) \quad (5)$$

$$w^{2n+1}_{0,0}(t) = \sqrt{2} \sum_k g(k) w^n_{1,k}(2t - k) \quad (6)$$

h(k) 와 g(k) 는 LPF(low pass filter)와 HPF(high pass filter)의 필터계수(coefficient)이고, WP(wavelet packet) 계수 를 나타내는 $d^n_{j,k}$ 는 아래와 같이 작동 소음 신호 x(t) 기본 웨이블릿 기저 함수 $w^n_{j,k}$ 사이의 내적에 의해서 얻어진다.

$$d^n_{j,k} = \langle x(t), w^n_{j,k} \rangle = \int x(t) w^n_{j,k} dt \quad (7)$$

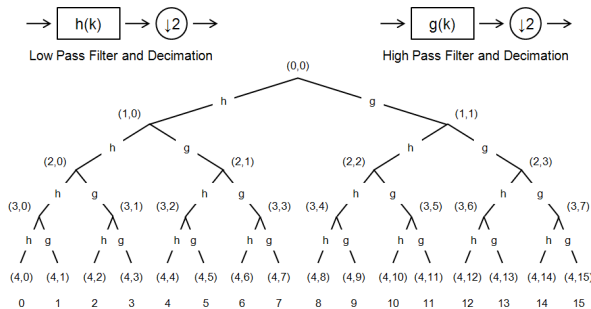


Fig. 5 Tree structure of wavelet packet transform with four level layers

결과적으로, 작동 소음 신호 x(t)는 LPF 계수와 HPF 세부 계수 두 부분으로 분해된다. WPT 의 트리 구조(tree-structur) 는 scale 매개변수 j 에 따라 동일한 대역폭을 가지는 여러 개의 부분공간으로 구성되어 있다. WPT 의 적용에서, 작동 소음 x(t) 가 50kHz 의 샘플링으로 원래 녹음되었을 지라도, 그것의 각각의 부분공간의 대역폭을 적절히 조정하기 위해 12.5kHz 로 줄였다. 작동 소음 x(t)는 시간 축에 50%의 overlap 을 시켜서 12,500 블록으로 분해하였고, Fig. 5 와 같이 각 시간 블록은 주파수 축에 대해 네 단계 층의 16 부분공간으로 분해 된다. 따라서, WP 계수를 추출하는 것은 가능하고, 그것은 식 (1)의 소음 부분인 $\epsilon(t)$ 를 제외하고 오직 원하는 신호 부분인 s(t)만을 포함하고, 부분공간의 동등한 대역폭에서 결함의 세가지 유형 중 하나와 매우 관련이 있다.

3.2 정규화된 Shannon 엔트로피

Shannon 엔트로피의 이론적인 개념은 communication theory⁽⁴⁻⁶⁾와 연계된 Shannon(1949)에 의해 처음으로 소개되었고 관련 연구에 기계 부품의 결함 진단을 위한 각각의 부분공간에서 WP 계수의 희박성이나 임의성을 평가하는데 널리 사용되었다. 여기서 표준 Shannon 엔트로피는 다음과 같이 WP 계수의 함수로 정의되어 있다.

$$E_n = \sum_{k=1}^N (d^n_{4,k})^2 \log((d^n_{4,k})^2) \quad (8)$$

그리고 4 단계 층의 WPT 을 통해 얻어진 16 개의 WP 계수는 식 (8)을 사용하여 표준 Shannon 엔트로피의 입력 벡터의 형태로 표현될 수 있다.

$$P = [E_0, E_1, E_2, \dots, E_{15}] \quad (9)$$

Fig. 6 은 일반적인 조건에 대한 스펙트럼에서 표준 Shannon 엔트로피의 분포와 결함 조건의 세가지 유형을 나타낸다. x 축은 부분공간 개수이고, y 축은 표준 Shannon 엔트로피의 크기이며, z 축은 0 과 1 사이의 입력 데이터 샘플들의 확률 밀도이다. 모든 부분공간들이 결함 진단에 대해 유용한 정보를 가지고 있다는 것이 기대되고 있을지라도, 첫번째 부분공간의 표준 Shannon 엔트로피인 E_0 은 ANN 을 사용하는 결함 분류 과정에서 관련없는 소음이기 때문에 고려되지 않는다. 게다가, Daubechies 기본 웨이블릿 기저 함수의 차수변화에 의한 표준 Shannon 엔트로피의 분포에 미치는 영향을 조사하기 위해서, 차수는 WPT 의 적용




Fig. 6 Comparison of the distribution of normalized Shannon entropy for the original data samples according to the fault conditions in a moving transfer robot (a) Normal, (b) Bearing, (c) Gearbox & Motor, (d) LM Guide

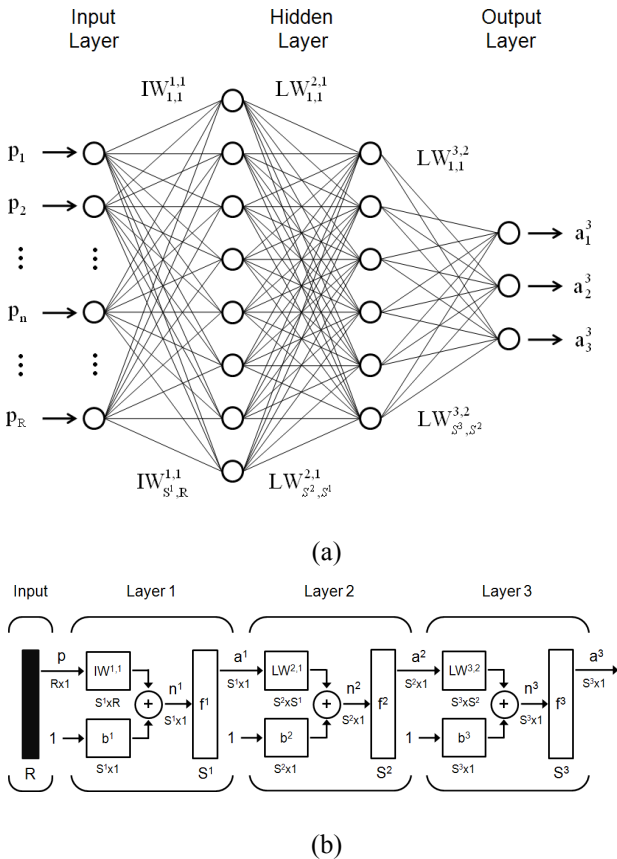


Fig. 7 Schematic representation of the multi-layer feed-forward artificial neural network for the fault classification of a moving transfer robot having three types of faults (a) Schematic representation, (b) Logical structure

과정인 4 차수의 간격에서 4 차수에서 20 차수 사이로 조정된다. 그러나, 관련 연구의 결과와 달리, 차수변화의 효과는 중요하지 않다. 그 이유는 초당 12,500 샘플링된 분해 블록은 관련된 연구와 비교하면 너무 길고, 변화 폭이 너무 크다. 그러므로, 위에서 언급한 바와 같이, D4 기본 웨이블릿 기저 함수는 본 연구를 통해 WPT의 적용에 사용되어졌다.

4. 결함 진단

4.1 인공신경망 회로 이론(ANN)

인공신경망 회로(ANN)는 입력 값과 목표값을 이용하여 학습되고, 학습과정에서 ANN의 가중치와 절편은 최적값을 향하여 업데이트 된다.⁽⁷⁻⁹⁾ 이 과정에 사용되는 알고리즘은 다양하며 본 연구에서는 역전파(feed-forward back-propagation) 알고리즘을 사용하였다. ANN은 결함 분류 과정에서의 특징 추출과 결함 분류 과정 사이의 비선형 관계적인 모델로서 사용되어 왔다. Fig. 7은 다층 인공신경망 회로의 도식 표현을 보여준다. 그리고 이것의 구조는 세 종류의 입력층, 은닉층, 출력층으로 구성되어 있다. 첫째로, 입력층은 Section 3에서 WPT의 적용을 통해 얻어지고 Shannon 엔트로피를 표준으로 하는 입력정보에 대응하는 뉴런의 수 R 을 포함한다. 작동 소음이 4레벨 층까지 분해 되기 때문에, 입력 정보의 16개의 요소들은 결함 분류에 대한 입력 데이터로 취득하여 사용된다. 둘째로, 출력층은 이동공정로봇에서 결함의 세 가지 유형에 관한 세 가지 뉴런을 포함한다. Section 2에 언급한대로, 작동 소음의 녹음을 포함한 실험에만 유지 보수 및 검사 전후에 실시되므로, 결함의 진행 상태를 제외하고, 출력 벡터는 각각 정상과 비정상적인 상태를 의미하는 0과 1의 조합으로 구성되어 있다. 셋째로, 은닉층은 가장 중요한 부분인데 인공신경 네트워크에서 블랙박스의 형태로 결함 분류의 핵심 논리를 포함한다. 무엇보다도, 은닉층의 복잡성과 학습된 ANN의 오류 사이의 최적의 균형 지점을 적절히 선택하는 것이 중요하다. 그 이유는 은닉층의 더 복잡한 구조 타입을 이용함으로써 여러 가지 경우를 고려할 수 있는 것이지만, 입력 및 대상 데이터 샘플의 최소로 요구되는 수 또한 Fig. 7과 같이 인공신경 네트워크의 최적의 가중치 w_{ij} (weight)와 절편 b_{ij} (bias value)의 집중성에 대해 증가한다. 최적의 구조 타입은 12개 뉴런의 입력층,

8 개 뉴런의 은닉층, 6 개 뉴런의 두번째 은닉층, 그리고 제한된 입력과 대상 정보의 학습된 ANN의 오류 감소에 대한 3 개 뉴런의 출력층을 결합한 형태로 선택된다. 이 구조 타입을 선택한 이유는 다양한 구조 타입의 비교를 기반으로 한 이 단락의 마지막 부분에서 설명할 것이다. Fig. 7(b)는 Fig. 7(a)보다 더 자세하게 인공신경 네트워크의 논리적 구조를 보여준다. 여기, 하나의 입력층, 두개의 은닉층, 그리고 하나의 출력층이 순차적으로 연결되어 있다. 각각의 층은 가중치 행렬 W , bias 벡터 b , 그리고 출력 벡터 a 를 가지고 있다. 첫번째 은닉층은 다음과 같이 정의된다.

$$a^1 = f^1(IW^{1,1}P + b^1) \quad (10)$$

위의 p 는 입력 벡터이고, $IW^{1,1}$ 은 가중치 매트릭스이며, f^1 은 전달함수이다. Second 은닉층과 출력층 또한 마찬가지로 다음과 같이 정의된다.

$$a^2 = f^2(LW^{2,1}a^1 + b^2) \quad (11)$$

$$a^3 = f^3(LW^{3,2}a^2 + b^3) \quad (12)$$

$LW^{2,1}$ 과 $LW^{3,2}$ 는 각 층(layer)의 가중치 매트릭스와 입력벡터 p 와 네트워크 출력 벡터 a^3 사이의 신경 네트워크 모델이고 y 로 표시되는데, 순차적으로 위의 세 방정식을 연결하여 정의할 수 있다.

$$y = a^3 = f^3(LW^{3,2}f^1(IW^{1,1}P + b^1) + b^2) + b^3 \quad (13)$$


가중치(Weight) 와 절편은 역전과 학습 알고리즘을 사용하는 훈련 과정에 의해 결정된다. 이 섹션의 나머지 부분에서, 두 가지 타입의 개선 방안은 재생과 입력 및 대상 정보의 직교화(orthogonalization)을 통한 학습된 ANN의 오류를 줄이기 위해 적용되었다.

4.2 데이터 샘플의 재생성


ANN의 훈련 과정은 학습된 ANN의 오류를 줄이는 방향으로 반복을 통해 최적의 가중치와 절편으로 수렴하기 위해서는 입력과 대상 데이터 샘플의 충분한 다양성과 그 수를 필요로 한다. 그러나 Section 2에 언급한 것처럼, 이동 공정보트에서 방출된 작동 소음의 녹음을 위한 실험은 실험실 내부의 실험 조건 하에 실시되지 않았기 때문에, 이전 연구에서 했던 것처럼, 부족한 반복 입력 및 대상 데이터에 대한 샘플의 수와 다양성이 부족하기 때문에 가중치와 절편의 수렴으로 실시되었다.

Table 1 Results of the entropy based feature selection method for the orthogonalization of input vector


Rank	Fault #1 (bearing)		Fault #2 (gearbox & motor)		Fault #3 (LM guide)	
	Subspace No.	Entropy	Subspace No.	Entropy	Subspace No.	Subspace Entropy
1	4 (○)	907	3 (○)	720	1 (○)	615
2	12 (○)	702	2 (○)	683	11 (○)	479
3	5 (○)	491	7 (○)	552	3	477
4	7	375	6 (○)	504	10 (○)	445
5	13 (○)	366	5	277	14	405
6	6	202	12	181	9 (○)	405
7	1	194	4	160	8	284
8	2	188	13	136	15	272
9	15	181	15	132	2	240
10	3	87	14	64	13	230
11	9	60	10	31	7	200
12	14	57	1	25	6	196
13	11	57	9	14	5	195
14	8	53	8	10	12	187
15	10	39	11	4	4	182



(a)



(b)



(c)

Fig. 8 Comparison of the variance in the normalized Shannon entropy according to the fault conditions and the selected subspaces for the classification of each fault condition; (a) Bearing, (b) Gearbox & Motor, (c) LM Guide

이러한 이유로, 각 결함 조건에 대한 입력 및 대상 데이터 샘플은 WP 계수의 각 부분공간 사이의 통계적 특성을 기반으로 무작위로 재 생성되었다. 각 결함 조건에 대한 원본 데이터 샘플의 개수는 100 이하이다. 재생 후에, 각 오류 조건에 대한 재생 데이터 샘플의 수는 400 까지 증가했다. 그 결과, 총 1,600 개의 샘플의 입력 및 대상이 정보로 사용되었다.

4.3 특징 선택법에 의한 엔트로피

입력 벡터의 직교화(orthogonalization)는 최소로 요구된 은닉층의 복잡성과 학습된 ANN 의 오류를 줄이는 좋은 방법이기 때문에, 이동하는 공정로봇의 세 가지 유형의 결함과 관련하여, 입력 벡터와 서로 관련되지 않은 부분공간은 입력 벡터의 중복을 최소화하기 위해 제거될 필요가 있다. 이러한 이유로, 특징 추출 방법 기반의 엔트로피는 아래와 같은 정상적인 상태와 관련하여 표준 Shannon 엔트로피의 상대적 변화를 비교하여 입력 벡터에서 어떤 부분공간이 각 결함 조건에 크게 관련이 있는지 찾는데 사용되었다.

$$\Delta E_n = E_{n,fault} - E_{n,normal} \quad (14)$$

위의 E_n 은 n 번째 WP 계수의 표준 Shannon 엔트로피의 상대적 변화이다. 표준 Shannon 엔트로피의 변화가 비교적 높은 수준인 부분공간은 각 결함 조건보다 밀접하게 상관 관계가 있다고 간주된다. 그 결과, 16 개의 부분공간이 Table 1 에 나열된 것처럼, 내림차순으로 정렬되어있고, 각 결함 조건에 대한 상관 부분공간은 중복 없이 Table 2 에 나열된 것처럼, 위의 식 (14)의 정의에 따라 분류되었다. Fig. 8 은 막대 그래프의 형태로 결함 조건에 따라 표준 Shannon 엔트로피의 상대적 변화를 보여준다. 녹색 색깔의 막대는 각 결함 조건에 대한 높은 상관 관계가 있는 부분공간을 나타낸다. Fig. 9 은 4 단계 층의 WPT 의 트리구조 대한 표준 Shannon 엔트로피의 전파 경로를 보여준다. 위 결과를 바탕으로 Table 2 에 나열된 네 개의 상관 없는 부분공간을 제외하고 오직 12 개의 상관 관계

Table 2 Classification of subspaces based on the entropy based feature selection method

Fault #1 (bearing)	Fault #2 (gearbox & motor)	Fault #3 (LM guide)	Removed Vectors
4, 5, 12, 13	2, 3, 6, 7	1, 9, 10, 11	0, 8, 14, 15

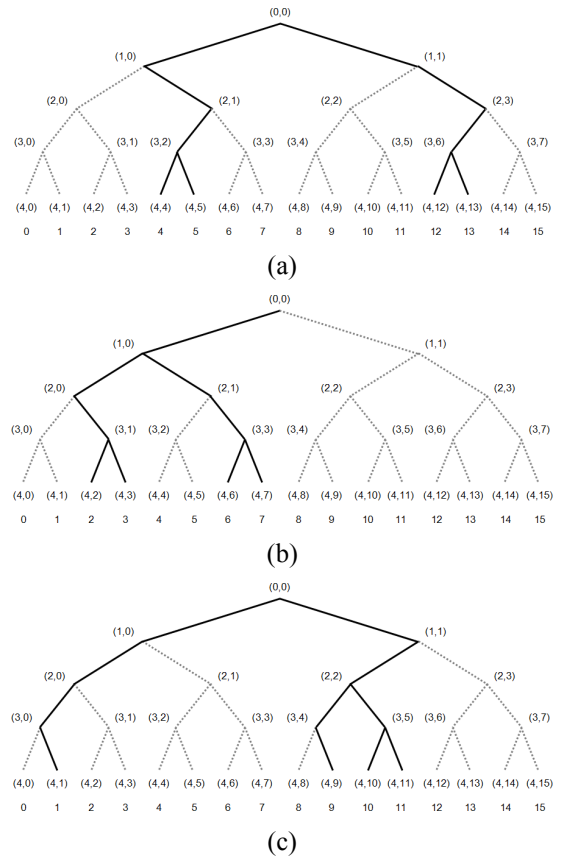


Fig. 9 Comparison of the propagation path of normalized Shannon entropy on the tree structure of wavelet packet transform with four level layers; (a) Bearing, (b) Gearbox & Motor, (c) LM Guide




Fig. 10 Comparison of the probability density on the error distribution of trained ANN; (a) Original data samples, (b) Regenerated data samples




Fig. 11 Comparison of the probability density on the uncertainty distribution of trained ANN before and after the regeneration of data samples; (a) Original data samples, (b) Regenerated data samples

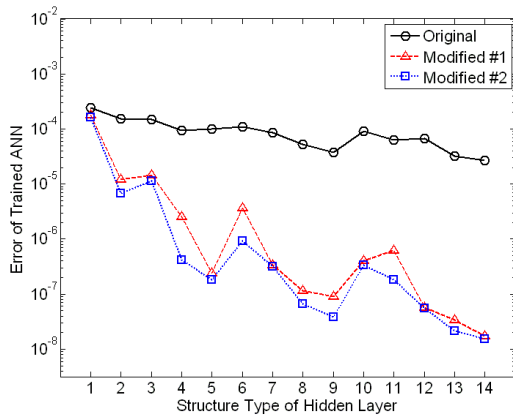


Fig. 12 Comparison of the error of trained ANN according to the structure type of a hidden layer and the improvement methods

인 부분공간은 인공 신경 네트워크를 기반으로 결합 분류에 대해 유용한 정보를 가지고 있다고 간주된다.

4.4 결합 분류 결과

앞선 섹션에서 두 종류의 개선방법이 입력 벡터의 직교화와 입력 및 대상 데이터 샘플의 재생을 설명하여 학습된 ANN의 오류를 줄이기 위해 도입되었다. 결합 분류의 결과는 학습된 ANN의 오

Table 3 Comparison of the uncertainty of trained ANN before and after the regeneration of input and target data samples

Original	Modified #1
1.1587	0.0000

류와 정확성에 대한 개선 전후의 차이를 식별하기 위해 비교되었고, 학습된 ANN의 낮은 레벨의 오류를 가진 은닉층의 최적 구조 형식을 찾기 위해 비교되었다. Fig. 10은 학습된 ANN의 입력 및 대상 데이터 샘플의 재생 전후 오류 분포의 확률 밀도를 보여준다. Fig. 10(a)에서, 오류의 편차가 너무 크기 때문에, 82.46%의 정확도의 반대 상태로 오해할 수 있다. 그러나 Fig. 10(b)에서 100%의 정확도로 오류의 편차가 거의 없다. Fig. 10에서 두 결과 사이의 차이를 확실히 보여주기 위해, Shannon 엔트로피는 결합 분류 논리의 불확실성에 대해 위의 차이를 비교하는데 사용되었고, 다음과 같이 정의된다.

$$H = -P \log_2 p \quad (15)$$

P는 학습된 ANN의 오류 분포에 발생 확률이다. 입력 및 대상 데이터 샘플의 재생 전에, 충분한 반복을 통해 교육 과정은 입력 및 대상 데이터 샘플의 다양성과 수 때문에 Fig. 7에 보여진 것과 같이 최적의 가중치와 절편로 수렴하지 않았다. Fig. 11은 이러한 종류의 문제에 의한 결합 분류 논리의 불확실성을 분명하게 보여준다. 재생 후에, 수렴 문제는 해결되었고 결합 분류 논리의 불확실성은 Fig. 11(b)에서 보여진 것처럼 1.1587에서 0으로 완전히 제거되었다.

Table 3은 재생 전후 식 (15)를 사용하여 계산된 Shannon 엔트로피의 분산을 보여준다. Fig. 12은 은닉층의 구조 타입과 두 가지 개선 방법에 따라 학습된 ANN의 오류의 변화를 보여준다. Table 4는 학습된 ANN의 오류가 반비례로 감소하는 것과 더불어 은닉층의 구조 타입의 복잡성에서 증가하는 경향을 가지고 있다는 것을 보여준다. 이러한 결과는 100번의 각 조건에 대해 반복 훈련 과정을 통해 오류 값을 평균하여 얻어진다. Fig. 12에서 변경된 #1은 입력 벡터의 재생 후 결과이고, 변경된 #2는 입력 벡터의 재생과 직교화 후의 결과이다. 위의 결과를 바탕으로, 재생 과정이 직교화과정에서의 감소하는 것보다 학습된 ANN의 오류를 감소하는 것이 더 유용하다고 확인되었다.

Table 4 Comparison of the error of trained ANN according to the structure type of a hidden layer and the improvement methods of input vector

No.	Structure of Hidden Layer	Original	Modified #1	Modified #2
1	4	2.3984 e-04	1.7919 e-04	1.6462 e-04
2	4-2	1.5414 e-04	1.1929 e-05	6.7836 e-06
3	6	1.5081 e-04	1.4409 e-05	1.1293 e-05
4	6-2	9.4038 e-05	2.5031 e-06	4.2066 e-07
5	6-4	1.0027 e-04	2.4028 e-07	1.8079 e-07
6	8	1.0793 e-04	3.6991 e-06	9.2306 e-07
7	8-2	8.5908 e-05	3.3607 e-07	3.1336 e-07
8	8-4	5.2277 e-05	1.1480 e-07	6.5526 e-08
9	8-6	3.7166 e-05	8.9970 e-08	3.8519 e-08
10	10	9.2218 e-05	3.9903 e-07	3.3782 e-07
11	10-2	6.2529 e-05	6.2266 e-07	1.8487 e-07
12	10-4	6.7671 e-05	5.6235 e-08	5.5971 e-08
13	10-6	3.2365 e-05	3.3782 e-08	2.1299 e-08
14	10-8	2.6820 e-05	1.7149 e-08	1.5436 e-08

구조 타입의 9 번은 이송공정로봇의 결함의 제한된 입력 및 대상 정보에 관계없이 다른 구조 타입과 비교해봤을 때 낮은 레벨의 오류 때문에 은닉층의 최적의 구조타입으로 선택된다. Fig. 7 에 보여진 것처럼, 구조 타입 #9 는 8 개 뉴런의 은닉층과 6 개 뉴런의 두번째 은닉층을 가지고 있다. 따라서, 작동 소리를 녹음하는 실험 과정에서의 제한과 어려움에 기인하는 학습된 ANN 의 큰 오류를 위의 제안 절차를 통해 최소화한다고 결론 지을 수 있다.

5. 결론

LCD 제조업체의 대량 생산 라인에서 이동하는 공정로봇의 결함 감지 방법이 조사되었다. 이동하는 공정로봇에서 방출되는 비정상적인 작동 사운드가 확인되기 때문에 결함 진단을 위해서 결함신호로사용이 유용하다. 이 작업에서, 불특정 공정로봇의 작동 사운드는 현장 엔지니어의 도움으로 한국의 한 LCD 회사의 실제 대량 생산 라인에서 여러 번 불규칙적으로 기록되었다. 환경 소음의 부정적인 영향뿐만 아니라 대상 결함에 대해 상대적으로 큰 레벨의 민감도 때문에 최적의 마이크로폰의 위치는 작업 공간 내부로 선정 되었다.

제안된 결함 진단 방법은 특징 추출 및 결함 분류 두 부분으로 구성되어 있다. 첫째, 네 단계 층과 Daubechies D4 기본 웨이블릿 기저 함수와 합

계 WPT 는 비정상적인 작동 사운드의 기계적 구성 요소의 결합으로 인한 사소한 특징을 추출하는데 사용되었다. 둘째, ANN 은 추출된 특징과 결합의 진행 상태 사이의 비선형관계를 형성하는데 사용되었다. 입력 및 대상 데이터 샘플의 수와 그 다양성의 부족으로 인한 학습된 ANN 의 오류는 입력 벡터의 재생과 직교화를 통해 최소화하였다. 상대적으로 낮은 오류 레벨을 가지고 있는 은닉층의 구조 타입은 여러 가지 구조 타입의 비교를 통해 선정되었다. 결론적으로, 청각기능에 바탕을 둔 결합 결정 과정에서의 엔지니어의 불확실성은 존재하지만, 결합신호와 같은 비정상 작동 소음에 적용하기 위한 제안된 결합 진단 방법이 이런 불확실성을 최소화 한다. 비정상 작동 소음과 같은 결합신호 뿐 아니라 신호 처리 기술과 기계적 알고리즘을 바탕으로 하는 진동, 음향 방출, 전기 신호의 결합 진단 시스템의 결합신호의 사용은 유용하다.

후 기

이 논문은 정부(교육과학기술부)의 재원으로 한국연구재단의 Mid-career Researcher Program의 지원을 받아 수행된 연구임. (No.2010-0014260)

참고문헌

- (1) Rafiee, J. and Tse, P.W., 2009, "Use of Autocorrelation of Wavelet Coefficients for Fault Diagnosis," *Mechanical Systems and Signal Processing*, Vol. 23, No. 5, pp. 1554~1572.
- (2) Kim, M. S. and Lee, S. K., 2009, "Detection of Leak Acoustic Signal in Buried Gas Pipe Based on the Time-Frequency Analysis," *Journal of Loss Prevention in the Process Industries*, Vol. 22, No. 6, pp.990~994.
- (3) Mallat, S.G., 1989, "A Theory of Multi-Resolution Signal Decomposition: the Wavelet Representation," *IEEE Transactions on Pattern and Machine Intelligence*, Vol. 11, No. 7, pp. 674~693.
- (4) Wickerhauser, M. V. and Coifman, P. R., 1992, "Entropy Based Methods for Best Basis Selection," *IEEE Transactions on Information Theory*, Vol. 38, No. 2, pp. 713~718.
- (5) Daubechies, I., 1990, "The Wavelet Transformation, Time-Frequency Localization and Signal Analysis," *IEEE Transaction on Information Theory*, Vol 36, pp. 961~1005.
- (6) Shannon, C.E. and Weaver, W., 1949, *Mathematical Theory of Communication*, University of Illinois Press,

- Urbana.
- (7) Bishop, C. M., 1995, *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford, UK.
- (8) Matrn, H., 1996, *Neural Network Design*. PWS Publishing Company, Boston, USA.
- (9) Lee, H.-H., Kim, S.-J. and Lee, S.-K., 2009, "Design of New Sound Metric and Its Application for Quantification of an Axle Gear Whine Sound by Utilizing Artificial Neural Network," *Journal of Mechanical Science and Technology*, Vol. 23, No. 4, pp. 1182~1193.