Análise de Topologias de Redes Neurais Artificiais NARX na Estimação do Estado de Carga de Baterias de Lítio-Íon

Jonathan J. P. Moura* Juan M. M. Villanueva*
Frank W. Rodrigues* Pedro H. M. de Andrade*

* Departamento de Engenharia Elétrica, Universidade Federal da Paraíba, PB, (e-mail: {jonathan.moura, jmauricio, frank.rodrigues, pedro.andrade}@cear.ufpb.br)

Abstract: The State of Charge (SoC) is a parameter of fundamental importance for the correct operation of the Battery Management Systems (BMS). Determining the SoC of a battery is not a simple task since the relationship between the SoC and the battery voltage presents a high nonlinearity. In this context, the present work contains a performance analysis of SoC estimators for lithium-ion batteries based on Artificial Neural Networks on the point of view of the number of neurons per layer and the number of layers of the network. The structure of the networks was analyzed aiming to observe the impact that these variations would generate in the performance of the SoC estimation. After metrics verification, networks with two layers showed better performance when compared to only one layer, having an MSE and MAPE value of 0,0073 and 0,1509%, respectively.

Resumo: O Estado de Carga (SoC) é um parâmetro de fundamental importância para a correta operação de Sistemas de Gerenciamento de Baterias (BMS). Determinar o SoC de uma bateria não é uma tarefa simples, uma vez que a relação entre o SoC e a tensão da bateria apresenta uma elevada não-linearidade. Neste contexto, o presente trabalho contém uma análise de desempenho de estimadores SoC para baterias de lítio-íon baseado em Redes Neurais Artificiais a partir de análises de quantidade de neurônios por camada e quantidade de camadas da rede. A estrutura das redes foi analisada objetivando observar o impacto que estas variações iriam gerar no desempenho da estimação do SoC. Após verificação das métricas, as redes com duas camadas apresentaram um melhor desempenho quando comparado apenas uma camada, tendo um valor de MSE e MAPE de 0,0073 e 0,1509%, respectivamente.

Keywords: State of Charge, Lithium-ion batteries, Artificial Neural Network.

Palavras-chaves: Estado de Carga, baterias de Lítio-íon, Redes Neurais Artificiais.

1. INTRODUÇÃO

Estudos de sistemas utilizados para gerenciar o armazenamento de energia elétrica têm crescido nas últimas duas décadas, tornando-se foco de interesse para pesquisadores, montadoras de automóveis, empresas de geração de energias alternativas e renováveis, etc. O setor automotivo, acima de tudo, está agora à beira de uma mudança drástica, uma vez que os regulamentos internacionais sobre consumo de combustível e emissões de carbono estão se tornando cada vez mais recorrentes e, portanto, a fabricação de veículos comuns movidos a gasolina ou diesel pode não ser mais permitida (Cittanti et al., 2017).

O principal componente dos sistemas de armazenamento de energia são os bancos de baterias. Existem vários tipos de baterias empregadas nesta aplicação, como Níquel Metal Hidreto (Ni-MH), Níquel Cádmio (Ni-Cd), Lítio íon (Li-íon) e Chumbo Ácido. Baterias de Li-íon são largamente utilizadas em sistemas de armazenamento de energia devido a sua elevada densidade energética, alta

tensão de célula específica e custo reduzido (Ismail et al., 2017).

Independente da bateria, um dos parâmetros mais importantes para que a mesma opere de forma segura e que prolongue sua vida útil é o Estado de carga, do inglês *State of Charge* (SoC).

Determinar o SoC de uma bateria não é uma tarefa simples, uma vez que a relação entre o SoC e a tensão nos terminais da bateria apresenta uma elevada não-linearidade, dificultando o desenvolvimento de um modelo capaz de aproximar esta relação com exatidão. Além disto, a curva do SoC é afetada por vários outros fatores como envelhecimento e principalmente a temperatura ambiente a qual a bateria é submetida.

Uma limitação que dificulta a determinação do SoC se deve ao fato dele não ser obtido diretamente. Em vez disto, ele é estimado a partir de parâmetros mensuráveis da bateria como corrente, tensão nos terminais e temperatura (Chitnis et al., 2018). Existem vários tipos de métodos para estimação do SoC, como o método de Tensão de

Circuito Aberto (*Open Circuit Voltage- OCV*) e *Coulomb Counting*. Com o surgimento da inteligência artificial, Lógica *Fuzzy*, Filtros de Kalman e Redes Neurais Artificiais (RNA) foram incluídos neste tipo de aplicação (Liu et al., 2018).

Definir uma arquitetura e função de ativação capaz de realizar rapidamente o aprendizado dos parâmetros, de forma que a rede apresente grande capacidade de generalização, quase sempre é um processo dispendioso. Com isso, muitas pesquisas tem se concentrado neste assunto (Baldi et al., 2015).

Os métodos já conhecidos para determinação do SoC, muitas vezes, não consideram o efeito da variação de temperatura em seus modelos, tornando-os ineficientes em aplicações onde a bateria é submetida a alterações da temperatura ambiente.

Uma segunda consideração, diz respeito à determinação do SoC por meio de modelos utilizando RNA, em que a escolha da topologia de rede empregada pode afetar de forma considerável o desempenho do modelo.

Outro ponto observado é o uso da corrente de carga/descarga como parâmetro para determinação do SoC, que pode ser implementada através de sensores de corrente como: resistor *shunt* ou sensor de efeito *hall*. Resistores *shunt* consomem energia do sistema, e por outro lado os sensores de efeito *hall* possuem preços elevados.

Considerando o que foi dito, neste trabalho são realizadas comparações de topologias utilizando RNA do tipo Não-Linear Autorregressivas com Entradas Exógenas (NARX). As redes desenvolvidas contam com o diferencial de apresentar como parâmetros de entrada da rede a tensão nos terminais da bateria no instante k , temperatura no instante k e SoC no instante $k - 1$. Outro diferencial é a ausência da corrente na determinação do SoC, utilizando apenas tensão e temperatura como entradas externas, que são duas grandezas mensuradas de forma direta.

2. ESTADO DE CARGA (SOC)

Baterias são usualmente modeladas utilizando resistores, capacitores e alguns indutores. Durante cada ciclo de carga e descarga todos os parâmetros internos da bateria mudam com o SoC, de tal modo que este parâmetro varia de acordo com a química empregada na bateria.

Em geral, o SoC é definido como a razão entre a capacidade atual da bateria Q_{atual} e a capacidade nominal Q_{nom} , que pode ser dada por (1).

$$SoC(t) = \frac{Q_{atual}}{Q_{nom}} \times 100\% \quad (1)$$

A capacidade nominal difere de bateria para bateria e é dada pelos fabricantes, ela representa a carga máxima da bateria (Khayat and Karami, 2016).

3. MODELO DA BATERIA

Nesta seção, é descrito o modelo de bateria usado para desenvolver as RNAs propostas neste trabalho, assim como uma breve explicação dos efeitos térmicos do SoC nas baterias de Li-íon.

3.1 Modelo Simulink Utilizado

O desenvolvimento de modelos de identificação de sistemas baseados em RNA possuem como demanda, a construção de um banco de dados com várias amostras. Considerando a quantidade elevada de horas que são necessárias para esta construção, optou-se pela utilização do *toolbox* de fontes da ferramenta Simulink®, que implementa um modelo dinâmico genérico parametrizado que representa os tipos mais populares de baterias recarregáveis. Na Figura 1, é representada a configuração do modelo utilizado para extrair os dados de treinamento da RNA proposta (MathWorks, 2008).

Figura 1. Diagrama de blocos da bateria.

Onde V_{batt} é a tensão nos terminais da bateria em Volts e o SoC é o estado de carga da bateria em porcentagem.

Optou-se pela utilização deste modelo como referência para a construção do banco de dados dos cenários de descarga da bateria, levando-se em consideração correntes pulsadas.

Os parâmetros para configuração da bateria utilizada são descritos na Tabela 1.

Tabela 1. Configurações da bateria.

Parâmetros	Valor
Tipo	LiCoO ₂
Tensão nominal	3,35 V
Capacidade nominal	2,05 Ah
Tensão de corte	2,5125 V
Tensão de carga total	4,2 V
Resistência interna	16,5 $\mu\Omega$
Capacidade na tensão nominal	1,81 Ah
Tensão na zona exponencial	3,71 V
Capacidade na zona exponencial	0,6 Ah
Resistência térmica	0,06 °C/W

3.2 Efeito Térmico no SoC de Baterias de Lítio-íon

Como pode ser visto na Figura 2, o comportamento das curvas de descarga a uma corrente constante de 19,5 A em uma bateria de Li-íon modelo AMP20 para temperaturas distintas demonstra que, utilizando uma mesma corrente de descarga, baterias expostas a temperaturas mais baixas apresentam uma redução na capacidade entregue (AMP, 2014).

Isto provoca uma redução no tempo de descarga da bateria, fazendo com o que o SoC chegue mais rapidamente a 0%, diminuindo assim o seu tempo de utilização.

Figura 2. Curvas de descarga de baterias para várias temperaturas.

Este fenômeno é frequentemente desconsiderado em modelos de estimação do SoC, limitando suas aplicações a um único valor de temperatura.

4. ESTIMAÇÃO DO SOC UTILIZANDO REDES NEURAIS

A relação entre a tensão nos terminais da bateria e o seu SoC contém uma elevada não-linearidade, uma vez que muitos parâmetros tem influência na curva de SoC. Na Figura 3, onde se tem curvas obtidas a partir de um ensaio de descarga pulsada, esta não-linearidade fica evidente.

Figura 3. Relação entre SoC e tensão nos terminais de uma bateria de $LiCoO_2$.

Uma opção para modelagem da não-linearidade característica de uma curva de SoC, dá-se através da utilização de Redes Neurais Artificiais. RNAs são algoritmos computacionais de referência no que diz respeito a aproximação e mapeamento de curvas com um alto grau de não-linearidade. Além disto, RNAs possuem capacidade de auto-aprendizagem.

Pelas razões descritas nesta seção, o desenvolvimento de modelos para estimar o SoC de baterias de Li-íon utilizando RNA tem ganhado cada vez mais espaço nos estudos científicos, como em Ismail et al. (2017), Chitnis

et al. (2018) e Chaoui and Ibe-Ekeocha (2017). Porém, a utilização de RNA não se restringe apenas a determinação do SoC. Em Shahriari and Farrokhi (2013), uma RNA do tipo *radial basis* foi utilizada apenas para identificar os parâmetros do Modelo de Circuito Equivalente (MCE), e então, usando SoC como uma das variáveis de estado implementada em um Filtro de Kalman Estendido, o SoC foi estimado. Os parâmetros de entrada da RNA foram SoC, corrente e tensão, e a saída foi o OCV.

5. MÉTODO PROPOSTO

Nesta seção, são apresentados os procedimentos para construção do modelo de estimação do SoC baseado em NARX, assim como os critérios para treinamento e teste.

5.1 Redes Propostas

Tomando como ponto de partida para a construção da estrutura de sinais de entrada das redes desenvolvidas, foi observado o efeito que a variação de temperatura provoca na curva de SoC das baterias de Li-íon como o descrito na Seção 3.2.

Em seguida, visando o ponto de vista da aquisição de dados de uma bateria real, propôs-se que, para reduzir custos com sensores de efeito *hall* ou consumo extra através do uso de um resistor *shunt*, a utilização de corrente na RNA seria descartada.

Assim, as redes implementadas neste trabalho possuem como entrada: tensão no instante k , temperatura no instante k e SoC no instante $k - 1$. Na Figura 4, é ilustrada a estrutura base para o desenvolvimento das redes.

Figura 4. Estrutura de rede proposta.

Para observar o desempenho da estimação do SoC a partir da escolha da estrutura de rede, foram desenvolvidas RNAs variando a quantidade de neurônios por camada, quantidade de camadas escondidas e funções de ativação por camada escondida. Para isto, foram criadas redes com uma e duas camadas escondidas

Nas redes com uma camada escondida, variou-se a quantidade de neurônios de 1 a 10 e suas funções de ativação entre logarítmica e tangente hiperbólica.

Já para as redes com duas camadas, foram criadas variações contendo desde 1 neurônio em ambas as camadas

escondidas até 10 neurônios na primeira e 20 na segunda. Para a primeira camada escondida foi utilizada uma Função de Ativação (FA) logarítmica, enquanto que para a segunda camada se adotou uma FA tangente hiperbólica. As Equações (2) e (3) descrevem as funções logarítmica e tangente hiperbólica, respectivamente. Não foram utilizadas outras FAs como puramente linear ou degrau pelo fato destas funções não adaptarem muito bem sinais com uma não-linearidade elevada, como é observado na relação entre SoC e tensão nos terminais de uma bateria de Li-íon.

$$\log(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3)$$

Assim, ao somar a quantidade de redes com uma e duas camadas escondidas, foram desenvolvidas um total de 220 possibilidades de redes. Nas Figuras 5, 6 e 7 são descritas as estruturas de rede utilizadas.

Figura 5. Rede com uma camada escondida usando FA logarítmica.

Figura 6. Rede com uma camada escondida usando FA tangente hiperbólica.

Figura 7. Rede com duas camadas escondidas.

5.2 Banco de Dados e Treinamento

Redes Neurais demandam um banco de dados para treinamento de tal forma que, a partir destes dados, a rede é capaz de determinar saídas através da generalização do conceito aprendido na fase de treinamento.

As faixas de valores utilizadas para compor o banco de dados de treinamento são resumidas na Tabela 2.

Os parâmetros de corrente e temperatura foram utilizados por representarem uma ampla faixa de valores que podem ser implementados para uma bateria de $LiCoO_2$.

A respeito da metodologia de aprendizagem, foi utilizado o método de aprendizagem supervisionado. O diagrama ilustrado na Figura 8 representa o procedimento descrito para esta metodologia de aprendizagem.

Tabela 2. Banco de dados para validação e treinamento das redes.

Corrente de descarga	2 a 10 A com passo de 2
Temperatura	10 a 35 °C com passo de 5
Nº de ensaios de treinamento	30
Nº de ensaios de validação	7
Total de ensaios	37

Figura 8. Metodologia de aprendizagem.

Neste processo de aprendizagem, dados de entrada são inseridos na RNA e então os resultados obtidos são comparados aos valores previstos. A partir do erro, os pesos da rede são ajustados para alcançar um erro mínimo pré-definido.

5.3 Métricas de Validação do Modelo

Para quantificar a exatidão das redes desenvolvidas, o Erro Quadrático Médio (*Mean Square Error* - MSE) e o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error* - MAPE) foram usado para comparar os desempenhos. Nas Equações (4) e (5) são definidas estas métricas.

$$MSE = \frac{1}{N} \sum_{k=1}^N (SoC_{th}(k) - SoC(k))^2 \quad (4)$$

$$MAPE = \frac{1}{N} \sum_{k=1}^N \left| \frac{SoC_{th}(k) - SoC(k)}{SoC_{th}(k)} \right| \times 100\% \quad (5)$$

6. RESULTADOS

Após descrever a metodologia empregada para determinação do SoC, nesta seção são apresentados os resultados obtidos a partir da avaliação de várias estruturas de RNA.

6.1 Redes com Uma Camada

Na Figura 9, são apresentados os resultados do ponto de vista do MSE para as redes utilizando apenas uma camada escondida. Notou-se que as redes apresentaram máximos globais de erro quadrático entre as faixas de 1 a 3 neurônios.

Ao se incrementar a quantidade de neurônios, não foram verificadas melhorias significativas na rede. Desta forma, uma quantidade muito elevada de neurônios não produz um custo benefício relacionado ao desempenho.

Tabela 3. Máximos e Mínimos do MSE para redes com uma camada.

FA Logarítmica		FA Tan. Hiperbólica	
Máximo	Mínimo	Máximo	Mínimo
5,174	0,065	1,803	0,028
Nº neurônios	Nº neurônios	Nº neurônios	Nº neurônios
2	5	1	6

Tabela 4. Máximos e Mínimos do MAPE para redes com uma camada.

FA Logarítmica		FA Tan. Hiperbólica	
Máximo	Mínimo	Máximo	Mínimo
4,556%	0,454%	2,892%	0,325%
Nº neurônios	Nº neurônios	Nº neurônios	Nº neurônios
2	5	1	6

Figura 9. Resultados de MSE para as redes com uma camada.

São referenciados na Tabela 3 os valores de máximos e mínimos globais para cada estrutura de rede com relação a métrica MSE. Observando os valores obtidos, percebe-se um melhor desempenho por parte da rede contendo a FA Tangente Hiperbólica.

Verificando a avaliação do erro percentual, pôde-se constatar que em termos percentuais, a rede com FA tangente hiperbólica teve uma piora em seus resultados. Porém, como pode ser visto na Tabela 4, os erros percentuais para FA tangente hiperbólica continuam com melhor desempenho quando comparados as redes contendo funções de ativação logarítmica.

6.2 Redes com Duas Camadas

Uma vez realizada a análise dos resultados referentes as redes contendo apenas uma camada escondida em sua estrutura, partiu-se para as considerações a respeito das redes com estruturas compostas por duas camadas escondidas.

A partir da análise da Figura 11, percebe-se inicialmente que o valor de erro mínimo obtido foi de 0,0073 para 3 neurônios na primeira camada e 19 na segunda, um valor 3,8356 vezes menor em relação ao menor erro atingido pelas redes com apenas uma camada escondida. Porém, além de demandar uma quantidade de neurônios sete vezes maior, este tipo de estrutura gerou erros muito elevados, em alguns casos chegando a um MSE acima de 1000.

Figura 10. Resultados de MAPE para as redes com uma camada.

Figura 11. Resultados de MSE para as redes com duas camadas.

No que diz respeito ao MAPE, novamente se obteve um desempenho superior por parte da rede com duas camadas escondidas. Porém, ao visualizar a Figura 12, constata-se que é necessária uma quantidade muito elevada de neurônios para atingir o MAPE mínimo, de modo que não existe um custo benefício satisfatório. Outro ponto de destaque se refere a quantidade de neurônios da segunda camada ser bem mais elevada em relação a quantidade de neurônios da primeira camada.

Figura 12. Resultados de MAPE para as redes com duas camadas.

7. CONCLUSÕES

Neste trabalho foram desenvolvidas redes NARX para estimação do SoC de baterias de Li-íon. Em relação as estruturas, foram consideradas como entradas a tensão nos terminais da bateria no instante k , a temperatura ambiente no instante k e o próprio SoC no instante $k - 1$. O modelo de estrutura proposto tem como contribuição a utilização da tensão em vez de corrente para estimar o SoC, uma vez que efetuar a medição de tensão é mais simples e menos custoso.

As redes foram divididas em duas classes de acordo com a quantidade de camadas escondidas em suas estruturas de rede, sendo elas redes com uma e duas camadas escondidas. As redes com duas camadas apresentaram um melhor desempenho quando comparado as de uma, tendo um valor de MSE e MAPE de 0,0073 e 0,1509%, respectivamente. Porém, ao analisar o custo benefício associado a quantidade de neurônios e valor de erro obtido, chegou-se a conclusão de que redes com apenas uma camada escondida são mais eficientes para estimação do SoC quando não se faz necessária uma exatidão muito elevada por parte do modelo.

AGRADECIMENTOS

Os autores gostariam de agradecer ao Grupo de Inteligência Computacional Aplicada (GICA) da Universidade Federal da Paraíba pelo suporte durante a realização deste trabalho.

REFERÊNCIAS

- (2014). *Battery Pack, Design, Validation, and Assembly Guide using A123 Systems Nanophosphate® Cells*. A123 Systems.
- Baldi, P., Sadowski, P., and Whiteson, D. (2015). Enhanced higgs boson to $\tau^+ \tau^-$ search with deep learning. *Physical review letters*, 114(11), 111801.
- Chaoui, H. and Ibe-Ekeocha, C.C. (2017). State of charge and state of health estimation for lithium batteries using recurrent neural networks. *IEEE Transactions on vehicular technology*, 8773–8783.
- Chitnis, M.S., Pandit, S.P., and Shaikh, M. (2018). Electric vehicle li-ion battery state of charge estimation

using artificial neural network. In *2018 International Conference on Inventive Research in Computing Applications (ICIRCA)*, 992–995. IEEE.

- Cittanti, D., Ferraris, A., Airale, A., Fiorot, S., Scavuzzo, S., and Carello, M. (2017). Modeling li-ion batteries for automotive application: A trade-off between accuracy and complexity. In *2017 International Conference of Electrical and Electronic Technologies for Automotive*, 1–8. IEEE.
- Ismail, M., Dlyma, R., Elrakaybi, A., Ahmed, R., and Habibi, S. (2017). Battery state of charge estimation using an artificial neural network. In *2017 IEEE Transportation Electrification Conference and Expo (ITEC)*, 342–349. IEEE.
- Khayat, N. and Karami, N. (2016). Adaptive techniques used for lifetime estimation of lithium-ion batteries. In *2016 Third International Conference on Electrical, Electronics, Computer Engineering and their Applications (EECEA)*, 98–103. IEEE.
- Liu, V.T., Sun, Y.K., Lu, H.Y., and Wang, S.K. (2018). State of charge estimation for lithium-ion battery using recurrent neural network. In *2018 IEEE International Conference on Advanced Manufacturing (ICAM)*, 376–379. IEEE.
- MathWorks (2008). Implement generic battery model. Acessado em 19 de fevereiro de 2019.
- Shahriari, M. and Farrokhi, M. (2013). Online state-of-health estimation of vrla batteries using state of charge. *IEEE Transactions on Industrial Electronics*, 191–202.