

해밍네트워크를 이용한 리튬이온 배터리의 특성 분석

김중훈, 이재문, 조보형
서울대학교 전기, 컴퓨터공학부

A Characteristics Analysis of a Li-Ion Battery using Hamming Network

J. H Kim, J. M. Lee and B. H. Cho
School of Electrical Engineering and Computer Science
Seoul National University

ABSTRACT

같은 정격을 가진 배터리 일지라도 온도나 노화에 따라 용량, Direct current internal resistance(DCIR)이 서로 다른 값을 나타낸다. 또한, 용량과 DCIR의 상관관계가 항상 성립하는 것은 아니다. 이러한 특성으로 인해 펄스파워 관련 State of health(SOH)를 알기 어렵다. 이번 논문에서는 해밍네트워크를 이용한 리튬이온 배터리의 특성을 분석, 연구하였다. 펄스파워는 전압의 함수이다. 배터리 충방전 프로파일을 이용하여 전압 패턴들을 선정한 후 특성 파라미터를 이용하여 해밍네트워크에 사전에 학습시킨다. 다음, 임의의 배터리 데이터를 통계 처리하여 전압패턴 특성 파라미터를 추출한 후 신경회로망에 입력하여 학습한 전압패턴들 중 임의의 배터리에 맞는 배터리를 선정한다. 패턴선정은 상온에서 10개의 리튬이온 프레스 배터리 (1.3Ah)가 이용되었고 검증에 위해 DCIR 값을 구하였다.

1. 서 론

리튬이온 배터리는 에너지보존, 친환경적인 미래의 대체 에너지 원으로서 큰 각광을 받고 있다. 특히 하이브리드 차량의 어플리케이션으로 많이 사용되고 있다.

배터리의 수명을 나타내는 SOH는 State of charge(SOC)와 더불어 배터리의 성능을 알 수 있는 척도이다. 그 중, 배터리의 내부 임피던스를 이용해 얻어지는 펄스파워를 통해서 SOH를 얻는 방법이 대표적이다. 이러한 펄스파워는 같은 정격을 가진 배터리 일지라도 온도나 노화에 따라 서로 다른 값을 나타내며 용량과의 상관관계도 항상 성립하는 것은 아니다.

이번 논문에서는 뉴럴네트워크의 일종인 해밍네트워크[1]를 이용한 리튬이온 배터리의 특성을 분석, 연구하였다. 펄스파워는 배터리의 내부 임피던스를 이용하므로 전압의 함수로 이루어진다. 배터리 충방전 프로파일을 이용하여 전압패턴들을 선정한 후 특성 파라미터를 이용하여 해밍네트워크에 사전에 학습시킨다. 임의의 배터리 데이터를 통계 처리(평균, 분산, 표준편차)하여 전압패턴 특성 파라미터를 추출한 후 미리 사전에 학습시킨 신경회로망에 입력하여 학습한 전압패턴들 중 임의의 배터리에 가장 잘 맞는 배터리를 선정하였다. 실험은 상온(25℃)에서 이루어졌으며 패턴선정을 위해 리튬이온 프레스 배터리 18650type (1.3Ah) 10개가 이용되었으며 실험의 검증을 위해 배터리의 실제 DCIR 값을 구하였다.

2. Direct Current Internal Resistance(DCIR)

배터리의 간략화된 모델은 1개의 저항과 1개의 RC-ladder로 구성된다. 10초간 펄스전류를 가했을 때 나타나는 전압의 차이를 이용하여 DCIR을 구한다. 식 (1)은 DCIR을 나타내며, 식(2)는 펄스파워를 구하는 방법이다. 그림 1은 DCIR 테스트 프로파일과 배터리 모델을 나타낸다[2].

$$DCIR \approx Ri + Rct + Rd \quad (1)$$

$$Po = \frac{OCV - 2.8V}{DCIR} \times 2.8V \quad (2)$$

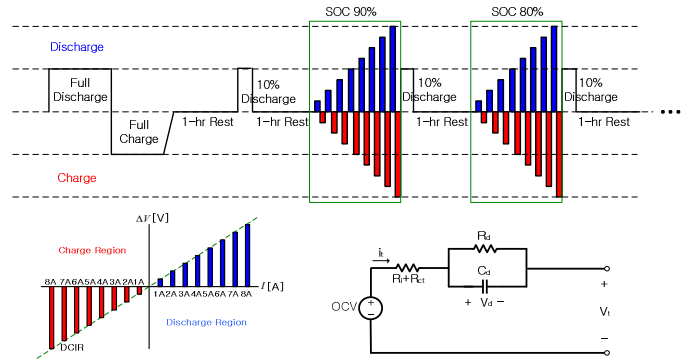


그림 1 DCIR 테스트 프로파일, 배터리 등가회로 모델
Fig. 1 DCIR test profile, Lumped parameter battery model

3. 해밍네트워크(Hamming Network)




그림 2 해밍네트워크
Fig. 2 Hamming network

해밍네트워크는 패턴인식에 이용되는 네트워크로서 그림 2와 같이 일반적으로 2개의 레이어(Feedforward layer, Recurrent layer)로 구성된다. 해밍네트워크는 실제적인 데이터가 아닌 일정한 통계처리에 의한 기준에 의해 1과 -1로 구성된 벡터가 이용되며 이는 패턴선정이나 네트워크상의 내적에 모두 적용된다.

3. 1 Feedforward Layer

첫 번째 레이어에서는 미리 선정된 패턴과 임의의 입력 벡터와의 내적이 수행된다. 통계처리를 통해 선정된 패턴은 weight matrix W^1 , bias 벡터 b^1 , 입력 벡터 p 로 나타낸다.

$$W^1 = [p_1 \ p_2 \ \dots \ p_n]^T \quad a^1 = \text{purelin}(W^1 p + b^1)$$

3. 2 Recurrent Layer

두 번째 레이어에서는 경쟁학습(Winner-take-all)을 통하여 네트워크에 들어온 임의의 입력에 가장 잘 맞는 패턴을 선정한다. 가장 잘 맞는 패턴이 선정될 때 0이 아닌 출력값이 얻어지게 되며 나머지는 0을 나타낸다. 첫 번째 레이어의 출력은 두 번째 레이어의 초기값이다. S 는 두 번째 레이어 뉴런 수이다.

$$a^2(0) = a^1 \quad a^2(t+1) = \text{poslin}(W^2 a^2(t))$$

$$W^2 = \begin{bmatrix} 1 & -\epsilon \\ -\epsilon & 1 \end{bmatrix} \quad \epsilon < \frac{1}{S-1}$$

4. 실험결과

4. 1 패턴선정

충방전 프로파일을 통해 전압, 전류, SOC가 얻어진다. 배터리의 펄스파워는 내부임피던스를 이용하여 전압의 함수로 얻어지므로 패턴을 선정하기 위해서는 전압 데이터를 얻어야 한다. 그림 3은 충방전 전류 프로파일(a)과 이를 이용하여 얻어진 전압(b)을 나타낸다.

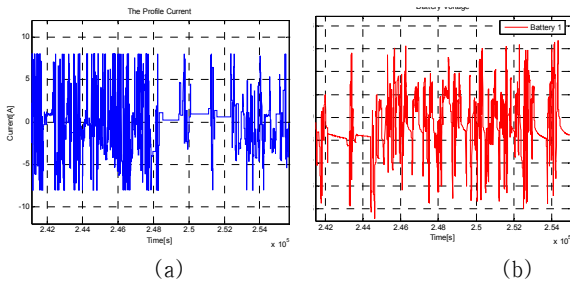


그림 3 (a) 충방전 전류프로파일 (b) 전압
Fig. 3 (a) Current profile (b) Voltage




그림 4 (a) 수정되지 않은 방전영역의 전압
Fig. 4 (a) Unmodified discharge region




그림 5 (a) 수정되지 않은 충전영역의 전압
Fig. 5 (a) Unmodified charge region

충방전 프로파일을 이용하여 10개 배터리의 전압을 구하였다. 패턴선정을 위해서는 얻어진 전압데이터의 통계처리가 필요하다. 충방전 프로파일에 따른 각 전압을 살펴보면 그림 4의 방전전압, 그림 5의 충전전압의 시작점이 일치하지 않는다. 평균, 표준편차

등의 통계처리를 위해서는 기준 배터리를 하나 정한 후 각 배터리의 전압 시작점을 하나로 맞춰야 한다. 그림 6에 간략히 나타내었다. 이 논문에서는 정확한 통계처리를 위해 방전전압과 충전전압을 나누어 통계처리 하였으며 이를 그림 7에 나타내었다.




그림 6 방전전압 시작점 재조정 방법
Fig. 6 Reset method Discharge voltage starting point

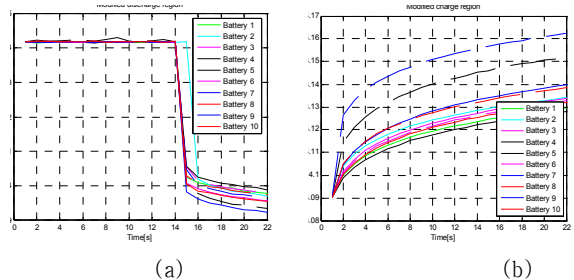


그림 7 전압 시작점 재조정 (a) 방전전압, (b) 충전전압
Fig. 7 Reset method starting point (a) Discharge (b) Charge

패턴선정을 위해 해밍네트워크에 학습시키기 위한 특성파라미터를 구해야 한다. 특성파라미터는 각 배터리 전압 데이터의 평균, 표준편차, 최대값, 최소값 등을 통하여 얻을 수 있다. 이 중 평균, 표준편차에 관련된 데이터가 중요하다. 10초간 펄스전류를 가했을 때 방전전압이 많이 낮아질수록 표준편차가 크며 충전전압도 같은 경우로서 성립한다. 충방전 시작점을 하나로 조정하였을 때는 위의 결과가 더욱 두드러진다. 다만, 충방전 시작점을 하나로 조정하지 않았을 경우 평균은 특성파라미터로 사용하지 않는다. 위의 조건을 바탕으로 7개의 특성파라미터(C1~C7)를 구하였다. 표 1은 특성파라미터를 나타내며 (R)은 충방전 전압 시작점 조정을 의미한다.

표 1 7개 특성파라미터
Table. 1 Seven Characteristic parameters

C1	충방전 전압 표준편차	C5	방전 전압 표준편차(R)
C2	방전 전압 표준편차	C6	충전 전압 평균(R)
C3	충전 전압 표준편차	C7	충전 전압 표준편차(R)
C4	방전 전압 평균(R)		방전 6번, 충전 1번 배터리 기준

특성파라미터의 실제값을 해밍네트워크에 적용하지 않고 이를 일정한 통계처리에 의한 기준에 의해 1과 -1로 구성된 벡터로 변환한다. 예를 들어 C3의 경우, 10개의 배터리가 있으므로 10개의 값이 연산되는데, 이 값들의 평균(m), 표준편차(std)를 구하고 3개의 값 ($m + (\alpha \times std)$, m , $m - (\alpha \times std)$)을 구하여 전압 데이터 실제값이 위 3개의 값 중 어느 범위에 속하는가에 따라 L1{-1,-1,-1}, L2{1,-1,-1}, L3{1,1,-1}, L4{1,1,1}을 부여한다. 그림 8에 이를 간략히 나타내었다. 즉, m 보다 작고 $m - (\alpha \times std)$ 보다 큰 경우에는 {1,-1,-1}을 할당한다. 이번 논문에서는 $\alpha=0.5$ 를 적용하였다.




그림 8 특성파라미터의 벡터 변환 범위
Fig. 8 Four Levels as to three standards

앞의 결과를 바탕으로 그림 2의 헤밍네트워크에 적용한다. Feedforward 레이어 weight matrix W^1 에는 10개 배터리의 특성파라미터(C1~C7)들이 1과 -1로 변환된 벡터형태로 저장되어 있다. 헤밍네트워크에 들어온 임의의 입력도 벡터로 변환되어 W^1 과 내적을 수행한다. Recurrent 레이어의 입z력은 10개의 요소를 가지는 벡터이며 경쟁학습을 통해 0이 아닌 가장 큰 값을 찾는다.

$$W_1 = \begin{bmatrix} P_1^T \\ P_2^T \\ \vdots \\ P_{10}^T \end{bmatrix} \quad W_2 = \begin{bmatrix} 1-\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon \\ -\epsilon & 1-\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & -\epsilon & 1 \end{bmatrix}$$

$R=21(7 \times 3), S=10, \epsilon=0.1, b=3$

4. 2 분석 결과

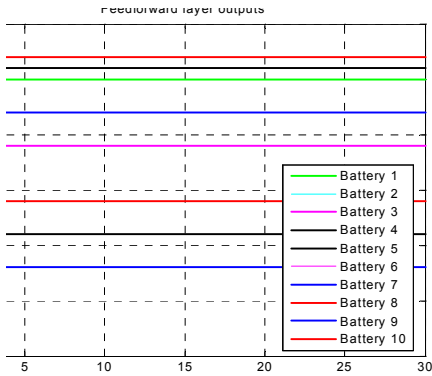


그림 8 Feedforward 레이어 출력값
Fig. 8 Feedforward layer outputs

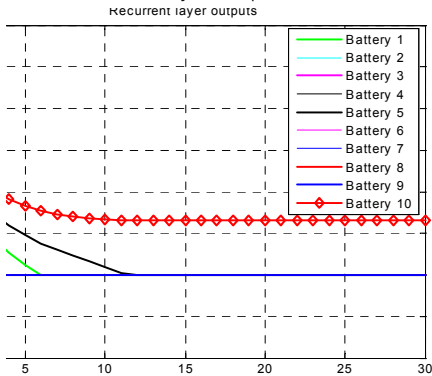


그림 9 Recurrent 레이어 출력값
Fig. 9 Recurrent layer outputs

그림 8은 Feedforward 레이어에서 내적을 수행하고 난 뒤의 결과이다. 이 결과는 Recurrent 레이어의 입력으로 들어가게 된다. 그림 9는 경쟁학습(Win-take-all)을 통해 얻어지는 출력값을 나타낸다. 경쟁학습에서의 승자는 0이 아닌 값을 가지며 다른 이의 값은 모두 0을 나타낸다. 임의의 배터리는 10번 배터리와 가장 유사한 패턴을 가진 것으로 예측되었다. 이를 검증하기 위해 10개 실험 배터리와 임의의 배터리의 DCIR값을 구하였다. 표 2는 SOC 30, 60%일 때 10개 배터리의 DCIR 값을 나타내며 그림 10은 임의의 배터리의 DCIR값을 나타내었다. 10번 배터리와 유사함을 알 수 있다. 그림 9를 통하여 5, 10번 배터리가 마지막까지 경쟁을 하였으며 5번도 10번과 근접한 값을 가짐을 알 수 있다.

표 2 10개 프레스 배터리 DCIR (30, 60% SOC)
Table. 2 10 fresh batteries DCIR (30, 60% SOC)

	1번	2번	3번	4번	5번
30%	0.072Ω	0.071Ω	0.079Ω	0.070Ω	0.070Ω
60%	0.071Ω	0.073Ω	0.080Ω	0.071Ω	0.071Ω
	6번	7번	8번	9번	10번
30%	0.078Ω	0.078Ω	0.079Ω	0.072Ω	0.070Ω
60%	0.080Ω	0.078Ω	0.080Ω	0.073Ω	0.069Ω

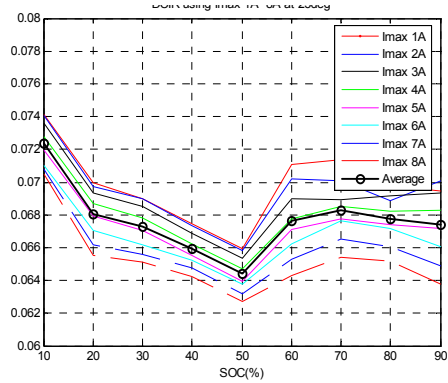


그림 10 임의의 배터리의 DCIR (SOC 10~90%, 1A-8A)
Fig. 10 Direct current internal resistance

4. 결론

배터리의 SOH를 알기 위하여 헤밍네트워크를 이용한 방법을 연구, 분석하였다. SOH를 잘 나타내는 척도인 펄스파워는 배터리 임피던스에 따른 전압의 함수로 이루어진다. 배터리 충전 전압 프로파일을 이용하여 특성파라미터 추출, 통계처리에 따른 전압패턴을 완성하여 이를 헤밍네트워크상에 적용하였으며 0이 아닌 출력값을 얻음으로써 임의의 배터리 특성에 가장 잘 맞는 배터리 패턴을 선정하였다. 검증을 위해 각 배터리의 DCIR값을 구하고 앞의 패턴선정 결과와 확인하였다. 이번 논문은 상온에서 프레스 배터리를 이용하여 진행되었다. 향후 배터리의 노화와 온도를 고려한 전압패턴이 구성되어야 하며 파워패턴을 적용하는 방법도 강구되어야 한다.

이 논문은 교육과학기술부/한국과학재단(R11-2002-102-00000-0)의 ERC 프로그램 연구비 지원에 의하여 연구되었습

참고 문헌

[1] Hagen, M. T., Demuth, H. B., and Beale, M., 1995, Neural Network Design, PWS Publishing Co., Boston.
[2] Jong Hoon Kim, Seong Jun Lee, Jae Moon Lee, Bo Hyung Cho, "A New Direct Current Internal Resistance and State of Charge Relationship for the Li-Ion Battery Pulse Power Estimation" 7th International Conference On Powerelectronics, Daegu, 2007