

Aplicação de Redes Neurais em Sistema de Gerenciamento de Bateria

N. N. Sánchez T. *, H. F. Scherer **,
O. H. Ando Junior*, J. J. Gimenez L. *

**Universidade Federal da Integração Latino-Americana (UNILA),
Foz do Iguaçu-Pr, Brasil (Tel: +55 45 988063336; e-mail:
norah.torres@aluno.unila.edu.br, oswaldo.junior@unila.edu.br, jorge.ledesma@unila.edu.br).*
***Fundação Parque Tecnológico Itaipu (FPTI), Av. Tancredo Neves, 6731.
Foz do Iguaçu-Pr, Brasil (e-mail:helton@pti.org.br)*

Abstract: This study has as main objective to employ the use of artificial neural networks, being one of its main applications to operate as a universal approximator of functions, mapping the functional relationship between the variables of a system from a known set of samples. In this scenario, this work addresses a method to predict the state of charge of batteries using techniques of artificial neural networks through a database and models of the charge curve of sodium and nickel chloride batteries and, thus, to analyze the behavior of the battery management system, using the models found in the output curves. In this way, this study at first presents a brief introduction, followed by the theoretical framework. Immediately thereafter, the methodology used is presented, in the MATLAB software, step by step to obtain the load curves. In this case, the proposed method uses a multilayer Perceptron artificial neural network, a feedforward architecture with backpropagation training algorithm. Finally, the results express the method's ability to indicate the battery charge status, as well as the analysis of the stipulated errors. One of the conclusions obtained is that the configuration used presents better performance when - adjusting the number of layers and can be applied in other types of batteries, as in the case of the lithium battery. With the errors and inconveniences found throughout this study, some future works are proposed.

Resumo: Este estudo tem como objetivo principal empregar o uso de redes neurais artificiais, sendo que umas das suas principais aplicações é operar como um aproximador universal de funções, mapeando a relação funcional entre as variáveis de um sistema a partir de um conjunto conhecido de amostras. Neste cenário, este trabalho aborda um método para prever o estado de carga de baterias usando técnicas de redes neurais artificiais através de um banco de dados e modelos da curva de carga de baterias de cloreto de sódio e níquel e, assim, analisar o comportamento do sistema de gerenciamento de bateria, através dos modelos encontrados nas curvas de saída. De tal modo, este estudo a princípio apresenta uma breve introdução, seguida pelo referencial teórico. Ato contínuo, a metodologia utilizada é apresentada, no software MATLAB®, passo a passo para obter as curvas de carga. Para o caso, o método proposto utiliza uma rede neural artificial Perceptron Multicamada, uma arquitetura de *Feedforward* com algoritmo de treinamento de retropropagação. Finalmente, os resultados expressam a capacidade do método de indicar o estado de carga da bateria, bem como a análise dos erros estipulados. Uma das conclusões obtidas é que a configuração utilizada apresenta melhor desempenho ao ajustar o número de camadas e pode ser aplicada em outros tipos de baterias, como no caso da bateria de lítio. Com os erros e inconvenientes encontrados ao longo deste estudo, alguns trabalhos futuros são propostos.

Keywords: State of charge; artificial neural networks; functionality.

Palavras-chaves: Estado da carga; redes neurais artificiais; funcionalidade.

1. INTRODUÇÃO

Com a demanda de energia elétrica, no Brasil em 2019 a energia total disponível atingiu 299,04 Mtep, registrando um crescimento de 2% em relação ao ano anterior. A participação de energias renováveis na matriz elétrica atingiu 84,2% em 2019. A energia hidráulica disponível cresceu 2,5% em relação a 2018. A geração eólica atingiu 4,815 Mtep, com um crescimento de 15,5% em relação ao ano

anterior, conforme reportado no balanço energético de 2020 (EPE, 2020; MME, 2020).

Neste contexto, e com a expansão de dispositivos eletrônicos e geração de energia, cresce a necessidade de sistemas de armazenamento, com grande capacidade, baixo custo e peso reduzido, além de sempre obter equipamentos que nos permitem reduzir poluentes para o meio ambiente. Um dos sistemas de armazenamento de energia mais utilizados são as baterias, que convertem a energia química armazenada em energia elétrica (Kauffman, 2008). Atualmente, as baterias

mais adequadas e com as melhores características do mercado são de lítio, além disso apesar de ser poluentes, as baterias de chumbo ainda são as mais baratas do mercado, mas novas baterias foram desenvolvidas, como no caso das baterias de sódio-cloreto de níquel, que possuem características como: desempenho constante e vida útil em uma ampla faixa de temperaturas, alto desempenho em aplicações de ciclo pesado, custo total de propriedade vantajoso ao longo dos anos e tecnologia verde sem chumbo e outros aditivos prejudiciais (Electrilabs Pty Ltd., 2018).

Diferentes tecnologias de baterias exigem um sistema de segurança, este dispositivo de segurança mais conhecido por seu acrônimo em inglês como BMS (*Battery Management Systems*), que nos ajuda a: (i) garantir a segurança do operador, (ii) detectar condições de operação e responder a elas, além de (iii) proteger a vida útil da bateria, mantendo-a em um estado em que possa atender aos requisitos funcionais de design e controlando para que a carga e descarga da bateria sejam realizadas corretamente.

O BMS é composto de software e hardware que controlam o carregamento e a descarga da bateria, garantindo uma operação confiável e segura. Além disso, o BMS também controla o equilíbrio celular e o gerenciamento térmico da bateria (Chaturvedi et al., 2010; Meissner and Richter, 2003).

O BMS possui vários recursos para controlar e monitorar o status operacional da bateria em diferentes níveis de células, módulos e baterias, o que nos fornece uma estimativa do estado de carga; mais conhecido por seu acrônimo em inglês como: *State of Charge* (SOC), e vida útil (SOH), bem como controle de carga da bateria (Rahimi-Eichi et al., 2013). O BMS examinará os parâmetros operacionais de tensão, corrente e temperatura interna da bateria durante a carga e descarga para estimar o estado da carga (SOC) e a saúde (SOH), protegendo a bateria contra danos (Haq et al., 2014).

É por esse motivo que a importância deste trabalho está na necessidade de aplicar o uso de redes neurais artificiais; mais conhecido por seu acrônimo em inglês como ANN (*Artificial Neural Networks*); para prever o comportamento da curva de carga nas baterias de sódio e, assim, ser capaz de modelar este comportamento no BMS.

As ANN são um algoritmo preciso e prático para obter a estimativa do SOC. Existem diferentes modelos para estimar o SOC, uma vez que estes não podem ser obtidos diretamente dos terminais da bateria, por isso é necessário desenvolver algoritmos de estimativa que utilizem variáveis elétricas como tensão, corrente e temperatura. (Julián et al., 2015). Cabe ressaltar, que os métodos convencionais requerem parâmetros variáveis, acesso ao eletrólito líquido, exigência de equilíbrio no estado da bateria, entre outros problemas (Chaoui and Ibe-Ekeocha, 2017; Martínez Bertran, 2017).

2. REFERENCIAL TEÓRICO

Conceitualmente, o Sistema de Gerenciamento da Bateria (BMS) é fabricado de maneira geral para trabalhar com a maioria dos tipos de células e muitos não conseguem ajudar no desempenho das células, mas como medida de segurança,

ele verifica constantemente o estado das células e garante que não exceda os limites estabelecidos (Plett, 2015).

2.1 Funções do BMS

As principais funções do BMS são: (i) Processar adequadamente todos os valores de temperatura, tensões, correntes etc.; (ii) Proteger a bateria, impedindo que a tensão da célula exceda os limites, parando a carga e a descarga; da mesma forma, evita que a temperatura das células exceda os limites, parando o sistema ou resfrie-o; e impedindo que a corrente exceda os limites, tanto na carga quanto na descarga, cortando ou limitando a corrente; (iii) Verificar o estado da carga (SOC) e o estado de saúde (SOH), (iv) Realizar o balanceamento adequado nas células, para garantir um nível de carga ideal em todas as células e (v) Manter um histórico da bateria consultando tensão, corrente, temperaturas, etc.

De acordo com Valdivia Mirando (2018), os BMS são classificados por uso comercial e por topologia. Por uso comercial pode ser: padrão e personalizado; por topologia pode ser: centralizado, modular, mestre-escravo e distribuído. Para o estudo de caso, o BMS usado é mostrado na Fig. 1, que é do tipo centralizado.



Fig. 1: BMS Centralizado

O SOC da bateria de acordo com Zong-You Hou (2017), pode ser claramente definido como a capacidade residual na bateria em relação à capacidade nominal.

Atualmente, alguns pesquisadores aplicam métodos convencionais e outros sistemas inteligentes, como redes neurais artificiais. Nos métodos convencionais, temos métodos como: medição direta, medição específica da gravidade, com base na intensidade (*Coulomb Counting*), tensão de circuito aberto (OCV) (Chaoui and Ibe-Ekeocha, 2017; Martínez Bertran, 2017).

Devido à característica de fácil inserção em qualquer tecnologia, a ANN será o método utilizado para determinar as curvas de saída, mas uma de suas desvantagens é que são necessários grandes quantidades de dados de treinamento e um estudo cuidadoso das configurações, arquiteturas e tipos de redes em treinamento.

3. METODOLOGIA

Este capítulo detalha, por meio de um fluxograma, mostrado na Fig. 2, o processo passo a passo para chegar ao modelo de

curva de carga. Com a ajuda do software MATLAB e da ferramenta *Neural Network Start (nnstart)* e *Neural Fitting (nftool)*, as curvas e os dados de saída serão encontrados.

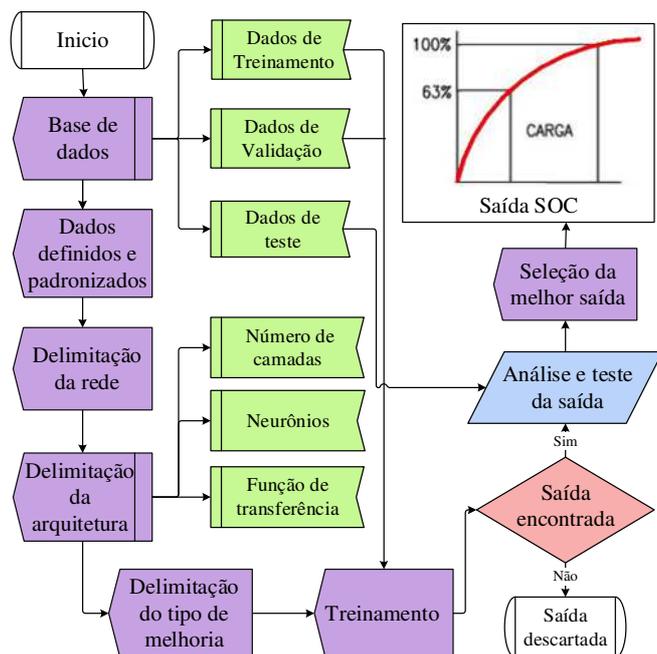


Fig. 2: Fluxograma do método proposto.

Na sequência, são dadas breves descrições dos blocos componentes da Fig. 2.

Base de dados: O banco de dados foi obtido experimentalmente a partir da bateria de sódio e lítio comercial, onde foram obtidos os valores de corrente, tensão e temperatura de uma bateria de 10 células para o sódio. Este banco de dados será utilizado para treinamento, validação e teste.

Dados definidos e padronizados: O banco de dados é convertido em PU, conforme explicado nos resultados.

Delimitação da rede: Aqui é definida a rede, Perceptron multicamada (MLP) como mostrado na Fig. 3, por ser a mais indicada para aproximação universal de funções.

Delimitação da arquitetura: Para a aprendizagem supervisionada, foi definida uma arquitetura *Feedforward* de várias camadas. Aqui, o número de camadas, o número de neurônios e a função de transferência são definidos.

Delimitação do tipo de melhoria: O tipo de melhoria é selecionado, que neste caso será para Levenberg – Marquardt (Benatti, 2017; Gavin, 2019; Singh, 2012), que ajuda na rapidez da convergência, uma vez que o algoritmo tende a ajustar os valores das matrizes de peso da rede MLP em relação à direção oposta do erro quadrático da função gradiente, que torna a convergência mais lenta e, portanto, requer maior esforço computacional.

Treinamento: Neste ponto, as curvas de carga foram treinadas, levando em consideração alguns parâmetros e algoritmos utilizados. O algoritmo de aprendizado aplicado durante o processo de treinamento é o *backpropagation*. A fase de propagação direta permite obter as respostas da rede,

levando em consideração os valores atuais dos pesos e limiares sinápticos de seus neurônios, que permanecerão inalterados a cada execução dessa fase (Silva et al., 2010). Para este trabalho, três parâmetros são considerados: a corrente, a tensão e a temperatura.

Saída encontrada: O modelo é obtido após o treinamento, que deve estar de acordo com o resultado, caso contrário, é descartado até que a melhor representação do modelo do SOC seja encontrada.

Análise e teste da saída: Logo que o modelo é encontrado, é analisado e testado com outros dados de entrada que não fazem parte do treinamento, para obter a curva de saída.

Seleção da melhor saída: Após a obtenção do melhor modelo, os dados de saída são plotados e os erros são calculados. Logo, as curvas encontradas são comparadas e analisadas.

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Nesta seção apresenta-se o banco de dados usado para aprendizado, desempenho e validação da rede onde são mostradas as curvas de saída encontradas e, para finalizar, os respectivos erros de saída encontrados.

4.1 Dados Utilizados para Aprendizagem

A ANN utilizada é a de tipo MLP, mostrado na Fig. 3. De acordo com a sua aprendizagem, no caso é supervisionada, pois, informa o resultado desejado e também tem aplicação na aproximação de funções que é o caso do estudo.

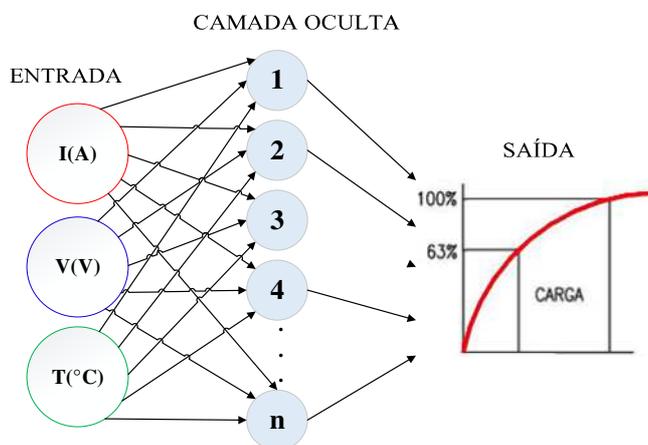


Fig. 3: Modelo de rede MLP utilizada.

E, de acordo com sua arquitetura de *feedforward* multicamada, foi escolhida a rede multicamada *Perceptron*, pois possuem pelo menos uma camada oculta, o que permitirá um melhor desempenho de saída, além de ser caracterizada por ter grandes possibilidades de aplicações em vários problemas, por exemplo: na aproximação de funções para prever a curva de carga. Com o aprendizado supervisionado e a arquitetura, a rede é mais efetiva.

As quantidades de dados experimentais medidos para o treinamento, e testes, são mostradas na Tabela 1.

Os parâmetros iniciais dos dados de treinamento e teste de lítio e sódio estão no sistema internacional de unidades, para temperatura, corrente e tensão (°C, A, V), conforme mostrado na Tabela 2; sendo que os dados foram convertidos em PU.

Tabela 1: Quantidade de dados utilizados na rede.

Modo de entrada na rede	Dados
Treinamento_3,8A	9 110
Teste_3A	10 282
Teste_7,6A	7 273
Teste_11,4A	7 484
Teste_Litio_0,520A	10 479

Tabela 2: Dados de treinamento.

%SOC	T (°C)	I BAT(A)	V BAT(V)
9,989	269,561		24,501
10,003	269,550		24,505
10,017	269,542		24,511
10,031	269,531	3,8	24,515
10,045	269,522		24,519
10,059	269,512		24,523
10,073	269,501		24,525
10,086	269,492		24,529
10,100	269,482		24,533

Para converter os dados em PU, para um melhor treinamento e teste dos dados, será usada (1), assim como são necessários os valores nominais da bateria. Para a bateria de sódio foi utilizada uma corrente nominal de 9,5 A, tensão nominal de 25,8 V; capacidade nominal de 38 A.h, e a temperatura de 270 °C. Para o lítio foi utilizada a corrente nominal de 520 mA, tensão nominal de 3,7 V, a capacidade nominal de 2,34 A.h, temperatura de 60 °C. Para ambos os casos é considerado o %SOC a 100%.

$$PU = \frac{\text{Valor do Parâmetro}}{\text{Valor Nominal de cada Parâmetro}} \quad (1)$$

A Tabela 3, mostra alguns dos dados em PU, usados para o treinamento com bateria de sódio. O mesmo procedimento foi realizado para os dados utilizados para o teste em 3 A, em 7,6 A, e 11,4 A e lítio.

Tabela 3: Dados em PU para o treinamento

% SOC	T	I BAT	V BAT
0,09989	0,99837		0,94965
0,10003	0,99833		0,94981
0,10017	0,99830		0,95004
0,10031	0,99826		0,95019
0,10045	0,99823	0,4	0,95035
0,10059	0,99819		0,95050
0,10073	0,99815		0,95058
0,10086	0,99812		0,95074
0,10100	0,99808		0,95089

4.2 Desempenho da Rede

Após a coleta de dados já convertidos em PU, a rede e a arquitetura escolhida, o treinamento começa com dados em 3,8 A e com três entradas.

O número de camadas é dois e o número de neurônios para este treinamento será dez, enquanto a função de ativação será usada a função tangente hiperbólica, para a camada oculta, que, como qualquer função de transferência, calcula a saída de uma camada a partir de sua entrada. Em seguida, para a camada de saída a função é linear.

Ao final, o modelo da curva de saída não era o esperado, pois apresenta comportamentos irregulares no curso da curva, como será explicado mais adiante. Por isso, foi planejado aumentar o número de neurônios para 28, seguindo as mesmas considerações, mantendo a mesma função de transferência. Os resultados, mostraram irregularidades maiores que no caso anterior, explicados e graficados posteriormente.

Nesse contexto, optou-se por manter as mesmas configurações, sendo o número de neurônios o único a ser modificado, por 7 neurônios, encontrando os melhores modelos da curva de carga, espera-se sempre que, ao aumentar o número de neurônios, seja encontrado um melhor desempenho, mas, no nosso caso, foi o contrário.

A rede funciona melhor em problemas de ajuste de função do que em problemas de reconhecimento de padrões, além de ser o mais rápido para a função de treinamento padrão. A topologia Perceptron multicamada selecionada para o tratamento da rede neural é muito conveniente, pois simplifica o design da rede, bem como seu treinamento, simulação e implementação.

4.3 Validação da Rede

Para entender um pouco como funciona a carga nos dados de treinamento, e observar o comportamento nas curvas de saída encontradas, na Fig. 4 mostra, o comportamento da corrente e da tensão, bem como o %SOC que é o objetivo, sendo que esses valores são em função do tempo.

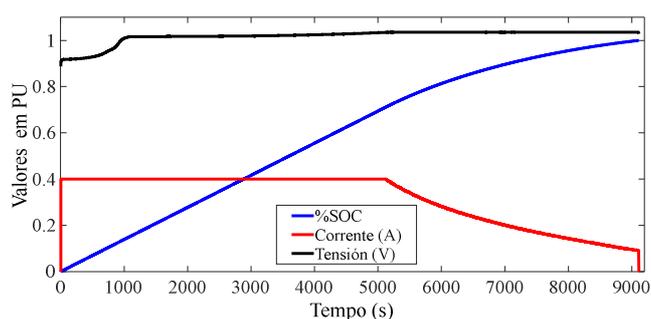


Fig. 4: Curvas de carga a 3,8A.

Uma função do BMS é que a corrente e a tensão não excedem os limites e, por sua vez, monitora o status da temperatura de operação, não permite que a bateria comece a carregar se não tiver a temperatura necessária. Como a carga em qualquer bateria é observada que em correntes mais altas cresce mais rapidamente do que em tensão constante, a curva azul cresce a uma corrente de 3,8 A, até que o BMS detecte que a tensão atingiu seu limite, naquele momento a corrente cai e começa a carregar em tensão constante mais lentamente, até o BMS detectar 100% da carga e os parâmetros irem para

zero. O tempo de carregamento pode levar em torno de 12 horas.

Após o treinamento da rede, os testes começaram em 3 A, 7,6 A, 11,4 A e para a bateria de lítio 0,520 A e, em seguida, os dados foram representados graficamente.

4.3.1 Rede com 10 Neurônios

Para o estudo de caso com 10 neurônios, como se mostra na Fig. 5, pode-se observar que as curvas de sódio e lítio mostram oscilações no início da carga, além de irregularidades no final. Por outro lado, para 3 A, mantém as oscilações em 50% da curva de carga.

Nas curvas de sódio em correntes mais altas (7,6A e 11,4A), pequenas quedas são observadas no final, de modo que os problemas podem ser ao iniciar o carregamento a uma tensão constante, além de estar longe da curva de treinamento (3.8A). Para 3A, que está mais próximo do treinamento, as quedas são menores.

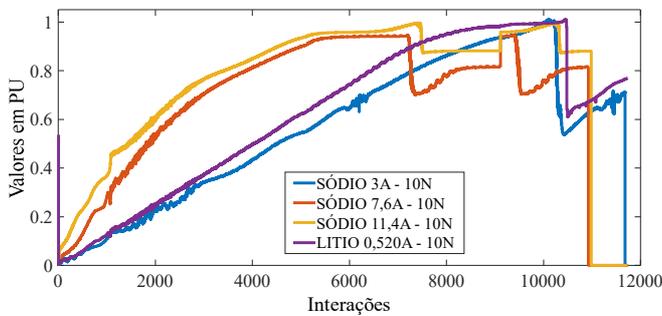


Fig. 5: Curvas com 10 neurônios.

4.3.2 Rede com 28 Neurônios

A seguir, para o estudo de caso com 28 neurônios, como mostra na Fig. 6, pode-se observar que nas curvas de sódio e lítio, apresentam oscilações no início da carga e irregularidades no final. Nesse caso, a curva de lítio é a que apresenta mais irregularidades, em sua totalidade de carga, em relação às demais.

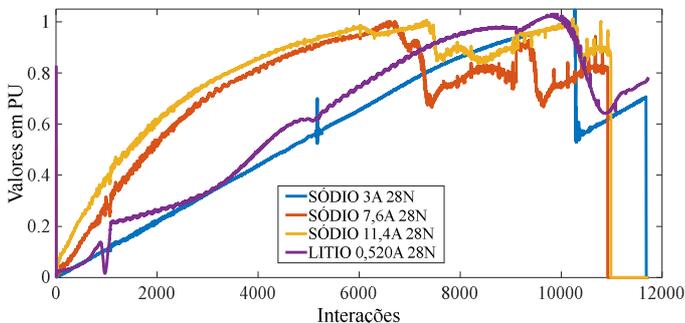


Fig. 6: Curvas com 28 neurônios.

4.3.3 Rede com 7 Neurônios

Finalmente, para o estudo de 7 neurônios, as oscilações são menores do que nos casos anteriores, isso não significa que

sejam perfeitas, mas estão mais alinhadas às expectativas. O gráfico obtido após a validação e teste dos dados é mostrado na Fig. 7.

Por outro lado, um fator que deve ser levado em consideração é a temperatura, que no caso da bateria de lítio está quase na temperatura ambiente, enquanto no caso do sódio os valores são três dígitos. Mas em ambas as curvas os valores de temperatura variaram em torno de um grau ou decimais.

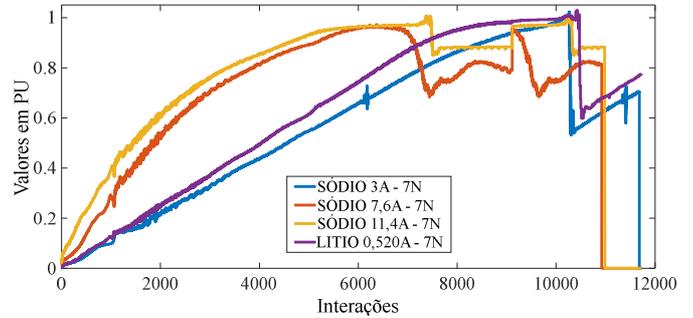


Fig. 7: Curvas com 7 neurônios.

Lembrando que essas curvas de saída são uma função da tensão e da corrente e não uma função do tempo, pois esse parâmetro foi descartado, pois não é um parâmetro que influenciou o comportamento do BMS. No caso da temperatura, é um dos parâmetros que não varia muito, não influencia as curvas de carga, mas sim o BMS, pois não inicia o carregamento se não tiver a temperatura operacional necessária. Tanto para o sódio quanto para o lítio, o BMS é semelhante, eles podem ter variações, mas fazem o trabalho de monitorar os limites de tensão e corrente.

4.4 Estimativa do Erro de Saída

Após encontrar as curvas, os erros são exportados, mostrado na Tabela 4, a seguir. Equação (2), foi utilizada para encontrar o erro.

$$E_{ABS} = \left| \left(Saída_{Test} - Saída_{Trein} \right) \right| * 100 \quad (2)$$

Tabela 4: Erros estimados nas curvas de saída.

Erros da Rede	Sódio 3A	Sódio 7,6A	Sódio 11,4A	Lítio 0,52A
n = 10	0,075	0,129	0,034	0,254
n = 28	0,198	0,024	0,059	0,095
n = 7	0,041	0,013	0,165	0,142

O erro para as curvas treinadas com 7 neurônios é menor que os outros casos, demonstrando que o erro pode ser dado pelo número de neurônios nas camadas. Esses erros também se devem ao fato de as curvas com correntes mais altas estarem longe dos dados de treinamento, portanto, há uma grande variação.

Por outro lado, o número de dados, o número de vezes que a rede foi treinada, as configurações, a função de transferência (linear, tangencial, logarítmica, etc.), o tipo de arquitetura, entre outros fatores que influenciam no carregamento da bateria, devem ser levados em consideração.

5. CONSIDERAÇÕES FINAIS

Em conclusão, este trabalho mostrou a implementação e análise dos resultados de uma rede neural artificial para estimar o estado de carga das baterias e, assim, estudar o comportamento no BMS.

Os resultados mostram que, para o caso com uma corrente mais baixa, 3 A, mais próxima do modelo de treinamento, a curva de carga apresenta um comportamento melhor do que em correntes mais altas. Por esse motivo, são necessários mais dados de entrada para o treinamento em rede, com mais variações de corrente e temperatura para obter uma melhor análise.

Por outro lado, deve-se notar que o melhor funcionamento da rede ocorreu quando o número de neurônios na camada oculta variou; indicando que uma curva de carga é mais eficiente ao variar as configurações no treinamento.

Por fim, implementou-se as redes neurais para prever a aproximação de funções e foram observados resultados que indicam uma possibilidade do uso de redes neurais, mas ainda precisa melhorar antes de aplicar na bateria para estimação em tempo real.

Como continuidade desta pesquisa sugere-se: (i) utilização de um maior faixa de variação de temperatura nas operações; (ii) modelagem da capacidade da bateria com base nos ciclos, para encontrar o estado de vida da bateria; (iii) por fim, a implementação em um BMS para comparação em tempo real com a técnica tradicional de estimação de SOC.

AGRADECIMENTOS

Esta pesquisa conta com o apoio: da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, do Programa Institucional Agenda Tríplice (Edital PRPPG 137/2018) da Universidade Federal de Integração da América Latina - UNILA, Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Nº 307223/2017-5 e Nº 407531/2018-1), ao Instituto de Tecnologia Aplicada e Inovação (ITAI), Fundação Parque Tecnológico Itaipu (FPTI) e do projeto de pesquisa P&D COPEL 2866-0452/2016. Os autores, em nome do Grupo de Pesquisa em Energia e Sustentabilidade Energética (GPEnSE), agradecem o apoio.

REFERÊNCIAS

- Benatti, K.A. (2017), *O Método de Levenberg-Marquardt Para o Problema de Quadrados Mínimos Não Linear*, Dissertação de Mestrado, Universidade Federal de Paraná, Curitiba.
- 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*, Vol. 66 No. 10, pp. 8773–8783.
- Chaturvedi, N.A., Klein, R., Christensen, J., Ahmed, J. and Kojic, A. (2010), “Modeling, estimation, and control challenges for lithium-ion batteries”, *Proceedings of the 2010 American Control Conference*, presented at the 2010 American Control Conference (ACC 2010), IEEE, Baltimore, MD, pp. 1997–2002.

- Electrilabs Pty Ltd. (2018), “Sodium Nickel Batteries”, Apresentação de Produtos, Sudáfrica.
- EPE [Empresa de Pesquisa Energética]. (2020), “Balanço Energético Nacional (BEN) 2020: Ano base 2019”, January.
- Levenburg-Marquardt Algorithm For Nonlinear Least Squares Curve-Fitting Problems”, *Department of Civil and Environmental Engineering Duke UniversityDuke University*, pp. 1–20.
- Haq, I.N., Leksono, E., Iqbal, M., Sodami, F.X.N., Nugraha, Kurniadi, D. and Yulianto, B. (2014), “Development of battery management system for cell monitoring and protection”, *2014 International Conference on Electrical Engineering and Computer Science (ICEECS)*, pp. 203–208.
- Julián, D., Patarroyo, R., Alexander, R., Porras, G., Felipe, A. and Fajardo, C. (2015), “Sistemas de gestión de baterías (BMS) y su importancia para los sistemas de almacenamiento de baterías (BESS)”, *Tecnura*, Vol. 19, pp. 51–56.
- Kauffman, R. (2008), “Baterias Energia de Íon de Lítio”, Manual do Usuário, Manual do Usuário, Rio de Janeiro, November.
- Martínez Bertran, J. (2017), *Métodos de Estimación Del Estado de Carga de Baterías Electroquímicas*, Trabajo de Final de Grado, Escola Tècnica Superior d'Enginyeria Industrial de Barcelona, Bcelona, April.
- Meissner, E. and Richter, G. (2003), “Battery Monitoring and Electrical Energy Management”, *Journal of Power Sources*, Vol. 116 No. 1–2, pp. 79–98.
- MME [Ministério de Minas e Energia]. (2020), “Boletim de Monitoramento do Sistema Elétrico”, *Secretaria de Energia Elétrica*, 9 March.
- Plett, G.L. (2015), *Battery Management Systems, Volume II: Equivalent-Circuit Methods*, Artech House.
- Rahimi-Eichi, H., Ojha, U., Baronti, F. and Chow, M.-Y. (2013), “Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles”, *IEEE Industrial Electronics Magazine*, Vol. 7 No. 2, pp. 4–16.
- Silva, I.N., Spatti, D.H. and Flauzino, R.A. (2010), “Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas”, *São Paulo: Artliber*.
- Singh, S. (2012), *Backpropagation Learning Algorithm Based on Levenberg Marquardt Algorithm*, Vol. 2.
- Valdivia Miranda, C. (2018), “Diseño de un BMS para baterías de tecnología Li-ion”, p. 150.
- Zong-You Hou, Pang-Yen Lou and Wang, C.-C. (2017), “State of charge, state of health, and state of function monitoring for EV BMS”, *2017 IEEE International Conference on Consumer Electronics (ICCE)*, presented at the 2017 IEEE International Conference on Consumer Electronics (ICCE), IEEE, Las Vegas, NV, USA, pp. 310–311.