Sistema de Detecção de Falhas em Geradores de Indução Duplamente Alimentados

Raphael R. Haddad*, Alfeu J. Sguarezi Filho*, Alain S. Potts*

* *Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas -Universidade Federal do ABC -SP. Brasil (e-mail: raphael.haddad@ufabc.edu.br, e-mail: alfeu.sguarezi@ufabc.edu.br, e-mail: alain.segundo@ufabc.edu.br)*

Abstract: The world is increasingly focused on more sustainable and environmentally friendly energy sources. In this context, wind energy has been gaining prominence. To ensure a continuous and accessible energy supply to consumers, it is essential that wind turbines constantly improve their performance. A fundamental component of these turbines is the Doubly Fed Induction Generator (DFIG). This work aims to study ways to model and diagnose the health of the DFIG, focusing on condition-based preventive maintenance (CBM) to enhance the overall availability of wind turbines. In an initial analysis, the application of CBM techniques to the DFIG can increase both availability and electrical safety for consumers.

Resumo: O mundo está cada vez mais voltado para fontes de energia sustentáveis, como a energia eólica, que tem ganhado muito destaque. Este trabalho se propõe a estudar maneiras de modelar e diagnosticar a saúde do gerador de indução duplamente alimentado (DFIG, do inglês *"Doubly Fed Induction Generator"*), fundamental nos aerogeradores. A abordagem de manutenção preventiva baseada na condição (CBM, do inglês *"condition-based maintenance"*) visa aprimorar a disponibilidade geral dos aerogeradores, aumentando tanto a disponibilidade quanto a segurança elétrica para os consumidores. Os resultados iniciais sugerem que a aplicação de técnicas de CBM no DFIG pode trazer benefícios significativos em termos de desempenho e confiabilidade.

Keywords: DFIG; CBM; Fuzzy; failure detection; model simulation.

Palavras-chaves: DFIG; CBM; Lógica difusa; detecção de falha; simulação do modelo

1. INTRODUÇÃO

Na busca por fontes de energia renováveis e sustentáveis, a energia eólica tem se destacado como uma alternativa promissora para reduzir a dependência dos combustíveis fósseis e mitigar os impactos das mudanças climáticas. Dentro deste cenário, os geradores de indução duplamente alimentados (DFIG, do inglês *"Doubly Fed Induction Generator"*) surgem como uma tecnologia chave na geração de energia eólica em larga escala.

Os DFIGs têm se tornado uma escolha popular devido à sua eficiência, flexibilidade e capacidade de controle. Ao contrário dos geradores de indução convencionais, que estão conectados diretamente à rede elétrica, os DFIGs possuem dois sistemas de alimentação independentes: um sistema de alimentação direta conectado à rede e outro sistema de alimentação indireta (através de um conversor de potência) conectado ao rotor do gerador.

Essa configuração permite que os DFIGs controlem ativamente a velocidade e a potência gerada, otimizando o aproveitamento da energia eólica em diferentes condições de vento. Além disso, os DFIGs oferecem a vantagem de proporcionar uma resposta mais rápida às flutuações de carga e às variações na velocidade do vento, aumentando assim a estabilidade do sistema elétrico, quando comparado aos geradores diretamente conectados a rede elétrica.

Devido à grande complexidade dos sistemas de geração de energia eólica, para seu controle é necessário o domínio de modelos complexos, transformações de sistemas referenciais e estrategias de controle aprimoradas. Para a implementação de uma melhor solução de CBM, do inglês *"condition-based maintenance"*, além desses conhecimentos, é desejável ter também conhecimentos outras de técnicas avançadas, como a lógica difusa, inteligencia artificial, aprendizado de máquinas ou aprendizagem profunda.

Ao investigar os métodos de detecção de falhas em DFIGs, destacam-se trabalhos como o de Merabet et al. (2015), no qual a identificação das falhas foi realizada por meio de lógica neuro difusa. Esse estudo desenvolveu uma estrutura lógica capaz de distinguir os diferentes estados de operação do DFIG, incluindo condições saudáveis, falha de fase aberta, curto-circuito e curto-circuito crítico. No entanto, para alcançar uma abordagem semelhante, é necessário percorrer um extenso caminho de compreensão dos modelos e conceitos relacionados às falhas e ao funcionamento do DFIG.

Nesse sentido, há uma vasta gama de possibilidades no desenvolvimento de pesquisas sobre a detecção de falhas em DFIGs, não limitando-se apenas à análise de métodos

existentes, mas também envolve o desenvolvimento de outras técnicas como inteligência artificial, aprendizado de máquina e análise de dados em tempo real. Portanto, este trabalho é o primeiro passo para alcançar uma compreensão inicial e a implementação eficaz de uma dessas técnicas.

1.1 Métodos de detecção de falhas

Ao considerarmos os modelos de falhas, conforme destacado em Isermann (2006) e Elshenawy et al. (2024), há uma variedade de razões para sua ocorrência. É possível classificá-las em três categorias principais: falhas de projeto (ou construção), falhas de operação (ou falta de manutenção) e falhas decorrentes do uso durante a operação. Focando em um modelo básico das falhas relacionadas ao uso durante a operação, podem-se identificar três formas possíveis de falha em uma variável: falha abrupta, falhas incipientes (onde a variável de processo gradualmente vai se desviando do valor esperado) e falhas intermitentes. É importante observar que essas falhas podem ocorrer em qualquer um dos três componentes de controle: sensores, atuadores ou no próprio processo. O entendimento das formas de falha é importante para a implementação de estratégias de monitoramento e manutenção mais eficazes, reduzindo assim o risco de falhas catastróficas e maximizando a confiabilidade e o desempenho dos sistemas de controle industrial.

2. MODELO DO DFIG E CONTROLE

O modelo que foi utilizado tem como base no trabalho de G. Abad (2011) com as seguintes equações:

$$\overrightarrow{V}_s^s = R_s.\overrightarrow{i}_s^s + \frac{d\overrightarrow{\psi}_s^s}{dt} \tag{1}$$

$$\overrightarrow{V}_r^r = R_r.\overrightarrow{i}_r^r + \frac{d\overrightarrow{\psi}_r^r}{dt} \tag{2}$$

Onde $\overrightarrow{V_s}$, $\overrightarrow{V_r}$, $\overrightarrow{i_s}$, $\overrightarrow{i_r}$, $\overrightarrow{\psi_s}$ e $\overrightarrow{\psi_r}$ são os vetores de tensão, corrente e fluxo eletromagnético do estator e rotor em um dado referencial. Além disso, R_s e R_r são as resistências do estator e rotor, respectivamente.

A partir das equações (1) e (2) foi seguindo o mesmo procedimento descrito em Sguarezi (2022), com bloco das correntes, bloco dos fluxos e bloco de torque. Desta forma, as tensões em ABC do estator e rotor são entradas do modelo, além da carga total mecânica aplicada ao rotor. As correntes do estator e rotor em ABC são as saídas do modelo. Entre a entrada e a saída, há uma série de transformações para o sistema coordenado Alfa-Beta-Zero além do dq-Zero. O ponto que é mais relevante para o correto funcionamento do modelo é que a entrada de tensão do rotor e a carga mecânica total são valores nulos e constantes durante toda a simulação. Para facilitar o entendimento, foi adicionado a Figura 1 o esquema do modelo do DFIG utilizado. Na Tabela 1 são mostrados os parâmetros que foram usados na simulação.

Estes parâmetros têm como base a bancada de simulação instalada no Laboratório de Eletrônica de Potência e Smart Grids da UFABC - Universidade Federal do ABC (Figura 2).

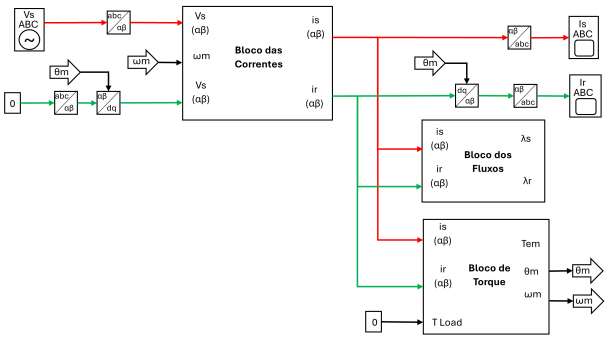

Figura 1. Esquemático do modelo do DFIG.

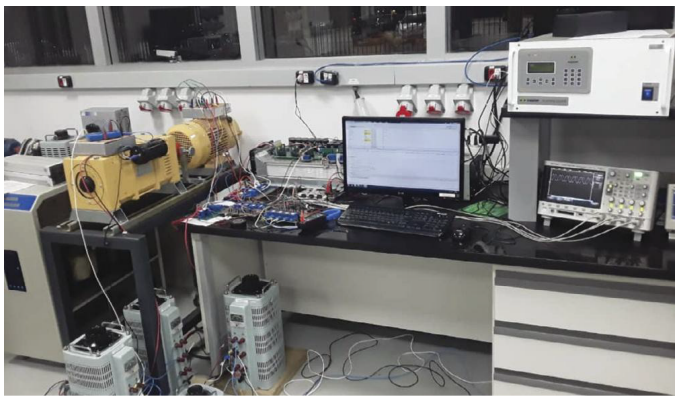

Figura 2. Laboratório de Eletrônica de Potência e Smart Grids da UFABC.

Para o controle, foi escolhido o DTC (*"Direct Torque Control"*, em inglês) por histerese, conforme Abad et al. (2011). Neste controle, é necessária a referência de velocidade mecânica (ω_m), que fará um controle por meio de um controlador Proporcional Integral (PI). A saída do controlador será a referência do torque eletromagnético (T_{em}). Com a referência do T_{em} será feito um controle por histerese cuja saída constitui a entrada do DTC. Este último bloco é o responsável pelo controle das chaves do inversor. São entradas também do controle DTC o angulo do fluxo eletromagnético do estator e outro controle por histerese do módulo do fluxo eletromagnético do estator. Todos os parâmetros utilizados no controle DTC podem ser consultados na Tabela 2.

2.1 Modelagem em espaço de estados

A fim de criar um sistema de detecção de falhas, foi necessário utilizar um modelo de espaços de estados do DFIG. O modelo escolhido foi o descrito G. Abad (2011) que consiste em:

Tabela 1. Parâmetros do modelo.

Parâmetro	Descrição
$R_s = 1\ \Omega$	Resistência do Estator
$R_r = 3{,}1322\ \Omega$	Resistência do Rotor
$L_s = 0{,}2100$ H	Indutância do Estator
$L_r = 0{,}2100$ H	Indutância do Rotor
$L_m = 0{,}1917$ H	Indutância Mútua
NP = 2	Par de polos
u = 1	Relação de espiras estator/rotor
J = 0,05 kg.m2	Indutância do Rotor

$$\frac{d}{dt}\begin{bmatrix} i_{\alpha s} \\ i_{\beta s} \\ i_{\alpha r} \\ i_{\beta r} \end{bmatrix} = A \begin{bmatrix} i_{\alpha s} \\ i_{\beta s} \\ i_{\alpha r} \\ i_{\beta r} \end{bmatrix} + B \begin{bmatrix} v_{\alpha s} \\ v_{\beta s} \\ v_{\alpha r} \\ v_{\beta r} \end{bmatrix} \tag{3}$$

$$A = \left(\frac{1}{\sigma L_s L_r}\right) \times \begin{bmatrix} -R_s L_r & \omega_m L_m^2 & R_r L_m & \omega_m L_m L_r \\ -\omega_m L_m^2 & -R_s L_r & -\omega_m L_m L_r & R_r L_m \\ R_s L_m & -\omega_m L_s Lm & -RrLs & -\omega_m L_r L_s \\ \omega_m L_s L_m & R_s L_m & \omega_m L_r L_s & -R_s L_s \end{bmatrix} \tag{4}$$

$$B = \left(\frac{1}{\sigma L_s L_r}\right) \times \begin{bmatrix} L_r & 0 & -L_m & 0 \\ 0 & L_r & 0 & -L_m \\ -L_m & 0 & L_s & 0 \\ 0 & -L_m & 0 & L_s \end{bmatrix} \tag{5}$$

$$\sigma = 1 - \frac{L_m^2}{L_s L_r} \tag{6}$$

Onde $i_{\alpha s}$, $i_{\beta s}$, $v_{\alpha s}$ e $v_{\beta s}$ são as correntes e tensões do estator na coordenada $\alpha\beta$. $i_{\alpha r}$, $i_{\beta r}$, $v_{\alpha r}$ e $v_{\beta r}$ são as correntes e tensões do rotor na coordenada $\alpha\beta$.

Analisando a equação (3), pode-se concluir que a as tensões $v_{\alpha s}$, $v_{\beta s}$, $v_{\alpha r}$ e $v_{\beta r}$ são as variáveis de entrada enquanto as correntes $i_{\alpha s}$, $i_{\beta s}$ e $i_{\alpha r}$, $i_{\beta r}$ são as variáveis de saída.

3. CÁLCULO DO RESÍDUO

Para identificar os problemas existentes no modelo, foi implementado um cálculo de resíduo. O resíduo foi calculado a partir da diferença entre a saída do modelo fenomenológico obtido em Sguarezi (2022) a partir das equações (1) e (2), com o modelo em espaço de estados descrito pela equação (3). Exemplificando melhor esse cálculo, as saídas das tensões do conversor de potência são as entradas para as duas formas distintas de cálculo das correntes de saída. A primeira representa o DFIG pelas equações (1) e (2) onde serão simuladas as falhas. A segunda, descrita pela equação (3) será a base de comparação do comportamento sem falhas.

Percebe-se durante os primeiros 0,4s da simulação, que o DFIG está acelerando até atingir o ω_m de referência. Portanto, foi adicionada uma lógica para deixar o cálculo do resíduo zerado na resposta em regime transitório do sinal, isto é, nos 0,4s iniciais da simulação, uma vez que o modelo em espaço de estados se mostrou incapaz de aproximar de forma satisfatória a resposta transitória do sistema. Isso acontece pois o valor usado na simulação de ω_m no modelo em espaço de estados é o ω_m de referência que é fixo durante a simulação.

A fim de aproximar o trabalho à realidade e simular medições ruidosas, adicionou-se um sinal de ruído no sinal nas correntes. Esse ruído foi gerado por um número randômico com uma distribuição normal com um valor máximo de 3% da amplitude das correntes sem a adição de nenhuma falha do sistema. Como é possível verificar na Figura 3, até o instante de 1s, somente há o ruido como resíduo. A partir de 1s, além do ruido, há a diferença entre as equações (falha).

Tabela 2. Parâmetros do controle DTC.

Parâmetro	Descrição
sf nom = 0,99 wb	Fluxo eletromagnético nominal do estator
T non = 16 Nm	Torque nominal
Ki=0,141	Constante integral do PI
Kp = 3,0160	Constante Proporcional do PI
Ts = 2e-5 s	Ciclos de amostragem
Vdc = 700	Tensão DC do inversor

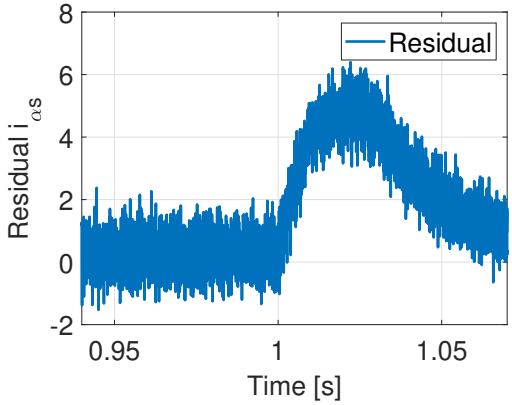

Figura 3. Exemplo do sinal de resíduo da $i_{\alpha s}$.

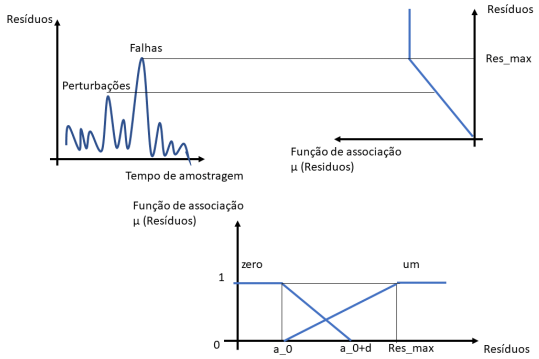

Figura 4. Utilização da lógica difusa para detecção de falhas. Fonte: Frank and Ding (1997)

3.1 Lógica Difusa

É possível verificar a utilização da lógica difusa em trabalhos com DFIG em Merabet et al. (2015) e em outras aplicações como pode ser observado em Cabeza (2023). A vantagem em se utilizar a lógica difusa está na capacidade de trabalhar com incertezas e imprecisões de forma mais flexível do que a lógica booleana. Enquanto a lógica booleana trabalha com valores verdadeiros ou falsos (0 ou 1), a lógica difusa permite representar valores intermediários entre esses extremos. Para o caso do resíduo, a lógica tem que ser capaz de identificar e dar a probabilidade de existir um problema, mesmo tendo ruídos nas variáveis medidas.

Para ilustrar ainda mais a aplicação da lógica difusa na detecção de falhas, é possível examinar o estudo de Frank and Ding (1997), que demonstra como a utilização de um limiar fixo para detectar falhas em resíduos pode resultar em alarmes falsos. Comparando esse estudo com a Figura 4, as perturbações representadas nessa figura equivalem aos ruídos introduzidos na simulação.

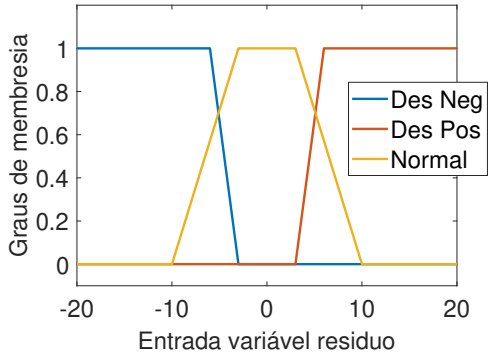

Figura 5. Funções de Membresia para cada sinal residual dascorre ntes de saída.

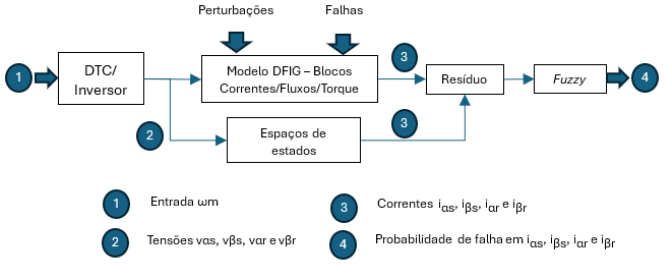

Figura 6. Exemplo do sinal de resíduo da $i_{\alpha s}$.

Dependendo do valor do limiar fixo estabelecido, ele pode interpretar o ruído como uma falha. É por isso que a aplicação da lógica difusa é benéfica na identificação de falhas, permitindo lidar com incertezas de forma mais eficaz, reduzindo assim os alarmes falsos. Em uma aplicação prática, não há certeza sobre o nível de ruído presente nos sinais medidos. Portanto, ao utilizar um limiar fixo, é provável que ocorram falsos alarmes. Neste trabalho, para cada um dos sinais ($i_{\alpha s}$, $i_{\beta s}$ e $i_{\alpha r}$, $i_{\beta r}$), foram estabelecidas três funções de membresia: uma de operação normal e duas para sinalizar falhas a partir de desvios positivos e negativos do sinal residual. Os graus de filiação e sua implementação podem ser observados na Figura 5 e na Tabela 3.

O método de inferência escolhido foi o Takagi-Sugeno-Kang. Além de detectar a falha, a lógica difusa tem que conseguir detectar o problema mesmo com a adição do ruído. A saída da lógica difusa irá mostrar qual a probabilidade de o DFIG apresentar um problema.

Tabela 3. Pontos considerados das entradas na forma trapezoidal.

Entrada	Pontos
Normal	[-10 -3 3 10]
Desvio Positivo	[3 6 20 20]
Desvio Negativo	[-20 -20 -6 -3]

De modo geral, é possível sintetizar todas as partes já descritas neste trabalho em um esquema de diagnóstico de falhas, conforme apresentado na Figura 6. Para esta simulação, foi considerado apenas o sinal de ruído como pertubação. Há outros tipos de perturbações do processo, como a troca do valor de referência $i_{\alpha s}$, $i_{\beta s}$ e $i_{\alpha r}$, $i_{\beta r}$, durante a operação.

3.2 Senários de falhas

Analisando as equações do espaço de estados, mais precisamente a parte dos atuadores (matriz das 4 tensões em $\alpha\beta$) e considerando o que foi estabelecido com as tensões no rotor serem zero conclui-se que apenas falhas na tensão do estator ($v_{\alpha s}$ e $v_{\beta s}$) resultarão em mudanças nas correntes de saída do modelo ($i_{\alpha s}$, $i_{\beta s}$, $i_{\alpha r}$ e $i_{\beta r}$). Portanto, iremos simular falhas abruptas e falhas intermitentes somente nas tensões do estator. Será demonstrado que quanto há uma falha abrupta, é possível identificá-la somente olhando a alteração das correntes de saída. Para tal caso, serão simuladas as falhas a partir de 1s de simulação. As falhas serão somente geradas no regime permanente no sistema. Os gráficos dos resultados das tensões serão mostrados no sistema de coordenadas ABC, a fim de simular a visualização de um operador em um sistema de supervisão.

4. RESULTADOS

Nos resultados a seguir foram simuladas falhas na tensão do estator, especificamente na fase C. No primeiro caso, foi simulada uma falha que fixou a tensão em 350 V no intervalo de 1s até 2s. Já a segunda simulação apresenta uma falha intermitente na tensão do estator, fase C, onde a tensão é reduzida em 10% do seu valor nominal, porém essa redução acontece apenas por um instante e depois volta para a operação normal. Isso se repete ciclicamente no intervalo de 1s até 2s.

Todos os gráficos a seguir foram limitados no intervalo de tempo que vai de 0,94s até 1,07s. Esta limitação foi implementada apenas para uma melhor visualização dos gráficos deste artigo.

4.1 Falha Abrupta

É possível identificar na Figura 7 que há uma nítida mudança no padrão de comportamento dás três fases de corrente do estator a partir de 1s da simulação. Apesar do esforço do controle DTC, a mudança é perceptível. Na prática, caso um operador estivesse acompanhando a operação do DFIG, poderia identificar a falhas com essa mudança de comportamento.

Como era de se esperar, a saída do bloco de lógica difusa indica que há algum problema no sistema. Para exemplificar a identificação do problema, os dados foram agrupados na Tabela 4. Nesta tabela identifica-se em qual instante a probabilidade da falha ultrapassou 50% e qual foi a maior probabilidade, dentre os quatro cálculos de resíduo processados pela lógica difusa. Verificamos que $i_{\beta s}$ atingiu pela primeira vez uma probabilidade de 64% de falha a 1,2ms do início da falha. Essa mesma corrente apresentou uma probabilidade de 100% a 2,5ms da falha. As outras 3 correntes também indicaram uma probabilidade de falha alta, também atingindo 100% de probabilidade.

4.2 Falhas intermitentes

Já neste caso de falhas intermitentes (Figura 8), um operador não conseguiria identificar a falha na tensão da fase C, com uma queda intermitente de 10% ciclicamente

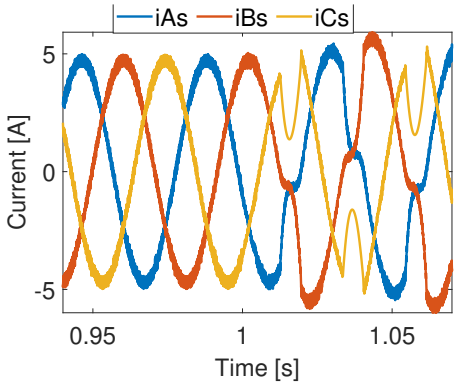

Figura 7. Falha Abrupta: Mudança de comportamento a partir de 1s nas correntes do estator.

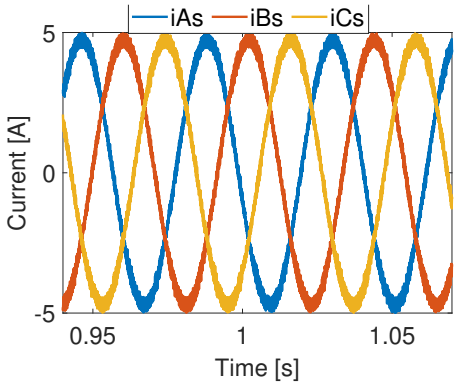

Figura 8. Falhas intermitentes: Não há uma mudança de comportamento a partir de 1s nas correntes do estator.

a partir de 1s. O controle DTC também ajuda a mascarar uma visualização dessa falha com a correção para esse desbalanceamento.

Por outro lado, o resultado da lógica difusa nos mostra que há uma grande probabilidade de haver uma falha. De acordo com os dados da Tabela 5, a maior probabilidade de falha foi de 66% após 22,1ms da falha com o resíduo da $i_{\alpha s}$. Também verifica-se que na $i_{\beta s}$, em apenas 9,5ms e com uma probabilidade de 65% de que há alguma falha no DFIG.

Tabela 4. Resultado falha abrupta.

	Probabilidade maior que 50%		Maior probabilidade	
	Probabilidade de falha	Tempo [s]	Probabilidade de falha	Tempo [s]
$i_{\alpha s}$	0,52	1,0018	1,00	1,0043
$i_{\beta s}$	0,64	1,0012	1,00	1,0025
$i_{\alpha r}$	0,53	1,0027	1,00	1,0055
$i_{\beta r}$	0,50	1,0015	1,00	1,0032

Tabela 5. Resultado falha intermitente.

	Probabilidade maior que 50%		Maior probabilidade	
	Probabilidade de falha	Tempo [s]	Probabilidade de falha	Tempo [s]
$i_{\alpha s}$	0,50	1,0105	0,66	1,0221
$i_{\beta s}$	0,55	1,0057	0,65	1,0095
$i_{\alpha r}$	0,52	1,0207	0,54	1,0251
$i_{\beta r}$	-	-	0,36	1,0104

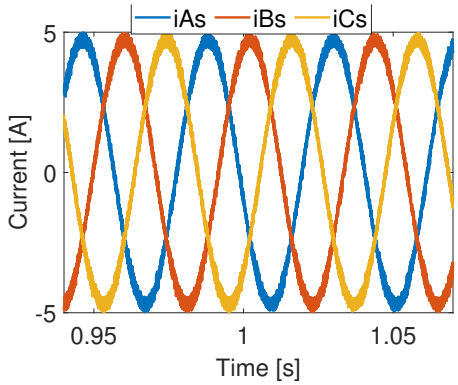

Figura 9. Falhas nas fases A, B e C: Não há uma mudança de comportamento a partir de 1s nas correntes do estator.

4.3 Falhas nas fases A, B e C

Além das duas falhas previamente simuladas, foi adicionado mais um cenário de falha. Nesta falha após 1s as tensões A, B e C diminuem 10% simultaneamente e permanece assim até o final da simulação. Da mesma forma que a falha intermitente, as correntes de saída não alteram o comportamento normal, conforme a Figura 9. Analisando os dados na Tabela 6, cujo dados são similares aos casos anteriores, é percebido que a detecção da falha é efetiva, porém a probabilidade máxima de falha é de 44% na corrente $i_{\beta s}$. Este comportamento é resultado do controle DTC, que consegue compensar essa falha nas três fases, minimizando o diagnóstico, porém através da lógica difusa, existe uma probabilidade de 65% de que há alguma falha no DFIG.

Tabela 6. Resultado falha nas fases ABC.

	Probabilidade maior que 50%		Maior probabilidade	
	Probabilidade de falha	Tempo [s]	Probabilidade de falha	Tempo [s]
$i_{\alpha s}$	-	-	0,17	1,0057
$i_{\beta s}$	-	-	0,44	1,0166
$i_{\alpha r}$	-	-	0,00	-
$i_{\beta r}$	-	-	0,00	-

Na Figura 11 o comportamento da saída da lógica difusa referente ao resíduo da $i_{\beta s}$ (Figura 10). Esse comportamento é diferente dos outros casos de falha, pois mostra a probabilidade de falha é um valor diferente de zero entre os instantes 1,01s e 1,03s. Na maior parte dos outros instantes, essa probabilidade é zero.

5. CONCLUSÕES

Os resultados alcançados mostram a viabilidade da metodologia empregada. A utilização de um limiar difuso na análise do sinal residual permite que exista uma discriminação entre o ruido, erros produzidos por fenômenos não modelados e a ocorrência de falhas. Como resultado, por meio da aplicação do método proposto foi possível identificar falhas, neste caso específico, falhas abruptas e intermitentes nos atuadores. Ao simular falhas intermitentes, não foi possível identificar a falha apenas verificando a saída do processo, mas sim olhando o resultado da lógica difusa. Já simulando uma falha abrupta, é possivel identificar tanto

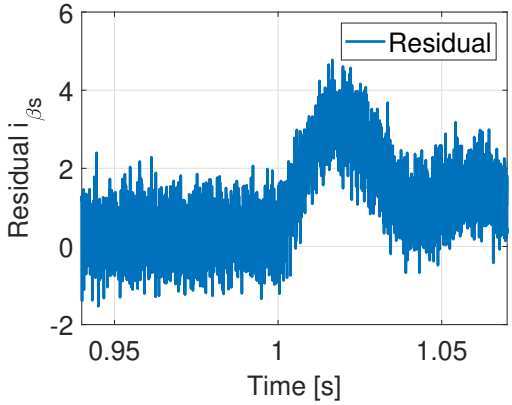

Figura 10. Resíduo da corrente $i_{\beta s}$ com a falhas nas fases A, B e C.

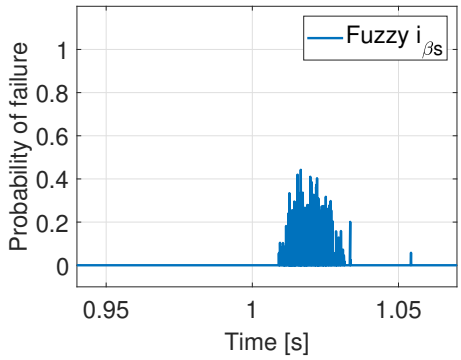

Figura 11. Saída da lógica difusa com a falhas nas fases A, B e C.

olhando a saída do processo quanto o resultado da lógica difusa.

Como trabalhos futuros, será planejado implementar novas falhas no processo e nos sensores, similareas aos mensionados em Hamza et al. (2023), com o propósito de desenvolver metodologias de diagnóstico mais abrangentes. Além disso, será realizado a classificação das falhas, similar aos trabalhos de Cuéllar et al. (2023) e Dawood et al. (2024). Com isso, não será apenas identificada a presença de falhas, mas também para localizá-las com precisão.

REFERÊNCIAS

Abad, G., Lopez Taberna, J., Rodriguez, M., Marroyo, L., and Iwanski, G. (2011). *Doubly Fed Induction Machine: Modeling and Control for Wind Energy Generation*, volume 86. John Wiley Sons, Ltd. doi:10.1002/9781118104965.

Cabeza, R. (2023). Diagnóstico de falhas baseado em modelos neurodifusos e avaliação residual com umbrales difusos aplicado a um sistema fotovoltaico. *UFABC*.

Cuéllar, J., Ramos, G., and Giraldo, L. (2023). Learning the geometry of short-circuit faults in power systems for real-time fault detection and classification. *IET Cyber-Physical Systems: Theory Applications*, 8, n/a–n/a. doi:10.1049/cps2.12074.

Dawood, A., Hasaneen, B., and Abdel-Aziz, A. (2024). Design of an efficient neural network model for detection and classification of phase loss faults for three-phase induction motor. *Neural Computing and Applications*, 36, 1–19. doi:10.1007/s00521-023-09387-y.

Elshenawy, L., Gafar, A., Awad, H., and AbouOmar, M. (2024). Fault detection of wind turbine system based on data-driven methods: a comparative study. *Neural Computing and Applications*, 36, 1–18. doi:10.1007/s00521-024-09604-2.

Frank, P. and Ding, X. (1997). Survey of robust residual generation and evaluation methods in observer-based fault detection systems. *Journal of Process Control*, 7, 403–424. doi:10.1016/S0959-1524(97)00016-4.

G. Abad, J. López, M.A.R.L.M.G.I. (2011). *Doubly Fed Induction Machine*. John Wiley & Sons, Inc.

Hamza, T., Ganouche, A., AHMIDA, Z., hacene, B., and Tachi, F. (2023). Real-time current sensor fault detection and localization in dfig wind turbine systems. *International Journal of Power Electronics and Drive Systems (IJPEDS)*, 14. doi:10.11591/ijpeds.v14.i4.pp2388-2397.

Isermann, R. (2006). Fault-diagnosis systems. Springer Berlin, Heidelberg.

Merabet, H., Tahar, B., and Noura, H. (2015). Condition monitoring and fault detection in wind turbine based on dfig by the fuzzy logic. *Energy Procedia*, 74, 518–528. doi:10.1016/j.egypro.2015.07.737.

Sguarezi, A. (2022). *Model Predictive Control for Doubly-Fed Induction Generators and Three-Phase Power Converters*. Elsevier Science. URL `https://books.google.com.br/books?id=LRyOzgEACAAJ`.