

건전성예측 및 관리기술 연구동향 및 응용사례

최주호^{1,†}

¹한국항공대학교 항공우주 및 기계공학부

A review on prognostics and health management and its applications

Joo-ho Choi^{1,†}

¹School of Aerospace and Mechanical Engineering, Korea Aerospace University

Abstract : Objective of this paper is to introduce a new technology known as prognostics and health management (PHM) which enables a real-time life prediction for safety critical systems under extreme loading conditions. In the PHM, Bayesian framework is employed to account for uncertainties and probabilities arising in the overall process including condition monitoring, fault severity estimation and failure predictions. Three applications - aircraft fuselage crack, gearbox spall and battery capacity degradation are taken to illustrate the approach, in which the life is predicted and validated by end-of-life results. The PHM technology may allow new maintenance strategy that achieves higher degree of safety while reducing the cost in effective manner.

Key Words : Prognostics and Health Management, Prognostics, Reliability, Uncertainty Quantification, Bayesian Theory, Condition Based Maintenance, Fatigue Crack, Wind Turbine Gear Box, Battery

1. 서 론

본 논문에서는 가혹환경에서 운용되는 고안전성 시스템의 재해적 사고예방을 위해 실시간으로 건전성(health)을 평가하고 이로부터 미래의 고장시점을 예측하는 기술을 소개한다. 주요 대상은 고장 발생시 대형 인명손실로 이어지거나 수리비용이 높은 것으로, 항공기 또는 원전배관의 균열, 헬리콥터/풍력발전기의 기어장치, 무인기/전기차의 배터리 등이 있으며, 이들은 극한의 하중을 받으면서 결함이 성장하거나 성능이 열화되며, 어느 순간 급격히 고장수준에 도달하게 된다. 이를 방지하기 위해 현재는 주기적 예방정비(PM, Preventive Maintenance)를 시행하고 있지만 잦은 down time 및 교체로 가동을 저하와 고비용의 문제가

있다. 최근 이러한 문제를 해결하고자 시스템의 핵심 고장모드를 대상으로 운용 중 고장을 예측하는 기술을 개발하고, 이를 통해 필요한 경우에만 정비를 하는 건전성예측 및 관리(Prognostics and Health Management, PHM) 기술이 활발히 연구되고 있다 [1]. 본 논문에서는 이러한 PHM의 핵심기술과 함께 본 저자가 진행하고 있는 세가지 연구사례를 소개한다. 첫째는 항공기 또는 원전배관에 존재하는 기계/열피로균열, 둘째는 헬리콥터나 풍력발전기의 기어박스에 발생하는 스폴결함, 셋째는 전기자동차 배터리의 충방전에 의한 용량열화이다. 이들에 대해 어떻게 운용 중 건전성 데이터를 확보하고, 예측모델을 이용하여 고장을 예측하며, 실제 발생한 고장과 비교하여 결과를 검증하는 지를 설명함으로써, PHM 기술을 처음 접하는 이들의 이해를 돕고 응용분야를 넓히는 데 도움이 되고자 한다.

Received: March ##, ##### Revised: July ##, ##### Accepted: June ##, #####

† Corresponding Author

Tel: +82-10-5846-0005, E-mail: jhchoi@kau.ac.kr

Copyright © The Society for Aerospace System Engineering

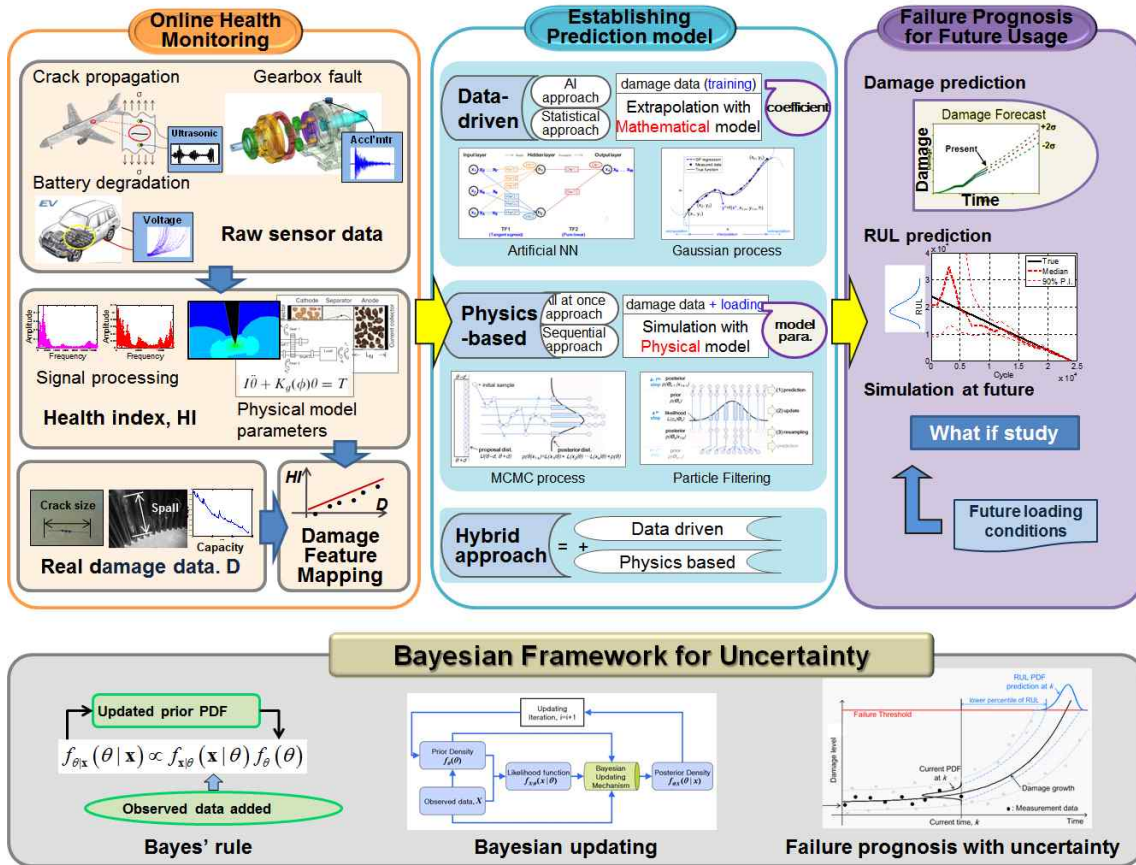


Fig. 1 Overall process of proposed research

2. PHM 연구개요 및 핵심기술

PHM 기술개발을 위한 전체적인 연구개요는 Fig. 1와 같으며, 이를 요약하면 다음과 같다. :

단계 1. 실시간 건전성 모니터링 (Online health monitoring)

가동 중인 시스템의 결함크기를 평가하기 위해 센서로부터 데이터를 획득하고, 이로부터 결함을 잘 나타내는 건전성 지수(health index, HI)를 구한다. 이를 위해 FFT와 같은 시그널 처리 의한 결함 특징추출(feature extraction) 또는 물리적 해석을 토대로 한 결함 파라미터 추정을 수행하며, 실제 측정된 결함크기 D와 HI의 상관관계를 구축함으로써, HI를 통해 현 시점의 결함크기 D를 실시간 모니터링한다.

단계 2. 예측모델 확립 (Establishing prediction model)

단계 1에서 얻어진 건전성 지수 HI와 하중조건 데이터를 바탕으로 고장예측 모델을 확립하고 관련 계수를 추정한다. 손상물리의 존재여부에 따라 데이터기반 및 물리기반 두 방법을 개발하며, 고장모드 종류, 센서특성 및 제공 데이터(하중조건, 선행시험)에 따라 적절한 방법과 함께 융합형(hybrid) 모델을 제시한다.

단계 3: 미래 고장시점 예측 (Failure prognosis for future usage)

단계 2에서 확립된 모델을 이용하여 미래 조건에서 결함성장(열화) 거동을 시뮬레이션하고, 고장시점 또는 잔존수명(Remaining Useful Life, RUL)을 예측하거나 특정 시점에서 수행능력여부를 what-if study한다.

공통 기반기술: 불확실성을 고려한 베이지안 프레임워크 (Bayesian framework for uncertainty) 건전성 모니터링 및 고장예측의 전체 과정에는 여러 가지 불확실성(센서오차, 데이터부족, 물리모델 단순화 등)이 존재하며, 이를 효과적으로 고려하기 위해 베이지안 (Bayesian) 기법에 기반한 추정 및 예측 알고리즘을 개발한다. 그 결과 고장예측정보는 확률분포로 표현되며 시간이 지날수록 데이터가 증가하면서 정확도는 점점 향상된다.

이중에서 단계 1은 해당 고장모드(예를 들어 피로균열, 기어결함, 배터리용량열화) 별로 건전성 모니터링을 위해 매우 다양한 기술이 필요한 측면이 있어 다음 장에서 응용사례별로 소개할 예정이며, 본 장에서는 비교적 공통적으로 적용이 가능한 단계 2와 3에서 필요한 핵심기술을 소개한다. 일반적으로 실시간 건전성 평가 기술에 확보되면 일정 사이클 마다 건전성 데이터를 축적할 수 있으며, 이를 이용하여 고장예측을 할 수 있다. 여기에는 물리모델 기반 및 데이터 기반의 두 방법이 있으며, 이를 본 절에서 소개한다. 또한 이들의 융합적 선택적 방법에 대해서도 설명하며, 가속수명 데이터를 활용한 데이터 부족 문제 해결, 베이지안 기법을 이용한 불확실성 정량화 방법에 대해서도 서술한다[2].

2.1 물리기반 고장예측

(Physics based prognostics)

물리기반 고장예측방법은 결합성장 또는 열화에 대한 물리모델이 존재할 경우 적용된다. 핵심 아이디어는 현재까지 축적한 건전성 데이터와 하중조건(usage) 데이터를 이용하여 현 시점에서의 열화모델 파라미터를 실시간 추정하는 것이다. 추정된 파라미터를 이용하여 미래 조건에서의 성장거동을 시뮬레이션할 수 있고, 그 결과 임계 수준(failure threshold)에 이를 때까지의 잔존수명(RUL)을 추정할 수 있다. 이를 Fig. 2에 예시하였다. 본 방법의 정확도는 열화모델의 우수성, 측정된 데이터의 오차/바이어스에 의해 좌우되며, 이러한 영향을 평가하기 위해 (a) 베이지안 가설검정기법을 활용한 모델적합도 평가 (b) 측정데이터의 오차/바이어스가 존재할 경우 효과적으로 모델 파라미터를 추정하는 방법 (c) 베이지안 통계에 기반한 잔존수명의

확률적 예측등이 주요 핵심 연구주제이다. 물리 기반 예측방법에는 여러가지 추정 알고리즘이 소개되어 있으나 본 연구에서는 대표적으로 두가지 - Particle filter 및 Bayesian 방법을 소개한다.

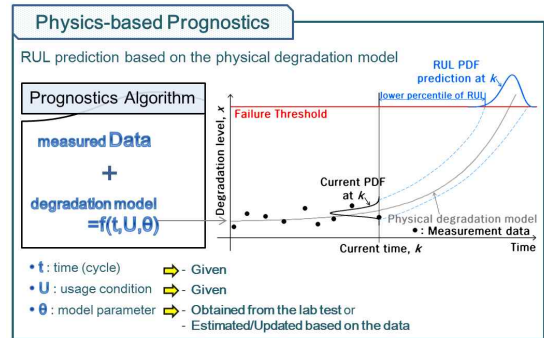


Fig. 2 Illustration of physics-based prognostics

Particle filter 방법 : Particle filter (PF) 방법은 고장예측 연구분야에서 가장 대표적으로 사용되는 방법으로서 모델 파라미터의 사후분포를 유한개의 파티클 (또는 샘플) 및 그들의 가중치로 표현하는 것이다. 이는 베이지안 추론을 매 데이터 측정시점 마다 반복하는 것과 같다. PF는 세 단계로 구성되는데 (1) 예측단계에서는 전 스텝의 사후분포가 현 스텝의 사전분포가 되고, 이것을 열화모델에 적용하여 현 시점의 예비 사후분포를 구한다. (2) 갱신단계에서는 이렇게 구해진 분포를 현 시점에서 측정된 데이터의 우도 (likelihood)에 기반하여 가중치를 적용하여 보정한다. (3) 리샘플 단계에서는 가중치를 가지는 샘플들에 대해 중복 또는 제거 과정을 통해 샘플을 재분배한다. 이렇게 구해진 분포가 최종적으로 사후분포가 되는 것이며, 이는 또다시 다음 스텝에서의 사전분포가 된다. 이 과정을 Fig. 3에 보였다.




Fig. 3 Illustration of particle filter process

Bayesian 방법 : 이 방법은 현 시점에서 지금까지 측정된 모든 데이터를 활용하여 우도를 만들고 이를 바탕으로 모델 파라미터의 사후분포를 추정하는 것이다. 분포가 결정되고 나면 샘플링 기법을 이용하여 해당 분포를 만족하는 샘플을 만들 수 있는데 이를 위한 가장 대표적 방법으로 Markov-chain Monte Carlo (MCMC)을 들 수 있다. 이 방법은 random walk 개념에 기반한 것으로 그 과정을 Fig. 4에 보였다.

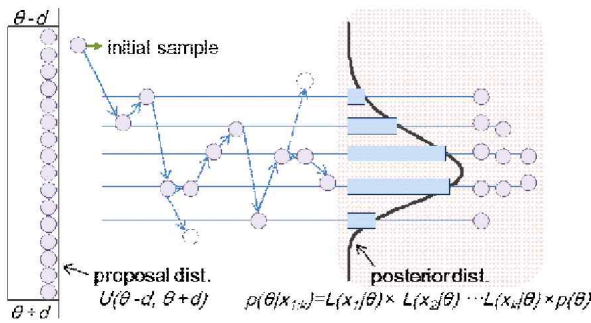


Fig. 4 Illustration of MCMC process

2.2 데이터기반 고장예측

(Data-driven prognostics)

데이터기반 방법은 열화에 관한 물리모델이 없는 경우에 적용되며, 정확한 예측을 위해 기존에 확보한 건전성 데이터(training data)를 활용한다. 이 방법에서는 적절한 수확모델을 수립하고 모델에 사용되는 계수(또는 가중 파라미터)를 트레이닝 데이터에 기반하여 결정한다. 이 방법은 물리적 열화거동을 모르기 때문에 근접한 미래시점, 특히 고장발생이 임박한 시점에서의 거동예측에 더 유효하다. 본 연구에서는 이와 관련하여 신경망(neural-network, NN) 방법과 가우스 프로세스(Gaussian process, GP) 방법을 소개한다.

Neural Network 방법 : 입출력 및 hidden 레이어로 구성된 신경망 네트워크(NN) 모델을 수립하고, 이전 사이클의 건전성 데이터와 하중조건 데이터를 입력 변수로, 현 사이클의 건전성 데이터를 출력변수로 사용하여, 입출력 간의 관계를 규정짓는 파라미터를 최적화 기법에 의해 결정한다. 대표적 NN 모델을 Fig. 5에 보였으며, 여기서 Hw 및 Qw가 가중치 파라미터, Hb, Ob가 바이어스 파라미터를 나타내며, 입출력 데이터를 이용하여 이들을 결정하는 과정을 훈련

(training) 또는 학습(learning)이라 한다. 학습된 NN을 이용하면 새로운 입력조건에서의 출력값을 구할 수 있다. 이 방법의 어려운 점은 (a) NN모델의 설정(노드와 레이어의 개수) (b) 가중/바이어스 파라미터 최적해 (c) 데이터 오차에 따른 불확실성 등이 있으며, 최근 본 저자는 이를 효과적으로 해결하는 방안을 연구하고 있다.

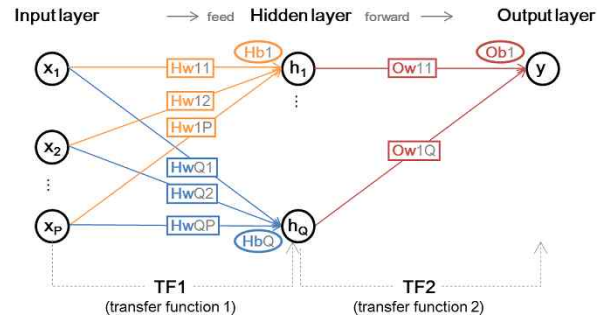


Fig. 5 Illustration of neural network process

Gauss Process 방법 : 가우스 프로세스(GP)는 원래 회귀모델 구축을 위한 방법인데, 이를 고장예측에도 활용하고 있다. GP는 전역 모델과 이의 국부적 벗어남으로 구성되며, 가장 큰 특징은 Fig. 6에 보듯 측정점과 점 사이를 매끄럽게 보간한다는 것이다. 그러나 이 방법의 문제는 고장예측과 같이 예측점이 측정점 바깥에 있으면서 점점 멀어질 경우 GP해가 전역 모델에 의해 결정되면서 예측정확도가 떨어진다는 것이다. 또한 (a) 전역모델 및 공분산함수의 적절한 선정 (b) GP 파라미터의 안정적 최적해 (c) 유효한 활용이 되기 위해 많은 데이터가 필요한 점 (d) 데이터 오차에 따른 불확실성의 문제도 있다. 이들에 대해 해결방안을 연구하고 있다.

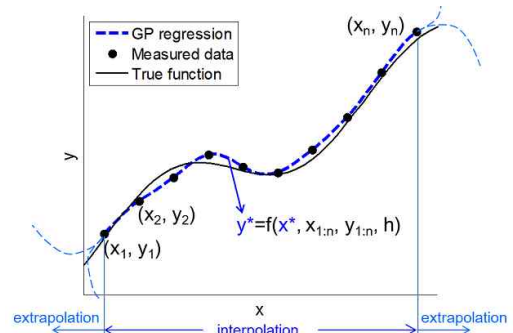





Fig. 6 Illustration of Gaussian process



(a) Johnson distribution



(b) Damage prognosis by NN



(c) Damage growth of 4 quantiles

Fig. 7 Illustration of NN based prognosis using Johnson distribution

2.3 데이터기반 고장예측에서 불확실성의 고려

일반적으로 고장예측에서는 물리적 열화모델이 존재하지 않는 경우가 많다. 이런 이유로 데이터기반 연구가 훨씬 더 많이 이뤄졌고, 이를 위해 신경망회로(NN) 방법이 가장 많이 이용되었다. 그러나 NN은 근본적으로 결정론적(deterministic) 해를 제공하는 방법이므로 본 연구와 같이 여러 불확실성이 존재하는 문제에 그대로 적용하는 데 한계가 있다. 결함 데이터가 단일값이 아닌 분포로 제공될 경우, 이들의 미래거동에 대한 예측 또한 분포로 제시되어야 한다. 본 연구에서는 이를 해결하기 위해 불확실성을 고려한 NN 기반 고장예측 연구를 수행하고 있으며, 이를 위해 Johnson 분포를 이용하는 새로운 방법을 제시하였다 [3]. 이는 결함분포를 Johnson 분포로 모델링하고, 이를 대표하는 4곳의 변위치(quantiles)를 대상으로 각각 NN을 적용

하여 예측을 한 후 이를 다시 Johnson 분포로 제시하는 것이다. 이 방법을 항공기 동체균열 문제에 시험적으로 적용한 사례를 Fig. 7에 설명하였다. 항공기 동체균열은 Paris 모델에 의해 Fig. 7(c)처럼 성장하는데, 이러한 균열이 단일 지점이 아닌 여러 곳에 분포해 있을 경우 이들의 확률분포를 대상으로 균열성장거동을 예측할 필요가 있다. 그 경우, 균열분포는 성장하면서 그 패턴이 임의적으로 변화하므로 이를 위해서 Johnson 분포를 이용하며, 4개의 quantile 점(a)에 대해 NN 기법(b)을 이용하여 미래거동을 예측(c)한 후 이것을 Johnson 분포로 다시 변환하여 결과로 활용한다.

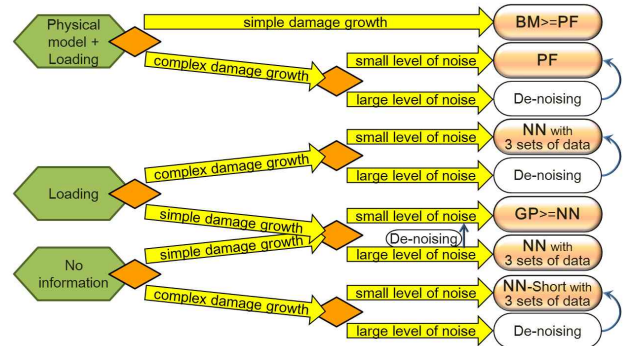


Fig. 8 Selection tree for an appropriate prognostics method

2.4 융합적 고장예측

(Fusion of prognostics algorithms)

고장예측은 모든 경우에 잘 적용되는 단일 알고리즘이 존재할 수 없다. 따라서 개발되는 여러 알고리즘을 선택적으로 사용해야 한다. 이를 위해 본 저자는 균열 성장 문제를 대상으로 가상의 synthetic data를 생성하고, 이로부터 고장예측을 위한 가이드라인을 제시한 바 있다. (Fig. 8 참조) 일반적으로 고장예측에서 건전성 데이터의 충분한 확보는 많은 비용으로 인해 어려운 반면, 고장예측 알고리즘을 적용하는 것은 비교적 쉽다. 따라서 앞에서 제시된 여러 알고리즘 중 한가지를 선택하기 보다는 여러 알고리즘을 적용하고 이들을 적절히 혼합하여 답을 제시하는 것이 더 바람직할 것이다. 즉, 정확도를 어느 정도 유지하면서 예측의 불확실성을 최대한 감소시키는 융합적 방법론의 제시가 필

요하다. 여기에는 복수의 결과로부터 가중합(weighted sum) 또는 median을 택하는 것 등이 있다. 자세한 내용은 문헌 [2]를 참고하기 바란다.

2.5 가속수명시험 데이터의 활용

시스템 운용 중에 건전성 데이터를 충분히 확보하는 것은 쉽지 않으며, 나아가서 종종 field 하중조건 데이터도 확보하기 어려운 경우가 많은데, 이러한 정보부족 문제는 고장예측의 정확도, 신뢰도를 저하시키는 요인이 된다. 반면 개발단계에서 설계를 검증할 목적으로 실제 운용하기 전에 가속조건에서 end-of-life 까지 시험을 실시한다. 이 경우 가속조건과 field 조건은 하중크기 면에서 큰 차이가 있는데, 균열문제의 경우 Fig. 9와 같은 것을 연상하면 되며, 여기서 위 그림이 가속조건에서의 균열성장을, 아래 그림의 별표가 field 조건에서의 균열성장을 나타낸다. 문헌 [4]에서는 이러한 정보부족 하에서 가속수명 데이터를 잘 활용하여 운용 중 시스템의 고장예측 정확도를 향상시키는 방법을 간단한 균열성장 문제를 대상으로 연구하였다.

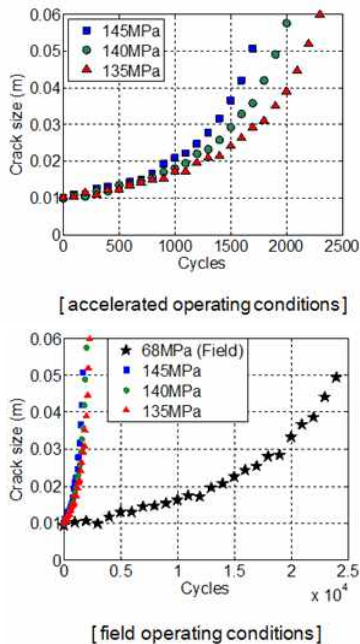


Fig. 9 Crack growths under accelerated and field loading conditions

2.5 불확실성을 고려한 베이지안 프레임워크

베이지안 프레임워크(Bayesian Framework)는 온라인/오프라인 프로세스에서 발생하는 여러 가지 불확실성을 확률적으로 표현하고, 다음 식과 같이 정의 되는 베이즈 정리(Bayes theorem)에 의거하여 분석, 추정 및 업데이트하는 방법론이다[5].

$$p(\theta | \mathbf{y}) \propto L(\mathbf{y} | \theta) p(\theta) \quad (1)$$

여기서 θ 는 추정하고자 하는 모델 변수, \mathbf{y} 는 측정된 데이터, $p(\theta)$ 는 기존의 경험으로 알고 있는 사전(prior) 분포지식, $L(\mathbf{y} | \theta)$ 는 샘플분포의 우도(likelihood)로서 \mathbf{y} 에 의해 추가되는 지식, $p(\theta | \mathbf{y})$ 는 기존 지식이 측정된 데이터에 의해 업데이트된 사후(posterior) 분포를 나타낸다. 새로운 데이터가 추가되면 사후분포는 다시 사전분포가 되며, 이러한 과정이 반복되면서 θ 에 대한 믿음의 정도(degree of belief)를 점점 더 향상시키게 되는데 이를 베이지안 학습효과라 하며, Fig. 10에 프로세스를 나타내었다. 이러한 베이지안 프로세스는 불확실성 변수 모델 구축 및 추정을 위한 가장 탁월한 방법으로 인식되고 있으며, 이에 기반한 PHM 연구가 최근 여러 분야에서 활발히 진행되고 있다.

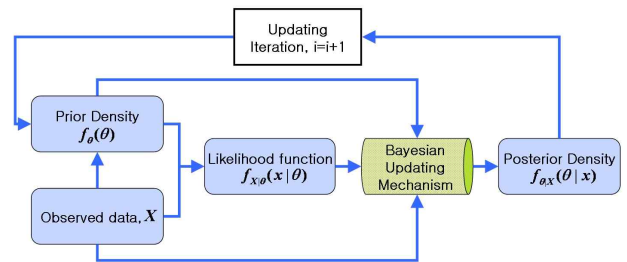


Fig. 10 Process of Bayesian updating

고장예측관련 베이지안 접근법은 Fig. 11을 통해 설명된다. 현 시점 t1까지 측정된 결함(건전성) 데이터에 기반하여 결함성장(열화) 모델(분홍색 파선 커브) 및 신뢰 상하한, 현재의 결함분포(t1 선상 PDF), t2에서의 미래예측 결함분포(t2 선상 분홍색 PDF), 고장임계수준(failure threshold)까지의 잔여수명(Remaining Useful Life, RUL) 분포(빨간색 수평선상 분홍색

PDF) 및 B10수명(10% 리스크 감안한 잔여수명) 등을 구할 수 있다. 시스템이 계속 운용되면서 결함데이터가 추가되어 t2 시점이 되면 t1에서 예측한 PDF는 사전분포가 되고, 추가 데이터에 의해 t2의 결함분포가 사후분포로 업데이트(t2 선상 파란색 PDF)된다. 또한 열화모델(파란색 파선 커브), RUL분포 (빨간색 수평선상 파란색 PDF)도 업데이트되며, 이것이 계속 반복되면서 고장이 임박할수록 RUL분포는 점점 더 정확해진다. 이와 같이 매 시점마다 B10잔여수명을 확인하면서 사용함으로써 고장 전 필요한 기간 동안 부품조달 정비인력 배치 등 사전 준비를 충분히 할 수 있고 이를 통해 상태기반 정비를 구현하는 것이다.

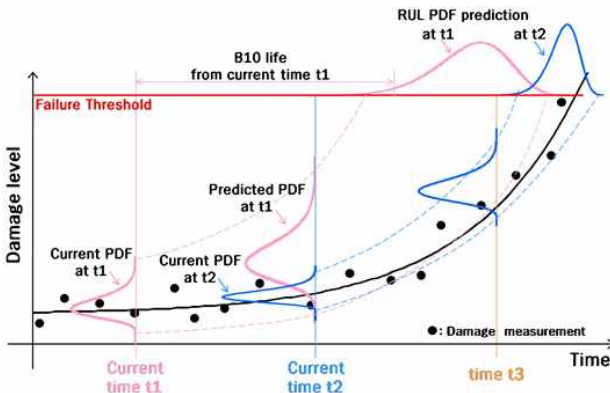


Fig. 11 Prognosis concept considering uncertainty

3. PHM 연구사례

본 저자는 PHM 기술의 성공적 개발을 위해 고안전성 시스템에서 다루는 대표적 고장모드 세가지 즉, 항공기 동체 피로균열, 기어박스 스플결함, 배터리 용량저하 문제에 대해 고장예측기술의 실증을 위한 랩 스케일의 시험장치를 운영하고, 예측고장을 실측고장과 비교하여 효용성을 입증하는 연구를 진행하고 있다. 이때 가동 중인 상태에서의 결함은 직접 측정하는 것이 어려우므로 센서로부터 데이터를 획득하고, 이로부터 결함을 나타내는 건전성 지수(health index, HI)를 추출하는 것이 중요하다. 즉 결함 관련 물리적 거동을 해석하거나 FFT와 같은 시그널 처리기법을 이용하여 HI를 구하고, 이를 통해서 결함크기를 간접 추정하고

있다. 건전성 모니터링 방법은 고장모드 별로 다르므로 세 문제 마다 각각 달리 개발해야 한다.

3.1 항공기 동체 피로균열

현재 항공기 동체균열은 잦은 정기 점검(Periodic Maintenance)을 통해 0.01" 이상의 균열발생 시 무조건 수리교체를 의무화하고 있다. 그러나 이는 정비 비용과 시간을 낭비할 뿐 아니라 정비주기 사이에 발생할 수도 있는 돌발 하중조건이나 비정상적 균열성장으로 인한 사고를 예방하는 데에 한계가 있다. 따라서 선진 연구기관에서는 주요 균열성장 위험위치(hot spot)에 센서를 설치, 균열을 모니터링하고 이에 기반하여 정비시점을 정하는 상태기반 정비기술을 개발하고 있다. 피로균열의 경우 손상물리에 기반한 균열성장 모델(Paris, Wheeler, Huang's model)이 비교적 잘 확립되어 있고, 관련 파라미터 또한 문헌에 제시되어 있다.

Paris model :

$$da = C(\Delta K)^m, \Delta K = \Delta\sigma \sqrt{\pi a} \quad (2)$$

Huang's model :

$$\frac{da}{dN} = C[(\Delta K_{e0})^m - (\Delta K_{th0})^m],$$


$$\Delta K_{e0} = M M_P \Delta K \quad (3)$$

여기에는 C,m을 포함하여 여러가지 물성파라미터들이 사용되고 있는데, 이들은 동일 균열 및 하중조건이라 해도 여러 불확실성으로 인해 실제 운용 항공기에서는 균열이 다르게 성장하기 때문에 문헌치를 활용하는 것은 매우 위험하다. 본 연구에서는 균열성장모델의 파라미터를 문헌값을 이용하는 대신 측정된 균열데이터를 이용하여 실시간 추정하고 이를 바탕으로 미래 균열성장을 예측하는 기법을 개발하고 있다[6]. 이를 위해 항공기 동체 균열을 모사한 시편을 제작하고, 기 보유한 재료시험기 및 비파괴 균열측정 장치를 이용(Fig. 12(a),(b) 참조)하여 이착륙시 압력변화에 해당하는 하중을 반복하면서 균열크기를 측정하였다. 균열측정은 두가지 방법을 병행하였다. 첫째는 예비연구로서 확대렌즈를 이용한 육안측정이며 이는 측정센서의


불확실성을 배제한 조건에서 고장예측을 얼마나 정확히 할 수 있는지 파악하기 위한 것이다. 둘째는 실전 연구로서 압전센서를 이용한 초음파 송수신을 통해 크기를 간접 측정하는 것이며 센서로 인한 오차가 고장 예측에 반영된다. 초음파를 이용한 크기 측정 개념도를 Fig. 12(d)에 보였다.



(a) Test setup



(b) Ultrasonic equipment



(c) Specimen dimension (d) Measuring principle

Fig. 12 Experiment for prognosis of crack and ultrasonic sensors attached to the damaged structure

3.2 기어박스의 기어 및 베어링 스폴결함

헬리콥터나 초대형 해상풍력발전기(높이 160미터 5MW급)에 사용되는 기어박스는 보통의 시스템과 달리 매우 높은 하중이 불균일하게 가해지고 있어 고장 위험이 매우 높으며, 고장발생 시 각각 인명손실과 높은 수리비용이 발생한다. 헬리콥터와 풍력발전 기어박스는 각각 엔진 고속회전을 감속하거나, 풍력 블레이

드의 저회전을 증속하는 것만 다를 뿐 많은 부분 유사한 특성이 있다. 이들의 핵심고장모드는 스폴결함으로서 어느 정도 이상의 크기가 되면 기어박스 전체의 파손을 유발하므로 높은 수준의 관리가 필요하나 잦은 점검은 위치적, 시간적으로 쉽지 않을 뿐 아니라 높은 비용이 수반된다. 본 연구에서는 이러한 점에 착안하여 스폴결함을 실시간 측정하고 이들의 성장을 모니터링하면서 고장발생 시점을 예측하는 기술을 개발하기 위해 소형 스퍼기어 시험장치를 구축(Fig. 13)하였다. 이 장치의 기어 및 베어링에 스폴결함을 다양한 크기로 제작한 후 센서를 이용하여 결함 관련 특성을 측정하고 있다.




Fig. 13 Experiment setup of gear box and spalls of gear tooth and bearing

기어스폴의 결함측정을 위해서는 입출력 샤프트의 끝단에 엔코더(tachometer)를 설치하여 기어결함에 의한 전달오차(transmission error, TE)를 측정한다. 기어는 맞물림에 의해 회전을 하는데 이때 기어 변형으로 인해 강성이 유한값을 가지면서 이상적 회전각 대비 오차가 발생하는데 이를 TE라 하며, 이빨에 스폴결함이 있을 경우 강성은 더 작아지고 TE는 더 커지게 된다. 본 연구에서는 TE를 측정 후 물리해석 모델을 이용하여 기어의 강성을 추정 후, 유한요소해석을 이용하여 이것과 스폴결함 관계를 구하고, 스폴 크기를 추정한다. 이 때 기어의 강성이 건전성 지수 HI에 해당한다. HI를 구하고, 이것과 스폴결함 관계를 토대로 결함추정하는 과정을 Fig. 14에 보였다[7].

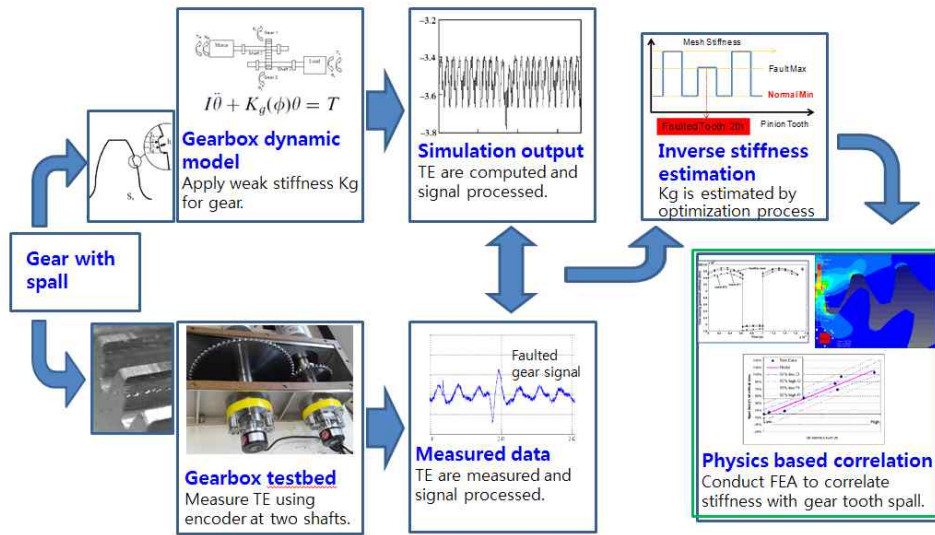




Fig. 14 Process of estimating gear spall size


베어링의 스폴결함은 내외륜에서 많이 발생하며, 그 크기가 1인치 이상이 되면 고장으로 간주한다. 이를 측정하기 위해 베어링 하우징에 가속도 센서를 부착하여 진동신호를 측정한다. 일반적으로 베어링은 물리 해석 모델이 너무 복잡하여 기어스플과 달리 물리모델 대신 순수하게 데이터 만 이용하여 고장을 예측한다. 본 연구에서는 이를 위해 FFT 및 엔트로피에 기반한 새로운 건전성지수(HI)를 개발하고 있다. 이를 기존에 연구된 베어링 문제에 적용한 사례를 그림 12에 보였다. 이는 미국 NASA Ames prognostics data repository에서 제공한 것(Fig. 15(a))으로, 베어링에 설치된 가속도 센서로부터 일정 시간간격으로 0.1초에 2560 샘플을 10초 간격으로 채취한 raw 데이터 (b)를 FFT 변환(c) 및 주파수별로 사이클에 따른 진폭거동을 모니터링(d)한다. 이들에 대해 각각 엔트로피를 계산(e), 이 중에서 엔트로피가 감소하는 것만 추출 및 평균(f)을 내어 이것을 건전성 지수(HI)로 정의하고, 이것을 가지고 고장예측 모델을 수립하는 것이다.




(a) NASA Ames prognostics data




(b) Raw data from bearing



(c) FFT results at each cycle



(d) Amplitude and (d) Entropy at each frequency

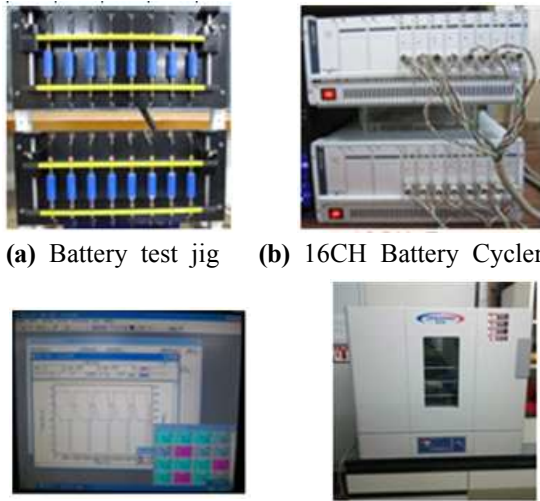


(f) Choose and average decreasing

Fig. 15 Illustration of extracting health index (HI) from bearing vibration data

3.3 리튬이온 배터리 용량열화

리튬이온 배터리는 높은 효율과 에너지 밀도로 여러 분야에서 사용이 늘어나고 있다. 하지만 사용량과 충전 방전 상황에 따라 배터리 물질이 화학적으로 불안정한 상태가 되어 폭발하거나, 용량이 저하되는 문제점은 아직도 완전히 해결되지 않고 있다. 특히 용량 감소는 배터리의 충전 상태를 예측하는 수치 모델에 오차를 유발하고, 이는 잔존 주행거리 예측 등 배터리의 BMS 기능에 대한 신뢰성에 문제를 발생시킨다. 본 연구에서는 이와 관련한 배터리의 건전성(State of Health:SOH)과 잔존수명(State of Life, SOL)을 실시간 평가하기 위해 배터리 실험장치(Fig. 16)를 구축하였다. 여기에 소용량 배터리를 투입하여 다양한 온도 및 충전 조건에서 배터리 용량저하를 유도하고, 일정 사이클 마다 충전 전압, 전류 곡선을 측정하고 있다.




(a) Battery test jig (b) 16CH Battery Cycler
(c) Battery test program (d) Environmental chamber
Fig. 16 Experimental setup of battery degradation

최근 배터리의 충전 거동을 시뮬레이션할 수 있는 다양한 스케일의 전기화학적 해석모델이 개발되어 있다. 본 연구에서는 이 중에서 Pseudo 2D 수치모델을 활용하며, 이를 위해서는 Fig. 17와 같은 해석 파라미터가 필요한데, 충전방전이 거듭되면서 이들 파라미터가 변화(또는 열화)를 겪게 된다. 본 연구에서는 충전시 측정된 전압곡선을 활용하여 이들을 추정하며, 이렇게 추정된 파라미터들이 건전성 지수 HI로 활용된다. 이것을 이용하면 현 시점에서 정확한 배터리 해석을 할 수 있으며, 용량계산은 물론, 여러가지 방전조건에서 시뮬레이션하는 것이 가능하다[8].

4. 결론

본 연구에서는 가혹환경에서 운용되는 고안전성 시스템의 사고예방을 위해 실시간으로 안전 도를 평가하고 고장을 예측하는 건전성 예측 및 관리(PHM) 기술을 소개하였다. 이를 위한 핵심기술로서 물리기반 및 데이터기반 방법, 이들을 융합적으로 활용하는 방법, 다양한 불확실성을 고려하기 위한 베이지안 방법론 등을 소개하였다. 이의 응용예로서 항공기 동체 피로균열, 기어장치 결함 및 배터리 용량열화에 대해 각각 실증 시험장치를 운영, 가동 중 고장발생 시점을 예측하고, 실제로 발생한 결과와 비교함으로써 개발된 기술의 유효성을 검증하는 사례도 함께 제시하였다. 본 연구를 통해 운용 중인 시스템의 신뢰도를 극대화함과 동시에 성능유지비용을 획기적으로 절감하는 것이 가능할 것으로 판단하며, 이런 점에서 PHM 연구의 미래는 매우 밝다고 생각된다.



Mechanism of capacity fade	Possible affected parameters
Capacity fade during formation cycles	$x_{20}, x_{n0}, \epsilon_p, \epsilon_n, D_{2p}, D_{2n}, k_p, k_n$
Overcharging that results in decrease in capacity in both positive and negative electrodes	D_{2p}, D_{2n}, k_p, k_n
Decomposition of the electrolyte during the reduction process	D_1, k_p, k_n
Self-discharge depending on the purity of materials used in manufacturing	D_{2p}, D_{2n}, k_p, k_n
Formation of a passive film on the electrode that grows in thickness as the cycle number increases	k_p, R_{film}
Loss of active material during cycling	$x_{20}, x_{n0}, \epsilon_p, \epsilon_n, \epsilon_{f,p}, \epsilon_{f,n}$

Fig. 17 P2D electrochemical model and its input parameters

참고 문헌

- [1] G. Vachtsevanos, et al., "Intelligent Fault Diagnosis and Prognosis for Engineering Systems," John Wiley & Sons, 2006.
- [2] D. An, N. H. Kim, and J. H. Choi, "Practical options for selecting data-driven or physics-based prognostics algorithms with reviews," Reliability Engineering & System Safety, 2014.
- [3] D. An, N. H. Kim, and J. H. Choi, "Statistical Aspects in Neural Network for the Purpose of Prognostics," AIAA, National Harbor, Maryland, January 2014
- [4] D. An, J. H. Choi, and N. H. Kim, "Practical Use of Accelerated Test Data for the Prognostics Methods," Annual Conference of the Prognostics and Health Management Society, New Orleans, October 2013.
- [5] A. Gelman, J. B. Carlin, H. S. Stern, and D. B. Rubin, "Bayesian data analysis," Chapman and Hall, New York, 2004.
- [6] D. An, J. H. Choi, and N. H. Kim, "Identification of correlated damage parameters under noise and bias using Bayesian inference," Structural Health Monitoring, 2011
- [7] 임상혁, 박성훈, 최주호, "풍력 터빈 기어박스 내의 기어 균열에 대한 모델 기반 고장 진단," 한국전산구조공학회 논문집 제26권 제6호, pp. 447-454, (2013.12)
- [8] J. Lee, J. H. Choi, and W. Sung, "MCMC (Markov Chain Monte Carlo) Approach for Parameter Estimation in Li-ion Battery," CJK-OSM8 conference, Gyeongju, May 2014.

저자 소개



최 주 호

1981년 한양대 기계공학과 졸업.
 1983년 한국과학기술원 기계공학과 석사. 1987년 동 대학 박사. 1987년~1988년 University of Iowa 박사 후 연구원. 1989년~1996년 삼성코닝(주) 선임연구원, 수석연구원. 1997년~현재 한국항공대학교 항공우주 및 기계공학부 조교수, 부교수, 교수. 관심분야는 최적설계, 신뢰성공학, 신뢰성분석 및 설계, 건전성 예측 및 관리 등