

◎ 논문

터보회전기기의 진동모니터링 및 진단을 위한 이산 은닉 마르코프 모델에 관한 연구

이종민* · 황요하* · 송창섭**

A Study on Discrete Hidden Markov Model for Vibration Monitoring and Diagnosis of Turbo Machinery

Jong-Min Lee*, Yo-ha Hwang*, Chang-Seop Song**

Key Words: Discrete hidden markov model (DHMM, 이산 은닉 마르코프 모델), Vector quantization (VQ, 벡터 양자화), Feature vector (특징벡터), Fault recognition (결함인식), Condition monitoring (상태진단), Unbalance (불평형), Oil whirl (오일휠)

ABSTRACT

Condition monitoring is very important in turbo machinery because single failure could cause critical damages to its plant. So, automatic fault recognition has been one of the main research topics in condition monitoring area. We have used a relatively new fault recognition method, Hidden Markov Model(HMM), for mechanical system. It has been widely used in speech recognition, however, its application to fault recognition of mechanical signal has been very limited despite its good potential. In this paper, discrete HMM(DHMM) was used to recognize the faults of rotor system to study its fault recognition ability. We set up a rotor kit under unbalance and oil whirl conditions and sampled vibration signals of two failure conditions. DHMMs of each failure condition were trained using sampled signals. Next, we changed the setup and the rotating speed of the rotor kit. We sampled vibration signals and each DHMM was applied to these sampled data. It was found that DHMMs trained by data of one rotating speed have shown good fault recognition ability in spite of lack of training data, but DHMMs trained by data of four different rotating speeds have shown better robustness.

1. 서론

터보회전기는 고장 발생시 전체 설비 및 생산에 커다란 손실을 주기 때문에 이의 상태진단 (condition monitoring)은 매우 중요하며, 이상이 발생할 경우 정확한 고장진단 및 신속한 조치가 요구된다. 이에 따라

고장인식의 자동화가 터보회전기기 상태진단 분야에서 중요한 연구 주제 중 하나가 되었으며, 현재 전문가 시스템, 신경망 (neural network), 퍼지 (fuzzy) 추론 등을 사용한 결합의 자동 인식에 대한 연구가 많이 진행되고 있다⁽¹⁾.

본 논문에서는 은닉 마르코프 모델 (HMM, Hidden Markov Model)을 터보회전기기의 결합인식에 사용되는 새로운 방법으로 제안한다. HMM은 1960년대 음성 인식 분야에서 연구되기 시작하여 현재 대부분의 음성

* 한국과학기술연구원 시스템연구부

** 한양대학교 기계공학부

책임저자 E-mail : ljm2293@kist.re.kr

인식 프로그램에서 사용되는 방법이다. 1980년대 후반부터는 음성인식 분야 이외의 여러 분야에서 신호의 패턴 (pattern)을 인식하는데 적용되고 있으며 점차 그 응용분야를 넓혀가고 있다. HMM은 하나의 통계처리 과정 내부에 또 다른 통계처리 과정이 있는 2중 통계 처리 구조로 되어있기에 통계특성이 숨어있는 신호를 모델링하는데 유용하고, 다양한 수학적 구조가 있으며 몇몇 응용분야에서 우수한 결과를 보여준 검증된 모델링 기법이다⁽²⁾. HMM의 특징을 살펴보면, 학습패턴으로 적절히 학습시키면 안정적이고 정확한 인식 및 예측성능을 지니고 있고, 알고리즘을 수정하지 않고서도 유사한 시스템에 적용할 수 있으며, 학습하지 않은 패턴이 나중에 발견되어도 그 패턴에 대한 모델만 학습시켜 학습된 모델집합에 추가하면 되는 등 다양한 장점이 있다⁽³⁾. 그러나 아직 기계 상태진단 분야에서는 본격적으로 연구되지 않았으며 적용사례도 미미하다.

HMM은 모델링될 신호가 기호인 이산 (discrete) HMM (DHMM)과 벡터인 연속 (continuous) HMM (CHMM)으로 분류가 되는데, 일반적으로 DHMM은 계산이 빠르며 외란에 강건 (robust)하게 패턴을 구분해낼 수 있으며, CHMM은 보다 정밀한 값으로 패턴을 구분하면서 우수한 예측기능을 가지고 있다. 기계 상태진단에 HMM을 이용한 연구결과를 살펴보면, Wong 등은 비등온 연속 교반탱크 반응기의 상태진단에⁽⁴⁾, Kwon 등은 핵발전소에서의 사고가 발생했을 때 초기 단계에서 사고형태를 확인하는데 DHMM을 사용하였다⁽⁵⁾. 한편, Bunks 등은 CHMM이 헬리콥터 기어박스의 상태진단에 적용될 수 있다고 제안하였으며⁽⁶⁾, Ertunc 등은 드릴 날의 마모상태진단에 CHMM을 사용하여 좋은 결과를 얻었다⁽⁷⁾. 저자들은 선반가공시 발생하는 채터현상과 저널베어링 마모의 진단⁽³⁾, 회전체 공진예측⁽⁸⁾에 CHMM을 이용하였으며, 회전체의 결합인식에 HMM의 사용을 제안하여 연구를 수행하였다⁽⁹⁾.

저자들의 연구결과, 회전체 시스템에서 측정되는 각 결합신호의 특징벡터들은 일반적으로 HMM이 적용되었던 신호들과는 달리 분산이 매우 적기 때문에 계산상 많은 문제를 야기하므로, HMM 알고리즘을 대폭 수정하여 사용하였다⁽⁹⁾. 또한, CHMM은 지능모니터링에 매우 유용한 예측성능을 보여주고 있지만⁽³⁾, DHMM과 비교하면 상대적으로 외란에 대한 강건성 (robustness)이 나쁘다 것을 알 수 있었다⁽⁹⁾.

본 논문에서는 터보회전기기의 상태진단시 결합인식에 사용될 수 있는 DHMM의 특성을 알아보기 위하-

여, 회전수 변화에 따른 결합인식 성능을 연구한 이전 연구⁽⁹⁾와는 달리 DHMM의 학습에 사용된 시스템과 유사한 시스템의 결합신호에 학습된 DHMM을 적용하여 결합인식 성능을 알아보았다. 이를 위하여 두 가지 방법으로 DHMM을 구하였다. 우선 회전체 실험장치를 구성하여 여러 회전수에서 결합신호를 얻은 다음 한 회전수에서 측정된 신호로 DHMM을 학습시켰고, 다음에는 여러 회전수에서 측정된 신호로 DHMM을 학습시켰다. 결합인식을 위하여 회전체 실험장치 각 요소들의 배치 및 회전속도를 변경하고 나서 얻은 결합신호에 두 가지 방법으로 학습된 DHMM들을 적용하여 그 인식결과를 비교하였다. 매우 적은 학습데이터로 학습된 DHMM이었지만 두 경우 모두 좋은 결과를 얻었으며, 특히 여러 회전수에서 측정된 결합신호로 학습된 DHMM의 경우는 결합인식 성능을 크게 개선하는 결과를 얻어, 터보회전기기의 상태진단에 DHMM을 사용할 수 있다는 것을 보였다.

2. DHMM 이론

2.1 DHMM의 정의 및 구조

시스템의 출력신호를 식 (1)의 M 개의 기호 중 하나로 표현할 수 있을 때, 일정시간 간격으로 T_k 시간 동안 관측하여 얻은 기호들을 순서대로 나열한 관측기호 순열, $O^{(k)}$ 를 K 개 모은 집합, \mathbf{O} 가 식 (2)와 같이 주어졌다고 하자.

$$V = \{v_1, v_2, \dots, v_M\} \quad (1)$$

$$\mathbf{O} = \{O^{(1)}, O^{(2)}, \dots, O^{(K)}\} \quad (2)$$

여기서, $O^{(k)} = [o_1^{(k)} \ o_2^{(k)} \ \cdots \ o_{T_k}^{(k)}]$, $o_t^{(k)} \in V$

식 (2)와 같은 학습용 관측기호 순열집합을 출력하는 DHMM, λ 를 구하면, 식 (3)과 같은 임의의 관측기호 순열이 λ 에서 출력될 확률, $P(O^D|\lambda)$ 를 ($P(\cdot)$ 는 확률) 구할 수 있다는 것이 DHMM 이론이다.

$$O^D = [o_1^D \ o_2^D \ \cdots \ o_{T_d}^D], \ o_t^D \in V \quad (3)$$

DHMM의 구조는 식 (4)와 같이 각 관측기호들이 관측될 확률분포가 각각 다른 N 개의 상태 (state)들로 구성된다. 여기에 식 (5)~(7)과 같이 초기 관측기호가 n 번째 상태에서 출력될 초기상태확률분포를 π_n 으로, 시간, t 에서의 관측기호가 i 번째 상태에서 출력되었을 때 시간, $t-1$ 에서의 관측기호가 j 번째 상태에서 출력될 상태천이확률분포를 a_{ij} 로, n 번째 상태에서 m 번째 기호가 관측될 관측기호확률분포를 b_{nm} 으로 정의하면 (여기서, q_t 는 t 에서의 상태로 $q_t \in S$), 식 (2)에서 주어진 관측순열 집합으로부터 log-Viterbi 알고리즘⁽¹⁰⁾과 구간별 k-평균 군집화 (segmental k-means clustering) 알고리즘⁽¹⁰⁾을 사용하여 $\lambda = \{\pi, A, B\}$ 의 초기값을 구한 다음, 이 초기값과 Baum-Welch 알고리즘^{(2),(10)}을 사용하여 $\lambda = \{\pi, A, B\}$ 를 구한다. 또한, 식 (3)의 임의의 관측기호 순열이 λ 로부터 관측될 확률의 상용대수값, $\log(P(O^D|\lambda))$ 를 스케일된 전진 변수 (scaled forward variable)^{(9),(10)}를 이용하여 구한다.

$$S = \{s_1, s_2, \dots, s_N\} \quad (4)$$

$$\pi = [\pi_1 \ \pi_2 \ \dots \ \pi_N]^T \quad (5)$$

여기서, $\pi_n = P[q_1 = s_n]$, $\sum_{n=1}^N \pi_n = 1$

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{N1} & a_{N2} & \cdots & a_{NN} \end{bmatrix} \quad (6)$$

여기서, $a_{ij} = P[q_{t+1} = s_i | q_t = s_j]$,

$$\sum_{j=1}^N a_{ij} = 1 \quad \forall i$$

$$B = \begin{bmatrix} b_{11} & b_{12} & \cdots & b_{1M} \\ b_{21} & b_{22} & \cdots & b_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ b_{N1} & b_{N2} & \cdots & b_{NM} \end{bmatrix} \quad (7)$$

여기서, $b_{nm} = P[o_t^{(k)} = v_m | q_t = s_n]$,

$$\sum_{m=1}^M b_{nm} = 1 \quad \forall n$$

2.2 DHMM의 예

DHMM, λ_1 의 구조가 식 (8)과 같이 관측기호가 4개이며, 3개의 상태로 이루어져 있고, 초기상태확률분포, 상태천이확률분포, 관측기호확률분포 값은 식 (9)와 같다고 하자.

$$V = \{\xi, \theta, \psi, \omega\}, \quad S = \{s_1, s_2, s_3\} \quad (8)$$

$$\pi = \begin{bmatrix} 0.714 \\ 0.286 \\ 0 \end{bmatrix}, \quad A = \begin{bmatrix} 0.4 & 0.4 & 0.2 \\ 0.1 & 0.5 & 0.4 \\ 0 & 0.3 & 0.7 \end{bmatrix}, \quad (9)$$

$$B = \begin{bmatrix} 0.5 & 0.1 & 0.4 & 0 \\ 0.25 & 0.375 & 0.125 & 0.25 \\ 0 & 0.25 & 0.125 & 0.625 \end{bmatrix}$$

이를 블록선도 (block diagram)로 나타내면 Fig. 1과 같고, 이 시스템의 출력을 만들어 내는 과정은,

- ① $t=1$: π 의 확률로 q_1 을 선택하고, q_1 의 B 확률 ($[b_{q_11} \ b_{q_12} \ \dots \ b_{q_1M}]$)로 기호를 선택하면 $o_1^{(k)}$ 이다.

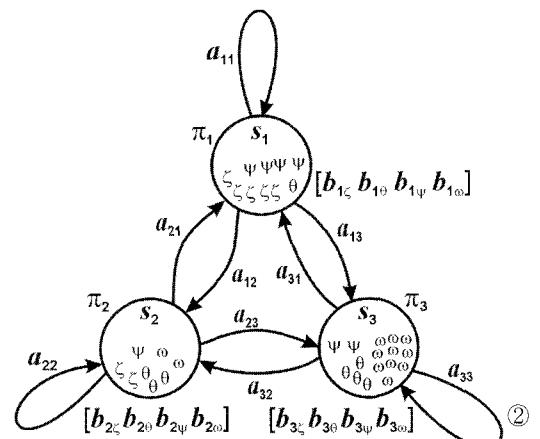


Fig. 1 Structure of 4-symbol 3-state ergodic DHMM

$t=t+1 : q_{t-1}$ 의 A 확률
 $([a_{q_{t-1}1} \ a_{q_{t-1}2} \ \dots \ a_{q_{t-1}N}])$ 로 q_t 를 선택하고,
 q_t 의 B 확률 $([b_{q,1} \ b_{q,2} \ \dots \ b_{q,M}])$ 로 기호를
선택하면 $o_t^{(k)}$ 이다.

③ ②를 $t = T_k$ 가 될 때까지 반복한다.

와 같다. 이와 같은 방법으로 λ_1 에서 출력되는 기호를 $T_k = 10$ 일 때까지 50번 관찰한 관측기호순열 집합은 식 (10)과 같다.

$$\begin{aligned} O^{(1)} &= [\zeta \ \zeta \ \psi \ \theta \ \zeta \ \psi \ \psi \ \zeta \ \psi \ \omega] \\ O^{(2)} &= [\zeta \ \psi \ \omega \ \omega \ \theta \ \theta \ \omega \ \omega \ \omega] \\ &\vdots \quad \vdots \\ O^{(50)} &= [\zeta \ \theta \ \theta \ \omega \ \omega \ \omega \ \omega \ \theta \ \theta] \end{aligned} \quad (10)$$

식 (10)을 살펴보면 뚜렷한 통계적 특성을 찾을 수 없으나, DHMM으로 모델링하면 2중 통계적 특성을 찾을 수 있는데, 5개의 관측기호 순열로 학습시킨 DHM M , λ_2 는 식 (11)과 같고, 50개의 관측기호 순열로 학습시킨 DHMM, λ_3 는 식 (12)와 같다.

$$\pi = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \ A = \begin{bmatrix} 0.646 & 0.354 & 0 \\ 0.075 & 0.5 & 0.425 \\ 0 & 0.416 & 0.584 \end{bmatrix}, \quad (11)$$

$$B = \begin{bmatrix} 0.462 & 0.247 & 0.291 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0.931 & 0.069 & 0 \end{bmatrix}$$

$$\pi = \begin{bmatrix} 0.63 \\ 0 \\ 0.37 \end{bmatrix}, \ A = \begin{bmatrix} 0 & 1 & 0 \\ 0.082 & 0.918 & 0 \\ 0.567 & 0 & 0.433 \end{bmatrix}, \quad (12)$$

$$B = \begin{bmatrix} 0.288 & 0.28 & 0.285 & 0.147 \\ 0.142 & 0.25 & 0.129 & 0.469 \\ 0.499 & 0 & 0.501 & 0.000 \end{bmatrix}$$

학습모델 λ_2 와 λ_3 인 식 (11), (12)는 원래 모델 λ_1 인 식 (9)과는 많은 차이가 있지만 λ_1 에서 관측된 또 다른 51개의 관측기호 순열을 3 모델로 인식한 결과인 Fig. 2를 살펴보면, λ_2 만 4개의 관측기호순열을 오인하였고 나머지는 λ_1 과 비슷하게 인식하였다. λ_3 의 경우는 λ_1 의 인식결과와 아주 유사하였다. 이상의 결과

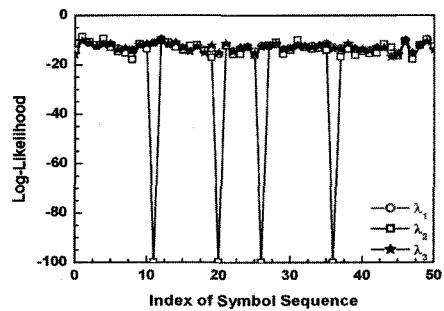


Fig. 2 Recognition results of DHMMs

로 적은 학습데이터로도 DHMM이 관측기호순열을 인식할 수 있는 도구로 사용될 수 있고, 학습데이터 양이 많아지면 더욱 정확하게 인식한다는 것을 알 수 있다.

2.3 데이터의 전처리 과정

기계시스템에 장착된 센서로부터 측정되는 신호는 시계열 (time series) 데이터로 이러한 데이터는 직접 DHMM의 학습에 사용될 수 없다. 따라서 시계열 데이터에 담겨있는 대상 기계시스템의 특징을 추출하기 위하여 특징벡터 (feature vector) 추출과정과 이 특징벡터를 양자화하여 기호로 변환하는 벡터 양자화 (VQ, vector quantization) 등 전처리 과정이 필요하다.

진단하고자 하는 결함의 특징을 가장 잘 나타낼 수 있는 방법을 특징벡터 추출방법으로 선택해야 한다. 예를 들면, 단위시간 동안 시계열 데이터의 통계적 특성 (평균, 분산 등), 자기회기 (AR, auto-regressive) 모델 계수, 필터뱅크 (filter bank)⁽¹⁰⁾를 통과한 자기파워스펙트럼 계수, 필터뱅크를 통과한 켭스트럼 (cepstrum) 계수 등 가장 적절한 방법을 선택하여 시계열 데이터를 특징벡터순열로 변환한다.

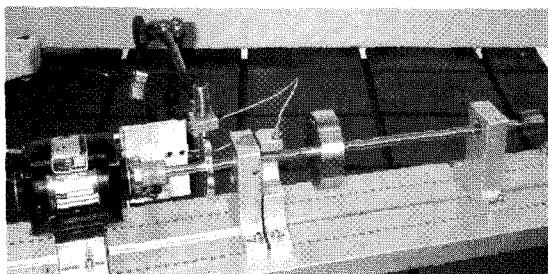
이와 같이 변환한 특징벡터순열은 다시 DHMM에 맞도록 VQ를 이용하여 기호화 하여 관측기호순열로 변환해야 한다^(10,11).

3. 회전체 결함 인식

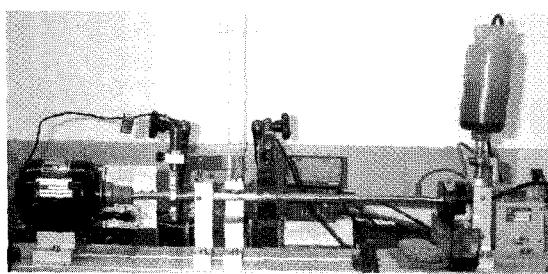
3.1 학습 및 진단용 데이터

3.1.1 실험장치 및 방법

불평형 (unbalance) 결함과 오일휠 (oil whirl) 결함



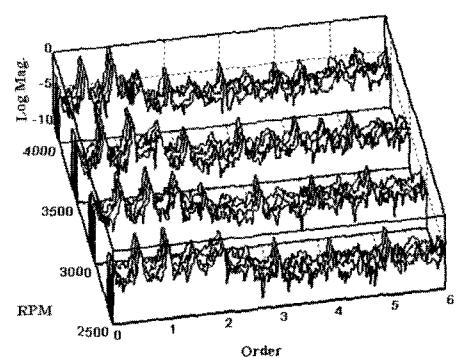
(a)



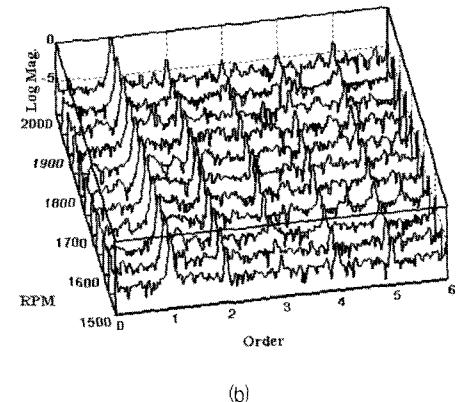
(b)

Fig. 3 Rotor test kit for (a) unbalance and (b) oil whirl

에 대한 회전체 결합 신호를 얻기 위하여, Fig. 3과 같이 회전체 모의실험장치를 구성하였다. 이 장치는 모터 축에 회전수를 측정하면서 A/D변환기의 트리거(trigger) 신호로 사용하기 위한 12개의 이빨이 있는톱니바퀴가 있으며, 축 정렬불량(misalignment)의 영향을 최소화하기 위하여 모터 축과 회전축은 가요성 축이음(flexible coupling)으로 연결하였다. 회전축 양단에는 회전축을 지지하는 저널 베어링(journal bearing)과 하우징(housing)을 설치하였으며, 축 가운데에는 하중을 주기 위한 원판을 설치하였다. 모터 축에 가까운 베어링 근처에서 변위센서로 회전축의 수직변위를 한 회전당 12번 샘플링(sampling)하여 한 번 실험에 2,000개(약 166.7회전)의 데이터를 기록하였다. 우선 학습용 데이터를 얻기 위하여 두 결합에 대하여 각각 회전속도를 2,500 rpm에서 4,000 rpm까지 500 rpm씩 증가시키면서 각 rpm에서 네 번씩 총 16번 실험하였다. 다음에 학습되지 않은 시스템으로부터 진단용 데이터를 얻기 위하여 베어링 하우징 간격을 바꾸고 하중용 원판의 위치도 바꾼 다음 두 결합에 대하여 각각 회전속도를 1,500 rpm에서 2,000 rpm까지 50 rpm씩 증가시키면서 각 rpm당 1번씩 총 11번 실험을 하였다.



(a)



(b)

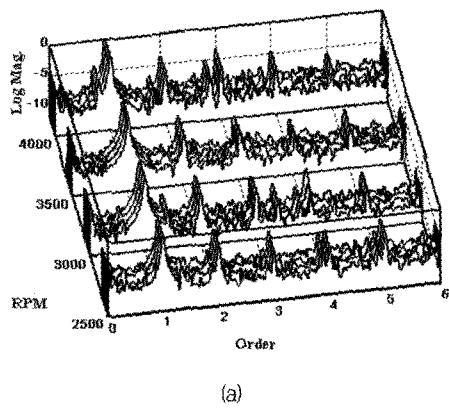
Fig. 4 Normalized auto-power spectrums of unbalance signals for (a) training^[9] and (b) diagnosis

3.1.2 불평형 데이터

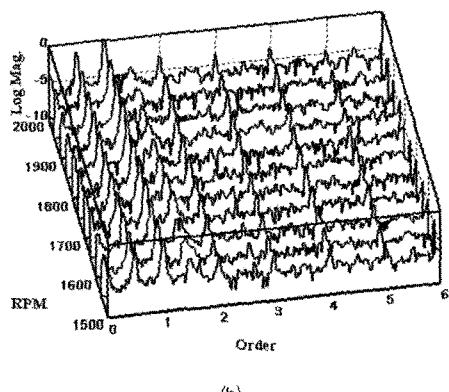
우선 Fig. 3(a)와 같이 회전축 양단을 저널 베어링으로 지지하고서 그 사이에 설치된 원판에 불평형 질량을 부가하여 회전시켰다. 그때 회전축의 수직 변위 데이터의 자기파워스펙트럼을 구하여 1차(order) 회전주파수(1x) 성분의 크기로 정규화(9)한 그래프는 Fig. 4와 같다. Fig. 4(a)는 31.2절에서 언급한 방법으로 얻은 학습용 데이터이고, Fig. 4(b)는 진단용 데이터이다. 학습용 데이터를 보면 1x 성분의 크기가 제일 크게 나타나며, 1x 성분의 크기에 비하여 상대적으로 상당히 작은 크기로 2x, 3x, 4x에서 피크(peak)가 나타났다. 진단용 데이터는 학습용 데이터와 비슷한 경향을 보이고 있으나, 실험장치의 각 부품의 위치가 바뀌고 회전수가 낮은 관계로 2x 성분의 크기에 비하여 3x, 4x 성분의 크기가 크게 줄어들었다. 이는 불평형 결합의 진동으로 판단할 수 있다^[12].

3.1.3 오일휠 데이터

다음에 Fig. 3(b)와 같이 모터에서 먼 쪽의 베어링을 유체 베어링으로 바꾸고 원판에 부가되었던 불평형 질량을 제거하고서 오일휠 결합을 구현하였다. Fig. 5(a)는 3.1.2절에서 언급한 방법으로 얻은 학습용 데이터를, Fig. 5(b)는 진단용 데이터를 1x 성분의 크기로 정규화한 자기파워스펙트럼이다. Fig. 5를 보면 1x 성분의 크기가 제일 크고 $0.5x$ 와 $1.5x$ 에서 피크가 발생하였으므로 불평형과 러빙(rubbing)이 축의 처짐 때문에 저널 베어링쪽에서 발생했다고 할 수 있으나 $1x$ 와 $1.5x$ 의 피크 크기가 작기 때문에 그 크기는 미약하다⁽⁹⁾. 또한, 스펙트럼의 주파수 분해능 때문에 $0.5x$ 에서의 피크는 실제로는 $0.486x$ 에서의 피크이며, 이는 러빙의 피크인 $0.5x$ 보다는 오일휠의 피크인 $0.42\sim0.48x$ 에 가깝기 때문에 오일휠로 볼 수 있다⁽¹²⁾.



(a)

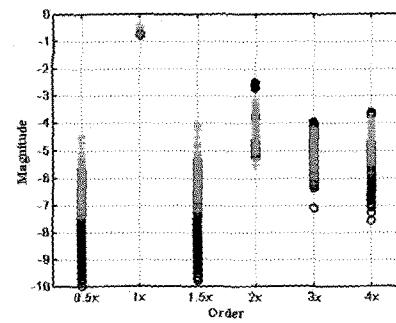


(b)

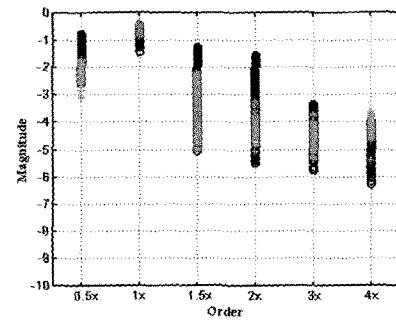
Fig. 5 Normalized auto-power spectrums of oil whirl signals for (a) training⁽⁹⁾ and (b) diagnosis

3.1.4 특징벡터의 추출

각실험에서 얻은 2,000개의 축 수직변위 시계열 데이터는 512개씩 중첩(overlapping)되도록 나누어 1x 성분 크기로 정규화한 24개 자기파워스펙트럼으로 변환하였다. 이는 24개의 257차 벡터순열이 되는데, 257차 특징벡터는 벡터의 크기가 DHMM에 바로 적용하면 VQ 학습시 오버플로우(overflow)가 발생하거나 무한루프(loop)에 빠지는 계산상 문제를 야기하기 때문에 벡터차수를 줄여야 했다. 따라서, Fig. 4와 Fig. 5에서 보듯이 두 결합은 자기파워스펙트럼의 피크로 그 특징을 구분할 수 있으므로, 통과대역(pass band)이 $0.07x$ 이고 각 중심 차수가 $0.5x$, $1x$, $1.5x$, $2x$, $3x$, $4x$ 인 6개의 대역통과 필터로 이루어진 필터뱅크를 통과시켜 6차 특징벡터로 변환하였다⁽⁹⁾. 각 실험에서 얻은 6차 특징벡터들의 각 성분 분포는 Fig. 6과 같다. Fig. 6(a)는 불평형 특징벡터, Fig. 6(b)는 오일휠 특징벡터들 각 성분 분포인데, 학습용 특징벡터들은 짙은 색 ■ 표시들이 있고, 진단용 특징벡터들은 흐린 색 + 표시들이이다. 그림에서 보면 오일휠 특징벡터들은 $0.5x$ 와 $4x$ 에서 몇 개의



(a)



(b)

Fig. 6 Distributions of feature vectors about (a) unbalance and (b) oil whirl

경우를 제외하면 진단용 특징벡터들은 학습용 특징 터들 안에 분포되어 있으나, 불평형의 경우에는 $0.5x$ 와 $1.5x$ 에서 진단용 특징벡터들이 학습용 특징벡터들이 분포된 범위 밖에 많이 분포되어 있음을 알 수 있다.

3.2 결합인식 결과

3.2.1 한 회전수에서 학습된 DHMM

3,500 rpm에서 얻은 8개 (불평형 4개, 오일휠 4개)의 특징벡터순열의 모든 순열을 벡터공간에서의 기하학적 거리를 이용하여 6개의 집단 (group)으로 분류하고 각 집단의 중심벡터를 VQ 코드북으로 하고 이 6개의 중심벡터에 각각 기호를 배정하였다. 특징벡터순열의 각 특징벡터를 이 VQ 코드북의 중심벡터 중 가장 가까운 중심벡터에 배정된 기호로 변환하여 기호순열로 변환하였다.

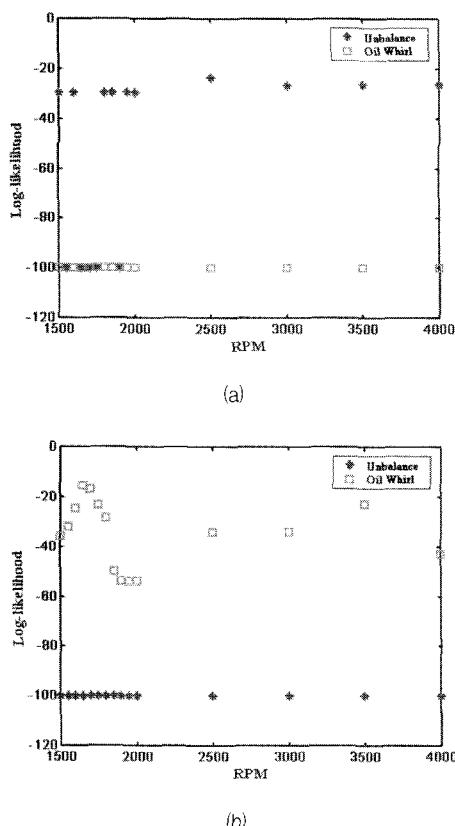


Fig. 7 Recognition results of DHMM trained at 3,500 rpm about (a) unbalance and (b) oil whirl

각각 4개의 기호순열을 사용하여 2개의 3상태 DHMM을 구하고, 전체 특징벡터 순열에 앞에서 구한 VQ와 DHMM을 적용하여 이상을 진단하여 보았다. 그 결과는 Fig. 7에 나타나 있는데, 짙은 색 ■ 기호는 측정된 신호가 불평형 DHMM에서 출력될 대수우도 (log-likelihood)⁽¹³⁾이고 흐린 색 □ 기호는 오일 휠 DHMM에서 출력될 로그우도이다. DHMM은 학습된 3,500 rpm에서 뿐만 아니라 다른 회전수에서도 정확하게 진단하는 우수한 결과를 보여주었지만, Fig. 7(a)에서 보듯이 저 회전수에서 불평형 결합을 1,550, 1,650, 1,700, 1,750, 1,900 rpm에서 인식하지 못했다. 이는 회전수가 낮아짐에 따라 불평형 신호의 1x 성분의 크기가 크게 줄어들어 상대적으로 $0.5x$ 와 $1.5x$ 성분 값들이 좀더 높은 값들에 분포되었기에 Fig. 6(a)에서 보듯이 특징벡터의 $0.5x$ 와 $1.5x$ 성분 값들의 분포가 차이가 나기 때문이다. 그러나 한 회전수에서의 단 4개의 학습 데이터만으로 학습시킨 것을 고려한다면, DHMM이 우수한 회전체 결합인식 방법임을 알 수 있다.

3.2.2 여러 회전수에서 학습된 DHMM

DHMM의 불평형 결합인식 성능을 높이기 위하여 2,500, 3,000, 3,500, 4,000 rpm에서의 두 결합에서 각각 1개씩 총 8개 (불평형 4개, 오일휠 4개)의 특징벡터 순열을 사용하여 3.2.1절과 동일한 방법으로 DHMM을 구하여 이상을 진단하였다. 그 결과는 Fig. 8에 나타나 있는데, 여러 회전수의 데이터로 학습된 DHMM은 Fig. 8(a)에서 보는 바와 같이 불평형의 1,550 rpm을 제외한 모든 경우에 정확하게 결합을 인식하였다. 이는 1,550 rpm에서의 특징벡터들이 학습용 특징벡터들의 분포범위 밖에 분포되어 있기 때문이다(Fig. 6(a)). 따라서 여러 경우에 대한 학습 데이터가 확보된다면, 회전수 및 시스템이 바뀌어서 노이즈 성분 및 피크 성분이 바뀐 경우에 DHMM의 회전체 결합인식 성능이 개선되는 것을 보여주고 있다.

한편, 오일휠 특징벡터의 분포(Fig. 6(b))를 검토하였을 때 예상한 바와 같이 오일휠 결합 인식 결과는 Fig. 7(b)와 Fig. 8(b)에서 보듯이 학습된 시스템은 물론 학습되지 않는 시스템에 대하여서도 아주 훌륭하게 인식하였다. 따라서 시스템의 특징벡터를 결합의 특성을 대표할 수 있는 벡터로 선정할 수 있다면 아주 적은 학습데이터만으로도 DHMM의 인식 성능 및 강건성을 확보할 수 있다는 것을 알 수 있었다.

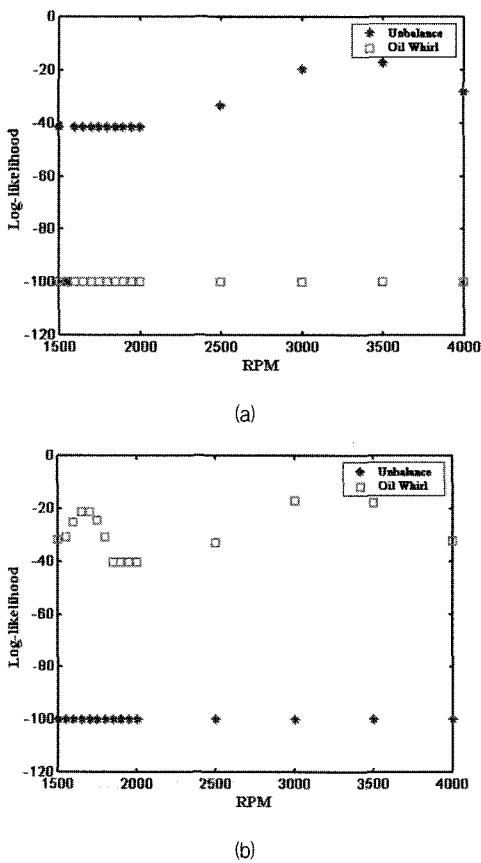


Fig. 8 Recognition results of DHMM trained at 2,500~4,000 rpm about (a) unbalance and (b) oil whirl

4. 결론

터보회전기기 결합인식을 위한 DHMM의 특성을 알아보기 위하여 회전체 실험장치를 구성하여 진동신호를 얻고, 한 회전속에서의 진동신호로 학습시킨 DHMM과 여러 회전속에서의 진동신호로 학습시킨 DHMM을 구하였다. 그런 다음 학습된 DHMM을 사용하여 실험장치 각 요소의 배치와 회전속도를 바꾸고 실험하여 얻은 진동신호의 불평형과 오일휠 결합을 인식을 한 결과 다음과 같은 결론을 얻었다.

적은 수의 학습 데이터에도 불구하고 DHMM은 우수하게 회전체 시스템의 결합을 인식하였다. DHMM의 결합인식 성능은 결합의 특성을 대표할 수 있는 특징벡터의 선정이 매우 중요하였다. 그러나 특징벡터가 결합의 특성을 완벽하게 대표하지 못하는 경우라도,

한 회전수에서 얻은 데이터로 학습시킨 DHMM도 다른 유사 시스템에 적용할 수 있었으며, 여러 회전수에서 얻은 데이터로 학습시킨다면 인식률을 더욱 높일 수 있었다. 그러므로 좀더 많은 회전체 시스템에서 얻은 데이터로 학습시킨다면, 유사한 회전체 시스템의 이상을 알고리즘을 변경하지 않고서도 정확하고 강건하게 결합을 인식하는 도구로 사용될 수 있음을 확인하였다.

터보회전기기 상태진단 시스템의 자동화와 관련 결합의 자동 인식이 중요한 분야로 대두되고 있으며, 이와 관련하여 많은 방법이 제시되고 연구되고 있다. 본 논문에서 제시한 DHMM 방법은 회전체의 결합의 자동 인식에 유용한 도구로 사용될 수 있다고 판단된다.

참고문헌

- (1) 송성진, 2003, “컨디션 모니터링이 최신 가스터빈에 미치는 영향,” 유체기계저널, 제6권, 제1호, pp. 131~136.
- (2) Rabiner, L. R., 1989, “A Tutorial on Hidden Markov Models and Selected Application in Speech Recognition,” Proceedings of the IEEE, Vol. 77, No. 2, pp. 257~286.
- (3) 이종민, 김승종, 황요하, 송창섭, 2003, “AR 계수를 이용한 Hidden Markov Model의 기계 상태진단 적용,” 한국소음진동공학회논문집, 제13권, 제1호, pp. 48~55.
- (4) Wong, J. C., McDonald, K. A. and Palazoglu, A., 2001, “Classification Abnormal Plant Operation using Multiple Process Variable Trends,” Journal of Process Control, Vol. 11, pp. 409~418.
- (5) Kwon, K.-C. and Kim, J.-H., 1999, “Accident Identification in Nuclear Power Plants using Hidden Markov Models,” Engineering Applications of Artificial Intelligence, Vol. 12, pp. 491~501.
- (6) Bunks, C., McCarthy, D. and Al-Ani, T., 2000, “Condition-based Maintenance of Machines using Hidden Markov Models,” Mechanical Systems and Signal Processing, Vol. 14, pp. 597~612.
- (7) Ertunc, H. M., Loparo, K. A. and Ocak, H.,

- 2001, "Tool Wear Condition Monitoring in Drilling Operations using Hidden Markov Models," International Journal of Machine Tools and Manufacture, Vol. 41, pp. 1363~1384.
- (8) Lee, J. M., Kim, S.-J., Hwang, Y. and Song, C.-S., 2003, "Condition Monitoring of Rotor Fault Signal using Hidden Markov Model," The 32nd International Congress and Exposition on Noise Control Engineering, pp. 3138~3145(CD-ROM).
- (9) 이종민, 김승종, 황요하, 송창섭, 2003, "은닉 마르코프 모형을 이용한 회전체 결합신호의 패턴 인식," 대한기계학회논문집 A권, 제 27 권, 제 11 호, pp. 1864~1872.
- (10) Rabiner, L. R. and Jaung, B.-H., 1993, FOUNDAMENTALS OF SPEECH RECOGNITION, Prentice Hall Inc., New Jersey U.S.A., pp. 69~140 & pp. 321~389.
- (11) Gray, R. M., 1984, "Vector Quantization," IEEE ASSP Magazine, pp. 4~28.
- (12) Rao, J. S., 2000, VIBRATORY CONDITION MONITORING OF MACHINES, Narosa Publishing House, New Delhi India, pp. 312~382.
- (13) 정보통신연구회, 2001, 우도의 이해, 교우사, 서울 대한민국, pp. 7~22.