



대표적인 건전성 예측 방법의 소개 및 사용기준 제시

안다운**, 김남호***, 최주호*

(*한국항공대학교 · 플로리다대, **플로리다대, ***한국항공대학교)

1. 머리말

기계 장치의 성능 및 수명을 보장하고 안전을 고려하기 위해서는 설계 및 제조단계에서부터 뿐만 아니라 이후의 유지·보수 관리에서의 신뢰성이 요구된다. 특히 항공우주, 원자력/풍력 발전 및 대용량 배터리와 같이 고안정성 고가의 장치에서는 정비 비용 감소 및 오류를 줄이기 위한 방법으로써 상태기반정비(condition-based maintenance, CBM)가 관심을 받고 있다. 상태기반정비에서 정비 계획은 기계 장치의 건전성 상태에 따라 결정되며, 센서를 통한 상태 감시 데이터를 통해 결함의 위치 및 크기를 추정하는 진단

(diagnostics)과 이 결함 데이터를 기반으로 미래의 결함 크기 및 잔존유효수명을 예측하는 건전성 예측(prognostics)에 기반하여 실행될 수 있다. 이 글에서는 대표적인 건전성 예측 방법의 특성을 소개하고, 건전성 예측에 있어 현재 주어져 있는 어려움에 대해 논함으로써 그 해결 방향에 대해 모색해 보고자 한다.

2. 건전성 예측 방법 및 알고리즘의 종류

건전성 예측 방법 및 특성이 그림 1에 요약되어 있다. 일반적으로 건전성 예측 방법은 물리 모델 기반 방법(physics-based approaches), 데이터 기반

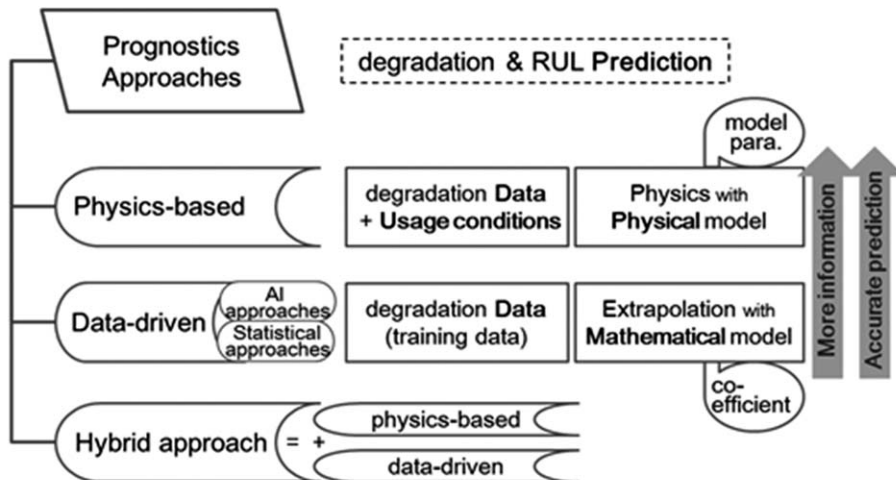


그림 1 건전성 예측 방법의 분류 및 정의

* E-mail : jhchoi@kau.ac.kr

방법(data-driven approaches), 그리고 이 둘의 장점을 결합하고자 하는 방법(hybrid approaches, 이 방법은 고등 연구가 많이 진행되어 있지 않기에 자세한 소개에서 제외한다)으로 구분된다. 물리 모델 기반 방법은 물리 모델(대표적인 예로 Paris model이 있다)에 상태 감시 데이터를 결합하여 모델 변수(예를 들면, Paris model의 m 과 C)를 추정함으로써 잔존유효수명을 예측하는 것이다. 대표적인 알고리즘으로는 파티클 필터와 베이지안 방법이 있다. 데이터 기반 방법은 물리 모델 대신 적절한 수학적 모델을 사용하는데, 이를 이용해 결합성장 거동을 표현하기 위해서는 보통 여러 셋의 데이터가 필요하며, 이를 훈련데이터(training data)라고 한다. 대표적인 알고리즘으로는 인공신경망(neural network)과 가우시안 프로세스 회귀 모델 등이 있다. 다음에 네 알고리즘의 특성을 요약하였다.

2.1 파티클 필터 & 베이지안 방법

이 두 방법은 모두 베이즈 정리(Bayes' theorem)에 기반하여 모델 변수를 갱신하는 물리 모델 기반 방법의 대표적인 알고리즘이다. 두 방법을 사용한 예측결과에서의 차이는 미미하지만, 조건에 따라 사용 효율 측면에서 크게 차이가 날 수 있다. 파티클 필터는 순차적인 방법으로 갱신 절차가 이루어지기 때문에 현재 결합크기가 이전 결합크기 및 증분의 형태로 표현되는 경우 베이지안 방법보다 효과적이다. 반면, 베이지안 방법은 모델 변수 갱신에 초기부터 현재까지의 데이터를 한 번에 사용하는 방법으로, 현재 결합크기가 사이클의 함수로 표현될 수 있는 간단한 모델식의 경우에 효과적이다.

2.2 인공신경망

인공신경망은 데이터기반 방법에서 가장 널리 사용되는 대표적인 알고리즘으로 입력변수와 출력변수의 관계를 전달함수 및 가중치변수를 통해 나타낸다. 가장 큰 특징 중 하나는, 입력과 출력변수 사이에 여러 층(layers)과 절점(nodes)을

더하여 다양한 함수의 조합을 만들어냄으로써 어떠한 형태의 모델이든 만들 수 있다는 것이다. 하지만 층과 절점의 개수가 늘어남으로써 추정해야 하는 가중치변수들이 증가하게 되는 문제점이 따른다.

2.3 가우시안 프로세스

가우시안 프로세스 회귀 모델은 입력·출력변수들의 상관관계를 이용하는 것으로, 새로운 입력에 대한 출력 값은 기존 입·출력 변수들과의 상관도를 계산하여 결정된다. 이 상관도에 의한 예측 값의 정확도는 새 입력 값이 기존 값들 사이에 있을 때(내삽, interpolation) 높아지며, 기존 값들과 멀어질수록(외삽, extrapolation) 정확도는 급격히 감소한다.

3. 균열 크기 예측 적용 사례

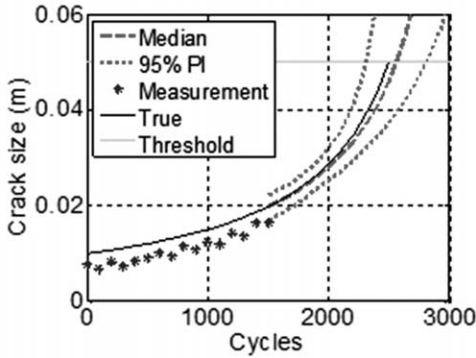
앞서 소개된 알고리즘들의 특성을 균열성장 예측 문제를 통해 확인해 본다.

그림 2는 물리 모델 기반 방법을 사용한 균열 성장 예측 예제로, 단순한 균열 성장(Paris model)과 복잡한 균열 성장(Huang's model)의 경우를 나타내었다. 단순 모델의 경우(그림 2(a))에는 파티클 필터나 베이지안 방법이 결과면에서 큰 차이가 없기 때문에 하나의 결과(베이지안 방법)만 나타내었다. 그림 2(a)는 데이터가 실제 모델에 일정간격 떨어져 측정된 예라 있음에도 불구하고, 데이터에 의한 갱신이 이루어짐에 따라 일정한 크기의 이 여러 값이 추정되어 교정될 수 있다는 물리 모델 기반 방법의 특징을 보여주고 있다. 그림 2(b)는 현재 균열 크기가 이전 균열 크기와 증분의 형태로 표현되는 복잡한 모델의 경우로, 파티클 필터를 사용한 결과를 나타내었다(베이지안 방법을 사용할 경우 오랜 시간이 걸려 매우 비효율적이다). 복잡한 모델임에도 불구하고 예측의 중앙값은 실제 모델과 매우 가깝게 나타난다. 반면, 추정해야 할 변수가 많고 변수의 작은 변화가 균열 성장 결과에

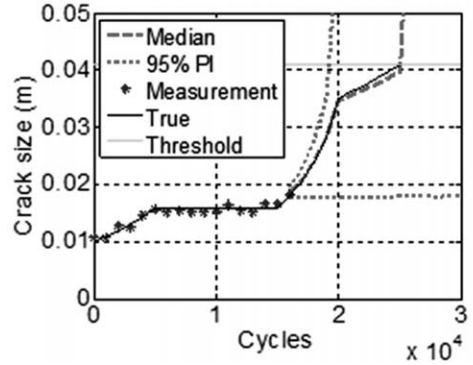
큰 차이를 만들기 때문에 예측 산포는 매우 크게 나타난다.

그림 3과 4는 Paris model에 기반하여 여러 하

중조건에서 가상의 데이터를 생성한 후, 물리 모델이 주어지지 않다고 가정할 후 데이터 기반 방법을 적용하여 예측한 결과들이다. 데이




(a) 단순한 균열 성장(베이지안 방법)




(b) 복잡한 균열 성장(파티클 필터)

그림 2 물리 모델 기반 방법을 사용한 균열성장 예측 결과

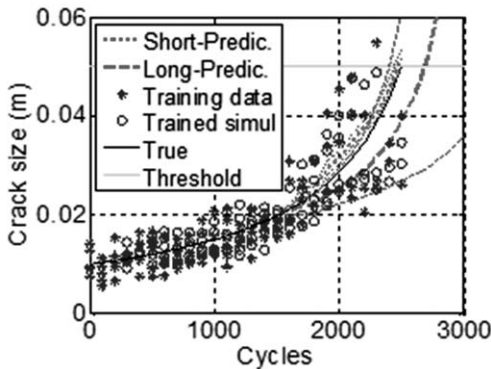


(a) 인공신경망

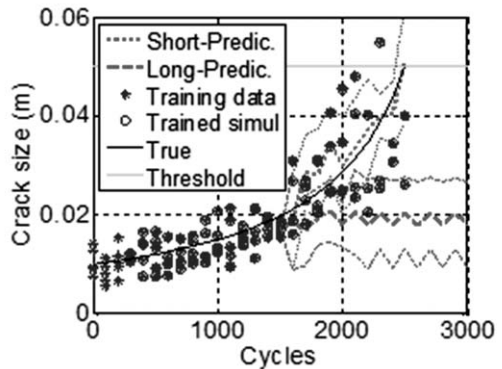


(b) 가우시안 프로세스

그림 3 데이터 기반 방법을 사용한 균열성장 예측 결과: 2 data set & zero noise



(a) 인공신경망



(b) 가우시안 프로세스

그림 4 데이터 기반 방법을 사용한 균열성장 예측 결과: 4 data set & large noise

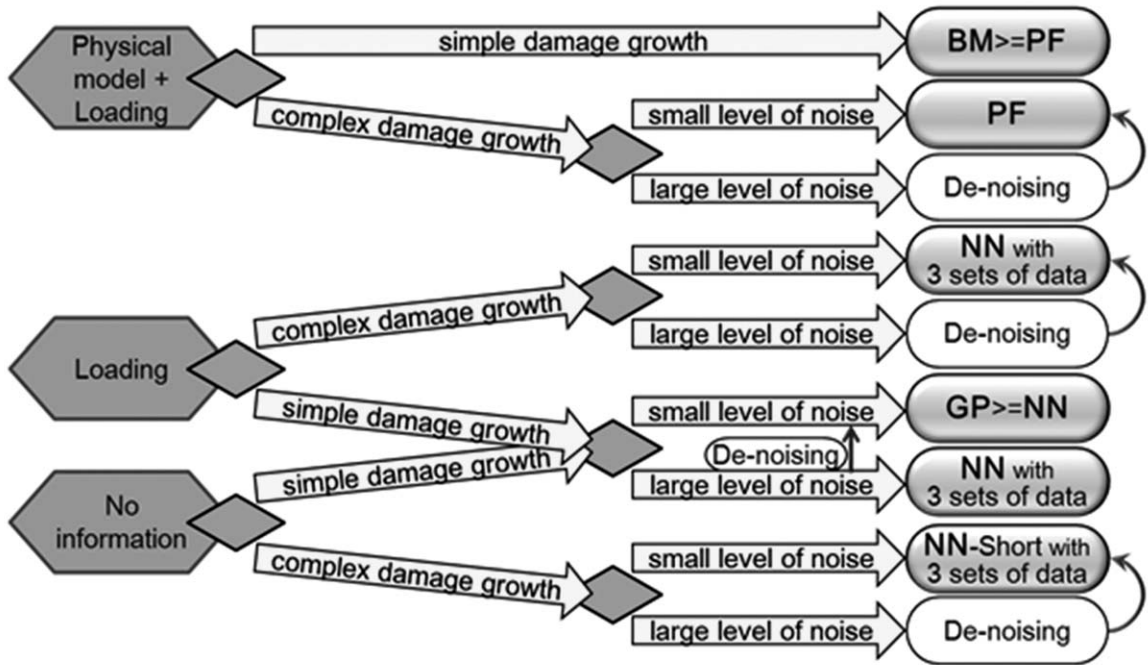


그림 5 건전성 예측 알고리즘 선택 트리

터의 노이즈가 작고 결합성장 거동이 단순한 경우에 가우시안 프로세스를 사용하면 인공신경망 보다 쉽고 빠르게 예측 결과를 얻을 수 있다. 또한 예측을 위한 데이터들이 내삽조건으로 주어진 경우에 인공신경망 보다 정확한 결과를 보여준다(그림 3). 반면, 인공신경망은 노이즈가 크고 복잡한 결합성장 거동의 예측 시 가우시안 프로세스 보다 예측결과가 정확하다(그림 4). 인공신경망을 사용하면 그림 2(b)와 같이 복잡한 균열 성장의 경우도 예측이 가능하다. 다만, 물리 모델 기반 방법과 비슷한 결과를 얻기 위해서는 적어도 세 세트 이상의 훈련데이터가 필요하게 된다.

대표적인 건전성 예측 방법들에 대한 특성을 간략히 소개하고 균열성장 문제에 적용해 보았다. 이 글을 통해 건전성 예측 분야를 처음 접하는 사람들에게 알고리즘 사용기준이 제시 될 수 있기를 바라며, 마지막으로 알고리즘 선택 트리를 그림 5에 나타내었다. 선택 트리의 시작은 사용가능한 정보에 따라서 나누어진다. 물리 모델

과 하중조건이 모두 주어져 있는 경우에는 물리 모델 기반 방법을 쓰는 것이 당연하며, 복잡한 결합 성장 모델의 경우 파티클 필터를 사용하는 것이 효율 측면에서 바람직하다. 물리 모델의 부재 시 단순한 결합성장 모델일 경우에는 가우시안 프로세스 회귀 모델을 복잡한 모델이나 데이터에 노이즈가 많을 경우에는 인공신경망을 사용한다. 물리 모델이 없더라도 하중조건이 주어져 있다면, 데이터 기반 방법을 사용한 예측의 정확도를 높이는 데 도움이 된다.

4. 맺음말

물리 모델 기반 방법은 결합 성장 거동이 물리 모델 변수에 의존하기 때문에 변수 추정이 중요한 문제이다. 하지만, 변수 간 상관관계 및 데이터에 포함된 노이즈·바이어스(bias) 등에 의해 정확한 예측이 어려운 문제가 있다. 다행히도 이러한 문제는 다양한 기법들을 통해 해결이 가능하다. 보다 근본적인 문제는 잘 정립된 물리 모델

이 거의 드물어 실제 문제 적용에 제한적일 수밖에 없다는 것이다. 물리 모델이 없는 경우에는 데이터에 크게 의존할 수밖에 없으며, 데이터 기반 방법에서 예측의 정확도를 높이기 위해서는 여러 셋의 데이터가 필요하다. 하지만 운용중인 장치로부터 파손이 발생 될 때까지의 상태 감시 데이터를 얻기란 시간·비용 측면에서 매우 비싸다는 문제가 있다.

제한적인 물리 모델의 존재와 데이터의 부재를 해결하고자 하는 방법이 바로 하이브리드 방법이지만 아직까지 그렇다할 방법론이 개발되고 있지 않다. 여러 알고리즘의 예측결과들을 조합하여 정확도를 높이려는 노력이 주로 이루어지고는 있지만, 물리 모델 및 데이터 기반 방법의 특성들의 결합에 의한 것이 아니기 때문에 진정한 하이브리드 방법이라고 말할 수는 없다.

방법론에서의 이슈들을 논하기에 앞서 무엇보다

다 중요한 것은 결합 성장 데이터 자체이다. 결합 크기를 직접 측정할 수 있는 경우는 드물며, 센서를 통해 간접적으로 측정되는 경우가 대부분이기 때문이다. 대표적인 예로 베어링의 건전성 상태가 진동신호를 통해 모니터링 되고, 이 진동신호를 통해 현재 베어링의 결합 크기를 추정하기 위한 방법들이 연구되고 있다. 하지만 같은 치수·종류, 같은 운용조건에서 실험된 베어링이라도 수명의 차이가 크게 나고, 모니터 된 진동신호는 파손 직전에만 변화를 나타내는 등 결합특성을 추출하는 일반적인 방법의 개발이 쉽지가 않은 실정이다.

건전성 예측 앞에 놓인 이러한 과제들을 해결하기 위해서는 결합의 물리적 특성에 대한 이해가 우선된 후, 이 물리적 지식을 어떻게 효과적으로 구현 할 것인가에 대한 참신한 아이디어들이 개발 되어야 할 것이다. **KSNVE**

소음·진동 용어해설

(출처 : “소음·진동 용어해설집”, (사)한국소음진동공학회 발행)

Machine Diagnostics 기계 진단

운전 중인 기계의 속도, 가속도와 같은 진동 신호나 그 밖의 출력을 분석함으로써 기계의 운전 상태나 고장의 유무 등을 진단하는 일련의 행위를 말한다.

진단 방법의 종류는 진단하고자 하는 기계에 따라 광범위하며 대체적으로 다양한 신호 처리 방법을 적절히 사용하고 있다. 대표적인 신호 처리 방법은 진폭을 시간 영역에서 분석하는 기본적인 방법부터, 모드 요소 즉 질량, 강성 등의 변화를 분석하는 방법, 신호 포괄(signal envelope) 분석 방법, 힐버트 변환을 이용하는 방법, 캡스트럼을 이용하는 방법, 인공 지능을 이용하는 방법 등 다양하다.

Dynamic Range 동적 범위

액추에이터(actuator)의 경우 발생시킬 수 있는 최소치(변위, 음압 등)와 최대치 사이의 범위를 말하며, 센서(sensor)의 경우 동일한 개념으로 측정 가능한 최소치와 최대치의 범위를 말한다. 일반적으로 사람 귀의 동적 범위는 약 0~140 dB로 알려져 있다.

Dynamic Stiffness 동적 강성(동강성)

역학계의 임의의 지점에서 단순 조화 운동으로 가진된 변위에 대한 힘의 복소비를 의미하며, 동적 강성(dynamic stiffness)은 동적 컴플라이언스(dynamic compliance)의 역수이다.