

# 배터리 잔존 유효 수명 예측을 위한 전기화학 모델 기반 고장 예지 및 건전성 관리 기술

최요환\*, 김홍석<sup>o</sup>

## Prognostics and Health Management for Battery Remaining Useful Life Prediction Based on Electrochemistry Model: A Tutorial

Yohwan Choi\*, Hongseok Kim<sup>o</sup>

### 요약

고장 예지 및 건전성 관리 기술(Prognostics and Health Management; PHM)은 시스템의 현재 상태를 진단하고 향후 발생 가능한 고장 시점을 신뢰성 있게 예지하는 기술로써 유지 보수 비용의 절감 및 시스템의 안정성 향상을 꾀하고자 하는 다양한 산업분야에서 활발하게 이용되고 있다. 스마트 그리드의 에너지 저장장치, 전기차, 스마트폰, 항공우주산업 등 광범위한 사용처에서 중요한 에너지원으로 사용되고 있는 배터리 또한 성능 저하 및 폭발의 위험성으로부터 자유로울 수 없기 때문에 이러한 고장 예지 및 건전성 관리 기술이 반드시 적용되어야 할 어플리케이션이다. 본 논문에서는 PHM의 기본적인 개념을 소개함과 동시에 배터리의 잔존 유효 수명(Remaining Useful Life; RUL)을 예측하는 각종 알고리즘 및 성능 평가 지표 서술에 초점을 맞추도록 한다. 더불어 배터리의 기능적 동작 원리 및 전기화학 기반의 모델링에 대한 설명을 통해 향후 잠재적인 가능성을 지닌 배터리의 전반적인 특성에 대한 깊은 이해 및 응용 기술에 대한 통찰력을 제시하고자 한다.

**Key Words** : Remaining Useful Life, Lithium-ion Battery, Prognostics and Health Management, Electrochemistry

### ABSTRACT

Prognostics and health management(PHM) is actively utilized by industry as an essential technology focusing on accurately monitoring the health state of a system and predicting the remaining useful life(RUL). An effective PHM is expected to reduce maintenance costs as well as improve safety of system by preventing failure in advance. With these advantages, PHM can be applied to the battery system which is a core element to provide electricity for devices with mobility, since battery faults could lead to operational downtime, performance degradation, and even catastrophic loss of human life by unexpected explosion due to non-linear characteristics of battery. In this paper we mainly review a recent progress on various models for predicting RUL of battery with high accuracy satisfying the given confidence interval level. Moreover, performance evaluation metrics for battery prognostics are presented in detail to show the strength of these metrics compared to the traditional ones used in the existing forecasting applications.

\* 본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20161210200360)

• First Author : Sogang University Department of Electronic Engineering, yohwanchoi@sogang.ac.kr, 학생회원

o Corresponding Author : Sogang University Department of Electronic Engineering, hongseok@sogang.ac.kr, 종신회원

논문번호 : KICS2017-02-044, Received February 16, 2017; Revised April 10, 2017; Accepted April 10, 2017

## I. 서 론

시스템의 현재 상태를 진단(diagnosis)하고 미래 성능을 예지(prognostics)하는 기술은 시스템의 안정적인 운영과 유지비용 감소 및 사고 발생 위험성을 최소화하는 측면에 있어서 매우 중요한 의미를 가진다. 이렇듯 시스템 운영의 불확실성을 관리하기 위한 기술을 고장 예지 및 전전성 관리 기술(Prognostics and Health Management; PHM)이라고 하며 기계설비, 제조, 통신 및 군사용 등 다양한 산업 분야에서 활용되고 있다<sup>1,2)</sup>. 고장특성이 언제 발생할지에 대한 예측과 판단이 가능하다면 시스템 동작을 최적화하기 위한 여러 조치를 취할 수 있다. 또한 일정 주기마다 정기적으로 정비를 수행하던 기존의 패러다임에서 벗어나 PHM을 통해 신뢰성 있게 예측된 시점에만 정비를 하기 때문에 비용 절감 측면에서 큰 효과를 거둘 수 있는 장점이 존재한다. 잔존 유효 수명(Remaining Useful Life; RUL)은 현재 시점에서 시스템의 고장이 발생할 미래 시점까지 남아있는 기간으로 정의할 수 있고, 이를 신뢰성 있게 예측하는 것이 시스템의 상태 진단 및 예지 기술을 통한 안전성 확보와 시스템의 장기 운용측면에서 매우 중요하다. ISO 13381-1에서는 고장 예지의 정의를 통해 고장이 발생할 시점을 예측하고 계산된 잔존수명과 연관된 신뢰성 구간을 추정하는 방법에 대한 방향성을 제시하고 있다<sup>3)</sup>.

스마트 그리드가 에너지 분야의 새로운 패러다임으로 떠오르고 있는 현대 사회에서 배터리는 이동성을 갖춘 전자장비에 동력원을 공급하는 핵심 구성요소로서 스마트폰, 전기 자동차(Electric Vehicle; EV), 에

너지 저장장치(Energy Storage System; ESS), 사물 통신 분야의 무선 네트워크 디바이스 및 항공우주장비 등 다양한 산업분야에서 널리 활용되고 있다<sup>4,5)</sup>. 하지만 내부 또는 외부 요인으로 인한 고장 시에 야기되는 성능 저하 및 폭발로 인한 사고는 그림 1과 같이 심각한 인명 손실 및 재산 피해를 유발할 수 있다. 때문에 배터리 분야에 PHM 적용이 반드시 필요하며, 이를 통해 상태를 진단하고 잔존 유효 수명을 예측하는 과정이 매우 중요하다고 할 수 있다. 배터리는 내부의 화학 반응에 의해 발생한 화학적 에너지를 전기 에너지로 변환하는 장치이다. 하지만 시간이 지남에 따라 반복되는 화학 반응으로 인하여 배터리의 출력 및 저장 능력에 영향을 주는 물질들이 감소하고 그로 인한 성능 저하가 필수적으로 수반된다.

본 논문에서는 배터리의 잔존 유효 수명 예지 및 전전성 관리 기술에 활용되는 다양한 알고리즘들에 대해 살펴보고 특히 전기화학 기반 모델링의 높은 잠재 가능성에 대한 통찰력을 제시하고자 한다. 잔존수명은 예지 기술에 속하는 부분이므로 진단 기술에 대한 설명은 개념적인 수준에서 다루고 예지 기술의 분류 및 잔존 유효 수명에 대한 내용을 주로 다루고자 한다. 이어지는 논문의 II장에서는 배터리의 기본적인 충방전 원리를 설명하고, III장에서는 전기화학 기반 모델링을 포함한 배터리 모델링 기법을 소개한다. IV장에서는 RUL 예측 기법을 분류하고, V장을 통해 RUL 예측 성능을 평가하기 위한 지표를 제시한다. 마지막으로 VI장에서는 논문의 결론을 맺는다.

## II. 배터리 기본 동작 원리

본 논문에서는 현재 2차 전지로써 산업계에서 가장 널리 상용화되고 있는 리튬이온 배터리를 기준으로 충방전 과정을 소개한다. 배터리를 구성하는 화학물질에 따른 성능 및 특성 차이는 어느 정도 존재하나 충방전의 기본 원리는 동일하다. 배터리를 구성하는 기본 요소는 양극(positive electrode), 음극(negative electrode), 분리막(separator) 및 전해액(electrolyte)으로 분류할 수 있다<sup>6)</sup>. 양극은 주로  $LiCoO_2$ 와 같은 금속이 결합된 리튬산화물로 이루어져 있으며 최근에는  $LiFePO_4$ 와 같은 리튬인산철이 저렴한 가격으로 많이 사용되고 있다. 양극은 리튬이온 배터리 제조비용 중 가장 큰 비중을 차지한다. 음극은 탄소, 실리콘 또는 흑연(graphite)이 사용되며 흑연과 리튬이 결합된  $Li_xC$ 와 같은 물질로서 주로 구성되어 있다. 양극과



그림 1. 배터리 폭발로 인한 각종 사고발생 사례  
Fig. 1. Examples of battery explosion

음극 모두 충전전 과정을 통해 리튬 이온을 가역적으로 흡수/방출하는 과정을 반복하며 전극 내로 리튬 이온이 삽입(intercalation)되어 전자와 전기적 중성을 이루면서 전기 에너지가 저장되는 원리이기 때문에 이온을 최대한 많이 저장하기 위해 다공성(porous) 물질의 특징을 지닌다. 분리막은 양극과 음극의 물리적인 접촉을 방지하며 마이크로미터 단위의 미세한 구멍을 통해 이온의 흐름을 가능하게 하는 다공성 필름이다. 절연성이 좋아야 하며 전기화학적 안정성 또한 요구된다. 마지막으로 전해액은 리튬 이온이 양극과 음극 사이를 이동할 수 있게 하는 이온 전도도가 높은 매개체이다. 충전과 방전의 기본 원리는 다음과 같다<sup>[8]</sup>.

### 2.1 방전(Discharge)

그림 2와 같이 방전이 수행될 때에는 음극에서의 산화반응을 통해 식 (1)의 이온화 과정을 거쳐 리튬 이온과 전자가 생성된다. 리튬 이온과 전자는 각각 전해액과 외부 도선을 통해 양극으로 이동하고 전류는 전자의 이동방향과 반대로 흐르게 된다. 양극에서는 이동된 리튬 이온과 전자가 반응하여 식 (2)와 같이 환원하게 된다.

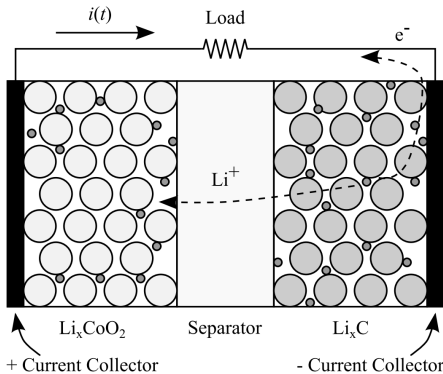




그림 2. 방전 시 리튬 이온 배터리 내부<sup>[8]</sup>  
Fig. 2. Li-ion battery during discharging

### 2.2 충전(Charge)

그림 3과 같이 충전과정은 방전과 반대로 양극에서 산화반응이 발생한다. 리튬 이온과 전자는 양극에서 음극으로 이동하며 음극에서는 이를 통한 환원반응이





그림 3. 충전 시 리튬 이온 배터리 내부<sup>[8]</sup>  
Fig. 3. Li-ion battery during charging

진행된다. 이 과정은 식 (3-4)의 과정을 통해 확인할 수 있다.



## III. 배터리 모델링

배터리의 현재 상태를 정확하게 파악하는 것은 향후 배터리 활용 및 제어측면에 있어서 높은 자유도를 제공하는, 매우 중요한 과정이다. 화학 에너지를 전기 에너지로 변환시키는 비선형적 특성을 지닌 배터리는 다양한 방법들로 모델링 될 수 있으며 이 장에서는 일반적으로 많이 사용되는 등가회로 모델(Equivalent Circuit Model; ECM)과 높은 정확성을 지닌 전기화학 모델(Electrochemical Model)에 대해 설명하도록 한다.

### 3.1 등가회로 모델

그림 4와 같이 전기회로의 저항, 캐패시터 등 각종 소자들을 활용하여 배터리의 특성을 나타낸 가장 보편적인 배터리 모델로써 구현과 적용이 용이하다는 장점은 있지만 정확성은 전기화학 모델에 비해 상대적으로 떨어진다는 단점이 존재한다. 배터리 충전상태(State of Charge; SOC) 예측을 위한 ECM의 상태공간 모델은 아래 식 (5)와 같이 표현할 수 있다.

$$\begin{aligned} x_{k+1} &= x_k - \eta T i_k / C_r + w_k, \\ y_k &= OCV(x_k) - i_k R + h_k + v_k \end{aligned} \quad (5)$$




그림 4. 등가회로 배터리 모델[9]  
Fig. 4. Equivalent circuit model

$x_{k+1}$ 은 시간  $k+1$ 일 때의 SOC이며 충방전 효율  $\eta$ , 전류  $i_k$ , 적산 시간  $T$  및 정격 용량  $C_r$ 일 때의 물량 적산량은  $\eta T i_k$ 이다.  $y_k$ 는 단자 전압(terminal voltage)으로서 개방회로전압(Open Circuit Voltage; OCV)과 내부 저항  $R$ , 히스테리시스 특성으로 인해 발생하는 전압 변화  $h_k$ 와의 관계로 표현된다. 히스테리시스 특성은 이전 전압의 상태 변화에 따라 전압값이 변하는 특성을 뜻하며

$$h_k = \exp\left(-\left|\frac{\eta_i i_{k-1} \gamma \Delta t}{C_r}\right|\right) h_{k-1} + \left(1 - \exp\left(-\left|\frac{\eta_i i_{k-1} \gamma \Delta t}{C_r}\right|\right)\right) M \quad (6)$$

와 같이 히스테리시스 모델로 표현된다.  $\gamma$ 는 감소 비율을 조절하는 양수이며,  $M$ 은 polarization 계수이다[9].

### 3.2 전기화학 모델

배터리 내부 입자들의 물리적인 움직임을 편미분 방정식(Partial Differential Equations; PDE) 및 시공간에 대한 상미분 방정식(Ordinary Differential Equations; ODE)로 수식화한 모델링으로써 정확성은 높지만 수학적 복잡성이 높다는 단점이 존재한다. 전기화학 모델을 설명하기 위해 요구되는 복잡한 미분 방정식들은 참조 논문들을 통해 확인할 수 있다[7,10-11]. 초기에 제안된 Doyle-Fuller-Newman (DFN) 모델은 다공성 양극 셀과 리튬 이온 농도 변화 등을 모델링 하였으며 기본적인 포텐셜의 옴의 법칙(Ohm's law)을 포함한 이온 농도를 나타내는 픽스의 법칙(Fick's law) 및 전극에서의 반응에 의한 전류밀도 관계를 나타내는 버틀러-볼머 방정식(Butler-Volmer equation) 또한 나타낸다. 하지만 PDE의 복잡도가 너무 높고 분

석적(analytical) 해가 존재하지 않는다는 단점 때문에 공간적 이산화(spatial discretization)에 기반한 finite difference, finite element 및 finite volume과 같은 근사적 접근방법이 연구되기 시작했다. Pseudo-two-dimensional model (P2D)이 대표적이며 실제 실험 결과들과 비교했을 때 매우 정확하게 배터리의 내부 상태를 예측했지만 여전히 계산 복잡도 및 시간 측면에서 비효율적이었다. 때문에 온보드(onboard) 제어 활용 측면에서 적절하지 못하였다[9]. 다음 세대로 등장한 모델은 다공성 전극 이론에 기반한 reduced-order model(ROM)이며, 이 중 가장 잘 알려진 모델이 아래 그림 5와 같이 전해액 상(electrolyte phase) 내의 변화를 무시하는 가정을 바탕으로 단일 파티클로서 양극을 표현한 single-particle model(SPM)이다[10]. 하지만 1C 이하의 낮은 방전율(C-rate)에서는 기존의 모델들과 별 차이 없는 정확성을 보이지만 높은 방전율에서는 정확성이 급격히 떨어지는 한계를 보인다. 이는 SPM이 높은 전해액 전도율을 가정하고 있기 때문이다.

전기화학 모델이 최근 큰 주목을 받고 있는 이유는 컴퓨터 하드웨어의 발전으로 인해 주요 단점으로 거론되던 계산 복잡도로 인한 실시간 처리 이슈가 상당히 줄어들고 있으며 또한 다른 모델들에 비해 배터리 내부 입자의 환경 조건 변화에 따른 농도, 움직임 등의 변화를 가장 민감하고 정확도 높게 반영할 수 있는 모델이기 때문이다.




그림 5. Single particle 모델의 개념도[11]  
Fig. 5. Basic concept of SPM

## IV. RUL 예측을 위한 고장 예지 기법

PHM의 기능적 요소는 크게 진단과 예지로 구분할 수 있다. 이 장에서는 진단과 예지의 개념적 구분을 통해 기능적 역할에 대한 차이점을 확실히 인지하고

자 한다. 다만 본 논문에서는 예지 기술 및 배터리 잔존 유효 수명 예측에 좀 더 초점을 맞추고 있으므로 진단에 관련된 내용은 상대적으로 간단하게 짚고 넘어가도록 한다.

#### 4.1 진단(Diagnosis)

진단은 용어 그대로 배터리의 상태, 발생한 문제 및 조건의 특성을 조사/분석하는 단계이다<sup>[12]</sup>. 즉 배터리 내부 시스템에서 발생한 고장을 인지하고 감지하는 일련의 과정으로 정의 가능하다. 그림 6과 같이 진단 과정은 고장 발견(fault detection), 고장 분리(fault isolation) 및 고장 확인(fault identification)의 세 단계로 구분 지을 수 있다<sup>[13]</sup>. 먼저 고장 발견을 통해 평소의 운영조건에서 벗어나는 움직임을 감지, 보고하고 고장 분리과정을 통해 어떤 부분에서 고장이 발생했는지 또는 발생중인지 근원지를 분리 및 감지한다. 마지막으로 고장 확인과정을 통해 고장의 범위와 그 특성을 추정한다. 배터리 분야에서는 SOC 추정을 통해 전압 또는 전류 측정 및 모니터링과 같은 다양한 추정 방식으로 배터리의 현재 상태를 진단하고 있다<sup>[14]</sup>.

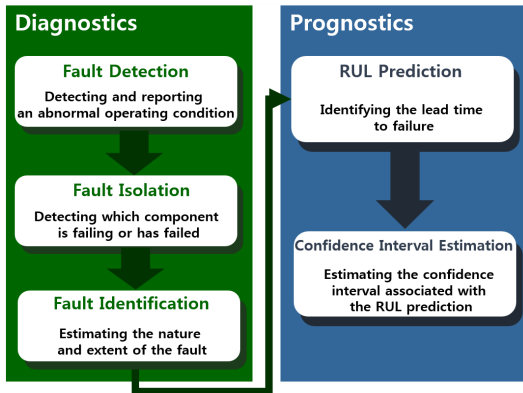


그림 6. 진단과 예지의 기능적 구성 관계를 나타낸 개요도 [13]  
Fig. 6. Basic steps involved in obtaining a prognostic result and the relationship to diagnostics

#### 4.2. 예지(Prognosis)

예지는 이용 가능한 데이터와 적절한 알고리즘을 바탕으로 미래의 결과를 예측하는 일련의 과정이다<sup>[12]</sup>. 여기에서 미래의 결과란 배터리가 어느 시점에 수명이 다할 것인지, 얼마나 미리 신뢰성 있게 그 시점을 예측할 수 있는지 등 다양하게 정의된 예측 요구조건이다. 따라서 실제로 고장이 발생할 시점과 최대한 가깝게 예측하는 것이 관건이며 이를 위해 다양한 불확실성을 알고리즘에 반영하여 신뢰구간을 도출하고

있다. 예지 과정은 크게 RUL 예측과 신뢰구간 추정(confidence interval estimation)으로 구분 지을 수 있다. 앞서 언급한 진단의 가장 마지막 과정인 고장 확인을 통해 시스템의 현재 상태에 대한 전반적인 데이터가 예지 과정에 입력되면 이를 바탕으로 다양한 예측 알고리즘과 결합하여 배터리의 수명이 다하는 시점, 즉 RUL을 예측한다. 그 이후에는 RUL 예측과 연관된 신뢰구간을 추정 및 적용하여 다른 불확실 요소들이 어떻게 RUL에 영향을 미치는지 또는 얼마나 빨리 배터리 노화가 진행될 것인지 등에 대한 판단을 수행하게 된다. 이와 관련된 내용은 V장에서 RUL 예측 성능 지표와 함께 다루도록 한다.

지금부터는 그림 7과 같이 네 가지 큰 분류를 통해 RUL 예측 알고리즘을 설명하고 그 특징에 대해 서술하도록 한다<sup>[15]</sup>.

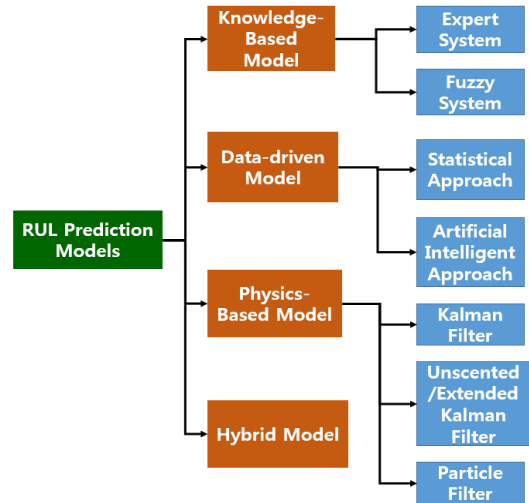


그림 7. RUL 예측 모델 분류  
Fig. 7. Model categories for prediction of remaining useful life

##### 4.2.1 지식 기반 모델(Knowledge-based model)

전문가의 지식과 공학적 경험을 토대로 관측된 과거 측정 데이터 또는 이벤트를 가지고 RUL을 추론하는 방법이다. 이러한 전문가 시스템(expert system)은 이해가 쉽고 결과 해석도 용이하다는 장점이 있지만 매우 정확하고 철저한 룰에 기반하기 때문에 입력과 출력의 개수가 증가함에 따라 복잡도가 기하급수적으로 증가한다는 단점이 있다<sup>[16]</sup>. 퍼지 시스템(Fuzzy system) 또한 지식 기반 모델 중 하나이며 전문가 시스템보다 적은 룰을 필요로 하고 신뢰성과 관련된 제한조건이 고려된다는 점에서 상대적으로 장점을 가지

나 시스템 특성에 맞는 적절한 멤버십 함수 (membership function)를 디자인해야 한다는 단점이 존재한다<sup>13,17)</sup>.

4.2.2 데이터 중심 모델(Data-driven model)

관측된 데이터만으로 시스템의 상태와 RUL을 예측하는 접근방식이다. 이러한 데이터들을 기반으로 통계적(statistical) 접근 또는 인공지능적(artificial intelligence) 접근을 취할 수 있다. 통계적 접근은 일반적으로 autoregressive integrated moving average (ARIMA) 또는 autoregressive moving average (ARMA)와 같은 시계열 회귀분석(regression) 방식을 예로 들 수 있다<sup>18)</sup>. 하지만 단기간 예측에서 유효한 반면에 장기간 예측에서는 안정적이지 못한 단점이 존재한다. 또한 고장 예지를 함에 있어서 시스템에서 측정되는 신호와 시스템에 노이즈가 많이 포함되어 있고 비단조적(non-monotonic) 특성을 보이는 것은 선형 회귀분석법이 안정적인 결과를 도출하지 못하는 이유가 된다. 인공지능적 접근에서는 주로 neural network(NN), support vector machine (SVM) 또는 relevance vector machine(RVM) 방식 등이 사용된다<sup>18-19)</sup>. NN을 통해서 는 보유한 방대한 데이터를 학습 시켜 그로인해 시스템의 특성을 추출 하고 고장 확률을 계산하여 특정 한계치보다 확률이 작아지는 순간의 시점을 예측된 RUL로 계산하게 된다. SVM 및 RVM은 일반적으로 n 차원의 데이터를 최대 마진을 보장하는 범위 내에서 n-1 차원의 초평면(hyperplane)으로 분류하는 알고리즘이며 확률기반의 결과가 부재하다는 단점으로 인해 배터리 진단 분야에서는 필터 알고리즘과 함께 활용하는 형식으로 주로 사용되고 있다<sup>20)</sup>.

4.2.3 물리 기반 모델(Physics-based model)

RUL 예측을 위해 시스템의 퇴화 과정을 수학적으 로 모델링 하는 접근방식이다. 수식적 접근을 통해 시스템 동작의 물리적인 메커니즘을 직관적으로 이해 가능하다는 장점이 있는 반면, 복잡한 시스템에는 활용하기가 어렵다는 단점 또한 존재한다. 복잡한 시스템일수록 고장과 연관된 모든 동작 조건 및 파라미터 들 간의 상관관계를 파악하는 것이 불가능하기 때문이다. 또한 모델 파라미터들을 정립하는 과정 또한 방대한 실험을 통한 결과를 필요로 하기 때문에 시스템의 특성에 맞게 주의를 기울여 적용해야 한다. 선형적인 시스템 모델 특성을 가진 경우에는 선형 칼만 필터 (Kalman Filter; KF) 알고리즘이 주로 사용된다<sup>21)</sup>. 칼

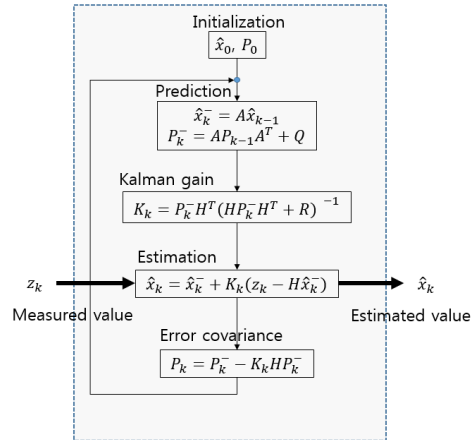


그림 8. 선형 칼만 필터의 기본 동작  
Fig. 8. Basic process of linear Kalman filter

만 필터는 그림 8과 같이 시스템 모델 또는 측정 데이터에 포함된 노이즈로부터 강건하게 구하고자 하는 상태 변수(state variable)를 재귀적으로 예측하는 알고리즘이다. 비선형 시스템 모델의 경우에는 자코비안 (Jacobian)을 활용한 확장 칼만 필터(Extended Kalman Filter; EKF)를 사용할 수 있다<sup>22)</sup>. 한 걸음 더 나아가 비선형 함수 자체를 모사하지 않고 이 함수의 확률 분포를 Unscented Transformation 방법으로 도출하는 무향 칼만 필터(Unscented Kalman Filter; UKF) 방식도 활용되고 있다<sup>23)</sup>. 파티클 필터(Particle Filter; PF) 알고리즘은 칼만 필터와는 달리 비선형 시스템 및 비가우시안 분포 가정하에서도 적용될 수 있다는 장점이 있으며 상태 방정식이 1차 마르코프 프로세스형태라는 가정이 있기 때문에 현재 시간의 상태변수가 직전 시간의 상태변수에 의해 결정되는 특성을 지닌다<sup>24-25)</sup>.

4.2.4 하이브리드 모델(Hybrid model)

하나의 모델만 이용했을 때에 발생하는 단점을 보완하기 위해 앞서 소개된 모델들을 조합하여 각 모델이 지니는 단점을 극복하는 하이브리드 모델에 대한 연구가 활발히 이루어지고 있다<sup>26-27)</sup>. 이 장에서는 그 중에서 가장 많은 연구가 이루어지고 있는 데이터 중심 모델과 물리 기반 모델의 조합방법에 대한 내용을 소개하고자 한다<sup>15)</sup>. 그림 9와 같이 측정된 신호 데이터에서 시스템의 특성을 추출한 뒤 측정 모델을 구성하는 과정은 수많은 데이터들을 기반으로 하는 데이터 중심 모델을 사용하는 것이 더욱 정확성 높은 시스템 모델의 구성을 가능하게 한다. 이와 더불어 시스템




그림 9. 데이터 중심 모델과 물리 기반 모델이 혼용된 접근 방식 개요도[15]  
 Fig. 9. A hybrid approach which consists of a data-driven model to deduce the measurement model and a physics-based model to predict the RUL

의 물리적 특성을 잘 반영할 수 있는 물리 기반 모델을 활용하여 실제 배터리 내부의 활물질과 전해액 간의 상호작용 및 이온의 가역/비가역 반응으로 유발되는 퇴화현상을 구성 및 연동하면 각 모델링이 가지는 단점은 보완하고 장점이 극대화되는 새로운 유형의 RUL 예측 모델을 도출할 수 있다<sup>[28]</sup>.

### V. RUL 예측 성능 평가 지표

정확성을 평가하는 Mean Squared Error(MSE) 또는 Mean Absolute Percentage Error(MAPE)와 같은 기존의 지표들은 일반적인 시스템의 통계적인 특성을 설명할 수 있으나 연속적인 정보 업데이트가 시간이 지남에 따라 지속적으로 이루어지면서 예측 성능의 향상이 일어나는 RUL 예측 기법의 특성을 설명하기에는 한계가 존재한다. RUL의 예측은 얼마나 미리 예측을 해야 정확하게 신뢰도 구간추정이 가능한지에 대한 고려가 필요하므로 모든 시간 범위에서 신뢰성 높은 강건한 지표가 요구된다. NASA Ames research center에서 수행된 연구를 통해 대표적인 네 가지 지표에 대해 알아보도록 한다<sup>[16,29-30]</sup>. 평가 지표를 이해하기 위해 필요한 파라미터들은 표 1.과 같이 정리할 수 있다. 그림 10에서 빨간색 점들은 예측 RUL을 나타낸 것이고 파란색 점들은 실측 RUL들을 나타낸 것으로서 l번째 테스트를 진행했을 때 시점 t<sub>k</sub>에서의 예측 RUL을 r<sup>l</sup>(k), 실측 RUL을 r<sup>\*</sup>(k)로 각각 정의한다. 이 때 t<sub>EoUP</sub>와 t<sub>EoP</sub> 사이의 특정 시점 즉, 시정조치(corrective action)가 이루어지는 시점부터 End of Life(EoL)가 발생하는 t<sub>EoL</sub>\* 사이의 기간을 logistics lead time이라고 하며 시정조치가 이루어지는데 소요되는 시간이다. 상황에 따라 다르겠지만 시정조치는 정비가 될 수도 있고 시스템을 안전 운행 모드로 전환하는 조치가 될 수도 있다.

표 1. 성능 지표에 사용되는 파라미터[29]  
 Table 1. Nomenclature for performance metric

파라미터	설명
EoL	End of Life, time instant when a RUL prediction crosses a failure threshold
EoP	End of Prediction, time index for the last RUL prediction before EoL is reached
EoUP	End of Useful Predictions, time index beyond which it is futile to update a RUL prediction because no corrective action is possible in the time available before EoL
i <sub>αβ</sub>	First time index when predictions satisfy β-criterion for a given α, $\min\{j   (j \in P) \wedge (\pi[r(j)]_{-\alpha}^{+\alpha}) \geq \beta\}$
P	Set of all time indices when predictions are made
β	Minimum desired probability threshold
r(j)	Predicted RUL at time index t <sub>j</sub>
π[r(j)] <sub>-α</sub> <sup>+α</sup>	Probability mass of the prediction PDF within the α-bounds, $\alpha^+ = r_* + \alpha t_{EOL}, \alpha^- = r_* - \alpha t_{EOL}$
λ	Time window modifier, $t_\lambda = t_p + \lambda(t_{EOL} - t_p)$ where λ ∈ [0, 1]
r*(t <sub>i</sub> )	Ground truth RUL at time index t <sub>i</sub>
r'(t <sub>i</sub> )	Appropriate central tendency point estimate of the predicted RUL distribution at time index t <sub>i</sub>
C <sub>M</sub>	Euclidean distance between the center of mass (x <sub>c</sub> , y <sub>c</sub> ) and (t <sub>p</sub> , 0)
M(i)	Non-negative prediction accuracy or precision metric with a time varying value
(x <sub>c</sub> , y <sub>c</sub> )	Center of mass of the area under the curve M(i) between t <sub>p</sub> and t <sub>EoUP</sub>




그림 10. 주요한 시간 인덱스들의 정의/개념을 도식한 그래프[29]  
 Fig. 10. An overview depicting critical prognostic time indices

5.1 예지 범위(Prognostic Horizon)

Prognostic Horizon(PH)은 실제 EoL 근처에서 특정 예리 마진 범위 내로 예측하는지 여부를 살펴볼 때에 사용하는 지표이다. 즉, 예측이 처음으로 특정 성능 기준을 만족했을 때의 시점과 EoL의 시점간의 차이를 나타낸다. 성능 요구조건은 실제 EoL 근처의 허용 가능한 예리 범위  $\alpha$ 로 지정되며,  $\alpha$ 는 시정조치를 취하기 위해 요구되는 추정 시간에 따라 가변한다. PH는 수식적으로 식(7)과 같이 정의된다.

$$PH = t_{EoL} - t_{i_{\alpha\beta}} \quad (7)$$

그림 11(a)는 두 개의 어떤 RUL 예측 알고리즘의 PH 결과를 나타내었다. 두 번째 알고리즘(파란색)의 PH가 더 길기 때문에 필요한 조치를 취할 수 있는 시간적 여유가 더 많이 생겨서 좋은 성능을 나타낸다고 해석할 수 있지만 자세히 보면 첫 번째 알고리즘(빨간색)과의 성능차이도 그리 크지 않은 것을 알 수 있다. 이것은 오직 추정된 포인트 하나의 값만 이용했기 때문이며 그림 11(b)와 같이  $\beta$ -criterion을 사용함에 따라 개선가능하다.  $\beta$ 보다 큰 확률질량(probability

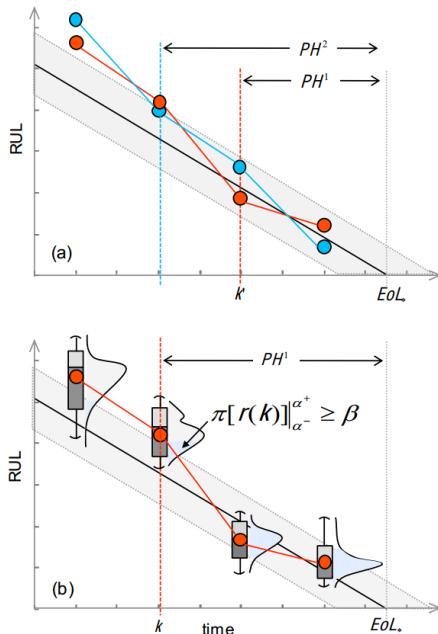


그림 11. Prognostic Horizon 지표를 이용한 두 알고리즘의 결과[29]  
Fig. 11. (a) Illustration of Prognostics Horizon by comparing two algorithms based on point estimates (distribution means) (b) PH based on  $\beta$ -criterion results in a more robust metric

mass) 조건을 적용하면 첫 번째 알고리즘 또한 주어진  $\alpha$  범위 내에 존재하여 두 번째 알고리즘과 동일한 PH 결과를 도출한다. 이를 통해  $\beta$ -criterion 조건이 좀 더 강건한 지표 생성에 기여함을 확인할 수 있다.

5.2  $\alpha-\lambda$  Performance

특정 시점에 제한 범위 내에 예측이 들어왔는지 여부를 판단하는, 즉 예측 결과의 우수성을 나타내는 지표이다. 우선 식 (8)의  $\alpha-\lambda$  accuracy는  $\beta$ -criterion을 만족하면 1, 그 외에는 0을 갖는 바이너리(binary) 형태의 값을 가진다.

$$\alpha-\lambda \text{ Accuracy} = \begin{cases} 1 & \text{if } \pi[r(t_\lambda)]_{-\alpha}^{+\alpha} \geq \beta \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

$\alpha$ 는 정확도 조정자(accuracy modifier)로서 0과 1 사이의 값을 가지며 예를 들어  $\alpha=0.1$ 일 경우 예측이 실측값 범위 기준, 정확도 10% 내에 들어올 경우를 뜻한다. 이 지표는 그림 12와 같이 시간이 지남에 따라 정확도 범위(어두운 영역)가 줄어들기 때문에 PH보다 더욱 설득력 있는 지표로 판단된다. 이 지표에서는  $\pi[r(t_\lambda)]_{-\alpha}^{+\alpha}$ 을 해석하는 데에 있어서 PH의 경우와는 다른 의미로서  $\alpha^+ = r_*(t_\lambda) + \alpha r(t_\lambda)$  및  $\alpha^- = r_*(t_\lambda) - \alpha r(t_\lambda)$ 와 같이 사용되었다.

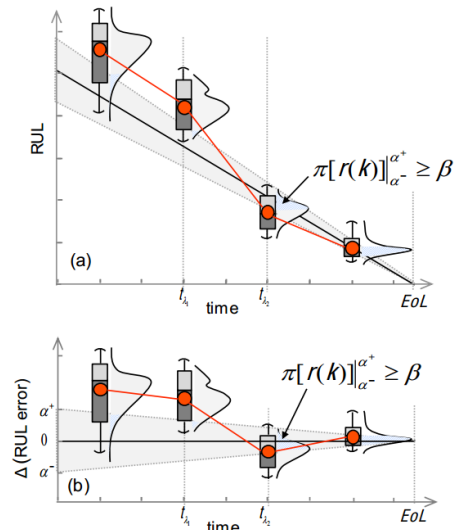


그림 12.  $\alpha-\lambda$  accuracy를 이용한 RUL 성능 측정 결과 [29]  
Fig. 12. (a)  $\alpha-\lambda$  accuracy with the accuracy cone shrinking with time on RUL vs. time plot. (b) Alternate representation of  $\alpha-\lambda$  accuracy on RUL-error vs. time plot.



5.3 상대적 정확도(Relative Accuracy)

특정 시간  $t_i$ 에서 실제 RUL  $r_*(t_i)$ 과 예측 RUL  $r'(t_i)$ 간의 상대적인 에러로 정의된다. 앞서 설명한 식 (8)과 의미가 비슷하다고 볼 수 있지만, 특정 시간에 예측이 주어진 정확도 레벨 내에 들어오는지 여부를 판단하는 것이 아니라 정확도가 그림 13의  $\Delta_1$ 과  $\Delta_2$ 처럼 실제 측정된다는 점에서 차이를 가진다.

$$RA = 1 - \frac{|r_*(t_i) - r'(t_i)|}{r_*(t_i)}, \quad (9)$$

where  $t_\lambda = t_p + \lambda(t_{EOL} - t_p)$




그림 13. 두 가지 알고리즘으로 비교한 RA 지표 결과[29]  
Fig. 13. Schematic illustrating Relative Accuracy

5.4 수렴(Convergence)

시간에 따라 정확성이 향상되는 임의의 metric M의 속도를 수량화하는 지표이다. 그림 14를 통해 세 개의 케이스가 서로 다른 수렴 속도를 보이고 있음을 확인할 수 있다. 각 케이스 별로 계산된 점(마름모)을 연결한 아래 영역의 무게중심(원)  $C_M$ 은 식 (10)과 같이 정의되고  $(x_c, y_c)$ 로 표현된 벡터로서 유클리디안 거리를 계산한다. 결과적으로 이 거리가 짧을수록 수렴속도가 빠름을 의미한다.

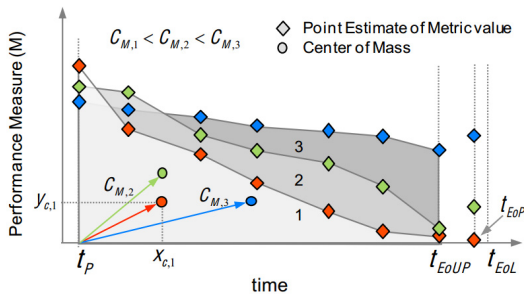


그림 14. 세 가지 케이스에 따른 서로 다른 수렴 속도[29]  
Fig. 14. Convergence compares the rates at which different algorithms improve

$$C_M = \sqrt{(x_c - t_p)^2 + y_c^2} \quad (10)$$

$$x_c = \frac{\frac{1}{2} \sum_{i=P}^{EoUP} (t_{i+1}^2 - t_i^2) M(i)}{\sum_{i=P}^{EoUP} (t_{i+1} - t_i) M(i)}, \quad y_c = \frac{\frac{1}{2} \sum_{i=P}^{EoUP} (t_{i+1} - t_i) M(i)^2}{\sum_{i=P}^{EoUP} (t_{i+1} - t_i) M(i)} \quad (11)$$

VI. 결론 및 향후 연구

본 논문에서는 배터리 잔존 유효 수명 예측 및 관리 기법 및 성능 평가 지표에 대한 학계의 연구 방법과 기술 현황을 소개했으며 특히 전기화학 기반의 배터리 모델링의 향후 잠재적 활용 가능성에 대해 강조했다. 이는 현재까지 산업계에서 주로 활용되고 있는 단순한 lumped 파라미터 기반의 ECM 모델은 배터리 내부 입자들의 전기화학적 움직임을 정확하게 반영할 수 없는 한계가 있기 때문이다. 향후 연구로써는 이러한 전기화학 기반 모델링에 불충분한 온도 및 확산(diffusion)에 따른 요소를 고려한 더욱 정교한 모델링을 정립하고 및 이를 활용한 진보된 배터리 진단 및 예지 알고리즘을 개발 하고자 한다.

References

- [1] K. Goebel, et al., "Prognostics in battery health management," *IEEE Instrumentation & Measurement Mag.*, vol. 11, no. 4, Aug. 2008.
- [2] B. Saha, et al., "Prognostics methods for battery health monitoring using a Bayesian framework," *IEEE Trans. Instrumentation and Measurement*, vol. 58, no. 2, pp. 291-296, 2009.
- [3] ISO 13381-1, *Condition monitoring and diagnostics of machines—prognostics. Part1: General guidelines*, International Standard (2004), Retrieved Jan., 30, 2017, from <https://www.iso.org/obp/ui#iso:std:iso:13381:-1:ed-1:v1:en>
- [4] J. Jun, et al., "Trend on IoT device product and technology," *KICS Inf. and Commun. Mag.*, vol. 31, no. 4, pp. 44-52, Mar. 2014.
- [5] K. Kim, S. Lee and J. Park "Technological trend analysis for configuration of energy storage system using retired electric vehicle

- battery,” *KICS Inf. and Commun. Mag.*, vol. 33, no. 7, pp. 47-52, Jun. 2016.
- [6] Y. Ryu and J. Park, “Open energy storage system based on a profile,” *KICS Inf. and Commun. Mag.*, vol. 33, no. 7, pp. 40-46, Jun. 2016.
- [7] Y. Choi and H. Kim, “Electrochemistry modeling based control of battery management system: A tutorial,” *KIC News*, vol. 18, no. 5, pp. 47-60, 2015.
- [8] M. J. Daigle and S. K. Chetan, “Electrochemistry-based battery modeling for prognostics,” 2013.
- [9] J. Li, S. Zhou, and Y. Han, *Advances in Battery Manufacturing, Services, and Management Systems*, John Wiley & Sons, 2016.
- [10] S. K. Rahimian, S. Rayman, and R. E. White, “Extension of physics-based single particle model for higher charge - discharge rates,” *J. Power Sources*, vol. 224, pp. 180-194, Feb. 2013.
- [11] S. Dey and B. Ayalew, “A diagnostic scheme for detection, isolation and estimation of electrochemical faults in lithium-ion cells,” in *Proc. ASME 2015 Dynamic Systems and Control Conf.*, Columbus, Ohio, Oct. 2015.
- [12] J. Lee, et al., “Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications,” *Mechanical Syst. and Sign. Process.*, vol. 42, no. 1, pp. 314-334, Jan. 2014.
- [13] J. Z. Sikorska, M. Hodkiewicz, and L. Ma, “Prognostic modelling options for remaining useful life estimation by industry,” *Mechanical Syst. and Sign. Process.*, vol. 25, no. 5, pp. 1803-1836, Jul. 2011.
- [14] A. T. Elsayed, C. R. Lashway, and O. A. Mohammed, “Advanced battery management and diagnostic system for smart grid infrastructure,” *IEEE Trans. Smart Grid*, vol. 7, no. 2, pp. 897-905, 2016.
- [15] L. Liao and F. Köttig, “Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction,” *IEEE Trans. Reliability*, vol. 63, no. 1, pp. 191-207, 2014.
- [16] N.-H. Kim, D. An, and J.-H. Choi, *Prognostics and Health Management of Engineering Systems: An Introduction*, Springer, 2016.
- [17] H.-J. Zimmermann, “Fuzzy set theory,” *Wiley Interdisciplinary Rev.: Computational Statistics*, vol. 2, no. 3, pp. 317-332, 2010.
- [18] J. Zhang and J. Lee, “A review on prognostics and health monitoring of Li-ion battery,” *J. Power Sources*, vol. 196, no. 15, pp. 6007-6014, 2011.
- [19] A. Malhi, R. Yan, and R. X. Gao, “Prognosis of defect propagation based on recurrent neural networks,” *IEEE Trans. Instrumentation and Measurement*, vol. 60, no. 3, pp. 703-711, 2011.
- [20] B. Saha, K. Goebel, and J. Christophersen, “Comparison of prognostic algorithms for estimating remaining useful life of batteries,” *Trans. Inst. Measurement and Control*, vol. 31, no. 3-4, pp. 293-308, 2009.
- [21] J. R. Galvan, A. Saxena, and K. Goebel, “Uncertainty representation and interpretation in model-based prognostics algorithms based on kalman filter estimation,” *Annu. Conf. Prognostics and Health Management Soc. 2012*, 2012.
- [22] R. K. Singleton, E. G. Strangas, and S. Aviyente, “Extended kalman filtering for remaining-useful-life estimation of bearings,” *IEEE Trans. Ind. Electron.*, vol. 62, no. 3, pp. 1781-1790, 2015.
- [23] X. Zhang and P. Pisu, “An unscented kalman filter based approach for the health -monitoring and prognostics of a polymer electrolyte membrane fuel cell,” *Annu. Conf. Prognostics and Health Management Soc.*, 2012.
- [24] S. H. Sim, et al., “Remaining useful life prediction of Li-Ion battery based on charge voltage characteristics,” *Trans. Korean Soc.*

*Mech. Eng. B*, vol. 37, no. 4, pp. 313-322, 2013.

- [25] Y. Qian and R. Yan, "Remaining useful life prediction of rolling bearings using an enhanced particle filter," *IEEE Trans. Instrumentation and Measurement*, vol. 64, no. 10, pp. 2696-2707, 2015.
- [26] M. Bressel, et al., "Remaining useful life prediction and uncertainty quantification of proton exchange membrane fuel cell under variable load," *IEEE Trans. Ind. Electron.*, vol. 63, no. 4, pp. 2569-2577, 2016.
- [27] J. K. Kimotho, T. Meyer, and W. Sextro, "PEM fuel cell prognostics using particle filter with model parameter adaptation," *IEEE Conf. PHM*, pp. 1-6, 2014.
- [28] M. R. Palacín, and A. de Guibert, "Why do batteries fail?," *Science*, vol. 351, no. 6273, 1253292, Feb. 2016.
- [29] A. Saxena, et al., "Metrics for offline evaluation of prognostic performance," *Int. J. Prognostics and Health Management*, vol. 1, no. 1, pp. 4-23, 2010.
- [30] A. Saxena, et al., "Metrics for evaluating performance of prognostic techniques," *IEEE Conf. PHM*, pp. 1-17, 2008.

**최 요 환 (Yohwan Choi)**



2013년 : 서강대학교 전자공학과 학사  
 2013년~현재 : 서강대학교 전자공학과 석박사통합과정  
 <관심분야> 에너지 저장장치/신재생 에너지 최적화 및 제어, 배터리 관리 시스템, 전기화학 기반 배터리 모델링 및 진단

**김 흥 석 (Hongseok Kim)**



1998년 : 서울대학교 전기공학부 학사  
 2000년 : 서울대학교 전기공학부 석사  
 2000년~2005년 : KT 통신망연구소 선임 연구원  
 2009년 : The University of Texas at Austin, Electrical Computer Eng. 박사  
 2009년~2010년 : Princeton University, 박사후 연구원  
 2010년~2011년 : Bell Labs, Alcatel-Lucent, NJ, USA, 책임연구원  
 2011년 9월~현재 : 서강대학교 전자공학과 부교수  
 <관심분야> 에너지ICT, 에너지 빅데이터 분석, 에너지 저장장치/신재생 에너지 최적화 및 제어, Transactive Energy, 수요반응, 마이크로그리드, 무선통신네트워크