

# 고차 시간-주파수 해석과 신경망 회로를 이용한 냉장고 압축기의 건전성 연구

## A Study on Health Monitoring of a Refrigerator Compressor Based on Higher Order Time-Frequency Analysis and Artificial Neural Network

신태진<sup>1</sup>, 이상권<sup>1,✉</sup>, 장지욱<sup>1</sup>

Tae-Jin Shin<sup>1</sup>, Sang-Kwon Lee<sup>1,✉</sup>, and Ji Uk Jang<sup>1</sup>

<sup>1</sup> 인하대학교 기계공학과 (Department of Mechanical Engineering, Inha Univ.)

✉ Corresponding author: sangkwon@inha.ac.kr, Tel: 032-860-7305

Manuscript received: 2012.3.27 / Revised: 2012.9.9 / Accepted: 2012.9.15

*Condition monitoring of the reciprocating compressor is important task. As a traditional method, health monitoring system of refrigerator depends on decision of a skilled person based on his experience. However, the skilled person cannot monitor all the compressors completely. If a sampled compressor is faulty, thousands of compressors manufactured at that place are regarded as faulty compressors. Therefore it is necessary to monitor all compressors in the production line. In the paper real time health monitoring system is developed based on high order time frequency method and artificial neural network. The system is installed in the mass production line. The result of the application has been very successful, and currently the system is working very well on the production line.*

Key Words: Time Frequency Analysis (시간 주파수 분석), Refrigerator (냉장고), Neural Network (신경망 회로), Kurtosis (커토시스), Impact Wave (충격파)

### 1. 서론

대량 생산 체제에서 결함 계측시스템은 제조비용 절감 면에서 매우 중요하다. 냉장고의 왕복 압축기에 대한 결함 계측 시스템의 경우 전문가들의 경험을 바탕으로한 불량 압축기 검출 방법이 용이하였다. 그러나 전문가의 감정상태에 의존함에 따라 잘못된 결정이 발생하기 때문에 컴퓨터에 의존하는 계측시스템이 필요하다. 계측 시스템에 관한 많은 연구에서는 컴퓨터 산업의 발전과 디지털 신호 처리 기술<sup>1-10</sup>에 관한 연구가 많이 발표되어 왔다. 이런 결과들이 생산라인에 널리 적용되었다. 디지털 신호처리 기술에는 푸리에 변환

(Fourier transform), 파워 스펙트럼 밀도 분석(power spectrum density),<sup>1</sup> 시간 계열(time series analysis)<sup>2</sup>의 통계분석부터 켈스트럼(cepstrum),<sup>3</sup> 능동신호처리(adaptive filter),<sup>4</sup> 시간 주파수(time-frequency analysis),<sup>5</sup> 웨이블릿 변환 (wavelet transform),<sup>6</sup> 시간 평균화 방법(time average method),<sup>7</sup> 고차 시간 주파수(higher order time frequency),<sup>8</sup> 고차 스펙트럼(higher order spectra)<sup>9</sup> 과 ANN(artificial neural network)<sup>10</sup>이 있다. 이러한 신호처리의 기술들은 기계부품의 결함에 관련된 신호들의 특징을 검출하는데 사용된다. 본 논문에서는 냉장고 생산 라인에서 압축기의 양품과 불량품을 검출하는데 사용하고자 한다. 우선 양품과 불량품에 대한 특징적인 신호의

검출을 위해서 고차 시간-주파수<sup>11</sup> 기법을 적용하고, 생산라인에서 자동으로 불량품과 양품의 패턴을 분류하기 위해서 ANN 을 사용하고자 한다. 본 연구에서의 기본 압축기의 개수는 140 대이다. 그 중 135 대는 양품이었고, 5 대는 불량품이었다.

**2. 인공 신경망 회로(ANN) 이론**

ANN 은 생물학적 신경시스템의 기능을 신호처리 기술을 이용하여 모사한 모델이다. ANN 시스템은 일반적으로 학습과정을 통하여 입력되는 신호들을 다양한 목적함수 (cost function) 에 따라 원하는 목표치 (target)로 신호의 패턴을 분류할 수가 있다. ANN 은 원하는 목표치를 달성하기 위한 ANN 모델의 최적화 과정에서 학습과정 (training process) 이 다양하다. 따라서 다양한 학습과정에 따른 다양한 알고리즘이 개발 되었으며, 본 논문에서는 비교적 사용이 간편한 역전파 (back-propagation)<sup>12</sup> 알고리즘을 사용하였다. 역전파 알고리즘을 사용하는 ANN 의 목적은 입력신호 벡터  $x$  를 함수화 시켜 특징화된 패턴  $y$  로 분류하는 것으로 수식적 표현은 다음과 같다.

$$x_{N \times 1} \rightarrow y_{M \times 1} \tag{1a}$$

그리고 일반화 시키면,

$$x^{(p)} \rightarrow y^{(p)}, \text{ for } p=1, 2, \dots, P \tag{1b}$$

$p$  는 패턴의 수이다. Fig. 1 은 다층 입력과 단일 신경  $i$  로 표현되는 단층 (single layer) 구조 ANN




Fig. 1 Structure of artificial neural network with neuron

이다. 이 구조에서 입력 신호  $x_j$  는 신경 블록  $\Sigma$  로 합산되고, 함수  $F$  를 통하여 출력  $y_j$  가 도출된다. 이 과정을 수학적으로 표현하면 식 (2)와 같다.

$$y_i = F(z_i), z_i = \sum_{j=1}^N w_{ij}x_j + b_i \tag{2}$$

여기서,  $z_j$  는 active potential,  $w_{ij}$  는 weights of connection,  $b_i$  는 bias parameter 이다. 함수  $F(z)$  는 다음과 같다.

$$F(z) = \frac{1}{1 + e^{-\gamma z}} \in (0,1) \text{ for } \gamma > 0, \tag{3}$$

Fig. 2 는 다층 (multiple layer) ANN 다. 다층 ANN 는 입력층 (input layer), 은닉층 (hidden layer), 출력층 (output layer) 으로 각각 구성된다. 각 신경 (neuron) 단위는 연속적으로 이어지는 층으로 연결되어 있지만, 내부 층에는 연결이 되지 않는다.




Fig. 2 Structure of artificial neural network with multi-layer

Fig. 2 는 4-5-3-2 구조를 가진 다층 ANN 이다. 가중치 (weight)  $w_{i,j}$  와 절편 (biases)  $b_{i,j}$  ( $1$  은 층의 개수이다)은 ANN 변수이며, ANN 변수의 값은 ANN 의 학습 과정에서 반복적으로 업데이트 후 최적화 된다. 학습과정에서 신호  $x_i^{(p)}$  는 입력에서 출력까지의 순방향으로 진행된다. 알고리즘의 목적 함수가 되는 오차는 출력 벡터  $y_i^{(p)}$  와 목표치 벡터  $t_i^{(p)}$  의 비교 후 계산되며, 식 (4) 같이 표현된다.

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{i=1}^M (t_i^{(p)} - y_i^{(p)})^2 \quad (4)$$

여기서  $E$  는 평균자승오차 (mean-square-error) 이며 목적함수이다. ANN 의 가중치는 식 (5)을 이용하여 다음과 같이 계산 된다.

$$w_{i,j}(s+1) = w_{ij}(s) + r_{ij}(s) \quad (5)$$

$s$  는 반복 계수이고,  $r_{ij}$  는 네트워크 가중치의 수정을 위해서 사용되는 증분값이며, 이 값을 Gradient formula 에 상응하는 간단한 공식으로 나타내면 식 (6)과 같다.

$$r_{ij}(s) = \Delta w_{ij}(s) = -\eta \frac{\partial E}{\partial w_{ij}} \Big|_s \quad (6)$$

$\eta$  는 학습률 (learning rate)이다. ANN 의 가중치와 절편의 수정은 Fig. 2 의 역방향으로 진행된다. 위의 방식으로 학습된 ANN 은 역전파 (back-propagation) ANN 기술로 불려진다. 모든 패턴과 역방향의 에러에 상응하는 하나의 전달 신호는 Epoch 로 불려진다. Epoch 은 반복되는 단계이다. 반복되는 과정에 사용되는 Gradient formula 은 공식 (6)에 의하면 학습률에 비해 민감하며, 학습과정은 보통 느리게 수렴한다. 따라서 많은 epoch 이 필요하다. 이 epoch 의 횟수를 줄이기 위해서 ANN 연구에서 다양한 학습방법이 개발되어 왔다. 본 연구에서는 Levenberg-Marquardt learning 방법<sup>12</sup>을 적용 하였다.

### 3. 결합 특징 추출 기술

기계시스템에서 측정된 신호로부터 결합의 특징을 추출하기 위해 사용한 디지털 신호처리 기술은 3 가지 방법으로 분류할 수 있다. 첫 번째 기술은 통계학에 기초한 시간데이터분석 (time series analysis) 이며, 두 번째 기술은 주파수분석 (spectrum analysis), 이고 마지막으로 시간-주파수 분석 (timefrequency analysis) 이다. 각 기술에 대해서 다양한 방법들이 개발되어 왔으나 건전성 시스템에 적용하는 것은 기계시스템의 특징에 따라서 다르게 적용된다. 본 연구에서 사용된 기술을 설명하면 다음과 같다.

### 3.1 통계학에 근거한 시간데이터 분석 기술

기계적 시스템의 결함으로부터 측정된 시간데이터에 대한 통계학적인 확률밀도함수 (probability density function)는 신호의 결합에 따라서 다르다. 기계시스템으로부터 측정된 데이터에 대한 확률밀도함수에서 분산(variance)을 나타내는 것은 2 차 모멘트이고, 비대칭도(skewness) 를 나타내는 것은 3 차 모멘트이며, 첨도 (kurtosis)는 4 차 모멘트가 나타난다. 분산은 다음과 같이 표현된다.<sup>8</sup>

$$Var = E[(x - \mu)^2] \quad (7)$$

여기서  $x$  는 측정된 데이터이며,  $E$  는 예상값이며,  $\mu$  는 데이터의 평균을 나타낸다. 분산은 램덤변수 (random variable)의 평균값 (mean value)으로 부터의 분포의 정도를 나타내준다. 비대칭도 (skewness) 는 램덤변수들의 평균값으로부터 쏠림의 정도를 설명해준다. 수학적 표현은 다음과 같다.

$$Skewness = E[(x - \mu)^3] \quad (8)$$

첨도 (kurtosis) 는 램덤변수들의 집중도를 나타내며, 그것의 수학적 표현은 식 (9)과 같다.

$$Kurtosis = E[(x - \mu)^4] \quad (9)$$

첨도 (kurtosis) 은 기계적 시스템의 결함에 의해서 발생하는 충격신호들의 집중도를 발견하기 위해 사용되어왔다. 충격 신호가 발생하는 경우 매우 용이하게 응용된다.

### 3.2 주파수 분석 기술

일반적으로 기계시스템에서 측정된 신호들이 결정신호 (deterministic signal) 인 경우에는 이 신호에 대한 스펙트럼은 푸리에 변환을 통하여 구할 수 있다. 그러나 실제 시스템에서는 랜덤 신호가 대부분이며, 랜덤신호 (random signal)들은 PSD (power spectrum density) 를 통하여 구할 수 있다. PSD 함수는 일반적으로  $S_{xx}(f)$  로 표현되며 식 (10)과 같다.<sup>9</sup>

$$S_{xx}(f) = E \left[ \int \lim_{T \rightarrow \infty} \frac{|X_T(f)|^2}{T} df \right] \quad (10)$$

여기서  $f$  주파수이며,  $T$  는 푸리에 변환의 윈도우 주기이고,  $X_T(f)$  랜덤신호의 푸리에 변환이다. 따라서 PSD 는 주파수 영역에서의 분석 중의 하나이다.

### 3.3 고차 시간-주파수 분석 기술

시간-주파수 분석 기술은 랜덤변수들을 시간-주파수 영역에서 동시에 분석하는 기술이다. 특히 랜덤변수의 2 차 모멘트를 시간-주파수 영역에서 분석한 것이 이중선형 분포 (bilinear distribution) 이며, 이것의 대표적인 방법이 위그너 분포 (wigner-Ville Distribution) 이다. 위그너 분포는 식 (11)과 같이 시간 영역의 신호 함수  $s(t)$  를 이용하는 경우와 그것의 주파수 변환을 이용한 스펙트럼 함수  $S(f)$  를 이용하는 경우가 있다.

$$W(t, f) = \int s(t - \tau/2) s^*(t + \tau/2) e^{-2\pi i f \tau} d\tau \quad (11a)$$

$$= \int S(f - \nu/2) S^*(f + \nu/2) e^{-2\pi i \nu t} d\nu \quad (11b)$$

위그너 분포의 특징은 시간-주파수 분해능 (resolution) 이 좋은 것이다. 그러나 단점은 물리적으로 의미 없는 상호 상관 (cross-term) 항목이 발생함하여 위그너 분포의 적용에는 한계가 있다. 따라서 상호상관항목을 제거하기 위해서 위그너 분포에서 이차원 (2 dimension) 저주파필터를 적용시키면 상호상관항목이 줄어드는 것을 볼 수 있다. 이러한 저주파 필터를 적용한 것의 일반적인 형태가 Cohen 방법으로 식 (12)과 같이 정의 된다.

$$C(t, f) = \iint W(t', f') \Phi(f' - f, t' - t) dt' df' \quad (12)$$

여기서  $C(t, f)$  는 Cohen 이중선형 분포 (bilinear distribution) 이며,  $\Phi(t, f)$  는 이차원 저주파 필터이다. 고차 위그너 분포 (Higher Order Wigner distribution) 는 식 (12)을 이용하여 다음과 같이 정의 된다.<sup>11</sup>

$$HOW_i(t, f) = \frac{1}{2} \int H(f) C(t, f - \nu) C(t, f + \nu) d\nu \quad (13)$$

이것은 이중선형분포에 대한 먹으로 랜덤변수의 4 차 모멘트를 이용한 것이다. 여기서  $H(f)$  는 윈도우함수이며 고차위그너 분포에서 잡음을 제거하고 신호만을 향상시키는 윈도우함수이다. 일반

적으로 다양한 윈도우함수가 있으나 본 연구에서는 Hanning 윈도우함수를 사용한다. 윈도우함수를 사용하면 자기상관이 제거되고, 추가적인 상호상관이 발생하지 않게 한다.

### 4. 압축기의 계측 시스템

냉장고 생산 회사들은 양품과 불량품의 계측을 위해서 고도의 숙련된 청각 기능 전문가를 이용하였다. 그러나, 전문가들은 공장의 모든 생산라인의 압축기 검사를 하지 못한다. 샘플 검사를 통하여 압축기가 불량으로 판정이 나면, 동 시간대에 만들어진 수천 개의 압축기가 불량으로 판정이 난다. 따라서, 생산비용이 증가한다. 비용을 절약하기 위해서는 생산 라인의 모든 압축기에 계측시스템을 사용하여 검사하는 것이 중요하다. 본 연구에서는 컴퓨터를 바탕으로 하는 계측 시스템을 개발하였다. 이 시스템은 불량 압축기와 양품 압축기의 패턴 (pattern)을 분석하기 위해서 사용된다.

#### 4.1 실험

본 논문에서는 냉장고 압축기의 결합패턴을 분석을 하기 위해서 ANN 을 사용하였다. 첫째로, ANN 의 최적화된 가중치를 얻기 위해서 ANN 을 학습하였다. ANN 을 학습하기 위해서, 입력 데이터와 목표치 데이터가 요구된다. ANN 의 입력 데이터는 압축기의 상단 부분에서 측정된 진동 값이다. 이 진동 데이터는 앞선 세션에서 언급되었던 디지털 신호 처리 과정을 사용함으로써 결합특징을 추출 할 수 있다. Fig. 3 은 압축기의 진동 측정과정




Fig. 3 Compressor used for vibration measurement

이며, 본 연구를 위해서 다양한 부분에서 진동이 측정되었으나 Fig. 3(c) 에서 보여지는 상단지점을 최적 점으로 선택하였다. ANN 의 목적 값은 숙련된 청취 전문가의 결정과 무향실에서의 음압 측정을 통해서 정하였다. 음압 레벨이 83 dB 이상이면 불량으로 간주하였다. 본 연구를 위해서, 140 개의 압축기가 ANN 의 학습과 검증에 사용되었다.

### 4.2 결함 특징 검출

압축기의 상태에 따른 특징을 추출을 하기 위해서는 분산(Variance), 비대칭도(skewness), 첨도(kurtosis)가 진동데이터로부터 계산되어야 한다. 진동 데이터의 파워 스펙트럼 밀도 함수는 식 (10)에 의해서 계산되었다. 고차 시간 주파수 분석은 식 (13)을 이용하여 계산하였다. Fig. 4 는 140 개의 압축기 중에서 6 개의 샘플 압축기에 대한 진동 측정 결과를 보여준다. 진동은 Fig. 3 에서 보여준 바와 같이 압축기의 상단지점에서 측정된 것이다. Fig. 5 는 파워 스펙트럼 밀도를 보여준다. Fig. 6 은 진동 데이터의 고차 시간 주파수 분석을 나타낸다. 횡축 x 축은 진동 신호를 시간 축으로 나타내며 종축 y 축은 주파수를 나타낸다. Fig. 4, 5 와 6 의 좌측 상단의 숫자는 140 개 압축기 중에 건본 압축기의 일련 번호이다. Fig. 4 의 신호를 보면, 압축기의 이상 유무를 판단할 특징을 찾을 수 없다. Fig. 5 에서도 신호에 대한 주파수 분석 결과에서도 압축기의 이상 유무를 결정지을 특징을 찾기 힘들다. Fig. 6 에서도 압축기의 이상 상태를 언급하기 복잡하다. 그러나 전문가들은 샘플 압축기의 no. 122 와 no. 125 는 불량이고, 다른 압축기들은 양품이라고 판단하였다. 전문가들의 판단과 Fig. 6(b), (d)를 비교하여

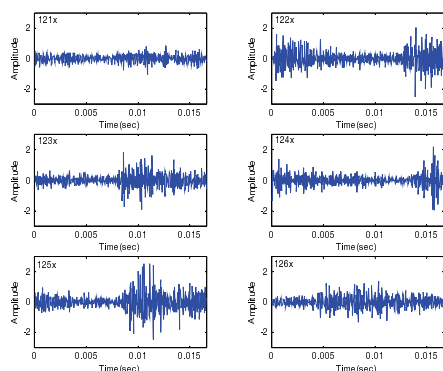


Fig. 4 Vibration data measured on the top of a reciprocating compressor

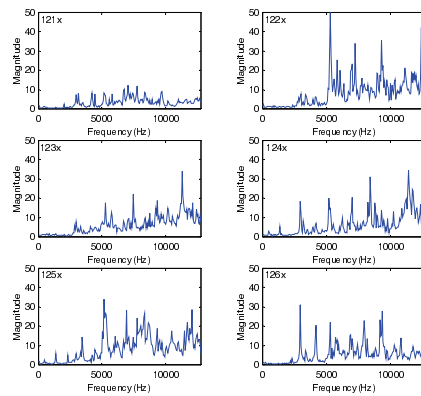


Fig. 5 Power spectra density analysis of the vibration data

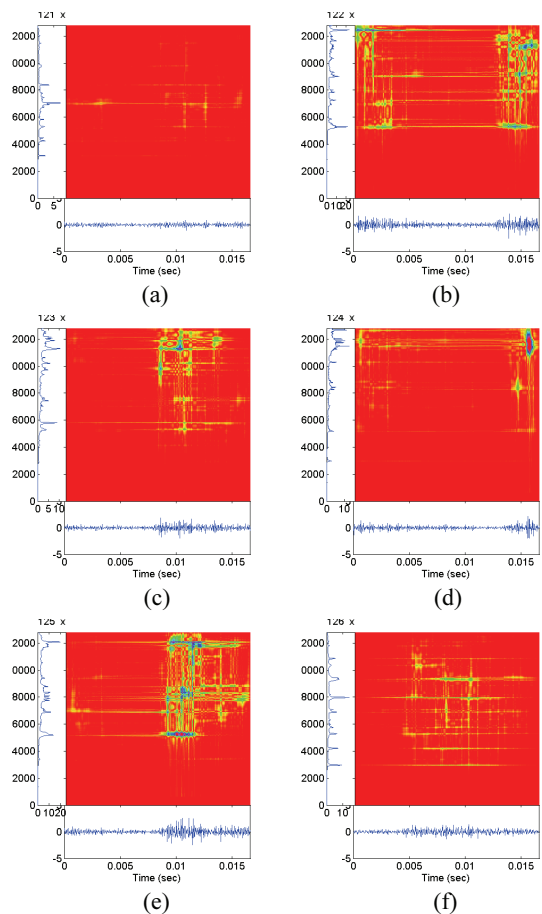


Fig. 6 Higher time frequency analysis for the the vibration data measured on the top of sampled reciprocating compressors: figures (a), (c), (d), and (f) are distribution for a healthy compressor and figures (b) and (e) are for a faulty compressor

보면 불량품의 특징으로는 y-축상의 5000 Hz 에서 크기 10 을 가지는 파워 스펙트럼 라인이 생기는 것을 알 수 있다. 그러나 고차 시간-주파수 분석의 결과는 Fig. 6 에서 보여지는 것처럼, 대부분의 압축기는 5000 Hz 성분의 요소를 가지고 있다. 따라서 불량 압축기의 특징 추출을 위해서는 크기가 10 이상인 스펙트럼 라인의 임계값을 사용하여야 한다.

### 4.3 결함 분류

Fig. 1 및 Fig. 2 에서 보여지는 것처럼, ANN 의 가중치 값은 입력 데이터와 목적 데이터로 구성된 데이터 세트의 절반을 사용함으로써 학습되어진다. 다른 절반의 데이터 세트는 실험에 사용된다. 입력 데이터의 두 가지 유형이 있다. 첫째는 진동 데이터의 시간계열의 통계상의 값들이며, 둘째는 140 개 압축기를 고차 시간-주파수 분석을 통한 5000 Hz 에서 크기 10 을 가지는 스펙트럼 라인이다. 전문가들은 목표 (target value) 값을 결정하였다. 전문가들에 의하면 불량 압축기는 81, 82, 122, 125, 139 번이다. ANN 이용시 학습과정 식 (4) 에서 보여지는 불량압축기의 목표값은 1 이다. 양품압축기의 목표값은 0 이다. Fig. 7(a)은 ANN 의 목적값이고 Fig. 7(b)는 출력값을 나타낸다. ANN 의 입력값은 상단 압축기에 대한 시계열의 분산 (variance), 비대칭도(skewness), 첨도(kurtosis) 값들이다. 이 실험에 사용된 Fig. 2 의 ANN 구조는 3-4-1 이다. 입력 데이터 개수는  $N = 3$  으로 나타낸다. 첫 번째 은닉층의 개수는  $H_1 = 4$  이고, 출력데이터의 개수는  $M = 1$  이다. Levenberg-Marquardt 은 ANN 훈련을 통한 학습 방법이다. Fig. 7 의 결과를 보면 목표값대비 출력값의 차이가 존재한다. 82 번의 불량은 양품으로 검출되었고, 128 번의 양품은 불량으로 검출되었다. 따라서 시계열 데이터의 통계적 방법은 검사시스템으로 적용할 수가 없다. Fig. 8 은 특징 추출로서 5000 Hz 의 크기 10 인 스펙트럼 라인을 사용해서 얻은 ANN 의 목표값과 출력값이다. 따라서 ANN 의 입력 데이터는 크기 10 인 스펙트럼 라인이다. 이번 실험의 ANN 의 구조는 10-4-1 구조이다. 입력 데이터의 개수는  $N = 10$  이다. 첫 번째 은닉층의 신경 개수는  $H_1 = 4$  이고, 출력 데이터의 개수  $M = 1$  이다. ANN 의 학습 방법은 Levenberg-Marquardt 의 반복 작업이다. Fig. 8(a)는 목표 값이고, Fig. 8(b)는 ANN 의 출력 값이다.

이 결과에 의하면 82 번의 불량을 양품으로 나타내는 것 이외는 검출이 잘된 것이다. 즉 140 개 가운데 70 개 학습 후 70 개를 시험한 결과 1 개의 판단 오류가 발생하였다. Fig. 8(b) 에서 보여주는 바와 같이 목표치를 0.5 로 낮추면 양품을 불량으로 판단 할 수 있으므로 주의가 필요하다. 결과적으로, 불량 압축기에 대한 임계값을 ANN 의 출력으로 설정 해둔다면, 모든 불량 압축기들은 계측 될 것이다.

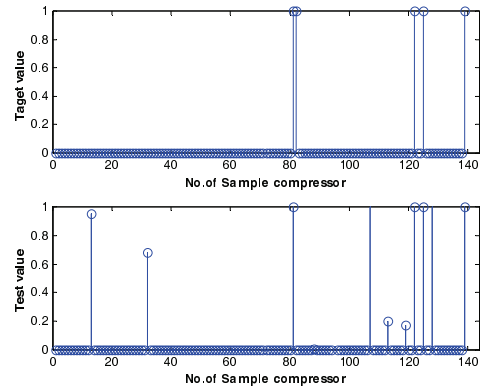


Fig. 7 Target value and output of the ANN using the statistical value as the feature extraction of faulty compressors

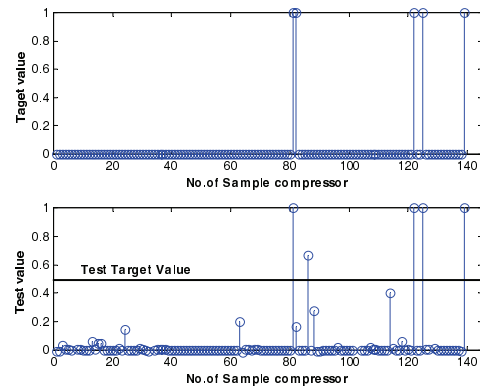


Fig. 8 Target value and output of the ANN using magnitudes of 10 spectra lines as the feature extraction of faulty compressors

### 5. 결론

본 논문에서 Fig. 9 에서 보여지는 것처럼 컴퓨터를 바탕으로 계측 시스템을 생산라인에 접목시

켰다. 이 시스템은 불량 압축기 계측과 생산 비용 절감에 적합하다. 이 논문에 사용된 도구들은 디지털 신호 처리 방법이다.

압축기의 특징 추출을 위해서 시간 계열의 통계적 수치와 파워 스펙트럼 밀도, 및 고차 시간-주파수 함수를 사용하였다. 우리는 불량 압축기의 특징 추출에 있어서 후자를 사용하였고, 불량 압축기와 정품 압축기를 찾기 위해서 인공 신경 회로망을 사용하였다. 10-4-1 구조의 ANN 을 계측 시스템으로 채택하여 사용하였다. 이 시스템이 Fig. 10 처럼 생산라인에 설치 되었다. 자동 진동 측정 장치는 두 압축기의 가속도를 측정 하기 위해 설치 된다. 측정 데이터는 계측 장비로 전송되고, 자동적으로 분석된다. 향후 제품 전수 검사에서는 100% 신뢰성을 보장하기 위해서 더 많은 데이터를 축적하여 ANN 을 학습함으로써 신뢰성 높은 계측 시스템을 구현해야 한다.



Fig. 9 Mass production line of the reciprocating compressor without health monitoring system



Fig. 10 Mass production line of the reciprocating compressor with health monitoring system

## 후 기

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

## 참고문헌

1. Key, M., "Modern Spectra Estimation Theory & Application," Prentice Hall, 1988.
2. Dyer, D. and Stewart, R. M., "Detection of Rolling Element Bearing Damage by Statistical Vibration Analysis," Journal of Mechanical Design, Vol. 100, pp. 229-235, 1978.
3. Randall, R., "B&K Application Note," Technical Report, pp. 13-150, 1981.
4. Lee, S. K. and White, P. R., "Two-Stage Adaptive Line Enhancer and Sliced Wigner Trispectrum for the Characterization of Faults from Gear Box Vibration Data," Journal of Vibration and Acoustics, Vol. 121, pp. 488-494, 1999.
5. Zhuge, Q., "Non-stationary modeling of vibration signals for monitoring the condition of machinery," Mechanical Systems and Signal Processing, Vol. 4, pp. 355-365, 1990.
6. Wang, Y., He, Z., and Zi, Y., "Enhancement of signal denoising and multiple fault signatures detecting in rotating machinery using dual-tree complex wavelet transform," Mechanical Systems and Signal Processing, Vol. 8, pp. 119-137, 2010.
7. McFadden, P. D., "Examination of a Technique for the Early Detection of Failure in Gears by Signal Processing of the Time Domain Average of the Meshing Vibration," Mechanical Systems and Signal Processing, Vol. 1, pp. 177-183, 1987.
8. Lee, S. K. and White, P. R., "Higher-Order Time-Frequency Analysis and Its Application to Fault Detection in Rotating Machinery," Mechanical Systems and Signal Processing, Vol. 11, pp. 637-650, 1997.
9. Meegan, G. M., Nelson, H. R., Barlirt, M. L., and Wilson, G. R., "Fault detection in engines through higher order spectral analysis of acoustic signatures," Journal of the Acoustical Society of America, Vol. 106, pp. L1-L6, 1999.

10. Wyk, P. V. and Hoffnan, A. J., "Detecting long-term trends in turbo-generator stator end-winding vibrations through neural network modelling," *Journal of Sound and Vibration*, Vol. 253, pp. 529-544, 2002.
11. Lee, S. K., "A New Method of Smoothing Non-Oscillation Cross-Terms in Sliced Wigner Fourth Order Moment," *Mechanical Systems and Signal Processing*, Vol. 15, pp. 1023-1029, 2001.
12. Matr, H., "Neural Network Design," PWS Publishing Company, 1996.