

# Estimação de Parâmetros Elétricos do Motor de Indução Trifásico Utilizando Redes Neurais Artificiais

Gabriel Lourenço \* Gabriel Tavore de Arruda \*  
Victor Emanuel Correia de La Rosa \* Marcelo Favoretto Castoldi \*  
Alessandro Goedtel \* Wesley Angelino de Souza \*  
Wagner Fontes Godoy \*

\* Departamento de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, PR, (e-mail: [lowrencog@alunos.utfpr.edu.br](mailto:lowrencog@alunos.utfpr.edu.br); [gabriel.2019@alunos.utfpr.edu.br](mailto:gabriel.2019@alunos.utfpr.edu.br); [victoremanuel@alunos.utfpr.edu.br](mailto:victoremanuel@alunos.utfpr.edu.br); [marcastoldi@utfpr.edu.br](mailto:marcastoldi@utfpr.edu.br); [agoedtel@utfpr.edu.br](mailto:agoedtel@utfpr.edu.br); [wesleyangelino@utfpr.edu.br](mailto:wesleyangelino@utfpr.edu.br); [wagnergodoy@utfpr.edu.br](mailto:wagnergodoy@utfpr.edu.br)).

**Abstract:** The three-phase induction motor is the most widely used machine in industry for drive systems due to its robustness and simple maintenance. Understanding the parameters of the motor's equivalent circuit is essential for sizing and designing the control system, enhancing the system's efficiency and reliability. With the advancement of intelligent systems, computational techniques are increasingly applied to this task, emerging as an alternative to conventional methods. In this context, this work proposes a reliable and generalist method based on artificial neural networks to estimate the parameters of the equivalent electrical circuit of three-phase induction motors based on data provided by the manufacturer. A total of 542 different motors was considered, with power ranging from 0.75 kW to 55 kW. Two approaches were compared: the first uses a single neural network to estimate all parameters of the machine, while the second employs a specialist network to estimate each parameter individually. The proposed methodology presented results consistent with the literature.

**Resumo:** O motor de indução trifásico é a máquina mais utilizada na indústria em sistemas motrizes devido à sua robustez e manutenção simples. O conhecimento dos parâmetros do circuito equivalente do motor é essencial para o dimensionamento e projeto do controle de acionamento, aumentando a eficiência e confiabilidade do sistema. Com a evolução dos sistemas inteligentes, técnicas computacionais estão sendo aplicadas para essa tarefa, surgindo como uma alternativa aos métodos convencionais. Nesse contexto, este trabalho propõe um método confiável e generalista, baseado em redes neurais artificiais, para estimar os parâmetros do circuito elétrico equivalente de motores de indução trifásicos com dados fornecidos pelo fabricante. Um total de 542 motores foi considerado, com potências variando de 0,75 kW a 55 kW. Duas abordagens foram comparadas: a primeira usa uma única rede neural para estimar todos os parâmetros, enquanto a segunda usa uma rede especialista para estimar cada parâmetro individualmente. A metodologia proposta apresentou resultados condizentes com a literatura.

**Keywords:** Induction Motor; Equivalent Circuit; Parameter Estimation; Machine Learning; Artificial Neural Networks.

**Palavras-chaves:** Motor de Indução; Circuito Equivalente; Estimação de Parâmetros; Aprendizado de Máquina; Redes Neurais Artificiais.

## 1. INTRODUÇÃO

Os motores elétricos desempenham um papel essencial na execução de diversos processos dentro do setor industrial. De acordo com Gangsar and Tiwari (2020), cerca de 50% de toda a eletricidade produzida no mundo é consumida por sistemas de motores.

Os Motores de Indução Trifásicos (MITs) ocupam uma posição proeminente nas indústrias, especialmente em aplicações que exigem a conversão de energia elétrica em energia mecânica. Essa preferência é atribuída à sua estrutura

simples, robustez e custo-efetividade (Morfin et al., 2023). Os MITs podem ser classificados como rotor em gaiola de esquilo e rotor bobinado (Chuan and Gan, 2020). Os motores com rotor em gaiola de esquilo são amplamente utilizados em processos industriais devido ao seu menor custo de aquisição e adaptabilidade a ambientes desafiadores, como umidade, temperaturas elevadas e condições empoeiradas.

Dado o uso extensivo de motores de indução trifásicos em aplicações que exigem precisão e velocidades específicas, conhecer seus parâmetros elétricos é essencial. Isso é cru-

cial para aplicar métodos avançados de controle e garantir o dimensionamento adequado, evitando a perda de eficiência por superdimensionamento (Wang et al., 2018; Ghosh et al., 2020).

Apesar da importância de entender os parâmetros elétricos do motor, os fabricantes normalmente não fornecem esses dados, o que requer o uso de métodos e experimentos para estimar esses parâmetros (Guedes et al., 2018). A estimação de parâmetros pode ser alcançada utilizando métodos convencionais, como testes de rotor bloqueado, ensaio a vazio e corrente contínua direta (Sengamalai et al., 2022). Alternativamente, técnicas computacionais que utilizam algoritmos bioinspirados ou meta-heurísticos, como Redes Neurais Artificiais (RNAs), fornecem soluções viáveis para o problema (Guedes et al., 2018).

Em Fortes et al. (2013) é proposta a estimação dos parâmetros elétricos do MIT a partir dos dados de corrente e do escorregamento da máquina, utilizando o modelo do circuito equivalente da máquina por meio de um Algoritmo Genético (GA - do inglês, *Genetic Algorithm*), produzindo resultados que se aproximam dos valores reais aplicados pelo modelo de Chapman. Já em Guedes et al. (2018) é proposta a estimação dos parâmetros elétricos e mecânicos do MIT a partir de diferentes sinais de entrada de corrente usando um algoritmo baseado em Evolução Diferencial (DE - do inglês, *Differential Evolution*), que produziu resultados satisfatórios. No entanto, as meta-heurísticas evolutivas podem exigir um tempo computacional considerável para atingir a convergência, pois são métodos baseados em população. Além disso, como esses métodos são intrinsecamente estocásticos, podem não alcançar sempre um ponto de ótimo global para os problemas propostos (Peres and Castelli, 2021).

Além disso, Ipek et al. (2023) propôs a estimativa dos parâmetros elétricos do MIT utilizando diferentes modelos de Redes Neurais Artificiais (RNAs), sendo *Multilayer Perceptrons* (MLP), *Radial Basis Function* (RBF) e *General Regression Neural Network* (GRNN). Os parâmetros elétricos são estimados a partir dos dados do *datasheet* do motor, utilizando uma única RNA com cinco neurônios na camada de saída, usada para estimar todos os parâmetros de uma vez, alcançando um valor aceitável de raiz do erro quadrático médio (RMSE - do inglês, *Root Mean Square Error*) na fase de teste da rede.

Neste contexto, este estudo propõe a implementação de um sistema especialista composto por cinco redes MLPs, em que cada rede se concentra em estimar um parâmetro elétrico específico do circuito equivalente do MIT. O objetivo é demonstrar a eficácia da abordagem do sistema especialista baseado em RNA em comparação com o sistema generalista na estimativa de parâmetros do MIT.

## 2. CIRCUITO EQUIVALENTE DO MOTOR DE INDUÇÃO TRIFÁSICO

Na operação em estado estacionário, o sistema trifásico dos MITs é representado pelo circuito equivalente monofásico simplificado, no qual as perdas no núcleo são negligenciadas, conforme mostrado na Figura 1 (Chapman, 2012; Umans and Fitzgerald, 2014).




Figura 1. Circuito monofásico equivalente do MIT.

Onde  $r_1$  representa a resistência do estator,  $x_1$  a reatância do estator,  $r_2$  a resistência do rotor,  $x_2$  a reatância do rotor,  $x_m$  a reatância de magnetização,  $s$  o escorregamento,  $I_1$  a corrente do estator,  $I_0$  a corrente de magnetização,  $I_2$  a corrente do rotor e  $V$  a tensão de alimentação do motor.

A potência ativa do motor de indução é descrita de acordo com (1).

$$P_{out} = P_{in} - P_{j1} - P_{j2} - P_{rot} \quad (1)$$

onde  $P_{out}$  é a potência de saída,  $P_{in}$  é a potência de entrada,  $P_{j1}$  e  $P_{j2}$  são as perdas Joule nos enrolamentos do estator e do rotor, e  $P_{rot}$  são as perdas rotacionais.

A Equação (1) pode ser reescrita em (2) (Amaral et al., 2021).

$$P_{out} - (1 - s)P_{in} = [-(1 - s)3I_1^2 - 1] \begin{bmatrix} r_1 \\ P_{rot} \end{bmatrix} \quad (2)$$

A Equação (2) pode ser escrita considerando as condições de carga de 50%, 75% e 100%, conforme expressa (3), onde a resistência do estator  $r_1$  pode ser calculada.

$$\begin{bmatrix} P_{out50} - (1 - s_{50})P_{in50} \\ P_{out75} - (1 - s_{75})P_{in75} \\ P_{out100} - (1 - s_{100})P_{in100} \end{bmatrix} = \begin{bmatrix} -(1 - s_{50})3I_{150}^2 & -1 \\ -(1 - s_{75})3I_{175}^2 & -1 \\ -(1 - s_{100})3I_{1100}^2 & -1 \end{bmatrix} \cdot \begin{bmatrix} r_1 \\ P_{rot} \end{bmatrix} \quad (3)$$

De forma análoga às (2)-(3), para realizar o cálculo da resistência do rotor  $r_2$ , Amaral et al. (2021) descreve (4).

$$\frac{s(P_{out} + P_{rot})}{(1 - s)} = [3I_1^2 \ 1] \cdot \begin{bmatrix} r_2 \\ k \end{bmatrix} \quad (4)$$

onde  $k$  é dado por (5)

$$k = -3r_2I_0^2 \quad (5)$$

As Equações (6) e (7) podem ser aplicadas para estimar a reatância do estator  $x_1$ , a reatância do rotor  $x_2$  e a reatância de magnetização  $x_m$ .

$$I_0x_m = I_2\sqrt{\frac{r_2^2}{s} + x_2^2} \quad (6)$$

$$3x_mx_0^2 = Q - 3\left(I_1^2 + \frac{I_1^2}{a} - \frac{I_0^2}{a}\right)x_1 \quad (7)$$

Onde  $P_{out_i}$  é a potência de saída do motor para cada condição de operação,  $P_{in_i}$  é a potência de entrada para cada condição de operação,  $s_i$  é o escorregamento para cada condição de operação,  $I_{1_i}$  é a corrente do estator para cada condição de operação,  $I_2$  é a corrente no rotor,  $I_0$  é a corrente que passa pelo ramo de magnetização,  $Q$  é a potência reativa e  $a$  é a razão entre  $x_1$  e  $x_2$ .

Como os parâmetros elétricos dos MIT raramente são fornecidos pelos fabricantes, é viável gerar uma aproximação dos parâmetros elétricos dos motores para treinar e testar as RNAs usando a modelagem proposta neste trabalho, considerando os valores obtidos pelo método de aproximação como valores de referência.

### 3. REDE NEURAL ARTIFICIAL

As RNAs pertencem à classe de algoritmos bioinspirados que se inspiram no comportamento dos neurônios no cérebro humano (Abdolrasol et al., 2021a; Al Bataineh et al., 2022). Em uma MLP, os neurônios são organizados em camadas: uma camada de entrada recebe os dados, uma ou mais camadas ocultas processam as informações, e uma camada de saída produz o resultado final, conforme apresentado na Figura 2.




Figura 2. Ilustração de uma rede MLP com 2 camadas escondidas.

Durante a etapa de treinamento, a rede ajusta seus pesos por meio de um processo chamado *backpropagation*, minimizando a diferença entre as saídas previstas e reais usando uma função de custo escolhida (Abdolrasol et al., 2021b; Roy et al., 2021). O processo de aprendizado iterativo permite que as RNAs reconheçam padrões, generalizem dados e façam previsões, possibilitando a execução de tarefas não lineares complexas que envolvem regressão ou classificação (Kuruca et al., 2024; Benti et al., 2023).

Além disso, as RNAs podem utilizar diversos sinais de entrada, tornando-as versáteis para a estimativa de parâmetros usando diferentes tipos de dados do motor. Seja com base em sinais de corrente, variações de velocidade ou outros parâmetros operacionais, as RNAs podem aprender e generalizar a partir de conjuntos de dados diversos, melhorando sua aplicabilidade em cenários do mundo real.

A capacidade das RNAs de ajustar seus parâmetros internos durante o treinamento, juntamente com a habilidade de aprender de forma não supervisionada e adaptativa, faz delas ferramentas poderosas para resolver problemas complexos e dinâmicos. Através da integração de técnicas avançadas de otimização e arquitetura de redes, as RNAs podem ser adaptadas para uma ampla gama de aplicações, desde a modelagem e previsão até o controle e automação,

demonstrando sua flexibilidade e eficácia em diferentes domínios da engenharia e ciências aplicadas (Kuruca et al., 2024; Benti et al., 2023).

### 4. METODOLOGIA

A metodologia empregada neste estudo segue a abordagem proposta por Amaral et al. (2021) para extrair informações de 542 motores dos catálogos do fabricante WEG (2023), com potências variando de 0.75 kW a 55 kW. A partir dessas informações, os parâmetros elétricos do circuito equivalente  $r_1$ ,  $r_2$ ,  $x_1$ ,  $x_2$  e  $x_m$  foram extraídos. Após a coleta dos parâmetros nos catálogos de motores da WEG, foi realizada uma análise exploratória de dados para eliminar variáveis categóricas, mantendo apenas as características numéricas listadas na Tabela 1. Posteriormente, a normalização *z-score* (Cheadle et al., 2003) foi aplicada aos dados, e um conjunto de dados foi criado com os 19 características e os valores dos parâmetros do fabricante, calculados de acordo com (3)-(7).

Tabela 1. Atributos utilizados como entrada da rede.

Atributos
Tensão Nominal (V)
Polos
Escorregamento
Potência (kW)
$I_p / I_n$
Conjugado de partida (%)
Conjugado máximo (%)
Momento de inercia (kgm <sup>2</sup> )
Tempo de Rotor Bloqueado (s)
Nível de ruído (dB(A))
Fator de serviço
Rotação nominal (rpm)
$\eta$ 50%
$\eta$ 75%
$\eta$ 100%
FP 50%
FP 75%
FP 100%
Corrente Nominal (A)

Após a normalização, um sistema especialista foi implementado usando cinco MLPs. Cada MLP é composta por 19 valores de entrada, uma única camada oculta contendo 15 neurônios e um neurônio de saída que representa um dos parâmetros do motor:  $r_1$ ,  $r_2$ ,  $x_1$ ,  $x_2$  e  $x_m$ . Para treinamento e teste, foi empregada uma divisão de dados de 80/20, totalizando 433 amostras de treinamento e 109 amostras para teste.

O Erro Médio Quadrático (MSE - do inglês, *Mean Squared Error*) foi analisado como critério de convergência. Um critério de convergência de  $\epsilon = 10^{-7}$  foi utilizado, conforme apresentado nas (8) e (9).

$$MSE = \frac{1}{N} \sum_{k=1}^N (d^k - u)^2 \quad (8)$$

$$|MSE^{Current} - MSE^{Previous}| \leq \epsilon \quad (9)$$

onde  $N$  é o número de amostras,  $d^k$  é a amostra real na iteração  $k$  e  $u$  é a amostra estimada pela rede. Com base

em testes empíricos, foi adotada uma taxa de aprendizado de  $\eta = 10^{-4}$  e um coeficiente de *momentum* de  $\alpha = 0.9$ .

Para a camada oculta, a função logística foi utilizada como função de ativação, e para a camada de saída, a função linear foi usada, conforme expresso nas (10) e (11), respectivamente.

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (10)$$

$$g(u) = u \quad (11)$$

onde  $\beta$  é uma constante real associada ao nível de inclinação da função logística, sendo definido  $\beta = 1$ .

A novidade deste método reside na aplicação de uma metodologia bem estabelecida (Amaral et al., 2021) a um conjunto de dados de motores WEG, demonstrando sua adaptabilidade e potencial para estimativa precisa de parâmetros. Além disso, em contraste com Ipek et al. (2023), que implementou um modelo MLP generalista, este trabalho propõe que o uso de cinco MLPs pode melhorar a estimativa dos parâmetros do motor.

## 5. RESULTADOS E DISCUSSÕES

As curvas de convergência média dos motores e os valores finais de MSE para os cinco MLPs e para o modelo MLP generalista são apresentados na Figura 3 e na Tabela 2, respectivamente.

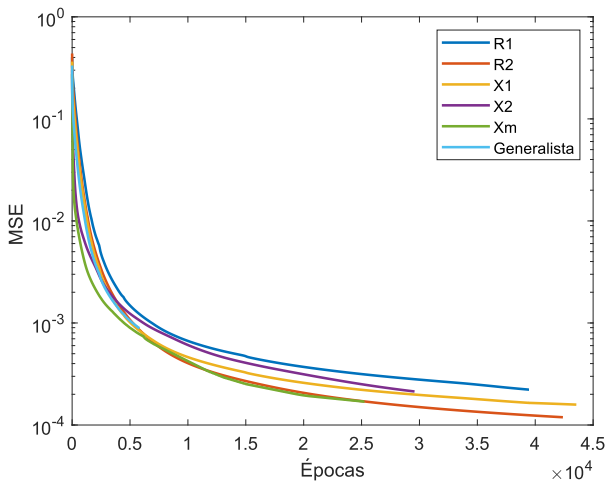


Figura 3. Convergência das MLPs.

Observa-se que a MLP que convergiu mais rapidamente foi a que estimou o parâmetro  $x_m$ , convergindo em 24.458 épocas e alcançando um MSE de  $1.6384 \times 10^{-4}$ . Por outro lado, a MLP que levou mais tempo para convergir foi a que estimou o parâmetro  $x_1$ , requerendo 43.523 épocas e apresentando um MSE de  $1.5836 \times 10^{-4}$ . A MLP generalista atingiu a convergência em 5.709 épocas, obtendo um MSE de  $8.8659 \times 10^{-4}$ .

Tendo em vista os menores erros apresentados pelas MLPs especialistas para cada parâmetro, dez motores com potências apresentadas na Tabela 3 foram selecionados aleatoriamente do conjunto de dados de teste para avaliar e diagnosticar o desempenho dos modelos MLP.

Tabela 2. Valores de convergência das MLPs.

Parâmetros	Épocas	MSE
$r_1$	39483	$2,2200 \times 10^{-4}$
$r_2$	42363	$1,1907 \times 10^{-4}$
$x_1$	43523	$1,5836 \times 10^{-4}$
$x_2$	29558	$2,1321 \times 10^{-4}$
$x_m$	24458	$1,6384 \times 10^{-4}$
Generalista	5709	$8,8659 \times 10^{-4}$

Tabela 3. Potência dos motores selecionados.

ID do motor	Potência (kW)
1	3,7
2	4,5
3	7,5
4	9,2
5	11,0
6	15,0
7	18,5
8	22,0
9	30,0
10	45,0

As Tabelas 4 a 8 exibem a comparação entre o valor de referência, a saída da MLP especialista e a saída da MLP generalista para 10 motores selecionados aleatoriamente na etapa de teste do modelo MLP.

A Tabela 4 apresenta as estimativas produzidas pelas MLPs especialista e generalista em conjunto com o valor de referência do parâmetro  $r_1$ . Discrepâncias são evidentes entre os diferentes IDs de motores ao comparar os valores estimados de  $r_1$  gerados pelas MLPs especialista e generalista com o valor de referência. Os valores estimados de  $r_1$  variaram consideravelmente entre as duas MLPs para determinados IDs de motores, incluindo os IDs 2, 3 e 10. Além disso, a MLP especialista tende a estimar parâmetros mais próximos do valor de referência de  $r_1$  do que a MLP generalista.

Tabela 4. Comparação do valor de referência do parâmetro  $r_1$  e o estimado pelas MLPs especialista e generalista.

ID do motor	Valor de referência de $r_1$ ( $\Omega$ )	$r_1$ estimado pela rede MLP especialista ( $\Omega$ )	$r_1$ estimado pela rede MLP generalista ( $\Omega$ )
1	0,3573	0,3421	0,3003
2	0,2088	0,2105	0,1615
3	0,4354	0,4485	0,3165
4	0,6325	0,6028	0,7320
5	0,5290	0,5551	0,6374
6	0,0710	0,0751	0,0782
7	0,1455	0,1541	0,1101
8	0,0594	0,0621	0,0945
9	0,1118	0,1086	0,1546
10	0,0177	0,0181	0,0280

Além disso, para o parâmetro  $r_2$ , conforme apresentado na Tabela 5, em relação aos IDs dos motores 3, 6 e 7, ambas as MLPs exibem desvios leves, mas discerníveis, do valor de referência de  $r_2$ . Observa-se que a MLP generalista, nos motores com IDs 3 e 6, apresentou os maiores erros para este parâmetro.

Já na Tabela 6, para os IDs dos motores 4, 6, 8 e 10, as estimativas fornecidas pela MLP generalista se desviam dos valores de referência de  $x_1$ . Além disso, as estimativas da MLP especialista estão mais próximas dos valores de

Tabela 5. Comparação do valor de referência do parâmetro  $r_2$  e o estimado pelas MLPs especialista e generalista.

ID do motor	Valor de referência de $r_2$ ( $\Omega$ )	$r_2$ estimado pela rede MLP especialista ( $\Omega$ )	$r_2$ estimado pela rede MLP generalista ( $\Omega$ )
1	0,2378	0,2411	0,1876
2	0,2171	0,2212	0,2501
3	0,1618	0,1701	0,2524
4	0,3901	0,4012	0,3200
5	0,3263	0,3310	0,2891
6	0,0535	0,0510	0,0151
7	0,1359	0,1415	0,1010
8	0,0276	0,0283	0,0345
9	0,0622	0,0671	0,0491
10	0,0168	0,0177	0,0201

referência de  $x_1$ . De acordo com a Tabela 7, para os IDs dos motores 4, 2 e 10, as estimativas fornecidas pela MLP generalista se desviam significativamente dos valores de referência de  $x_2$ , enquanto a MLP especialista tende a oferecer estimativas mais próximas dos valores desejados de  $x_2$  para esses IDs de motores.

Tabela 6. Comparação do valor de referência do parâmetro  $x_1$  e o estimado pelas MLPs especialista e generalista.

ID do motor	Valor de referência de $x_1$ ( $\Omega$ )	$x_1$ estimado pela rede MLP especialista ( $\Omega$ )	$x_1$ estimado pela rede MLP generalista ( $\Omega$ )
1	0,7027	0,6801	0,8215
2	0,6268	0,5999	0,4619
3	1,0726	1,1120	0,9201
4	1,5145	1,4782	1,9999
5	1,2667	1,2799	1,4768
6	0,1439	0,1534	0,1898
7	0,6089	0,6210	0,7001
8	0,1326	0,1338	0,1892
9	0,3380	0,3186	0,4100
10	0,0771	0,0823	0,0991

Tabela 7. Comparação do valor de referência do parâmetro  $x_2$  e o estimado pelas MLPs especialista e generalista.

ID do motor	Valor de referência de $x_2$ ( $\Omega$ )	$x_2$ estimado pela rede MLP especialista ( $\Omega$ )	$x_2$ estimado pela rede MLP generalista ( $\Omega$ )
1	1,0334	1,0501	1,2418
2	0,9218	0,9081	0,7100
3	1,5774	1,5912	1,3295
4	2,2273	2,2009	2,8983
5	1,8628	1,8799	2,2010
6	0,2116	0,2198	0,2385
7	0,8955	0,8702	1,0012
8	0,1951	0,1910	0,2120
9	0,5126	0,4889	0,5991
10	0,1134	0,1111	0,1391

Conforme pode ser observado na Tabela 8, para os IDs dos motores 10, 9 e 8, as estimativas fornecidas pela MLP generalista se desviam significativamente dos valores de referência de  $x_m$ . Já a MLP especialista tende a fornecer estimativas mais próximas dos valores desejados de  $x_m$  para esses IDs de motores.

Em comparação com os valores de referência dos parâmetros, a MLP especialista é superior à MLP generalista na

Tabela 8. Comparação do valor de referência do parâmetro  $x_m$  e o estimado pelas MLPs especialista e generalista.

ID do motor	Valor de referência de $x_m$ ( $\Omega$ )	$x_m$ estimado pela rede MLP especialista ( $\Omega$ )	$x_m$ estimado pela rede MLP generalista ( $\Omega$ )
1	16,5952	17,7112	18,124
2	10,0635	9,8254	7,8601
3	28,2206	27,1236	27,7761
4	26,1749	26,412	21,6723
5	21,8918	23,521	18,9840
6	5,2990	5,5778	6,1274
7	17,0205	17,9541	18,9874
8	3,1601	3,0812	4,0010
9	10,9031	11,0103	8,1410
10	1,6767	1,7100	2,3045

previsão dos parâmetros para diferentes IDs de motores. A MLP especialista exibe uma aproximação mais precisa aos valores de referência para os parâmetros  $r_1$ ,  $x_1$ ,  $x_2$  e  $x_m$  na maioria dos motores e geralmente é melhor para o parâmetro  $r_2$ . No entanto, a MLP generalista mostra desvios maiores dos valores desejados, indicando limitações em sua capacidade de generalizar efetivamente entre vários tipos de motores. Portanto, a MLP especialista é recomendada para tarefas que requerem uma estimativa precisa dos parâmetros do motor.

As variações observadas nos tempos de convergência e erros destacam a necessidade de RNAs específicas para estimar os parâmetros do motor, reconhecendo as complexidades inerentes à modelagem do motor.

### 5.1 Comparação com a literatura

A Tabela 9 compara os erros relativos em porcentagem, indicando os menores e maiores erros relativos entre os resultados obtidos na fase de teste deste estudo e os resultados do trabalho de Ipek et al. (2023) para os cinco parâmetros. A tabela também mostra os intervalos de erros obtidos entre os motores selecionados.

Tabela 9. Comparação entre os erros relativos em porcentagem para os motores apresentados na fase de teste.

Parâmetros	Este trabalho		Ipek et al. (2023)	
	Min. (%)	Max. (%)	Min. (%)	Max. (%)
$r_1$	0,82	5,91	0,09	31,73
$r_2$	1,39	7,88	0,25	54,17
$x_1$	0,91	6,60	0,33	3,54
$x_2$	0,87	4,62	0,28	3,31
$x_m$	0,91	7,44	0,04	1,55

Neste trabalho, observa-se que o menor intervalo foi para o parâmetro  $r_1$ , onde o erro mínimo foi de 0,82% e o máximo de 5,91%. O maior intervalo foi para o parâmetro  $x_m$ , com erro mínimo de 0,91% e máximo de 7,44%. Em Ipek et al. (2023), o menor intervalo foi para o parâmetro  $x_m$ , com erro mínimo de 0,04% e máximo de 1,55%, e o maior intervalo foi para o parâmetro  $r_2$ , com erro mínimo de 0,25% e máximo de 54,17%.

Observa-se que os intervalos dos erros relativos obtidos na fase de teste neste trabalho, para os parâmetros  $r_1$  e  $r_2$ , são menores do que os apresentados por Ipek et al. (2023),

indicando uma melhor convergência da rede especialista para esses parâmetros. No entanto, para os demais parâmetros, Ipek et al. (2023) apresentou intervalos menores. É possível observar que a magnitude dos intervalos exibidos neste trabalho está próxima da mesma faixa de valores para todos os parâmetros.

## 6. CONCLUSÃO

Este estudo apresentou uma abordagem robusta para estimar os parâmetros elétricos de motores de indução trifásicos usando redes neurais artificiais. O uso de modelos MLP especialistas para cada parâmetro do motor demonstrou uma maior precisão na estimativa dos parâmetros em comparação com um modelo MLP generalista. Embora alguns parâmetros apresentem valores de MSE mais altos em comparação com estudos anteriores, o desempenho geral dos modelos MLP especialistas foi superior ao do modelo MLP generalista.

Para pesquisas futuras, propõe-se o refinamento da metodologia por meio da expansão do banco de dados, exploração de arquiteturas alternativas de redes neurais artificiais e otimização dos hiperparâmetros do modelo. Além disso, investigar o impacto de diferentes técnicas de pré-processamento e métodos de seleção de características e avaliar o desempenho dos modelos.

## AGRADECIMENTOS

Os autores agradecem o suporte financeiro fornecido pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) por meio da bolsa de Demandas Sociais (DS), Fundação Araucária, Superintendência Geral de Ciência, Tecnologia e Ensino Superior (SETI), e a Universidade Tecnológica Federal do Paraná (UTFPR).

## REFERÊNCIAS

- Abdolrasol, M.G.M., Hussain, S.M.S., Ustun, T.S., Sarker, M.R., Hannan, M.A., Mohamed, R., Ali, J.A., Mekhilef, S., and Milad, A. (2021a). Artificial neural networks based optimization techniques: A review. *Electronics*, 10(21).
- Abdolrasol, M.G.M., Hussain, S.M.S., Ustun, T.S., Sarker, M.R., Hannan, M.A., Mohamed, R., Ali, J.A., Mekhilef, S., and Milad, A. (2021b). Artificial neural networks based optimization techniques: A review. *Electronics*, 10(21).
- Al Bataineh, A., Kaur, D., and Jalali, S.M.J. (2022). Multi-layer perceptron training optimization using nature inspired computing. *IEEE Access*, 10, 36963–36977.
- Amaral, G.F.V., Baccarini, J.M.R., Coelho, F.C.R., and Rabelo, L.M. (2021). A High Precision Method for Induction Machine Parameters Estimation From Manufacturer Data. *IEEE Transactions on Energy Conversion*, 36(2), 1226–1233.
- Benti, N.E., Chaka, M.D., and Semie, A.G. (2023). Forecasting renewable energy generation with machine learning and deep learning: Current advances and future prospects. *Sustainability*, 15(9).
- Chapman, S.J. (2012). *Electric machinery fundamentals*. McGraw-Hill, New York, 5th ed edition.
- Cheadle, C., Vawter, M.P., Freed, W.J., and Becker, K.G. (2003). Analysis of microarray data using z score transformation. *The Journal of Molecular Diagnostics*, 5(2), 73–81.
- Chuan, H. and Gan, L. (2020). Investigation of the power losses in induction machines with rotor eccentricity. *Electrical Engineering*, 102(3), 1393–1403.
- Fortes, M.Z., Ferreira, V.H., and Coelho, A.P.F. (2013). The Induction Motor Parameter Estimation Using Genetic Algorithm. *IEEE Latin America Transactions*, 11(5), 1273–1278.
- Gangsar, P. and Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical Systems and Signal Processing*, 144, 106908.
- Ghosh, P.K., Sadhu, P.K., Basak, R., and Sanyal, A. (2020). Energy efficient design of three phase induction motor by water cycle algorithm. *Ain Shams Engineering Journal*, 11(4), 1139–1147.
- Guedes, J.J., Castoldi, M.F., Goedel, A., Agulhari, C.M., and Sanches, D.S. (2018). Parameters estimation of three-phase induction motors using differential evolution. *Electric Power Systems Research*, 154, 204–212.
- Ipek, S.N., Taskiran, M., Bekiroglu, N., and Aycicek, E. (2023). Optimal induction machine parameter estimation method with artificial neural networks. *Electrical Engineering*.
- Kurucan, M., Özbaltan, M., Yetgin, Z., and Alkaya, A. (2024). Applications of artificial neural network based battery management systems: A literature review. *Renewable and Sustainable Energy Reviews*, 192, 114262.
- Morfin, O.A., Ruiz-Cruz, R., Valenzuela, F.A., Ramirez-Betancour, R., Castañeda, C.E., and Ornelas-Tellez, F. (2023). Robust cascade controller for the power factor of the three-phase supply and the induction motor velocity. *ISA Transactions*.
- Peres, F. and Castelli, M. (2021). Combinatorial optimization problems and metaheuristics: Review, challenges, design, and development. *Applied Sciences*, 11(14).
- Roy, R.B., Rokonzaman, M., Amin, N., Mishu, M.K., Alahakoon, S., Rahman, S., Mithulanathan, N., Rahman, K.S., Shakeri, M., and Pasupuleti, J. (2021). A comparative performance analysis of ann algorithms for mppt energy harvesting in solar pv system. *IEEE Access*, 9, 102137–102152.
- Sengamalai, U., Anbazhagan, G., Thamizh Thentral, T.M., 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).
- Umans, S.D. and Fitzgerald, A.E. (2014). *Fitzgerald & Kingsley's electric machinery*. McGraw-Hill Companies, New York, 7th ed edition.
- Wang, F., Zhang, Z., Mei, X., Rodríguez, J., and Kennel, R. (2018). Advanced Control Strategies of Induction Machine: Field Oriented Control, Direct Torque Control and Model Predictive Control. *Energies*, 11(1), 120.
- WEG (2023). *Electrical Motor Catalog*. Jaraguá do Sul, SC. Available on: [https://ecatalog.weg.net/tec\\\_cat/tech\\\_motor\\\_sel\\\_web.asp](https://ecatalog.weg.net/tec\_cat/tech\_motor\_sel\_web.asp).