

Adaptatividade na Estimativa da Capacidade de Baterias Estacionárias

Patrick Cadier D’Aquino e Baroni Santos

Escola Politécnica
Universidade de São Paulo
São Paulo, Brasil
patrickcdbs@gmail.com

Resumo— Neste artigo é proposto um método adaptativo para medir a capacidade e o envelhecimento de baterias estacionárias. Neste projeto usou-se redes neurais para estimar a capacidade de uma bateria com os valores da resistência e capacitância interna dessa bateria. Os dados recolhidos são apresentados e analisados. Com esses dados foi possível criar um sistema que estime a capacidade da bateria e que se adapte a novos dados apresentados.

Palavras chaves—Baterias estacionárias, adaptatividade, SOH.

I. INTRODUÇÃO

Baterias de lítio-íon são essenciais para diversos projetos em eletrônica e o uso delas está aumentando devido aos avanços tecnológicos e ao barateamento dos circuitos eletrônicos. Uma aplicação para baterias de lítio são baterias estacionárias, elas fornecem energia quando a fonte principal não está presente, ou seja, elas funcionam como um buffer para a fonte principal. Esse tipo de aplicação é importante para sistemas de segurança ao se protegerem de quedas de energia. As baterias podem fornecer energia quando há um pico de demanda ou quando não há fornecimento de energia por outra fonte. Dois parâmetros essenciais para a análise do estado da bateria são o SOC (State Of Charge ou estado da carga) e o SOH (State Of Health ou estado de saúde).

A. SOC: State Of Charge

Suozzo [1] explica que o SOC descreve o quanto a bateria já foi descarregada em relação a sua capacidade nominal. Como esse parâmetro é escrito em porcentagem, 100% representa uma bateria com a carga igual a sua capacidade nominal e 0% representa uma bateria totalmente descarregada. Um dos métodos para prever o SOC é contagem de Coulomb como é descrito por Juang [2]. Medindo a corrente de saída é possível prever o quanto resta de carga na bateria. Os outros métodos descritos por Juang [2] são a estimativa pela tensão nos terminais ou pela impedância de saída. O problema de estimar o SOC pela tensão nos terminais é que a impedância da descarga ou da carga influencia na medição e muitas vezes não é possível medir a tensão em circuito aberto (Juang [2]).

B. SOH: State Of Health

O SOC é ruim para mostrar o estado de vida da bateria, pois uma bateria carregada terá um SOC de 100%

independente se ela está envelhecida ou nova. Para isso temos o SOH. O SOH é definido por Chen et al [3], Barlak et al [4] e Le et al [5] como a relação entre a capacidade atual da bateria e a capacidade nominal da bateria. Como pode ser visto na equação, o SOH é um número expresso em porcentagem.

$$SOH = \frac{C_{\text{atual}}}{C_{\text{nominal}}} \times 100\% \quad (1)$$

Portanto o SOH quantifica o quanto a bateria envelheceu. Diferentes fontes (GPI [6], Groot [7], He et al [8] e Xing et al [9]) explicam que a bateria atinge o fim da vida (EOL – End Of Life) quando o SOH chega a 80%. He et al [8] afirma que uma bateria com SOH menor que 80% tem ciclos de carga e descarga muito instáveis, pois a sua perda de capacidade tem um caráter exponencial.

C. Outros parâmetros

Outro conceito usado no estudo de baterias é o SOF (State of Function ou estado de funcionalidade). Segundo Juang [2], o SOF é normalmente uma pergunta de Sim ou Não que indica se a bateria está apta a realizar determinada função de uma aplicação. O exemplo mais comum é se a bateria do carro tem carga suficiente para ligá-lo.

II. REDES NEURAIS

Mukherjee [10] compila as diferentes publicações que usam redes neurais para gerenciar baterias, medindo principalmente o SOC e o SOH de baterias. Mukherjee [10] e O’Gorman et al [11] justificam que o uso de redes neurais para esse propósito é vantajoso porque a análise deixa de ser estática e depende menos dos dados adquiridos em laboratórios. Como os parâmetros variam de modelo para modelo e de bateria para bateria, o uso de redes neurais na análise seria uma maneira de contornar isso. O’Gorman et al [11] explica outras vantagens das redes neurais como a baixa complexidade computacional desse método. Portanto usando redes neurais é possível economizar tempo na análise e na medição dos parâmetros (O’Gorman et al [11]).

Nesse projeto usou-se uma rede neural com duas camadas internas, a primeira com 9 neurônios e a segunda com 5 neurônios. Uma representação da rede pode ser vista a seguir.

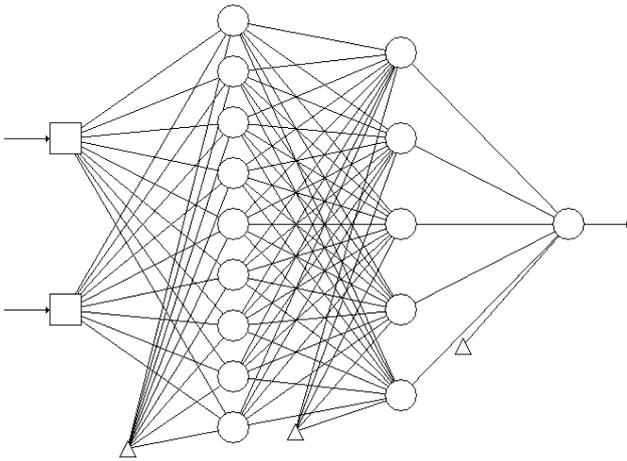


Fig. 1. Representação da rede neural.

III. ADAPTATIVIDADE

O conceito de adaptatividade é um conceito amplo, por isso temos na literatura várias formas de definir esse conceito. Santos [12] define um dispositivo adaptativo como um dispositivo que “pode ser representado por um conjunto de regras expressas em qualquer formato e um conjunto de operações associado a cada uma das regras”. Com essa definição, a adaptatividade pode ser usada em diversas áreas basta que o algoritmo seja definido por um conjunto de regras. Assim as operações associadas a essas regras modificam as repostas do algoritmo. Santos [12] utiliza as formulações definidas por Neto [13]: o dispositivo adaptativo é composto por um dispositivo não adaptativo e um mecanismo adaptativo (Neto [13]). Além disso para definir o dispositivo é preciso definir um conjunto de regras não adaptativas, um conjunto de regras adaptativas, um conjunto de ações adaptativas e os mecanismos que relacionam uma ação adaptativa a uma regra adaptativa.

Whittle et al [14] definem sistemas adaptativos como sistemas com a “capacidade de maneira autônoma de modificar o seu comportamento” durante a execução. Segundo Whittle et al [14], um dos principais desafios de sistemas adaptativos é lidar com a incerteza, tanto a incerteza que deriva das entradas quanto a incerteza que deriva dos requisitos, que poderiam mudar de caso a caso.

Porém a formulação escolhida em redes neurais adaptativas é um pouco diferente. Cichocki et al [15] diminuem o tempo de convergência modificando a taxa de aprendizado de acordo com os dados de entradas. Diferente do que é feito em redes neurais não adaptativas onde é utilizada uma taxa de aprendizado fixa ou uma taxa de aprendizado que diminui com uma função pré-definida. Shun-ichi et al [16] fazem algo parecido ao usarem um algoritmo adaptativo para modificar o algoritmo de aprendizagem da rede neural em busca de maior eficiência estatística e menor tempo de convergência. Lin et al [17] apresentam uma solução parecida para um sistema híbrido entre rede neural e lógica fuzzy. O principal objetivo também é diminuir o tempo de convergência do algoritmo de aprendizado, o que é crítico principalmente para a inferência

das regras do sistema de lógica fuzzy tradicional. No artigo, Lin et al [17] apresentam duas soluções híbridas e mostram que a adaptatividade do algoritmo de aprendizagem apresenta resultados melhores que o sistema tradicional.

Podemos concluir que a adaptatividade é principalmente usada em redes neurais para facilitar e simplificar o processo de aprendizado e diminuir o tempo de convergência, ou seja um pouco diferente do que é feito em outras áreas da adaptatividade.

IV. MÉTODO

Nesse estudo foi coletado 1050 dados de 21 baterias. Para cada dado foi coletado a resistência e a capacitância interna da bateria medida por um micro controlador. Além disso, mediu-se a capacidade da bateria naquele momento, o que permitiu calcular o SOH. Os gráficos da relação entre capacitância, resistência e SOH são os seguintes.

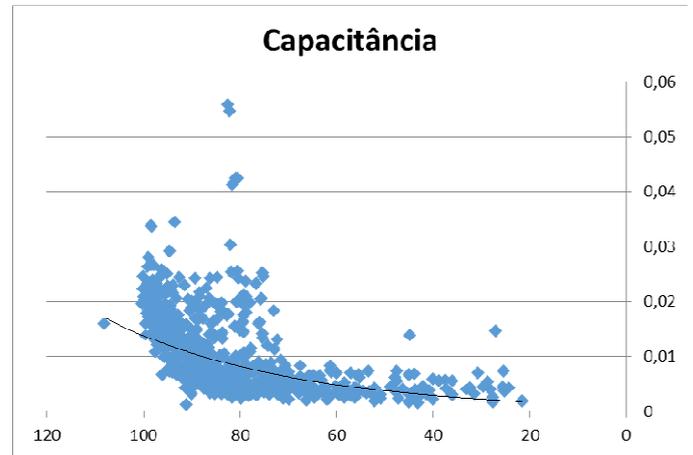


Fig. 2. Relação entre a capacitância e o SOH.

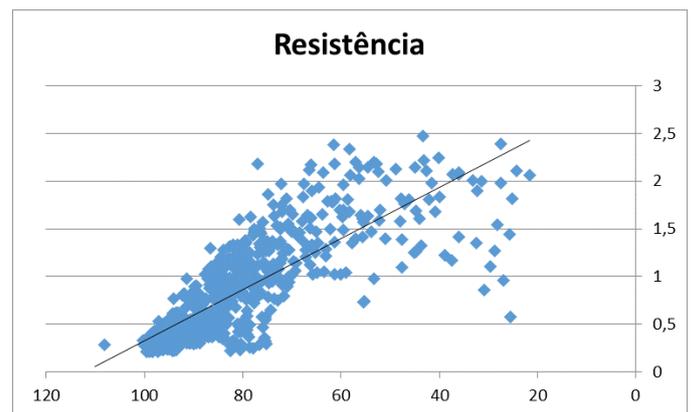


Fig. 3. Relação entre a resistência e o SOH.

Diferentemente do que é feito na literatura, inserimos adaptatividade na rede neural depois da rede neural já ter os seus pesos definidos. Primeiramente, foi usado os dados de 20 baterias (1000 conjuntos de dados) para treinar a rede neural, em seguida os 50 dados da última bateria restante foram usados para testar a rede neural e o algoritmo adaptativo, mudando os pesos da rede neural (ou as regras de execução da rede neural)

para que esta se adapte aos dados da última bateria, estimando com maior precisão a capacidade atual da bateria. Repetiu-se o processo 21 vezes, criando assim 21 redes neurais, uma para cada bateria, e o objetivo era atualizar esses dados de forma adaptativa e verificar que o erro médio fosse menor.

Nesse processo, simulamos a obtenção de dados que o dispositivo conectado à bateria conseguiria. Como a função da rede neural é prever a capacidade em um momento da bateria, e essa capacidade muda de tempo em tempo, o dispositivo terá que realizar diversas previsões. Assim, a vantagem de uma rede neural adaptativa é que as previsões ficam mais precisas para cada dado recebido. É importante notar que essa técnica só é possível em caso onde a capacidade da bateria pode ser medida de outra maneira. Por exemplo, se soubermos a corrente de descarga, é possível calcular a capacidade da bateria com o tempo de descarga. Portanto no estudo os dados possuem uma ordem definida e o objetivo será melhorar a previsão do próximo dado. Uma aplicação que essa técnica pode ser utilizada é na medição da qualidade de baterias de desfibriladores. Quando a bateria está nova, é conhecido o número de vezes que o desfibrilador pode ser usado com uma carga cheia. Assim, um modo de calcular o SOH dessa bateria é o número vezes que o aparelho foi usado. Obtém-se assim a evolução do SOH.

No final, o erro médio da rede neural adaptativa é comparado ao erro médio da rede neural inicial. O esperado era que o erro médio da rede adaptativa diminuísse para cada dado novo e que fosse menor que o erro médio da rede inicial. Como veremos nos resultados, a diminuição não é constante nem garantida. Por isso, criou-se um 2º algoritmo adaptativo que atualizava a rede somente quando a diferença entre o erro médio da rede inicial e o erro médio adaptativo aumentasse. A premissa é que os dados que obtiveram um erro maior na rede adaptativa são diferentes dos outros dados da bateria por razões aleatórias (temperatura ambiente, corrente de carga ou descarga, etc). Assim para obter um erro médio adaptativo menor, esse dado é ignorado na atualização da rede.

Além disso, o dispositivo pode escolher qual das duas redes (a adaptativa ou a inicial) ele utilizará para prever o próximo dado considerando qual tem um erro médio menor para os dados já adquiridos. Sendo assim, criou-se um 3º algoritmo que escolhe a previsão da rede com menor erro médio atual.

A premissa é que os dados mudam um pouco de bateria para bateria e que os dados de uma dada bateria são mais próximos entre si. Os algoritmos adaptativos buscam se aproveitar dessa particularidade para obter resultados mais precisos.

Esses algoritmos são simples de serem implementados em micro controladores, os mesmos necessários para fazer as medições da resistência e capacitância interna das baterias.

V. RESULTADOS

A. Primeiro algoritmo adaptativo

Em um primeiro passo, criou-se um algoritmo adaptativo que simplesmente atualizava os seus pesos para cada dado

obtido. Na seguinte tabela temos os resultados dos erros médios de cada rede para os 50 dados de cada bateria.

TABLE I. ERRO MÉDIO NO PRIMEIRO ALGORITMO

Bateria	Erro médio no primeiro algoritmo		
	Erro médio para os 50 dados	Erro médio adaptativo para os 50 dados	Diminuição em %
1	6,224	5,62	9,704
2	1,837	1,855	-1,005
3	6,392	4,359	31,806
4	6,535	6,026	7,795
5	10,603	9,886	6,768
6	8,497	5,655	33,45
7	8,708	9,055	-3,826
8	5,991	5,672	5,328
9	8,808	5,347	39,293
10	6,734	6,472	3,886
11	3,163	3,277	-3,454
12	5,495	4,634	15,665
13	5,726	6,517	-12,137
14	7,32	6,324	13,607
15	8,901	5,275	40,737
16	8,281	6,002	27,526
17	10,599	12,751	-16,876
18	15,268	9,769	36,015
19	10,209	10,13	0,78
20	8,059	7,808	3,106
21	8,906	10,122	-12,011
Média	7,727	6,788	12,143

Como podemos ver na tabela, algumas redes adaptativas possuem resultados piores que a rede inicial. A rede da bateria 17 por exemplo tem um aumento do erro médio da ordem de 16,9%. Entretanto a média de diminuição do erro é alta (12,14%) e mostra que com poucos dados já é possível especializar a rede neural para a determinada bateria.

Outros resultados importantes são as evoluções do erro médio da rede neural adaptativa em comparação com o erro médio da rede inicial. Essa análise permitiu modificar o algoritmo adaptativo para otimizá-lo.

Era esperado que a diminuição do erro médio seguisse uma curva parecida à curva da bateria 3, que pode ser vista na seguinte figura.

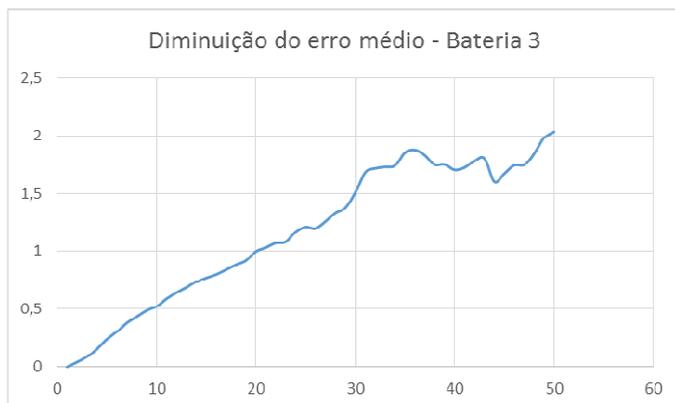


Fig. 4. Diminuição do erro médio da bateria 3 para cada dado novo no 1º algoritmo.

Como podemos ver na figura, a curva é em sua maior parte crescente e monótona, indicando que o erro médio diminuiu constantemente. Porém não é o que vimos na maioria dos casos. Um caso que pode ilustrar isso é o caso da bateria 5, como é visto no seguinte gráfico.

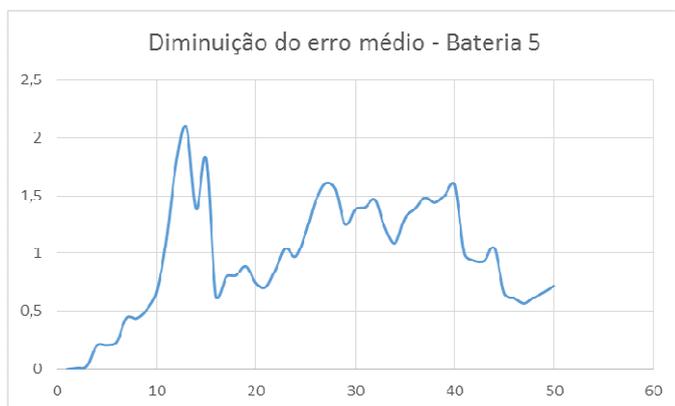


Fig. 5. Diminuição do erro médio da bateria 5 para cada dado novo no 1º algoritmo.

Apesar do erro médio adaptativo sempre ser menor que o erro médio inicial, já que a curva sempre é positiva, a curva tem diversos pontos de inflexão. Ou seja, alguns dados aumentam o erro médio adaptativo e seriam tratados melhores pela rede inicial. Assim, as últimas previsões não são as mais precisas do conjunto de dado. Claramente há espaço para otimizar esse algoritmo. Por isso criou-se um novo algoritmo descrito anteriormente para aproveitar somente os dados que possuem melhor relação entre si.

B. Segundo algoritmo adaptativo

Criou-se um novo algoritmo que não atualiza a rede neural adaptativa quando o novo dado diminuiu a diferença entre o erro médio da rede inicial com o erro médio da rede adaptativa, ou seja, toda vez que há uma queda na curva da diferença dos erros. O objetivo é que as curvas tenham uma forma mais parecida com a curva da bateria 3.

Na tabela a seguir podemos ver que houve uma melhora no algoritmo.

TABLE II. ERRO MÉDIO NO SEGUNDO ALGORITMO

Bateria	Erro médio no primeiro algoritmo		
	Erro médio para os 50 dados	Erro médio adaptativo para os 50 dados	Diminuição em %
1	6,786	6,383	5,951
2	2,061	2,518	-18,152
3	6,222	4,318	30,6
4	6,455	5,925	8,213
5	10,646	8,249	22,519
6	8,875	5,665	36,166
7	8,267	8,816	-6,227
8	7,067	6,104	13,62
9	9,047	5,749	36,447
10	7,556	8,861	-14,721
11	2,676	2,797	-4,339
12	5,614	4,351	22,505
13	6,705	7,077	-5,252
14	7,543	6,909	8,4
15	8,886	4,429	50,16
16	7,441	5,492	26,192
17	10,243	11,565	-11,424
18	15,627	10,573	32,344
19	10,269	10,551	-2,668
20	8,263	8,295	-0,377
21	9,882	10,652	-7,23
Média	7,911	6,918	12,553

Em algumas baterias o 2º algoritmo obteve um resultado pior, como é o caso da bateria 3, porém na média o resultado do 2º algoritmo é melhor.

Uma das baterias que obtiveram uma melhora considerável foi a bateria 5, como podemos ver na figura.

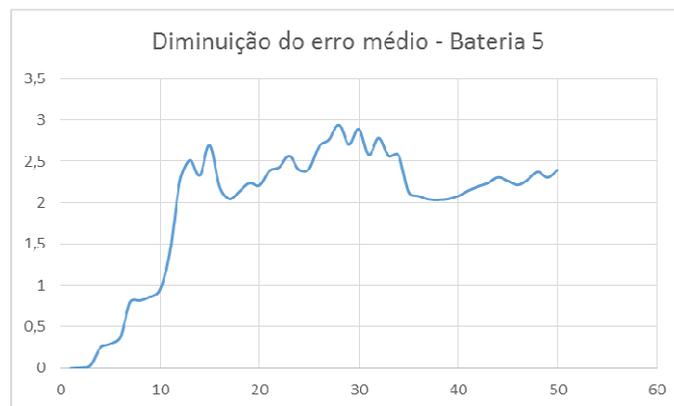


Fig. 6. Diminuição do erro médio da bateria 5 para cada dado novo no 2º algoritmo.

Podemos ver que nesse exemplo o objetivo da premissa foi atingido já que as quedas que ocorrem na curva do 1º algoritmo ocorrem com menor intensidade no 2º algoritmo, diminuindo os efeitos negativos de um dado que diverge do restante do conjunto de dados.

C. Terceiro algoritmo adaptativo

Nesse 2º algoritmo, é necessário calcular os resultados das duas redes neurais e algumas vezes a rede neural inicial obtém resultados melhores. Por isso, criou-se um 3º algoritmo que escolhe o resultado da rede neural (rede neural inicial ou rede neural adaptativa) que tem o menor erro médio no conjunto de dados já adquiridos daquela bateria. Essa diferença é simples de projetar e evita que a previsão seja piorada.

Os resultados desse 3º algoritmo estão na seguinte tabela.

TABLE III. ERRO MÉDIO NO TERCEIRO ALGORITMO

Bateria	Erro médio no primeiro algoritmo		
	Erro médio para os 50 dados	Erro médio adaptativo para os 50 dados	Diminuição em %
1	6,786	6,383	5,951
2	2,061	2,119	-2,725
3	6,222	4,318	30,6
4	6,455	5,998	7,088
5	10,646	8,249	22,519
6	8,875	5,665	36,166
7	8,267	8,269	-0,022
8	7,067	6,104	13,62
9	9,047	5,749	36,447
10	7,556	7,761	-2,635
11	2,676	2,808	-4,708
12	5,614	4,39	21,807
13	6,705	6,845	-2,04
14	7,543	6,909	8,4
15	8,886	4,429	50,16
16	7,441	5,492	26,192
17	10,243	10,795	-5,107
18	15,627	10,934	30,035
19	10,269	10,643	-3,514
20	8,263	8,336	-0,868
21	9,882	10,013	-1,313
Média	7,911	6,772	14,401

Como vemos, a vantagem do 3º algoritmo em relação ao 2º se dá nos conjuntos de dados onde o 2º algoritmo é pior que a rede inicial. Para esses casos o erro diminuiu consideravelmente. Porém para os casos onde o 2º algoritmo é melhor que o 3º (bateria 4 por exemplo), a diferença entre os dois não é considerável.

Podemos ver a vantagem do 3º algoritmo no gráfico da bateria 10. Enquanto o 2º algoritmo é melhor que a rede inicial, o 3º algoritmo não oferece vantagem, porém a partir da 34ª medida, o 3º algoritmo evita que erro aumente.

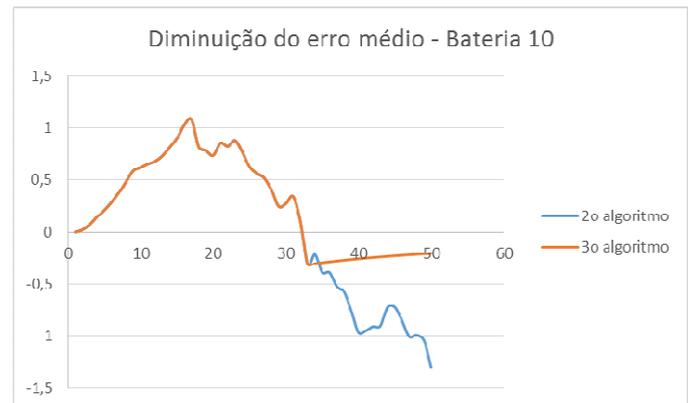


Fig. 7. Comparação da diminuição do erro médio para o 2º e 3º algoritmo com a bateria 10.

Em suma, três algoritmos adaptativos foram criados para reduzir o erro médio da previsão do próximo dado a ser coletado. A diminuição do erro médio obtida pelo 3º algoritmo (o mais completo) para os 21 conjuntos de dados foi de 14,4%. Esses algoritmos podem ser facilmente inseridos no código do micro controlador que controla a bateria.

VI. CONCLUSÃO

É possível concluir que o objetivo foi atingido já que um algoritmo adaptativo foi projetado e apresentou resultados satisfatórios para o conjunto de testes. Além disso, o algoritmo não oferece grande esforço computacional, garantindo que possa ser usado em diversas aplicações que usem baterias estacionárias.

O algoritmo no final permite minimizar erros decorrentes de peculiaridades das baterias usadas e melhorar a previsão da capacidade da bateria.

REFERÊNCIAS

- [1] C. Suozzo, Lead-acid battery aging and state of health diagnosis, 2008
- [2] L.W. JUANG, Online battery monitoring for state-of-charge and power capability prediction, 2010.
- [3] Z. Chen, C.C. mi, Y. Fu, J. Xu, X. Gong, "Online battery state of health estimation based on Genetic Algorithm for electric and hybrid vehicle applications." Journal of Power Sources, 240: 184-192, 2013.
- [4] C. Barlak, Y. Özkazanç, "Determination of battery state-of-health via statistical classification." Commun. Fac. Sci. Univ. Ank. Series A2-A3 vol. 52(2) pp 1-9 2010.
- [5] D. Le, X. Tang, "Lithium-ion Battery State of Health Estimation Using Ah-V Characterization." Annual Conference of the Prognostics and Health Management Society, 2011
- [6] "Lithium Ion technical handbook" Gold Peak Industries Ltd. November 2003.
- [7] J. Groot, State-of-Health Estimation of Li-ion Batteries: Cycle Life Test Methods
- [8] W. He, N. Williard, M. Osterman, M. Pecht, "Prognostics of lithium-ion batteries based on Dempster-Shafer theory and the Bayesian Monte Carlo method." Journal of Power Sources 196, 10314– 10321, 2011
- [9] Y. Xing, E.W.M Ma, K.L. Tsui, M. Pecht, "Battery management systems in electric and hybrid vehicles." Energies, 4, 1840-1857 ,2011
- [10] A. Mukherjee, Advances in battery management using neural networks and fuzzy logic. 2003.

- [11] C.C. O’gorman, D. Ingersoll, R.G Jungst, T.L. paez, “Artificial Neural Network Simulation of Battery Performance.” IEEE 98, 2008.
- [12] J.M.N. Santos, “Dispositivos Adaptativos Cooperantes”, X Workshop de Tecnologia Adaptativa”, 2016.
- [13] J.J. Neto, “Adaptative rule-driven devices – general formulation and a case study”, In: CIAA’2001 Sixth International Conference on Implementation and Application of Automata, pages 234–250, Pretoria, South Africa, July 2001.
- [14] J. Whittle; P. Sawyer; N. Bencomo; B.H.C. Chengy; J.M. Bruel, “RELAX: Incorporating Uncertainty into the Specification of Self-Adaptive Systems”, Requirements Engineering Conference, 2009.
- [15] A. Cichocki, S. Amari, M. Adachi, W. Kasprzak, “Self-Adaptive Neural Networks For Blind Separation Of Sources”, IEEE International Symposium On Circuits And Systems, 1996.
- [16] S. Amari, A. Cichocki, “Adaptive Blind Signal Processing – Neural Network Approaches”, Proceedings Of The IEEE, vol. 86, no. 10, 1998
- [17] C. Lin, C.S. Lee, “Neural Network Based Fuzzy Logic Control And Decision System”, IEEE Transactions On Computers, vol 40, no 12, 1991