

신경회로망을 이용한 전기자동차용 배터리 잔존용량계

변성천*, 김의선, 류영재, 임영철
전남대학교 전기공학과

State of Charge Indicator for Electric Vehicle using Neural Networks

Sung-Chun Byun*, Eui-Sun Kim, Young-Jae Ryoo, Young-Cheol Lim
Dept. of Electrical Engineering, Chonnam National University

Abstract - A new approach to developing battery SOC indicator for electric vehicle is discussed in this paper. One of the most difficult problems associated with the development of electric vehicle is the battery indicator which reliably informs the state of charge(SOC) of the battery to the driver. And the condition to be satisfied with SOC indicator installed on the electric vehicle is that it should be used under frequently variable load. A new method to determining SOC using neural networks(NN) is proposed to satisfy the condition. The training data of NN are obtained by using mathematical model of lead-acid battery, and calculating discharge currents and terminal voltages while battery discharges with constant current. The 3-layered NN with back propagation algorithm is used. Simulation results show that the proposed method is appropriate as SOC indicator of the battery.

1. 서 론

본 연구에서는 전기자동차의 효율적인 운행과 갑작스런 운행 정지라는 위급한 상황을 방지하기 위해 내연기관 자동차의 연료계의 역할을 하는 전기자동차용 배터리 잔존용량계를 제안하였다. 전기자동차와 같이 부하전류가 급변하는 시스템에서 사용할 수 있도록 언제나 순간 순간 단자전압과 방전전류만을 계속하면, 정확하게 잔존용량을 알 수 있도록 신경회로망을 이용한 잔존용량계에 대해서 연구하였다.

일반적으로 잔존용량(SOC)을 측정하는 방법에는 전해액의 비중을 측정하는 비중계법, 전지가 무부하 상태에서 전압을 측정하는 개로전압 측정법, 초기 설정된 전계 배터리 용량에서 방전된 전류의 양을 감산해서 잔존 용량을 계산하는 축적전류계법 등이 있으며, 아래와 같은 문제점을 가지고 있다.

- (1)비중계법 : 배터리가 안정화된 상태에서 잔존용량을 가장 정확하게 나타낼 수 있으나, 전기 자동차와 같이 빈번히 변동하는 부하에는 사용할 수 없다 [1][2].
- (2)개로전압 측정법 : 전압이 안정화되는 시간이 필요하므로 부하가 급변하는 전기자동차용으로는 적합하지 못하다[1].
- (3)축적전류계법 : 초기의 배터리 용량을 정확히 설정해야 할 뿐 아니라, 오차의 축적으로 인해 시간이 경과함에 따라 많은 오차를 유발한다[3][4][5].

따라서, 본 연구에서는 배터리의 수학적 모델을 이용하여 방전특성곡선을 구하고, 여기서 계산된 단자전압, 방전전류와 잔존용량에 관한 관계를 다층 신경회로망에 학습시킨다. 이렇게 학습된 신경회로망을 이용하여 배터리의 전압과 전류만을 계속함으로써, 초기 잔존용량에 무

관하고, 부하가 변하는 상태에서도 정확하게 잔존용량을 산출해내는 신경회로망을 이용한 잔존용량계를 제안한다 (6)[7][8][9].

기존의 잔존용량계종의 하나인 축적전류계법과 본 연구에서 제안한 방법을 비교하므로써 타당성을 입증하였다.

2. 배터리 모델링

2.1 배터리 모델링

배터리를 수학적으로 모델링하기 위하여, 파라미터로 개방전압, 내부저항 및 잔존용량을 사용하였다. 잔존용량은 배터리로부터 흘러나간 전류를 연속적으로 적분해서 축적된 전류량을 초기 용량으로 나누어 산출하였다. 그리고, 개방전압은 배터리가 안정화된 상태에서 개방전압이 배터리의 잔존용량과 선형적인 관계가 있다는 사실을 이용하였다. 내부저항은 잔존용량에 의해 변한다는 사실을 바탕으로, 잔존용량에 대한 내부저항의 변화 데이터를 기존의 실험 데이터로 사용하였다. 표1에서 제시된 데이터 이외의 데이터에 대해서는 스플라인 3차 보간법을 이용하였다.

표1 배터리의 모델링 데이터

잔존용량(%)	개방전압(V)	내부저항(Ω)
100	2.13	0.00120
90	2.11	0.00120
80	2.09	0.00121
70	2.07	0.00121
60	2.05	0.00121
50	2.03	0.00122
40	2.01	0.00124
30	1.99	0.00124
20	1.97	0.00131
10	1.95	0.00144
0	1.93	0.00176

2.2 방전 특성 곡선

일정한 부하전류로 방전시켰을 때, 방전율에 따라 배터리의 단자전압이 비선형적으로 변한다. 방전전류를 다르게 하면, 방전시간과 방전종지전압이 변하지만, 일반적인 특성 곡선 형태는 유지한다. 배터리의 특성을 학습시키기 위해서 방전 특성 곡선을 이용하였고, 신경회로망의 학습데이터로서 입력데이터는 방전전류와 단자전압을 사용하였으며, 출력데이터는 잔존용량을 사용하였다. 그림 1.은 방전전류를 0.5C에서 2.7C까지 변화시키면서 단자전압의 변화를 표시하였다.




그림 1. 방전 특성 곡선.

3. 신경회로망

신경회로망은 비선형 시스템을 수학적으로 모델링할 필요가 없다는 장점을 가지고 있다. 상호 연결된 뉴런들에 의하여 임의의 입력과 출력 사이에 비선형 사상을 하는 것으로 생각할 수 있으며, 이러한 사상 특성에 따라 연상 기억, 필터, 인식, 최적화 등의 기능을 수행할 수 있다. 신경회로망의 분류방법 중 감독학습방법중의 하나인 역전파 알고리즘을 사용했다. 이 학습방법은 구성하기가 용이하며, 학습 계수의 선정에 따른 수렴성도 우수하기 때문에 군사적인 목적의 패턴인식에서부터 의학 진단, 자동제어 등의 다양한 분야에 널리 이용되고 있다[6].

3.1 학습과정

- ① 신경망의 모든 연결 가중치를 적당한 값으로 초기화하는 것이다. 이때 초기값은 주로 1보다 작은 임의의 값이 사용된다.
- ② 신경망에 학습시킬 입력패턴을 선정한다.
- ③ 학습스케줄에 의해 결정된 입력 패턴을 신경망에 경험하게 한다.
- ④ 신경망의 신경세포들을 차례로 동작시킨다.
- ⑤ 신경망의 출력패턴과 목표패턴을 비교한다.
- ⑥ 선택된 학습 규칙을 사용하여 연결 가중치를 조절한다.
- ⑦ 신경망이 모든 학습 패턴을 경험할 수 있도록 학습 스케줄에 따라 입력 패턴과 목적 패턴을 다시 선택하여 위의 과정을 반복한다.
- ⑧ 일곱번째 단계를 신경망이 완전히 학습할 때까지 반복한다.

3.2 역전파 알고리즘

본 논문에서는 배터리 모델로부터 데이터를 수집하고 이를 학습하기 위해 역전파 알고리즘을 이용하였다. 역전파 알고리즘이란 일반화된 델타 규칙이라고 불리는 감독학습 방식의 알고리즘으로서 다층 신경회로망을 통해서 얻고자 하는 목표 출력과 실제 출력과의 오차를 줄이는 방향으로 각 층의 가중치를 갱신하는 방법을 사용한다. 위의 방법은 순방향 연산과 역방향 연산으로 나누어진다[7].

순방향 연산에서 뉴런은 시냅스와 셀로 구성되는데 뉴런의 입력값과 가중치를 곱한 결과를 활성화함수를 거쳐 출력하게 된다. 이것은 다음의 식(1)과 식(2)에 의하여 표현된다.

$$net_j = \sum W_{ji} X_i \quad (1)$$

$$y_j = f(net_j) \quad (2)$$

역방향 연산은 순방향 연산의 결과값과 목표값의 오차를 식(3)에 의하여 구한다. 오차를 최소화하기 위하여 이를 역방향으로 전파하여 가중치를 갱신시킨다. 이것은 식(4)와 식(5)으로 표현된다.

$$\delta_j = (t_j - y_j) f'(net_j) \quad (3)$$

$$\Delta W_{ji} (t) = \eta \delta_j y_i + \alpha \Delta W_{ji} (t - 1) \quad (4)$$

$$W_{ji} (t + 1) = W_{ji} (t) + \Delta W_{ji} (t) \quad (5)$$

뉴런의 활성화함수는 시그모이드 함수를 사용하며 이는 비선형 함수로 다음 식(6)으로 나타낸다.

$$f(net) = [1 + \exp(-net)]^{-1} \quad (6)$$

3. 신경회로망을 이용한 잔존용량계

배터리의 비선형 특성때문에 배터리는 모델링하기 어렵다. 그래서, 배터리의 잔존용량을 수식적으로 계산하기 어렵기 때문에 모델링을 하지 않고, 신경회로망을 이용하여 배터리를 학습시켜 잔존용량을 알아내는 방법을 제안한다. 방전특성곡선을 이용하여 단자전압, 방전전류 및 잔존용량을 구하였다. 그리고, 그림 2.와 같이 방전전류와 단자전압은 신경망의 입력데이터로, 잔존용량은 출력데이터로 하여 10,000회 정도 학습시킨다. 이렇게 학습된 신경회로망은 입력층과 은닉층사이의 가중치와 은닉층과 출력층 사이의 가중치가 적절하게 조절한다. 학습이 완료된 상태에서 방전전류와 단자전압을 신경회로망에 입력하면, 학습에 의해서 조절된 가중치에 의해서 잔존용량을 산출한다. 은닉층의 신경소자를 약 10개 사용하면, 배터리의 방전특성곡선을 완전하게 표현할 수 있다.




그림 3. 신경회로망의 구조.

4. 모의실험

4.1 가변 부하에 대한 모의실험




그림 2. 가변부하에 대한 SOC.

부하전류가 변화하는 경우에 대하여 타당성을 검증하기 위해서 모의실험하였다. 그림 3. 에서 볼 수 있듯이 부하전류가 변함에 따라 배터리의 단자전압도 크게 변함을 볼 수 있다. 그러나, 신경회로망을 이용한 잔존용량계는 축적전류계법을 사용한 잔존용량값을 5% 범위 이내의 오차안에서 추종하고 있다.

4.2 축적전류계법과 제안된 방법의 비교

축적전류계법(AH; Ampere-Hour Method)이 이상적인 경우 즉, 샘플링 시간이 아주 짧아서 급변하는 모든 전류를 계속 측정 가능하다면, 잔존용량을 정확하게 측정하지만, 샘플링 시간이 길면 변화하는 모든 전류를 계속할 수 없어서 오차를 유발한다. 특히, 축적전류계법은 전류를 연속적으로 적분해가는 방식이므로 샘플링 시간에 의해 생긴 오차는 시간이 경과함에 따라 누적되어 큰 오차를 유발한다. 그림 4.와 그림5. 에서 샘플링 시간이 짧은 경우, 샘플링 시간이 긴 경우와 제안된 방법에 의한 경우를 비교하였다. 오차를 줄이기 위해서는 샘플링 시간을 짧게 하면 되지만, 이는 고기능, 고가격의 하드웨어를 요구하게 된다.




그림 4. 완만한 부하에 대한 축적전류계법과 비교.




그림 5. 급변하는 부하에 대한 축적전류계법과 비교.

5. 결 론

잔존용량계를 전기자동차가 사용할 수 있기 위해서는 급변하는 부하전류에도 사용할 수 있어야 한다. 대부분의 잔존용량계는 배터리가 안정화되기까지 기다려야 한다는 문제점이 있어 사용하기 부적당하다. 축적전류계법은 초기 배터리 용량을 알아야 한다는 문제점을 가지고 있기 때문에, 비중계법이나 개로전압법을 병합하여 초기의 잔존용량을 알아내기도 한다. 그러나, 축적전류계법

은 정확한 잔존용량을 측정하기 위해서 샘플링 시간에 의한 오차가 누적되어 커진다는 단점을 가지고 있다.

제안된 방법은 다음과 같은 특징이 있다.

1. 잔존용량값을 알고자 할 때만 단자전압과 방전전류값을 계속하면 되므로, 고기능, 고가격의 하드웨어가 필요하지 않다.
2. 모의실험에 의하면, 10 ~ 30 이내의 은너층의 신경소자만을 구성하여도 배터리의 특성을 표현 가능하므로, 적은 메모리로 구현할 수 있어서, 하드웨어에 대한 부담을 줄일 수 있다.

본 연구에서 모의실험은 근사적인 배터리 모델의 데이터틀을 이용하였고, 신경회로망을 이용하여 적절히 배터리 특성을 학습하였다.

앞으로 온도에 의한 잔존용량의 변화에 관한 연구가 필요하다.

(참 고 문 헌)

- [1] James H. Aylor, "A Battery State-of-Charge Indicator for Electric Wheelchairs", *IEEE Transactions on Industrial Electronics*, Vol.39, No.5, October 1992.
- [2] R. Weiss, J. Appelbaum, "Battery State of Charge Determination in Photovoltaic Systems", *Electrochem. Soc.* Vol.129, no.9, pp.1928-33, 1982.
- [3] Minoru Kitagawa, Hiroshi Shibuya, Jun Takenhara, Nao Kasagi, Norihiro Okubo, "Development of Battery State of Charge Indicator for Electric Vehicles", Technical Research Center, pp. 293-302, 1993.
- [4] J.H Aylor and K.L Short, "A Microcomputer-based Battery Monitor," *Proc. 1985 RESNA Conf., Memphis, TM June 24-28, 1985.*
- [5] C.Armenta-Deu, T.Donaire "Statistical Analysis of the Error Function in the Determination of the State-of-charge in Lead/acid Batteries.", *J. Power Sources (Switzerland)*, Vol.39, no.1, pp.95-105, 1992.
- [6] R. Hecht-nielsen, "Neurocomputing: Picking the human brain", *IEEE Spectrum*, pp. 36-41, 1988.
- [7] J. M. Zurade, Introduction to artificial neural systems, Info access distribution pte ltd, pp. 185-206, 1992.
- [8] C. T. Lin and C. S. G. Lee, Neural Fuzzy Systems, Prentice Hall, Upper Saddle River, 1996.
- [9] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning internal representations by error propagation", *Parallel Distributed processing*, vol. 2, pp. 318-362, MIT Press, Cambridge, 1987.