

**Previsão de demanda de potência em sistema híbrido de armazenamento de energia em veículos elétricos utilizando redes Narx****Power demand forecasting on hybrid energy storage system in electric vehicles using Narx networks**

DOI:10.34117/bjdv5n10-048

Recebimento dos originais: 10/09/2019

Aceitação para publicação: 04/10/2019

**Lucas Fernandes Rocha Lago**

Engenheiro Mecatrônico pelo Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais (IF Sudeste MG) - Campus Juiz de Fora.

Instituição: Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais - Campus Juiz de Fora.

Endereço: Rua Bernardo Mascarenhas, 1283 Bloco I - Bairro Fábrica, Juiz de Fora, MG, Brasil

E-mail: lucaslago275@gmail.com

**Isabela Miranda de Mendonça**

Doutora em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (UFJF)

Instituição: Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais (IF Sudeste MG) - Campus Juiz de Fora.

Endereço: Rua Bernardo Mascarenhas, 1283 - Bloco I - Bairro Fábrica, Juiz de Fora, MG, Brasil

E-mail: isabela.mendonca@ifsudestemg.edu.br

**Silvana Terezinha Faceroli**

Doutora em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)

Instituição: Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais (IF Sudeste MG) - Campus Juiz de Fora.

Endereço: Rua Bernardo Mascarenhas, 1283 - Bloco B - Bairro Fábrica, Juiz de Fora, MG, Brasil

E-mail: silvana.faceroli@ifsudestemg.edu.br

**Márcio do Carmo Barbosa Poncilio Rodrigues**

Doutor em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (UFJF)

Instituição: Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais (IF Sudeste MG) - Campus Juiz de Fora.

Endereço: Rua Bernardo Mascarenhas, 1283 - Bloco I - Bairro Fábrica, Juiz de Fora, MG, Brasil

E-mail: marcio.carmo@ifsudestemg.edu.br

**RESUMO**

O uso de múltiplas fontes de energia na alimentação de veículos puramente elétricos possibilita melhorar seu desempenho, aumentando sua autonomia e prolongando a vida útil do banco de baterias embarcado, que é o elemento de maior custo deste tipo de automóvel. Neste trabalho, é proposto o uso de técnicas de inteligência computacional na gestão de um sistema híbrido de armazenamento de energia baseado em bateria e supercapacitor, ambos embarcados em um veículo elétrico. Para isso, é apresentada uma metodologia de previsão e separação da demanda das frações de potência utilizando uma rede neural baseada no Modelo Autorregressivo Não Linear com Entradas Exógenas (NARX). A partir das simulações realizadas e dos ajustes dos parâmetros da rede, encontrou-se um erro muito pequeno em relação aos sinais previstos. Com base nos resultados obtidos é possível concluir que o método proposto se mostrou bastante eficiente e promissor para a aplicação em cálculo de demanda de energia em veículos elétricos.

**Palavras-chave:** Ciclo de condução; veículo elétrico; gerenciamento de energia; séries temporais, rede neural NARX.

**ABSTRACT**

The use of multiple energy sources as power supply of an electric vehicle allows improving its performance by increasing its autonomy and extending the life cycle of the onboard battery pack, which is the most expensive element of this type of automobile. In this work, it is proposed the use of computational intelligence techniques in the management of a hybrid energy storage system based on battery and supercapacitor, both embedded in an electric vehicle. For this purpose, a methodology for prediction and separation of the fractions of power demand, using neural networks based on the Non-Linear Autoregressive Model with Exogenous Inputs (NARX), is presented. From the simulations carried out and the adjustments of the networks parameters, a low error was obtained evaluating the predictions of power demand signals. Based on the obtained results, it is possible to conclude that the proposed method was very efficient and promising for the calculation of energy demand in electric vehicles.

**Keywords:** Driving cycle; electric vehicle; power management; time series, NARX neural network.

**1 INTRODUÇÃO**

Atualmente, significativa porção das emissões atmosféricas de poluentes relacionadas à atividade humana, em particular aos gases de efeito estufa (GEE), está diretamente ligada ao setor de transportes (Lucena, 2011; Rezvani et al., 2015). Somente o transporte rodoviário (automóveis, caminhões, ônibus, utilitários e motocicletas, que utilizam predominantemente combustíveis fósseis como fonte de energia) pode chegar a apresentar contribuição nas emissões de GEE maior que a de todo o setor industrial (CETESB, 2011). Neste contexto, a possibilidade de substituição da frota de veículos baseada em motor de combustão interna por

veículos elétricos surge como um importante fator para a melhoria das condições ambientais nos centros urbanos, com a redução não só das emissões de gases de efeito estufa, mas também de outros poluentes atmosféricos nocivos à saúde humana e da poluição sonora (Reis and Silva, 2017; Queiroz, 2006).

Pode-se definir por veículo elétrico (VE) aquele cuja propulsão é realizada, total ou parcialmente, por meio de um motor elétrico (Ehsani et al., 2010; Rodrigues, 2014). Atualmente, todos os grandes fabricantes de automóveis produzem modelos de propulsão elétrica (Welch and Ebhardt, 2017). O custo relativamente alto para aquisição destes veículos vem sendo, de certa forma, compensado por ações governamentais em diversos países, com incentivos (bônus e/ou isenção de impostos) e restrições ao uso de automóveis movidos a combustíveis fósseis (Vasconcelos, 2017; Fernandes, 2017).

Apesar dos incentivos citados, o alto custo inicial e menor autonomia em relação aos automóveis convencionais, fatores associados principalmente às baterias, fazem com que os veículos elétricos ainda sejam uma opção menos atrativa para o consumidor. Muitos esforços e investimentos vem sendo empenhados na pesquisa de novas tecnologias de bateria, buscando a obtenção de características que melhor atendam aos requisitos para um VE (basicamente, alta energia específica, maior vida útil e menor custo) (Zuo et al., 2017). Além disso, sistemas híbridos de armazenamento de energia (HESS, do inglês *hybrid energy storage system*) como, por exemplo, sistemas baseados em bateria e supercapacitor (SC), vem também sendo propostos (Amjadi and Williamson, 2012; Ferreira et al., 2008; Sankar et al., 2019; Kouchachvili et al., 2018; Herrera et al., 2016; Song et al., 2017; García et al., 2013; Kanchev et al., 2018).

Supercapacitores (ou ultracapacitores) são capacitores eletroquímicos de dupla camada e que apresentam valor extremamente elevado de capacitância, sendo capazes de armazenar uma quantidade de energia muito maior que qualquer capacitor convencional de massa ou volume equivalentes (Ferreira et al., 2007). A utilização de uma adequada estratégia de gestão de energia em um HESS baseado em baterias e supercapacitores, além de contribuir para o aumento da autonomia do veículo e para a melhoria da resposta dinâmica de seu sistema de propulsão, possibilita a redução de esforços de corrente no banco de baterias embarcado e consequente prolongamento de sua vida útil (Rodrigues, 2014; Kouchachvili et al., 2018). Diferentes estratégias de gestão de energia em HESS composto por bateria e supercapacitor aplicados a veículos elétricos são encontradas na literatura. De forma geral, são associadas são

de controle de processos e inteligência computacional para execução das tarefas envolvidas na gestão de um HESS (Lago, 2019). Estratégias de controle linear são utilizadas em Amjadi and Williamson (2012) e em Ferreira et al. (2008), havendo neste, combinação com sistema supervisorio baseado em lógica *Fuzzy*. Técnica de controle *Fuzzy* adaptativa é empregada em Herrera et al. (2016). Song et al. (2017) utiliza combinação de técnicas de controle não linear (modos deslizantes) e robusto. Já em Kanchev et al. (2018) são utilizadas redes neurais artificiais na gestão de energia do HESS considerado.

Dentro deste contexto, neste trabalho é apresentada uma proposta de metodologia de previsão da potência demandada por um VE para percorrer determinado trajeto, visando sua aplicação na gestão de energia em HESS composto por bateria e supercapacitor. A técnica proposta utiliza uma Rede Neural baseada no Modelo Autorregressivo Não Linear com Entradas Exógenas (NARX, do inglês Nonlinear AutoRegressive with External inputs). Considerando a estratégia de gestão de energia adotada, descrita na próxima seção, destaca-se como as contribuições mais significativas deste trabalho a previsão e a separação das componentes de potência instantânea que devem estar associadas a cada um dos elementos do HESS, informações que serão utilizadas como referência para os sistemas eletrônicos de controle do VE. A metodologia utilizada no desenvolvimento deste trabalho é descrita na Seção 2. Os resultados obtidos, bem como sua discussão, são apresentados na Seção 3.

## **2 MATERIAIS E MÉTODOS**

### **2.1 VISÃO GERAL DO SISTEMA PROPOSTO**

A topologia de conexão do HESS considerado neste trabalho é apresentada na Figura 1. Trata-se de uma configuração totalmente ativa (Sankar et al., 2019; Kouchachvili et al., 2018), em que os bancos de baterias e de supercapacitores do HESS são conectados por meio de conversores estáticos a um barramento CC (corrente contínua), responsável por alimentar o sistema de tração do VE (designado por “carga” na Figura 1). Tal arranjo é considerado em diversos trabalhos encontrados na literatura técnica (Ferreira et al., 2008; García et al., 2013; Rodrigues, 2014; Song et al., 2017; Kanchev et al., 2018).

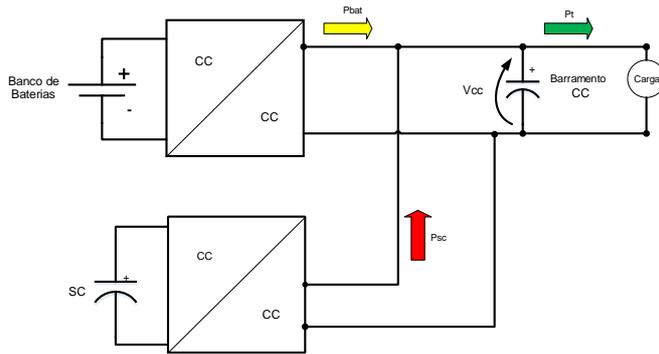


Figura 1. Configuração do HESS considerado.

Considera-se que a gestão de energia do HESS descrito é realizada por meio de uma estrutura de controle hierárquico em dois níveis (Kamal et al., 2017; Papadimitriou et al., 2015; Bouzid et al., 2015; Silva Junior, 2017), conforme ilustrado na Figura 2. No “Nível 1” é realizado o controle de correntes e tensões dos conversores CC/CC que realizam a interface entre bateria/supercapacitor e barramento CC/sistema de tração do VE. Já no “Nível 2”, está localizada a rede neural artificial, cuja análise

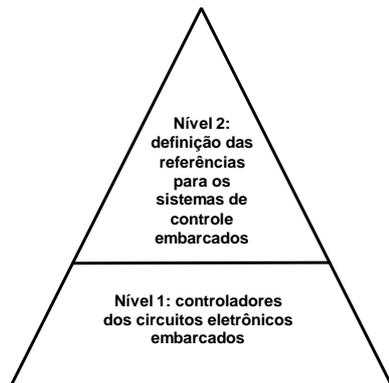


Figura 2. Estrutura de controle hierárquico considerada para a gestão de energia de HESS baseado em bateria e supercapacitor.

e desenvolvimento é abordada neste trabalho. Tal rede neural artificial é responsável pela definição da demanda de potência a ser atribuída a cada um dos elementos do HESS, possibilitando a geração das referências de corrente e tensão das malhas de controle de “Nível 1”.

A estimativa da demanda de potência associada aos bancos de bateria e supercapacitores foi realizada por meio do cálculo da potência de tração necessária para que o VE seja capaz de percorrer determinado trajeto, seguindo perfil de velocidades definido em ciclo de condução padronizado. Levando em consideração as características dinâmicas de baterias e supercapacitores, a estratégia de gestão de energia foi definida considerando as seguintes premissas:

- (1) O banco de baterias deve fornecer, a cada instante, a potência média solicitada pelo sistema de tração. Desta forma é possível minimizar os esforços de corrente no banco de baterias, prejudiciais ao processo eletroquímico de armazenamento de energia de uma bateria;
- (2) O banco de supercapacitores fica responsável pelo fornecimento das variações da potência de tração, uma vez que supercapacitores apresentam melhores características dinâmicas que baterias (associadas ao armazenamento de energia em campo elétrico).

Desta forma, o banco de baterias fornece energia para situações de cruzeiro enquanto o banco de supercapacitores apresenta atuação predominante na alimentação do sistema em transitórios relacionados a aceleração/frenagem do veículo. Neste trabalho considerou-se que o dimensionamento do HESS embarcado no VE foi realizado de forma a atender da demanda de energia ao ciclo de condução ao padronizado sob avaliação (tal dimensionamento está fora do escopo deste artigo, sendo objeto de futuras publicações dos autores).

## 2.2 CICLO DE CONDUÇÃO PADRONIZADO E CÁLCULO DE POTÊNCIA DE TRAÇÃO

Ciclos de condução padronizados são utilizados para a avaliação do desempenho de automóveis, seja para analisar do consumo de combustível ou emissão de poluentes (para o caso de veículos com motor de combustão interna) ou determinar a demanda de potência e consumo de energia, como realizado para o caso de veículos elétricos (Tanaka, 2013; Bingham et al., 2012). Neste trabalho, foi considerado o perfil de velocidades definido no *New European Driving Cycle* (NEDC), exibido na Figura 3(a), o qual possui duração de 1200 s. Em termos de composição, é caracterizado por quatro ciclos ECE-15 (*European Committee of Emissions*) nos seus primeiros 800 s e um *Extra Urban Driving Cycle* (EUDC) em seus 400 s finais, o que possibilita a avaliação de diferentes condições de direção de um veículo (Rosca, 2013).

A potência necessária para o deslocamento de um veículo, denominada potência de tração ( $P_t$ ), seguindo perfil de velocidades ( $v(t)$ ) definido em determinado ciclo de condução pode ser calculada segundo a análise da Figura 4 (Tanaka, 2013; Ferreira et al., 2007). Para tanto, considera-se forças de resistência ao rolamento, componente tangencial da força peso e arrasto aerodinâmico. Além disso, dados como área frontal do veículo ( $A_f$ ), coeficientes de atrito das rodas com o solo ( $f_r$ ) e de arrasto aerodinâmico ( $C_D$ ), aceleração da gravidade ( $g = 9,8 \text{ m/s}^2$ ), massa do massa do veículo ( $m$ ) e densidade do ar ( $\rho = 1,25 \text{ kg/m}^3$ ) e

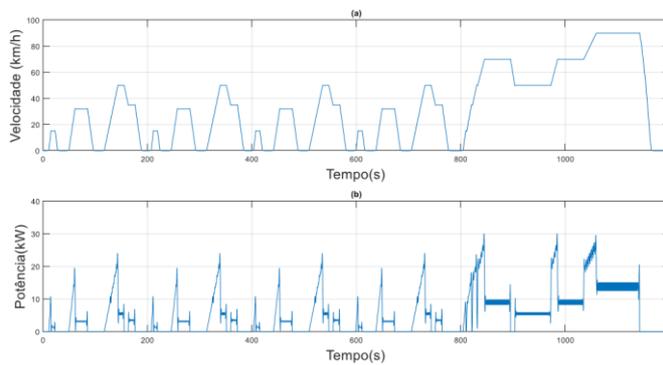


Figura 3. Ciclo de condução ao NEDC: (a) Perfil de velocidade; (b) Potência de tração ou total (exemplo utilizando dados do VE Tesla S P90 D).

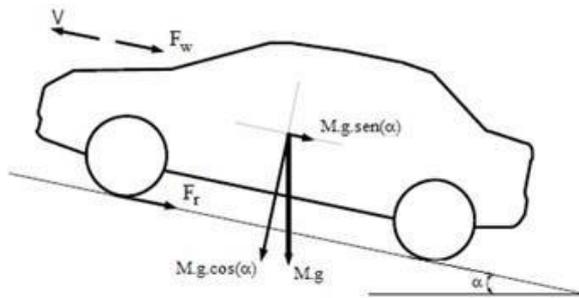


Figura 4. Forças atuantes sobre o veículo (adaptado de Ferreira et al. (2007)).

velocidade do vento ( $v_w$ ), devem ser considerados, como definido na equação (1). Considerando-se os dados referentes ao modelo do ano 2016 do VE Tesla S P90 D ( $A_f = 2,39 \text{ m}^2$ ,  $m = 2239 \text{ kg}$  e  $C_D = 0.24$ ), ângulo de inclinação  $\alpha = 0$ , velocidade do vento nula e perfil de velocidades da Figura 3(a), chega-se à potência de tração necessária para que o veículo cumpra o deslocamento proposto no ciclo de condução ao NEDC, cuja curva em função do tempo é exibida na Figura 3(b).

$$P_t = \left[ m \cdot \frac{dv(t)}{dt} + m \cdot g \cdot \sin(\alpha) + m \cdot g \cdot f_r \cdot \cos(\alpha) + \frac{1}{2} \cdot \rho \cdot A_f \cdot C_D \cdot (v(t) + v_w)^2 \right] \cdot v(t) \quad (1)$$

### 2.3 REDES NARX

Neste trabalho, foi desenvolvido e avaliado um modelo de previsão de séries temporais para o dimensionamento do sistema híbrido de energia embarcado do VE. O objetivo é estimar a demanda da potência nas duas frações consideradas: a demanda de cruzeiro, requisitada do banco de baterias, e os valores de pico de potência, que devem ser fornecidos pelo banco de supercapacitores. Este modelo de previsão é ilustrado na Figura 5, em que  $velocidade(n)$  é a velocidade do veículo no instante atual e  $P_{bat}(n+5)$  e  $P_{sc}(n+5)$  são, respectivamente, as potências demandadas



Figura 5. Modelo de previsão.

dos bancos de bateria e supercapacitores após 0,5 segundos.

Para o modelo de previsão, foi utilizada uma rede Perceptron com Múltiplas Camadas (MLP) baseada no Modelo Auto Regressivo Não Linear com Entradas Exógenas (NARX) (Reynoso-Hernández et al., 2015). Nesta arquitetura, há a realimentação pelo próprio sistema, conforme mostrado na Figura 6, aumentando a capacidade de mapeamento não-linear da rede.

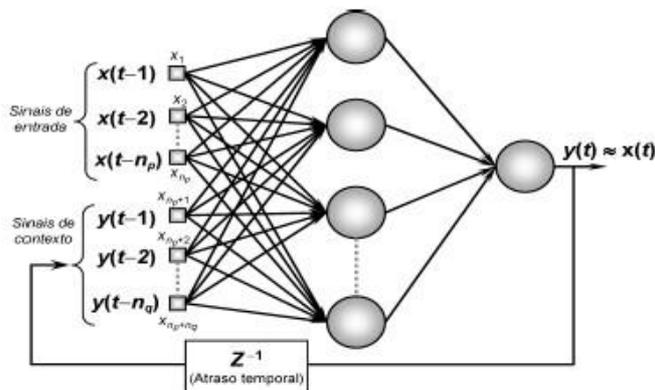


Figura 6. Arquitetura da Rede Neural NARX (adaptado de (Reynoso-Hernández et al., 2015)).

O processo de desenvolvimento, treinamento e teste da Rede NARX para a previsão de demanda de potência foi implementado utilizando o *software* MATLAB. Foram utilizadas as funções *Tansig* e *Purelin* como funções de ativação para a camada escondida e para a camada de saída, respectivamente. Os dados foram divididos sendo 70% para treinamento, 15% para teste e 15% para validação, em um conjunto de 24.000 amostras. O algoritmo de aprendizagem utilizado foi *Levenberg–Marquardt*. O número de neurônios na camada escondida foi variado para verificação do comportamento da rede diante deste parâmetro.

## 3 RESULTADOS E DISCUSSÃO

### 3.1 VARIAÇÃO DO ERRO EM FUNÇÃO DO NÚMERO DE NEURÔNIOS NA CAMADA ESCONDIDA

Na Figura 7, pode-se verificar o comportamento da Rede NARX com a variação do número de neurônios na camada escondida. Neste caso, verificou-se que utilizando 18 neurônios obtém-se o menor erro médio quadrático (MSE) para a predição das potências referentes aos supercapacitores e ao banco de baterias, adotando como entrada a velocidade em função do tempo.

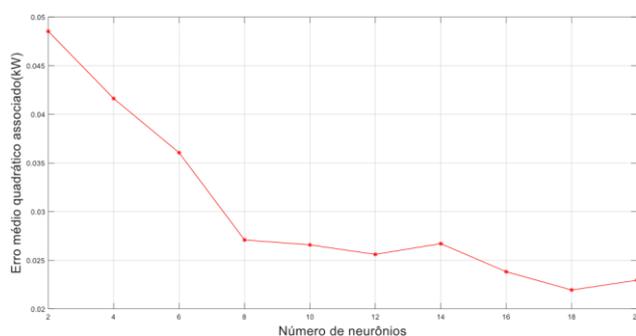


Figura 7. Erro em função do número de atrasos

### 3.2 ANÁLISE DO DESEMPENHO DA REDE

Considerando o modelo de rede NARX proposto com 18 neurônios na camada escondida, obtém-se um erro médio quadrático de aproximadamente 0,02, conforme pode ser visto na curva apresentada na Figura 8. Este resultado indica que a técnica utilizada é promissora realizando a previsão de demanda com alto desempenho.

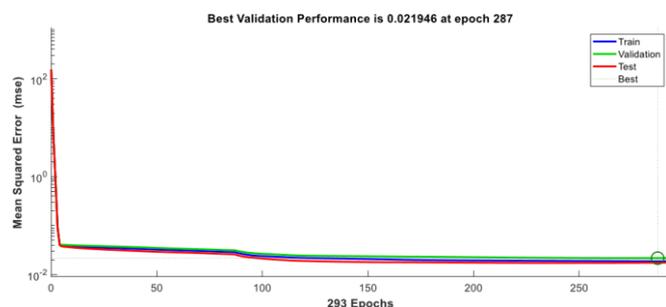


Figura 8. Gráfico de desempenho

**Curvas previstas:** A Figura 9 mostra, respectivamente, as curvas previstas para a demanda de potência do banco de baterias (a) e dos supercapacitores (b). É importante chamar atenção ao fato de que a soma das potências apresentadas nos gráficos da Figura 9(a) e (b) são aproximadamente iguais à potência de tração da Figura 3(b) (a diferença encontra-se no erro de previsão das curvas de potência). Tratando-se de um sistema de armazenamento convencional (apenas com baterias) e tomando como referência a Figura 3(b), picos de potência de cerca de 30 kW seriam demandados do banco de baterias. Por outro lado, no HESS considerado e com o uso técnica de gestão de energia proposta, utilizando rede NARX, é possível verificar considerável redução dos picos de demanda de potência associados ao banco de baterias (que ficam em, no máximo, cerca de 4 kW). Assim, é possível vislumbrar prolongamento da vida útil das baterias embarcadas no VE, uma vez que os maiores esforços de variação de potência (e, conseqüentemente, de corrente) ficam impostos aos supercapacitores, que são dispositivos que possuem características físicas mais adequadas para tal finalidade.

Um detalhamento das curvas previstas, em intervalo em que o ciclo NEDC impõe aceleração ao VE, é exibido na Figura 10. É possível verificar, conforme detalhe da Figura 10(b), que

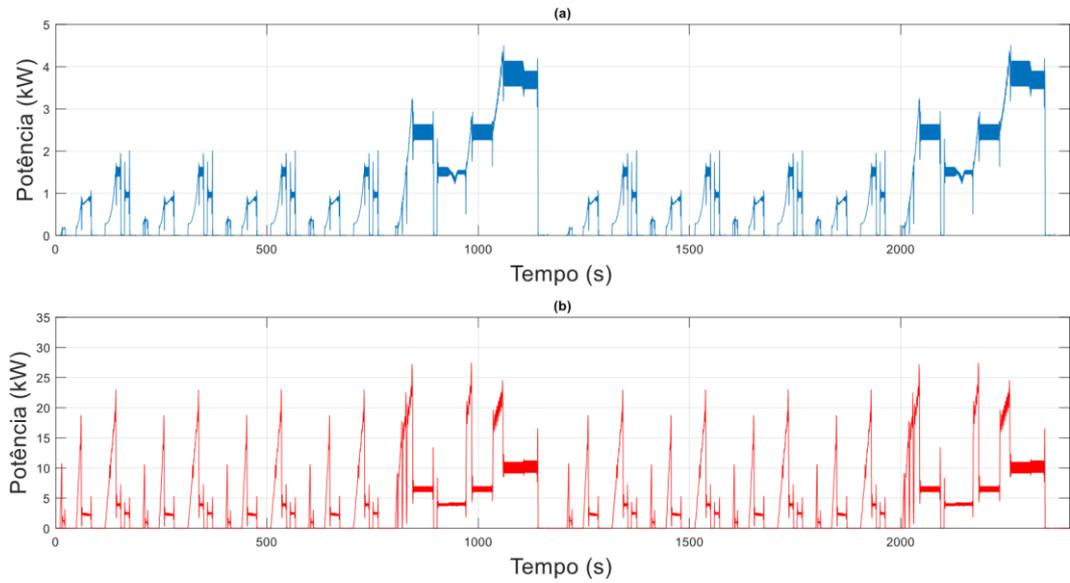


Figura 9. Curva prevista para a demanda de potência associada ao banco de: (a) baterias; (b) supercapacitores.

praticamente toda potência durante a aceleração do VE fica atribuída aos supercapacitores, como desejado.

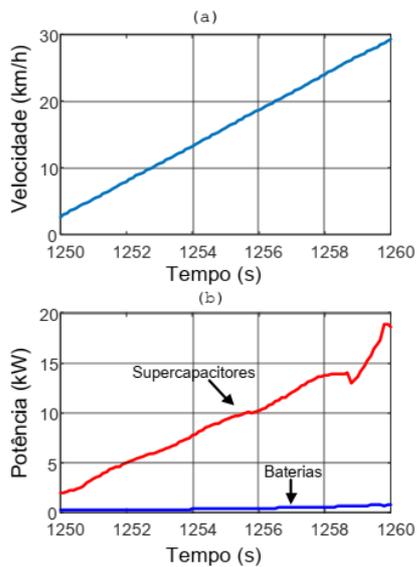


Figura 10. Detalhamento da previsão: (a) velocidade (trecho do ciclo NEDC com aceleração do VE); (b) Potência demandada dos bancos de baterias (curva em azul) e de supercapacitores (curva em vermelho).

#### 4 CONCLUSÃO

Este trabalho apresentou uma estratégia para previsão de demanda de energia para a bateria e para o supercapacitor em um VE utilizando redes neurais baseada no modelo Auto Regressivo Não Linear com Entradas Exógenas (NARX). O algoritmo desenvolvido considera como entrada a velocidade do veículo elétrico e calcula a demanda de potência associada aos elementos do HESS para 0,5 segundos à frente. Com isso, pode-se definir com precisão as referências dos sistemas eletrônicos de controle do VE, possibilitando a implementação de estratégia de gestão de energia capaz de proporcionar o prolongamento da vida útil do banco de baterias embarcado e o aumento da autonomia veículo. Com os resultados obtidos, foi possível confirmar que a utilização de redes NARX para previsão de demanda das frações de potência é uma técnica eficiente e promissora, gerando erros consideravelmente baixos no que se refere aos dados previstos.

Como trabalho futuro, será realizada a implementação em plataforma embarcada da técnica de previsão utilizando a rede NARX para avaliação do comportamento do HESS por meio de simulação em tempo real.

#### AGRADECIMENTOS

Os autores registram seu agradecimento ao CNPq e ao IF Sudeste MG - *Campus* Juiz de Fora pelo suporte financeiro ao desenvolvimento deste projeto de pesquisa.

#### REFERÊNCIAS

- Amjadi, Z. and Williamson, S.S. (2012). Prototype design and controller implementation for a battery-ultracapacitor hybrid electric vehicle energy storage system. *IEEE Transactions on Smart Grid*, 3(1), 332–340. doi:10.1109/TSG.2011.2161623.
- Bingham, C., Walsh, C., and Carroll, S. (2012). Impact of driving characteristics on electric vehicle energy consumption and range. *IET Intelligent Transport Systems*, 6(1), 29–35.
- Bouid, A.M., Guerrero, J.M., Cheriti, A., Bouhamida, M., Sicard, P., and Benhanem, M. (2015). A survey on control of electric power distributed generation systems for microgrid applications. *Renewable and Sustainable Energy Reviews*, 44, 751–766.
- CETESB (2011). Primeiro inventário de emissões antrópicas de gases de efeito estufa diretos e indiretos. Technical report, Companhia Ambiental do Estado de São Paulo - CETESB.

- Ehsani, M., Gao, Y., and Emadi, A. (2010). *Modern Electric Hybrid Electric and Fuel Cell Vehicles*. CRC Press.
- Fernandes, D. (2017). Porque os carros movidos a gasolina e diesel estão com os dias contados e países europeus e vários emergentes.
- Ferreira, A.A., Pomilio, J.A., Spiazzi, G., and de Araujo Silva, L. (2008). Energy management fuzzy logic supervisory for electric vehicle power supplies system. *IEEE Transactions on Power Electronics*, 23(1), 107–115. doi: 10.1109/TPEL.2007.911799.
- Ferreira, A.A., Pomilio, J.A., Silva, E., and Cambra, D.V.P. (2007). Metodologia para dimensionar múltiplas fontes de suprimento de energia de veículos elétricos. In *ABVE-VE 2007*.
- García, P., Torreglosa, J.P., Fernández, L.M., and Jurado, F. (2013). Control strategies for high-power electric vehicles powered by hydrogen fuel cell, battery and supercapacitor. *Expert Systems with Applications*, 40(12), 4791–4804.
- Herrera, V., Milo, A., Gaztañaga, H., Etxeberria-Otadui, I., Villarreal, I., and Camblong, H. (2016). Adaptive energy management strategy and optimal sizing applied on a battery-supercapacitor based tramway. *Applied Energy*, 169, 831–845.
- Kamal, E., Adouane, L., Abdrakhmanov, R., and Ouddah, N. (2017). Hierarchical and adaptive neuro-fuzzy control for intelligent energy management in hybrid electric vehicles. *IFAC-PapersOnLine*, 50(1), 3014–3021.
- Kanchev, H., Hinov, N., Gilev, B., and Francois, B. (2018). Modelling and control by neural network of electric vehicle traction system. *Elektronika ir Elektrotechnika*, 24(3), 23–28.
- Kouchachvili, L., Yaïci, W., and Entchev, E. (2018). Hybrid battery/supercapacitor energy storage system for the electric vehicles. *Journal of Power Sources*, 374, 237–248.
- Lago, L.F.R. (2019). *Gestão do sistema híbrido de energia de um veículo elétrico utilizando redes neurais artificiais*. Monografia, Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais.
- Lucena, S.E. (2011). A survey on electric and hybrid electric vehicle technology. In S. SOYLER (ed.), *Electric Vehicles - The Benefits and Barriers*, 1–18. In Tech.

- Papadimitriou, C., Zountouridou, E., and Hatziargyriou, N. (2015). Review of hierarchical control in dc microgrids. *Electric Power Systems Research*, 122, 159–167.
- Queiroz, J.F. (2006). *Introdução do Veículo Híbrido no Brasil: Evolução Tecnológica Aliada à Qualidade de Vida*. Master's thesis, Universidade de São Paulo, São Paulo.
- Reis, S.R. and Silva, E.A. (2017). Motores elétricos flex a etanol: uma nova era no setor automotivo mundial. *Revista de Ciências Exatas e Tecnologia*, 12(12), 45–48.
- Reynoso-Hernández, A., Rayas-Sánchez, J.E., AguilarLobo, L.M., Loo-Yau, J.R., Ortega-Cisneros, S., and Moreno, P. (2015). Application of the narx neural network as a digital predistortion technique for linearizing microwave power amplifiers.
- Rezvani, Z., Jansson, J., and Bodin, J. (2015). Advances in consumer electric vehicle adoption research: A review and research agenda. *Transportation research part D: transport and environment*, 34, 122–136.
- Rodrigues, M.C.B.P. (2014). *Integração de Filtro Ativo de Potência Monofásico e Bifásico ao Sistema de Propulsão de um Veículo Elétrico*. Ph.D. thesis, Universidade Federal de Juiz de Fora, Juiz de Fora, Brasil.
- Rosca, A. (2013). *Light Duty Vehicle Test Cycle Generation Based on Real-World Data*. Master thesis, Instituto Superior Técnico.
- Sankar, G.U., Moorthy, C.G., and RajKumar, G. (2019). Smart storage systems for electric vehicles – a review. *Smart Science*, 7(1), 1–15. doi:10.1080/23080477.2018.1531612.
- Silva Junior, D.C. (2017). *Modelagem e Controle de Funções Auxiliares em Inversores Inteligentes para Suporte a Microrredes CA - Simulação em Tempo Real com Controle Hardware In the Loop*. Master's thesis, Universidade Federal de Juiz de Fora, Juiz de Fora.
- Song, Z., Hou, J., Hofmann, H., Li, J., and Ouyang, M. (2017). Sliding-mode and lyapunov function-based control for battery/supercapacitor hybrid energy storage system used in electric vehicles. *Energy*, 122, 601–612.
- Tanaka, C.N. (2013). *Metodologia de Dimensionamento do Sistema de Tração para Veículos Elétricos*. Master's thesis, Universidade de São Paulo, São Paulo, Brasil.
- Vasconcelos, Y. (2017). A ascensão dos elétricos. *Revista Pesquisa FAPESP*, (258), 19–27.
- Welch, D. and Ebhardt, T. (2017). Montadoras criam “guerra do carro elétrico” caríssima por causa da Tesla.
- Zuo, W., Li, R., Zhou, C., Li, Y., Xia, J., and Liu, J. (2017). Battery-supercapacitor hybrid devices: recent progress and future prospects. *Advanced Science*, 4(7), 1600539.

