

은닉 마르코프 모형을 이용한 회전체 결함신호의 패턴 인식

이종민[†] · 김승종^{*} · 황요하^{*} · 송창섭^{**}

(2002년 12월 30일 접수, 2003년 9월 19일 심사완료)

Pattern Recognition of Rotor Fault Signal Using Hidden Markov Model

Lee, Jong Min., Kim, Seung-Jong, Hwang, Yoha and Song, Chang-Seop

Key Words : Hidden Markov Model(HMM, 은닉 마르코프 모형), Rotor Fault Signal(회전체 결함신호), Machine Diagnosis(기계 진단), Unbalance(불평형), Oil Whirl(오일 훨)

Abstract

Hidden Markov Model(HMM) has been widely used in speech recognition, however, its use in machine condition monitoring has been very limited despite its good potential. In this paper, HMM is used to recognize rotor fault pattern. First, we set up rotor kit under unbalance and oil whirl conditions. Time signals of two failure conditions were sampled and translated to auto power spectrums. Using filter bank, feature vectors were calculated from these auto power spectrums. Next, continuous HMM and discrete HMM were trained with scaled forward/backward variables and diagonal covariance matrix. Finally, each HMM was applied to all sampled data to prove fault recognition ability. It was found that HMM has good recognition ability despite of small number of training data set in rotor fault pattern recognition.

1. 서 론

은닉 마르코프 모형(Hidden Markov Model, HMM)은 1960년대에 음성인식 분야에서 본격적으로 연구되기 시작하여 1980년대 후반 이후부터 다양한 분야에 적용되고 있다. HMM은 2종의 통계적 과정으로 이루어진 2종 통계모델이기 때문에 통계적으로 보이지 않는 신호를 모델링 할 수 있고, 다양한 수학적 구조를 지니고 있으며, 몇몇 응용 분야에서 매우 뛰어난 결과를 보여주고 있기 때문에 큰 주목을 받고 있는 모델링 기법이다.⁽¹⁾ HMM은 대상 시스템에서 학습패턴을 수집한 후 적절한 학습과정을 통하여 일단 모델을 구하고 나면 안정적이고, 외란에 대하여 강건하고 정확한 판단을 내리고 우수한 예측성능을 지니고 있으며, 알고리듬을 수정하지 않고서도 유사한 시스템에

바로 적용할 수 있고, 학습되지 않은 패턴이 나중에 발견되어도 그 패턴에 대한 모델만 학습시켜 학습된 모델집합에 추가하기만 하면 되는 등의 다양한 장점이 있다. 현재까지 가장 성공적인 응용 분야는 음성인식 분야이며 신호분석 및 패턴인식 분야 등에 사용되고 있으나 아직 기계 상태진단 분야에서는 본격적으로 연구되지 않았으며 적용사례도 미미하다.

HMM은 관측되는 벡터의 관측확률을 표현하는 방법에 따라 이산(Discrete) HMM(DHMM)과 연속(Continuous) HMM(CHMM)으로 분류가 되는데, DHMM은 계산이 빠르며 외란에 강건하게 패턴을 구분해낼 수 있으며, CHMM은 보다 정밀한 값으로 패턴을 구분하면서 우수한 예측기능을 가지고 있다. 기계 상태진단에 HMM을 이용한 연구결과를 살펴보면, Smyth⁽²⁾는 안테나 제어시스템의 이상 진단에 DHMM을 적용하였고, Ying⁽³⁾ 등은 불완전한 측정결과로도 이상진단을 할 수 있는 적응 DHMM 알고리듬을 소개하였으며, Wong⁽⁴⁾ 등은 비등온 연속 교반 탱크 반응기(non-isothermal continuously stirred tank reactor)의 상태진단에 DHMM을 사용하였다. 또한 Bunks⁽⁵⁾ 등은 헬리콥

[†] 책임저자, 회원, 한국과학기술연구원 트라이볼로지 연구센터

E-mail : ljm2293@kist.re.kr

TEL: (02)958-5669 FAX: (02)958-5659

^{*} 회원, 한국과학기술연구원 트라이볼로지연구센터

^{**} 회원, 한양대학교 기계공학부

터 기어박스의 상태진단에 CHMM 을 사용하였고, Ertunc⁽⁶⁾ 등은 드릴링 작업 중 드릴 날의 마모상태 진단에 CHMM 을 사용하였다. 국내에서 수행된 관련연구를 살펴보면 권과 김⁽⁷⁾은 핵발전소에서의 사고가 발생했을 때 초기단계에서 사고형태를 확인하는데 DHMM 을 사용하였으며, 저자들^(8,9,10)은 CHMM 을 이용하여 선반가공시 발생하는 채터현상과 정하중하에서의 저널베어링 마모를 진단, 예측하였다.

저자의 연구에 의하면 일반적으로 기계신호에서는 각 이상상태 특징벡터들의 분산이 매우 적기 때문에 CHMM 을 기계신호에 적용하여 본 결과 확률이 상당히 큰 값으로 나타나게 되고, 또 이러한 특징을 가진 신호를 구분하는데 있어서 어떤 그룹에는 소속된 벡터가 없는 경우가 있어서 그 그룹의 통계적 특성을 구하지 못하는 문제점이 나타났다.^(9,10) 또한 확률을 계획적으로 곱하는 연산에서 계산기의 계산 범위를 벗어나는 경우도 자주 발생하였다.

기계신호에 적용시 발생하는 위와 같은 문제점을 해결하기 위해서 본 논문에서는 일반적인 CHMM 알고리듬을 다음과 같이 수정하였다. 우선 스케일 전진 및 후진 변수(scaled forward/backward variable)를 도입하고, 공분산행렬의 행렬식에 하한값과 대각행렬을 필요시 옵션으로 사용할 수 있도록 하였다. 이와 같이 수정된 방법을 베어링으로 지지된 회전체의 불균형(unbalance) 회전신호와 오일 훨(oil whirl) 회전신호에 적용하여 본 결과 수정 전에는 계산 범위를 벗어나 모델을 구하지 못하였지만, 수정 후에는 쉽게 모델을 구할 수 있을 뿐만 아니라 두 이상 상태를 구분하면서도 우도(likelihood)⁽¹¹⁾의 절대값을 줄일 수 있었으며 소속 벡터가 없어서 통계적 특성을 구할 수 없는 경우가 현저히 줄어들었다. 그렇다 하더라도 아직 우도가 1 보다 크게 나오므로, DHMM 을 동일 신호에 적용하여 그 결과를 비교하여 보았다. DHMM 을 적용한 경우에는 최대 우도가 1 을 넘지 않으면서도 두 이상 상태를 보다 정확하게 구분하였다.

2. HMM 의 이론

CHMM 에 관련된 기본 이론은 문헌 (9)와 (10)에 자세히 기술되어 있으므로 본 논문에서는 수정된 내용만 기술하였으며, DHMM 에 대한 이론을 자세히 기술하였다.

2.1 수정된 CHMM 알고리듬

2.1.1 스케일 전진/후진 변수

문헌 (9)에 기술된 전진변수 및 후진변수의 값들은 확률의 반복적인 합과 곱으로 구하기 때문에 점점 그 크기가 줄어들어 실제 계산에서 계산기의 계산범위를 벗어나는 경우가 자주 발생한다. 이를 해결하기 위하여 스케일 전후진변수⁽¹²⁾를 다음과 같이 구하여 사용하였다.

k 번째 관측벡터열 $O^{(k)} = \{\bar{o}_1^{(k)}, \bar{o}_2^{(k)}, \dots, \bar{o}_{T_k}^{(k)}\}$ 가 CHMM $\lambda_C = (A, \mu, U, \pi)$ 에서 관측될 가능성 $P[O^{(k)}|\lambda_C]$ 를 계산하고, 관측벡터열 집합, $O = \{O^{(1)}, O^{(2)}, \dots, O^{(k)}\}$ 의 CHMM 파라미터 A, μ, U, π 를 추정하는데 필요한 $\alpha_{i,n}^{(k)}$ 와 $\beta_{i,n}^{(k)}$ 는 다음과 같이 구할 수 있다.⁽⁹⁾

$$\alpha_{i,n}^{(k)} = \pi_n \cdot b_{i,n}^{(k)}, \quad 1 \leq n \leq N$$

$$\alpha_{i,n}^{(k)} = \left(\sum_{i=1}^N \alpha_{i-1,i}^{(k)} \cdot a_{i,n}^{(k)} \right) \cdot b_{i,n}^{(k)}, \quad 2 \leq t \leq T_k, \quad 1 \leq n \leq N \quad (1)$$

$$\beta_{T_k,n}^{(k)} = 1, \quad 1 \leq n \leq N$$

$$\beta_{i,n}^{(k)} = \sum_{j=1}^N a_{n,j} \cdot b_{i+1,j}^{(k)} \cdot \beta_{i+1,j}^{(k)}, \quad T_k - 1 \geq t \geq 1, \quad 1 \leq n \leq N \quad (2)$$

여기서, 스케일 계수, $c_t^{(k)}$ 를 다음과 같이 정의하고 사용하면 항상 안정적인 스케일 전진 및 후진 변수($\hat{\alpha}_{i,n}^{(k)}, \hat{\beta}_{i,n}^{(k)}$)를 구할 수 있다.^(1,12)

$$\alpha_{i,n}^{(k)} = \pi_n \cdot b_{i,n}^{(k)}$$

$$c_t^{(k)} = 1 / \sum_{i=1}^N \alpha_{i,i}^{(k)}, \quad 1 \leq n \leq N$$

$$\hat{\alpha}_{i,n}^{(k)} = c_t^{(k)} \cdot \alpha_{i,n}^{(k)} \quad (3)$$

$$\hat{\alpha}_{i,n}^{(k)} = \left(\sum_{i=1}^N \hat{\alpha}_{i-1,i}^{(k)} \cdot a_{i,n}^{(k)} \right) \cdot b_{i,n}^{(k)}$$

$$c_t^{(k)} = 1 / \sum_{i=1}^N \hat{\alpha}_{i,i}^{(k)}, \quad 2 \leq t \leq T_k, \quad 1 \leq n \leq N \quad (4)$$

$$\hat{\alpha}_{i,n}^{(k)} = c_t^{(k)} \cdot \hat{\alpha}_{i,n}^{(k)}$$

$$\beta_{T_k,n}^{(k)} = 1$$

$$\hat{\beta}_{T_k,n}^{(k)} = c_{T_k}^{(k)} \cdot \beta_{T_k,n}^{(k)}, \quad 1 \leq n \leq N \quad (5)$$

$$\hat{\beta}_{i,n}^{(k)} = \sum_{j=1}^N a_{n,j} \cdot b_{i+1,j}^{(k)} \cdot \hat{\beta}_{i+1,j}^{(k)}, \quad T_k - 1 \geq t \geq 1, \quad 1 \leq n \leq N \quad (6)$$

$$\hat{\beta}_{i,n}^{(k)} = c_t^{(k)} \cdot \beta_{i,n}^{(k)}$$

또한, 이 스케일 변수를 사용하여, k 번째 관측벡

터 순열이 학습된 CHMM에서 관측될 확률의 대수(log)값을 식 (7)과 같이 구할 수 있다.

$$\log(P^{(k)}) = \log(\mathbb{P}[O^{(k)} | \lambda_C]) = -\sum_{t=1}^{T_k} \log c_t^{(k)} \quad (7)$$

2.1.2 공분산행렬의 수정

CHMM에서 관측벡터의 관측확률을 구하기 위해서는 평균벡터와 공분산행렬을 사용하여야 하는데, 계산상 공분산행렬의 역행렬이 사용된다. 이 때 공분산행렬의 행렬식이 매우 작을 경우 역행렬을 구할 수 없는 문제가 발생하는데, 이를 방지하기 위하여 식 (8)과 같이 행렬식이 설정된 하한값보다 작을 경우 설정된 하한값을 사용하도록 하였다.

$$\det(U_n) = \begin{cases} U_\epsilon, & \text{if } \det(U_n) \leq U_\epsilon \\ \det(U_n), & \text{if } \det(U_n) > U_\epsilon \end{cases} \quad (8)$$

또한, 계산량을 줄이기 위하여 관측벡터의 각 성분이 서로 독립이라고 가정하면, 공분산행렬은 대각행렬이 될 것이다. 그러므로 공분산행렬을 구하였을 때 대각행렬이 아니더라도

$$U_n = \text{diag}(U_n) \quad (9)$$

와 같이 대각선 성분을 제외한 나머지 요소들을 0으로 치환하여 대각선행렬로 바꾸어 주더라도 CHMM의 판단결과가 크게 변하지 않는다면, 계산량을 크게 줄일 수 있는 효과가 있으므로 많이 사용된다.⁽¹³⁾

2.2 DHMM 알고리듬

2.2.1 DHMM의 정의

각각 T_k 개의 기호(symbol)로 이루어진 관측기호열(observation symbol sequence) K 개로 이루어진 집합이

$$O = \{O^{(1)}, O^{(2)}, \dots, O^{(K)}\} \quad (10)$$

여기서, $O^{(k)} = \{o_1^{(k)}, o_2^{(k)}, \dots, o_{T_k}^{(k)}\}$.

와 같이 주어졌다고 하자. 이때 상태(state)들의 개수를

$$S = \{s_1, s_2, \dots, s_N\} \quad (11)$$

와 같이 N 개로 선택하고, 관측되는 기호, $o_i^{(k)}$ 는

$$V = \{v_1, v_2, \dots, v_M\} \quad (12)$$

와 같이 M 개 중에 하나라고 하면, 식 (10)에서 관측된 기호들에 내재된 통계적 특성을 모델링한 DHMM은

$$\lambda_D = (A, B, \pi) \quad (13)$$

와 같이 표기된다. 여기서, q_t 가 시간 t 에서의 상태라고 하면, 초기상태확률분포 π , 상태천이확률분포 A , 관측기호확률분포 B 는 다음과 같이 정의된다.

$$\pi = [\pi_1, \pi_2, \dots, \pi_N]^\top \quad (14)$$

여기서, $\pi_n = \mathbb{P}[q_1 = s_n] \geq 0, \sum_{n=1}^N \pi_n = 1$.

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{N1} & a_{N2} & \cdots & a_{NN} \end{bmatrix} \quad (15)$$

여기서, $a_{ij} = \mathbb{P}[q_{t+1} = s_j | q_t = s_i] \geq 0, \sum_{j=1}^N \pi_{ij} = 1 (\forall i)$.

$$B = \begin{bmatrix} b_{11} & b_{12} & \cdots & b_{1M} \\ b_{21} & b_{22} & \cdots & b_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ b_{N1} & b_{N2} & \cdots & b_{NM} \end{bmatrix} \quad (16)$$

여기서, $b_{nm} = \mathbb{P}[v_m | s_n] \geq 0, \sum_{j=1}^M \pi_{nj} = 1 (\forall i)$.

한편, 확률 계산량을 줄여주기 위하여 사용되는 전진 및 후진변수는 2.1 절에서 설명한 스케일 전진/후진변수를 사용한다. 단, 식 (3)~(6)에서 사용된 $b_{i,n}^{(k)}$ 대신에

$$\tilde{b}_n(o_i^{(k)}) = \mathbb{P}[o_i^{(k)} | q_i = s_n] \quad (17)$$

를 사용하여야 한다.^(1,12)

2.2.2 DHMM 파라미터의 추정

학습용 관측기호열 집합이 식 (10)과 같이 주어지고 DHMM 이 식 (11)~(13)과 같이 정의되면, DHMM 파라미터들은 다음과 같이 구해진다.

(1) 초기 추정

다음에 설명할 재추정 방법이 극소값 보다는 최소값으로 수렴하도록 돋기 위하여 DHMM 파라미터들을 다음과 같이 초기 추정한다.

- 가) 식 (14), (15)의 조건에 맞게 임으로 π 와 A 를 초기화한다.
- 나) 대수-Viterbi 알고리듬⁽¹²⁾으로 상태열 군집화(state sequence segmentation)를 한다.
- 다) 구간별 k-평균 군집화(segmental k-means clustering) 알고리듬⁽¹²⁾으로 π , A , B 를 추정한다.
- 라) 이전 모델과의 거리측정값이 수렴할 때까지 나)~다) 과정을 반복한다.

(2) 재추정

앞에서 설명한 방법으로 구한 초기 추정값을 초기값으로 한 Baum-Walch 알고리듬^(1,12)을 사용하여 다음과 같이 DHMM 파라미터를 재추정한다.

- 가) 식 (3)~(6)으로 스케일 전진/후진변수를 구하고, 식 (7)로 확률을 구한다.
- 나) 다음 식 (18)~(20)으로 DHMM 파라미터를 재추정한다.

$$\hat{\pi}_n = \frac{\sum_{k=1}^K (\hat{\alpha}_{1,n}^{(k)} \times \hat{\beta}_{1,n}^{(k)} / P^{(k)})}{\sum_{k=1}^K (1/P^{(k)})} \quad (18)$$

$$\hat{a}_{ij} = \frac{\sum_{k=1}^K \sum_{t=1}^{T_k-1} (\hat{\alpha}_{t,i}^{(k)} \times a_{ij} \times \tilde{b}_j(o_{t+1}^{(k)}) \times \hat{\beta}_{t+1,j}^{(k)})}{\sum_{k=1}^K P^{(k)}} \quad (19)$$

$$\hat{b}_{nm} = \frac{\sum_{k=1}^K \sum_{t=1}^{T_k} (\hat{\alpha}_{t,i}^{(k)} \times \hat{\beta}_{t,j}^{(k)} \times \delta_{o_{t+1}^{(k)}, v_m})}{\sum_{k=1}^K P^{(k)}} \quad (20)$$

여기서, $\delta_{i,j} = \begin{cases} 1, & \text{if } i = j \\ 0, & \text{if } i \neq j \end{cases}$

- 다) 재추정된 DHMM에서 학습데이터 관측기호 열 집합이 나올 확률과 이전 DHMM에서의 확률과의 차이가 수렴할 때까지 가), 나) 과정을 반복한다.

2.2.3 기호화 전처리 과정

회전체의 진동신호를 DHMM에 사용하기 위해서는 입력되는 특징벡터들을 전처리 과정인 벡터

양자화(vector quantization, VQ) 기법을 이용하여 기호로 바꿔야 한다. VQ의 학습 및 변환 방법은 다음과 같다.^(12,14)

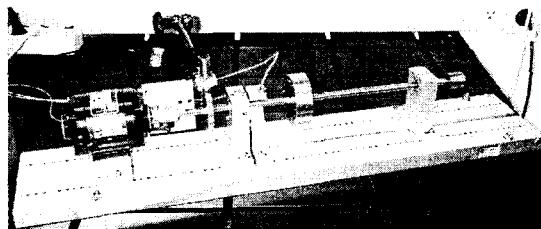
- 가) 벡터공간(vector space)상의 기하학적 거리를 이용하여 학습용 벡터들을 M 개의 집단(group)으로 나눈다.
- 나) 각 집단에 소속된 벡터들의 평균벡터를 구하고 식 (12)에 있는 기호를 차례대로 부여한다. 이를 코드북(code book)이라고 한다.
- 다) 기호로 변환해야 될 벡터가 입력되면, 코드북에 있는 평균벡터 중 입력벡터와 가장 가까운 평균벡터를 찾아서 이 평균벡터에 부여된 기호를 출력한다.

3. 회전체 이상신호

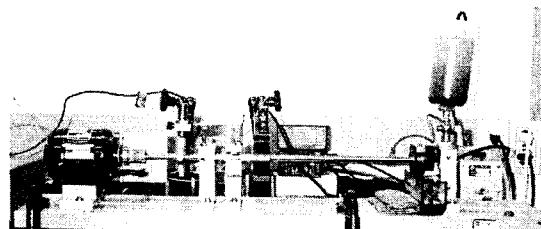
3.1 신호의 측정

회전체의 이상신호를 측정하기 위하여 Fig. 1과 같은 회전체 모의실험장치를 사용하였다. 이 장치는 모터로 구동되며, 모터축에는 회전수를 측정하면서 A/D 변환의 트리거(trigger)신호로 사용하기 위한 12 개 이빨이 있는 기어가 있으며, 모터축과 회전축은 유연 커플링(flexible coupling)으로 연결되어 있다.

회전축 양단에는 회전축을 지지하는 베어링과 하우징을 설치하였으며, 축 가운데에는 하중을 주기 위한 원판을 설치하였다. 모터측에 가까운 베



(a) Unbalance test setup



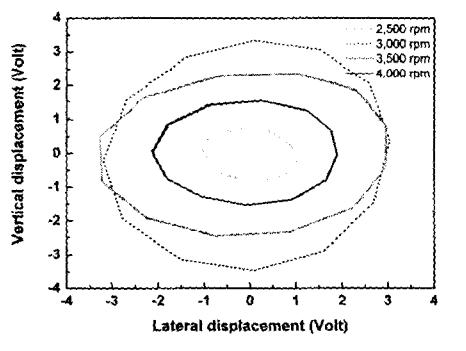
(b) Oil whirl test setup

Fig. 1 Rotor training kit

어링 근처에서 2 개의 변위 센서로 회전축의 수직과 수평 변위를 1 회전 당 12 번 샘플링하여 한번 실험에 2,000 개(약 166.7 회전 동안의)의 데이터를 기록하였다. 회전속도를 2,500 rpm에서 4,000 rpm 까지 500 rpm 씩 증가시키면서 각 rpm 당 내 변색 총 16 번 실험하였다.

3.2 불평형 실험

회전축 양단을 Fig. 1(a)와 같이 저널 베어링으로 지지하고서 가운데 설치된 원판에 불평형 질량을 부가하여 불평형 상태를 구현하였다. 각 회전수별 측정결과를 Fig. 2에서 보여주고 있는데 (a)는 5 회전 동안의 축궤적 선도이며, (b)는 1x 의 크기로 정규화된 수직변위의 자기 파워스펙트럼을 회전수별로 비교하기 위하여 각 실험 당 한 개씩 나타내었다. 1x 의 크기로 정규화한 이유는 회전수에 따른 진폭정보가 상실되는 문제가 발생하지만, 이로 인하여 파워스펙트럼에서 회전수에 따른 특징이 제거됨으로써 회전수를 고려하지 않고서도 이상 상태를 진단할 수 있기 때문이다.



(a) Orbit

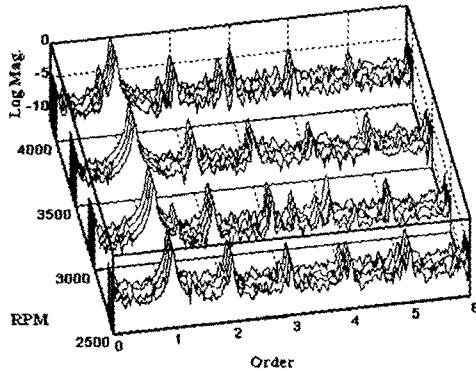
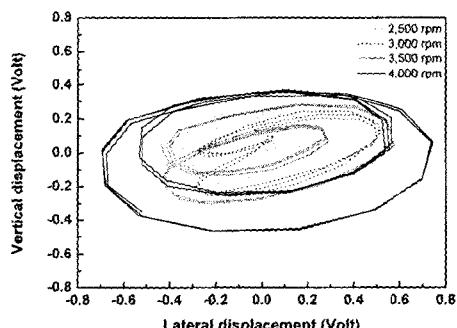
(b) Normalized auto power spectrum
Fig. 2 Unbalance test results

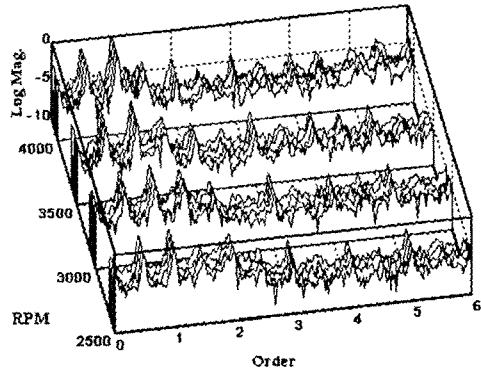
Fig. 2(a)에서 보면 가운데 흐린 점선으로 된 가장 작은 타원이 2,500 rpm 일 때의 축궤적이고 다음 짙은 실선으로 된 타원이 4,000 rpm, 다음 흐린 실선으로 된 타원이 3,500 rpm, 원에 가까운 짙은 점선으로 된 가장 큰 타원이 3,000 rpm 일 때의 축궤적이다. 진동의 크기가 2,500 rpm 일 때 제일 작고, 3,000 rpm 일 때 제일 커졌다가 3,500 rpm 4,000 rpm 으로 증가하면서 점차 작아지므로 공진이 3,000 rpm 근처에 존재함을 알 수 있다. 그러나, Fig. 2(b)에서 보면 1x 에서 피크가 가장 크게 나타나며, 상당히 작은 크기로 2x, 3x, 4x 에서 차례로 피크가 나타나면서 그 크기가 줄어드는 비슷한 경향이 각 회전수에서 동일하므로 불평형 상태에서 진동신호로 간주할 수 있다.⁽¹⁵⁾

3.3 오일 훨 실험

불평형 실험과 같이 실험 구성을 하였으나, 원판에 부가되었던 불평형 질량을 제거하였고, Fig. 1(b)와 같이 모터에서 먼 쪽의 베어링을 저널 베어링에서 유체베어링으로 교환하여 오일 훨 상태



(a) Orbit

(b) Normalized auto power spectrum
Fig. 3 Oil whirl test results

를 구현하였다. Fig. 3에 각 회전수 별 측정 결과를 나타내었는데, (a)는 5회전 동안의 축궤적 선도이며, (b)는 1x의 크기로 정규화된 수직변위 자기 파워스펙트럼을 회전수별로 비교하기 위하여 각 실험 당 한 개씩 나타내었다.

Fig. 3(a)에서 보면 모든 회전수에서 한번 꼬인 타원모양의 축궤적을 그리고 있는데 이는 오일 휠 회전의 특성을 잘 나타내고 있다. 단, 불평형 회전의 경우와 달리 회전수가 커지면서 진동의 크기가 커지는 것을 알 수 있는데 이는 한 쪽 베어링을 유체베어링으로 교체하여 시스템의 특성이 바뀌었기 때문이다. 또한 Fig. 3(b)를 보면 불평형 회전의 경우와 같이 1x에서 가장 큰 피크가 나타나고 있어서 불평형의 영향이 있음을 알 수 있으나 Fig. 2(a)와 Fig. 3(a)를 비교해 보면 진동의 크기가 불평형에 비하여 무시할 수 있는 수준임을 알 수 있다. 이어서 2x, 3x, 4x에서 차례로 작은 피크가 나타나기는 하지만 그 2x, 3x, 4x의 크기가 줄어드는 경향이 다르다. 특히 1/2x에서 피크가 1x의 피크의 크기에 약 1/4 정도의 크기로 발생하고 있으며, 3/2x에서도 작은 피크가 나타나는 특성을 보여주고 있다. 따라서 러빙(rubbing)이 발생한 것을 알 수 있으나, 1/2x의 크기에 비하여 3/2x, 2x, 3x, 4x의 크기가 상대적으로 아주 작기 때문에 러빙이 미약하게 발생했다고 할 수 있다.⁽¹⁵⁾ 또한 자기 파워스펙트럼의 분해능 때문에 1/2x에서 피크가 나타난 것이고 실제로는 0.486x에서 피크가 발생하고 있다. 이는 러빙의 피크 중 하나인 1/2x 성분⁽¹⁵⁾ 보다는 오일 휠 피크인 0.42~0.48x 성분⁽¹⁵⁾에 가깝기 때문에 본 논문에서는 ‘미약한 불평형 및 러빙을 동반한 오일 휠’이라는 표기대신에 단순히 ‘오일 휠’로 표기하였다.

4. HMM을 이용한 회전체 이상진단

4.1 특징 벡터의 추출

총 16개의 데이터 집합 각각은 측정된 2,000개의 수직변위로 선택하였다. 각 데이터 집합을 87.5% 중첩(overlap)되도록 512개씩 나누어 24개의 1x로 정규화된 자기 파워스펙트럼으로 변환하였다. 따라서 각 이상회전에 대하여 384개의 특징벡터를 구하였다. 이때 특징벡터의 크기는 257차로 HMM의 특징벡터로는 사용하기에 너무 크다. 따라서 앞의 3장에서 고찰한 바와 같이 불평형과 오일 휠을 구분할 수 있는 특징을 추출하기 위하여 257차 특징벡터를 통과대역이 0.07x이며

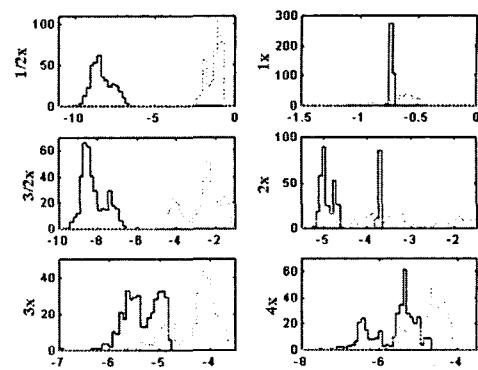


Fig. 4 Histogram of the feature vectors

각 중심오디가 1/2x, 1x, 3/2x, 2x, 3x, 4x인 6개의 대역통과 필터로 이루어진 필터뱅크를 통과시켜 6차 특징벡터로 출력된다. 이 특징벡터들의 각 차수별 분포가 Fig. 4에 나타나 있다. 그림에서 X축은 빈도수이며, Y축은 특징벡터 각 성분의 값을 나타낸다.

Fig. 4에서 짙은 색 실선은 불평형 특징 벡터들의 분포이며, 옅은 색 점선이 오일 휠 특징벡터들의 분포이다. 그림에서는 1/2x, 3/2x, 3x, 4x의 성분을 보면 오일 휠의 경우가 더 큰 값을 가지고 있으며, 1x와 2x의 성분은 불평형의 경우 일정한 값 근처에 집중되어 이는 반면에 오일 휠의 경우에는 비교적 넓게 분포하고 있음을 보여주고 있다. 이를 보면 6차의 특징벡터가 서로 다른 두 이상 회전상태를 뚜렷하게 구분하고 있음을 알 수 있다.

4.2 수정 전 CHMM에 의한 진단

CHMM 파라미터를 재추정하는 Baum-Welch 알고리듬에 필요한 전진/후진 변수를 스케일하지 않고, 공분산행렬도 대각행렬을 사용하지 않고 3,500 rpm 일 때 측정된 4개의 데이터 집합으로 CHMM을 학습시키려고 하였으나 계산기의 계산범위를 넘어서는 경우가 발생하여 CHMM을 구할 수 없었다.

4.3 수정된 CHMM에 의한 진단

스케일된 전진/후진 변수와 대각 공분산행렬을 사용하여, 두 경우 모두 3,500 rpm 일 때 측정된 4개의 데이터 집합으로 CHMM을 학습시켰다. 모델을 구하는데 수정 전 CHMM의 경우와 같이 계산기의 계산범위를 넘는 경우는 발생하지 않았다. 불평형 CHMM은 상태를 3개로, 오일 휠 CHMM은 상태를 2개로 하여 학습시켰다. 3,500 rpm

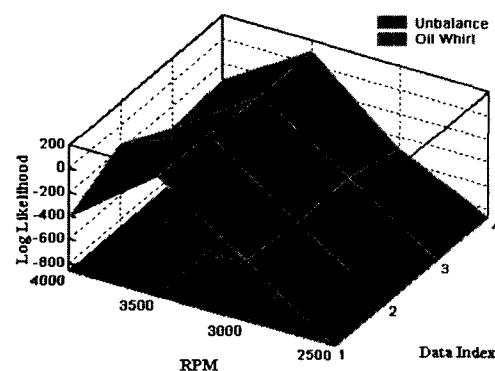
에서 학습된 두개의 모델로 모든 회전수의 데이터 집합을 진단해 본 결과가 Fig. 5에 나타나 있다.

Fig. 5(a)는 16 개의 불평형 회전 데이터 집합을 학습된 두개의 모델로 진단해 본 결과인데, ‘RPM’ 축은 측정할 때의 모터 회전수를 나타내고 ‘Data Index’ 축은 각 회전수에서 측정된 데이터 집합의 차례를 의미하며, “Log Likelihood” 축은 데이터 집합이 CHMM 으로부터 관측될 가능성을 로그우도 (*log likelihood*)로 표시한 것이다. 우도를 로그로 표시한 이유는 스케일 전진변수를 사용할 경우 식 (7)과 같이 우도의 로그값을 구하게 되고 또 우도의 값의 차이가 너무 크므로 작은 값들을 구분하기가 어렵기 때문이다. 그림에서 짙은 색 곡면이 불평형 CHMM 의 로그우도이고, 옅은 색 곡면이 오일 훨 CHMM 의 로그우도이다. 학습된 3,500 rpm 뿐만 아니라 학습시키지 않은 회전수의 경우에도 오일 훨 회전일 가능성이 더욱 크게 나타나 정확하게 판단하였다. 단, 2,500 rpm 과 4,000 rpm 의 경우는 오일 훨일 가능성성이 다른 회전수일 경우보다 상당히 적게 나왔는데, 이는 데이터의 특성이 나쁘기 때문이다.

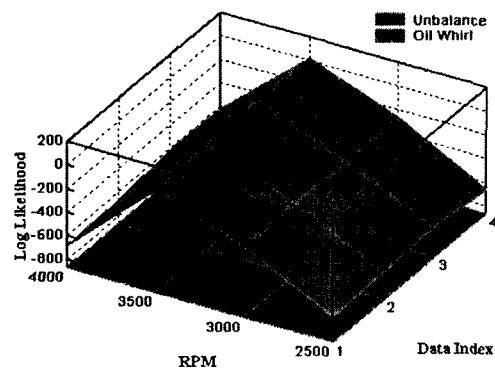
2,500 rpm 의 경우는 불평형도 아니고 오일 훨도 아니라고 판단을 내렸는데 이는 2,500 rpm 불평형 회전의 특성벡터가 Fig. 4에서 보듯 2x 성분이 다른 회전수의 2x 성분과는 통계적 특성이 다르기 때문이다.

Fig. 5(b)는 16 개의 오일 훨 데이터 집합을 두개의 모델로 진단해 본 결과인데, 축은 Fig. 5(a)와 같다. 짙은 색 곡면이 불평형 CHMM 의 로그우도이고, 옅은 색 곡면이 오일 훨 CHMM 의 로그우도이다. 학습된 3,500 rpm 뿐만 아니라 학습시키지 않은 회전수의 경우에도 오일 훨 회전일 가능성이 더욱 크게 나타나 정확하게 판단하였다. 단, 2,500 rpm 과 4,000 rpm 의 경우는 오일 훨일 가능성성이 다른 회전수일 경우보다 상당히 적게 나왔는데, 이는 데이터의 특성이 나쁘기 때문이다.

일반적으로 CHMM 의 학습에 사용되는 데이터 집합보다 매우 적은 데이터 집합으로 학습시킨 것을 감안하면 매우 훌륭한 진단 결과를 보여주고

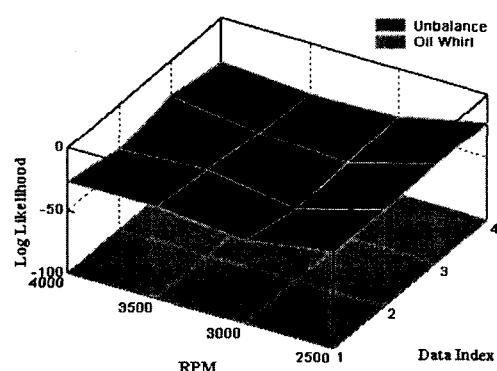


(a) For unbalance data

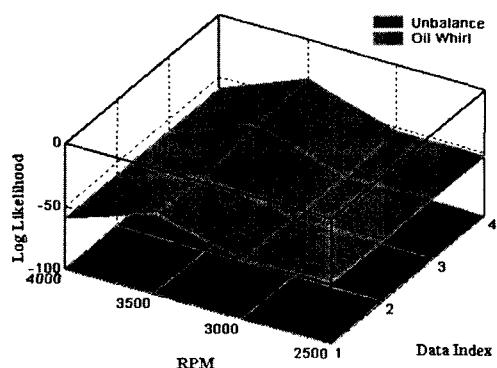


(b) For oil whirl data

Fig. 5 Diagnosis results of modified CHMM



(a) For unbalance data



(b) For oil whirl data

Fig. 6 Diagnosis results of DHMM

있다.

4.4 DHMM에 의한 진단

스케일된 전진/후진 변수를 이용하여 두 경우 모두 3,500 rpm 4 개의 데이터 집합으로 10 개의 기호로 이루어진 VQ 코드북을 구하여 VQ 를 행한 후 두 이상상태에 대한 DHMM 을 구하였다. 불평형 및 오일 훨 DHMM 모두 상태를 3 개로 선택하여 학습시켰다. 학습된 두개의 모델로 모든 회전수의 데이터 집합을 진단해 본 결과가 Fig. 6 에 나타나 있다. 그림에서 축은 Fig. 5 와 같다.

Fig. 6(a)는 16 개의 불평형 데이터 집합을 두개의 모델로 진단해 본 결과이다. 짙은 색 곡면이 불평형 DHMM 의 로그우도이고, 옅은 색 곡면이 오일 훨 DHMM 의 로그우도이다. 학습된 3,500 rpm 뿐만 아니라 학습시키지 않은 회전수인 경우에도 불평형일 가능성에 더욱 크게 나타나 정확하게 판단하였으며 로그우도의 값도 0 을 넘지 않았다.

Fig. 6(b)는 16 개의 오일 훨 데이터 집합을 두개의 모델로 진단해 본 결과이다. 짙은 색 곡면이 불평형 DHMM 의 로그우도이고, 옅은 색 곡면이 오일 훨 DHMM 의 로그우도이다. 불평형의 경우와 마찬가지로 모든 회전수에서 오일 훨일 가능성에 더욱 크게 나타나 정확하게 판단하였으며 로그우도의 값도 0 을 넘지 않았다.

CHMM 의 경우보다 DHMM 이 학습되지 않은 다른 회전수에서의 이상 상태 구분능력이 뛰어 난다. 이는 CHMM 은 학습에 사용된 하나의 이상상태의 데이터를 기준으로 세밀하게 판단하기 때문에 판단하고자 하는 데이터가 약간 차이가 나도 이를 바로 다른 데이터로 판단하여 버리기 때문이다. 그러나 DHMM 은 DHMM 을 학습시키기 전에 학습에 사용될 모든 이상상태의 데이터로 VQ 코드북을 구하기 때문에 세밀한 판단 능력은 떨어지나 판단하고자 하는 데이터가 약간 변화가 있어도 이를 무시하는 좀더 강건한(robust) 특성이 있기 때문이다.

5. 결 론

회전체의 이상신호의 패턴을 구분해 내는데 통계학적인 기법인 HMM 기법을 적용하여 보았다. 우선 CHMM 과 DHMM 의 기계시스템 적용에 따른 문제점을 해결할 수 있도록 기본 이론을 수정하여 적용하였으며, 실험데이터에 적용하여 본 결과 매우 정확하며 하나의 이상상태 모델이 다양한

회전조건에서의 같은 이상상태에서도 잘 적용되었다. 이상의 결과로부터 다음과 같은 결론을 얻었다.

첫째로 스케일된 전방/후방 변수를 사용하여 Baum-Welch 알고리듬을 구현하면 다른 적용분야처럼 회전체 이상신호의 HMM 을 구하는데도 계산기 계산범위를 벗어나는 문제를 해결할 수 있었다. 둘째로 일반적으로 적은 학습 데이터로는 HMM 의 인식 능력이 나쁘다고 알려져 있으나, 실험결과 회전체의 이상 신호를 인식해 내는 능력은 4 개 만의 학습 데이터로 학습시킨 HMM 의 경우에도 훌륭한 인식 능력을 보여주었다. 셋째로 CHMM 은 좀더 세밀하게 인식하는 능력을 가지고 있어서 문헌 (9)와 (10)에서와 같이 기계신호의 이상상태가 점점 발전해 가고 있음을 예측해내는 우수한 능력을 보여주고 있으나 본 논문에서와 같이 기계신호의 약간의 변화에도 민감하게 그 차이를 구분해 내는데 반하여 DHMM 은 약간의 차이가 존재하는 유사한 기계신호에 대하여서도 강건하게 이상상태를 확실하게 구분해주는 능력이 있음을 알 수 있었다.

이상의 연구결과로 HMM 기법이 기계의 이상상태, 특히 회전체의 이상상태를 인식하는 능력이 우수하다는 것을 알 수 있었다. 앞으로 좀 더 많은 데이터를 가지고서 더욱 많은 회전체 이상상태와 학습되지 않는 회전체의 이상상태를 인식 할 수 있는 실용적 HMM 적용에 대한 연구가 있을 예정이다.

참고문헌

- (1) 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.
- (2) Smyth, P., 1994, "Hidden Markov Models for Fault Detection in Dynamic Systems," *Pattern Recognition*, Vol. 27, No. 1, pp. 149~164.
- (3) Ying, J., Kirubarajan, T., Pattipati, K. R. and Pattersonhine, A., 2000, "A Hidden Markov Model-Based Algorithm for Fault Diagnosis with Partial and Imperfect Tests," *IEEE Transactions on Systems, Man, and Cybernetics – Part C: Applications and Reviews*, Vol. 30, No. 4, pp. 463~473.
- (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) 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.
- (6) 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 & Manufacture*, Vol. 41, pp. 1363~1384.
- (7) 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.
- (8) Lee, J. M. and Hwang, Y., 2000, "Diagnosis of Machine Signal Using Hidden Markov Model," *Proceeding of KSME Dynamic & Control Division*, KSME 00DC052, pp. 130~236.
- (9) Lee, J. M., Kim, S.-J., and Hwang, Y., 2002, "Mechanical Signal Analysis Using Hidden Markov Model," *9th International Congress on Sound and Vibration*, Orlando, USA.
- (10) Lee, J. M., Hwang, Y., Kim, S.-J. and Song, C.-S., 2003, "Application of Hidden Markov Model Using AR Coefficients to Machine Diagnosis," *Transactions of the KSNVE*, Vol. 13, No. 1, pp. 48~55.
- (11) Kim, J. H., Shim, K. B. et al., 2001, *COMPREHENSION OF LOG-LIKELIHOOD*, Kyo Woo Sa, Chapter 2, pp.7~22.
- (12) Rabiner, L. R. and Jaung, B.-H., 1993, *FUNDAMENTALS OF SPEECH RECOGNITION*, Prentice Hall Inc., Chapter 3 and 6, pp. 69~140 & 321~389.
- (13) Gales, M. J. G., 1999, "Semi-Tied Covariance Matrices for Hidden Markov Models," *IEEE Transactions on Speech and Audio Processing*, Vol. 7, No. 3, pp. 272~281.
- (14) Gray, R. M., 1984, "Vector Quantization," *IEEE ASSP Magazine*, pp. 4~28.
- (15) Rao, J. S., 2000, *VIBRATORY CONDITION MONITORING OF MACHINES*, Narosa Publishing House, Chapter 9, pp. 312~382.