

Estimação de parâmetros elétricos de motores de indução trifásicos via métodos de otimização heurísticos^{*}

Gabriel Biscardi^{*} Lucas Jonys R. Silva^{*} Márcio V. Rondow Campos^{*}
Deniver R. Schutz^{*} Ricardo Q. Machado^{*} Vilma A. Oliveira^{*}

^{*} Universidade de São Paulo, Av. Trabalhador Sancarlense, 400. São Carlos, São Paulo, Brasil (e-mail: gabriel.biscardi, lucasjonys, marciovonrondow, deniver, rquadros, voliveira@usp.br).

Abstract: The accurate estimation of the electrical parameters of a three-phase induction motor is important for modeling and tuning controllers. This work presents results of estimating the parameters of a three-phase induction motor model W22 IR3 Premium using two heuristic methods: Particle Swarm Optimization (PSO) and Differential Evolution Optimization (DEO). The results are compared with parameter estimation via direct current, locked rotor and no-load tests. The validation of the methods used is carried out based on the torque, efficiency, power factor curves provided by the manufacturer. The results show that the parameters obtained by optimization present a smaller percentage error than the parameters obtained through experimental tests.

Resumo: A estimação precisa dos parâmetros elétricos de um motor de indução trifásico é importante para a modelagem e sintonia de controladores. Este trabalho apresenta resultados da estimação dos parâmetros de um motor de indução trifásico comercial modelo W22 IR3 Premium usando dois métodos heurísticos: otimização por enxame de partículas (PSO em inglês de particle swarm optimization) e otimização por evolução diferencial (DEO das iniciais em inglês). Os resultados são comparados com a estimação de parâmetros via ensaios de corrente contínua, rotor bloqueado e à vazão. A validação dos métodos utilizados é realizada com base nas curvas de torque, rendimento e fator de potência fornecidas pelo fabricante. Os resultados evidenciam que os parâmetros obtidos por otimização apresentam menor erro percentual que os parâmetros obtidos via ensaios experimentais.

Keywords: Three-phase induction motor; parameter estimation; heuristic optimization; particle swarm optimization; differential evolution.

Palavras-chaves: Motor de indução trifásico; estimação de parâmetros; otimização heurística; otimização por enxame de partículas; evolução diferencial.

1. INTRODUÇÃO

O motor de indução trifásico (MIT) é um tipo de máquina elétrica amplamente difundido nas mais diferentes aplicações industriais (Sengamalai et al., 2022). Seu funcionamento baseia-se no princípio da indução eletromagnética, caracterizado por um rotor móvel e um estator fixo, este formado a partir de um conjunto de três bobinas espaçadas entre si de 120° elétricos. Ao ser alimentado por uma tensão trifásica um campo magnético girante é gerado no interior do motor induzindo correntes no rotor. Essas correntes induzidas geram um campo magnético no rotor que ao interagir com o campo magnético girante do estator produz um torque que impulsiona o giro do rotor.

Devido à sua eficiência, robustez e facilidade de controle, os MITs são amplamente utilizados em ambiente industrial, doméstico e agrícola, representando entre 35% e 40% do consumo de eletricidade produzida no mundo. Conhecer os parâmetros elétricos do circuito equivalente do motor de indução é muito importante para a aplicação em projetos de controladores, diagnóstico de falhas e em *hardware in the loop* (HIL) (Vukašinović et al., 2022).

Métodos clássicos e convencionais para estimar os parâmetros do circuito equivalente do motor de indução são baseados em ensaios práticos considerando o motor bloqueado, à vazão e em curto circuito (Sengamalai et al., 2022). No entanto, essas estimações não podem ser implementadas facilmente, pois estão sujeitas a imprecisões derivadas de erro humano ou dos instrumentos disponíveis. O método de estimação de parâmetros *offline* não necessita da realização de ensaios e pode ser realizado a partir de algoritmos de otimização, como os algoritmos meta-heurísticos para modelos lineares e não lineares.

^{*} Reconhecimentos aos suportes financeiros: Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) processo nº 2022/00628-9, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) processo nº 88887.703189/2022-00 e Fundação de Desenvolvimento da Pesquisa-Fundep Rota 2030/Linha V 27192/27.

Em Sakthivel et al. (2010) o método PSO é aplicado para estimar os parâmetros de um motor de indução utilizando o modelo de circuito simplificado e circuito exato. Foi comparado com o método de otimização por algoritmos genéticos (GA), apresentando resultados mais próximo dos parâmetros ideais e com menor desvio padrão. Além disso, o PSO apresentou melhor taxa de convergência e menor sensibilidade a população inicial em relação ao GA por não realizar o processo de mutação, que demanda um maior esforço computacional. Em Vukašinić et al. (2022) foi utilizado o algoritmo *Wild horse optimization* (WHO) com a mesma função custo e motores utilizados em Sakthivel et al. (2010), o algoritmo apresentou uma maior velocidade de convergência e um menor desvio padrão em relação ao PSO, mas não foi realizado uma comparação com o algoritmo *differential evolution optimization* (DEO).

Visando reproduzir e validar os métodos de otimização meta-heurísticos para a estimação *offline* de parâmetros em um MIT (modelo WEG), este trabalho realiza a comparação entre os parâmetros estimados por ensaios a vazio, a rotor bloqueado e em curto circuito e os parâmetros estimados pelos métodos PSO e DEO adaptados. Os resultados obtidos mostraram uma melhor estimação dos parâmetros utilizando o método de otimização *offline*.

2. PRELIMINARES

Um MIT pode ser modelado via o circuito equivalente da Figura 1. Os parâmetros do circuito equivalente descritos na Tabela 1 podem ser obtidos seguindo três ensaios: o ensaio à vazio, o ensaio à rotor bloqueado, e o ensaio em curto-circuito (Sengamalai et al., 2022).




Figura 1. Circuito equivalente monofásico de um motor de indução trifásico.

Tabela 1. Parâmetros do circuito equivalente

Parâmetro	Descrição
V_ϕ	Tensão de fase
I_e	Corrente do estator
I_r	Corrente do rotor
I_ϕ	Corrente de magnetização
R_e	Resistência do estator
R_r	Resistência do rotor
R_c	Resistência do núcleo
X_e	Reatância do estator
X_r	Reatância do rotor
X_m	Reatância de magnetização
s	Escorregamento

2.1 Ensaio a curto-circuito

No ensaio à curto-circuito, aplica-se uma tensão $V_{\phi,cc}$ variável em corrente contínua entre duas fases do MIT,

medindo os valores correspondentes de corrente $I_{e,cc}$. O coeficiente angular da reta gerada pela interpolação linear dos diferentes pontos ($V_{\phi,cc}, I_{e,cc}$) fornece R_{cc} , a resistência equivalente entre as duas fases. Para um MIT com conexão em delta, a relação entre R_{cc} e R_e é dada por (Chapman, 2013):

$$R_{cc} = R_e \parallel 2R_e = \frac{2}{3}R_e. \quad (1)$$

2.2 Ensaio à vazio

No ensaio à vazio, aplica-se no motor em vazio a tensão trifásica nominal à frequência nominal. A tensão $V_{\phi,vz}$ de fase em vazio, a potência $P_{3\phi,vz}$ trifásica em vazio e a corrente $I_{e,vz}$ do estator em vazio são medidas. Com estas grandezas é possível determinar R_c e estabelecer uma relação entre X_m e X_e (Chapman, 2013):

$$\begin{cases} R_c = \frac{V_{\phi,vz}^2}{P_{3\phi,vz} - 3R_e I_{e,vz}^2} \\ X_e + X_m \approx \frac{V_{\phi,vz}}{I_{e,vz}} \end{cases}. \quad (2)$$

2.3 Ensaio à rotor bloqueado

No ensaio à rotor bloqueado, aplica-se a corrente de linha nominal no motor em condições de rotor bloqueado. A tensão $V_{\phi,rb}$ de fase em rotor bloqueado, a potência $P_{3\phi,rb}$ trifásica em rotor bloqueado e a corrente $I_{\phi,rb}$ de fase em rotor bloqueado são medidas. Com estas grandezas, considerando que o ensaio foi feito à frequência nominal, é possível encontrar relações entre X_e e X_r , bem como entre R_e e R_r (Chapman, 2013):

$$\begin{cases} \theta = \cos^{-1} \left(\frac{P_{3\phi,rb}}{\sqrt{3}V_{\phi,rb} I_{e,rb}} \right) \\ R_e + R_r = \frac{V_{\phi,rb}}{I_{\phi,rb}} \cos \theta \\ X_e + X_r = \frac{V_{\phi,rb}}{I_{\phi,rb}} \sin \theta \end{cases}. \quad (3)$$

Segundo o *datasheet*, o MIT estudado é da categoria N descrita pela norma ABNT (2018), equivalente à categoria A descrita pela norma NEMA (Bonnett, 1999). Portanto a relação entre X_r e X_e é:

$$X_r = X_e. \quad (4)$$

3. OBTENÇÃO DOS PARÂMETROS VIA OTIMIZAÇÃO

A obtenção dos parâmetros do MIT via ensaios experimentais descritos na Seção 2 estão sujeitos à imprecisão dos instrumentos de medição empregados, temperatura de operação e também aos erros de leitura. Uma solução alternativa é utilizar as curvas experimentais fornecidas pelo fabricante para obtenção dos parâmetros via otimização numérica. Para isso, a função custo F_{cost} a ser otimizada é dada por:

$$F_{cost} = \sum_{i=1}^9 \left(\frac{x_i - x_{i,dt}}{x_{i,dt}} \right)^2, \quad (5)$$

em que $x_{i,dt}$ para $i = 1, 2, \dots, 9$ são dados fornecidos pelo *datasheet*, detalhados de acordo com a Tabela 2, enquanto

os parâmetros x_i são os valores correspondentes dessas grandezas para um MIT cujos parâmetros do circuito equivalente monofásico são R_e , R_r , X_e , X_r , R_c e X_m , obtidos via equações dos MITs vistas em Chapman (2013).

Tabela 2. Parâmetros obtidos pelo *datasheet*.

Parâmetro	Descrição
$x_{1,dt}$	Fator de potência (plena carga)
$x_{2,dt}$	Fator de potência (50% de carga)
$x_{3,dt}$	Torque nominal
$x_{4,dt}$	Torque máximo
$x_{5,dt}$	Torque de partida
$x_{6,dt}$	Rendimento (plena carga)
$x_{7,dt}$	Rendimento (50% de carga)
$x_{8,dt}$	Corrente nominal
$x_{9,dt}$	Corrente de partida

3.1 Otimização por enxame de partículas

O primeiro algoritmo de otimização empregado neste artigo é o método PSO. É um método iterativo heurístico que consiste em mover partículas, isto é, soluções candidatas, no espaço de pesquisa com base na posição e velocidade de cada partícula bem como na melhor posição local conhecida, de acordo com um determinado critério de escolha (Huang et al., 2023; Grassi et al., 2023). Embora haja risco da solução encontrada através do método PSO não convergir para a melhor solução global, o método não emprega gradiente, portanto é aplicável em problemas não diferenciáveis. Matematicamente, o algoritmo PSO pode ser descrito por (Huang et al., 2023):

$$\begin{aligned} \mathbf{V}_k^{it+1} &= \omega_{ps} \mathbf{V}_k^{it} + C_{ps1} rps_1 (\mathbf{P}_k^{it} - \mathbf{X}_k^{it}) + \dots \\ &\quad \dots + C_{ps2} rps_2 (\mathbf{P}_g^{it} - \mathbf{X}_k^{it}), \quad (6) \\ \mathbf{X}_k^{it+1} &= \mathbf{X}_k^{it} + \mathbf{V}_k^{it+1} \end{aligned}$$

em que \mathbf{X}_k e \mathbf{V}_k são a posição e a velocidade do k -ésimo conjunto de partículas, respectivamente, \mathbf{P}_k e \mathbf{P}_g é a melhor solução da iteração anterior e a melhor solução global, respectivamente, it é o número de iterações, ω_{ps} é o peso de inércia, C_{ps1} é o grau social, C_{ps2} é o grau cognitivo e rps_1 e rps_2 são intervalos aleatórios entre 0 e 1. O Algoritmo 1 descreve o procedimento de otimização PSO.

3.2 Evolução diferencial

O segundo algoritmo de otimização empregado neste artigo é o método DEO. Assim como o PSO, o DEO é um método iterativo heurístico que não emprega gradientes, podendo ser usado em problemas não diferenciáveis. A otimização via DEO é feita iterativamente através da criação de novas soluções possíveis através da combinação de um número de partículas da iteração anterior com as melhores medidas de qualidades segundo um critério de escolha escolhido (Liu et al., 2023; Chakraborty et al., 2023). Matematicamente, o algoritmo DEO pode ser descrito pelas relações (Pant et al., 2020; Leon, 2014):

$$\mathbf{V}_k^{it} = \mathbf{X}_{r_1}^{it} + F_{dc} (\mathbf{X}_{r_2}^{it} - \mathbf{X}_{r_3}^{it}), \quad (7)$$

$$\mathbf{T}_k^{it}[j] = \begin{cases} \mathbf{V}_k^{it}[j], & \text{se } \text{rand}[0, 1] < CR \text{ ou } j = j_r \\ \mathbf{X}_k^{it}[j], & \text{caso contrário} \end{cases}, \quad (8)$$

Algoritmo 1 PSO, adaptado de Nammalvar (2018)

Entrada: Número de iterações (n), Número de partículas (m), tamanho da população (N_{ps}), dimensão da solução (dim), grau social (C_1), grau cognitivo (C_2), inércia (ω), Limites inferiores e superiores (LB e UB) e função objetivo (F_{cost})

Saída: Custo por iteração (**Custo**) e solução (**Sol**)

início

Inicia os vetores e parâmetros

Inicia a velocidade e posição das partículas aleatoriamente

para (1 até N_{ps}) **faça**

Atualiza os parâmetros aleatoriamente

fim

para (it de 1 até n) **faça**

para (1 até N_{ps}) **faça**

para (1 até dim) **faça**

Atualiza a velocidade das partículas

Atualiza a posição das partículas

Corrige a posição entre LB e UB

fim

Avalia o custo das partículas

Atualiza o melhor pessoal

Atualiza o melhor global:

fim

$Custo(it)$ recebe o melhor custo global da iteração atual

fim

Retorna **Custo**

Retorna **Sol** do melhor global

fim

$$\mathbf{X}_k^{it+1} = \begin{cases} \mathbf{T}_k^{it}, & \text{se } F_{cost}(\mathbf{T}_k^{it}) < F_{cost}(\mathbf{X}_k^{it}) \\ \mathbf{X}_k^{it}, & \text{caso contrário} \end{cases}, \quad (9)$$

em que \mathbf{X}_k e \mathbf{V}_k são, respectivamente, a posição e o vetor de mutação da k -ésima partícula, os índices $r_1, r_2, r_3 \in \{1, 2, \dots, N_{ps}\}$ são inteiros gerados aleatoriamente, it é o índice correspondente a it -ésima geração, e $F_{ds} \in [0, 2]$ é o fator de escala, onde \mathbf{T}_k^{it} é o vetor de teste da k -ésima partícula na it -ésima geração, o índice $j_r \in \{1, 2, \dots, N_{de}\}$ é um inteiro gerado aleatoriamente, CR é a constante de *crossover* relacionada com a probabilidade de recombinação e j é o índice de cada parâmetro num vetor.

A operação de *crossover* é descrita por (8), utilizada para realizar a combinação entre as partículas da população real e do vetor de mutação, sendo que a cada iteração ao menos um elemento do vetor mutante entrará no vetor de teste.

Por fim, a escolha das partículas para a próxima geração é dada por (9). O Algoritmo 2 apresenta os passos do método DEO.

Algoritmo 2 DEO, adaptado de Reddy (2007); Leon (2014)

Entrada: Número de iterações (n), tamanho da população (N_{de}), dimensão da solução (dim), *crossover* (CR), fator de escala (F_{de}), Limites inferiores e superiores (LB e UB) e função objetivo (F_{cost})

Saída: Custo por iteração ($Custo$) e solução (Sol)

início

```

Inicia os vetores e parâmetros
Gera a população inicial
Avalia o custo de cada indivíduo
enquanto ( $it \leq n$ ) faça
  para ( $i$  de 1 até  $N_{de}$ ) faça
    Gera três números inteiros aleatórios,  $r_1, r_2, r_3 \in (1, N_{de})$ , com  $r_1 \neq r_2 \neq r_3 \neq i$ 
    Gera um número inteiro  $j_r \in (1, dim)$ 
    para cada parâmetro  $j$  faça
      se ( $rand(0, 1) < CR$  ou  $j = j_r$ ) então
        Gera um vetor de teste ao indivíduo  $j$  da geração atual (crossover)
      senão
        Mantém o vetor teste com os parâmetros da geração anterior
      fim
    fim
  fim
  Corrige o vetor teste entre LB e UB
  Avalia o custo do vetor de testes

  Atualiza a população da próxima geração com as melhores soluções

   $Custo(it)$  recebe o melhor custo global
   $Sol$  recebe a melhor solução
fim
 $it = it + 1$ 
fim
Retorna  $Custo$ 
Retorna  $Sol$ 

```

fim

4. RESULTADOS

Nesta seção, as estratégias de otimização para obtenção dos parâmetros elétricos do MIT são validadas. O MIT utilizado foi o W22 IR3 Premium 0.33 cv 2P 63 3F 220/380 V 60 Hz IC411 - TFVE - B3D da WEG. De forma a avaliar os métodos propostos, os ensaios clássicos descritos na Seção 2 também foram realizados, sendo apresentados a seguir.

4.1 Ensaios experimentais

As medidas realizadas no ensaio à vazio e em rotor bloqueado são exibidos na Tabela 3. Os valores de corrente $I_{\phi,cc}$ e tensão $V_{\phi,cc}$, bem como a reta gerada por interpolação linear dos pontos, podem ser vistas na Figura 2, o que permite calcular o valor de R_{cc} . Por fim, utilizando as medições em (1), (2), (3) e (4), os demais parâmetros

do MIT podem ser calculados. Os resultados obtidos são exibidos na Tabela 4.

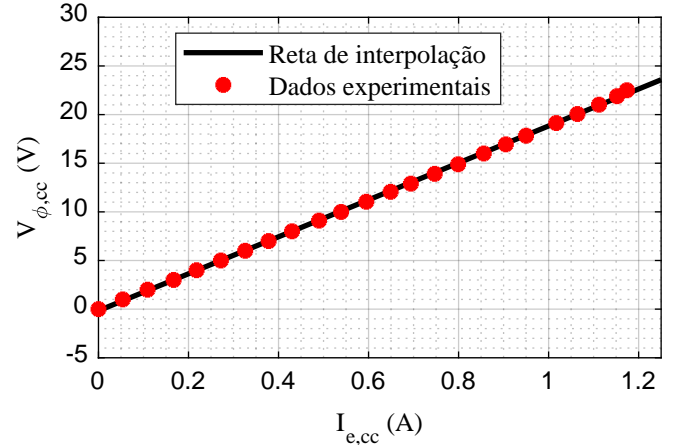


Figura 2. Curva tensão \times corrente obtida via ensaio CC.

Tabela 3. Medições dos ensaios experimentais.

Grandeza	Ensaio	
	Vazio	Rotor bloqueado
$P_{3\phi}$ (W)	65	50
V_{ϕ} (V)	220,3	37,30
I_e (A)	0,769	1,177

Tabela 4. Parâmetros obtidos via ensaios experimentais.

Parâmetro	Valor experimental (Ω)
R_e	28,494
R_r	7,619
X_e	20,679
X_r	20,679
X_m	265,672
R_c	3368,940

4.2 Resultados via otimizações

Os parâmetros utilizados para aplicação do algoritmo dos métodos de otimização PSO e DEO são exibidos na Tabela 5 e 6, respectivamente. Os parâmetros iniciais para os métodos de otimização empregados neste estudo são definidos na forma vetorial como $p = [R_e^0 \ R_r^0 \ X_r^0 \ R_c^0 \ X_m^0]$, sendo iguais aos valores obtidos dos ensaios experimentais na Tabela 4.

Considera-se a relação entre X_r e X_e em (4) e que R_r , R_e , X_r e X_m têm um intervalo de variação de 0,1 à 10 vezes seus respectivos valores iniciais, faixa escolhida de forma arbitrária com base nos resultados prévios dos ensaios clássicos. O parâmetro R_c tem um intervalo de variação de 0,5 à 1000 vezes seu valor inicial, também definido de forma arbitrária. Trata-se de uma faixa maior pois esse parâmetro normalmente possui maior ordem de grandeza que os demais. Assim, os limites inferior e superior são definidos vetorialmente como:

$$\begin{cases} LB = 0,1 [R_e^0 \ R_r^0 \ X_r^0 \ 5R_c^0 \ X_m^0] \\ UB = 10 [R_e^0 \ R_r^0 \ X_r^0 \ 100R_c^0 \ X_m^0] \end{cases} \quad (10)$$

Tabela 5. Parâmetros do algoritmo PSO.

Parâmetro	Descrição	Valor
m	Número de partículas	50
n	Número de iterações	500
ω	Peso de inércia	0,7298
C_1	Grau social	2
C_2	Grau cognitivo	2
dim	Dimensão da solução	5
N_{ps}	Tamanho da população	50

Tabela 6. Parâmetros do algoritmo DEO.

Parâmetro	Descrição	Valor
CR	<i>Crossover</i>	0,7
F_{de}	Fator de escala	2
n	Número de iterações	500
dim	Dimensão da solução	5
N_{de}	Tamanho da população	60

O comportamento do menor valor de F_{cost} de cada iteração gerado através da otimização PSO e DEO pode ser visto na Figura 3. Para ambos os métodos aqui tratados, F_{cost} converge para aproximadamente 0,3428. O método PSO convergiu para este valor em 110 iterações, enquanto o método DEO convergiu em 90 iterações.

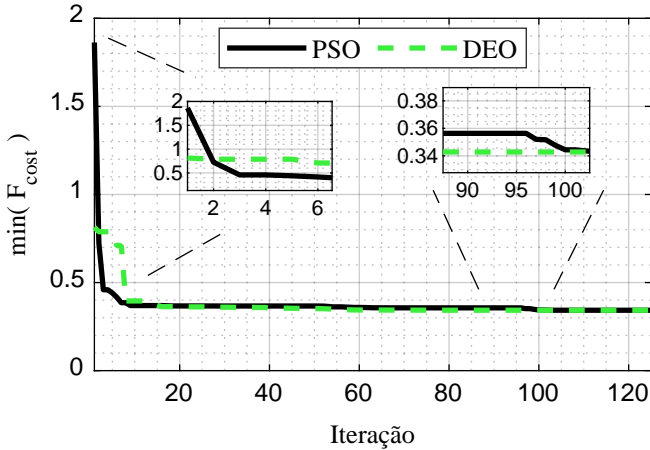


Figura 3. Menor valor da função custo para 125 iterações do método PSO e DEO.

Os parâmetros do circuito equivalente obtidos pelo método de otimização PSO e DEO estão na Tabela 7. É possível perceber que ambos os métodos obtiveram o mesmo valor para todos os parâmetros. Todavia, o método DEO apresentou a vantagem de convergir com uma menor quantidade de iterações que o método PSO.

Tabela 7. Parâmetros do circuito equivalente do motor obtidos via métodos de otimização.

Parâmetro	Valor obtido via otimização (Ω)	
	PSO	DEO
R_e	32,642	32,642
R_r	17,745	17,745
X_e	11,183	11,183
X_r	11,183	11,183
X_m	294,671	294,671
R_c	$4,285 \times 10^3$	$4,285 \times 10^3$

As curvas de torque, rendimento e fator de potência obtidas com os parâmetros dos ensaios experimentais, com

os parâmetros obtidos via PSO e DEO e as curvas do *datasheet* são exibidos na Figura 4.




Figura 4. Curvas do MIT obtidas via ensaios experimentais e otimizações.

Para comparação matemática, o erro médio percentual (e_v) de uma variável v para as curvas obtidas via ensaios experimentais e otimizações em relação à curva obtida via *datasheet* foram calculados por:

$$e_v(\%) = \frac{100}{N_a} \sum_{k=1}^{N_a} \left| \frac{v_{dt}[k] - v[k]}{v_{dt}[k]} \right|, \quad (11)$$

sendo v_{dt} o valor fornecido pelo *datasheet*, v o valor da variável obtido pelo ensaio e otimizações e N_a o número de amostras utilizadas no cálculo, variando conforme os dados fornecidos em *datasheet*. Os valores de erros são exibidos na Tabela 8, onde τ denota torque, η denota rendimento e FP denota fator de potência.

Tabela 8. Erro médio percentual das curvas de desempenho do MIT para os parâmetros obtidos via ensaio e por otimização PSO e DEO.

Erro (%)	Ensaio	PSO	DEO
e_τ	40,544	18,794	18,794
e_η	14,819	3,715	3,715
e_{FP}	24,645	14,254	14,254

5. CONCLUSÕES

Este trabalho apresentou uma estratégia de obtenção de parâmetros elétricos de MITs via otimização através das curvas fornecidas pelos fabricantes e estimativas iniciais obtidas via ensaios clássicos. Os métodos PSO e DEO foram utilizados, apresentando o mesmo resultado final para os parâmetros. Todavia, a convergência via DEO foi cerca de 1,22 vezes superior à do PSO em relação ao número de iterações.

Em relação à obtenção dos parâmetros por meio dos ensaios experimentais clássicos, os métodos baseados em otimização apresentaram erros médios percentuais cerca de 2 vezes inferior para as curvas de torque e fator de potência, e cerca de 4 vezes inferior para a curva de rendimento, evidenciando uma melhoria na estimação dos parâmetros pelas técnicas de otimização empregadas.

Dessa maneira, considerando situações nas quais é desejado reduzir o erro na estimação de parâmetros inerentes aos ensaios convencionais, este trabalho oferece uma alternativa de baixa complexidade. Além disso, em situações nas quais a realização dos ensaios experimentais não é possível, a metodologia proposta é aplicável, bastando ter um estimativa dos parâmetros para a condição inicial de forma a reduzir o número de iterações do método. Os próximos passos incluem a utilização dos parâmetros elétricos do MIT obtidos para aplicação em HIL em uma bancada de emulação veicular.

AGRADECIMENTOS

Reconhecimentos aos suportes financeiros: Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) processo nº 2022/00628-9, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) processo nº 88887.703189/2022-00 e Fundação de Desenvolvimento da Pesquisa-Fundep Rota 2030/Linha V 27192/27.

REFERÊNCIAS

- ABNT, N. (2018). 17094-1 máquinas elétricas girantes parte 1 motores de indução trifásicos-requisitos. *Rio de Janeiro*.
- Bonnett, A.H. e Soukup, G. (1999). Nema motor-generator standards for three-phase induction motors. *IEEE Industry Applications Magazine*, 5(3), 49–63. doi:10.1109/2943.758901.
- Chakraborty, S., Saha, A.K., Ezugwu, A.E., Agushaka, J.O., Zitar, R.A., and Abualigah, L. (2023). Differential evolution and its applications in image processing problems: A comprehensive review. *Archives of Computational Methods in Engineering*, 30(2), 985–1040.
- Chapman, S.J. (2013). *Fundamentos de máquinas elétricas*. AMGH editora, 5ª edição.
- Grassi, S., Huang, H., Pareschi, L., and Qiu, J. (2023). Mean-field particle swarm optimization. In *Modeling and Simulation for Collective Dynamics*, 127–193. World Scientific.
- Huang, H., Qiu, J., and Riedl, K. (2023). On the global convergence of particle swarm optimization methods. *Applied Mathematics & Optimization*, 88(2), 30.
- Leon, Miguel e Xiong, N. (2014). Investigation of mutation strategies in differential evolution for solving global optimization problems. In *Artificial Intelligence and Soft Computing: 13th International Conference, ICAISC 2014, Zakopane, Poland, June 1-5, 2014, Proceedings, Part I 13*, 372–383. Springer.
- Liu, D., He, H., Yang, Q., Wang, Y., Jeon, S.W., and Zhang, J. (2023). Function value ranking aware differential evolution for global numerical optimization. *Swarm and Evolutionary Computation*, 78, 101282.
- Nammalvar, Pachaivannan e Ramkumar, S. (2018). Parameter improved particle swarm optimization based direct-current vector control strategy for solar pv system. *Advances in Electrical e Computer Engineering*, 18(1), 105–112.
- Pant, M., Zaheer, H., Garcia-Hernandez, L., Abraham, A., et al. (2020). Differential evolution: A review of more than two decades of research. *Engineering Applications of Artificial Intelligence*, 90, 103479.
- Reddy, M Janga e Kumar, D.N. (2007). Multiobjective differential evolution with application to reservoir system optimization. *Journal of computing in civil engineering*, 21(2), 136–146.
- Sakthivel, V., Bhuvaneshwari, R., and Subramanian, S. (2010). Multi-objective parameter estimation of induction motor using particle swarm optimization. *Engineering Applications of Artificial Intelligence*, 23(3), 302–312.
- Sengamalai, U., Anbazhagan, G., Thamizh Thentral, T., Vishnuram, P., Khurshaid, T., and Kamel, S. (2022). Three phase induction motor drive: a systematic review on dynamic modeling, parameter estimation, and control schemes. *Energies*, 15(21), 8260.
- Vukašinović, J., Milovanović, M., Arsić, N., Radosavljević, J., Štatković, S., Perović, B., and Jovanović, A. (2022). Parameter estimation of induction motors using wild horse optimizer. In *9th International Conference on Electrical, Electronic and Computing Engineering*. Novi Pazar, Servia.