

AR계수를 이용한 Hidden Markov Model의 기계상태진단 적용

Application of Hidden Markov Model Using AR Coefficients
to Machine Diagnosis

이 종 민† · 황 요 하* · 김 승 종* · 송 창 섭**

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

(2002년 8월 7일 접수 : 2003년 1월 7일 심사완료)

Key Words : Hidden Markov Model(HMM, 히든 마르코브 모델), Autoregressive Model(AR모델, 자기회기모델), Diagnosis(상태진단), Chatter(채터), Wear(마모)

ABSTRACT

Hidden Markov Model(HMM) has a doubly embedded stochastic process with an underlying stochastic process that can be observed through another set of stochastic processes. This structure of HMM is useful for modeling vector sequence that doesn't look like a stochastic process but has a hidden stochastic process. So, HMM approach has become popular in various areas in last decade. The increasing popularity of HMM is based on two facts: rich mathematical structure and proven accuracy on critical application. In this paper, we applied continuous HMM(CHMM) approach with AR coefficient to detect and predict the chatter of lathe bite and to diagnose the wear of oil journal bearing using rotor shaft displacement. Our examples show that CHMM approach is very efficient method for machine health monitoring and prediction

기호설명

$\hat{\cdot}$	추정치	N	상태의 수
{ }	집합	O	관측벡터열 집합
A	상태천이확률분포 행렬($N \times N$ 차)	$O^{(k)}$	k 번째 관측벡터열
a_{ij}	상태 s_i 에서 상태 s_j 로 천이할 확률	$\bar{o}_t^{(k)}$	$O^{(k)}$ 시간 t 에서의 관측벡터(D 차)
$b_{i,n}^{(k)}$	관측벡터 $\bar{o}_t^{(k)}$ 가 상태 s_n 에서 관측될 확률	$P[\cdot]$	확률
D	관측벡터의 차원 또는 AR 모델의 차수	$P^{(k)}$	$O^{(k)}$ 가 CHMM λ 에서 관측될 확률
\bar{E}	AR 모델 오차 벡터(H 차)	q_t	시간 t 에서의 상태
e_t	시간 t 에서 y_t 와 AR 모델 추정치와의 오차	S	상태집합
K	O 에 속한 관측벡터열의 개수	s_n	n 번째 상태
<hr/>		T	전치행렬
<hr/>		T_k	$O^{(k)}$ 의 벡터 개수
<hr/>		t	현재 시간
<hr/>		U	공분산행렬 집합
<hr/>		U_n	상태 s_n 에서의 공분산 행렬($D \times D$ 차)
<hr/>		X	AR 모델 입력 행렬($H \times D$ 차)
<hr/>		\bar{Y}	AR 모델 출력 벡터(H 차)
<hr/>		y_t	시간 t 에서 대상 시스템 출력

- $\alpha_{t,n}^{(k)}$: $O^{(k)}$, 시간 t , 상태 s_n 에서의 전진변수
 $\beta_{t,n}^{(k)}$: $O^{(k)}$, 시간 t , 상태 s_n 에서의 후진변수
 λ : CHMM
 μ : 평균벡터 집합
 $\vec{\mu}_n$: 상태 s_n 에서의 평균 벡터(D 차)
 $\vec{\pi}$: 초기상태확률분포 벡터(N 차)
 π_n : 초기상태 q_1 이 상태 s_n 일 확률
 $\vec{\phi}$: AR 모델 계수 벡터(D 차)
 ϕ_d : d 차 AR모델 계수

1. 서 론

HMM은 1960년대에 음성인식 분야에서 연구되기 시작하여 1980년대 후반 이후 다양한 분야에 적용되기 시작하였다. HMM이 각광을 받는 이유로는 2종의 통계적 과정으로 이루어진 통계모델이기 때문에 다양한 수학적 구조를 지니고 있으며, 몇몇 응용분야에서 매우 뛰어난 결과를 보여주었기 때문이다.⁽¹⁾ 현재까지 가장 뛰어난 응용분야는 음성인식 분야이며, 신호 분석 및 예측, 패턴인식 등에 사용되고 있으나 아직 기계 상태진단 분야에는 본격적으로 연구되지 않았으며 적용사례도 미미하다.

기계 상태진단에는 전문가시스템이나 신경회로망, 퍼지(fuzzy)추론 등을 이용하고 있다. 전문가시스템은 전문가가 복잡한 알고리즘을 대상 시스템에 알맞게 수정하여야 하는 단점이 있으며, 퍼지추론 진단시스템은 대상 시스템에 잘 부합되는 멤버쉽(membership) 함수를 선정해야만 하는 것이 관건이다. 또한, 신경회로망 진단시스템은 대상 시스템마다 학습패턴을 구하여 학습을 시켜야 한다는 단점이 있다. 그러나 HMM을 이용하면, 대상 시스템에서 학습패턴을 구하여야 하기는 하지만 일단 학습이 되면 알고리즘을 수정하지 않고서도 유사 시스템에 바로 적용할 수 있으며 학습되지 않은 이상신호가 나중에 발견된다면 그에 대한 모델만 학습시켜 추가하기만 하면 된다는 장점이 있다. 또한 통계과정을 통하여 판단하는 것이므로 적절하게 학습된다면 아주 정확한 판단을 내리며, 훌륭한 예측 성능이 있으므로 상태진단을 하기위한 우수한 방법이 될 것이다.

기계 상태진단에 HMM을 이용한 연구결과를 살펴

보면, Smyth는 안테나 제어시스템의 이상진단에 HMM을 적용하였고,⁽²⁾ Ying 등은 불완전한 측정결과로도 이상진단을 할 수 있는 적응 HMM 알고리즘을 소개했다.⁽³⁾ 국내에서는 본 논문의 저자들이 처음으로 HMM을 이용하여 선반가공시 발생하는 채터현상을 진단, 예측하여 보았다.⁽⁴⁾

본 논문에서는 AR 계수를 특징벡터로 하는 연속(continuous) HMM(CHMM)을 선반가공시 발생하는 채터 신호 진단에 적용하여 채터진단, 예측기능을 검토한 후, 회전체에서 회전축 진동신호로 저널베어링(journal bearing)의 유후유 오염도 진단에 적용하여 우수한 결과를 얻었다. 따라서 기계 상태진단에 CHMM 기법의 적용 가능성을 제시했다.

2. CHMM 및 AR 이론

본 논문에서는 HMM과 관련된 일반적인 이론 및 여러 방법을 본 논문에서 사용된 CHMM에 맞추어 순차적으로 재구성하였다.

2.1 CHMM의 정의^(1,5)

D 차원 벡터들이 각각 T_k 개로 이루어진 관측벡터열(observation vector sequence)들 K 개가

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

$$\text{여기서, } O^{(k)} = \left\{ \bar{o}_1^{(k)} \quad \bar{o}_2^{(k)} \quad \dots \quad \bar{o}_{T_k}^{(k)} \right\}$$

와 같이 주어지면, 이의 벡터들의 통계적 특성을 모델링(modeling)한 CHMM을 구하기 위하여 우선 상태(state)를

$$S = \{ s_1 \quad s_2 \quad \dots \quad s_N \} \quad (2)$$

와 같이 N 개로 선택한다. 그러면 CHMM은

$$\lambda = (\vec{\pi}, A, \mu, U) \quad (3)$$

와 같이 표기되는데 CHMM의 파라미터(parameter)들은 q_t 가 시간 t 에서의 상태, $P[\cdot]$ 를 확률이라고 하면, 다음과 같이 정의된다.

초기상태확률분포 π 와 상태천이확률분포 A 는

$$\pi = [\pi_1 \ \pi_2 \ \cdots \ \pi_N]^T \quad (4)$$

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

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{N1} & a_{N2} & \cdots & a_{NN} \end{bmatrix} \quad (5)$$

여기서, $a_{ij} = P[q_{t+1} = s_j | q_t = s_i] \geq 0$,

$$1 \leq i \leq N, \quad 1 \leq j \leq N,$$

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

와 같고 평균 μ 와 공분산 U 는

$$\mu = \{\bar{\mu}_1 \ \bar{\mu}_2 \ \cdots \ \bar{\mu}_N\} \quad (6)$$

여기서, $\bar{\mu}_n$ 은 상태 s_n 에서의 D 차원 평균벡터

$$U = \{U_1 \ U_2 \ \cdots \ U_N\} \quad (7)$$

여기서, U_n 은 상태 s_n 에서의 $D \times D$ 차원 공분산행렬

와 같다. 위와 같이 CHMM이 정의 되면, k 번째 관측벡터열 $O^{(k)}$ 의 t 번째 관측벡터 $\vec{o}_t^{(k)}$ 가 상태 s_n 에서 관측될 관측벡터 확률밀도함수를 Gaussian 밀도함수라고 하면 다음과 같다.

$$b_{t,n}^{(k)} = \frac{\exp\left(-\frac{(\vec{o}_t^{(k)} - \bar{\mu}_n)^T \cdot U_n^{-1} \cdot (\vec{o}_t^{(k)} - \bar{\mu}_n)}{2}\right)}{\sqrt{(2 \times 3.141592)^2 \times |U_n|}} \quad (8)$$

한편, 확률 계산량을 줄여주기 위하여 전진변수(forward variable)와 후진변수(backward variable)를 사용하는데, 전진변수^(1,5,6)를

$$\alpha_{t,n}^{(k)} = P[\vec{o}_1^{(k)} \ \vec{o}_2^{(k)} \ \cdots \ \vec{o}_t^{(k)}, q_t = s_n | \lambda] \quad (9)$$

와 같이 정의하면 식 (10), (11)로 구해진다.

$$\alpha_{1,n}^{(k)} = \pi_n \times b_{1,n}^{(k)}, \quad 1 \leq n \leq N \quad (10)$$

$$\alpha_{t,n}^{(k)} = \left(\sum_{i=1}^N \alpha_{t-1,i}^{(k)} \times a_{in} \right) \times b_{t,n}^{(k)}, \quad t = 2, 3, \dots, T_k, \quad 1 \leq n \leq N \quad (11)$$

그리면, CHMM에서 관측벡터열 $O^{(k)}$ 이 관측될 확률 $P^{(k)}$ 와 관측벡터열 집합이 관측될 확률(기대치)은

$$P[\mathbf{O} | \lambda] = \prod_{k=1}^K P^{(k)} = \prod_{k=1}^K \left(\sum_{n=1}^N \alpha_{T_k,n}^{(k)} \right) \quad (12)$$

와 같다. 또한, 후진변수^(1,5,6)를

$$\beta_{t,n}^{(k)} = P[\vec{o}_{t+1}^{(k)} \ \vec{o}_{t+2}^{(k)} \ \cdots \ \vec{o}_{T_k}^{(k)} | q_t = s_n, \lambda] \quad (13)$$

와 같이 정의하면, 식 (14), (15)로 구해진다.

$$\beta_{T_k,n}^{(k)} = 1, \quad 1 \leq n \leq N \quad (14)$$

$$\beta_{t,n}^{(k)} = \sum_{j=1}^N (a_{nj} \times b_{t+1,j}^{(k)} \times \beta_{t+1,j}^{(k)}), \quad t = T_k - 1, T_k - 2, \dots, 1, \quad 1 \leq n \leq N \quad (15)$$

2.2 CHMM의 파라미터의 추정(estimation)

학습용 관측벡터열들이 주어지고 CHMM이 2.1절과 같이 정의되면, CHMM의 파라미터들을 다음과 같이 구할 수 있다.

(1) 초기 추정(initial estimation)

2.2(2)에서 설명 할 재추정(reestimation) 방법이 극소값(local minimum) 보다는 최소값(global minimum)으로 수렴하도록 돋기 위하여 CHMM의 파라미터들을 다음과 같이 초기추정을 한다.

① 식 (4, 5)의 조건에 맞게 임으로 초기상태확률 분포와 상태천이확률분포를 초기화. 평균과 공분산은 관측벡터들 중 서로 가장 멀리 떨어진 N 개의 벡터로 관측벡터를 군집화(clustering)하고 각 군집(cluster)들의 평균과 공분산으로 초기화.¹⁾

② 로그(log)-Viterbi 알고리즘^(5,6)으로 상태열(state sequence) 세분화(segmentation)하고 나서, 구간별 k 평균 군집화(segmental k -means clustering) 알고리즘^(5,6)으로 CHMM 파라미터 추정.

③ 이전 모델과의 거리측정(distance measure)⁽⁶⁾

값이 수렴할 때까지 ②~③을 반복.

본 논문에서는 초기값을 선정하는 ①의 과정에서 평균과 공분산을 임으로 선정하지 않고 최대거리 군집화(maximum distance clustering) 방법⁽⁴⁾을 제안하였는데, 이는 구간별 k 평균 군집화 방법의 수렴속도를 빠르게 한다.

(2) 재추정

위에서 설명한 초기 추정값을 초기값으로 한 Baum-Walch 알고리즘^(1, 5, 6)을 사용하여 다음과 같이 CHMM의 파라미터를 재추정⁽⁷⁾ 한다.

① 식 (8)을 사용하여 관측벡터 확률밀도함수를 구한 다음, 식 (10), (11)로는 전진변수를, 식 (14), (15)로는 후진변수를, 식 (12)로는 확률을 계산한다.

② 위에서 구한 전진변수와 후진변수, 확률을 이용하여 다음 식 (16)~(19)로 CHMM 파라미터를 재추정⁽⁷⁾ 한다.

$$\hat{\pi}_n = \frac{\sum_{k=1}^K \alpha_{1,n}^{(k)} \times \beta_{1,n}^{(k)}}{P^{(k)}} \quad (16)$$

$$\hat{a}_{ij} = \frac{\sum_{k=1}^K \sum_{t=1}^{T_i-1} \alpha_{t,i}^{(k)} \cdot a_{ij} \cdot b_{t+1,j}^{(k)} \cdot \beta_{t+1,t}^{(k)}}{\sum_{k=1}^K \sum_{t=1}^{T_i-1} \alpha_{t,i}^{(k)} \cdot \beta_{t+1,t}^{(k)}} \quad (17)$$

$$\hat{\mu}_n = \frac{\sum_{k=1}^K \sum_{t=1}^{T_i} \alpha_{t,n}^{(k)} \cdot \beta_{t,n}^{(k)} \cdot \bar{o}_t^{(k)}}{\sum_{k=1}^K \sum_{t=1}^{T_i} \alpha_{t,n}^{(k)} \cdot \beta_{t,n}^{(k)}} \quad (18)$$

$$\hat{U}_n = \frac{\sum_{k=1}^K \sum_{t=1}^{T_i} \alpha_{t,n}^{(k)} \cdot \beta_{t,n}^{(k)} \cdot (\bar{o}_t^{(k)} - \bar{\mu}_n)^2}{\sum_{k=1}^K \sum_{t=1}^{T_i} \alpha_{t,n}^{(k)} \cdot \beta_{t,n}^{(k)}} \quad (19)$$

③ 재추정된 CHMM에서 학습데이터 관측벡터열이 나올 확률과 이전 CHMM에서의 확률과의 차이가 수렴할 때까지 ①~③을 반복한다.

2.3 CHMM을 이용한 진단

앞에서 설명한 방법으로 학습시킨 각 고장원인에 관한 CHMM들이 있다면, 진단하고자 하는 관측벡터

열 $O^{(k)}$ 가 어떤 고장원인으로 인하여 발생했는지 진단할 수 있다. 식 (12)를 사용하여 각 CHMM에 대한 $O^{(k)}$ 의 $P^{(k)}$ 를 구하여 가장 큰 $P^{(k)}$ 값을 가지는 CHMM이 관측벡터열 $O^{(k)}$ 의 고장원인이 된다.

2.4 자기회기(autoregressive, AR) 모델⁽⁸⁾

이상진단 대상시스템에서 센서(sensor)로 측정되는 시계열(time series) 데이터(data)를 HMM에 이용하기 위해서는 대상 시스템의 특성을 잘 표현하는 특징 벡터로 변환하는 전처리 과정이 필요하다. 예를 들어 음성의 특성은 음성신호의 켈스트럼(cepstrum)⁽⁹⁾이 가장 잘 표현하고 있기 때문에 음성인식에 사용되는 HMM의 특징벡터로는 켈스트럼 계수를 사용하고 있다. 본 논문에서는 시계열의 특성을 잘 표현하는 AR 모델의 계수를 사용하였다.

AR 모델은 대상시스템의 현재 출력은 과거 출력의 선형 합과 오차 e 로 표현된다고 가정하여 그 출력특성을 모델링 하는 것으로, D 차 AR모델의 경우

$$y_t = \sum_{d=1}^D \phi_d \cdot y_{t-d} + e_t \quad (20)$$

와 같이 표현되며, 이를 t 부터 $t-D+H-1$ 시간까지의 시계열 데이터에 적용하면 H 개의 방정식이 세워지고 이를 행렬 방정식으로 표현하면,

$$\vec{Y} = X \cdot \vec{\phi} + \vec{E} \quad (21)$$

$$\text{여기서, } \vec{Y} = [y_t \ y_{t+1} \cdots \ y_{t+H-1}]^T,$$

$$X = \begin{bmatrix} y_{t-1} & y_{t-2} & \cdots & y_{t-D} \\ y_t & y_{t-1} & \cdots & y_{t-D+1} \\ \vdots & \vdots & \ddots & \vdots \\ y_{t+H-2} & y_{t+H-3} & \cdots & y_{t-D+H-1} \end{bmatrix},$$

$$\vec{\phi} = [\phi_1 \ \phi_2 \cdots \ \phi_D]^T,$$

$$\vec{E} = [e_t \ e_{t+1} \cdots \ e_{t+H-1}]^T$$

와 같이 된다. 식 (21)에서 오차벡터 \vec{E} 를 최소로 하는 AR모델계수 $\vec{\phi}$ 를 최소제곱법(least square method)으로 구하면 다음과 같다.

$$\hat{\vec{\phi}} = (X^T \cdot X)^{-1} \cdot X^T \cdot \vec{Y} \quad (22)$$

3. 채터 현상의 진단 및 예측⁽⁴⁾

3.1 채터 신호의 CHMM

선반의 절삭가공시 발생하는 채터 현상을 진단하고자 선반 공구대에서 정상 가공부터 채터가 완전히 발생한 구간까지의 가속도 신호를 Fig. 1의 위 그림과 같이 118,879개 수집하여, 10,000개씩 나누어 각각을 하나의 시계열로 하였다.

CHMM의 입력이 되는 특징벡터는 10,000개의 데이터를 300개씩 중첩하여 600개씩 나누어 32개의 데이터 집합으로 구분한 다음 각 데이터집합은 7차 AR 모델로 모델링하여 그 계수를 특징벡터로 삼았다. 즉, 10,000개의 시계열 데이터를 32개의 7차 벡터열로 만들어 3개의 상태를 가지는 CHMM의 입력으로 사용하였다. 본 실험에 사용된 데이터는 95% F-기준(criterion)⁽⁸⁾에 의하면 32차 AR 모델이 적절한 모델이지만, CHMM의 수렴에는 4~9차 벡터가 적절하며 CHMM의 상태 수나 AR모델의 차수를 변경해가며 학습 및 진단을 해본 결과 상태 3개, 7차로 AR 모델의 경우가 CHMM학습이나 진단에 최적으로 판단되었다. 이는 CHMM 방법을 사용하는 목적이 원래신호와 똑 같은 신호를 찾아내는 것이 아니고 원래신호의 특징을 모델링하여 비슷한 특징을 가지는 신호를 찾아내는 것이기 때문이다.

학습은 우선 정상가공중인 정상단계(20,001~40,000번째 데이터, λ_1), 정상단계와 천이단계가 섞여있는 혼합단계(48,001~68,000번째 데이터, λ_2), 채터로 바뀌는 천이단계(60,001~80,000번째 데이터, λ_3), 채터가 완전히 발생한 채터단계(98,878~118,879번째 데이터, λ_4)로 구분하여 각 과정에서 각각 10,000개의 데이터로 이루어진 10개의 데이터 집합을 선택하여 이를 학습데이터로 하여 4개의 CHMM을 구하였다.

3.2 채터 신호의 CHMM 진단

위에서 구한 4개의 CHMM으로 전체 측정데이터를 진단한 결과가 Fig. 1의 아래 그림에 나타나있다. 그림에서 보면, 점선이 정상단계(λ_1)의 기대치를 나타내는 선이고, 일점쇄선은 혼합단계(λ_2), 실선은 천이단계(λ_3), 파선이 채터단계(λ_4)일 기대치($P^{(k)}$)를 나타내는 선이다.

가속도 데이터에서는 정상단계로 보이는 약 50,000번째 데이터에서부터 혼합단계의 기대치가 증가를 하여 서서히 진동의 크기가 증가하고 있는 약 60,000번째 데이터에 이르러서는 혼합단계의 기대치가 최고치에 이르러 경고를 나타내고 있음으로써 원래의 데이터로서는 감지하기 어려운 상황에서도 정확하게 채터를 조기에 감지해 내는 예측기능도 가지고 있으며, 천이단계와 채터단계를 정확하게 구분해내는 우수한 결과를 가져왔다

4. 베어링 마모의 진단

4.1 베어링 마모 시험 장치

저널베어링의 마모를 측정하기 위하여 Fig. 2와 같이 실험장치를 구성하였다.⁽¹⁰⁾ 회전축을 2개의 저널베어링으로 양단이 지지되어 있으며, 모터로 구동된다. 회전축에 인위적으로 정하중 부하를 가하기 위하여 두 저널베어링 사이에 공압 실린더를 사용하여 하부는 지지되지 않고 회전만 하지 못하도록 설계된 저널베어링하우징을 위에서 아래로 밀면서 로드셀로 그 미는 힘을 측정하는 정하중부과장치를 설치하였다.

3개의 저널베어링에는 각각 윤활유가 순환되도록 하였고, 광센서를 이용하여 윤활유 내의 오일 입자로 베어링의 마모량을 1분에 한번씩 실시간으로 측정하는 마모측정센서⁽¹¹⁾를 각 윤활유 순환관로에 설치하였다. 또한, 진동신호는 변위측정기를 각 베어링 하우징(housing) 옆에 설치하여 축변위를 1분마다 10초간 1 kHz로 측정하였다.

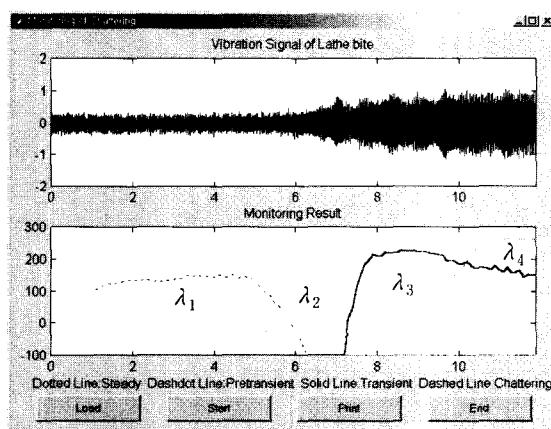


Fig. 1 Tool-post acc. and diagnosis of chatter

4.2 정하중 마모 시험

저널베어링의 마모를 측정하기 위하여 Fig. 2의 베어링 마모 시험장치를 5kg_f의 정하중하에서 1,900 rpm으로 정속 회전시키다가 23분부터 정하중을 10 kg_f로 증가시켰다. 총 시험시간은 5시간이었다.

Fig. 3의 위 그림은 이때 마모지수(wear index⁽¹¹⁾)의 변화를 보여주며, 아래 그림은 정하중이 주어지는 가운데 저널베어링의 근처에서 측정한 회전축 수직면 위 평균값의 변화이다. 정하중이 10 kg_f로 증가하자 축면위는 0.06 mm 정도 더 커지고, 시간이 지나면서 서서히 치짐량이 증가하고 있다. 그러나 마모지수는 처음 약간의 변화만 보이다가 약 50분이 지난 다음부터는 급격히 증가하고, 1시간 30분 후부터는 2시간 동안 완만하게 증가하다가 이후 마모량이 포화되어 마모지수가 일정하게 되었다.

본 논문에서는 Fig. 3에서와 같이 초기 마모구간(30분~1시, 진한 점선구간, λ1)과 마모량 증가구간(2시~2시 30분, 흐린 점선구간, λ2), 두 구간으로 나누었다. 우선 두 구간의 상하방향 축 진동신호를 주파수 분석하여 보았다.

Fig. 4는 초기마모구간의 진동신호와 그 스펙트럼(spectrum)이고 Fig. 5는 마모증가 구간의 스펙트럼이다. 두 그림을 비교하여 보면 진동신호는 육안으로

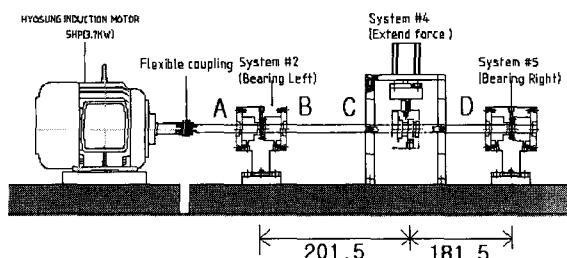


Fig. 2 Structure of bearing wear test rig

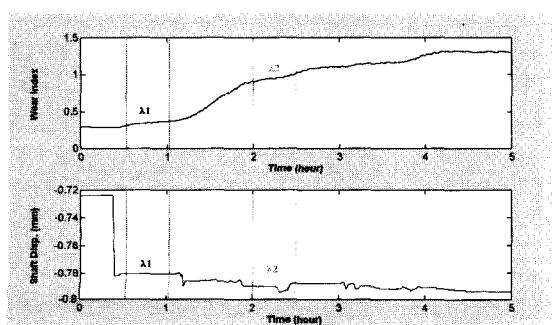


Fig. 3 Wear index and shaft displacement

구분할 수 없을 만큼 똑같고, 스펙트럼 역시 회전수의 조화(harmonic) 주파수에서의 형태가 매우 유사하고 단지 부조화(sub-harmonic) 주파수에서 값들이 마모증가구간에서 좀더 커졌다는 차이를 보여주고 있다. 따라서 주파수 분석만으로 진동신호로부터 마모의 진행을 판단해 내는 데에는 어려움이 있다. 이는 과도한 정하중에 의하여 축과 베어링 사이의 마찰이 발생하고 이로 인하여 윤활유내 마모입자가 증가하여 마모지수는 증가하여 포화에 다다르나 축과 베어링 사이의 마찰로 인한 진동신호에는 큰 영향이 없기 때문이다.

4.3 CHMM을 이용한 마모진단

우선 CHMM을 위한 전처리 과정으로, 1분당 10,000개의 진동신호를 각각 960개씩 나누어 10개의 데이터 집합으로 구분한 다음, 각 데이터 집합을 5차

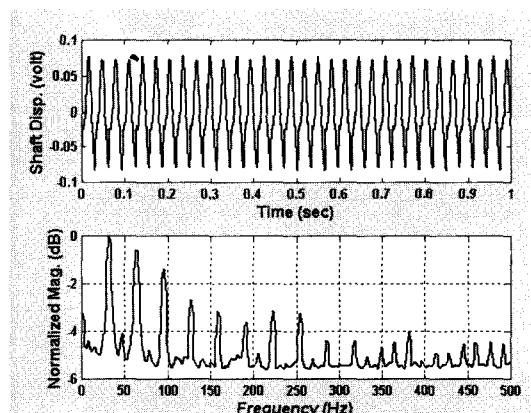


Fig. 4 Time series and spectrum of $\lambda 1$

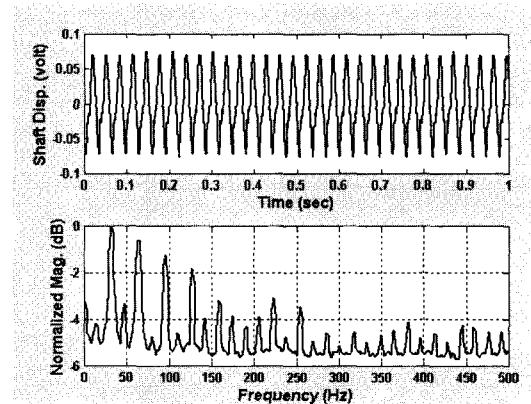


Fig. 5 Time series and spectrum of $\lambda 2$

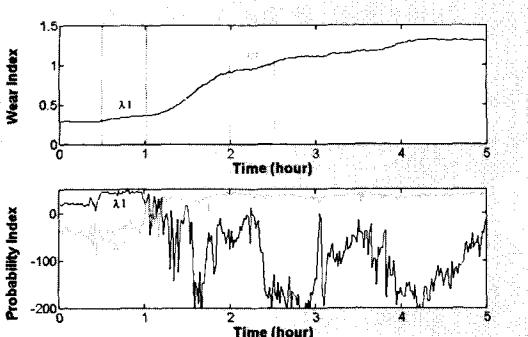


Fig. 6 Wear detection using CHMM

AR 모델로 모델링하여 그 계수를 특징벡터로 삼았다. 즉, 1분당 10,000개의 시계열 데이터를 1분당 10개의 5차 벡터열로 변환하였다. 이중에서 초기마모구간에 해당하는 31개의 벡터열을 학습데이터로 하는 초기마모 CHMM, λ_1 을 구하였고, 마모증가구간의 31개 벡터열로 마모증가 CHMM, λ_2 를 구하였다. 이렇게 구한 λ_1 , λ_2 를 가지고서 5시간 동안의 전 데이터에 대하여 마모상태를 판단한 결과가 Fig. 6에 나타나 있다.

Fig. 6에서 위 그림은 시간에 따른 마모지수의 변화를 보여준다. 아래 그림은 2개의 CHMM으로 대상 시스템의 마모상태를 판단한 그림이다. 절은 실선이 초기마모 CHMM일 기대치를 나타내고 있으며, 흐린 실선이 마모증가 CHMM일 기대치를 나타내고 있다. 정하중이 증가하기 전에는 초기마모 CHMM일 기대치가 상대적으로 높으며, 정하중이 증가하면서 초기 마모 CHMM일 기대치는 높아졌으나 마모증가 CHMM일 가능성의 변화는 없었다. 그러나 하중이 증가한 후 30분 정도 지나면서 마모지수가 증가하기 전부터 초기마모 CHMM일 기대치는 저하되기 시작하고, 마모증가 CHMM일 기대치가 급증하기 시작했다. 이는 예측기능이 이 문제에서도 잘 작동되고 있음을 보여준다. 이후로는 마모량이 증가하고 있다는 것을 진동신호로 정확하게 판단하고 있다. 따라서 CHMM이 기계상태진단 및 예측에 성공적으로 적용될 수 있다는 것을 알 수 있다.

5. 결 론

기계의 상태진단에 통계적 기법인 CHMM을 적용하여 그 가능성 및 예측기능을 확인하였다. 사용된

방법은 대상 시스템으로부터 측정된 시계열 데이터의 AR 모델 계수를 특징벡터로 하여 CHMM을 학습시켜, 학습된 CHMM으로 대상 시스템의 출력이 어느 CHMM에 더 가까운지를 계산하여 대상 시스템의 상태를 진단하는 것이다.

본 논문에서는 이 기법을 선반의 절삭 가공시 발생하는 채터 신호에 적용하여 예측 및 진단 기능을 확인하였고, 저널베어링으로 지지되는 회전체 시스템에 적용하여 진동신호로 마모상태를 판단하고 예측하는 우수한 성능을 입증하였다. 따라서 본 논문에서 제시한 방법을 온라인(online) 기계상태진단/예측 시스템에 적용한다면 좀더 지능적이고 강력한 상태진단 도구가 될 수 있을 것이다. 그러므로 이에 대한 체계적이고 심층적인 연구가 필요하다.

참 고 문 헌

- (1) Lawrence, R. 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) Padhraic, S., 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 Patterson-Hine, 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) 이종민, 황요하, 2000, "Hidden Markov Model을 이용한 기계 신호의 이상 예측 및 감지," 대한기계학회, 춘계학술대회논문집, pp. 230~236.
- (5) 공호성 등, 1999, "지능형 시스템 모니터링 기술 개발, 1차년도 연구보고서," 한국과학기술연구원, KIST-2000연구사업단, 제 2 장, pp. 11~64.
- (6) Rabiner, L. and Juang, B. H., 1993, FUNDAMENTALS OF SPEECH RECOGNITION, Prentice Hall Inc., Chapter 6, pp. 321~389.
- (7) Hannaford, B. and Lee, P., 1991, "Hidden Markov Model Analysis of Force/Torque Infor-

- mation in Telemanipulation," The International Journal of Robotics Research, Vol. 10, No. 5, pp. 528~539.
- (8) Pandit, S. M. and Wu, S. M., 1983, TIME SERIES AND SYSTEM ANALYSIS WITH APPLICATIONS, John Wiley & Sons, Inc., Chapter 4, pp. 142~176.
- (9) 최영철, 김양한, 2000, "최소 분산 캡스트럼을 이용한 노이즈 속에 묻힌 임펄스 검출 방법-베어링 결합 검출에의 적용," 한국소음진동공학회논문집, 제 10 권, 제 6 호, pp. 958 ~ 990.
- (10) 공호성 등, 2000, "지능형 시스템 모니터링 기술 개발, 2차년도 연구보고서," 한국과학기술연구원, KIST-2000연구사업단, 제 2 장, pp. 17~194.
- (11) 조성용 등, 2001, "윤활유 오염에 따른 광투과율 변화에 관한 실험적 연구," 한국윤활학회지, 제 17 권, 제 16 호, pp. 482~489.