

충전 전압 특성을 이용한 리튬 이온 배터리의 잔존 수명 예측

심성흠* · 강진혁* · 안다운* · 김선일* · 김진영* · 최주호**†

* 한국항공대학교 항공우주 및 기계공학과

Remaining Useful Life Prediction of Li-Ion Battery Based on Charge Voltage Characteristics

Seong Heum Sim*, Jin Hyuk Gang*, Dawn An*, Sun Il Kim*, Jin Young Kim* and Joo Ho Choi**†

* Dept. of Aerospace and Mechanical Engineering, Korea Aerospace Univ.

(Received February 20, 2012 ; Revised December 10, 2012 ; Accepted January 7, 2013)

Key Words : Prognostics and Health Management(건전성 관리 및 예측), Particle Filter(파티클 필터), Li-Ion Battery(리튬 이온 배터리), Remaining Useful Life(잔존 유효 수명)

초록: 배터리는 최근 여러 분야에서 중요한 에너지원 역할을 하고 있는데, 사용 중 충방전을 거듭하면 용량이 점차 저하되며 초기 대비 80% 이하로 떨어지면 고장으로 간주되므로, 이를 예측하기 위한 수명 예측 기법이 활발히 개발되고 있다. 본 연구에서는 사용중인 배터리에 대해 충전곡선 기울기를 이용하여 배터리의 용량을 평가하고 이를 바탕으로 잔존수명을 예측하는 새로운 방법을 제안하였다. 이 과정에서 발생하는 여러 불확실성을 고려하기 위해 베이지안 접근법에 기반한 파티클 필터 방법을 활용하였고 그 결과 잔존수명을 확률분포로 구하였다. 개발된 방법을 미국 NASA Ames 연구소와 본 연구실에서 직접 수행한 배터리 충방전 시험 데이터에 대해 각각 적용한 결과 충전곡선 기울기가 용량 열화를 잘 나타내며 파티클 필터로 예측된 잔존수명 신뢰구간은 실제 수명을 잘 포함함을 확인할 수 있었다.

Abstract: Batteries, which are being used as energy sources in various applications, tend to degrade, and their capacity declines with repeated charging and discharging cycles. A battery is considered to fail when it reaches 80% of its initial capacity. To predict this, prognosis techniques are attracting attention in recent years in the battery community. In this study, a method is proposed for estimating the battery health and predicting its remaining useful life (RUL) based on the slope of the charge voltage curve. During this process, a Bayesian framework is employed to manage various uncertainties, and a Particle Filter (PF) algorithm is applied to estimate the degradation of the model parameters and to predict the RUL in the form of a probability distribution. Two sets of test data—one from the NASA Ames Research Center and another from our own experiment—for an Li-ion battery are used for illustrating this technique. As a result of the study, it is concluded that the slope can be a good indicator of the battery health and PF is a useful tool for the reliable prediction of RUL.

1. 서론

국내외 2 차 전지 관련 연구는 전기자동차와 맞물려 크게 증가하고 있으나 이는 주로 대용량화, 경량화 및 급속 충전 등의 성능 향상에 집중되어 있다.⁽¹⁾ 한편 미국의 경우에는 NASA 화성 탐사선이 예상치 못한 배터리 고장으로 인해 계획된 탐사 목표를 달성하지 못하는 사고를 계기로 고장

예측의 중요성을 인식하면서 건전성 예측 및 관리(Prognostics and Health Management, PHM)라는 새로운 분야의 연구가 활발히 진행되었다.⁽²⁾

PHM 은 구조물이나 시스템의 건전성을 실시간으로 모니터링 하여 상태를 진단하고 고장 시점을 미리 예측하는 연구 분야이다. PHM 의 궁극적인 목표는 시스템의 상태와 무관하게 일정 주기가 되면 무조건 정비를 실시하던 기존의 방법과 달리 필요한 경우에만 조치를 취하는 상태 기반 정비(Condition Based Maintenance)를 구현하는 것이다. PHM 기술은 진단 기술과 예측 기술로 구분할 수 있는데 진단 기술은 비교적 오래 전부터 연구되어

† Corresponding Author, jhchoi@kau.ac.kr

© 2013 The Korean Society of Mechanical Engineers

은 반면 예측 기술은 최근 연구가 시작되고 있다.

그 동안 PHM 은 주로 매우 고가이거나 고안전성을 요구하는 시스템의 핵심 파트, 예를 들어 항공기 가스터빈이나 헬리콥터 기어박스 등에 적용되어 왔다.⁽³⁻⁵⁾ 최근에는 부품 자체는 저가이면서 소모품이지만 그 부품의 고장이 곧 시스템 전체에 영향을 미치는 부분에도 PHM 이 적용되고 있으며 그 대표적인 예로 무인항공기나 전기자동차에 쓰이는 배터리를 들 수 있다.

배터리는 충/방전을 거듭하면서 용량(capacity)이 점차 저하되고 보통 초기 대비 80% 이하로 용량이 떨어지게 되면 수명이 다한 것으로 판단하게 된다. 배터리의 상태에 관한 인자는 크게 State of Charge (SOC), State of Health (SOH), State of Life (SOL)로 나뉠 수 있는데 이 중 SOC, 즉 충전 상태는 비교적 오래 전부터 연구되어 왔으나 배터리의 건전성을 평가하는 SOH, 배터리의 고장을 예측하는 SOL 에 관한 연구는 최근에 와서 활발히 진행되고 있다.^(6,7) SOH 는 현재까지 저하된 용량의 수준을 평가하는 것으로 이를 정확히 측정하려면 완전 충/방전 시험을 실시해야 하는데 사용 중 측정이 불가능할 뿐만 아니라 시간이 오래 걸리기 때문에 효과적이지 않다. SOL 은 SOH 를 토대로 고장예측, 즉 고장까지 남아있는 사이클 또는 시간을 평가하는 것으로 충/방전을 거듭함에 따른 용량의 변화추이를 알아야 가능하다. SOH 와 SOL 에 관한 연구들은 Lee⁽⁶⁾와 Pecht⁽⁷⁾의 리뷰 논문에 잘 정리되어 있는데 대표적인 연구들을 정리하면 다음과 같다.

SOH 를 추정하기 위한 연구는 NASA Ames Prognostics Center 에서 가장 많이 연구되었으며 이들은 임피던스라는 배터리 용량을 대변하는 특성치를 이용하여 SOH 를 간접 추정하였고 관련 연구결과로서 배터리 실험 데이터를 공개하였다. Widodo⁽⁹⁾는 이러한 데이터를 대상으로 용량을 대변하는 특성치로 샘플 엔트로피(Sample Entropy)를 사용할 것을 제안하였다. Chan⁽⁸⁾은 인공신경망(Artificial Neural Network, ANN) 기법을 이용하여 방전 전류와 용량 사이의 상관관계를 규명하였고, Plett⁽¹⁰⁾은 SOC 가 최대 용량과 현재까지 사용한 전류량의 비로 나타내어진다는 개념을 제안하였다. 그러나 NASA 에서 제안한 임피던스 측정은 장비가 매우 고가이고 난이도가 높은 실험 방법이기 때문에 실시간(online) 예측 활용에 부적절한 측면이 있다. 또한 Widodo 및 Chan 의 연구는 배터리

의 사용 중 방전 속도(C-rate)가 수시로 변할 수 있기 때문에 실제 적용하기에 한계가 있다. 또 다른 연구로서 He⁽¹²⁾의 것이 있는데 이 역시 NASA 와 마찬가지로 임피던스를 특성치로 활용하였다. 최근에는 보다 실제 적용이 가능한 방안으로 서로 다른 방전 깊이(Depth of Discharge)를 갖는 충/방전 조건에서 비슷한 방전 깊이를 갖는 사이클들을 모은 뒤 Coulomb Counting 에 기반한 용량(Capacity) 추정 방법이 제안되었다.⁽¹³⁾ 하지만 이 방법 역시 방전 속도를 부분적으로 일정하다고 가정했기 때문에 아직 실제 적용에는 무리가 있다.

SOH 가 현재의 용량을 추정하는 것이라면, SOL 은 잔존수명을 평가하는 것이다. 이를 위해서는 충방전 사이클 진행에 따라 용량의 감소추이를 나타내는 열화모델이 필요하다. 가장 바람직한 방법은 충방전 반복에 따라 용량이 저하되는 현상을 전기화학적으로 분석하는 고장물리 방법으로 이를 위해 지난 10 년간 몇 가지 연구사례⁽¹²⁾가 제시되어 있으나 아직 유효성이 입증되지 못하고 있다. 한편 SOL 예측에서는 모델변수, 측정오차, 미래조건 등과 관련한 불확실성을 고려하는 것이 필수적이다. 이를 위한 연구는 매우 최근에 수행되어 사례가 많지 않으며, NASA 의 것이 대표적이다. 이들은 Relevance Vector Machine (RVM) 과 파티클 필터(Particle Filter)를 이용한 방법⁽¹¹⁾을, Plett⁽¹⁰⁾은 이중 확장 칼만 필터(Dual Extended Kalman Filter)를 제안하였다.

본 연구에서는 이러한 기존 연구들의 한계를 극복하기 위해, SOH, 즉 용량을 대변하는 특성치로 충전 곡선의 기울기를 이용하는 새로운 방법을 제안하고자 한다. 이는 배터리 충전 중 전압만 모니터링 하면 쉽게 측정이 가능하므로 기울기와 용량간의 관계식만 구축되면 편리하게 사용 가능한 방법이다. 이렇게 얻어지는 SOH 데이터를 바탕으로 몇 가지 열화모델을 대상으로 SOL, 즉 수명 예측을 수행하였다. 이를 위해 파티클 필터 방법을 적용하였다. 이는 온라인 데이터를 활용하여 모델 파라미터(여기서는 열화모델)를 실시간 추정하는 방법으로 최근 여러 분야에서 활발히 활용되고 있다. 본 연구에서는 이것과 비선형 커브피팅 방식과의 비교를 통해 그 우수성을 판단해보았다. 연구에 사용된 배터리 데이터는 NASA 의 것과 본 연구에서 직접 실험한 것 두 가지를 대상으로 하였다.

2. NASA 의 실험 데이터와 특성치 추출

본 연구에서 활용한 배터리 실험 데이터는 NASA Ames Prognostics Center 에서 공개하고 있는 데이터이다.⁽¹⁴⁾ 이 데이터는 Electrochemical Impedance Spectroscopy (EIS) 라는 실험 방법을 이용한 임피던스 측정 데이터를 포함하고 있다. 이 실험의 목적은 Fig. 1 과 같이 충/방전 사이클이 진행됨에 따라 임피던스가 변화하는 경향과 Fig. 2 와 같은 임피던스와 용량 사이의 선형적인 관계를 이용하여 배터리의 고장 예측을 수행하는 것이었다. 하지만 이미 언급한 바와 같이 EIS 측정 장비가 매우 고가이고 난이도가 높은 실험 방법이기 때문에 실시간 고장 예측을 적용하기 어려운 접근법이였다. 본 연구에서는 #5 와 #7 실험 데이터를 이용하였는데 이들의 실험 조건은 1.5Ah 의 일정한 전류로 충전을, 전압이 각각 2.7V, 2.2V 가 될 때까지 2Ah 의 전류를 가하여 방전을 실시한 것이다.

본 연구에서는 EIS 의 문제점을 극복하기 위해 배터리가 사용을 거듭할수록 충방전 시간이 감소한다는 점에 주목하고 이를 통해 용량을 추정하는 보다 쉬운 방법을 조사하였다. 이중에서 방전은 통상 임의 사용조건인 반면, 충전은 대부분 일정한 충전기에서 행해지므로 C-rate 가 고정되는 충전곡선을 대상으로 충/방전 사이클이 진행됨에 따

른 충전 전압 곡선을 분석하였으며, #5 배터리의 것을 Fig. 3 에 보였다. 이에 의하면 충방전이 반복됨에 따라 충전곡선이 점차 왼쪽으로 이동하는, 다시 말해 충전되는데 걸리는 시간이 짧아지며, 곡선의 기울기 또한 점차 증가하는 경향을 보이고 있다.

따라서 충전 전압곡선의 기울기와 배터리 용량에는 상관관계가 있음을 확인할 수 있으며, #5, #7 배터리에 대해 매 사이클 마다 이들의 측정된 값을 Fig. 4 에 점 데이터로 나타내었다. 임피던스와 달리 이들은 비선형적 관계를 나타내고 있으며, 따라서 이들의 관계식은 여러 시행착오 결과 다음과 같이 설정하였다.

$$C' = a + b \cos(dG') + c \sin(dG') \quad (1)$$

여기서 $C' = \ln(C(t)/C(1))$, $G' = \ln(G(t)/G(1))$ 는 각각 초기대비 현 시점의 상대용량의 로그값과 기울기의 로그값이고, t 는 시간 또는 충방전 사이클이다. 파라미터 a, b, c, d 는 측정데이터로부터 최소자승오차법으로 구하였다. 이들은 배터리의 종류(모델) 및 충전 C-rate 에 따라라도 달라질 것이나 동일 모델, 동일 C-rate 에서는 동일할 것이라는 가정 하에 하나의 배터리에 대해 파라미터를 추정하고 나면, 이를 동일한 다른 배터리의 용량추정 및 열화예측에 활용하였다. 여기서는 #5 데이터에 대해 추정된 커브를 Fig. 4 에 검은색 선으로 도시하였다.

Fig. 5 를 보면 배터리 사이클 초기에는 충전전압곡선이 그 이후와 확연히 달라진다. 따라서 측정된 충전전압 기울기가 어느 정도 수준으로 안정된 시점의 사이클을 첫째로 놓고 분석하였다. 안정된 시점의 사이클의 판단은 충전전압의 기울기가 0.00025V/s 이하가 된 이후의 시점으로 보아 #5




Fig. 1 EIS Impedance data⁰




Fig. 2 Linear correlation between capacity and impedance




Fig. 3 Charge voltage curve of battery #5

와 #7의 배터리에 대해서 각각 2번째 사이클과 3번째 사이클을 첫째로 놓았다. 충전 전압 곡선 기울기는 3.8V 부터 3.9V 까지의 평균기울기로 구하였다. 관계식과 실제 용량간의 오차의 평균제곱근 RMSE 는 0.0269V 로 나타났다. 한편 Fig. 4 에는 #7 배터리의 기울기, 용량간의 데이터도 함께 도시하였다. 동일한 배터리임에도 불구하고, 방전종지전압이 다르기 때문에 #5 와 차이를 보이고 있다. 그럼에도 불구하고 #5 로부터 얻은 관계식을 활용하여 #7 배터리의 용량추정 및 열화예측을 정확히 수행할 수 있으며, 이를 4 절에서 입증하였다.

3. 본 연구 실험 데이터와 특성치 추출

충전 전압기울기와 용량간의 관계를 보이기 위해 NASA 의 데이터 외에 본 연구에서 직접 충방전 실험을 수행하였다. 실험을 수행한 실험 기구는 Fig. 6 와 같으며, 실험 방법은 ㉔(컴퓨터)에서

배터리 충방전 사이클을 계획하면 ㉓(배터리 충방전기기)에서 컴퓨터의 명령을 받아 배터리 충방전을 실행하고 ㉒(배터리)의 충방전이 이루어진다.




Fig. 6 Experimental setup of battery degradation

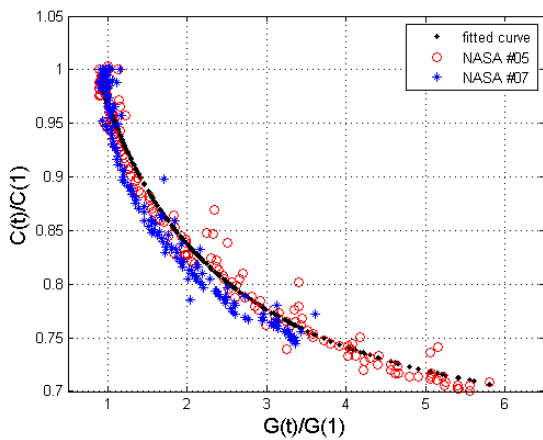


Fig. 4 Correlation between capacity and gradient of NASA #5, #7 batteries

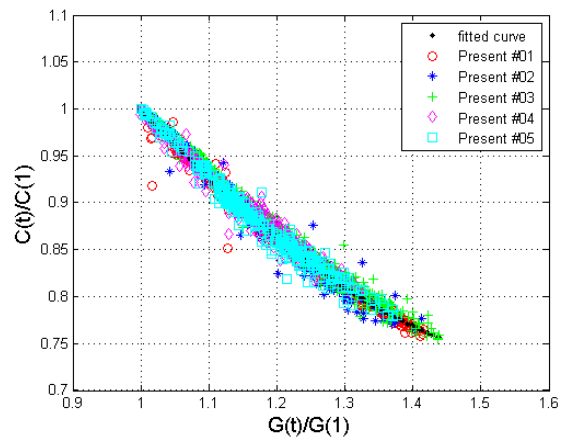


Fig. 7 Correlation between capacity and gradient of present #1, #2, #3, #4, #5 batteries




Fig. 5 Gradient of charge voltage curve of NASA #5

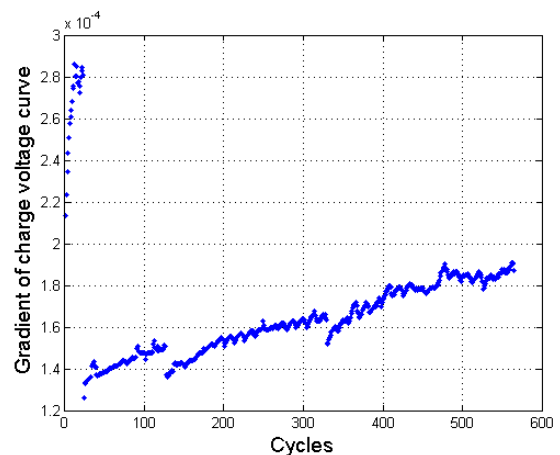


Fig. 8 Gradient of charge voltage curve of present #1

배터리 및 충방전기의 모델명은 각각 EEMB LIR17500 (1100mAh) 및 WBCS3000S (Wonatech) 이다. NASA 배터리의 충방전 실험에서는 주변 온도를 일정하게 하였으나 본 실험에서는 대기온도를 일정하게 유지하지 않고 상온에 두었다.

본 연구를 위해 1 번부터 5 번까지 5 개 채널에서 동일 배터리 모델에 대해 동일조건으로 실험을 실시하였다. 충방전 조건은 1.1Ah 의 일정 전류로 충방전을 실시하였고, 방전종지전압은 2.7V 로 설정하였다.

NASA 데이터와 마찬가지로 Fig. 8 을 보면 배터리 사이클 초기에는 충전전압곡선의 추이가 그 이후와 많이 다름을 볼 수 있다. 따라서 그 추이가 안정된 이후의 사이클을 첫 번째 사이클로 보고 분석하였다. 충전 전압 곡선의 기울기는 3.81V 부터 4.15V 까지의 평균기울기를 사용하였다.

상대 기울기와 상대 용량 데이터 및 이들을 토대로 추정된 관계식 커브를 Fig. 7 에 도시하였고 이로부터 식 (1)이 실제의 데이터를 잘 표현하고 있음을 확인할 수 있었다.

NASA 의 경우와 달리 본 경우에는 5 개의 배터리가 동일한 조건에서 실험되었기 때문에 거의 한 가지 데이터로 나타났다.

4. 파티클 필터 알고리즘

본 연구에서 수명예측을 위해 사용한 방법인 파티클 필터는 Sequential Monte Carlo (SMC) 라고도 하며 주로 제어 분야 등에서 위치 추적, 패턴 인식 등을 위해 최근 많이 사용되는 기법이다.⁽¹⁷⁾ 비슷한 목적의 칼만 필터 및 확장 칼만 필터 등이 있지만 이들은 각각 시스템 모델이 선형이거나 시스템의 확률 분포를 가우시안 분포로 가정해야 하는 한계가 있는 반면 본 방법은 비선형, 비가우시안 시스템에도 적용 가능한 우수한 알고리즘이다. 베이지안 접근법에 기반한 이 알고리즘은 잡음 또는 오차를 포함하는 측정치를 이용하여 추정하고자 하는 시스템 상태 변수의 사후분포를 구하는데 이때 사후분포는 해석적으로 구해지는 것이 아니라 다수의 샘플(파티클)과 각 샘플이 가지는 가중치를 통해 표현된다. 일반적으로 시스템 모델과 측정 모델은 식 (2)와 같이 나타낼 수 있다.

$$\begin{aligned} x_k &= f_k(x_{k-1}, n_k) \leftrightarrow p(x_k | x_{k-1}) \\ y_k &= h_k(x_k, v_k) \leftrightarrow p(z_k | x_k) \end{aligned} \quad (2)$$

여기서 x 는 상태 변수, y 는 측정치, n 과 v 는 각각 시스템 모델과 측정 모델의 잡음이며, k 는

현재의 사이클이다. 본 연구에서는 x, y 는 각각 배터리 용량 및 기울기를, f, g 는 각각 열화모델과 식 (1)로 주어진 관계식을 뜻한다.

파티클 필터는 예측(Prediction)과 갱신(Update) 단계로 나뉘어지는데 예측 단계에서는 식 (3)과 같이 시스템 모델을 이용하여 다음 측정치가 얻어지는 시점에서의 상태 변수 분포를 예측하고, 갱신 단계에서는 식 (4)와 같이 측정치를 이용하여 예측 단계에서 얻어진 분포를 수정한 사후 분포를 구하게 된다.

$$p(\mathbf{x}_k | \mathbf{y}_{1:k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{y}_{k-1}) d\mathbf{x}_{k-1} \quad (3)$$

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) = p(\mathbf{y}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{y}_{1:k-1}) \quad (4)$$

일반적으로 식 (4)는 정확한 수식(closed form)으로 표현하기 어렵기 때문에 샘플링이라는 수치적인 방법을 이용해야 한다. 이때 $\mathbf{x}_k^i, i=1, \dots, N$ 를 랜덤 샘플 또는 파티클이라 하고 w_k^i 를 각 파티클에 대응되는 가중치라 한다면 사후분포는 식 (5)로 나타낸다.

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) \approx \sum_{k=1}^N w_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (5)$$

여기서 $\delta(\cdot)$ 는 Dirac delta function 을 뜻하며, 가중치는 측정오차 v 가 정규분포라는 가정하에 다음과 같은 우도에 비례하는 것으로 주어진다.

$$w_k^i \propto p(\mathbf{y}_k | \mathbf{x}_k^i) = \frac{1}{\sqrt{2\pi}\sigma_k} \exp\left[-\frac{1}{2\sigma_k^2} \sum_{i=1}^N (y_k - h(x_k^i))^2\right] \quad (6)$$

마지막으로 이렇게 가중치 w_k^i 에 비례하는 파티클들은 Fig. 9 과 같이 resampling 과정을 거치게 된다. 파티클 필터의 전체적인 알고리즘을 Table 1 에 정리하였다.

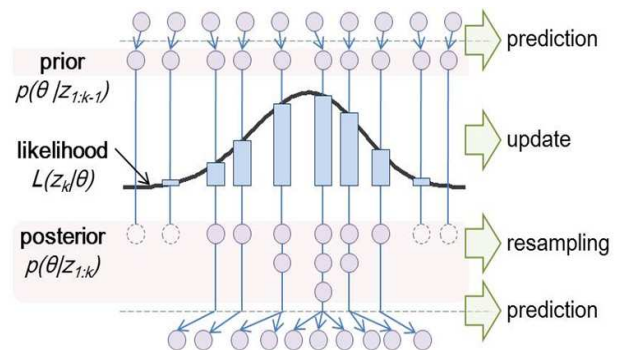


Fig. 9 Illustration of the PF process

Table 1 Particle filter algorithm⁽¹⁷⁾

$$\left[\left\{ \mathbf{x}_k^i, w_k^i \right\}_{i=1}^N \right] = \text{PF} \left[\left\{ \mathbf{x}_{k-1}^i, w_{k-1}^i \right\}_{i=1}^N, \mathbf{y}_k \right]$$

- for $i = 1 : N$
 Draw $\mathbf{x}_k^i \sim q(\mathbf{x}_k | \mathbf{x}_{k-1}^i, \mathbf{y}_k)$
 Assign the particle a weight, w_k^i , according to (4)
 - end

- Calculate total weight : $t = \text{sum} \left[\left\{ w_k^i \right\}_{i=1}^N \right]$

- for $i = 1 : N$
 Normalize : $w_k^i = t^{-1} w_k^i$
 - end

$$\left[\left\{ \mathbf{x}_k^i, w_k^i \right\}_{i=1}^N \right] = \text{Resampling} \left[\left\{ \mathbf{x}_k^i, w_k^i \right\}_{i=1}^N \right]$$




Fig. 10 NASA #07 – model 1 at 20 cycles (PF)




Fig. 11 NASA #07 – model 1 at 50 cycles (PF)

5. 배터리 수명 예측

본 연구에서는 충전전압 곡선에서의 기울기를 통해 용량을 추정하였고, 추정된 용량을 바탕으로




Fig. 12 NASA #07 – model 1 at 80 cycles (PF)




Fig. 13 NASA #07 – model 2 at 20 cycles (PF)




Fig. 14 NASA #07 – model 2 at 50 cycles (PF)

수명 예측을 하였다. 수명 예측을 위해 파티클 파티클 필터 방법을 적용하였고, 그 결과를 비선형 최소자승법을 사용한 커브피팅 적용법과 비교하였다. 편의를 위해 NASA의 배터리 실험 자료의 경우 5 사이클마다 한번씩 자료를 받아 수명예측에 활용하였고, 본 연구에서 수행한 배터리 실험 자료는 20 사이클마다 한번씩 자료를 받아 수명예측




Fig. 15 NASA #07 – model 2 at 80 cycles (PF)




Fig. 18 NASA #07 – model 1 at 80 cycles (CF)

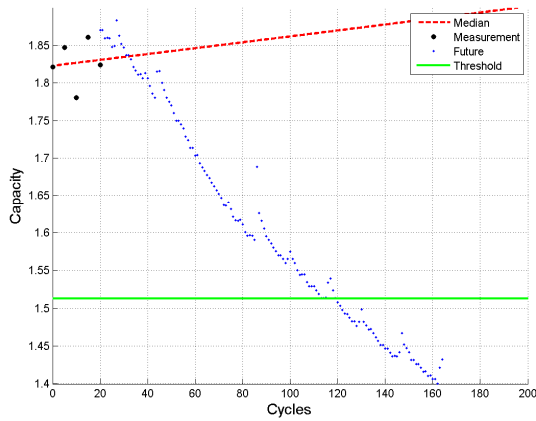


Fig. 16 NASA #07 – Model 1 at 20 cycles (CF)




Fig. 19 NASA #07 model 1 RUL (PF)




Fig. 17 NASA #07 – model 1 at 50 cycles (CF)




Fig. 20 Present #2 model 1 RUL (PF)

에 활용하였다.

파티클 필터의 적용에 있어 초기분포의 설정은 결과에 상당한 영향을 미친다. 따라서 적절한 초기분포의 설정이 필요하다. 한편 본 연구에서는 기준이 되는 배터리를 두고 그 배터리가 failure 수준까지 열화사이클을 거친 데이터를 가지고 열화모델계수를 구한 다음, 다른 배터리의 열화예측

을 하기 위한 초기분포로 이들 값의 1.5 배 상하한을 이용하였다. 기준 배터리는 NASA의 경우 #5, 실험을 수행한 배터리의 경우 #1로 정하였다.

배터리의 열화모델을 위해서는 식 (7)과 같은 두 가지 모델을 고려하였다.

$$\begin{aligned} \text{Model 1: } & a \exp(bt) \\ \text{Model 2: } & a + b \cos(dt) + c \sin(dt) \end{aligned} \quad (7)$$




Fig. 21 Present #3 model 1 RUL (PF)




Fig. 22 Present #4 model 1 RUL (PF)

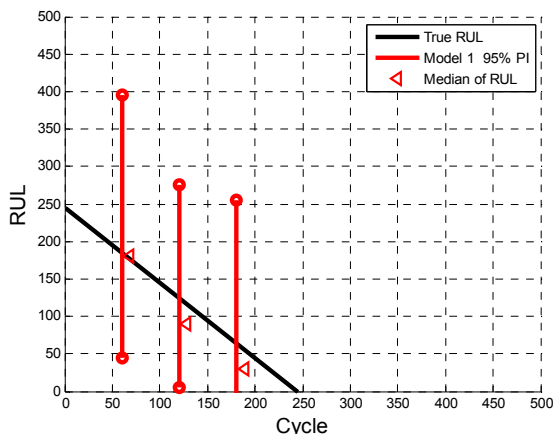


Fig. 23 Present #5 model 1 RUL (PF)

NASA 배터리를 대상으로 #5 배터리에서 얻은 관계식을 가지고 #7 배터리에 대해 수명예측을 수행하였다. 20, 50, 80 사이클까지의 것을 바탕으로 파티클 필터 방법으로 열화거동을 예측한 결과를 열화모델 1에 대해 Fig. 10~12에, 열화모델 2에 대해 Fig. 13~15에 나타내었다. 그림에서 가운데

및 위아래의 선들은 해당 시점에서 예측의 median 및 95% 신뢰수준 상하한을, 검은색 굵은 점들은 추정에 활용된 측정된 데이터를, 파란색 작은 점들은 실제 데이터로서 예측 커브와의 비교를 위해 표시한 것이며, 초록색 수평선은 임계용량선으로 실제 첫 사이클에서의 용량의 80%가 되는 지점으로 용량이 이 값으로 떨어지면 고장으로 간주한다. 그림에서 확인할 수 있듯이 모델 2는 계수가 많음에 따라 오히려 Fig. 13과 같이 열화거동을 제대로 예측하지 못하는 측면이 있다고 판단, 제외하였다. 한편 모델 1을 가지고 해당 시점까지의 데이터를 토대로 단순 커브피팅에 의한 예측작업도 시도해 보았다. 이를 위해 MATLAB의 비선형 최소자승 알고리즘에 의한 fit 함수를 이용하였고, 수명예측 그래프를 Fig. 16~18에 추가하였는데, 이들 결과는 파티클 필터의 것에 비해 매우 부정확하여 사용하면 안됨을 알 수 있었다. 따라서 모델 1을 이용하여 파티클 필터로 예측을 수행하는 것이 가장 바람직하였다. Fig. 10~12에서 사이클이 진행되면서 데이터가 추가되면, 실제 열화거동과 비교할 때 열화예측 커브의 정확도가 점점 향상되며, 신뢰구간도 좁아짐을 알 수 있다. 잔여수명은 해당 시점에서 실제 고장까지의 남은 사이클을 뜻하는 것으로 열화모델 1을 이용하여 파티클 필터로 예측한 결과를 Fig. 19에 보였다. 여기서 검은 실선은 실제 잔여수명을, 세 개의 수직선은 각각 20, 50, 80 사이클에서 추정된 잔여수명에 대해 median 및 상하한으로 표시한 것이다. 앞의 열화 커브와 마찬가지로 잔여수명 또한 사이클이 진행되면서 실제 잔여수명과의 오차가 점점 감소하고 있고, 신뢰구간 또한 점차 감소하는 추세를 보이고 있다.

위와 같은 방법으로 본 연구에서 수행한 배터리를 가지고 #1에서 관계식을 도출하고 #2, #3, #4, #5에서 열화모델과 파티클 필터로 수명예측을 수행하였고, 각각의 배터리에 대해 60, 120, 180 사이클에서 예측한 잔여수명을 Fig. 20~23에 보였다. Fig. 20~23에서 보듯 같은 모델의 배터리와 동일한 실험 조건이라도 개별 배터리마다 수명은 제각각이었다. 그럼에도 파티클 필터 방법은 실시간 데이터에 기반하여 이런 배터리 특성차이를 잘 반영하여 수명예측하고 있다.

6. 결론 및 토의

본 연구에서는 배터리 용량을 대변할 수 있는

새로운 특성치인 충전전압 기울기와 파티클 필터 기법을 활용하여 실시간으로 측정되는 데이터로부터 수명을 예측하는 기법을 제안하였고 다음과 같은 결론을 얻을 수 있었다.

(1) 배터리 용량을 대변하는 특성치로 선정된 충전전압곡선의 기울기는 기존의 EIS 와 같은 고가의 시험장비가 필요없이 충전 중 손쉽게 자동 측정이 가능하며, 이것과 용량간의 관계식을 확립하고 나면 동일 배터리의 용량추정에 활용할 수 있다.

(2) 잔여수명(SOL) 예측을 위한 파티클 필터링 방법은 단순한 커브피팅에 의한 예측보다 정확성이 더 높을 뿐 아니라 데이터 부족 및 측정에 의한 불확실성을 신뢰구간에 반영하고 있어 매우 유효하다.

(3) 파티클 필터링에 의한 수명예측은 배터리의 측정데이터에 기반하여 열화모델 상수를 지속적으로 실시간 업데이트하고 이를 토대로 수명예측을 하는 방법으로서, 배터리 별로 수명을 달리 예측한다.

배터리의 수명 예측 연구는 최근 활발히 진행되고 있으며 아직 실제 적용이 가능하기 위해서는 개선해야 할 문제들이 많이 존재하고 있다. 충/방전 조건 중 배터리의 수명에 영향을 미치는 인자로 방전 속도와 방전 깊이가 있는데 NASA 의 배터리 데이터는 방전 깊이는 달랐지만, 방전 속도는 같았으며 본 연구에서의 실험은 방전 속도가 일정한 조건에서 실험을 수행하였다.

실제 사용 조건에서 방전의 사용 조건이 다양하다 하더라도 충전은 대부분의 경우 특정한 충전기에서 행해지므로 일정한 C-rate 에서 이루어 질 것이다. 본 연구에서는 방전 조건이 바뀌더라도 충전 조건이 같다면 연구 결과에 큰 영향을 안 줄 것이라는 가정을 하였는데 실제 실험에서는 방전 조건을 다양하게 부여하지 못하였다. 향후의 연구는 일반적인 사용과 같은 방전 조건에서도 이러한 방법이 잘 적용될 수 있는지에 대한 연구가 진행 될 것이다.

후 기

이 논문은 2011 년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2009-0081438).

참고문헌

(1) Cho, M., Son, Y. M., Nah, D. B., Kil, S. C. and Kim,

S. W., 2010, "Lithium-Ion Batteries for Plug-In Hybrid Electric Vehicle," *Journal of Energy Engineering*, Vol. 19, No. 2, pp. 81~91.

(2) Goebel, K., Saha, B., Saxena, A., Celaya, J. R. and Christophersen, J. P., 2008, "Prognostics in Battery Health Management," *IEEE Instrumentation & Measurement Magazine*, pp. 33~40.

(3) Bechhoefer, E., Bernhard, A., He, D. and Banerjee, P., 2006, "Use of Hidden Semi-Markov Models in the Prognostics of Shaft Failure," *American Helicopter Society 62th Annual Forum*, Phenix, USA.

(4) Orchard, M. E. and Vachtsevanos, G. J., 2007, "A Particle Filtering Approach for On-Line Failure Prognosis in a Planetary Carrier Plate," *International Journal of Fuzzy Logic and Intelligent Systems*, Vol. 7, No. 4, pp. 221~227.

(5) Bolander, N., Qiu, H., Eklund, N., Hindle, E. and Rosenfeld, T., 2009, "Physics-Based Remaining Useful Life Prediction for Aircraft Engine Bearing Prognosis," *Annual Conference of the Prognostics and Health Management Society*, San Diego, USA.

(6) Zhang, J. and Lee, J., 2011, "A Review on Prognostics and Health Monitoring of Li-Ion Battery," *Journal of Power Sources*, Vol. 196, No. 15, pp. 6007~6014.

(7) Xing, Y., Ma, E. W. M., Tsui, K. L. and Pecht, M., 2011, "Battery Management Systems in Electric and Hybrid Vehicles," *Energies*, Vol. 4, No. 11, pp. 1840~1857.

(8) Chan, C. C., Lo, E. W. C. and Weixiang, S., 2000, "The Available Capacity Computation Model Based on Artificial Neural Network for Lead-Acid Batteries in Electric Vehicles," *Journal of Power Sources*, Vol. 87, No. 1~2, pp.201~204.

(9) Widodo, A., Shim, M. C., Caesarendra, W. and Yang, B. S., 2011, "Intelligent Prognostics for Battery Health Monitoring Based on Sample Entropy," *Expert Systems with Applications*, Vol. 38, pp. 11763~11769.

(10) Plett, G. L., 2004, "Extended Kalman Filtering for Battery Management Systems of LiPB-based HEV Battery Packs Part 3. State and Parameter Estimation," *Journal of Power Sources*, Vol. 134, No. 2, pp. 277~292.

(11) Saha, B., Goebel, K., Poll, S. and Christophersen, J., 2009, "Prognostics Methods for Battery Health Monitoring Using a Bayesian Framework," *IEEE Transactions on Instrumentation and Measurement*, Vol. 58, No. 2, pp. 291~296.

(12) He, W., Williard, N., Osterman, M. and Pecht, M., 2011, "Prognostics of Lithium-Ion Batteries Based on Dempster-Shafer Theory and the Bayesian Monte Carlo Method," *Journal of Power Sources*, Vol. 196,

- No. 23, pp. 10314~10321.
- (13) Williard, N., He, W., Osterman, M. and Pecht, M., 2011, "Improved SOH Estimation Through Coulomb Counting," BMS Workshop at the Prognostics and System Health Management Conference 2011.
- (14) Saha, B. and Goebel, K., 2007, "Battery Data Set," *NASA Ames Prognostics Data Repository*, NASA Ames, Moffett Field, CA.
- (15) Richman, J. S. and Moorman, J. R., 2000, "Physiological Time Series Analysis Using Approximate Entropy and Sample Entropy," *The American Journal of Physiology Heart and Circulatory Physiology*, Vol. 278, No. 6, pp. 2039~2049.
- (16) Xing, Y., Williard, N., Tsui, K.-L. and Pecht, M., 2011, "A Comparative Review of Prognostics-Based Reliability Methods for Lithium Batteries," Prognostics and System Health Management Conference 2011, pp. 1~6.
- (17) Arulampalam, M. S., Maskell, S., Gordon, N. and Clapp, T., 2002, "A Tutotial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking," *IEEE Transactions on Signal Processing*, Vol. 50, No. 2, pp. 174~188.