

## Algoritmo de evolução diferencial embarcado para a identificação de falhas em máquinas elétricas.

### Embedded differential evolution algorithm for fault identification in electrical machines.

#### RESUMO

**Victor Takeo Ferreira Takase**  
[takase@alunos.utfpr.edu.br](mailto:takase@alunos.utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

**Alessandro Goedel**  
[agoedel@utfpr.edu.br](mailto:agoedel@utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

**Erick Araújo Nunes**  
[ericknunes@alunos.utfpr.edu.br](mailto:ericknunes@alunos.utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

O motor de indução trifásico é a principal forma de conversão de energia elétrica em energia mecânica e, mesmo possuindo características construtivas robustas, pode apresentar falhas severas, causando paradas não programadas. Este trabalho apresenta o estudo do algoritmo de evolução diferencial, aplicado em um ambiente embarcado, para estimar os parâmetros do circuito elétrico equivalente do motor de indução trifásico, utilizados para diagnosticar falhas em máquinas elétricas. Os dados de entrada do sistema são a tensão da fase A, a corrente da fase A e a velocidade do motor. Estes são submetidos ao algoritmo, resultando nos valores estimados dos parâmetros do motor. Assim, permitindo a realização de análises *online* das falhas, auxiliando no agendamento de manutenções e reduzindo os gastos com paradas não programadas no processo de produção industrial.

**PALAVRAS-CHAVE:** Localização de falhas. Algoritmos genéticos. Sistemas embarcados. Processamento de sinais. Motores elétricos de indução.

**Recebido:** 19 ago. 2019.

**Aprovado:** 01 out. 2019.

**Direito autorial:** Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



#### ABSTRACT

The three-phase induction motor is the main way to convert electrical energy to mechanical energy and, even with its robust construction characteristics, it could have severe failures, causing unscheduled shutdowns. This paper presents the study of the differential evolution algorithm, applied in an embedded environment, to estimate the parameters of the equivalent electric circuit of the three-phase induction motor, used to diagnose faults in electric machines. The system input data is the voltage of phase A, current of phase A, and motor speed. These data are informed to the algorithm, resulting in the estimated values of the motor parameters. Thus, allowing online analysis of failures, assisting in the scheduling of preventive maintenance and reducing expenses with shutdowns in the industrial production process.

**KEYWORDS:** Location of system faults. Genetic algorithms. Embedded systems. Signal processing. Induction motors.

## INTRODUÇÃO

Os Motores de Indução Trifásicos (MITs) são máquinas elétricas rotativas, cuja principal função é transformar a energia elétrica em energia mecânica. O tipo gaiola de esquilo representa mais de 90% das máquinas elétricas rotativas, devido ao seu baixo custo, robustez e baixo custo de manutenção se comparado aos demais tipos (MICOLTA et al., 2016).

Apesar de possuir características construtivas robustas, os MITs não estão isentos de falhas severas, que podem resultar em paradas não programadas e grandes perdas econômicas. Para reduzir estes custos, diversas pesquisas estão sendo realizadas nas últimas décadas para possibilitar a rápida identificação de anomalias (KANG; KIM, 2014).

As falhas nos MITs podem ser classificadas em dois grupos: falhas mecânicas e falhas elétricas. As falhas mecânicas estão relacionadas a problemas de excentricidade, desalinhamento, rolamento e desgaste de acoplamento. As falhas elétricas são decorrentes de curto-circuito nas espiras do estator, barras de rotor quebradas ou anéis quebrados. Segundo Khireddine et al. (2014) as proporções de ocorrência destas falhas são 40% de rolamento, 38% de enrolamento de estator, 10% de problemas relacionados ao rotor e 12% para demais falhas.

Há uma grande variedade de técnicas sendo desenvolvidas para diagnosticar falhas em máquinas elétricas, estas são baseadas principalmente nas medidas de corrente, tensão, potência, fluxo, vibração e velocidade, e se destacam por detectarem falhas provenientes de defeitos elétricos e defeitos mecânicos (PEZZANI et al., 2013).

No trabalho de Guedes et al. (2018) são empregados dados de corrente, tensão e velocidade para diagnóstico de falhas de curto-circuito nos enrolamentos do estator. A técnica apresentada toma como base a estimativa dos parâmetros do circuito equivalente do motor de indução trifásico utilizando o algoritmo de evolução diferencial, do inglês *Differential Evolution* (DE). A identificação das falhas foi realizada através de observações da variação do parâmetro de magnetização em relação a uma referência num espectro de falhas.

Assim, a proposta deste trabalho consiste em utilizar a técnica apresentada por Guedes et al. (2018) para estimar os parâmetros do MIT, e implementar estes algoritmos em um hardware que fará o processo de aquisição e tratamento dos dados.

## MATERIAIS E MÉTODOS

O *hardware* utilizado no desenvolvimento deste trabalho é o processador digital de sinais, do inglês *Digital Signal Processor* (DSP), LAUNCHXL-F28379D, devido ao grande poder de processamento necessário para implementar o algoritmo.

O DE é um algoritmo baseado na teoria da evolução e na genética, e tem como base uma população composta de possíveis soluções, que sofrem modificações genéticas a cada iteração para melhorar o grau de aptidão dos indivíduos em relação a uma função objetivo.

O DE tem início com uma população inicial de cromossomos, composta de genes, onde cada gene é um parâmetro do circuito equivalente do motor de indução trifásico. Estes valores iniciais são aleatórios dentro de um espaço de busca, definido empiricamente por Guedes et al. (2018). Os espaços de busca estão descritos na Tabela 1 abaixo:

Tabela 1 – Espaço de busca dos genes

Parâmetro	Espaço de Busca
$R_1$ ( $\Omega$ )	[2 20]
$R_2$ ( $\Omega$ )	[2 20]
$L_1$ (H)	[0.001 0.5]
$L_2$ (H)	[0.001 0.5]
$L_M$ (H)	[0.01 5]

Fonte: Guedes et al. (2018).

Estes intervalos são os valores que cada gene pode assumir durante as iterações do algoritmo, para restringir estes parâmetros a valores reais.

A cada iteração é calculado o grau de aptidão, é realizada a mutação e o cruzamento de toda a população, o que dá origem a uma nova população, descendente da primeira. Para realizar o cálculo da aptidão, também chamado de *fitness*, é realizada a reconstrução do sinal de corrente, utilizando a impedância equivalente calculada com os parâmetros estimados e o sinal de tensão adquirido utilizando a Primeira Lei de Ohm, descrito na Equação 1 abaixo:

$$I = \frac{V}{Z} \quad (1)$$

Com o sinal de corrente estimado e o sinal de corrente adquirido, é calculado o *fitness* através de uma Função Objetivo. Foi escolhido como FO o erro quadrático médio, dada pela Equação 2 abaixo:

$$FO = \frac{1}{2} \sum_i^{n_{\text{pontos}}} \frac{(I_{\text{aquisitado},i} - I_{\text{estimado},i})^2}{n_{\text{pontos}}} \quad (2)$$

Onde:  $n_{\text{pontos}}$  é o número de pontos de amostragem de cada sinal;  $I_{\text{aquisitado},i}$  é o ponto de amostragem do sinal de corrente adquirido;  $I_{\text{estimado},i}$  é o ponto de amostragem do sinal de corrente estimado.

No processo de mutação são utilizados um indivíduo que sofrerá a mutação, chamado de *target vector*, e outros dois indivíduos escolhidos aleatoriamente. A mutação é a exposição do *target vector* às características genéticas dos outros indivíduos, que ocorre, matematicamente, pela adição de uma diferença multiplicada por um fator de ponderação ao *target vector*, conforme a Equação 3 abaixo:

$$X_{m,i} = X_i + F \cdot (X_y - X_z) \quad (3)$$

Onde:  $X_{m,i}$  é o elemento  $i$  da população mutada;  $X_i$  é o *target vector*;  $F$  é o fator de ponderação;  $X_y$  e  $X_z$  são os cromossomos escolhidos aleatoriamente para influenciar a mutação do *target vector*.

O fator de ponderação tem valores típicos entre 0 e 1, que influenciará diretamente na intensidade da perturbação que a mutação causará, o valor adotado neste estudo foi de 0,1. Todos os indivíduos da população original devem

ser submetidos ao processo de mutação para, em seguida, dar início ao processo de cruzamento.

O cruzamento ocorre entre o indivíduo mutado e o *target vector* que participou do processo de mutação do mesmo, e gera uma população cruzada que contém características dos dois indivíduos. A seleção do gene dominante é realizada de forma aleatório, comparando um valor aleatório de 0 a 1 a um fator de cruzamento com um valor pré-fixado no intervalo, o valor adotado neste trabalho foi de 0,5. Quanto menor a taxa de cruzamento, maior a chance de características da população original persistir, e quanto maior a taxa de cruzamento, maior a chance de um gene mutado persistir.

Portanto, se o valor aleatório for menor que a taxa de cruzamento, o gene será herdado do *target vector*, caso contrário o gene herdado será o do cromossomo mutado.

Ao finalizar o processo de cruzamento, é realizado um novo cálculo de fitness para esta nova população criada a partir do cruzamento. Os processos de mutação e cruzamento não garantem que os novos indivíduos terão uma melhor aptidão, portanto, são comparadas as aptidões dos cromossomos de cada população, e prevalece a melhor solução. Estes processos de cálculo de fitness, mutação, cruzamento e seleção ocorrem em ciclo até que um critério de parada seja atingido. Neste trabalho os critérios de parada adotados foram 0.1% de erro ou 65535 gerações.

O DE foi implementado na linguagem C, que tem grande compatibilidade com o *hardware* escolhido, e permite realizar testes com mais agilidade. É importante destacar que estes testes foram realizados a partir de uma base de dados fornecido pelo Laboratório de Sistemas Inteligentes (LSI) da UTFPR Campus Cornélio Procópio.

Após validar o funcionamento do algoritmo, realizou-se a portabilidade do código para o kit DSP, utilizando a mesma base de dados, a fim de comparar os resultados dos algoritmos.

## RESULTADOS E DISCUSSÕES

Os resultados obtidos dos parâmetros estimados através do algoritmo desenvolvido em C, em 3 execuções diferentes, estão apresentados na Tabela 2 abaixo:


Tabela 2 – Parâmetros estimados pelo DE em C.

$R_1$	$L_1$	$R_2$	$L_2$	$L_M$
12.6716	0.0285	4.4164	0.0103	0.4199
12.3375	0.0211	4.6761	0.0100	0.4209
13.7130	0.0191	4.7356	0.0107	0.4173

Fonte: Autoria própria (2019).

A partir desses resultados, utilizou-se os resultados dos testes para construir um gráfico comparando o sinal de referência e os sinais estimados. O resultado está apresentado na Figura 1 abaixo:

Figura 1 – Gráfico dos resultados do DE implementado em C



Fonte: Autoria própria (2019).

Os resultados obtidos dos parâmetros estimados através do algoritmo embarcado no kit DSP, em 5 execuções diferentes, estão apresentados na Tabela 3 abaixo:


Tabela 3 – Parâmetros estimados pelo DE embarcado.

$R_1$	$L_1$	$R_2$	$L_2$	$L_M$
11.8139	0.0254	4.5592	0.0120	0.4141
13.7073	0.0277	4.5688	0.0144	0.4115
13.0635	0.0149	4.7036	0.0144	0.4268

Fonte: Autoria própria (2019).

A partir desses resultados, utilizou-se os resultados dos testes para construir um gráfico comparando o sinal de referência e os sinais estimados. O resultado está apresentado na Figura 2 abaixo:

Figura 2 – Gráfico dos resultados do DE embarcado



Fonte: Autoria própria (2019).

Ao comparar os resultados dos parâmetros estimados e os gráficos, é verificado que os parâmetros e os gráficos obtidos em C e embarcado apresentaram resultados semelhantes. Estes resultados provam a viabilidade da

implementação do DE em um ambiente embarcado, que poderá ser utilizado no diagnóstico de falhas em máquinas elétricas.

## CONCLUSÃO

Este trabalho de iniciação científica apresenta a implementação de um DE em um kit DSP como estimador de parâmetros de MITs. Foi possível estimar parâmetros semelhantes nos dois métodos utilizados, atingindo o objetivo desta pesquisa. Com os resultados obtidos será possível dar sequência à pesquisa, implementando o sistema de aquisição de sinais e um algoritmo capaz de classificar os parâmetros em falhas de MIT, uma vez que a base para este sistema já foi estudada e construída.

## AGRADECIMENTOS

Este trabalho conta com o apoio da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processo N°06/56093-3), do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (Processo N°474290/2008-5, 473576/2011-2, 552269/2011-5) e Bolsa de Iniciação Científica do CNPq.

## REFERÊNCIAS

GUEDES, J. J.; CASTOLDI, M. F.; GOEDEL, A.; AGULHARI, C. M.; SANCHES, D. S. Differential evolution applied to line-connected induction motors stator fault identification. **Soft Computing**, 2018. DOI: 10.1007/s00500-018-3674-z.

KANG, M.; KIM, J. M. Reliable fault diagnosis of multiple induction motor defects using a 2-D representation of shannon wavelets. **IEEE Transactions on Magnetics**, v. 50, n. 10, 2014.

KHIREDDINE, M. S.; SLIMANE, N.; ABDESSEMED, Y.; MAKHLOUFI, M. T. Fault detection and diagnosis in induction motor using artificial intelligence technique. In: MATEC. **Web of Conferences** 16, 2014.

MICOLTA, J.E.; OSLINGER, J.L.; FRANCO, E. Aportes al diagnóstico en línea de fallas de cortocircuito entre espiras de un motor de inducción mediante parámetros eléctricos de secuencia inversa. **DYNA** 83 (198), p. 213-218, 2016.

PEZZANI, C.; BOSSIO, C.; ANGELO, C. de. Winding distribution effects on induction motor rotor faults diagnosis. **Mechatronics**, v. 24, p. 1050-1058, Elsevier, 2014.