Algoritmos Genéticos para a Estimação de Parâmetros em Motores de Indução Trifásicos

Luís Gustavo dos Santos Paludo*, Emerson Giovani Carati*, César Claure Torrico*.

* *Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Campus Pato Branco, UTFPR, PR, (e-mails: lgspaludo@alunos.utfpr.edu.br, emerson@utfpr.edu.br, cesartorrico@utfpr.edu.br).*

Abstract: This article investigates the parameterization of three-phase induction motors, focusing on the accurate estimation of parameters - including stator and rotor resistance, mutual and leakage inductances - for developing robust control systems. The approach adopted for parameter estimation is the application of genetic algorithms. This approach allows us to go beyond the limitations of traditional experimental techniques in restricted scenarios. Varied selection, crossover, and mutation strategies are examined to increase parameterization accuracy. Such analyzes offer an important mechanism for optimizing three-phase induction motor drive systems. The results confirm the efficacy of the approach, with a maximum error of 4.39% in the estimation of motor parameters, especially in the absence of machine data, where conventional methods are insufficient.

Resumo: Este artigo investiga a parametrização de motores de indução trifásicos, com foco na estimativa precisa de parâmetros - incluindo resistência estatórica e do rotor, indutâncias mútuas e de dispersão - para desenvolvimento de sistemas de controle robustos. A abordagem adotada para estimativa de parâmetros é a aplicação de algoritmos genéticos. Esta abordagem permite ir além das limitações das técnicas experimentais tradicionais em cenários restritos. Estratégias variadas de seleção, cruzamento e mutação são examinadas para aumentar a exatidão da parametrização. Tais análises oferecem um mecanismo importante para a otimização de sistemas de acionamento de motores de indução trifásicos. Os resultados confirmam a eficácia da abordagem, com um erro máximo de 4.39% na estimação dos parâmetros do motor, especialmente na falta de dados da máquina, onde os métodos convencionais são insuficientes.

Keywords: Induction Motor; Optimazation; Genetic Algorithms; Estimation.
Palavras-chaves: Motor de Indução; Otimização; Algoritmos Genéticos; Estimação.

1. INTRODUÇÃO

Desde a fase de concepção até a implementação de sistemas de controle em motores de indução trifásicos, geralmente o conhecimento ou estimação com exatidão dos parâmetros da máquina é muito importante. É possível afirmar que o alicerce para um projeto de controle de alto desempenho reside na acurada estimação de parâmetros essenciais tais como a resistência estatórica, resistência rotórica, além das indutâncias envolvidas (Houili et al., 2023).

Conforme documentado na literatura especializada (Chapman, 2005), o método mais tradicional para a estimação destes parâmetros é por meio de dois procedimentos experimentais específicos: o ensaio a vazio e o ensaio de rotor bloqueado. No ensaio a vazio, opera-se a máquina na sua tensão nominal sem qualquer carga aplicada ao eixo, realizando-se medições de potência, corrente e tensão. Durante o ensaio de rotor bloqueado, o rotor é mecanicamente travado, e a tensão é gradualmente elevada até a obtenção da corrente nominal, seguindo-se com as medições equivalentes. Essa metodologia é reconhecidamente precisa, contudo, a natureza específica de cada teste pode apresentar desafios na sua execução sob determinadas condições. Em cenários onde a realização de um ensaio de rotor bloqueado se mostra inviável ou a desativação temporária da máquina em funcionamento não é possível, empregar técnicas de otimização, notadamente algoritmos genéticos, surge como uma alternativa viável para estimação dos parâmetros.

Entre os algoritmos genéticos, uma diversidade de técnicas se destaca por sua adaptabilidade a contextos distintos, com resultados de elevada qualidade. Métodos de seleção como Torneio, Roleta, Estocástica, juntamente com técnicas de *crossover* (1P, 2P, Uniforme e BLX-α) e estratégias de mutação (gaussiana, *creep*, uniforme), formam o núcleo desta abordagem. O propósito deste estudo concentra-se em investigar a eficácia de diferentes combinações dessas técnicas ao longo das fases de um algoritmo genético. O foco é aprimorar a exatidão na parametrização de motores de indução trifásicos, um passo essencial para alcançar controles de máquina mais eficientes e precisos.

⋆ Os autores agradecem o suporte financeiro da CAPES - Bolsa DS, também como ANEEL, Fundação Araucária, FINEP e UTFPR pela infraestrutura de pesquisa.

2. MODELO DO MOTOR DE INDUÇÃO TRIFÁSICO

A Figura 1 ilustra o circuito equivalente por fase de um motor de indução trifásico (MIT), conforme proposto por Bose (2002). Este circuito destaca os principais parâmetros do modelo matemático. A partir deste modelo é possível se obter o modelo matemático dinâmico do MIT, representado pelas equações (1)-(7) (Bose (2002)). O modelo

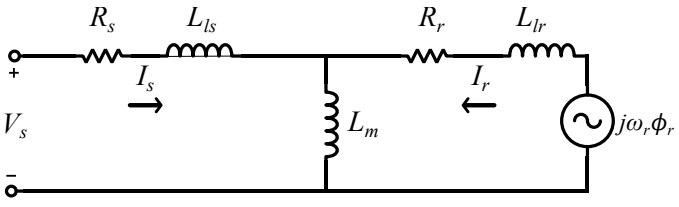

Figura 1. Circuito equivalente do motor de indução trifásico no sistema de referência estacionário.

dinâmico do MIT considerado é dado em função dos fluxos (Φ), tensões (v) e correntes (i) para os eixos d e q, tanto para o estator quanto para o rotor:

$$\frac{d\Phi_{qs}}{dt} = v_{qs} - \omega_e\Phi_{ds} - \frac{R_s}{L_{ls}}(\Phi_{qs} - \Phi_{qm}) \quad (1)$$

$$\frac{d\Phi_{ds}}{dt} = v_{ds} + \omega_e\Phi_{qs} - \frac{R_s}{L_{ls}}(\Phi_{ds} - \Phi_{qm}) \quad (2)$$

$$\frac{d\Phi_{qr}}{dt} = (\omega_r - \omega_e)\Phi_{dr} - \frac{R_r}{L_{lr}}(\Phi_{qr} - \Phi_{qm}) \quad (3)$$

$$\frac{d\Phi_{dr}}{dt} = (\omega_e - \omega_r)\Phi_{qr} - \frac{R_r}{L_{lr}}(\Phi_{dr} - \Phi_{dm}) \quad (4)$$

$$T_e = \frac{3P}{4}\left[\Phi_{ds}i_{qs} - \Phi_{qs}i_{ds}\right] \quad (5)$$

- fluxos: Φ_{qs}, Φ_{ds}, Φ_{qr}, e Φ_{dr} referem-se aos fluxos no estator e rotor, respectivamente, nas direções q e d.
- tensões e correntes: v_{qs}, v_{ds}, i_{qs}, e i_{ds} representam tensões e correntes no estator.
- velocidades: ω_e, e ω_r são as frequências de rotação do eixo de referência e a de rotação do motor, respectivamente;
- resistências: R_s e R_r são resistências do estator e rotor.
- indutâncias: L_{ls}, L_{lr}, e L_m representam indutâncias de dispersão do estator, do rotor, e de magnetização.

As variáveis Φ_{qm} e Φ_{dm} são fluxos de magnetização; T_e é o torque eletromagnético; P é o número de polos do motor. Os fluxos de magnetização são dados por:

$$\Phi_{qm} = \frac{L_{ml}}{L_{ls}}\Phi_{qs} + \frac{L_{ml}}{L_{lr}}\Phi_{qr} \quad (6)$$

$$\Phi_{dm} = \frac{L_{ml}}{L_{ls}}\Phi_{ds} + \frac{L_{ml}}{L_{lr}}\Phi_{dr} \quad (7)$$

A indutância equivalente L_{ml} é expressa por:

$$L_{ml} = \left(\frac{1}{L_m} + \frac{1}{L_{ls}} + \frac{1}{L_{lr}}\right)^{-1} \quad (8)$$

O modelo mecânico, considerando atrito (K) e inércia (J) e considerando o torque de carga (T_L), pode se expresso por:

$$\frac{d\omega_r}{dt} = \frac{1}{J}(T_e - T_L - K\omega_r) \quad (9)$$

3. ALGORITMOS GENÉTICOS

O algoritmo genético (GA) destaca-se no campo dos algoritmos evolutivos Goldberg (2013), buscando replicar o mecanismo de seleção natural. Este modelo opera através de uma coletividade de indivíduos, cada um representando uma alternativa de solução para uma problemática específica. Avaliados conforme sua eficácia, aqueles com desempenho superior são favorecidos para reprodução, originando prole que preserva suas qualidades. Por conseguinte, essa população atravessa um processo evolutivo, melhorando sua adaptação à resolução do problema em análise. Nesse paradigma, a possibilidade de reprodução se estende a todos os indivíduos, fomentando um vasto espaço de exploração que gradualmente se afunila em direção a uma solução adequada, à medida que a eficácia dos indivíduos aumenta com as sucessivas gerações. Define-se a população como um agrupamento de alternativas viáveis para a otimização do problema proposto. Inicializados com valores aleatórios dentro de um espectro definido, os indivíduos da geração corrente são substituídos por seus sucessores, que continuam a empreitada na solução do enigma.

Este trabalho se concentra na parametrização do motor de indução trifásico, com cada entidade composta por quatro cromossomos, representando os parâmetros fundamentais do motor de indução: as resistências estatóricas e rotóricas, e as indutâncias mútua e de dispersão. Dentro da estrutura de implementação de algoritmos genéticos, a eficiência desta metodologia está intrinsecamente atrelada às estratégias selecionadas para cada parte do processo evolutivo. Visando uma exploração abrangente, o estudo foi além a análise tradicional de funções de custo, investigando uma série de técnicas que podem ser aplicadas em cada etapa do GA, conforme mostra a Figura 2.

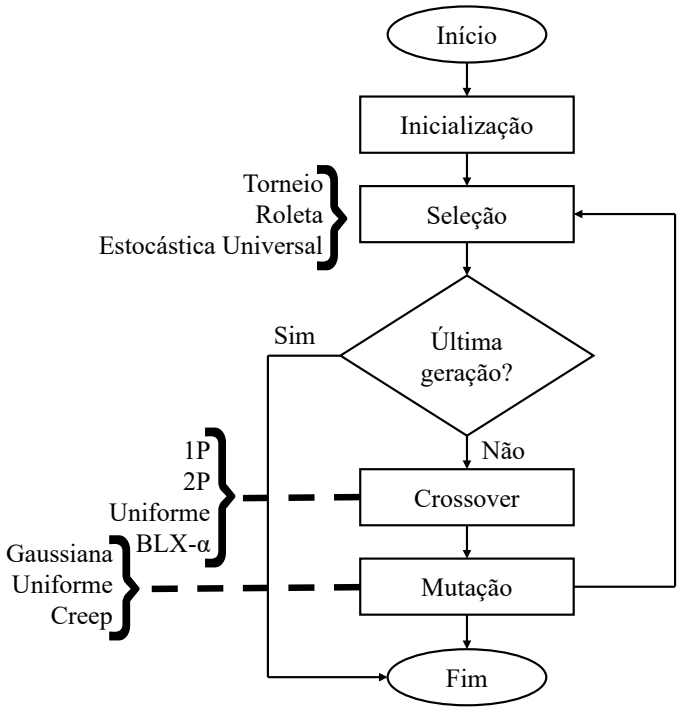

Figura 2. Fluxograma típico de um GA com etapas de Seleção, Crossover e Mutação.

3.1 Etapa de Seleção

O início do processo evolutivo em algoritmos genéticos é marcado pela seleção dos indivíduos destinados a gerar a próxima geração. Neste estudo, três técnicas de seleção foram meticulosamente examinadas. Duas delas, a seleção por roleta e por torneio (Simon, 2013), já são amplamente reconhecidas por sua eficácia. A terceira técnica, conhecida como estocástica universal (Baker, 1987), representa uma evolução refinada da seleção por roleta, prometendo otimização no processo de escolha dos indivíduos.

3.2 Etapa de Crossover

A etapa subsequente nos algoritmos genéticos é a combinação dos indivíduos selecionados, visando a criação de um novo elemento que fará parte da geração seguinte. Neste estágio, avaliou-se quatro métodos distintos: "um ponto"(1P) e também "dois pontos"(2P) (Mitchell, 1998), Uniforme (De Jong, 2006) e *BLX-*α (Herrera et al., 1998) para identificar qual exibe superior eficácia no enfrentamento do problema proposto.

3.3 Etapa de Mutação

A mutação constitui uma fase que ocorre de maneira esporádica, guiada por uma taxa de incidência estabelecida pelo usuário. Esta fase é essencial para assegurar a diversidade genética dos indivíduos, contribuindo para um espectro de busca mais abrangente. A mutação é aplicada ao indivíduo recém-gerado, isto é, subsequente à fase de *crossover*. Em contextos de problemas binários, a metodologia de mutação é frequentemente simplista, consistindo majoritariamente em inversões de bit. Entretanto, para problemas de natureza contínua, como o abordado neste estudo, adotam-se técnicas variadas. Neste trabalho, foram exploradas três técnicas específicas: gaussiana, uniforme (Eiben and Smith, 2007) e *creep* (Sivanandam and Deepa, 2007).

3.4 Função de Custo

Para avaliar a aptidão de cada membro da população, assim como os novos indivíduos gerados para a subsequente geração, é essencial a aplicação de uma função de custo. Dentro do escopo deste problema, opta-se pelo uso do modelo em espaço de estados do motor de indução (Equações 1 à 5), tal como descrito em Bose (2002). Este modelo é empregado para calcular as correntes estatóricas e rotóricas, considerando a tensão de alimentação como entrada e o torque eletromagnético como saída.

Na simulação do comportamento do motor, são consideradas duas situações distintas: a primeira simulação analisa o motor operando em vazio até alcançar a velocidade nominal; a segunda se concentra nas condições de regime permanente. No cenário inicial, o custo é calculado pela equação (10), onde as curvas de corrente de um acionamento real do motor (i_{qs} e i_{ds}) são confrontadas com os resultados da simulação ($\widehat{i}_{qs}$ e $\widehat{i}_{ds}$) sob condições de entrada idênticas, permitindo uma análise minuciosa que favorece uma exatidão elevada dos resultados, apesar de exigir maior tempo de simulação.

$$C = \int [(i_{qs}(t) - \widehat{i}_{qs}(t))^2 + (i_{qs}(t) - \widehat{i}_{ds}(t))^2]dt \qquad (10)$$

Ja cenário de regime permanente, o custo é calculado pela equação (11), onde os valores instantâneos de corrente (i_{qs}e i_{ds}) e a velocidade instantânea (ω_r), derivados de um teste real, são comparados com os resultados instantâneos simulados ($\widehat{i}_{qs}$, $\widehat{i}_{ds}$ e $\widehat{\omega}_r$). Esta técnica visa a eficiência, reduzindo o tempo de simulação às custas de uma exatidão marginalmente inferior.

$$C = (i_{qs} - \widehat{i}_{qs})^2 + (i_{qs} - \widehat{i}_{ds})^2 + (\omega_r - \widehat{\omega}_r)^2 \qquad (11)$$

4. IDENTIFICAÇÃO DOS PARÂMETROS COM GA

A implementação das técnicas foi feita considerando um motor de indução com as características dispostas na tabela 1:

Tabela 1. Parâmetros de placa do motor

Parâmetro	Valor	Unidade
Pólos	8	un
Potência	4	cv
Frequência Nominal	60	Hz
Tensão de Linha Nominal	220	V_{rms}
Corrente Nominal	12,7	A

Dois cenários computacionais, bem correlacionados com situações experimentais, foram considerados nesse estudo:

- **Cenário Ideal**: O motor está a vazio com controle escalar, variando de velocidade zero até a nominal, capturando i_{qs} e i_{ds} para maior exatidão dos dados.
- **Cenário Operacional**: O motor, já em regime permanente, tem medições instantâneas de corrente (i_{qs}, i_{ds}) e velocidade (ω_r) coletadas, priorizando baixo custo computacional em detrimento da exatidão.

Para cada cenário proposto, utilizou-se 36 estratégias diferentes, combinando as técnicas propostas com algoritmos genéticos. Para contornar a aleatoriedade inicial e promover comparações equilibradas, cada estratégia foi executada cinco vezes, adotando-se a mediana dos custos como base para comparação. Esse processo foi implementado duas vezes, em duas configurações diferentes do GA: a primeira com 100 indivíduos e 100 gerações, e a segunda com 200 indivíduos e 200 gerações.

4.1 Primeira Abordagem - Abundância de dados

A Tabela 2 consolida informações relativas à execução do algoritmo em um cenário ótimo, que permite o acionamento do motor e a coleta de curvas de corrente. Com uma população de 100 indivíduos durante 100 gerações, o tempo médio de execução foi de 35 segundos em um computador com Core i7-2.9GHz/RAM 16GB. É importante ressaltar que este tempo de execução pode variar conforme a configuração do sistema computacional onde o algoritmo é executado, sendo mencionado aqui apenas para possibilitar comparações relativas entre diferentes técnicas. Na mesma tabela, identifica-se a combinação ótima de técnicas para a configuração especificada, considerando diversas técnicas de seleção e *crossover*. Além disso, apresenta-se a mediana dos custos para cada configuração implementada. Observou-se que, para a seleção por Torneio, a melhor performance foi alcançada com o *crossover* Uniforme e mutação *creep*. Para as seleções Roleta e Estocástica Universal, a combinação de *crossover* $BLX-\alpha$ com mutação

Tabela 2. Comparação das abordagens utilizando (10) - (100 indivíduos, 100 gerações).

Seleção / Crossover	Torneio	Roleta	Estocástica	
1 Ponto	Creep 54,4	Creep 22,2	Creep 29,7	Mutação Custo
2 Pontos	Creep 35,1	Gauss 153,6	Gauss 26,5	Mutação Custo
Uniforme	Creep 8,6	Gauss 163,7	Uniform 153,8	Mutação Custo
BLX-α	Uniform 86,6	Creep 3,2	Creep 1,2	Mutação Custo

creep demonstrou ser a mais eficiente. Na Tabela 3, é apresentado um conjunto de resultados para uma configuração que envolve 200 indivíduos ao longo de 200 gerações. O algoritmo em questão teve um tempo de execução médio de 140 segundos. Notou-se uma melhoria significativa nos resultados, com a mediana do custo para todas as implementações permanecendo abaixo de 20. As técnicas ótimas para essa implementação foram consistentes com aquelas da implementação anterior, com a notável exceção da seleção por roleta combinada ao *crossover* $BLX - \alpha$. Para esta configuração, a mutação gaussiana demonstrou ser a mais eficaz.

Os custos indicados nas Tabelas 2 e 3 estão diretamente vinculados ao desempenho dos parâmetros configurados pelo algoritmo genético na simulação do comportamento do motor de indução trifásico, visando replicar as características observadas nos ensaios reais do motor. Quanto menor o custo, maior é a exatidão dos parâmetros simulados em relação aos valores reais. Para estabelecer um ponto de comparação, foram realizados ensaios a vazio e com rotor bloqueado no motor de indução, permitindo a estimação dos seus parâmetros por meio de técnicas bem estabelecidas teórica e praticamente. Essa abordagem possibilita a avaliação da exatidão dos resultados obtidos pelo algoritmo genético.

Tabela 3. Comparação das abordagens utilizando (10) - (200 indivíduos, 200 gerações).

Seleção / Crossover	Torneio	Roleta	Estocástica	
1 Ponto	Creep 14,2	Gauss 0,6	Creep 6,1	Mutação Custo
2 Pontos	Creep 13,4	Creep 6,2	Creep 0,2	Mutação Custo
Uniforme	Creep 2,0	Creep 3,9	Creep 2,6	Mutação Custo
BLX-α	Creep 2,2	Gauss 4,0e-4	Creep 4,6e-4	Mutação Custo

Na Tabela 4, é apresentado um resumo dos resultados alcançados com o uso de algoritmos genéticos, mostrando os valores médios dentro de faixas de custo específicas. Nota-se que os erros associados aos parâmetros estimados pelo algoritmo genético, especialmente na faixa de custo (0,1), são consideravelmente baixos, com o erro mais elevado sendo de $4,39\%$ na estimação da indutância de magnetização. As Figura 3 demonstra claramente a exatidão alcançada na estimação dos parâmetros para custos situados no intervalo (0,1). Nota-se que intervalos de custo superiores também exibem resultados promissores. Observam-se algumas variações na amplitude dos valores e nuances nos tempos de assentamento. Contudo, as características oscilatórias e os valores em regime permanente permanecem notavelmente consistentes, até mesmo para custos mais elevados, situados no intervalo (100,200). Esses achados corroboram a eficácia da técnica empregada na estimação dos parâmetros.

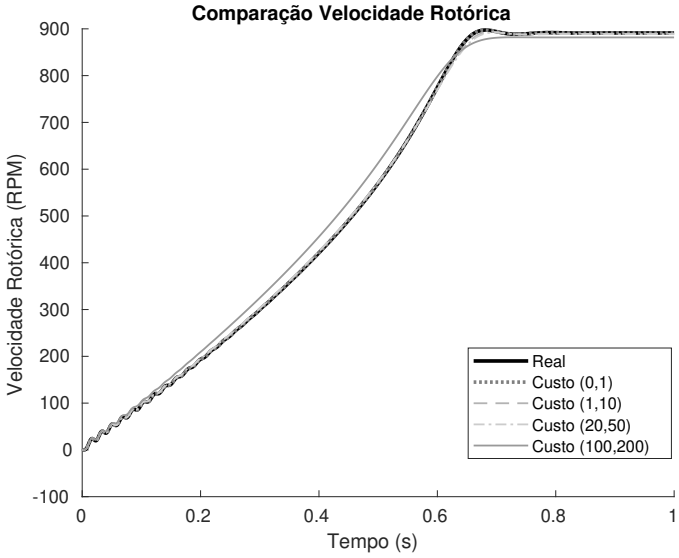

Figura 3. 1° Abordagem - Velocidade rotórica ω_r para diferentes intervalos de custo.

4.2 Segunda Abordagem - Escassez de dados

Apresentada na Tabela 5, a coleta de resultados foi realizada no cenário que utiliza uma quantidade de dados bastante limitada. Repetindo o procedimento inicial, cada conjunto de implementações foi executado cinco vezes, sendo a mediana dos resultados exibida na tabela. Na configuração inicial, o algoritmo genético foi ajustado para uma população de 100 indivíduos por 100 gerações de aprendizado, resultando em custos notavelmente baixos. Os resultados mais significativos vieram da aplicação da técnica de seleção por Roleta com *crossover* $BLX - \alpha$ e mutação uniforme, bem como da seleção Estocástica Universal com *crossover* $BLX - \alpha$ e mutação Gaussiana. Destaca-se também o tempo de processamento para esta configuração, que foi de 9 segundos, evidenciando a eficiência da utilização de menos dados, contrapondo-se aos 35 segundos necessários na abordagem anterior com idêntica configuração. Seguindo a metodologia aplicada no primeiro cenário, foram repetidas as simulações para uma configuração que inclui uma população de 200 indivíduos ao longo de 200 gerações de aprendizado. Conforme indicado na Tabela 6, observa-se uma redução significativa nos custos, com os melhores resultados alcançando a magnitude de $1e^{-10}$. Destacaram-se, em termos de desempenho, as técnicas que combinam a seleção estocástica universal com o *crossover* $BLX - \alpha$ e mutação gaussiana, bem como a seleção por roleta com *crossover* $BLX - \alpha$ e mutação *creep*, superando significativamente as demais implementações. É relevante mencionar também o tempo de execução, que foi de aproximadamente 36 segundos nesta configuração, apresentando uma similaridade com o tempo registrado na implementação inicial do primeiro cenário (população de 100 indivíduos em 100 gerações de aprendizado).

Tabela 4. Valor médio e erro médio dos parâmetros obtidos por intervalo de valor de custo.

Parâmetro	Estimação via ensaio a Vazio e Rotor Bloqueado	Valor médio por custo							
		(0,1)		(1,10)		(20,50)		(100,200)	
		Valor	Erro (%)	Valor	Erro (%)	Valor	Erro (%)	Valor	Erro (%)
$R_s(\Omega)$	0,6759	0,6751	0,12	0,6821	0,92	0,6359	5,92	0,5790	14,34
$R_r(\Omega)$	0,2615	0,2577	1,45	0,2807	7,34	0,3127	19,58	0,3884	48,53
$L_m(H)$	0,0387	0,0404	4,39	0,0331	14,47	0,0354	8,53	0,0196	49,35
$L_l(H)$	0,0028	0,0028	0,00	0,0029	3,57	0,0031	10,71	0,0033	17,86

Tabela 5. Comparação das abordagens utilizando (11) - (100 indivíduos, 100 gerações).

Seleção / **Crossover**	Torneio	Roleta	Estocástica	
1 Ponto	Creep	Creep	Gauss	Mutação
	6,4	20,1	44,2	Custo
2 Pontos	Gauss	Gauss	Creep	Mutação
	39	40,4	28,2	Custo
Uniforme	Creep	Creep	Creep	Mutação
	4,3	5,4	7,2	Custo
BLX-α	Creep	Uniforme	Gauss	Mutação
	2,2	1,8e-6	6,3e-7	Custo

Tabela 6. Comparação das abordagens utilizando (11) - (200 indivíduos, 200 gerações).

Seleção / **Crossover**	Torneio	Roleta	Estocástica	
1 Ponto	Creep	Creep	Creep	Mutação
	0,7	0,9	1,7	Custo
2 Pontos	Creep	Gauss	Creep	Mutação
	2,3	4,8	3,3	Custo
Uniforme	Creep	Uniform	Creep	Mutação
	1,5	11,3	4,5	Custo
BLX-α	Creep	Creep	Gauss	Mutação
	1,6	1,2e-10	1,2e-10	Custo

Os dados na Tabela 7 evidenciam os resultados da parametrização (mediante valores médios nos distintos intervalos de custo) em um cenário que considera três medições específicas: amplitudes de corrente i_{qs} e i_{ds} e a velocidade ω_r, todos em estado estacionário. Os parâmetros R_s, R_r e L_m alcançaram níveis de exatidão satisfatórios nos intervalos de custo estudados, com um pico de erro de $7,46\%$ na indutância de magnetização Lm no cenário de maior custo. O desafio enfrentado foi a estimativa imprecisa da indutância de dispersão $L_{ls} - L_{lr}$, que mostrou erros elevados, em alguns casos até 50%. Esse problema deriva da limitação do algoritmo genético, que não leva em conta o processo de acionamento da máquina, focando apenas em seu funcionamento em regime permanente. A indutância de dispersão, sendo uma constante de tempo no modelo matemático, tem sua relevância principalmente no início do acionamento, o que minimiza sua percepção em análises de regime permanente.

Na Figura 4, são apresentadas simulações conduzidas com parâmetros estimados por meio de uma abordagem que minimiza a quantidade de dados requerida no processo de estimação e aprendizagem do GA. Observa-se significativamente o impacto negativo decorrente da imprecisão na estimativa da indutância de dispersão, o que compromete de forma acentuada a dinâmica de acionamento do motor. Essa imprecisão resulta em uma redução no tempo de acionamento, causando variações nas amplitudes das correntes e nos tempos em que os picos ocorrem. No entanto, os valores alcançados em regime permanente mostram-se extremamente precisos em relação aos valores teóricos esperados.

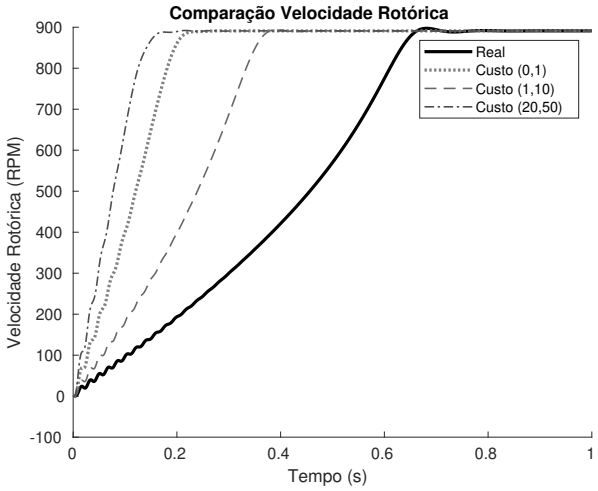

Figura 4. 2° Abordagem - Velocidade rotórica ω_r para diferentes intervalos de custo.

5. COMPARAÇÃO COM OUTROS TRABALHOS

Na Tabela 8, apresenta-se os melhores resultados obtidos com a abordagem proposta, em comparação com diversas metodologias empregadas por outros autores. O intuito desta comparação é destacar a eficácia e a acurácia das estimativas alcançadas tanto por métodos que se baseiam em grande volume de dados quanto por aqueles que operam com dados restritos. Observa-se que, independentemente da metodologia aplicada, os parâmetros como a indutância de dispersão (L_l) e a resistência rotórica (R_r) frequentemente sofrem distorções significativas. A primeira abordagem proposta demonstra uma exatidão excepcional em todos os parâmetros analisados, enquanto a segunda abordagem também mostra resultados precisos, exceto por um erro elevado na estimação da indutância de dispersão. Vale-se ressaltar que os modelos matemáticos utilizados para representar o MIT podem diferir entre os trabalhos comparados.

A literatura consultada, incluindo os trabalhos de Raptis and Kladas (2019), Huang et al. (1999), Zamboti Fortes et al. (2013) e Antonelli et al. (2023), oferece informações limitadas sobre as configurações das técnicas utilizadas, dificultando uma análise comparativa detalhada no mesmo contexto deste estudo. Assim, a análise se restringe à comparação dos erros observados nas melhores abordagens de cada trabalho. É importante destacar que os resultados de Antonelli et al. (2023) são exibidos graficamente para cada parâmetro, sem a descrição dos valores exatos de erro,

Tabela 7. Valor médio e erro médio dos parâmetros obtidos por intervalo de valor de custo.

Parâmetro	Estimação via ensaio a Vazio e Rotor Bloqueado	Valor médio por custo (0,1)		(1,50)		(50,100)	
		Valor	Erro (%)	Valor	Erro (%)	Valor	Erro (%)
$R_s(\Omega)$	0,6759	0,6846	1,29	0,6780	0,31	0,6465	4,35
$R_r(\Omega)$	0,2615	0,2770	5,93	0,2752	5,24	0,2810	7,46
$L_m(H)$	0,0387	0,0391	1,03	0,0391	1,03	0,0392	1,29
$L_l(H)$	0,0028	0,0017	39,29	0,0019	32,14	0,0014	50,00

Tabela 8. Comparação dos erros da metodologia proposta com outras abordagens.

Parâmetro	Erro médio por abordagem (%)					
	1° Abordagem	2° Abordagem	Raptis e Kladas	Huang et al.	Zamboti Fortes et al.	Antonelli et al.
$R_s(\Omega)$	0,12	1,29	1,06	0,018	0,81	∼5
$R_r(\Omega)$	1,45	5,93	11,89	11,76	0,74	>10
$L_m(H)$	4,39	**1,03**	7,16	6,18	0,49	∼4,5
$L_l(H)$	0,00	39,29	30,00	0,32	16,67	∼2

o que justifica a apresentação dos valores aproximados na Tabela 8.

6. CONCLUSÃO

Neste artigo, investigou-se a eficiência dos algoritmos genéticos na estimação de parâmetros em motores trifásicos sob dois cenários: um com um volume substancial de dados sobre o funcionamento do motor, e outro limitado ao conhecimento de valores em regime permanente. Observou-se que ambas as metodologias ofereceram bons resultados nas estimações. Contudo, a segunda estratégia revelou uma deficiência notável na estimação da indutância de dispersão, atribuída à falta de dados sobre as dinâmicas de funcionamento da máquina. Este trabalho também destaca a eficácia de variadas configurações de algoritmos genéticos, ressaltando combinações com potencial para o aperfeiçoamento da técnica. Atualmente, o objetivo é explorar métodos para superar as discrepâncias observadas ao utilizar dados em regime permanente, dada a já verificada eficácia dessa abordagem. Ademais, enfatiza-se a importância de refinar o algoritmo genético, ajustando parâmetros chave (população, gerações e taxa de mutação/*crossover*) e aprimorando técnicas de seleção, *crossover* e mutação.

AGRADECIMENTOS

Os autores agradecem aos financiadores, especialmente à CAPES - Bolsa DS, ANEEL, Araucária e à FINEP pelo suporte financeiro e fortalecimento da estrutura laboratorial da UTFPR.

REFERÊNCIAS

Antonelli, S.L., Donolo, P.D., Pezzani, C.M., Quispe, E.C., and De Angelo, C.H. (2023). Identification of induction motor parameters using genetic algorithms. In *2023 IEEE Workshop on Power Electronics and Power Quality Applications (PEPQA)*, 1–7. doi:10.1109/PEPQA59611.2023.10325774.

Baker, J.E. (1987). Reducing bias and inefficienry in the selection algorithm. In *International Conference on Genetic Algorithms*.

Bose, B. (2002). *Modern Power Electronics and AC Drives*. Eastern Economy Edition. Prentice Hall PTR.

Chapman, S. (2005). *Electric Machinery Fundamentals*. Electric machinery fundamentals. McGraw-Hill Companies,Incorporated.

De Jong, K.A. (2006). *Evolutionary Computation: A Unified Approach*.

Eiben, A. and Smith, J. (2007). *Introduction to Evolutionary Computing*. Natural Computing Series. Springer Berlin Heidelberg.

Goldberg, D. (2013). *Genetic Algorithms*. Pearson Education India.

Herrera, F., Lozano, M., and Verdegay, J. (1998). Tackling real-coded genetic algorithms: Operators and tools for behavioural analysis. *Artificial Intelligence Review*, 12, 265–319.

Houili, R., Hammoudi, M.Y., Betka, A., and Titaouine, A. (2023). Stochastic optimization algorithms for parameter identification of three phase induction motors with experimental verification. In *2023 International Conference on Advances in Electronics, Control and Communication Systems (ICAECCS)*, 1–6.

Huang, K., Kent, W., Wu, Q., and Turner, D. (1999). Parameter identification of an induction machine using genetic algorithms. In *Proceedings of the 1999 IEEE International Symposium on Computer Aided Control System Design (Cat. No.99TH8404)*, 510–515. doi:10.1109/CACSD.1999.808700.

Mitchell, M. (1998). *An Introduction to Genetic Algorithms*. Complex Adaptive Systems. MIT Press.

Raptis, D.S. and Kladas, A.G. (2019). Adaptive predictive control of induction motors with on line parameter estimation using a modified genetic algorithm. In *2019 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, volume 1, 103–108. doi:10.1109/WEMDCD.2019.8887799.

Simon, D. (2013). *Evolutionary Optimization Algorithms*. Wiley.

Sivanandam, S.N. and Deepa, S.N. (2007). *Introduction to Genetic Algorithms*. Springer Berlin Heidelberg, 1 edition.

Zamboti Fortes, M., Hugo Ferreira, V., and Palma Francisco Coelho, A. (2013). The induction motor parameter estimation using genetic algorithm. *IEEE Latin America Transactions*, 11(5), 1273–1278. doi:10.1109/TLA.2013.6684404.