

ESTUDO SOBRE IMPLEMENTAÇÃO DE MÉTODOS DE OTIMIZAÇÃO DO RIPPLE E DO CONTROLE DE UM MOTOR DE RELUTÂNCIA

Isabella Silva de Campos¹, Renato Giacomini¹, Milene Galeti¹, Rudolf T. Buhler¹, Arianne S. N. Pereira²,

¹ Departamento de Elétrica, Centro Universitário FEI

² Departamento de Elétrica, ISPGAYA (Portugal)

unieiscampos@fei.edu.br

Resumo: Este trabalho propõe uma estrutura de simulação em Python para analisar torques e correntes em um motor de relutância trifásico. O foco é a extração e análise de parâmetros de máquinas de relutância síncronas (SyRM), especialmente torque e correntes em ângulos de fase. A pesquisa visa superar a limitação da variação de torque usando técnicas de Inteligência Artificial (IA) para otimizar o desempenho das máquinas de relutância síncronas.

1. Introdução

As máquinas de relutância síncronas (SyRM) são conhecidas por sua operação eficiente e veloz [1]. No entanto, sua aplicação em sistemas de alto desempenho é limitada pela alta variação de torque, que gera ruído indesejado e restringe seu uso. Minimizar esse efeito, chamado de ripple de torque, é crucial para várias aplicações, incluindo sistemas automotivos [2].

O ripple de torque é a produção desigual de torque durante a rotação do rotor em um motor energizado [3][4]. Coletar dados é fundamental antes de abordar soluções. Com base nisso, sistemas de acionamento elétrico inteligentes podem ser desenvolvidos para minimizar essa variação através do controle de corrente.



Figura 1 - Imagem do motor síncrono de relutância modelo do fabricante da ABB (SynRMABB) [2]

A inteligência artificial é um avanço que permite que máquinas tomem decisões de forma autônoma, usando grandes conjuntos de dados. As Redes Neurais Artificiais (RNAs) fazem parte da Inteligência Artificial e se inspiram no neurônio, a unidade básica do cérebro. O cérebro biológico apresenta capacidades notáveis para processar vastas quantidades de informações simultaneamente por meio de uma rede neural complexa [5].

Neurônios em RNAs são projetados para tarefas específicas e têm entradas ponderadas. Após combinação, passam por uma "função de ativação" que determina a saída [6]. A Figura 2 mostra a arquitetura de formação de redes neurais.




Figura 2 - Representação da arquitetura de um neurônio artificial [5].

Usar RNAs para reduzir a variação de torque tem vantagens, já que não exige modelagem analítica completa, o que é difícil em operações não lineares [6]. Não é necessário criar manualmente parâmetros para caracterizar um evento, já que o processo de treinamento em dados brutos extrai características, acelerando o desenvolvimento de sistemas de análise.

2. Métodos e Materiais

Este projeto propõe uma abordagem que analisa harmônicas, corrente, velocidade e potência mecânica para extrair perdas e reduzir a variação de torque.

O primeiro passo envolveu o desenvolvimento de um código para simular a máquina de relutância. Essa representação estrutural foi elaborada utilizando o ambiente Spyder em conjunto com o software FEMM [7]. O código foi programado em Python e com o auxílio da biblioteca PyFemm para se comunicar com o FEMM, sendo possível realizar uma simulação calculando o campo magnético em relação ao ângulo de posição do rotor.

A máquina estudada neste projeto é um motor de relutância síncrono trifásico. Essa máquina será amplamente analisada, uma vez que faz parte de um projeto mais abrangente, que inclui um projeto avançado de controle no Centro Universitário FEI.

O motor de relutância analisado possui 24 ranhuras, 2 pares de polos e dimensões específicas, com raio externo de 47,5 mm e raio interno de 28,5 mm. A configuração inclui uma sequência de fases que define a polaridade e direção da corrente. O ângulo máximo de operação é de 30 graus, a amplitude da corrente é de 10 A e o deslocamento de fase é de 22,5 graus. Esses parâmetros são fundamentais para a configuração e interpretação dos resultados da simulação do motor de relutância.

3. Resultados

É importante observar que os resultados apresentados até agora são preliminares. O extenso conjunto de dados gerado neste estudo serve como base para treinar uma Rede Neural Artificial (RNA). O objetivo principal é fornecer à RNA uma ampla gama

de valores de torque, corrente e variação obtidos a partir de diferentes formas de onda de corrente.

Este conjunto de dados de treinamento visa aprimorar a capacidade da rede em analisar e prever soluções ótimas, resultando em um desempenho melhor na minimização da variação de torque e na obtenção dos resultados desejados. Durante a simulação, foram geradas representações gráficas para ilustrar a relação entre corrente e torque em função da posição. Essas visualizações oferecem insights valiosos sobre o comportamento do sistema e orientam análises posteriores.

O primeiro gráfico na Figura 3 ilustra o torque em função da posição angular. A curva azul representa a forma de onda de entrada senoidal, que para garantir variedade dos dados optou-se por utilizar valores aleatórios dos coeficientes da série de Fourier que formam uma senoide. Por outro lado, a curva amarela representa a forma de onda de saída do motor de relutância.




Figura 3 - Torque x Ângulo

Assim, o segundo gráfico, Figura 4, mostra a corrente em função da posição, sendo que cada curva representa a corrente em uma fase diferente. Isso representa a relação que a corrente tem com a potência elétrica.




Figura 4 - Corrente x Ângulo

Para garantir um banco de dados eficaz para a criação de uma rede neural artificial capacitada para lidar com diferentes variações de corrente e torque em cenários do mundo real, foram realizadas 110 simulações, a Tabela I representa 3 resultados das realizadas.

Tabela I – Resultados de 3 simulações.

Torque Máximo	Torque Médio	Torque Mínimo	Ripple
0.11263296	0.02789446	-0.06404730	0.17668026
0.27549249	0.06281534	-0.12830343	0.40379592
0.19420925	0.05577992	-0.04879871	0.24300797

Para uma análise mais aprofundada dos dados, serão gerados gráficos utilizando o software MATLAB, a fim de assegurar a precisão e confiabilidade das informações geradas para avaliar o desempenho do motor de relutância.

O próximo passo envolverá a importação para o ambiente de trabalho do aplicativo MATLAB, utilizando explicitamente a ferramenta "Classification Learner". Essa ferramenta permite treinar vários modelos de redes neurais para determinar a mais eficaz que pode ser identificada por meio do software.

4. Conclusões

Este estudo mostra a implementação bem-sucedida do motor projetado e a simulação integrada com programação, analisando várias formas de onda para avaliar o torque da máquina de relutância. O uso do Método dos Elementos Finitos Magnéticos (FEMM) é eficaz para análises precisas da variação de torque.

A simulação calculou o torque e o ângulo do motor, fornecendo insights para otimizações futuras na redução da variação em máquinas de relutância. A integração das Redes Neurais Artificiais (RNAs) mostra potencial em identificar parâmetros ideais para diminuir a variação.

Esse estudo é base para futuras explorações da variação de torque em máquinas de relutância usando IA. Estudos posteriores podem melhorar o desempenho de motores elétricos.

5. Referências

- [1] A. K. Singh, R. Raja, T. Sebastian, and K. Rajashekara, "Torque Ripple Minimization Control Strategy in Synchronous Reluctance Machines," *IEEE Open Journal of Industry Applications*, vol. 3, pp. 141–151, Jul. 2022, doi: 10.1109/ojia.2022.3190905.
- [2] DIAS, M.; MARQUES, L. C. De S. Robust control of permanent magnet synchronous motor based on higher-order sliding mode approach. In: 2009 Brazilian Power Electronics Conference. Bonito-Mato Grosso do Sul, Brazil, 2009. p. 1163-1170. DOI: 10.1109/COBEP.2009.5347721.
- [3] H. Wu, D. Depernet, V. Lanfranchi, K. E. K. Benkara, and M. A. H. Rasid, "A Novel and Simple Torque Ripple Minimization Method of Synchronous Reluctance Machine Based on Torque Function Method," *IEEE Transactions on Industrial Electronics*, vol. 68, no. 1, pp. 92–102, Jan. 2021
- [4] C. Donaghy-Spargo, Synchronous reluctance motortechnology: industrial opportunities, challenges and future direction Eng. Technol. Ref., May 2016, doi:10.1049/ETR.2015.0044
- [5] R. Izbicki and T. Mendonça dos Santos, "Aprendizado de máquina: uma abordagem estatística.", vol.1, pp.27-36, 2020.
- [6] "Neural Networks - A Comprehensive Foundation - Simon Haykin", vol.1, pp. 91 – 106, 2008.
- [7] "refman-4.0," FEMM Documentation, Accessed: May 27, 2023. Available: <https://www.femm.info/wiki/Download>

Agradecimentos

À instituição Centro Universitário FEI pelo do suporte financeiro.

¹ Aluno de IC do Centro Universitário FEI (PIBIC-FEI). Projeto com vigência de 03/2023 a 03/2024.

