

Estimação *Online* dos Parâmetros do Circuito Equivalente do Motor de Indução Trifásico via Metaheurísticas

João M. R. Baccharini*. Francisco C. R. Coelho*.
Lane M. Rabelo*. Gleison F. V. Amaral*

*Departamento de Engenharia Elétrica, Universidade Federal de São João del-Rei
36307-352, Praça Frei Orlando, 170, São João del-Rei, MG, Brasil
(jaomarcos.rb@hotmail.com; franciscocoelho@ufsj.edu.br; rabelo@ufsj.edu.br; amaral@ufsj.edu.br)

Abstract: The three-phase induction motor model is a widespread tool, employed in several electrical engineering projects. Its equivalent circuit parameters can be obtained by classical no-load and blocked-rotor tests. However, this is not always possible in an industrial environment. Thus, online estimation techniques can be used as alternatives. In this work, Particle Swarm Optimization (PSO), Genetic Algorithm (GA) and Evolution Strategy (ES) are applied to the three-phase induction machine parameter estimation, based on calculated values from estimated circuit and measured values. In order to evaluate the methodology, a 2HP, four pole machine is tested. The obtained results show that this problem has multiple optimal solutions, with different sets of circuit parameters. This makes the optimization task really difficult from the optimization algorithms perspective. By means of statistical analysis, it can be said that PSO outperforms the GA and ES regarding the precision of the results and computational effort, whether this last feature is essential for online applications.

Resumo: A representação do Motor de Indução Trifásico (MIT) por meio de um modelo matemático é uma ferramenta muito utilizada em projetos e implementações de engenharia elétrica. A obtenção dos parâmetros do circuito equivalente por meio de testes definidos nas normas nem sempre é viável em uma planta industrial. Assim, técnicas de estimação *online* destes parâmetros podem ser empregadas como alternativa. Neste trabalho, as metaheurísticas Enxame de Partículas (PSO), Algoritmo Genético e Estratégias de Evolução são empregadas para estimação dos parâmetros do MIT com base na comparação de valores calculados a partir do circuito estimado, com valores medidos. A metodologia é aplicada a um MIT de 2HP e quatro polos. Os resultados obtidos demonstram que o problema formulado possui múltiplas soluções ótimas, com diferentes conjuntos de parâmetros, dificultando a tarefa dos algoritmos de otimização. Por meio de análises estatísticas, constata-se a superioridade do PSO na resolução do problema aqui formulado, em termos de precisão e tempo computacional, sendo esta última característica essencial para algoritmos com atuação em tempo real (*online*).

Keywords: Three-phase Induction Motor; Online Parameter Estimation; Particle Swarm Optimization; Genetic Algorithm; Evolution Strategy.

Palavras-chaves: Motor de Indução Trifásico; Estimação de Parâmetros *Online*; Enxame de Partículas; Algoritmo Genético; Estratégias de Evolução.

1. INTRODUÇÃO

No setor industrial, existe uma preferência de escolha pelo Motor de Indução Trifásico (MIT) para o acionamento de cargas, não apenas no Brasil, mas no mundo todo. Esta popularidade se deve principalmente à sua robustez, boa eficiência e custo de manutenção reduzido. Além disso, com o advento das tecnologias dos dispositivos de estado sólido, ampliou-se sua utilização em aplicações que necessitam de ajuste fino no controle de velocidade e de conjugado (Chapman, 2013).

A representação do MIT por meio de um modelo matemático, normalmente denominado de circuito equivalente, é uma maneira de se compreender, analisar e prever sua operação. Esta representação matemática consiste em um conjunto de

parâmetros elétricos que são úteis para estimar, por exemplo, o rendimento, o fator de potência e o torque, para diversas condições de operação, especialmente quando os testes reais com carga não podem ser executados.

Existem ensaios para a determinação dos parâmetros do circuito equivalente MIT, como padronizado pela norma americana IEEE Std 112 (IEEE – Institute of Electrical and Electronics Engineers, 2017) e a norma Nacional (ABNT - Associação Brasileira de Normas Técnicas, 2018). Geralmente, esses métodos requerem tempo e recursos humanos significativos, além de duas montagens diferentes em relação ao eixo do motor: (i) teste sem carga; e (ii) teste de rotor travado. Portanto, esses métodos nem sempre são possíveis ou práticos de serem aplicados no chão de fábrica (Al-Badri, Pillay and Angers, 2017).

Em algumas aplicações que necessitam de controle fino do torque, velocidade ou posição, os parâmetros devem ser conhecidos com alta precisão. A incompatibilidade entre valores reais e estimados leva a erros de rastreamento de trajetória (Lee *et al.*, 2017). Inúmeros métodos foram desenvolvidos para estimar parâmetros *offline* e *online*, visando aplicações de acionamentos de alto desempenho. Em (Toliat, Levi and Raina, 2003), os autores revisam os principais métodos propostos até a data da publicação do trabalho, apresentando seus recursos fundamentais de aplicação. Alguns desses algoritmos já foram implementados em conversores de frequência comerciais. No entanto, pesquisadores continuam estudando o tema de forma a propor novos métodos para reduzir o erro de estimação e melhorar a resposta nos ajustes das malhas de controle (Helonde and Mankar, 2019), (Rajput, Bender and Averbukh, 2020), (Al-Badri, Pillay and Angers, 2017), (Wengerkievicz *et al.*, 2017), (Kenné *et al.*, 2009).

Em algumas propostas, a utilização de ferramentas metaheurísticas têm mostrado resultados cada vez melhores (Bhowmick, Manna and Chowdhury, 2018). O grande apelo para utilização destas técnicas inteligentes é a possibilidade de resolução de problemas multimodais, com inúmeros máximos e mínimos locais.

Os Algoritmos Genéticos (AG) são técnicas de busca baseadas nos mecanismos genéticos e de evolução. Seu princípio básico é a manutenção de um conjunto de soluções (população) para um problema na forma de informações individuais codificadas que se desenvolvem no tempo. A evolução é baseada em leis de seleção natural e recombinação de informação genética dentro da população. O desenvolvimento da população testa o espaço de busca e acumula conhecimentos sobre áreas de boa ou má qualidade, recombina este conhecimento para formar soluções com bom desempenho para problemas específicos (Oliveira, 2004).

O fato de não ocorrer recombinação de informações é a principal diferença entre a Estratégia de Evolução (EE) e o Algoritmo Genético. Desta forma, trata-se de um algoritmo mais simples devido a redução do número de parâmetros de ajuste.

O método de Enxame de Partículas (PSO) foi criado por Kennedy e Eberhart em 1995, inspirada na inteligência coletiva dos animais (Kennedy and Eberhart, 1995). Assim como AG, trata-se de uma técnica populacional, que pode ser incluída no conjunto de algoritmos evolutivos.

Neste trabalho, dentre as muitas técnicas metaheurísticas existentes, as três consideradas como clássicas, foram as escolhidas para serem testadas diante do problema de otimização na estimação de parâmetros do MIT: Estratégias de Evolução (EE), Algoritmo Genético (AG) e Enxame de Partículas (PSO). Pretende-se avaliar as três em termos da precisão e exatidão dos resultados, além do tempo de execução.

2. METODOLOGIA

A metodologia adotada neste projeto pode ser dividida em três partes principais: (i) A formulação matemática do problema de otimização; (ii) As ferramentas de otimização que serão aplicadas ao problema: EE, AG e PSO. (iii) estimação de parâmetros. Os resultados serão comparados com os obtidos através de testes experimentais

2.1 Formulação Matemática

Na Figura 1 é mostrado o circuito equivalente, por fase, normalmente utilizado para a representação do MIT em regime permanente, considerando a fonte de alimentação equilibrada. Os subíndices 1 são de grandezas do estator e os subíndices 2 são grandezas do rotor referidas ao estator. As demais grandezas do ramo de magnetização são, corrente à vazio (I_0), resistência que representam as perdas no ferro do estator e do rotor (R_c) e a reatância de magnetização (X_m).

Em função das resistências (R_1, R_2, R_c) e reatâncias (X_1, X_2, X_m), é possível calcular a corrente de entrada, o rendimento e o fator de potência do motor. Isto para uma dada tensão de entrada V e valor de escorregamento s específico (ou velocidade, dado o número de pólos da máquina).

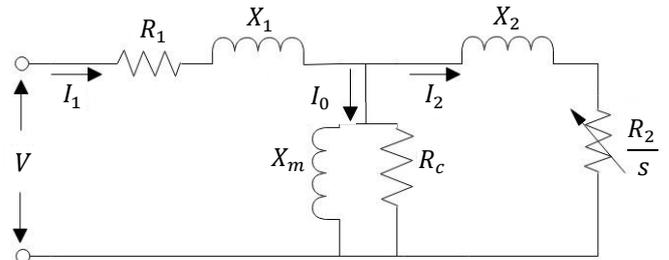


Fig 1. Circuito Equivalente do MIT, por fase, regime permanente (Arkan, Kostic-Perovic and Unsworth, 2005).

A função objetivo que se pretende minimizar foi descrita em (Bhowmick, Manna and Chowdhury, 2016), conforme Equação (1).

$$\text{Minimizar } F_{Obj} = \left\{ \left(\frac{I_1 - I_1^{est}}{I_1} \right)^2 + \left(\frac{\eta - \eta^{est}}{\eta} \right)^2 + \left(\frac{fp - fp^{est}}{fp} \right)^2 + \left(\frac{I_0 - I_0^{est}}{I_0} \right)^2 \right\} \quad (1)$$

sendo:

F_{Obj}	Função objetivo
I_1	Corrente medida no estator (A)
I_1^{est}	Corrente estimada no estator (A)
I_0	Corrente medida no estator, motor sem carga (A)
I_0^{est}	Corrente estimada no estator, motor sem carga (A)
η	Rendimento medido (%)
η^{est}	Rendimento estimado (%)
fp	Fator de potência medido
fp^{est}	Fator de potência estimado

Com exceção de I_0 , mantido constante na FOB durante as medições, todos os outros valores são medidos em tempo real, para estimação dos parâmetros do circuito equivalente. O que se espera é que o conjunto de parâmetros que minimize a função objetivo corresponda aos parâmetros obtidos via ensaios com a máquina. Isto para quaisquer valores de

corrente, eficiência e fator de potência, permitindo assim o monitoramento da máquina em tempo real através da execução dos algoritmos de otimização. Ressalta-se que a potência de saída, para cálculo do rendimento, é obtida das medições de torque e velocidade.

2.2 As Metaheurísticas

2.2.1 Algoritmo Genético

O algoritmo tem início com um conjunto de indivíduos (soluções) chamado de população. Alguns destes indivíduos são selecionados para formar uma nova população. Isto é motivado pelos métodos de seleção que fazem com que a nova população seja, em média, melhor que a primeira. Soluções para formar novas gerações podem ser obtidas de diversas maneiras, desde que, de alguma forma, carreguem consigo características de qualidade dos indivíduos. Este processo é repetido até que se atinja uma convergência, ou seja, que após um certo número de gerações, não ocorra mais mudança no melhor indivíduo ou que o número limite de gerações seja atingido.

No primeiro passo escolhe-se uma população inicial, normalmente formada por indivíduos criados aleatoriamente, ou através de uma inicialização inteligente. Avalia-se toda a população de indivíduos segundo algum critério, determinado por uma função que analisa a qualidade do indivíduo (função de aptidão ou *fitness*);

Em seguida, realizam-se alterações nas características dos indivíduos ao longo do tempo, definindo-se novas gerações. Uma nova geração é obtida aplicando-se sobre os indivíduos selecionados operações que misturem suas características (chamadas "genes"), através dos operadores de "cruzamento" (*crossover*) e "mutação". As figuras 2 e 3, retiradas de (Ikeda, 2009), apresentam um exemplo de aplicação de tais operadores. Ressalta-se que estas figuras demonstram estes operadores em codificação binária, correspondente à proposição original do AG. Nada impede que estes vetores sejam adaptados para problemas contínuos (como no caso deste trabalho), por meio de sua codificação real.

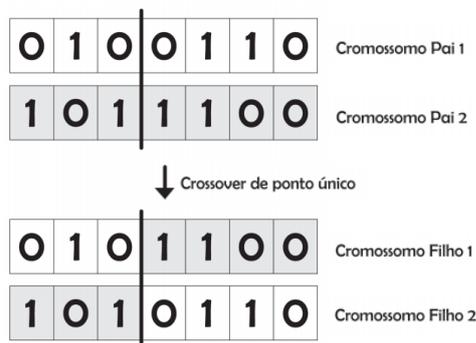


Figura 2. Operador Genético de Cruzamento.

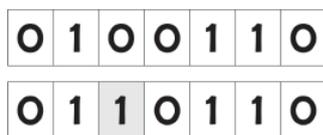


Figura 3. Operador Genético de Mutação

Os novos indivíduos são avaliados e, em seguida, através do operador de "seleção", escolhem-se os indivíduos que sobreviverão para a próxima geração, que corresponde a um novo conjunto de possíveis soluções para o problema. Esta seleção pode ser simplesmente uma escolha dos melhores indivíduos (com base na função objetivo), como também uma escolha tanto de indivíduos bons quanto ruins, visando uma variedade maior na população de forma que a função objetivo tenha uma menor chance de ficar presa em um mínimo local.

Estes passos são repetidos até que uma solução aceitável seja encontrada, até que o número predeterminado de iterações seja atingido ou até que o algoritmo não consiga mais melhorar a solução já encontrada (Pozo *et al.*, 2011).

2.2.2 Estratégia de Evolução

Assim como o Algoritmo Genético, a Estratégia de Evolução pertence ao grupo dos algoritmos chamados evolutivos. As EE's foram desenvolvidas inicialmente na Alemanha, na década de 1960, com o intuito de resolver problemas contínuos de otimização paramétrica, sendo estendidas, recentemente, para o tratamento de problemas discretos.

A estrutura do EE é similar à do AG, sendo que a diferença entre esses dois algoritmos é o *crossover*, que não está presente no EE.

Para iniciar o processo de busca via EE, deve-se definir uma população inicial. Este procedimento pode ser realizado aleatoriamente ou utilizando, por exemplo, técnicas inteligentes. A população inicial deve possuir indivíduos que estejam bem distribuídos pelo espaço de busca aumentando a probabilidade de encontrar o ótimo global.

Cada iteração (ou geração) passa por um processo de clonagem, que nada mais é do que a replicação dos indivíduos da população inicial. Estes clones passam, então, por um processo de mutação, que consiste na alteração de algumas de suas características, também chamadas de "genes" (Paula, 2017). Em seguida, estes indivíduos são avaliados seguindo a função objetivo e alguns dos indivíduos são selecionados conforme critério estabelecido pelo operador, podendo ser uma escolha aleatória ou buscando melhores valores. Por fim, verifica-se o número de máximo de iterações ou algum outro critério de parada. Caso contrário, o ciclo se reinicia.

2.2.3 Enxame de Partículas

A posição de uma partícula i em uma iteração k pode ser representada por x_k^i , enquanto sua velocidade é descrita por v_k^i . Os vetores de posição e velocidade desta partícula i são armazenados durante o processamento do algoritmo em uma iteração k e utilizados para a atualização da população na iteração $k + 1$.

Os vetores de velocidade e posição serão então utilizados para atualizar a população. Além desses dois valores é necessário também saber a melhor posição da partícula durante o processo, definida por p_k^i e a posição desta melhor partícula p_k^g de todo enxame até o momento.

A atualização da velocidade de cada partícula é calculada em (2).

$$v_{k+1}^i = wv_k^i + c_1 rnd_1 \frac{(p_k^i - x_k^i)}{\Delta t} + c_2 rnd_2 \frac{(p_k^g - x_k^i)}{\Delta t} \quad (2)$$

sendo:

w	Fator de Inércia
rnd	Variável aleatória independente
c_1	Fator cognitivo
c_2	Fator social
Δt	Espaço de Tempo

Os fatores cognitivo e social, determinam, respectivamente, a ênfase dada à melhor posição já ocupada pela partícula até então, e à melhor partícula da população.

A partir de (2) é possível então atualizar o posicionamento de cada partícula através de (3)

$$x_{k+1}^i = x_k^i + v_{k+1}^i \Delta t \quad (3)$$

O algoritmo do PSO básico, está descrito no passo a passo abaixo

1. Inicializar um conjunto de partículas na iteração $k = 0$ com velocidades e posições aleatoriamente distribuídas dentro do espaço de busca;
2. Avaliar a função objetivo de cada uma das partículas da população;
3. Atualizar a melhor posição de cada partícula individualmente e a melhor posição do bando;
4. Atualizar a posição de cada partícula no tempo $k + 1$ baseado na posição e velocidade no tempo k ;
5. Repetir os processos de 2 a 4 até que uma condição de parada seja satisfeita.

No caso de problemas de otimização restrita, como no caso do problema abordado neste trabalho, o conjunto inicial de partículas é gerado de forma aleatória e independentemente espalhado pelo espaço de busca conforme a (4) e (5) (Silva, 2014). As variáveis rnd_3 e rnd_4 têm distribuição de probabilidade uniforme e estão contidas no intervalo [0 1].

$$x_0^i = x_{min} + rnd_3(x_{max} - x_{min}) \quad (4)$$

$$v_0^i = x_{min} + rnd_4(x_{max} - x_{min}) \quad (5)$$

3. RESULTADOS

3.1 Dados de Ensaios

Para avaliação da metodologia de estimação proposta, utilizou-se um motor de indução de 2 HP e quatro polos. A Tabela 1 mostra os parâmetros desta máquina, obtidos via ensaios (IEEE – Std 112, 2017). Estes dados foram obtidos de (Bhowmick, Manna and Chowdhury, 2018). A reatância equivalente X_{eq} representa a soma das reatâncias de estator e de rotor ($X_1 + X_2$). A Tabela 2 mostra dados do motor extraídos de catálogo para o motor operando com 100% de carga. Tais valores são essenciais no cálculo da função objetivo. O rendimento, que é um dos dados de entrada na função objetivo, foi obtido da divisão da potência de saída pela potência de entrada.

Tabela 1. Parâmetros de ensaios do motor

$R_1(\Omega)$	$R_2(\Omega)$	$X_{eq}(\Omega)$	$R_c(\Omega)$	$X_m(\Omega)$
0,3	0,492	1,05	68,2	9,71

Tabela 2. Dados do motor

$I_1(A)$	$P_{in}(W)$	$P_{out}(W)$	fp	$I_0(A)$
12,4035	1915,382	1498,0002	0,81051	5,9048

Sendo:

I_1	Corrente do Estator
I_0	Corrente de Magnetização (ou a Vazio)
P_{in}	Potência de Entrada
P_{out}	Potência de Saída
fp	Fator de Potência

3.2 Parametrização das Metaheurísticas

As Tabelas 3, 4 e 5 mostram os valores utilizados nos parâmetros das três metaheurísticas em comparação. Estes parâmetros são definidos pelo usuário, a partir de testes em busca de se encontrar valores que irão produzir resultados de qualidade.

Tabela 3. Parâmetros da EE

n_{ind}	i_{max}	C_{mut}				
		R_1	R_2	X_{eq}	R_c	X_m
250	4000	0,75	0,75	0,75	40	3

Tabela 4. Parâmetros do AG

n_{ind}	i_{max}	C_{cruz}	C_{mut}				
			R_1	R_2	X_{eq}	R_c	X_m
250	4000	0,9	0,2	0,2	0,2	15	1

Tabela 5. Parâmetros do PSO

n_{ind}	i_{max}	c_1	c_2	w
250	4000	1	1	0,5

Sendo:

n_{ind}	Número de indivíduos por iteração
i_{max}	Número máximo de iterações
C_{cruz}	Coefficiente de Cruzamento
C_{mut}	Coefficiente de Mutação

A Tabela 6 (Bhowmick, Manna and Chowdhury, 2016) apresenta os limites para as variáveis de decisão, isto é as faixas de valores permitidos para os parâmetros do circuito equivalente. Estes limites são cruciais no desempenho das metaheurísticas já que estabelecem o espaço de busca no qual as mesmas devem trabalhar. Destaca-se que estes valores podem ser utilizados para máquinas de maior potência dado que há uma tendência de queda nos valores em p.u. conforme a potência nominal aumenta (Guimarães *et al.*, 2014).

Tabela 6. Parâmetros Gerais – Limites (em Ω)

Parâmetro	R_1	R_2	X_{eq}	R_c	X_m
Limite Inferior	0,01	0,01	0,01	1	0,01
Limite Superior	5	5	5	200	20

3.3 Simulações

Os Algoritmos metaheurísticos possuem uma série de vantagens em relação a técnicas clássicas, como a flexibilidade para lidar com restrições e descontinuidades de maneira relativamente simples, além da capacidade de se desprender de ótimos locais (Yang, 2014). No entanto, estas técnicas não garantem a solução ótima e há uma certa variabilidade em seus resultados devido aos mecanismos de busca possuir atributos parcialmente aleatórios. Desta forma, foram feitas 40 simulações para cada uma das metaheurísticas.

Todos os resultados foram obtidos utilizando o *software* MATLAB 2010a. Adicionalmente, é importante ressaltar que o computador utilizado para todas as simulações foi o mesmo, e que nenhum outro aplicativo estava aberto durante a execução das técnicas. Ao se replicar este trabalho em um outro computador pode-se esperar resultados diferentes no que se refere ao tempo médio de simulação.

Para a organização dos resultados, os mesmos estão dispostos em diagramas de caixas, comumente chamados de *box plots* (Montgomery; Runger, 2014). Os *box plots* mostram a dispersão dos dados: neste caso, os resultados provenientes das 40 simulações realizadas com cada metaheurística. A linha interna, que divide a caixa, corresponde à mediana destes dados. Os limites de cada caixa representam o primeiro e terceiro quartis, o que significa que metade dos resultados obtidos se encontram dentro da caixa. Além disso, as linhas retas que saem das caixas mostram os limites dentro dos quais se encontram todos os resultados. Os símbolos de “+” em vermelho que aparecem em algumas imagens representam os valores discrepantes, ou *outliers*, e são desconsiderados da análise estatística.

3.3.1 Valores das resistências R_1 , R_2 e R_c

As Figuras 4, 5 e 6 mostram o *box plot* para as três resistências, respectivamente, estator, rotor e do ramo de magnetização. O eixo “y” está representado em Ω , o eixo “x” é dedicado a separar cada um dos métodos analisados.

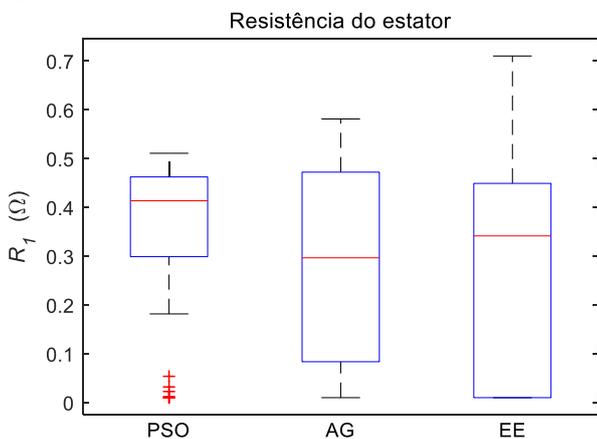


Figura 4 – Valores estimados pelas metaheurísticas: R_1 .

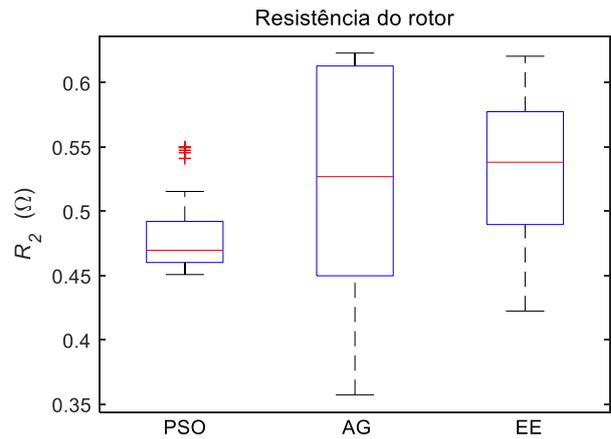


Figura 5 – Valores estimados pelas metaheurísticas: R_2

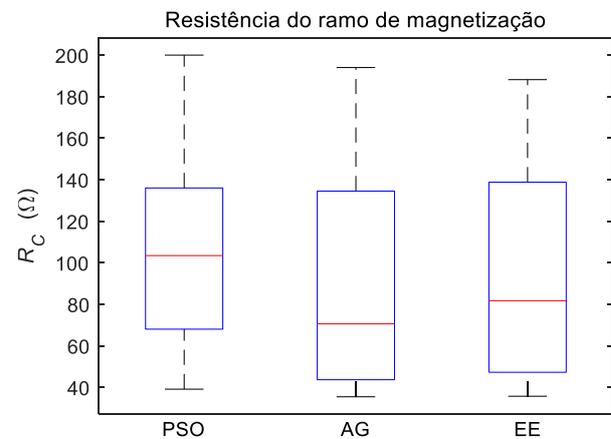


Figura 6 – Valores estimados pelas metaheurísticas: R_c

Os valores obtidos para R_1 e R_c estão dentro de um extenso espaço de possibilidades para as três técnicas, podendo apresentar altos desvios dos valores de ensaio a depender da simulação. Para a obtenção de R_2 , o PSO se destacou, com baixa dispersão relativa e mediana próxima ao valor de ensaio.

3.3.2 Valores de reatâncias X_{eq} e X_m

As Figuras 7 e 8 mostram os *boxplots* referentes às indutâncias equivalentes e de magnetização, respectivamente.

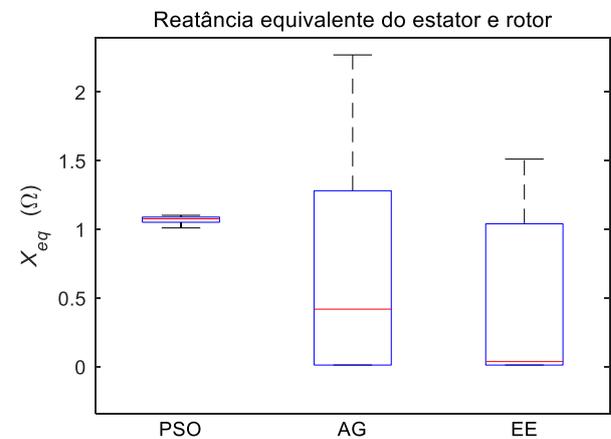


Figura 7 – Valores estimados pelas metaheurísticas: X_{eq}

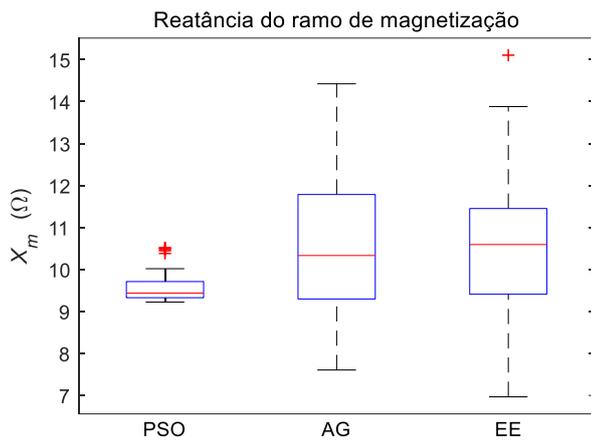


Figura 8 – Valores estimados pelas metaheurísticas: X_m

Na estimação das indutâncias o PSO é quem apresenta os melhores resultados. O tamanho da caixa em que se encontram os resultados é mais estreita e próxima do valor dos ensaios (Tabela 1). Nota-se que, no caso de X_{eq} AG e EE apresentam muitos resultados finais próximos ao limite inferior do espaço de busca.

3.3.3 Função Objetivo e Tempo de simulação

As Figuras 9 e 10 mostram os *boxplots* com os valores da FOB e tempo de simulação para as três técnicas em comparação. Nota-se que o PSO foi significativamente mais eficaz na minimização da FOB, cujo valor ideal é zero. Além do fato de que sua eficiência em termos do tempo computacional é considerável. Enquanto o AG passa dos 150 segundos para uma única estimação dos parâmetros, o PSO é capaz de realizar esta tarefa em torno de 10 segundos. O tempo que o algoritmo leva para ser executado é decisivo nos casos em que a tecnologia é “embarcada” em equipamentos industriais.

Neste ponto do trabalho, é importante chamar atenção para uma característica deste problema de estimação de parâmetros do circuito equivalente do MIT. Como se percebe na Figura 9, o PSO praticamente zera a FOB em todas as ocasiões. Ou seja, todos os 40 conjuntos de parâmetros obtidos pelo PSO produzem valores iguais aos medidos de: Corrente no estator; rendimento; fator de potência; e corrente no ramo de magnetização (Conforme se vê na Equação (1)). No entanto, os valores estimados para os parâmetros podem apresentar desvios expressivos em relação aos dados de ensaio, e também entre si, conforme se nota no caso de R_1 e R_C (Figuras 4 e 6). O significado destes resultados é o de que existem múltiplos pontos ótimos para este problema, o que dificulta consideravelmente a tarefa dos métodos de otimização, justificando os trabalhos de pesquisa que se propõe a resolvê-lo.

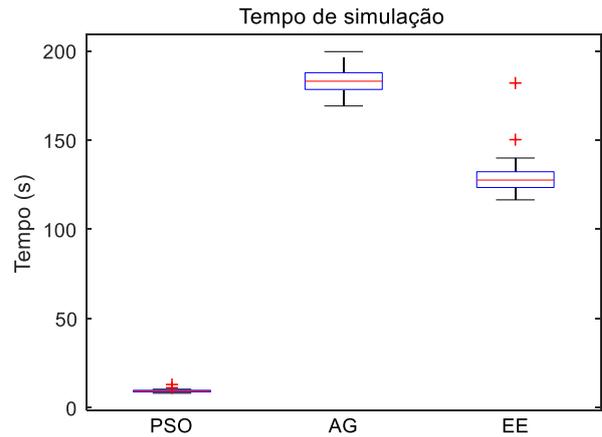


Figura 9 – Boxplot do Tempo de Simulação

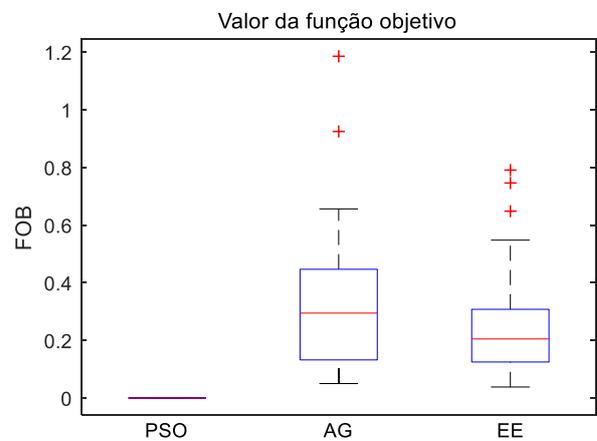


Figura 10 – Boxplot da Função Objetivo.

Em geral, o Algoritmo Genético e Estratégias de Evolução apresentaram resultados de baixa qualidade. O motivo para este desempenho, de acordo com (Sakthivel, Bhuvaneshwari and Subramanian, 2010) é que o algoritmo tem sua performance prejudicada quando o problema em questão tem parâmetros que são altamente correlacionados ou seja, dependem um do outro. A estimação de parâmetros é um desses casos e essa correlação prejudica a capacidade de busca do algoritmo.

3.3.4 Detalhamento dos resultados

Nesta seção, apresentam-se os melhores resultados obtidos por cada uma das metaheurísticas, assim como as curvas resultantes de fator de potência e torque. A Tabela 7 mostra os dados obtidos na melhor simulação (FOB mais baixa) de cada algoritmo.

Tabela 7. Melhor conjunto de parâmetros de cada metaheurística

	$R_1(\Omega)$	$R_2(\Omega)$	$X_{eq}(\Omega)$	$R_c(\Omega)$	$X_m(\Omega)$
PSO	0,2935	0,4933	1,0487	66,948	9,7264
AG	0,0100	0,5434	1,0461	40,396	10,030
EE	0,3753	0,4816	0,9916	92,928	9,0490

Como forma de avaliação dos melhores parâmetros obtidos, duas curvas foram produzidas com cada circuito equivalente estimado. Estas curvas estão em comparação com as curvas decorrentes dos parâmetros de ensaios nas Figuras 11 e 12. A primeira curva mostra a variação do fator de potência na entrada do motor para uma variação linear no escorregamento. Na Figura 12, apresenta-se o torque interno desenvolvido também em função do escorregamento.

Observa-se que o conjunto de parâmetros encontrados pelo PSO resulta em curvas mais adequadas, ou próximas das curvas obtidas com os parâmetros de ensaios. É possível a afirmação de que, nas simulações realizadas, o AG não produziu nenhum conjunto satisfatório de parâmetros, visto que mesmo seu resultado de menor FOB resulta em curvas tão discrepantes das desejadas. É importante destacar que não foi levado em conta o efeito pelicular, ou seja, os parâmetros do ramo de magnetização são considerados constantes para todos os valores de escorregamento.

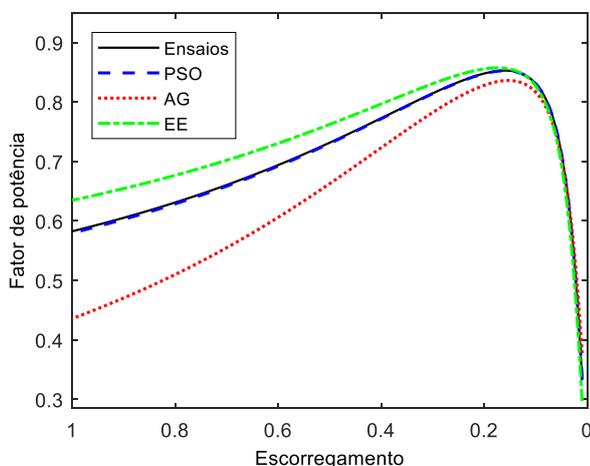


Figura 11 – Fator de Potência em função do escorregamento.

4. CONCLUSÃO

Neste trabalho, três técnicas de otimização metaheurísticas foram aplicadas ao problema de estimação de parâmetros do circuito equivalente de máquinas de indução trifásicas. A função objetivo é definida como o erro quadrático entre medições e cálculos de algumas grandezas do motor, em operação. Partindo da definição prévia de faixas de valores admissíveis para os parâmetros, seus valores são buscados pelos algoritmos de otimização.

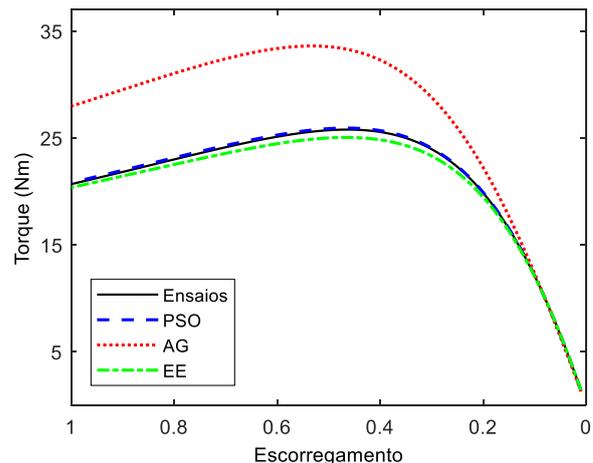


Figura 12 – Torque em função do escorregamento.

Praticamente em todos os resultados produzidos, a metaheurística PSO se mostrou superior às outras duas técnicas implementadas, Algoritmo Genético e Estratégias de Evolução. Inclusive, o PSO apresentou tempo de simulação significativamente menor, o que é um fator determinante para escolha de algoritmos de estimação “embarcados” em conversores de frequência para estimação *online*.

Outro fator que chama a atenção neste problema é a multiplicidade de soluções que atingem o objetivo de minimizar a FOB, sem no entanto corresponder à valores adequados para os parâmetros estimados. Este fato, por si só, já justifica a investigação do problema, tanto no que diz respeito à sua formulação matemática quanto às técnicas de otimização empregadas.

AGRADECIMENTOS

Os autores prestam agradecimentos pelo apoio financeiro recebido da CAPES/CNPq/INERGE/FAPEMIG.

REFERÊNCIAS

- ABNT - Associação Brasileira de Normas Técnicas (2018) ‘Máquinas elétricas girantes Parte 3: Testes em Motores de Indução Trifásicos’, ABNT NBR 17094-3.
- Al-Badri, M., Pillay, P. and Angers, P. (2017) ‘A Novel In Situ Efficiency Estimation Algorithm for Three-Phase Induction Motors Operating With Distorted Unbalanced Voltages’, IEEE Transactions on Industry Applications, 53(6), pp. 5338–5347. doi: 10.1109/TIA.2017.2728786.
- Arkan, M., Kostic-Perovic, D. and Unsworth, P. J. (2005) ‘Modelling and simulation of induction motors with interturn faults for diagnostics’, Electric Power Systems Research, 75(1), pp. 57–66. doi: 10.1016/j.epsr.2004.08.015.
- Bhowmick, D., Manna, M. and Chowdhury, S. K. (2016) ‘Online estimation and analysis of equivalent circuit parameters of three phase induction motor using particle swarm optimization’, in 2016 IEEE 7th Power India International Conference (PIICON). IEEE, pp. 1–5. doi: 10.1109/POWERI.2016.8077256.

- Bhowmick, D., Manna, M. and Chowdhury, S. K. (2018) 'Estimation of Equivalent Circuit Parameters of Transformer and Induction Motor from Load Data', *IEEE Transactions on Industry Applications*, 54(3), pp. 2784–2791. doi: 10.1109/TIA.2018.2790378.
- Chapman, Stephen, J. (2013) *Fundamentos de Máquinas Elétricas. 5ª Edição*. Edited by McGrawHill - Bookman. Porto Alegre: McGrawHill - Bookman.
- Douglas C. Montgomery; George C. Runger (2014) *Applied Statistics and Probability for Engineers. Sixth Edit.* Danvers, MA: John Wiley & Sons, Inc.
- Guimaraes, J. M. C. et al. (2014) 'Parameter Determination of Asynchronous Machines From Manufacturer Data Sheet', *IEEE Transactions on Energy Conversion*, 29(3), pp. 689–697. doi: 10.1109/TEC.2014.2317525.
- Helonde, A. R. and Mankar, M. M. (2019) 'Identifying Three Phase Induction Motor Equivalent Circuit Parameters from Nameplate Data by Different Analytical Methods', *International Journal of Trend in Scientific Research and Development, Volume-3(Issue-3)*, pp. 642–645. doi: 10.31142/ijtsrd22934.
- IEEE – Institute of Electrical and Electronics Engineers (2017) *Standard Test Procedure for Polyphase Induction Motors and Generators (ANSI), IEEE Std 112-2017*, IEEE standards. doi: 10.1029/2010GB003772.
- Ikeda, P. A. (2009) 'Introdução aos Algoritmos Genéticos'.
- Kenné, G. et al. (2009) 'An improved rotor resistance estimator for induction motors', *IFAC Proceedings Volumes (IFAC-PapersOnline)*, 15(PART 1), pp. 308–313. doi: 10.3182/20090706-3-FR-2004.0172.
- Kennedy, J. and Eberhart, R. (1995) 'Particle swarm optimization', in *Proceedings of ICNN'95 - International Conference on Neural Networks*. IEEE, pp. 1942–1948. doi: 10.1109/ICNN.1995.488968.
- Lee, S. H. et al. (2017) 'Identification of Induction Motor Parameters at Standstill Based on Integral Calculation', *IEEE Transactions on Industry Applications*, 53(3), pp. 2130–2139. doi: 10.1109/TIA.2017.2650141.
- Oliveira, S. A. de (2004) 'Metaheurísticas aplicadas ao planejamento da expansão da transmissão de energia elétrica em ambientes de processamento distribuído', *Universidade Estadual de Campinas*, p. 290.
- Paula, A. N. de (2017) 'Planejamento dinâmico da transmissão considerando o custo da confiabilidade', *Universidade Federal de São João del-Rei*, p. 75.
- Pozo, A. et al. (2011) 'Computação Evolutiva', *Departamento de Informática, UFP*, p. 61.
- Rajput, S., Bender, E. and Averbukh, M. (2020) 'Simplified algorithm for assessment equivalent circuit parameters of induction motors', *IET Electric Power Applications*, 14(3), pp. 426–432. doi: 10.1049/iet-epa.2019.0822.
- Sakthivel, V. P., Bhuvaneshwari, R. and Subramanian, S. (2010) 'Multi-objective parameter estimation of induction motor using particle swarm optimization', *Engineering Applications of Artificial Intelligence*. Elsevier, 23(3), pp. 302–312. doi: 10.1016/j.engappai.2009.06.004.
- Silva, A. F. (2014) 'Algoritmo de Otimização com Enxame de Partículas Auxiliado Por Metamodelos', pp. 28–30.
- Toliyat, H. A., Levi, E. and Raina, M. (2003) 'A review of RFO induction motor parameter estimation techniques', *IEEE Transactions on Energy Conversion*. IEEE, 18(2), pp. 271–283. doi: 10.1109/TEC.2003.811719.
- Wengerkiewicz, C. A. C. et al. (2017) 'Estimation of Three-Phase Induction Motor Equivalent Circuit Parameters from Manufacturer Catalog Data', *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, 16(1), pp. 90–107. doi: 10.1590/2179-10742017v16i1873.
- Yang, X.-S. (2014) 'Introduction to Algorithms', in *Nature-Inspired Optimization Algorithms*. Elsevier, pp. 1–21. doi: 10.1016/b978-0-12-416743-8.00001-4.