

결함 데이터를 필요로 하지 않는 연속 은닉 마르코프 모델을 이용한 새로운 기계상태 진단 기법

New Machine Condition Diagnosis Method Not Requiring Fault Data Using Continuous Hidden Markov Model

이 종 민*·황 요 하*

Jong Min Lee and Yoha Hwang

(2010년 11월 29일 접수 ; 2011년 1월 17일 심사완료)

Key Words : Machine Condition Diagnosis(기계상태 진단), Hidden Markov Model(HMM, 은닉 마르코프 모델), Pattern Recognition(패턴인식), Failure Detection(결함 감지), Weld Defect(용접 결함)

ABSTRACT

Model based machine condition diagnosis methods are generally using a normal and many failure models which need sufficient data to train the models. However, data, especially for failure modes of interest, is very hard to get in real applications. So their industrial applications are either severely limited or impossible when the failure models cannot be trained. In this paper, continuous hidden Markov model(CHMM) with only a normal model has been suggested as a very promising machine condition diagnosis method which can be easily used for industrial applications. Generally hidden Markov model also uses many pattern models to recognize specific patterns and the recognition results of CHMM show the likelihood trend of models. By observing this likelihood trend of a normal model, it is possible to detect failures. This method has been successively applied to arc weld defect diagnosis. The result shows CHMM's big potential as a machine condition monitoring method.

1. 서 론

은닉 마르코프 모델(hidden Markov model, HMM)은 기존의 마르코프 체인(Markov chain)이론⁽¹⁾을 1960년대에 Baum 등^(2,3)이 음성인식분야에 적용하기 위하여 확장연구를 시작하여 1980년대에 완성된⁽⁴⁾ 이후 다양한 분야에 적용되고 있다. 현재까지 HMM의 가장 뛰어난 응용분야는 음성인식 분야이며, 생체인식, 신호분석 및 예측, 패턴인식 등으로

그 적용분야를 넓혀가고 있다. HMM이 각광을 받는 이유는 2중의 통계적 과정으로 이루어진 통계모델이기 때문에 다양한 수학적 구조를 지니고 있으며, 몇몇 응용분야에서 매우 뛰어난 결과를 보여주고 있기 때문이다⁽⁵⁾. HMM의 뛰어난 성능에도 불구하고 이를 기계 상태진단 분야에 적용하고자 하는 연구는 아직 초기단계로 몇몇의 연구⁽⁶⁻¹⁰⁾ 결과만 발표된 상태이다.

일반적으로 HMM을 기계상태 모니터링의 진단기법으로 적용하기 위해서는 다른 방법과 마찬가지로 정상작동 단계를 포함하여 진단하고자 하는 결함 단계들의 신호들을 수집한 다음, 각각의 신호에 대하여 HMM을 학습시켜서 정상 모델 및 각 결함의 대표 모델을 만들어야 한다. 진단 방법은 미지의 신

* 교신저자; 정회원, 한국과학기술연구원 에너지메카닉스센터

E-mail : ljm2293@kist.re.kr

Tel : (02)958-5669, Fax : (02)958-5659

* 정회원, 한국과학기술연구원 에너지메카닉스센터

호가 각 모델들에서 발생할 가능성을 계산하여 가장 높은 가능성을 가진 모델을 미지의 신호에 해당하는 모델로 진단한다. HMM알고리즘은 확률 값들의 역수나 곱, 합으로 이루어진 연산들로 이루어져 있으며 이를 기계상태진단에 적용하면 애매모호함이 없는 정확한 진단, 외란에 강인한 진단 및 결함에 측이 가능한 매우 우수한 특성을 보여준다⁽⁶⁾. 이는 HMM의 특성상 각 모델들에서 발생할 가능성의 차이가 매우 커서 쉽게 구분할 수 있기 때문이다. 인식해야 할 패턴이 기호열(symbol series)이면 이산(discrete) HMM(DHMM)을 적용하고, 벡터열(vector series)이면 연속(continuous) HMM(CHMM)을 적용한다. 일반적으로 DHMM은 CHMM에 비하여 상대적으로 계산시간이 빠르며 강건한 인식성능을 지니고 있으며, CHMM은 정밀한 판단에 유효하며 우수한 예측성능을 지니고 있다⁽⁶⁾.

이 논문에서는 HMM의 고유한 특성중의 하나를 이용하여 결함모델이 없는 경우에도 정상 단계의 CHMM 만을 사용하여 기계 결함 발생을 감지하는 새로운 기계상태 진단 기법을 제시한다. 정상과 각 결함 CHMM모델이 존재하는 경우 미지의 신호가 연속적으로 입력되고 있으면, 각각 CHMM의 진단 결과값들의 변화가 진단하고자 하는 시스템의 단계변화 경향을 아주 잘 보여준다⁽⁶⁾. 이는 매 순간 최고의 가능성을 보여주는 모델은 하나이며 나머지 모델들의 가능성은 HMM의 특성상 상대적으로 매우 낮은 값들을 지니게 되기 때문이다. 다양한 결함에 대하여 완벽한 모델들을 가지고 있을 경우에는 최고의 가능성을 지닌 모델의 진단 결과값이 감소하기 시작하는 경우 다른 한 모델의 진단 결과값이 상승하는 것을 관찰할 수 있으며 이에 따라 이상의 발생을 미리 예측하는 것이 가능하다⁽⁶⁾. 이때 결함 모델들의 진단결과 값들을 제외하고 정상모델의 진단 결과값의 변화 추이만을 살펴보면, 정상단계에 있는지, 정상단계에서 벗어나고 있는지, 정상단계가 아닌지를 추정할 수 있다. 이 특성을 이용하여 정상단계의 신호로 모델링된 CHMM의 진단결과 수치만으로 현재 단계가 정상단계인지 아닌지를 판단할 수 있는 새로운 방법을 제시하였다.

현재 연구되고 있는 대부분의 패턴을 인식하는 지능적인 방법들은 정상단계의 신호와 각 결함단

계의 신호들을 비교하여 모델이나 판단기준을 만들어서 결함을 감지한다. 따라서 결함감지 알고리즘이나 모델들을 완성하기 위해서는 정상단계의 신호와 각 결함단계의 신호들을 모아서 분석해야만 한다. 이러한 작업은 실험실에서는 가능하지만, 실험실에서 만들어진 모델이나 판단기준을 현장 시스템에 적용하면 시스템과 작업환경의 차이 때문에 많은 문제가 발생하여 실험실 수준의 모델이나 판단기술을 적용할 수 없다. 또한 현장에서 정상운전 신호를 모으는 일은 비교적 쉽지만, 각 결함운전 신호를 모으는 일은 매우 힘들거나 많은 경우 불가능하다. 기계에 결함이 발생하기를 기다려야 하거나, 정상적인 기계에 일부러 결함을 만들어 신호를 취득해야 하기 때문이다. 더욱이 이렇게 취득한 결함신호 구간이 매우 짧아서 모델링하기 부족한 경우도 있다. 또한 모델이나 판단기준에 포함되어 있지 않은 예상치 못한 결함인 경우에는 감지하지 못하게 된다. 이런 점들을 감안하면 이 논문에서 제안하는 정상단계의 신호로 모델링된 CHMM만으로 기계상태를 진단하는 방법은 현장에서 매우 효과적으로 쓰일 수 있다. 물론 이 경우 결함모델들이 없기 때문에 결함의 종류를 알아낼 수는 없지만 결함발생을 정확하게 감지할 수 있으며, HMM의 특성에 따라 추후 발생하는 다양한 결함은 각각의 결함단계 신호로 학습시킨 모델 추가가 가능하여 결함을 감지할 수 있다.

이 논문에서는 정상상태의 시계열(time series) 데이터의 주기성을 모형화하는 방법인 AR(auto-regressive) 모델의 계수를 특징벡터로 선정하고 정상상태 CHMM만으로 이 특징벡터의 패턴의 변화를 인식하는 기법을 새로운 기계결함감지기법으로 제안하였다. 제안된 방법을 사용하여 로봇을 이용한 자동 아크용접의 기공결함을 성공적으로 탐지함으로써 그 성능을 입증하였다.

2. 연속 은닉 마르코프 모델

2.1 CHMM의 정의⁽⁷⁾

관측되는 데이터의 통계적 특성이 일정하지 않을 경우 하나의 확률분포함수(평균, 공분산, 혼합물(mixture))로 모델링된 확률모델은 정확하지 않다.




Fig. 1 Example structure of 3-state 4-mixture ergodic CHMM

정확한 확률모델을 만들기 위하여 확률모델이 변화하는 패턴을 모델링한 것이 CHMM으로 CHMM의 일반적인 구조는 Fig. 1에 나타나 있다. Fig. 1은 3-상태(state) 4-혼합물 에르고딕(ergodic) CHMM 모델이다. 각 상태는 서로 다른 4-혼합물 관측 확률분포함수를 가지고 있으며 각 상태에서는 다음 상태로 이동은 어느 상태로도 이동 가능한(에르고딕) 모델이다. 현재 시간에 i 번째 상태에 머무르고 있으면 그 상태의 관측 확률분포함수에 의하여 관측데이터가 관측된 다음, 다음 시간에는 상태전이확률에 의하여 다음 상태로 옮겨가 그 상태의 관측 확률분포함수에 의하여 다음 관측데이터가 관측되는 모델이다.

기계상태 진단에 적용하기 위하여 우선 CHMM을 다음과 같이 정의한다. 하나의 증상에 대하여 습득한 데이터들로부터 D 차원 특징벡터(feature vector)를 추출하여 시간순서로 나열한 D 차원 벡터 T_k 개로 이루어진 관측벡터열(observation vector sequence)들 K 개가

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

$$O^{(k)} = \{\bar{o}_1^{(k)}, \bar{o}_2^{(k)}, \dots, \bar{o}_T^{(k)}\} \quad (1)$$

와 같이 주어진다고 하자. 이 벡터열들의 2중의 통계적 특성을 모델링한 CHMM을 구하기 위하여는 우선 상태와 각 상태에 소속된 벡터들의 혼합물의 수를 식 (2)와 (3)과 같이 각각 N, M 개로 선택하면 CHMM은 식 (4)와 같이 정의된다.

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

$$X = \begin{Bmatrix} x_{11} & x_{12} & \dots & x_{1M} \\ x_{21} & x_{22} & \dots & x_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{NM} \end{Bmatrix} \quad (3)$$

$$\lambda = (\bar{\pi}, A, \mu, \mathbf{U}, C) \quad (4)$$

여기서, s_n 은 n 번째 상태이고, x_{nm} 은 s_n 의 m 번째 혼합물이다.

CHMM의 파라미터(parameter)들은 q_t 가 시간 t 에서의 상태, $P[\bullet]$ 를 확률이라고 하면, 다음과 같이 정의된다. 우선 첫 번째 관측벡터가 몇 번째 상태에서 관측될 확률인 초기상태확률분포 $\bar{\pi}$ 와 현재 관측벡터가 i 번째 상태에서 관측될 때 다음 번 관측벡터가 j 번째 상태에서 관측될 확률인 상태전이확률분포 A 는

$$\bar{\pi} = [\pi_1, \pi_2, \dots, \pi_N]^T$$

$$\pi_n = P[q_1 = s_n] \geq 0$$

$$\sum_{n=1}^N \pi_n = 1 \quad (5)$$

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

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

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

와 같고, 각 상태에서 관측될 관측벡터의 평균 μ 와 공분산 \mathbf{U} , 혼합물 이동행렬 C 는 식 (7), (8), (9)와 같이 정의된다.

$$\mu = \begin{Bmatrix} \bar{\mu}_{11} & \bar{\mu}_{12} & \dots & \bar{\mu}_{1M} \\ \bar{\mu}_{21} & \bar{\mu}_{22} & \dots & \bar{\mu}_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\mu}_{N1} & \bar{\mu}_{N2} & \dots & \bar{\mu}_{NM} \end{Bmatrix} \quad (7)$$

$$\mathbf{U} = \begin{Bmatrix} U_{11} & U_{12} & \dots & U_{1M} \\ U_{21} & U_{22} & \dots & U_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ U_{N1} & U_{N2} & \dots & U_{NM} \end{Bmatrix} \quad (8)$$

$$C = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1M} \\ c_{21} & c_{22} & \cdots & c_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ c_{N1} & c_{N2} & \cdots & c_{NM} \end{bmatrix} \quad (9)$$

$$c_{nm} \geq 0, \quad \sum_{m=1}^M c_{nm} = 1 \quad \forall n = 1, 2, \dots, N$$

여기서, $\bar{\mu}_{nm}$ 은 s_n 의 x_{nm} 에서의 D 차원 평균벡터이고, U_{nm} 은 s_n 의 x_{nm} 에서의 $D \times D$ 차원 공분산행렬, c_{nm} 은 s_n 의 x_{nm} 의 이득이다. 이와 같이 CHMM이 정의 되면, k 번째 관측벡터열 $O^{(k)}$ 의 t 번째 관측벡터 $\bar{o}_t^{(k)}$ 가 상태 s_n 에서 관측될 관측벡터 확률밀도함수를 가우시안(Gaussian) 밀도함수의 혼합물이라고 하면 다음과 같다.

$$b_{t,n}^{(k)} = \sum_{m=1}^M c_{nm} \times \left[\frac{\exp\left(-\frac{(\bar{o}_t^{(k)} - \bar{\mu}_{nm})^T \cdot U_{nm}^{-1} \cdot (\bar{o}_t^{(k)} - \bar{\mu}_{nm})}{2}\right)}{\sqrt{(2\pi)^2 \times |U_{nm}|}} \right] \quad (10)$$

2.2 CHMM 파라미터의 추정

우선 진단하고자 하는 시스템들로부터 데이터를 수집하고, 이를 특징을 잘 표현할 수 있는 특징벡터 추출 방법을 사용하여 학습용 관측벡터열들로 변환한다. 학습용 관측벡터열들이 주어지고 CHMM이 2.1절과 같이 정의되면, CHMM의 파라미터들을 Fig. 2와 같은 방법으로 추정한다. 우선 각 파라미터에 임의의 값을 배정한 후 구간별 k -평균 군집화(segmental k-means clustering)^(5,7) 방법으로 초기값을 선택한다. 다음 Baum-Welch 알고리즘으로^(5,7) 각 파라미터의 정확한 값을 추정하여 CHMM을 구한다.

그러나 특징벡터의 분산이 매우 적은 기계신호의 일반적인 특성 때문에 CHMM을 기계신호에 적용할 경우 Fig. 2에 제시된 방법을 이용하여 통계적 특성을 구하기 어려워져 위의 알고리즘은 매우 제한된 범위에서만 수렴되는 특성을 보여주고 있다⁽⁶⁾. 따라서, 저자들은 아래에 설명된 수정된 알고리즘을 사용하여 CHMM이 기계 결합신호에도 정확하고 강건하게 적용할 수 있도록 하였다.

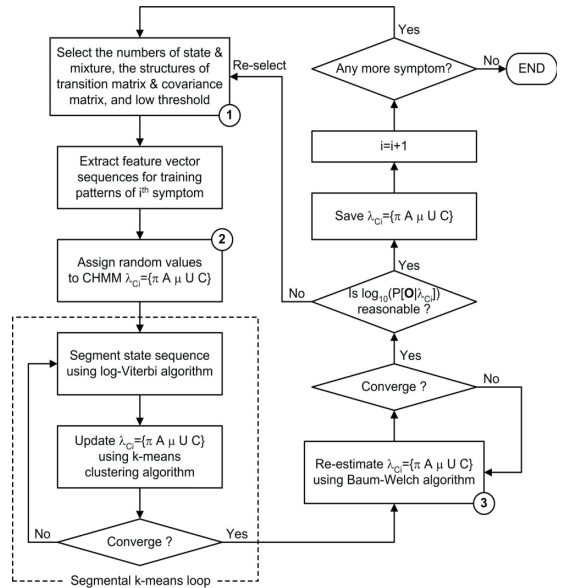


Fig. 2 Flow chart of CHMM training⁽⁷⁾

모든 계산 결과에 적절한 하한값(low threshold)을 적용하여(Fig. 2의 ①) 언더플로우(underflow)를 막을 수 있었다. 또한, Fig. 2의 ②에서는 임의의 값을 초기값으로 하는 일반적인 방법 대신에 최대거리 군집화 방법^(7,11)으로 선정된 초기값을 사용함으로써, 다음의 k -평균 군집화 방법의 반복 횟수를 획기적으로 줄이고 각 모집단의 소속 벡터들을 적절히 분배시켜 통계적 안정화를 이루었다. 한편, Fig. 2의 ③에서는 축척 전진/후진 변수(scaled forward/backward variable)⁽⁵⁾들을 적용하여 매우 큰 값이나 작은 값을 안정적으로 계산할 수 있도록 하였다. 이와 같은 방법들을 이용하여 CHMM을 다양한 기계신호에 적용한 결과 매우 안정적으로 Fig. 2의 알고리즘을 수행시켜 CHMM을 성공적으로 학습시킬 수 있었다⁽⁷⁾.

이렇게 학습된 CHMM들을 사용하여 구한 학습용 관측벡터열들의 로그우도(loglikelihood)⁽¹²⁾로 각 결합을 적절히 인식하지 못한다면, 적절히 인식할 때까지 CHMM의 구조나 특징벡터추출 방법을 바꾸어 전 학습과정을 반복한다. 이와 같이 모델을 학습시킨 후 학습용 데이터에 적용하여 모델의 타당성을 검토하는 이유는 최적모델구조를 선택하는 방법이 없어서 경험에 의하여 모델구조를 선택하기 때문이다⁽⁵⁾.

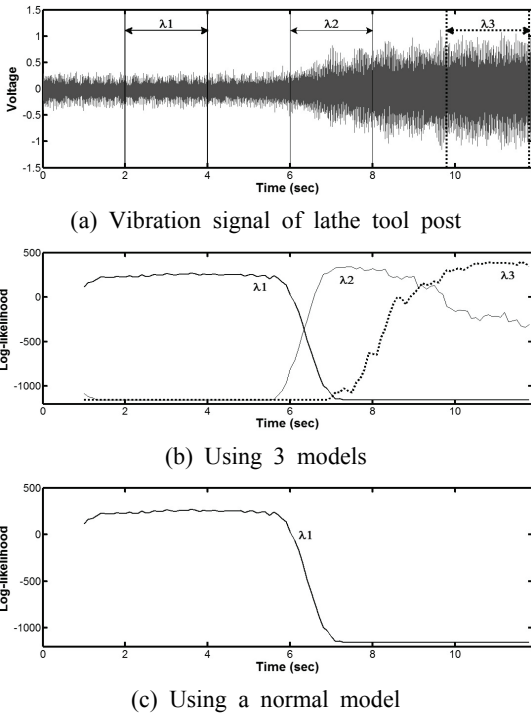


Fig. 3 Diagnosis results using CHMM⁽⁷⁾

2.3 정상단계 CHMM만을 이용한 결함 진단

진단하고자 하는 시스템에 대한 CHMM이 구해지면, 대상 시스템으로부터 신호를 얻어 CHMM 학습 과정에서와 동일한 방법으로 특징벡터들을 추출한 다음, 이 특징벡터들로부터 2.2절에 언급한 매 시간에서의 축척 전진변수의 합들을 곱하여 로그를 취한 값을 각 결함의 CHMM에서 관측될 로그우도로 정한다^(5,7). 그러면 가장 큰 로그우도를 가지는 CHMM에 해당하는 결함을 대상 기계의 결함으로 진단한다.

선반의 절삭가공시 발생하는 채터 현상을 진단하는데 CHMM을 적용한 결과는 Fig. 3⁽⁷⁾과 같다. Fig. 3(a)는 선반 공구대에서 측정된 가속도 신호로 정상적인 절삭가공에서 채터가 완전하게 발생하는 구간까지의 변화를 보여준다. 이를 정상단계(λ_1), 천이단계(λ_2), 채터단계(λ_3)로 나누어 각 영역의 화살표 구간의 데이터로 모델을 학습시켜 진단한 그림이 Fig. 3(b)이다. 각 구간에서 자신의 모델이 가장 큰 로그우도 값을 보여주며 다른 모델의 로그우도 값은 상대적으로 매우 낮은 값을 보여줌으로써 정확하게 진단하는 특성을 보여주고 있으며, 노

이즈에 로그우도 값들이 크게 흔들리지 않아서 판단하기 쉽게 해주는 등 강인한 진단 특성도 보여준다. 그리고 정상단계의 로그우도 값(굵은 실선)이 천이구간에 접어들기 전부터 천천히 감소하기 시작하여 천이구간 동안 하한값까지 떨어져서 정상단계일 가능성의 추이를 잘 보여 주고 있으며, 천이단계 모델의 로그우도 값(가는 실선)도 정상단계 모델의 로그우도 값이 감소할 때부터 증가하였다가 천이구간이 끝나고 채터구간으로 바뀔 때 따라 감소하기 시작하고, 채터모델의 로그우도 값(굵은 점선)은 천이구간 중간쯤부터 서서히 상승하기 시작하여 채터구간에 접어들면서 최고의 값을 보여준다. 즉, 가공상태변화의 추이를 각 모델의 로그우도 값들이 극명하게 보여주며, 우수한 예측성능을 가지고 있음을 알 수 있다. 이때 Fig. 3(c)와 같이 정상단계의 모델인 λ_1 의 로그우도 값의 경향을 잘 관찰하고 있으면 정상단계에서 비정상단계로 변화하고 있음을 감지할 수 있다. 이러한 특성을 이용하면 비정상단계의 모델인 λ_2 나 λ_3 없이 λ_1 만의 로그우도 값의 변화를 감지하면 현재의 단계가 정상이 아니고 결함이 발생하기 시작하였는지, 결함이 완전히 진전되었는지를 감지할 수 있다. 이러한 방법은 정상신호만 가지고 있는 경우, 결함신호를 얻을 수 없는 경우, 결함신호가 매우 짧거나 적은 경우, 어떠한 결함이 발생할지 알 수 없는 현장 시스템을 진단하고자 하는 경우에 매우 효과적으로 결함을 감지할 수 있는 방법이 된다^(13,14).

3. 아크 용접의 결함 진단

3.1 인위적 아크 용접 결함의 진단

로봇을 이용한 아크 자동용접시 현재 산업계에서는 주요한 용접부위는 용접이 완료된 후 초음파나 X선 검사 등의 비파괴 검사를 이용하여 결함을 찾아내고 있다. 한편 실시간으로 결함을 감지하기 위하여 용접 중에 모니터링한 전류와 전압의 시계열 신호의 변화를 이용하는 방법을 사용하는 등의 연구^(15,16)가 진행되고 있으나 성능상의 문제로 실제 현장에서 신호의 미묘한 변화에 대한 대응이 미흡하여 적용의 어려움을 겪고 있다.

제안한 방법을 실제로 현장에서 아크 용접 결함 진단에 적용하였다. 두꺼운 판재를 용접하기 때문에




Fig. 4 Photo of blow hole after the 1-pass arc welding

두 번에 걸쳐(1-pass, 2-pass) 용접을 하여야 완성되는 용접으로서, 의도적으로 용접불량을 유도하기 위하여 용접 일부 구간에 방청제를 도포하여 용접 중 방청제가 고온에 연소하여 기공이 발생하도록 하였고, 일부 구간에서는 아크를 보호하기 위해서 용접 봉 주위에서 분사되는 CO₂가스를 차단하여 아크가 불안정하게 발생하도록 하였다. 첫 번째 패스를 용접하고 난 후 육안으로 용접표면을 확인한 결과 방청제를 도포한 구간에서 용접 표면에 기공 하나가 Fig. 4의 하얀 점선 내부의 구멍과 같이 발생한 것을 확인할 수 있었으며 나머지 구간은 깨끗하였다. 두 번째 패스를 용접하고 난 후에는 모든 용접표면은 육안으로 검사한 결과 모두 깨끗하였다.

용접 중 측정된 전압 신호는 Fig. 5의 (a), (b)의 위 그래프와 같다. Fig. 5(a)는 첫 번째 패스, (b)는 두 번째 패스의 그래프이다. Fig. 5(a)에서 보면 약 110초 부근과 220초 부근에서 전압신호의 큰 변화가 있었는데, 110초 부근은 방청제가 도포된 부분을 용접할 때이고, 220초 부근은 CO₂가스를 차단하고 용접한 부근에 해당한다. 이는 각각 Fig. 5(b)의 140초 부근과 270초 부근에 해당한다. 첫 번째 패스와 두 번째 패스와 시간차이가 나는 이유는 두 패스에서의 용접속도가 다르기 때문이다. 용접신호의 특징벡터로는 AR 모델의 계수를 사용하였다. AR 모델은 시간 영역에서 시계열 데이터의 주기성을 모델링하고, 모델링에 사용되는 데이터에 따라 그 계수가 변화하는 특징이 있으므로 HMM을 위한 특징벡터로 유용하다⁽¹¹⁾. 특징벡터는 시계열 데이터를 AR 모델 계수를 변환하여 사용하였으며, 첫 번째 패스와 두 번째 패스의 정상용접구간의 데이터 중 Fig. 5의 (a), (b)의 위 그래프에서 화살표 구간의 데

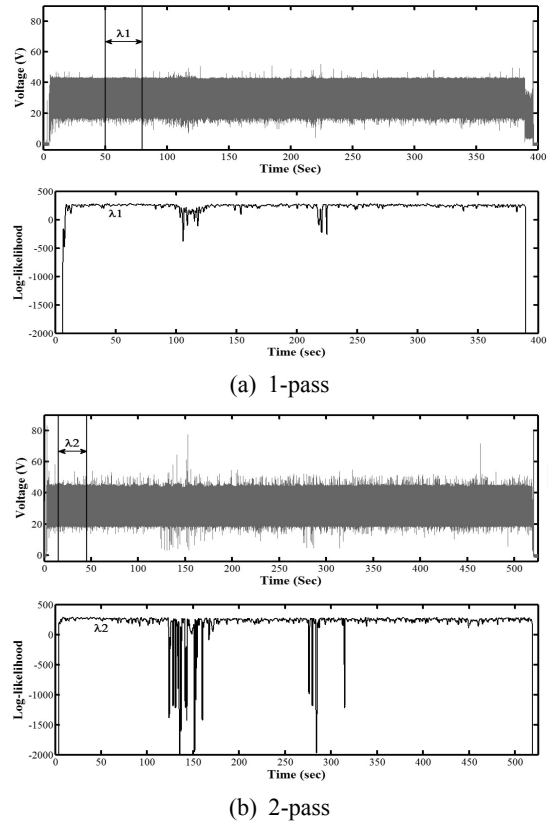


Fig. 5 Welding diagnosis results on artificial defect

이터를 선택하여 첫 번째 패스와 두 번째 패스에 대하여 정상용접 CHMM(λ_1 , λ_2)을 각각 학습시켰다.

첫 번째 패스의 정상용접 CHMM(λ_1)으로 첫 번째 패스를 진단한 결과는 Fig. 5(a)의 아래 그래프이고, 두 번째 패스의 정상용접 CHMM(λ_2)으로 두 번째 패스를 진단한 결과는 Fig. 5(b)의 아래 그래프이다. 진단결과 의도적으로 불량용접을 시도하였던 구간에서 정상 용접일 가능성이 떨어져 문제가 발생하고 있음을 알 수 있다. 이러한 결과는 육안 검사결과 첫 번째 패스의 방청제를 도포한 구간에서만 기공이 하나 발생한 것과 일치하지 않았다. 이에 따라 CHMM으로 진단결과 정상모델의 로그우도 값이 크게 떨어져서 용접결함이 의심되는 부분을 가우징(gouging)으로 파보았으며, 용접 내부의 모습은 Fig. 6의 (a)와 (b)의 사진과 같다. 사진에서 보는 바와 같이 표면은 깨끗했음에도 불구하고 내부에는 많은 기공들이 발생하였고, 이는 Fig. 5의 (a)와 (b)의 진단 결과와 정확히 일치하고 있다.



(a) Region spread with corrosion inhibitor



(b) Region with CO₂ gas shut off

Fig. 6 Photo of blow holes after gouging




Fig. 7 Photo of blow hole occurred during arc welding process




Fig. 8 Diagnostic results of arc welding

3.2 용접공정 중 발생한 용접결함 진단

3.1절에서 발생한 결함은 인위적으로 발생시킨 결함을 검출한 실험이었으나 제안된 방법이 매우 효과적으로 사용될 가능성을 보여주었다. 이에 실제 현장에서의 작업에 본 방법을 적용하여 보았다. 적용대상은 두꺼운 판재의 1-패스 아크용접이다. 용접 작업 중에 Fig. 7과 같이 기공 결함이 발생하였으며 해당 기공 발생을 제안된 방식을 적용하였을 경우 효과적으로 검출이 가능함을 검사하였다. 용접신호와 진단 결과는 Fig. 8과 같다. 위 그림의 용접전압 신호에서 보는 바와 같이 용접 시간은 약 200초가 걸렸으나 용접전압신호에서는 특이한 신호의 이상을 관찰할 수 없다. 정상용접 CHMM으로 신호를 진단한 결과는 Fig. 8의 아래 그림과 같다. 그림에서 보는 바와 같이 용접이 시작되면서 정상모델의 로그우도 값이 높은 값을 계속 유지하다가 150초가 약간 지난 후 급격히 떨어졌다 다시 되돌아 왔다. 이곳이 Fig. 7에서 보여 준 기공결함이 발생한 부위이다. 이 예는 제안된 방법에 따라 정상모델의 진단 결과만 모니터링하고 있으면 어떤 결함인지는 알

수 없어도 결함이 발생했음을 정확하게 찾아낼 수 있다는 것을 알려주고 있다.

4. 결 론

기존의 기계상태 진단 방법의 경우 실제 현장 적용 시에 예상되는 다양한 결함데이터의 획득과 모델링이 어렵거나 불가능함에 따라 현장에서의 사용이 매우 제한적인 문제점을 지니고 있다. 이러한 문제점을 극복하는 새로운 시도로서 정상상태의 모델만으로 기계신호의 결함패턴을 인식하는 새로운 방법을 제안하였다. CHMM의 고유한 특성 중 하나를 이용하여 정상작동시의 데이터를 이용하여 CHMM을 모델링하고 이 모델의 로그우도 값의 변화를 이용하여 로그우도 값이 급격히 떨어지는 지점을 결함이 발생한 구간으로 판정하였다. 제안된 방법은 용접결함을 감지하는데 적용하여 그 성능을 확인하였다. 로봇을 이용한 자동 아크 용접에서 전압신호

의 시계열 데이터나 주파수 분석만으로는 용접결합을 찾아내는 것이 매우 어렵지만 제안된 방식을 따라 AR 모델계수와 정상용접의 CHMM만 사용하여 정확하게 기공결합을 감지할 수 있었다.

이에 따라 제시한 방법이 기계상태 모니터링 분야에서 결함신호를 얻을 수 없는 경우, 결함신호가 매우 짧거나 적은 경우, 어떠한 결함이 발생할지 알 수 없는 경우에 정상신호만 가지고 매우 효과적으로 결함을 감지할 수 있다는 것을 이 논문에서 제시하였다.

후 기

이 연구는 2009년도 지식경제부의 재원으로 한국 에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 20093010020011).

참 고 문 헌

(1) Norris, J. R., 1997, Markov Chains, Cambridge University Press.

(2) Baum, L. E. and Petre, T., 1966, Statistical Inference for Probabilistic Functions of Finite State Markov Chain, Ann. Math. Stat., Vol. 37, pp. 1554~1563.

(3) Baum, L. E. and Egon, J. A., 1967, An Inequality with Applications to Statistical Estimation for Probabilistic Functions of a Markov Process and to a Model for Ecology, Bull. Amer. Meteorol. Soc., Vol. 73, pp. 360~363.

(4) Levinson, S. E., Rabiner, L. R. and Sondhi, M. M., 1983, An Introduction to the Application of the Probabilistic Functions of a Markov Process to Automatic Speech Recognition, Bell Syst. Tech. J., Vol. 62, No. 4, pp. 1035~1074.

(5) 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.

(6) Lee, J. M., Hwang, Y., Kim, S.-J. and Song, C.-S., 2003, Pattern Recognition of Rotor Fault Signal Using Hidden Markov Model, Transactions of

the Korean Society of Mechanical Engineering A, Vol. 27, No. 11, pp. 1864~1872.

(7) Lee, J. M., Kim, S.-J., Hwang, Y. and Song, C.-S., 2004, Diagnosis of Mechanical Fault Signals Using Continuous Hidden Markov Model, Journal of Sound and Vibration, Vol. 276, pp. 1065~1080.

(8) Li, Z., Wu, Z., He, Y. and Fulei, C., 2005, Hidden Markov Model-based Fault Diagnostic Method in Speed-up and Speed-down Process for Rotating Machinery, Mechanical Systems and Signal Processing, Vol. 19, pp. 329~339.

(9) Zhou, Z.-J., Hu, C.-H., Xu, D.-L., Chen, M.-Y. and Zhou, D.-H., 2010, A Model for Real-time Failure Prognosis based on Hidden Markov Model and Belief Rule Base, European Journal of Operational Research, Vol. 207, pp. 265~283.

(10) Chen, J., Hsu, T.-Y., Chen, C.-C. and Cheng, Y.-C., 2010, Monitoring Combustion using HMM Probabilistic Reasoning in Dynamic Flame Images, Applied Energy, Vol. 87, pp. 2169~2179.

(11) 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 Korean Society for Noise and Vibration Engineering, Vol. 13, No. 1, pp. 48~55.

(12) Society for the Research of Information Statistics, 2001, Comprehension of Likelihood, Kyo Woo Sa.

(13) Hwang, Y. and Lee, J. M., 2010, Method for Monitoring Welding Deficiency, Korea Patent Application No. 10-2010-0012970.

(14) Hwang, Y. and Lee, J. M., 2010, Method of Monitoring Machine Condition, U.S. Patent Application No. 12/859,753.

(15) Cho, S.-M., Choi, K.-W. and Lee, K.-W., 2000, Trends of Monitoring Technology for the Arc Welding Quality, Journal of the Korean Welding Society, Vol. 18, No. 4, pp. 417~423.

(16) Cho, S.-M., 2005, Application of Quality Monitoring Technology at Arc and Resistance Welding Manufacturing Site, Proceeding of the Korean Welding Society Conference, Seoul, Korea.