


MODELAGEM DE TORQUE EM MOTORES SÍNCRONOS DE ÍMÃ PERMANENTE (PMSM) POR MEIO DE REDES NEURAIS ARTIFICIAIS

TORQUE MODELING IN PERMANENT MAGNET SYNCHRONOUS MOTORS (PMSM) USING ARTIFICIAL NEURAL NETWORKS

Wilson Furlan Júnior¹ 

Clainer Bravin Donadel² 

Reginaldo Barbosa Nunes³ 

Resumo: As aplicações de inteligência artificial e aprendizado de máquina têm se expandido rapidamente, influenciando diversas áreas, incluindo veículos elétricos (VEs) e sistemas correlatos, como *Vehicle-to-Grid* (V2G) e redes inteligentes. Essas tecnologias são empregadas em diagnósticos de falhas, previsão de consumo de energia e otimização da infraestrutura de carregamento de VEs. Modelos como redes neurais artificiais (RNA) e algoritmos de aprendizado profundo, como o *long short-term memory* (LSTM), têm sido utilizados para melhorar o desempenho desses sistemas. A aplicação de *machine learning* também é explorada em setores como o planejamento de operações e a precificação de sistemas de carregamento, contribuindo para a formação de uma base sólida de estudos sobre o tema. No contexto dos VEs, a estimativa de torque, uma grandeza de difícil obtenção, é um dos focos de interesse, devido à sua relevância no desempenho de motores síncronos de ímã permanente (*permanent magnet synchronous motor*, PMSM), comumente usados em VEs. Assim, este artigo propõe um modelo de RNA do tipo *feed-forward backpropagation* para estimar o torque, utilizando dados experimentais para avaliar o desempenho do modelo e sua precisão. Após o treinamento, o algoritmo desenvolvido alcançou um erro médio em comparação com os dados alvo de 2,62% ao alcançar sua centésima época. Os resultados obtidos permitem identificar os principais desafios da implementação e apontam para o potencial de aplicação em sistemas mais complexos, oferecendo uma abordagem promissora para otimização e controle desses sistemas.

Palavras-chave: Redes Neurais Artificiais. Aprendizado de Máquina. Veículos Elétricos. Motor Síncrono de Ímã Permanente.

Abstract: Applications of artificial intelligence (AI) and machine learning have rapidly expanded, impacting various fields, including electric vehicles (EVs) and related systems such as Vehicle-to-Grid (V2G) and smart grids. These technologies are employed in fault diagnosis, energy consumption forecasting, and optimization of EV charging infrastructure. Models such as artificial neural networks (ANN) and deep learning algorithms, including long short-term memory (LSTM), have been used to enhance the performance of these systems. The application of machine learning is also explored in areas such as operation planning and pricing of charging systems, contributing to a solid research foundation on the subject. In the context of EVs, torque

¹ Bacharelado em Engenharia Elétrica, IFES – *campus* Vitória, furlanjr.wilson@gmail.com.

² Doutorado em Engenharia Elétrica, IFES – *campus* Vitória, cdonadel@ifes.edu.br.

³ Doutorado em Engenharia Elétrica, IFES – *campus* Vitória, regisbn@ifes.edu.br.

estimation—a challenging metric to obtain—emerges as a key area of interest due to its importance in the performance of permanent magnet synchronous motors (PMSM), commonly used in EVs. This article proposes a feed-forward backpropagation ANN model for torque estimation, utilizing experimental data to assess the model's performance and accuracy. After training, the developed algorithm achieved a mean error of 2.62% compared to target data upon reaching its 100th epoch. The results obtained highlight the main challenges of implementation and suggest the potential for applying this approach to more complex systems, offering a promising method for optimizing and controlling these systems.

Keywords: Artificial Neural Networks. Machine Learning. Electric Vehicle. Permanent Magnet Synchronous Motors.

1 INTRODUÇÃO

No mundo contemporâneo, aplicações de inteligência artificial e aprendizado de máquina se tornaram cada vez mais comuns e presentes no cotidiano. Além disso, tais aplicações são empregadas nas mais diversas áreas, como: artes, música, literatura, programação, entre outros. As técnicas têm se tornado cada vez mais complexas e têm um escopo cada vez maior, ao passo que, mesmo em áreas onde tais aplicações antes foram inimaginadas, passam a receber tais inovações. Um exemplo de aplicação de inteligência artificial em uma área de conteúdo pouco explorada é apresentado por Santos *et al.* (2008). Em seu trabalho são discutidos, dentro do campo dos sistemas de gerenciamento de conteúdo, métodos e possíveis aplicações derivadas da integração com soluções de inteligência artificial (IA).

Uma área que também possui alto potencial de aplicação de métodos de IA e aprendizado de máquina é a dos veículos elétricos (VE) e outros sistemas correlatos, como *Vehicle-to-Grid* (V2G), redes inteligentes, entre outros. Dentre essas aplicações, tem-se a trazida por Kaplan *et al.* (2021), no qual é implementado um algoritmo baseado em *long short-term memory* (LSTM), o qual foi treinado a partir de dados coletados (de forma intrusiva) por medidores posicionados em pontos estratégicos de um protótipo de veículo elétrico que estava ao dispor dos pesquisadores, com a finalidade de usar a aplicação para diagnóstico de falhas do sistema. Já Nabi *et al.* (2023) parte para uma abordagem diferente, na qual são utilizados ciclos de direção regulamentados, como o *EPA Federal Test Procedure 75* (FTP75), o *New European Driving Cycle* (NEDC), o US06, dentre outros. Ao inserir os dados destes ciclos em um modelo de veículo elétrico proposto pelos pesquisadores, é obtida uma série de parâmetros relativos ao veículo, como potência do motor (kW), velocidade do motor (km/h), capacidade da bateria (mAh), entre outros. Então, a partir desses dados, é treinada uma rede neural artificial (RNA) que utiliza uma Unidade Linear Retificada (ReLU) e processo de ativação linear com técnica de otimização Adam com a finalidade de prever o consumo de energia (kWh) do VE modelado.

Ainda no mesmo campo de estudo, Madeira *et al.* (2021) realizaram um ensaio conceitual sobre as vantagens da adoção dos VEs e de aplicações V2G e enfatiza a necessidade de realizar a coleta em tempo real de dados da operação do sistema (através de IoT, por exemplo) para fins de otimização e controle. Porém, os autores ressaltam a presença de um grande volume de dados a ser processado, propondo a utilização de algoritmos de aprendizado de máquina como alternativa. Além disso, é recomendada a aplicação do processo de *knowledge discovery in databases* (KDD) para a extração de dados úteis das bases de dados, visando um aumento da eficiência na realização dos procedimentos, já que o KDD proporciona uma maior clareza e objetividade durante cada uma das etapas previstas pelo método.

Outro trabalho que discute aprendizado de máquina em benefício do uso de veículos elétricos é o apresentado por Fescioglu-Unver *et al.* (2023), no qual se discute a utilização nos setores de planejamento de infraestrutura, precificação e roteamento de sistemas postos de carregamento dos VEs. Durante o estudo, os autores compilam e descrevem diversos artigos e pesquisas que tratam da aplicação de *machine learning* na área e em seus subgrupos, como no planejamento de operações de serviço e em problemas de otimização. Tal abordagem contribuiu para formação de uma perspectiva ampla sobre os principais trabalhos acadêmicos recentes sobre o tema, além de apresentar diversos métodos de aprendizado de máquina.

O artigo apresentado por Rajagopalan *et al.* (2023) discute a previsão de demanda de veículos elétricos a curto prazo e estima o tempo ocioso de sistemas V2G através de *machine learning*. No estudo são utilizados diversos algoritmos para tratar dos dois objetivos propostos: SARIMA, Floresta Aleatória (RF), Redes Neurais Artificiais (RNA), Regressão Logística (RL) e *Support Vector Classifier* (SVC). Além disso, o conjunto escolhido pelos autores compreende mais de 30.000 sessões de carregamento contendo dados históricos de carregamento coletados de uma garagem do *campus* da Caltech durante três anos, de 2018 a 2021. Essa informação é crucial já que, a partir dela, pode-se concluir que uma abundante quantidade de dados inserida no

treinamento dos algoritmos se mostra como um dos principais pilares para a obtenção de resultados positivos.

Neste contexto, a estimativa de torque em VEs desponta com particular interesse por ser uma grandeza cuja medição é considerada intrusiva. Assim, este artigo propõe a modelagem de torque em motores síncronos de ímã permanente (PMSM), tipicamente aplicados em VEs, por meio de redes neurais artificiais. O modelo proposto foi treinado por meio de um banco de dados contendo parâmetros colhidos experimentalmente, visando estudos de desempenho e precisão alcançados com o algoritmo. A partir dos resultados foi possível mapear os desafios a serem enfrentados durante esse processo, avaliar a viabilidade da implementação e projetar expectativas para aplicações semelhantes em sistemas motorizados mais robustos e complexos, como veículos elétricos ou sistemas de geração de energia elétrica.

2 METODOLOGIA


Esta seção é dedicada a detalhar a metodologia utilizada para seleção e tratamento dos dados a serem processados, definição do método de aprendizado de máquina escolhido, além dos procedimentos tomados para a obtenção dos resultados.

2.1 Definição do Conjunto de Dados

Dentre os dados disponíveis, o conjunto elaborado por Kirchgässner *et al.* (2021a), o qual compila parâmetros colhidos de diversos ciclos de trabalho de um motor do tipo síncrono de ímã permanente ou em inglês, *permanent magnet synchronous motor* (PMSM), destacou-se e foi adotado pelos autores como o escolhido para o treinamento. Vale destacar que o motor analisado no conjunto é do mesmo tipo utilizado por vários carros elétricos no mercado, inclusive o Chevrolet Bolt, carro utilizado no projeto de Mobilidade Elétrica do Espírito Santo, ao qual este estudo está vinculado.

Nesse conjunto de dados estavam disponíveis um total de 1.330.816 amostras, obtidas com frequência de amostragem de 2Hz ($T=0,5s$), contendo diversos parâmetros, como: velocidade do motor, torque do motor, corrente (em coordenadas d-q), tensão (em coordenadas d-q), temperatura em diversos pontos do motor, entre outros. A título de exemplo, uma parcela dos dados pode ser observada na Figura 1.

Figura 1 - Exemplo de dados contidos no banco de dados utilizado.



Fonte: gerado a partir dos dados obtidos em Kirchgässner *et al.* (2021a).

2.2 Definição dos Parâmetros de Entrada/Saída

Nesta proposta, o torque foi definido como a variável de saída, uma vez que sua medição precisa é altamente intrusiva, tornando sua aplicação inviável em diversas situações práticas. Além disso, dependendo do método adotado, sua implementação pode apresentar um custo elevado. Para as variáveis de entrada, optou-se por utilizar parâmetros que possuam uma relação direta com a variável de saída selecionada (Fitzgerald, 2013). Dessa forma, as variáveis de entrada e saída consideradas neste estudo estão apresentadas no Quadro 1.

Quadro 1 – Parâmetros adotados como variáveis de entrada e saída

TIPO DE VARIÁVEL	NOME DAS VARIÁVEIS
Entrada	u_d (tensão-d), u_q (tensão-q), i_d (corrente-d), i_q (corrente-q), motor_speed (velocidade do motor)
Saída	torque (torque do motor)

Fonte: autoria própria (2024)

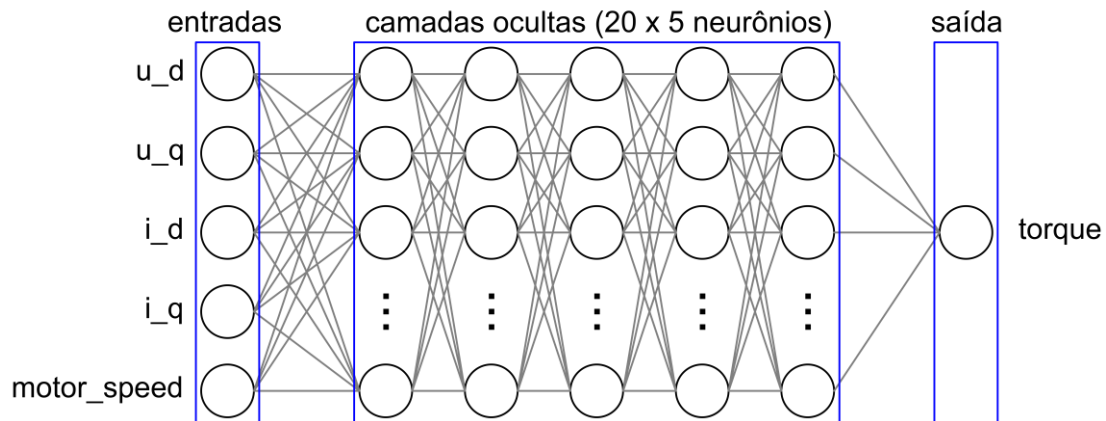
Os parâmetros relacionados à temperatura não foram considerados na elaboração do conjunto de treinamento, devido à baixa correlação observada entre essas variáveis e o torque. Dessa forma, a inclusão dessas variáveis demandaria um esforço computacional elevado para que a rede neural consolidasse essa relação, tornando sua utilização menos eficiente no contexto do estudo.

2.3 Definição do Método de Aprendizado de Máquina

Ao analisar as recomendações das referências consultadas e as características do conjunto de dados utilizado para o treinamento, optou-se pelo uso de uma RNA do tipo *feed-forward backpropagation*, implementada no software MATLAB®. Embora diversos métodos tenham sido considerados, a escolha deste modelo específico justifica-se por sua simplicidade de implementação, adequação ao conjunto de dados selecionado e maior eficiência computacional em relação a outros tipos de redes neurais.

Com a aplicação de aprendizado de máquina definida, assim como suas variáveis de entrada e saída, pode-se esquematizar um modelo simplificado da RNA desenvolvida. Esse modelo pode ser visto na Figura 2.

Figura 2 - Representação gráfica da RNA desenvolvida pelos autores, representando as variáveis de entrada, as camadas ocultas e a variável de saída.



Fonte: autoria própria (2024).

Ainda sobre o algoritmo, os dados foram divididos de forma randômica entre os conjuntos de treinamento, validação e testes, o tipo de treinamento adotado foi o *Levenberg-Marquardt* (LM), e a performance foi medida através de erro quadrático médio ou no inglês, *mean squared error* (MSE). O número de épocas foi definido em 100, enquanto o número máximo de falhas consecutivas nas verificações de validação foi estabelecido em 6, com base em ajustes empíricos, visando garantir a convergência da RNA.

Diversos ensaios foram feitos em busca do melhor resultado. Após a simulação com configurações diversas, o melhor resultado foi obtido com a seguinte estrutura: 5 variáveis de entrada (uma para cada parâmetro de entrada), 5 camadas ocultas contendo 20 neurônios cada e 1 variável de saída (para o parâmetro de saída).

3 RESULTADOS E DISCUSSÕES

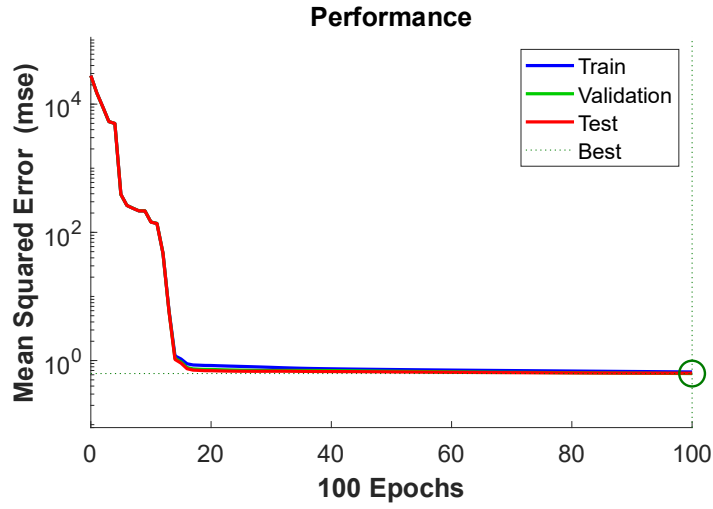
Os resultados do treinamento da RNA proposta estão apresentados na Figura 3, Figura 4 e Figura 5. O gradiente, apresentado na Figura 4, é uma medida que se refere ao gradiente do erro da rede em relação aos seus pesos. Em uma rede do tipo *backpropagation*, o gradiente atua na atualização dos pesos da rede entre épocas, com o objetivo de minimizar o erro observado na

saída. Além disso, o gradiente permite estabelecer o método de otimização Descida do Gradiente (*Gradient Descent*), elemento essencial do algoritmo *Levenberg-Marquardt* mencionado anteriormente.

O parâmetro Mu (também denotado como μ), também ilustrado na Figura 4, é um dos principais parâmetros do algoritmo de otimização *Levenberg-Marquardt*, utilizado durante o treinamento da RNA. Esse parâmetro regula o equilíbrio entre o método de *Gauss-Newton* e o método de Descida do Gradiente, proporcionando um mecanismo de ajuste que pode aprimorar a convergência do algoritmo. Em termos gerais, valores maiores de μ fazem com que o algoritmo LM se aproxime do método Descida do Gradiente, enquanto valores menores aproximam-no do método de *Gauss-Newton*.


Além desses, as verificações de validação, também apresentadas na Figura 4, têm como função indicar se durante uma determinada época houve ou não uma redução na métrica de erro da RNA (neste caso, o MSE) em relação à época anterior. Se a métrica não for reduzida, ocorre uma falha na verificação e o contador de falhas será incrementado. O contador continua sendo incrementado a cada falha consecutiva nas verificações das épocas subsequentes, até atingir o limite máximo estabelecido (neste estudo, o valor adotado foi 6), interrompendo o treinamento da rede. Por outro lado, caso a métrica de erro se reduza durante uma das épocas, o contador é zerado, retornando ao seu valor inicial.

Figura 3 - Erro quadrático médio (MSE) em função do número de épocas.



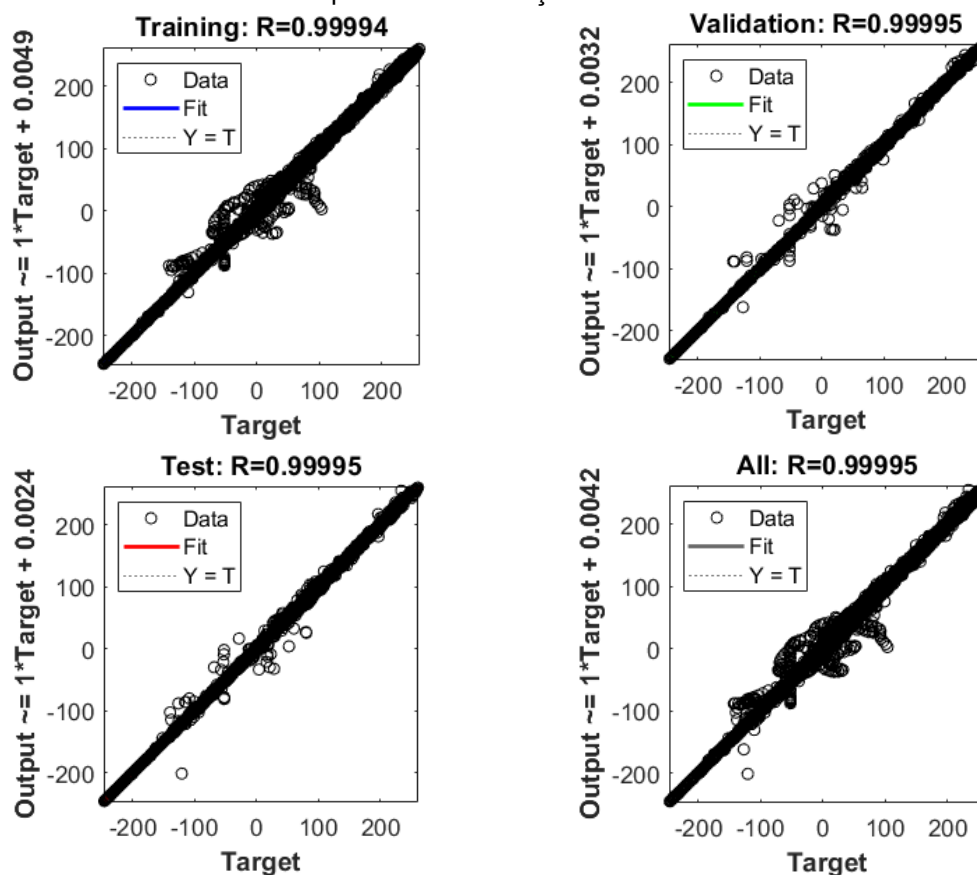
Fonte: autoria própria (2024).

Figura 4 - Gradiente, Mu e estado das verificações de validação em função do número de épocas.



Fonte: autoria própria (2024).

Figura 5 - Resultado para as etapas de treinamento, validação e testes, tendo o progresso obtido pela RNA em função do valor alvo.




Fonte: autoria própria (2024).

A performance da rede, avaliada pelo MSE, atingiu um valor final de 0,664, correspondendo a um erro médio de 2,62%, o que foi considerado satisfatório pelos autores. Esse resultado se torna ainda mais relevante ao considerar que os dados utilizados no treinamento do algoritmo são experimentais e não passaram por nenhum tratamento prévio antes de serem inseridos na RNA desenvolvida (como a aplicação de filtros para suavização de ruídos). Além disso, os valores das métricas R e R^2 para o conjunto de testes foram 0,99995 e 0,99990, respectivamente, indicando uma excelente aderência do modelo proposto, conforme ilustrado na Figura 5. Quanto mais próximo de 1 estiver R^2 , melhor será a capacidade do modelo de representar a relação entre as variáveis. Por fim, ressalta-se que o conjunto de testes não foi utilizado no

treinamento da RNA, garantindo que os resultados refletem a capacidade preditiva real do modelo.

A análise do perfil das previsões geradas pelo algoritmo, especialmente observada na Figura 5, revela que os resultados obtidos apresentam uma alta proximidade com os valores-alvo, com desvios mínimos e pontuais. Um exemplo comparativo entre os valores medidos e estimados de torque é apresentado na Figura 6.

Figura 6 – Comparação entre os valores medidos e estimados de torque (exemplo).



Fonte: autoria própria (2024).

Embora os resultados obtidos sejam satisfatórios, identificou-se que o número de épocas atuou como um fator limitante para o desempenho da RNA. Dessa forma, um aumento no número de épocas poderia, potencialmente, melhorar a performance do modelo. No entanto, testes realizados com um incremento de 10 vezes no número máximo de épocas demonstraram que, apesar de uma ligeira melhora na precisão, o tempo de execução, que já era elevado (aproximadamente 2 horas para 100 épocas), aumentou significativamente.

Além disso, em todos os testes realizados, o treinamento foi interrompido antes de atingir 1000 épocas, devido a falhas consecutivas nas verificações de validação. Esse comportamento sugere que o algoritmo não conseguiu

aprimorar o desempenho em relação à época anterior, impedindo ganhos substanciais na performance além do que foi obtido com 100 épocas.

Conforme ilustrado na Figura 3, é válido destacar que, pouco antes de atingir 40 épocas, o algoritmo já apresentava sinais de estagnação, resultando em ganhos irrisórios de desempenho nas épocas subsequentes. Esse comportamento é corroborado pela Figura 4, que revela, entre as épocas 30 e 40, uma sequência de falhas nas verificações de validação, quase atingindo o limite máximo de 6 falhas. Esse fenômeno sugere que o algoritmo estava tentando ajustar seu modelo, culminando em uma mudança de comportamento, na qual os ganhos significativos de desempenho observados inicialmente deram lugar a melhorias mais discretas por época, tendência que persistiu até o final da execução.

Em relação à não inclusão das variáveis de temperatura, observa-se que este aspecto representa uma possível melhoria para o modelo desenvolvido. Ao adotar uma abordagem de aprendizado de máquina mais robusta, capaz de capturar relações complexas entre as variáveis, espera-se obter maior estabilidade nos resultados. Isso ocorre porque o algoritmo passaria a contar com um conjunto mais amplo de informações, potencialmente aprimorando sua capacidade preditiva.

Nesse contexto, os resultados obtidos por Kirchgässner et al. (2021b) estão alinhados com as expectativas. Nesse estudo, os autores exploraram a estimativa de temperatura em um motor síncrono de ímã permanente (PMSM) utilizando aprendizado de máquina residual profundo, especificamente por meio de redes neurais recorrentes (RNNs) e redes temporais convolucionais (TCNs). Os experimentos foram conduzidos com o mesmo banco de dados empregado no presente trabalho. Entretanto, como o objetivo do estudo de Kirchgässner et al. (2021b) era a predição de um conjunto de variáveis diferente daquele considerado neste artigo, os autores adotaram uma estratégia distinta para a divisão dos dados no treinamento dos modelos de aprendizado de máquina.

4 CONCLUSÕES

Os resultados deste estudo demonstram que a aplicação de RNAs para a estimação de torque em PMSMs é uma abordagem viável, reduzindo a dependência de medições diretas, que podem ser intrusivas e onerosas. O modelo proposto, baseado em uma RNA do tipo *feed-forward backpropagation*, apresentou um alto grau de correlação entre os valores preditos e os valores reais, com coeficiente de determinação (R^2) próximo de 1 e erro médio reduzido (2,62%). Esses resultados indicam que o método pode ser integrado em sistemas de controle de motores elétricos, substituindo ou complementando sensores físicos.

A análise do treinamento revelou que o número de épocas desempenha um papel crítico na convergência do modelo. Embora um aumento no número de épocas possa proporcionar melhorias na precisão, verificou-se que há um limite a partir do qual os ganhos tornam-se marginais, enquanto o tempo de processamento cresce significativamente. Testes realizados com um aumento de 10 vezes no número máximo de épocas evidenciaram que o tempo de treinamento superou 2 horas, sem ganhos expressivos na precisão. Além disso, a interrupção prematura do treinamento devido a falhas consecutivas nas verificações de validação indicou que o modelo alcançou um platô de aprendizado, reforçando a necessidade de técnicas avançadas de regularização para evitar a estagnação do desempenho.

Outro ponto relevante é a exclusão das variáveis de temperatura no conjunto de entrada, que foi motivada pela baixa correlação observada entre essas variáveis e o torque. No entanto, essa decisão representa uma limitação do modelo, visto que, em cenários operacionais reais, fatores térmicos podem influenciar significativamente o comportamento do motor. Assim, a inclusão dessas variáveis em futuras abordagens poderia aprimorar a estabilidade e robustez das predições.

Como trabalho futuro, sugere-se a integração de técnicas mais avançadas de aprendizado de máquina, que possam capturar padrões dinâmicos mais complexos no comportamento do motor. Além disso, a aplicação do modelo em ambientes industriais e automotivos reais permitiria avaliar sua robustez diante

de variações operacionais, tais como mudanças de carga, temperatura e desgaste dos componentes.

Por fim, os resultados deste estudo reforçam o potencial das redes neurais como ferramenta de otimização e monitoramento em sistemas elétricos, viabilizando soluções mais inteligentes e eficientes para o controle de motores elétricos. A possibilidade de substituir sensores físicos por estimativas baseadas em modelos preditivos abre novas perspectivas para aplicações em veículos elétricos, robótica e automação industrial, contribuindo para a redução de custos e maior confiabilidade dos sistemas elétricos modernos.

REFERÊNCIAS

FESCIOGLU-UNVER, N.; YILDIZ AKTAŞ, M. Electric vehicle charging service operations: A review of machine learning applications for infrastructure planning, control, pricing and routing. **Renewable and Sustainable Energy Reviews**, v. 188, p. 113873, 2023. Disponível em: <https://doi.org/10.1016/J.RSER.2023.113873>.

FITZGERALD, A. E.; KINGSLEY JR., Charles; UMANS, Stephen D. **Máquinas Elétricas**. 6. ed. Porto Alegre: AMGH, 2013.

KAPLAN, H.; TEHRANI, K.; JAMSHIDI, M. A Fault Diagnosis Design Based on Deep Learning Approach for Electric Vehicle Applications. **Energies**, v. 14, n. 20, p. 6599, 2021. Disponível em: <https://doi.org/10.3390/en14206599>.

KIRCHGÄSSNER, W.; WALLSCHEID, O.; BÖCKER, J. Electric Motor Temperature [Data set]. **Kaggle**, 2021a. Disponível em: <https://doi.org/10.34740/KAGGLE/DSV/2161054>.

KIRCHGÄSSNER, W.; WALLSCHEID, O.; BÖCKER, J. Estimating Electric Motor Temperatures With Deep Residual Machine Learning. **IEEE Transactions on Power Electronics**, v. 36, n. 7, 2021b. Disponível em: <https://doi.org/10.1109/TPEL.2020.3045596>.

MADEIRA, F. M.; MATTOS, C. A. Framework para Modelo de Previsão de Demanda em Vehicle-to-Grid (V2G) e Rede Inteligente Através de Big Data, Machine Learning e IoT. **ENEGEP - Encontro Nacional de Engenharia de Produção**, 2021. Disponível em:

http://doi.org/10.14488/ENEGEP2021_TN_STO_359_1855_42454.

NABI, M. N.; RAY, B.; RASHID, F.; AL HUSSAM, W.; MUYEEN, S. M. Parametric analysis and prediction of energy consumption of electric vehicles using machine learning. **Journal of Energy Storage**, v. 72, p. 108226, 2023.

Disponível em: <https://doi.org/10.1016/j.est.2023.108226>.

RAJAGOPALAN, P.; THORNBY, J.; RANGANATHAN, P. Short-Term Electric Vehicle Demand Forecasts and Vehicle-to-Grid (V2G) Idle-Time Estimation Using Machine Learning. **2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)**, p. 1279–1286, 2023.

Disponível em: <https://doi.org/10.1109/CCWC57344.2023.10099356>.

SANTOS, F. C.; CARVALHO, C. L. **Aplicação da Inteligência Artificial em Sistemas de Gerenciamento de Conteúdo**. 2008. Disponível em:

https://ww2.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-08.pdf.