

Armando Souza Guedes

**ESTUDO E PROPOSIÇÃO DE TÉCNICAS  
PARA A AVALIAÇÃO DO ISOLAMENTO EM  
MOTORES DE INDUÇÃO TRIFÁSICOS DE  
BAIXA E MÉDIA TENSÃO**

Belo Horizonte

Março de 2018



Armando Souza Guedes

# **ESTUDO E PROPOSIÇÃO DE TÉCNICAS PARA A AVALIAÇÃO DO ISOLAMENTO EM MOTORES DE INDUÇÃO TRIFÁSICOS DE BAIXA E MÉDIA TENSÃO**

Texto da Tese de Doutorado submetida ao Curso de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica.

UNIVERSIDADE FEDERAL DE MINAS GERAIS  
PROGRAMA DE PÓS-GRADUAÇÃO  
EM ENGENHARIA ELÉTRICA

Orientador: Prof. Dr. Sidelmo Magalhães Silva

Belo Horizonte

Março de 2018

G924e

Guedes, Armando Souza.

Estudo e proposição de técnicas para a avaliação do isolamento em motores de indução trifásicos de baixa e média tensão [manuscrito] / Armando Souza Guedes. - 2018.

210 f., enc.: il.

Orientador: Sidelmo Magalhães Silva.

Tese (doutorado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 202-210.

Bibliografia: f. 191-200.

1. Engenharia elétrica - Teses. 2. Inteligência computacional - Teses. 3. Motores elétricos de indução - Teses. I. Silva, Sidelmo Magalhães. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 621.3(043)



**"Estudo e Proposição de Técnicas Para A Avaliação do Isolamento Em Motores de Indução Trifásicos de Baixa e Média Tensão"**

**Armando Souza Guedes**

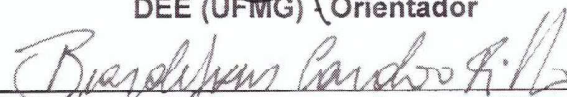
Tese de Doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Doutor em Engenharia Elétrica.

Aprovada em 22 de março de 2018.

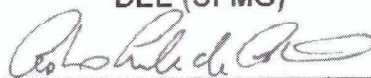
Por:



Prof. Dr. Sidelmo Magalhães Silva  
DEE (UFMG) Orientador



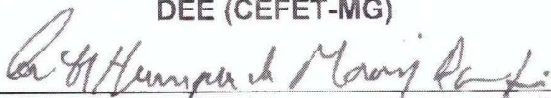
Prof. Dr. Braz de Jesus Cardoso Filho  
DEE (UFMG)



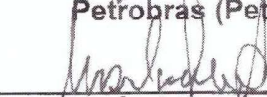
Prof. Dr. Cristiano Leite de Castro  
DEE (UFMG)



Prof. Dr. Anderson Vagner Rocha  
DEE (CEFET-MG)



Prof. Dr. Carlos Henrique de Moraes Bomfim  
Petrobras (Petrobras)



Prof.ª Dr.ª Úrsula do Carmo Resende  
DEE (CEFET-MG)



*Este trabalho é dedicado ao meu querido pai e ao meu sogro,  
exemplos de dedicação, trabalho e amor à família.*



# Agradecimentos

À minha amada esposa Camila por sempre ter me apoiado e incentivado para vencer mais um desafio.

Aos meus queridos e amados filhos Davi e Luísa que são a luz da minha vida.

Ao meu orientador Professor Dr. Sidelmo Magalhães Silva, pelos anos de apoio e orientação, sem os quais este trabalho não teria sido realizado.

Aos colegas do laboratório TESLA/UFMG, por toda a troca de experiências e conhecimentos, em especial aos amigos Reginaldo Vagner e Cláudio Conceição.

À gerência de manutenção de elétrica e instrumentação da REGAP-Petrobras pelo apoio para a realização deste trabalho.

Muito Obrigado!



# Resumo

Referências apontam que a segunda maior causa de falhas em Motores de Indução Trifásicos (MIT) é a baixa Resistência de Isolamento ( $R_I$ ) do estator para terra. Para a identificação desse problema em MITs de Baixa Tensão (BT) e Média Tensão (MT), a maioria dos setores de manutenção elétrica industriais, contam apenas com ferramentas preditivas que são aplicadas quando o motor não está em operação (*off-line*), como em paradas programadas de manutenção da planta. As técnicas aplicadas são a medição da  $R_I$  com um megôhmetro e o cálculo dos Índices de Polarização ( $IP$ ) e Absorção ( $IA$ ), cuja avaliação limita-se a uma abordagem de “aprovado” ou “não aprovado”, sem realizar nenhuma inferência sobre fatores de estresse aos quais o isolamento do motor possa estar submetido. Neste contexto, o presente trabalho apresenta técnicas preditivas promissoras para o diagnóstico e a identificação de falhas no isolamento de MITs de BT e MT com o motor desenergizado (*off-line*) e com a máquina em operação (*on-line*), cuja abordagem não é afetada pelo não cumprimento dos planos de manutenção que necessitam da parada do equipamento.

A utilização de Inteligência Computacional (IC) para o diagnóstico de falhas em MITs está se tornando cada vez mais popular, apresentando ótimos resultados quando comparada com as metodologias tradicionais. Desta forma, com o emprego de Redes Neurais Artificiais (RNA) são propostos classificadores *on-line* e *off-line* para a determinação dos fatores de estresse e um preditor para o Tempo de Falha ( $TF$ ) do isolamento do estator. Os resultados do classificador *off-line* mostra que é possível identificar com boa acurácia o fator de estresse e avaliar a condição de operação do motor a partir da  $R_I$  e dos índices  $IP$  e  $IA$ . Utilizando-se como entradas para o classificador *on-line* as componentes resistivas e capacitivas da corrente de fuga  $I_L$ , demonstra-se que também é possível acompanhar e avaliar o estado do isolamento de forma *on-line* para uma operação confiável do motor.

Os testes experimentais *on-line* mostram bons resultados da metodologia para a classificação do fator de estresse e para a previsão do  $TF$  do isolamento do motor. Baseado nestes resultados, os gestores, os técnicos e os engenheiros de manutenção terão suporte suficiente para a tomada de decisão a respeito da continuidade operacional do MIT e a realização adequada de sua manutenção. Assim, as novas técnicas apresentadas neste trabalho contribuirão de forma significativa para o aumento da confiabilidade e disponibilidade operacional destes equipamentos.

**Palavras-chaves:** Resistência de Isolamento. Motor de Indução Trifásico. Inteligência Computacional.



# Abstract

Studies indicate that the second most important cause of failures in Induction Motors (IMs) is the low Resistance to Ground ( $R_G$ ) of the stator insulation. To identify this problem in Low and Medium Voltage (LV, MV) IMs, most of the departments of industrial electrical maintenance uses only predictive tools that are applied when the motor is out of service, as during a plant maintenance shutdown. The evaluation techniques commonly used are the measurement of the  $R_G$  using a megohmmeter and the calculation of the Polarization and Absorption Index ( $PI$ ,  $AI$ ), whose results are limited the status of “approved” or “not approved”, without any inference about stress that the motor insulation may be subjected to. In this context, this work presents promising predictive techniques for the evaluation of the insulation of LV and MV IMs when the motor is out of service (off-line) or in operation (on-line), whose approach is not affected by no-execution of maintenance plans that require of the equipment shutdown.

The use of Computational Intelligence (IC) to diagnose failures in IMs is becoming increasingly popular, presenting excellent results when compared to traditional methodologies. In this way, an Artificial Neural Networks (ANN) are proposed to classify the stress factors, along with a predictor for the Time to Failure ( $TF$ ) of the stator insulation. The results of the off-line classifier show that it is possible to identify with good accuracy the stress factor and evaluate the motor operating condition from  $R_G$  and  $PI$  and  $AI$  indexes. Using as inputs for on-line classifier the measuring of the resistive and capacitive components of the leakage current  $I_L$ , shows that it is also possible to monitor and evaluate the insulation state on-line for a reliable motor operation.

The on-line experimental tests show good results for the classification of the stress factor and for the prediction of  $TF$  of the motor insulation. Based on these results, managers, technicians and maintenance engineers will have sufficient support for decision about the operational continuity of the motor and its proper maintenance. Thus, the new techniques presented in this work will contribute significantly to increasing the reliability and operational availability of these equipments.

**Keywords:** *Resistance to Ground. Induction Motor. Computational Intelligence.*



# Lista de figuras

Figura 1.1 – Diagrama esquemático para a avaliação do isolamento de MITs de MT através da medição das correntes de fuga nas três fases. . . . .	30
Figura 2.1 – Decomposição da corrente $I_T$ durante o ensaio para medição da $R_I$ . . .	39
Figura 2.2 – Circuito típico para medição <i>off-line</i> de DPs. . . . .	43
Figura 2.3 – Resultado típico de isolamento apresentado descargas parciais internas. . .	45
Figura 2.4 – Resultado típico de isolamento apresentado descargas parciais nas ranhuras ( <i>slots</i> ) do núcleo. . . . .	45
Figura 2.5 – Resultado típico de isolamento apresentado descargas parciais externas. . .	45
Figura 2.6 – a) Circuito equivalente para o isolamento do MIT. b) Diagrama fasorial de tensões e correntes do isolamento para o cálculo do $FD$ . . . . .	46
Figura 2.7 – Exemplo de uma série de medições de $FD$ para determinação do $FD_{TV}$ . . . . .	48
Figura 2.8 – Pulso de tensão padronizado pelo IEEE Std-522 para o <i>Surge Test</i> . . . . .	52
Figura 2.9 – Exemplos de formas de ondas típicas esperadas no <i>Surge Test</i> . . . . .	53
Figura 2.10 – Circuito padrão para a medição <i>on-line</i> das descargas parciais. . . . .	54
Figura 2.11 – Circuito diferencial para a medição <i>on-line</i> das descargas parciais. . . . .	55
Figura 2.12 – Circuito para a medição <i>on-line</i> das descargas parciais com RFTCs. . . . .	55
Figura 2.13 – Esquema para a medição <i>on-line</i> das descargas parciais com uso de antenas nas cabeças de bobinas. . . . .	56
Figura 2.14 – Avaliação <i>on-line</i> do isolamento com 3 HSCTs e 3 TPs. . . . .	57
Figura 2.15 – Sistema de monitoramento <i>on-line</i> MSIM da GE para MITs de MT [45]. . . . .	57
Figura 2.16 – Circuito equivalente do isolamento em c.a. adaptado de Lee e Younsi [12, 25, 26]. . . . .	58
Figura 2.17 – Circuito equivalente por fase para o teste <i>off-line</i> em c.c. [25]. . . . .	60
Figura 2.18 – Circuito para a proteção de falta a terra de MITs (ANSI 50GS). . . . .	61
Figura 3.1 – Foto de uma bobina <i>random</i> montada no estator de um MIT de BT [69]. . . . .	70
Figura 3.2 – Foto de uma bobina <i>form</i> montada no estator de um MIT de MT [69]. . . . .	70
Figura 3.3 – Sistema de isolamento de uma bobina do tipo <i>random</i> [68]. . . . .	71
Figura 3.4 – Processo de impregnação por imersão de MITs de BT construídos por bobinas <i>random</i> [69]. . . . .	72
Figura 3.5 – Sistema de isolamento de uma bobina do tipo <i>form</i> [68]. . . . .	72
Figura 3.6 – Etapas do processo de VPI em MITs de MT [70]. . . . .	73
Figura 3.7 – Estatística dos fatores de estresse e causas de falhas no isolamento do estator de grandes MITs [74–76]. . . . .	79
Figura 3.8 – Pinos de lubrificação de rolamentos de um MIT de BT [69]. . . . .	83
Figura 3.9 – Sistema automático de lubrificação de MITs [69]. . . . .	83
Figura 3.10 – <i>Boxplot</i> das curvas de PRI de motores com isolamento bom. . . . .	92

Figura 3.11– <i>Boxplot</i> das curvas de PRI de motores apresentando umidade no isolamento. . . . .	92
Figura 3.12– <i>Boxplot</i> das curvas de PRI de motores apresentando contaminação por óleo/sujeira no isolamento. . . . .	93
Figura 3.13– <i>Boxplot</i> das curvas de PRI de motores sob ação térmica no isolamento. . . . .	93
Figura 3.14–Gráfico com as curvas de PRI que representam o centroide de cada agrupamento realizado pelo algoritmo <i>K-means</i> . . . . .	94
Figura 3.15–Estator de um motor com isolamento em bom estado. . . . .	95
Figura 3.16–Curva de PRI típica de um motor com o isolamento em bom estado a $40^{\circ}C$ . . . . .	95
Figura 3.17–Estator de um motor com o isolamento apresentando umidade. . . . .	96
Figura 3.18–Curva de PRI de um MIT em processo de absorção de umidade a $40^{\circ}C$ . . . . .	97
Figura 3.19–Estator de um motor com o isolamento apresentando degradação térmica. . . . .	98
Figura 3.20–Curva de PRI de um MIT apresentando degradação térmica a $40^{\circ}C$ . . . . .	98
Figura 3.21–Estator de um motor com o isolamento contaminado por óleo/sujeira. . . . .	99
Figura 3.22–Curva de PRI de um MIT apresentando contaminação por óleo/sujeira a $40^{\circ}C$ . . . . .	99
Figura 3.23–Arquitetura da RNA para a avaliação do isolamento do estator <i>off-line</i> . . . . .	101
Figura 3.24–Resultado da classificação e da avaliação do isolamento dos MITs no processo de validação realizada pela RNA3. . . . .	104
Figura 3.25–Classificação dos dados do Apêndice A e limites para <i>IP</i> e <i>IA</i> . . . . .	105
Figura 4.1 – Diagrama proposto para a avaliação do isolamento a partir da medição de $\dot{I}_0$ . . . . .	109
Figura 4.2 – Circuito equivalente simplificado para a avaliação do isolamento a partir da medição de $\dot{I}_0$ . . . . .	109
Figura 4.3 – Decomposição da corrente $\dot{I}_0$ em função das parcelas de corrente resistiva ( $\dot{I}_{a,b,cL-R}$ ) e capacitiva ( $\dot{I}_{a,b,cL-C}$ ) por fase. . . . .	110
Figura 4.4 – Decomposição da corrente $\dot{I}_0$ através das parcelas resistivas e capacitivas por fase. . . . .	111
Figura 4.5 – Identificação da fase em processo de degradação do isolamento em função da localização do ângulo $\theta_0$ . . . . .	113
Figura 4.6 – Erro de aproximação e ângulo esperados para um isolamento absorvendo umidade. . . . .	116
Figura 4.7 – Erro de aproximação e ângulo esperados para um isolamento afetado por estresse térmico. . . . .	117
Figura 4.8 – Erro de aproximação e ângulo esperados para um isolamento contaminado por óleo e sujeira. . . . .	118
Figura 4.9 – Arquitetura da RNA proposta para avaliação do isolamento do estator <i>on-line</i> . . . . .	121

Figura 4.10–Separação realizada pelo classificador <i>on-line</i> para os dados de validação.	121
Figura 4.11–Separação realizada pelo classificador <i>on-line</i> para os dados dos 88 motores utilizados na validação e treinamento da rede. . . . .	122
Figura 4.12–Visualização das classes dos 88 motores utilizados na validação e treinamento do classificador <i>on-line</i> . . . . .	122
Figura 5.1 – Circuito do sensor HSCT. . . . .	127
Figura 5.2 – Diagrama de blocos do sensor HSCT. . . . .	127
Figura 5.3 – Resultado de simulação para $I_p = 1\mu A$ para o modelo proposto para o HSCT. . . . .	128
Figura 5.4 – Resultado de simulação para $I_p = 2mA$ para o modelo proposto para o HSCT. . . . .	129
Figura 5.5 – Erro (exatidão) e ângulo do HSCT após uso da técnica de SAR. . . . .	131
Figura 5.6 – Resposta em frequência do HSCT. . . . .	131
Figura 5.7 – Diagrama de blocos do sistema de medição e dos circuitos de alimentação, condicionamento e processamento dos sinais. . . . .	132
Figura 5.8 – Gráfico de medição instantânea dos ruídos captados pelo HSCT e pelo sistema de SAR após processamento para corrente primária $I_p = 0\mu A$ .	135
Figura 5.9 – Gráfico de medição instantânea das correntes medidas pelo HSCT e pelo sistema de SAR após processamento para corrente primária $I_p = 1\mu A$ .	136
Figura 5.10–Diagrama de blocos do Detector de Fase (DF) utilizado no FB-PLL. . . . .	136
Figura 5.11–Diagrama de blocos da Análise Dinâmica de Fourier (ADF) do FB-PLL.	137
Figura 5.12–Diagrama de blocos do Sistema de Monitoramento <i>On-line</i> para o Isolamento de MITs de BT e MT - SIMOI. . . . .	138
Figura 5.13–Fotografia da montagem experimental para testes do SIMOI. . . . .	139
Figura 5.14–Estufa, painel de alimentação e sistema de injeção de névoa. . . . .	140
Figura 5.15–Placas eletrônicas, interface gráfica do SIMOI, sensor HSCT e antena do sistema de SAR. . . . .	140
Figura 5.16–Corrente $I_0$ e ângulo $\theta_0$ do teste <i>on-line</i> de envelhecimento acelerado. . . . .	143
Figura 5.17–Correntes $I_R$ e $I_C$ do teste <i>on-line</i> de envelhecimento acelerado. . . . .	143
Figura 5.18–Fator de Dissipação $FD_{eq}$ do teste <i>on-line</i> de envelhecimento acelerado.	144
Figura 5.19–Fotografia do estator do MIT após o teste <i>on-line</i> de envelhecimento acelerado. . . . .	144
Figura 5.20–Foto da montagem dos tubos de injeção de água e do termopar no motor.	146
Figura 5.21–Corrente $I_0$ e ângulo $\theta_0$ do teste <i>on-line</i> de absorção de umidade. . . . .	148
Figura 5.22–Correntes $I_R$ e $I_C$ do teste <i>on-line</i> de absorção de umidade. . . . .	149
Figura 5.23–Fator de Dissipação $FD_{eq}$ do teste <i>on-line</i> de absorção de umidade. . . . .	149
Figura 5.24–Amostras de óleos de lubrificação de motores da REGAP-Petrobras. . . . .	150
Figura 5.25–Foto do estator do motor após o fim do teste de contaminação e após sua limpeza e secagem. . . . .	153

Figura 5.26–Corrente $I_0$ e ângulo $\theta_0$ do teste <i>on-line</i> de contaminação. . . . .	154
Figura 5.27–Correntes $I_R$ e $I_C$ do teste <i>on-line</i> de contaminação. . . . .	154
Figura 5.28–Fator de Dissipação $FD_{eq}$ do teste <i>on-line</i> de contaminação. . . . .	155
Figura 6.1 – Gráfico da série temporal da corrente $I_R$ do motor que sofreu falha no isolamento devido ao estresse térmico. . . . .	159
Figura 6.2 – Gráfico da série temporal da corrente $I_R$ do motor que sofreu falha no isolamento devido à absorção de umidade. . . . .	160
Figura 6.3 – Gráfico da série temporal da corrente $I_R$ do motor que sofreu falha no isolamento devido à contaminação por óleo. . . . .	160
Figura 6.4 – Correlogramas da série temporal da corrente $I_R$ do motor que sofreu falha no isolamento devido ao estresse térmico. . . . .	162
Figura 6.5 – Correlogramas da série temporal da corrente $I_R$ do motor que sofreu falha no isolamento devido à absorção de umidade. . . . .	163
Figura 6.6 – Correlogramas da série temporal da corrente $I_R$ do motor que sofreu falha no isolamento devido à contaminação por óleo. . . . .	163
Figura 6.7 – Gráficos das correntes $I_R$ observada, filtrada e transformada do motor que sofreu falha no isolamento devido ao estresse térmico. . . . .	167
Figura 6.8 – Gráficos das correntes $I_R$ observada, filtrada e transformada do motor que sofreu falha no isolamento devido à absorção de umidade. . . . .	167
Figura 6.9 – Gráficos das correntes $I_R$ observada, filtrada e transformada do motor que sofreu falha no isolamento devido à contaminação por óleo. . . . .	168
Figura 6.10–Correlogramas das funções FAC e FAP da corrente $I_R$ transformada do motor que sofreu falha no isolamento devido ao estresse térmico. . . . .	168
Figura 6.11–Correlogramas das funções FAC e FAP da corrente $I_R$ transformada do motor que sofreu falha no isolamento devido à absorção de umidade. . . . .	168
Figura 6.12–Correlogramas das funções FAC e FAP da corrente $I_R$ transformada do motor que sofreu falha no isolamento devido à contaminação por óleo. . . . .	169
Figura 6.13–Fluxograma para a seleção do modelo ARMA( $p, q$ ) a partir dos critérios de informação de Akaike e Bayesiano. . . . .	171
Figura 6.14–Gráficos de previsão do modelo ARMA para a série de corrente $I_R$ até a falha do isolamento do motor submetido ao estresse térmico. . . . .	173
Figura 6.15–Gráficos de previsão do modelo ARMA para a série de corrente $I_R$ até a falha do isolamento do motor submetido à absorção de umidade. . . . .	174
Figura 6.16–Gráficos de previsão do modelo ARMA para a série de corrente $I_R$ até a falha do isolamento do motor submetido à contaminação por óleo. . . . .	175
Figura 6.17–Exemplo de partição dos dados da série transformada nos conjuntos de treinamento e validação para as RNAs. . . . .	178
Figura 6.18–Fluxograma para a seleção da RNA a ser utilizada para estimar as correntes $I_R$ e prever o $TF$ do isolamento. . . . .	179

Figura 6.19–Diagrama de blocos do preditor utilizando RNAs. . . . .	180
Figura 6.20–Gráficos de previsão do modelo RNA para a série de corrente $I_R$ até a falha do isolamento do motor submetido ao estresse térmico. . . . .	181
Figura 6.21–Gráficos de previsão do modelo RNA para a série de corrente $I_R$ até a falha do isolamento do motor submetido à absorção de umidade. . . . .	182
Figura 6.22–Gráficos de previsão do modelo RNA para a série de corrente $I_R$ até a falha do isolamento do motor submetido à contaminação por óleo. . . . .	183
Figura 6.23–RMSE e EPTF dos modelos ARMA e RNA para o motor submetido a falha no isolamento devido ao estresse térmico. . . . .	184
Figura 6.24–RMSE e EPTF dos modelos ARMA e RNA para o motor submetido a falha no isolamento devido à absorção de umidade. . . . .	185
Figura 6.25–RMSE e EPTF dos modelos ARMA e RNA para o motor submetido a falha no isolamento devido à contaminação por óleo. . . . .	185



# Lista de tabelas

Tabela 1.1 – Resumo do levantamento de defeitos/falhas em MITs de jan/2010 a fev/2015 na REDUC. . . . .	32
Tabela 1.2 – Defeitos/falhas elétricas em MITs de jan/2010 a fev/2015 por classe de tensão na REDUC. . . . .	33
Tabela 2.1 – Guia para a aplicação de tensão c.c. para o teste de medição de resistência de isolamento. . . . .	38
Tabela 2.2 – Valores mínimos de $R_I$ recomendados a $40^{\circ}C$ . . . . .	40
Tabela 2.3 – Valores mínimos padronizados do $IP$ e do $IA$ . . . . .	41
Tabela 2.4 – Valores do $IP$ e do $IA$ recomendados por fabricantes de MITs. . . . .	41
Tabela 2.5 – Resumo dos diagnósticos obtidos a partir da medição da $C_I$ e da $C_{TV}$ . . . . .	49
Tabela 2.6 – Valores de tensão e tempo para a realização do teste de <i>Hipot</i> c.c. . . . .	50
Tabela 2.7 – Valores de tensão e tempo para a realização do teste de <i>Hipot</i> c.a. . . . .	51
Tabela 2.8 – Ajustes recomendados para a função de proteção 50GS. . . . .	61
Tabela 3.1 – Valores típicos de $K$ e $n$ de isolantes novos a base de epoxi, mica e poliéster. . . . .	75
Tabela 3.2 – Classe térmica do isolamento. . . . .	80
Tabela 3.3 – Quantitativo de motores por potência e classe de tensão do banco de dados (Apêndice A). . . . .	89
Tabela 3.4 – Rotulação feita para os grupos resultantes do <i>K-means</i> . . . . .	94
Tabela 3.5 – Testes do motor MVE104 exemplificando uma curva de PRI de um motor em bom estado. . . . .	96
Tabela 3.6 – Testes do motor MP1328 em bom estado e apresentando umidade. . . . .	97
Tabela 3.7 – Testes do motor AGM1 em bom estado e apresentando degradação térmica. . . . .	98
Tabela 3.8 – Testes do motor MP102B em bom estado e contaminado por óleo/sujeira. . . . .	100
Tabela 3.9 – Acurácia por classe no treinamento e validação para as redes RNA3, RNA4 e RNA5. . . . .	103
Tabela 3.10–Acurácia Média, Falsos Positivos e Negativos das RNAs. . . . .	103
Tabela 3.11–Comparação entre as performance das RNAs. . . . .	103
Tabela 3.12–Limites do $IP$ e do $IA$ por classe para as RNAs. . . . .	105
Tabela 4.1 – Medição de resistência e de capacitância por fase de MITs da REDUC [27]. . . . .	110
Tabela 4.2 – Quadro resumo para a determinação de $I_R$ , $I_C$ , $R_{eq}$ , $C_{eq}$ e $FD_{eq}$ para a avaliação <i>on-line</i> do isolamento a partir de $\dot{I}_0$ . . . . .	115
Tabela 4.3 – Resultados de simulação para a avaliação do erro considerando desequilíbrios nas correntes do isolamento em mais de uma fase. . . . .	119
Tabela 4.4 – Limites de $C_I$ e $FD$ por classe para o classificador <i>on-line</i> proposto. . . . .	123

Tabela 5.1 – Resultados dos testes <i>off-line</i> para o motor submetido ao estresse térmico.	141
Tabela 5.2 – Resultados dos testes <i>on-line</i> para o motor submetido ao estresse térmico.	142
Tabela 5.3 – Resistividade e permeabilidade de alguns tipos de água que podem ser absorvidas pelo isolamento. . . . .	145
Tabela 5.4 – Resultados dos testes <i>off-line</i> para o motor submetido a absorção de umidade. . . . .	146
Tabela 5.5 – Resultados dos testes <i>on-line</i> para o motor submetido a absorção de umidade. . . . .	147
Tabela 5.6 – Resistividade e permeabilidade de óleos lubrificantes que podem contaminar o isolamento. . . . .	150
Tabela 5.7 – Resultados dos testes <i>off-line</i> para o motor submetido a contaminação por óleo. . . . .	151
Tabela 5.8 – Resultados dos testes <i>on-line</i> para o motor submetido a contaminação por óleo. . . . .	152
Tabela 6.1 – Quadro resumo para a identificação de modelos tentativos ARMA( $p, q$ ) a partir da inspeção visual dos correlogramas das funções FAC e FACP.	169
Tabela A.1 – Dados de testes e classificação do mecanismo de falha de motores da REDUC. . . . .	202

# Lista de abreviaturas e siglas

ADC	<i>Analogic Digital Converter</i>
ADP	Análise de Descargas Parciais
AEC	Assinatura Elétrica de Corrente
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
AOP	Amplificador Operacional
AR	<i>Auto Regressive</i>
ARMA	<i>Auto Regressive Moving Average</i>
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
AT	Alta Tensão
BT	Baixa Tensão
c.a	Corrente Alternada
CART	<i>Classification and Regression Tree</i>
c.c.	Corrente Contínua
CCM	Centro Controle de Motores
DP	Descargas Parciais
EPTF	Erro de Previsão do Tempo de Falha
FAC	Função de Auto Correlação
FACP	Função de Auto Correlação Parcial
FB-PLL	<i>Fourier-Based Phase-Locked Lopp</i>
FMM	<i>Fuzzy Max-Min</i>
IC	Inteligência Computacional
HSCT	<i>High Sensitivity Current Transformer</i>
MCC	Manutenção Centrada em Confiabilidade

MIT	Motor de Indução Trifásico
MLP	<i>Multilayer Perceptron</i>
MAE	<i>Mean Absolute Error</i>
MSE	<i>Mean Square Error</i>
NARMA	<i>Nonlinear Auto Regressive Moving Average</i>
RMSE	<i>Root Mean Square Error</i>
MSIM	<i>Motor Stator Insulation Monitor</i>
MTBF	<i>Mean Time Between Failure</i>
MT	Média Tensão
PDIV	<i>Partial Discharge Inception Voltage</i>
PRI	Perfil da Resistência de Isolamento
p.u.	por unidade
RBF	<i>Radial Basis Function</i>
RF	Rádio Frequência
RFCT	<i>Radio Frequency Current Transformer</i>
RIPPER	<i>Repeated Incremental Pruning to Produce Error Reduction</i>
RNA	Redes Neurais Artificiais
SAR	Supressão Ativa de Ruído
SMO	<i>Sequential Minimal Optimization;</i>
SMOI	Sistema de Monitoramento <i>On-line</i> do Isolamento
SVM	<i>Support Vector Machines</i>
TC	Transformador de Corrente
TP	Transformador de Potencial
TRIP	Referente ao desligamento de um equipamento
VPI	<i>Vacuum Pressure Impregnation</i>

# Lista de símbolos

$AIC$	Critério informacional de Akaike
$BIC$	Critério informacional Bayesiano
$C_I$	Capacitância do Isolamento ( $pF$ )
$C_{eq}$	Capacitância Equivalente do Isolamento ( $pF$ )
$C_{TU}$	Capacitância <i>Tip-Up</i> do Isolamento ( $pF$ )
$FD$	Fator de Dissipação do Isolamento
$FD_{eq}$	Fator de Dissipação Equivalente do Isolamento
$FD_{TU}$	Fator de Dissipação <i>Tip-Up</i> do Isolamento
$FP$	Fator de Potência do Isolamento
$FP_{TU}$	Fator de Potência <i>Tip-Up</i> do Isolamento
$I_0$	Corrente de Sequência Zero ( $\mu A$ )
$I_{0R}$	Parcela resistiva da corrente $I_0$ ( $\mu A$ )
$I_{0C}$	Parcela capacitiva da corrente $I_0$ ( $\mu A$ )
$IA$	Índice de Absorção
$I_C$	Corrente Capacitiva do Isolamento ( $\mu A$ )
$I_G$	Corrente Condutiva do Isolamento ( $\mu A$ )
$I_L$	Corrente de Fuga do Isolamento ( $\mu A$ )
$I_P$	Corrente de Polarização do Isolamento ( $\mu A$ )
$IP$	Índice de Polarização
$I_{Pick-up}$	Valor de corrente que inicia a atuação do réle de proteção ( $A$ )
$I_R$	Corrente Resistiva do Isolamento ( $\mu A$ )
$K_T$	Coefficiente de correção da $R_I$ em função da temperatura
$lag$	Unidade de atraso de tempo adotado para previsão ( <i>horas</i> )

$Q_+$	Carga provenientes de DP positivas ( $pC$ )
$Q_-$	Carga provenientes de DP negativas ( $pC$ )
$Q_T$	Carga total provenientes de DP ( $pC$ )
$R_{eq}$	Resistência Equivalente do Isolamento ( $M\Omega$ )
$R_I$	Resistência de Isolamento ( $M\Omega$ )
$T$	Temperatura ( $^{\circ}C$ )
$TF$	Tempo de Falha ( <i>horas</i> )
$U_i$	Pulso de tensão gerada por uma DP ( $mV$ )
$U_N$	Tensão eficaz nominal de fase-neutro ( $V$ )
$U_{N-FF}$	Tensão eficaz nominal de fase-fase ( $V$ )
$\alpha$	Referente ao eixo direto
$\beta$	Referente ao eixo em quadratura
$\gamma$	Função de Autocovariância amostral
$\epsilon$	Permissividade elétrica ( $F/m$ )
$\theta_0$	Ângulo de fase da Corrente $I_0$ ( $^{\circ}$ )
$\theta_r$	Ângulo de fase da medição do ruído ( $^{\circ}$ )
$\theta_a$	Ângulo de fase da tensão $U_a$ ( $^{\circ}$ )
$\mu$	Média amostral
$\rho$	Resistividade elétrica ( $\Omega m$ )
$\sigma$	Condutividade elétrica ( $S/m$ )
$\psi$	Função de Autocorrelação amostral

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>27</b>
<b>1.1</b>	<b>Relevância</b>	<b>27</b>
<b>1.2</b>	<b>Justificativa</b>	<b>31</b>
<b>1.3</b>	<b>Propostas, Objetivos e Contribuições</b>	<b>34</b>
<b>1.4</b>	<b>Organização do Trabalho</b>	<b>35</b>
<b>1.5</b>	<b>Conclusões</b>	<b>36</b>
<b>2</b>	<b>TÉCNICAS PARA A AVALIAÇÃO DO ISOLAMENTO DE MITs</b>	<b>37</b>
<b>2.1</b>	<b>Técnicas <i>Off-line</i> para a Avaliação do Isolamento de MITs</b>	<b>37</b>
2.1.1	Teste de $R_I$ e Cálculo de $IP$ e do $IA$	38
2.1.2	Análise de Descargas Parciais <i>Off-Line</i>	41
2.1.3	Medição do $FD$ e do $FD_{TU}$	46
2.1.4	Medição da $C_I$ e da $C_{TU}$	48
2.1.5	Teste de Tensão Aplicada <i>Hipot c.c.</i> e <i>Hipot c.a.</i>	50
2.1.6	<i>Surge Test</i>	51
<b>2.2</b>	<b>Técnicas <i>On-line</i> para a Avaliação do Isolamento de MITs</b>	<b>53</b>
2.2.1	Análise de Descargas Parciais <i>On-line</i>	54
2.2.2	Medição da Corrente de Fuga por Fase com HSCTs	56
2.2.3	Proteção <i>Ground Sensor</i>	60
<b>2.3</b>	<b>Utilização de Redes Neurais para o Diagnóstico de Falhas em MITs</b>	<b>62</b>
<b>2.4</b>	<b>Conclusões</b>	<b>66</b>
<b>3</b>	<b>DESENVOLVIMENTO DE TÉCNICAS <i>OFF-LINE</i> PARA A AVALIAÇÃO DO ISOLAMENTO</b>	<b>69</b>
<b>3.1</b>	<b>Modelo do Isolamento de MITs</b>	<b>69</b>
3.1.1	Isolamento de MITs de BT e MT	69
3.1.2	Modelo do Isolamento no Domínio do Tempo Submetido a Tensão c.c. e c.a.	74
<b>3.2</b>	<b>Fatores de Estresse e Mecanismos de Degradação do Isolamento</b>	<b>78</b>
3.2.1	Estresse Térmico	79
3.2.2	Fatores Ambientais	81
3.2.2.1	Absorção de Umidade	82
3.2.2.2	Contaminação por Óleo	82
3.2.3	Estresse Elétrico	84
3.2.4	Fatores Mecânicos	84
3.2.5	Fatores de Estresse em MITs de BT e MT Alimentados Diretamente pela Rede	85

<b>3.3</b>	<b>Projeto de RNAs para a Classificação dos Fatores de Estresse do Isolamento</b> . . . . .	<b>88</b>
3.3.1	Avaliação do Isolamento através do PRI . . . . .	88
<b>3.4</b>	<b>Classificador <i>Off-line</i> para a Avaliação do Isolamento</b> . . . . .	<b>100</b>
3.4.1	Resultados do Classificador <i>Off-Line</i> . . . . .	102
<b>3.5</b>	<b>Conclusões</b> . . . . .	<b>105</b>
<b>4</b>	<b>DESENVOLVIMENTO DE TÉCNICAS <i>ON-LINE</i> PARA A AVALIAÇÃO DO ISOLAMENTO</b> . . . . .	<b>107</b>
<b>4.1</b>	<b>Proposta para a Avaliação <i>On-line</i> do Isolamento</b> . . . . .	<b>107</b>
4.1.1	Avaliação <i>On-Line</i> do Isolamento pela Análise da Corrente $\dot{I}_0$ . . . . .	108
<b>4.2</b>	<b>Avaliação do Erro a partir da Análise de <math>\dot{I}_0</math></b> . . . . .	<b>115</b>
<b>4.3</b>	<b>Classificador <i>On-Line</i> para a Avaliação do Isolamento</b> . . . . .	<b>120</b>
<b>4.4</b>	<b>Conclusões</b> . . . . .	<b>123</b>
<b>5</b>	<b>SISTEMA DE MONITORAMENTO <i>ON-LINE</i> PARA O ISOLAMENTO DE MITS DE BT E MT - SIMOI</b> . . . . .	<b>125</b>
<b>5.1</b>	<b>Sistema de Medição e Processamento dos Sinais</b> . . . . .	<b>125</b>
5.1.1	Medição da Tensão e da Corrente $\dot{I}_0$ . . . . .	126
5.1.2	Condicionamento e Processamento dos Sinais . . . . .	132
5.1.3	Supressão Ativa de Ruído - SAR . . . . .	134
<b>5.2</b>	<b>Testes Experimentais <i>On-Line</i></b> . . . . .	<b>139</b>
5.2.1	Ensaio de Envelhecimento Acelerado . . . . .	140
5.2.2	Ensaio de Absorção de Umidade . . . . .	145
5.2.3	Ensaio de Contaminação por Óleo . . . . .	149
<b>5.3</b>	<b>Conclusões</b> . . . . .	<b>155</b>
<b>6</b>	<b>PREDITOR DE TEMPO DE FALHA DO ISOLAMENTO</b> . . . . .	<b>157</b>
<b>6.1</b>	<b>Análise de Séries Temporais</b> . . . . .	<b>157</b>
<b>6.2</b>	<b>Modelo ARMA para Previsão do <math>TF</math></b> . . . . .	<b>165</b>
<b>6.3</b>	<b>Modelo RNA para Previsão do <math>TF</math></b> . . . . .	<b>176</b>
<b>6.4</b>	<b>Avaliação dos Resultados de Previsão dos Modelos</b> . . . . .	<b>184</b>
<b>6.5</b>	<b>Conclusões</b> . . . . .	<b>185</b>
<b>7</b>	<b>CONCLUSÕES E PROPOSTAS DE CONTINUIDADE</b> . . . . .	<b>187</b>
<b>7.1</b>	<b>Conclusões</b> . . . . .	<b>187</b>
<b>7.2</b>	<b>Propostas de Continuidade</b> . . . . .	<b>189</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>191</b>
<b>A</b>	<b>APÊNDICE</b> . . . . .	<b>202</b>

<b>A.1</b>	<b>Banco de Dados de Testes de Motores da REDUC</b> . . . . .	<b>202</b>
<b>B</b>	<b>APÊNDICE</b> . . . . .	<b>207</b>
<b>B.1</b>	<b>Modelo do Sensor HSCT</b> . . . . .	<b>207</b>



# 1 Introdução

A UTILIZAÇÃO de acionamentos elétricos com o motor de indução vem crescendo de forma acentuada na indústria de processo, sobretudo pelo aumento da confiabilidade e da flexibilidade na operação destes equipamentos. A robustez da sua construção e os baixos requisitos de manutenção conferem ao Motor de Indução Trifásico (MIT), atualmente, seu uso nos processos mais críticos de uma planta, substituindo os acionamentos antes realizados por turbinas a vapor [1].

Apesar do seu alto tempo médio entre falhas (MTBF - *Mean Time Between Failures*), fatores associados ao acoplamento à carga, ambientais, operacionais e da qualidade de energia, podem levar à sua indisponibilidade prematura. Essa, por sua vez, acarreta inúmeros prejuízos que podem variar da parada imediata e não programada de uma unidade operacional, levando ao lucro cessante da ordem de dezenas a centenas de milhões de reais por dia, ou à sua manutenção corretiva como a troca de rolamentos e mancais, núcleo magnético e re-enrolamento, que muitas vezes, levam dias ou meses de intervenção [1, 2].

Visando detectar de forma preditiva as falhas prematuras nos MITs, alguns estudos e técnicas vêm sendo desenvolvidos de modo que a parada para a manutenção destas máquinas seja feita de forma programada, minimizando os impactos como as perdas de produção ou a sua manutenção corretiva. Neste contexto, as falhas elétricas do isolamento, responsáveis por cerca de 30% das falhas em MITs, tornam-se um importante problema a ser investigado do ponto de vista preditivo. Assim, o acompanhamento desse tipo de defeito evitará falhas no isolamento que podem acarretar na indisponibilidade total da máquina [3, 4].

## 1.1 Relevância

Tendo em vista o aumento da competitividade, as empresas têm buscado cada vez mais a excelência na gestão de seus processos. O aumento da produtividade baseado na eficácia das plantas de processo vem ganhando espaço. Várias metodologias estão sendo propostas, como a redução do tempo de suprimento no setor logístico, projetos de eficiência energética, reutilização ou reuso de insumos como água, mudança de *lay-outs* no parque fabril e estratégias que reduzam o custo efetivo de manutenção com maior disponibilidade da planta [5]. Neste contexto, a manutenção tem um papel fundamental, quebrando o paradigma da manutenção corretiva, cujo foco se baseia na substituição e reparo de partes defeituosas, para os horizontes da manutenção preventiva e preditiva.

Na manutenção preventiva, a intervenção no equipamento é programada a partir

de um calendário periódico, onde são realizados testes, inspeções e substituição de peças, prevenindo uma falha indesejada (etapa final de vida do equipamento - fase de desgaste). Na manutenção preditiva são utilizadas técnicas que predizem o tempo de vida útil dos componentes da máquina, de forma que esse tempo seja melhor aproveitado. Nesse tipo de manutenção, a intervenção (manutenção corretiva programada) será recomendada a partir do monitoramento e do acompanhamento de variáveis que mostrem a perda da eficiência e do desempenho do equipamento [5,6].

O objetivo do acompanhamento preditivo é o de identificar o início da fase de desgaste do equipamento, tentando-se prever os mecanismos e fatores aleatórios que desencadeiam as falhas. Alguns estudos mostram que os investimentos em manutenção preventiva e preditiva aumentam a disponibilidade dos equipamentos em torno de 20%, além da redução de custos da ordem de 15% [5–8].

Uma metodologia que vem ganhando espaço no ramo industrial, exceto na indústria aeronáutica que já a utiliza por mais de 25 anos, é a MCC (Manutenção Centrada na Confiabilidade) [9]. Essa metodologia tem como objetivo estabelecer um processo racional e sistemático para a confiabilidade e a segurança operacional com o menor custo. Dentro da MCC, uma de suas tarefas para identificar, classificar e mitigar ou prevenir falhas é o uso de tecnologias preventivas e preditivas. A tarefa selecionada deve, então, satisfazer os seguintes critérios: ser aplicável (i.e. prevenir ou mitigar a falha, detectar o seu início, ou descobrir uma falha oculta) e ser custo-eficiente (i.e. ser a opção mais eficaz entre as candidatas) [9].

Segundo Garcia [10], mais de 60% dos acionamentos utilizados na indústria são baseados em MITs, sendo, em muitos casos, classificados como equipamentos críticos cuja parada imediata impacta diretamente nos resultados de produção. Neste contexto, o desenvolvimento de técnicas e metodologias para a atuação preditiva de falhas prematuras em MITs torna-se essencial para o sucesso da implantação de programas de gerenciamento de manutenção, contribuindo para a produtividade e a redução dos custos de manutenção.

Referências apontam que de 60 a 70% das falhas em MITs são causadas por problemas mecânicos, sobretudo falhas em rolamentos causados por falta da sua lubrificação [4,11]. A segunda maior parcela de falha, de 30 a 40%, nos MITs são de origem elétrica, destacando-se as falhas do isolamento no estator que abrangem de 80 a 90% deste percentual. Em máquinas de média tensão, o percentual total de falhas de origem elétrica pode alcançar valores entre 60 e 70% [12].

Para o caso de falhas mecânicas, os programas preditivos de manutenção a partir da análise de vibração, estão bem difundidos, trazendo resultados significativos de economia e redução de custos de manutenção onde empregados [6,7]. Para as falhas elétricas nos MITs, as técnicas preditivas mais difundidas são:

- medição da Resistência de Isolamento ( $R_I$ ) entre enrolamentos e carcaça, cálculo do Índice de Polarização ( $IP$ ) e do Índice de Absorção ( $IA$ ) [13, 14];
- análise do espectro da corrente elétrica do estator ou “Assinatura Elétrica de Corrente” (AEC) [15–18];
- Análise de Descargas Parciais (ADP) [19–23].

A medição de  $R_I$  e o cálculo do  $IP$  e do  $IA$  são técnicas preditivas que dão suporte às equipes de manutenção e produção para continuidade operacional do motor. Entretanto, sendo realizadas com o motor desconectado da rede (*off-line*), não informam sobre a(s) causa(s) da redução da  $R_I$  ou do tempo de vida do isolamento até uma falha.

Atualmente, uma das técnicas bastante difundidas para a avaliação preditiva de MITs é a AEC. Baseada na análise do espectro da corrente elétrica de estator, a AEC possibilita a detecção e o diagnóstico de defeitos e falhas como:

- desequilíbrio ôhmico e/ou indutivo no estator causado por curtos-circuitos entre espiras no enrolamento ou desequilíbrio de tensões;
- barras quebradas no rotor;
- desbalanceamento mecânico do rotor;
- defeitos em rolamentos e mancais;
- desalinhamento do acoplamento entre motor e carga.

A AEC é uma técnica cujo diagnóstico é obtido com o motor em operação (*on-line*). Quando bem empregada, a AEC também auxilia a análise mecânica de vibração [18]. Entretanto, a AEC não detecta nenhum defeito que informe o estado do isolamento do MIT.

A ADP também é uma técnica preditiva *on-line* e seu objetivo é o de informar o estado do isolamento do motor através da medição das descargas parciais. Sua utilização necessita da instalação de capacitores nos terminais da máquina para a medição das descargas. Atualmente, apenas grandes máquinas, críticas para os processos, possuem analisadores de descargas parciais *on-line* que auxiliam no diagnóstico da redução da resistência do isolamento do estator [3].

Em motores alimentados diretamente pela rede elétrica, a ADP apresenta bons resultados em máquinas com classe de isolamento em alta tensão ( $> 6kV$ ). Entretanto, para MITs de média ( $< 6kV$ ) e baixa ( $< 1kV$ ) tensão conectados diretamente a rede elétrica a ADP não é eficaz, pois normalmente, as tensões não excedem os valores para o início ou limiar das descargas parciais ou *Partial Discharge Inception Voltage* - PDIV [19, 20, 24].

Younsi e Lee [25,26] propõem um sistema de monitoramento *on-line* para a avaliação do estado do isolamento de MITs de MT baseado na medição da corrente de fuga ( $I_L$ -*Leakage Current*). A corrente de fuga diferencial é medida por fase com a utilização de transformadores de alta sensibilidade HSCTs - *High Sensitivity Current Transformers*. Nessa técnica, é necessário que o motor tenha disponível os 6 terminais na sua caixa de ligação e no cubículo para que seja possível a instalação dos HSCTs.

A Figura 1.1 ilustra a proposta para o acompanhamento do isolamento de MITs a partir da medição das correntes de fuga por fase  $\dot{I}_{aL}$ ,  $\dot{I}_{bL}$  e  $\dot{I}_{cL}$ . A técnica apresenta bons resultados para motores de MT, entretanto, seu emprego não é possível em motores que não dispõem dos seis terminais para a sua conexão.

Os resultados apresentados nos estudos de Lee e Younsi [25,26] não se apresentaram adequados para o acompanhamento da redução da  $R_I$  em MITs de BT. Como a corrente  $I_L$  por fase é menor, a medição pelos HSCTs fica comprometida por ruídos e erros de *offset* do sensor e do condicionador de sinal, tornando-se necessário um aperfeiçoamento dos sensores empregados. Ainda para MITs de BT, a técnica apresenta outro ponto negativo relacionado à dificuldade da instalação dos HSCTs nas gavetas de CCM (Centro de Controle de Motores), que em sua maioria, contam com pouco espaço para a sua instalação.

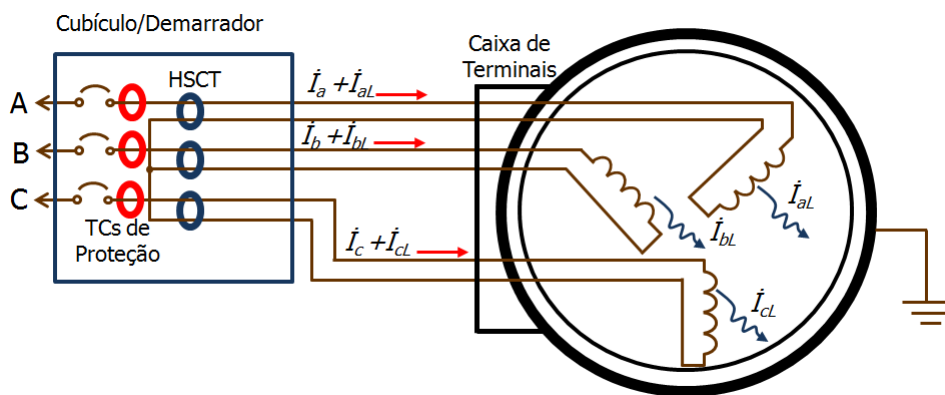


Figura 1.1 – Diagrama esquemático para a avaliação do isolamento de MITs de MT através da medição das correntes de fuga nas três fases.

Neste contexto, as técnicas preditivas *on-line* que se aplicam à avaliação do estado do isolamento dos MITs são, em sua maioria, empregadas em motores de MT e AT. Entretanto, nem sempre a perda da função destas grandes máquinas, compromete o funcionamento de uma planta de processo. Muitas vezes MITs auxiliares alimentados em BT podem ser tão importantes quanto a máquina principal. Por exemplo, em uma planta petroquímica os acionamentos de grandes compressores ou bombas utilizam redundância de motores elétricos e turbinas a vapor, ou seja, na perda do motor elétrico, a turbina a vapor é posta em operação, garantido a continuidade da produção. Porém, se a bomba auxiliar do óleo de lubrificação da turbina, que é acionada por um motor de baixa tensão, estiver

indisponível, a produção da planta será interrompida, gerando distúrbios operacionais e perdas financeiras.

Desta forma, o desenvolvimento de técnicas preditivas capazes de possibilitar a avaliação do estado do isolamento do estator em motores de baixa e média tensão é primordial para o sucesso de um programa de manutenção preditiva incorporado a MCC.

## 1.2 Justificativa

Para a identificação de problemas de baixa resistência do isolamento no estator, a maioria dos setores de manutenção elétrica industriais contam apenas com ferramentas preditivas que são aplicadas em paradas programadas do equipamento, denominados de testes *off-line*. Em muitas plantas industriais, alguns motores, sobretudo os de carga para processos contínuos como em refinarias e plataformas de petróleo, ficam energizados continuamente por semanas ou até meses. Nem sempre o equipamento reserva está disponível, o que impossibilita um rodízio adequado. Assim, a avaliação preditiva do motor não obedece um calendário definido, sendo então feita quando disponíveis tempo e recursos por oportunidade.

As técnicas *off-line* empregadas, na maior parte dos casos, se resumem à medição da Resistência de Isolamento ( $R_I$ ) com um megôhmetro e o cálculo do Índice Polarização ( $IP$ ) [13]. A avaliação do isolamento do MIT a partir da  $R_I$  e do  $IP$  não é suficiente para a determinação de um diagnóstico do estado do isolamento. Assim, a manutenção preditiva a partir da análise da  $R_I$  e do  $IP$  não apresenta informações suficientes que permitam aos técnicos, engenheiros e gestores de manutenção uma decisão sobre o custo eficiente para a manutenção corretiva programada do motor.

Aspectos relacionados à disponibilidade do MIT para a manutenção, afetam significativamente o sucesso de programas preventivos e preditivos *off-line*. Pode-se citar fatores como o planejamento inadequado da intervenção, que em muitos casos não prevê um tempo hábil para a sua manutenção completa (testes, ensaios, secagem em estufa, rejuvenescimento dos enrolamentos, limpeza etc). A falta de outro equipamento para a substituição imediata, quando detectado um defeito, também leva a intervenção incompleta no MIT sob manutenção. Esses fatos levam muitas vezes à perda total do motor, que após pouco tempo de operação pode vir a sofrer uma falha mais severa, como um curto-circuito entre o enrolamento de estator e o núcleo magnético. Além de causar distúrbios operacionais e perdas financeiras inesperadas para a planta, esse tipo de dano leva a intervenções muito mais demoradas e de maior custo.

Um levantamento realizado na Refinaria Duque de Caxias da Petrobras [27], entre janeiro/2010 a fevereiro/2015 mostrou que, dos 1878 motores de baixa e média tensão que sofreram manutenção corretiva ou preventiva, 624 acusaram defeitos de origem elétrica,

um percentual de 33%. Deste total, apenas 46 motores (7%) foram ensaiados e indicados para manutenção pela equipe preditiva de elétrica da refinaria devido ao baixo isolamento e não necessitaram ser re-enrolados. Outro dado importante deste levantamento é que 451 motores foram re-enrolados, ou seja, um percentual de 72%.

A Tabela 1.1 mostra o resumo do levantamento realizado. Os dados levantados representam uma amostragem de uma população de 3521 motores de indução instalados na refinaria, dos quais 321 são de média tensão. Ainda a respeito desse levantamento, na estatística de falhas foram considerados apenas motores alimentados diretamente pela rede elétrica.

Tabela 1.1 – Resumo do levantamento de defeitos/falhas em MITs de jan/2010 a fev/2015 na REDUC.

Descrição do defeito/falha		Quantitativo de defeitos/falhas	Percentual (%)
Defeitos/falhas de origem mecânica	- Rolamentos e mancais	978	52,09
	- Quebra de eixo	40	2,13
	- Quebra da ventoinha	36	1,92
	- Pé quebrado	10	0,53
	- Carcaça torcida/tampa	69	3,67
Defeitos/falhas de origem Elétrica	-Baixo isolamento estator (detectado pela equipe preventiva elétrica)	46	2,45
	- Curto-circuito para massa	451	24,0
	- Curto-circuito entre fases	125	6,65
	- Barra quebrada no rotor	2	0,01
Outras (desalinhamento, revisão, retrabalho, etc.)		123	6,55
Total		1878	100,0

A Tabela 1.2 relaciona os motores de baixa tensão (BT) e média tensão (MT) quanto às falhas elétricas. O percentual de motores de baixa ou média tensão que falharam e que necessitaram ser re-enrolados é da mesma ordem grandeza, sendo 72% e 66% respectivamente. Os dados indicam que a técnica de manutenção preditiva tradicional para a detecção da redução da  $R_I$  de MITs de BT ou de MT na refinaria não se mostra eficaz.

De forma geral, o levantamento feito na REDUC demonstra uma fragilidade do programa de manutenção preditiva da planta, que é afetado por fatores como [7]:

- falta de redundância (equipamento reserva);
- indisponibilidade do equipamento reserva;
- dificuldades de liberação operacional;
- fatores relacionados à perda de produção e produtividade;

- fatores relacionados à liberação (segurança) com risco de acidente.

Tabela 1.2 – Defeitos/falhas elétricas em MITs de jan/2010 a fev/2015 por classe de tensão na REDUC.

Descrição do defeito/falha		Quantitativo de defeitos/falhas	Percentual (%)
Motores de BT	-Baixo isolamento estator (detectado pela equipe preventiva elétrica)	42	7,07
	- Curto-circuito para massa	431	72,56
	- Curto-circuito entre fases	121	20,37
	- Barra quebrada no rotor	0	0
	Total BT	594	100
Motores de MT	-Baixo isolamento estator (detectado pela equipe preventiva elétrica)	4	13,33
	- Curto-circuito para massa	20	66,67
	- Curto-circuito entre fases	4	13,33
	- Barra quebrada no rotor	2	6,67
	Total MT	30	100

Assim, como a periodicidade adequada para o cumprimento dos planos de manutenção preventivas e preditivas são afetados por fatores de naturezas diversas, justifica-se a pesquisa com o desenvolvimento de técnicas que antecedam o diagnóstico da redução da resistência do isolamento de MITs com a máquina em operação (*on-line*). A previsão do defeito antes de uma falha mais severa acarretará menores custos de manutenção e, sobretudo, a redução de distúrbios e indisponibilidade operacionais.

Atualmente, as metodologias empregadas para a análise e a avaliação do estado do isolamento do estator de MITs são baseadas no conhecimento de padrões e normas que não caracterizam os fatores que levam a deterioração do isolamento com o motor em operação (*on-line*). Esses padrões e normas também não mencionam como realizar um acompanhamento preditivo para a previsão do tempo de falha do isolamento com o motor fora de operação (*off-line*). Neste sentido, o uso de Inteligência Computacional (IC) apresenta-se como uma boa opção para a detecção, a identificação e a previsão de defeitos e falhas no isolamento do estator de MITs.

Pesquisas e estudos recentes, apresentadas na Seção 2.3, mostram algumas aplicações de detecção, identificação e previsão do tempo de falha em equipamentos industriais e MITs. Os resultados alcançados nos estudos demonstram uma grande acurácia na determinação dos diagnósticos de falha. Destaca-se neste contexto, o uso de Redes Neurais Artificiais (RNA) com arquitetura do tipo *Multilayer Perceptron* (MLP). A aplicação de RNAs para

as análises de ADP e AEC apresentam desempenho superior ao das técnicas clássicas de diagnósticos.

Assim, devido à capacidade de aprendizagem e generalização do conhecimento das RNAs, justifica-se o seu uso neste trabalho para a detecção e a classificação dos fatores de estresse que deterioram o isolamento, bem como a elaboração de um modelo para a previsão do tempo de falha.

Neste sentido, o presente trabalho propõe desenvolver técnicas e metodologias que permitam o monitoramento de forma *on-line* para a avaliação do estado do isolamento dos MITs de BT e MT. O objetivo é prover os gestores, técnicos e engenheiros de diagnósticos precisos, para que o planejamento de manutenção nos motores mantenham a produtividade e a disponibilidade operacional da planta.

### 1.3 Propostas, Objetivos e Contribuições

A proposta deste trabalho é apresentar o desenvolvimento de técnicas e metodologias para a detecção e o acompanhamento preditivo dos fatores que acarretam a redução da resistência de isolamento do estator em MITs de BT e MT. Neste contexto, Destacam-se os seguintes objetivos:

- proposição de técnica e metodologia de avaliação *off-line* do isolamento para a compreensão e modelagem dos fatores de estresse que acarretam a degradação do isolamento de MITs de BT e MT ;
- proposição de técnica e metodologia para a avaliação do isolamento *on-line* de MITs de BT e MT;
- proposição de classificadores baseados em RNAs para a detecção *off-line* e *on-line* dos fatores de estresse que acarretam a degradação do isolamento de MITs de BT e MT;
- proposição de um modelo baseado em RNA para a previsão *on-line* do Tempo de Falha (*TF*) do isolamento de MITs de BT e MT.
- apresentação de resultados experimentais que comprovam os objetivos esperados.

A proposta do trabalho trará significantes contribuições. Do ponto de vista acadêmico e tecnológico, pode-se destacar:

- estudo para a caracterização dos principais fatores de estresse que acarretam a degradação do isolamento de MITs de BT e MT;

- nova técnica para a medição e a decomposição das correntes capacitivas e resistivas do isolamento aplicável em MITs de BT e MT;
- estudo e proposição de metodologia *off-line* para a o agrupamento das curvas de Perfil de Resistência do Isolamento (PRI) como ferramenta de auxílio à identificação dos fatores de estresse que levam à falha do isolamento;
- proposição de classificadores baseado em RNAs para a detecção preditiva *off-line* dos fatores de estresse que degradam o isolamento e determinação da condição de operação de MITs de BT e MT;
- proposição de um classificador baseado em RNAs para a detecção preditiva *on-line* dos fatores de estresse que deterioram o isolamento de MITs de BT e MT a partir da variação da resistência, da capacitância e do Fator de Dissipação ( $FD$ ) do isolamento que levam a falha do isolamento;
- proposição de um sistema de monitoramento e proteção preditiva *on-line* para o isolamento de MITs de BT e MT;
- proposição de um modelo baseado em RNAs para a previsão *on-line* do Tempo de Falha ( $TF$ ) do isolamento do estator de MITs de BT e MT.

Cabe ressaltar que neste trabalho não são abordadas as falhas no isolamento de motores de baixa e média tensão alimentados por conversores eletrônicos de potência. Também, não é escopo desta pesquisa a avaliação do isolamento de motores alimentados em alta tensão.

## 1.4 Organização do Trabalho

O trabalho está estruturado em sete capítulos. O primeiro capítulo aborda a relevância do tema no contexto das falhas de isolamento do estator em MITs de BT e MT, bem como a justificativa e a importância da pesquisa e as contribuições esperadas.

O segundo capítulo apresenta o estado da arte das principais técnicas *on-line* e *off-line* para a avaliação do estado do isolamento do estator de MITs. Também, neste capítulo é mostrada uma revisão bibliográfica com trabalhos que abordam a detecção e o diagnóstico de falhas em equipamentos industriais e MITs com uso de IC.

O terceiro capítulo apresenta o desenvolvimento das técnicas e metodologias *off-line* propostas, abordando:

- um modelo no domínio do tempo para o sistema de isolamento do estator alimentado em corrente contínua (c.c.) e alternada (c.a.);

- descrição dos fatores de estresse e mecanismos de degradação que afetam o isolamento de MITs;
- uso das curvas de Perfil de Resistência de Isolamento (PRI) para a rotulação dos fatores de estresse que levam à degradação do isolamento utilizando IC;
- um modelo de um classificador *off-line* baseado em RNA para inferir o fator de estresse a partir de uma base de dados de testes de motores da Petrobras.

O quarto capítulo apresenta a metodologia para a medição e a avaliação *on-line* da resistência de isolamento. O desenvolvimento teórico e as condições de validação da técnica são abordados. Um estudo a partir de simulação para a avaliação do erro de medição das correntes de fuga e a proposição de um classificador *on-line* baseado em RNA para a avaliação do isolamento, também são apresentados.

No quinto capítulo é apresentado o Sistema de Monitoramento *On-line* para o Isolamento de MITs de BT e MT - SIMOI. São mostrados os resultados experimentais de testes realizados em laboratório utilizando-se o SIMOI para a classificação do fator de estresse e o acompanhamento preditivo da falha no isolamento. São descritos os sistemas de medição e de tratamento de sinal que garantem a aplicação da metodologia *on-line* em motores de BT e MT.

No sexto capítulo são apresentadas as propostas de dois preditores para a previsão do  $TF$  do isolamento. São mostrados o desenvolvimento de um modelo ARMA e um modelo baseado em RNA a partir das curvas de corrente resistiva ( $I_R$ ) obtidas dos testes experimentais do SIMOI. São descritas as etapas para a identificação e a seleção dinâmica de modelos para a corrente  $I_R$  que seja independente do fator de estresse que acarreta a falha do isolamento.

No sétimo capítulo são apresentadas as conclusões a partir dos estudos e resultados obtidos, bem como as propostas de continuidade para o desenvolvimento de trabalhos futuros.

## 1.5 Conclusões

Este capítulo teve como objetivo apresentar, em linhas gerais, o tema abordado nesta pesquisa mostrando sua relevância, justificativa, metodologia empregada, objetivos e contribuições.

Espera-se, a partir desta introdução, facilitar a leitura e permitir ao leitor que as diversas etapas do trabalho possam ser compreendidas e avaliadas no contexto das metas previamente estabelecidas.

## 2 Técnicas para a Avaliação do Isolamento de MITs

NESTE capítulo é apresentado o estado da arte das técnicas e metodologias empregadas para a avaliação do estado do isolamento do estator de MITs. A revisão da literatura aborda as técnicas preditivas clássicas de medição *off-line* (motor desenergizado), bem como as técnicas preditivas *on-line* (motor energizado).

Inicialmente, são apresentadas as técnicas preditivas *off-line* para a avaliação do isolamento do estator de MITs encontradas nas principais referências sobre o tema. Recomendações de padronizações, de estudos e fabricantes são citados, bem como os pontos positivos e os negativos de cada técnica sob o ponto de vista do acompanhamento do estado do isolamento ao longo do ciclo de vida do motor.

As técnicas preditivas *on-line*, como a Análise de Descargas Parciais (ADP), a medição das correntes de fuga por fase e a proteção *Ground Sensor* são apresentadas. Os pontos positivos e os negativos de cada método sob o ponto de vista do monitoramento preditivo do estado do isolamento são apontados.

Por fim, são apresentados alguns estudos de aplicação utilizando Inteligência Computacional (IC) para a detecção e o diagnóstico de falhas em equipamentos e sistemas industriais incluindo MITs. O objetivo desta revisão é apresentar os resultados alcançados, sobretudo, das técnicas que utilizam Redes Neurais Artificiais (RNA).

Na organização do capítulo, a Seção 2.1 trata das técnicas preventivas clássicas *off-line* e, a Seção 2.2 mostra as metodologias preditivas *on-line*, ambas sob o ponto de vista do acompanhamento do estado do isolamento ao longo do ciclo de vida do motor. A Seção 2.3 apresenta uma revisão de estudos de aplicação com IC para a detecção e o diagnóstico de falhas em equipamentos e MITs. Por fim, a Seção 2.4 apresenta as conclusões a partir da revisão bibliográfica realizada.

### 2.1 Técnicas *Off-line* para a Avaliação do Isolamento de MITs

As técnicas *off-line* para a avaliação do estado do isolamento de MITs são aplicados em motores de baixa, média e alta tensão, onde [21]:

- Baixa Tensão (BT): motores com tensão nominal fase-fase menor que  $1kV$ ;
- Média Tensão (MT): motores com tensão nominal fase-fase maior que  $1kV$  e menor que  $6kV$ ;

- Alta Tensão (AT): motores com tensão nominal fase-fase maiores que  $6kV$ ;

Neste contexto, destacam-se as seguintes técnicas e ensaios:

- Medição da Resistência do Isolamento ( $R_I$ ) e cálculos dos Índices de Polarização ( $IP$ ) e Absorção ( $IA$ ) [12–14];
- Análise de Descargas Parciais (ADP) *off-line* [22, 23];
- Medição do Fator de Dissipação ( $FD$ ) e Medição do Fator de Dissipação *Tip-Up* ( $FD_{TU}$ ) do isolamento [21, 28–31];
- Medição da Capacitância ( $C_I$ ) e da Capacitância *Tip-Up* ( $C_{TU}$ ) do isolamento [28, 32];
- Testes de tensão aplicada *Hipot* c.a. (corrente alternada) [33] e *Hipot* c.c. (corrente contínua) [34];
- Teste de surto de tensão (*Surge Test*) [35].

A seguir são apresentadas as principais características de cada teste, destacando-se os itens mais importantes do ponto de vista do diagnóstico fornecido a respeito do estado do isolamento do motor.

### 2.1.1 Teste de $R_I$ e Cálculo do $IP$ e do $IA$

O teste de  $R_I$  é realizado com a aplicação de tensão c.c. entre os enrolamentos do estator e o núcleo (carcaça) do motor por 10 minutos. A magnitude da tensão a ser aplicada depende da classe de tensão do motor. A Tabela 2.1 resume os valores de tensão de acordo com o padrão IEEE Std-43 [13].

Tabela 2.1 – Guia para a aplicação de tensão c.c. para o teste de medição de resistência de isolamento.

Classe de tensão do motor (V)	Valor da tensão c.c. recomendada (V)
< 1000	500
1000 – 2500	500 – 1000
2501 – 5000	1000 – 2500
5001 – 1200	2500 – 5000
> 12001	5000 – 10000

Durante o ensaio a corrente total  $I_T$  que circula pelo isolamento pode ser decomposta em quatro componentes, como mostrado na Figura 2.1 [36].

- corrente condutiva  $I_G$ : parcela da corrente  $I_T$  constante durante todo o teste compreendendo as perdas dielétricas do material isolante;
- corrente de fuga  $I_L$ : parcela da corrente  $I_T$  de natureza capacitiva e resistiva que ocorre devido à contaminação do material dielétrico por partículas condutoras, água ou outro contaminante (óleo, graxa, poeira, etc). Essa corrente tem decaimento exponencial rápido, ficando constante no período posterior. Um isolamento limpo (livre de contaminantes) e seco tem esta parcela de corrente tendendo a zero;
- corrente de polarização ou absorção  $I_P$ : parcela da corrente  $I_T$  que representa o deslocamento de cargas dentro do material dielétrico para sua polarização. O decaimento desta corrente é exponencial e tipicamente se torna constante após 10 minutos do início do teste;
- corrente capacitiva  $I_C$ : parcela da corrente  $I_T$  que ocorre devido a natureza capacitiva do sistema de isolamento. Seu decaimento exponencial é rápido e se aproxima de zero no primeiro minuto após o início do teste.

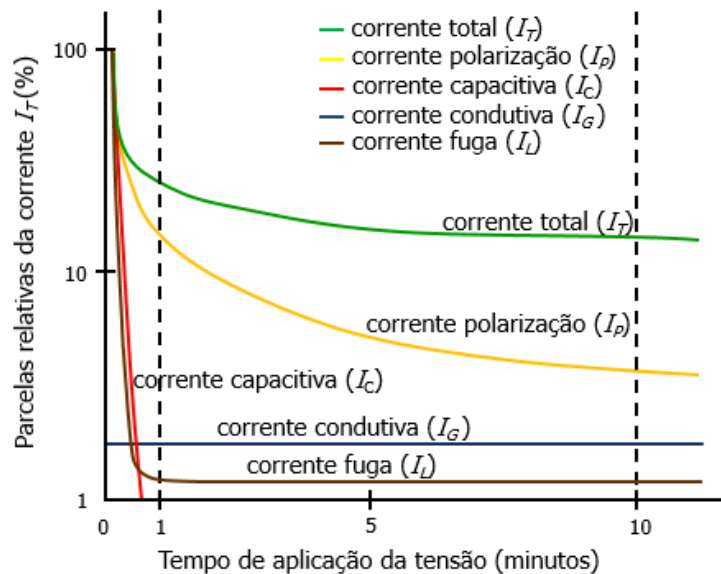


Figura 2.1 – Decomposição da corrente  $I_T$  durante o ensaio para medição da  $R_I$ .

O valor da Resistência de Isolamento ( $R_I$ ) é medida após 1 minuto do início do teste. O valor da  $R_I$  é corrigido para a temperatura de  $40^{\circ}C$  para permitir sua comparação ao longo do ciclo de vida do motor.

As equações (2.1) a (2.4) mostram como calcular a  $R_I$  corrigida para a temperatura de referência. O valor de  $K_T(T)$  é determinada conforme o tipo de material que compõe o isolamento, onde a temperatura  $T$  é dada em ( $^{\circ}C$ ).

$$R_{I-Corrigida}(40^{\circ}C) = R_{I-Medida} K_T(T) \quad (2.1)$$

Para materiais termoplásticos, como isolamentos a base de mica asfáltica, ou enrolamentos fabricados antes de 1970, o valor de  $K_T(T)$  pode ser determinado por [13]:

$$K_T(T) = 0,5^{(40-T)/10} \quad (2.2)$$

No caso de isolamentos mais novos, fabricados após 1970, constituídos de materiais termofixos como epoxi e poliéster, o valor de  $K_T(T)$  pode ser determinado de acordo com as equações (2.3) e (2.4) [13]:

$$K_T(T) = e^{-1245(\frac{1}{T+273} - \frac{1}{313})} \quad \text{para, } 10^{\circ}C < T < 40^{\circ}C \quad (2.3)$$

$$K_T(T) = e^{-4230(\frac{1}{T+273} - \frac{1}{313})} \quad \text{para, } 40^{\circ}C < T < 85^{\circ}C \quad (2.4)$$

Os valores mínimos recomendados de  $R_I$  segundo o IEEE Std-43 são vistos na Tabela 2.2.

Tabela 2.2 – Valores mínimos de  $R_I$  recomendados a  $40^{\circ}C$ .

Motor em teste	$R_{I-MIN}$ ( $M\Omega$ )
Motores fabricados antes de 1970 e outros não listados abaixo.	$kV^{1+1}$
Motores fabricados após 1970 com enrolamento de bobinas pré-formadas.	100
Para motores com enrolamentos randômicos no estator, motores com enrolamentos de bobinas pré-formadas com tensão abaixo de $1kV$ e armaduras de motores de c.c.	5

<sup>1</sup>  $kV$ : Tensão nominal fase-fase do motor.

Os valores dos índices  $IP$  e  $IA$  são definidos como:

$$IP = \frac{R_{I-10minutos}}{R_{I-1minuto}} \quad (2.5)$$

$$IA = \frac{R_{I-60segundos}}{R_{I-30segundos}} \quad (2.6)$$

Os valores mínimos do  $IP$  de acordo com o IEEE Std-43 e do  $IA$  conforme a NFPA (*National Fire Protection Association*) para a avaliação do estado do isolamento são mostrados na Tabela 2.3.

Tabela 2.3 – Valores mínimos padronizados do  $IP$  e do  $IA$ .

$IP$ (IEEE)		$IA$ (NFPA)
Motores com isolamento classe temperatura A	$> 1,5$	$> 1,5$
Motores com isolamento classe temperatura B, F e H	$> 2,0$	

A Tabela 2.4 mostra os valores do  $IP$  e do  $IA$  utilizados por fabricantes de motores para a avaliação do isolamento. Os valores do  $IP$  e do  $IA$  são divididos e combinados em faixas que fornecem um diagnóstico da condição do isolamento [32, 36].

Tabela 2.4 – Valores do  $IP$  e do  $IA$  recomendados por fabricantes de MITs.

$IP$	$IA$	Estado do isolamento
$IP < 1,0$	-	ruim
$1,0 < IP < 2,0$	$1,0 \leq IA < 1,25$	questionável
-	$1,25 \leq IA < 1,4$	aceitável
$2,0 \leq IP < 4,0$	$1,4 \leq IA < 1,6$	bom
$IP \geq 4,0$	$IA \geq 1,6$	muito bom

### 2.1.2 Análise de Descargas Parciais *Off-Line*

Descargas Parciais (DPs) são descargas elétricas que ocorrem devido à ionização transiente em um gás. Quando sua rigidez dielétrica é ultrapassada, ocorre a formação do arco elétrico com a circulação de corrente que ocasiona a erosão do material dielétrico [19].

Quando uma tensão elevada é aplicada em um material isolante, o campo elétrico que se distribui, submete os vazios e cavidades existentes no seu interior a um gradiente de tensão superior à rigidez dielétrica dos gases no interior destes. Esse fenômeno dará origem a pequenas descargas disruptivas no interior da cavidade, acarretando num processo temporal de deterioração progressivo do material e eventual falha do isolamento [20].

As DPs podem ter sua origem devido ao Efeito Corona. Neste caso, a ionização do gás não leva de imediato à descarga elétrica. O aspecto azulado acompanhado de ruído e formação de ozônio são características do efeito que ioniza parcialmente o gás. A formação do ozônio deteriora o material isolante que, por sua vez, diminui a rigidez dielétrica do isolamento, levando a descargas que conduzem à posterior falha do isolamento [20, 22].

Em MITs, a origem de descargas parciais são diversas, podendo estar relacionadas ao projeto, processo de fabricação, condições operacionais, condições ambientais, instalação e manutenção.

Métodos inadequados de fabricação originam cavidades ou vazios no interior do material isolante que levam a descargas parciais. Estes vazios estão associados a processos inadequados de impregnação, secagem e cura do enrolamento, sendo os maiores responsáveis pela formação desses [20]. Descargas internas também podem ocorrer no isolamento devido ao envelhecimento e a delaminação causados por sobretemperatura no MIT. Outras fontes de DP em MITs são [22, 23]:

1. Associado ao projeto:
  - descargas em cabeças de bobinas: ocasionadas por distâncias elétricas inadequadas entre o enrolamento (condutor) e a carcaça (terra);
2. Associado ao processo de fabricação:
  - efeito Corona no sistema de alívio de tensão nos condutores: defeito na montagem de fitas ou na aplicação da pintura semicondutiva;
  - descargas entre o material isolante e o núcleo: geralmente ocorrem nas ranhuras do núcleo do estator ocasionados por vazios gerados no processo de impregnação como no global VPI - *Vacuum Pressure Impregnation*;
3. Associado à operação:
  - redução da distância de isolamento ocasionada por movimentação da bobina por vibração: condições operacionais inadequadas, como as que provocam cavitação em bombas, podem levar a perda da amarração das bobinas com a redução das distâncias elétricas;
  - sobrecargas e altas variações no ciclo de carga: levando a delaminação e fissuras no material isolante;
4. Associado às condições ambientais e instalação:
  - descargas na superfície do isolamento: ocasionado por partículas condutoras, poeira, contaminação por água, óleo, etc;
5. Associado à manutenção:
  - descargas em terminações, conexões e isoladores da alimentação do MIT: ocasionadas por falta de manutenção (limpeza) e/ou procedimentos inadequados durante a manutenção.

As descargas parciais ocorrem em MITs de alta tensão (AT) cuja tensão de alimentação fase-fase é superior a  $6kV$ , valor que normalmente, em relação a terra, excede o limite de  $3kV/mm$  (limite da rigidez dielétrica do ar) [24].

O ensaio para a medição de DPs *off-line* é realizado com o motor desenergizado. Uma fonte externa com a tensão e a frequência nominal fase-neutro do MIT é conectada a um enrolamento por vez para que as medições possam ser realizadas. A Figura 2.2 ilustra um circuito típico do ensaio com um capacitor de acoplamento  $C_{acoplamento}$  e uma impedância de medição  $Z_{medição}$ . Após o condicionamento do sinal, os valores de pulsos de tensão podem ser apresentados num osciloscópio ou armazenados num sistema de aquisição para a avaliação do isolamento.




Figura 2.2 – Circuito típico para medição *off-line* de DPs.

O princípio de medição se baseia no fato de que quando da ocorrência das DPs, alguns picocoulombs de carga atravessam o material isolante em um curto intervalo de tempo resultando num pulso de tensão entre fase-terra. O capacitor  $C_{acoplamento}$  tem valor adequado para permitir que este pulso de alta frequência passe para o sistema de medição e filtre as componentes de baixa frequência da alimentação. O valor do  $C_{acoplamento}$  varia entre 100 a 10000  $pF$ , sendo escolhido durante o teste o valor que apresentar uma melhor visualização dos pulsos referentes às descargas. O sistema de condicionamento e medição deve ser adequado para medir uma faixa de frequência de dezenas de  $kHz$  a centenas de  $MHz$ .

O padrão IEEE Std-1434 e a norma IEC-60270 mostram outras sugestões de circuitos para a medição das DPs, orientando os usuários conforme a finalidade do teste. São apresentados circuitos para teste de prova em amostras de bobina do enrolamento, testes de inspeção e aceitação, ou acompanhamento para a manutenção preditiva. A padronização também recomenda a avaliação de descargas parciais *off-line* através de outras técnicas [22, 23, 37]:

- detecção e localização das descargas através de medição da emissão de rádio frequência (RF) produzidos pelas DPs;
- detecção e localização das descargas através da medição da emissão de ondas acústicas e ultrassônicas produzidos pelas DPs;

- detecção e localização das descargas em câmara escura através de inspeção visual (*Black-out Test*).

A Análise de Descargas Parciais (ADP) *off-line* se baseia, sobretudo, na quantidade, na forma, e na frequência das DPs. A avaliação do estado do isolamento é realizada através da quantidade total de carga que atravessa o material. Para enrolamentos novos de MITs de AT, a norma IEC-60270 recomenda que a carga seja menor que  $10.000pC$ . A forma e espectro de frequência das DPs permitem avaliar o mecanismo de geração e a localização das descargas [19, 21, 38]. A carga total  $Q_T$  proveniente das DPs pode ser calculada como:

$$Q_T = F_n(Q_+ + Q_-) = F_n C_{acoplamento} \sum_{i=1}^n |U_i| \quad (2.7)$$

Onde:

- $Q_+$ : carga proveniente das DPs positivas (semi-ciclo negativo da tensão de alimentação);
- $Q_-$ : carga proveniente das DPs negativas (semi-ciclo positivo da tensão de alimentação);
- $U_i$ : magnitude da tensão de cada pulso gerado pela DP;
- $F_n$ : fator de normalização adquirido a partir de ajustes na  $Z_{medicção}$  em função da capacitância do isolamento. Este fator deve ser armazenado para utilização em testes posteriores.

O Anexo C do IEEE Std-1434 mostra alguns resultados de ensaios *off-line* de DPs [22]. As Figuras 2.3, 2.4 e 2.5 ilustram o formato e a quantidade de carga esperada para algumas destas falhas.

A Figura 2.3 caracteriza a ocorrência de atividade elevada de descargas internas no isolamento. Neste caso, o formato das DPs positivas e negativas são semelhantes aos semi-ciclos da senóide. As descargas internas também são caracterizadas pela quantidade de carga em ambos semi-ciclos serem semelhantes ( $Q_+ \approx Q_-$ ).

A Figura 2.4 caracteriza a ocorrência de atividade elevada de DPs no interior das ranhuras do núcleo. Neste caso, o formato das DPs positivas e negativas são semelhantes a triângulos retângulos. As descargas em ranhuras se caracterizam geralmente pelas quantidades de carga serem diferentes em cada semi-ciclo ( $Q_+ < Q_-$ ).

A Figura 2.5 caracteriza a ocorrência de atividade de DPs externas provenientes de descargas superficiais (contaminação devido a partículas condutoras, poeira, água, etc) ou defeito no sistema de alívio de tensão dos condutores (fitas e tintas semicondutoras). Neste caso, o formato das DPs positivas e negativas são semelhantes aos semi-ciclos da senóide

da alimentação. Estas descargas, também se caracterizam pela diferença da quantidade de carga em cada semi-ciclo ( $Q_+ < Q_-$ ).

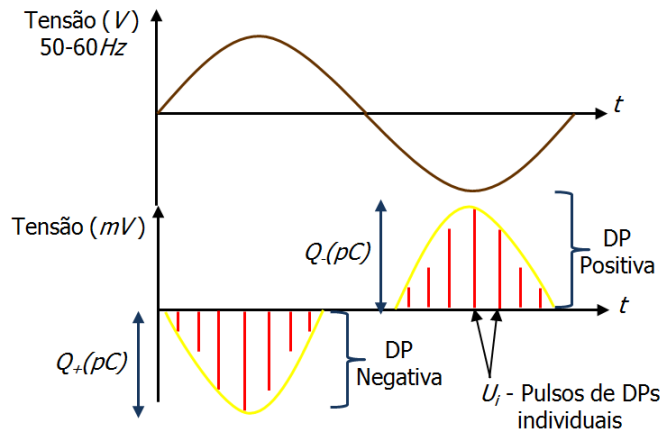


Figura 2.3 – Resultado típico de isolamento apresentado descargas parciais internas.




Figura 2.4 – Resultado típico de isolamento apresentado descargas parciais nas ranhuras (*slots*) do núcleo.

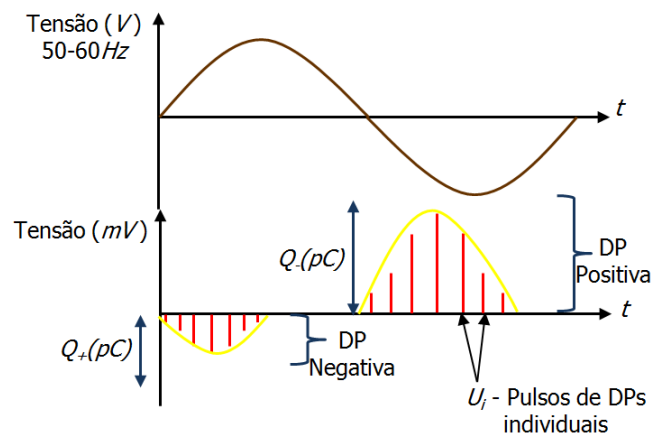


Figura 2.5 – Resultado típico de isolamento apresentado descargas parciais externas.

Para que a técnica de ADP *off-line* seja eficaz na previsão de uma falha no isolamento são necessárias várias medições ao longo do ciclo de vida do MIT. A padronização recomenda que o teste seja realizado pelo menos a cada 1 ano nos primeiros 5 anos de operação do motor e, que este intervalo seja reduzido pela metade após este período ou em caso de evidência de aumento da atividade das DPs no isolamento [22]. O uso da ADP *off-line* como ferramenta de monitoramento preditivo depende, sobretudo, do histórico de dados e cumprimento da periodicidade das medições [21].

### 2.1.3 Medição do $FD$ e do $FD_{TU}$

A Figura 2.6 mostra o circuito equivalente e respectivas correntes consideradas para o cálculo do Fator de Dissipação ( $FD$ ). Isolamentos em bom estado apresentam a relação  $|I_R| \ll |I_C|$  e  $|I_R| \ll |I_T|$ .




Figura 2.6 – a) Circuito equivalente para o isolamento do MIT. b) Diagrama fasorial de tensões e correntes do isolamento para o cálculo do  $FD$ .

A partir da Figura 2.6, pode-se definir o  $FD$ . Também pode ser obtido o Fator de Potência ( $FP$ ), outra medida utilizada para inferir as perdas dielétricas do isolamento. Quando o valor do  $FD$  estiver entre  $0 < FD < 0,1$ , os valores do  $FD$  e do  $FP$  são praticamente os mesmos ( $FD \approx FP$ ).

$$FD = \tan(\delta) = \frac{|I_R|}{|I_C|} \quad (2.8)$$

$$FP = \cos(\phi) = \cos(90^\circ - \delta) = \frac{|I_R|}{|I_T|} \quad (2.9)$$

A medição do Fator de Dissipação ( $FD$ ), ou fator de perdas, revela o nível das perdas dielétricas no material isolante. Um acompanhamento preditivo do  $FD$  indica a

degradação do isolamento por contaminação devido à agentes externos ou, que o isolamento foi submetido a ação de sobrecargas térmicas (sobretensão) [26].

Uma simples medição do  $FD$  não revela o estado do isolamento, uma vez que mudanças nas perdas dielétricas dependem do material do qual este é constituído, tamanho da máquina, condições ambientais e operacionais. Entretanto, o acompanhamento do  $FD$  ao longo do ciclo de vida do motor pode informar um diagnóstico do fator que está acarretando a degradação do isolamento [21, 28]. Muitos fabricantes utilizam o fator de dissipação para avaliar a qualidade da impregnação, secagem e cura do isolamento ao longo do processo de fabricação do enrolamento [21].

O teste do  $FD$  é realizado com tensão e frequência nominais do motor utilizando uma ponte de Shering. Para facilitar a medição, em caso de testes em campo, o padrão IEEE Std-286 prevê a realização do ensaio em frequências menores ( $0,1Hz$  por exemplo). O ensaio deve ser realizado em ambiente com a temperatura controlada, geralmente  $25^{\circ}C$ , para testes em bobinas e enrolamentos novos. No caso do ensaio em campo, o valor do  $FD$  deve ser corrigido conforme o tipo de material de que é constituído o isolamento aplicando o fator  $K_T$  vistos nas equações (2.2) a (2.4) [30].

O ensaio de  $FD$  é recomendado para motores de qualquer classe de tensão para o acompanhamento das perdas dielétricas do isolamento. O aumento de  $FD$  revela a degradação do isolamento por efeitos térmicos (delaminação, fissuras ou envelhecimento). Entretanto, para a verificação da contaminação do isolamento por água, óleo ou substâncias químicas, o monitoramento do valor de  $FD$  pode não ser muito eficaz, pois nesse caso as parcelas de corrente  $|I_R|$  e  $|I_C|$  apresentarão magnitudes semelhantes, levando a pouca variação no  $FD$  ao longo do ciclo de vida do motor [28].

O Fator de Dissipação *Tip-Up* ( $FD_{TU}$ ) ou o Fator de Potência *Tip-Up* ( $FP_{TU}$ ) do isolamento são definidos, respectivamente, como a diferença da medição do  $FD$  ou do  $FP$  em dois diferentes níveis de tensão. A padronização também possibilita a medição do  $FD_{TU}$  e do  $FP_{TU}$  em degraus de tensão de 20% da tensão nominal fase-neutro do isolamento ( $U_N$ ) [29–31].

O padrão IEEE Std-286 define o  $FD_{TU}$  e o  $FP_{TU}$  respectivamente como:

$$FD_{TU} = \Delta \tan(\delta) = \tan(\delta)_{0,8U_N} - \tan(\delta)_{0,2U_N} \quad (2.10)$$

$$FP_{TU} = \Delta \cos(\phi) = \cos(\phi)_{0,8U_N} - \cos(\phi)_{0,2U_N} \quad (2.11)$$

A norma IEC-60894 define o  $FD_{TU}$  e o  $FP_{TU}$  respectivamente como:

$$FD_{TU} = \Delta \tan(\delta) = \tan(\delta)_{0,8U_N} - \tan(\delta)_{0,6U_N} \quad (2.12)$$

$$FP_{TU} = \Delta \cos(\phi) = \cos(\phi)_{0,8U_N} - \cos(\phi)_{0,6U_N} \quad (2.13)$$

Além das diferenças dos níveis de tensão para a determinação do  $FD_{TU}$  definidos pelo padrão e a norma, o IEEE Std-286 prevê o teste do  $FD_{TU}$  com uma tensão de até 120% da  $U_N$ .

A Figura 2.7 mostra um exemplo de uma série de medições do  $FD$  para a determinação do  $FD_{TU}$  [29]. Observa-se que o  $FD$  não aumenta linearmente com a tensão aplicada, pois a corrente total ( $I_T$ ) que circula no isolamento não aumenta linearmente com a mesma. A corrente condutiva ( $I_G$ ) juntamente com a parcela resistiva da corrente fuga ( $I_L$ ) são incrementadas de forma linear com a tensão, entretanto, a corrente capacitiva  $I_C$  e a parcela capacitiva de  $I_L$ , também aumentam com o acréscimo da atividade das descargas parciais.

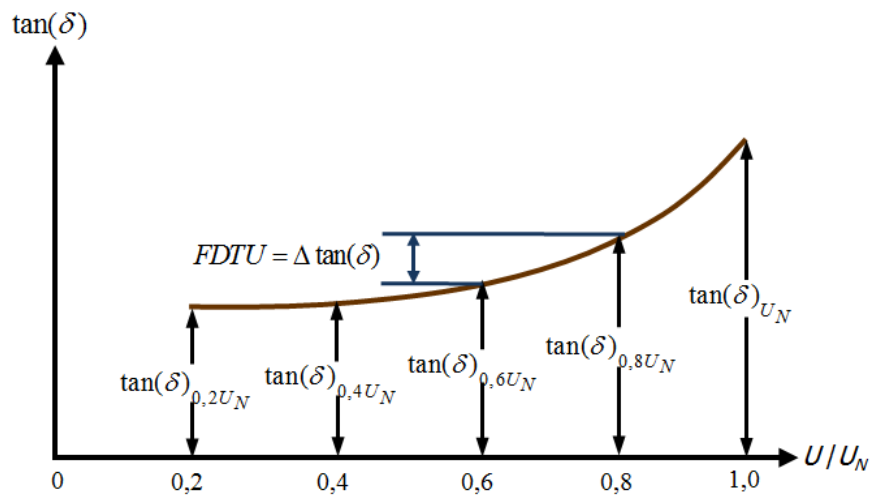


Figura 2.7 – Exemplo de uma série de medições de  $FD$  para determinação do  $FD_{TU}$ .

O teste de  $FD_{TU}$  é recomendado para motores de alta tensão devido à possibilidade da verificação do aumento da atividade das DPs, o que não é observado para motores de BT e MT. Neste caso, o aumento da  $FD_{TU}$  ao longo do ciclo de vida do motor permitirá o diagnóstico da degradação do isolamento pelo efeito das DPs [21].

#### 2.1.4 Medição da $C_I$ e da $C_{TU}$

A medição da capacitância do isolamento  $C_I$  pode ser considerada como um ensaio complementar ao teste do  $FD$ . Dependendo do método adotado para medição do  $FD$ , o valor da  $C_I$  também pode ser determinado no mesmo ensaio [32].

A medição isolada da  $C_I$  não informa nenhum diagnóstico sobre o estado do isolamento. É necessário o seu acompanhamento ao longo do ciclo de vida do motor para diagnosticar a ocorrência de algum fator de estresse que possa causar a degradação do isolamento. A tendência do aumento da  $C_I$  indica a contaminação do isolamento por agentes externos como água (umidade), óleo, sujeira, algum produto químico, etc. A

redução da  $C_I$  ao longo do tempo revela que o isolamento está sob a ação de algum estresse térmico causando delaminação, fissuras e envelhecimento (ressecamento) [32].

A medição da Capacitância *Tip – Up* ( $C_{TU}$ ) é definida como a diferença da capacitância medida entre dois níveis de tensão diferentes (baixa-*Low* e alta-*High*).

$$C_{TU} = C_{I-High} - C_{I-Low} \quad (2.14)$$

Os mesmos referenciais de tensão empregados nos ensaios do  $FD_{TU}$  e do  $FP_{TU}$  podem ser utilizados para a medição da  $C_{TU}$ :

$$High = 0,8U_N \quad (2.15)$$

$$Low = 0,6U_N \quad \text{para a IEC-60894} \quad (2.16)$$

$$Low = 0,2U_N \quad \text{para o IEEE-286} \quad (2.17)$$

A medição da  $C_I$  é recomendada para motores de qualquer classe de tensão. Entretanto, o ensaio da  $C_{TU}$  só é efetivo para motores de alta tensão, uma vez que o objetivo é verificar o aumento das DPs que não ocorre para motores de baixa e média tensão [26, 32].

A medição isolada da  $C_{TU}$  não revela as condições do isolamento. Para um diagnóstico preditivo são necessárias várias medições ao longo do ciclo de vida do motor. Um aumento da  $C_{TU}$  indica incremento na atividade das DPs, revelando que o isolamento está sob ação de algum tipo de contaminação ou estresse térmico.

Um acompanhamento das variações da  $C_I$  e da  $C_{TU}$  permite determinar o estado e o fator de estresse que está levando à deterioração do isolamento. A Tabela 2.5 resume os diagnósticos que podem ser obtidos pelo acompanhamento da  $C_I$  e da  $C_{TU}$  [32].

Tabela 2.5 – Resumo dos diagnósticos obtidos a partir da medição da  $C_I$  e da  $C_{TU}$ .

Teste	Classe de tensão do MIT	Diagnóstico para a tendência de aumento	Diagnóstico para a tendência de redução
Medição $C_I$	BT, MT e AT	presença de umidade ou contaminação por óleo, sujeira, etc, no isolamento	estresse térmico acarretando em envelhecimento e/ou ressecamento do isolamento
Medição $C_{TU}$	AT	aumentos de descargas parciais no isolamento	-

### 2.1.5 Teste de Tensão Aplicada *Hipot* c.c. e *Hipot* c.a.

A aplicação de tensão c.c., *Hipot* c.c., é recomendada, conforme o padrão IEEE Std-95 [34], para motores de média e alta tensão (acima de 2,3kV). O teste consiste na aplicação de tensão c.c. de forma controlada por um tempo determinado.

A Tabela 2.6 mostra a magnitude da tensão e o tempo recomendado para a realização do teste em motores novos e em manutenção. A NEMA MG-1 [39] orienta a aplicação de um valor menor de tensão para motores em manutenção, em torno de 125 – 150% de  $2U_{N-FF}$ , que corresponde a 65 – 75% de  $2U_{N-FF} + 1000V$ .

Para que não ocorra a falha prematura do isolamento durante o teste, devido a circulação de altas correntes capacitivas (elevados  $C \frac{dU}{dt}$ ), a NEMA MG-1 [39] recomenda que o gradiente de tensão não ultrapasse a taxa de  $1kV/s$ .

Tabela 2.6 – Valores de tensão e tempo para a realização do teste de *Hipot* c.c.

Condição do motor	Tensão do teste $U_{Teste}(V)$	Tempo de aplicação $t_{Teste}$
novos ou re-enrolados	$2U_{N-FF} + 1000$	1 minuto
manutenção	125 – 150% $2U_{N-FF}$	1 minuto

A avaliação do estado do isolamento no teste de *Hipot* c.c. pode ser realizado através do cálculo da  $R_I$  (quociente da tensão aplicada pela corrente medida em 1 minuto) e o cálculo do  $IA$ . Quando possível a extensão do teste por mais tempo (5 a 10 minutos) pode-se determinar o valor do  $IP$  para auxílio no diagnóstico. Utilizando as recomendações do IEEE Std-43, pode ser realizada uma avaliação quanto à condição de operação do motor. Entretanto, para um diagnóstico relacionado aos fatores de estresse que acarretam a degradação do isolamento, são necessárias medições periódicas que possibilitem o acompanhamento da tendência da  $R_I$ , do  $IP$  e do  $IA$  ao longo do ciclo de vida do motor.

O acompanhamento dos resultados vindos do teste de *Hipot* c.c. possibilita a detecção de [34]:

- rachaduras e fissuras ocasionadas por movimentação do enrolamento no interior das ranhuras do núcleo;
- cura e impregnação da resina inadequados em enrolamentos novos;
- contaminação superficial por óleos, sujeira, partículas condutoras, etc;
- delaminação no isolamento devido a estresse térmico;

- absorção de umidade.

O teste de *Hipot* c.a. é recomendado segundo o padrão IEEE Std-56 para grandes motores, com tensão e potência superiores a  $6kV$  e  $10MVA$  respectivamente. O ensaio de *Hipot* c.a. é realizado de forma similar ao teste de *Hipot* c.c., com a exceção que é aplicada tensão c.a. com frequência nominal ( $50Hz$  ou  $60Hz$ ). O propósito do teste é determinar se existe alguma falha incipiente no isolamento antes da entrada do motor em operação. O teste tem uma concepção de aceitação “GO” ou “NO GO”, não trazendo nenhuma informação relevante para o acompanhamento preditivo de manutenção.

A Tabela 2.7 mostra a magnitude da tensão e o tempo recomendado para a realização do teste em motores novos e em manutenção. O padrão IEEE Std-433 [40] orienta a aplicação de valores menores de tensão para motores em manutenção, em torno de  $120 - 150\%$  da  $U_{N-FF}$ .

Tabela 2.7 – Valores de tensão e tempo para a realização do teste de *Hipot* c.a.

Condição do motor	Tensão do teste $U_{Teste}(V)$	Tempo de aplicação $t_{Teste}$
novos ou re-enrolados	$1,63U_{N-FF}$	1 minuto
em manutenção	$120 - 150\% U_{N-FF}$	1 minuto

Os testes de *Hipot* c.c. e *Hipot* c.a. submetem o isolamento a um certo estresse que pode levá-lo a sua ruptura durante o ensaio. Desta forma, a utilização do *Hipot* durante a manutenção é recomendado apenas quando o isolamento do motor estiver isento de contaminação e apresentando  $R_I > 100M\Omega$  [41]. A norma NEMA MG-1 recomenda que esses ensaios sejam realizados apenas em motores novos ou re-enrolados [39].

### 2.1.6 Surge Test

A aplicação de pulsos de tensão no enrolamento do estator, também conhecido como *Surge Test*, é outro ensaio utilizado para a avaliação do estado do isolamento de MITs. Este ensaio é recomendado, segundo o padrão IEEE Std-522, para motores de qualquer classe de tensão mas de potência superior a  $200kW$ , ou motores cujo enrolamento é construído a partir de bobinas pré-formadas [35].

O *Surge Test* consiste na aplicação de pulsos de tensão c.c. padronizado em 2 enrolamentos iguais do estator. A Figura 2.8 mostra o formato do pulso segundo o IEEE Std-522 para a realização do ensaio.

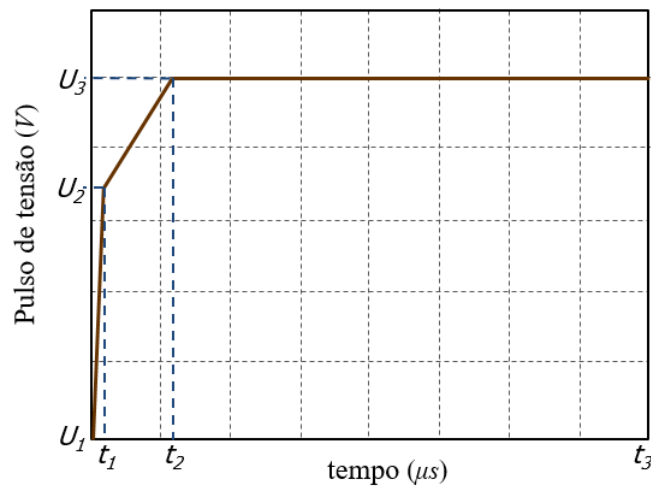


Figura 2.8 – Pulso de tensão padronizado pelo IEEE Std-522 para o *Surge Test*.

As equações (2.18), (2.19) e (2.20) definem o formato da elevação de tensão do pulso.

$$U_1 = \sqrt{2}U_N \quad \text{em, } t = 0\mu\text{s} \quad (2.18)$$

$$U_2 = 3,5U_1 \quad \text{em, } t = t_1 = 0,1\mu\text{s} \quad (2.19)$$

$$U_3 = 5,0U_1 \quad \text{para, } t \geq t_2 = 1,2\mu\text{s} \quad (2.20)$$

O valor de  $t_3$  dependerá de ajustes no gerador de pulso para uma visualização adequada das formas de onda, sendo necessário seu armazenamento para testes e comparações posteriores. Para motores em manutenção, a padronização recomenda que as tensões aplicadas sejam reduzidas em 25% [35].

As formas de onda obtidas no teste revelam a condição do isolamento do enrolamento do motor entre espiras e para a carcaça (terra) [35]. As respostas obtidas podem ser utilizadas para diagnosticar o estado do isolamento. A Figura 2.9 ilustra algumas formas de onda típicas esperadas no *Surge Test*. O Anexo A do IEEE Std-522 mostra como realizar a análise das formas de onda, bem como o diagnósticos de outros defeitos que podem ser obtidos pelo ensaio.

A Figura 2.9 apresenta alguns resultados típicos do teste de isolamentos nas seguintes condições:

- Figura 2.9-a: resultado do teste para o isolamento em bom estado (observa-se sobreposição dos sinais);
- Figura 2.9-b: resultado do teste para curto-circuito entre espiras em um dos enrolamentos (observa-se defasagem entre os sinais);

- Figura 2.9-c: resultado do teste para um enrolamento desconectado ou aberto (resposta com decaimento exponencial sem ocorrência de oscilações para o enrolamento desconectado);
- Figura 2.9-d: resultado do teste para um enrolamento totalmente curto-circuitado para a terra (a resposta de tensão é nula para o enrolamento em curto).

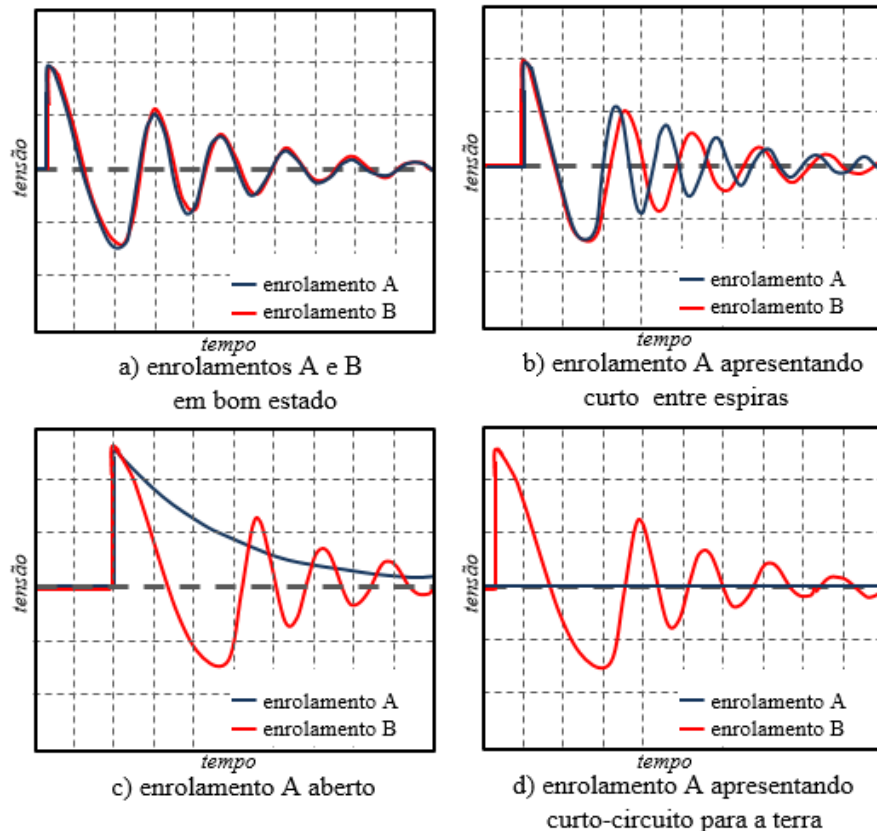


Figura 2.9 – Exemplos de formas de ondas típicas esperadas no *Surge Test*.

## 2.2 Técnicas On-line para a Avaliação do Isolamento de MITs

As técnicas para a avaliação *on-line* de falhas no isolamento do estator de MITs estão concentradas, sobretudo, em motores de AT, destacando-se a Análise de Descargas Parciais (ADP) *on-line* [19, 20, 42]. Para motores de baixa ou média tensão, onde a ADP não é aplicada, estudos vêm se concentrando em técnicas que se baseiam na medição da corrente líquida de fuga por fase com HSCTs (transformadores de corrente de alta sensibilidade) [12, 25, 26].

O uso da proteção de *ground sensor*, recomendado para motores de qualquer classe de tensão, não chega a ser uma técnica para a avaliação do estado isolamento. Entretanto, seu emprego reduz os danos de uma falha no isolamento (curto-circuito fase-terra), que pode

levar a perda total do enrolamento. Nas próximas seções são apresentadas as principais características destas técnicas, destacando-se o caráter preditivo de cada uma.

### 2.2.1 Análise de Descargas Parciais *On-line*

A análise de descargas parciais *on-line* tem como objetivo a avaliação do estado do isolamento com o motor em operação. Seu princípio é semelhante ao apresentado no teste *off-line*, onde a magnitude e o formato dos pulsos de tensão gerados pelas DPs são avaliados para detectar e determinar o tipo de falha no isolamento [22, 23, 43].

Os métodos mais difundidos por normas e padrões utilizam capacitores de acoplamento com impedância de medição, ou o emprego de transformadores de corrente de rádio frequência (RFCT-*Radio Frequency Current Transformers*) [43]. A escolha do circuito para a medição das DPs *on-line* depende do objetivo pretendido. O emprego de técnicas para a medição das DPs em baixa frequência ( $10\text{kHz} - 30\text{MHz}$ ) possibilita um diagnóstico do estado e a determinação dos fatores que deterioram o isolamento. Já as técnicas de detecção em alta frequência ( $20\text{MHz} - 350\text{MHz}$ ) são importantes para determinar a localização (fonte) das DPs no isolamento [22, 23, 43].

As Figuras 2.10 e 2.11 ilustram os circuitos típicos para a medição das DPs através de capacitores de acoplamento e impedância de medição. Esses, apresentam bons resultados na faixa de frequência compreendida entre  $30\text{kHz}$  a  $10\text{MHz}$ . A Figura 2.10 mostra o circuito padrão mais utilizado para a medição das descargas parciais *on-line*, cujo princípio é similar ao empregado no teste *off-line* [19, 22, 23, 44].

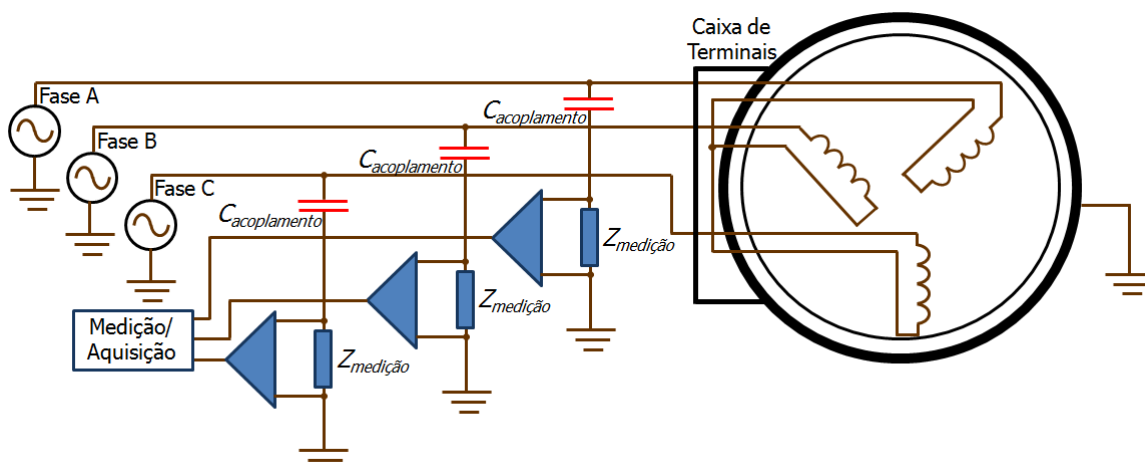


Figura 2.10 – Circuito padrão para a medição *on-line* das descargas parciais.

A Figura 2.11 mostra a medição com dois capacitores de acoplamento, conhecida como medição diferencial [22]. Apesar do seu emprego estar bem difundido para a medição das DPs em geradores, a técnica também está sendo empregada em motores [38]. Esta configuração é recomendada quando a distância entre o motor e o cubículo de alimentação

for menor que  $30m$ . Para que a medição não seja afetada por ruídos, a padronização recomenda que a distância entre a instalação dos capacitores seja  $L > 2m$  [22].

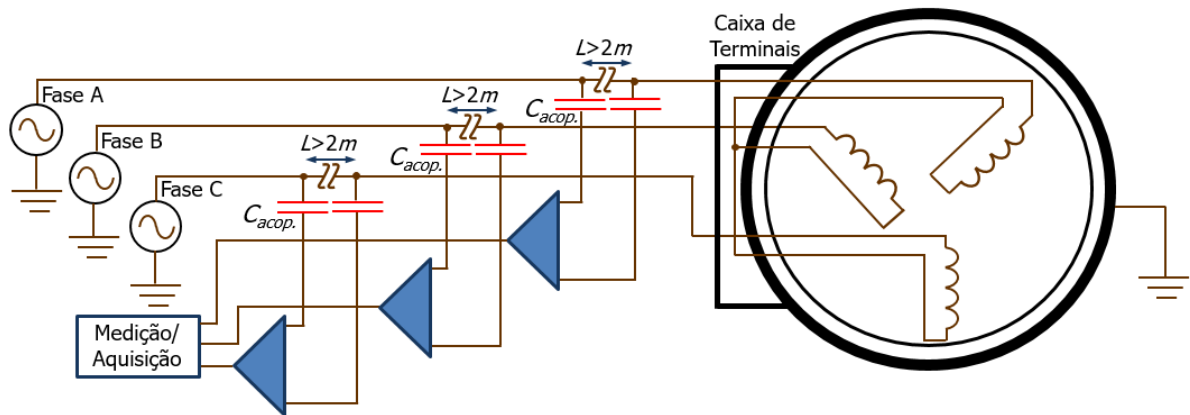


Figura 2.11 – Circuito diferencial para a medição *on-line* das descargas parciais.

A Figura 2.12 mostra a configuração para a medição das DPs utilizando-se RFTCs. A técnica é aplicada para a detecção e a medição, cujo RFTC deve responder as faixas de frequências de  $20MHz - 350MHz$  e  $100kHz - 30MHz$ , respectivamente [22].

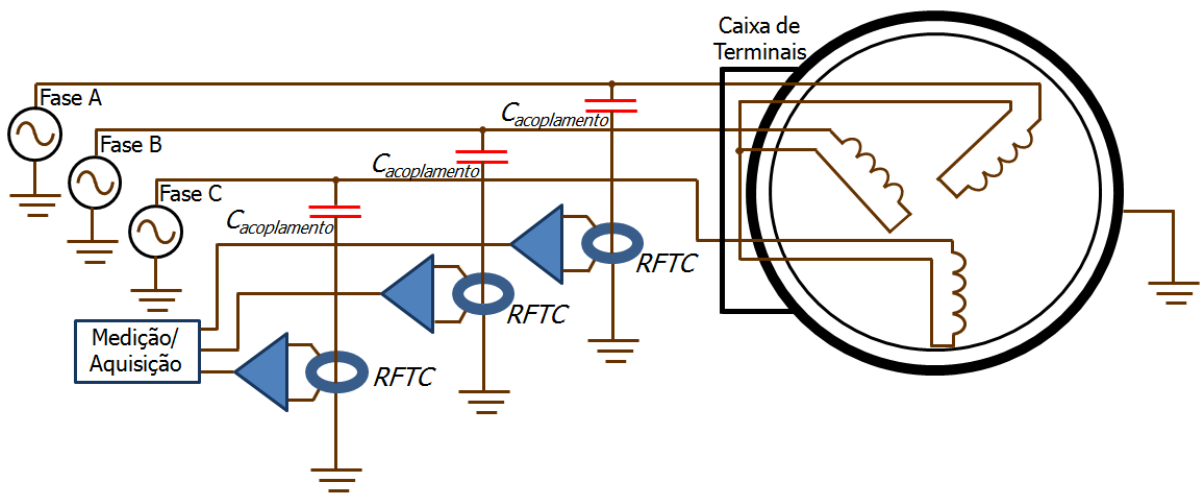


Figura 2.12 – Circuito para a medição *on-line* das descargas parciais com RFTCs.

O padrão IEEE Std-1434 e a norma IEC-60270 também relaciona a detecção das DPs *on-line* a partir de [22, 23]:

- detectores de ozônio instalados no interior do *hood* (enclausuramento) do motor;
- micro antenas instaladas dentro do motor (próximo as cabeças de bobina).

A ação das DPs superficiais, sobretudo nas cabeças de bobinas do motor, produzem uma reação química em contato com o ar adjacente. Um dos subprodutos formados é

o ozônio. A concentração de ozônio cresce com o aumento das DP superficiais, o que não ocorre para as DP internas que não gera uma quantidade significativa deste gás. A instalação de detectores eletrônicos ou tubos que coletam o gás para um analisador externo pode ser utilizado para inferir o aumento das descargas superficiais e a deterioração do isolamento em regiões como nas cabeças de bobinas do enrolamento do estator [22].

As DPs irradiam ondas eletromagnéticas de alta frequência (1,6GHz a 2,0GHz). A instalação de antenas de faixa estreita (*microstrip*) no interior do *hood* do motor pode ser utilizada para detecção de DPs *on-line*. O uso das antenas é recomendado nas proximidades das cabeças de bobinas para a detecção de descargas superficiais e, no interior das ranhuras do núcleo juntamente com os sensores de temperatura do enrolamento para a detecção de descargas internas [22]. A Figura 2.13 ilustra a montagem de uma antena para a detecção de DPs na cabeça de bobinas do enrolamento.




Figura 2.13 – Esquema para a medição *on-line* das descargas parciais com uso de antenas nas cabeças de bobinas.

A avaliação e a detecção da fonte das DPs *on-line* (ADP *on-line*), pode ser realizada empregando as mesmas técnicas da análise *off-line*, sendo algumas apresentadas na Seção 2.1.2 deste trabalho. A padronização não determina valores ou limites de DPs que recomende a parada do motor para a inspeção ou a manutenção. A previsão de defeitos ou falhas no isolamento, a partir da ADP *on-line*, depende, sobretudo, de uma abordagem analítica por parte de especialistas para determinar o estado do isolamento do motor e sua continuidade operacional. [19, 38, 44].

## 2.2.2 Medição da Corrente de Fuga por Fase com HSCTs

Esforços recentes têm se concentrado em técnicas que permitam a avaliação do estado do isolamento do estator de motores de baixa e média tensão. A medição da corrente de fuga com a utilização de HSCTs vem apresentado bons resultados no monitoramento *on-line* do estado do isolamento [12, 25, 26].

As avaliações do isolamento nos trabalhos apresentados por Lee e Younsi [12, 25, 26] utilizam a medição da corrente de fuga por fase dos enrolamentos do estator. A Figura 2.14 mostra como a técnica é empregada, sendo necessários 3 HSCTs e 3 Transformadores

de Potencial (TP). Alternativamente, podem ser empregado 2 TPs com a utilização da conexão em delta aberto para obtenção das tensões de fase. Os autores apresentam o estudo para MITs de BT e MT, com resultados satisfatórios para a avaliação da resistência, da capacitância e do fator de dissipação do isolamento.




Figura 2.14 – Avaliação *on-line* do isolamento com 3 HSCTs e 3 TPs.

Recentemente a empresa americana Bently Nevada, pertencente a General Electric (GE), lançou no mercado o sistema MSIM (*Motor Stator Insulation Monitor*). O MSIM apresenta uma arquitetura de medição similar a apresentada na Figura 2.14. Entretanto, a proposta do fabricante menciona a aplicação do sistema apenas para MITs de MT e de potência entre 1000 e 6000cv. A Figura 2.15 mostra os sensores empregados (HSCTs e TPs), bem como um exemplo da aplicação instalada num cubículo de um MIT de MT [45].




Figura 2.15 – Sistema de monitoramento *on-line* MSIM da GE para MITs de MT [45].

A Figura 2.16 mostra o circuito equivalente simplificado para o sistema de isolamento do motor proposto por Lee e Younsi [12,25,26]. Nessa figura são consideradas as impedâncias de isolamento entre fases e entre fase e terra, sendo:

- $\dot{I}_a$ ,  $\dot{I}_b$  e  $\dot{I}_c$ : corrente de linha do motor das fases  $a$ ,  $b$  e  $c$ ;
- $\dot{I}_{aL}$ ,  $\dot{I}_{bL}$  e  $\dot{I}_{cL}$ : corrente de fuga das fases  $a$ ,  $b$  e  $c$ ;

- $\dot{I}_{L-ab}$ ,  $\dot{I}_{L-bc}$  e  $\dot{I}_{L-ca}$ : corrente de fuga entre as fases  $a$ - $b$ ,  $b$ - $c$  e  $c$ - $a$ ;
- $\dot{I}_{L-ag}$ ,  $\dot{I}_{L-bg}$  e  $\dot{I}_{L-cg}$ : corrente de fuga entre as fases  $a$ ,  $b$  e  $c$  para terra;
- $R_{ab}$ ,  $R_{bc}$  e  $R_{ca}$ : resistência de isolamento entre as fases  $a$ - $b$ ,  $b$ - $c$  e  $c$ - $a$ ;
- $C_{ab}$ ,  $C_{bc}$  e  $C_{ca}$ : capacitância de isolamento entre as fases  $a$ - $b$ ,  $b$ - $c$  e  $c$ - $a$ ;
- $R_{ag}$ ,  $R_{bg}$  e  $R_{cg}$ : resistência de isolamento entre as fases  $a$ ,  $b$  e  $c$  para terra;
- $C_{ag}$ ,  $C_{bg}$  e  $C_{cg}$ : capacitância de isolamento entre as fases  $a$ ,  $b$  e  $c$  para terra;




Figura 2.16 – Circuito equivalente do isolamento em c.a. adaptado de Lee e Younsi [12, 25, 26].

Considerando a tensão de alimentação por fase e a medição das correntes de fuga, os valores equivalentes da resistência ( $R_{eq}^{ca}$ ), da capacitância ( $C_{eq}^{ca}$ ) e do fator de dissipação ( $FD_{eq}^{ca}$ ) *on-line* em c.a. para as fases  $a$ ,  $b$  e  $c$  podem ser obtidos por [25]:

$$R_{eq-a,b,c}^{ca} = \frac{|\dot{U}_{a,b,c}|}{2|\dot{I}_{L-a,b,c}| \sin(\delta_{a,b,c})} \quad (2.21)$$

$$C_{eq-a,b,c}^{ca} = \frac{2|\dot{I}_{L-a,b,c}| \cos(\delta_{a,b,c})}{\omega|\dot{U}_{a,b,c}|} \quad (2.22)$$

$$FD_{eq-a,b,c}^{ca} = \tan(90^\circ - \angle \frac{\dot{U}_{a,b,c}}{\dot{I}_{L-a,b,c}}) \quad (2.23)$$

Por simplicidade de notação, o subscrito  $a, b, c$  utilizado nas equações (2.21), (2.22) e (2.23) representam uma forma compacta a representação por fase desses cálculos. Por exemplo, para fase- $a$  deve ser utilizado  $\dot{U}_a$ ,  $\dot{I}_{aL}$  e  $\delta_a$  para o cálculo dessas respectivas grandezas  $R_{eq-a}^{ca}$ ,  $C_{eq-a}^{ca}$  e  $FD_{eq-a}^{ca}$ . Esta notação também será utilizada em outras partes do trabalho.

Considerando-se o sistema de isolamento equilibrado [25]:

$$\begin{aligned} R_{ab} &= R_{bc} = R_{ca} = R_{ff} \\ R_{ag} &= R_{bg} = R_{cg} = R_{fg} \\ C_{ab} &= C_{bc} = C_{ca} = C_{ff} \\ C_{ag} &= C_{bg} = C_{cg} = C_{fg} \end{aligned} \quad (2.24)$$

Os valores da  $R_{eq}^{ca}$ , da  $C_{eq}^{ca}$  e  $FD_{eq}^{ca}$  *on-line* em c.a. por fase, podem ser expressos de forma alternativa como [25]:

$$R_{eq-a,b,c}^{ca} = \frac{R_{fg}R_{ff}}{3R_{fg} + R_{ff}} \quad (2.25)$$

$$C_{eq-a,b,c}^{ca} = C_{fg} + 3C_{ff} \quad (2.26)$$

$$FD_{eq-a,b,c}^{ca} = \frac{3R_{fg} + R_{ff}}{\omega R_{fg}R_{ff} + C_{fg} + 3C_{ff}} \quad (2.27)$$

A partir do circuito da Figura 2.17, proposto por Lee [25], é obtida a resistência  $R_{eq}^{cc}$ , a capacitância  $C_{eq}^{cc}$  e o fator de dissipação  $FD_{eq}^{cc}$  do isolamento por fase para o teste *off-line* (teste realizado com tensão c.c.):

$$R_{eq-a,b,c}^{cc} = \frac{R_{fg}R_{ff}}{2R_{fg} + R_{ff}} \quad (2.28)$$

$$C_{eq-a,b,c}^{cc} = C_{fg} + 2C_{ff} \quad (2.29)$$

$$FD_{eq-a,b,c}^{cc} = \frac{2R_{fg} + R_{ff}}{\omega R_{fg}R_{ff} + C_{fg} + 2C_{ff}} \quad (2.30)$$

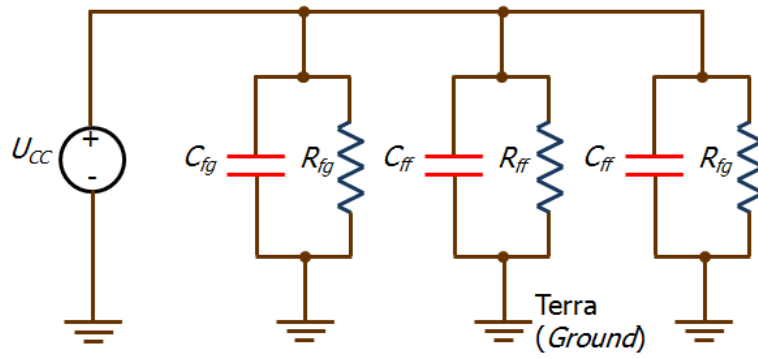


Figura 2.17 – Circuito equivalente por fase para o teste *off-line* em c.c. [25].

A comparação analítica das expressões (2.25) a (2.30) mostra que os valores da resistência, da capacitância e do fator de dissipação obtidos *on-line* são diferentes dos medidos no ensaio *off-line*. De forma geral:

$$\begin{aligned} R_{eq-a,b,c}^{ca} &< R_{eq-a,b,c}^{cc} \\ C_{eq-a,b,c}^{ca} &> C_{eq-a,b,c}^{cc} \\ FD_{eq-a,b,c}^{ca} &> FD_{eq-a,b,c}^{cc} \end{aligned} \quad (2.31)$$

Apesar da diferença entre os valores obtidos, a medição *on-line* mostra-se mais conservadora, uma vez que a resistência de isolamento *on-line* é menor que a encontrada no teste *off-line*. Assim, o acompanhamento preditivo a partir  $R_{eq-a,b,c}^{ca}$  permite a parada do motor antes que o valor mínimo de  $R_I$  recomendado pela IEEE Std-43 seja alcançado [25].

Os trabalhos de Lee e Younsi [12,25,26] apresentam alguns resultados experimentais para o acompanhamento da redução do resistência de isolamento. O primeiro é obtido por meio da instalação de um resistor externo em uma das fases do motor que simula a redução da  $R_I$ . No segundo ensaio a diminuição da  $R_I$  é obtida através do teste de envelhecimento acelerado (*Endurance Test*). De forma similar ao esperado nos testes *off-line*, os resultados obtidos nos experimentos mostram que a técnica *on-line* proposta permite acompanhar e determinar a deterioração do isolamento a partir da resistência, da capacitância e do fator de dissipação com exatidão satisfatória.

### 2.2.3 Proteção *Ground Sensor*

A proteção *ground sensor* não é considerada uma técnica para o acompanhamento preditivo de falhas no isolamento do estator de MITs. Entretanto, esta proteção tem um valor histórico, sendo considerada um dos primeiros esforços para se evitar danos severos ao isolamento quando da ocorrência de sua falha. A função principal da técnica é a de reduzir os danos causados no isolamento pela passagem da corrente de curto-circuito monofásico, limitando-a a valores centenas de vezes menor [46].

A Figura 2.18 mostra a instalação do transformador de corrente (TC) toroidal para realizar a proteção ANSI IEEE 50GS [47] em MITs. O cabo tripolar de alimentação passa através da janela do TC. Os fluxos magnéticos produzidos pelas correntes de fase, quando equilibradas, são anuladas. Desta forma, ao ocorrer o desequilíbrio de corrente em uma das fases (falta monofásica), uma corrente no secundário do TC será induzida e detectada pelo relé de proteção. Caso a corrente seja superior ao ajustado ( $I_{Pick-up}$ ) no relé, o disjuntor ou contator que realiza a alimentação do motor será comandado a abrir, interrompendo a falta [46].

O TC utilizado na função de proteção 50GS, normalmente, tem um range fixo de relação de transformação ( $50 : 5A$ ), independente da potência do motor. Quando o dispositivo de manobra é um disjuntor, a função 50GS tem atuação instantânea, ou seja, não há temporização, causando o desligamento imediato do motor. A Tabela 2.8 mostra os ajustes típicos recomendados [46].




Figura 2.18 – Circuito para a proteção de falta a terra de MITs (ANSI 50GS).

Tabela 2.8 – Ajustes recomendados para a função de proteção 50GS.

Dispositivo de manobra	$I_{Pick-up}(A)$	Tempo ( $ms$ )
disjuntor	15-20A ou $0,2I_{N-motor}$	instantâneo
contator	15-20A	200-400

## 2.3 Utilização de Redes Neurais para o Diagnóstico de Falhas em MITs

O uso de Inteligência Computacional (IC) está se tornando cada vez mais popular na indústria para a detecção, a previsão, o reconhecimento de padrões e a avaliação de sistemas e equipamentos industriais. Técnicas utilizando algoritmos de agrupamento *C-means* e *Fuzzy C-means* para o reconhecimento de padrões de falhas em termogeradores são encontradas no trabalho de Pereira et al. [48]. O emprego de inferência *Fuzzy* e ANFIS (*Adaptive Neuro-Fuzzy Inference System*) para a previsão de carga em sistemas de distribuição de energia elétrica, é o objeto de estudo do trabalho de Ismail et al. [49]. Neste contexto, destaca-se um grande número de aplicações que utilizam Redes Neurais Artificiais (RNA) para a detecção, a classificação e a previsão de falhas. Para a detecção e a avaliação de falhas em equipamentos industriais e MITs, o emprego de RNAs tem se destacado, sendo aplicadas com sucesso no diagnóstico de:

- detecção de falhas em robôs e sistemas de controle industriais [50, 51];
- ADPs *on-line* em MITs [52];
- AEC em MITs para a detecção de barras quebradas, curto entre espiras, etc, [53–57];
- análise de gases dissolvidos em óleo de transformador [58];
- análise de vibração em turbinas a vapor [59];
- detecção de falhas em mancais e rolamentos de turbinas e motores [18, 60, 61].
- previsão do Tempo de Falha (*TF*) em sistemas eletromecânicos e de bombeamento [62, 63];
- estimação de parâmetros de confiabilidade em sistemas robóticos [64];

A capacidade de generalização e aprendizado das RNAs tem motivado sua utilização em diversas áreas de conhecimento (engenharia, medicina, economia, biologia, etc). Aplicações em controle, previsão, reconhecimento de padrões, classificação, detecção e diagnóstico de falhas utilizando RNAs têm sido realizadas com sucesso [65, 66].

Em sistemas industriais, as RNAs estão sendo empregadas para a previsão de falhas em sistemas de controle. No trabalho de Rigatos [50, 51], as RNAs são aplicadas na detecção preditiva de falhas em máquinas e robôs, sendo responsáveis pela segregação da parte defeituosa da célula de manufatura e a sua reconfiguração, sem parada do processo produtivo.

Em equipamentos industriais (motores, bombas, compressores, turbinas, etc), as RNAs tem auxiliado a análise de vibração para diagnosticar e classificar:

- desalinhamento, desbalanceamento e folga mecânica entre motor e carga [18].
- falhas em rolamentos e mancais [61];
- atrito e colisão axial entre rotor e carcaça [60];
- desbalanceamento de rotor de turbinas [59].

As RNAs também têm sido aplicadas com sucesso na previsão de parâmetros de confiabilidade e no tempo de falha de sistemas eletromecânicos e bombas [62–64].

O emprego das RNAs para a previsão do Tempo Falha ( $TF$ ) em sistemas eletromecânicos é aplicado no trabalho de Shprekher et al. [62]. A camada de entrada é composta pelos dados de vibração, temperatura, tensão e corrente dos seis motores da máquina. O autor utiliza uma abordagem que avalia as condições técnicas de operação do sistema. Nesta abordagem duas RNAs são empregadas. A primeira, com estrutura fixa, é usada para classificar a possível falha do equipamento, e a segunda, com uma estrutura semi-estática, é utilizada para a previsão do tempo de falha. Assim, a partir da classificação da falha realizada pela primeira RNA, somente as entradas significativas para aquele modo de falha serão utilizadas pela segunda RNA para a previsão do  $TF$ . Os autores relatam um aumento de 27% de acerto na previsão do  $TF$  utilizando esta abordagem.

No trabalho de Pang et al. [63] é vista uma aplicação de uma RNA do tipo MLP para previsão do  $TF$  de uma bomba de circulação de água em uma usina termelétrica. Os autores realizam uma comparação da previsão do  $TF$  da RNA com um modelo ARIMA (*Auto Regressive Integrated Moving Average*). Os autores comparam o desempenho das técnicas a partir da raiz do erro quadrático médio ( $RMSE$  - *Root Mean Square Error*) para a probabilidade de falha um mês a frente. A RNA apresenta desempenho ligeiramente superior, representando e modelando melhor as não-linearidades da série.

Sheptunov et al. [64] utiliza uma RNA, denominada pelos autores como *ANN Modular Multilayer*, para estimar o valor da função de confiabilidade de um sistema robótico através da sua decomposição em sub-funções realizadas por camadas da RNA. Os autores relatam redução significativa no custo computacional com a utilização da técnica, além da capacidade da RNA em solucionar problemas de complexidade elevada, que não podem ser realizados por *softwares* comerciais de confiabilidade.

Em MITs, as aplicações de RNAs estão concentradas em diagnósticos baseados nas medições das correntes de estator, técnica conhecida com Assinatura Elétrica de Corrente (AEC). Neste contexto as RNAs detectam e classificam defeitos como:

- barras quebradas no rotor [53];
- desbalanceamento e excentricidade do rotor [57];

- sobrecarga e problemas de qualidade da energia na alimentação do motor [54];
- curto-circuito entre espiras do enrolamento do estator [53, 56].

A referência [53] apresenta a aplicação de uma RNA do tipo MLP (*Multilayer Perceptron*) para o diagnóstico de falhas de barras quebradas no rotor, desequilíbrio na tensão de alimentação e curto-circuito entre espiras do enrolamento do estator. A RNA projetada foi treinada utilizando 6 diferentes tipos de algoritmos de aprendizagem:

1. Levenberg Marquardt (LM);
2. *Scaled Conjugate Gradient* (SCG);
3. *Gradient Descent* (GD);
4. *Gradient Descent with Adaptive and Momentum Learning Rate Backpropagation* (GDX);
5. *Conjugate Gradient Backpropagation* (CGB);
6. BFGS Quasi-Newton (BFGS).

O algoritmo de aprendizado que alcançou maior acurácia (95%), com menor tempo e número de iterações para a convergência do MSE (*Mean Square Error*), foi o LM. Os demais algoritmos apresentaram acurácias entre 75% e 90% e maior custo computacional.

A referência [57] mostra a aplicação de um sistema híbrido de IC, construída a partir da combinação do mecanismo de inferência *Fuzzy Max-Min* (FMM) e uma árvore de regressão do tipo CART (*Classification and Regression Tree*), denominado pelos autores com FMM-CART. Neste trabalho, o mecanismo de inferência FMM extrai as regras de aprendizado que serão utilizadas como entrada para a árvore CART.

O algoritmo FMM-CART determina a melhor separação das classes a partir da construção da árvore hierárquica. O sistema foi aplicado para a classificação e o diagnóstico de falhas de excentricidade no rotor de MITs. O espectro de frequência das correntes de estator são utilizadas como entrada. Os resultados mostram acurácias superiores a 99%, acima do obtido pelas redes MLPs, mas próximo dos valores encontrados por SVMs (*Support Vector Machines*).

A referência [54] apresenta a aplicação de uma RNA com função de ativação do tipo RBF (*Radial Basis Function*). Nesta aplicação a RNA detecta e classifica falhas relacionadas à condição de carga e a alimentação do motor. A RNA projetada é usada como algoritmo base para a detecção de falhas elétricas (faltas), substituindo as tradicionais funções de proteção utilizadas em relés de motores. A proposta deste estudo foi detectar e classificar faltas devido a:

1. sobrecarga no motor;
2. subtensão e sobretensão no motor;
3. desequilíbrio de tensão na alimentação;
4. falta de fase no motor;
5. motor sem falha.

As correntes instantâneas do estator são utilizadas como entrada da rede RBF. Após o treinamento, foram alcançadas acurácias de 100% em todos os cenários previstos.

A referência [55] apresenta um estudo comparativo entre diferentes técnicas de IC para a detecção de falhas em MITs. Os métodos abordados neste estudo são:

1. Naive Bayes;
2. *K-Nearest Neighbor*;
3. SMO (*Sequential Minimal Optimization*);
4. Rede Neural MLP;
5. RIPPER (*Repeated Incremental Pruning to Produce Error Reduction*);
6. Árvore de Decisão C4.5.

Falhas em rolamentos, curto-circuito entre espiras no enrolamento do estator, barra quebrada no rotor, variações de carga mecânica e na qualidade da alimentação foram avaliadas a partir da AEC do motor. A rede neural MLP e a SVM apresentaram as maiores acurácias, com valores superiores a 99% em todos os cenários de testes considerados no estudo.

Para a detecção e o diagnóstico de falhas em isolamento de equipamentos elétricos, as pesquisas estão focadas em ADPs de motores de alta tensão, estimação do tempo de vida de materiais isolantes em laboratório e análise de gases dissolvidos em óleo de transformadores.

A referência [52] apresenta a aplicação de uma RNA MLP para classificar e diagnosticar a localização de DPs devido a:

1. efeito corona;
2. descargas internas no isolamento;
3. descargas em cabeça de bobinas;

4. descargas externas (superficiais);
5. descargas no interior de ranhuras do núcleo;
6. sem presença de DPs.

O algoritmo de aprendizado utilizado na rede MLP foi o *Back-Propagation* tipo GD. No estudo, os autores apresentam acurácias de 94,5% para a classificação das falhas. Este resultado é superior as metodologias tradicionais de ADP que não utilizam IC, as quais, em média, alcançam acurácias em torno de 80%.

A referência [58] apresenta a aplicação de RNAs para o diagnóstico e a previsão de falha de transformadores através da análise da concentração de gases dissolvidos no óleo isolante. A rede empregada é do tipo MLP e o algoritmo de aprendizado utilizado é o Levenberg Marquardt (LM). Após o treinamento da rede, foram obtidas acurácias de 93,75% para o diagnóstico e 91,66% para a previsão do tempo de falha do transformador. Os resultados alcançados são superiores aos métodos tradicionais que não empregam inteligência computacional.

A referência [67] mostra a aplicação de uma RNA para a previsão do tempo de falha do material isolante *Relanex*. Neste trabalho, a rede MLP é empregada com o algoritmo de aprendizado LM. A estrutura da rede é composta pelas seguintes entradas:

- $B_a$ : enregia de ativação para polarização do material;
- $B_V$ : energia de ativação para condução;
- $U_k$ : tensão de ruptura;
- $t$ : tempo de avaliação.

A saída da rede fornece uma função aproximada da tensão de ruptura do material, que quando excedido o valor  $U_k$ , retorna o tempo estimado para falha do material. São testadas arquitetura de RNAs com 6, 7 e 10 neurônios na camada escondida, sendo que esta última apresentou resultados de acurácia superiores a 98%.

## 2.4 Conclusões

Este capítulo apresentou o estado da arte das técnicas empregadas para a avaliação do isolamento de MITs. Os principais testes *off-line* e *on-line* padronizados foram relacionados, destacando-se o caráter preditivo de cada um. Uma revisão bibliográfica com alguns trabalhos que utilizam IC, em particular RNAs, também é apresentada.

Nota-se, que a maior parte das técnicas empregadas para a avaliação do isolamento de MITs só podem ser utilizadas quando o motor está fora de operação (*off-line*). Para

o caso *on-line*, as técnicas estão concentradas na ADPs de motores de alta tensão, onde um número significativo de trabalhos e padrões são apresentados. Apenas recentemente, alguns estudos têm sido realizados para a avaliação *on-line* do isolamento de motores de baixa e média tensão, estando concentrados na utilização de HSCTs.

A respeito da utilização de IC com RNAs para o diagnóstico de falhas em equipamentos, seu emprego tem sido implementado com sucesso. Em MITs, seu uso está concentrado na análise de falhas mecânicas a partir de sinais de vibração para identificar falhas em rolamentos, excentricidade do rotor, folga, etc. Para as falhas elétricas, os estudos estão focados no uso da AEC para a detecção de barras quebradas, curto entre espiras e ADPs em motores de alta tensão.

Desta forma, observa-se que existe uma lacuna de técnicas que avaliem o estado do isolamento *on-line* de MITs de baixa e de média tensão. Nota-se também, que ainda não são comuns as aplicações de técnicas de IC no diagnóstico de falhas em isolamento de máquinas elétricas. Essas ferramentas, conforme mostrado neste trabalho, permite a análise mais célere e efetiva por parte dos especialistas.



## 3 Desenvolvimento de Técnicas *Off-line* para a Avaliação do Isolamento

NESTE capítulo é apresentado um estudo com os fundamentos teóricos para a compreensão do sistema de isolamento de MITs. O objetivo deste estudo é fornecer a base para o desenvolvimento das técnicas para a avaliação do sistema de isolamento com o MIT fora de operação (*off-line*), e embasar as propostas de avaliação do isolamento com o motor em operação (*on-line*) que são descritas no Capítulo 4.

Inicialmente é apresentada uma breve introdução a respeito dos tipos de bobinas e materiais empregados no isolamento do estator de MITs de BT e MT. Em sequência, são abordados os modelos que descrevem a circulação de corrente no isolamento quando submetido à aplicação de tensão c.c. e c.a. Os modelos apresentam a decomposição das componentes de corrente que circulam no material, permitindo identificar e compreender o comportamento dos fatores de estresse que acarretam a falha do isolamento de MITs de BT e MT. Também, são descritos os fatores de estresse que acarretam a degradação do isolamento, bem como as principais causas geradoras para estas falhas.

A partir da análise do banco de dados de teste da Petrobras-REDUC [27], são propostos projetos de classificadores baseados em RNAs para a avaliação *off-line* do isolamento de MITs. O classificador *off-line* é projetado a partir do agrupamento das curvas de Perfil da Resistência de Isolamento (PRI) utilizando o algoritmo *K-means*.

Na organização do Capítulo, a Seção 3.1 apresenta os tipos construtivos de bobinas utilizadas no isolamento do estator de MITs de BT e MT, e os modelos em c.c. e c.a. propostos. A Seção 3.2 descreve os principais fatores de estresse e mecanismos de degradação do isolamento. A Seção 3.3 apresenta as propostas para a avaliação *off-line* do isolamento a partir das curvas de PRI e o projeto de classificadores baseados em RNAs. A Seção 3.4 mostra os resultados da classificação dos fatores de estresse do banco de dados de MITs da Petrobras. Por fim, a Seção 3.5 apresenta as conclusões a partir dos estudos realizados e dos resultados obtidos.

### 3.1 Modelo do Isolamento de MITs

#### 3.1.1 Isolamento de MITs de BT e MT

Os enrolamentos de motores de baixa e média tensão, são respectivamente, construídos por bobinas do tipo *random* (aleatórias) e *form* (pré-formadas) [68]. As Figuras 3.1 e 3.2 ilustram os dois tipos de bobinas montadas em estatores de MITs de BT e MT

respectivamente.

As bobinas do tipo *random* são utilizados em motores de baixa tensão ( $< 1000V$ ) e potência até  $100kW$ . As bobinas do tipo *form* são utilizadas em motores de baixa e média tensão ( $> 1000V$ ) com potência superior a  $100kW$  [68,69].




Figura 3.1 – Foto de uma bobina *random* montada no estator de um MIT de BT [69].



Figura 3.2 – Foto de uma bobina *form* montada no estator de um MIT de MT [69].

A Figura 3.3 mostra a montagem em corte de uma bobina *random* na ranhura do estator de um MIT de BT. Nos enrolamentos construídos por este tipo de bobinado, o isolamento entre espiras é formado por um verniz a base de poliesterimida que suporta altas

temperaturas (até  $180^{\circ}\text{C}$ ). Na sua montagem no núcleo, é colocado um filme isolante a base de poliéster e aramida entre as bobinas, formando o “isolamento entre bobinas” [68, 70].

Um papel a base de mica com alto poder de absorção da resina epoxi forma o isolamento principal, ou “*groundwall*”, que envolve um conjunto de bobinas, isolando-as do núcleo. Um filme isolante pode ser colocado na parte superior da bobina para evitar espaços vazios durante a montagem da cunha. Essa, por sua vez, fornece rigidez mecânica à bobina dentro da ranhura para o processo de impregnação [68, 70].

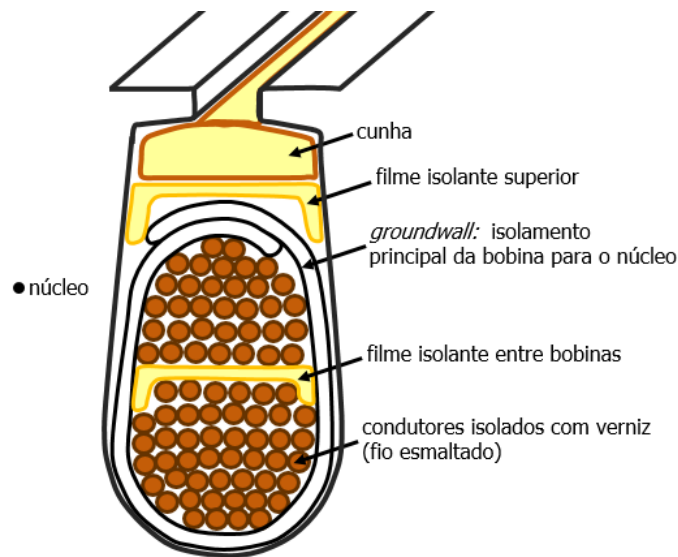


Figura 3.3 – Sistema de isolamento de uma bobina do tipo *random* [68].

Após a montagem das bobinas no núcleo do estator, é realizada a impregnação por imersão e cura do isolamento em estufa. O objetivo desse processo é possibilitar que o verniz preencha os espaços vazios entre as camadas isolantes, assegurando aderência entre os condutores e o núcleo, evitando que movimentações internas ou vibrações danifiquem o isolamento. A Figura 3.4 ilustra um conjunto de estatores de MITs de BT sendo imersos em um tanque com resina epoxi [69].

A Figura 3.5 ilustra a montagem em corte de uma bobina *form* na ranhura do estator de um MIT de MT. Os condutores das espiras deste tipo de enrolamento tem seção retangular, e também são isolados entre si por uma camada de verniz a base de poliesterimida. O conjunto de espiras, que formam a bobina, é isolado com camadas de filamentos de fibra de vidro ou fita a base de mica [68].

O isolamento principal das bobinas do tipo *form* consiste em papel de mica altamente absorvente e tecido de fibra de vidro como base. A resina epoxi é aplicada sobre a bobina para o preenchimento dos espaços vazios e fornecer resistência mecânica durante o processo de impregnação do enrolamento. Em MITs cuja  $U_{N-F} > 5\text{kV}$ , é montada uma fita semicondutora a base de partículas de carbono sobre o conjunto das bobinas para

evitar o efeito corona. Por fim, para a montagem da cunha, filmes isolantes são colocados na parte superior, inferior e entre as bobinas para diminuir os espaços vazios [68, 70].




Figura 3.4 – Processo de impregnação por imersão de MITs de BT construídos por bobinas *random* [69].




Figura 3.5 – Sistema de isolamento de uma bobina do tipo *form* [68].

Após a montagem das bobinas *form* no estator, é realizado o processo de impregnação e cura do enrolamento. O *Global VPI* (*Vacuum Pressure Impregnation*) é, atualmente, a técnica que garante a melhor impregnação para MITs de MT. Após a impregnação é realizado o processo de cura do isolamento através de secagem em estufa [68, 70].

A Figura 3.6 ilustra as etapas de impregnação através do processo de VPI [70]:

- Figura 3.6-a: o enrolamento é colocado dentro de um tanque onde é retirado o ar e a umidade do isolamento com uso de vácuo;
- Figura 3.6-b: o tanque é preenchido com resina a temperatura em torno de  $60^{\circ}C$ , onde o enrolamento será mergulhado. Nesta etapa o vácuo é aplicado para retirada de bolhas na resina;
- Figura 3.6-c: é aplicada pressão positiva no tanque para que a resina preencha os espaços vazios do isolamento;
- Figura 3.6-d: o enrolamento fica em repouso para o escoamento e a drenagem do tanque sob pressão atmosférica.




Figura 3.6 – Etapas do processo de VPI em MITs de MT [70].

### 3.1.2 Modelo do Isolamento no Domínio do Tempo Submetido a Tensão c.c. e c.a.

O modelo matemático para o isolamento, apresentado nesta seção, permite compreender o comportamento da corrente de fuga ( $I_L$ ) que circula através do material dielétrico. A partir da sua avaliação é possível determinar a influência dos fatores de estresse nas componentes da corrente  $I_L$ , possibilitando inferir a causa para a degradação do isolamento.

De forma geral, a densidade de corrente  $\vec{J}(t)$  que atravessa um material isolante pode ser escrita como [71]:

$$\vec{J}(t) = \sigma \vec{E}(t) + \epsilon_0 \frac{\partial \vec{E}(t)}{\partial t} + \frac{\partial \vec{P}(t)}{\partial t} \quad (3.1)$$

Onde:

- $\vec{J}(t)$ : densidade de corrente em ( $A/m^2$ );
- $\sigma$ : condutividade do material em ( $S/m$ );
- $\epsilon_0$ : permissividade no vácuo ( $8,85419 \text{ pF/m}$ );
- $\vec{E}(t)$ : campo elétrico em ( $V/m$ );
- $\vec{P}(t)$ : polarização elétrica ( $C/m^2$ ).

O vetor de polarização elétrica  $\vec{P}(t)$ , pode ser decomposto em duas parcelas, uma de polarização rápida  $\vec{P}(t)_{\text{Rapid}}$  e outra de polarização lenta  $\vec{P}(t)_{\text{Slow}}$  [71]:

$$\vec{P}(t) = \vec{P}(t)_{\text{Rapid}} + \vec{P}(t)_{\text{Slow}} \quad (3.2)$$

$$\vec{P}(t)_{\text{Rapid}} = \epsilon_0(\epsilon_r - 1)\vec{E}(t) \quad (3.3)$$

$$\vec{P}(t)_{\text{Slow}} = \epsilon_0 \int_0^t f(\tau)\vec{E}(t - \tau)d\tau \quad (3.4)$$

A parcela  $\vec{P}(t)_{\text{Rapid}}$  corresponde a polarização de cargas livres no material, que formam a parcela de natureza capacitiva da corrente. A porção  $\vec{P}(t)_{\text{Slow}}$  representa a interação da resposta dos dipolos elétricos do material  $f(\tau)$  com o campo elétrico externo  $\vec{E}(t)$  [71, 72].

Substituindo as equações (3.3) e (3.4) em (3.1), tem-se:

$$\vec{J}(t) = \sigma \vec{E}(t) + \epsilon_0 \epsilon_r \frac{\partial \vec{E}(t)}{\partial t} + \epsilon_0 \int_0^t f(\tau)\vec{E}(t - \tau)d\tau \quad (3.5)$$

O primeiro, o segundo e o terceiro termos da equação (3.5) correspondem, respectivamente, às parcelas de densidade de corrente condutiva, capacitiva e de polarização (absorção). Aplicando-se uma tensão  $U(t)$ , obtém-se a expressão para a corrente que circula no material isolante [72]:

$$I(t) = \sigma U(t) \frac{C_0}{\epsilon_0} + C_0 \epsilon_r \frac{\partial U(t)}{\partial t} + C_0 \int_0^t f(\tau) U(t - \tau) d\tau \quad (3.6)$$

Onde:

- $C_0$ : capacitância do material isolante considerando suas dimensões no vácuo ( $F$ );
- $\epsilon_r$ : permissividade relativa do material isolante;
- $C_0 \epsilon_r = C_I$ : capacitância do material isolante ( $F$ ).

Se  $U(t) = \alpha t$ , onde  $\alpha$  é o gradiente da tensão aplicada em c.c., a função  $f(t)$  para temperatura constante pode ser aproximada por [72, 73]:

$$f(t) = At^{-n} \quad \text{onde } A = K \frac{C_I}{C_0} = K \epsilon_r, \text{ para } t > 1s \quad (3.7)$$

O valor de  $K$  pode ser interpretado como a energia inicial de polarização do material. Os valores de  $K$  e  $n$  dependem do tipo de isolante empregado. Nos trabalhos de Farahani [72] e David [73] são mostrados resultados de testes para o levantamento destas constantes em materiais a base de epoxi, mica e poliéster. A Tabela 3.1 mostra os valores típicos de  $K$  e  $n$  para isolantes novos à temperatura de  $25^{\circ}C$  [73].

Tabela 3.1 – Valores típicos de  $K$  e  $n$  de isolantes novos a base de epoxi, mica e poliéster.

Material	$K(S^{n-1})$	$n$
mica-epoxi	0,012	0,93
mica asfáltica	0,054	0,85
poliéster	0,12	0,68

Solucionando a equação (3.6) a partir da aproximação de  $f(t)$  dada em (3.7), tem-se:

$$I(t) = \sigma U(t) \frac{C_0}{\epsilon_0} + C_I U(t) \delta(t) + C_I U(t) K t^{-n} \quad (3.8)$$

A equação (3.8) mostra as parcelas de corrente que circulam no isolamento durante a aplicação de tensão c.c., onde:

- $I_G(t) = \sigma U(t) \frac{C_0}{\epsilon_0}$  é a corrente condutiva responsável pelas perdas no material isolantes;

- $I_C(t) = C_I U(t) \delta(t)$  é a corrente de surto capacitiva;
- $I_P(t) = C_I U(t) K t^{-n}$  é a corrente necessária para a polarização do material isolante.

A análise da equação (3.8) mostra a influência de cada parcela de corrente que circula no isolamento durante o ensaio de  $R_I$ . De forma geral, a  $R_I$  com a aplicação de tensão c.c. ao longo do tempo pode ser dada por:

$$R_I(t) = \frac{U(t)}{I_G(t) + I_C(t) + I_P(t)} = \frac{1}{\sigma \frac{C_0}{\epsilon_0} + C_I \delta(t) + C_I K t^{-n}} \quad (3.9)$$

A medição de  $R_I$  é realizada após 1 minuto (60s) do início do teste. Desta forma, como a corrente de surto capacitiva é praticamente nula após este intervalo, o valor de  $R_I$  será apenas função de  $I_P + I_G$ , assim:

$$R_{I-1min} \approx \frac{U(t)}{I_G + I_{P-1min}} = \frac{1}{\sigma \frac{C_0}{\epsilon_0} + C_I K 60^{-n}} = \frac{1}{\sigma K_0 + C_I K_1} \quad (3.10)$$

Onde:

- $K_0 = \frac{C_0}{\epsilon_0}$ ;
- $K_1 = K 60^{-n}$

Para determinar os índices de polarização ( $IP$ ) e absorção ( $IA$ ) do isolamento, são utilizadas relações a partir das medições de  $R_I$  conforme visto na Seção 2.1.1. Na medição de  $R_{I-10min}$ , a parcela de corrente  $I_P$  após 10 minutos se torna desprezível, circulando apenas a parcela de corrente condutiva  $I_G$ , desta forma:

$$R_{I-10min} \approx \frac{U(t)}{I_G} = \frac{1}{\sigma K_0} \quad (3.11)$$

A  $R_{I-30s}$  pode ser derivada da equação (3.10) como:

$$R_{I-30s} \approx \frac{U(t)}{I_G + I_{P-30s}} = \frac{1}{\sigma K_0 + 2^{-n} C_I K_1} \quad (3.12)$$

Desta forma, os valores de  $IP$  e  $IA$  podem ser re-escritos como:

$$IP = \frac{R_{I-10min}}{R_{I-1min}} \approx \frac{C_I K_1}{\sigma K_0} + 1 \quad (3.13)$$

$$IA = \frac{R_{I-1min}}{R_{I-30s}} \approx \frac{\sigma K_0 + 2^n C_I K_1}{\sigma K_0 + C_I K_1} \quad (3.14)$$

As equações (3.13) e (3.14) mostram como os parâmetros de capacitância ( $C_I$ ) e condutividade ( $\sigma$ ) do isolamento influenciam na determinação dos índices de polarização

e absorção. Quando ocorre a degradação do isolamento por algum fator de estresse, os valores da  $C_I$  e da  $\sigma$  sofrem alterações. Assim, é possível avaliar o estado do isolamento através da variação dos índices  $IP$  e  $IA$  com a máquina fora de operação (*off-line*). Na Seção 3.2 serão discutidos os fatores de estresse que levam a deterioração do isolamento, bem como as relações entre os fatores e as variações esperadas para o  $IP$  e o  $IA$ .

Quando uma tensão c.a. é aplicada ao isolamento, a parcela de corrente devido à polarização lenta do material pode ser considerada desprezível ( $\vec{P}(t)_{slow} \approx 0$ ) [71]. Desta forma, a equação (3.6) pode ser escrita como:

$$I(t) = \sigma K_0 U(t) + C_I \frac{\partial U(t)}{\partial t} \quad (3.15)$$

Considerando a aplicação da tensão  $U(t) = U_{N-max} sen(\omega t)$ :

$$I(t) = U_{N-max} \{ \sigma K_0 sen(\omega t) + \omega C_I cos(\omega t) \} \quad (3.16)$$

A equação (3.16) pode ser escrita na forma fasorial como:

$$\dot{I} = |\dot{I}_R| + j|\dot{I}_C| \quad (3.17)$$

Onde:

- $|\dot{I}_R| = I_R = \sigma K_0 U_{N-max}$
- $|\dot{I}_C| = I_C = \omega C_I U_{N-max}$

Assim, pode-se determinar a resistência e capacitância equivalente em c.a. como:

$$R_{eq} = \frac{U_{N-max}}{|I_R|} = \frac{1}{\sigma K_0} \quad (3.18)$$

$$C_{eq} \approx C_I \quad (3.19)$$

Da definição de Fator de Dissipação ( $FD$ ) da Seção 2.1.3, tem-se:

$$FD = \frac{I_R}{I_C} = \frac{\sigma K_0}{\omega C_I} \approx \frac{1}{2\pi f C_{eq} R_{eq}} \quad (3.20)$$

Nota-se que o valor de  $FD$  pode ser obtido a partir dos parâmetros equivalentes de resistência ( $R_{eq}$ ) e capacitância ( $C_{eq}$ ) do isolamento em c.a. Observa-se que, a menos de constates, o  $FD$  é uma relação inversa dos índices  $IP$  e  $IA$ . Uma redução no  $IP$  ou no  $IA$  obtidos a partir dos testes do isolamento em c.c., refletirão num aumento do  $FD$  do ensaio em c.a.

Conforme apresentado na Seção 2.1.3, a identificação do estado do isolamento sujeito a estresse térmico pode ser feito a partir da monitoração do aumento do  $FD$ .

Entretanto, para a identificação de contaminação ou absorção de umidade, o valor do  $FD$  deve ser monitorado juntamente com o aumento da capacitância ( $C_{eq}$ ).

Os valores de  $R_{eq}$ ,  $C_{eq}$  e  $FD$  podem ser obtidos de forma *on-line*, conforme mostrado na Seção 2.2.2, ou através da proposta apresentada na Seção 4.1 deste trabalho. Desta forma, nota-se que é possível a realização da avaliação do estado do isolamento, e a identificação dos fatores que acarretam na sua degradação com o motor em operação (*on-line*).

A análise isolada dos parâmetros e índices, não permite determinar de forma precisa os fatores de estresse que deterioram o isolamento. Como mostrado no Capítulo 2, é necessária a análise conjunta dos dados. O desenvolvimento teórico apresentado demonstra que é possível realizar o diagnóstico do estado do isolamento a partir da avaliação:

- *off-line* da  $R_I$ ,  $C_I$ ,  $IP$  e  $IA$  em c.c.;
- *on-line* da  $R_{eq}$ ,  $C_{eq}$  e  $FD$  em c.a.

Nas Seções 3.3 e 4.3 serão propostos, respectivamente, classificadores *off-line* e *on-line*, baseados em redes neurais para a avaliação do estado do isolamento utilizando como entradas as grandezas e índices destacados acima.

## 3.2 Fatores de Estresse e Mecanismos de Degradação do Isolamento

A redução da  $R_I$ , normalmente, está associada a algum fator de estresse que está agindo sobre o isolamento, alterando a estrutura física ou química do material. Esses fatores disparam algum mecanismo de degradação que causam redução gradativa da sua capacidade dielétrica. Stone et al. [68] relaciona os fatores térmico, elétrico, mecânico e ambiental, cujos os autores denominam como " *Team Stress* ", como sendo os mais relevantes no processo de degradação do isolamento.

O gráfico da Figura 3.7 mostra o estudo realizado por O'Donnell [74–76] com o levantamento dos fatores de estresse e as suas respectivas causas. A estatística foi realizada com 483 motores em indústrias do setor de óleo e gás dos Estados Unidos, mostrando que o estresse térmico é o fator que mais causa falhas no isolamento do estator de MITs.

Os fatores de estresse podem agir de forma constante ao longo do tempo ou atuar de forma transiente. Quando a ação do fator é constante, o tempo de falha será proporcional ao número de horas de operação do motor. Por outro lado, uma ação transiente de um fator de estresse acarreta num tempo de falha proporcional à magnitude e ao número de transientes ao qual a máquina foi submetida [68].




Figura 3.7 – Estatística dos fatores de estresse e causas de falhas no isolamento do estator de grandes MITs [74–76].

### 3.2.1 Estresse Térmico

O estresse térmico é o fator que desencadeia a maior parcela de falhas em isolamentos. Segundo estudos de O'Donnell [74–76] e de Thorsen et al. [77], o estresse térmico representa cerca de 43% das falhas no isolamento elétrico do estator de MITs de MT e AT, podendo ser superior a 50% em MITs de BT. A origem de temperaturas elevadas no isolamento, superior à sua classe térmica, está associada a condições operacionais, fatores ambientais, defeitos no sistema de proteção e problemas de qualidade na alimentação do motor. Dentre algumas dessas causas pode-se citar [32, 68]:

- sobrecargas mecânicas: elevação da temperatura devido ao aumento da carga no eixo do motor. Associado a esse fato, normalmente, a proteção térmica ou de sobrecarga está com o ajuste superior ao recomendado;
- defeitos em relés térmicos: perda da calibração permitindo que o motor opere com sobrecarga;
- deficiência ou perda do sistema de refrigeração do motor: quebra de ventoinhas, obstrução dos trocadores de calor, baixa vazão dos fluidos de resfriamento (água, ar), etc;
- ciclos de partidas excessivas: o motor opera em regime de trabalho diferente da sua especificação, sendo demandadas várias partidas em curtos intervalos de tempo, acarretando em ciclos de aquecimento e resfriamento que ocasionam a delaminação acelerada do isolamento;

- desequilíbrio de tensões: aumentam a magnitude das correntes de sequência negativa no estator, contribuindo para a elevação de temperatura e torque pulsante na carga;
- distorção harmônica na tensão de alimentação: harmônicas de sequência negativa na tensão de alimentação também ocasionam a circulação de correntes de sequência negativa no enrolamento do estator.

As causas relacionadas acima acarretam a elevação da temperatura do isolamento acima da temperatura especificada pela sua classe térmica. De acordo com o limite de trabalho dos materiais empregados no isolamento, a norma IEC 60034-1 [78] relaciona as classes vistas na Tabela 3.2:

Tabela 3.2 – Classe térmica do isolamento.

classe	temperatura ( $^{\circ}C$ )
A	105
E	120
B	130
F	155
H	180

Quando o isolamento é submetido a temperaturas acima da sua classe térmica, ocorre uma reação de oxidação no material dielétrico, ocasionando degradações como o ressecamento, a formação de fissuras (rachaduras) e a delaminação do isolamento. A delaminação é o processo de separação do material em camadas devido à perda da força de coesão da resina de impregnação. O tempo de vida do isolamento em função do estresse térmico pode ser aproximado pela Lei de Arrhenius [79]:

$$L = L_n e^{-k \left( \frac{\Delta T}{T_n(T_n + \Delta T)} \right)} \quad (3.21)$$

Onde:

- $L$ : tempo de vida restante do isolamento (horas);
- $L_n$ : tempo de vida nominal do isolamento (horas);
- $T_n$ : temperatura de nominal do isolamento de acordo com sua classe ( $^{\circ}C$ );
- $\Delta T$ : elevação da temperatura do isolamento ( $K$ );
- $k$ : constante que depende do material isolante. Para o isolamento a base epoxi-mica  $k \approx 2011, 1^{\circ}C^{-1}$ .

Segundo a equação (3.21), para cada incremento de  $\Delta T = 10^0C$  na temperatura nominal do isolamento, a vida útil do isolamento é reduzida pela metade. Nota-se, então, a criticidade para se identificar algum processo de degradação do isolamento ocasionado pelo estresse térmico.

O isolamento submetido a algum mecanismo de degradação térmica apresenta alterações em suas propriedades físico-químicas (densidade, dureza, tensão superficial, energia de polarização, etc) e elétricas. Ocorre o aumento da condutividade ( $\sigma$ ) do isolamento com a redução da capacitância ( $C_I$ ). Nesse último caso, a delaminação e o ressecamento aumenta a quantidade de espaços vazios no isolamento que serão preenchidos com ar, que possui permissividade menor que a do material dielétrico [72].

O efeito da degradação térmica faz com que ocorra o aumento no valor de  $K$  (energia inicial de polarização) e da condutividade, com a redução do expoente  $n$ , uma vez que os dipolos restantes no material são aqueles com forte energia de ligação. Assim, apesar do aumento da condutividade diminuir o valor do  $IP$  e do  $IA$  (equações (3.13) e (3.14)), a elevação do valor de  $K$  associado à redução de  $n$ , resulta numa elevação global de  $IP$  e  $IA$  [72].

No trabalho de Farahani [72] são apresentadas algumas expressões aproximadas para  $K$  e  $n$  em função da exposição permanente de um isolante a base de epoxi a uma determinada temperatura. Em seu estudo, amostras de bobinas são submetidas a uma diferença de potencial e temperatura constantes por um período de 1600 horas. As equações (3.23) e (3.22), mostram que, o valor de  $K$  pode aumentar em 60 vezes, e  $n$  pode diminuir em até 30% para o intervalo de temperatura considerado.

$$n(T) = 0,878e^{-0,00226T} \quad , \text{ para } 40^0C < T < 180^0C \quad (3.22)$$

$$K(T) = 0,016e^{0,029T} \quad , \text{ para } 40^0C < T < 180^0C \quad (3.23)$$

Assim, quando o isolamento é afetado pelo estresse térmico, os valores dos índices  $IP$  e  $IA$  tendem a aumentar com o tempo, isto porque os valores de  $K$  e  $n$  não são mais constantes, sendo alterados em função da ação da temperatura. O valor da condutividade aumenta e a capacitância tende a sofrer uma pequena redução ao longo do tempo [72, 80].

### 3.2.2 Fatores Ambientais

Os fatores ambientais estão relacionados à absorção de umidade, ou à contaminação do material dielétrico por óleo/graxa e sujeira com presença de partículas condutoras ou agentes químicos. [32, 68]. Em conjunto, os fatores ambientais correspondem a 32% das falhas do isolamento do estator de MITs de MT e AT, sendo que este percentual pode chegar a quase 40% para MITs de BT [74–77].

### 3.2.2.1 Absorção de Umidade

Para MITs de MT e AT a absorção de umidade representa um percentual de 20% de falhas no isolamento de MIT, e para MITs de BT este percentual ultrapassa os 30% [32, 68]. A característica higroscópica do material dielétrico faz com que a umidade seja absorvida, ocorrendo o preenchimento dos espaços vazios entre as moléculas do material dielétrico pelas moléculas de água. Isto ocorre porque a pressão de vapor da água no isolante, normalmente, é menor que a sua pressão de vapor no ar [68].

Os sais dissolvidos na água são absorvidos pelo isolamento aumentando a sua condutividade. Também, ocorre aumento da capacitância, pois a permissividade da água é maior que a do dielétrico. O mecanismo de degradação do isolamento pela absorção de umidade ocorre pela redução acentuada da resistência do isolamento, ocasionando elevadas correntes de fuga com maiores perdas dielétricas. Esse processo, muitas vezes, acarreta a elevação de temperatura localizada num ponto do isolamento, culminando em sua falha [32].

Normalmente, a absorção de umidade está associada a problemas de vedação nas caixas de ligação do motor, ou de furos em tubos internos do sistema de refrigeração, no caso do motor possuir sistema de resfriamento por água [80]. A água presente no interior do motor é absorvida pelo isolamento ocasionando rápida redução da  $R_I$  e aumento da  $C_I$ . O acréscimo relativo de 1% na umidade do isolamento, acarreta um aumento de quase 100 vezes da sua condutividade, e de até 50 vezes da sua capacitância [81, 82].

Motores mantidos desenergizados por longos períodos podem apresentar redução da resistência do isolamento pela absorção de umidade ambiente. Isso ocorre, principalmente, pelo fato da resistência de aquecimento do motor estar desenergizada, ou da sua ausência no MIT. Motores operando continuamente com temperaturas inferiores a  $80^{\circ}\text{C}$  também podem ter o seu isolamento afetado pela absorção de umidade [32].

### 3.2.2.2 Contaminação por Óleo

Cerca de 11% das falhas no isolamento de MITs é originada da contaminação do material dielétrico por óleo/graxa e sujeira com presença de partículas condutoras [74–76]. Geralmente, a contaminação do isolamento está associada ao excesso de material lubrificante nos rolamentos ou nos mancais do motor que migram para o material dielétrico. Em MITs de BT a lubrificação pode ser realizada por óleo ou graxa em seus rolamentos. O excesso de graxa, normalmente é atribuída a quantidade inadequada do lubrificante colocada nos pinos de lubrificação em manutenções preventivas. Já, o excesso de óleo é atribuída a ajustes inadequados dos dosadores automáticos [68, 80]. A Figura 3.8 ilustra a localização do pino de lubrificação na carcaça de um MIT de BT. A Figura 3.9 mostra um sistema automático de lubrificação, conhecido como "oil mist" [69].

O sistema de *oil mist* da Figura 3.9 é composto por uma central eletrônica programável, uma bomba e um reservatório de óleo. Do sistema são ramificadas várias saídas que são conectadas aos pinos de lubrificação dos rolamentos dos MITs.



Figura 3.8 – Pinos de lubrificação de rolamentos de um MIT de BT [69]




Figura 3.9 – Sistema automático de lubrificação de MITs [69]

Em MITs de MT e AT, o excesso de lubrificante está associado a defeitos dos anéis de selagem dos mancais que permite que o óleo migre para o material isolante. Normalmente, o óleo ou a graxa de lubrificação está contaminada por partículas condutoras (advindo de sujeira ou do desgaste dos metais dos rolamentos ou dos mancais). O óleo ou a graxa contaminada gera uma camada na superfície do isolamento que aumenta as correntes de

fuga, contribuindo para o aumento das perdas dielétricas. Quando associado a temperatura, o processo de contaminação é intensificado, pois o óleo ou a graxa sofre um processo de oxidação acelerada, aumentando a condutividade do isolamento com consequente redução da  $R_I$  [68, 80].

Na contaminação superficial por óleo, ou na absorção de umidade, ocorre o aumento da condutividade e da capacitância do isolamento. Entretanto, a  $C_I$  é maior quando o dielétrico absorve umidade, pois a permissividade da água é maior que a do óleo ou da graxa. Como consequência os valores do  $IP$  e do  $IA$  serão reduzidos, porém, para o caso da absorção de umidade os valores do  $IP$  e do  $IA$  serão ligeiramente maiores. [36, 80].

### 3.2.3 Estresse Elétrico

Para MITs de AT, o estresse elétrico representa 18% das falhas no isolamento do estator. Esse fator está associado, sobretudo, a ocorrência das DPs [74–76]. Conforme visto na Seção 2.1.2, as DPs acarretam a degradação do isolamento por um processo erosivo das descargas disruptivas, ocasionado então, a falha do material dielétrico. As DPs ocorrem em MITs de AT ( $> 6kV$ ) alimentados diretamente pela rede elétrica. Entretanto, as DPs também podem ocorrer em MITs BT e MT alimentados por conversores eletrônicos de potência [83, 84], cujas altas taxas de variação de tensão ( $dU/dt$ ) da saída destes conversores podem ultrapassar os limiares para a geração de descargas no interior do isolamento. Associado ainda ao estresse elétrico, o isolamento pode vir a falhar devido a sobretensões transitórias, como impulsos de manobras (energização de transformadores, transferências de alimentadores, etc) e descargas atmosféricas [68].

Cabe ressaltar que não será investigada a degradação do isolamento devido ao estresse elétrico, uma vez que não é objetivo deste trabalho abordar as falhas no isolamento de MITs de AT, ou MITs de BT e MT alimentados por conversores eletrônicos de potência.

### 3.2.4 Fatores Mecânicos

Em grandes motores (MITs de AT e de MT com potência superiores a 300cv), o estresse mecânico representa um percentual de 7% das falhas totais no isolamento. Em MITs de BT este percentual é menor que 1% [77].

O estresse mecânico está associado a forças centrífugas, esforços eletrodinâmicos durante a partida do motor e a vibração mecânica ao qual o isolamento possa estar submetido. As forças centrífugas agem no rotor da máquina podendo ocasionar a quebra ou o desprendimento das barras (condutores) do rotor, acarretando curto-circuitos, ou abrasão de materiais entre o rotor e o núcleo do estator [32, 68].

Durante a partida do motor, as altas correntes que circulam no estator e rotor, geram forças de atração e repulsão entre os condutores que podem fragilizar as fixações

do isolamento do estator, promovendo abrasão entre os condutores e posterior falha do isolamento [68].

A vibração no isolamento pode ter origem [32, 68]:

- na carga mecânica acoplada ao eixo do motor;
- no desbalanceamento de massa do eixo do rotor do motor;
- em torques pulsantes gerados por desequilíbrios de tensão ou da distorção harmônica na tensão de alimentação;

Para os casos citados acima, o efeito da vibração também pode gerar a quebra das amarrações das cabeças das bobinas em grandes motores, ocasionando a abrasão entre os condutores e danos ao isolamento. Também, caso as cunhas e calços dos condutores nas ranhuras do núcleo não estejam bem fixas, pode ocorrer a abrasão do isolamento entre os condutores das bobinas com consequente ruptura do isolamento [68].

O mecanismo de degradação de um fator de estresse mecânico atua criando microfissuras no isolamento, ou no caso da abrasão, a perda de massa e rigidez dielétrica do material. Em MITs de AT, onde as DPs estão presentes, o processo de falha é acelerado, pois nos espaços vazios criados pelas microfissuras ocorre a erosão do isolante pela ação das descargas [68].

Conforme mostrado nos Capítulos 1 e 2, existem um grande número de técnicas para a realização dos diagnósticos do circuito e do desbalanceamento do rotor a partir da AEC (Assinatura Elétrica de Corrente) que permitem identificar a ação do estresse mecânico sobre o motor. Também, já se encontra bem consolidada, a detecção de falhas relacionadas a carga acoplada no eixo do motor a partir da análise de vibração mecânica. Em ambos os casos, são obtidos resultados satisfatórios onde empregadas essas técnicas.

Desta forma, como os fatores de estresse mecânicos podem ser tratados através de outras técnicas preditivas, além de serem pouco representativas nas falhas totais de isolamento em MITs de BT e MT, tais fatores não serão objetos de estudo deste trabalho.

### 3.2.5 Fatores de Estresse em MITs de BT e MT Alimentados Diretamente pela Rede

Mais de um fator de estresse pode agir simultaneamente no isolamento do motor. Para MITs de AT, o estresse elétrico ocasionados por DPs sempre estará presente. Assim outros fatores como o estresse térmico, o mecânico ou o ambiental podem estar degradando simultaneamente o isolamento do motor [32].

Para o caso de MITs de BT ou MT alimentados diretamente pela rede, onde as DPs não estão presentes, normalmente, a degradação do isolamento se dá apenas por um fator de estresse.

Os fatores ambientais (absorção de umidade e contaminação por óleo/sujeira) e o estresse térmico são naturalmente excludentes. Isto significa que, se o isolamento estiver absorvendo umidade e ocorrer elevação da temperatura acima de  $100^{\circ}\text{C}$ , a umidade será eliminada do isolamento, e apenas o estresse térmico permanecerá. Caso ocorra a contaminação por óleo e ocorrer o estresse térmico, a contaminação por óleo vai prevalecer, pois a temperatura irá deteriorar o óleo de forma acelerada, acentuando a condutividade no isolamento e gerando a sua falha antes da ação de oxidação da temperatura. Neste último caso, o mecanismo de degradação presente está mais relacionado à contaminação do material dielétrico do que os efeitos de delaminação ou fissuras causados pelo estresse térmico.

Ainda para MITs de BT e MT, na ocorrência de absorção de umidade ou de contaminação por óleo/sujeira, também encontra-se uma situação de prevalectimento de apenas um fator de estresse afetando o isolamento. Como as duas substâncias são imiscíveis, o mecanismo de degradação que prevalecerá será aquele que agir primeiro no isolamento ao longo do tempo. Por exemplo, caso ocorra primeiro a absorção de umidade e posteriormente a contaminação por óleo, a camada de óleo funcionará como uma barreira, possibilitando que a umidade permaneça no isolamento. Numa situação inversa, a umidade seria impedida de ser absorvida, pois a camada de óleo não permitiria a penetração da água no isolamento.

Caso estejam presentes os fatores de estresse mecânico e ambiental, o fator ambiental prevalecerá, pois as micro-fissuras causadas pelo estresse mecânico facilitará a absorção e a contaminação do isolamento, levando a sua falha em um tempo muito menor. De forma geral, os fatores ambientais agem de forma mais acelerada, ocasionando a falha do isolamento em um tempo menor, quando comparado aos fatores mecânicos e térmicos. No Capítulo 5 deste trabalho, são apresentados resultados experimentais que reforçam esta tese. Os testes mostram que um MIT submetido a absorção de umidade, por exemplo, pode ter a falha do seu isolamento em questão de dias. Por outro lado, para que ocorra a falha deste mesmo MIT pelo estresse térmico, é necessário a exposição contínua do seu isolamento a uma temperatura de  $200^{\circ}\text{C}$  por quase um mês.

Para os casos em que os fatores mecânicos e térmicos estejam presentes, a distinção destes através do acompanhamento dos índices  $IP$  e  $IA$ , ou da  $C_I$  e  $FD$ , por exemplo, são difíceis de serem realizados, pois os mecanismos de degradação em ambos os casos apresentam efeitos semelhantes no material dielétrico. Em outras palavras, como a ação destes dois fatores de estresse acarretam em degradações como fissuras e delaminação do isolamento, as variações no  $IP$ , no  $IA$ , na  $C_I$  e no  $FD$  serão semelhantes. Entretanto, a ação do estresse mecânico para MITs de BT e MT apresenta-se como um fator de falha

percentualmente baixo (menor que 1% [77]). Assim é plausível desconsiderá-lo como um fator de estresse que afeta o isolamento de MITs de BT e MT.

O Apêndice A mostra a compilação de um banco de dados de testes com a classificação de falhas do isolamento de MITs de BT e MT. Os motores classificados neste banco de dados apresentaram somente um fator de estresse (térmico, umidade ou contaminação óleo/sujeira) como a causa da falha do seu isolamento, reforçando a tese mencionada acima.

Para cada um dos fatores de estresse agindo sobre o isolamento, é previsto um procedimento adequado para a manutenção do motor. Neste trabalho são abordados os fatores de estresse térmico e ambientais (absorção de umidade e contaminação por óleo e sujeira). Assim, para esses fatores devem ser utilizadas as seguintes recomendações de manutenção [68]:

- motor sob ação de estresse térmico (degradação térmica como ressecamento, fissuras ou delaminação): neste caso é recomendado rejuvenescimento do isolamento através da imersão do estator em verniz. Para motores de MT, recomenda-se impregnação sob vácuo, para evitar bolhas no isolamento. Após a secagem na estufa, em temperatura inferior a  $120^{\circ}C$ , deve-se realizar os ensaios elétricos, prevendo, no mínimo, a medição da resistência de isolamento e o cálculo do  $IP$ ;
- motor apresentando umidade: caso o motor possua a resistência de aquecimento, inicialmente pode se tentar a secagem do enrolamento em campo através da mesma por no mínimo 24 horas. Se o motor continuar apresentando  $R_I$  menor que o recomendado, será necessário a secagem do enrolamento em estufa, em temperatura inferior a  $120^{\circ}C$ . Geralmente, esse procedimento é capaz de retirar a umidade do isolamento tornando-o apto novamente à operação. Após a secagem, caso o motor apresente baixa resistência de isolamento, será necessário realizar o procedimento de rejuvenescimento;
- motor contaminado por óleo, agentes químicos, partículas condutoras, etc: trata-se do procedimento com maior complexidade, pois, em primeiro lugar é necessário a lavagem cuidadosa do estator com solventes dielétricos e sua posterior secagem em estufa. Caso o motor apresente baixa resistência de isolamento, será necessário realizar o procedimento de rejuvenescimento;

Nas próximas seções, são abordadas técnicas para a detecção e a classificação dos fatores de estresse térmico e ambientais (absorção de umidade e contaminação por óleo/sujeira), que abrangem a maior parcela dentre os fatores de estresse que afetam o isolamento de MITs de BT e MT alimentados diretamente pela rede.

### 3.3 Projeto de RNAs para a Classificação dos Fatores de Estresse do Isolamento

A determinação do fator de estresse que acarreta a degradação prematura do isolamento é de grande importância para o planejamento de manutenção. A identificação prévia do estado do isolamento do motor proporciona aos gestores um controle de custo e prazo eficiente sobre a intervenção.

As próximas seções abordam o desenvolvimento de algoritmos baseados em IC para avaliar e classificar os fatores de estresse mencionados anteriormente, bem como definir a condição de operação do MIT.

#### 3.3.1 Avaliação do Isolamento através do PRI

Inteligência Computacional (IC) vem sendo empregada com êxito em aplicações de classificação de dados. Neste contexto, ferramentas de aprendizagem não supervisionadas, como os algoritmos de agrupamento *K-means*, *Hierarchical Clustering* e *Fuzzy C-means* são utilizados para o entendimento e a construção de modelos, que auxiliam na análise exploratória e visualização de agrupamentos (classes) [85, 86].

Neste trabalho, o algoritmo *K-means* foi empregado para o agrupamento das curvas de Perfil de Resistência de Isolamento (PRI) semelhantes, que auxiliam o especialista na classificação do banco de dados mostrado no Apêndice A deste trabalho. O agrupamento das curvas de PRI semelhantes permite inferir qual o fator de estresse está deteriorando o isolamento de cada motor.

O Anexo A do IEEE Std-43 [13] menciona a possibilidade da avaliação da condição do isolamento a partir da curva obtida durante o ensaio de resistência de isolamento, cujo resultado é o Perfil de Resistência de Isolamento (PRI). Entretanto, o padrão não mostra como avaliar o estado do isolamento a partir do PRI.

Este trabalho sugere o agrupamento de curvas de PRI semelhantes para auxiliar na identificação do fator de estresse que está degradando o isolamento. O banco de dados de motores apresentado no Apêndice A possui as curvas de PRI e os relatórios de testes dos motores.

O banco de dados do Apêndice A foi construído a partir dos relatórios de testes de 116 motores. Desse total, 100 motores apresentam 2 resultados de testes e 16 possuem apenas um. Assim, são disponíveis um total de 216 dados de  $R_I$ ,  $C_I$ ,  $IP$ ,  $IA$  e  $FD$ . Devido à quantidade de dados das curvas de PRI, seus valores não são disponibilizados neste trabalho.

A Tabela 3.3 mostra a quantidade de MITs por potência e classe de tensão do banco de dados apresentado no Apêndice A.

Os motores testados estão em operação por períodos que variam de 5 a 15 anos na Refinaria Duque de Caxias (REDUC) da Petrobras, em unidades operacionais de processo e utilidades (geração de energia elétrica e vapor). Os MITs são de baixa e média tensão com potência superior a 50cv e são considerados críticos para o processo onde estão instalados. Conforme estabelecido no plano de manutenção, esses motores são testados anualmente.

Tabela 3.3 – Quantitativo de motores por potência e classe de tensão do banco de dados (Apêndice A).

Aplicação	Potência (cv)	Classe de tensão	Quantidade de motores
Processo	$50 < P \leq 250$	BT	18
	$> 250$	MT	41
Utilidades	$50 < P \leq 250$	BT	18
	$> 250$	MT	39

O agrupamento das curvas de PRI foi feito utilizando-se o algoritmo *K-means*. O princípio do algoritmo é construir grupos (*clusters*) de dados similares minimizando a variância intra-*clusters* [87].

$$\underset{(C_1 \dots C_K)}{\text{Minimizar}} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i,i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\} \quad (3.24)$$

A equação (3.24) pode ser escrita em função dos centroides de cada *cluster* como:

$$\underset{(C_1 \dots C_K)}{\text{Minimizar}} \left\{ \sum_{k=1}^K 2 \sum_{i \in C_k} \sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2 \right\} \quad (3.25)$$

$$\bar{x}_{kj} = \frac{1}{|C_k|} \sum_{i \in C_k} x_{ij} \quad (3.26)$$

Onde:

- $K$ : número total de *clusters* (centroides);
- $x_{ij}$ : conjunto dos dados (*data sets*), contendo  $i$  amostras (observações) e  $j$  características;
- $\bar{x}_{kj}$ : é a média da característica  $j$  no cluster  $k$  (centroide);
- $|C_k|$ : número de amostras em cada *cluster*;

O algoritmo *K-means* é utilizado para medir a similaridade entre as amostras e os centroides  $\bar{x}_{kj}$  de um conjunto de dados  $x_{ij}$ . A lógica do algoritmo *K-means* funciona da seguinte forma:

- 1 - é atribuído a uma amostra  $i$ , pertencer a um determinado *cluster*  $k$  de forma aleatória (preenchimento da matriz de partição  $U$ );
- 2 - é calculado o centroide  $\bar{x}_{kj}$  de cada *cluster*;
- 3 - é calculada a distância (variância) entre todas as  $i$  amostras em relação a todos os  $K$  centroides;
- 4 - é verificada a mínima distância de cada amostra em relação a cada centroide. Assim, é atribuído a esta amostra pertencer ao *cluster* cuja variância seja a mínima (menor distância);
- 5 - atualização da matriz  $U$ ;
- 6 - o algoritmo é repetido até que a matriz  $U$  não mude entre duas interações consecutivas.

As equações (3.27), (3.28), (3.29) e (3.30) apresentam as principais medidas de similaridades utilizadas para a construção dos *clusters* [88, 89]:

- Euclideana: é a distância métrica ordinária entre as amostras  $x_{ij}$  em relação a média  $\bar{x}_{kj}$  do *cluster*  $k$ .

$$d = \sqrt{\sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2}$$

$$i \in C_k$$

$$k = 1 : K$$
(3.27)

- correlação: é a medida de similaridade entre dois conjuntos de dados  $x_{ij}$  com *cluster*  $C_k$ , e  $x_{hj}$  com *cluster*  $C_c$ , utilizado a correlação de Pearson. A medida de correlação varia de  $-1 \leq \rho \leq 1$ . Se  $\rho = 1$  os conjuntos são idênticos. Caso  $\rho = 0$  os conjuntos são completamente não correlacionados, e se  $\rho = -1$  os conjuntos são perfeitamente opostos.

$$\rho = \frac{\sum_{j=1}^p (x_{ij} - \bar{x}_{kj})(x_{hj} - \bar{x}_{cj})}{\sqrt{\sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2} \sqrt{\sum_{j=1}^p (x_{hj} - \bar{x}_{cj})^2}}$$

$$i \in C_k \quad \text{e} \quad h \in C_c$$

$$k, c = 1 : K$$
(3.28)

- cosseno: mede a similaridade entre dois vetores ( $x_{ij}$  e  $x_{hj}$ ) com produto interno no espaço através da medida do cosseno do ângulo entre eles.

$$c = 1 - \frac{\sum_{j=1}^p (x_{ij} x_{hj})}{\sqrt{\sum_{j=1}^p x_{ij}^2} \sqrt{\sum_{j=1}^p x_{hj}^2}}$$

$$i \in C_k \text{ para todo } k \quad \text{e} \quad h \in C_c \text{ para todo } c$$
(3.29)

- Manhattan: também conhecida como distância de Cityblock, é a soma das diferenças absolutas entre as coordenadas cartesianas de dois conjuntos de amostras ( $x_{ij}$  e  $x_{hj}$ ).

$$m = \sqrt{\sum_{j=1}^p |x_{ij} - x_{hj}|} \quad (3.30)$$

$i \in C_k$  para todo  $k$  e  $h \in C_c$  para todo  $c$

O tipo de medida de similaridade empregada no algoritmo *K-means* depende da aplicação. Em séries temporais, onde o formato é mais importante, a distância baseada na correlação pode apresentar melhores resultados quando comparada a métricas baseadas apenas na magnitude (distâncias Euclidiana ou Manhattan) [87].

Cada curva de PRI dos motores testados apresenta 120 pontos de medição de resistência de isolamento amostradas a cada 5s (total de 10 minutos de teste de acordo com o IEEE Std-43).

Utilizando a equação (3.31), as curvas foram normalizadas para o intervalo entre 0 a 1. Esta normalização é necessária, pois as curvas possuem magnitudes com grande variabilidade, o que pode aumentar o custo computacional ou comprometer o desempenho esperado pelo algoritmo.

$$y_n(k) = \frac{y(k)}{y_{máx}} \quad (3.31)$$

Onde:

- $y_n(k)$ : é o vetor de dados normalizados;
- $y(k)$ : é a série a ser normalizada;
- $y_{máx}$ : é o maior valor da série;

*A priori*, conforme a classificação pré-definida, foi considerado um número de *clusters* igual a 4, sendo esperado 3 classes de motores com defeito e 1 classe de motores sem defeito. Aplicando o algoritmo *K-means* nas curvas de PRI com a medida de correlação para a similaridade (equação (3.28)), 4 distintos grupos foram obtidos. Alguns relatórios da base de dados possuem fotografias das inspeções dos motores. Essas informações auxiliaram na identificação dos 4 agrupamentos retornados pelo algoritmo *K-means* em:

- motores com isolamento bom;
- motores com isolamento apresentando absorção de umidade;
- motores com isolamento apresentando contaminação por óleo/sujeira;
- motores com isolamento sob ação térmica.

As Figuras 3.10, 3.11, 3.12 e 3.13 mostram os *boxplots* dos agrupamentos obtidos pelo *K-means*. O *boxplot* é uma ferramenta estatística que auxilia visualmente a análise de dispersão de dados. São mostrados nas figuras a mediana de cada amostra (círculo com um ponto preto no centro). Os limites do retângulo (*box*) representam a quantidade de valores compreendidos entre os *quartis* 25% e 50%. As linhas acima e abaixo do *box* possuem tamanho de 1,5 vezes a sua altura, compreendendo 99,3% dos valores da amostra ( $\pm 2,7\sigma$  - desvio padrão) quando estas estão normalmente distribuídas. Os demais valores, fora do *box* são representados pelo marcador "+" nos gráficos.

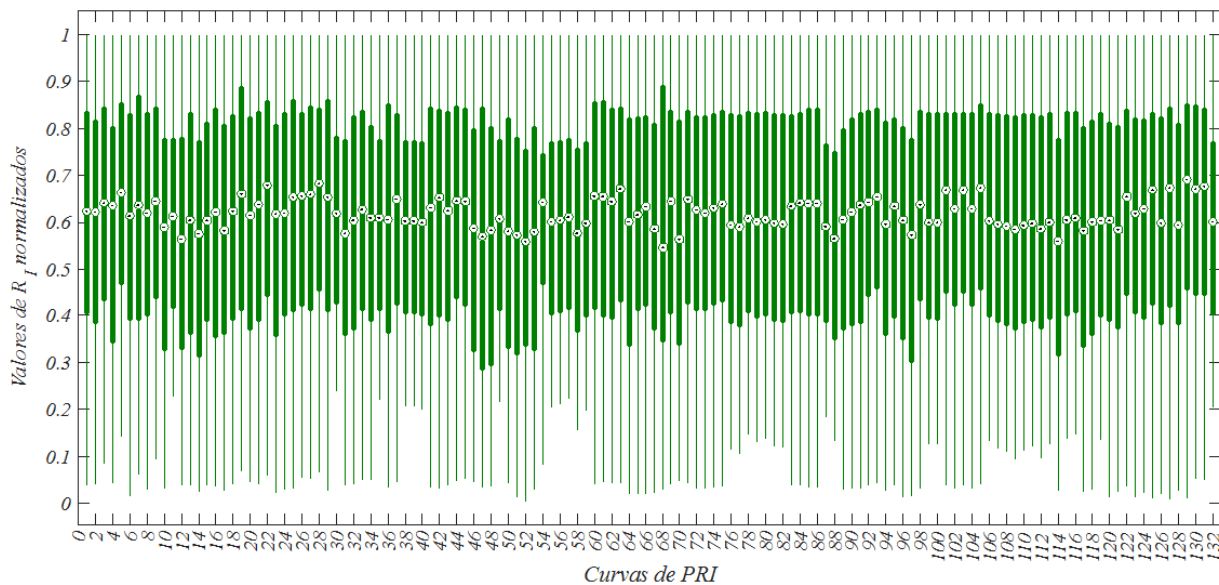


Figura 3.10 – *Boxplot* das curvas de PRI de motores com isolamento bom.




Figura 3.11 – *Boxplot* das curvas de PRI de motores apresentando umidade no isolamento.




Figura 3.12 – *Boxplot* das curvas de PRI de motores apresentando contaminação por óleo/sujeira no isolamento.




Figura 3.13 – *Boxplot* das curvas de PRI de motores sob ação térmica no isolamento.

A análise visual das Figuras 3.10, 3.11, 3.12 e 3.13 mostra que a mediana e a distribuição das amostras por agrupamento (classe) possuem um certo padrão. Entretanto, nota-se uma distinção considerável da mediana e da distribuição dos dados entre as classes, o que permitiu a distinção dos grupos pelo *K-means* utilizando a métrica de correlação.

A Tabela 3.4 mostra o quantitativo de PRIs por grupo produzido pelo algoritmo *K-means*, e a rotulação identificada para cada grupo (classe).

A Figura 3.14 mostra o gráfico com as curvas de PRI que representam os centroides de cada grupo. Conforme esperado, as curvas possuem perfis distintos para cada tipo de fator de estresse que age sob o isolamento. De forma geral, o perfil das curvas centroides,

representam o comportamento médio esperado no ensaio de  $R_I$  para um isolamento bom, ou afetado por algum fator de estresse (umidade, contaminação ou térmico).

Tabela 3.4 – Rotulação feita para os grupos resultantes do *K-means*.

<i>Cluster</i>	Número de motores
Umidade	34
Óleo/sujeira	39
Bom	132
Térmico	10




Figura 3.14 – Gráfico com as curvas de PRI que representam o centroide de cada agrupamento realizado pelo algoritmo *K-means*

Alguns exemplos de curvas de PRIs para os agrupamentos realizados pelo algoritmo *K-means* são mostrados a seguir.

A Figura 3.15 mostra a fotografia do estator de um motor de baixa tensão exemplificando um isolamento em bom estado. Esse motor foi removido para manutenção devido a um problema mecânico. O isolamento do estator foi inspecionado e testado, não apresentando nenhuma evidência de falha ou contaminação. A curva de PRI desse motor é apresentada na Figura 3.16.

A Figura 3.16 mostra a curva de PRI típico de um isolamento em bom estado. O aumento exponencial da resistência ocorre antes do primeiro minuto de teste com a redução das correntes  $I_C$  e  $I_P$ . Após esse intervalo a corrente  $I_C$  é praticamente nula e o aumento da  $R_I$  seguirá o decaimento lento da corrente de polarização  $I_P$ . Os isolamentos

em bom estado apresentam  $IP > 2,5$  e  $IA > 1,5$ , sem mudanças abruptas da  $R_I$  durante o teste.




Figura 3.15 – Estator de um motor com isolamento em bom estado.




Figura 3.16 – Curva de PRI típica de um motor com o isolamento em bom estado a 40°C.

A Tabela 3.5 mostra os resultados de  $R_I$ ,  $C_I$ ,  $IP$ ,  $IA$  e  $FD$  para o estator do motor em bom estado apresentado na Figura 3.15.

Tabela 3.5 – Testes do motor MVE104 exemplificando uma curva de PRI de um motor em bom estado.

Data do teste	$R_I(M\Omega)$	$C_I(pF)$	$IP$	$IA$	$FD(\%)$
Nov/2011	1750	37750	4,59	1,53	0,04015

A Figura 3.17 mostra a fotografia de um motor de baixa tensão retirado de operação e encaminhado para a manutenção devido à umidade em seu isolamento. Observa-se marcas de ferrugem no núcleo provocadas por oxidação devido à presença da água. A curva de PRI desse motor é apresentada na Figura 3.18.



Figura 3.17 – Estator de um motor com o isolamento apresentando umidade.

A Figura 3.18 mostra o efeito da umidade sobre a curva de PRI. Observa-se uma redução acentuada na  $R_I$  ocasionada pelo aumento significativo das correntes condutiva  $I_G$  e capacitiva  $I_C$ .

A Tabela 3.6 apresenta os resultados de  $R_I$ ,  $C_I$ ,  $IP$ ,  $IA$  e do  $FD$  antes e no momento da parada do motor da Figura 3.17, que ocorreu antes da falha do seu isolamento. Verifica-se que o aumento da condutividade  $\sigma$  (proporcional ao inverso da resistência) é maior que o da capacitância do isolamento. Assim, a partir de uma rápida investigação das equações (3.13) e (3.14), nota-se que os valores de  $IP$  e  $IA$ , como esperado, são menores. Desta forma, quando o isolamento do motor está absorvendo umidade, os valores de  $IP$  e  $IA$  tem ordem de grandezas semelhantes, porém menores que o recomendado.




Figura 3.18 – Curva de PRI de um MIT em processo de absorção de umidade a  $40^{\circ}C$ .

Tabela 3.6 – Testes do motor MP1328 em bom estado e apresentando umidade.

Data do teste	$R_I(M\Omega)$	$C_I(pF)$	$IP$	$IA$	$FD(\%)$
Ago/2014	1286	7100	3,7	1,54	0,78610
Out/2015	151	15800	1,37	1,23	6,0530

A Figura 3.19 mostra o estator de um motor de baixa tensão retirado de operação e levado para manutenção devido à degradação térmica em seu isolamento. Nesta figura podem ser observados sinais de ressecamento através da coloração escura do enrolamento e das amarrações quebradas nas cabeças de bobinas, provocadas pela exposição ao efeito térmico por longos períodos. A curva de PRI desse motor é apresentada na Figura 3.20.

A Figura 3.20 mostra a redução e a ocorrência de variações na  $R_I$  ao longo do teste. Essas podem ser explicadas pela ocorrência de falhas nas camadas do isolamento por delaminação ou descargas parciais internas. Assim, quando o isolamento é sujeito à ação térmica, os valores do  $IP$  e do  $IA$  aumentam significativamente, sendo superiores aos recomendados.

A Tabela 3.7 apresenta os resultados de  $R_I$ ,  $C_I$ ,  $IP$ ,  $IA$  e do  $FD$  antes e no momento da parada do motor, que ocorreu antes da falha de seu isolamento. Uma investigação da tabela mostra que a capacitância do isolamento quase não se altera. Entretanto, a resistência é reduzida significativamente. O aumento do  $IP$  e do  $IA$  está atribuído, conforme visto na Seção 3.1.2, a alterações estruturais do material que demanda maior energia para a sua polarização.




Figura 3.19 – Estator de um motor com o isolamento apresentando degradação térmica.




Figura 3.20 – Curva de PRI de um MIT apresentando degradação térmica a  $40^{\circ}\text{C}$ .

Tabela 3.7 – Testes do motor AGM1 em bom estado e apresentando degradação térmica.

Data do teste	$R_I (M\Omega)$	$C_I (pF)$	$IP$	$IA$	$FD(\%)$
Jun/2012	2259	40250	4,88	1,81	0,05860
Dez/2013	210,8	37825	9,66	5,87	0,5450

A Figura 3.21 mostra o estator de um motor de média tensão retirado de operação e encaminhado para manutenção devido a contaminação por graxa e sujeira em seu isolamento. Na figura pode ser observado grande quantidade de graxa lubrificante dos mancais do motor sobre o enrolamento do estator. A curva de PRI desse motor é apresentada na Figura 3.22. A Tabela 3.8 apresenta os resultados de  $R_I$ ,  $C_I$ ,  $IP$ ,  $IA$  e do  $FD$  antes e no momento da parada do motor, que ocorreu antes da falha de seu isolamento.



Figura 3.21 – Estator de um motor com o isolamento contaminado por óleo/sujeira.




Figura 3.22 – Curva de PRI de um MIT apresentando contaminação por óleo/sujeira a  $40^{\circ}C$ .

A Figura 3.22 mostra a ocorrência de variações na  $R_I$  ao longo do teste, que podem ser explicadas por descargas parciais na superfície contaminada pelo óleo e partículas condutoras depositadas sobre o isolamento. Assim, quando o isolamento está sujeito a esse tipo de contaminação, os valores do  $IP$  e do  $IA$  também são menores que o recomendado.

A Tabela 3.8 mostra que ocorre o aumento da capacitância com a redução da resistência do isolamento. Entretanto, as variações são menores quando comparada ao mecanismo de absorção de umidade. Como o redução da  $R_I$  é mais acentuada que o aumento da  $C_I$ , uma avaliação do  $IP$  e do  $IA$  a partir das equações (3.13) e (3.14), mostra que, também, ocorrerão a redução destes índices.

Tabela 3.8 – Testes do motor MP102B em bom estado e contaminado por óleo/sujeira.

Data do teste	$R_I(M\Omega)$	$C_I(pF)$	$IP$	$IA$	$FD(\%)$
Nov/2011	1210	22300	4,71	1,64	0,20870
Dez/2012	357	33500	1,82	1,43	0,41220

### 3.4 Classificador *Off-line* para a Avaliação do Isolamento

O algoritmo *K-means* auxiliou na identificação e na rotulação das curvas de PRI dos motores. Entretanto, não é possível determinar a condição de operação do motor pelo mesmo. Como mencionado anteriormente, a maioria dos setores de manutenção elétrica realizam apenas o ensaio de resistência de isolamento, com um megôhmetro, quando ocorre a parada do motor. Assim, a falta do recurso apropriado para a obtenção da curva de PRI, impossibilita a detecção do fator de estresse que está deteriorando o isolamento a partir do algoritmo *K-means*, conforme apresentado na Seção 3.4.1.

Desta forma, propõem-se nesta seção o projeto de RNAs para a detecção e a classificação do fator de estresse que está acarretando a degradação do isolamento do estator, bem como determinar a condição de operação do MIT.

Nas RNAs propostas, são utilizadas as seguintes entradas de dados:

- RNA3: 3 entradas ( $R_I$ ,  $IP$  e  $IA$ );
- RNA4: 4 entradas ( $R_I$ ,  $IP$ ,  $IA$  e  $C_I$ );
- RNA5: 5 entradas ( $R_I$ ,  $IP$ ,  $IA$ ,  $C_I$  e  $FD$ ).

As RNAs propostas foram testadas com 6, 8 e 10 neurônios numa arquitetura com apenas uma camada escondida. Os resultados de acurácias das RNAs foram muito similares e, por razões de custo computacional, optou-se pelo uso da arquitetura com 6

neurônios na camada escondida. Os resultados de acurácia e de performance das redes são apresentadas na Seção 3.4.1.

Motores com  $R_I$  menores que  $100M\Omega$  e  $5M\Omega$ , em média tensão e baixa tensão, respectivamente, foram considerados inapropriados para operar. Assim, a camada de saída do classificador foi definida com 4 neurônios, onde:

- saída 1 (bom): motor em condição de operação (1-motor opera, 0-motor não opera);
- saída 2 (umidade): motor apresentando degradação ou falha no isolamento devido à presença de umidade (1-existência de umidade, 0-sem umidade);
- saída 3 (óleo/sujeira): motor apresentando degradação ou falha no isolamento devido à contaminação de óleo/sujeira (1-existência de óleo/sujeira, 0-sem óleo/sujeira);
- saída 4 (térmico): motor apresentando degradação ou falha no isolamento devido a estresse térmico ou envelhecimento (1-existência de estresse térmico, 0-sem estresse térmico);

A Figura 3.23 mostra a arquitetura da RNA projetada para a avaliação do isolamento dos MITs do banco de dados do Apêndice A. A rede utilizada é do tipo *Multilayer Perceptron* (MLP) *feedforward*. Do total dos padrões apresentados no banco de dados, 70% foram usados para o treinamento e 30% para a validação da rede.




Figura 3.23 – Arquitetura da RNA para a avaliação do isolamento do estator *off-line*.

O algoritmo de aprendizado utilizado foi o *Resilient Backpropagation* (RPROP) [90]. Esse método utiliza o sinal da derivada parcial  $\partial e(t)/\partial w_{ij}$  (derivada parcial do erro em

relação ao peso  $w_{ij}$ ), ao invés do valor da derivada para ajustar os pesos da rede. Essa estratégia elimina as pequenas correções realizadas nos pesos quando a derivada tende a 0 ou 1. Assim, o peso  $w_{ij}(t)$  e o seu incremento  $\Delta w_{ij}(t)$  numa interação  $t$  serão ajustados conforme as equações (3.32) e (3.33) [65, 90]:

$$w_{ij}(t) = w_{ij}(t - 1) + \Delta w_{ij}(t) \quad (3.32)$$

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t), & \text{se } \frac{\partial e(t)}{\partial w_{ij}} > 0 \\ +\Delta_{ij}(t), & \text{se } \frac{\partial e(t)}{\partial w_{ij}} < 0 \\ 0, & \text{se } \frac{\partial e(t)}{\partial w_{ij}} = 0 \end{cases} \quad (3.33)$$

O incremento  $\Delta_{ij}(t)$  será adaptado de acordo com o sinal da derivada entre duas iterações. O objetivo é avaliar se o último ajuste reduziu o erro, permitindo reforçar a taxa de aprendizagem  $\eta$  para acelerar a convergência do algoritmo. Assim, quando  $\partial e(t)/\partial w_{ij}$  mantém o sinal, indicando que na última iteração o incremento de  $\Delta_{ij}(t)$  reduziu o erro, o valor de  $\Delta_{ij}(t)$  é aumentado pelo fator  $\eta^+$ . No caso de mudança do sinal, indicando que a correção foi elevada, o valor de  $\Delta_{ij}(t)$  é reduzido pelo fator  $\eta^-$ , alterando a direção do ajuste dos pesos  $w_{ij}$ . A equação (3.34) resume a regra de adaptação descrita [90].

$$\Delta_{ij}(t) = \begin{cases} \eta^+ \Delta_{ij}(t - 1), & \text{se } \frac{\partial e(t-1)}{\partial w_{ij}} \frac{\partial e(t)}{\partial w_{ij}} > 0 \\ \eta^- \Delta_{ij}(t - 1), & \text{se } \frac{\partial e(t-1)}{\partial w_{ij}} \frac{\partial e(t)}{\partial w_{ij}} < 0 \\ \Delta_{ij}(t - 1), & \text{se } \frac{\partial e(t)}{\partial w_{ij}} = 0 \end{cases} \quad (3.34)$$

### 3.4.1 Resultados do Classificador *Off-Line*

Esta seção apresenta os resultados da classificação do banco do Apêndice A das RNAs projetada na Seção 3.3. Foram realizados um total de 20 treinamentos para cada uma das RNAs, e apenas as redes que apresentaram acurácias iguais a 100% no treinamento foram utilizadas para a validação.

A Tabela 3.9 mostra os resultados de acurácias por classe (saída) para as redes RNA3, RNA4 e RNA5 no processo de treinamento e de validação. As acurácias por saídas foram superiores a 96% na validação para as 3 arquiteturas de redes consideradas.

Tabela 3.9 – Acurácia por classe no treinamento e validação para as redes RNA3, RNA4 e RNA5.

Classe	Acurácia treinamento (%)	Acurácia validação (%)		
		RNA5	RNA4	RNA3
Umidade	100	100	100	100
Óleo/sujeira	100	100	98,46	98,46
Bom	100	98,46	98,46	96,62
Térmica	100	100	100	100

A Tabela 3.10 mostra a comparação da acurácia média considerando os acertos para as 4 saídas das redes. Esta tabela também apresenta o resultado de Falsos Positivos e Falsos Negativos das RNAs. Nota-se que os resultados de acurácia, os Falsos Positivos e os Falsos Negativos entre as RNAs são muito semelhantes, onde:

- Falso Positivo: motor apresentado falha ou sofrendo com a ação de algum fator de estresse, mas a rede o avalia em condição de operação e/ou não apresentando fator de estresse agindo no seu isolamento;
- Falso Negativo: motor em condição de operação e não sofrendo com a ação de algum fator de estresse, mas a rede o avalia sem condição de operação e/ou apresentando algum fator de estresse degradando seu isolamento;

Tabela 3.10 – Acurácia Média, Falsos Positivos e Negativos das RNAs.

RNA	Acurácia média		Treinamento		Validação	
	treinamento	validação	F. Pos.	F. Neg.	F.Pos.	F. Neg.
RNA5	100%	98.46%	0	0	0	1
RNA4	100%	98.46%	0	0	0	1
RNA3	100%	96.62%	0	0	0	2

A Tabela 3.11 mostra o erro, o gradiente do erro, o tempo de processamento e o número de épocas durante o processo de treinamento das redes. Os resultados demonstram que o número de entradas não afetam significativamente a performance das RNAs.

Tabela 3.11 – Comparação entre as performance das RNAs.

Parâmetro	RNA3	RNA4	RNA5
Erro	$5,21 \times 10^{-3}$	$4,00 \times 10^{-4}$	$2,00 \times 10^{-4}$
Gradiente	$7,13 \times 10^{-4}$	$3,31 \times 10^{-6}$	$7,7 \times 10^{-8}$
Tempo (s)	115	105	115
Épocas	3000	3000	3000

Considerando os resultados do processo de validação apresentados pela RNA3, cuja acurácia foi superior a 96%, é possível visualizar graficamente, através da Figura 3.24, a separação de classes e a avaliação da condição de operação do motor realizada por essa rede. Nota-se que, além da classificação quanto ao fator de estresse que está afetando o isolamento, a RNA3 mostra os motores que não estão aptos a operar (padrões marcados com “x” vermelho na figura).

A Figura 3.25 mostra o gráfico em 2D da classificação de todos os dados do Apêndice A considerando os índices  $IP$  e  $IA$ . Conforme esperado, nota-se que existe uma separação entre os grupos que determina os fatores de estresse, de forma análoga aos grupos produzidos pelo algoritmo *K-means* vistos na Seção 3.3.1.

A Figura 3.25 mostra uma sugestão de intervalos que delimitam as regiões para cada classe. A partir da figura, é construída a Tabela 3.12 onde são inferidos limites numéricos de  $IP$  e de  $IA$  para a determinação das classes. Os intervalos mostrados na tabela são orientativos, cujo objetivo é de permitir que técnicos de manutenção possam detectar e classificar um fator de estresse agindo no isolamento de forma rápida. Entretanto, por poder ocorrer sobreposição de alguma variável ( $IP$  e  $IA$ ) na determinação das classes, um diagnóstico mais preciso deve ser obtido com o uso da RNA proposta.




Figura 3.24 – Resultado da classificação e da avaliação do isolamento dos MITs no processo de validação realizada pela RNA3.




Figura 3.25 – Classificação dos dados do Apêndice A e limites para  $IP$  e  $IA$ .

Tabela 3.12 – Limites do  $IP$  e do  $IA$  por classe para as RNAs.

Classe	Limites das Classes	
	$IP$	$IA$
bom	$2,5 < IP < 8,0$	$1,5 < IA < 2,5$
umidade	$0,9 < IP < 1,4$	$0,8 < IA < 1,2$
óleo/sujeira	$1,4 < IP < 2,5$	$1,2 < IA < 1,6$
térmico	$6 < IP < 14$	$4,5 < IA < 9$

### 3.5 Conclusões

Este capítulo apresentou a fundamentação teórica que fornece a base de sustentação desta pesquisa. Os tipos de bobinas e isolamentos empregados em motores de baixa e média tensão foram apresentados. Foram abordadas as diferenças de construção e processo de fabricação dos enrolamentos do tipo *random* para MITs de BT e *form* para MITs de MT. Em ambos, os materiais empregados no isolamento para terra, atualmente, são os mesmos.

A dedução das equações para os cálculos do  $IP$  e do  $IA$  em função da capacitância  $C_I$  e da condutividade  $\sigma$  do isolamento permitem associar a variação destas grandezas, obtidas a partir do ensaio *off-line* do motor (aplicação de c.c.), com um determinado fator de estresse agindo sobre o isolamento. Quando submetido a tensão c.a. (*on-line*), a identificação do fator de estresse pode ser realizada pelo acompanhamento da alteração da resistência equivalente  $R_{eq}$  e da capacitância equivalente  $C_{eq}$ .

Os estudos mostram que a maior parcela de falha no isolamento de MITs são ocasionados por estresse térmico. Para o caso de MITs de BT e MT, os fatores ambientais como a absorção de umidade e a contaminação por óleo e sujeira, apresenta-se como o segundo maior fator de estresse que causa a falha no isolamento, e que para essas duas classes de motores, os fatores elétricos e mecânicos podem ser desconsiderados como agentes causadores de degradação no isolamento.

A avaliação das curvas de PRI com o algoritmo *K-means* permitiu o agrupamento dos motores do banco de dados do Apêndice A em 4 grupos. Assim, um determinado fator de estresse agindo sobre o isolamento pode ser caracterizado pela sua curva de PRI. Como a disponibilidade do PRI depende de uma ferramenta mais sofisticada que um simples megômetro, normalmente disponível em oficinas de manutenção elétrica, o projeto de classificadores baseado em RNAs torna-se uma alternativa atraente para identificar o mecanismo de falha do isolamento.

Os classificadores *off-line* projetados apresentaram performance satisfatória para a categorização dos dados. A RNA3 mostra que é possível realizar a avaliação do estado do isolamento e a condição operacional do motor através da medição da resistência de isolamento  $R_I$  e da determinação dos índices de absorção  $IA$  e de polarização  $IP$ .

## 4 Desenvolvimento de Técnicas *On-line* para a Avaliação do Isolamento

NESTE capítulo são abordadas a teoria e as propostas para a avaliação *on-line* do isolamento do estator de MITs de BT e MT. O desenvolvimento da nova proposta para a avaliação *on-line* do isolamento é apresentada. São apontados os aspectos que asseguram a validade da técnica, bem como o seu alto potencial de sucesso como ferramenta preditiva para a avaliação do estado do isolamento de motores novos e em operação.

É apresentado um modelo para a avaliação *on-line* do isolamento a partir da medição do corrente de sequência zero  $\dot{I}_0$ . O desenvolvimento teórico mostra que é possível a obtenção das parcelas de corrente resistiva e capacitiva do isolamento que permitem identificar o fator de estresse e acompanhar preditivamente a resistência de isolamento equivalente  $R_{eq}$ .

Por meio de simulação, é avaliado o erro da aproximação do modelo *on-line* proposto na determinação das correntes de fuga capacitiva e resistiva no isolamento utilizando à decomposição da corrente  $\dot{I}_0$ . São simulados variações de resistência e de capacitância esperadas quando o isolamento do MIT está submetido aos fatores de estresse térmico e ambientais (umidade e contaminação).

Por fim, é apresentada a proposta para um classificador *on-line* para a avaliação do isolamento, onde são definidos os critérios de classificação em função da alteração do Fator de Dissipação  $FD_{eq}$ , da resistência  $R_{eq}$  e da capacitância equivalente  $C_{eq}$ .

Na organização do capítulo, a Seção 4.1 aborda a proposta da nova metodologia *on-line* para a avaliação do isolamento, destacando os aspectos relevantes que asseguram o emprego da técnica para o acompanhamento do estado do isolamento ao longo do ciclo de vida do motor. A Seção 4.2 aborda a avaliação do erro de aproximação da metodologia *on-line* a partir da corrente  $\dot{I}_0$ . A Seção 4.3 apresenta a proposta do projeto de um classificador *on-line* para a avaliação do isolamento. Por fim, a Seção 4.4 apresenta as conclusões a partir da teoria e dos resultados obtidos.

### 4.1 Proposta para a Avaliação *On-line* do Isolamento

Na Seção 2.2.2 é apresentada a técnica para a avaliação *on-line* do isolamento utilizando 3 HSCTs (1 por fase) [25]. Para que a técnica seja aplicada, também é necessário o uso de TPs para a determinação do ângulo de perdas  $\delta$  do isolamento por fase. Apesar

dos bons resultados apresentados para a avaliação do estado do isolamento, a técnica apresenta as seguintes dificuldades de aplicação:

- seu emprego se limita a motores que tenham disponível os 6 terminais para ligação;
- em motores já instalados (em operação), que não possuam os 6 terminais, a técnica não pode ser aplicada;
- custo elevado de implantação: em motores de BT e MT que possuam os 6 terminais, mas sem espaço para a instalação dos HSCTs na sua caixa de ligação, é necessária a montagem de cabos e infra-estrutura até a subestação;
- dificuldade de montagem em gavetas de motores de BT que não possuem espaço necessário para a instalação dos sensores (3 HSCTs e 3 ou 2 TPs). Neste caso, haverá um aumento de adicional de custo, pois será necessário modificar ou trocar a gaveta.

A proposta apresentada neste trabalho baseia-se no uso de apenas um HSCT e um TP para a avaliação do estado do isolamento do motor. Diferente da técnica citada anteriormente, a abordagem com 1 HSCT, apresenta as seguintes vantagens:

- emprego em motores de BT e MT com 6 ou 3 terminais de ligação;
- facilidade e rapidez de instalação em motores novos ou que já estão em operação;
- baixo custo de instalação;
- não é necessária nenhuma montagem adicional de cabos e infra-estrutura nos motores que já se encontram em operação;
- assim como na técnica com 3 HSCTs, a proposta utilizando 1 HSCT também é não invasiva, não trazendo nenhuma influência na operação ou no modo de falha do motor;
- dispensa da instalação do TP em gavetas que já possuem pelo menos 1 TP de proteção ou medição. Como alternativa, ainda pode ser utilizado o TP de medição do painel.

A seguir é apresentado o embasamento teórico e as condições que asseguram a aplicabilidade da técnica proposta.

#### 4.1.1 Avaliação *On-Line* do Isolamento pela Análise da Corrente $\dot{I}_0$

A técnica *on-line* para a avaliação do estado do isolamento proposta neste trabalho baseia-se na decomposição das componente da corrente de sequência zero  $\dot{I}_0$ , medida a partir das correntes de fase.

A Figura 4.1 apresenta conceitualmente o diagrama elétrico proposto. A corrente medida pelo HSCT é a soma fasorial das correntes de fase do motor ( $\dot{I}_a$ ,  $\dot{I}_b$  e  $\dot{I}_c$ ) somadas às parcelas das correntes de fuga respectivamente ( $\dot{I}_{aL}$ ,  $\dot{I}_{bL}$  e  $\dot{I}_{cL}$ ). Como o circuito do motor é equilibrado, as correntes de fase serão equilibradas e se anularão. Assim, a corrente medida pelo sensor será função das correntes de fuga por fase.

$$I_L = 3\dot{I}_0 = \dot{I}_{aL} + \dot{I}_{bL} + \dot{I}_{cL} \quad (4.1)$$




Figura 4.1 – Diagrama proposto para a avaliação do isolamento a partir da medição de  $\dot{I}_0$ .

A Figura 4.2 mostra o circuito equivalente simplificado para a avaliação do isolamento a partir da medição da corrente  $\dot{I}_0$ .

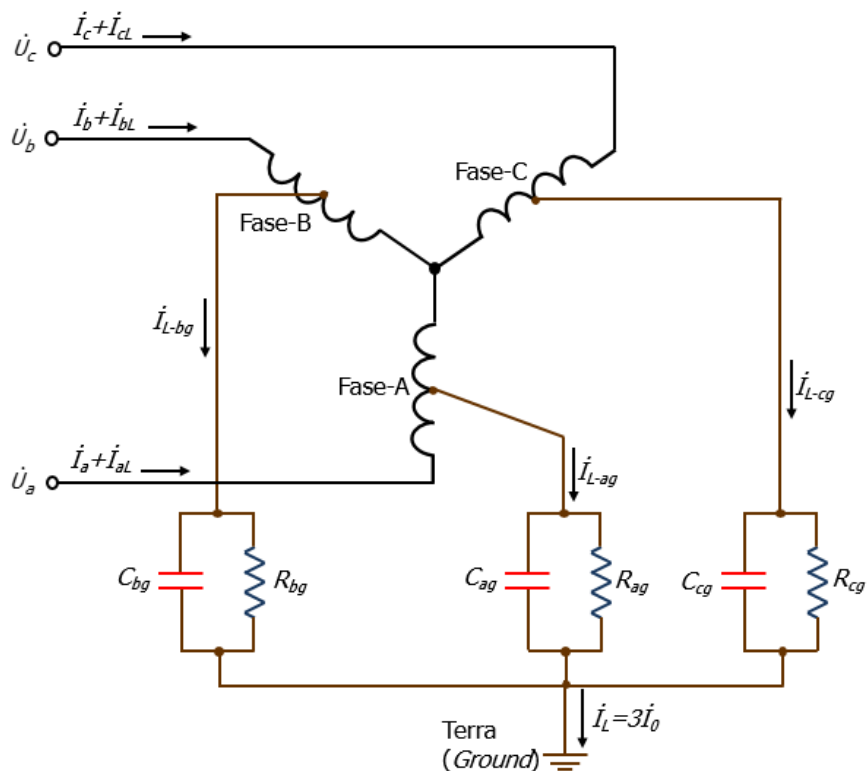


Figura 4.2 – Circuito equivalente simplificado para a avaliação do isolamento a partir da medição de  $\dot{I}_0$ .

Mesmo em isolamentos novos ou reparados, a corrente  $\dot{I}_0$  não é nula pois os valores de capacitância e de resistência por fase equivalentes do isolamento não são iguais. A Tabela 4.1 mostra a medição por fase de capacitância e de resistência de alguns motores de média tensão da Refinaria REDUC-Petrobras após retornarem de manutenção. Na Tabela 4.1, podem ser encontradas diferenças entre os valores de resistência e capacitância por fase superiores a 30%.

Tabela 4.1 – Medição de resistência e de capacitância por fase de MITs da REDUC [27].

TAG	$R_{ag}(M\Omega)$	$R_{bg}(M\Omega)$	$R_{cg}(M\Omega)$	$C_{ag}(pF)$	$C_{bg}(pF)$	$C_{cg}(pF)$
1210-MVE-101	2805	2104	3206	12030	15420	11800
1210-MP-101D	6862	5670	4783	25440	30350	22090
1220-MC-204	3141	4024	2907	22805	21050	31104
1250-MP-5008A	5992	6851	6208	48201	38063	39014
2200-MB-2001	3624	4272	5022	43403	38626	39045

As correntes de fuga por fase podem ser decompostas em uma parcela resistiva ( $\dot{I}_{a,b,cL-R}$ ) e uma capacitiva ( $\dot{I}_{a,b,cL-C}$ ). A corrente  $\dot{I}_0$  pode ser escrita em termos destas componentes como:

$$\dot{I}_0 = \dot{I}_{0R} + \dot{I}_{0C} \quad (4.2)$$

$$\dot{I}_{0R} = \frac{\dot{I}_{aL-R} + \dot{I}_{bL-R} + \dot{I}_{cL-R}}{3} \quad (4.3)$$

$$\dot{I}_{0C} = \frac{\dot{I}_{aL-C} + \dot{I}_{bL-C} + \dot{I}_{cL-C}}{3} \quad (4.4)$$

A Figura 4.3 mostra a decomposição fasorial das correntes de fuga por fase.

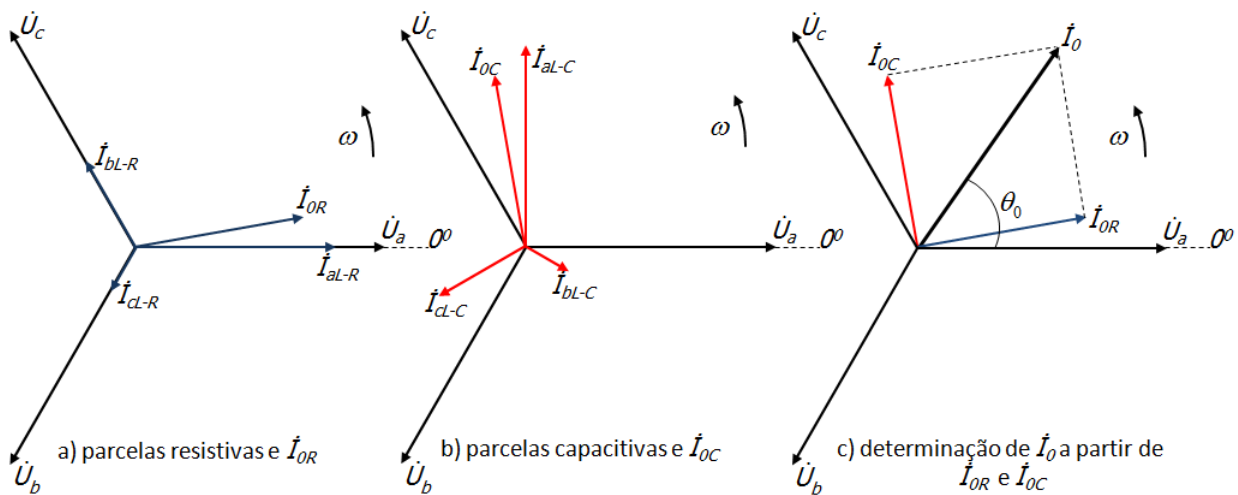


Figura 4.3 – Decomposição da corrente  $\dot{I}_0$  em função das parcelas de corrente resistiva ( $\dot{I}_{a,b,cL-R}$ ) e capacitiva ( $\dot{I}_{a,b,cL-C}$ ) por fase.

A Figura 4.3-a mostra a contribuição das correntes que estão em fase com a tensão, representado as parcelas de corrente resistiva no isolamento, que somadas, resultam na corrente  $\dot{I}_{0R}$ . A Figura 4.3-b mostra as correntes adiantadas  $90^\circ$  em relação a tensão, representado as parcelas de corrente capacitiva do isolamento, cuja soma resulta na corrente  $\dot{I}_{0C}$ . A Figura 4.3-c mostra que, a partir da soma  $\dot{I}_{0R} + \dot{I}_{0C}$ , a corrente  $\dot{I}_0$  pode ser obtida.

As correntes  $\dot{I}_{0R}$  e  $\dot{I}_{0C}$  podem ser escritas utilizando-se o referencial  $\alpha$ - $\beta$ . A Figura 4.4 mostra como pode ser realizada a decomposição. As Figuras 4.4-a e b mostram que as correntes  $\dot{I}_{0R}$  e  $\dot{I}_{0C}$  podem ser expressas em função de suas componentes no eixo  $\alpha$ - $\beta$ . A Figura 4.4-c mostra que a soma dessas componentes de corrente nos respectivos eixos  $\alpha$ - $\beta$  também resulta na corrente  $\dot{I}_0$ .




Figura 4.4 – Decomposição da corrente  $\dot{I}_0$  através das parcelas resistivas e capacitivas por fase.

A notação sem o ponto de uma grandeza fasorial indicará, no restante deste trabalho, o módulo do fasor, ex.:  $|\dot{I}_0| = I_0$ . Também, será considerado que as grandezas já estão expressas por seu valor eficaz.

As correntes  $I_{0\alpha-R}$ ,  $I_{0\alpha-C}$ ,  $I_{0\beta-R}$  e  $I_{0\beta-C}$  podem ser expressas em função dos módulos das suas respectivas correntes de fase como:

$$I_{0\alpha-R} = \frac{1}{3} \left\{ I_{aL-R} - \frac{1}{2}(I_{bL-R} + I_{cL-R}) \right\} \quad (4.5)$$

$$I_{0\alpha-C} = \frac{1}{3} \left\{ 0 + \frac{\sqrt{3}}{2}(I_{bL-C} - I_{cL-C}) \right\} \quad (4.6)$$

$$I_{0\beta-R} = \frac{1}{3} \left\{ 0 - \frac{\sqrt{3}}{2}(I_{bL-R} + I_{cL-R}) \right\} \quad (4.7)$$

$$I_{0\beta-C} = \frac{1}{3} \left\{ I_{aL-C} - \frac{1}{2}(I_{bL-C} + I_{cL-C}) \right\} \quad (4.8)$$

O módulo da corrente  $\dot{I}_0$  pode ser escrito em função das suas componentes no eixo  $\alpha$ - $\beta$  como:

$$I_0^2 = I_{0\alpha}^2 + I_{0\beta}^2 \quad (4.9)$$

$$I_{0\alpha} = I_{0\alpha-R} + I_{0\alpha-C} \quad (4.10)$$

$$I_{0\beta} = I_{0\beta-R} + I_{0\beta-C} \quad (4.11)$$

As equações (4.10) e (4.11) mostram que existe um acoplamento entre as parcelas de corrente resistiva e capacitiva que determinam as componentes do módulo de  $\dot{I}_0$  nos eixos  $\alpha$ - $\beta$ . Substituindo as equações (4.5), (4.6), (4.7) e (4.8) nas equações (4.10) e (4.11), pode-se expressar as correntes  $I_{0\alpha}$  e  $I_{0\beta}$  como:

$$I_{0\alpha} = \frac{1}{3} \left\{ I_{aL-R} - \frac{1}{2}(I_{bL-R} + I_{cL-R}) + \frac{\sqrt{3}}{2}(I_{bL-C} - I_{cL-C}) \right\} \quad (4.12)$$

$$I_{0\beta} = \frac{1}{3} \left\{ I_{aL-C} - \frac{1}{2}(I_{bL-C} + I_{cL-C}) - \frac{\sqrt{3}}{2}(I_{bL-R} - I_{cL-R}) \right\} \quad (4.13)$$

A análise da Figura 4.4-c mostra que o acoplamento existente entre as componentes é devido às contribuições de correntes das demais fases. Num processo de degradação do isolamento o ângulo  $\varphi$  tenderá a zero, pois é esperado que uma das fases apresente um processo mais acelerado de falha. Assim, as seguintes relações passam a ser válidas:

$$I_{0\alpha} \approx I_{0R} \approx I_0 \cos \theta_0 \quad (4.14)$$

$$I_{0\beta} \approx I_{0C} \approx I_0 \sin \theta_0 \quad (4.15)$$

Referências apontam que 80% das falhas em equipamentos elétricos industriais são ocasionados por curto-circuitos monofásicos. Estas falhas têm origem de defeitos no isolamento de uma fase, acarretando numa falta monofásica, que posteriormente evolui para uma falta bifásica e ou trifásica [4, 68]. Em MITs de BT o percentual de falhas monofásicas no isolamento para a terra está também em torno de 80%, segundo o IEEE [4], podendo chegar a quase 90% pelos dados do EPRI (*Electric Power Research Institute*) [11].

No levantamento realizado na Refinaria Duque de Caxias-REDUC [27], apresentado no Capítulo 1, as falhas relacionadas à baixa resistência de isolamento em uma das fases dos motores estão em torno de 80% para motores de baixa e de média tensão. Desta forma, para a avaliação da condição do isolamento através da corrente  $\dot{I}_0$ , é adotada a condição de

que apenas uma das fases terá seu isolamento afetado por algum fator de estresse. Assim, através da medição de  $\dot{I}_0$  e do seu ângulo  $\theta_0$  em relação à tensão da fase-a, é possível obter as correntes  $I_{0R}$  e  $I_{0C}$  que permitem a avaliação do estado do isolamento.

A partir da consideração anterior, pode-se, através do ângulo  $\theta_0$ , identificar qual a fase está sob ação de algum fator de estresse em seu isolamento. A Figura 4.5 mostra as possíveis regiões de localização do ângulo  $\theta_0$  e a respectiva fase afetada.




Figura 4.5 – Identificação da fase em processo de degradação do isolamento em função da localização do ângulo  $\theta_0$ .

Com a identificação da fase em processo de degradação do isolamento, as equações (4.14) e (4.15) podem ser expressas em função das suas componentes de fase. As correntes resistiva  $I_R$  e capacitiva  $I_C$  do isolamento também podem ser escritas em função destas componentes:

- Para fase-a:  $0 < \theta_0 < 90^\circ$  e  $I_{aL} \gg I_{bL}$  e  $I_{aL} \gg I_{cL}$ :

$$I_{0\alpha} = I_0 \cos(\theta_0) = \frac{I_{aL-R}}{3} \quad (4.16)$$

$$I_{0\beta} = I_0 \text{sen}\theta_0 = \frac{I_{aL-C}}{3} \quad (4.17)$$

$$I_R \approx 3I_{0\alpha} = I_{aL-R} \quad (4.18)$$

$$I_C \approx 3I_{0\beta} = I_{aL-C} \quad (4.19)$$

- Para fase-b:  $240^\circ < \theta_0 < 330^\circ$  e  $I_{bL} \gg I_{aL}$  e  $I_{bL} \gg I_{cL}$ :

$$I_{0\alpha} = I_0 \text{cos}\theta_0 = \frac{1}{3} \left\{ -\frac{1}{2}I_{bL-R} + \frac{\sqrt{3}}{2}I_{bL-C} \right\} \quad (4.20)$$

$$I_{0\beta} = I_0 \text{sen}\theta_0 = \frac{1}{3} \left\{ -\frac{\sqrt{3}}{2}I_{bL-R} - \frac{1}{2}I_{bL-C} \right\} \quad (4.21)$$

$$I_{bL-R} = \frac{-3I_0 \text{cos}(\theta_0) - 3\sqrt{3}I_0 \text{sen}(\theta_0)}{2} \quad (4.22)$$

$$I_{bL-C} = \frac{3\sqrt{3}I_0 \text{cos}(\theta_0) - 3I_0 \text{sen}(\theta_0)}{2} \quad (4.23)$$

$$I_R \approx 3I_{0\alpha} = I_{bL-R} \quad (4.24)$$

$$I_C \approx 3I_{0\beta} = I_{bL-C} \quad (4.25)$$

- Para fase-c:  $120^\circ < \theta_0 < 210^\circ$  e  $I_{cL} \gg I_{aL}$  e  $I_{cL} \gg I_{bL}$ :

$$I_{0\alpha} = I_0 \text{cos}\theta_0 = \frac{1}{3} \left\{ -\frac{1}{2}I_{cL-R} + \frac{\sqrt{3}}{2}I_{cL-C} \right\} \quad (4.26)$$

$$I_{0\beta} = I_0 \text{sen}\theta_0 = \frac{1}{3} \left\{ -\frac{\sqrt{3}}{2}I_{cL-R} - \frac{1}{2}I_{cL-C} \right\} \quad (4.27)$$

$$I_{cL-R} = \frac{-3I_0 \text{cos}(\theta_0) + 3\sqrt{3}I_0 \text{sen}(\theta_0)}{2} \quad (4.28)$$

$$I_{cL-C} = \frac{-3\sqrt{3}I_0 \text{cos}(\theta_0) - 3I_0 \text{sen}(\theta_0)}{2} \quad (4.29)$$

$$I_R \approx 3I_{0\alpha} = I_{cL-R} \quad (4.30)$$

$$I_C \approx 3I_{0\beta} = I_{cL-C} \quad (4.31)$$

A Tabela 4.2 resume a metodologia empregada para a determinação de  $I_R$ ,  $I_C$ ,  $R_{eq}$ ,  $C_{eq}$  e  $FD_{eq}$  *on-line* a partir da corrente  $\dot{I}_0$ .

Tabela 4.2 – Quadro resumo para a determinação de  $I_R$ ,  $I_C$ ,  $R_{eq}$ ,  $C_{eq}$  e  $FD_{eq}$  para a avaliação *on-line* do isolamento a partir de  $\dot{I}_0$ .

Ângulo $\theta_0$	Fase	$I_R$	$I_C$	$R_{eq}$	$C_{eq}$	$FD_{eq}$
$0^\circ < \theta_0 < 90^\circ$	a	$I_{aL-R}$ (eq. 4.16)	$I_{aL-C}$ (eq. 4.17)	$\frac{U_N}{I_{aL-R}}$	$\frac{U_N}{I_{aL-C}}$	$\frac{I_{aL-R}}{I_{aL-C}}$
$240^\circ < \theta_0 < 330^\circ$	b	$I_{bL-R}$ (eq. 4.22)	$I_{bL-C}$ (eq. 4.23)	$\frac{U_N}{I_{bL-R}}$	$\frac{U_N}{I_{bL-C}}$	$\frac{I_{bL-R}}{I_{bL-C}}$
$120^\circ < \theta_0 < 210^\circ$	c	$I_{cL-R}$ (eq. 4.28)	$I_{cL-C}$ (eq. 4.29)	$\frac{U_N}{I_{cL-R}}$	$\frac{U_N}{I_{cL-C}}$	$\frac{I_{cL-R}}{I_{cL-C}}$

A exatidão na determinação das correntes  $I_R$  e  $I_C$  depende do desequilíbrio das componentes resistivas  $\dot{I}_{a,b,cL-R}$  e capacitivas  $\dot{I}_{a,b,cL-C}$  por fase. Quanto maior o desequilíbrio causado pelo mecanismo de degradação em uma fase, melhor será o diagnóstico da falha. Na Seção 4.2 será apresentado um estudo a partir de simulação para a avaliação do erro das aproximações feitas para as correntes  $I_{0R} \approx I_0 \cos(\theta_0)$  e  $I_{0C} \approx I_0 \sin(\theta_0)$ .

## 4.2 Avaliação do Erro a partir da Análise de $\dot{I}_0$

Para avaliar o erro das aproximações feitas para as correntes  $I_{0R} \approx I_0 \cos(\theta_0)$  e  $I_{0C} \approx I_0 \sin(\theta_0)$ , as equações (4.3) e (4.4) serão escritas considerando um fator de desequilíbrio resistivo  $D_{a,b,c-R}$  e capacitivo  $D_{a,b,c-C}$ , que podem assumir valores de 0 a  $\infty$ . O objetivo do fator é tentar simular a variação da capacitância e da resistência provocada por algum fator de estresse que causa degradação no isolamento.

$$\dot{I}_{0R} = \frac{D_{a-R}\dot{I}_{aL-R} + D_{b-R}\dot{I}_{bL-R} + D_{c-R}\dot{I}_{cL-R}}{3} \quad (4.32)$$

$$\dot{I}_{0C} = \frac{D_{a-C}\dot{I}_{aL-C} + D_{b-C}\dot{I}_{bL-C} + D_{c-C}\dot{I}_{cL-C}}{3} \quad (4.33)$$

Conforme visto na Seção 4.1, a falha do isolamento do motor é geralmente originada de um defeito em uma das suas fases. Esse, por sua vez, pode ter origem no processo de fabricação ou de mecanismos externos que alteram a sua resistência e capacitância. Desta forma, o fator de desequilíbrio resistivo  $D_R$  e capacitivo  $D_C$ , é aumentado ou reduzido mais em uma fase do que nas demais.

A partir das equações apresentadas na Tabela 4.2, foram simuladas condições de desequilíbrios para avaliar o erro entre as correntes de fuga  $I_{a,b,cL-R}$  e  $I_{a,b,cL-C}$  e as respectivas aproximações a partir do conhecimento de  $\dot{I}_0$  e  $\theta_0$ . A convergência entre o

ângulo da fase que está sob ação de algum fator de estresse em seu isolamento e o ângulo  $\theta_0$ , também é apresentado.

A parcela capacitiva da corrente de fuga foi considerada inicialmente como sendo 10 vezes maior que a resistiva ( $I_{a,b,cL-C} = 10I_{a,b,cL-R}$ ). O objetivo é que as correntes utilizadas na simulação representem variações semelhantes ao esperado em uma situação de degradação real no isolamento. Os erros de aproximação são determinados por:

$$Erro_{I_0}(\%) = \frac{3I_0 - I_{a,b,cL}}{I_{a,b,cL}} \times 100 \quad (4.34)$$

$$Erro_{I_{0R}}(\%) = \frac{3I_0 \cos(\theta_0) - I_{a,b,cL-R}}{I_{a,b,cL-R}} \times 100 \quad (4.35)$$

$$Erro_{I_{0C}}(\%) = \frac{3I_0 \sin(\theta_0) - I_{a,b,cL-C}}{I_{a,b,cL-C}} \times 100 \quad (4.36)$$

A Figura 4.6 mostra a convergência do erro para um desequilíbrio na fase-*c* de até 50 vezes na parcela resistiva  $I_{cL-R}$  da corrente de fuga. A parcela capacitiva  $I_{cL-C}$  também foi alterada, porém numa proporção 5 vezes menor, ou seja, uma variação de até 10 vezes em  $I_{cL-R}$  significa uma variação de 2 vezes em  $I_{cL-C}$ . As correntes de fuga das fases *a* e *b*, foram mantidas constantes.

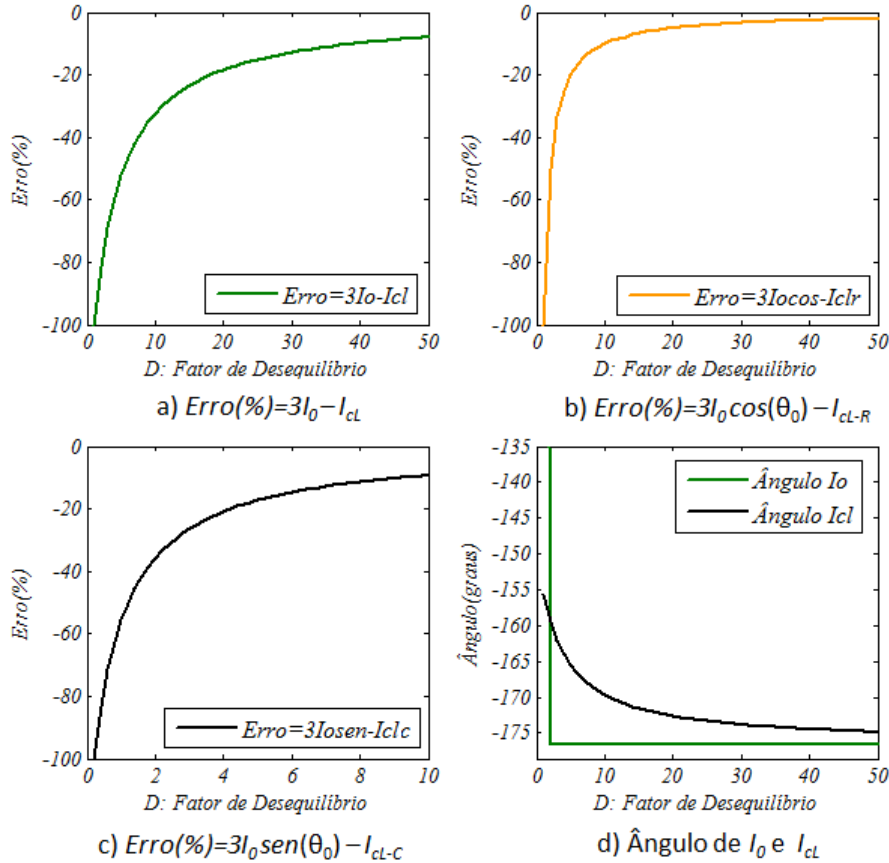


Figura 4.6 – Erro de aproximação e ângulo esperados para um isolamento absorvendo unidade.

A Figura 4.6-a apresenta o erro entre a corrente de fuga total da fase- $c$   $I_{cL}$  e a aproximação dada por  $3I_0$ , cujo erro se torna menor que 10% para desequilíbrios superiores a 50. As Figuras 4.6-b e c mostram que valores de desequilíbrios em torno de 10 vezes em  $I_{cL-R}$  e em  $I_{cL-C}$ , tornam os erros dessas parcelas de corrente, em relação as aproximações  $3I_0 \cos(\theta_0)$  e  $3I_0 \sin(\theta_0)$ , também menores que 10%.

O resultado da simulação apresentado na Figura 4.6 procura reproduzir a degradação do isolamento devido à absorção de umidade, onde ocorre maior aumento da corrente resistiva em relação à capacitiva. A Figura 4.6-d mostra que o ângulo  $\theta_0$  converge nas primeiras iterações, sendo que para desequilíbrios da ordem de 50 vezes em  $I_{cL-R}$  e 10 vezes em  $I_{cL-C}$ , o erro angular torna-se menor que 5 graus.

A Figura 4.7 mostra a convergência do erro da corrente e do ângulo que simula um isolamento sendo afetado por estresse térmico na fase- $a$ . Nesse caso, a corrente resistiva da fase- $a$   $I_{aL-R}$  foi aumentada em 50 vezes, e a capacitiva  $I_{aL-C}$  foi reduzida em 10%. As correntes das demais fases permaneceram com os seus valores inalterados.

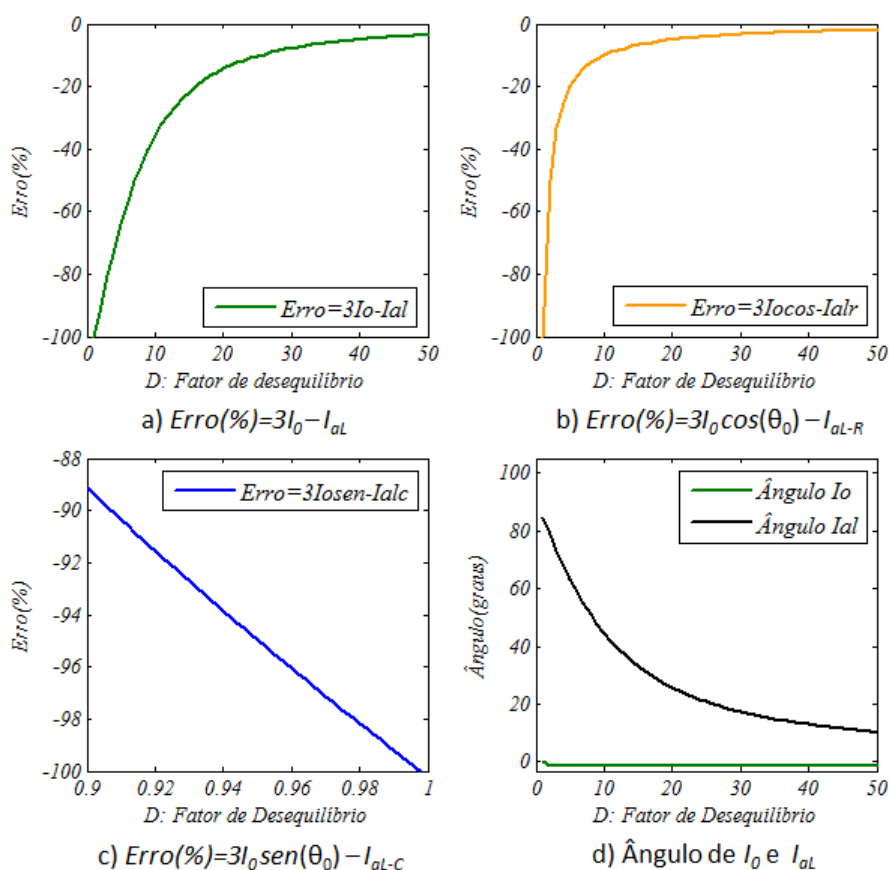


Figura 4.7 – Erro de aproximação e ângulo esperados para um isolamento afetado por estresse térmico.

A Figura 4.7-a apresenta o erro entre a corrente de fuga total da fase- $a$   $I_{aL}$  e a aproximação dada por  $3I_0$ , cujo erro se torna menor que 10% para desequilíbrios superiores

a 30. As Figuras 4.7-b e c mostram que o erro da aproximação da parcela resistiva da corrente de fuga dada por  $3I_0 \cos(\theta_0)$ , torna-se menor que 10% para um aumento em torno de 10 vezes em  $I_{aL-R}$ . Entretanto, como a parcela de corrente capacitiva  $I_{aL-C}$  é pouco alterada no mecanismo de degradação térmica, o erro em relação a aproximação dada por  $3I_0 \sin(\theta_0)$  é bastante elevado.

A Figura 4.7-d mostra que o ângulo  $\theta_0$  converge nas primeiras iterações. Para aumentos da ordem de 50 vezes em  $I_{aL-R}$  e redução da ordem de 10% em  $I_{aL-C}$ , o erro angular se torna próximo a 10 graus.

A Figura 4.8 mostra a simulação de um isolamento apresentado contaminação por óleo e sujeira na fase-b. A parcela resistiva da corrente de fuga  $I_{bL-R}$  foi aumentada em 50 vezes e a parcela capacitiva  $I_{bL-C}$  em 5 vezes. As correntes de fuga das fases a e c foram mantidas constantes.

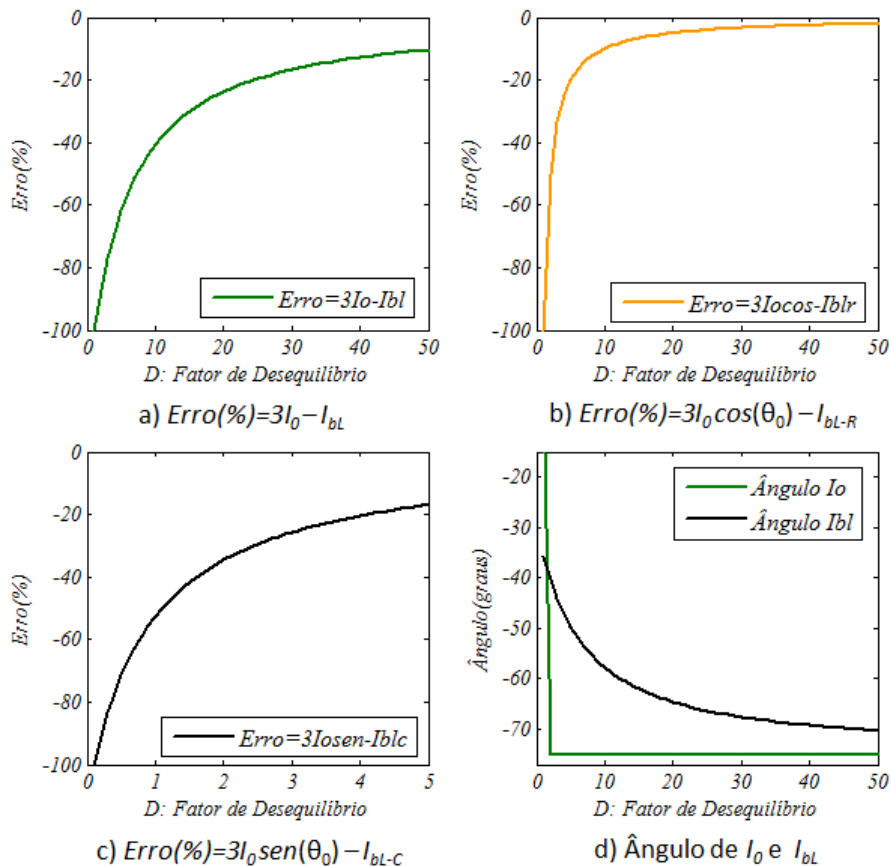


Figura 4.8 – Erro de aproximação e ângulo esperados para um isolamento contaminado por óleo e sujeira.

A Figura 4.8-a apresenta o erro entre a corrente de fuga total da fase-b  $I_{bL}$  e a aproximação dada por  $3I_0$ , cujo erro se torna menor que 10% para desequilíbrios superiores a 50. As Figuras 4.8-b e c mostram que o erro para a aproximação  $3I_0 \cos(\theta_0)$ , em relação a  $I_{bL-R}$ , é menor que 10% para desequilíbrios em torno de 10 vezes. Para a aproximação da

parcela capacitiva  $3I_0\text{sen}(\theta_0)$ , o erro está em torno de 17% para desequilíbrios da ordem de 5 vezes. A Figura 4.8-c mostra que, o aumento em  $I_{bL-C}$  para um isolamento contaminado por óleo é menor quando comparada a absorção de umidade visto na Figura 4.6-c. Desta forma, o erro para a aproximação dada por  $3I_0\text{sen}(\theta_0)$  será maior. A Figura 4.8-d mostra que erros menores que 10 graus no ângulo ocorrerão para desequilíbrios iguais ou maiores que 50 vezes em  $I_{bL-R}$ .

A Tabela 4.3 apresenta outros resultados de simulação, plausíveis de ocorrerem, considerando aumento e/ou redução simultâneos, porém desequilibrados, nas parcelas de corrente fuga capacitiva e resistiva do isolamento. A tabela mostra o aumento relativo em *p.u.* do desequilíbrio provocado em cada parcela de corrente. Por exemplo, se o fator foi igual a 2, significa que a corrente original foi acrescida do mesmo valor, ou seja, com o desequilíbrio a corrente será de  $2p.u.$ . Para fins de comparação, a tabela apresenta a fase-*a* como sendo a mais afetada pelo fator de estresse.

As três primeiras linhas da Tabela 4.3 simulam aumentos nas correntes capacitivas e resistivas do isolamento provocadas por absorção de umidade. Da quarta a sexta linha, é considerado que o desequilíbrio foi provocado por contaminação do isolamento por óleo ou sujeira. As três últimas linhas tentam reproduzir a falha no isolamento devido ao estresse térmico. Uma análise da tabela mostra que, a medida que o desequilíbrio relativo das parcelas de corrente entre as fases é aumentado, o erro para a aproximação, utilizando-se os valores de  $I_0$  e  $\theta_0$ , é reduzido. Desta forma, como a tendência da falha do isolamento é acarretar desequilíbrios cada vez maiores, a determinação das correntes  $I_{a,b,cL-R}$  e  $I_{a,b,cL-C}$  a partir das aproximações dadas por  $3I_0\text{cos}(\theta_0)$  e  $3I_0\text{sen}(\theta_0)$  se tornarão mais exatas.

Tabela 4.3 – Resultados de simulação para a avaliação do erro considerando desequilíbrios nas correntes do isolamento em mais de uma fase.

$D_{a-R}$	$D_{b-R}$	$D_{c-R}$	$D_{a-C}$	$D_{b-C}$	$D_{c-C}$	$Erro_{I_{0R}}$ (%)	$Erro_{I_{0C}}$ (%)	$Erro_{I_0}$ (%)	$\theta_0(^{\circ})$
50	1	1	5	1	1	-2,0	-16,94	-10,39	45
50	1	10	5	1	2,5	-54,23	-23,32	-34,44	63,18
50	5	10	5	1,5	2,5	-33,67	-42,97	-38,91	45,41
50	1	1	2	1	1	-2,0	-33,78	-9,17	21,80
50	1	5	2	1	1,5	-32,36	-44,27	-35,44	25,99
50	2,5	5	2	1,25	1,5	-13,59	-72,13	-24,30	10,80
50	1	1	0,9	1	1	-2,0	-89,73	-3,53	-1,14
50	1	10	0,9	1	0,95	-6,05	-61,10	-7,28	4,27
50	5	10	0,9	0,95	0,95	-16,70	-47,52	-17,49	-6,45

### 4.3 Classificador *On-Line* para a Avaliação do Isolamento

O estudo realizado na Seção 4.2, mostra que é possível acompanhar a tendência de aumento ou de redução das parcelas resistivas e capacitivas da corrente de fuga do isolamento de forma *on-line* a partir da medição de  $\dot{I}_L = 3\dot{I}_0$ . À medida em que os desequilíbrios entre as correntes aumentam, a determinação de suas componentes, e a fase que está sendo afetada, são obtidas com maior exatidão. Assim, através do cálculo da resistência  $R_{eq}$ , da capacitância  $C_{eq}$  e do fator de dissipação  $FD_{eq}$  equivalente, também pode se inferir o fator de estresse que está degradando o isolamento.

As medições da corrente e da tensão *on-line* para a determinação da  $R_{eq}$ ,  $C_{eq}$  e  $FD_{eq}$  são apresentadas no Capítulo 5. Assim, o classificador *on-line* proposto nessa seção utilizará os dados do Apêndice A. A RNA proposta foi treinada e avaliada com estes dados.

Um isolamento afetado por algum fator de estresse, apresentará medições *off-line* com tendências semelhantes às obtidas de forma *on-line*. Assim, é aceitável utilizar as informações análogas *off-line* para a determinação dos limites das superfícies de separação do classificador *on-line*. São utilizados os dados de  $R_I$ ,  $C_I$  e  $FD$  do banco de dados do Apêndice A. Desse, são selecionados 88 motores que possuem medições de  $R_I$ ,  $C_I$  e  $FD$  em dois períodos distintos. São utilizados dados de MITs que se apresentam em bom estado em ambos os períodos, ou que tiveram sua  $R_I$  ou  $C_I$  alterados por algum fator de estresse.

O classificador proposto tem caráter preditivo, ou seja, ele irá rotular o motor em uma determinada classe a partir do aumento relativo entre duas medições de  $R_I$ ,  $C_I$  e  $FD$ . Assim, a primeira medição realizada no motor será a linha de base para a comparação com as demais. Por exemplo, o motor MP1328, visto na Tabela 3.6, apresenta uma  $C_I = 7100pF$  em agosto de 2014. Este valor será considerado a base de  $1p.u.$  para a comparação com o valor de  $C_I = 15800pF$  obtida em outubro de 2015, que em relação ao valor anterior de capacitância representa  $2,22p.u.$ .

O classificador *on-line* proposto, assim como o classificador *off-line*, é também baseado em RNAs. A arquitetura utilizada é semelhante a apresentada na Figura 3.23. No classificador *on-line* os MITs da classe “ruim” não são utilizados, pois os valores de  $FD$  e de  $R_I$  não apresentam tendências regulares para a condição de falha, dificultando o treinamento e gerando muitos Falsos Positivos e Negativos na validação da rede. A avaliação da condição de operação *on-line* do motor é realizada pela proteção preditiva que é apresentada na Seção 5.1.2. A Figura 4.9 apresenta a arquitetura da RNA do classificador *on-line* proposto.

Foram utilizados 70% dos dados para o treinamento e 30% para a validação da rede MLP proposta. As acurácias no treinamento e na validação foram de 100% em ambos os casos.




Figura 4.9 – Arquitetura da RNA proposta para avaliação do isolamento do estator *on-line*.

A Figura 4.10 mostra a separação de classes realizada no processo de validação. Nota-se que há uma boa separação entre as classes, podendo ser visualizada, principalmente através do eixo que apresenta as variações em *p.u.* da capacitância do isolamento  $C_I(p.u.)$ .




Figura 4.10 – Separação realizada pelo classificador *on-line* para os dados de validação.

A Figura 4.11 apresenta o resultado da classificação dos 88 motores utilizados no treinamento e na validação da rede. Neste caso, também pode se observar uma boa

separação das classes, principalmente avaliando-se a variação conjunta da  $C_I(pu)$  e do  $FD(pu)$  do isolamento.




Figura 4.11 – Separação realizada pelo classificador *on-line* para os dados dos 88 motores utilizados na validação e treinamento da rede.

A Figura 4.12 mostra a visualização em duas dimensões (2D) de uma proposta para a separação das classes a partir da  $R_I(p.u.)$  e da  $C_I(p.u.)$ , visto na Figura 4.12-a e, do  $FD(p.u.)$  e da  $C_I(p.u.)$  mostrado na Figura 4.12-b.




Figura 4.12 – Visualização das classes dos 88 motores utilizados na validação e treinamento do classificador *on-line*.

Uma avaliação da Figura 4.12-b, mostra que uma separação adequada das classes

pode ser feita a partir da  $C_I(p.u.)$  e  $FD(p.u.)$ . Nota-se que as variações da capacitância e do fator de dissipação mostram-se bem definidas para o fator de estresse térmico. Para os caso de umidade e contaminação por óleo, a variação da capacitância é o parâmetro que melhor consegue distinguir estas classes. A Tabela 4.4 sugere os limites de intervalos de  $C_I(p.u.)$  e  $FD(p.u.)$  que delimitam cada classe para a proposta do classificador *on-line*.

Tabela 4.4 – Limites de  $C_I$  e  $FD$  por classe para o classificador *on-line* proposto.

Classe	Limites das Classes	
	$C_I(p.u.)$	$FD(p.u.)$
bom	$0,95 < C_I < 1,1$	$0,95 < FD < 1,1$
umidade	$C_I > 2,0$	$2,0 < FD < 8,0$
óleo/sujeira	$1,1 < C_I < 2,0$	$1,5 < FD < 8,0$
térmico	$C_I < 0,95$	$FD > 8,0$

Os intervalos de variação para a  $C_I(p.u.)$  e para o  $FD(p.u.)$  mostrados na Tabela 4.4 tem caráter orientativo. O objetivo é permitir que técnicos de manutenção possam detectar e classificar um fator de estresse agindo no isolamento de forma rápida. Entretanto, uma vez que pode ocorrer sobreposição das variáveis na determinação das classes, um diagnóstico mais preciso deve ser obtido com o uso da RNA proposta.

## 4.4 Conclusões

Este capítulo apresentou o embasamento teórico da proposta para a avaliação *on-line* a partir da medição da corrente  $\dot{I}_0$ . Também foi apresentado o projeto de um classificador baseado em RNA para a detecção e a avaliação do estado do isolamento.

A nova proposta para a avaliação *on-line* do isolamento com emprego de 1 HSCT baseado na análise da corrente  $\dot{I}_0$ , mostra-se promissora. A simplicidade da técnica quanto à sua realização prática, aliado ao baixo custo de implementação e emprego em qualquer motor de baixa e média tensão, potencializam o sucesso da proposta.

O estudo realizado para a avaliação do erro no cálculo das correntes de fuga capacitivas e resistivas do isolamento a partir da medição de  $\dot{I}_0$ , mostra que, quanto maior o desequilíbrio provocado pelo mecanismo de degradação do isolamento mais exato será a determinação das mesmas. Assim, a abordagem proposta neste trabalho apresenta grande potencial para o acompanhamento preditivo do estado do isolamento de motores de baixa e média tensão.

Por fim, o classificador *on-line* proposto a partir dos dados de  $R_I(p.u.)$ ,  $C_I(p.u.)$  e  $FD(p.u.)$  do Apêndice A, apresentou bons resultados para a classificação dos fatores de estresse térmico e ambientais que acarretam a degradação do isolamento. A inferência dos

intervalos que delimitam cada classe, vistos na Tabela 4.4, podem ser utilizados para uma avaliação rápida a respeito do estado do isolamento. No Capítulo 5 são apresentados os resultados desse classificador a partir dos dados *on-line* da  $Req$ , da  $C_{eq}$  e do  $FD_{eq}$ .

## 5 Sistema de Monitoramento *On-Line* para o Isolamento de MITs de BT e MT - SIMOI

NESTE capítulo é apresentado o Sistema de Monitoramento *On-Line* para o Isolamento de MITs de BT e MT - SIMOI. São descritas as partes constituintes e as funcionalidades do SIMOI, como o sistema de medição e condicionamento dos sinais, o monitoramento e a proteção preditiva e o classificador do fator de estresse do isolamento.

É apresentado o sistema de medição de corrente e tensão do SIMOI, o qual, possui papel fundamental no sucesso da determinação dos diagnósticos. São mostrados o princípio de funcionamento do HSCT e a sua modelagem matemática. São abordados os desafios e as soluções propostas para a medição de correntes de fuga da ordem de  $1\mu A$  com o emprego do sistema de Supressão Ativa e Ruído (SAR).

O caráter preditivo do SIMOI é avaliado por meio de testes realizados em motores de baixa tensão submetidos aos fatores de estresse térmicos e ambientais (absorção de umidade e contaminação por óleo). Os resultados alcançados demonstram grande eficácia do classificador para a determinação do fator de estresse e da proteção preditiva para evitar falhas mais severas no isolamento.

Na organização do capítulo, a Seção 5.1 apresenta o sistema de medição e as etapas do processamento de sinal empregados para a obtenção da corrente  $\dot{I}_0$  e do ângulo  $\theta_0$ , bem como os algoritmos empregados no SIMOI para o monitoramento e a proteção preditiva do isolamento. A Seção 5.2 descreve a metodologia dos testes e os resultados obtidos nos ensaios de envelhecimento acelerado, absorção de umidade e contaminação por óleo realizados em MITs de BT. Por fim, a Seção 5.3 apresenta as conclusões acerca dos resultados obtidos.

### 5.1 Sistema de Medição e Processamento dos Sinais

Para que seja possível a realização do diagnóstico a respeito do fator de estresse que está degradando o isolamento e estimar o tempo para a sua falha, é necessário que o sistema de medição possua grande sensibilidade, exatidão e repetibilidade. O módulo da corrente de fuga  $\dot{I}_L$  no isolamento de MITs de BT é muito pequeno, em alguns casos menor que  $1\mu A$ . Erros ocasionados por ruídos irradiados e conduzidos nos sensores ou nos circuitos de condicionamento de sinal podem levar a diagnósticos imprecisos, ocasionando desligamentos desnecessários do motor (TRIPs espúrios), ou a sua parada para manutenção de forma precoce.

Um fator que dificulta a determinação das componentes resistivas e capacitivas da corrente de fuga  $\dot{I}_L$  proposta neste trabalho é o fato dessas serem obtidas a partir da corrente  $\dot{I}_0$ . Em isolamentos novos, cujos desequilíbrios resistivos e capacitivos do isolamento são menores, normalmente o módulo da corrente  $\dot{I}_0$  é menor que os módulos das correntes de fuga por fase  $\dot{I}_{a,b,cL}$ . Assim, a alta sensibilidade e a imunidade a ruído do sistema de medição é fator primordial para o emprego das metodologias *on-line* descritas no Capítulo 4.

### 5.1.1 Medição da Tensão e da Corrente $\dot{I}_0$

O sistema de medição empregado possui um transformador de potencial (TP) conectado da fase-*a* para a terra, e um transformador de corrente de alta sensibilidade (HSCT). A tensão medida pelo TP possui magnitude e ângulos que não apresentam normalmente variação ao longo do tempo. Assim, um TP de medição ou de proteção com classe de exatidão conhecida pode ser utilizado, sem a necessidade do estabelecimento de algum critério mais rigoroso quanto à sua especificação. Entretanto, para a medição da corrente  $\dot{I}_0$ , é necessário que o sensor tenha sensibilidade suficiente para medir correntes de  $1\mu A$  a  $2000\mu A$ , mantendo sua exatidão e erro de fase (ângulo) ao longo de toda essa faixa.

O HSCT utilizado neste trabalho emprega a tecnologia de medição de zero fluxo com realimentação negativa [91–93]. A Figura 5.1 mostra o circuito do HSCT com o conceito de funcionamento do sensor, e a Figura 5.2 apresenta um modelo em diagrama de blocos no domínio da frequência.

O HSCT visto na Figura 5.1 apresenta 2 núcleos com dois enrolamentos cada. Os núcleos são feitos de material de alta permeabilidade magnética (liga *alloy*). Para permitir a detecção da corrente  $I_p(t)$  da ordem de micro-Ampéres, os enrolamentos  $N_1$  possuem maior quantidade de espiras que os enrolamentos  $N_2$ .

Os enrolamentos  $N_1$  são os enrolamentos de excitação e detecção, que tem como funções manter um fluxo mínimo de excitação  $\phi_e(t)$  nos núcleos e detectar o fluxo gerado pela corrente a ser medida  $I_p(t)$ . Os enrolamentos  $N_2$  são os enrolamentos de *feedback*. Na presença da corrente a ser medida  $I_p(t)$ , que gera um fluxo  $\phi_p(t)$ , uma tensão diferencial na entrada dos amplificadores operacionais irá gerar uma corrente  $I_s(t)$  que tenderá a cancelar o fluxo  $\phi_p(t)$  pela ação do fluxo  $\phi_s(t)$ . Assim, o fluxo resultante ( $\phi_r(t) = \phi_p(t) - \phi_e(t) - \phi_s(t)$ ) continuará a ser igual ao fluxo de excitação  $\phi_e(t)$  para qualquer corrente  $I_p(t)$  que passa pelos núcleos. Desta forma, a tensão de saída  $U_s(t)$  do circuito será diretamente proporcional a corrente  $I_p(t)$ . Como as correntes a serem medidas são da ordem de micro-Ampéres, faz-se necessário o uso de dois núcleos para que o fluxo de excitação  $\phi_e(t)$  não induza ou distorça o fluxo produzido pela corrente  $I_p(t)$  a ser medida. Assim, os enrolamentos de excitação produzem fluxos opostos para que seja mantido fluxo zero no interior do sensor quando a  $I_p(t) = 0$ . No caso de  $I_p(t) \neq 0$ , a corrente  $I_s(t)$  irá gerar um fluxo  $\phi_s(t)$

contrário a  $\phi_p(t)$ , mantendo o fluxo magnético nulo no interior do núcleo.

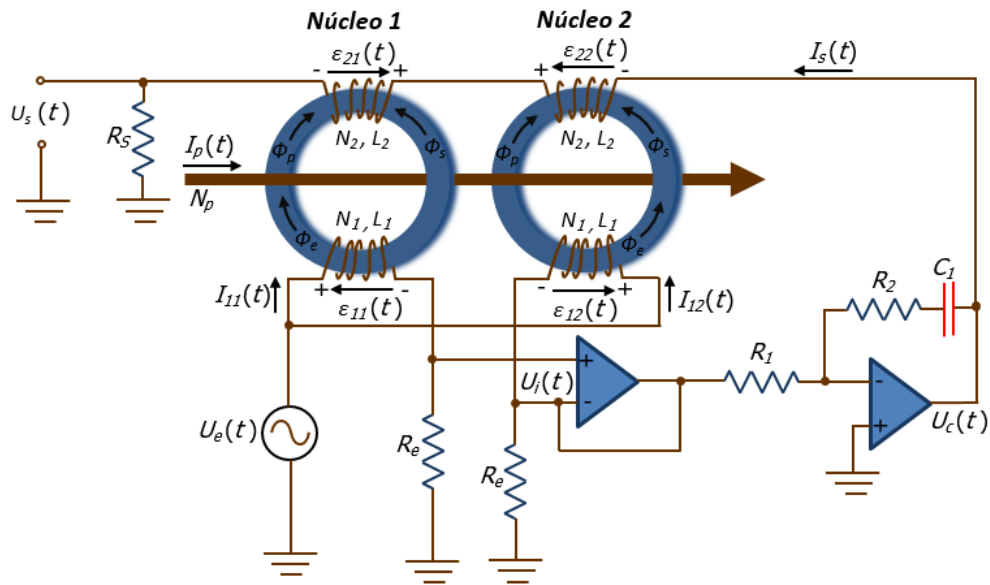


Figura 5.1 – Circuito do sensor HSCT.

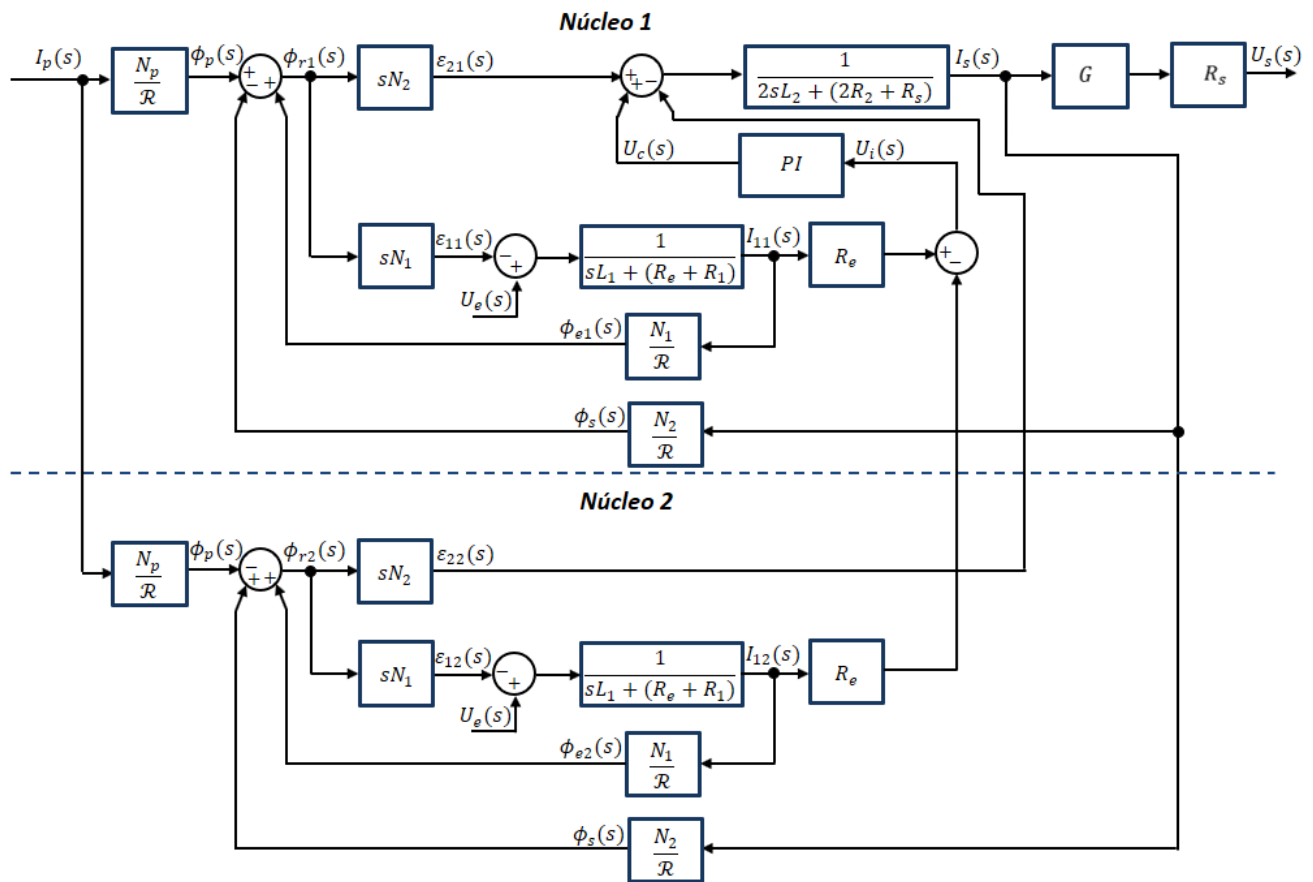


Figura 5.2 – Diagrama de blocos do sensor HSCT.

No diagrama de blocos da Figura 5.2 estão representadas as relações matemáticas entre os fluxos magnéticos, as correntes e as tensões nos núcleos do sensor. O Apêndice B

deste trabalho resume as principais equações e os parâmetros utilizados para a simulação do seu funcionamento.

As Figuras 5.3 e 5.4 mostram os resultados de simulação do sensor para o modelo proposto. As figuras apresentam os gráficos de valor instantâneo e eficaz da corrente primária e da tensão de saída, respectivamente, para  $I_p(t) = 1\mu A$  e  $I_p(t) = 2mA$ .

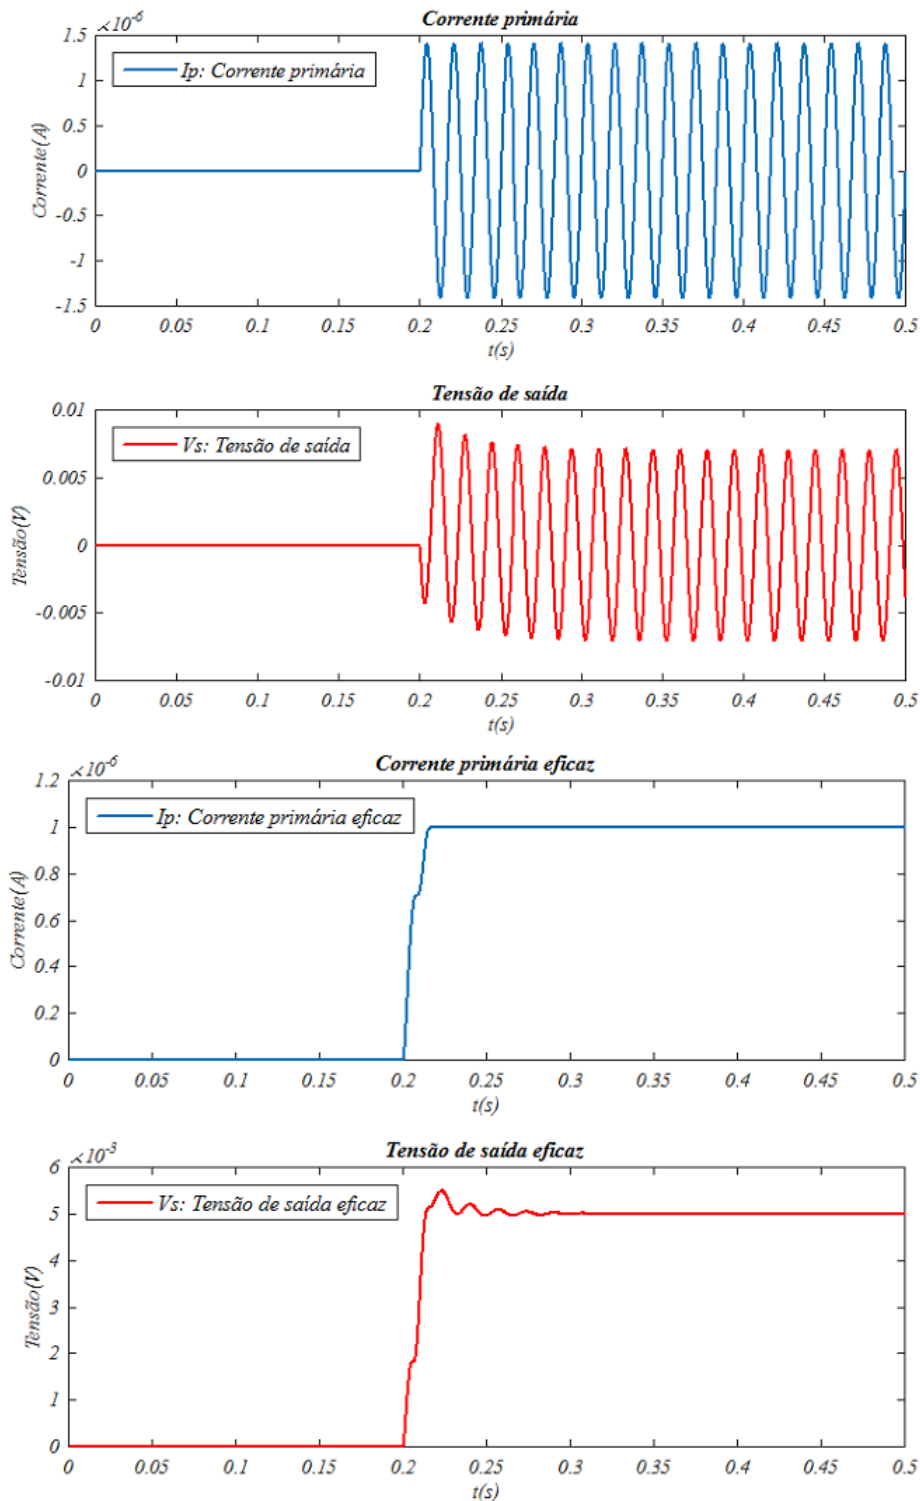


Figura 5.3 – Resultado de simulação para  $I_p = 1\mu A$  para o modelo proposto para o HSCT.

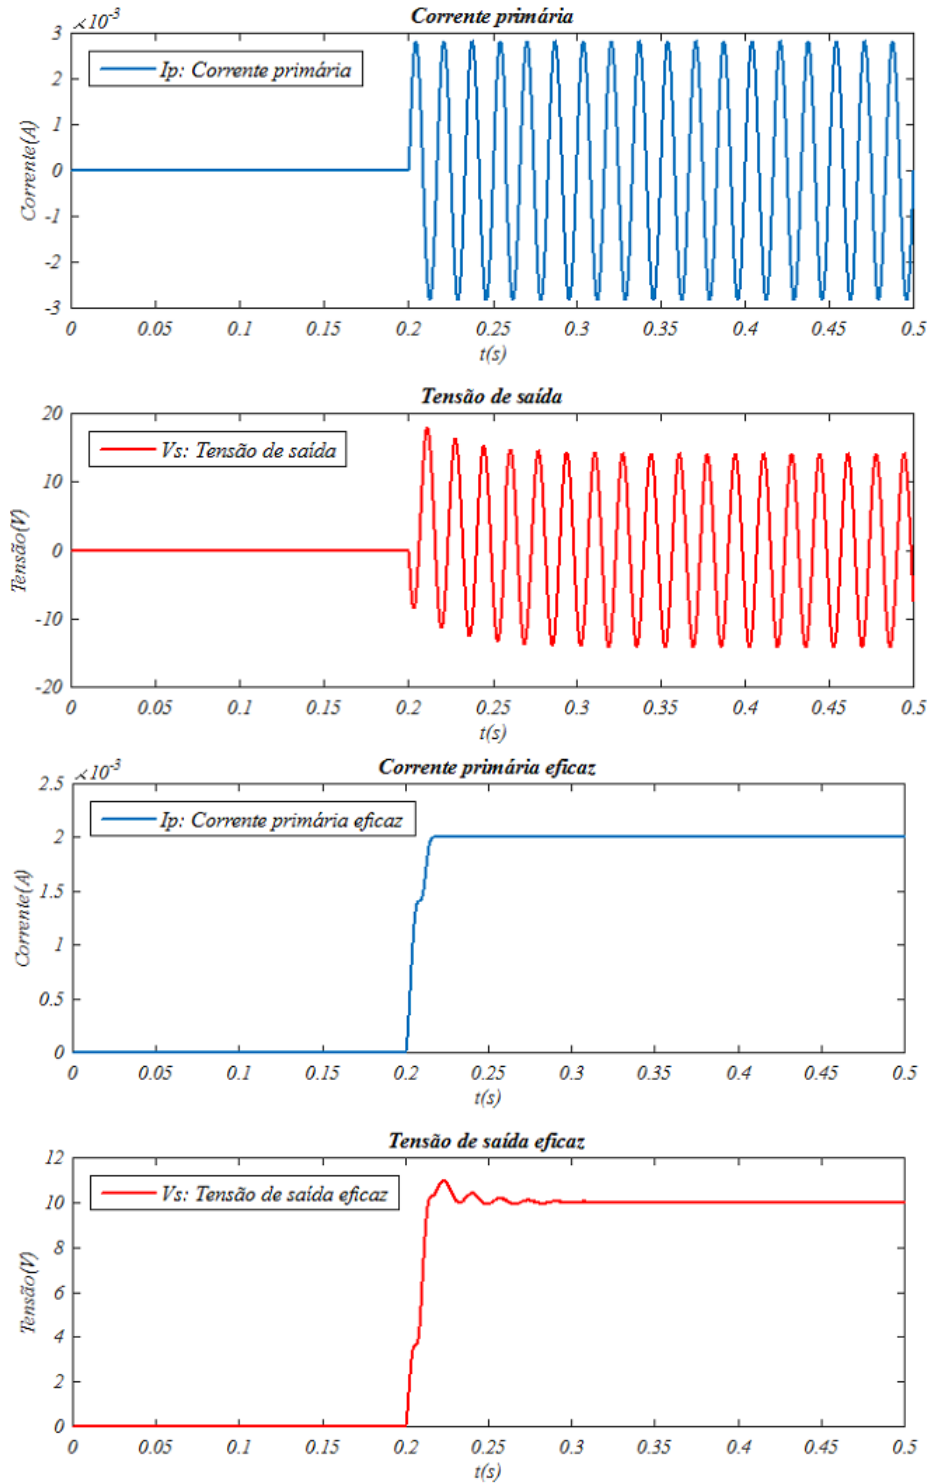


Figura 5.4 – Resultado de simulação para  $I_p = 2mA$  para o modelo proposto para o HSCT.

O ruído eletromagnético predominante na medição do HSCT está na mesma frequência da medição do sinal desejado ( $60Hz$ ). Neste caso, a utilização de filtros analógicos e digitais de condicionamento do sinal não são eficientes para a eliminação do ruído, uma vez que o sinal gerado pela corrente também será atenuado. Conforme mostrado por Ott [94] e Paul [95], o ruído de baixa frequência induzido no sensor é caracterizado por uma fonte magnética de campo próximo (*near-field*). Para estes casos, a blindagem

magnética proporcionada por chapas metálicas é diretamente proporcional a sua espessura, ou seja para uma grande atenuação do campo é necessário o uso de chapas mais espessas.

A profundidade de penetração ( $\delta$ ) do campo magnético próximo em baixa frequência pode ser obtido por [94, 95]:

$$\delta = \frac{1}{\sqrt{\pi f \mu \sigma}} \quad (5.1)$$

A equação (5.1) mostra que para uma dada frequência  $f$ , o campo magnético que penetra no material será atenuado conforme se aumenta a sua condutividade ( $\sigma$ ) e/ou a sua permeabilidade ( $\mu$ ). Assim, somente a utilização de material metálico para a atenuação da interferência causada pelo campo próximo acarreta num grande aumento de peso e volume da blindagem. Desta forma, a solução custo eficiente passa pela utilização de uma arquitetura dupla, associando o uso de materiais condutores e magnéticos de alta permeabilidade.

O HSCT empregado neste trabalho foi projetado e construído exclusivamente para essa aplicação. O HSCT apresenta dupla blindagem, uma mais externa composta de material metálico (aço carbono), e uma mais interna de material magnético (*mumetal*). Originalmente, a faixa de medição de corrente do sensor era de  $10\mu A$  a  $2000\mu A$  com erro de  $\pm 1\mu A$ . Entretanto, após o emprego da técnica de Supressão Ativa de Ruído (SAR), o HSCT passou a medir correntes de  $1\mu A$  com erros menores que  $\pm 2,5\%$  (para correntes da ordem de  $1\mu A$ ). As melhorias realizadas no HSCT possibilitaram seu aumento de sensibilidade e compatibilidade eletromagnética adequadas para o monitoramento de correntes de fuga da ordem de micro-Ampères. A técnica de SAR consiste em captar através de uma micro-antena, instalada próximo ao sensor, o ruído externo e subtraí-lo do sinal medido pelo HSCT. A Seção 5.1.3 apresenta maiores detalhes sobre a técnica.

A Figura 5.5 apresenta os gráficos de erro da medição (exatidão) e de ângulo do HSCT para a corrente primária variando de  $1\mu A$  a  $2000\mu A$ . O maior erro de medição ocorre para a corrente de  $1\mu A$ , não ultrapassando o valor de  $2,5\%$ . Para correntes primárias maiores que  $10\mu A$  o erro se torna menor que  $1\%$ . O HSCT apresenta uma defasagem máxima de  $1,5$  graus para correntes primárias em torno de  $1\mu A$ . Para correntes maiores que  $10\mu A$ , a diferença entre o ângulo da corrente medida pelo HSCT e da corrente de referência (gerada e medida com um instrumento padrão), se torna menor que  $1,0$  grau. Nota-se grande estabilidade do erro e do ângulo do HSCT para toda a faixa de medição considerada. Esses resultados só foram possíveis devido a eliminação do ruído na medição proporcionada pelo uso da técnica de SAR.

A Figura 5.6 apresenta o gráfico de resposta em frequência do HSCT. Esse teste foi realizado com uma corrente primária de  $1mA$ , sem o emprego da filtragem digital descrita na Seção 5.1.2, mas com o sistema SAR ativo. Nota-se uma boa faixa de passagem

do sensor que mantém seu ganho de corrente (amplitude) e ângulo bem estáveis até frequências da ordem de  $4kHz$ . Apesar da medição de corrente neste trabalho estar na frequência de  $60Hz$ , nota-se que o HSCT pode ser empregado na medição de correntes para a detecção de outras anomalias em frequências da ordem de kilohertz.




Figura 5.5 – Erro (exatidão) e ângulo do HSCT após uso da técnica de SAR.




Figura 5.6 – Resposta em frequência do HSCT.

### 5.1.2 Condicionamento e Processamento dos Sinais

Uma etapa de grande importância deste trabalho diz respeito ao condicionamento e processamento do sinal da tensão e da corrente medida pelo HSCT. A Figura 5.7 apresenta em forma de diagrama de blocos o sistema de medição e os circuitos empregados para a aquisição da tensão  $U_a(t)$ , do ruído externo  $I_{ruído}(t)$  e da corrente  $I_{0-medida}(t)$ .

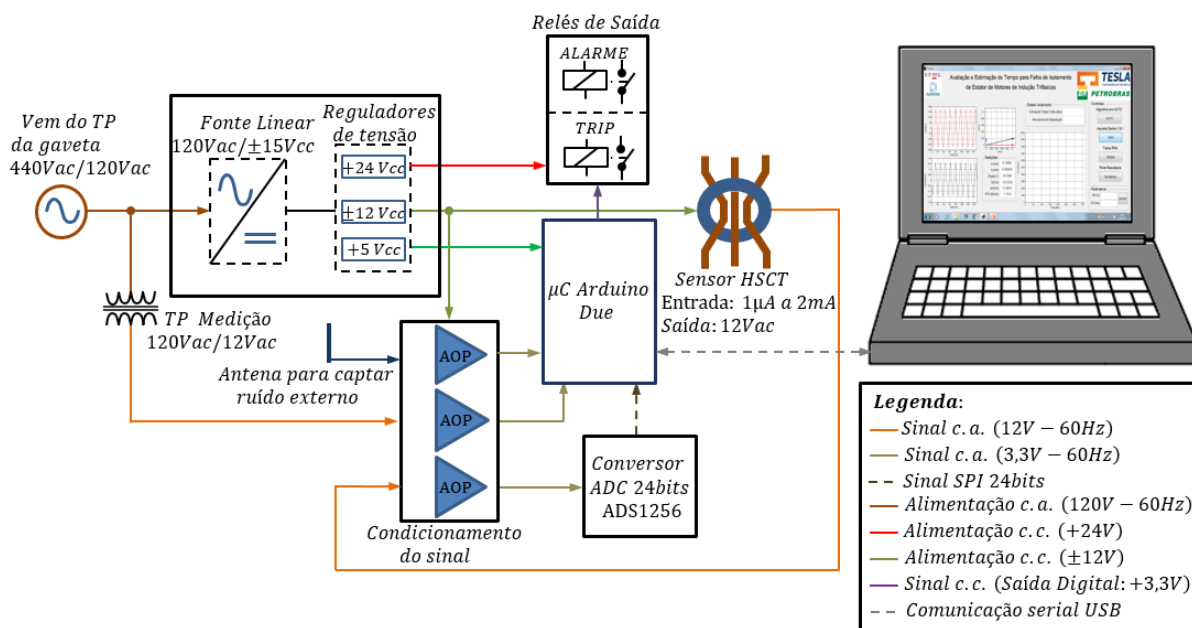


Figura 5.7 – Diagrama de blocos do sistema de medição e dos circuitos de alimentação, condicionamento e processamento dos sinais.

No diagrama de blocos da Figura 5.7 são apresentados a fonte de alimentação, os circuitos de condicionamento dos sinais (tensão do TP, ruído externo e corrente do HSCT), o conversor ADC (*Analogic Digital Converter*) de 24 *bits*, o micro-controlador ( $\mu C$ ) e os relés de saída. A fonte de alimentação empregada é do tipo linear, o que possibilitou a redução dos ruídos conduzidos e irradiados para os demais circuitos. A tensão de ondulação (*ripple*) dos reguladores é menor que 0,1% por saída. Nos circuitos condicionadores de sinal são empregados amplificadores de instrumentação (AOP) com rejeição de ruído de modo comum de 115dB. Na saída dos AOPs existe um filtro passa-baixa (*anti-alias*) com frequência de corte em 2,3kHz.

A faixa de medição esperada para a corrente  $I_0$ , medida pelo HSCT, é da ordem de 2000 (*range* de 1 $\mu A$  a 2000 $\mu A$ ). Os conversores ADC do micro-controlador possuem resolução de 12 *bits* (0 a 4095), o que não possibilita uma boa reconstrução do sinal para os valores esperados da corrente  $I_0$ . Com uma resolução de 12 *bits* o menor valor de corrente (1  $\mu A$ ) seria reconstruído por 4 níveis de tensão, o que aumenta significativamente os erros no módulo e na fase da corrente  $I_0$  ocasionados pela aquisição do sinal. Desta forma, foi necessário o emprego de um ADC de 24 *bits* (0 a 16777215). Para essa resolução, a

menor corrente  $I_0$  seria reconstruída com 8388 níveis de tensão, muito superior a resolução apresentada pela conversão de 12 *bits*.

O ADC utilizado foi o ADS1256 da Texas Instruments [96]. Esse ADC tem capacidade de processar 8 canais multiplexados com taxas de amostragem de até 30.000 amostras por segundo. Neste trabalho o ADS1256 foi configurado para a taxa de amostragem de 4620 amostras por segundo (mesma taxa de amostragem configurada para a aquisição da tensão e do ruído pelo micro-controlador). Essa taxa permite que o sinal da corrente  $I_0$ , na frequência de 60Hz, seja amostrado 77 vezes por ciclo. Esse valor de amostragem é duas vezes maior que as taxas empregadas nos melhores relés de proteção, que atualmente é de 32 amostras por ciclo.

O micro-controlador ( $\mu C$ ) utilizado é o ATMEL SAM3X8E, que está montado na plataforma de *hardware* aberto Arduino DUE [97]. Esse  $\mu C$  possui arquitetura RISC (*Reduced Instruction Set Computer*) de 32 *bits* e *clock* de 84MHz. O  $\mu C$  conta com memória E<sup>2</sup>PROM *Flash* de 512kbytes, SRAM de 100kbytes, 54 pinos configuráveis como entrada/saídas digitais, 12 entradas analógicas de 12 *bits*, 12 saídas PWM de 12 *bits*, além de diversas interfaces de comunicação serial (USB, RS-232, SPI, I2C, Ethernet, etc). Os recursos oferecidos, e seu baixo custo, tornam esse  $\mu C$  um dos mais utilizados no mercado para as mais diversas aplicações.

O micro-controlador tem a função de aquisição e transmissão de dados dos sensores para o computador, onde esses são processados através de pacotes computacionais do *Matlab*. Os valores da corrente  $I_{0-medida}(t)$  obtidos pelo ADC ADS1256 são enviados para o  $\mu C$  pela interface SPI (*Serial Peripheral Interface*). Os dados aquisitados pelas entradas analógicas e pela interface SPI, são enviados para o *Matlab* pela porta serial USB do  $\mu C$ . Os valores de  $U_a(t)$ ,  $I_{ruído}(t)$  e  $I_{0-medida}(t)$  são filtrados digitalmente no *software* por um filtro passa-baixa Butterworth de 5<sup>a</sup> ordem com frequência de corte em 120Hz.

No micro-controlador, também são executadas as rotinas do monitoramento e da proteção preditiva do isolamento. O monitoramento preditivo é realizado em tempo real comparando o valor de  $R_{eq}$ , calculada conforme a Tabela 4.2, com os valores mínimos de resistência de isolamento recomendados pelo IEEE Std-43. O relé de saída de “ALARME” é ativado se:

$$\begin{cases} R_{eq} < 5M\Omega & \text{para MITs de BT} \\ R_{eq} < 100M\Omega & \text{para MITs de MT} \end{cases} \quad (5.2)$$

A proteção preditiva realizada no microcontrolador é feita a partir dos valores eficazes da corrente  $I_{0-medida}$  ou da corrente  $I_R$ , calculada conforme a Tabela 4.2. O relé de saída “TRIP” é desativado para desligar o motor se uma das condições foram alcançadas:

$$\begin{cases} I_R > 1mA \\ 3I_{0-medida} > 2mA \end{cases} \quad (5.3)$$

Os valores eficazes da corrente  $I_{0-medida}$  e da tensão  $U_N$ , necessários para a execução do algoritmo de monitoramento e proteção preditiva, são calculados de acordo com as equações:

$$I_{0-medida} = \sqrt{\frac{1}{N} \sum_{i=1}^N [I_{0-medida}(i)]^2} \quad (5.4)$$

$$U_N = \sqrt{\frac{1}{N} \sum_{i=1}^N [U_a(i)]^2} \quad (5.5)$$

Onde:

- $N = 77$ : número de amostras por ciclo;
- $I_{0-medida}(i)$ : amostra de corrente  $i$  do HSCT;
- $U_a(i)$ : amostra de tensão  $i$  do TP.

### 5.1.3 Supressão Ativa de Ruído - SAR

Como mencionado anteriormente, o ruído e a corrente medida pelo HSCT encontram-se na mesma frequência. Como os campos magnéticos gerados pelas correntes de fuga são muito baixos, as técnicas tradicionais de blindagem não foram suficientes para eliminar o ruído externo. Assim, foi empregado a técnica de Supressão Ativa de Ruído (SAR). A técnica consiste em capturar o ruído externo através de uma micro-antena dipolo e subtraí-lo do sinal do HSCT.

Como os sensores apresentam princípios de funcionamento diferentes (antena: capacitiva, HSCT: indutiva), ocorre defasamento entre os ruídos captados pela antena e pelo HSCT. Assim, para que a eliminação do ruído seja adequada é necessária a realização de uma calibração do sistema de SAR. A calibração consiste em ajustar a fase e a amplitude do ruído captado pela antena e pelo HSCT.

Com a corrente primária nula, os sinais da antena e do HSCT são aquisitados e filtrados digitalmente no *Matlab* (filtro passa baixa Butterworth). O ângulo de defasagem  $\theta_r$  do ruído captado pela antena em relação ao ruído do HSCT é obtido com o emprego do FB-PLL [98, 99], cujo funcionamento será descrito no cálculo do ângulo  $\theta_0$ . A partir do ângulo  $\theta_r$  é calculada a defasagem em número de amostras  $n$  do ruído captado pela antena.

$$n = arred\left(\frac{\theta_r}{2\pi}N\right) \quad (5.6)$$

- *arred*: arredonda o resultado para o inteiro mais próximo.

O defasamento  $n$  é aplicado ao sinal do ruído captado pelo HSCT, produzindo um sinal em fase com o ruído captado pela antena. A amplitude do ruído captado pela antena

é ajustada a partir do ganho  $k_a$ . Desta forma, o ruído na medição realizada pelo HSCT será eliminado. A corrente  $I_0(t)$  para a avaliação do isolamento será determinada por:

$$I_0(i) = I_{0\text{-medida}}(i + n) - k_a I_{\text{ruído}}(i), \quad \text{para } i = 1 : N_{\text{amostras}} \quad (5.7)$$

As Figuras 5.8 e 5.9 demonstram o funcionamento do sistema de SAR. A Figura 5.8 apresenta os gráficos da medição instantânea dos ruídos (representado em corrente) captados pelo HSCT e pela antena do sistema de SAR após o processamento (filtragem) desses sinais. A corrente primária que passa pelo sensor neste caso é zero. Aplicando-se a equação (5.7) nos sinais, o resultado é uma corrente  $I_0(t)$  praticamente nula (linha azul), mostrando a eficácia do emprego da técnica de SAR.

A Figura 5.9 apresenta os gráficos de medição instantânea das correntes medidas pela antena (ruído) e pelo sensor HSCT. Neste caso, circula uma corrente primária pelo HSCT de  $1\mu A$ . A corrente medida pelo HSCT é o resultado da soma da corrente primária e do ruído externo. A partir da subtração da corrente captada pela antena do sistema de SAR conforme a equação (5.7), a corrente  $I_0$  considerada para a avaliação do isolamento é muito próxima de  $1\mu A$  (linha azul), demonstrando novamente a eficácia do sistema de SAR. Cabe ressaltar que o processo de calibração do sistema SAR é realizado de forma automática toda vez que o motor se encontra desligado, ou seja  $I_p(t) = 0$ .

O ângulo da tensão da fase- $a$  ( $\theta_a$ ) é obtido através de um PLL monofásico baseado na análise de Fourier denominado FB-PLL (*Fourier-Based Phase-Locked Loop*) [98, 99]. Originalmente, o FB-PLL foi utilizado em aplicações de sincronismo de fase e detecção seletiva de harmônicos em filtros ativos de potência. A alta robustez do FB-PLL frente a ruídos e distúrbios, aliado a alta velocidade de resposta, motivaram o seu emprego neste trabalho.




Figura 5.8 – Gráfico de medição instantânea dos ruídos captados pelo HSCT e pelo sistema de SAR após processamento para corrente primária  $I_p = 0\mu A$ .




Figura 5.9 – Gráfico de medição instantânea das correntes medidas pelo HSCT e pelo sistema de SAR após processamento para corrente primária  $I_p = 1\mu A$ .

As Figuras 5.10 e 5.11 mostram os diagramas de blocos do FB-PLL. Para a determinação do ângulo  $\theta_a$  são utilizados os blocos de Detecção de Fase (DF) e Análise Dinâmica de Fourier (ADF) com a reconstrução do sinal. O DF visto na Figura 5.10 estima o valor do ângulo de fase  $\hat{\theta}_a$  a partir do erro entre as tensões  $U_a(t)$  medida e  $\hat{U}_a(t)$  estimada. A tensão  $\hat{U}_a(t)$  é obtida pela ADF (Figura 5.11), que fornece como saída os termos  $a_n$  e  $b_n$  da Série de Fourier do sinal de entrada  $U_a(t)$ . A reconstrução do sinal  $\hat{U}_a(t)$  é obtido pela soma dos termos da série:

$$\hat{U}_a(t) = a_n \cos[\hat{\theta}_a(t)] + b_n \sin[\hat{\theta}_a(t)] \quad (5.8)$$

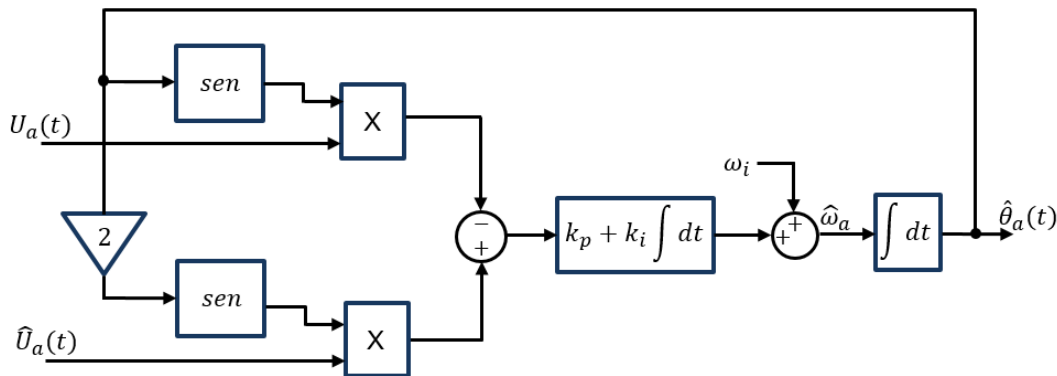


Figura 5.10 – Diagrama de blocos do Detector de Fase (DF) utilizado no FB-PLL.

A determinação dos ganhos  $k_p$  e  $k_i$  do detector de fase podem ser obtidos pelas equações [98, 99].

$$k_i = \frac{0,16\omega_i^2}{U_{a-m\acute{a}x}} \quad (5.9)$$

$$k_p = \frac{2\sqrt{2}}{\sqrt{\frac{U_{a-máx}}{k_i}}} \quad (5.10)$$

Onde:

- $\omega_i = 2\pi f$ : frequência fundamental da corrente  $I_0$  ( $f = 60Hz$ );
- $U_{a-máx}$ : tensão máxima (pico) da fase- $a$ .

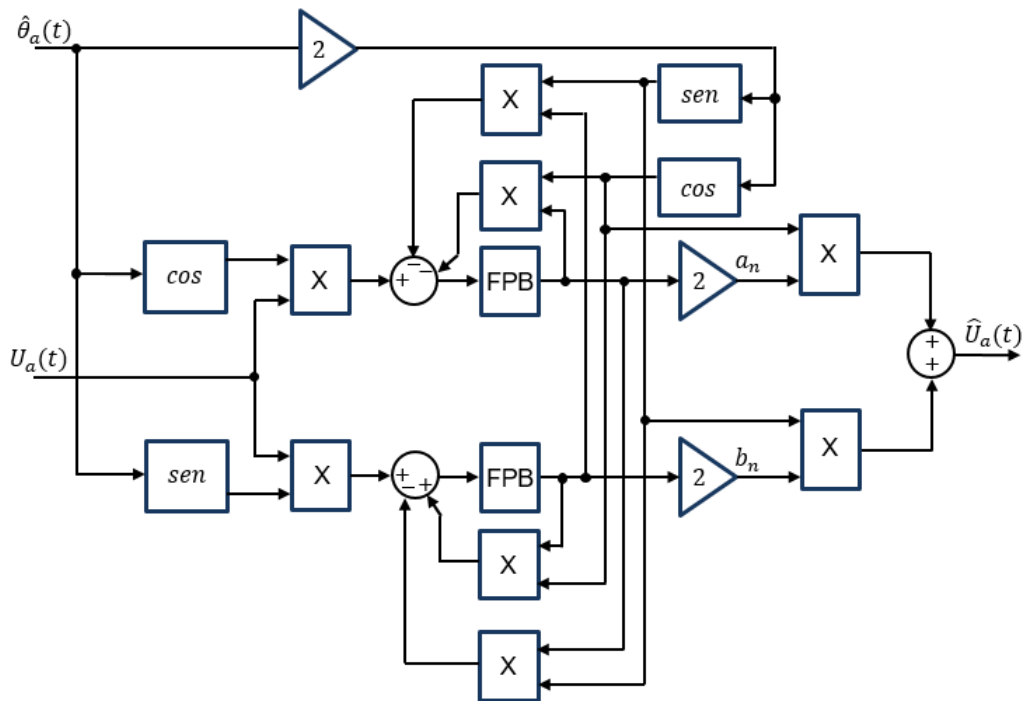


Figura 5.11 – Diagrama de blocos da Análise Dinâmica de Fourier (ADF) do FB-PLL.

Os Filtros Passa Baixa (FPB) da ADF são de primeira ordem, cuja constante de tempo  $\tau$  é dada por:

$$\tau = \frac{\sqrt{2}}{\omega_i} \quad (5.11)$$

$$FPB(s) = \frac{1}{\tau s + 1} \quad (5.12)$$

Para o cálculo do ângulo  $\theta_0(t)$ , foi utilizado uma abordagem semelhante ao empregado pelo FB-PLL. São obtidas as componentes em fase ( $a_0$ ), e defasadas  $90^\circ$  ( $b_0$ ) da corrente  $I_0(t)$  em relação a tensão  $U_a(t)$ . As componentes  $a_0$  e  $b_0$  são análogas aos termos  $a_n$  e  $b_n$  da Série de Fourier.

$$a_0 = \frac{2}{T} \int_0^T I_0(t) \cos[\hat{\theta}_a(t)] dt \quad (5.13)$$

$$b_0 = \frac{2}{T} \int_0^T I_0(t) \sin[\hat{\theta}_a(t)] dt \quad (5.14)$$

$$T = \frac{1}{f}, \quad \text{para } f = 60\text{Hz} \quad (5.15)$$

O valor de  $\theta_0$  pode ser calculado como:

$$\theta_0 = \arctan\left(\frac{b_0}{a_0}\right) \quad (5.16)$$

O diagrama de blocos da Figura 5.12 resume a proposta para o Sistema de Monitoramento *On-line* do Isolamento (SIMOI) de MITs de BT e MT. Com os valores da corrente  $I_0(t)$  e da tensão  $U_a(t)$ , são calculados os valores eficazes das grandezas e o ângulo  $\theta_0$ . Se o ângulo  $\theta_0$  pertencer a um intervalo válido para a avaliação do isolamento, os valores de  $I_0(t)$  e  $U_a(t)$  serão utilizados para determinar  $I_R$ ,  $I_C$ ,  $R_{eq}$ ,  $C_{eq}$  e  $FD_{eq}$  conforme as equações indicadas na Tabela 4.2 do Capítulo 4. Os valores de  $R_{eq}$ ,  $C_{eq}$  e  $FD_{eq}$  em *p.u.* são utilizados na RNA para a classificação do fator de estresse que está afetando o isolamento. A proteção preditiva é realizada com os valores de  $I_0$  e de  $I_R$ . O monitoramento preditivo do isolamento é feito a partir dos valores de  $R_{eq}$ , que também são utilizados para a previsão do Tempo de Falha (*TF*), cujos modelos serão discutidos no Capítulo 6.

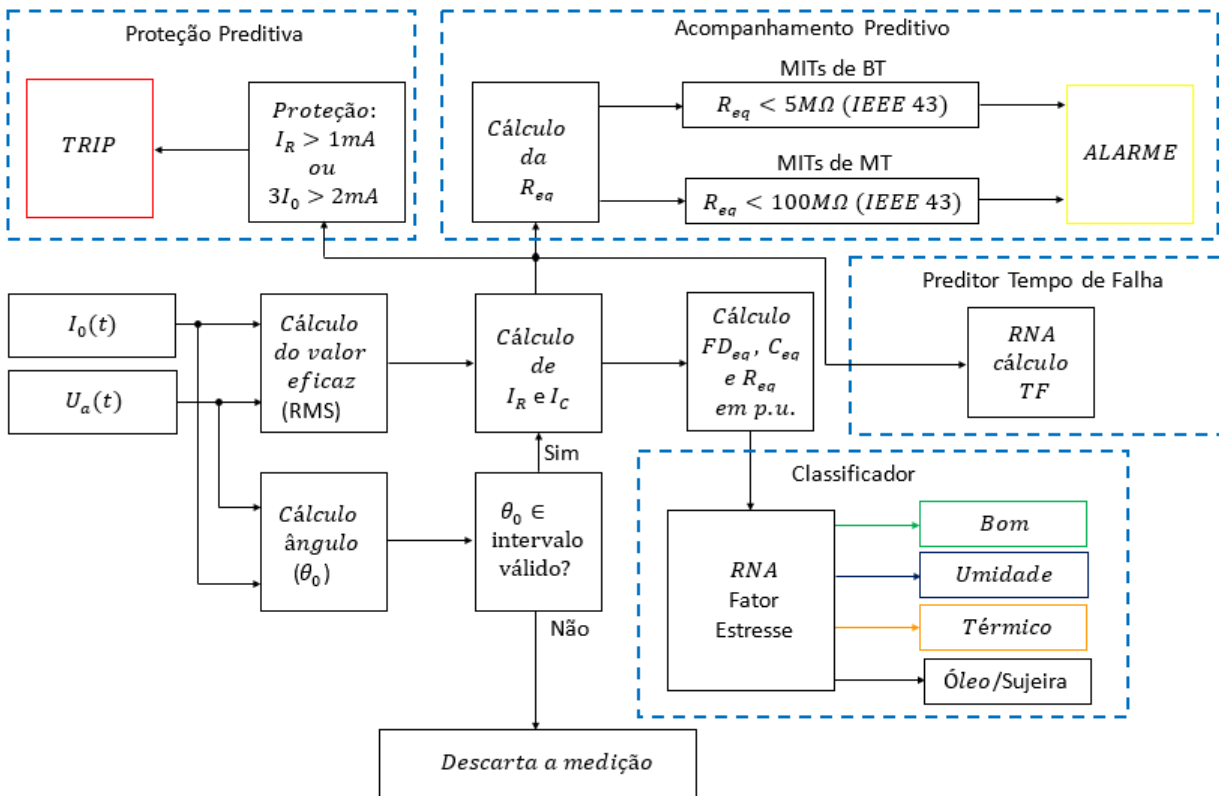


Figura 5.12 – Diagrama de blocos do Sistema de Monitoramento *On-line* para o Isolamento de MITs de BT e MT - SIMOI.

## 5.2 Testes Experimentais *On-Line*

Esta seção apresenta os resultados experimentais do sistema de monitoramento e proteção preditiva *on-line* proposto “SIMOI”. A montagem experimental para a obtenção dos resultados foi construída no Laboratório de Instrumentação e Automação da Refinaria Gabriel Passos (REGAP) da Petrobras, localizada na cidade de Betim-MG.

A montagem experimental foi desenvolvida para possibilitar a inserção de falhas no isolamento provocadas por estresse térmico, absorção de umidade e contaminação por óleo. A Figura 5.13 mostra a fotografia da montagem experimental desenvolvida.



Figura 5.13 – Fotografia da montagem experimental para testes do SIMOI.

As Figuras 5.14 e 5.15 mostram as fotografias com mais detalhes da montagem desenvolvida. Na Figura 5.14 destaca-se:

- a estufa com controle automático de temperatura com *range* de 0 a 300<sup>0</sup>C de ajuste;
- o sistema pneumático com controle automático de injeção de névoa. O sistema permite que seja ajustado a vazão de injeção de água ou óleo em forma de névoa;
- o painel de alimentação, comando e proteção do motor em teste.

Na Figura 5.15 são mostradas as placas eletrônicas (fonte, condicionadores de sinal, micro-controlador, relés, transdutores, TPs, etc), o computador com a interface gráfica do SIMOI, o sensor HSCT e a antena do sistema de SAR.




Figura 5.14 – Estufa, painel de alimentação e sistema de injeção de névoa.

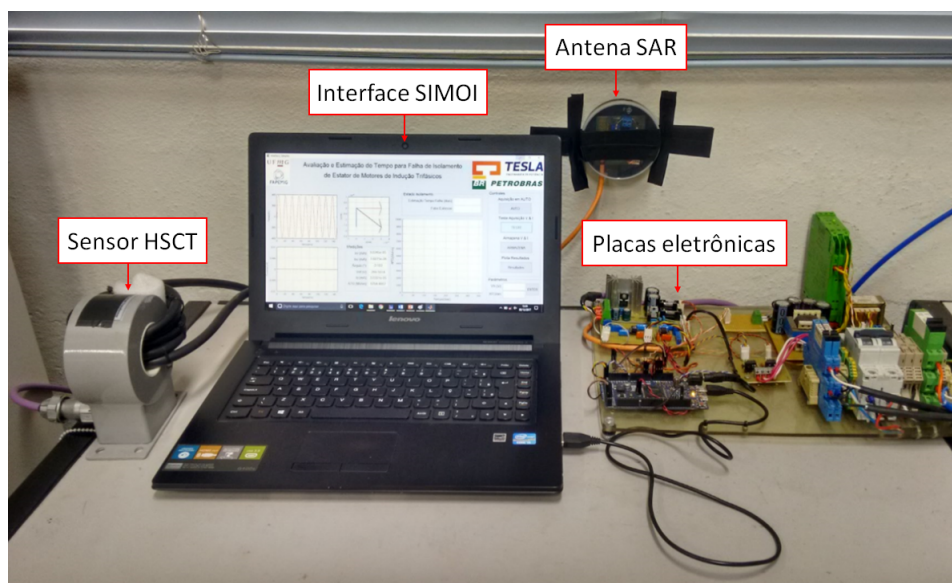


Figura 5.15 – Placas eletrônicas, interface gráfica do SIMOI, sensor HSCT e antena do sistema de SAR.

### 5.2.1 Ensaio de Envelhecimento Acelerado

O ensaio de envelhecimento acelerado tem o objetivo de submeter o isolamento do motor ao mecanismo de degradação do isolamento devido ao estresse térmico. O teste foi realizado em um motor de 0,5cv de potência, tensão nominal de 440V e isolamento

classe F ( $155^{\circ}C$ ). O ensaio foi realizado com o motor energizado dentro da estufa, cuja temperatura do isolamento foi medida e mantida constante em torno de  $205^{\circ}C$ .

O tempo de vida nominal de isolamentos novos é de 20.000 horas [100]. Segundo a Lei de Arrhenius (equação (3.21)), para a elevação de temperatura  $\Delta T = 50^{\circ}C$ , utilizada no ensaio, o tempo de falha previsto é para que ocorra após 840 horas de operação.

O tempo inicial ( $t = 0$ ) do ensaio foi considerado a partir do momento em que o ângulo  $\theta_0$  se tornasse válido após 2 amostragens consecutivas. Para o ensaio de envelhecimento o ângulo  $\theta_0$  apresentou-se estável após 60 horas de operação na estufa. Para demonstrar a eficácia do SIMOI, os resultados do diagnóstico *on-line* foram comparados com as medições *off-line* obtidas com parada momentânea do ensaio *on-line* a cada 24 ou 48 horas. As Tabelas 5.1 e 5.2 apresentam os resultados dos testes *off-line* e *on-line*, respectivamente. A Tabela 5.1 apresenta os valores de resistência e capacitância do isolamento total e por fase, os cálculos dos índices *IP* e *IA* e a classificação do estado do isolamento realizado pela RNA3 apresentada no Capítulo 3. A Tabela 5.2 mostra os valores calculados para a resistência, a capacitância e o *FD* equivalente *on-line* do isolamento, a classificação do fator de estresse e a atuação do monitoramento preditivo do SIMOI.

Tabela 5.1 – Resultados dos testes *off-line* para o motor submetido ao estresse térmico.

$t(h)$	$R_I$ por fase ( $M\Omega$ )			$C_I$ por fase ( $pF$ )			$R_I$	$C_I$	<i>IP</i>	<i>IA</i>	<i>RNA off-line</i>
	$R_{I-a}$	$R_{I-b}$	$R_{I-c}$	$C_{I-a}$	$C_{I-b}$	$C_{I-c}$					
0	51300	36780	56300	705	680	700	34780	1100	2,54	2,38	Bom
48	50500	27450	45080	705	680	700	25200	1100	3,76	2,72	Bom
96	48900	21900	43450	705	680	700	19900	1100	4,15	2,61	Bom
144	47400	21100	42500	705	680	700	19600	1100	5,03	3,20	Bom
192	45750	15400	42100	705	680	700	13450	1100	4,98	3,25	Bom
240	44500	14360	42050	700	670	700	12200	1100	4,92	3,93	Bom
288	41900	10400	40550	700	660	690	9200	1100	5,68	3,95	Bom
336	42100	6240	39050	700	660	690	5800	1080	5,98	4,73	Térmico
384	41800	2320	38000	700	650	690	1980	1080	5,66	4,38	Térmico
432	39000	1780	37800	700	560	690	1670	1080	5,70	4,91	Térmico
480	37900	890	32300	700	510	690	840	970	6,04	4,97	Térmico
528	34500	280	31600	700	440	680	260	900	6,50	5,00	Térmico
576	31350	58,0	28900	700	340	680	55,0	800	6,00	6,11	Térmico
624	26700	23,0	22300	700	300	680	22,0	760	5,33	5,64	Térmico
672	24050	5,80	21900	695	370	680	4,80	710	5,29	5,33	Térmico
696	23600	4,40	20350	690	310	680	3,10	690	4,33	4,77	Ruim
744	21200	1,40	18300	690	230	660	1,20	630	2,38	1,44	Ruim
792	18900	0,50	16700	680	180	650	0,45	560	2,00	1,50	Ruim

Tabela 5.2 – Resultados dos testes *on-line* para o motor submetido ao estresse térmico.

$t(h)$	$R_{eq}(M\Omega)$	$C_{eq}(pF)$	$FD_{eq}$	$R_{eq}(pu)$	$C_{eq}(pu)$	$FD_{eq}(pu)$	RNA <i>on-line</i>	Relé Saída
0	627,1	15,3	0,28	-	-	-	-	-
48	590,0	12,5	0,36	0,9410	0,82	1,30	Bom	-
96	364,2	10,1	0,72	0,5810	0,66	2,62	Bom	-
144	270,6	9,2	1,07	0,4310	0,60	3,89	Bom	-
192	241,4	10,5	1,20	0,3470	0,68	4,34	Bom	-
240	236,8	10,9	1,18	0,3390	0,71	4,28	Bom	-
288	225,1	14,5	0,81	0,3690	0,95	2,94	Bom	-
336	204,0	12,4	0,88	0,3990	0,81	3,18	Bom	-
384	205,3	13,5	0,84	0,3750	0,88	3,03	Bom	-
432	120,1	15,9	1,39	0,1920	1,04	5,04	Térmico	-
480	76,6	14,1	2,45	0,1220	0,92	8,90	Térmico	-
528	22,2	16,0	7,47	0,0450	1,04	27,10	Térmico	-
576	14,6	18,5	9,82	0,0230	1,21	35,60	Térmico	-
624	9,5	11,9	23,39	0,0150	0,78	83,54	Térmico	-
672	2,6	12,3	82,63	0,0042	0,80	295,11	Térmico	Alarme
696	2,0	13,6	98,01	0,0032	0,89	350,04	Térmico	Alarme
720	1,6	14,9	108,10	0,0036	0,97	386,07	Térmico	Alarme
744	1,2	13,4	167,30	0,0019	0,88	597,50	Térmico	Alarme
768	0,8	13,0	249,10	0,0013	0,85	889,64	Térmico	Alarme
792	0,3	21,6	382,10	0,0005	1,41	1364,64	Térmico	TRIP

As Tabelas 5.1 e 5.2 mostram que a classificação do fator de estresse térmico é caracterizado em ambos os testes entre o período compreendido de 300h a 400h. O diagnóstico *on-line* aciona a saída de alarme após 620h de operação do motor, mais conservador que o resultado *off-line* que indicou que o isolamento estava “ruim” num período posterior (por volta de 700h).

Como o ensaio de envelhecimento tem caráter “destrutivo” o isolamento do motor foi testado até uma condição crítica (falha do isolamento). O objetivo era a verificação da atuação da proteção preditiva, que neste caso ocorreu como previsto. O desligamento do motor (TRIP) ocorreu após 792h de operação para uma  $R_{eq} \approx 0,3k\Omega$ .

A Figura 5.16 mostra os gráfico com os valores da corrente  $I_0$  e do ângulo  $\theta_0$  ao longo do ensaio de envelhecimento acelerado. Nota-se que o ângulo  $\theta_0$  está compreendido entre  $240^\circ < \theta_0 < 330^\circ$ , que corresponde às correntes de fuga provenientes da fase-*b*. Assim, observa-se que o diagnóstico *on-line* da fase em processo de degradação, coincide com a redução da resistência do isolamento da fase-*b* dos testes *off-line* vistos na Tabela 5.1.




Figura 5.16 – Corrente  $I_0$  e ângulo  $\theta_0$  do teste *on-line* de envelhecimento acelerado.

A Figura 5.17 mostra a evolução das correntes resistiva  $I_R$  e capacitiva  $I_C$  do isolamento ao longo do ensaio de envelhecimento acelerado. Como esperado, a corrente capacitiva  $I_C$  permanece praticamente constante durante todo o teste. Entretanto, com a acentuação do processo de falha, em torno de 500 horas, a corrente  $I_C$  apresenta uma pequena redução. Essa redução pode ser explicada pelo preenchimento com ar dos espaços vazios ocasionados pela secagem do isolamento, que de forma geral, reduz a sua capacitância.




Figura 5.17 – Correntes  $I_R$  e  $I_C$  do teste *on-line* de envelhecimento acelerado.

A perda da característica isolante é percebida pelo aumento da corrente resistiva  $I_R$ , acompanhado do aumento substancial do Fator de Dissipação equivalente ( $FD_{eq}$ ) visto na

Figura 5.18 . O aumento destas grandezas, que possuem comportamentos quase análogos, evidencia a perda da característica dielétrica do isolamento devido à ação da temperatura.




Figura 5.18 – Fator de Dissipação  $FD_{eq}$  do teste *on-line* de envelhecimento acelerado.

A Figura 5.19 mostra a fotografia do estator do motor submetido ao ensaio de envelhecimento acelerado. Como esperado, observa-se o isolamento com aspecto escuro e quebradiço. A recuperação do isolamento deste motor só é possível através de rebobinagem completa dos enrolamentos do estator.




Figura 5.19 – Fotografia do estator do MIT após o teste *on-line* de envelhecimento acelerado.

## 5.2.2 Ensaio de Absorção de Umidade

Este ensaio tem o objetivo de submeter o isolamento à condição de falha devido à absorção de umidade pelo isolamento. Conforme descrito na Seção 3.2.2, a absorção de umidade no isolamento está relacionada a problemas de vedação na caixa de ligação e tampas do motor, ou furos internos no sistema de refrigeração. A água que é absorvida pelo isolamento nesses casos pode ser oriunda de chuva ou dos sistema de refrigeração. A água utilizada em sistemas de refrigeração pode variar conforme a especificação do fabricante do motor, podendo se encontrar sistemas que utilizam água desmineralizada, ou sistemas que operam com água industrial.

A Tabela 5.3 mostra dados de resistividade ( $\rho$ ) e permissividade ( $\epsilon$ ) para alguns tipos de água utilizadas em sistemas de refrigeração da REGAP-Petrobras e da mica-epoxi utilizada no isolamento de MITs de BT e MT. Comparado-se os valores de  $\rho$  e  $\epsilon$  dos tipos de água em relação a da mica, nota-se que a resistividade da água é de 13000 a 900000 vezes menor que a da mica. Assim, caso o isolamento absorva, por exemplo, a água desmineralizada, que possui a maior resistividade dentre as amostras águas consideradas, o valor da  $R_I$  seria reduzido significativamente. Em outras palavras, a absorção de qualquer tipo de água da Tabela 5.3, ocasionará falha no isolamento do motor.

Tabela 5.3 – Resistividade e permeabilidade de alguns tipos de água que podem ser absorvidas pelo isolamento.

Dielétrico	$\rho(k\Omega.m)$	$\epsilon(nF/m)$
Água potável	3,28125	1024
Água de chuva	8,59375	304
Água industrial	1,17188	3520
Água desmineralizada	76,5625	35,2
Mica	1.000.000	0,0478

Para o ensaio de absorção de umidade do isolamento foi selecionada a água potável. A razão para essa escolha passa em primeiro lugar pela facilidade de se obter esse tipo de água. Em segundo, o fato da condutividade e da permissividade estarem em uma faixa intermediária, quando comparada aos demais tipos de água, faz com que a duração dos testes não seja nem muito longos e nem muito curtos, o que propicia um período mais adequado para o acompanhamento da falha.

O ensaio de absorção de umidade foi realizado com um motor de potência de 0,5cv, tensão nominal de 440V e isolamento classe F. A Figura 5.20 mostra o detalhe da montagem dos tubos de injeção de umidade do sistema de névoa, e do termopar para o monitoramento da temperatura do isolamento. O ensaio foi realizado com o motor energizado, cuja temperatura do isolamento foi mantida em média em torno de 80°C, temperatura que permite que a água absorvida permaneça no isolamento. Para manter

a temperatura próxima a  $80^{\circ}\text{C}$ , foi necessário estabelecer ciclos de parada e partida do motor, onde:

- o motor era desligado se a temperatura do isolamento fosse maior que  $90^{\circ}\text{C}$ ;
- o motor era ligado se a temperatura do motor fosse menor que  $70^{\circ}\text{C}$ ;
- a cada 1 hora era injetado pelo sistema de névoa aproximadamente  $2,5\text{ml}$  de água.




Figura 5.20 – Foto da montagem dos tubos de injeção de água e do termopar no motor.

O tempo  $t = 0$ , para o início do ensaio, foi estabelecido após 10 horas de operação do motor, quando o ângulo  $\theta_0$  se tornou válido entre 2 medições consecutivas. Os diagnósticos do SIMOI foram comparados com as medições *off-line* obtidas com parada momentânea do ensaio *on-line* a cada 12 ou 24 horas. As Tabelas 5.4 e 5.5 apresentam os resultados dos testes *off-line* e *on-line*, respectivamente. As medições de  $R_I$  e  $C_I$  por fase e total, os índices  $IP$  e  $IA$  e a classificação do estado do isolamento feito pela RNA3 *off-line* são mostrados na Tabela 5.4. Os resultados análogos *on-line* de  $R_{eq}$ ,  $C_{eq}$ ,  $FD_{eq}$ , da classificação do fator de estresse e do monitoramento preditivo são vistos na Tabela 5.5.

Tabela 5.4 – Resultados dos testes *off-line* para o motor submetido a absorção de umidade.

$t(h)$	$R_I$ por fase ( $M\Omega$ )			$C_I$ por fase ( $pF$ )			$R_I$	$C_I$	$IP$	$IA$	$RNA$ <i>off-line</i>
	$R_{I-a}$	$R_{I-b}$	$R_{I-c}$	$C_{I-a}$	$C_{I-b}$	$C_{I-c}$					
0	46300	29200	41000	980	980	980	26900	1550	3,12	2,32	Bom
24	18500	15800	18800	990	990	990	14400	1650	2,74	2,12	Bom
36	9900	14800	14300	1010	1005	1000	12800	1690	2,54	1,98	Bom
48	18900	14500	21400	1210	10005	1000	11500	1750	2,20	1,50	Bom
61	70	1830	26000	1950	1010	1005	78	2400	1,41	1,32	Umidade
73	5,95	980	720	2850	1050	1020	6,10	3200	1,20	1,10	Umidade
86	0,67	89	67	4250	1070	1090	0,67	4700	1,10	1,05	Ruim

Tabela 5.5 – Resultados dos testes *on-line* para o motor submetido a absorção de umidade.

$t(h)$	$R_{eq}(M\Omega)$	$C_{eq}(pF)$	$FD_{eq}$	$R_{eq}(pu)$	$C_{eq}(pu)$	$FD_{eq}(pu)$	RNA <i>on-line</i>	Relé Saída
0	351,8	17,4	0,43	-	-	-	-	-
12	335,4	19,4	0,41	0,9533	1,12	0,94	Bom	-
18	341,8	21,4	0,36	0,9716	1,23	0,83	Bom	-
24	359,4	19,8	0,37	1,0216	1,14	0,86	Bom	-
30	331,0	20,7	0,39	0,9409	1,19	0,89	Bom	-
36	345,6	21,3	0,36	0,9824	1,23	0,83	Bom	-
42	325,7	21,5	0,38	0,9258	1,24	0,87	Bom	-
48	360,3	19,3	0,38	1,0242	1,11	0,88	Bom	-
54	304,1	18,7	0,47	0,8644	1,08	1,07	Bom	-
60	96,0	29,3	0,94	0,2729	1,69	2,17	Umidade	-
62	82,1	33,3	0,97	0,2334	1,92	2,23	Umidade	-
64	63,5	41,4	1,01	0,1805	2,39	2,32	Umidade	-
66	27,4	93,2	1,04	0,0780	5,37	2,39	Umidade	-
68	17,7	132,4	1,13	0,0503	7,63	2,61	Umidade	-
70	11,8	186,5	1,20	0,0336	10,77	2,79	Umidade	-
71	11,7	189,4	1,20	0,0333	10,92	2,75	Umidade	-
72	9,4	229,3	1,23	0,0267	13,22	2,83	Umidade	-
73	7,3	292,1	1,24	0,0208	16,84	2,85	Umidade	-
74	6,6	319,8	1,25	0,0189	18,43	2,87	Umidade	-
75	5,4	389,2	1,27	0,0153	22,43	2,92	Umidade	-
76	4,1	504,8	1,29	0,0116	29,09	2,96	Umidade	Alarme
77	3,6	571,8	1,29	0,0102	32,96	2,97	Umidade	Alarme
78	3,4	596,1	1,32	0,0096	34,36	3,03	Umidade	Alarme
79	2,0	1009,0	1,32	0,0057	58,20	3,04	Umidade	Alarme
80	1,7	1203,0	1,33	0,0047	69,37	3,06	Umidade	Alarme
81	1,5	1316,0	1,34	0,0043	75,86	3,07	Umidade	Alarme
82	1,2	1630,0	1,34	0,0035	93,98	3,08	Umidade	Alarme
83	1,1	1837,0	1,35	0,0030	105,92	3,10	Umidade	Alarme
84	0,9	2154,8	1,36	0,0026	124,20	3,12	Umidade	Alarme
85	0,6	3107,0	1,36	0,0018	179,13	3,13	Umidade	Alarme
86	0,3	4551,0	1,76	0,0008	262,32	4,09	Umidade	TRIP

As Tabelas 5.4 e 5.5 mostram que a absorção de umidade no isolamento é detectada em ambos os testes após 60 horas do início do ensaio. O diagnóstico *on-line* aciona a saída de alarme após 75h de operação do motor, mais conservador que o resultado *off-line* que

indicou que o isolamento estava “ruim” num período posterior (por volta de 86h).

No ensaio de absorção de umidade pôde se verificar a eficácia da proteção preditiva do SIMOI. A atuação do relé de TRIP ocorreu para uma  $R_{eq} \approx 0,3k\Omega$ . Neste caso, o motor sob ensaio foi levado a estufa por 24 horas a uma temperatura de  $120^{\circ}C$ . Após a secagem, o motor foi ensaiado novamente, os testes apresentaram  $R_I > 40000M\Omega$  a  $25^{\circ}C$ , indicando a recuperação da resistência do isolamento.

A Figura 5.21 mostra os gráfico com os valores da corrente  $I_0$  e do ângulo  $\theta_0$  ao longo do ensaio de absorção de umidade. Nota-se que o ângulo  $\theta_0$  está compreendido entre  $0^{\circ} < \theta_0 < 90^{\circ}$ , que corresponde as correntes de fuga provenientes da fase-*a*. Desta forma, observa-se que o diagnóstico *on-line* da fase em processo de degradação, coincide com a redução da resistência de isolamento da fase-*a* dos testes *off-line* vistos na Tabela 5.4.




Figura 5.21 – Corrente  $I_0$  e ângulo  $\theta_0$  do teste *on-line* de absorção de umidade.

A Figura 5.22 mostra a evolução das correntes resistiva  $I_R$  e capacitiva  $I_C$  do isolamento ao longo do ensaio de absorção de umidade. Como esperado, as correntes resistiva  $I_R$  e capacitiva  $I_C$  aumentam de forma semelhante durante o teste. Entretanto, com a acentuação do processo de falha, em torno de 70 horas, a corrente  $I_R$  apresenta uma maior elevação em sua taxa de crescimento. Esse aumento pode ser explicado pelo fato da condutividade da água ser relativamente maior que a sua permeabilidade, que de forma geral, faz com que a corrente  $I_R$  seja maior que a corrente  $I_C$  no processo de absorção de umidade pelo isolamento.

A perda da característica isolante é percebida pelo aumento da corrente resistiva  $I_R$ . No caso da absorção de umidade pelo isolamento, o Fator de Dissipação equivalente ( $FD_{eq}$ ), visto na Figura 5.23, aumenta muito pouco. A pequena alteração observada é

justificada pelo aumento proporcional da corrente capacitiva  $I_C$ , o que caracteriza a perda da rigidez dielétrica do isolamento devido à absorção de umidade.




Figura 5.22 – Correntes  $I_R$  e  $I_C$  do teste *on-line* de absorção de umidade.




Figura 5.23 – Fator de Dissipação  $FD_{eq}$  do teste *on-line* de absorção de umidade.

### 5.2.3 Ensaio de Contaminação por Óleo

Este ensaio tem o objetivo de submeter o isolamento a condição de falha devido à contaminação. Conforme descrito na Seção 3.2.2, esta falha está associada a contaminação superficial do material dielétrico por óleo ou graxa contaminados por partículas condutoras. Geralmente, o material contaminado entra em contato com isolamento devido a dosagem inadequada (excesso) de lubrificante e/ou defeitos nos sistemas de selagem (labirintos)

das caixas de mancais e rolamentos do motor. Quanto maior o nível de contaminação do óleo/graxa mais acelerada é a falha do isolamento. A Tabela 5.6 apresenta valores de resistividade ( $\rho$ ) e permissividade ( $\epsilon$ ) de amostras de óleo lubrificantes de motores da REGAP-Petrobras. A Figura 5.24 mostra a fotografia com as amostras de óleo, onde da esquerda para direita tem-se o frasco com o óleo novo, o óleo da amostra 1 e o óleo da amostra 2.

A Tabela 5.6 mostra os valores de  $\rho$  e  $\epsilon$  do óleo lubrificante industrial Lubrax Hydra XP 68 em seu estado novo [101]. O óleo novo apresenta resistividade elevada, semelhante à da mica-epoxi utilizada no isolamento de MITs. As amostras de óleo 1 e 2 apresentam valores de resistividade e permissividade de óleos de mancais de motores da REGAP-Petrobras. Nessas amostras, observa-se a redução acentuada da resistividade de ambos os óleos, entretanto a permissividade é pouco alterada.

Tabela 5.6 – Resistividade e permeabilidade de óleos lubrificantes que podem contaminar o isolamento.

Dielétrico	$\rho(k\Omega.m)$	$\epsilon(nF/m)$
Óleo novo	312500	52,8
Amostra de óleo 1	375	40,5
Amostra de óleo 2	21,88	36,8
Mica	1000000	0,0478



Figura 5.24 – Amostras de óleos de lubrificação de motores da REGAP-Petrobras.

Para o ensaio de contaminação foi selecionado o óleo da amostra 1. O uso desse óleo é justificada por esse apresentar resistividade intermediária, possibilitando um acompanhamento mais adequado da falha ao longo da operação do motor.

O ensaio de contaminação por óleo foi realizado com um motor de potência de 0,5cv, tensão nominal de 440V e isolamento classe F. Para a injeção do óleo contaminado (amostra 1) foi utilizado o mesmo sistema de injeção de névoa do ensaio de absorção de umidade. O ensaio foi realizado com o motor energizado, cuja temperatura do isolamento foi mantida em média em torno de  $120^{\circ}C$ , temperatura inferior à classe de isolamento do motor ( $155^{\circ}C$ ). Para manter essa temperatura, foi necessário estabelecer ciclos de parada e partida do motor, onde:

- o motor era desligado se a temperatura do isolamento fosse maior que  $130^{\circ}C$ ;
- o motor era ligado se a temperatura do motor fosse menor que  $110^{\circ}C$ ;
- a cada 2 horas era injetado pelo sistema de névoa aproximadamente 1,0ml de óleo.

O tempo  $t = 0$ , para o início do ensaio, foi estabelecido após 50 horas de operação do motor, quando o ângulo  $\theta_0$  se tornou válido entre 2 medições consecutivas. Os diagnósticos do SIMOI foram comparados com as medições *off-line* obtidas com parada momentânea do ensaio *on-line* a cada 24 ou 48 horas. As Tabelas 5.7 e 5.8 apresentam os resultados dos testes *off-line* e *on-line* respectivamente. As medições de  $R_I$  e  $C_I$  por fase e total, os índices  $IP$  e  $IA$  e a classificação do estado do isolamento feito pela RNA3 *off-line* são mostrados na Tabela 5.7. Os resultados análogos *on-line* de  $R_{eq}$ ,  $C_{eq}$ ,  $FD_{eq}$ , da classificação do fator de estresse e do monitoramento preditivo são vistos na Tabela 5.8.

Tabela 5.7 – Resultados dos testes *off-line* para o motor submetido a contaminação por óleo.

$t(h)$	$R_I$ por fase ( $M\Omega$ )			$C_I$ por fase ( $pF$ )			$R_I$	$C_I$	$IP$	$IA$	RNA <i>off-line</i>
	$R_{I-a}$	$R_{I-b}$	$R_{I-c}$	$C_{I-a}$	$C_{I-b}$	$C_{I-c}$					
0	28100	28500	35400	1010	1010	1010	25200	1660	2,45	1,66	Bom
48	25200	25300	34500	1015	1015	1010	24200	1700	2,55	1,62	Bom
96	24100	24700	30800	1025	1020	1020	22300	1700	2,72	1,56	Bom
144	23750	17600	28900	1030	1035	1030	15800	1725	2,68	1,62	Bom
192	23200	9600	27850	1035	1050	1035	8300	1760	2,68	1,48	Bom
336	23200	1030	26500	1050	1090	1050	980	1800	2,04	1,45	Óleo
456	22350	880	24900	1060	1140	1070	810	1870	1,93	1,56	Óleo
564	22200	510	24550	1060	1160	1070	410	1890	1,86	1,57	Óleo
660	21700	160	23800	1070	1190	1070	140	1910	1,87	1,56	Óleo
760	21650	154	22600	1070	1200	1070	121	1930	1,89	1,64	Óleo
960	21500	110	22550	1080	1210	1080	90,0	2010	1,80	1,43	Óleo
1360	9400	28,0	8900	1110	1250	1100	21,0	2120	1,62	1,44	Óleo
1560	1120	7,00	1380	1130	1350	1120	5,00	2230	1,67	1,50	Óleo
1680	670	4,00	560	1150	1450	1160	3,00	2350	1,50	1,33	Ruim

As Tabelas 5.7 e 5.8 mostram que a contaminação do isolamento é detectada em ambos os testes após 300h do início do ensaio. O diagnóstico *on-line* aciona a saída de alarme após 1260h de operação do motor, mais conservador que o resultado *off-line* que indicou que o isolamento estava “ruim” num período posterior (por volta de 1680h).

Tabela 5.8 – Resultados dos testes *on-line* para o motor submetido a contaminação por óleo.

$t(h)$	$R_{eq}(M\Omega)$	$C_{eq}(pF)$	$FD_{eq}$	$R_{eq}(pu)$	$C_{eq}(pu)$	$FD_{eq}(pu)$	RNA <i>on-line</i>	Relé Saída
0	276,6	262,5	1,83	-	-	-	-	-
24	295,2	287,8	1,88	1,0672	1,10	1,03	Bom	-
48	256,5	290,8	2,04	0,9273	1,11	1,11	Bom	-
84	238,6	293,7	2,07	0,8626	1,12	1,13	Bom	-
120	217,4	297,7	2,11	0,7860	1,13	1,16	Bom	-
156	195,6	304,3	2,11	0,7072	1,16	1,15	Bom	-
192	192,5	303,5	2,17	0,6960	1,16	1,19	Bom	-
228	183,7	302,9	2,30	0,6641	1,15	1,26	Bom	-
264	184,0	307,1	2,15	0,6652	1,17	1,18	Bom	-
300	38,2	300,5	3,96	0,1381	1,14	2,16	Óleo	-
336	23,7	306,9	3,97	0,0856	1,17	2,17	Óleo	-
372	18,6	354,8	4,01	0,0674	1,35	2,20	Óleo	-
396	17,9	351,4	4,22	0,0646	1,34	2,31	Óleo	-
444	15,8	412,9	4,06	0,0572	1,57	2,22	Óleo	-
456	15,5	406,5	4,22	0,0559	1,55	2,31	Óleo	-
516	12,9	403,1	5,10	0,0467	1,54	2,79	Óleo	-
588	11,5	463,1	4,98	0,0415	1,76	2,73	Óleo	-
660	10,8	487,2	5,04	0,0391	1,86	2,76	Óleo	-
756	9,5	500,0	5,59	0,0343	1,90	3,06	Óleo	-
852	8,8	521,6	5,81	0,0317	1,99	3,18	Óleo	-
960	7,8	538,5	6,33	0,0281	2,05	3,46	Óleo	-
1068	6,5	588,6	6,95	0,0234	2,24	3,80	Óleo	-
1176	5,3	626,5	8,05	0,0190	2,39	4,41	Óleo	-
1260	5,0	636,0	8,40	0,0179	2,42	4,60	Óleo	Alarme
1356	4,4	636,6	9,38	0,0161	2,43	5,13	Óleo	Alarme
1464	4,0	590,2	11,12	0,0146	2,25	6,08	Óleo	Alarme
1560	3,4	593,0	13,33	0,0121	2,26	7,29	Óleo	Alarme
1608	3,2	593,4	13,82	0,0117	2,26	7,56	Óleo	Alarme
1656	3,0	633,7	13,99	0,0108	2,41	7,65	Óleo	Alarme
1680	2,8	619,3	15,04	0,0103	2,36	8,23	Óleo	Alarme

No ensaio de contaminação não se verificou a atuação da proteção preditiva do SIMOI. A não atuação do relé de TRIP pode ser explicada pelo fato da contaminação ter alcançado um valor de estabilidade para a resistência de isolamento. Assim, para a amostra de óleo escolhida para a realização do ensaio (amostra 1), a atuação do TRIP só ocorreria em um tempo muito longo, com a ocorrência do processo de oxidação (envelhecimento) do óleo lubrificante.

O motor sob ensaio foi lavado com solvente dielétrico e levado à estufa por 24 horas a uma temperatura de  $120^{\circ}\text{C}$ . Após a limpeza e a secagem, o motor foi ensaiado novamente, cujos testes apresentaram  $R_I > 10000\text{M}\Omega$  a  $25^{\circ}\text{C}$ , indicando a recuperação da resistência do isolamento. A Figura 5.25 mostra o estator do motor após o fim do teste de contaminação por óleo (a) e depois do processo de limpeza e secagem do isolamento (b).




Figura 5.25 – Foto do estator do motor após o fim do teste de contaminação e após sua limpeza e secagem.

A Figura 5.26 mostra os gráficos com os valores da corrente  $I_0$  e do ângulo  $\theta_0$  ao longo do ensaio de contaminação. Nota-se que o ângulo  $\theta_0$  está compreendido entre  $240^{\circ} < \theta_0 < 330^{\circ}$ , que corresponde às correntes de fuga provenientes da fase-b. Desta forma, observa-se que o diagnóstico *on-line* da fase em processo de degradação, coincide com a redução da resistência de isolamento da fase-b dos testes *off-line* vistos na Tabela 5.7.

A Figura 5.27 mostra a evolução das correntes resistiva  $I_R$  e capacitiva  $I_C$  do isolamento ao longo do ensaio de contaminação. A corrente capacitiva  $I_C$  aumenta nas primeiras 300h de ensaio, ficando praticamente constante no restante do teste. A corrente resistiva  $I_R$  aumenta durante todo o ensaio, aumentando sua taxa de crescimento com acentuação do processo de falha, que também ocorre para tempos superiores a  $t > 300\text{h}$ .

A corrente  $I_R$  aumenta mais que a corrente  $I_C$ , pois a condutividade do óleo contaminado é relativamente maior que a sua permeabilidade, fazendo com que a corrente  $I_R$  seja maior que a corrente  $I_C$  durante o processo contaminação do isolamento.




Figura 5.26 – Corrente  $I_0$  e ângulo  $\theta_0$  do teste *on-line* de contaminação.




Figura 5.27 – Correntes  $I_R$  e  $I_C$  do teste *on-line* de contaminação.

A perda da rigidez dielétrica do isolamento é percebida pelo aumento da corrente resistiva  $I_R$ . No caso da contaminação superficial do isolamento, o Fator de Dissipação equivalente ( $FD_{eq}$ ), visto na Figura 5.28, também aumenta. O aumento do  $FD_{eq}$  é justificada pelo maior aumento da corrente resistiva  $I_R$  em relação a corrente capacitiva  $I_C$ . Comparado ao aumento do  $FD_{eq}$  devido ao estresse térmico, na contaminação superficial

o aumento do  $FD_{eq}$  é menor. O aumento relativo do  $FD_{eq}$  e da corrente  $I_R$  caracterizam a perda da rigidez dielétrica devido à contaminação superficial do isolamento.




Figura 5.28 – Fator de Dissipação  $FD_{eq}$  do teste *on-line* de contaminação.

### 5.3 Conclusões

Esse capítulo apresentou o Sistema de Monitoramento *On-line* para o Isolamento de MITs de BT e MT (SIMOI). Foram abordados os desafios e as soluções adotadas para a medição e o processamento da corrente de fuga do isolamento da ordem de  $\mu A$ . Também, foram apresentadas a metodologia e os resultados dos testes experimentais *on-line* de motores submetidos a falhas no isolamento devido ao estresse térmico, à absorção de umidade e à contaminação por óleo.

O sistema de medição utilizado a partir do HSC T apresentou excelente exatidão para a medição e monitoramento da corrente  $I_0$  do isolamento. Estes resultados só foram possíveis com a aplicação do sistema de Supressão Ativa de Ruído (SAR), que possibilitou a medição de correntes da ordem de  $1\mu A$  com exatidão de  $\pm 2,5\%$  e erro de fase menor que 1,5 graus.

Os estudos e metodologias desenvolvidas para o acompanhamento preditivo *on-line* do isolamento puderam ser avaliadas a partir dos testes experimentais. Os ensaios realizados em MITs de BT mostraram resultados satisfatórios para a detecção e a classificação do fator de estresse que estava degradando o isolamento, bem como a eficácia da proteção preditiva em desenergizar o MIT antes de uma falha catastrófica no seu isolamento. Em termos comparativos, a eficiência dos diagnósticos produzidos pelo SIMOI foram comprovados pelos resultados do acompanhamento preditivo *off-line*, o que suporta de forma definitiva

a possibilidade da realização de diagnósticos de falhas no isolamento de forma *on-line* em MITs de BT e MT.

Assim, o SIMOI apresenta-se como uma solução bastante promissora para o monitoramento preditivo *on-line* para o isolamento de MITs de BT e MT.

## 6 Preditor de Tempo de Falha do Isolamento

NESTE capítulo são apresentadas duas propostas de modelos para a previsão do Tempo de Falha ( $TF$ ) do isolamento de MITs de BT e MT para incorpora-se ao SIMOI. O primeiro modelo, ARMA (*Auto Regressive Moving Average*), é baseado numa abordagem estocástica de característica linear e o outro é baseado em RNAs.

São apresentados os principais fundamentos para a análise e a elaboração de modelos para séries temporais utilizando a metodologia clássica ARMA e empregando RNAs. Para a construção dos modelos são utilizadas as medições da corrente resistiva  $I_R$  do isolamento obtidas dos testes experimentais realizados com o SIMOI apresentadas no Capítulo 5.

São apresentados os desafios e as soluções propostas para a construção de modelos que possam representar as séries temporais independente do conhecimento do mecanismo que gera a falha no isolamento. O objetivo é de que os preditores propostos tenham a capacidade de monitorar e prever o tempo de falha independente do fator de estresse que está causando a degradação do isolamento. A comparação do desempenho dos preditores é realizado pela avaliação do RMSE (*Root Mean Square Error*) e do EPTF (Erro de Previsão do Tempo de Falha).

Na organização do capítulo, a Seção 6.1 apresenta os fundamentos para a análise de séries temporais, bem como as estratégias e as justificativas escolhidas para a elaboração dos modelos. A Seção 6.2 apresenta a proposta do preditor ARMA, e a Seção 6.3 descreve a elaboração do modelo neural. Na Seção 6.4 é mostrada a avaliação dos modelos propostos para a previsão do  $TF$  do isolamento a partir do RMSE e do EPTF. Por fim, a Seção 6.5 apresenta as conclusões acerca dos resultados obtidos.

### 6.1 Análise de Séries Temporais

O objetivo da análise de séries temporais é a modelagem do fenômeno, a obtenção de conclusões em termos estatísticos e a avaliação da adequação do modelo para a previsão. Um modelo de previsão pode ser interpretado como uma representação matemática dos dados observados, cujo objetivo é que esse seja capaz de descrever o comportamento dos dados que o gerou [102, 103].

O modelo matemático de uma série temporal pode ser realizado por meio da modelagem dos fenômenos físicos, onde são conhecidas as relações temporais das variáveis. Neste caso, são utilizados modelos econométricos e determinísticos, trazendo bons resultados para previsões a curto e médio prazo. Entretanto, essas abordagens necessitam de um grande

número de informações para a construção do modelo, que nem sempre estão disponíveis. Assim, uma abordagem estatística, baseado na probabilidade da existência da correlação entre os dados passados e futuros, apresenta-se como uma solução atraente para a obtenção de modelos com boa precisão e menor complexidade [103].

Um modelo estocástico parte do pressuposto que em um fenômeno dependente no tempo há muitos fatores desconhecidos, para os quais não é possível descrever um modelo determinístico que permita o cálculo exato do comportamento futuro. O que pode-se obter é um modelo capaz de calcular a probabilidade de um valor futuro estar entre dois limites especificados. Tal representação é chamado de modelo de probabilidade ou estocástico [102, 103].

A representação matemática para uma série temporal pode ser obtida empregando modelos probabilísticos ou estocásticos. Conforme a complexidade e as relações esperadas, a série pode ser representada por modelos lineares AR (*Auto Regressive*), ARMA (*Auto Regressive Moving Average*), ARIMA (*Auto Regressive Integrated Moving Average*), ou não lineares como os modelos NARMA (*Nonlinear Auto Regressive Moving Average*), ANFIS (*Artificial Neuro-Fuzzy Inference System*), RNAs (Redes Neurais Artificiais), etc [103].

Nesse trabalho, basicamente dois modelos são propostos e avaliados:

- um modelo linear ARMA;
- um modelo não-linear baseado em RNAs.

Uma série temporal  $x_t$  é um conjunto de dados de uma ou mais variáveis observadas no tempo. Uma série temporal discreta é obtida quando os dados são amostrados em intervalos de tempo regular. Uma forma clássica de decomposição de uma série temporal  $x_t$  pode ser escrita como [104, 105]:

$$x_t = m_t + p_t + y_t \quad (6.1)$$

Onde:

- $m_t$ : componente de tendência;
- $p_t$ : componente de sazonalidade com período  $d$ ;
- $y_t$ : componente de ruído aleatório;
- $t$ : subscrito que representa o tempo ou instante em que é observada a série ou suas componentes;

A componente de tendência  $m_t$  representa a característica de crescimento ou decrescimento dos valores esperados da série ao longo do tempo. A parcela  $p_t$  exprime

o comportamento periódico da série que são influenciadas por fatores cíclicos no tempo, como por exemplo a dependência da série com as estações do ano, ciclos de demanda de energia ao longo do dia, variação de consumo ao longo do ano, etc. [106]. A componente  $y_t$  representa o comportamento aleatório da série. Normalmente, essa parcela é caracterizada como um ruído branco representado por um processo estocástico estacionário [104].

O processo estocástico estacionário é caracterizado por:

- valor esperado é a média  $\mu_x$  para todo  $t$ ;
- função de densidade de probabilidade conjunta gaussiana.

O modelo ARMA é uma representação bastante utilizada para séries temporais caracterizadas como um modelo estocástico estacionário. Entretanto, para séries que apresentam-se como um processo não-estacionário, não possuindo uma média natural, o modelo mais adequado pode ser obtido com o ARIMA [104]. Na seção 6.2 são discutidas algumas técnicas para a transformação de séries não-estacionárias. O objetivo é que a série transformada possibilite o uso de um modelo ARMA para a previsão do  $TF$  neste trabalho.

O primeiro passo para a análise de qualquer série é a representação gráfica dos dados. Uma inspeção visual mostra como pode ser realizada o processo de decomposição da série em suas componentes [105].

As Figuras 6.1, 6.2 e 6.3 mostram as séries temporais das correntes resistivas  $I_R$  observadas que serviram de base para a construção dos modelos para a previsão do  $TF$  do isolamento.




Figura 6.1 – Gráfico da série temporal da corrente  $I_R$  do motor que sofreu falha no isolamento devido ao estresse térmico.




Figura 6.2 – Gráfico da série temporal da corrente  $I_R$  do motor que sofreu falha no isolamento devido à absorção de umidade.




Figura 6.3 – Gráfico da série temporal da corrente  $I_R$  do motor que sofreu falha no isolamento devido à contaminação por óleo.

A Figura 6.1 mostra a evolução ao longo do tempo da corrente resistiva  $I_R$  do isolamento do motor que sofreu falha devido a ação da temperatura. Na Figura 6.2 é apresentada a corrente  $I_R$  do motor cuja falha do isolamento foi proveniente da absorção de umidade, e a Figura 6.3 mostra a corrente  $I_R$  do motor que teve seu isolamento contaminado por óleo. O maior valor de corrente apresentado nos gráficos está próximo a  $54 \mu A$ . Esse valor representa uma resistência de isolamento equivalente de  $R_{eq} \approx 5 M\Omega$ , critério utilizado neste trabalho para indicar falha do isolamento em MITs de BT. Para facilitar a análise, o eixo da abscissa dos gráficos estão representados por unidades de atraso de tempo ( $lags$ ).

O tamanho do atraso (*lag*) deve ser escolhido de tal forma que o dado observado para esse *lag* represente o valor da série daquele intervalo sem que ocorra perda significativa de informação [103]. Neste trabalho, uma expectativa para o tempo de falha auxiliou inicialmente escolha para o tamanho do atraso. Para os ensaios de estresse térmico e contaminação por óleo, onde a expectativa do *TF* era elevado, um *lag*=12 horas mostrou-se adequado para a representação das séries nos dois casos. Já para o ensaio de absorção de umidade, cuja a expectativa de falha era mais acelerada, adotou-se o *lag*=1 hora. Na explicação sobre o pré-tratamento dos dados, vista mais adiante nessa seção, é mostrado como foi realizada a seleção do valor observado para cada *lag*.

A inspeção gráfica das Figuras 6.1, 6.2 e 6.3, como esperado, mostra a presença evidente da componente de tendência ( $m_t$ ). Como a corrente de fuga do isolamento não é afetada por fatores como a condição de carga do motor ou a variação de temperatura ambiente, pode-se admitir a ausência da componente de sazonalidade  $p_t$  na corrente de fuga do isolamento. Assim, é aceitável modelar as séries temporais para a previsão do *TF* do isolamento a partir da componente de tendência ( $m_t$ ) somada a componente de ruído aleatório ( $y_t$ ).

Uma das principais ferramentas utilizadas para selecionar um modelo para séries temporais, que reflita o grau de dependência presente nos dados observados da série  $\{x_1, x_2, \dots, x_n\}$ , é a análise da Função de Autocorrelação (FAC). Se um conjunto de observações de  $x_t$  possuir características de estacionariedade, uma estimativa da FAC pode sugerir possíveis modelos candidatos para representar a dependência entre dados passados e futuros. Por exemplo, se a FAC de uma série se encontrar próxima de zero para todos os atrasos (*lags*) diferentes de zero, então um modelo apropriado para a série pode ser um ruído branco [105]. A FAC exprime a medida de dependência temporal da série com ela mesma em diversos instantes de tempo. Quanto mais determinística a série, maior será a sua autocorrelação. A Função de Autocorrelação  $\psi_x(h)$  no *lag* =  $h$  é expressa por [107]:

$$\psi_x(h) = \frac{\gamma(h)}{\gamma(0)} \quad (6.2)$$

$$\gamma(h) = \frac{1}{n} \sum_{t=h+1}^n \{[x_{t-h} - \mu_x][x_t - \mu_x]\} \quad (6.3)$$

$$\mu_x = \frac{1}{n} \sum_{t=1}^n x_t \quad (6.4)$$

Onde:

- $\gamma(h)$ : Função de Autocovariância;
- $\mu_x$ : média de  $x_t$ ;
- $n$ : número de observações da série.

Normalmente a FAC é representada através de um gráfico conhecido como correlograma. Esse é construído a partir dos valores calculados de  $\psi_h$  delimitados pelos intervalos de confiança  $\pm 2s_\psi$  (95% de confiança). Valores de autocorrelação inferiores ao intervalo de confiança são estatisticamente não significativos [108].

$$s_\psi = \sqrt{\frac{1}{n} \left( 1 + 2 \sum_{i=1}^h \psi_i^2 \right)} \quad (6.5)$$

As funções de autocovariância e autocorrelação podem ser computadas para qualquer conjunto de dados, não sendo restritas a séries estacionárias. Para séries que apresentam a componente de tendência  $m_t$  a FAC apresentará um leve decréscimo em  $\psi_h$  a medida que  $h$  aumenta. Para séries que apresentam componentes de sazonalidade,  $\psi_h$  apresentará variações periódicas semelhantes a da série original [105].

A Função de Auto Correlação Parcial (FACP) é outra ferramenta utilizada para a identificação de modelos que se ajustem aos dados observados. A FACP computa a correlação de  $x_t$  e  $x_{t-k}$  removendo os efeitos das observações  $x_{t-1}, x_{t-2}, \dots, x_{t-k+1}$ , ou seja [108].:

$$\phi_{kk} = \text{Covariância}(x_t, x_{t-k} | x_{t-1}, x_{t-2}, \dots, x_{t-k+1}) \quad (6.6)$$

Assim como na FAC, a FACP também pode ser representada por um correlograma com os valores de  $\phi_{kk}$  delimitados pelos intervalos de confiança  $\pm 2s_\phi$  (95% de confiança). Valores de autocorrelação parcial inferiores ao intervalo de confiança são estatisticamente não significativos [108].

$$s_\phi = \frac{1}{\sqrt{n-1}} \quad (6.7)$$

As Figuras 6.4, 6.5 e 6.6 apresentam os correlogramas das funções FAC para os 20 primeiros lags das series de corrente resistiva  $I_R$  do isolamento utilizadas para a previsão do  $TF$  do isolamento.




Figura 6.4 – Correlogramas da série temporal da corrente  $I_R$  do motor que sofreu falha no isolamento devido ao estresse térmico.




Figura 6.5 – Correlogramas da série temporal da corrente  $I_R$  do motor que sofreu falha no isolamento devido à absorção de umidade.




Figura 6.6 – Correlogramas da série temporal da corrente  $I_R$  do motor que sofreu falha no isolamento devido à contaminação por óleo.

A análise dos correlogramas das FAC das Figuras 6.4, 6.5 e 6.6 mostram o decaimento dos valores de autocorrelação  $\psi_h$  com aumento do número de  $lags$ . As FACs mostram valores de autocorrelação elevados para os primeiros  $lags$  em todos os correlogramas, evidenciando a dependência temporal entre os dados passados, e a forte presença da componente de tendência  $m_t$  em todas as séries.

Para a utilização da metodologia sugerida por Box e Jenkins [104], na modelagem de séries temporais através do processo ARMA, é necessário a transformação da série original de forma a garantir as características de estacionariedade necessárias. A Seção 6.2 apresenta alguns processos aplicados a series não-estacionárias para torná-las estacionárias.

De forma geral, independente da abordagem adotada para a modelagem de uma série temporal (modelo ARMA ou RNA), pode-se citar as seguintes etapas do processo [108, 109]:

- 1 - pré-tratamento dos dados;

- 2 - identificação de modelos tentativos dos parâmetros;
- 3 - estimação e/ou cálculo dos parâmetros;
- 4 - teste ou validação do modelo;
- 5 - aplicação do modelo.

No pré-tratamento dos dados são utilizadas ferramentas de seleção, compactação ou filtros para a eliminação de valores muito discrepantes da série, que podem acarretar em erros elevados na estimação dos parâmetros e nos testes de previsão [103]. Nesse trabalho, o pré-tratamento do sinal foi feito a partir da seleção da mediana das observações. Para a série da corrente  $I_R$  do motor cujo isolamento sofreu falha devido à absorção de umidade, o valor válido da observação  $x_t$  foi tomado como sendo o próprio valor medido a cada 1 hora ( $lag=1$  hora)). No caso das séries da corrente  $I_R$  dos motores cujas falhas foram provenientes do estresse térmico ou da contaminação por óleo, o valor considerado para  $x_t$  foi a mediana das 12 observações realizadas no intervalo de 12 horas. Nesses dois últimos casos, como as variações nos valores destas observações não foram muito significativas foi possível a utilização de um atraso maior ( $lag=12$  horas). Quando possível, o emprego de estratégias de compactação de informação, como a citada anteriormente, deve ser empregada, pois essas contribuem para a filtragem e eliminação de ruídos e tendências que podem dificultar a modelagem da série [103].

Na etapa de identificação é determinado o tipo e a ordem do modelo. No modelo ARMA é determinada a ordem dos parâmetros auto-regressivos ( $p$ ) e de média móvel ( $q$ ). Para o modelo baseado em RNAs é selecionado o número de neurônios da camada escondida. Nesse trabalho, a determinação dos modelos ARMA e RNA para a previsão do  $TF$  são feitos de forma dinâmica. Para cada conjunto de observações  $x_h$  da série são avaliados os critérios de informação de Akaike e Bayesiano [106], que determinarão a ordem do modelo ARMA. Para o caso das RNAs, o número de neurônios da camada escondida é selecionado através da avaliação do mínimo RMSE para os dados de validação da rede. As seções 6.2 e 6.3 apresentarão mais detalhes das abordagens adotadas.

Para o modelo ARMA, a estimação e o cálculo dos parâmetros do modelo é feito, geralmente, pela minimização do erro entre os valores estimados e observados utilizando algoritmos como o de mínimos quadrados ou da máxima verossimilhança [108]. No caso do modelo RNA, a etapa de estimação é realizada com o treinamento da rede onde são ajustados os pesos das conexões sinápticas [66, 109].

O teste ou validação do modelo ARMA é realizado através da avaliação dos resíduos gerados entre a série estimada  $\hat{x}_t$  e as observações  $x_t$  ( $r_t = \hat{x}_t - x_t$ ). Um modelo bem ajustado apresenta resíduos  $r_t$  com comportamento semelhante ao ruído branco (média zero e variância constante). Espera-se também que os resíduos não sejam auto

correlacionados [108]. No modelo baseado em RNAs, a etapa de validação é realizada através de testes do modelo ajustado no processo de treinamento. É utilizado um conjunto de observações que não foram utilizadas no treinamento para avaliar a adequação e a generalização da RNA. A avaliação pode ser feita por meio do cálculo e da comparação de índices como o RMSE (*Root Mean Square Error*), o MSE (*Mean Square Error*), o MAE (*Mean Absolute Error*), etc. O objetivo é que a RNA treinada seja capaz de aprender a função que está gerando os dados, sendo capaz de generalizar e prever o comportamento futuro da série. O processo de validação e teste da RNA é de fundamental importância para se evitar problemas como o *over fitting* e *under fitting* durante o treinamento da rede [65, 66].

As etapas descritas são repetidas várias vezes com teste de diversos modelos, até a obtenção de um modelo satisfatório. Assim, após verificadas essas condições, o modelo poderá ser aplicado para a previsão.

Neste trabalho, o desempenho da previsão dos modelos é avaliado segundo duas métricas, o RMSE e o Erro de Previsão do Tempo de Falha (EPTF) dados pelas equações a seguir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{x}_t - x_t)^2} \quad (6.8)$$

$$EPTF = \frac{\hat{TF} - TF}{TF} \times 100 \quad (6.9)$$

Onde:

- $\hat{x}_t$ : valores estimados da série dos modelos ARMA ou RNA (correntes resistivas estimadas  $\hat{I}_R$  do isolamento);
- $x_t$ : valores observados da série (correntes resistivas  $I_R$  observadas);
- $\hat{TF}$ : tempo de falha em *lags* estimado pelos modelos ARMA ou RNA para que a corrente  $\hat{I}_R \geq 54\mu A$ ;
- $TF$ : tempo de falha em *lags* observado para que a corrente  $I_R \geq 54\mu A$ .

## 6.2 Modelo ARMA para Previsão do TF

Um modelo ARMA pode ser entendido como um modelo matemático para um processo estocástico estacionário  $z_t$ , podendo ser representado pela soma da combinação linear das observações passadas  $\{z_{t-1}, z_{t-2}, \dots, z_{t-p}\}$ , mais a combinação linear de uma componente de ruído aleatório  $e_t$  e suas observações  $\{e_{t-1}, e_{t-2}, \dots, e_{t-q}\}$  [108].

$$z_t = \theta_1 z_{t-1} + \theta_2 z_{t-2} + \dots + \theta_p z_{t-p} + e_t + \phi_1 e_{t-1} + \phi_2 e_{t-2} + \dots + \phi_q e_{t-q} \quad (6.10)$$

Como mostrado anteriormente as séries de corrente  $I_R$  não são estacionárias. Desta forma, para a utilização do modelo ARMA( $p, q$ ) é necessário a transformação da série para estimar ou eliminar a componente de tendência. A seguir são relacionadas algumas técnicas que podem ser empregadas, onde  $z_t$  representa a série  $x_t$  transformada.

1 - Transformação de Box-Cox [106]: É definida conforme a equação (6.11):

$$z_t = \begin{cases} \frac{x_t^\lambda - c}{\lambda} & \text{se } \lambda \neq 0 \\ \ln(x_t) & \text{se } \lambda = 0 \end{cases} \quad (6.11)$$

O valor de  $\lambda$  e  $c$  são os parâmetros a serem estimados. O  $\lambda$  é obtido a partir de uma varredura sobre um intervalo de valores possíveis, no qual procura-se identificar aquele que apresente a menor soma dos quadrados dos resíduos.

2 - Diferenciação [108]: A componente de tendência da série pode ser eliminada através do processo de diferenciação introduzido pelo operador de diferença  $\nabla$ . As equações (6.12) e (6.13) mostram como podem ser obtidas as séries transformadas pelo operador de primeira e segunda diferença respectivamente.

$$z_t = \nabla x_t = x_t - x_{t-1} \quad (6.12)$$

$$z_t = \nabla^2 x_t = x_t - 2x_{t-1} + x_{t-2} \quad (6.13)$$

3 - Filtro de Média Móvel Bilateral [105]: Nessa técnica é aplicado sobre a série de observações  $x_t$  um filtro de médias móveis de janela  $2q + 1$  para estimar a componente de tendência  $\hat{m}_t$ .

$$\hat{m}_t = \frac{1}{2q + 1} \sum_{j=-q}^q x_{t-j} \quad (6.14)$$

A série transformada  $z_t$ , que será modelada pelo processo ARMA( $p, q$ ) utilizando o filtro de médias móveis bilateral, é dada pela diferença entre  $\hat{m}_t$  e  $x_t$ .

$$z_t = \hat{m}_t - x_t \quad (6.15)$$

Nesse trabalho foi utilizada a técnica da filtragem de média móvel bilateral para estimar a componente de tendência e obter a característica de estacionariedade para as séries de corrente  $I_R$ . A justificativa para escolha desse método passa pela simplicidade de implementação do filtro aliado aos bons resultados obtidos utilizando uma filtragem de janela igual a 3 ( $q = 1$ ) para as 3 séries consideradas. Apesar dos bons resultados apresentados, a transformação de Box-Cox não foi selecionada por apresentar maior complexidade de implementação. Para a técnica de diferenciação, foi necessário a alteração da ordem do operador  $\nabla$  para a transformação das séries. Neste caso, além de se identificar

a ordem do modelo ARMA, é necessário determinar a ordem do operador de diferença  $\nabla$  a ser aplicado em cada série, o que aumenta a complexidade de implementação.

As Figuras 6.7, 6.8 e 6.9 mostram os gráficos das correntes  $I_R$  das séries observadas, filtradas e transformadas a partir da equação (6.15). A avaliação estatística das séries transformadas mostraram que essas possuem uma característica de estacionariedade forte com média aproximadamente nula e variância praticamente constante.

As Figuras 6.10, 6.11 e 6.12 mostram os correlogramas para os primeiros 10 *lags* das funções FAC e FACP das 3 séries para as corrente  $I_R$  transformadas.




Figura 6.7 – Gráficos das correntes  $I_R$  observada, filtrada e transformada do motor que sofreu falha no isolamento devido ao estresse térmico.

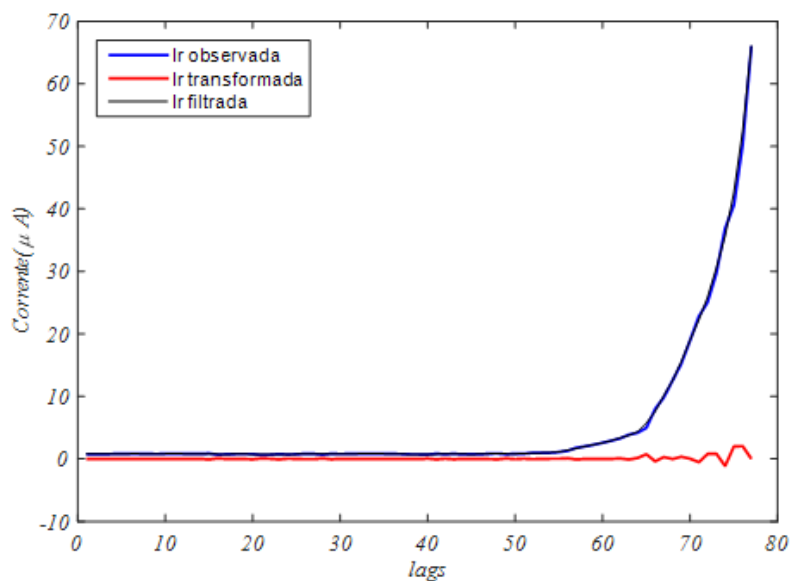


Figura 6.8 – Gráficos das correntes  $I_R$  observada, filtrada e transformada do motor que sofreu falha no isolamento devido à absorção de umidade.

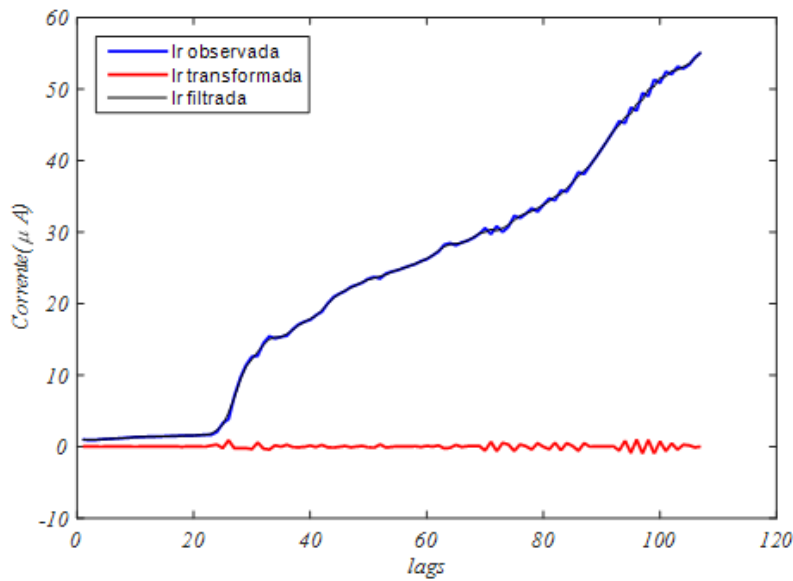


Figura 6.9 – Gráficos das correntes  $I_R$  observada, filtrada e transformada do motor que sofreu falha no isolamento devido à contaminação por óleo.




Figura 6.10 – Correlogramas das funções FAC e FACP da corrente  $I_R$  transformada do motor que sofreu falha no isolamento devido ao estresse térmico.




Figura 6.11 – Correlogramas das funções FAC e FACP da corrente  $I_R$  transformada do motor que sofreu falha no isolamento devido à absorção de umidade.

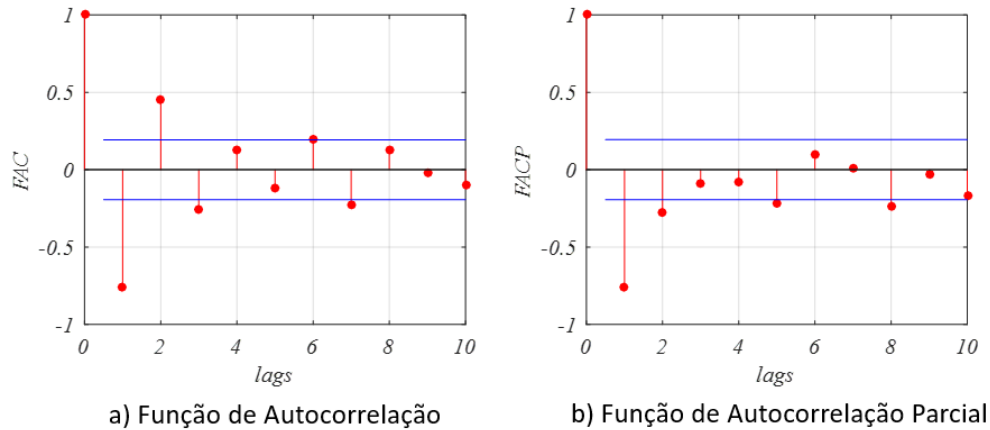


Figura 6.12 – Correlogramas das funções FAC e FAP da corrente  $I_R$  transformada do motor que sofreu falha no isolamento devido à contaminação por óleo.

De forma geral, a identificação da ordem do modelo  $ARMA(p, q)$  pode ser obtida através de uma inspeção visual dos correlogramas das funções FAC e FACP. A Tabela 6.1 mostra como realizar a identificação de alguns modelos tentativos  $ARMA(p, q)$ , a partir da inspeção visual dos correlogramas das funções FAC e FACP [109].

Tabela 6.1 – Quadro resumo para a identificação de modelos tentativos  $ARMA(p, q)$  a partir da inspeção visual dos correlogramas das funções FAC e FACP.

Modelo	FAC	FACP
MA(1)	1 pico no $lag = 1$	decréscimo exponencial
AR(1)	decréscimo exponencial	1 pico no $lag = 1$
MA(2)	1 pico no $lag = 1$ e no $lag = 2$	mistura de exponenciais ou ondas senoidais amortecidas
AR(2)	mistura de exponenciais ou ondas senoidais amortecidas	1 pico no $lag = 1$ e no $lag = 2$
ARMA(1,1)	1 pico no $lag = 1$ seguido de decaimento exponencial	1 pico no $lag = 1$ seguido de decaimento exponencial
ARMA(0,0)	pequenos valores e sem picos	pequenos valores e sem picos

Uma análise visual dos correlogramas das Figuras 6.10, 6.11 e 6.12 mostra que as séries apresentam características distintas quanto ao comportamento das suas funções de autocorrelação e autocorrelação parcial. Os correlogramas não apontam para a identificação de um modelo tentativo único e genérico para a modelagem  $ARMA(p, q)$  das séries. Isso, pode ser explicado pelo fato de que cada fator de estresse que degrada o isolamento acarreta em uma forma particular de dependência temporal entre as observações da série. Assim, para a seleção de um modelo  $ARMA(p, q)$  que não seja afetado pelo fator de estresse, será adotado neste trabalho o critério de informação Akaike e Bayesiano [106] para escolha do modelo que melhor represente os valores observados da corrente  $I_R$ .

O critério de informação de Akaike ( $AIC$ ) e Bayesiano ( $BIC$ ) são índices utilizados para selecionar um modelo tentativo para o ajuste dos dados observados de uma série temporal. Ambos os critérios têm como princípio determinar o modelo que maximize a função de verossimilhança entre os dados observados e a saída estimada do modelo. Quando a série tem características de estacionariedade com distribuição normal, os critérios informacionais de  $AIC$  e  $BIC$  podem ser simplificados e calculados pelas seguintes expressões [106, 109]:

$$AIC = n \ln(\hat{L}_p^2) + 2(p + 1) \quad (6.16)$$

$$BIC = n \ln(\hat{L}_p^2) + (p + 1) \ln(n) \quad (6.17)$$

$$\hat{L}_p^2 = \frac{1}{n} \sum_{i=1}^n (z_i - \hat{\mu}_i)^2 \quad (6.18)$$

Onde:

- $\hat{L}_p^2$ : estimador de máxima verossimilhança da variância do erro;
- $p$ : número de parâmetros do modelo;
- $\hat{\mu}_i$ : média da série  $\hat{z}_t$  estimada pelo modelo.

O termo adicionado a  $\hat{L}_p^2$  é chamado de função de penalidade, que tem o objetivo de corrigir o viés proveniente da comparação de modelos com diferentes números de parâmetros. Dentre os vários modelos candidatos, deve-se escolher aquele que apresenta o menor valor de  $AIC$  ou  $BIC$  [106].

Segundo Hurvich e Tsai, o critério de informação de Akaike apresentado na equação (6.16) é recomendado se a relação  $n/p \geq 40$ . Quando  $n/p < 40$ , melhores resultados podem ser obtidos utilizando o critério informacional de Akaike corrigido ( $AIC_c$ ) [106, 110].

$$AIC_c = AIC + \frac{2(p + 1)(p + 1)}{n - p - 2} \quad (6.19)$$

A seleção do modelo  $ARMA(p, q)$  utilizado para a previsão das séries das correntes  $I_R$  deste trabalho é realizado de forma dinâmica. A partir das séries de observações até o  $lag = h$ , são ajustados e testados os modelos  $ARMA(0,0)$  a  $ARMA(2,2)$  (total de 9 modelos) e avaliados os critérios informacionais de  $AIC$ ,  $AIC_c$  e  $BIC$ . Nas simulações realizadas não foi necessário utilizar modelos de ordem superior a  $p = 2$  e  $q = 2$  para o ajuste das séries.

O critério informacional ( $AIC$ ,  $AIC_c$  ou  $BIC$ ) utilizado para a identificação do modelo que se ajuste aos dados observados com o menor número de parâmetros, foi selecionado a partir da relação  $h/p$ . Quando a relação  $h/p < 40$ , foi escolhido o modelo

que apresentou o menor valor de  $AIC_c$ . Caso  $h/p \geq 40$ , o modelo selecionado foi aquele que apresentou o menor valor de  $AIC$  ou  $BIC$ . O fluxograma apresentado na Figura 6.13 explica de forma sintetizada a descrição para a identificação dinâmica do modelo  $ARMA(p, q)$  descrita anteriormente.

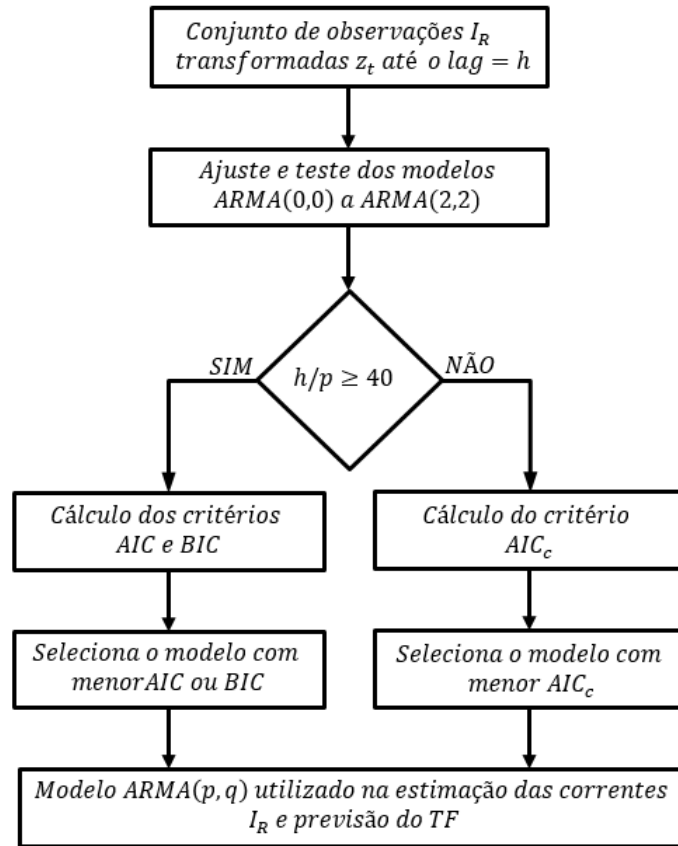


Figura 6.13 – Fluxograma para a seleção do modelo  $ARMA(p, q)$  a partir dos critérios de informação de Akaike e Bayesiano.

Com o modelo  $ARMA(p, q)$  selecionado, a previsão das correntes  $I_R$  e do TF podem ser realizadas. Tomando como exemplo a seleção de um modelo  $ARMA(1,1)$ , a previsão um passo a frente  $\hat{x}_{t+1}$  para as séries pode ser obtida por:

$$\hat{x}_{t+1} = 2x_t - x_{t-1} - 3\hat{z}_t \quad (6.20)$$

$$\hat{z}_t = p_1 x_{t-1} + e_t + q_1 e_{t-1} \quad (6.21)$$

A previsão de mais passos a frente, por exemplo  $\hat{x}_{t+2}$ , é realizada substituindo o valor anteriormente estimado  $\hat{x}_{t+1}$  nas equações (6.20) e (6.21). Esse processo é realizado sucessivamente até que a corrente estimada seja maior ou igual a  $54\mu A$ . As previsões realizadas para as correntes  $I_R$  são apresentadas com um intervalo de confiança ( $ic$ ) de 95% [109].

$$ic = \pm 1,96 \sqrt{\frac{1}{h-1} \sum_{i=1}^h (z_i - \mu_i)^2} \quad (6.22)$$

$$\mu_i = \frac{1}{h} \sum_{i=1}^h (z_i) \quad (6.23)$$

A Figuras 6.14, 6.15 e 6.16 mostram os resultados das previsões realizadas para as séries de corrente  $I_R$  de alguns *lags* específicos. Os resultados das previsões serão avaliados a partir do  $lag = 25$ , atraso para o qual os modelos iniciaram sua convergência em relação as séries originais.

A Figura 6.14 mostra os gráficos da corrente estimada  $\hat{I}_R$  para o motor submetido ao estresse térmico no isolamento em diferentes *lags*. Estão indicados nos gráficos o respectivo modelo ARMA selecionado para o ajuste dos dados observados e o intervalo de confiança para cada previsão. Nota-se que com o aumento dos *lags*, os valores estimados convergem para os dados observados. A corrente estimada  $\hat{I}_R$  apresenta erros elevados para  $lags < 40$ . Para  $lags > 40$ , quando a característica exponencial da série é incorporada ao modelo ARMA, a corrente estimada  $\hat{I}_R$  se aproxima dos valores observados  $I_R$ , possibilitando utilizá-la como uma boa previsão para determinar o tempo de falha do isolamento.

A Figura 6.15 mostra os gráficos da corrente estimada  $\hat{I}_R$  para o motor submetido à absorção de umidade pelo isolamento em diferentes *lags*. Nos gráficos estão indicados o respectivo modelo ARMA selecionado para o ajuste dos dados observados e o intervalo de confiança para cada previsão. Assim como na falha por estresse térmico, na falha do isolamento por absorção de umidade ocorre a convergência entre os valores estimados da corrente  $\hat{I}_R$  para os dados observados com o aumento dos *lags*. A corrente estimada  $\hat{I}_R$  apresenta erros elevados para  $lags < 60$ . Para  $lags > 60$ , quando o modelo ARMA incorpora a forte característica exponencial da série, a corrente estimada  $\hat{I}_R$  se aproxima dos valores observados  $I_R$ .

A absorção de umidade acarreta em um rápido aumento da corrente  $I_R$ , tornando difícil a previsão da falha do isolamento. Outros modelos tentativos ARMA não apresentaram desempenho superior para previsão desta falha. A seção 6.3 mostra melhores resultados na previsão da falha por absorção de umidade utilizando um modelo baseado em RNA.

A Figura 6.16 mostra os gráficos da corrente estimada  $\hat{I}_R$  para o motor submetido à contaminação por óleo no isolamento em diferentes *lags*. Nos gráficos estão indicados o respectivo modelo ARMA selecionado para o ajuste dos dados observados e o intervalo de confiança para cada previsão. Para  $lags > 40$ , que corresponde a menos de 40% do  $TF$ , a corrente estimada  $\hat{I}_R$  praticamente converge para os valores observados da série. Diferente dos outros dois fatores de estresse citados anteriormente, a contaminação por óleo acarreta em uma degradação mais lenta no isolamento, possibilitando uma excelente previsão para o tempo de falha.

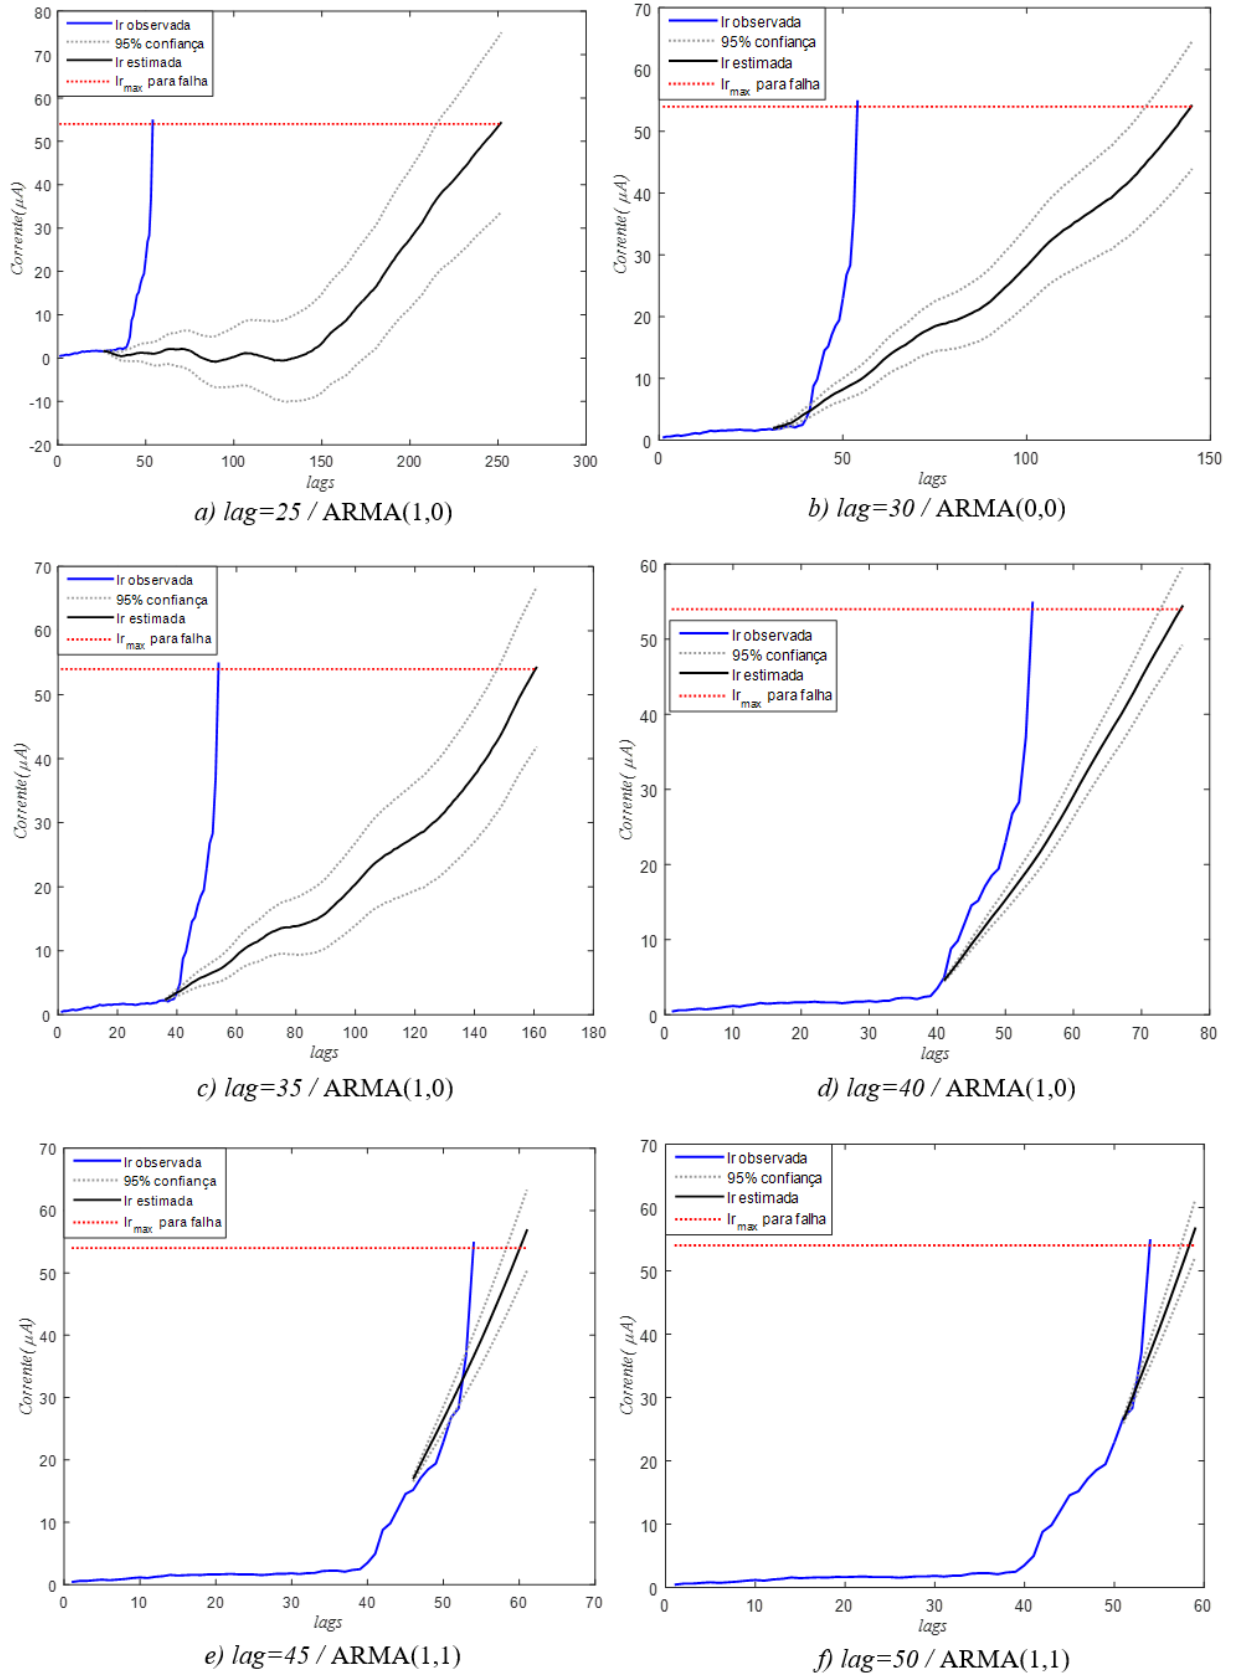


Figura 6.14 – Gráficos de previsão do modelo ARMA para a série de corrente  $I_R$  até a falha do isolamento do motor submetido ao estresse térmico.

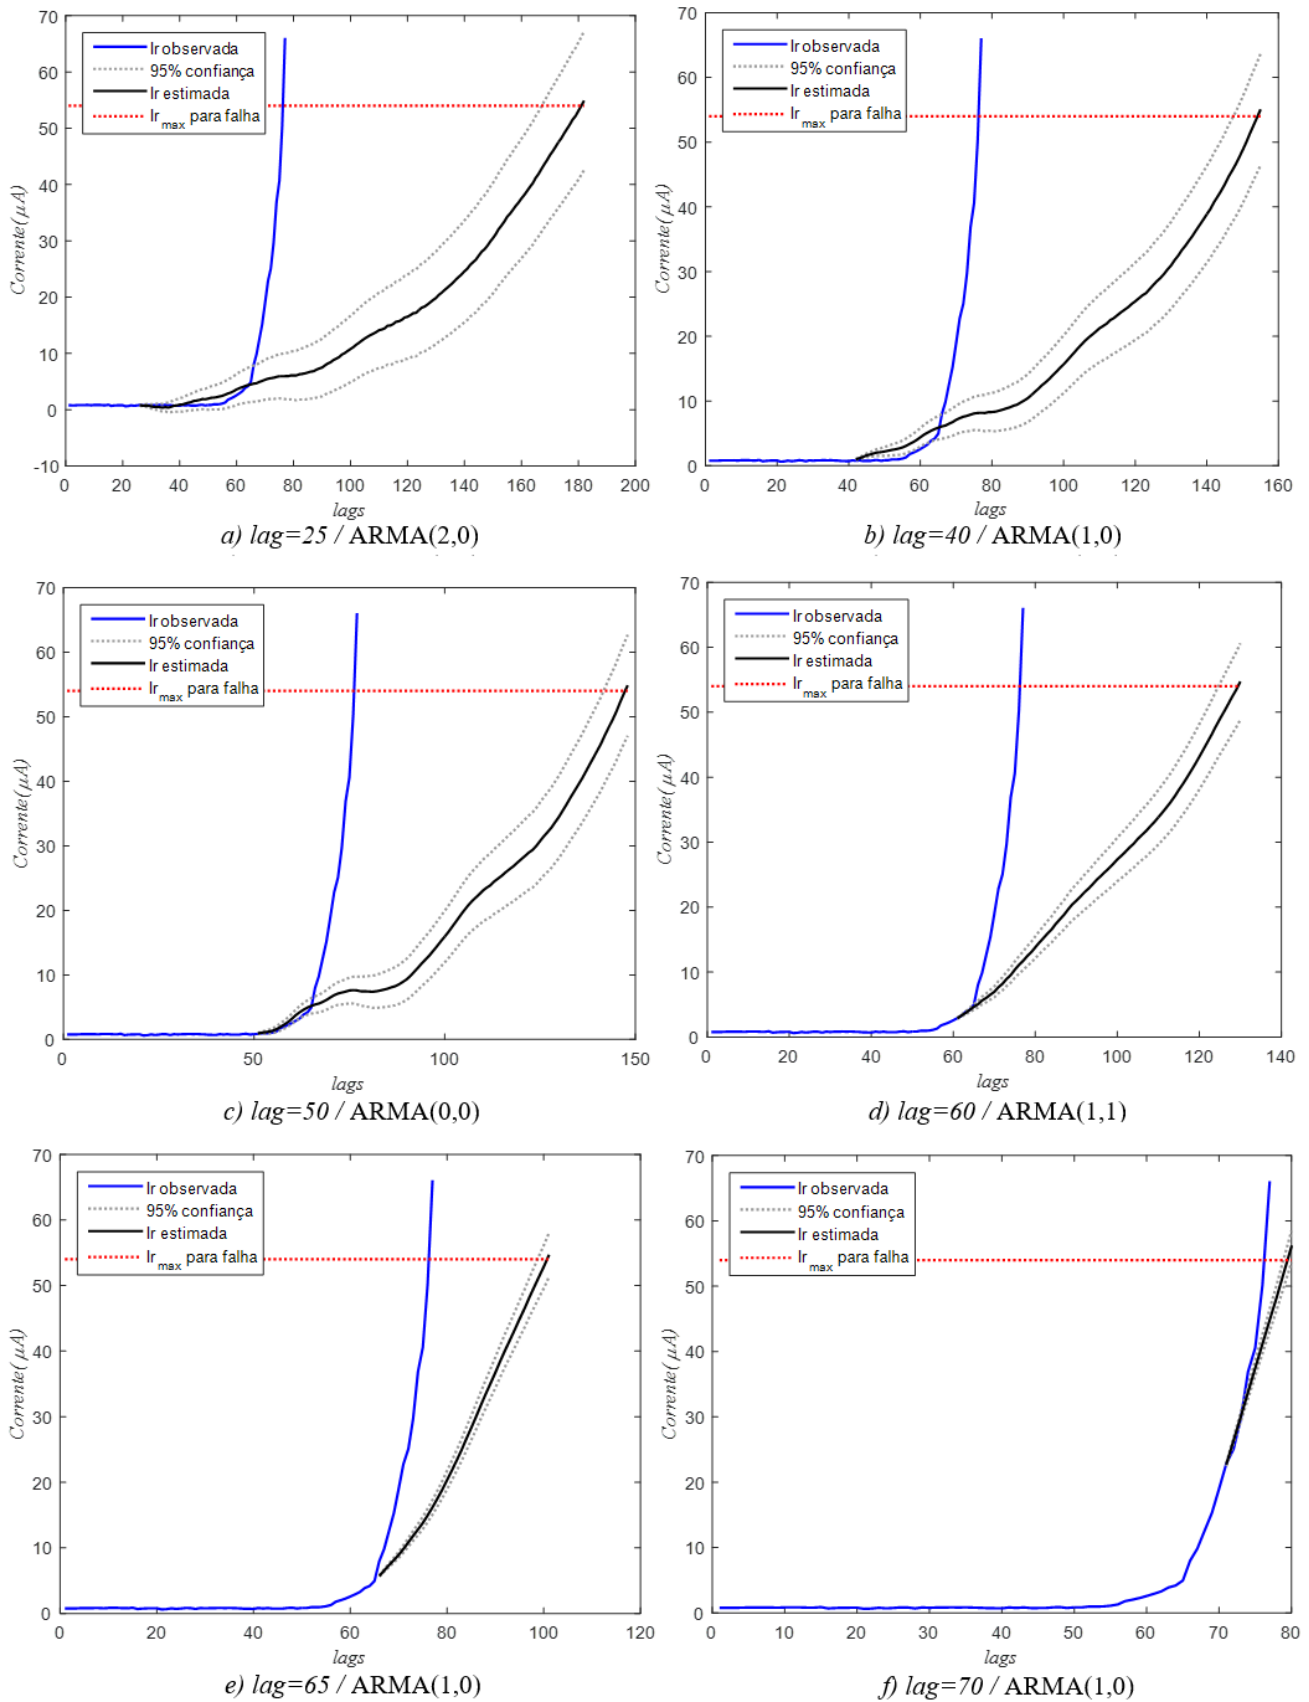


Figura 6.15 – Gráficos de previsão do modelo ARMA para a série de corrente  $I_R$  até a falha do isolamento do motor submetido à absorção de umidade.

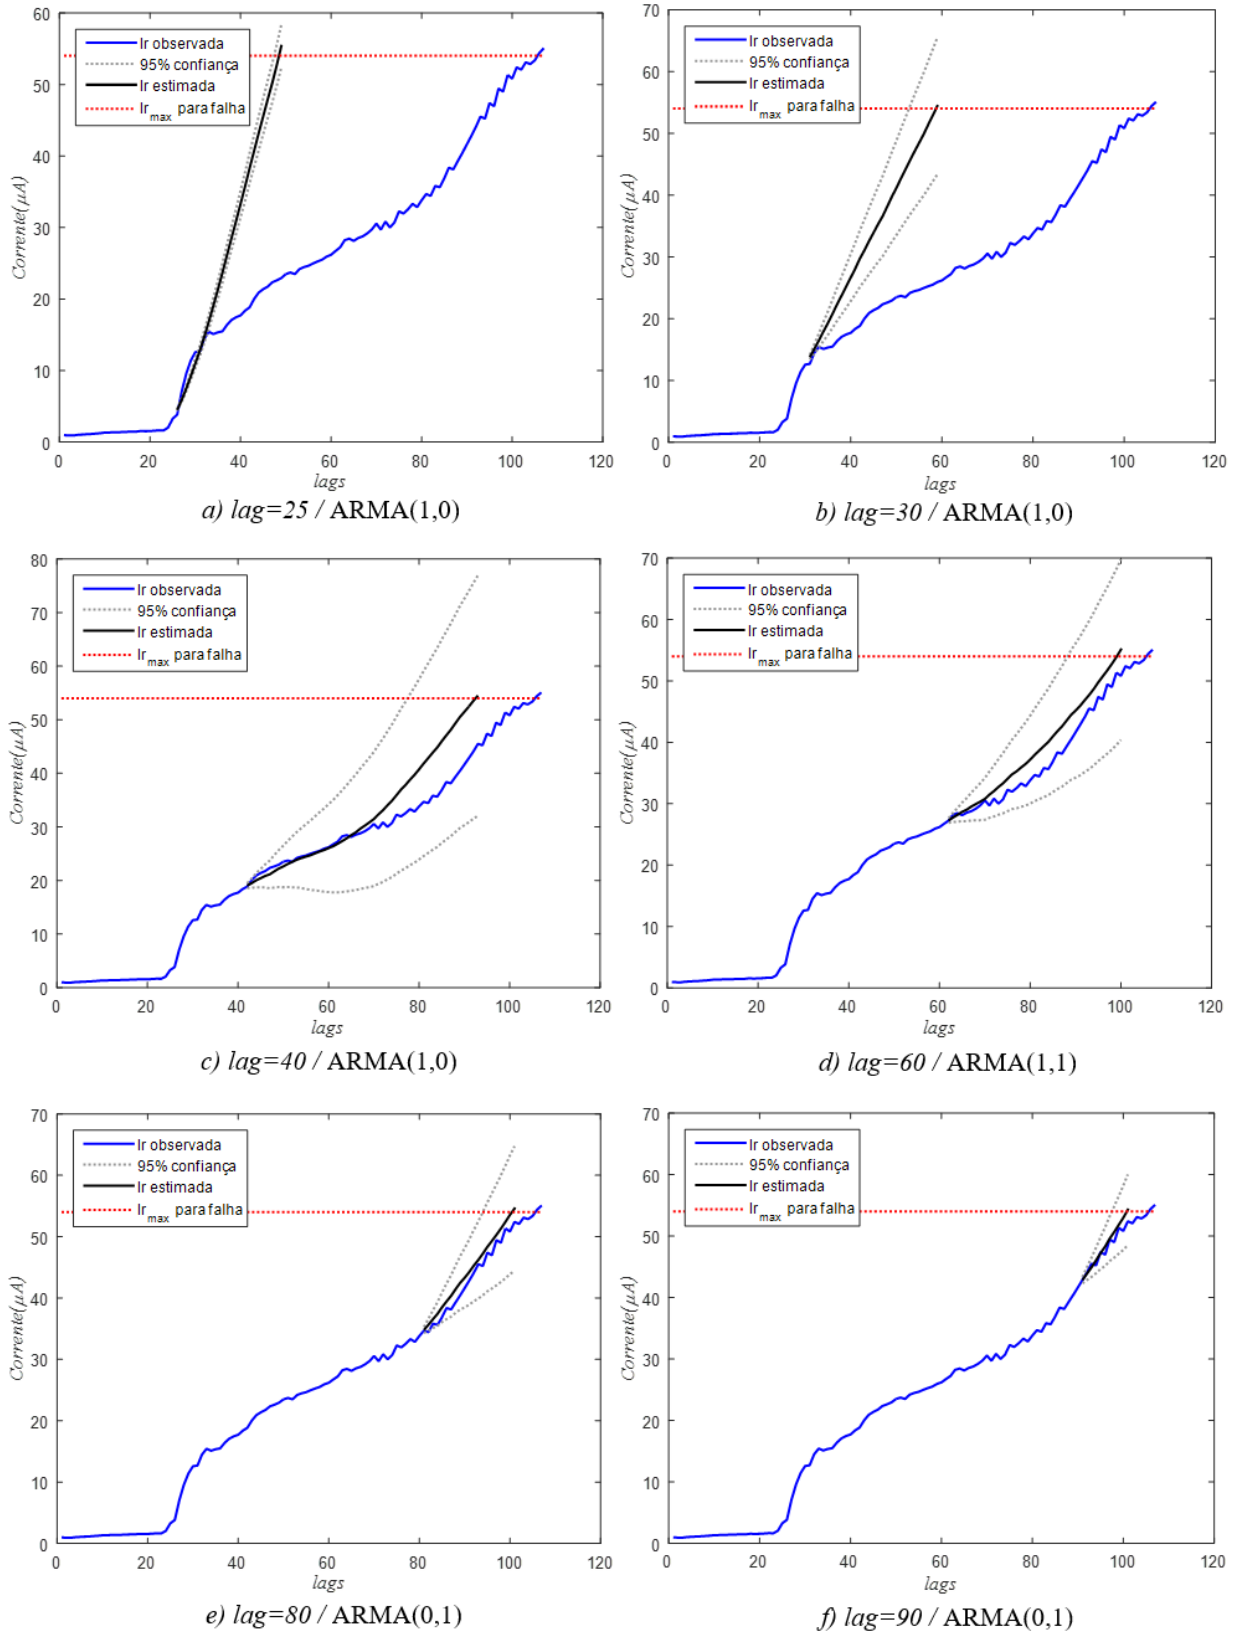


Figura 6.16 – Gráficos de previsão do modelo ARMA para a série de corrente  $I_R$  até a falha do isolamento do motor submetido à contaminação por óleo.

### 6.3 Modelo RNA para Previsão do $TF$

Devido a sua capacidade de aproximar funções lineares e não lineares multivariáveis, mapeando essas relações mesmo que desconhecidas, um modelo baseado em Redes Neurais Artificiais (RNAs) é proposto para estimar a corrente resistiva ( $I_R$ ) e prever o Tempo de Falha ( $TF$ ) do isolamento. Acredita-se que a capacidade de generalização e aprendizado das RNAs apresenta-se como uma ferramenta mais geral e flexível para a previsão de séries temporais.

Um dos desafios da elaboração de uma RNA aplicada à modelagem de séries temporais é a definição do tipo da rede e sua arquitetura (número de entradas, número de camadas escondidas, número de neurônios da camada escondida e número de saídas). Devido à sua ampla aplicação e bons resultados onde empregada, será utilizado neste trabalho a RNA MLP (*Multilayer Perceptron*) [65, 66, 102, 103].

A definição do número de entradas de uma RNA pode ser obtida pela avaliação dos correlogramas das funções FAC e FACP das séries observadas [102, 103]. Conforme visto nos correlogramas das Figuras 6.4, 6.5 e 6.6, as séries de corrente  $I_R$  apresentam graus de dependência elevados com os dados passados, remetendo a um número elevado de entradas para a RNA. Para os correlogramas dos motores submetidos a falha por estresse térmico e absorção de umidade, o grau de dependência é de aproximadamente 6 *lags* (correlogramas das Figuras 6.4 e 6.5). Entretanto, para o motor cuja falha no isolamento foi devido à contaminação por óleo, o grau de dependência leva a construção de uma RNA com aproximadamente 20 entradas (correlograma da Figura 6.6). Assim, o projeto de uma RNA a partir dos dados originais das séries de correntes  $I_R$  torna-se um problema complexo, cuja definição do número mínimo de entradas passa a ser mais uma variável para a identificação de um modelo único e genérico que modele as séries.

A abordagem adotada para a identificação do número de entradas da RNA é semelhante a empregada no modelo ARMA. Na seção anterior, a estacionariedade das séries de corrente  $I_R$  foram obtidas através da filtragem de médias móveis bilateral com a posterior subtração entre os dados observados e filtrados. Os correlogramas das funções FAC transformadas ( $z_t$ ) apresentados nas Figuras 6.10-a, 6.11-a e 6.12-a, mostram picos nas funções de autocorrelação no  $lag = 1$  para todas as séries transformadas  $z_t$ . Assim, a RNA será definida com uma entrada, que receberá o valor de  $z_{t-1}$ .

O Teorema da Aproximação Universal afirma que uma RNA MLP com apenas uma camada escondida é capaz de realizar o mapeamento de uma função não linear a partir de um conjunto de pares de observações entrada-saída [66]. Assim a arquitetura da RNA escolhida apresentará apenas uma camada escondida.

Numa abordagem clássica, o número de saídas de uma RNA aplicada a previsão de séries temporais pode ser definida conforme o horizonte de previsão. Por exemplo, caso

se deseje a previsão dois passos a frente, o número de saídas para a RNA será igual a dois ( $x_{t+1}$  e  $x_{t+2}$ ). Outra abordagem bastante utilizada, sobretudo para problemas de previsão a longo prazo, é a definição de uma única saída para a RNA ( $x_{t+1}$ ). Neste contexto, a previsão do próximo passo ( $x_{t+2}$ ) será realizada utilizando o valor da previsão anterior  $x_{t+1}$  como entrada para o cálculo desta nova previsão ( $x_{t+2}$ ). Esse processo de realimentação das novas previsões continua até que se alcance o horizonte de previsão desejado [109]. Neste trabalho, optou-se pela segunda abordagem, com apenas uma saída, visto que a previsão para o TF do isolamento é um problema de longo prazo.

Nas simulações realizadas, para que a RNA fosse capaz de modelar os dados observados das séries de corrente  $I_R$ , foi necessário mudar o número de neurônios da camada escondida. A princípio, não se encontrou uma RNA com número fixo de neurônios na camada escondida que fosse capaz de modelar todas as 3 séries. Assim, o número de neurônios dessa camada é definido de forma dinâmica, semelhante ao processo utilizado para a identificação do modelo ARMA( $p, q$ ). Nessas simulações foram testadas arquiteturas de RNAs com 2 a 10 neurônios na camada escondida. A seleção de qual arquitetura, dentre as 9 possíveis, foi feita a partir da avaliação do RMSE para a série estimada  $\hat{x}_t$  utilizando os dados de validação  $x_t$ . A RNA escolhida foi aquela que apresentou o menor valor de RMSE.

O processo de treinamento, validação e escolha da RNA para a previsão do TF é descrito a seguir:

- 1 - as nove RNAs são submetidas a 20 treinos para os  $m$  dados de treinamento. São escolhidas as redes que apresentarem os menores valores de RMSE para a série transformada  $z_t$ ;

$$RMSE_{treinamento} = \sqrt{\frac{1}{m} \sum_{t=1}^m (\hat{z}_t - z_t)^2} \quad (6.24)$$

- 2 - as 9 redes selecionadas na etapa 1 são testadas para os  $f$  dados de validação. O valor do RMSE é computado para cada RNA:

$$RMSE_{validação} = \sqrt{\frac{1}{f} \sum_{t=1}^f (\hat{x}_t - x_t)^2} \quad (6.25)$$

$$f = h - m \quad (6.26)$$

- 3 - a rede que apresentar o menor valor de RMSE dentre as 9 RNAs é selecionada para estimar as correntes  $I_R$  e prever o TF do isolamento.

A saída estimada para a validação ou para previsão um passo a frente  $\hat{x}_{t+1}$  é computada por:

$$\hat{x}_{t+1} = 2x_t - x_{t-1} - 3\hat{z}_t \quad (6.27)$$

Onde:

- $\hat{z}_t$ : representa a saída estimada pela RNA selecionada.

Os dados observados da corrente  $I_R$  até o  $lag = h$  são transformados ( $z_t$ ) e particionados em 2 conjuntos. Um conjunto para o treinamento das RNAs que corresponde a 60% dos dados, e outro conjunto para a validação que abrange os demais 40% dos dados. Entretanto, para maior eficácia no processo de aprendizagem da rede, as partições não são feitas de forma linear, são utilizadas faixas intercaladas entre os conjuntos de treinamento e validação. A Figura 6.17 mostra um exemplo de como foi realizado o particionamento dos dados observados para o treinamento e validação das RNAs. O algoritmo de aprendizado utilizado foi o *Resilient Backpropagation* (RPROP) [90].




Figura 6.17 – Exemplo de partição dos dados da série transformada nos conjuntos de treinamento e validação para as RNAs.

Com o objetivo de se evitar problemas computacionais e facilitar o processo de aprendizagem das RNAs, os dados transformados ( $z_t$ ) até o  $lag = h$  das séries de correntes  $I_R$  foram normalizados [66]. O intervalo de normalização utilizado foi de  $[-1, 1]$  dada pela transformação linear:

$$z_n = \frac{2(z_t - z_{min})}{z_{max} - z_{min}} - 1 \quad (6.28)$$

A Figura 6.18 mostra o fluxograma que resume os processos descritos anteriormente para a seleção da RNA que será utilizada para estimar as correntes  $I_R$  e prever o  $TF$  do isolamento.

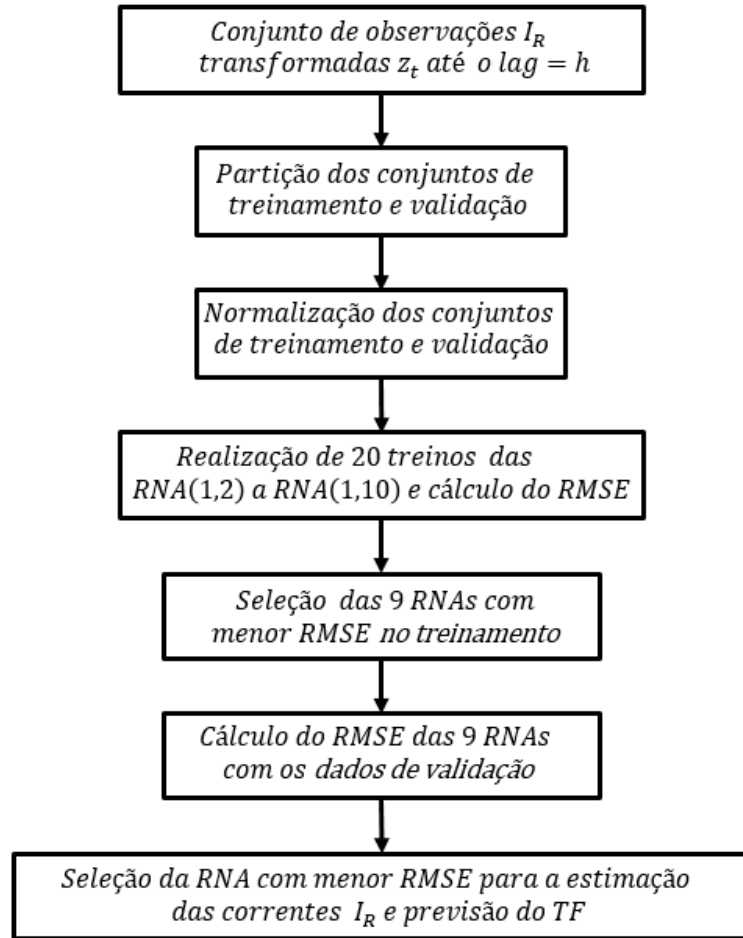


Figura 6.18 – Fluxograma para a seleção da RNA a ser utilizada para estimar as correntes  $I_R$  e prever o  $TF$  do isolamento.

A Figura 6.19 apresenta o diagrama de blocos do preditor utilizando RNAs. No diagrama é apresentada a RNA, o filtro de Média Móveis Bilateral (MMB) para a transformação da série e a implementação da equação (6.27) para a previsão um passo a frente  $\hat{x}_{t+1}$ . Como justificado anteriormente, a RNA possui uma entrada ( $z_{t-1}$ ), uma camada de saída ( $\hat{z}_t$ ), e o número de neurônios da camada escondida é determinado de forma dinâmica a partir do critério de mínimo RMSE descrito anteriormente. Na camada de saída da RNA foi utilizada uma função linear, correspondente ao somatório das combinações lineares das saídas dos neurônios da camada escondida. Na camada escondida foi utilizada a função sigmoide  $\tanh$ . A previsão de mais passos a frente é realizada a partir da realimentação de  $\hat{x}_{t+1}$  na entrada do preditor, o qual é cessado quando a corrente alcança o valor  $54\mu A$ .

As Figuras 6.20, 6.21 e 6.22 apresentam os resultados das previsões para as séries de correntes  $I_R$ . Para facilitar a comparação entre as respostas dos modelos ARMA e RNA, as figuras mostram os resultados das previsões das correntes estimadas  $\hat{I}_R$  para os mesmos lags utilizados nos modelos ARMA. Ainda, para os modelos neurais, os resultados das previsões também serão avaliados a partir do  $lag = 25$ , no qual se inicia a convergência dos modelos para as séries originais.

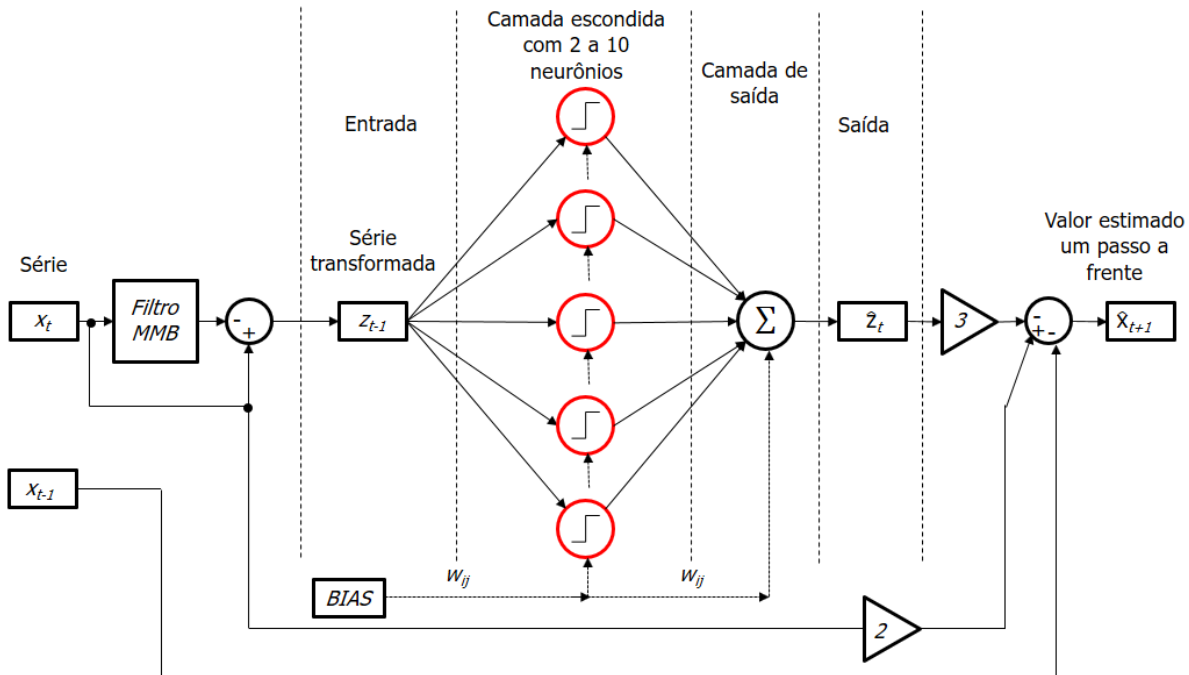


Figura 6.19 – Diagrama de blocos do preditor utilizando RNAs.

A Figura 6.20 mostra os gráficos da corrente estimada  $\hat{I}_R$  para o motor submetido a estresse térmico no isolamento em diferentes *lags*. Estão indicados nos gráficos o respectivo modelo RNA (entradas, neurônios camada oculta) selecionado para o ajuste dos dados observados e o intervalo de confiança para cada previsão. A corrente estimada  $\hat{I}_R$  apresenta erros bem menores para *lags* < 40 quando comparado ao modelo ARMA. Para *lags* > 40, a série estimada praticamente converge para a série original, viabilizando seu emprego para a previsão do tempo de falha do isolamento.

A Figura 6.21 mostra os gráficos da corrente estimada  $\hat{I}_R$  para o motor submetido à absorção de umidade pelo isolamento em diferentes *lags*. Nos gráficos estão indicados o respectivo modelo RNA (entradas, neurônios camada oculta) selecionado para o ajuste dos dados observados e o intervalo de confiança para cada previsão. Nota-se que o modelo neural apresenta menores erros de estimação da corrente  $\hat{I}_R$  quando comparado ao modelo ARMA para *lags* < 60. Para *lags* > 60, quando ocorre a rápida elevação exponencial dos dados observados, o modelo neural apresenta melhores ajustes à série original. Isso pode ser explicado pelo fato da RNA conseguir modelar essa não linearidade melhor que o modelo ARMA.

A Figura 6.22 mostra os gráficos da corrente estimada  $\hat{I}_R$  para o motor submetido à contaminação por óleo no isolamento em diferentes *lags*. Nos gráficos estão indicados o respectivo modelo RNA (entradas, neurônios camada oculta) selecionado para o ajuste dos dados observados e o intervalo de confiança para cada previsão. Assim como no modelo ARMA, o modelo neural praticamente converge para os valores observados da série para *lags* > 40, mas com menores erros de previsão para o *TF* do isolamento.

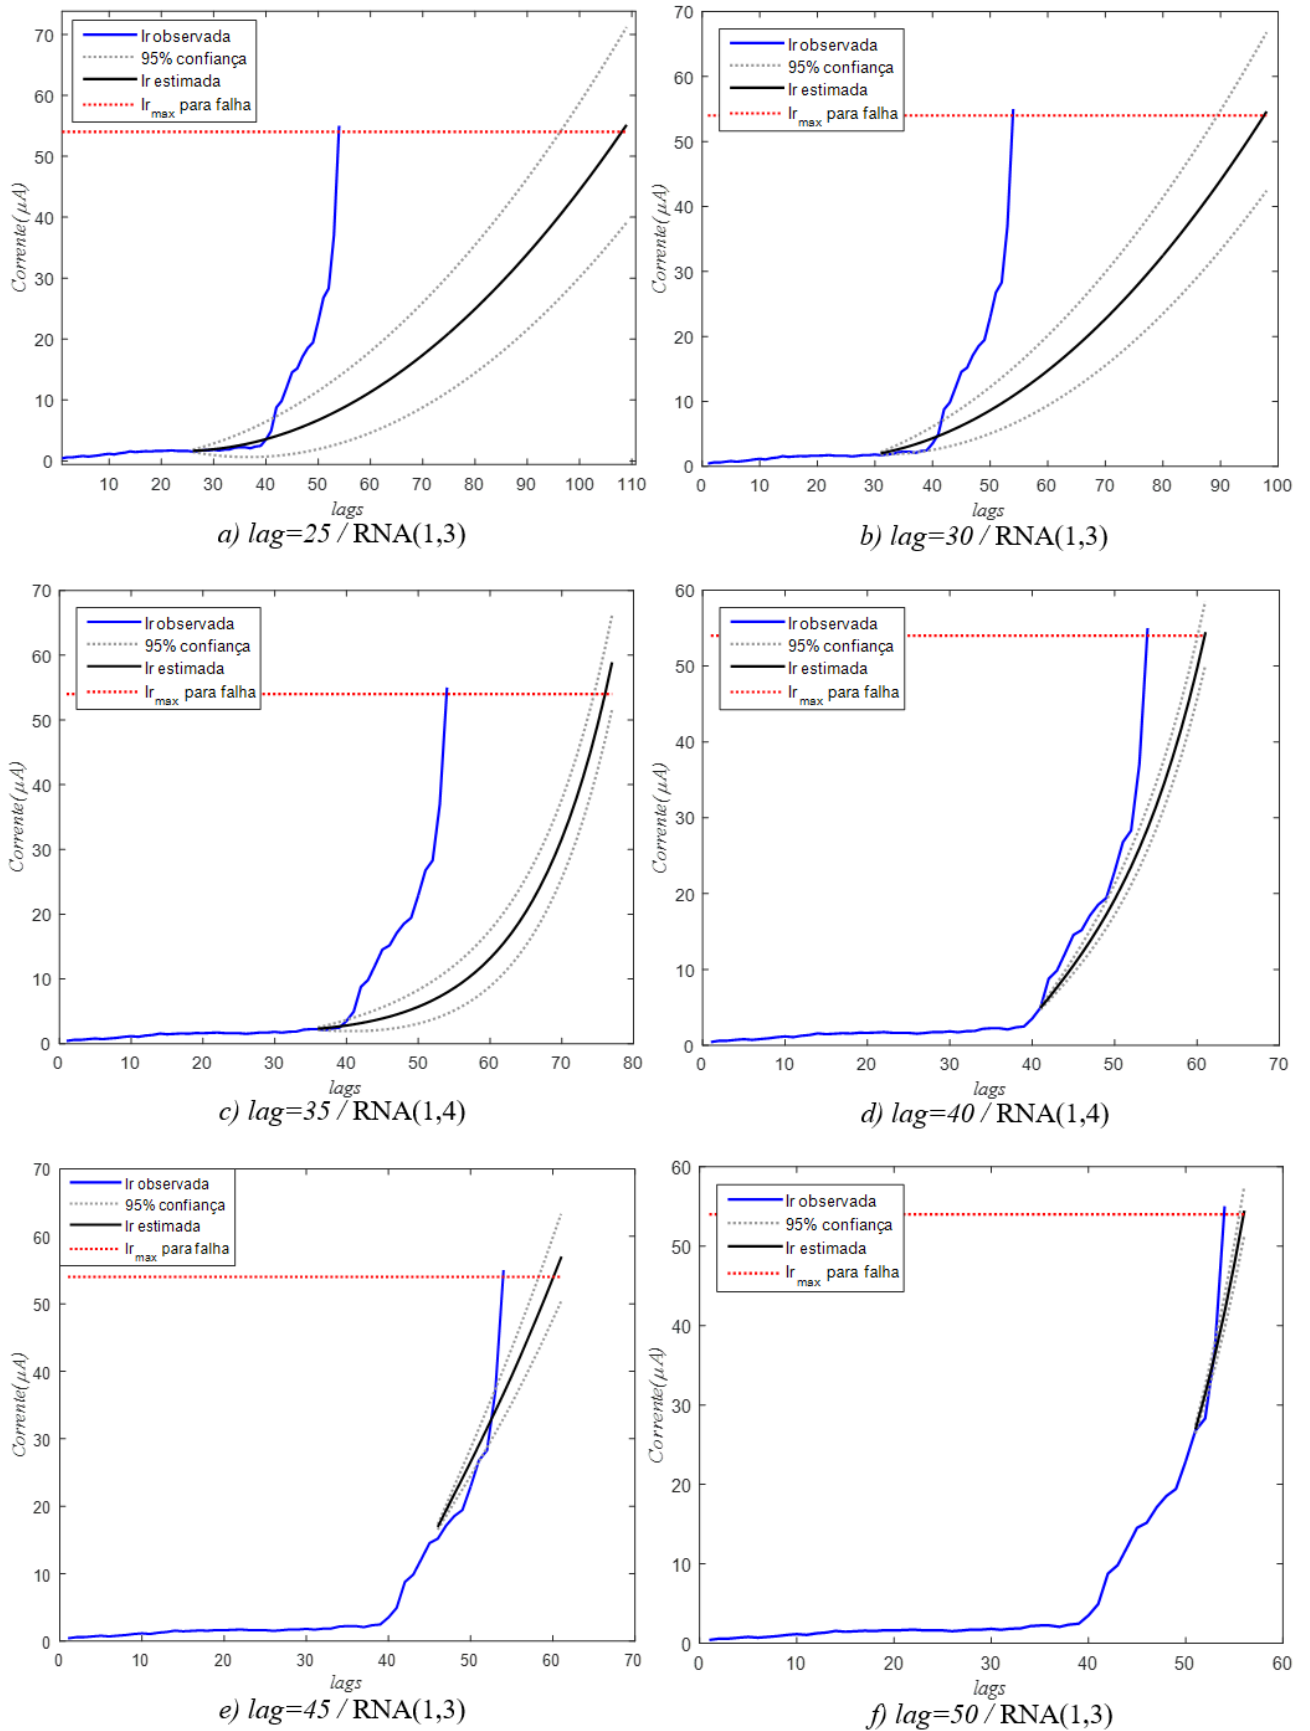


Figura 6.20 – Gráficos de previsão do modelo RNA para a série de corrente  $I_R$  até a falha do isolamento do motor submetido ao estresse térmico.

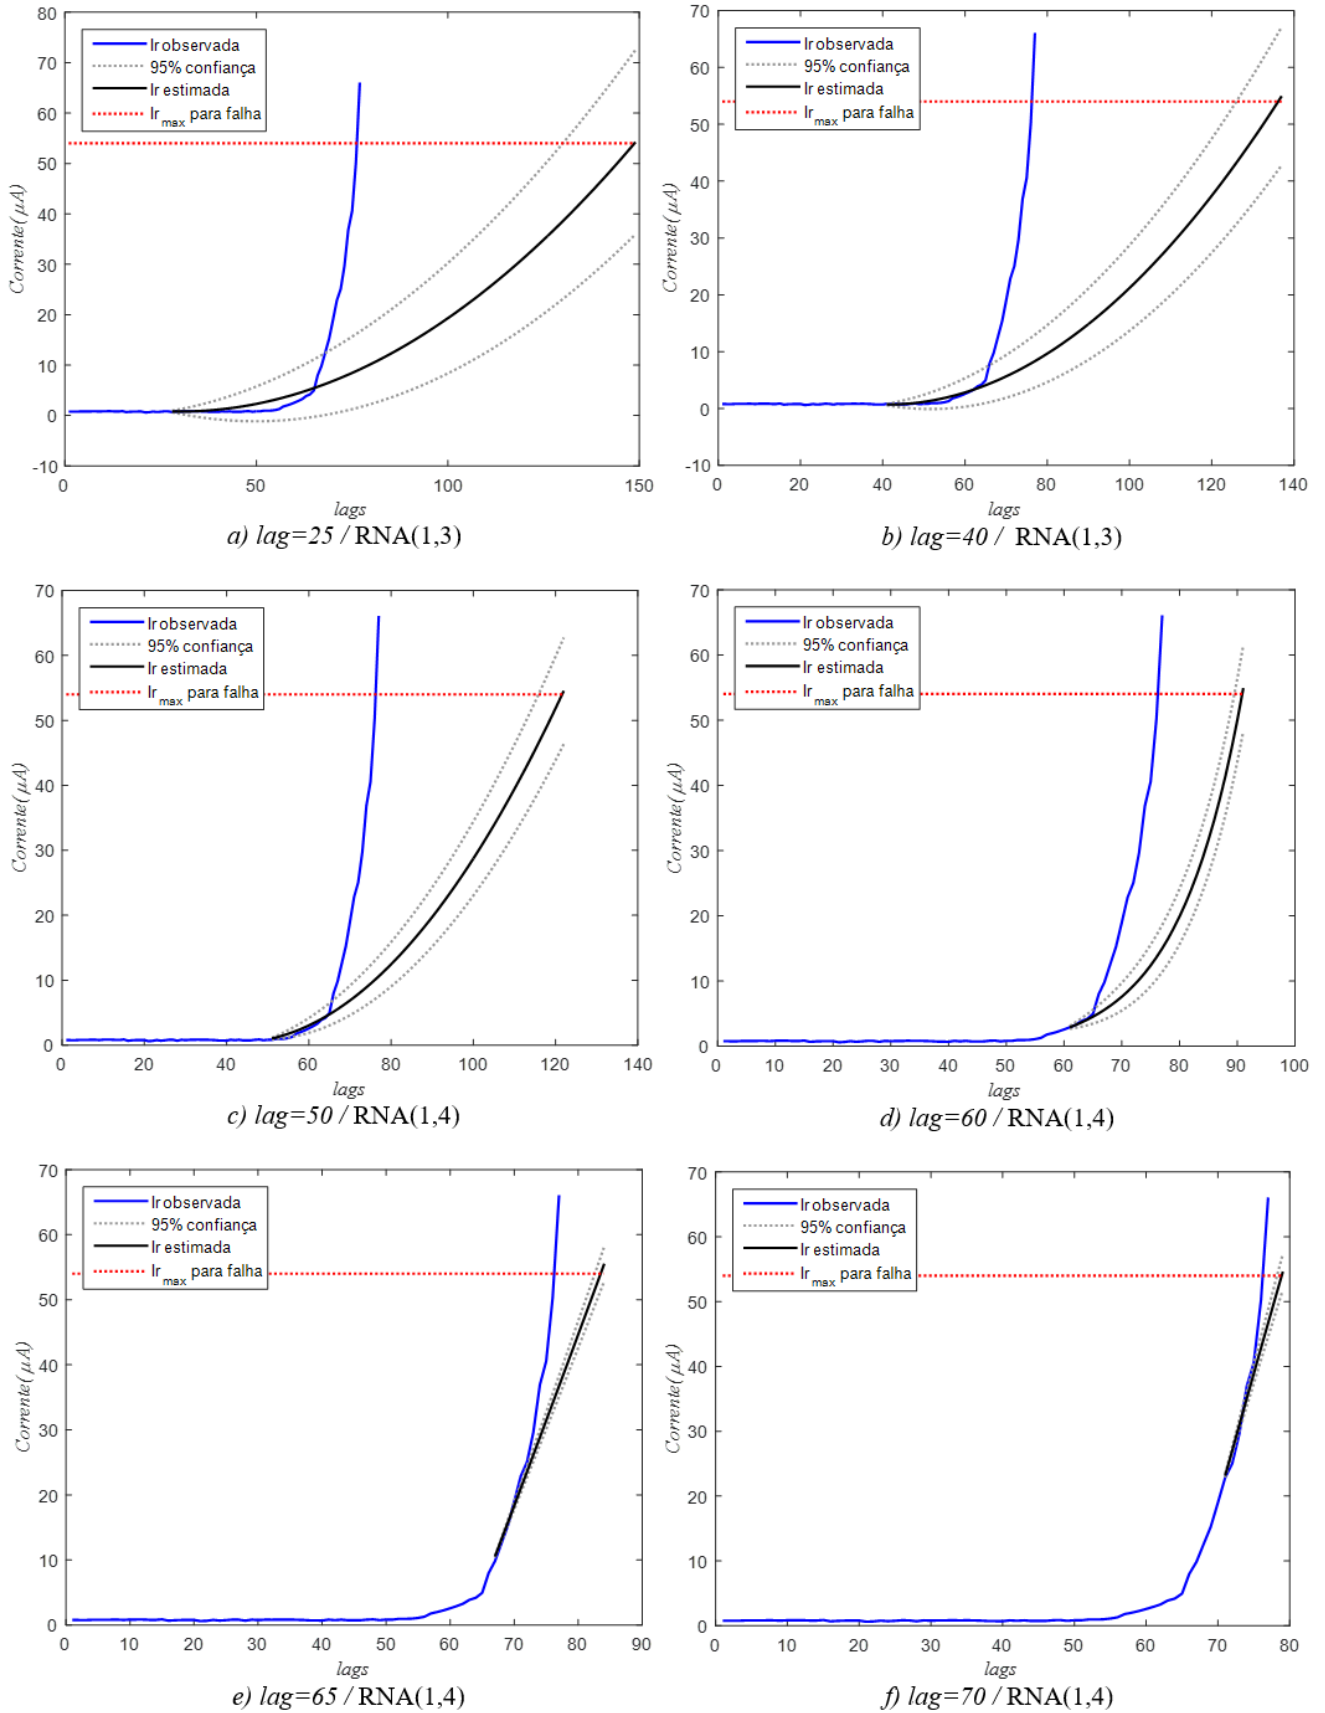


Figura 6.21 – Gráficos de previsão do modelo RNA para a série de corrente  $I_R$  até a falha do isolamento do motor submetido à absorção de umidade.

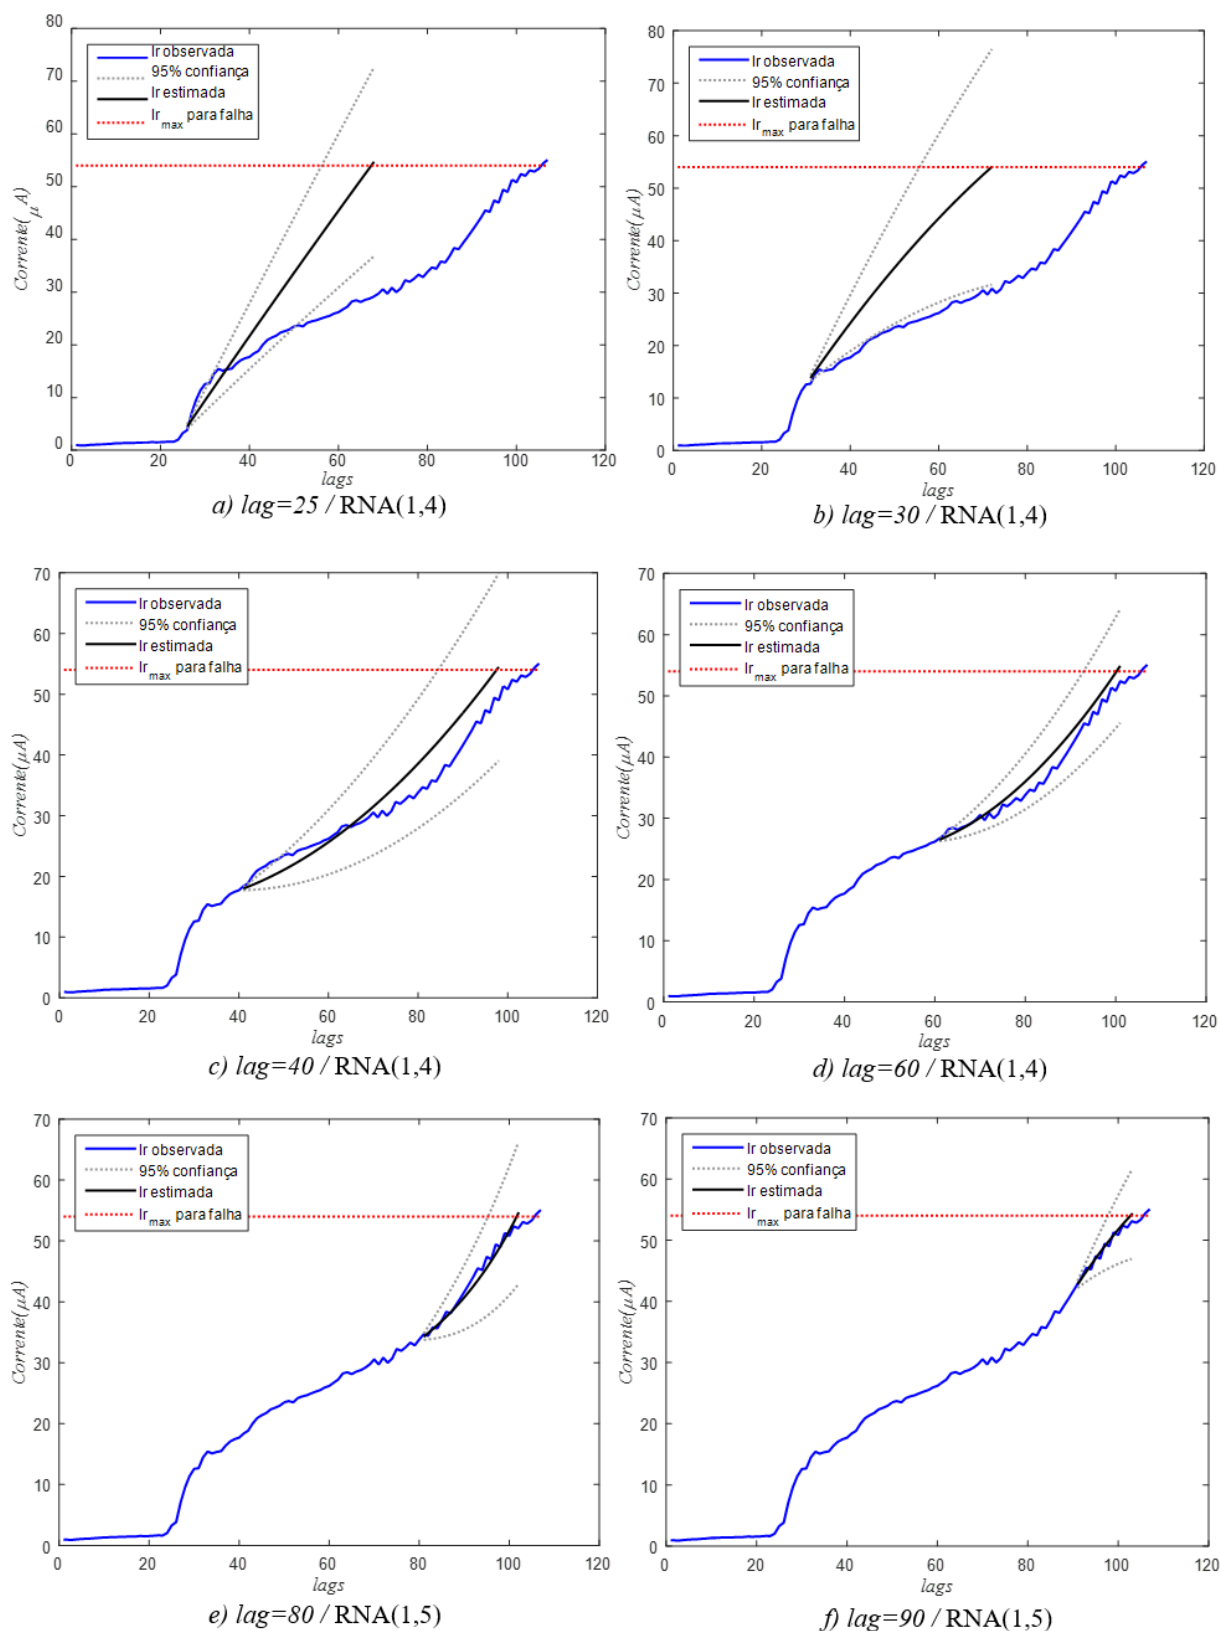


Figura 6.22 – Gráficos de previsão do modelo RNA para a série de corrente  $I_R$  até a falha do isolamento do motor submetido à contaminação por óleo.

## 6.4 Avaliação dos Resultados de Previsão dos Modelos

Os modelos propostos para a previsão do Tempo de Falha ( $TF$ ) devem assegurar que as correntes estimadas  $\hat{I}_R$  e o próprio  $TF$  em si, convirjam para os dados observados. Modelos que no início da série apresentam boa aproximação em relação aos dados observados, mas que divergem para as observações finais, podem apresentar baixo RMSE, porém altos valores para o  $TF$ .

Com o objetivo de realizar uma melhor avaliação dos modelos apresentados, as séries são avaliadas sob o ponto de vista do erro da corrente resistiva estimada  $\hat{I}_R$  através do RMSE, e do Erro de Previsão do Tempo de Falha (EPTF), vistos na Seção 6.1.

Os gráficos das Figuras 6.23, 6.24 e 6.25 mostram o RMSE para as séries das correntes estimadas  $\hat{I}_R$  e o EPTF associado as previsões. Como esperado, os modelos baseados em RNAs apresentaram menores RMSE e EPTF para os 3 cenários de falha.

Para as falhas no isolamento geradas pelo estresse térmico e absorção de umidade, que apresentam características exponenciais fortes, o erro de previsão EPTF foi reduzido significativamente com o uso do modelo neural (gráficos das Figuras 6.23-b e 6.24-b). Isso pode ser explicado pelo fato dos modelos neurais terem a capacidade de conseguir modelar a relação não linear presente nessas séries.

Para a falha do isolamento ocasionada pela contaminação por óleo, os modelos ARMA e RNA apresentaram bons desempenhos, mas o modelo RNA ainda mostra-se como uma melhor opção para a modelagem dessa série.

De forma geral, nota-se que os modelos neurais apresentam os melhores resultados, sendo preferidos para se incorporarem ao SIMOI no prognóstico do tempo de falha do isolamento.




Figura 6.23 – RMSE e EPTF dos modelos ARMA e RNA para o motor submetido a falha no isolamento devido ao estresse térmico.




Figura 6.24 – RMSE e EPTF dos modelos ARMA e RNA para o motor submetido a falha no isolamento devido à absorção de umidade.




Figura 6.25 – RMSE e EPTF dos modelos ARMA e RNA para o motor submetido a falha no isolamento devido à contaminação por óleo.

## 6.5 Conclusões

Esse capítulo apresentou os fundamentos para a análise e a elaboração de modelos de séries temporais para a previsão do Tempo de Falha ( $TF$ ) do isolamento de MITs de BT e MT. Foram apresentadas duas propostas de preditores para estimar o  $TF$ , uma abordando a metodologia clássica ARMA e a outra empregando RNAs. As medições das correntes  $I_R$  dos testes experimentais obtidas com o SIMOI foram utilizadas para a construção dos modelos propostos.

Assim, os modelos propostos para a previsão do  $TF$  demonstraram que é possível, dentro de um certo grau de incerteza, determinar o instante provável para a falha do isolamento. Os dois modelos desenvolvidos, ARMA e RNA, apresentaram-se generalistas

para prever o  $TF$  independente do fator de estresse que está degradando o isolamento. No comparativo entre os modelos, nota-se que o modelo baseado em RNAs apresenta menores erros para estimar a corrente  $I_R$  e prever o  $TF$ , sendo esse modelo o preferido para se integrar ao SIMOI.

Durante o desenvolvimento dos preditores, observou-se que a construção de modelos para a previsão do  $TF$  do isolamento é um grande desafio. A ação dos fatores de estresse modifica as correntes que circulam no isolamento, o que altera a função que gera a corrente  $I_R$  e dificulta a construção dos modelos. Apesar dos bons resultados alcançados com os modelos propostos, é necessário a realização de mais testes experimentais e, sobretudo, a coleta de dados de campo para a validação desses modelos.

Neste contexto, entende-se que a partir desses testes de campo, outros aspectos relevantes não citados ou ainda não conhecidos se apresentaram como novos desafios para a continuidade e aperfeiçoamento dos modelos apresentados.

## 7 Conclusões e Propostas de Continuidade

NESTE capítulo serão apresentadas as conclusões e propostas de continuidade para a pesquisa. São abordados os resultados mais relevantes, bem como as contribuições alcançadas até o momento. Também, são elencadas as propostas de continuidade para o desenvolvimento de trabalhos futuros.

### 7.1 Conclusões

Este trabalho apresentou um estudo e a proposição de técnicas para a avaliação do isolamento de MITs de BT e MT. Um levantamento feito na refinaria REDUC-Petrobras, bem como, referências relevantes sobre o tema mostram que o maior percentual de falhas elétricas em MITs é a baixa resistência do isolamento do estator para a carcaça. A revisão bibliográfica sobre o tema aponta que as ferramentas preditivas *on-line* para a avaliação do estado do isolamento estão concentradas na ADP para MITs de AT. As ferramentas de diagnósticos em MITs de BT e MT são, em sua maioria, aplicadas somente na parada do equipamento (*off-line*), onde os critérios para a determinação dos fatores de estresse que levam à degradação do isolamento não são identificados. Assim, esta pesquisa trouxe as seguintes contribuições acerca do tema:

- utilização do Perfil da Resistência de Isolamento (PRI) para o agrupamento e a identificação dos fatores de estresse que degradam o isolamento em MITs de BT e MT;
- desenvolvimento de classificadores *off-line* baseados em RNAs para a identificação do fator de estresse e a avaliação da condição de operação do motor. O classificador baseado na medição da  $R_I$ , do  $IP$  e do  $IA$  pode ser empregado por qualquer setor de manutenção elétrica que disponha de um megôhmetro;
- desenvolvimento de um modelo no domínio do tempo em c.c. e c.a. para o entendimento dos fatores de estresse que levam a degradação do isolamento, considerando a sua influência na resistência e na capacitância do isolamento;
- desenvolvimento de uma promissora metodologia *on-line* para a medição e a decomposição das correntes capacitivas e resistivas do isolamento baseada na corrente  $I_0$ ;
- desenvolvimento de um sistema de medição de corrente de fuga *on-line* do isolamento com aplicação de um sistema de Supressão Ativa de Ruído (SAR). O emprego do

sistema de SAR possibilitou que sistema alcançasse sensibilidade para a medição de correntes da ordem de  $1\mu A$ ;

- desenvolvimento de um classificador *on-line* baseado em RNA, que a partir da variação em  $pu$  da  $R_{eq}$ , da  $C_{eq}$  e do  $FD_{eq}$  permite identificar o fator de estresse que acarreta a degradação do isolamento.
- proposição de um modelo baseado em RNAs para a previsão do tempo de falha do isolamento;
- proposição de um sistema completo para o monitoramento *on-line* do isolamento de MITs de BT e MT, o “SIMOI”.

A respeito da avaliação *on-line* do isolamento para MITs de BT e MT, este trabalho mostrou o desenvolvimento teórico da técnica baseada na medição da corrente de sequência zero  $\dot{I}_0$ . A proposta apresenta as seguintes vantagens em relação a outras técnicas:

- sem restrição de aplicação, podendo ser empregado em MITs de BT e MT com 6 ou 3 terminais de ligação;
- facilidade e rapidez de instalação em motores novos ou em operação;
- baixo custo de instalação, dispensando qualquer gasto adicional com montagem e infra-estrutura (passagem de cabos, eletrodutos, modificação de gavetas, etc).

O trabalho mostra o desenvolvimento experimental do sistema de medição *on-line* para a detecção de correntes de fuga da ordem de  $1\mu A$  com o emprego de um sistema de Supressão Ativa de Ruído (SAR). O sistema de medição é fundamental para determinar as parcelas de corrente resistiva e capacitiva para avaliar o estado do isolamento. As medições apresentam erros menores que  $\pm 2,5\%$ , mostrando-se adequado para o monitoramento do isolamento de motores de BT e de MT.

A proposta do Sistema de Monitoramento *On-Line* para o Isolamento de MITs de BT e MT “SIMOI” apresenta-se como uma solução completa para o monitoramento preditivo do estado do isolamento. A proteção preditiva do SIMOI apresenta sensibilidade suficiente para proteger o isolamento da circulação de correntes elevadas de fuga para terra, evitando a falha catastrófica do motor.

Comparando-se os testes *off-line* e *on-line*, os resultados experimentais demonstram a eficácia do SIMOI para detectar o fator de estresse e realizar o acompanhamento preditivo. O diagnóstico de alarme do SIMOI é mais conservador, indicando falha no isolamento antes do diagnóstico *off-line*. Esse fato, permite aos gestores da manutenção um planejamento adequado para a parada e manutenção do motor.

Por fim, os modelos de previsão para o Tempo de Falha ( $TF$ ) se mostrou adequado para o prognóstico da falha do isolamento. Os dois modelos desenvolvidos, ARMA e RNA, são generalistas para estimar a corrente resistiva ( $I_R$ ) e indicar o provável  $TF$ , independente do fator de estresse que está degradando o isolamento. Entretanto, como esperado, o modelo neural apresentou menores erros de estimação para a corrente  $I_R$  e previsão para o  $TF$ , sendo esse o modelo preferido para se incorporar ao SIMOI.

## 7.2 Propostas de Continuidade

Como propostas para a continuidade da pesquisa, propõem-se:

- projeto e montagem do *hardware* eletrônico do SIMOI. O objetivo é a construção de um dispositivo que possa ser instalado dentro de gavetas de MITs de BT e MT;
- desenvolvimento de *software* do SIMOI. Esta proposta tem como finalidade a construção da *interface* gráfica e do banco de dados para a monitoração do diagnóstico de MITs de BT e MT numa planta industrial;
- revisão e aperfeiçoamento do modelo de previsão do tempo de falha do isolamento. Nessa proposta pretende-se aumentar a acurácia da previsão do tempo de falha a partir dos dados de campo do SIMOI.
- estudo e proposição de modelos do isolamento baseado na física da falha. Com esta proposta pretende-se construir modelos físicos que consigam auxiliar e validar os modelos estocásticos apresentados.
- estudo e proposição para a aplicação do SIMOI no diagnóstico de falhas no isolamento de MITs de BT e MT alimentados por conversores de frequência;
- estudo e proposição para a aplicação do SIMOI no diagnóstico de falhas no isolamento de MITs e MS (Máquinas Síncronas) de AT.



## Referências

- [1] P. Pieters and J. Rikomem, *Reliability of Adjustable Speed Drives: Applications of Drives in the Chemical Industry*, IEEE Industry Applications Magazine, vol. 16, (2010) 47–55. doi:{10.1109/MIAS.2010.938401}.
- [2] A. S. Guedes, *Avaliação da Eficiência Energética no Controle de Vazão Utilizando Conversores de Frequência*, Monografia, Universidade Petrobras - UP, Julho, 2011.
- [3] R. K. Mobley, *Maintenance Engineering Handbook*, 8th Edition, McGraw-Hill, 2014.
- [4] *IEEE Gold Book 493: Recommended Practice for the Design of Reliable Industrial and Commercial Power Systems*, 3th Edition, IEEE, 2007.
- [5] L. R. C. Souza, *Reduzindo as Quebras Através da Manutenção Profissional*, acessado em: 16/05/2016.  
URL <http://www.abraman.org.br/arquivos/125/125.pdf>
- [6] L. F. Gonçalves and O. L. D. Vescovi and K. Kattermann and J. C. K. Serrano, *Maximizando a Disponibilidade dos Ativos Através da Integração de Técnicas Preditivas e Variáveis de Processo*, acessado em: 20/03/2016.  
URL <http://www.abraman.org.br/arquivos/102/102.pdf>
- [7] M. Belinelli and L. Pilatti and A. C. Frasson, *A Manutenção Produtiva Total (TPM) como Ferramenta para Aumento de Disponibilidade de Máquina: Estudo de Caso em uma Indústria do Ramo Siderúrgico*, XVI SIMPEP Simpósio de Engenharia de Produção, (2009) 1–12.
- [8] R. A. Wuttke, M. A. Sellito, *Cálculo da Disponibilidade da Posição na Curva da Banheira de uma Válvula de Processo Petroquímico*, Revista Produção On-Line, vol.3/num.4, (2008) 1–23.
- [9] P. V. Fleming, M. F. Silva, S. R. O. França, *Aplicando a Manutenção Centrada em Confiabilidade (MCC) em Indústrias Brasileiras: Lições Aprendidas*, XIX ENGEPE Encontro de Engenharia de Produção, (1999) 1–17.
- [10] A. G. P. Garcia, *Impacto da Lei de Eficiência Energética para Motores Elétricos no Potencial de Conservação de Energia na Indústria*, Dissertação, Universidade Federal do Rio de Janeiro - UFRJ, Dezembro, 2003.
- [11] *Handbook to Assess the Insulation Condition of Large Rotating Machines*, 16th Edition, EPRI, 1989.

- [12] S. B. Lee, J. Yang, K. Younsi, R. Bharadwaj, *An On-line Groundwall and Phase to Phase Insulation Quality Assessment Technique for AC Machine Stator Windings*, IEEE Transactions on Industry Applications, vol. 42, (2006) 946–957. doi:10.1109/TIA.2006.876077.
- [13] *IEEE Standard 43: Recommended Practice for Testing Insulation Resistance of Electric Machinery*, 2nd Edition, IEEE, 2013.
- [14] *NFPA 70B: Recommended Practice for Electrical Equipment Maintenance*, 1st Edition, NFPA, 2013.
- [15] L. M. C. P. Filho, J. N. Brito, A. L. Christoforo, *Acompanhamento Preditivo de Motores de Indução Trifásicos através da Análise de Fluxo Magnético*, Revista Ciência e Tecnologia FATEC-JB, vol.4/num.1, (2012) 1–15.
- [16] C. Costa, M. H. Mathias, *Instrumento de Análise e Diagnóstico em Máquinas Rotativas de Indução*, Revista Sinergia, vol.12/num.2, (2011) 181–189.
- [17] C. G. Dias, *Proposta de um Novo Método para Detecção de Barras Rompidas em Motores de Indução com Rotor em Gaiola*, Tese, Universidade de São Paulo - USP, Novembro, 2006.
- [18] L. M. R. Baccarini, *Detecção e Diagnóstico de Falhas em Motores de Indução*, Tese, Universidade Federal de Minas - UFMG, Junho, 2005.
- [19] V. Warren, *Partial Discharge Testing on Air-Cooled Generators in Marine Environments*, IEEE Electrical Insulation Conference, (2013) 323–328. doi:10.1109/EIC.2013.6554259.
- [20] F. Guastavino, A. Rato, A. Dardano, E. Torelo, G. Biondi, G. Lodi, A. Ceci, *Comparison Among the PD Resistance Behavior of Different Enameled Wires When Subjected to PWM Voltage*, IEEE Electrical Insulation and Dielectric Phenomena Conference (CEIDP), (2011) 314–317. doi:10.1109/CEIDP.2011.6232659.
- [21] S. U. I. Haq, M. K. W. Stranges, A. O. Vouk, *Monitor Stator Insulation in Critical Motors: Choosing Diagnostic Tests*, IEEE Industry Applications Magazine, 20, (2014) 50–55. doi:10.1109/MIAS.2013.2282566.
- [22] *IEEE Standard 1434: Guide for the Measurement of Partial Discharges in AC Electric Machinery*, 2nd Edition, IEEE, 2014.
- [23] *IEC-60270: High-Voltage Test Techniques - Partial Discharge Measurements*, 3rd Edition, IEC, 2000-12.

- [24] S. Tetrault, G. C., H. G. Sedding, *Monitoring Partial Discharges on 4kV Motor Windings*, IEEE Petroleum and Chemical Industry Conference (PCIC), (1997) 159–165. doi:10.1109/PCICON.1997.648179.
- [25] S. B. Lee, K. Younsi, G. B. Kliman, *An On-line Technique for Monitoring the Insulation Condition of AC Machine Stator Windings*, IEEE International Electrical Machines and Drives Conference, (2005) 286–294. doi:10.1109/IEMDC.2005.195736.
- [26] K. Younsi, P. Neti, M. Shah, J. Y. Zhou, J. Krahn, K. Weeber, D. Whitefield, *Online Capacitance and Dissipation Factor Monitoring of AC Motor Stator Insulation*, IEEE International Power Modulation and High Voltage Conference (IPMHVC), (2010) 530–533. doi:10.1109/IPMHVC.2010.5958411.
- [27] Gerência de Manutenção Elétrica REDUC, *Levantamento de Dados de Manutenção de Motores na REDUC-Petrobras*, Acesso Restrito, Contrato: AE06SMPR14, 2015.
- [28] M. A. R. M. Fernando, W. M. L. B. Naranpanawa, R. M. H. M. Rathnayake, G. Jayantha, *Condition Assessment of Stator Insulation during Drying, Wetting and Electrical Ageing*, IEEE Transactions on Dielectrics and Electrical Insulation, 20, (2013) 2081–2090. doi:10.1109/TDEI.2013.6678856.
- [29] *IEC-60894: Guide for a Test Procedure for the Measurement of Loss Tangent of Coils and Bars for Machine Windings*, 1st Edition, IEC, 1987-03.
- [30] *IEEE Standard 286: IEEE Recommended Practice for Measurement of Power Factor Tip-Up of Electric Machinery Stator Coil Insulation*, 2nd Edition, IEEE, 2012.
- [31] *IEC-60034-27-3: Dielectric Dissipation Factor Measurement on Stator Winding Insulation of Rotating Electrical Machines*, 1st Edition, IEC, 2015-12.
- [32] O. D. Perez, M. P. Alonso, *Motores de Inducción: Técnicas de Mantenimiento Predictivo*, 1st Edition, @becedario, 2005.
- [33] *IEEE Standard 56: Guide for Insulation Maintenance of Large Alternating-Current Rotating Machinery (10 000 kVA and Larger)*, 1st Edition, IEEE, 1997.
- [34] *IEEE Standard 95: Recommended Practice for Insulation Testing of AC Electric Machinery (2300 V and Above) with High Direct Voltage*, 1st Edition, IEEE, 2002.
- [35] *IEEE Standard 522: Guide for Testing Turn Insulation of Form-Wound Stator Coils for Alternating Current Electric Machines*, 1st Edition, IEEE, 2004.
- [36] H. Torkaman, F. Karimi, *Measurement Variations of Insulation Resistance/Polarization Index During Utilizing Time in HV Electrical Machines – A Survey*, Elsevier Measurement, 59, (2015) 21–29. doi:10.1016/j.measurement.2014.09.034.

- [37] *IEEE Standard 1799: Recommended Practice for Quality Control Testing of External Discharges on Stator Coils, Bars, and Windings*, 1st Edition, IEEE, 2012-11.
- [38] G. C. Stone, V. Warren, *Objective Methods to Interpret Partial-Discharge Data on Rotating-Machine Stator Windings*, IEEE Transactions Industry Applications, 42, (2006) 195–200. doi:10.1109/TIA.2005.861273.
- [39] *NEMA MG-1: Motors and Generators*, 1st Edition, NEMA, 2014.
- [40] *IEEE Standard 433: Recommended Practice for Insulation Testing of AC Electric Machinery with High Voltage at Very Low Frequency*, 2nd Edition, IEEE, 2009-12.
- [41] G. C. Stone, *Recent Important Changes in IEEE Motor and Generator Winding Insulation Diagnostic Testing Standards*, IEEE Transactions on Industry Applications, (2005) 91–100. doi:10.1109/TIA.2004.840977.
- [42] G. C. Stone, *Advancements during the Past Quarter Century in On-line Monitoring of Motor and Generator Winding Insulation*, IEEE Transactions on Dielectrics and Electrical Insulation, 9, (2002) 746–751. doi:10.1109/TDEI.2002.1038661.
- [43] G. C. Stone, M. K. W. Stranges, D. G. . Dunn, *Common Questions on Partial Discharge Testing: A review of recent developments in IEEE and IEC standards for off-line and on-line testing of motor and generator stator windings*, IEEE Industry Applications Magazine, 22, (2015) 14–19. doi:10.1109/MIAS.2015.2458337.
- [44] Y. C. Leung, J. M. K. M. Alpine, *Initial Experience With the Partial Discharge Monitoring of High-Voltage Motors*, Elsevier Electric Power Systems Research, 61, (2002) 31–40. doi:10.1016/S0378-7796(01)00184-5.
- [45] C. D. Whitefield, *New Online Motor Stator Insulation Monitor (MSIM) for 3500 System.*, Acessado em: 06/06/2016.  
URL [https://www.gemeasurement.com/sites/gemc.dev/files/orbit\\_english.pdf](https://www.gemeasurement.com/sites/gemc.dev/files/orbit_english.pdf)
- [46] R. Bugarelli, *Proteção Térmica de Motores de Indução Trifásicos Industriais*, Dissertação, Universidade de São Paulo-USP, Agosto, 2006.
- [47] *ANSI IEEE Standard C37.2: Electrical Power System Device Function Numbers, Acronyms, and Contact Designations*, 2nd Edition, IEEE, 2008.
- [48] O. J. Pereira, L. A. Pacheco, S. S. Barreto, A. Emanuel, C. H. O. Fontes, C. A. M. T. Cavalcante, *Pattern Recognition Using Multivariate Time Series for Fault Detection in a Thermoelectric Unit.*, IEEE Proceedings of the 11th International Symposium on Process Systems Engineering, 31, (2012) 315–319.

- [49] M. M. Ismail, M. A. M. Hassan, *Artificial Neural Network Based Approach Compared with Stochastic Modelling for Electrical Load Forecasting*, IEEE Proceedings of International Conference on Modelling, Identification and Control, 1, (2013) 112–118.
- [50] G. G. Rigatos, *Fault Diagnosis in Robotic and Industrial Systems*, 1st Edition, iConcept Press Ltd, 2012.
- [51] G. G. Rigatos, *Modelling and Control for Intelligent Industrial Systems: Adaptive Algorithms in Robotics and Industrial Engineering*, 1st Edition, Springer, 2011.
- [52] Y. Asiri, A. Vouk, L. Renforth, D. Clark, J. Cooper, *Neural Network Based Classification of Partial Discharge in HV Motors*, IEEE Electrical Insulation Conference, (2011) 333–339. doi:10.1109/EIC.2011.5996173.
- [53] N. A. Nordin, H. Singh, *Detection and Classification of Induction Motor Faults Using Motor Current Signature Analysis and Multilayer Perceptron*, IEEE International Power Engineering Optimization and Conference (PEOCO), (2014) 35–40. doi:10.1109/PEOCO.2014.6814395.
- [54] A. Siddique, G. S. Yadava, B. Singh, *Identification of Three Phase Induction Motor Incipient Faults using Neural Network*, IEEE International Symposium on Electrical Insulation, (2004) 30–33. doi:10.1109/ELINSL.2004.1380432.
- [55] R. Palácios, I. N. Silva, A. Goedel, W. F. Godoy, *A Comprehensive Evaluation of Intelligent Classifiers for Fault Identification in Three-Phase Induction Motors*, Elsevier Electric Power Systems Research, 127, (2015) 249–258. doi:10.1016/j.epsr.2015.06.008.
- [56] A. Ukil, S. Shen, A. Andenna, *Detection of Stator Short Circuit Faults in Three-Phase Induction Motors Using Motor Current Zero Crossing Instants*, Elsevier Electric Power Systems Research, 81, (2011) 1036–1044. doi:10.1016/j.epsr.2010.12.003.
- [57] M. Seera, C. P. Lim, *Online Motor Fault Detection and Diagnosis Using a Hybrid FMM-CART Model*, IEEE Transactions on Neural Networks and Learning Systems, 25, (2014) 806–812. doi:10.1109/TNNLS.2013.2280280.
- [58] K. I. Annapoorani, D. B. Umamaheswari, *Fault Prediction Based on Dissolved Gas Concentration from Insulating Oil in Power Transformer Using Neural Network*, IEEE International Conference on the Properties and Applications of Dielectric Materials, (2012) 1–4. doi:10.1109/ICPADM.2012.6318954.

- [59] E. Zhang, H. Zhang, B. Xue, *Application of Integrated Neural Network Based on Information Combination for Fault Diagnosis in Steam Turbine Generator*, IEEE International Conference on Condition Monitoring and Diagnosis, (2008) 1293–1297. [doi:10.1109/CMD.2008.4580213](https://doi.org/10.1109/CMD.2008.4580213).
- [60] P. Peilin, D. Guangbin, *Vibration Diagnosis Method Based on Wavelet Analysis and Neural Network for Turbine-generator*, IEEE Chinese Conference Control and Decision, (2009) 5234–5237. [doi:10.1109/CCDC.2009.5195038](https://doi.org/10.1109/CCDC.2009.5195038).
- [61] P. Wen, *Vibration Analysis and Prediction of Turbine Rotor Based Grey Artificial Neural Network*, IEEE International Conference on Measuring Technology and Mechatronics Automation, (2009) 346–349. [doi:10.1109/ICMTMA.2009.426](https://doi.org/10.1109/ICMTMA.2009.426).
- [62] D. M. Shprekher, G. I. Babokin, E. B. Kolesnikov, *System of Neural Network Control and Prediction Technical Conditions Electromechanical Systems*, IEEE International Conference on Industrial Engineering, Applications and Manufacturing, 1, (2016) 1–4. [doi:10.1109/ICIEAM.2016.7911494](https://doi.org/10.1109/ICIEAM.2016.7911494).
- [63] M. Pang, L. Shu, J. Lu, *Fault Detection for Circulating Water Pump Using Time Series Forecasting and Outlier Detection*, IEEE International Conference on Communications and Networking in China, 1, (2013) 511–516. [doi:10.1109/ChinaCom.2013.6694649](https://doi.org/10.1109/ChinaCom.2013.6694649).
- [64] S. A. Sheptunov, M. V. Larionov, N. V. Suhanova, *Simulation Reliability of the System Software on the Basis of Artificial Intelligence*, IEEE Conference on Quality Management, Transport and Information Security, Information Technologies, 1, (2016) 193–197. [doi:10.1109/ITMQIS.2016.7751956](https://doi.org/10.1109/ITMQIS.2016.7751956).
- [65] A. P. Braga, A. P. D. Leon, F. D. Carvalho, T. B. Ludemir, *Redes Neurais Artificiais: Teoria e Aplicações*, 2nd Edition, LTC, 2014.
- [66] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd Edition, McMillan, 1994.
- [67] M. Hammer, T. Kozlovsk, R. Szabo, J. Svoboda, *The Use of Neural Networks for the Life Prediction of Insulating Material of Electric Rotating Machines*, IEEE International Conference on Solid Dielectrics, (2004) 546–549. [doi:10.1109/ICSD.2004.1350489](https://doi.org/10.1109/ICSD.2004.1350489).
- [68] G. C. Stone, E. A. Boutler, I. Culbert, H. Dhirani, *Electrical Insulation for Rotating Machines: Design, Evaluation, Aging, Testing and Repair*, IEEE Press Series on Power Engineering, 2004.

- [69] G. W. U. Motores, *Guia de Especificação de Motores Elétricos WEG.*, Acessado em: 15/06/2016.  
URL <http://ecatalog.weg.net/files/wegnet/WEG-guia-de-especificacao-de-motores.pdf>
- [70] A. L. M. Rodrigues, *Estudo Comparativo de Sistemas de Isolação em Motores de MT*, Dissertação, Faculdade de Engenharia da Universidade do Porto - FEUP, Junho, 2010.
- [71] A. Helgeson, U. Gafvert, *Dielectric Response Measurements in Time and Frequency Domain on High Voltage Insulation with Different Response*, IEEE International Symposium on Electrical Insulating Materials, 1, (1998) 393–398. doi:10.1109/ISEIM.1998.741766.
- [72] M. Farahani, H. Borsi, E. Gockenbach, *Dielectric Response Studies on Insulating System of High Voltage Rotating Machines*, IEEE Transactions on Dielectrics and Electrical Insulation, vol.13/num.2, (2006) 383–393. doi:10.1109/TDEI.2006.1624283.
- [73] E. David, T. Godin, J. Bellemare, L. Lamarre, *Modeling of the Dielectric Response of a Stator Winding Insulation from a DC Ramp Test*, IEEE Transactions on Dielectrics and Electrical Insulation, vol.14/num.6, (2007) 1548–1558. doi:10.1109/TDEI.2007.4401239.
- [74] P. O'Donnell, *Report of Large Motor Reliability Survey of Industrial and Commercial Inatalations: Part 1,*, IEEE Transactions on Industry Applications, 21, (1985) 853–864. doi:10.1109/TIA.1985.349532.
- [75] P. O'Donnell, *Report of Large Motor Reliability Survey of Industrial and Commercial Inatalations: Part 2,*, IEEE Transactions on Industry Applications, 21, (1985) 865–872. doi:10.1109/TIA.1985.349533.
- [76] P. O'Donnell, *Report of Large Motor Reliability Survey of Industrial and Commercial Inatalations: Part 3,*, IEEE Transactions on Industry Applications, 23, (1987) 153–158. doi:10.1109/TIA.1987.4504880.
- [77] O. V. Thorsen, M. Dalva, *Failure Identification and Analysis for High-Voltage Induction Motors in the Petrochemical Industry,*, IEEE Transactions on Industry Applications, 35, (1999) 810–818. doi:10.1109/28.777188.
- [78] *IEC 60034-1: Rotating Electrical Machines - Part 1: Rating and Performance*, 13th Edition, IEC, 2017.
- [79] K. Tshiloz, A. C. Smith, S. Djurovic, T. Feehally, *Real Time Insulation Lifetime Monitoring for Motor Winding,*, XXII Intenational Conference on Electrical Machines, 1, (2016) 2335–2340. doi:10.1109/ICELMACH.2016.7732847.

- [80] A. S. Guedes, S. M. Silva, B. J. C. Filho, C. A. Conceição, *Evaluation of Electrical Insulation in Three-Phase Induction Motors and Classification of Failures Using Neural Networks*, Elsevier Electric Power Systems Research, 140, (2016) 263–273. doi:10.1016/j.epsr.2016.06.016.
- [81] M. A. R. M. Fernando, W. M. L. B. Naranpanawa, R. M. H. M. Rathnayake, G. Jayantha, *Condition Assessment of Stator Insulation during Drying, Wetting and Electrical Ageing*, IEEE Transactions on Dielectrics and Electrical Insulation, 20, (2013) 2081–2090. doi:10.1109/TDEI.2013.6678856.
- [82] L. Xuezhong, Z. Tianlong, B. Yonggang, D. Xiaoxia, *Experimental Research on Stator Insulation System of 5 MW Offshore Wind Turbine Generator under Simulated Marine Environments*, IEEE Annual Report Conference on Electrical Insulation and Dielectric Phenomena, 20, (2013) 52–55. doi:10.1109/CEIDP.2013.6748199.
- [83] J. Yang, J. Cho, S. B. Lee, J. Y. Yoo, H. D. Kim, *An Advanced Winding Insulation Quality Assesment Technique for Inverter-Fed Machines*, IEEE Transactions on Industry Applications, 44, (2008) 555–564. doi:10.1109/TIA.2008.916753.
- [84] E. Persson, *Transient Effects in Application of PWM Inverters to Induction Motors*, IEEE Transactions on Industry Applications, 28, (1992) 1095–1101. doi:10.1109/28.158834.
- [85] J. S. R. Jang, C. T. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, 1st Edition, Prentice Hall, 1997.
- [86] T. Hastie, R. Tibshirani, J. Friedman, *Elements of Statistical Learning: Data Mining, Inference and Prediction*, 2nd Edition, Springer, 2009.
- [87] G. James, D. Witten, T. Hastie, R. Tibshirani, *An Introduction to Statistical Learning*, 1st Edition, Springer, 2013.
- [88] B. Chen, P. C. Tai, R. Harrison, Y. Pan, *Novel Hybrid Hierarchical-K-means Clustering Method (H-K-means) for Microarray Analysis*, IEEE Computational Systems Bioinformatics Conference, 1, (2005) 105–108. doi:10.1109/CSBW.2005.98.
- [89] C. Yiakopoulos, K. C. Gryllias, I. A. Antoniadis, *Rolling Element Bearing Fault Detection in Industrial Environments Based on a K-means Clustering Approach*, Elsevier Expert Systems with Applications, 38, (2011) 2888–2911. doi:10.1016/j.eswa.2010.08.083.
- [90] M. Riedmiller, H. Braun, *A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm*, IEEE International Conference on Neural Networks, 1, (1993) 586–591. doi:10.1109/ICNN.1993.298623.

- [91] Y. Suzuki, K. Yamasawa, *An Analysis of a Clamp-on Current Sensor with Zero-Flux Method*, IEEE Translation Journal on Magnetics in Japan, 1, (1993) 67–71.
- [92] Y. Suzuki, K. Yamasawa, A. Hirabayashi, *Analysis of a Zero-Flux Type Current Sensor*, IEEE Transactions on Magnetics, 1, (1993) 3183–3185.
- [93] M. J. García, A. Turó, *Improved Zero-Flux Type Large Bandwidth Current Sensor*, IEEE Instrumentation and Measurement Technology Conference, 1, (1996) 1475–1478.
- [94] H. W. Ott, *Electromagnetic Compatibility Engineering*, 1st Edition, John Wiley & Sons, 2009.
- [95] C. R. Paul, *Introduction to Electromagnetic Compatibility*, 2nd Edition, John Wiley & Sons, 2006.
- [96] T. Instruments, *Data Sheet ADC ADS1256.*, Acessado em: 15/12/2016.  
URL <http://www.ti.com/lit/ds/symlink/ads1255.pdf>
- [97] ATMEL, *Data Sheet uC SAM 3X8E ARM Cortex M3*, Acessado em: 15/12/2016.  
URL <http://www.atmel.com/Images/Atmel-11057-32-bit-Cortex-M3-Microcontroller-Datasheet.pdf>
- [98] R. V. Ferreira, *Detecção Seletiva de Harmônicos Baseado na Série de Fourier para Aplicação em Sistema de Filtragem Ativa*, Dissertação, Centro Federal de Educação Tecnológica de Minas Gerais - CEFET-MG, Abril, 2012.
- [99] R. V. Ferreira, S. M. Silva, B. J. C. Filho, C. H. G. Santos, *Fourier-Based PLL Applied for Selective Harmonic Estimation in Electric Power Systems*, Journal of Power Electronics, 13, (2013) 884–890.
- [100] *Electrical Insulating Materials - Thermal Endurance Properties - Part 1: Ageing Procedures and Evaluation of Test Results*, 6th Edition, IEC, 2013.
- [101] B. D. S.A., *Ficha de Informações de Segurança de Produtos Químicos*, Acessado em: 05/06/2017.  
URL <http://www.br.com.br/wcm/connect/5000232d-04a1-4e31-b6fb-27beabe1b09b/fispq-lub-ind-hidraulicos-hydra-xp-rev01.pdf.pdf?MOD=AJPERES&CVID=1n6bx56>
- [102] C. L. Castro, *Sistema Inteligente para Previsão On-Line do Índice IBOVESPA Baseado em Redes Neurais Artificiais*, Dissertação, Universidade Federal de Minas Gerais - UFMG, Janeiro, 2004.

- 
- [103] R. J. Campos, *Previsão de séries temporais com aplicações a séries de consumo de energia elétrica*, Dissertação, Universidade Federal de Minas Gerais - UFMG, Abril, 2008.
- [104] J. E. P. Box and J. M. Jenkins, *Times Series Analysis: Forecasting and Control*, Technical Report - Holden Day CA, 1976.
- [105] P. J. Brockwell and R. A. Davis, *Introduction to Times Series and Forecasting*, 1st Edition, Springer Verlag - New York, 1996.
- [106] F. E. Harrel Jr., *Regression Modeling Strategies: With Applications to Linear Models, Logistic Regression, and Survival Analysis*, 1st Edition, Springer Verlag - New York, 2001.
- [107] P. J. Brockwell and R. A. Davis, *Times Series: Theory and Methods*, 2nd Edition, Springer Verlag - New York, 1991.
- [108] G. E. P. Box and G. M. Jenkins and G. C. Reinsel, *Time Series Analysis: Forecasting and Control*, 3rd Edition, Prentice Hall, 1994.
- [109] W. Jacobs, R. R. Zanini, M. Costa, *Etudo Comparativo de Séries Temporais para a Previsão de Vendas de um Produto*, Revista Iberoamericana de Engenharia Industrial, 06, (2014) 112–133.
- [110] C. M. Hurvich, C. L. Tsai, *Regression and Times Series Model Selection in Small Samples*, Biometrika, 76, (1989) 297–307.
- [111] K. Ogata, *Engenharia de Controle Moderno*, 3rd Edition, Prentice – Hall do Brasil, 2000.



# A Apêndice

## A.1 Banco de Dados de Testes de Motores da REDUC

Tabela A.1 – Dados de testes e classificação do mecanismo de falha de motores da REDUC.

TAG	Data do teste	Tensão: BT=0, MT=1	$R_I (M\Omega)$	$C_I (pF)$	$IP$	$IA$	$tang\delta$ (%)	Operação: 0-Não, 1-Sim	Umidade	Óleo /Sujeira	Térmico
1210MP102B	22/11/11	1	1210	22300	4,71	1,64	0,20870	1	0	0	0
1210MP102B	21/12/12	1	357	33500	1,82	1,43	0,41220	1	0	1	0
1210MP102A	16/11/11	1	2234	24560	3,18	1,54	0,04834	1	0	0	0
1210MP102A	26/12/12	1	512	38250	1,98	1,14	0,13544	1	0	1	0
1210MP108B	7/10/11	0	1005,13	15670	3,78	1,65	0,16841	1	0	0	0
1210MP108B	27/12/12	0	5,13	216750	1,12	0,99	2,38552	0	1	0	0
1210MP108A	27/12/11	0	9426	15000	5,45	1,66	0,01876	1	0	0	0
1210MP108A	5/1/13	0	956	21000	1,95	1,31	0,13212	1	0	1	0
1210MP116C	8/3/11	1	12240	44500	4,63	1,62	0,00487	1	0	0	0
1210MP116C	8/2/12	1	10240	48900	4,16	1,59	0,00530	1	0	0	0
1210MVE101	3/11/11	1	2805	55500	4,69	1,59	0,01704	1	0	0	0
1210MVE101	5/11/12	1	2205	56500	4,09	1,49	0,02129	1	0	0	0
1210MVE104	18/11/11	1	1750	37750	4,29	1,53	0,04015	1	0	0	0
1210MVE104	21/11/12	1	1950	36650	4,39	1,83	0,03712	1	0	0	0
1210MP101D	16/11/11	1	16980	62500	3	1,55	0,00250	1	0	0	0
1210MP101D	21/10/12	1	6868	72500	2	1,34	0,00533	1	0	1	0
1210MP104B	10/10/11	1	12040	14750	4,1	1,68	0,01494	1	0	0	0
1210MP104B	12/11/12	1	1240	36750	1,35	1,17	0,05821	1	1	0	0
1210MP112A	10/11/11	1	37200	28000	5,64	1,65	0,00255	1	0	0	0
1210MP112A	13/11/12	1	32600	29000	5,21	1,63	0,00281	1	0	0	0
1210MP104A	13/12/11	1	2389	42000	4,18	1,6	0,02644	1	0	0	0
1210MP104A	19/12/12	1	1889	43500	3,98	1,58	0,03228	1	0	0	0
1210MP111A	4/10/11	1	24900	46750	4,88	1,77	0,00228	1	0	0	0
1210MP111A	14/11/12	1	4947	96750	1,31	1,17	0,00554	1	1	0	0
1210MP170B	16/11/11	1	4087	159000	3,65	1,56	0,00408	1	0	0	0
1210MP170B	16/11/12	1	483,7	559000	1,08	1,07	0,00981	1	1	0	0
1210MP148A	16/11/11	1	9880	17000	4,74	1,63	0,01579	1	0	0	0
1210MP148A	17/11/12	1	923	18000	4,44	1,59	0,15966	1	0	0	0
1220MC204	3/5/11	1	3140	76000	4,8	1,58	0,01112	1	0	0	0
1220MC204	5/6/12	1	3010	76500	4,43	1,53	0,01152	1	0	0	0
1220MP201A	21/6/12	1	7740	12150	3,35	1,58	0,02821	1	0	0	0
1220MP201A	10/7/13	1	1650	24250	1,35	1,12	0,06629	1	1	0	0
1220MP202A	3/5/11	1	18450	75750	7,16	1,89	0,00190	1	0	0	0
1220MP202A	5/6/12	1	15650	75750	7,08	2,01	0,00224	1	0	0	0
1230MP1346	30/7/12	0	3740	18750	3,89	1,62	0,03783	1	0	0	0
1230MP1346	29/8/13	0	87,57	163750	1,14	1,02	0,18498	1	1	0	0
1237MP13109A	10/9/12	0	6560	11500	3,33	1,54	0,03516	1	0	0	0
1237MP13109A	13/9/13	0	411,7	41500	1,12	1,04	0,15525	1	1	0	0
1250MP5011A	12/3/12	0	1005	48500	2,78	1,54	0,05442	1	0	0	0
1250MP5011A	10/4/13	0	0,01	830500	1,06	1	319,39	0	1	0	0
1250MP5008A	16/4/11	1	5992	130750	4,29	1,88	0,00339	1	0	0	0
1250MP5008A	26/4/12	1	6032	129750	4,31	1,9	0,00339	1	0	0	0
1250MP501A	16/11/11	0	11500	5000	7,5	1,58	0,04613	1	0	0	0
1250MP501A	17/11/12	0	1460	4900	7,9	1,88	0,37077	1	0	0	0
1251MVE5006A	16/4/11	0	34220	10750	6,52	1,73	0,00721	1	0	0	0
1251MVE5006A	26/4/12	0	3822	10300	6,12	1,63	0,06738	1	0	0	0
1320MB1251A	24/4/12	1	4560	50600	2,95	1,59	0,01150	1	0	0	0
1320MB1251A	5/4/13	1	1678	60000	1,95	1,29	0,02635	1	0	1	0
1320MB1251B	15/12/12	1	920	33750	5,1	1,88	0,08543	1	0	0	0
1320MB1251B	21/12/13	1	1,54	73750	1,71	1,32	23,355	0	0	1	0
1322MP1253B	8/11/11	1	1856	18250	2,97	1,71	0,07831	1	0	0	0
1322MP1253B	5/12/12	0	88,48	80250	1,17	1,08	0,37357	1	1	0	0
1322MP12015B	6/2/14	0	1089	16350	2,89	1,52	0,14897	1	0	0	0
1322MP12015B	8/2/15	0	64,46	36250	1,1	1,22	1,13517	1	1	0	0

TAG	Data do teste	Tensão: BT=0, MT=1	$R_I (M\Omega)$	$C_I (pF)$	$IP$	$IA$	$tang\delta$ (%)	Operação: 0-Não, 1-Sim	Umidade	Óleo /Sujeira	Degrad. térmica
1341MFL1401F	8/5/13	0	970	1000	2,75	1,56	2,735	1	0	0	0
1341MFL1401F	3/4/14	0	79,98	3000	1,2	0,66	11,055	1	1	0	0
1341MFL1401B	8/5/13	0	890	4300	3,22	1,73	0,69311	1	0	0	0
1341MFL1401B	3/4/14	0	0,73	23250	1,32	1,1	156,28	0	1	0	0
1341MFL1401D	8/5/13	0	740	5600	3,01	1,78	0,64009	1	0	0	0
1341MFL1401D	3/4/14	0	0,01	45500	0,9	0,79	582,97	0	1	0	0
1360MB1601B	27/3/12	0	12460	11500	2,91	1,76	0,01851	1	0	0	0
1360MB1601B	12/4/13	0	3388	15500	1,91	1,41	0,05051	1	0	1	0
1362MB136201B	12/3/12	1	5431	488940	2,94	1,62	0,00100	1	0	0	0
1362MB136201B	22/2/13	1	1169	592750	1,94	1,4	0,00383	1	0	1	0
1510MVE5102	10/9/12	0	770	11000	2,78	1,56	0,31317	1	0	0	0
1510MVE5102	10/8/13	0	17,09	70000	1,12	1,06	2,2173	1	1	0	0
1510MP5121A	12/4/12	0	29620	15000	4,77	1,53	0,00597	1	0	0	0
1510MP5121A	9/4/13	0	19620	21300	4,27	1,79	0,00635	1	0	0	0
1540MP5404	28/10/11	0	12167	1980	2,93	1,66	0,11011	1	0	0	0
1540MP5404	22/10/12	0	6578	2434	1,94	1,42	0,16567	1	0	1	0
1540MP5402A	8/5/13	0	9958	12250	2,87	1,75	0,02174	1	0	0	0
1540MP5402A	8/4/14	0	4780	15680	1,87	1,45	0,03539	1	0	1	0
1570MFL1401C	3/4/13	0	890	1200	3,56	1,79	2,4836	1	0	0	0
1570MFL1401C	9/4/14	0	2	15000	1,02	1	88,42	0	1	0	0
1710MP7121A	1/12/11	0	33820	11000	3,88	1,77	0,00713	1	0	0	0
1710MP7121A	3/12/12	0	27820	12400	3,58	1,57	0,00769	1	0	0	0
1710MP7143	3/12/11	0	2303	1750	3,06	1,54	0,65815	1	0	0	0
1710MP7104A	22/7/12	1	39170	15500	6,61	1,56	0,00437	1	0	0	0
1710MP7117A	22/7/12	1	14150	21000	6,81	1,69	0,00893	1	0	0	0
1710MP7117A	30/7/13	1	16150	20500	7,21	1,89	0,00801	1	0	0	0
1710MP7117B	22/7/12	1	2396	20000	5,24	1,55	0,05535	1	0	0	0
1710MP7128A	22/7/12	1	11420	18250	5,28	1,68	0,01273	1	0	0	0
1710MP7128A	30/7/13	1	9790	19250	4,88	1,62	0,01407	1	0	0	0
1710MP7134A	22/7/12	1	18060	23500	5,99	1,73	0,00625	1	0	0	0
1710MP7134A	30/7/13	1	17060	23900	5,39	1,63	0,00651	1	0	0	0
1710MP7134B	20/7/12	1	9732	23000	4,97	1,63	0,01185	1	0	0	0
1710MP7134C	20/7/12	1	14830	23500	4,91	1,65	0,00761	1	0	0	0
1710MP7144A	19/7/12	1	9892	31250	5,64	1,73	0,00858	1	0	0	0
1710MP7144B	8/6/12	1	1634	32500	2,58	1,71	0,04995	1	0	0	0
1710MP7144B	19/7/13	1	875	41567	1,78	1,41	0,07293	1	0	1	0
1710MVE7102	4/11/13	1	2719	5200	4,77	1,61	0,18761	1	0	0	0
1710MP7105	21/9/12	0	1640	12250	3,58	1,61	0,13203	1	0	0	0
1710MVE7101	4/11/13	0	6084	24250	5,27	1,57	0,01798	1	0	0	0
1710ME7143	4/9/13	0	14370	3750	5,2	1,78	0,04922	1	0	0	0
1710MP7143A	2/9/13	0	11840	2250	3,88	1,85	0,09957	1	0	0	0
1710MP7143A	4/10/14	0	5184	3230	1,88	1,35	0,15841	1	0	1	0
1720MP7205A	8/9/12	1	3693	111000	4,79	1,59	0,00647	1	0	0	0
1730MC7303	20/1/12	1	5640	43200	2,89	1,56	0,01089	1	0	0	0
1730MC7303	6/1/13	1	890	92100	1,34	1,27	0,03236	1	1	0	0
1790MP7906A	3/12/12	1	5921	59500	4,02	1,52	0,00753	1	0	0	0
2200MB2002	19/6/12	1	4884	133750	6,12	1,73	0,00406	1	0	0	0
2200MB2002	10/8/12	1	980	98700	2,72	1,53	0,02742	1	0	0	0
2200MB2002	10/10/13	1	17,28	140500	1,84	1,33	1,09254	0	0	1	0
2200MB2001	11/8/12	1	3624	136000	4,74	1,7	0,00538	1	0	0	0
2200TG2001	12/8/12	1	3900	116900	2,86	1,55	0,00582	1	0	0	0
2200TG2001	22/8/13	1	323,3	363750	1,14	1,1	0,02256	1	1	0	0
2200TG2002	8/10/12	1	2890	156590	2,91	1,61	0,00586	1	0	0	0
2200TG2002	18/10/13	1	268,4	451750	1,21	1,14	0,02188	1	1	0	0
2200VAE2002	10/10/12	0	4300	12900	3,31	1,61	0,04782	1	0	0	0
2200VAE2002	30/10/13	0	727,3	3750	1,25	1	0,97255	1	1	0	0
2600MC26003C	8/5/12	1	12615	120000	3,56	1,62	0,00175	1	0	0	0
2600MC26003C	8/6/13	1	2615	243000	1,36	0,97	0,00417	1	1	0	0
2600MC26003B	8/5/12	1	15450	110000	3,89	1,67	0,00156	1	0	0	0
2600MC26003B	8/6/13	1	1032	237000	1,31	1,28	0,01085	1	1	0	0
2600MC26003A	1/7/12	1	4581	149300	3,11	1,74	0,00388	1	0	0	0
2600MC26003A	8/6/13	1	1067	170500	2,04	1,31	0,01458	1	0	1	0
2600MC26002C	1/7/12	1	3106	243500	2,76	1,73	0,00351	1	0	0	0
2600MC26002C	11/6/13	1	1021	333500	1,92	1,3	0,00779	1	0	1	0

TAG	Data do teste	Tensão: BT=0, MT=1	$R_I (M\Omega)$	$C_I (pF)$	$IP$	$IA$	$tang\delta$ (%)	Operação: 0-Não, 1-Sim	Umidade	Óleo /Sujeira	Degrad. térmica
2600MC26002A	10/5/12	1	8095	135000	3,23	1,54	0,00243	1	0	0	0
2600MC26002A	11/6/13	1	272,6	657750	1,32	1,05	0,01479	1	1	0	0
2700MB27004	12/9/12	0	13450	2390	3,45	1,67	0,08252	1	0	0	0
2700MB27004	9/10/13	0	2631	7500	1,31	1,07	0,13442	1	1	0	0
2700MB27005B	25/10/12	1	2184	53500	6,75	1,85	0,02270	1	0	0	0
2800MB28007B	12/9/13	1	14560	34500	3,13	1,52	0,00528	1	0	0	0
2800MB28007B	15/8/12	1	1510	69750	1,25	1,11	0,02518	1	1	0	0
2800MC28002A	10/11/12	1	1510	194000	2,73	1,52	0,00905	1	0	0	0
2800MC28002A	17/12/13	1	678	264000	1,66	1,32	0,01482	1	0	1	0
3300MB33002	27/1/12	0	14260	1500	3,67	1,63	0,12401	1	0	0	0
3300MB33002	27/1/13	0	3170	5500	1,3	1,2	0,15214	1	1	0	0
3900MVE390012	14/6/12	0	32098	60250	5,72	1,78	0,00137	1	0	0	0
3900MVE390012	17/8/13	0	5960	65250	6,72	4,78	0,00682	1	0	0	1
4100MC41002B	22/12/12	1	4567	12300	3,12	1,54	0,04722	1	0	0	0
4100MC41002B	22/12/13	1	762,3	421000	1,21	1,14	0,00827	1	1	0	0
1045MP011	8/4/12	0	12345	9250	4,05	1,92	0,02323	1	0	0	0
1045MP011	21/4/13	0	5735	12250	2,1	1,51	0,03776	1	0	1	0
1045MP012	14/12/12	0	940	1250	2,96	1,59	2,2575	1	0	0	0
1045MP012	4/12/13	0	0,13	15250	1,28	1,13	133,80	0	1	0	0
1045MP013	14/12/12	0	982	1310	3,01	1,54	2,062	1	0	0	0
1045MP013	4/12/13	0	4,47	10750	1,28	1,12	55,20	0	1	0	0
1045MP014	14/12/12	0	1090	9750	3,12	1,48	0,24959	1	0	0	0
1045MP014	4/12/13	0	22,18	69450	1,17	1,02	1,72197	1	1	0	0
1750MX7508	4/5/12	0	2007	12300	3,34	1,62	0,10745	1	0	0	0
1750MX7508	24/5/13	0	23,79	582500	1,18	1,09	0,19141	0	1	0	0
1550MP5501	2/7/12	0	11670	15689	3,36	1,72	0,01449	1	0	0	0
1550MP5501	2/8/13	0	2137	22500	2,16	1,39	0,05517	1	0	1	0
1236MP1328	3/8/14	0	1286	7100	3,7	1,54	0,78610	1	0	0	0
1236MP1328	2/10/15	0	151	15800	1,37	1,23	6,053	1	1	0	0
1520MP5201	17/12/12	0	15090	5030	3,78	1,89	0,03495	1	0	0	0
1520MP5201	21/12/13	0	7507	7000	2,18	1,59	0,05048	1	0	1	0
0111TR04M1	14/10/14	1	5504	434750	4,8	1,68	0,00111	1	0	0	0
1120AGM1	12/6/12	0	2259	40250	4,88	1,81	0,05860	1	0	0	0
1120AGM1	16/12/13	0	210,8	37825	9,66	5,87	0,54500	1	0	0	1
1120AGM2	12/8/15	0	12640	416500	5,21	1,77	0,00050	1	0	0	0
1120AGM2	16/10/15	0	2286	376500	7,21	6,1	0,00308	1	0	0	1
1120AGM3	12/8/14	0	18500	517250	6,78	1,89	0,00028	1	0	0	0
1120AGM3	16/10/15	0	1650	467250	9,34	8,76	0,00344	1	0	0	1
1120AGM4	12/8/14	0	21075	478150	7,89	2,1	0,00026	1	0	0	0
1120AGM4	16/10/15	0	8075	457250	11,96	7,52	0,00072	1	0	0	1
130BP01	9/9/13	1	5397	24500	3,53	1,81	0,02006	1	0	0	0
130BP01	17/10/14	1	797	319500	1,93	1,51	0,01042	1	0	1	0
130BP02	9/9/13	1	4089	296700	2,92	1,72	0,00219	1	0	0	0
130BP02	17/10/14	1	889	485500	1,89	1,36	0,00615	1	0	1	0
130BP08	9/9/13	1	3882	456000	3,32	1,84	0,00150	1	0	0	0
130BP08	17/10/14	1	1882	617000	2,21	1,55	0,00228	1	0	1	0
130BP06	9/9/13	1	4221	435699	3,55	1,81	0,00144	1	0	0	0
130BP06	17/10/14	1	1045	574750	2,04	1,51	0,00442	1	0	1	0
130BP05	9/9/13	1	5328	345500	3,3	1,85	0,00144	1	0	0	0
130BP05	17/10/14	1	1094	446780	1,93	1,45	0,00543	1	0	1	0
130BP04	9/9/13	1	4295	423560	3,33	1,88	0,00146	1	0	0	0
130BP04	17/10/14	1	1345	526750	1,98	1,58	0,00374	1	0	1	0
130BP03	9/9/13	1	6028	214560	3,56	1,85	0,00205	1	0	0	0
130BP03	17/10/14	1	1090	339250	2,06	1,55	0,00717	1	0	1	0
121TR01	10/9/13	1	11789	291000	4,43	2,11	0,00077	1	0	0	0
121TR01	15/10/14	1	2060	342000	2,39	1,42	0,00377	1	0	1	0
311TR01M1	15/9/13	0	7588	112450	3,67	2,01	0,00311	1	0	0	0
311TR01M1	21/10/14	0	2258	165000	1,88	1,41	0,00712	1	0	1	0
311TR01M2	15/9/13	0	2092	98450	3,22	1,84	0,01288	1	0	0	0
311TR01M2	21/10/14	0	890	159500	1,75	1,35	0,01869	1	0	1	0
411BP01	16/9/13	1	1694	2135670	3,69	1,95	0,00073	1	0	0	0
411BP01	22/10/14	1	765	275750	1,79	1,25	0,01257	1	0	1	0
411MP02	12/10/14	1	8950	112600	3,12	1,65	0,00263	1	0	0	0
411MP02	22/10/15	1	1001	278500	1,37	1,14	0,00951	1	1	0	0

TAG	Data do teste	Tensão: BT=0, MT=1	$R_I (M\Omega)$	$C_I (pF)$	$IP$	$IA$	$tang\delta$ (%)	Operação: 0-Não, 1-Sim	Umidade	Óleo /Sujeira	Degrad. térmica
413VT01R	16/9/13	1	9595	1214690	4,23	2,23	0,00023	1	0	0	0
413VT01R	22/10/14	1	2098	157500	1,78	1,36	0,00803	1	0	1	0
413MC02	12/10/14	1	1458	45680	2,67	1,56	0,03983	1	0	0	0
413MC02	22/10/15	1	41,3	161000	1,27	1,03	0,39892	0	1	0	0
713BA01R	16/9/13	1	9085	632560	3,41	1,88	0,00046	1	0	0	0
713BA01R	22/10/14	1	2293	886500	1,9	1,36	0,00130	1	0	1	0
713BA02	16/9/13	1	2830	530670	3,81	2	0,00177	1	0	0	0
713BA02	22/10/14	1	630	770250	1,74	1,34	0,00547	1	0	1	0
713BA04	16/9/13	1	12376	75850	4,26	1,93	0,00283	1	0	0	0
713BA04	22/10/14	1	1347	105750	2,26	1,53	0,01862	1	0	1	0
2111MEBP01R	12/7/13	1	6913	76780	3,42	1,87	0,00500	1	0	0	0
2111MEBP01R	17/7/14	1	1010	100500	1,74	1,37	0,02613	1	0	1	0
2112MEBA02	12/7/13	0	6210	36983	3,38	1,84	0,01155	1	0	0	0
2112MEBA02	17/7/14	0	876	52500	1,61	1,38	0,05768	1	0	1	0
2112MEBA02R	12/7/13	0	11170	32500	4,06	1,79	0,00731	1	0	0	0
2112MEBA02R	17/7/14	0	1090	52500	1,79	1,46	0,04635	1	0	1	0
2211MEBA07M	12/7/13	0	12350	4200	4,42	1,93	0,05114	1	0	0	0
2211MEBA07M	17/7/14	0	1713	6000	2,31	1,41	0,25808	1	0	1	0
2211MEBP07M	14/7/13	0	10980	4980	3,67	1,82	0,04851	1	0	0	0
2211MEBP07M	22/7/14	0	1789	10500	1,7	1,42	0,14121	1	0	1	0
2211MEBP01M	6/5/14	0	17890	10120	4,96	1,76	0,01465	1	0	0	0
2211MEBP01M	15/7/15	0	1177	9250	8,96	7,64	0,24364	1	0	0	1
2211MEBP04M	14/7/13	0	10840	7500	2,99	1,76	0,03263	1	0	0	0
2211MEBP04M	22/7/14	0	940	22300	1,23	1,12	0,12654	1	1	0	0
4100MTN41002B	22/7/14	0	30080	27350	5,73	1,86	0,00322	1	0	0	0
4100MTN41002B	4/12/12	0	3050	26950	9,73	7,46	0,03227	1	0	0	1
4100MTN41002A	14/11/11	0	37360	26750	7,18	2,01	0,00265	1	0	0	0
4100MTN41002A	4/12/12	0	3,6	25620	10,8	8,4	28,76	0	0	0	1
4300MB43002B	11/10/12	0	36940	20750	6,09	1,94	0,00346	1	0	0	0
4300MC43002B	22/12/13	1	4160	20030	7,25	6,77	0,03183	1	0	0	1
4300MC43001B	11/10/13	1	21746	82450	5,68	1,71	0,00148	1	0	0	0
4300MC43001B	22/12/12	1	1746	79250	8,89	7,67	0,01917	1	0	0	1
2211MEBP04M	21/7/14	0	8520	8500	3,99	1,86	0,03663	1	0	0	0
2211MEBP04M	22/7/14	0	920	11500	1,79	1,36	0,25071	1	0	1	0



## B Apêndice

### B.1 Modelo do Sensor HSCT

O HSCT mostrado na Figura 5.1 do Capítulo 5 pode ser modelado segundo as equações a seguir. Como o fluxo magnético em ambos os núcleos é praticamente constante ( $\phi_e(t) = \text{constante}$ ) para qualquer corrente  $I_p(t)$  medida, a permeabilidade  $\mu$  e a relutância  $\mathcal{R}$  do núcleo também serão constantes.

$$\mathcal{R} = \frac{l_m}{\mu A_s} \quad (\text{B.1})$$

Onde:

- $\mathcal{R}$ : relutância magnética do núcleo em  $(Ae/Wb)$ ;
- $l_m$ : comprimento médio do núcleo em  $(m)$ ;
- $\mu$ : permeabilidade magnética do núcleo em  $(Wb/A.m)$ ;
- $A_s$ : seção transversal do núcleo em  $(m^2)$ .

Considerando o diagrama de blocos da Figura 5.2, os fluxos magnéticos  $\phi_p(s)$  e  $\phi_s(s)$  gerados pelas respectivas correntes  $I_p(s)$  e  $I_s(s)$  podem ser determinados por:

$$\phi_p(s) = \frac{N_p I_p(s)}{\mathcal{R}} \quad (\text{B.2})$$

$$\phi_s(s) = \frac{N_2 I_s(s)}{\mathcal{R}} \quad (\text{B.3})$$

Onde:

- $I_p$ : corrente primária a ser medida em  $(A)$ ;
- $I_s$ : corrente nos enrolamentos  $N_2$  em  $(A)$ ;
- $N_p$ : número de espiras do enrolamento primário;
- $N_2$ : número de espiras do enrolamento de *feedback*.

As forças eletromotrizes  $\varepsilon_{11}(s)$ ,  $\varepsilon_{12}(s)$ ,  $\varepsilon_{21}(s)$  e  $\varepsilon_{22}(s)$ , induzidas nos enrolamentos de detecção  $N_1$  e de *feedback*  $N_2$  dos núcleos 1 e 2 serão:

$$\varepsilon_{11}(s) = sN_1\phi_{r1} = sN_1[\phi_p(s) - \phi_s(s) + \phi_e(s)] \quad (\text{B.4})$$

$$\varepsilon_{21}(s) = sN_2\phi_{r1} = sN_2[\phi_p(s) - \phi_s(s) + \phi_e(s)] \quad (\text{B.5})$$

$$\varepsilon_{12}(s) = sN_1\phi_{r2} = sN_1[\phi_e(s) + \phi_s(s) - \phi_p(s)] \quad (\text{B.6})$$

$$\varepsilon_{22}(s) = sN_2\phi_{r2} = sN_2[\phi_e(s) + \phi_s(s) - \phi_p(s)] \quad (\text{B.7})$$

Os fluxos de excitação  $\phi_{e1}(s)$  e  $\phi_{e2}(s)$  nos respectivos núcleos 1 e 2 gerados pela tensão de excitação  $U_e(s)$  são dados por:

$$\phi_{e1}(s) = \frac{N_1 I_{11}(s)}{\mathcal{R}} \quad (\text{B.8})$$

$$I_{11}(s) = \frac{U_e(s) - \varepsilon_{11}(s)}{sL_1 + (R_1 + R_e)} \quad (\text{B.9})$$

$$\phi_{e2}(s) = \frac{N_1 I_{12}(s)}{\mathcal{R}} \quad (\text{B.10})$$

$$I_{12}(s) = \frac{U_e(s) - \varepsilon_{12}(s)}{sL_1 + (R_1 + R_e)} \quad (\text{B.11})$$

Onde:

- $R_1$ : resistência do enrolamento  $N_1$  ( $\Omega$ );
- $L_1$ : indutância do enrolamento  $N_1$  ( $H$ );
- $R_e$ : resistência limitadora da corrente de excitação ( $\Omega$ ).

Analisando o circuito da Figura 5.1, quando ocorre circulação da corrente  $I_p(t)$ , uma diferença de potencial  $U_i(t)$  surgirá nas entradas do primeiro amplificador operacional gerada pelo desbalanceamento no fluxo  $\phi_e(t)$  ocasionado pelo fluxo  $\phi_p(t)$  em ambos os núcleos. A ação proporcional e integral do segundo amplificador irá gerar uma tensão de compensação  $U_c(t)$  que aumentará a corrente de *feedback*  $I_s(t)$  tenderá a manter o fluxo  $\phi_e(t)$  anterior ao distúrbio gerado pela corrente  $I_p(t)$ . Assim, no domínio da frequência, a corrente  $I_s(s)$  e a tensão  $U_s(s)$  de saída serão determinadas por:

$$I_s(s) = \frac{\varepsilon_{21}(s) - \varepsilon_{22}(s) + U_c(s)}{2sL_2 + (2R_2 + R_s)} \quad (\text{B.12})$$

$$U_s(s) = GI_s(s)R_s \quad (\text{B.13})$$

Onde:

- $R_2$ : resistência do enrolamento  $N_2$  ( $\Omega$ );
- $L_2$ : indutância do enrolamento  $N_2$  ( $H$ );
- $R_s$ : resistência limitadora da corrente de saída ( $\Omega$ );
- $G$ : ganho de tensão;
- $\varepsilon_{21}$ : tensão  $\varepsilon_2$  induzida no núcleo 1;
- $\varepsilon_{22}$ : tensão  $\varepsilon_2$  induzida no núcleo 2.

A tensão de compensação  $U_c(s)$  gerada pelo controlador PI foi sintonizado de acordo com o critério de Ziegler-Nichols (Método da Sensibilidade Limite) [111]. O método é baseado na determinação do ganho crítico ( $K_u$ ) e do período crítico ( $T_u$ ). O ganho crítico é o máximo valor de ganho para um controlador com ação proporcional que torna a resposta criticamente estável (oscilações de amplitude constante). O período obtido para este valor de ganho é o período crítico. A tensão  $U_c(s)$  e os respectivos ganho proporcional  $K_p$  e tempo de integração  $T_i$  serão dados por:

$$U_c(s) = K_p U_i(s) + \frac{K_p}{sT_i} U_i(s) \quad (\text{B.14})$$

$$K_p = 0,4K_u \quad (\text{B.15})$$

$$T_i = 0,8T_u \quad (\text{B.16})$$

Abaixo segue os parâmetros utilizados na simulação:

- $r = 0,01m$  (raio da seção do núcleo);
- $R = 0,06m$  (raio do toroide);
- $l_m = 2\pi R$ ; (comprimento médio do núcleo);
- $A_s = \pi r^2$  (seção do núcleo);
- $\mu_0 = 4\pi 10^{-7}$  (permeabilidade do vácuo);
- $\mu_r = 100000$  (permeabilidade relativa da liga *alloy*);
- $\mu = \mu_0 \mu_r$  (permeabilidade do núcleo);
- $N_p = 1$  (número espiras do enrolamento primário);
- $N_1 = 1000$  (número de espiras do enrolamento de detecção);

- $N_2 = 100$  (número de espiras do enrolamento de *feedback*);
- $L_1 = \frac{\mu N_1^2 r^2}{2R}$  (indutância do enrolamento de detecção);
- $L_2 = \frac{\mu N_2^2 r^2}{2R}$  (indutância do enrolamento de detecção);
- $f = 60Hz$  (frequência);
- $R_s = 1000\Omega$  (resistência de saída);
- $R_e = 20000\Omega$  (resistência de limitação da corrente de excitação);
- $U_e = 10V$  (tensão eficaz do circuito de excitação);
- $U_e(t) = \sqrt{2}U_e \sin(2\pi ft)$
- $R_1$  e  $R_2$  serão desprezadas;
- $I_{p-max} = 2mA$  (corrente primária eficaz máxima medida pelo sensor);
- $U_{s-max} = 10V$  (tensão de saída eficaz máxima);
- $G = \frac{N_2 U_{s-max}}{N_1 I_{p-max}}$  (ganho do amplificador).