

Otimização por Enxame de Partículas Aplicada ao Projeto de uma SMPMSM

Eduardo M. C. S. de Oliveira *, Stefan T. C. A. dos Santos *,
Allan G. de Castro *, Geyverson T. de Paula **,
Jose R. B. de Almeida Monteiro *

* Departamento de Engenharia Elétrica e de Computação, Escola de Engenharia de São Carlos Avenida Trabalhador São-carlense, 400, CEP 13566-590 São Carlos, SP, Brasil, (e-mail: eduardoliveira@usp.br, stefan.santos@usp.br, allangregori@usp.br, jrm@sc.usp.br).

** Universidade Federal de Goiás - EMC - Engenharia Elétrica Av. Universitária, nº 1488, Quadra 86, Bloco A - 3º Piso CEP: 74605-010 - Setor Leste Universitário - Goiânia - GO - Brasil, (e-mail: geyverson@ufg.br).

Abstract:

This work aims to optimize the design of a Surface-Mounted Permanent Magnet Synchronous Machine and uses a single-objective algorithm where a composite objective function has been applied. The particle swarm algorithm was used in the optimization process, where a Finite-Element Analysis (FEA) software was also adopted to perform electromagnetic analysis in the development of the algorithm. Among the possibilities of design variables in the adopted machine, the magnet thickness, polar pitch and slot width ratio (which alters the slot proportionally) were considered. As a final objective, a cost function was developed, which must be minimized and is composed of optimization objectives. The optimization objectives are torque ripple and power density. Next, the results found are presented, where it was possible to obtain a reduction of 81.3% in torque *ripple* and an increase of 12.5% in power density.

Resumo: Este trabalho visa otimizar o projeto de uma Máquina Síncrona de Ímã Permanente Montado na Superfície, e utiliza um algoritmo de objetivo único, onde foi aplicada uma função objetivo composta. O algoritmo de enxame de partículas foi utilizado no processo de otimização, onde também foi adotado um software de Análise dos Elementos Finitos (FEA) para realizar a análise eletromagnética no desenvolvimento do algoritmo. Dentre as possibilidades de variáveis de projeto na máquina adotada, foram consideradas a espessura do ímã, o passo polar e a razão da largura da ranhura (que altera a ranhura proporcionalmente). Como objetivo final, foi desenvolvida uma função de custo, que deve ser minimizada e é composta por objetivos de otimização. Os objetivos de otimização são *ripple* de torque e densidade de potência. Em seguida, são apresentados os resultados encontrados, onde foi possível obter uma redução de 81,3% no *ripple* de torque e um aumento de 12,5% na densidade de potência.

Keywords: Surface-Mounted Permanent Magnet Synchronous Machine, Particle Swarm Optimization, Finite-Element Analysis.

Palavras-chaves: Máquina Síncrona com Ímã Permanente na Superfície do Rotor, Otimização por Enxame de Partículas, Análise de Elementos Finitos.

1. INTRODUÇÃO

Em diversas aplicações de acionamentos com máquinas elétricas, a máquina síncrona com ímã permanente na superfície do rotor (em inglês *Surface-Mounted Permanent Magnet Synchronous Machine* - SMPMSM) tem se tornado uma escolha adequada e preferível frente a outros tipos de máquinas, dada sua alta eficiência, a ausência de escovas para alimentação de enrolamentos no rotor e sua boa relação entre torque produzido e o peso final da

máquina (Levent et al., 2020). Como consequência, este tipo de máquina tem sido aplicada em veículos elétricos (Sreejith and Singh, 2021), servomecanismo (Li et al., 2019), geração de energia (Liu et al., 2021), entre outros. Ainda que a alocação dos ímãs na superfície do rotor possa deixar a máquina menos robusta para operação em velocidades elevadas, quando comparada com o PMSM com ímãs no interior do rotor, a fabricação mais simples e barata e o menor momento de inércia resultante colaboram para o amplo uso desse tipo de máquina (Paitandi and Sengupta, 2020).

* O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

É preciso ter atenção às características construtivas e de operação que devem ser consideradas para a obtenção de um desempenho adequado ou ótimo da máquina em determinada aplicação. Para que a SMPMSM alcance as condições de funcionamento almeçadas, por um lado, é possível utilizar técnicas de controle para produzir formas de onda de tensão que gerem um fluxo magnético apropriado para a operação da máquina; por outro lado, é possível escolher adequadamente os parâmetros do corpo da máquina ainda durante a fase de projeto (Zhao et al., 2020).

Dada a complexidade do projeto de SMPMSMs e de máquinas elétricas em geral, métodos de otimização têm sido aplicados. Na literatura, é possível encontrar uma semelhança entre diversos trabalhos que abordam otimização do projeto de máquinas elétricas, a escolha das mesmas variáveis de otimização. No caso de SMPMSMs, o tamanho dos *slots*, diâmetro interno e externo do estator, espessura dos ímãs montados na superfície do rotor e tamanho da lacuna de ar entre estator e rotor (*air gap*) são frequentemente abordados como variáveis de otimização (Zhao et al., 2020). Assim, por exemplo, entre os dados de projeto destacados, em Xing Jin et al. (2018) é mostrada a influência do tamanho dos slots e do comprimento do *air gap* sobre perdas por corrente parasita no ferro. Entre os objetivos de otimização, podem ser mencionados: maximização do conjugado eletromagnético produzido, minimização do *ripple* de torque, redução do volume e máxima eficiência (Lim et al., 2015).

A escolha do algoritmo de otimização é uma etapa importante, uma vez que existem diversos algoritmos inteligentes que podem ser utilizados. Por exemplo, o método de Monte Carlo foi adotado em Ibtissam et al. (2018), o qual exigiu alto número de iterações e conduziu a um projeto aprimorado em relação ao torque e à eficiência, porém não verdadeiramente ótimo. Autores em Zhao et al. (2020) adotaram Algoritmos Genéticos (AG) para uma otimização multi-objetivos, também obtendo melhores resultados quanto à amplitude do torque médio, à eficiência e à oscilação de torque; porém, um dos principais problemas de AG é o custo computacional (Mutluer and Bilgin, 2012). Um terceiro método largamente utilizado é a Otimização por Enxame de Partículas (em inglês *Particle Swarm Optimization* - PSO) (Soygenç and Ergene, 2020; Lee et al., 2016), o qual demonstra melhor desempenho e menor custo computacional comparado com AG (Mutluer and Bilgin, 2012). Outros algoritmos de otimização aplicados ao projeto de máquinas síncronas com ímã permanente são a evolução diferencial (Beniakar et al., 2010), o otimizador *Grey Wolf* (Karnavas et al., 2016), entre outros.

A forma como o algoritmo de otimização é aplicado também deve ser considerada. Diversos autores preferem considerar um modelo matemático da máquina, o qual relaciona parâmetros construtivos com os objetivos de otimização (Ibtissam et al., 2018; Karnavas and Korkas, 2014; Karnavas et al., 2016), enquanto outros preferem simular cada uma das soluções candidatas em análise de elementos finitos (em inglês *Finite Element Analysis* - FEA) (Piotuch and Palka, 2014; Son et al., 2020; Sun et al., 2021). Otimizar com base no modelo matemático é menos pesado computacionalmente se comparado ao uso de FEA, mas

torna mais difícil considerar fenômenos de acoplamento e saturação.

Tendo estas informações em vista, o presente trabalho busca aplicar, diretamente na etapa de FEA, um algoritmo de otimização multi-objetivos no projeto de uma máquina síncrona com ímã permanente na superfície do rotor. O método adotado é o PSO, cujas vantagens já foram listadas anteriormente. Após esta Introdução, a Seção 2 apresenta brevemente o algoritmo PSO. A seguir, a Seção 3 indica a estrutura da SMPMSM a ser otimizada e como o algoritmo altera os parâmetros da máquina. Na Seção 4, os resultados obtidos são mostrados, e então é feita a comparação entre a máquina inicial e a otimizada. Por fim, a Seção 5 apresenta as conclusões pertinentes.

2. OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)

Inspirado no comportamento de pássaros, cardume de peixes e nas regras subjacentes que permitem que um grande número de pássaros se reúnam em sincronia, em 1995 foi introduzido o conceito de otimização por enxame de partículas, por Kennedy and Eberhart (1995). O PSO também pode ser descrito como um método de otimização de funções não lineares, que estabelece um compromisso entre o rápido tempo de simulação computacional, enquanto mantém a confiabilidade dos pontos ótimos encontrados no processo de busca (Mutluer and Bilgin, 2012). Assim, devido a sua inspiração em comportamentos sociais encontrados na natureza, na sua concepção em Kennedy and Eberhart (1995) foi mencionado o conceito de partícula pela primeira vez. A partícula define o núcleo do PSO, e durante o desenvolvimento da ferramenta de otimização deve ser criada uma população de partículas de acordo com as necessidades do problema de otimização.

Na natureza, em algumas situações, o indivíduo beneficia-se mais em saber descobertas e melhores experiências anteriores dos outros membros da sociedade, ao contrário de competir por itens alimentares distribuídos de forma desordenada (Kennedy and Eberhart, 1995). Com base nessa observação, o PSO é construído de maneira que todas as partículas compartilhem informações entre si. As partículas compõem todas as possíveis soluções do problema a ser otimizado, e têm dimensão D , em um espaço de busca K , com a mesma dimensão. Considerando n partículas no espaço de busca K , a posição de cada partícula pode ser descrita por x_i , $i = 1, 2, 3, \dots, n$.

Assim, a posição é uma importante informação no desenvolvimento do PSO, pois com base nela é feita a avaliação da partícula em relação a ser uma candidata a solução ou não. A posição deve ser constantemente atualizada e isso é feito pela velocidade, que é calculada com base no melhor local que o indivíduo x_i já esteve, assim como a melhor posição considerando todos os indivíduos da população. Dessa forma, o movimento de cada partícula em direção ao custo otimizado não ocorre de forma isolada, mas sim de forma solidária em relação a toda população, tornando o algoritmo mais confiável, quando se trata de encontrar pontos ótimos globais e não locais (Xing Jin et al., 2018).

No desenvolvimento do PSO, o primeiro passo é criar as partículas e distribuí-las no espaço K de forma randômica.

Em seguida, a posição de cada indivíduo x_i deve ser avaliada com base em uma função custo F :

$$F(x_i) = f_1(x_i) + f_2(x_i) + f_3(x_i) + \dots + f_p(x_i), \quad (1)$$

onde p representa a quantidade de objetivos na otimização, assim como a função custo de mais de um objetivo em SOYGENÇ and ERGENE (2020).

Posteriormente, é necessário que a melhor posição em que cada indivíduo já esteve, assim como a melhor posição global, sejam conhecidas. Logo após, a velocidade v_i detalhada em (2), e a posição $x_i(j)$ descrita em (3) em cada iteração j , para todas as n partículas, devem ser atualizadas.

$$v_i(j) = wv_i(j-1) + c_1r_1[P_{best,i} - x_i(j-1)] + c_2r_1[G_{best} - x_i(j-1)] \quad (2)$$

$$x_i(j) = x_i(j-1) + v_i(j). \quad (3)$$

Na equação (2), $v_i(j)$ é a velocidade do i .ésimo indivíduo da população na j .ésima iteração e w o coeficiente de inércia desse indivíduo. $P_{best,i}$ representa a melhor posição que a i .ésima partícula já esteve, enquanto G_{best} refere-se à melhor posição global, considerando as n partículas, assumindo que comunicam-se entre si. Os valores c_1 e c_2 são taxas de aprendizagem do indivíduo e do grupo, respectivamente (também conhecidos como coeficientes de aceleração pessoal e global), e r_1 e r_2 são números aleatórios distribuídos no intervalo de 0 e 1 (Mutluer and Bilgin, 2012). Na equação (3), $x_i(j)$ é a posição do i .ésimo indivíduo da população na j .ésima iteração.

No passo final, é analisado se o algoritmo chegou na quantidade máxima de iterações ajustada. Caso não seja verdade, o processo é retomado e todas as partículas são avaliadas segundo a função F .

3. OTIMIZAÇÃO MULTI-OBJETIVO APLICADA AO PROJETO DE UMA SMPMSM

A máquina inicial considerada neste artigo é baseada no trabalho dos autores em Gyselinck et al. (2003), porém com adaptações para considerar os ímãs na superfície do rotor. Alguns dados da máquina-base são apresentados na Tabela 1, e sua seção transversal é indicada na Fig. 1.

A Fig. 1 também destaca as três variáveis de otimização consideradas neste artigo: a espessura do ímã l_m , o passo polar α_m e a proporção da largura do slot P_{lss} (que altera proporcionalmente a largura do slot tanto em sua região mais estreita k_{ss1} como na mais larga k_{ss2}). A Tabela 2 introduz a faixa de variação permitida para cada uma das grandezas listadas. É também realizada uma distinção entre as variáveis de valor fixo, devido às restrições de aplicação da máquina, como raio externo do estator e número de polos, e as variáveis de valores ajustáveis. A escolha das variáveis ajustáveis mencionadas é baseada na relação que existe com os objetivos finais de otimização.

Os objetivos considerados na otimização do projeto da máquina são a densidade de potência P_v , para maximização, e ondulação do torque eletromagnético r_{Te} , para minimização. Além disso, foram adicionados pesos aos objetivos de otimização $\varrho_1 = 4,33 \times 10^3$, e $\varrho_2 = 3,7 \times 10^6$,




Figura 1. Representação da seção transversal de dois polos da máquina-base.

Tabela 1. Dados da máquina-base.

Parâmetro	Valor	Unidade
Parâmetros fixos		
Pares de polos	n_p	4 -
Número de ranhuras	n_r	24 -
Comprimento axial	L_a	40 mm
Raio do eixo	r_a	10,5 mm
Comprimento do entreferro	g	1 mm
Comprimento do slot	h_{ss}	14 mm
Abertura do slot	h_{sas}	0,9 mm
Altura das sapatas	h_{sts}	0,6 mm
Raio interno do estator	$r_{s,i}$	26 mm
Raio externo do estator	$r_{s,e}$	46 mm
Parâmetros variáveis		
Espessura do ímã	l_m	1,8 mm
Passo polar	α_m	122,5 graus
Largura do slot	k_{ss1}	1,3 mm
Largura do slot	k_{ss2}	1,7 mm
Valores nominais		
Velocidade nominal	ω_n	1000 rpm
Corrente nominal ^a	I_n	4 A
Potência nominal	P_n	360 W
Torque nominal	T_n	3,45 N.m

^aValor de pico.

Tabela 2. Faixas de variação das variáveis de otimização.

Variável	Mínimo	Máximo	Unidade
Espessura do ímã	l_m	1,2 - 2,4	mm
Passo polar	α_m	72 - 180	graus
Prop. largura do slot	P_{lss}	0,8 - 1,2	-
Largura do slot ^a	k_{ss1}	1 - 1,5	mm
Largura do slot ^a	k_{ss2}	1,3 - 2	mm

^aVariação proporcional a P_{lss} .

com a finalidade de ponderar cada termo. Os valores dos pesos foram ajustados de acordo com (4) e (5):

$$\varrho_1 = 0,8 \times 10 \times \frac{1}{r_{Te0}^2} \quad (4)$$

$$\varrho_2 = 0,2 \times 10 \times P_{v0}^2 \quad (5)$$

Onde r_{Te0} e P_{v0} representam os valores iniciais de *ripple* de torque e densidade de potência, respectivamente, conforme a Tabela 5.

Assim, partindo de (1), a função custo é expressa em (6). Por fim, os demais parâmetros associados ao algoritmo PSO estão descritos na Tabela 3. O projeto dos coeficientes de aceleração pessoal, global e o fator de inércia foi baseado em Clerc and Kennedy (2002).

$$F(x_i) = \varrho_1 r_{Te}^2 + \varrho_2 \left(\frac{1}{P_v} \right)^2 \quad (6)$$

Tabela 3. Parâmetros do algoritmo PSO.

Parâmetro		Valor
Número de iterações	i	20
Número de partículas	n	50
Coefficiente de inércia	w	0,729
Coefficiente de aceleração pessoal	c_1	1,496
Coefficiente de aceleração global	c_2	1,496

A solução do problema de otimização proposto neste trabalho exigiu o uso de duas ferramentas computacionais distintas: a simulação em FEA é realizada utilizando o pacote ONELAB, que reúne e integra os *softwares* Gmsh (Geuzaine and Remacle, 2009) e GetDP (Dular et al., 1999); já o algoritmo de otimização e todo o tratamento matemático necessário para a resolução deste problema foram implementados utilizando o *software* MATLAB. O funcionamento do algoritmo completo é representado no fluxograma da Fig. 2. A curva que relaciona a densidade de fluxo magnético (B) e a intensidade de campo magnético (H) é linear nas simulações em FEA. Foram consideradas correntes senoidais nos enrolamentos da máquina.

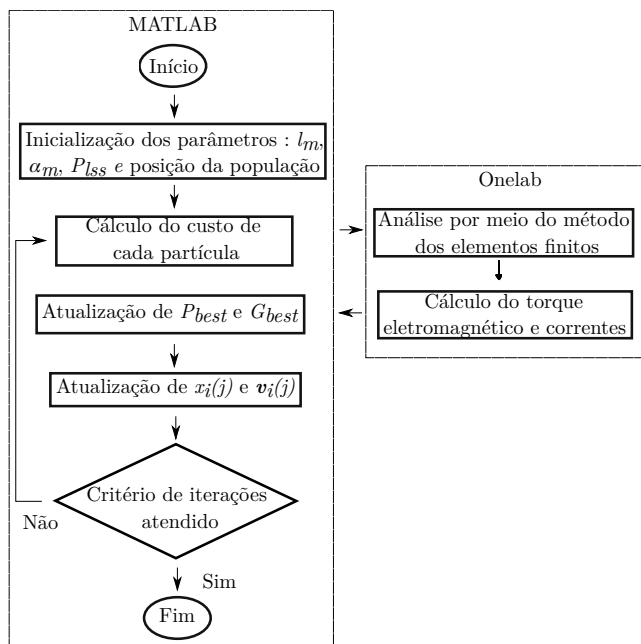


Figura 2. Ilustração das diversas etapas executadas pelo algoritmo de otimização em conjunto com a análise por elementos finitos.

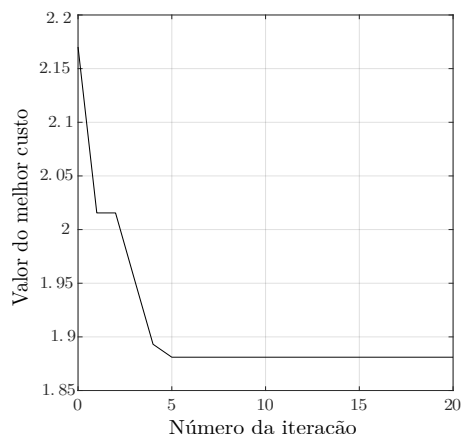


Figura 3. Valor da função custo em cada iteração.

4. RESULTADOS

A Tabela 4 mostra os valores iniciais e finais das variáveis de otimização após a execução do algoritmo PSO. Como mencionado anteriormente, os valores iniciais de projeto referem-se à máquina inicial apresentada em Gyselinck et al. (2003). É possível notar que, em relação à Tabela 1, o ímã apresenta dimensões superiores, resultando em uma maior quantidade de fluxo disponível no rotor.

Tabela 4. Valores finais das variáveis de otimização.

Parâmetro		Valor inicial	Valor otimizado	Unidade
Espessura do ímã	l_m	1,8	2,4	mm
Passo polar	α_m	122,5	137	graus
Largura do slot	k_{ss1}	1,3	1,1	mm
Largura do slot	k_{ss2}	1,7	1,5	mm

Tabela 5. Valores finais dos objetivos de otimização.

Parâmetro	Valor inicial	Valor otimizado	Variação percentual
Ripple de torque	4,3%	0,8%	-81,3%
Densidade de potência	1353,8W/m ³	1520,2W/m ³	12,5%

A Tabela 5 sintetiza os objetivos de otimização antes e após a aplicação do algoritmo PSO. Como se vê, o algoritmo de otimização foi capaz de levar a um projeto de SMPMSM com melhores valores de r_{Te} e P_v . Na tabela é mostrada a variação percentual dos objetivos de otimização em relação aos valores iniciais. Uma variação negativa representa diminuição, enquanto uma variação positiva simboliza aumento. Houve uma redução no valor do *ripple* de torque. Por outro lado, ocorreu um aumento no valor da densidade de potência, devido ao acréscimo do torque médio desenvolvido, que inicialmente era de 3,45N.m e foi para 3,86N.m. A Fig. 3 mostra a qualidade da otimização; a convergência da função custo expressa em (6) em função da iteração. Após cinco iterações, é possível observar que o valor da função custo se estabelece em 1,89.

As Fig. 4 e Fig. 5 mostram a distribuição da densidade de fluxo magnético na máquina para o caso inicial e

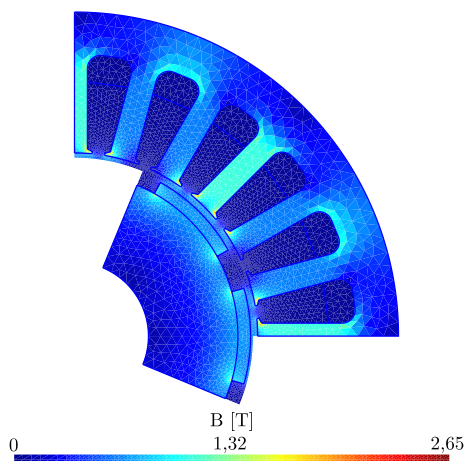


Figura 4. Distribuição da densidade do fluxo magnético: Máquina inicial.




Figura 5. Distribuição da densidade do fluxo magnético: Máquina otimizada.

otimizado. Observa-se uma redução na máxima densidade de fluxo do estator de 2,65 T para 2,05 T. Isso ocorreu devido à diminuição na largura do *slot*, conforme a Tabela 4, e o consequente aumento na dimensão dos dentes, que implica em uma menor relação de fluxo magnético por área. Apesar disso, a Tabela 4 também indica um aumento do ímã; isso leva a uma maior intensidade de campo magnético. Como consequência, houve redução do risco de desmagnetização dos ímãs quando comparado ao modelo inicial.

Com o aumento da espessura do ímã, também é possível observar um maior fluxo magnético concatenado por fase, cujo valor máximo passou de 0,1401 Wb para 0,1637 Wb. Desse modo, o algoritmo de otimização estabelece um compromisso entre as três variáveis de projeto, com o objetivo de manter o *ripple* de torque reduzido e, simultaneamente, elevar a quantidade de fluxo disponível no entreferro, com a finalidade de aumentar o torque produzido. A força contraeletromotriz também sofre influência da elevação na quantidade de fluxo disponível, com um valor máximo inicial de 54,5 V, chegando a um valor máximo otimizado de 58,7 V. Dessa forma, tal aumento no valor da força contraeletromotriz contribui para a elevação no valor do torque médio desenvolvido e, consequentemente, no au-




Figura 6. Resultados da análise em FEA para velocidade nominal da máquina inicial: Torque eletromagnético (T_e), força contraeletromotriz (U_a) e fluxo magnético (ϕ_a).




Figura 7. Resultados da análise em FEA para velocidade nominal da máquina otimizada: Torque eletromagnético (T_e), força contraeletromotriz (U_a) e fluxo magnético (ϕ_a).

mento da densidade de potência. O comportamento do torque desenvolvido, força contraeletromotriz e fluxo, no domínio do tempo, são apresentados nas Fig. 6 e Fig. 7, onde é possível observar graficamente os valores destacados na Tabela 5.

O perfil de força contraeletromotriz também pode ser decomposto no seu conteúdo harmônico para o caso inicial e otimizado. A Fig. 8 mostra as componentes harmônicas normalizadas em relação à componente fundamental para ambos os casos até a décima terceira ordem. Infere-se do gráfico que ocorreu uma redução na amplitude de todas as componentes não múltiplas de três, para o caso otimizado. Assim, como a aplicação da máquina em estudo não prevê conexão com neutro, todas as componentes ímpares, múltiplas do harmônico de terceira ordem, não influenciam no desempenho final do torque eletromagnético. As demais

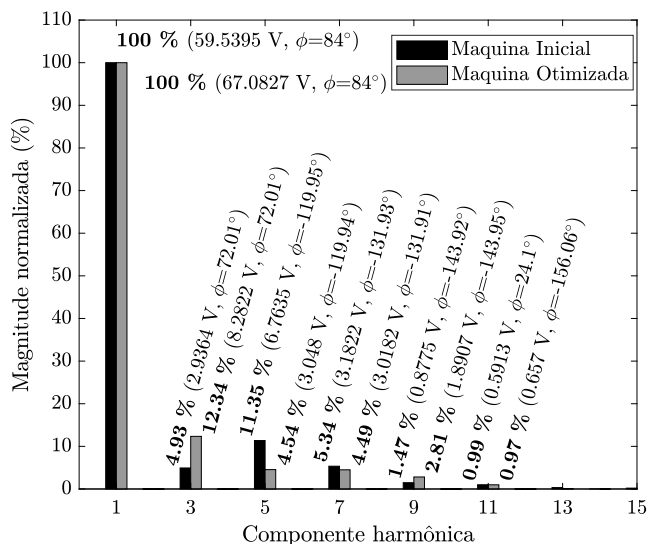


Figura 8. Decomposição discreta de *Fourier* da força contraeletromotriz.

componentes ímpares sofrem uma redução na amplitude, tornando a força contraeletromotriz menos oscilante, resultando em um torque eletromagnético com menos *ripple*.

5. CONCLUSÕES

Tendo em vista a complexidade do projeto de SMPMSMs e a utilidade de métodos de otimização para superar os desafios pertinentes a esta etapa, o presente trabalho propôs-se a aplicar, na etapa de FEA, o algoritmo de otimização PSO ao projeto de uma SMPMSM. As variáveis de otimização consideradas foram a espessura do ímã, o passo polar e a proporção da largura do *slot*, e os objetivos de otimização adotados foram a amplitude do *ripple* de torque, e a densidade de potência.

O algoritmo PSO foi capaz de encontrar, após cinco iterações, uma solução com custo mínimo. A qual aumentou a densidade de potência da máquina em 12,5% e reduziu o *ripple* de torque em 81,3%. Além disso, foi mostrado que a força contraeletromotriz para máquina otimizada apresenta componentes harmônicas ímpares não múltiplas de três reduzidas, em relação à máquina inicial. Por consequência, o *ripple* de torque sobre o conjugado eletromagnético sofre redução.

AGRADECIMENTOS

Os autores agradecem à CAPES e ao Programa Rota2030 pelo apoio financeiro.

REFERÊNCIAS

Beniakar, M., Tsampouris, E., Patsios, C., and Kladas, A. (2010). Evolutionary optimization of permanent magnet machine design for traction applications. In *Digests of the 2010 14th Biennial IEEE Conference on Electromagnetic Field Computation*, 1–1.

Clerc, M. and Kennedy, J. (2002). The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation*, 6(1), 58–73. doi:10.1109/4235.985692.

Dular, P., Geuzaine, C., Genon, A., and Legros, W. (1999). An evolutive software environment for teaching finite element methods in electromagnetism. *IEEE Transactions on Magnetics*, 35(3), 1682–1685.

Geuzaine, C. and Remacle, J.F. (2009). Gmsh: A 3-d finite element mesh generator with built-in pre- and post-processing facilities. *International Journal for Numerical Methods in Engineering*, 79(11), 1309–1331.

Gyselinck, J., Dular, P., Vandeveld, L., Melkebeek, J., Oliveira, A.M., and Kuo-Peng, P. (2003). Two-dimensional harmonic balance finite element modelling of electrical machines taking motion into account. *COMPEL - The international journal for computation and mathematics in electrical and electronic engineering*, 22(4), 1021–1036.

Ibtissam, B., Mourad, M., Medoued, A., and Soufi, Y. (2018). Multi-objective optimization design and performance evaluation of slotted halfbach pmsm using monte carlo method. *Scientia Iranica*, 25(3), 1533–1544.

Karnavas, Y., Chasiotis, I., and Peponakis, E. (2016). Permanent magnet synchronous motor design using grey wolf optimizer algorithm. *International Journal of Electrical and Computer Engineering*, 6(3), 1353–1362.

Karnavas, Y.L. and Korkas, C.D. (2014). Optimization methods evaluation for the design of radial flux surface pmsm. In *2014 International Conference on Electrical Machines (ICEM)*, 1348–1355. doi:10.1109/ICELMACH.2014.6960357.

Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-international conference on neural networks*, volume 4, 1942–1948. IEEE.

Lee, J.H., Kim, J.W., Song, J.Y., Kim, Y.J., and Jung, S.Y. (2016). A novel memetic algorithm using modified particle swarm optimization and mesh adaptive direct search for pmsm design. *IEEE Transactions on Magnetics*, 52(3), 1–4. doi:10.1109/TMAG.2015.2482975.

Levent, A.H., Lordoglu, A., and Aydeniz, M.G. (2020). Design and optimization of permanent magnet synchronous motor for electric vehicle applications. In *2020 2nd Global Power, Energy and Communication Conference (GPECOM)*, 148–151. IEEE.

Li, F., Wang, S., Li, J., Wang, L., and Li, Q. (2019). Adaptive robust position control of uncertain pmsm servo system using extended state observer. In *2019 22nd International Conference on Electrical Machines and Systems (ICEMS)*, 1–4. doi:10.1109/ICEMS.2019.8922298.

Lim, D.K., Yi, K.P., Jung, S.Y., Jung, H.K., and Ro, J.S. (2015). Optimal design of an interior permanent magnet synchronous motor by using a new surrogate-assisted multi-objective optimization. *IEEE Transactions on Magnetics*, 51(11), 1–4.

Liu, B., Li, Z., Dong, X., Yu, S.S., Chen, X., Oo, A.M.T., Lian, X., Shan, Z., and Liu, X. (2021). Impedance modeling and controllers shaping effect analysis of pmsg wind turbines. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 9(2), 1465–1478. doi:10.1109/JESTPE.2020.3014412.

Mutluer, M. and Bilgin, O. (2012). Design optimization of pmsm by particle swarm optimization and genetic algorithm. In *2012 International Symposium on Innovations in Intelligent Systems and Applications*, 1–4. IEEE.

- Paitandi, S. and Sengupta, M. (2020). Analysis, fabrication and detailed comparative study of surface and interior rotor pmsm prototypes of identical nominal ratings and stators. *Sadhana*, 45(69), 1–24.
- Piotuch, R. and Palka, R. (2014). Fem based ipmsm optimization. *Problem Issues Electrical Machines*.
- Son, J.C., Kang, Y.R., and Lim, D.K. (2020). Optimal design of ipmsm for fcev using novel immune algorithm combined with steepest descent method. *Energies*, 13(13).
- SOYGENÇ, O.C. and ERGENE, L.T. (2020). Particle swarm optimization implementation on pmsm design. In *2020 21st International Symposium on Electrical Apparatus Technologies (SIELA)*, 1–4. doi:10.1109/SIELA49118.2020.9167068.
- Soygenç, O.C. and Ergene, L.T. (2020). Particle swarm optimization implementation on pmsm design. In *2020 21st International Symposium on Electrical Apparatus Technologies (SIELA)*, 1–4.
- Sreejith, R. and Singh, B. (2021). Sensorless predictive current control of pmsm ev drive using dsogi-fl1 based sliding mode observer. *IEEE Transactions on Industrial Electronics*, 68(7), 5537–5547.
- Sun, X., Shi, Z., Lei, G., Guo, Y., and Zhu, J. (2021). Multi-objective design optimization of an ipmsm based on multilevel strategy. *IEEE Transactions on Industrial Electronics*, 68(1), 139–148. doi:10.1109/TIE.2020.2965463.
- Xing Jin, Y., yuan Wang, A., Wang, T., Sun, J., and Xing Wang, M. (2018). Optimal design of loss of permanent magnet synchronous motor based on particle swarm optimization. In *2018 IEEE Student Conference on Electric Machines and Systems*, 1–4. IEEE.
- Zhao, X., Sun, Z., and Xu, Y. (2020). Multi-objective optimization design of permanent magnet synchronous motor based on genetic algorithm. In *2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*, 405–409. IEEE.